



آینده پژوهی در خصوص سیستم‌های ارتباطی هوشمند و کاربردهای آنها در صنعت برق



مدیر پروژه: مهدی مظفری پور

مجری: شیدا سیدفرشی



آینده پژوهی در خصوص سیستم‌های ارتباطی هوشمند و کاربردهای آنها در صنعت برق

مدیر پروژه: مهدی مظفری پور

همکاران پروژه: محسن ظهیر، فروغ صدیقی

مجری: شیدا سیدفرشی

انتشارات پژوهشگاه نیرو

۱۴۰۰

ایران. وزارت نیرو. پژوهشگاه نیرو. گروه پژوهشی فناوری اطلاعات و ارتباطات
پروژه آینده پژوهی در خصوص سیستم‌های ارتباطی هوشمند و کاربردهای آنها در صنعت برق / مدیر پروژه: مهدی
مظفری‌پور. کارفرما: پژوهشگاه نیرو، ۱۴۰۰
۳۶۵ ص: مصور، نمودار، جدول
۱. ظهیر، محسن، همکار پروژه. ۲. صدیقی، فروغ، همکار پروژه. ۳. سیدفرشی، شیدا، مجری. ۴.
محور اصلی پروژه: تجهیزات و ارتباطات رادیویی.



انتشارات پژوهشگاه نیرو
گروه پژوهشی فناوری اطلاعات و ارتباطات

کلیه حقوق قانونی این اثر متعلق به پژوهشگاه نیرو است.

نشانی: تهران، شهرک غرب، انتهای بلوار شهید دادمان، پژوهشگاه نیرو، کدپستی: ۱۴۶۸۶۱۳۱۱۳

تلفن: ۸۸۰۷۹۴۰۱-۹

نمابر: ۸۸۰۷۸۲۹۶

وبگاه: www.nri.ac.ir

پست الکترونیک انتشارات: publications@nri.ac.ir

فرم تعهدنامه اصالت اثر

اینجانب مهدی مظفری پور متعهد می‌شوم که مطالب مندرج در این گزارش حاصل کار پژوهشی اینجانب و همکاران به شرح زیر است و به دستاوردهای پژوهشی دیگران که در این پژوهش از آن استفاده شده است، مطابق مقررات ارجاع و در فهرست منابع و مآخذ ذکر گردیده است.

کلیه حقوق مادی و معنوی این اثر متعلق به پژوهشگاه نیرو است.

همکاران :

۱. محسن ظهیر

۲. فروغ صدیقی

پیشگفتار

استفاده از هوش مصنوعی^۱ (AI) در کثیری از کاربردهای روزمره، صنعتی، نظامی و ... مورد توجه روزافزون قرار گرفته است. سیستم‌های ارتباطی نیز از این امر مبری نبوده و این روش‌ها در بخش‌های مختلف آنها مورد استفاده قرار می‌گیرند: از دسترسی به طیف‌های فرکانسی، طراحی آنتن‌ها، عملکردهای موجود در لایه فیزیکی، دسترسی به کانال، مدیریت شبکه، برقراری امنیت سیستم و ... همگی مورد توجه پژوهشگران بوده‌اند. این توجه به روش‌های هوش مصنوعی نه بر اساس یک توجه گذرا بلکه به علت پیچیدگی روزافزون بخش‌های مختلف سامانه‌ها و ناکارآمدی و چالش‌های بکارگیری روش‌های قدیمی جهت فائق آمدن بر این پیچیدگی‌ها و مشکلات منتج از آن هستند. از سوی دیگر، سیستم‌های ارتباطی جزء لاینفک شبکه‌های هوشمند برق هستند و از همین رو هرگونه ارتقاء عملکرد این سیستم‌های ارتباطی باعث بهبود عملکرد این شبکه‌های برق‌رسانی خواهند شد. در این پروژه به استفاده از روش‌های هوش مصنوعی در بخش‌های مختلف سیستم‌های ارتباطی، همانطور که در بالا اشاره شد، به صورت مجزا پرداخته خواهد شد و در تمامی مراحل آن، یک نگاه عملگرایانه و قابلیت بکارگیری آنها در بخش‌های مختلف صنعت برق سایه افکنده است. این پروژه در پنج مرحله به شرح زیر انجام شده است:

مرحله اول مطالعات مقدماتی و تطبیقی می‌پردازد. مرحله دوم اختصاص به انجام مطالعات و بررسی‌های مرتبط با به کارگیری روش‌های هوش مصنوعی برای آنتن‌ها دارد. در مرحله سوم به مطالعات و بررسی‌های مرتبط با کاربردهای روش‌های هوش مصنوعی در طراحی لایه‌های کنترل دسترسی به محیط (MAC^۲) پرداخته می‌شود. مرحله چهارم در خصوص هوشمندسازی مدیریت شبکه ارتباطی می‌باشد و سه موضوع مورد مطالعه قرار گرفته‌اند: (۱) بررسی روش‌های به کارگیری AI جهت تخصیص منابع در شبکه‌های ارتباطی. (۲) بررسی روش‌های به کارگیری AI جهت ارتقاء امنیت در شبکه‌های ارتباطی. (۳) بررسی برنامه‌های کاربردی هوشمند در سطح شبکه. در مرحله پنجم نیز با توجه به مطالعات صورت گرفته در این پروژه علاوه بر جمع‌بندی نهایی، فهرستی از فعالیت‌های پژوهشی که در آنها روش‌های یادگیری ماشینی می‌توانند در صنعت برق و شبکه هوشمند مورد استفاده قرار گیرند، در قالب تعریف پروژه ارائه شده‌اند.

این پروژه با مدیریت آقای دکتر مهدی مظفری‌پور، مجری‌گری سرکار خانم مهندس شیدا سیدفرشی مدیر محترم گروه پژوهشی فناوری اطلاعات و ارتباطات پژوهشگاه نیرو، نظارت سرکار خانم دکتر مریم صباغیان عضو محترم هیئت‌علمی دانشگاه تهران، داوری داخلی سرکار خانم دکتر چوبکار، همکاری آقای دکتر محسن ظهیر و خانم مهندس صدیقی در گروه پژوهشی فناوری اطلاعات و ارتباطات در پژوهشگاه نیرو طی سال‌های ۹۸-۹۹ انجام شده است.

¹ Artificial Intelligence

² Medium Access Control

فهرست مطالب

صفحه

عنوان

VI	پیشگفتار.....
۲۲	مرحله اول. مطالعات مقدماتی و تطبیقی.....
۲۳	مقدمه مرحله اول.....
۲۵	۱ فصل ۱ بررسی کاربرد رادیو شناختی در صنعت برق.....
۲۶	۱-۱- مقدمه.....
۲۷	۲-۱- معرفی شبکه‌های رادیو شناختی و شبکه برق هوشمند.....
۲۷	۱-۲-۱- شبکه رادیو شناختی.....
۲۸	۲-۲-۱- شبکه برق هوشمند.....
۲۹	۳-۲-۱- چالش‌های مخابراتی مختص شبکه برق هوشمند.....
۲۹	۴-۲-۱- انگیزه‌های استفاده از رادیو شناختی در شبکه برق هوشمند.....
۳۱	۵-۲-۱- استانداردسازی رادیو شناختی در شبکه برق هوشمند.....
۳۱	۳-۱- نمونه‌های استفاده از شبکه رادیو شناختی در شبکه هوشمند برق.....
۳۲	۴-۱- کاربردهای بالقوه و قابلیت‌های رادیو شناختی در شبکه هوشمند.....
۳۲	۱-۴-۱- کاربردها در شبکه خانگی.....
۳۳	۲-۴-۱- کاربردها در شبکه همسایگی.....
۳۵	۳-۴-۱- کاربردها در شبکه ناحیه گسترده.....
۳۵	۴-۴-۱- کاربردهایی در معماری‌های ارتباطی ترکیبی.....
۳۶	۵-۱- پیاده‌سازی و توپولوژی رادیو شناختی در شبکه برق هوشمند.....
۳۶	۱-۵-۱- توپولوژی شبکه خانگی.....
۳۷	۲-۵-۱- توپولوژی شبکه همسایگی.....
۳۷	۳-۵-۱- توپولوژی شبکه ناحیه گسترده.....
۳۷	۶-۱- معماری شبکه‌های هوشمند مبتنی بر رادیو شناختی.....
۳۸	۱-۶-۱- معماری‌های شبکه خانگی.....
۳۸	۲-۶-۱- معماری‌های ترکیبی.....
۴۵	۷-۱- روش‌های حس کردن پهنای باند مبتنی بر رادیو شناختی.....
۴۵	۱-۷-۱- روش آشکارسازی انرژی.....
۴۵	۲-۷-۱- روش استفاده از فیلتر تطبیق شده.....
۴۶	۳-۷-۱- روش تشخیص ویژگی.....
۴۶	۸-۱- پروتکل‌های MAC مبتنی بر رادیو شناختی برای شبکه هوشمند برق.....
۴۷	۹-۱- پروتکل‌های مسیریابی مبتنی بر رادیو شناختی برای شبکه هوشمند برق.....
۴۸	۱۰-۱- رادیو نرم‌افزار.....
۴۹	۱-۱۰-۱- تعریف.....
۵۱	۲-۱۰-۱- مزایا و معایب استفاده از SDR.....

۵۳	۱-۱۰-۳- پیاده‌سازی رادیو نرم‌افزاری
۵۴	۱-۱۱- جمع‌بندی فصل ۱
۵۵	مراجع فصل ۱
۶۱	۲ فصل ۲ بررسی پروژه‌های انجام شده در دنیا در خصوص هوشمندسازی سیستم‌های ارتباطی و بکارگیری آنها در صنعت برق
۶۲	۱-۲- مقدمه
۶۲	۲-۲- پروژه <i>SUNSEED</i>
۶۳	۱-۲-۲- ایجاد ارتباطات با ضریب اطمینان بالا از طریق شبکه‌های دسترسی چندگانه
۶۳	۲-۲-۲- مدل سیستم
۶۴	۳-۲-۲- روش‌های ارسالی داده‌ها
۶۶	۳-۲- پروژه <i>SMARTEREMC2</i>
۶۸	۴-۲- پروژه دانشگاهی
۶۸	۱-۴-۲- پروژه در یک نگاه
۶۹	۲-۴-۲- بخش‌های اصلی پروژه
۶۹	۳-۴-۲- نحوه پیاده‌سازی
۷۲	۵-۲- جمع‌بندی فصل ۲
۷۴	مراجع فصل ۲
۷۵	۳ فصل ۳ بررسی کاربردهای هوش مصنوعی در لایه فیزیکی
۷۶	۱-۳- مقدمه
۷۶	۲-۳- شبکه‌های بی‌سیم مبتنی بر هوش مصنوعی
۷۹	۳-۳- مروری بر یادگیری ماشین در لایه فیزیکی
۸۰	۱-۳-۳- چالش‌های استفاده از ابزار یادگیری ماشین در مخابرات بیسیم
۸۱	۲-۳-۳- بکارگیری یادگیری ماشین در آشکارسازی و دیکدینگ
۸۲	۳-۳-۳- یادگیری عمیق برای تخمین کانال و بازخورد اطلاعات کانال
۸۲	۴-۳-۳- تخمین کانال
۸۳	۵-۳-۳- فشرده سازی اطلاعات کانال
۸۵	۴-۳- مروری بر روش‌های یادگیری ماشینی و یادگیری عمیق مورد استفاده در سیستم‌های ارتباطی
۸۵	۱-۴-۳- یادگیری عمیق و یادگیری ماشین
۸۸	۲-۴-۳- یادگیری تقویتی
۹۱	۳-۴-۳- یادگیری عمیق با استفاده از شبکه‌های عصبی مصنوعی
۹۹	۵-۳- یادگیری ماشین در مدولاسیون و کدگذاری
۹۹	۱-۵-۳- یادگیری ماشین در <i>AMC</i>
۱۰۱	۲-۵-۳- <i>AMC</i> با کمک یادگیری هدایتی (<i>SL</i>)
۱۰۵	۳-۵-۳- پیاده‌سازی <i>AMC</i> با استفاده از یادگیری تقویتی (<i>RL</i>)
۱۰۸	۴-۵-۳- جمع‌بندی بکارگیری <i>ML</i> برای <i>AMC</i>
۱۰۹	۶-۳- یادگیری ماشین در یکسان‌سازی کانال

۱۱۰.....	۳-۶-۱- مروری بر یکسان‌سازی مبتنی بر شبکه‌های عصبی.....
۱۱۳.....	۳-۶-۲- آشکارسازی و یکسان‌سازی براساس شبکه‌های عصبی.....
۱۱۵.....	۳-۶-۳- یکسان‌سازی مبتنی بر شبکه‌های عصبی یادگیری عمیق (<i>DNN</i>).....
۱۱۸.....	۳-۶-۴- عملکرد سیستم <i>OFDM</i> با استفاده از یکسان‌سازی مبتنی بر شبکه عصبی.....
۱۲۲.....	۳-۶-۵- جمع‌بندی یادگیری ماشین در یکسان‌سازی کانال.....
۱۲۲.....	۳-۷- جمع‌بندی فصل ۳.....
۱۲۴.....	مراجع فصل ۳.....
۱۲۷.....	۴- فصل ۴ بررسی کاربردهای هوش مصنوعی در استفاده از طیف فرکانسی و رادیو شناختی.....
۱۲۸.....	۴-۱- مقدمه.....
۱۲۹.....	۴-۲- چالش‌های یادگیری ماشین در رادیو شناختی.....
۱۳۰.....	۴-۳- انواع نمونه‌های یادگیری ماشین.....
۱۳۱.....	۴-۴- انواع مسائل یادگیری در رادیو شناختی.....
۱۳۳.....	۴-۵- مروری بر روش‌های هوش مصنوعی مورد استفاده در رادیو شناختی.....
۱۳۳.....	۴-۵-۱- منطق فازی.....
۱۳۳.....	۴-۵-۲- الگوریتم ژنتیک (<i>GA</i>).....
۱۳۴.....	۴-۵-۳- شبکه عصبی مصنوعی (<i>ANN</i>).....
۱۳۴.....	۴-۵-۴- تئوری بازیها.....
۱۳۴.....	۴-۵-۵- <i>SVM</i>
۱۳۶.....	۴-۵-۶- یادگیری تقویتی (<i>RL</i>).....
۱۳۷.....	۴-۵-۷- حرکت دسته جمعی زنبورها (<i>ABC</i>).....
۱۳۸.....	۴-۵-۸- استدلال موردی (<i>CBR</i>).....
۱۳۸.....	۴-۵-۹- درخت تصمیم‌گیری.....
۱۳۹.....	۴-۵-۱۰- انتروپی.....
۱۳۹.....	۴-۵-۱۱- روش <i>Bayesian</i>
۱۳۹.....	۴-۵-۱۲- مدل مارکوف.....
۱۴۰.....	۴-۵-۱۳- سیستم‌های چند کاربره (<i>MAS</i>).....
۱۴۰.....	۴-۵-۱۴- مقایسه روش‌های هوش مصنوعی مورد استفاده در رادیو شناختی.....
۱۴۱.....	۴-۶- کاربرد هوش مصنوعی در دسترسی به طیف فرکانسی، شبکه و کنترل نرخ ارسال داده.....
۱۴۲.....	۴-۶-۱- دسترسی پویا به پهنای باند.....
۱۴۷.....	۴-۶-۲- ارتباط با کاربر متصل شده و دسترسی به طیف.....
۱۴۸.....	۴-۷- جمع‌بندی فصل ۴.....
۱۴۹.....	مراجع فصل ۴.....
۱۵۳.....	۵- فصل ۵ بررسی ملاحظات و ابزارهای مورد نیاز طراحی سیستمی جهت بکارگیری هوش مصنوعی.....
۱۵۴.....	۵-۱- مقدمه.....
۱۵۴.....	۵-۲- محدودیت‌های بکارگیری <i>DL</i> در شبکه‌های بی‌سیم.....
۱۵۵.....	۵-۳- بکارگیری <i>DL</i> در شبکه‌های موبایل.....

۱۵۷.....	۵-۳-۱- پردازش موازی پیشرفته.....
۱۵۸.....	۵-۳-۲- سیستم‌های یادگیری ماشین توزیع شده.....
۱۵۹.....	۵-۳-۳- کتابخانه‌های اختصاصی یادگیری عمیق.....
۱۶۱.....	۵-۳-۴- الگوریتم‌های سریع مورد استفاده در بهینه‌سازی.....
۱۶۳.....	۵-۳-۵- پردازش مه.....
۱۶۴.....	۵-۳-۶- سخت‌افزار.....
۱۶۴.....	۵-۳-۷- نرم‌افزار.....
۱۶۵.....	۵-۴- جمع‌بندی فصل ۵.....
۱۶۷.....	مراجع فصل ۵.....
۱۷۰.....	جمع‌بندی مرحله اول.....
۱۷۲.....	مرحله دوم. مطالعات مقدماتی و تطبیقی.....
۱۷۳.....	مقدمه مرحله دوم.....
۱۷۵.....	۶ فصل ۶ مطالعه و بررسی صفحات هوشمند <i>LIS</i>
۱۷۶.....	۶-۱- مقدمه.....
۱۷۸.....	۶-۲- موارد کاربرد <i>LIS</i>
۱۸۰.....	۶-۳- فناوری‌های مشابه <i>LIS</i>
۱۸۱.....	۶-۴- مبانی الکترومغناطیسی <i>LIS</i>
۱۸۴.....	۶-۵- ساخت و پیاده‌سازی <i>LIS</i>
۱۸۷.....	۶-۶- چالش‌های <i>LIS</i>
۱۸۷.....	۶-۶-۱- شکل دهی بیم غیرفعال.....
۱۹۱.....	۶-۶-۲- دریافت اطلاعات وضعیت کانال در <i>LIS</i>
۱۹۲.....	۶-۶-۳- استفاده از <i>LIS</i>
۱۹۳.....	۶-۷- نتیجه‌گیری فصل ۶.....
۱۹۵.....	مراجع فصل ۱.....
۱۹۷.....	۷ فصل ۷. بررسی کاربردهای شبکه‌های عصبی در سیستم‌های <i>MIMO</i> انبوه.....
۱۹۸.....	۷-۱- مقدمه.....
۱۹۹.....	۷-۲- انواع سیستم‌های چند ورودی-چند خروجی (<i>MIMO</i>).....
۲۰۰.....	۷-۳- <i>MIMO</i> انبوه.....
۲۰۱.....	۷-۳-۱- مزایای <i>MIMO</i> انبوه.....
۲۰۵.....	۷-۳-۲- چالش‌های <i>MIMO</i> انبوه.....
۲۰۷.....	۷-۴- کاربرد فناوری <i>MIMO</i> انبوه.....
۲۰۷.....	۷-۴-۱- رادیو شناختی.....
۲۰۸.....	۷-۴-۲- کاربرد در سیستم‌های سایر- فیزیکی.....
۲۰۹.....	۷-۵- استفاده از هوش مصنوعی در سیستم‌های <i>MIMO</i> انبوه.....
۲۱۲.....	۷-۵-۱- شکل دهی پرتو در <i>MIMO</i> انبوه با روش <i>RNN</i>
۲۱۳.....	۷-۶- نتیجه‌گیری.....

مراجع فصل ۷.....	۲۱۵
مرحله سوم. بررسی بکارگیری هوش مصنوعی در لایه‌های MAC و شبکه.....	۲۱۷
مقدمه مرحله سوم.....	۲۱۸
۸ فصل ۸. بررسی عملکرد هوش مصنوعی در لایه MAC سیستم‌های ارتباطی.....	۲۱۹
۸-۱- مقدمه.....	۲۲۰
۸-۲- روش DEEPMAC.....	۲۲۰
۸-۲-۱- بررسی نتایج.....	۲۲۲
۸-۳- پیاده‌سازی یادگیری-Q بر روی ALOHA.....	۲۲۳
۸-۴- روش RL-MAC.....	۲۲۷
۸-۵- مروری بر چند روش متفرقه در خصوص ارتقاء لایه MAC.....	۲۲۹
۸-۵-۱- ارتقاء عملکرد با ترکیب روش‌های سنتی MAC.....	۲۲۹
۸-۵-۲- یادگیری ماشین در لایه MAC چندکاربره.....	۲۳۰
۸-۵-۳- یادگیری تقویتی عمیق در طراحی MAC.....	۲۳۰
۸-۵-۴- طراحی MAC با استفاده از مدل مارکوف.....	۲۳۱
۸-۶- طراحی لایه MAC با استفاده از هوش مصنوعی محلی.....	۲۳۱
۸-۷- استفاده از منطق فازی در ارتقاء عملکرد لایه MAC.....	۲۳۳
۸-۷-۱- استفاده از منطق فازی جهت بهبود تأخیر در سیستم.....	۲۳۳
۸-۷-۲- استفاده از منطق فازی بر روی روش CSMA/CA.....	۲۳۴
۸-۸- استفاده از شبکه‌های عصبی بر روی CSMA.....	۲۳۵
۸-۹- مقایسه چند روش ML-MAC.....	۲۳۶
۸-۱۰- کاربردها در صنعت برق.....	۲۳۶
۸-۱۱- جمع‌بندی فصل ۸.....	۲۳۷
مراجع فصل ۸.....	۲۳۹
۹ فصل ۹ مطالعه و بررسی به کارگیری AI در لایه شبکه.....	۲۴۱
۹-۱- مقدمه.....	۲۴۲
۹-۲- به کارگیری هوش مصنوعی در کنترل ترافیک شبکه.....	۲۴۲
۹-۲-۱- لزوم.....	۲۴۳
۹-۲-۲- سودمندی.....	۲۴۳
۹-۲-۳- قابلیت تحقق.....	۲۴۳
۹-۳- ایجاد ارتباط مابین AI و NTC.....	۲۴۴
۹-۴- نحوه به کارگیری AI-NTC.....	۲۴۶
۹-۵- ارائه یک معماری جهت پیاده‌سازی AI-NTC.....	۲۴۷
۹-۶- یادگیری ماشینی در کنترل ترافیک شبکه‌های نرم‌افزار محور.....	۲۴۸
۹-۶-۱- استفاده از DRL در شبکه نرم‌افزار محور.....	۲۵۰
۹-۷- استفاده از شبکه عصبی در شبکه‌های ناهمگون.....	۲۵۲
۹-۸- استفاده از شبکه‌های عصبی در اینترنت اشیا.....	۲۵۷

۲۵۷.....	۹-۹- تقسیم منابع و زمان بندی.....
۲۵۹.....	۹-۱۰- به کارگیری یادگیری عمیق جهت بهبود مدل شبکه سلولی.....
۲۵۹.....	۹-۱۰-۱- بهینه سازی با روش مدل محور.....
۲۶۰.....	۹-۱۰-۲- بهینه سازی با روش داده محور.....
۲۶۱.....	۹-۱۰-۳- بهینه سازی با یادگیری انتقال شبکه محور.....
۲۶۳.....	۹-۱۱- بهبود مدل مصرف توان غیردقیق توسط یادگیری انتقال عمیق.....
۲۶۴.....	۹-۱۲- کاربردها در صنعت برق.....
۲۶۷.....	۹-۱۳- جمع بندی.....
۲۶۹.....	مراجع فصل ۹.....
۲۷۱.....	مرحله چهارم. هوشمندسازی مدیریت شبکه ارتباطی.....
۲۷۲.....	مقدمه مرحله چهارم.....
۲۷۳.....	۱۰ فصل ۱۰. بررسی روش های به کارگیری AI جهت تخصیص منابع در شبکه های ارتباطی.....
۲۷۴.....	۱۰-۱- مقدمه.....
۲۷۴.....	۱۰-۲- ویژگی های اینترنت اشیا در صنعت برق.....
۲۷۴.....	۱۰-۲-۱- ناهمگونی.....
۲۷۴.....	۱۰-۲-۲- مقیاس وسیع کاربرد و حجم بالای انتقال داده.....
۲۷۵.....	۱۰-۲-۳- اتصالات متقابل.....
۲۷۵.....	۱۰-۲-۴- مخابرات در فاصله نزدیک.....
۲۷۵.....	۱۰-۲-۵- مخابرات بسیار قابل اطمینان و کم تأخیر (URLLC).....
۲۷۵.....	۱۰-۲-۶- مخابرات کم توان و کم هزینه.....
۲۷۵.....	۱۰-۲-۷- خودسازمان یافتگی و خودترمیمی.....
۲۷۶.....	۱۰-۲-۸- تغییرات پویا در شبکه.....
۲۷۶.....	۱۰-۳- تخصیص منابع در شبکه اینترنت اشیا.....
۲۷۶.....	۱۰-۴- مشکلات مدیریت منابع در شبکه اینترنت اشیا.....
۲۷۶.....	۱۰-۴-۱- دسترسی تعداد زیادی از ادوات به کانال.....
۲۷۷.....	۱۰-۴-۲- مدیریت تداخل و تخصیص توان.....
۲۷۷.....	۱۰-۴-۳- تخصیص کاربر، انتخاب سلول و مدیریت واگذاری.....
۲۷۷.....	۱۰-۴-۴- همزیستی هماهنگ انسان با انسان و ترافیک اینترنت اشیا.....
۲۷۷.....	۱۰-۴-۵- گسترش پوشش دهی.....
۲۷۷.....	۱۰-۴-۶- مدیریت انرژی.....
۲۷۸.....	۱۰-۴-۷- پردازش زمان حقیقی و مخابره فوق العاده قابل اعتماد با تأخیر کم.....
۲۷۸.....	۱۰-۴-۸- کیفیت سرویس ناهمگن.....
۲۷۸.....	۱۰-۵- محدودیت های تکنیک های مرسوم در مدیریت منابع.....
۲۷۸.....	۱۰-۶- دلایل به کارگیری یادگیری ماشین برای مدیریت منابع.....
۲۷۸.....	۱۰-۶-۱- تخصیص منابع در شبکه های اینترنت اشیا سلولی.....
۲۷۹.....	۱۰-۶-۲- یادگیری ماشینی برای مدیریت منابع در محیط خانه هوشمند.....

۳۷۹.....	۱۰-۶-۳- استفاده از شبکه‌های عصبی در مدیریت منابع.....
۲۸۰.....	۱۰-۷- مدیریت منابع در شبکه‌های بی‌سیم.....
۲۸۰.....	۱۰-۸- کنترل توان مبتنی بر یادگیری ماشین.....
۲۸۱.....	۱۰-۸-۱- کنترل توان با استفاده از یادگیری تقویتی.....
۲۸۱.....	۱۰-۸-۲- کنترل توان با استفاده از یادگیری نظارت‌شده.....
۲۸۲.....	۱۰-۸-۳- کنترل توان با استفاده از یادگیری انتقال.....
۲۸۳.....	۱۰-۹- یادگیری ماشین برای مدیریت طیف.....
۲۸۴.....	۱۰-۱۰- استفاده از یادگیری ماشین در مدیریت بک‌هال.....
۲۸۶.....	۱۰-۱۱- مدیریت کشینگ مبتنی بر یادگیری ماشین.....
۲۸۶.....	۱۰-۱۱-۱- روش مبتنی بر یادگیری تقویتی.....
۲۸۷.....	۱۰-۱۱-۲- روش مبتنی بر یادگیری نظارت‌شده.....
۲۸۸.....	۱۰-۱۱-۳- روش مبتنی بر یادگیری انتقال.....
۲۸۹.....	۱۰-۱۲- مدیریت منابع محاسباتی مبتنی بر یادگیری ماشین.....
۲۸۹.....	۱۰-۱۳- شکل‌دهی پرتو مبتنی بر یادگیری ماشین.....
۲۹۰.....	۱۰-۱۴- جمع‌بندی.....
۲۹۱.....	مراجع فصل ۱۰.....
۲۹۵.....	فصل ۱۱. بررسی روش‌های به‌کارگیری AI جهت ارتقاء امنیت در شبکه‌های ارتباطی.....
۲۹۶.....	۱۱-۱- مقدمه.....
۲۹۸.....	۱۱-۲- راهکار هوش مصنوعی برای مسائل امنیتی در اینترنت اشیاء.....
۲۹۹.....	۱۱-۳- انواع حملات در لایه‌های مختلف.....
۲۹۹.....	۱۱-۳-۱- حمله فیزیکی.....
۳۰۰.....	۱۱-۳-۲- مسائل امنیتی لایه فیزیکی و لایه ارتباط داده.....
۳۰۱.....	۱۱-۳-۳- حملات لایه شبکه.....
۳۰۱.....	۱۱-۳-۴- حملات لایه انتقال.....
۳۰۱.....	۱۱-۳-۵- حملات لایه کاربرد.....
۳۰۲.....	۱۱-۳-۶- حملات چندلایه.....
۳۰۲.....	۱۱-۳-۷- مسائل امنیتی در اینترنت اشیاء مبتنی بر ابر.....
۳۰۳.....	۱۱-۴- کاربردهای هوش مصنوعی در امنیت شبکه.....
۳۰۳.....	۱۱-۴-۱- کاربرد هوش مصنوعی در حمله جمینگ.....
۳۰۵.....	۱۱-۴-۲- کاربرد هوش مصنوعی در آشکارسازی نفوذ.....
۳۰۷.....	۱۱-۴-۳- کاربرد هوش مصنوعی در حمله سایبر فیزیکی.....
۳۱۰.....	۱۱-۴-۴- کاربرد هوش مصنوعی در حفظ اتصال.....
۳۱۲.....	۱۱-۵- کاربرد هوش مصنوعی در امنیت صنعت برق.....
۳۱۳.....	۱۱-۵-۱- امنیت در صنعت برق.....
۳۱۵.....	۱۱-۵-۲- مهمترین زمینه‌های امنیت و پایداری در صنعت برق.....
۳۱۹.....	۱۱-۵-۳- روش‌های هوش مصنوعی برای شناسایی تهدیدات شبکه برق.....

۳۲۱.....	۱۱-۶- جمع بندی
۳۲۳.....	مراجع فصل ۱۱
۳۳۰.....	۱۲ فصل ۱۲. بررسی برنامه های کاربردی هوشمند
۳۳۱.....	۱۲-۱- مقدمه
۳۳۱.....	۱۲-۲- چالش ها و رویکردهای بکارگیری روشهای هوش مصنوعی در برنامه‌های کاربردی
۳۳۳.....	۱۲-۳- بررسی برنامه‌های کاربردی هوشمند
۳۳۳.....	۱۲-۳-۱- برنامه‌های کاربردی هوشمند در حوزه‌های مختلف
۳۳۵.....	۱۲-۳-۲- نوع داده‌های جمع‌آوری شده
۳۳۷.....	۱۲-۴- الگوریتم‌های مورد استفاده در یادگیری ماشینی
۳۳۸.....	۱۲-۵- کاربردها در شبکه هوشمند
۳۳۹.....	۱۲-۵-۱- پیش‌بینی بار / تقاضا
۳۴۰.....	۱۲-۵-۲- ریز شبکه‌ها
۳۴۱.....	۱۲-۵-۳- پاسخ بار
۳۴۲.....	۱۲-۵-۴- تشخیص نقص و خطا در تجهیزات الکتریکی
۳۴۲.....	۱۲-۵-۵- کنترل و تحلیل سیستم‌های قدرت
۳۴۳.....	۱۲-۵-۶- امنیت سایبری
۳۴۳.....	۱۲-۵-۷- پیش‌بینی تولید انرژی تجدیدپذیر
۳۴۳.....	۱۲-۵-۸- سایر کاربردها
۳۴۴.....	۱۲-۶- جمع بندی
۳۴۵.....	مراجع فصل ۱۲
۳۴۹.....	مرحله پنجم. جمع بندی و ارائه پیشنهاد برای ادامه کار
۳۵۰.....	۱۳ فصل ۱۳. جمع بندی نهایی و پیشنهاد عناوین پروژه‌هایی برای ادامه کار
۳۵۱.....	۱۳-۱- مقدمه
۳۵۱.....	۱۳-۲- فهرست پروژه‌های پیشنهادی
۳۵۱.....	۱۳-۲-۱- استفاده از رادیو شناختی در مخابرات شبکه برق کشور
۳۵۱.....	۱۳-۲-۲- استفاده از رادیو شناختی در اینترنت اشیا خانگی
۳۵۲.....	۱۳-۲-۳- آزمون ایده در خصوص به کارگیری یادگیری ماشینی در شبکه‌های کم مصرف وسیع
۳۵۲.....	۱۳-۲-۴- آزمون ایده در خصوص به کارگیری روش‌های یادگیری ماشینی در سامانه‌های MIMO انبوه و به کارگیری آن‌ها در شبکه هوشمند
۳۵۳.....	۱۳-۲-۵- استفاده از صفحات بزرگ هوشمند در خانه هوشمند
۳۵۴.....	۱۳-۲-۶- استفاده از صفحات هوشمند در اینترنت اشیا صنعتی
۳۵۴.....	۱۳-۲-۷- استفاده از صفحات هوشمند در بخش توزیع و انتقال شهری
۳۵۴.....	۱۳-۲-۸- آزمون ایده در خصوص به کارگیری روش‌های یادگیری ماشینی در مسیریابی داده‌ها در شبکه‌های ارتباطی
۳۵۴.....	مورد استفاده در صنعت برق
۳۵۵.....	۱۳-۲-۹- تشخیص حمله جمینگ به شبکه برق با استفاده از یادگیری ماشین
۳۵۵.....	۱۳-۲-۱۰- بررسی امنیت شبکه برق در اتصال با شبکه ابری

۳۵۵.....	۱۳-۲-۱۱- به کارگیری روش‌های یادگیری ماشینی برای پیش‌بینی بار و تقاضا.....
۳۵۶.....	۱۳-۲-۱۲- به کارگیری روش‌های یادگیری ماشینی در ریزشبکه‌ها.....
۳۵۶.....	۱۳-۲-۱۳- به کارگیری روش‌های یادگیری ماشینی در پاسخ بار.....
۳۵۶.....	۱۳-۲-۱۴- به کارگیری روش‌های یادگیری ماشینی جهت تشخیص نقص و خطا در تجهیزات الکتریکی.....
۳۵۶.....	۱۳-۲-۱۵- به کارگیری روش‌های یادگیری ماشینی در کنترل و تحلیل سیستم‌های قدرت.....
۳۵۷.....	۱۳-۲-۱۶- به کارگیری روش‌های یادگیری ماشینی در پیش‌بینی میزان تولید انرژی تجدیدپذیر.....
۳۵۷.....	۱۳-۳- کاربردهای شبکه هوشمند و نقش شبکه‌های ارتباطی در آنها.....
۳۵۹.....	۱۳-۴- مروری بر فعالیت‌های انجام شده و جمع‌بندی نهایی.....
۳۶۵.....	مراجع فصل ۱۳.....

فهرست شکل‌ها

عنوان

صفحه

شکل ۱. معماری شبکه هوشمند برق شامل HAN، NAN و WAN [۲۶].....	۲۸
شکل ۲. تقسیم بندی کاربردهای مخابرات CR در شبکه هوشمند [۲۶].....	۳۳
شکل ۳. معماری سه لایه شبکه برق هوشمند و درگاههای ارتباطی در هر لایه [۲۶].....	۳۶
شکل ۴. معماریهای مبتنی بر رادیو شناختی در شبکه هوشمند [۲۶].....	۳۹
شکل ۵. بلوک دیاگرام روش آشکارسازی انرژی [۸۲].....	۴۵
شکل ۶. بلوک دیاگرام روش فیلتر کالمن [۸۲].....	۴۶
شکل ۷. شکلی ایده آل از رادیو نرم افزاری.....	۵۰
شکل ۸. مقایسه سهم نرم افزار و سخت افزار در رادیوهای کنونی، SDR و SR.....	۵۱
شکل ۹. یک تجهیز M2M و مسیرهای ارتباطی آن با نود انتهایی (Remote Host).....	۶۳
شکل ۱۰. ارسال دادهها از طریق روشهای مختلف: (a) ارسال یکسان (Cloning)، (b) k-out of-N، (c) ضربدهی (Weighted).....	۶۵
شکل ۱۱. نتایج بدست آمده از اعمال Multi-Connectivity: رابطه ضرایب اطمینان (F(x)) بر اساس تأخیر.....	۶۵
شکل ۱۲. به کارگیری Massive-MIMO در شبکههای NAN مورد استفاده در شبکههای هوشمند.....	۶۶
شکل ۱۳. سیستم مورد استفاده برای پیادهسازی الگوریتم انتخاب آنتن.....	۶۷
شکل ۱۴. نتایج اعمال الگوریتم انتخاب آنتن (LASS) بر مقدار کارایی انرژی (EE)؛ ضرایب همبستگی $\phi=0.2, 0.6$	۶۷
شکل ۱۵. نحوه عملکرد یادگیری تقویتی در خصوص تعویض کانال [۶].....	۷۰
شکل ۱۶. نحوه عملکرد انتقال یادگیری و نقش نود خبره در خصوص تعویض کانال [۶].....	۷۱
شکل ۱۷. پیادهسازی بخشهای مختلف سخت افزاری و نرم افزاری سیستم [۶].....	۷۱
شکل ۱۸. نتایج بدست آمده از پیادهسازی روش یادگیری تقویتی و انتقال یادگیری (با استفاده از گره خبره) در مقایسه با روش سنتی Greedy در یک سیستم رادیوشناختگر [۶].....	۷۲
شکل ۱۹. رفتارهای نوعی از خطاهای آموزش و تست.....	۸۶
شکل ۲۰. مقایسه یادگیری عمیق با دیگر الگوریتمهای کلاسیک [۱].....	۸۸
شکل ۲۱. مدل یادگیری تقویتی.....	۸۹
شکل ۲۲. فرایند الگوریتم یادگیری Q.....	۹۰
شکل ۲۳. ساختار کلی شبکه عصبی feed-forward.....	۹۲
شکل ۲۴. 3D-convolution در شبکههای عصبی کانولوشن [۱].....	۹۳
شکل ۲۵. شبکه عصبی بازگشتی.....	۹۳
شکل ۲۶. کاربردهای مختلف یادگیری تقویتی عمیق.....	۹۵
شکل ۲۷. unfolding عمیق.....	۹۶
شکل ۲۸. نرخ متوسط براساس SNR متوسط برای کانال های متفاوت.....	۱۰۴
شکل ۲۹. PER براساس SNR متوسط برای کانال های متفاوت.....	۱۰۵
شکل ۳۰. تاثیر پارامتر τ بر همگرایی الگوریتم RL برای $\alpha = 0.4$	۱۰۷
شکل ۳۱. تاثیر نرخ α بر همگرایی الگوریتم RL برای $\tau = 0.4$	۱۰۷
شکل ۳۲. متوسط بازدهی طیفی جدول ارجاعی و RL برای کانال AWGN با تخمین ایده آل SNR.....	۱۰۸
شکل ۳۳. متوسط بازدهی طیفی lookup table و RL برای کانال AWGN با تخمین غیر ایده آل SNR.....	۱۰۸

شکل ۳۴. گره عصبی.....	۱۱۳
شکل ۳۵. یک مثال از مدل MLP.....	۱۱۴
شکل ۳۶. ساختار DNN.....	۱۱۵
شکل ۳۷. سیستم مدل برای یک یکسان‌ساز براساس DNN.....	۱۱۶
شکل ۳۸. یک لایه convolutional مرسوم.....	۱۱۷
شکل ۳۹. ساختار CNN.....	۱۱۷
شکل ۴۰. ساختار یک RNN : گراف تا شده و تا نشده.....	۱۱۸
شکل ۴۱. سیستم مدل برای OFDM با یکسان‌ساز براساس CNN و DNN.....	۱۱۸
شکل ۴۲. ساختار شبکه DNN برای سیستم OFDM.....	۱۱۹
شکل ۴۳. ساختار شبکه CNN برای سیستم OFDM.....	۱۱۹
شکل ۴۴. نرخ خطای بیت سیستم OFDM با یکسان‌ساز DNN, CNN, LS, and MMSE وقتی در کانال رایلی تک مسیره مخابره میکند [۳۲].....	۱۲۱
شکل ۴۵. نرخ خطای بیت سیستم OFDM با یکسان‌ساز DNN, CNN, LS, and MMSE وقتی در کانال رایلی بیسیم EPA مخابره میکند [32].....	۱۲۱
شکل ۴۶. نرخ خطای بیت سیستم OFDM با یکسان‌ساز DNN, CNN, LS, and MMSE وقتی در کانال انتخابگر فرکانسی ETU مخابره میکند [۳۲].....	۱۲۲
شکل ۴۷. چرخه شناخت برای یک رادیوبات [۶].....	۱۲۹
شکل ۴۸. روشهای عمومی یادگیری ماشین [۷].....	۱۳۰
شکل ۴۹. انواع مسائل یادگیری و الگوریتمهای یادگیری متناظر در رادیو شناختی [۷].....	۱۳۱
شکل ۵۰. روش SVM داده‌های یادگیری را با تعیین خطی که بیشترین جداسازی را بین دو طرف ایجاد میکند به دو دسته تقسیم کرده است.....	۱۳۵
شکل ۵۱. نگاشت نقاط با استفاده از kernel.....	۱۳۶
شکل ۵۲. چرخه یادگیری تقویتی.....	۱۳۷
شکل ۵۳. ساختار درخت تصمیم‌گیری.....	۱۳۸
شکل ۵۴. انتخاب کانال مشترک و ارسال بسته در اینترنت اشیاء.....	۱۴۴
شکل ۵۵. یک نمونه از حمله بر روی روش یادگیری عمیق.....	۱۵۴
شکل ۵۶. ابزارهای ایجادکننده یادگیری عمیق.....	۱۵۶
شکل ۵۷. ارتباطات بین یک ایستگاه پایه و کاربر موبایل، پرنده بدون سرنشین و خودرو هوشمند با استفاده از سطح بازتابنده هوشمند [۸].....	۱۷۶
شکل ۵۸. کاربرد RIS برای زمانی که کاربر در منطقه دید کور فرستنده قرار دارد [۷].....	۱۷۸
شکل ۵۹. نقش RIS در حفاظت لایه فیزیکی [۷].....	۱۷۹
شکل ۶۰. کاربرد صفحه بزرگ هوشمند در لبه سلول مخابراتی [۷].....	۱۷۹
شکل ۶۱. مخابرات دستگاه به دستگاه انبوه [۷].....	۱۷۹
شکل ۶۲. استفاده از صفحات بزرگ هوشمند برای انتقال هم‌زمان اطلاعات و توان [۷].....	۱۸۰
شکل ۶۳. آنتن فرستنده و گیرنده به همراه LIS بر روی زمین [۱].....	۱۸۲
شکل ۶۴. تصویری از LIS با ۲۰ المان بازتابی [۱].....	۱۸۳
شکل ۶۵. عملکرد بازتابی LIS با تصویر کردن فرستنده در محلی از فضا به صورت مجازی [۲۸].....	۱۸۴

- شکل ۶۶ ساختار پیاده‌سازی شده از یک LIS و المان آن [۷]..... ۱۸۵
- شکل ۶۷ مدار معادل المان LIS در زمان روشن و خاموش بودن دیود [۷]..... ۱۸۶
- شکل ۶۸ LIS با المان شکاف مربعی و دیود PIN [۱]..... ۱۸۶
- شکل ۶۹ استفاده از ورکتور (خازن متغیر) برای ایجاد قابلیت پیکربندی در LIS [۱]..... ۱۸۷
- شکل ۷۰ کنترل هم‌زمان LIS و المانهای فعال در شبکه نظیر ایستگاه‌های پایه و نقاط دسترسی..... ۱۸۸
- شکل ۷۱ آنتن ایستگاه پایه، LIS و کاربر تک آنتن در شبیه‌سازی [۷]..... ۱۸۹
- شکل ۷۲ توان ارسالی ایستگاه پایه بر حسب فاصله ایستگاه پایه تا کاربر [۷]..... ۱۸۹
- شکل ۷۳ توان ارسالی بر حسب تعداد المانهای LIS [۷]..... ۱۹۰
- شکل ۷۴ توان تداخل نرمالیزه شده بر حسب تعداد المانهای LIS [۷]..... ۱۹۱
- شکل ۷۵ آنتن چندگانه برای الف) نقطه دسترسی و ب) ایستگاه پایه در مخابرات سلولی [۱]..... ۱۹۹
- شکل ۷۶ سیستم MIMO تک کاربره [۱]..... ۱۹۹
- شکل ۷۷ سیستم‌های MIMO چند کاربره [۱]..... ۲۰۰
- شکل ۷۸ سیستم‌های MIMO انبوه در مقابل سیستم‌های مخابراتی امروزی (LTE)..... ۲۰۰
- شکل ۷۹ برخی از پیکربندی آنتن‌ها و سناریوهای استفاده برای یک ایستگاه پایه MIMO انبوه [۲]..... ۲۰۱
- شکل ۸۰ شکل‌دهی بیم و پترن تشعشعی آرایه خطی از آنتن‌ها با دو روش MRT و ZF [۲]..... ۲۰۲
- شکل ۸۱ نمودار بازدهی انرژی به بازدهی طیف فرکانسی [۲]..... ۲۰۳
- شکل ۸۲ مقایسه شکلهی معمولی بیم آنتن در MIMO با ارسال با دامنه ثابت در هر آنتن در MIMO انبوه [۲]..... ۲۰۴
- شکل ۸۳ نمایی از پهنای باند شبکه 5G [۱۲]..... ۲۰۸
- شکل ۸۴ سناریوهای کاربردی شبکه 5G مبتنی بر AI [۱۲]..... ۲۱۰
- شکل ۸۵ فناوری‌های تسهیل‌کننده 5G و روش‌های مبتنی بر شبکه عصبی که می‌توانند در پیاده‌سازی آن‌ها به کار روند. [۱۲]..... ۲۱۱
- شکل ۸۶ شکل‌دهی پرتو ZF در ایستگاه‌های پایه 5G [۱۲]..... ۲۱۳
- شکل ۸۷ بازدهی انرژی (بر حسب Mbit/J) با شکل‌دهی بیم ZF در یک سیستم MIMO انبوه با مبتنی بر RNN [۱۲]..... ۲۱۳
- شکل ۸۸ عملکرد DRL [2]..... ۲۲۱
- شکل ۸۹ چهارچوب Deep MAC [2]..... ۲۲۲
- شکل ۹۰ مقایسه عملکرد DeepMAC با روش CSMA/CA [2]..... ۲۲۳
- شکل ۹۱ مقایسه مقدار گذردهی تحت ترافیک مختلف [3]..... ۲۲۵
- شکل ۹۲ تأخیر برحسب ترافیک [3]..... ۲۲۶
- شکل ۹۳ هزینه انرژی برحسب نرخ بیت [3]..... ۲۲۶
- شکل ۹۴ هزینه انرژی بر ثانیه برحسب ترافیک [3]..... ۲۲۷
- شکل ۹۵ ساختار فریم در پروتکل RL-MAC. چرخه کاری انطباقی جهت بهینه‌سازی گذردهی و مصرف انرژی [4]..... ۲۲۸
- شکل ۹۶ مقایسه میزان گذردهی RL-MAC با روش‌های S-MAC و T-MAC [4]..... ۲۲۹
- شکل ۹۷ مقایسه میزان کارایی انرژی RL-MAC با روش‌های S-MAC و T-MAC [4]..... ۲۲۹
- شکل ۹۸ مقایسه عملکرد انرژی براساس تعداد مخابرات برای تعداد ۳۰ گره [15]..... ۲۳۲
- شکل ۹۹ مقایسه تأخیر براساس تعداد مخابرات برای تعداد ۳۰ گره [15]..... ۲۳۲
- شکل ۱۰۰ مقایسه عملکرد نرخ ارسال بسته براساس تعداد مخابرات برای تعداد ۳۰ گره [15]..... ۲۳۳
- شکل ۱۰۱ سیستم منطق فازی با ورودی نرخ ترافیک و طول صف [16]..... ۲۳۳

- شکل ۱۰۲. تغییرات مقدار گذردهی برحسب زمان [16]..... ۲۳۴
- شکل ۱۰۳. میزان متوسط تاخیر برحسب زمان [16]..... ۲۳۴
- شکل ۱۰۴. سیستم منطق فازی با ورودی میزان بار کاری و گذردهی [18]..... ۲۳۵
- شکل ۱۰۵. ارتباط مابین اطلاعات حوزه‌های شبکه و هوش مصنوعی [1]..... ۲۴۵
- شکل ۱۰۶. تکنیک تکنیکهای مورد استفاده در NTC [1]..... ۲۴۵
- شکل ۱۰۷. معماری پیشنهادی برای پیاده‌سازی AI-NTC [1]..... ۲۴۸
- شکل ۱۰۸. کنترل ترافیک چندرسانه‌ای مبتنی بر (a. DRL معماری (b) بروزرسانی شبکه اولیه با DDPG. [4]..... ۲۵۱
- شکل ۱۰۹. عملکرد مقدار میانگین نمره رای با روش‌های مختلف در توپولوژی INDIA35. [4]..... ۲۵۲
- شکل ۱۱۰. عملکرد بهبود میانگین نمره رای با توپولوژی‌های مختلف [4]..... ۲۵۲
- شکل ۱۱۱. سناریو شبکه و چالش مسیریابی [6]..... ۲۵۳
- شکل ۱۱۲. نحوه به کارگیری شبکه عصبی جهت انجام مسیریابی [6]..... ۲۵۳
- شکل ۱۱۳. یک مثال ساده از ارسال بسته از مسیریاب $R2$ به مسیریاب $R12$. [6]..... ۲۵۵
- شکل ۱۱۴. مقایسه عملکرد روش OSPF و یادگیری عمیق پیشنهاد شده [6]..... ۲۵۶
- شکل ۱۱۵. نمودار MSE نسبی برحسب تعداد دوره‌های فراگیری (training Epoch). [15]..... ۲۶۲
- شکل ۱۱۶. مقایسه روش‌های بهینه‌سازی مدل محور و داده‌محور (به تنهایی) و روش یادگیری انتقال عمیق [15]..... ۲۶۲
- شکل ۱۱۷. مقایسه روش‌های فراگیری با مدل و با داده‌های تجربی. [15]..... ۲۶۳
- شکل ۱۱۸. نحوه ارتباطی زیرسیستم‌های مختلف در شبکه هوشمند [18]..... ۲۶۶
- شکل ۱۱۹. معماری شبکه مخابراتی در شبکه هوشمند برق [18]..... ۲۶۷
- شکل ۱۲۰. لینک فراسو در سیستم دستگاه به دستگاه و سناریو C-RAN [۲۴]..... ۲۸۴
- شکل ۱۲۱. سیستم C-RAN توانمند شده با UAV [۲۴]..... ۲۸۸
- شکل ۱۲۲. حمله جمینگ در شبکه رادیو شناختی [۲]..... ۲۹۷
- شکل ۱۲۳. روش ضد جمینگ با استفاده از UAV [۴۲]..... ۳۰۴
- شکل ۱۲۴. آشکارسازی موارد غیرعادی در سیستم پایش با استفاده از روش‌های دسته‌بندی و خوشه‌بندی [۴۷]..... ۳۰۶
- شکل ۱۲۵. مدل دنبال کردن خودرو با حمله سایبر-فیزیکی [۵۸]..... ۳۰۸
- شکل ۱۲۶. آشکارسازی سایبرفیزیکی در سیستم‌های اینترنت اشیاء با استفاده از DQL [۵۹]..... ۳۰۹
- شکل ۱۲۷. حفظ اتصال یک شبکه چند UAV [۶۱]..... ۳۱۰
- شکل ۱۲۸. ساختار شبکه برق هوشمند بر اساس استاندارد NIST [۷۴]..... ۳۱۳
- شکل ۱۲۹. ادوات در معرض خطر حملات سایبری در شبکه برق [۷۴]..... ۳۱۴
- شکل ۱۳۰. معماری سیستم SCADA [۸۱]..... ۳۱۷
- شکل ۱۳۱. دسته‌بندی ارزیابی امنیت پویا [۸۱]..... ۳۱۸
- شکل ۱۳۲. مراحل دسته‌بندی اختلالات PQD [۸۱]..... ۳۲۰
- شکل ۱۳۳. استنتاج توزیع شده در دستگاه با روش MapReduce در مخابرات بی‌سیم [۴]..... ۳۳۳
- شکل ۱۳۴. حجم مطالعات صورت گرفته در هر حوزه‌های مختلف کاربردی برنامه‌های هوشمند [۵]..... ۳۳۴
- شکل ۱۳۵. درصد مطالعات صورت گرفته در زمینه‌های مختلف [۵]..... ۳۳۴
- شکل ۱۳۶. توزیع مقالات انتخاب شده در دوره زمانی ۲۰۰۷-۲۰۱۸ برای هر زمینه تحقیق [۵]..... ۳۳۵
- شکل ۱۳۷. درصد انواع داده جمع‌آوری شده [۵]..... ۳۳۶
- شکل ۱۳۸. درصد انواع مدل‌های یادگیری ماشینی [۵]..... ۳۳۶

شکل ۱۳۹. روند به کارگیری الگوریتم‌های یادگیری ماشینی [۵]..... ۳۳۷

فهرست جدول‌ها

صفحه

عنوان

۴۲	جدول ۱ خلاصه‌های از پارامترهای کلیدی استاندارد IEEE 802.22
۱۰۰	جدول ۲. لیست مدولاسیون و کدینگ مطرح شده در IEEE 802.11n
۱۴۰	جدول ۳. مزایا و معایب روشهای یادگیری مختلف مورد استفاده در رادیوشناختی
۱۵۶	جدول ۴. روشها و ابزار تسهیلگر کننده استفاده از یادگیری عمیق در سیستمهای مخابراتی سیار
۱۶۰	جدول ۵. خلاصه و مقایسه کتابخانه‌های نرم‌افزاری یادگیری عمیق
۱۶۲	جدول ۶ خلاصه‌سازی و مقایسه مزایا و معایب الگوریتم‌های بهینه‌سازی
۱۶۵	جدول ۷. مقایسه و جمع‌بندی پلتفرم‌های یادگیری عمیق موبایل
۱۸۱	جدول ۸. مقایسه LIS با دیگر فناوری‌های مشابه
۲۲۳	جدول ۹. انتخاب بلوکهای سازنده لایه MAC پس از اجرای الگوریتم یادگیری ماشینی [2]
۲۲۴	جدول ۱۰. پارامترهای شبیه‌سازی برای روش ALOHA-QIR [3]
۲۳۱	جدول ۱۱. پارامترهای شبیه‌سازی [15]
۳۰۶	جدول ۱۲. روش‌های آشکارسازی داده‌های خارج از محدوده در شبکه حسگر بی‌سیم با استفاده از یادگیری ماشینی
۳۲۰	جدول ۱۳. روشهای یادگیری ماشینی ارائه شده برای دسته‌بندی رویدادهای PQD
۳۲۰	جدول ۱۴. روشهای مبتنی بر یادگیری ماشینی در آشکارسازی نفوذ (IDS) برای حفاظت سیستم SCADA
۳۲۱	جدول ۱۵. روشهای مبتنی بر یادگیری ماشینی برای کاربرد در TSA
۳۲۱	جدول ۱۶. روشهای مبتنی بر یادگیری ماشینی برای ارزیابی پایداری ولتاژ (VSA)
۳۳۸	جدول ۱۷. تکنیک‌های یادگیری ماشینی به‌کاررفته در مقالات [۵]
۳۵۸	جدول ۱۸. فهرست کاربردهای شبکه هوشمند و نیازمندی‌های کیفیتی مخابراتی آنها [1]
۳۵۸	جدول ۱۹. فهرستی از فناوری‌های مخابراتی و کاربرد آنها در بخش‌های مختلف شبکه هوشمند [1]

مرحله اول. مطالعات مقدماتی و تطبیقی

مقدمه مرحله اول

این گزارش مربوط به مرحله اول پروژه "آینده‌پژوهی در خصوص سیستم‌های ارتباطی هوشمند و کاربرد آنها در صنعت برق" است که در ۵ فصل ارائه شده است و مطالعات اولیه و تطبیقی را در بر می‌گیرد.

فصل اول به مسائل مرتبط با دسترسی شناخت‌گرایانه به طیف و بخش منعطف رادیویی آن خواهد پرداخت؛ به عبارتی دیگر روش‌های رادیوشناختی (CR)^۱ و رادیونرم‌افزار^۲ و کاربردهای آن در بخش‌های مختلف صنعت برق مورد مطالعه و بررسی قرار می‌گیرد. در این فصل ابتدا به معرفی شبکه‌های CR و شبکه برق هوشمند پرداخته می‌شود و سپس کاربردهای موجود و بالقوه شبکه‌های CR در شبکه برق هوشمند مورد بررسی قرار می‌گیرد. معماری شبکه هوشمند برق مبتنی بر CR و روش‌های حس پهنای باند و پروتکل‌های MAC مبتنی بر CR نیز در ادامه خواهد آمد.

فصل دوم به ارائه و بررسی پروژه‌های انجام شده در دنیا که به هوشمندسازی سیستم‌های ارتباطی خود پرداخته‌اند و قابلیت بکارگیری در صنعت برق دارند، اختصاص یافته است. در این فصل دو پروژه صنعتی به نام‌های SunSeed و SmartEMC2 که در اتحادیه اروپا و معطوف به صنعت برق بوده‌اند، و نیز یک پروژه دانشگاهی که در دانشگاه آلباما و با پشتیبانی پژوهشگاه نیروی هوایی آمریکا صورت گرفته است، مورد بررسی قرار گرفته‌اند. این پروژه دانشگاهی یک نمونه از پیاده‌سازی موفق از روش‌های پیشرفته یادگیری ماشینی بر روی یک سیستم رادیوشناختی می‌باشد که دارای توانایی بالقوه جهت استفاده در سیستم‌های مورد استفاده در صنعت برق که از رادیوشناختی استفاده کنند را داراست.

در فصل سوم ابتدا یک مروری کلی بر روش‌های یادگیری ماشین و البته با یک نگاه عمومی بر آن دسته که تاکنون در سیستم‌های ارتباطی مورد کاربرد قرار گرفته‌اند شده است. در ادامه نتایج مرتبط با مطالعات و بررسی روش‌های AI مورد استفاده در لایه فیزیکی ارائه شده است. در این خصوص به چالش‌های بکارگیری روش‌های یادگیری ماشین در سیستم‌های ارتباطی پرداخته شده است. چند کاربرد از این روش‌ها در مکانیزم‌های موجود در لایه فیزیکی همچون مدولاسیون و کدینگ تطبیقی و انواع مختلف یکسان‌سازها به صورت عمیق مورد بررسی قرار گرفته‌اند.

در فصل چهارم به بررسی کاربردهای AI در استفاده از طیف فرکانسی پرداخته خواهد شد که در واقع ادامه‌ای بر مطالب ارائه شده در فصل اول است. در این فصل ابتدا به چالش‌هایی که در مسائل رادیوشناختی وجود دارد اشاره شده و یک دسته‌بندی از مسائل یادگیری ماشین در این حوزه ارائه شده است. همچنین روش‌های مختلف هوش مصنوعی که در حوزه CR می‌توانند مورد استفاده قرار گیرند به همراه مثالی از کاربرد آن‌ها معرفی شده و مزایا و معایب این روش‌ها با یکدیگر مقایسه شده‌اند. به دلیل نیاز به تصمیم‌گیری و همچنین پویا بودن و عدم قطعیت موجود در دسترسی به طیف در شبکه‌های رادیو شناختی روش‌های مبتنی بر یادگیری تقویتی برای حل این مسائل مناسب‌تر هستند. همچنین به دلیل گستردگی این شبکه‌ها و زیاد شدن وضعیت‌های مسأله، ترکیبی از یادگیری تقویتی و یادگیری عمیق معرفی شده که زمان رسیدن به راهبرد بهینه را در این مسائل کاهش می‌دهد و در عین حال دقت مناسبی نیز دارد. از میان مسائلی که در شبکه‌های مخابراتی وجود دارد، دسترسی پویا به پهنای باند در شبکه‌های رادیو شناختی از اهمیت بیشتری برخوردار می‌باشد که به طور مبسوط به آن پرداخته شده است. همچنین به مسائل دیگری چون همکاری با کاربر متصل شده به شبکه و کنترل نرخ داده نیز اشاره مختصری می‌شود.

فصل پنجم نیز به بررسی ملاحظات و ابزارهای مورد نیاز طراحی سیستمی جهت بکارگیری AI اختصاص داده شده است. در این فصل به دو موضوع محدودیت‌های بکارگیری روش‌های هوش مصنوعی و با تأکید بر یادگیری عمیق در سیستم‌های ارتباطی هوشمند و همچنین ملزومات و ابزارهای مورد نیاز برای پیاده‌سازی آن، پرداخته می‌شود. بخشی از محدودیت‌ها به پیچیدگی محاسباتی روش‌های یادگیری برمی‌گردد که برای حل آن نیاز است که سخت‌افزارهای قوی و با قابلیت پردازش بالا مورد استفاده

¹ CR: Cognitive Radio

² SDR: Software Defined Radio

قرار گیرند. در کنار این سخت‌افزارها، کتابخانه‌های نرم‌افزاری نیز ارائه شده‌اند که این سخت‌افزارها و الگوریتم‌های مورد استفاده در روش‌های یادگیری ماشینی را پشتیبانی می‌کنند. همچنین در صورت استفاده از سخت‌افزارها و نرم‌افزارهای ضعیف، دقت این روش‌ها ممکن است کاهش یابد؛ که در این خصوص روش‌هایی ارائه شده‌اند که می‌توانند حتی با استفاده از سخت‌افزارها و نرم‌افزارهای نه‌چندان قوی هم یادگیری ماشینی را پیاده‌سازی کنند.

فصل ۱

بررسی کاربرد رادیو شناختی در صنعت برق

۱-۱- مقدمه

امروزه شبکه‌های برق قدیمی به سمت شبکه‌های هوشمند در حال تغییر هستند که مشخصه آن‌ها ارتباطات چندجانبه بین قسمت‌های تولید، انتقال، توزیع و مصرف‌کننده می‌باشد. مدیریت هوشمند، قابل اطمینان و موثر شبکه‌های برق پیچیده نیازمند تکنولوژی اطلاعات و ارتباطات قابل اطمینان، سریع و ایمن است تا بتواند مصرف و تولید برق را پایش و کنترل نماید. با وجود چالش‌هایی مانند مصالحه بین پوشش مخابرات بی‌سیم و ظرفیت و همچنین پهنای باند محدود، امیدواری زیادی نسبت به کاربرد شبکه‌های مخابراتی بی‌سیم و در بین آن‌ها شبکه‌های رادیو شناختی^۱ (CR) در شبکه برق هوشمند وجود دارد. در این فصل به مروری بر معماری، ترکیب، کاربردها و تکنولوژی‌های مخابراتی مبتنی بر شبکه‌های CR در شبکه هوشمند برق پرداخته می‌شود. همچنین به روش‌های حس کردن پهنای باند و دسته‌بندی اصلی روش‌های آن و به طور مختصر به مسیریابی و پروتکل‌های MAC مبتنی بر رادیو شناختی اشاره می‌شود.

شبکه‌های برق معمول شبکه‌های متصل بزرگی هستند که به طور گسترده برق را از تولیدکننده به مصرف‌کننده توزیع می‌کنند. توان الکتریکی تنها از نیروگاه‌ها به مصرف‌کننده منتقل شده و اطلاعات تنها در شبکه‌های توزیعی که در داخل یک شهر برق را به مصرف‌کننده می‌رسانند مورد پایش قرار می‌گیرد. این شبکه‌های برق امروزه با چالش‌های جدیدی از جمله افزایش تقاضای انرژی، فرسودگی زیرساخت‌ها، ظهور منابع تجدیدپذیر انرژی و همچنین مسائل مربوط به قابلیت اطمینان و امنیت روبرو هستند. برای حل این مشکلات شبکه‌های برق هوشمند با تکنولوژی‌های بسیار متنوعی در زمینه حسگرها و جمع‌آوری داده، مخابرات، پردازش، کنترل و اتوماسیون پیشنهاد داده شده‌اند [۱-۳].

برخی از ویژگی‌هایی که شبکه‌های هوشمند را از شبکه‌های معمول متمایز می‌کند، سیستم‌های^۲ SCADA، AMI^۳، کنتورهای هوشمند، متعادل نمودن بار با مدیریت آنی تقاضا و قیمت‌گذاری، قرائت کنتور از راه دور، کیفیت توان، مقاوم بودن نسبت به خطا در سیستم و آشکارسازی مصارف غیر مجاز می‌باشند. همچنین شبکه‌های هوشمند از مزایایی مانند تشخیص و ایزوله کردن خطا و بازایی شبکه و خودترمیمی نیز برخوردار هستند [۴-۷].

پایش و مخابرات غیر قابل اطمینان، مسیریابی و توزیع غیر موثر برق، تجهیزات غیر هوشمند در سمت مصرف‌کننده دلایل اصلی هدر رفت انرژی در شبکه‌های قدیمی برق هستند. همچنین در این شبکه‌ها ذخیره انرژی کار بسیار دشواری است که در شبکه‌های برق هوشمند این مشکلات تا حدود زیادی کاهش می‌یابند [۸-۱۱].

تکنولوژی‌های مخابراتی مختلفی می‌توانند برای شبکه‌های برق هوشمند مورد استفاده قرار گیرند که از این بین می‌توان به PLC^۴ اشاره نمود که از زیرساخت سیم‌کشی موجود در شبکه برق برای توزیع استفاده می‌کند. با این حال، ایجاد اختلال الکترومغناطیسی در این خطوط از چالش‌های اصلی است. پیشرفت‌های مستمر در شبکه‌های مخابراتی بی‌سیم، توانسته با حذف سیم‌کشی این گزینه را برای برخی از کاربردها در شبکه هوشمند برق مناسب سازد. شبکه‌های بی‌سیم بخصوص برای بردهای کوتاه و نرخ انتقال داده‌های پایین ترجیح داده می‌شوند [۱۲، ۱۳]. همچنین شبکه‌های حسگر بی‌سیم (WSN^۵) نیز با طراحی و پیاده‌سازی مناسب گره‌های حسگر می‌توانند برای کاربردهای شبکه برق هوشمند به کار روند [۱۴-۱۶].

شبکه‌های بی‌سیم معمول از رویه تخصیص پهنای باند ثابتی استفاده می‌کنند که منجر به استفاده غیر بهینه از پهنای باند خواهد شد. رادیو شناختی که بر پایه اصول دسترسی دینامیک به پهنای باند (DSA)^۶ کار می‌کند، قسمت‌هایی از پهنای باند را

^۱ Cognitive Radio^۲ Supervisory control and data acquisition^۳ Advanced metering infrastructure^۴ Power Line Communication^۵ Wireless Sensor Network^۶ Dynamic spectrum access

که توسط کاربران دارای مجوز استفاده نشده است را شناسایی کرده و کانال بهینه را برای مخابره اطلاعات به گونه‌ای تخصیص می‌دهد که با کانال‌های ارتباطی دیگر تداخلی نداشته باشد [۱۷]. پس از شناسایی باندهای خالی، استفاده از پهنای باند می‌تواند با اشتراک پهنای باند به صورت مکانی و زمانی بهبود یابد [۱۸، ۱۹]. کاربردهای شبکه هوشمند برق بخصوص در زمینه مدیریت عرضه و تقاضا نیازمند ارتباطات ماشین به ماشین است. با زیاد شدن تعداد ادوات، پهنای باند به سرعت پر می‌شود و تکنولوژی رادیو شناختی می‌تواند گزینه مناسبی برای کاهش کمبود پهنای باند در شبکه برق هوشمند باشد [۲۰، ۲۱].

مقالات زیادی به مرور کاربردهای خاصی از شبکه‌های CR در شبکه هوشمند پرداخته‌اند [۲۲-۲۴] و مرجع [۲۵] نیز تحلیل جامعی از شبکه هوشمند مبتنی بر CR دارد. در این گزارش ابتدا به معرفی شبکه‌های CR و شبکه برق هوشمند پرداخته می‌شود. سپس کاربردهای موجود و بالقوه شبکه‌های CR در شبکه برق هوشمند مورد بررسی قرار می‌گیرد. معماری شبکه هوشمند برق مبتنی بر CR و روش‌های حس پهنای باند و پروتکل‌های MAC مبتنی بر CR نیز در ادامه خواهد آمد.

۲-۱- معرفی شبکه‌های رادیو شناختی و شبکه برق هوشمند

۱-۲-۱- شبکه رادیو شناختی

یک شبکه CR از ادوات CR تشکیل شده که قابلیت شناخت و پیکربندی مجدد را دارند و می‌توانند پارامترهای فرستنده خود را با توجه به محیطی که در آن کار می‌کنند تغییر دهند. در شبکه CR دو نوع کاربر وجود دارد: ۱) کاربران اولیه^۱ که کاربران دارای مجوز هستند و می‌توانند از پهنای باند از قبل تعیین شده‌ای استفاده کنند. ۲) کاربران ثانویه^۲ که کاربران بدون مجوز هستند و پهنای باند مشخصی ندارند. این کاربران به دنبال پهنای باند دارای مجوز یا بدون مجوز هستند و تنها در صورتی می‌توانند از پهنای باند استفاده کنند که تداخلی با کاربران اولیه نداشته باشند [۱۸، ۲۶].

چهار نوع عملکرد برای ادوات رادیو شناختی وجود دارد که عبارتند از: ۱) حس کردن پهنای باند شامل تشخیص پهنای باند استفاده نشده و حضور کاربران اولیه. ۲) مدیریت پهنای باند که شامل انتخاب بهینه کانال‌های در دسترس بر مبنای قدرت سیگنال دریافتی، تداخل، بازدهی انرژی، توان انتقالی، تعداد کاربران، کیفیت خدمات و الزامات امنیتی است. ۳) جابجایی پهنای باند که ارتباطات را بدون قطع شدن حفظ می‌کند و کانال را پس از تشخیص و آشکارسازی یک کاربر اولیه تخلیه می‌نماید. ۴) اشتراک پهنای باند که اتصال چندین رادیو شناختی را هدایت کرده و بر تخصیص توان متمرکز است [۱۸، ۲۲].

به طور کلی می‌توان مخابرات رادیو شناختی را به سه دسته کلی تقسیم‌بندی نمود که عبارتند از: ۱) در هم آمیخته^۳ که در آن کاربر ثانویه تنها در صورتی می‌تواند از پهنای باند استفاده کند که کاربر اولیه‌ای فعال نباشد. در صورت حضور کاربر اولیه، فعالیت‌های کاربر اولیه به طور پیوسته رصد می‌شود تا از تداخل با کاربر ثانویه جلوگیری شود. ۲) زیرلایه^۴ که در آن کاربران ثانویه اطلاعات را با توان کمی بدون توجه به فعالیت کاربر اولیه ارسال می‌کنند. توان ارسالی آنقدر کم است که زیر سطح نویز مخابرات کاربران اولیه قرار می‌گیرد. دو دسته اولی معمولاً داده‌های با نرخ پایین و بردهای کوتاهی دارند و بیشتر برای محیط‌های داخل منازل مناسب هستند. ۳) رولایه^۵ که در آن کد و پیام برای تشخیص کاربر اولیه استفاده شده و از تداخل جلوگیری می‌کند. در این حالت کاربر ثانویه می‌تواند در هر سطح توانی ارسال کند و با پیام‌هایی که از کاربران غیر رادیو شناختی دریافت می‌شود، امکان

^۱Primary user

^۲Secondary user

^۳Interweave


^۴Underlay

^۵Overlay

جبران تداخل وجود دارد. این دسته دارای نرخ بالای داده، امنیت و قابلیت اطمینان هستند و برای بردهای بیشتری نسبت به دو دسته قبلی مورد استفاده قرار می‌گیرند [۲۷، ۱۸].

۲-۱- شبکه برق هوشمند

شبکه برق هوشمند که نسل بعدی شبکه برق است علاوه بر منابع فعلی از منابع تجدیدپذیر نیز استفاده می‌نماید. مراکز کنترلی هوشمند با استفاده از فناوری‌های ارتباطی جدید امکان پایش و تعامل آنی با وسایل الکتریکی هوشمند از راه دور را دارند. دامنه عملکرد شبکه هوشمند شامل نیروگاه‌های تولید برق، شبکه انتقال و توزیع می‌باشد. در شبکه‌های قدیمی برق ارتباطات یک طرفه و از سمت ارائه دهنده خدمات به مشترکین است در حالی که در شبکه هوشمند برق ارتباطات دو طرفه است و مشترکین از قیمت‌گذاری آنی ناشی از مدیریت تقاضا بهره‌مند می‌شوند که منجر به صرفه‌جویی در مصرف برق و قیمت‌گذاری مناسب‌تر می‌گردد [۲۸، ۴، ۲]. همان‌طور که در شکل ۱ نشان داده شده است یک شبکه برق هوشمند از سه قسمت اصلی شبکه ناحیه خانگی HAN^1 ، شبکه ناحیه همسایگان NAN^2 و شبکه ناحیه وسیع WAN^3 تشکیل شده است. شبکه HAN کنترلهای هوشمند را به وسایل خانگی، شارژر خودروهای برقی، منابع انرژی توزیع شده و پنل‌های خورشیدی متصل می‌نماید. شبکه NAN اطلاعات کنترلهای و خدمات را از چندین شبکه HAN جمع‌آوری کرده و به یک درگاه یا نقطه جمع‌آوری داده که معمولاً یک ایستگاه برق یا دکل مخابراتی است انتقال می‌دهد. این درگاه شبکه NAN را به شبکه بالاتر یعنی WAN متصل می‌نماید. شبکه WAN به عنوان زیرساخت مخابرات بین درگاه‌ها و شبکه‌های NAN به کار رفته و مخابرات سیمی و بی‌سیم هر دو می‌تواند برای نیازهای مخابراتی در آن به کار رود [۲۹، ۲۶، ۱۸].



شکل ۱. معماری شبکه هوشمند برق شامل HAN ، NAN و WAN [۲۶]

¹ Home Area Network

² Neighborhood Area Network

³ Wide Area Network

۳-۲-۱- چالش‌های مخابراتی مختص شبکه برق هوشمند

چالش‌های اصلی و اختصاصی برای مخابرات در شبکه برق عبارتند از:

- (۱) شرایط سخت مخابرات بی‌سیم: همان‌طور که در شکل ۱ نشان داده شده است، شبکه برق محدوده وسیعی از داخل خانه تا نواحی بیرون از خانه در همسایگی و ایستگاه‌های توزیع برق را در بر گرفته است. یک چالش اصلی شبکه‌های مخابراتی در نزدیکی تجهیزات توان بالای برق است که معمولاً شامل سیم‌پیچ می‌باشند. این سیم‌پیچ‌ها می‌توانند مانند یک آنتن عمل کنند و با انتشار امواج الکترومغناطیسی با شبکه‌های مخابراتی بی‌سیم ایجاد تداخل نمایند [۳۰]. بویژه نویز ضربه و تغییرات توان بالا در سوئیچ‌های قدرت می‌تواند مخابرات بی‌سیم را قطع نماید [۳۱-۳۶]. علاوه بر این مخابرات بی‌سیم از وسایل داخل خانه تا کنتورهای بیرون از خانه می‌تواند دچار افت مسیر زیادی شوند [۳۷-۳۹].
- (۲) مخابرات قابل اطمینان و با تاخیر کم: برخی از کاربردهای کلیدی در شبکه هوشمند برق نیازمند کیفیت خدمات مخابرات دقیقی هستند. برای مثال، کنترل پاسخ به تقاضا، عملیات وسایل خانگی و اداری را برای کاهش تقاضا روی شبکه برق تنظیم می‌کند. بویژه در کنترل بار مستقیم، واحد تولیدی مصرف برق را کنترل می‌نماید، در نتیجه مخابرات دوطرفه قابل اطمینان برای پایش و کنترل شبکه برق لازم است [۴۰، ۴۱]. همچنین برای پایش و کنترل شبکه برق به انتقال اطلاعات با تاخیر پایین نیاز است [۴۲-۴۴].
- (۳) ساختار نامتوازن شبکه و ترافیک: شبکه برق در نواحی مختلفی که جمعیت‌های متفاوتی دارند گسترده شده است. چگالی شبکه در نقاط شهری بالا و در منطق حومه شهر و روستایی پایین است. شبکه مخابراتی شبکه هوشمند باید بتواند همه این مناطق را پوشش دهد. از طرفی نرخ داده در شبکه برق بسیار وسیع است و از چند ده یا صد بیت در دقیقه تا نرخ‌های بالا برای ارسال اطلاعات تصویری را دارا می‌باشد [۴۵].

۴-۲-۱- انگیزه‌های استفاده از رادیوشناختی در شبکه برق هوشمند

شبکه‌های CR قابلیت حمایت از گستره وسیعی از کاربردهای مخابراتی را دارند و ممکن است برای بسیاری از نیازهای مخابراتی شبکه برق هوشمند گزینه مناسبی باشند. در ادامه لیستی از مواردی که منجر به ترغیب استفاده از شبکه‌های CR در شبکه برق هوشمند می‌شوند، ارائه شده است.

- بسیاری از شبکه‌های بی‌سیم مانند Zigbee، Bluetooth و Wi-Fi در فرکانس 2.45 GHz در باند ISM¹ کار می‌کنند. همچنین بسیاری از وسایل خانگی که امواج الکترومغناطیسی قوی تولید می‌کنند و تجهیزات برق قدرت نیز در این باند تولید نویز می‌کنند. از طرفی کنتورهای هوشمند شبکه برق نیز به دلایل اقتصادی معمولاً در همین فرکانس ساخته می‌شوند. در نتیجه وجود تداخل بین وسایل خانگی و کنتورها و رقابتی که ممکن است بین کنتورهای مختلف برای ارسال داده ایجاد شود باعث به خطر افتادن مخابرات قابل اطمینان در شبکه هوشمند برق می‌شود. با این حال وسایل متنی بر CR می‌توانند برای حل مشکل تداخل در مخابرات HAN به کار گرفته شوند [۲۲، ۴۶].
- یکی از چالش‌های اصلی برای شبکه‌های مخابراتی موجود، جمع‌آوری و انتقال حجم بالای داده مربوط به انرژی الکتریکی است. شبکه‌های مبتنی بر CR می‌توانند به جمع‌آوری و انتقال حجم‌های بالای داده همزمان با بهبود استفاده از پهنای باند کمک کنند.

¹ Industrial Scientific Medical (ISM)

- معماری مخابرات شبکه هوشمند نواحی خانگی، نواحی همسایگی و نواحی وسیع را پوشش می‌دهد. رادیو شناختیهای هوشمند با سخت‌افزارهای قابل پیکربندی مجدد می‌توانند به مدیریت مخابرات در هر یک از این نواحی و در فواصل مختلف کمک کنند.
 - انتقال مبتنی بر CR می‌تواند لینک‌های مخابراتی اختصاصی کم تاخیری را برای داده‌های حساس به زمان شبکه هوشمند فراهم نماید [۴۷, ۴۸].
 - ادوات رادیو شناختی محیط را حس کرده و به طور بهینه سطوح توان ارسالی را تنظیم می‌کنند در نتیجه ممکن است بتوانند توان مصرفی و هزینه عملکرد را کاهش دهند.
 - پهنای باند خالی تلویزیون^۱ (TVWS) می‌تواند انتشار سیگنال در محیط داخل خانه را نسبت به باند 2.45 GHz بهبود داده و از کاهش پهنای باند جلوگیری نماید. همچنین مصرف توان در فرکانس‌های پایین تر TVWS، به طور معمول کم تر است. استفاده از شبکه‌های CR که بتوانند از باندهای خالی TVWS استفاده کنند منجر به پهنای باند بالا در سیستم‌های AMI در شبکه‌های NAN خواهد شد [۴۹, ۵۰].
 - در شبکه‌های WAN، حسگرها و کنتورهای زیادی برای پایش نواحی وسیع وجود دارد که جمع‌آوری داده را مشکل می‌کند. معماری شبکه WAN مبتنی بر CR که بر پایه استاندارد IEEE 802.22 WRANs می‌باشد می‌تواند جمع‌آوری داده در شبکه WAN را حمایت کند [۵۱].
 - در صورتی که از TVWS استفاده شود، درگاه و کنتورهای هوشمند ثابت باقی می‌مانند و حداکثر به 4W توان ارسالی برای حالت ثابت نیاز خواهند داشت. توان بالای ارسالی و همچنین مشخصات انتشاری بهتر در باند تلویزیون منجر به اتصال بهتر کنتورهای هوشمند می‌گردد. علاوه بر این دسترسی گسترده به کانال‌های TVWS در مناطق روستایی می‌تواند کمبود پهنای باند را کاهش دهد [۲۹].
 - مدیریت پاسخ به تقاضا با استفاده از کنتورهای برق چند نرخ و کاهش بار از ویژگی‌های مهم شبکه برق هوشمند است. اما این مهم تنها در صورت وجود مخابرات قابل اطمینان و به موقع محقق می‌شود که مخابرات مبتنی بر رادیو شناختی می‌تواند این امکان را فراهم نماید [۵۲].
 - شبکه‌های برق هوشمند آینده شامل نیروگاه‌های تولید توزیع شده مانند سلول‌های خورشیدی و توربین‌های بادی هستند که معمولاً در نقاط دوردستی قرار دارند. استفاده موفق از این توان الکتریکی به میزان زیادی به تضمین کیفیت توان بستگی دارد. رضایت از کیفیت توان نیازمند همکاری قسمت‌های مختلفی در شبکه برق هوشمند است. این همکاری نیز احتیاج به روش‌های مخابراتی مقیاس‌پذیر و انعطاف‌پذیر دارد و شبکه‌های CR یکی از گزینه‌های بالقوه است [۵۲, ۵۳].
- قطعی برق و کیفیت توان پایین اثرات اقتصادی بدی دارند. یکی از دلایل ایجاد این مشکلات پایش ضعیف سیستم-های شبکه برق است. از آنجا که شبکه برق در مناطق وسیعی گسترده شده، روش‌های مخابراتی مؤثر با مشخصات عملکردی خوب مانند نرخ داده بالا، تاخیر کم، احتمال پایین وقوع خطا در قیمت مناسب مورد نیاز است. در نتیجه شبکه‌های CR می‌توانند در کاهش قطعی و بهبود کیفیت توان مؤثر باشند [۵۲, ۵۳].

^۱ TV White Space

۵-۲-۱- استانداردسازی رادیو شناختی در شبکه برق هوشمند

در بخش قبل از انگیزه‌ها، کاربردها و مزایای بالقوه رادیوشناختی در شبکه برق هوشمند صحبت شد. در این بخش به کاربردهای بالفعل و استانداردسازی در این زمینه اشاره می‌شود. معمولاً استانداردسازی در مقوله‌ای انجام می‌گیرد که کارشناسان بر مزایای استفاده از آن اتفاق نظر دارند اما ممکن است به صورت‌های مختلفی پیاده‌سازی شود که برای یکسان‌سازی، استاندارد مناسبی برای آن ارائه می‌گردد. استانداردسازی در شبکه برق هوشمند سعی در ایجاد یک مدل داده کاربردی واحد برای شبکه برق هوشمند دارد تا تضمین کند رابط‌های شبکه هوشمند، پیام‌ها و جریان‌های کاری با یکدیگر به خوبی تعامل می‌کنند. علاوه بر تعامل، ایجاد یک مجموعه فشرده از پروتکل‌ها، برقراری امنیت اطلاعات و افزایش ایمنی ادوات و سیستم‌های شبکه هوشمند از دیگر اهداف فعالیت‌های استانداردسازی است. در این خصوص در جهان فعالیت‌هایی توسط پلتفرم فناوری اتحادیه اروپا و موسسه ملی استانداردهای ایالات متحده آمریکا در حال انجام است [۵۴، ۵۵].

استاندارد IEEE 802.22 از لحاظ تاریخی اولین استاندارد در حوزه رادیوشناختی می‌باشد. این استاندارد برای فناوری رادیوشناختی در شبکه‌های ^۱WRAN اختصاص داده شده که در باند TVWS کار می‌کند. این استاندارد مخابرات برد بلند، پهن‌بند و توان بالا را تحت حمایت دارد. تنظیم قوانین رادیویی به ادوات رادیوشناختی اجازه می‌دهد تا از قسمت‌های ^۲VHF و ^۳UHF از باند TVWS استفاده کنند. این استاندارد فواصل ۱۰ تا ۱۰۰ کیلومتر را پوشش می‌دهد و از آنجا که شبکه برق هوشمند مقیاس وسیعی دارد می‌تواند برای این شبکه یکی از گزینه‌ها باشد [۴۸].

استانداردسازی شبکه‌های وسایل هوشمند ^۴(SUN) در باند TVWS منجر به دو استاندارد IEEE 802.15.4g و IEEE 802.15.4e شد که به ترتیب در مورد لایه فیزیکی و لایه ^۵MAC در استاندارد IEEE 802.15.4 هستند. این استاندارد نرخ داده‌هایی از 40 kb/s تا 1000 kb/s را مورد نظر دارد. استانداردسازی باند TVWS همچنین توسط دیگر گروه‌ها از جمله کمیته‌های IEEE 802.11 af و IEEE 802.11 ah مورد بررسی قرار گرفته تا استاندارد IEEE 802.11 برای عملکرد شبکه WLAN در باند TVWS ایجاد شود. گروه Weightless نیز بر روی استانداردهای مخابرات ماشین به ماشین در باند TVWS فعالیت دارند. این استاندارد برای تراشه‌های کم توان با قیمت پایین ایجاد شده که می‌تواند در شبکه برق هوشمند نیز کاربرد داشته باشد [۵۶، ۵۷].

۳-۱- نمونه‌های استفاده از شبکه رادیو شناختی در شبکه هوشمند برق

در این قسمت چهار نمونه از کاربرد مخابرات CR در شبکه برق هوشمند ارائه شده است که عبارتند از:

(۱) مخابرات ماشین به ماشین رادیو شناختی در شبکه‌های AMI [۲۰]: در این نمونه پروتکل MAC مبتنی بر PRMA^۶ برای ایجاد الگوریتم زمان‌بندی برای کنتور هوشمند مورد بررسی قرار گرفته است. کنتورهای هوشمند در سمت مصرف‌کننده قرار داده شده و با یک باس تکی (Single Bus) متصل می‌شوند. یک نقطه دسترسی که قادر به حس کردن پهنای باند است اتصال را برای همه کنتورهای هوشمند فراهم می‌کند.

^۱ Wireless Regional Area Network

^۲ Very High Frequency

^۳ Ultra High Frequency

^۴ Smart Utility Networks

^۵ Medium Access Control

Packet Reservation Multiple Access


- (۲) رمزنگاری داده در شبکه‌های حسگر بی‌سیم مبتنی بر رادیو شناختی [۲۸]: در این مطالعه قابلیت اطمینان انتقال داده حسگر مبتنی بر رادیو شناختی در نظارت شبکه برق بررسی شده است. دمای اندازه‌گیری شده بر روی شبکه حسگر مبتنی بر CR مخابره شده تا آتش‌سوزی کابل‌ها مشخص شده و مدیریت پاسخ به تقاضای قابل اطمینانی به دست آید. نتایج نشان می‌دهد که رمزنگاری داده حسگر نظارتی برای یک نظارت قابل اطمینان در شبکه هوشمند مفید است.
- (۳) تحلیل قابلیت اطمینان گره‌های حسگر بی‌سیم مبتنی بر رادیو شناختی [۵۸]: در این بررسی ارزیابی عملکرد نرخ تحویل بسته‌های داده و متوسط زمان دریافت بسته در نظر گرفته شده است. مشاهده شده که افزایش مدت زمان حس کردن پهنای باند و احتمال حضور کاربر اولیه، نرخ تحویل بسته را کاهش می‌دهد. همچنین افزایش فعالیت کاربر اولیه مدت زمان متوسط دریافت بسته را افزایش می‌دهد.
- (۴) زمان‌بندی ترافیک بر پایه اولویت و بهینه‌سازی وسیله: در [۵۳] تخصیص کانال CR و زمان‌بندی مبتنی بر اولویت برای سیستم‌های شبکه هوشمند مبتنی بر CR مورد بررسی قرار گرفته است. روش زمان‌بندی برای ترافیک شبکه هوشمند ناهمگون شامل دستورات کنترلی، داده صوتی-تصویری حسگرها و قرائت کنتورها طراحی شده است. این روش خطاهای سوئیچ کانال و حس کردن پهنای باند را برای بهینه کردن سیستم مد نظر قرار داده است. داده‌های ترافیکی به ترتیب الویت به سه دسته تقسیم شده‌اند: (۱) داده‌های با اولویت بالا که پیام‌های بین گره‌ها و مرکز کنترل به منظور کنترل، حفاظت و مدیریت را شامل می‌شود. (۲) داده‌های پایش ارسالی از حسگرها شامل داده‌های نظارتی صوتی-تصویری (۳) داده قرائت کنتورها

۴-۱- کاربردهای بالقوه و قابلیت‌های رادیو شناختی در شبکه هوشمند

همان‌طور که در نمودار شکل ۲ نشان داده شده است کاربردهای مخابرات CR در شبکه هوشمند را می‌توان به کاربرد در سه حوزه HAN، NAN و WAN تقسیم نمود.

۴-۱-۱- کاربردها در شبکه خانگی

شبکه HAN، مخابرات را در بخش کاربران انتهایی معماری شبکه هوشمند فراهم می‌کند. یکی از کاربردهای معمول مخابرات CR در HAN، سیستم‌های مدیریت انرژی خانگی^۱ (HEM) است. این سیستم‌ها اتوماسیون و کنترل وسایل خانگی را فراهم کرده و با وسایل هوشمندی مانند کنتورهای هوشمند و نمایشگرهای خانگی هوشمند در ارتباطند. این سیستم‌ها با کنترل بهینه و متعادل نمودن بار می‌توانند منجر به کاهش هزینه‌ها شوند. در بخش صنعتی و تجاری نیز این سیستم‌ها برای اتوماسیون ساختمان، گرمایش، تهویه هوا، کنترل برق متناوب ولتاژ بالا و مدیریت انرژی صنعتی کاربرد دارند. یک HAN توسط یک کنتور هوشمند یا درگاه اینترنتی به دیگر خدمات یا سرویس‌دهندگان شبکه هوشمند متصل می‌شود. عملکرد موثر و قابل اطمینان سیستم‌های HEM نیازمند انتقال اطلاعات بلادرنگ و آنی است؛ در نتیجه شبکه CRN می‌تواند در اشتراک اطلاعات بلادرنگ بین سیستم‌های HEM مفید باشد [۵۹، ۶۰].



شکل ۲. تقسیم بندی کاربردهای مخابرات CR در شبکه هوشمند [۲۶]

۲-۴-۱- کاربردها در شبکه همسایگی

شبکه NAN اطلاعات کاربران در شبکه‌های HAN مجاور را جمع‌آوری نموده و این داده‌ها را به WAN منتقل می‌کند. برخی از کاربردهای شبکه هوشمند که در NAN انجام می‌شود عبارتند از قرائت کنتور، اتوماسیون توزیع و مدیریت خاموشی برق، نرخ انتقال داده و مسافت‌های تحت پوشش محدوده وسیعی را پوشش می‌دهد. یک شبکه CRN می‌تواند در موارد زیر گزینه مناسبی برای کاربرد در NAN باشد:

- (۱) قرائت کنتور: قرائت کنتور جمع‌آوری داده از کنتورهای هوشمند و انتقال آن به یک پایگاه داده مرکزی برای صدور صورتحساب یا تحلیل داده است. سه نوع قرائت کنتور وجود دارد: (۱) زمان نیاز^۱، که هنگامی که به این داده احتیاج است قرائت می‌شود. (۲) برنامه‌ریزی شده^۲: قرائت کنتور در بازه‌های زمانی از قبل تعیین شده انجام می‌شود. (۳) انتقال حجیم^۳، که همه کنتورها در یک منطقه مشخص قرائت می‌شوند. یک شبکه CRN می‌تواند در هر سه نوع قرائت کنتور انتقال اطلاعات را انجام دهد [۶۰].
- (۲) قیمت‌گذاری: اطلاعات قیمت به کنتورهای هوشمند یا وسایل هوشمند مخابره می‌شود که این اطلاعات به سه دسته، قیمت در زمان مصرف^۴، قیمت لحظه‌ای^۵ و قیمت در پیک^۶ مصرف تقسیم می‌شود. یک کنتور هوشمند می‌تواند با توجه به اطلاعات قیمت خدمات را قطع یا وصل نماید. همچنین ارائه‌دهندگان خدمات می‌توانند صورتحساب کاربران خود را محاسبه کرده و در صورت لزوم اقدامات لازم مانند ارسال پیام هشدار را انجام دهند [۶۰، ۶۱].
- (۳) مدیریت پاسخ به تقاضا: با استفاده از مدیریت پاسخ به تقاضا، ارائه‌دهندگان خدمات با وسایل هوشمند در سمت مصرف-کننده خانگی ارتباط داشته و بار روی شبکه توزیع را در زمان پیک مصرف کاهش می‌دهند. با این حال ارتباطات دو طرفه قابل اطمینان بین ارائه‌دهنده خدمات و کنترل‌کننده‌ای که در منازل مصرف‌کنندگان وجود دارد لازم و ضروری است [۴۱].
- (۴) اتوماسیون توزیع: اتوماسیون توزیع شامل پایش و کنترل شبکه توزیع می‌شود که اطلاعات عملکرد لحظه‌ای از تجهیزات توزیع مانند کنترل‌کننده‌های بانک خازنی، آشکارسازهای خطا، سوئیچ‌ها و تنظیم‌کننده‌های ولتاژ را فراهم می‌کند. نیازهای مخابراتی در بخش توزیع ممکن است از واحدی به واحد دیگر متفاوت باشد که شبکه‌های CRN این انعطاف پذیری را دارند [۶۰].
- (۵) مدیریت خاموشی و بازیابی: قطعی برق تبعات منفی اقتصادی به همراه دارد اما به دلیل نقص تحلیل خودکار معمولاً به صورت لحظه‌ای آشکارسازی نمی‌گردد. گره‌های رادیو شناختی می‌توانند در ناحیه وسیعی در سیستم‌های شبکه توزیع استفاده شده و قطعی برق را پایش نمایند. همچنین این تجهیزات می‌توانند افزایش یا کاهش ولتاژ را نیز گزارش نمایند [۶۰، ۶۲].
- (۶) اشتراک‌گذاری اطلاعات کاربران: کاربردهای اشتراک‌گذاری اطلاعات کاربران به کاربران اجازه می‌دهد تا از حساب و مصرف انرژی خود مطلع شوند. وسایل CR می‌توانند در انتقال اطلاعات کاربران از منازل به پایگاه داده مرکزی و بالعکس مفید باشند. اطلاعات کاربران می‌تواند در پیش‌بینی و استراتژی متعادل کردن بار شبکه برق مفید باشد [۵۸، ۶۰].
- (۷) سیستم‌های SCADA برای صنایع و سیستم‌های برق مدرن بسیار مهم هستند و سیستم SCADA مبتنی بر مخابرات رادیو شناختی با استاندارد IEEE 802.22 نیز ارائه شده است [۶۲، ۶۳].
- (۸) کاربردهای مولتی مدیا در شبکه هوشمند: شبکه بی‌سیم عملگرها و حسگرهای مولتی مدیا مانند نظارت تصویری می‌تواند در پایش واحدهای تولیدی، تجهیزات انتقال و توزیع و مصرف‌کنندگان مفید باشد. این کاربردهای مولتی‌مدیا پهنای باند زیادی نیاز دارند که می‌تواند توسط شبکه‌های CRN فراهم گردد [۵۱، ۶۴].

On- demand^۱

Scheduled^۲

Bulk transfer^۳

Time of Use (TOU)^۴

Real Time Pricing (RTP)^۵

Critical Peak Pricing (CPP)^۶

۳-۴-۱- کاربردها در شبکه ناحیه گسترده

- (۱) کاربردها در تولید برق: برای جلوگیری از سرریز در شبکه برق و متعادل نمودن عرضه و تقاضا، تولید برق می‌تواند در منابع تجدیدپذیر توزیع شده مانند سلول‌های خورشیدی و توربین‌های بادی در نزدیکی مصرف‌کنندگان خانگی انجام گیرد. با این حال سیستم‌های تولید برق معمولاً در نقاط دور هستند و نیازمند انتقال به ایستگاه‌های توزیع هستند. همچنین تولید توزیع شده تنها در صورتی امکان‌پذیر است که کیفیت توان، ولتاژ و ثبات فرکانس اندازه‌گیری و تحلیل شود. کاربردهای پایش از راه دور برای سیستم‌های تولید برق به دلیل شلوغی زیاد در پهنای باند غیر مجوزدار پرچالش است و در این زمینه مخابرات CR می‌تواند در بهبود پایش از راه دور تولید برق توزیع شده کمک کند [۵۸، ۲۲].
- (۲) پایش کنترل و حفاظت ناحیه وسیع: کنترل ناحیه وسیع شامل پایش داده‌های لحظه‌ای از گروهی از ادوات الکترونیکی هوشمند و واحدهای اندازه‌گیری فازوری (PMU) است. حفاظت ناحیه وسیع به صورت کاملاً خودکار حفاظت را در مقابل خاموشی وسیع یا حوادث ناخواسته را انجام می‌دهد [۵۹، ۶۰]. کنترل ناحیه وسیع نه تنها ادوات تولید، انتقال و توزیع شبکه را پایش می‌کند بلکه تراسفورماتورها، بانک‌های خازنی و وسایل حفاظت از شبکه را نیز رصد می‌نماید. بسیاری از تکنولوژی‌های مخابراتی مجوزدار و غیر مجوزدار می‌توانند برای این منظور به کار روند. با این حال باندهای مجوزدار هزینه‌بر هستند. تکنولوژی‌های غیر مجوزدار نیز با این که هزینه کم و راه‌اندازی آسانی دارند ولی در شبکه برق به دلیل تداخل عملکرد ضعیفی دارند. در نتیجه شبکه‌های CRN می‌توانند با دسترسی پهنای باند بهینه گزینه جذابی برای پایش، کنترل و حفاظت ناحیه وسیع در شبکه‌های هوشمند باشند [۲۲].
- (۳) پایش خطوط برق: خط انتقال برق با حوادث زیادی از جمله اصابت رعد و برق، یخبندان، طوفان‌ها، رانش زمین، برخورد پرندگان و گرمشدگی بیش از حد مواجه هستند. ذات گستردگی خطوط برق چالش‌های زیادی برای شبکه حسگرهای بی‌سیم ایجاد می‌کند که می‌توان به تعمیر و نگهداری، تنظیم قوانین پهنای باند، تداخل الکترومغناطیسی و محوشدگی^۱ اشاره نمود. مخابرات مبتنی بر CR می‌تواند برای پایش خطوط برق و ایستگاه‌ها با هزینه‌کرد بهینه مورد استفاده قرار گیرد [۲۲، ۶۳، ۶۵، ۶۶].

۴-۴-۱- کاربردهایی در معماری‌های ارتباطی ترکیبی


- (۱) زیرساخت پیشرفته اندازه‌گیری (AMI): AMI یک سیستم اندازه‌گیری و جمع‌آوری داده است که شامل کنتورها و دیگر وسایل هوشمند در سمت مصرف‌کننده، شبکه‌های مخابراتی بین مصرف‌کننده و ارائه دهنده خدمات و سیستم‌های مدیریت داده است. داده جمع‌آوری شده حائز اهمیت بوده و حجم بالایی دارد در نتیجه زیرساخت مخابراتی قابل اطمینان، ایمن، مقیاس‌پذیر و کم هزینه مورد نیاز است. معمولاً در شبکه‌های AMI به دلیل تعداد بالای کنتورهای هوشمند و نقاط دسترسی از شبکه مش استفاده می‌شود. در نقاط شهری باند ISM توسط وسایل زیادی مورد استفاده قرار می‌گیرد و این مساله مخابرات بین اجزای شبکه AMI را دچار تداخل می‌کند. پهنای باند پرازدحام ناهمگون عملکرد را کاهش داده و منجر به تاخیر زیاد و از دست رفتن بسته‌های داده می‌شود و امنیت و قابلیت اطمینان را خدشه دار می‌کند. سیستم‌های مخابراتی مبتنی بر CR در مقایسه با دیگر شبکه‌های بی‌سیم ناهمگون می‌توانند باعث افزایش قابلیت اطمینان، امنیت و بازدهی شبکه شوند [۴۸، ۵۸، ۶۵].
- (۲) ترکیب با رایانش ابری: یک مرکز داده ابری می‌تواند به آسانی و در زمان نیاز شبکه هوشمند برق را به منابع رایانشی قابل پیکربندی از جمله شبکه‌ها، سرورها و ذخیره‌کننده‌ها متصل نماید. در زیرساخت کم هزینه Net-AMI آتن‌های

^۱Fading

اضافه‌ای برای مخابرات CR بر روی دکل‌های مخابرات سلولی موجود نصب می‌شود تا کنتورهای AMI توسط آنها به مرکز داده ابری متصل شوند. این مرکز رایش ابری خدمات و پروتکل‌هایی را برای بهینه‌سازی عملیات شبکه برق هوشمند ارائه می‌دهد [۶۷].

۵-۱- پیاده‌سازی و توپولوژی رادیو شناختی در شبکه برق هوشمند

با توجه به ساختار سه لایه سلسله مراتبی که در شکل ۳ نشان داده شده است مخابرات مبتنی بر CR می‌تواند در سه لایه HAN، NAN/FAN و WAN با شبکه برق هوشمند ترکیب شود. هدف از این بخش ارائه نحوه پیاده‌سازی CR در شبکه هوشمند و معرفی اجزای آن و توپولوژی شبکه است که در سه حوزه HAN، NAN و WAN مورد بررسی قرار گرفته است.



شکل ۳. معماری سه لایه شبکه برق هوشمند و درگاه‌های ارتباطی در هر لایه [۲۶]

۱-۵-۱- توپولوژی شبکه خانگی

توپولوژی HAN ممکن است به صورت مش یا ستاره باشد و تکنولوژی‌های مختلف سیمی مانند PLC یا بی‌سیم مانند Bluetooth، Zigbee و WiFi در آن به کار رود؛ در نتیجه لازم است که یک درگاه قابل انعطاف برای مدیریت ارتباطات در یک HAN و همچنین بین HAN‌های مختلف مورد استفاده قرار گیرد. در منزل کنتورهای هوشمند، وسایل کنترل بار، وسایل شارژ خودروهای برقی و وسایل خانگی دیگری وجود دارد که درگاه HAN (HGW^1) باید بتواند با فناوری‌های مختلف در ارتباط بوده و اطلاعات مربوط به مصرف توان آنها را به صورت دوره‌ای جمع‌آوری نماید و به درگاه NAN منتقل نماید. همچنین

¹ HAN Gateway

اطلاعات مربوط به قیمت‌گذاری و پاسخ به تقاضا از درگاه NAN به HGW منتقل شده و سپس بین کنتورهای هوشمند و وسایل مختلف خانگی توزیع می‌شود. در این حالت HGW نقش یک گره در شبکه رادیو شناختی NAN را دارد [۶۸، ۶۹].

۲-۵-۱- توپولوژی شبکه همسایگی

توپولوژی NAN دارای دو نوع ادوات شبکه است: ۱) درگاه‌های NAN (NGW^1) ۲) درگاه‌های HAN. یک NGW به عنوان یک گره مرکزی، ارتباطات را با چند HGW از چندین HAN مختلف برقرار می‌کند و به عنوان یک نقطه دسترسی عمل می‌نماید. تکنولوژی‌های مخابراتی که برای NAN مورد استفاده قرار می‌گیرند می‌بایست بیش از یک کیلومتر را پوشش دهند و از آنجا که لازم است تا ارتباطات بین نقاط جمع‌آوری داده و کنتورهای هوشمند قابل اطمینان باشد، باید این ارتباط بدون تداخل باشد. به همین دلیل استفاده از باندهای مجوزدار می‌تواند گزینه مناسبی باشد. البته استفاده از پهنای باندهای ترکیبی نیز که از باندهای مجوزدار و غیر مجوزدار استفاده می‌کنند نیز ارائه شده است [۲۷].

۳-۵-۱- توپولوژی شبکه ناحیه گسترده

در WAN هر یک از NGWها می‌تواند مانند یک گره رادیو شناختی عمل کرده و با استفاده از باندهای فرکانسی استفاده نشده از طریق ایستگاه‌های CR که در نواحی جغرافیایی بزرگی گسترده هستند با مرکز کنترل ارتباط داشته باشد. همچنین یک واسط برای اشتراک منابع پهنای باند بین NANهای مختلف وجود دارد. تغییرات لحظه‌ای مقدار داده در شبکه و تغییرات ظرفیت کانال‌ها نیازمند پاسخ سریع واسط پهنای باند است. ممکن است در NANها، NGW در ناحیه جغرافیایی که پوشش CR دارد قرار نداشته باشد در نتیجه NGWها باید بتوانند از پهنای باند مجوزدار و غیر مجوزدار استفاده کنند تا بازدهی پهنای باند را افزایش داده و از هزینه خرید پهنای باند بکاهند.

شبکه‌های WAN معمولاً از دو شبکه هسته^۲ و پشتیبانی تشکیل شده‌اند. شبکه‌های هسته از فیبرهای نوری یا مخابرات بی‌سیم سلولی برای ارتباط با نرخ داده بالا و تاخیر کم با مرکز کنترلی استفاده می‌کنند. شبکه‌های پشتیبانی ارتباط پهن باندی را با NANها و ادوات پایش برقرار کرده و می‌توانند بر اساس شبکه‌های نوری، بی‌سیم یا ترکیبی از این دو باشند [۲۷].

۶-۱- معماری شبکه‌های هوشمند مبتنی بر رادیو شناختی

در این قسمت معماری‌های شبکه‌های هوشمند برق مبتنی بر CR بررسی شده که می‌توان آن‌ها را به دو دسته کلی معماری-های شبکه HAN و معماری‌های ترکیبی که برای ترکیبی از شبکه‌های HAN، NAN، WAN و AMI استفاده می‌شوند تقسیم نمود.

¹ NAN Gateway

² Core Network

۱-۶-۱- معماری‌های شبکه خانگی

(۱) معماری شبکه‌های حسگر بی‌سیم مبتنی بر CR برای شبکه هوشمند: یک معماری چند لایه از شبکه‌های بی‌سیم مبتنی بر CR در [۷۰] ارائه شده است. در یک شبکه حسگر بی‌سیم مبتنی بر CR^1 (CR-WSN) یک هدایت‌کننده^۲ و یک پایگاه داده مکان جغرافیایی، با همکاری یکدیگر اطلاعات پهنای باند را در واحدهای شبکه هوشمند جمع‌آوری می‌کنند. برای این کار از پروتکل Zigbee با استاندارد 802.15.4 استفاده شده است. پایگاه داده مکان جغرافیایی اطلاعات مربوط به فضاهای خالی در مناطقی که تا ۵۰ متر با یکدیگر فاصله دارند را نگه می‌دارد. هدایت‌کننده نقش مدیر شبکه را دارد، گزارش‌های کانال‌های خالی را جمع‌آوری می‌کند، به عنوان درگاه یا گره شاخه عمل کرده، دوره‌های حس کردن پهنای باند را برنامه‌ریزی نموده، همزمان‌سازی را تضمین کرده، از طریق کانال‌های غیر Zigbee با پایگاه داده مکان جغرافیایی در ارتباط بوده و لیست کانال‌های کاربران اولیه‌ای که باید مورد پایش قرار گیرند را آماده می‌کند. حسگرهای پهنای باند به محض آشکارسازی یک کاربر اولیه، پیام سوئیچ نمودن کانال را صادر می‌کنند همچنین یک لیست از کانال‌های مجوزدار و غیر مجوزدار آماده کرده و به هدایت‌کننده گزارش می‌دهند.

(۲) معماری شبکه هوشمند مبتنی بر تکنولوژی دسترسی رادیویی^۳ (RAT): ممکن است یک HAN دارای سیستم‌های بی‌سیم ناهمگون شامل چندین تکنولوژی دسترسی رادیویی باشد. برای ایجاد ترافیک بلادرنگ و بهینه کردن کاربردهای شبکه هوشمند، ادوات هوشمند می‌بایست دارای رادیوهای قابل پیکربندی باشند. معماری چنین شبکه‌ای در [۷۱] ارائه شده است که در آن دو نوع اپراتور کنترل منابع وجود دارد که عبارتند از: یک کنترل‌کننده منبع شبکه جهانی^۴ (GRC) و یک ایستگاه یا نقطه دسترسی برای هر (RAT). کنترل‌کننده مناسب‌ترین نقطه دسترسی را برای هر رادیوی قابل پیکربندی برای مدت زمان‌های بلند (چند ثانیه) تخصیص می‌دهد. برای زمان‌های کوتاه (چند میلی ثانیه) خود نقطه دسترسی منابع را مدیریت می‌کند.

۱-۶-۲- معماری‌های ترکیبی


این معماری شامل دو بخش است: یکی معماری‌های ترکیبی بین HAN، NAN و WAN و دیگری مربوط به AMI می‌باشد. مثال‌هایی از این ترکیب‌ها در شکل ۴ نشان داده شده است.

¹CR based wireless sensor network

^۲Coordinator

^۳Radio Access Technology

^۴Global Network Resource Controller(GRC)



شکل ۴. معماری‌های مبتنی بر رادیو شناختی در شبکه هوشمند [۲۶]

۱-۶-۲-۱ معماری ماشین به ماشین رادیو شناختی

در این قسمت سه نمونه از معماری‌های ماشین به ماشین رادیو شناختی در حوزه‌های HAN، NAN و WAN مورد بررسی اجمالی قرار می‌گیرد.

- M2M روی باند TVWS برای کنتور هوشمند: در [۳۸] یک معماری پیشرو/ پیرو^۱ برای مخابرات M2M روی باند TVWS به کمک رادیوشناختی امتحان شده است. کنتورهای هوشمند به صورت خوشه‌هایی^۲ در نظر گرفته شده‌اند که یک گره پیشرو و بقیه پیرو هستند. هر یک از کنتورها بنابر برنامه و قواعدی که وجود دارد می‌تواند نقش پیشرو یا پیرو را داشته باشد. گره پیشرو کانال‌های در دسترس را جستجو کرده و استفاده پهنای باند توسط پیروها را هدایت می‌کند. پیشرو عملیات حس کردن پهنای باند را شروع می‌کند و هر پیرو تنها اطلاعات را به پیشرو خود ارسال می‌نماید. پیشرو و پیروها هنگامی که در حال انجام عملیاتی نیستند در حالت خواب^۳ به سر می‌برند.
- M2M رادیوشناختی برای انرژی‌های تجدیدپذیر در FAN^۴: اضافه شدن منابع تجدید پذیر مانند انرژی خورشیدی، بادی و گرمایش زمین یکی از مشخصه‌های شبکه‌های برق هوشمند است. بخصوص در شبکه‌های توزیع برق آینده با مرزعه‌های توربین بادی سه نوع سناریوی مخابراتی M2M وجود دارد: M2M بین توربین‌های بادی در مزرعه توربین، M2M بین مزرعه توربین و کنترل مرکزی راه دور و M2M بین مزرعه توربین و جامعه‌های محلی. از آنجایی که مرزعه‌های توربین بادی از لحاظ جغرافیایی در ناحیه وسیعی گسترده شده‌اند، استفاده از TVWS می‌تواند گزینه در دسترس باشد [۴۸].
- M2M رادیو شناختی برای حفاظت شبکه‌های FAN: در یک FAN ممکن است تعدادی حفاظت کننده از شبکه وجود داشته باشد که در صورت آشکار سازی نوسانات، اختلالات یا قطعی برق، الگوریتم‌های حفاظتی را اجرا می‌کنند. مخابرات M2M می‌تواند یک راه حل سریع و قابل انعطاف برای به حداقل رساندن تلفات توان در شرایط غیرعادی باشد. مخابرات M2M بین کنتورهای هوشمند مبتنی بر رادیو شناختی و یک سرور مدیریت توان در ناحیه دور (RAPM) در [۴۸] ارائه شده است. در شبکه ارائه شده، از ادوات باند تلویزیون^۵ (TVBD) برای لایه ارتباطات که توان مصرفی در شبکه برق هوشمند را هدایت می‌کند استفاده می‌شود. این ادوات مخابرات آسان و دوطرفه‌ای بین واحدهای شبکه برق و مصرف کنندگان به همراه بازدهی انرژی و استفاده پهنای باند مناسب را فراهم می‌کنند [۷۲].

۱-۶-۲-۲ مدل‌های رادیو شناختی برای سلول‌های کوچک یا فمتوسل

کاربردهای مالی مدیا در شبکه هوشمند نیاز به پهنای باند زیاد داشته و مصرف انرژی برای مخابرات را افزایش می‌دهند. برای بهبود بازدهی انرژی برای این کاربردها، شبکه‌های موبایل رادیو شناختی با سلول‌های کوچک راه حل امیدوارکننده‌ای هستند. البته از آنجا که انرژی مورد نیاز شبکه‌های موبایل از شبکه برق تامین می‌شود باید ترکیب این دو مورد بررسی قرار گیرد [۷۳، ۷۴].

۱-۶-۲-۳ پایش خطوط برق و ایستگاه‌ها

یک طراحی ترکیبی مبتنی بر CR برای پایش خطوط و ایستگاه‌های شبکه هوشمند برق در [۶۶] ارائه شده است. طرح ارائه شده برای انتقال داده پایش از حسگرها می‌باشد که بازدهی ارتباطات و تامین انرژی را چالش‌های کلیدی پیاده‌سازی این سیستم معرفی می‌کند. فناوری‌های تجمیع شده در این سیستم شامل Zigbee، WiFi و WiMAX هستند که دو مورد اول برای مسافت‌های کوتاه و مورد سوم برای انتقال داده چندین حسگر با پهنای باند نسبتاً بالا مورد استفاده قرار می‌گیرند. حسگرها داده‌ها

^۱ Master/ Slave

^۲ Cluster

^۳ Sleep Mode

^۴ Field Area Network

^۵ TV band Device

را جمع‌آوری کرده و توسط اترنت یا واسط RS232 به یک ماژول مخابراتی WiFi/Zigbee انتقال می‌دهند. این ماژول نیز از طریق بی‌سیم داده‌های دریافتی را برای درگاه حسگر ارسال می‌کند. این درگاه شامل پنج قسمت می‌باشد که عبارتند از: یک واحد AP برای جمع‌آوری داده فرستاده شده از بخش WiFi/Zigbee، بخش پروکسی حسگر که سیگنال را از WiFi/Zigbee به WiMAX تغییر می‌دهد، بخش آشکارسازی پهنای باند، بخش تخصیص پهنای باند و بخش WiMAX برای ارسال داده به ایستگاه.

۱-۶-۲-۴ فناوری رادیو شناختی بر روی فیبر

در [۷۵] معماری یک سیستم شامل شبکه‌های CR با ارتباطات رادیو مجازی فضای آزاد^۱ برای پایش و کنترل پرسرعت شبکه هوشمند ارائه شده است. این معماری از تکنولوژی رادیو بر روی فیبر^۲ (RoF_MIMO) با چندین کاربر استفاده می‌کند که در آن در دو سمت فیبر نوری، آنتن‌های چند ورودی و چند خروجی وجود دارند. سه نوع RoF_MIMO برای شبکه‌های CR وجود دارند که عبارتند از: سری: که برای ارتباط راه دور بکار می‌رود، موازی: که برای کاهش تداخل در محیط‌هایی که پهنای باند ازدحام زیادی دارد و دیجیتال: که از فرمت پالس‌های دیجیتالی برای انتقال سیگنال‌های رادیویی استفاده می‌کند. سیگنال‌های رادیویی از یک فیلتر میان‌گذر عبور داده شده، نمونه‌برداری شده و در پورت ورودی دیجیتالی می‌شوند. در خروجی سیگنال‌های رادیویی توسط یک مبدل دیجیتال به آنالوگ بازیابی می‌شوند. روش‌های مختلف تسهیم^۳ در سیستم‌های RoF_MIMO استفاده می‌شوند که می‌توان به SCM^۴، TDM^۵ و CDM^۶ اشاره نمود.

۱-۶-۲-۵ شبکه‌های حسگر بی‌سیم مبتنی بر CR

برای کاربردهای شبکه هوشمند بر پایه شبکه‌های حسگر بی‌سیم، یک معماری SCSN^۷ در [۵۸] برای حل مشکلات ناشی از مشخصات متغیر مکانی-زمانی پهنای باند و شرایط تداخل زیاد شبکه هوشمند ارائه شده است. این معماری یک گزینه بالقوه برای کاربردهای پایش از راه دور کم‌هزینه و قابل اطمینان در شبکه هوشمند بخصوص حوزه‌های تولید، انتقال و توزیع می‌باشد.

۱-۶-۲-۶ روش پردازش گرافیک

روش‌های پردازش گرافیک می‌تواند حس نمودن سریع پهنای باند و دسترسی پویا به پهنای باند را فراهم سازند [۷۶]. در معماری ارائه شده در [۷۶]، مخابرات CR روی باندهای بدون مجوز در HANها استفاده شده در حالی که مخابرات CR روی باندهای دارای مجوز در NANها و WANها بکار گرفته شده است. این مطالعه بررسی می‌کند که چگونه معماری سلسله مراتبی رادیو شناختی در HANها، NANها و WANها می‌تواند دسترسی پویا به پهنای باند را برای جلوگیری از تداخل و بهینه‌سازی انتقال داده، مورد استفاده قرار دهد.

^۱Virtual Radio Free Space

^۲Radio on Fiber_MIMO

^۳Multiplexing

^۴SubCarrier Multiplexing

^۵Time Division Multiplexing

^۶Code Division Multiplexing

^۷Spectrum-aware cognitive sensor network

در مخابرات مبتنی بر CR در HANها، هر گره ارسال کننده و حس کننده به صورت دوره‌ای نرخ خطای بسته داده (PER)^۱ خود را مشخص می‌کند. اگر PER بالای یک حد آستانه از پیش تعیین شده باشد آنگاه یک گزارش به نقطه دسترسی (کنترل هوشمند) ارسال می‌شود تا کیفیت لینک ارتباطی آن بررسی شود. اگر کیفیت لینک از یک عدد مشخصی پایین تر بیاید، کنترل کننده یک دستور حس نمودن پهنای باند را شروع می‌نماید. گره‌های حسگر توزیع شده پهنای باند را حس نموده و به صورت دوره‌ای اطلاعات حس نمودن را به کنترل کننده ارسال می‌کنند. کنترل کننده در مورد باندهای استفاده نشده تصمیم می‌گیرد و این باندها را به گره ارسال کننده تخصیص می‌دهد.

در مخابرات مبتنی بر CR در NANها، داده می‌تواند دسته‌بندی و الویت‌بندی شود تا تحویل موفقیت‌آمیزی در شبکه‌های ناهمگون بوجود آید. شرایط اضطراری و اتفاقات ناگوار مانند افت ولتاژها، دستورات سوئیچ کردن یا حذف لینک‌های فیزیکی شبکه منجر به تولید داده‌هایی می‌شوند که زمان برای آن‌ها بسیار حائز اهمیت است. در چنین مواردی، انتقال داده با استفاده از شبکه‌های بی‌سیم قدیمی مانند شبکه‌های بی‌سیم سلولی یا اینترنت ترجیح داده می‌شود. از طرف دیگر، داده‌های عمومی مانند داده‌های قرائت خودکار کنترلر، اطلاعات کیفیت انرژی می‌تواند از طریق مخابرات CR انتقال داده شود. همچنین مخابرات CR می‌تواند برای انتقال داده‌های حساس با فراهم نمودن یک لینک رادیویی پشتیبانی در شرایط اضطراری مفید باشد. این مدل می‌تواند با مشخصات استاندارد IEEE 802.22 مانند انتقال داده بهینه، محدودیت نمودن ظرفیت به صورت نرم و پوشش دهی وسیع ترکیب شود.

۷-۲-۶-۱ استاندارد IEEE 802.22 و TVWS

استاندارد IEEE 802.22 یک استاندارد طراحی شده برای شبکه‌های WRAN می‌باشد که توسط فناوری‌های رادیو شناختی از فضای خالی باند تلویزیون TVWS استفاده می‌کند [۷۷]. ادوات رادیو شناختی برای پهنای باند TVWS دارای پهنای باند 6 MHz هستند و در باندهای فرکانسی VHF و UHF کار می‌کنند. محدوده این کانال‌ها عبارتند از 54-72 MHz، 76-88 MHz، 174-216 MHz و 470-806 MHz. طبق استاندارد IEEE 802.22 یک شبکه سلولی CR از یک ایستگاه پایه (BS)^۲ و گره‌های دستگاه مشترک-خانگی (CPE)^۳ تشکیل شده است. ایستگاه پایه محیط دسترسی را برای همه CPEهای داخل سلولش مدیریت می‌کند. مشخصات اصلی استاندارد IEEE 802.22 در جدول ۱ آورده شده است.

یک بستر تست مخابرات فضای خالی UHF برای مخابرات شبکه هوشمند برق در [۷۸] ارائه شده است. معماری شبکه برای تحلیل تولید پراکنده برق در مجموعه‌ها طراحی شده است. برای کاربردهای شبکه هوشمند مانند قرائت کنترلر از راه دور و تعادل بار در نقاط دور دست معمولاً کمبود زیرساخت مخابراتی وجود دارد. سیستم ارائه شده بر پایه شبکه‌ای از گره‌های متکی به ارتباط رادیویی است که مخابرات شبکه هوشمند را در نواحی حومه شهرها پشتیبانی می‌کنند. این سیستم دارای لینک‌های مخابراتی دوطرفه است و از یک پروتکل استاندارد 802.11 برای انتقال روی باند بدون مجوز UHF در فرکانس 758-766 MHz استفاده می‌کند. همچنین این سیستم ارتباطات پهن باندی را برای مجموعه‌های راه دور، ارتباطات یک نقطه به چند نقطه را در باند WiFi، فرکانس 5 GHz و باند TVWS برای نقاط دورتر و ارتباطات که در دید مستقیم نیستند فراهم می‌کند.

جدول ۱ خلاصه‌ای از پارامترهای کلیدی استاندارد IEEE 802.22

پارامتر	مشخصات
فاصله	30-100 km

^۱ Packet Error Rate (PER)

^۲ Base Station (BS)

^۳ Customer-Premises Equipment

روش	حس پهنای باند برای تشخیص کانال‌های خالی
پهنای باند کانال	6,7 , 8 MHz
مدولاسیون	OFDMA
ظرفیت کانال	18 Mbps
ظرفیت کاربر	Downlink: 1.5 Mbps, uplink: 384 Mbps

دو معماری WRAN مبتنی بر CR برای جریان داده Backhaul شبکه هوشمند بر پایه استاندارد IEEE 802.22 ارائه شده است که عبارتند از: معماری رادیویی مستقل^۱ و معماری رادیویی ثانویه^۲. نواحی حومه با چگالی پایین مشترکین معمولاً دسترسی بالایی به باندهای خالی تلویزیون دارند در نتیجه معماری رادیویی مستقل برای فراهم نمودن دسترسی پهن‌بند مخابرات زیرساخت پیشنهاد شده است [۷۹]. باندهای تلویزیون مشخصات انتشاری خوبی دارند که منجر به پوشش‌دهی نواحی وسیعی می‌شود که در اندازه‌گیری تلفات مسیر در نقاط شهری و حومه نیز مشخص شده است. استاندارد IEEE 802.22 به عنوان یک ارتباط رادیویی پشتیبانی برای انتقال داده‌های غیرحساس شبکه هوشمند در صورت بروز یک حادثه طبیعی، نشت اطلاعاتی و یا زمانی که چگالی مشترک نسبت به پهنای باند در دسترس TVWS زیاد است پیشنهاد شده است [۸۰]. برای برطرف نمودن تاخیرهای ذاتی مربوط به حس نمودن پهنای باند، یک معماری دوگانه برای انتقال در شبکه‌های WRAN مبتنی بر CR می‌تواند مورد استفاده قرار گیرد. این معماری دوگانه^۳ از یک حلقه رادیویی برای ارسال و دریافت داده شبکه هوشمند استفاده می‌کند و حلقه دوم را به حس نمودن پهنای باند اختصاص می‌دهد. رادیوهای حس‌کننده پهنای باند به طور پیوسته کانال‌های در دسترس جدید را جستجو می‌کنند و لازم نیست که انتقال داده برای جستجوی کانال‌های بی‌استفاده قطع شود. این معماری دوگانه بازدهی پهنای باند بالاتر و حس نمودن دقیق‌تری نسبت به معماری تک رادیویی^۴ دارد.

مزایای استفاده از معماری مخابرات CR ثانویه بر پایه استاندارد IEEE 802.22 برای شبکه هوشمند عبارتند از [۱۰، ۷۹، ۸۰]:

- محدودیت ظرفیت نرم: سیستم می‌تواند به صورت پویا از کانال‌های در دسترس تلویزیون برای افزایش ظرفیت سیستم و کاربردهای آینده استفاده کند. در یک کانال تلویزیون با پهنای باند 6 MHz طبق استاندارد، حداکثر نرخ 18 Mbps تعریف شده است. برای رسیدن به نرخ‌های بالاتری تا 24 Mbps لایه فیزیکی در این استاندارد اجازه اتصال کانال‌ها به یکدیگر را نیز می‌دهد.
- محدوده وسیع پوشش‌دهی: محدوده پوشش‌دهی ایستگاه پایه در استاندارد 802.22 نسبت به بقیه استانداردهای 802 بسیار بیشتر است. برای مثال، حداکثر مسافت برای استانداردهای IEEE 802.16 a/d/e به کمتر از 5 km محدود شده است. در حالی که پوشش‌دهی ایستگاه پایه در IEEE 802.22 در حالتی که سطح توان CPE برابر 4 W است، برابر 33 km می‌باشد. حتی این محدوده می‌تواند تا 100 km نیز افزایش یابد در صورتی که

^۱ Stand-alone radio architecture

^۲ Secondary radio architecture

^۳ Dual radio architecture

^۴ Single radio architecture

اجازه سطوح بالاتری از توان ارسالی داده شود که منجر به تعداد کمتری ایستگاه پایه شده و در هزینه‌ها صرفه‌جویی می‌شود.

- تحمل خطا و خود بازیابی: از دست دادن لینک‌های ارتباطی به دلیل حوادث طبیعی یا امنیتی با ایجاد ارتباط جدید باعث حفظ ارتباط خواهد شد.
- حس نمودن پیوسته پهنای باند: حس نمودن پیوسته با استفاده از معماری دوگانه به شبکه هوشمند اجازه می‌دهد تا جریان داده سریعی داشته باشد.
- ارتقاء آسان: از آنجایی که سیستم‌های مبتنی بر CR با استفاده از رادیو نرم‌افزاری بر روی کامپیوترهای شخصی یا ادوات دارای پردازشگر پیاده‌سازی می‌شوند، ارتقاء نرم‌افزار بر روی آنها آسان است و انعطاف پذیری بالایی دارند. این ارتقاء برای مشترکین نیز بسیار اهمیت دارد و از هزینه‌ها در زیرساخت‌های مخابراتی جلوگیری می‌کند.

به دلیل این مزایا مخابرات مبتنی بر CR روی باند TVWS با استاندارد IEEE 802.22 بسیار جذاب است و استانداردهای دیگری نیز مانند IEEE 802.19.1 و IEEE 802.15.4g برای شبکه‌های واحدهای هوشمند (SUN) ارائه شده‌اند که در شبکه برق هوشمند نیز کاربرد دارند [۲۴]. همچنین در [۶۲] تحلیلی بر پتانسیل استفاده از IEEE 802.22 در سیستم‌های SCADA و امکان سنجی و مزایای آن نسبت به دیگر سیستم‌های سیمی و بی‌سیم آورده شده است.

۸-۲-۶-۱ زیرساخت اندازه‌گیری پیشرفته

زیرساخت اندازه‌گیری پیشرفته (AMI) داده‌ها را جمع‌آوری کرده و مصرف انرژی را تحلیل کرده و تخمین می‌زند. این سیستم با کنتورهای هوشمند از طریق فناوری‌های مخابراتی ارتباط متقابل دارد. یک معماری دولایه برای مخابرات AMI در [۶۵] پیشنهاد شده است. این معماری دولایه از TVWS استفاده می‌کند و دو نوع شبکه بی‌سیم به صورت سلسله مراتبی دارد. مرتبه پایین‌تر دارای شبکه‌های کوچکتری است که از طریق WhiteFi مرتبط می‌شوند. فناوری WhiteFi نیز مانند WiFi است با این تفاوت که از فضاهای خالی باند UHF استفاده می‌کند. سطح بالاتر از شبکه‌های 802.22 تشکیل شده است که توسط ارائه‌دهندگان خدمات پهن‌بند پیاده‌سازی شده و نقاط دسترسی WhiteFi را به شرکت تولیدکننده وصل می‌کند. این شبکه‌ها همچنین می‌توانند دیگر مشتریان مانند وسایل خانگی و دستگاه‌های موبایل را نیز خدمات‌دهی کنند. این معماری دولایه کم‌هزینه بوده و می‌تواند ارتباطات نرخ بالا را با کنتورهای هوشمند برقرار کند. ارائه‌دهندگان خدمات 802.22 می‌توانند از داده حس پهنای باند توسط کنتورهای هوشمند تا ایستگاه پایه WhiteFi استفاده کنند. همچنین می‌توانند این داده را از دیگر مشترکین 802.22 یا حسگرهایی که به طور خاص برای حس پهنای باند استفاده می‌شوند دریافت نمایند. حتی اگر پایگاه داده‌ای از فرستنده‌ها در دسترس باشد، لیست کانال‌های در دسترس از حس پهنای باند و پایگاه داده فرستنده از هم جدا می‌شود تا لیست کانال‌های قابل دسترس بدست آید.

در مرجع [۸۱] یک شبکه رادیو شناختی LTE یا نسل چهارم با مرکز داده ابری برای یک شبکه کاربران اولیه معرفی شده است. در شبکه ارائه‌شده میزان پوشش ایستگاه پایه هر دو شبکه مبتنی بر رادیو شناختی و شبکه کاربران اولیه یکسان است. ایستگاه پایه کاربران اولیه تنها از این کاربران پشتیبانی می‌کند زیرا فاقد پروتکل برای کاربران ثانویه است. یک آنتن رادیو شناختی روی دکل BTS علاوه بر آنتن شبکه سلولی قرار داده می‌شود. ادوات مخابرات رادیو شناختی پهنای باند فرکانسی وسیعی بویژه پهنای باند داخل سلول را حس کرده و بعد از تشخیص باندهای استفاده نشده، اطلاعات به مرکز داده ابری انتقال داده می‌شود. هدف از این طرح ارائه یک چارچوب شبکه 4G رادیو شناختی برای کنترل تعداد زیادی کنتور هوشمند است که از لحاظ جغرافیایی پراکنده هستند. این مدل پنج مشخصه مهم از منظر شبکه هوشمند دارد که عبارتند از: حس پهنای باند، آشکارسازی انرژی، مدل فعالیت کاربر اولیه، زمان بهینه حس کردن و زمانبندی و الگوریتم برای کاربران رادیو شناختی.


در [۸۱] یک معماری برای داده بی سیم ابری (WCD)^۱ ارائه شده است که از چهار لایه اصلی تشکیل می‌شود. این چهار لایه عبارتند از: لایه کاربرد، لایه پلتفرم، لایه مخابرات رادیو شناختی و شبکه و لایه زیرساخت. دو لایه بالایی مشابه معماری‌های ابری حاضر است اما دو لایه پایینی برای شبکه رادیو شناختی و خدمات بی سیم ارتقاء داده شده است. لایه مخابرات رادیو شناختی و شبکه مربوط به خدمات رادیو شناختی، خدمات شکل موج، کنترل لینک رادیویی^۲ (RLC) و خدمات MAC می‌باشد.

۱-۷- روشهای حس کردن پهنای باند مبتنی بر رادیو شناختی

در زمینه شبکه هوشمند معمولاً سه روش برای حس کردن پهنای باند مورد بررسی قرار گرفته است که عبارتند از: آشکارسازی انرژی^۳، فیلتر تطبیق شده^۴ و آشکارسازی مشخصات^۵ که در ادامه توضیحاتی در مورد هر یک داده شده است [۸۲].

۱-۷-۱- روش آشکارسازی انرژی

این روش برای آشکارسازی سیگنال کاربران اولیه بر مبنای انرژی حس شده است. به دلیل سادگی و نیاز نداشتن به اطلاعات قبلی از کاربران اولیه معمول‌ترین روش در بین روش‌های غیرهماهنگ^۶ می‌باشد. بلوک دیاگرام روش آشکارسازی انرژی در شکل ۵ نشان داده شده است.



شکل ۵. بلوک دیاگرام روش آشکارسازی انرژی [۸۲]

در این روش سیگنال از یک فیلتر میان‌گذر با پهنای باند مشخص عبور داده شده در یک بازه زمانی انتگرال‌گیری می‌شود. خروجی بلوک انتگرال‌گیر با یک حد آستانه از قبل تعیین شده مقایسه می‌شود و از این طریق حضور یا غیاب کاربر اولیه مشخص می‌شود. مقدار آستانه می‌تواند بسته به شرایط کانال ثابت یا متغیر باشد.

۱-۷-۲- روش استفاده از فیلتر تطبیق شده

فیلتر تطبیق شده یک فیلتر خطی است که برای به حداکثر رساندن سیگنال به نویز برای یک سیگنال ورودی به کار می‌رود. این فیلتر زمانی استفاده می‌شود که اطلاعاتی از نوع سیگنال کاربر اولیه در اختیار باشد. پاسخ ضربه فیلتر تطبیق شده همان تصویر و شیفت داده شده در زمان سیگنال مرجع است و در حقیقت عملیات فیلتر تطبیق شده، همسانی سیگنال ورودی و سیگنال مرجع

^۱ Wireless Cloud Data (WCD)

^۲ Radio Link Control

^۳ Energy Detection

^۴ Matched Filter

^۵ Feature Detection

^۶ Non-cooperative

را نشان می‌دهد. این روش کم‌ترین زمان را برای تشخیص کاربر اولیه نسبت به روش‌های دیگر نیاز دارد و زمانی که نویز به صورت نویز گوسی باشد روش بهینه‌ای است. بلوک دیاگرام این روش در نشان داده شده است.



شکل ۶. بلوک دیاگرام روش فیلتر کالمن [۸۲]

۳-۷-۱- روش تشخیص ویژگی^۱

این روش از تناوب در سیگنال دریافت شده از کاربر اولیه برای تشخیص حضور این نوع کاربران استفاده می‌کند. این تناوب در حامل‌های سینوسی، قطارهای پالس، کدهای گسترش طیف و بازه‌های پرش فرکانس یا سرآمدهای سیگنال‌های کاربران اولیه تعبیه می‌شود. به دلیل وجود این تناوب‌ها، این سیگنال‌ها یک ویژگی‌های تناوبی را از خود نشان می‌دهند که در نویز و اختلال وجود ندارد. این روش در مقابل عدم قطعیت نویز مقاوم است و در مناطقی که سیگنال به نویز پایین است می‌تواند بهتر از روش آشکارسازی انرژی عمل نماید. با این حال این روش از پیچیدگی محاسبات بیشتر و زمان حس طولانی‌تری نسبت به آشکارسازی انرژی برخوردار است.

روش‌های دیگری نیز برای حس نمودن پهنای باند از جمله آشکارسازی هماهنگ و آشکارسازی اختلال نیز وجود دارد. بررسی انجام شده در [۸۳] یک روش مبتنی بر CR برای حس پهنای باند و سوئیچ کانال در شبکه هوشمند ارائه کرده و مساله مصالحه بین حس نمودن و عملکرد را تحلیل کرده است. حس پهنای باند و سوئیچ کانال به کنتورهای هوشمند اجازه می‌دهد که برای کاهش قطعی‌های مخابراتی، داده را روی کانال دارای مجوز یا غیر مجوز دار ارسال کنند. تحلیل انجام شده در [۸۳] بررسی می‌شود که چگونه حس پهنای باند در مخابرات CR، کیفیت ارتباطات را تحت تاثیر قرار می‌دهد و به تبع آن کیفیت ارتباطات روی عملکرد کنترل شبکه هوشمند بخصوص کنترل پاسخ به تقاضا اثر می‌گذارد.

تأثیر کیفیت کنترل پاسخ به تقاضا روی سود تأمین‌کننده برق و رفاه اجتماعی شبکه برق به صورت رضایت مشتری منهای هزینه تأمین‌کننده برق مورد تحلیل قرار گرفته است. بر اساس این تحلیل یک مصالحه بین حس کردن رادیو شناختی و عملکرد شبکه هوشمند مبتنی بر CR وجود دارد. نتایج نشان می‌دهد که یک زمان حس کردن خاصی وجود دارد که امکان ماکزیمم مصالحه را برای حفاظت از کاربران اولیه فراهم می‌کند.

۸-۱- پروتکل‌های MAC مبتنی بر رادیو شناختی برای شبکه هوشمند برق

در فصل‌های آتی به طور مفصل به کاربرد هوش مصنوعی در لایه MAC و لایه شبکه پرداخته خواهد شد. به همین دلیل در این قسمت و بخش بعدی به طور مختصر به پروتکل‌های MAC و مسیریابی مورد استفاده در CR در صنعت برق پرداخته شده است. در عملکرد لایه ارتباط داده شامل کنترل محیط دسترسی^۲ (MAC) و کنترل خطا می‌شود. معماری مخابرات مبتنی بر CR باید دارای پروتکل‌های MAC با مصرف انرژی بهینه باشد تا بتواند مدیریت پهنای باند دینامیک CR را در نظر بگیرد.

^۱ Feature detection

^۲ Medium Access Control

علاوه بر این محدودیت منابع، گسترش چگالی بالا، نیازهای کیفیت خدمات برای کاربردهای خاص، حس کردن پهنای باند و نیازهای تشخیص کانال باید در طراحی یک پروتکل MAC موثر برای شبکه‌های هوشمند برق مبتنی بر CR در نظر گرفته شود. تاکنون انواع مختلفی از پروتکل‌های MAC برای شبکه برق هوشمند مبتنی بر CR ارائه شده‌اند که در ادامه به طور مختصر به هر اشاره می‌شود [۸۴].

در [۸۵] یک راهکار مخابرات CR میان-لایه‌ای برای شبکه برق هوشمند بر اساس پروتکل CSMA/CA ارائه شده است. این روش پروتکل CSMA/CA را با دسترسی به پهنای باند دینامیک (DSA) ترکیب می‌کند و لیستی از کانال‌های دردسترس را مشخص می‌نماید.

در [۸۶] یک الگوریتم کنترل توزیع شده غیربهمینه بر پایه پروتکل CSMA MAC برای پشتیبانی از کیفیت خدمات موثر با استفاده از ترکیبی از تصمیمات انتخاب کانال با دسترسی به پهنای باند دینامیک، جریان کنترل و از دست رفتن بسته‌های داده ارائه شده است. الگوریتم کنترل کانال ارائه شده دارای چارچوبی با سه دوره برای حس نمودن پهنای باند، کنترل و انتقال داده است.

یک قدم مهم برای ترکیب شبکه‌های حسگر مجهز به CR با شبکه هوشمند، بهینه نمودن لایه MAC برای سربار کم دسترسی به پهنای باند، ترکیب حس نمودن و دوره فعالیت برای متعادل نمودن مصالحه بین استفاده بهمینه از پهنای باند و مصرف انرژی و عملکرد قابل اطمینان در محیط‌های بی‌سیم غیرهمگون می‌باشد. برای پشتیبانی از این ویژگی‌ها یک طراحی پروتکل MAC قابل اطمینان و دارای مصرف بهمینه (CRB-MAC) برای شبکه‌های حسگر مبتنی بر CR در شبکه هوشمند برق در [۸۷] ارائه شده است. فرض شده است که هر گره دارای یک فرستنده/گیرنده که می‌تواند روی هر کانال در باند دارای مجوز تنظیم شود. هر گره به صورت مستقل وضعیت خواب یا بیداری خود را انتخاب می‌کند و پهنای باند را در یک مدت از پیش تعیین شده برای آشکارسازی فعالین کاربر اولیه پایش می‌کند. در صورت حضور کاربر اولیه، فرستنده به وضعیت خواب می‌رود و عملیات ارسال، بعد از اینکه دوره پایش منقضی شد، دوباره تکرار می‌شود. حال اگر حضور کاربر اولیه‌ای تشخیص داده نشد، گره شروع به ارسال سرآمد^۱ و به دنبال آن، داده می‌نماید. همسایگان فرستنده بیدار شده، داده را دریافت می‌کنند و یک زمانی را قبل از ارسال داده به هاب بعدی تنظیم می‌کنند. بعد از پایان این زمان، هر کدام از همسایگان کانال را برای حضور کاربر اولیه پایش می‌کنند. نزدیک‌ترین گره به مقصد زمان کمتری نسبت به بقیه دارد و هر کدام از گره‌ها اگر بعد از پایان زمان پایش، داده توسط گره‌ها دیگر ارسال نشده بود، داده را ارسال می‌کنند. این عملیات ممکن است از طریق چندین هاب تکرار شود تا داده به مقصد نهایی برسد. پروتکل MAC دیگری که در [۲۰] برای ادوات M2M در سیستم‌های مخابراتی شبکه هوشمند طراحی شده است پروتکل مبتنی بر PRMA^۲ می‌باشد تا بتواند از شبکه M2M رادیوشناختی که به صورت همزمان با شبکه اولیه ایجاد می‌شود پشتیبانی کند.

۹-۱- پروتکل‌های مسیریابی مبتنی بر رادیو شناختی برای شبکه هوشمند برق

بسیاری از مسائل جدید در زمینه مسیریابی به دلیل محیط خاص شبکه برق هوشمند بوجود می‌آیند. پیکربندی این شبکه پیچیده، گره‌های زیادی دارد که داده‌های با تعداد متغیرهای بالا تولید می‌کنند که این داده‌ها باید جمع‌آوری شده و بر روی شبکه با شرایط تاخیر خاصی ارسال گردد. پروتکل‌های مسیریابی ممکن است در لایه‌های مختلف متفاوت باشند. در لایه HAN، پروتکل‌های مسیریابی باید در عین فراهم نمودن امنیت و حریم خصوصی، مصرف توان کمی داشته باشند. در لایه NAN و

^۱Preamble

^۲Packet Reservation Multiple Access

WAN پروتکل‌های مسیریابی باید الزامات کیفیت خدمات برای حجم‌های بالای داده را ارضاء کنند. در نتیجه برای یک شبکه هوشمند موثر مبتنی بر CR باید پروتکل‌های مسیریابی با دقت طراحی شوند.

همچنین شرایط چالشی و متغیر ارتباطات مانند تغییر نویز پس‌زمینه، تلفات، مجموعه کانال‌های دردسترس و پدیده انتشار امواج بی‌سیم باعث می‌شوند ارتباطات در شبکه CR شکننده باشد. شکننده بودن ارتباطات CR و مخابرات در حال تغییر شبکه برق هوشمند، مسیریابی در شبکه برق هوشمند مبتنی بر CR را بسیار چالش برانگیز نموده است. هدف از تحقیقات در زمینه مسیریابی، طراحی پروتکل مناسب برای تعیین مسیر^۱ و ارسال بسته^۲ می‌باشد. به طور کلی می‌توان پروتکل‌های مسیریابی را به دو دسته پروتکل‌های مسیریابی برای شبکه‌های رادیو شناختی عمومی و پروتکل‌های مسیریابی برای شبکه‌های حسگر بی‌سیم مبتنی بر CR تقسیم بندی نمود [۸۸-۹۰].

به نظر می‌رسد که پروتکل‌های مسیریابی برای شبکه‌های کم توان و تلفاتی (RPL)، پروتکل مسیریابی استاندارد برای اکثر کاربردهای شبکه هوشمند باشند که شامل شبکه‌های AMI نیز می‌شوند، باشند. در شبکه‌های مبتنی بر CR کاربران اولیه باید محافظت شوند. این محافظت به آشکارسازی فعالیت کاربران اولیه بستگی دارد. در نتیجه لایه شبکه کاربران CR باید از نواحی که توسط کاربران اولیه مورد استفاده قرار گرفته اجتناب کند. در نتیجه یک مصالحه عملکردی برای شبکه کاربران ثانویه وجود دارد. علاوه بر این، گره‌های شبکه رادیو شناختی در ارسال بسته‌ها حین حس کردن پهنای باند درگیر نیستند. برای حل این چالش‌ها پروتکلی تحت عنوان CORPL^۳ معرفی شده تا نیاز شبکه ثانویه نیز برآورده شود [۹۱].

اهداف عمومی طراحی مسیریابی برای معماری شبکه‌های حسگر بی‌سیم مبتنی بر CR در [۵۸] فرمول‌بندی شده‌اند. این شبکه‌ها از مسیریابی چند مسیر به بهره‌مند هستند که مسیرهای مختلف باعث می‌شود تداخل کاهش یابد. همچنین طرح‌های مسیریابی مشارکتی^۴ می‌تواند برای بالابردن بازدهی ارسال بسته‌ها به کار برده شود. پروتکل‌های مسیریابی انرژی و پهنای باند بهینه برای شبکه‌های حسگر بی‌سیم مبتنی بر CR که در HAN شبکه هوشمند به کار می‌روند برای باندهای دارای مجوز و بدون مجوز در [۷۰] مورد بررسی قرار گرفته‌اند. برای استفاده از مزیت صرفه‌جویی در انرژی در کاربردهای شبکه هوشمند مبتنی بر CR، این پروتکل‌ها که برای CR-WSN ها ارائه شده بر روی RPL ساخته می‌شوند. طراحی‌های بر مبنای RPL دارای عدم تقارن است بدین معنی که جریان بسته‌های داده از مسیرهای مختلف و جهت‌های مختلف و با در نظر گرفتن قابلیت‌های مختلف گره‌های شبکه انجام می‌شود تا بتواند مسیریابی قابل اطمینان و کم تاخیری را برای شبکه‌های رادیو شناختی با مقیاس بزرگ در شبکه هوشمند فراهم کند.

۱۰-۱- رادیو نرم‌افزار^۵

یکی از راه‌های پیاده‌سازی رادیو شناختی می‌تواند رادیو نرم‌افزاری باشد و به دلیل مشابهت‌هایی که این دو می‌تواند در اهداف خود با یکدیگر دارند می‌توانند به یکدیگر مربوط باشند. البته در قسمت‌های آتی در مورد ملاحظات نرم‌افزاری و سخت‌افزاری مورد نیاز برای پیاده‌سازی هوش مصنوعی به طور جداگانه توضیحاتی داده خواهد شد.

پیشرفت روز افزون علم و افزایش تقاضا برای ارتباطات بی‌سیم و در پی آن به وجود آمدن پروتکل‌های مختلف ارتباطی باعث شده است که نیاز برای یک سیستم مخابراتی که بتواند با پروتکل‌ها و استانداردهای مختلف کار کند، بیش از پیش احساس شود.

^۱ Path determination scheme

^۲ Packet forwarding scheme

^۳ Cognitive and Opportunistic RPL

^۴ Cooperative Routing

^۵ Software Defined Radio

واضح است پیاده کردن چنین سیستمی با استفاده از سخت‌افزار مشکلات زیادی از جمله حجم زیاد و هزینه بالایی را در پی خواهد داشت. از طرفی با افزایش قدرت محاسباتی و سرعت پردازنده‌ها و انعطاف‌پذیری سیستم‌های نرم‌افزاری و دیجیتال، این سیستم‌ها به سرعت در حال گسترش بوده و جایگزین سیستم‌های آنالوگ می‌شوند. یکی از این تغییر و تحولات، معرفی مفهومی به نام رادیو نرم‌افزاری است. با استفاده از رادیو نرم‌افزاری این امکان بوجود می‌آید که به جای سخت‌افزارهای متداول در سیستم‌های فرستنده و گیرنده، تراشه‌های پردازنده پرسرعت با اجرا کردن نرم‌افزار مناسب و پردازش سیگنال دیجیتال نقش آن‌ها را ایفا کنند. به این ترتیب یک سیستم رادیو نرم‌افزاری می‌تواند با به کارگیری کدهای نرم‌افزاری برای استانداردهای مخابراتی مختلف و باندهای فرکانسی مختلف بکار گرفته شود. در این صورت هزینه تولید و ارتقاء سیستم و خدمات برای تولید کننده دستگاه‌های فرستنده و گیرنده و همچنین برای اپراتورها کاهش می‌یابد.

رادیو نرم‌افزاری اولین بار در سال ۱۹۹۱ توسط جوزف میتولا^۱ مطرح گردید و اولین مقاله درباره آن در سال ۱۹۹۲ توسط وی منتشر شد [۹۲]. از آن تاریخ به بعد، با گسترش فناوری‌های سخت‌افزاری و فنون پیاده‌سازی نرم‌افزاری، گستره‌ی پژوهش‌های رادیو نرم‌افزاری رو به فزونی نهاده است. امروزه بسیاری از سیستم‌های فرستنده و گیرنده از جمله تلفن‌های موبایل براساس اصول این فناوری طراحی و به بازار عرضه می‌شوند. به کارگیری نرم‌افزار در ساختار سیستم رادیو امکان هوشمندسازی رفتار رادیو را در ابعاد مختلف فراهم می‌کند. برای مثال سیستم رادیویی می‌تواند براساس تغییرات و شرایط محیطی به نوعی عمل کند که به سرعت بر اساس نیازهای مختلف کاربر خود واکنش مناسب نشان داده و افزایش بهره‌وری در بکارگیری طیف فرکانس و مدیریت آن و کاهش هزینه‌های ارتباطی را موجب شود. وجود نرم‌افزار باعث می‌شود همه این بهینه‌سازی‌ها به صورت اتوماتیک و بدون دخالت کاربر صورت پذیرد. در ادامه چارچوب‌های کلی رادیو نرم‌افزاری و معماری آن، فناوری مبدل‌های مورد نیاز و ساختارهای پردازشی مورد استفاده مورد بحث قرار می‌گیرد.


۱-۱۰-۱- تعریف

رادیو وسیله‌ای است که برای انتقال اطلاعات در باند RF^۲ سیگنال را به صورت بی‌سیم ارسال و دریافت می‌کند. با این تعریف انواع فرستنده‌ها و گیرنده‌های مخابراتی به نوعی یک رادیو هستند. تمام سیستم‌های رادیویی از بخش‌های نسبتاً ثابتی تشکیل شده‌اند، که بسته به نوع و کاربرد، با تفاوت‌هایی در ساختارها ظاهر می‌شوند. به طور کلی رادیوها از اجزاء مشابه شامل آنتن، تقویت کننده، میکسر و مدولاتور تشکیل شده‌اند. رادیوهای قدیمی از نظر کاربرد چندگانه محدودیت دارند. دلیل عمده آن است که در این سیستم‌ها تغییر عملکرد تنها با تغییر سخت‌افزار ممکن است که در نتیجه هزینه‌ی زیادی به سازنده تحمیل شده و انعطاف پذیری کاهش می‌یابد. در صورتیکه نیاز باشد یک رادیو (برای مثال یک گوشی موبایل) با استانداردهای مختلفی به تبادل اطلاعات بپردازد، اگر از نرم‌افزار استفاده نشود باید برای هر پروتکل مخابراتی امکانات سخت‌افزاری جدیدی را به سیستم اضافه نمود. این موجب افزایش پیچیدگی سیستم، توان مصرفی، حجم و قیمت آن می‌شود. فناوری رادیو نرم‌افزاری راه حلی برای این مسئله است و این امکان را فراهم می‌آورد که سیستم‌های مخابراتی چندباند، چندحالت و چندمنظوره قابل بهبود با ارتقای نرم‌افزاری داشته باشیم. به این صورت که انجام کلیه عملیات مخابراتی مانند مدولاسیون، دمدولاسیون و غیره توسط نرم‌افزار انجام می‌گیرد. مزیت عمده این روش این است که به جای استفاده از مدارات اضافی برای دسترسی به انواع سیگنال‌های رادیویی، کافی است از یک برنامه مناسب استفاده شود. با این کار یک دستگاه بر اساس نوع برنامه‌ریزی می‌تواند یک رادیو AM باشد یا یک تلفن بی‌سیم و یا به عنوان یک سیستم WiFi، DVB یا Bluetooth عمل کند. این انعطاف‌پذیری نرم‌افزاری، قدرت انجام کارهای سخت یا حتی غیر ممکن توسط رادیوهای سنتی را فراهم می‌آورد. در واقع رادیو نرم‌افزاری، نوعی فناوری است که می‌کوشد سهم نرم‌افزار

^۱ Joseph Mitola

^۲ Radio Frequency

را در پیاده‌سازی سیستم‌های مخابراتی افزایش دهد. در حالت ایده‌آل این سهم می‌تواند تا پایین‌ترین لایه‌های فیزیکی و نزدیکترین موقعیت به آنتن افزایش یابد. همان‌طور که در شکل ۷ نشان داده شده است در مسیر گیرنده پس از دریافت سیگنال از آنتن و تقویت آن بلافاصله سیگنال آنالوگ به دیجیتال تبدیل می‌شود و بقیه عملیات توسط نرم‌افزار انجام می‌گیرد. به همین ترتیب، در مسیر فرستنده نیز پس از انجام کلیه کارها توسط نرم‌افزار، نمونه‌های دیجیتال به آنالوگ تبدیل شده و برای ارسال تحویل آنتن می‌شود. لکن در حال حاضر محدودیت‌هایی برای این کار وجود دارد از جمله محدودیت نرخ و فرکانس کار میدل‌های آنالوگ به دیجیتال (ADC)^۱ و دیجیتال به آنالوگ (DAC)^۲. از این رو در موارد عملی عموماً لازم است تبدیل سیگنال آنالوگ به دیجیتال و بالعکس در فرکانس‌های پایین‌تر انجام شود و برخی پردازش‌ها در حوزه آنالوگ صورت گیرد. نکته‌ی کلیدی در توانمندی رادیو نرم‌افزاری، قابلیت برنامه‌ریزی نرم‌افزاری است که امکان تغییر مشخصات بنیادی رادیو از جمله نوع مدولاسیون، فرکانس کار، پهنای باند، نحوه‌ی دسترسی چندگانه، روش‌های گسترده‌ی طیف فرکانسی و الگوریتم‌های رمزنگاری و رمزگشایی را فراهم می‌آورد. بستر پیاده‌سازی و اجرای نرم‌افزار در یک رادیو نرم‌افزاری می‌تواند انواع DSP، FPGA، پردازنده‌های تعبیه شده یا حتی پردازنده‌های رایانه‌های شخصی باشد [۹۳].



شکل ۷. شکلی ایده‌آل از رادیو نرم‌افزاری

برای تحقق رادیو نرم‌افزاری لازم است ابتدا امواج آنالوگ دریافتی در گیرنده پس از انتقال به باند فرکانسی پایینیتر، با استفاده از میدل‌های آنالوگ به دیجیتال به نمادهای دیجیتال تبدیل شوند. در واحدهای فرستنده نیز خروجی بخش‌های نرم‌افزاری با استفاده از میدل‌های دیجیتال به آنالوگ به سیگنال آنالوگ ارسالی تبدیل می‌شود. این میدل‌ها مرز بین دامنه‌های سخت‌افزار و نرم‌افزار هستند. از جمله مشخصه‌هایی که در این میدل‌ها مورد توجه است فرکانس نمونه‌برداری، وضوح^۳، نسبت سیگنال به نویز، اتلاف توان، حوزه رفتار خطی و غیره است که برای رسیدن به حالت ایده‌آل، میدل مورد استفاده باید مشخصه‌های مورد نیاز طراحی را برآورده کند. به عنوان مثال، برای آنکه تبدیل گسسته زمان به پیوسته زمان، بدون از دست دادن اطلاعات باشد، رعایت نرخ ناپکوئیست^۴، حداقل دو برابر بالاترین فرکانس سیگنال آنالوگ، در نمونه‌برداری ضروری است. از طرف دیگر به منظور پیاده‌سازی ایده‌آل تمام قسمت‌های رادیو به صورت نرم‌افزاری، باید تا جای ممکن میدل‌های ADC و DAC به سمت آنتن منتقل شوند تا بخش بزرگتری از ساختار رادیو، در حوزه‌ی دیجیتال محقق گردد. اما سیگنال‌های آنالوگ در نزدیکی آنتن، در فرکانس‌های به نسبت بالا قرار دارند. بنابراین با توجه به وجود محدودیت‌های انتخاب میدل‌ها و پردازنده‌ها، ممکن است میدل‌ها در طبقات با فرکانس میانی قرار گیرند. بدین ترتیب سهم کمتری از پیاده‌سازی به واحدهای نرم‌افزاری خواهد رسید [۹۳].

^۱ Analog to Digital Converter

^۲ Digital to Analog Converter


^۳ Resolution

^۴ Nyquist Rate

از این رو با توجه به میزان استفاده از نرم‌افزار، سه سطح مختلف برای پیاده‌سازی رادیو نرم‌افزاری به صورت زیر تعریف می‌شود:

- اگر دیجیتال کردن بعد از انتقال سیگنال RF به فرکانس‌های میانی صورت گیرد، آن را SDR گویند. واضح است در سمت فرستنده هم مبدل دیجیتال به آنالوگ در موقعیتی مشابه قرار می‌گیرد.
- اگر تبدیل آنالوگ به دیجیتال بلافاصله بعد از آنتن یا بسیار نزدیک به آن انجام شود به آن (SR) Software Radio گویند که این کار مستلزم استفاده از مبدل‌های پرسرعت و پردازش دیجیتال سریع می‌باشد.
- اگر به SR قابلیت هوشمندی افزوده شود به این صورت که متناسب با محیط مورد استفاده، قابلیت تصمیم‌گیری داشته باشد و خود را با محیط وفق دهد به آن Adaptive Intelligent Software Radio گویند.

همان‌طور که در شکل ۸ ملاحظه می‌شود، مقایسه‌ای از مقدار سهم مربوط به نرم‌افزار و سخت‌افزار در رادیوهای کنونی، SDR و SR نشان داده شده است.



شکل ۸. مقایسه سهم نرم‌افزار و سخت‌افزار در رادیوهای کنونی، SDR و SR

۲-۱۰-۱- مزایا و معایب استفاده از SDR

رادیو نرم‌افزاری مزایای زیادی برای تولیدکنندگان تجهیزات مخابراتی و مصرف‌کنندگان خواهد داشت. مهمترین این مزایا عبارتند از: [۹۴]

- کاهش قیمت: معمولاً به دلیل کاهش تعداد قطعات مورد نیاز و امکان استفاده مجدد از طراحی‌های قبلی، هزینه تمام شده سیستم‌های رادیو نرم‌افزاری از سیستم‌های سخت‌افزاری کمتر است. به خصوص در تولید انبوه این تفاوت چشمگیرتر خواهد بود. در یک سیستم رادیو نرم‌افزاری، می‌توان با استفاده از یک سخت‌افزار مبتنی بر پردازنده و کدهای مختلف، قابلیت‌های گوناگونی را برای سیستم فراهم آورد.

- سهولت در طراحی، ساخت و ارتقا؛ در حالت کلی، تجهیزاتی که در محدوده RF کار می‌کنند به دلیل بالا بودن فرکانس کاری، دارای رفتارهای پیچیده‌ای هستند و در نتیجه ساخت آنها به دقت زیادی نیاز دارد. حال اگر چند سیستم با سخت‌افزارهای متفاوت داشته باشیم و بخواهیم این اجزا با یکدیگر به صورت بهینه کار کنند، به همان اندازه کار مشکل‌تر خواهد شد. این مساله باعث طولانی‌تر شدن مراحل طراحی، ساخت و پیاده‌سازی یک دستگاه جدید می‌گردد. در صورت استفاده از رادیوی نرم‌افزاری، هرچقدر عملیات دیجیتال کردن سیگنال در گیرنده زودتر اتفاق بیافتد، به همان اندازه نیاز به هماهنگی اجزای سخت‌افزاری کمتر بوده و چرخه‌ی طراحی یک محصول جدید ساده‌تر و سریع‌تر می‌شود و امکان استفاده مجدد از طرح‌های قبلی وجود خواهد داشت. همچنین ارتقاء یک سیستم بر مبنای نرم‌افزار به مراتب ساده‌تر از یک سیستم سخت‌افزاری است. در این سیستم‌ها، صرفاً با به روز رسانی نرم‌افزار می‌توان کارایی و عملکرد سیستم را بهبود داد.
- پشتیبانی از استانداردهای مختلف: در رادیوهای سنتی، دو طرف ارتباط می‌بایست از یک استاندارد واحد تبعیت کنند و عدم سازگاری دو طرف، مانع از برقراری ارتباط می‌شود. برای مثال واحدهای مختلف نظامی اعم از ارتش یا نیروی هوایی در برقراری ارتباط با مشکل عدم سازگاری تجهیزات رو به رو هستند. همچنین پلیس ممکن است همین مشکل را در برقراری ارتباط با واحدهای آتشنشانی داشته باشد. علاوه بر این سیستم‌های مخابراتی در محدوده‌های متفاوت جغرافیایی، از استانداردهای گوناگونی برای خدمات‌دهی استفاده می‌کنند، که در صورت ایجاد سازگاری بین محدوده‌های مختلف، رومینگ و پوشش خدمات در محدوده‌های وسیع‌تر، راحت‌تر اتفاق می‌افتد. فراهم کردن سازگاری بین استانداردهای مختلف ارتباطی، در محیط‌های نرم‌افزاری و از طریق الگوریتم‌های پردازشی راحت‌تر انجام می‌شود و با به کارگیری رادیو نرم‌افزاری یک سیستم می‌تواند پاسخگوی نیازهای مختلف در این حوزه باشد.

در کنار مزایای ذکر شده، این فناوری معایب و محدودیت‌هایی هم دارد که می‌توان به موارد زیر اشاره کرد:

- به دلیل استفاده از پردازنده‌ها و سخت‌افزارهایی که برای مصارف عمومی‌تر طراحی شده‌اند ممکن است توان مصرفی افزایش یابد.
- چنانچه وظایف بلوک دیگرام‌های سیستم پیچیده‌تر شود، حجم نرم‌افزاری که باید در پردازنده‌های دیجیتال ذخیره گردد، افزایش یافته و زمان ذخیره و اجرای نرم‌افزار طولانی‌تر می‌شود. با افزایش حجم نرم‌افزار، مدیریت و در نظر گرفتن معماری مناسب برای آن بسیار ضروری و امری تخصصی خواهد بود.
- به علت چند استاندارد بودن سیستم و وجود باند های فرکانسی مختلف به آنتن‌های باند پهن و طبقه‌ی RF با پهنای باند وسیع نیاز است. در نتیجه طراحی طبقه‌ی RF و انتخاب آنتن مناسب در رادیو نرم‌افزاری از اهمیت زیادی برخوردار است. توجه شود که با توجه به پهنای باند محدود آنتن‌ها، ممکن است استفاده از چند آنتن لازم باشد، که در پایانه‌های سیار چندان مطلوب نیست.
- به علت چندحالتی و چند استاندارد بودن رادیو نرم‌افزاری و همچنین پهن باند بودن طبقه‌ی RF، رنج دینامیکی سیگنال دریافتی نسبت به سیستم‌های متداول بیشتر است. در نتیجه به علت محدودیت رنج دینامیکی ADCهای موجود، باید نوعی مصالحه در طراحی سیستم و انتخاب ADC انجام شود.
- در نرم‌افزارهای ذخیره شده در سیستم، مشخصات سیستمی و انواع مهارت‌ها و تکنیک‌های به کار گرفته شده توسط برنامه‌نویس، اعم از روش‌های بهینه‌سازی و الگوریتم‌های محاسباتی به صورت نرم‌افزاری قابل دستیابی است و این امکان وجود دارد که این مهارت‌ها به طور غیر قانونی توسط رقبا کشف شود.
- برنامه‌ریزی نرم‌افزار و امکان دستکاری آن از سوی اشخاص غیر مسئول می‌تواند موجب بروز مشکلات شده و این وسایل برای مقاصد امنیتی مورد استفاده قرار گیرد.

۳-۱-۱- پیاده‌سازی رادیو نرم‌افزاری

امروزه پروژه‌های مبتنی بر رادیو نرم‌افزاری بر خلاف نام آن از دو بخش نرم‌افزار و سخت‌افزار تشکیل می‌شود و کاربران برای ساخت سیستم مورد نظر باید در هر دو حوزه‌ی نرم‌افزار و سخت‌افزار دست به طراحی و انتخاب گزینه‌های موجود بزنند. در حال حاضر ابزارهای سخت‌افزاری و نرم‌افزاری آماده‌ای که بستری را برای آزمایش‌ها و پژوهش‌های این حوزه فراهم می‌آورد، وجود دارد و کاربر باید با توجه به نیازها و همچنین در نظر گرفتن محدودیت‌ها و ضرورت‌ها، مورد مناسب را انتخاب نماید. وجود چنین بستری این امکان را برای پژوهشگران فراهم می‌آورد که به جای صرف توان و زمان برای ساخت این ابزار، از ابزارهایی که قبلاً مورد استفاده قرار گرفته و آزمایش شده است، استفاده نمایند و همچنین از تجربیات کسانی که قبلاً با آنها کار کرده‌اند نیز بهره‌مند گردند. این ابزارها را می‌توان در قالب دو بخش سخت‌افزار و نرم‌افزار مورد بررسی قرار داد [۹۴].

۱-۱۰-۳-۱ سخت افزار

شرکت‌های بزرگی که در زمینه رادیو نرم‌افزاری فعالیت دارند، برای تولید محصول، هر یک سخت‌افزار خاصی را برای رسیدن به اهداف خود در پروژه‌ها طراحی و استفاده می‌کنند ولی مراکز دانشگاهی و تحقیقاتی با توجه به محدودیت‌های بیشتر در هزینه‌ها و نیاز به تجهیزات با گستره‌ی عمل وسیع‌تر، برای اثبات عملی بودن ایده‌ها از سیستم‌های موجود در بازار با کاربرد عمومی استفاده می‌کنند. در انتخاب سخت‌افزار مولفه‌های مختلفی ایفای نقش می‌کنند که از مهمترین آنها می‌توان به داشتن قابلیت برآوردن نیازهای فنی پروژه، قیمت مناسب، در دسترس بودن منابع (منبع باز بودن) و سهولت استفاده اشاره نمود. سخت‌افزارهای خانواده USRP9 یکی از رایج‌ترین سخت‌افزارهای مورد استفاده در انواع پروژه‌های رادیو نرم‌افزاری هستند. علاوه بر این می‌توان به سخت‌افزارهای شرکتی، National Instruments Lyrtech Signal Processing و غیره اشاره نمود که تجهیزات به نسبت گرانقیمت‌تری را برای کاربردهای عمدتاً نظامی و تجاری ارائه می‌دهند. ابزار جنبی رادیو نرم‌افزاری جهانی یا به اختصار USRP^۱ سیستمی سخت‌افزاری است که توسط شرکت Ettus ارائه شده است و به کامپیوترهای شخصی امکان می‌دهد که به عنوان سیستم‌های رادیو نرم‌افزاری با پهنای باند بالا عمل کنند. در واقع این سیستم بخش‌های باند پایه و فرکانس‌های میانی دیجیتال یک سیستم مخابراتی را در دسترس کاربر قرار می‌دهد. ایده اصلی طراحی این سیستم فراهم آوردن امکان انجام تمام پردازش‌های مربوط به امواج رادیویی مانند مدولاسیون و دمدولاسیون در محیط دیجیتال و بر روی پردازنده مرکزی رایانه میزبان است. این تجهیزات هم‌اکنون در بسیاری از پروژه‌های رادیو نرم‌افزاری، به عنوان سخت‌افزار استفاده می‌شود. از جمله دلایلی که باعث محبوبیت این سخت‌افزار شده است می‌توان به متن باز بودن تمام نقشه‌ها و کدهای نرم‌افزاری مورد استفاده برای ساخت این سخت‌افزار اشاره کرد که کاربر را قادر می‌سازد به فراخور نیاز خود نسبت به تغییر و تصحیح بخش‌هایی از سخت‌افزار اقدام نماید. همچنین هزینه‌ی به نسبت مناسب آن در قبال امکاناتی که در اختیار می‌گذارد و وجود جمع‌کثیری از طراحان و کاربران آشنا با سیستم که از طریق اینترنت با هم در ارتباط بوده و با همکاری یکدیگر مشکلات سیستم را مرتفع می‌کنند، از دیگر عوامل محبوبیت آن می‌باشد.

۲-۱۰-۳-۱ نرم‌افزار

از جمله مهمترین بسته‌های نرم‌افزاری رایگان که امروزه در حوزه‌ی رادیو نرم‌افزاری مورد استفاده پژوهشگران قرار می‌گیرد، می‌توان به بسته‌ی نرم‌افزاری GNU Radio اشاره کرد. این بسته امکاناتی را برای توسعه نرم‌افزاری سیستم‌های مخابراتی در اختیار کاربر قرار می‌دهد. این نرم‌افزار به طور پیش فرض کتابخانه‌ای را برای ارتباط با سخت‌افزارهای خانواده USRP در خود

دارد، اما کاربران می‌توانند از امکانات این نرم‌افزار در ارتباط با سایر سخت‌افزارها نیز استفاده نمایند. این نرم‌افزار بر بستر سیستم عامل لینوکس نصب می‌شود و کاربران به فراخور نیازهای خود می‌توانند کدهای آن را تغییر داده و یا کدهایی به آن اضافه نمایند. از دیگر نرم‌افزارهای رایج در حوزه‌ی رادیو نرم‌افزاری می‌توان به Simulink اشاره کرد. این نرم‌افزار که از زیرمجموعه‌های نرم‌افزار MATLAB می‌باشد، قابلیت نصب بر روی سیستم عامل‌های ویندوز و لینوکس را دارد و به صورت پیش فرض کتابخانه‌ای برای ارتباط با سخت‌افزارهای خانواده USRP در آن تعبیه شده است. کدها و بلوک‌های نرم‌افزاری آماده برای استفاده در پروژه رادیو نرم‌افزاری، روز به روز به این نرم‌افزار اضافه می‌شود و در اختیار کاربران قرار می‌گیرد.

۱۱-۱- جمع‌بندی فصل ۱

شبکه هوشمند برق یک نسخه ارتقاء یافته از شبکه برق قدیمی است که در آن تکنولوژی‌های اطلاعات و ارتباطات به طور عمیقی با سیستم‌های شبکه برق پیوند می‌خورند. یکی از ویژگی‌های پیشرفته شبکه هوشمند کنترل تطبیقی و مدیریت پویای پاسخ به تقاضاست که به بازدهی و قابلیت اطمینان خدمات ارائه شده شبکه برق کمک می‌کند. مخابرات بی‌سیم به طور موثری بسیاری از کاربردها و ویژگی‌های شبکه هوشمند که نیاز به ارتباطات قابل انعطاف در نقاط جغرافیایی مختلف دارد را پشتیبانی می‌نماید. در این گزارش به استفاده از رادیو شناختی در شبکه هوشمند برق پرداخته شده که برخلاف شبکه‌های بی‌سیم معمولی که از اختصاص پهنای باند به صورت ثابت و مشخص استفاده می‌کنند، از ظرفیت پهنای باند به صورت پویا و بهینه استفاده می‌نماید. کاربردهای مختلف رادیو شناختی به همراه معماری‌های مختلف آن در شبکه هوشمند مورد بررسی قرار گرفته است و نشان داده شده که می‌تواند در قسمت‌های مختلف شبکه برق از جمله تولید، انتقال و توزیع مفید باشد. از منظر گستردگی و فاصله نیز این کاربردها به سه دسته خانگی، همسایگی و نواحی گسترده تقسیم می‌شوند. شبکه خانگی از وسایل هوشمند خانگی تشکیل شده که به یک درگاه خانگی متصل می‌شوند. از مجموعه چند درگاه خانگی یک شبکه همسایگی بوجود می‌آید که آن‌ها نیز اطلاعات خود را به یک درگاه همسایگی ارسال می‌کنند. در این بخش علاوه بر درگاه‌های خانگی معمولاً منابع تولید توزیع شده نیز وجود دارند. اطلاعات درگاه‌های همسایگی و همچنین اطلاعات نیروگاه‌ها و دیگر تولیدکننده‌ها به مرکز داده شبکه ناحیه گسترده مخابره می‌شود تا براساس نیاز شبکه برای مصرف‌کننده و تولیدکننده تصمیم گرفته شود.

برای اینکه یک وسیله رادیو شناختگر تلقی شود باید بتواند چندین کار را انجام دهد. ابتدا رادیو شناختگر باید بتواند محیط اطراف خود را از لحاظ پهنای باند و طیف فرکانسی حس کرده و پایش نماید که روش‌های مختلف حس نمودن پهنای باندی که در شبکه هوشمند برق بیشتر مورد استفاده هستند نیز در گزارش آورده شده است. همچنین پس از پایش طیف فرکانسی و تشخیص فرکانس‌های خالی و مورد استفاده و همچنین نوع کاربرانی که قرار است به آن‌ها پهنای باند اختصاص داده شود، رادیو شناختگر باید تصمیمی برای اختصاص کانال فرکانسی اتخاذ کند. این تصمیم می‌تواند با اهداف مختلفی از جمله استفاده بهینه از ظرفیت، کاهش تداخل بین کانال‌ها، استفاده بهینه از توان و غیره صورت گیرد. علاوه بر حس، پایش و اختصاص کانال که در لایه فیزیکی اتفاق می‌افتد، ادوات رادیو شناختی باید اطلاعات جمع‌آوری شده را به نقاط یا درگاه‌هایی ارسال کنند تا تصمیم بهینه در مورد شبکه گرفته شود. به همین منظور پروتکل‌های مربوط به لایه MAC و مسیریابی که مختص شبکه‌های مبتنی بر رادیو شناختی هستند نیز اهمیت پیدا کرده که مختصری نیز به آن‌ها پرداخته شده است.

مراجع فصل ۱

- [1] S.-L. Kim, P. Kitsos, M. Nekovee, F. R. Yu, and Y. Zhang, "Guest editorial: Smart grid communications systems," *IEEE Systems Journal*, vol. 8, pp. 417-421, 2014.
- [2] W. Wang, Y. Xu, and M. Khanna, "A survey on the communication architectures in smart grid," *Computer networks*, vol. 55, pp. 3604-3629, 2011.
- [3] R. Yu, Y. Zhang, S. Gjessing, C. Yuen, S. Xie, and M. Guizani, "Cognitive radio based hierarchical communications infrastructure for smart grid," *IEEE network*, vol. 25, pp. 6-14, 2011.
- [4] V. Dehalwar, M. Kolhe, and S. Kolhe, "Cognitive radio application for smart grid," *Int. J. Smart Grid Clean Energy*, vol. 1, pp. 79-84, 2012.
- [5] H. Sun, A. Nallanathan, B. Tan, J. S. Thompson, J. Jiang, and H. V. Poor, "Relaying technologies for smart grid communications," *IEEE Wireless Communications*, vol. 19, pp. 52-59, 2012.
- [6] E. Yaacoub and A. Abu-Dayya, "Automatic meter reading in the smart grid using contention based random access over the free cellular spectrum," *Computer Networks*, vol. 59, pp. 171-183, 2014.
- [7] M. Yigit, V. C. Gungor, and S. Baktir, "Cloud computing for smart grid applications," *Computer Networks*, vol. 70, pp. 312-329, 2014.
- [8] S. F. Bush, "Network theory and smart grid distribution automation," *IEEE Journal on Selected Areas in Communications*, vol. 32, pp. 1451-1459, 2014.
- [9] R. Deng, Z. Yang, M.-Y. Chow, and J. Chen, "A survey on demand response in smart grids: Mathematical models and approaches," *IEEE Transactions on Industrial Informatics*, vol. 11, pp. 570-582, 2015.
- [10] R. Ma, H.-H. Chen, Y.-R. Huang, and W. Meng, "Smart grid communication: Its challenges and opportunities," *IEEE transactions on Smart Grid*, vol. 4, pp. 36-46, 2013.
- [11] Ş. Temel, V. Ç. Gungor, and T. Koçak, "Routing protocol design guidelines for smart grid environments," *Computer Networks*, vol. 60, pp. 160-170, 2014.
- [12] S. Güzelgöz, H. Arslan, A. Islam, and A. Domijan, "A review of wireless and PLC propagation channel characteristics for smart grid environments," *Journal of Electrical and Computer Engineering*, vol. 2011, p. 15, 2011.
- [13] G. Sebaali and B. L. Evans, "Design tradeoffs in joint powerline and wireless transmission for smart grid communications," in *2015 IEEE International Symposium on Power Line Communications and Its Applications (ISPLC)*, 2015, pp. 83-88.
- [14] C. Eris, M. Saimler, V. C. Gungor, E. Fadel, and I. F. Akyildiz, "Lifetime analysis of wireless sensor nodes in different smart grid environments," *Wireless networks*, vol. 20, pp. 2053-2062, 2014.
- [15] V. C. Gungor, B. Lu, and G. P. Hancke, "Opportunities and challenges of wireless sensor networks in smart grid," *IEEE transactions on industrial electronics*, vol. 57, pp. 3557-3564, 2010.
- [16] M. Yigit, O. D. Incel, and V. C. Gungor, "On the interdependency between multi-channel scheduling and tree-based routing for WSNs in smart grid environments," *Computer Networks*, vol. 65, pp. 1-20, 2014.
- [17] A. S. Cacciapuoti, M. Caleffi, F. Marino, and L. Paura, "Sensing-time optimization in cognitive radio enabling smart grid," in *2014 Euro Med Telco Conference (EMTC)*, 2014, pp. 1-6.

- [18] I. F. Akyildiz, W.-Y. Lee, M. C. Vuran, and S. Mohanty, "NeXt generation/dynamic spectrum access/cognitive radio wireless networks: A survey," *Computer networks*, vol. 50, pp. 2127-2159, 2006.
- [19] W. He, K. Li, Q. Zhou, and S. Li, "A CR spectrum allocation algorithm in smart grid wireless sensor network," *Algorithms*, vol. 7, pp. 510-522, 2014.
- [20] A. Aijaz and A.-H. Aghvami, "PRMA-based cognitive machine-to-machine communications in smart grid networks," *IEEE Transactions on Vehicular Technology*, vol. 64, pp. 3608-3623, 2014.
- [21] Q. Li, Z. Feng, W. Li, T. A. Gulliver, and P. Zhang, "Joint spatial and temporal spectrum sharing for demand response management in cognitive radio enabled smart grid," *IEEE Transactions on Smart Grid*, vol. 5, pp. 1993-2001, 2014.
- [22] V. C. Gungor and D. Sahin, "Cognitive radio networks for smart grid applications: A promising technology to overcome spectrum inefficiency," *IEEE Vehicular Technology Magazine*, vol. 7, pp. 41-46, 2012.
- [23] Z. A. Khan and Y. Faheem, "Cognitive radio sensor networks: Smart communication for smart grids—A case study of Pakistan," *Renewable and Sustainable Energy Reviews*, vol. 40, pp. 463-474, 2014.
- [24] C.-S. Sum, H. Harada, F. Kojima, Z. Lan, and R. Funada, "Smart utility networks in TV white space," *IEEE Communications Magazine*, vol. 49, pp. 132-139, 2011.
- [25] A. A. Khan, M. H. Rehmani, and M. Reisslein, "Cognitive radio for smart grids: Survey of architectures, spectrum sensing mechanisms, and networking protocols," *IEEE Communications Surveys & Tutorials*, vol. 18, pp. 860-898, 2015.
- [26] M. H. Rehmani, A. C. Viana, H. Khalife, and S. Fdida, "Surf: A distributed channel selection strategy for data dissemination in multi-hop cognitive radio networks," *Computer Communications*, vol. 36, pp. 1172-1185, 2013.
- [27] V. Kouhdaragh, D. Tarchi, A. V. Coralli, and G. E. Corazza, "Cognitive radio based smart grid networks," in *2013 24th Tyrrhenian International Workshop on Digital Communications-Green ICT (TIWDC)*, 2013, pp. 1-6.
- [28] B. Ramanathan and V. Vittal, "A framework for evaluation of advanced direct load control with minimum disruption," *IEEE Transactions on Power Systems*, vol. 23, pp. 1681-1688, 2008.
- [29] J. Wang, M. Ghosh, and K. Challapali, "Emerging cognitive radio applications: A survey," *IEEE Communications Magazine*, vol. 49, pp. 74-81, 2011.
- [30] A. Abdrabou and A. M. Gaouda, "Uninterrupted wireless data transfer for smart grids in the presence of high power transients," *IEEE Systems Journal*, vol. 9, pp. 567-577, 2013.
- [31] A. Abdrabou and A. M. Gaouda, "Considerations for packet delivery reliability over polling-based wireless networks in smart grids," *Computers & Electrical Engineering*, vol. 41, pp. 368-382, 2015.
- [32] S. A. Bhatti, Q. Shan, I. A. Glover, R. Atkinson, I. E. Portugues, P. J. Moore, *et al.*, "Impulsive noise modelling and prediction of its impact on the performance of WLAN receiver," in *2009 17th European Signal Processing Conference*, 2009, pp. 1680-1684.
- [33] C. Klünder and J. L. ter Haseborg, "Effects of high-power and transient disturbances on wireless communication systems operating inside the 2.4 GHz ISM band," in *2010 IEEE International Symposium on Electromagnetic Compatibility*, 2010, pp. 359-363.
- [34] M. G. Sanchez, I. Cuinas, and A. V. Alejos, "Interference and impairments in radio communication systems due to industrial shot noise," in *2007 IEEE International Symposium on Industrial Electronics*, 2007, pp. 1849-1854.

- [35] Q. Shan, S. Bhatti, I. A. Glover, R. Atkinson, I. E. Portugues, P. J. Moore, *et al.*, "Characteristics of impulsive noise in electricity substations," in *2009 17th European Signal Processing Conference*, 2009, pp. 2136-2140.
- [36] Q. Yu and R. J. Johnson, "Integration of wireless communications with modernized power grids: EMI impacts and considerations," in *2011 IEEE International Symposium on Electromagnetic Compatibility*, 2011, pp. 329-334.
- [37] L. Bedogni, A. Achtzehn, M. Petrova, and P. Mähönen, "Smart meters with TV gray spaces connectivity: A feasibility study for two reference network topologies," in *2014 Eleventh Annual IEEE International Conference on Sensing, Communication, and Networking (SECON)*, 2014, pp. 537-545.
- [38] L. Bedogni, A. Trotta, M. Di Felice, and L. Bononi, "Machine-to-machine communication over TV white spaces for smart metering applications," in *2013 22nd International Conference on Computer Communication and Networks (ICCCN)*, 2013, pp. 1-7.
- [39] C. Müller, H. Georg, M. Putzke, and C. Wietfeld, "Performance analysis of radio propagation models for smart grid applications," in *2011 IEEE International Conference on Smart Grid Communications (SmartGridComm)*, 2011, pp. 96-101.
- [40] N. Lu, "An evaluation of the HVAC load potential for providing load balancing service," *IEEE Transactions on Smart Grid*, vol. 3, pp. 1263-1270, 2012.
- [41] L. Zheng, N. Lu, and L. Cai, "Reliable wireless communication networks for demand response control," *IEEE Transactions on Smart Grid*, vol. 4, pp. 133-140, 2013.
- [42] L. T. Berger and K. Iniewski, *Smart grid applications, communications, and security*: John Wiley & Sons, 2012.
- [43] V. Terzija, G. Valverde, D. Cai, P. Regulski, V. Madani, J. Fitch, *et al.*, "Wide-area monitoring, protection, and control of future electric power networks," *Proceedings of the IEEE*, vol. 99, pp. 80-93, 2010.
- [44] H. Wu, K. S. Tsakalis, and G. T. Heydt, "Evaluation of time delay effects to wide-area power system stabilizer design," *IEEE Transactions on Power Systems*, vol. 19, pp. 1935-1941, 2004.
- [45] U. DoE, "Communications requirements of smart grid technologies," *US Department of Energy, Tech. Rep.*, pp. 1-69, 2010.
- [46] T. Li, J. Ren, and X. Tang, "Secure wireless monitoring and control systems for smart grid and smart home," *IEEE Wireless Communications*, vol. 19, pp. 66-73, 2012.
- [47] R. C. Qiu, Z. Hu, Z. Chen, N. Guo, R. Ranganathan, S. Hou, *et al.*, "Cognitive radio network for the smart grid: Experimental system architecture, control algorithms, security, and microgrid testbed," *IEEE Transactions on Smart Grid*, vol. 2, pp. 724-740, 2011.
- [48] Y. Zhang, R. Yu, M. Nekovee, Y. Liu, S. Xie, and S. Gjessing, "Cognitive machine-to-machine communications: visions and potentials for the smart grid," *IEEE network*, vol. 26, pp. 6-13, 2012.
- [49] P. Ferrari, E. Sisinni, A. Flammini, and A. Depari, "Adding accurate timestamping capability to wireless networks for smart grids," *Computer Networks*, vol. 67, pp. 1-13, 2014.
- [50] Z. Zhu, S. Lambotharan, W. H. Chin, and Z. Fan, "Overview of demand management in smart grid and enabling wireless communication technologies," *IEEE Wireless Communications*, vol. 19, pp. 48-56, 2012.
- [51] M. Erol-Kantarci and H. T. Mouftah, "Energy-efficient information and communication infrastructures in the smart grid: A survey on interactions and open issues," *IEEE Communications Surveys & Tutorials*, vol. 17, pp. 179-197, 2014.

- [52] N. Ghasemi and S. Hosseini, "Comparison of smart grid with cognitive radio: Solutions to spectrum scarcity," in *2010 The 12th International Conference on Advanced Communication Technology (ICACT)*, 2010, pp. 898-903.
- [53] J. Huang, H. Wang, Y. Qian, and C. Wang, "Priority-based traffic scheduling and utility optimization for cognitive radio communication infrastructure-based smart grid," *IEEE Transactions on Smart Grid*, vol. 4, pp. 78-86, 2013.
- [54] V. C. Gungor, D. Sahin, T. Kocak, S. Ergut, C. Buccella, C. Cecati, *et al.*, "Smart grid technologies: Communication technologies and standards," *IEEE transactions on Industrial informatics*, vol. 7, pp. 529-539, 2011.
- [55] U. S. Premaratne, I. Khalil, and M. Atiquzzaman, "Secure and reliable surveillance over cognitive radio sensor networks in smart grid," *Pervasive and Mobile Computing*, vol. 22, pp. 3-15, 2015.
- [56] K.-H. Chang and B. Mason, "The IEEE 802.15. 4g standard for smart metering utility networks," in *2012 IEEE Third international conference on smart grid communications (SmartGridComm)*, 2012, pp. 476-480.
- [57] C. R. Stevenson, G. Chouinard, Z. Lei, W. Hu, S. J. Shellhammer, and W. Caldwell, "IEEE 802.22: The first cognitive radio wireless regional area network standard," *IEEE communications magazine*, vol. 47, pp. 130-138, 2009.
- [58] A. O. Bicen, O. B. Akan, and V. C. Gungor, "Spectrum-aware and cognitive sensor networks for smart grid applications," *IEEE Communications Magazine*, vol. 50, pp. 158-165, 2012.
- [59] E. Ancillotti, R. Bruno, and M. Conti, "The role of communication systems in smart grids: Architectures, technical solutions and research challenges," *Computer Communications*, vol. 36, pp. 1665-1697, 2013.
- [60] M. Kuzlu, M. Pipattanasomporn, and S. Rahman, "Communication network requirements for major smart grid applications in HAN, NAN and WAN," *Computer Networks*, vol. 67, pp. 74-88, 2014.
- [61] K. Sharma and L. M. Saini, "Performance analysis of smart metering for smart grid: An overview," *Renewable and Sustainable Energy Reviews*, vol. 49, pp. 720-735, 2015.
- [62] M. B. Mollah and S. S. Islam, "Towards IEEE 802.22 based SCADA system for future distributed system," in *2012 International Conference on Informatics, Electronics & Vision (ICIEV)*, 2012, pp. 1075-1080.
- [63] J. Zhou, R. Q. Hu, and Y. Qian, "Traffic scheduling for smart grid in rural areas with cognitive radios," in *2012 IEEE Global Communications Conference (GLOBECOM)*, 2012, pp. 5172-5176.
- [64] H. Wang, Y. Qian, and H. Sharif, "Multimedia communications over cognitive radio networks for smart grid applications," *IEEE wireless communications*, vol. 20, pp. 125-132, 2013.
- [65] O. Fatemieh, R. Chandra, and C. A. Gunter, "Low cost and secure smart meter communications using the TV white spaces," in *2010 3rd International Symposium on Resilient Control Systems*, 2010, pp. 37-42.
- [66] B. Li, B. Zhang, J. Guo, and J. Yao, "Study on cognitive radio based wireless access communication of power line and substation monitoring system of smart grid," in *2012 International Conference on Computer Science and Service System*, 2012, pp. 1146-1149.
- [67] K. Nagothu, B. Kelley, M. Jamshidi, and A. Rajaei, "Persistent Net-AMI for microgrid infrastructure using cognitive radio on cloud data centers," *IEEE Systems Journal*, vol. 6, pp. 4-15, 2011.

- [68] F. Liu, J. Wang, Y. Han, and P. Han, "Cognitive radio networks for smart grid communications," in *2013 9th Asian Control Conference (ASCC)*, 2013, pp. 1-5.
- [69] J. K. Thathagar, "Cognitive radio communication architecture in smart grid reconfigurability," in *2012 1st International Conference on Emerging Technology Trends in Electronics, Communication & Networking*, 2012, pp. 1-6.
- [70] A. A. Sreesha, S. Somal, and I.-T. Lu, "Cognitive radio based wireless sensor network architecture for smart grid utility," in *2011 IEEE Long Island Systems, Applications and Technology Conference*, 2011, pp. 1-7.
- [71] R. Amin, J. Martin, and X. Zhou, "Smart grid communication using next generation heterogeneous wireless networks," in *2012 IEEE Third International Conference on Smart Grid Communications (SmartGridComm)*, 2012, pp. 229-234.
- [72] Q. D. Vo, J.-P. Choi, H. M. Chang, and W. C. Lee, "Green perspective cognitive radio-based M2M communications for smart meters," in *2010 International Conference on Information and Communication Technology Convergence (ICTC)*, 2010, pp. 382-383.
- [73] S. Bu and F. R. Yu, "Green cognitive mobile networks with small cells for multimedia communications in the smart grid environment," *IEEE Transactions on Vehicular Technology*, vol. 63, pp. 2115-2126, 2014.
- [74] S. Bu, F. R. Yu, and Y. Qian, "Energy-efficient cognitive heterogeneous networks powered by the smart grid," in *2013 Proceedings IEEE INFOCOM*, 2013, pp. 980-988.
- [75] S. Komaki, "Heterogeneous cognitive radio on fiber technologies for university and/or community smart grids," in *2013 IEEE 4th International Conference on Photonics (ICP)*, 2013, pp. 1-4.
- [76] Y. Han, J. Wang, Q. Zhao, and P. Han, "Cognitive information communication network for smart grid," in *2012 IEEE International Conference on Information Science and Technology*, 2012, pp. 847-850.
- [77] A. S. Cacciapuoti, M. Caleffi, F. Marino, and L. Paura, "Enabling smart grid via TV white space cognitive radio," in *2015 IEEE International Conference on Communication Workshop (ICCW)*, 2015, pp. 568-572.
- [78] M. Brew, F. Darbari, L. H. Crockett, M. B. Waddell, M. Fitch, S. Weiss, *et al.*, "UHF white space network for rural smart grid communications," in *2011 IEEE International Conference on Smart Grid Communications (SmartGridComm)*, 2011, pp. 138-142.
- [79] J. Gao, J. Wang, B. Wang, and X. Song, "Cognitive radio based communication network architecture for smart grid," in *2012 IEEE International Conference on Information Science and Technology*, 2012, pp. 886-888.
- [80] A. Ghassemi, S. Bavarian, and L. Lampe, "Cognitive radio for smart grid communications," in *2010 First IEEE International Conference on Smart Grid Communications*, 2010, pp. 297-302.
- [81] A. Rajaei, K. Nagothu, B. Kelley, and M. Jamshidi, "Throughput analysis on cognitive radio networks for AMI meters in smart grid," in *Proc. ICNC*, 2012.
- [82] M. Subhedar and G. Birajdar, "Spectrum sensing techniques in cognitive radio networks: A survey," *International Journal of Next-Generation Networks*, vol. 3, pp. 37-51, 2011.
- [83] R. Deng, J. Chen, X. Cao, Y. Zhang, S. Maharjan, and S. Gjessing, "Sensing-performance tradeoff in cognitive radio enabled smart grid," *IEEE Transactions on Smart Grid*, vol. 4, pp. 302-310, 2013.

- [84] Y. Saleem and M. H. Rehmani, "Primary radio user activity models for cognitive radio networks: A survey," *Journal of Network and Computer Applications*, vol. 43, pp. 1-16, 2014.
- [85] G. A. Shah, V. C. Gungor, and O. B. Akan, "A cross-layer design for QoS support in cognitive radio sensor networks for smart grid applications," in *2012 IEEE International Conference on Communications (ICC)*, 2012, pp. 1378-1382.
- [86] G. A. Shah, V. C. Gungor, and O. B. Akan, "A cross-layer QoS-aware communication framework in cognitive radio sensor networks for smart grid applications," *IEEE Transactions on Industrial Informatics*, vol. 9, pp. 1477-1485, 2013.
- [87] A. Aijaz, S. Ping, M. R. Akhavan, and A.-H. Aghvami, "CRB-MAC: A receiver-based MAC protocol for cognitive radio equipped smart grid sensor networks," *IEEE Sensors Journal*, vol. 14, pp. 4325-4333, 2014.
- [88] K. Akkaya, S. Uludag, X. Cheng, K.-S. Lui, C. Hu, F. Zhang, *et al.*, "Editorial for the special issue on routing in smart grid communication networks," *Ad Hoc Networks*, vol. 22, pp. 1-2, 2014.
- [89] R. Prior, D. E. Lucani, Y. Phulpin, M. Nistor, and J. Barros, "Network coding protocols for smart grid communications," *IEEE Transactions on Smart Grid*, vol. 5, pp. 1523-1531, 2014.
- [90] A. I. Sabbah, A. El-Mougy, and M. Ibnkahla, "A survey of networking challenges and routing protocols in smart grids," *IEEE Transactions on Industrial Informatics*, vol. 10, pp. 210-221, 2013.
- [91] A. Aijaz, H. Su, and A.-H. Aghvami, "CORPL: A routing protocol for cognitive radio enabled AMI networks," *IEEE Transactions on Smart Grid*, vol. 6, pp. 477-485, 2014.
- [92] J. Mitola, "Software radios: Survey, critical evaluation and future directions," *IEEE Aerospace and Electronic Systems Magazine*, vol. 8, pp. 25-36, 1993.
- [93] T. Hentschel, G. Fettweis, and W. Tuttlebee, "The digital front-end: Bridge between RF and baseband processing," in *Software defined radio: enabling technologies*, ed: Wiley Online Library, 2002, pp. 151-198.
- [94] T. Ulversoy, "Software defined radio: Challenges and opportunities," *IEEE Communications Surveys & Tutorials*, vol. 12, pp. 531-550, 2010.

فصل ۲

بررسی پروژه‌های انجام شده در دنیا در خصوص هوشمندسازی سیستم‌های ارتباطی و بکارگیری آنها در صنعت برق

۲-۱- مقدمه

در این فصل نتایج حاصل از مطالعات تطبیقی در خصوص پروژه‌های انجام شده در دنیا که در رابطه با هوشمندسازی سیستم‌های ارتباطی و کاربردهایشان در صنعت برق بوده است، ارائه می‌شود. نظر به جدید بودن استفاده از روش‌های هوش مصنوعی در سیستم‌های ارتباطی انتظار اولیه ما بر این بود که پروژه‌های زیادی در این خصوص که در صنعت برق نیز مورد استفاده قرار گرفته شده باشند یافت نشوند و این امر در حین جستجوهای صورت گرفته مورد تأیید قرار گرفت. با اینحال دو پروژه در صنعت که در قالب پروژه‌های صورت گرفته در برنامه‌های پژوهشی اتحادیه اروپا (FP7) و یک پروژه انجام شده در دانشگاه آلیامای آمریکا و با پشتیبانی واحد تحقیقات نیروی هوایی آمریکا صورت گرفته بود، معرفی و مورد تحلیل قرار گرفت.

پروژه اول Sunseed می‌باشد که در بخشی از آن جهت افزایش ضریب اطمینان ارتباطات، مفهوم چند-ارتباطی^۱ را مورد توجه قرار داده و از آن به صورت مستقیم در شبکه هوشمند برق استفاده نموده است. پروژه دوم که ان هم در اروپا انجام شده است، SmartEMC2 می‌باشد که یک سامانه مبتنی بر Massive-MIMO^۲ را جهت بکارگیری در یک شبکه هوشمند برق معرفی نموده است؛ که جهت کاهش واحدهای سخت‌افزاری و قیمت، یک روش انتخاب آنتن را ارائه نموده است. گفتنی است که استفاده از روش‌های مختلف مبتنی بر هوش مصنوعی جهت ارتقاء عملکرد واحدهای M-MIMO در مرحله بعدی این پروژه به صورت مبسوط‌تری مورد توجه و بررسی قرار خواهند گرفت. با اینحال یک مورد عملی از آن در این پروژه ارائه و مورد بررسی قرار گرفته است. پروژه سوم نیز یک نمونه آزمایشگاهی از پیاده‌سازی الگوریتم‌های یادگیری تقویتی و انتقال یادگیری بر روی واحدهای سخت‌افزاری و نرم‌افزاری جهت انجام تعویض فرکانس در یک سیستم رادیو شناختی را ارائه می‌دهد.

گفتنی است که روش‌های مبتنی بر هوش مصنوعی و یادگیری ماشین در پروژه‌های مختلفی (منجمله پروژه‌های اروپایی) جهت ارتقاء عملکرد سامانه‌های مختلف مورد استفاده در شبکه‌های هوشمند برقرسانی (نظیر پایش سیستم) ارائه و مورد بررسی قرار گرفته‌اند ولی آنچه مورد توجه ما در این پروژه است، آندسته از پروژه‌هایی هستند که این روش‌های هوش مصنوعی در بخش‌های ارتباطی آنها مور استفاده قرار گرفته‌اند.

۲-۲- پروژه SUNSEED

این پروژه توسط اتحادیه اروپا در خلال سالهای ۲۰۱۴ تا ۲۰۱۷ و با بودجه‌ای بالغ بر ۴.۷ €M و تحت عنوان FP7-ICT-2013-11 صورت گرفته است [۱]. رویکرد اتخاذ شده در این پروژه مبتنی بر تحقیق، طراحی و توسعه روش‌هایی جهت استفاده از شبکه‌های ارتباطی کنونی از سوی اپراتورهای مخابرات و زیرساخت‌های مخابراتی مورد استفاده در بخش انرژی می‌باشد. این شبکه‌ها می‌توانند به طور مناسب برای تشکیل زیرساخت ارتباطی همگرا برای شبکه‌های انرژی هوشمند آینده متصل شوند. در بخشی از این پروژه با استفاده همزمان از شبکه‌های دسترسی چندگانه روش‌هایی را جهت ارتقاء ضریب اطمینان سیستم ارتباطی ارائه می‌دهد که در بخش بعدی به آن خواهیم پرداخت.

¹ Multi-Connectivity


² Multiple Input Multiple Output

۱-۲-۲- ایجاد ارتباطات با ضریب اطمینان بالا از طریق شبکه‌های دسترسی چندگانه

معماری ارتباطات در پروژه SUNSEED مبتنی بر نودهای سیستم WAMS¹ است که از طریق شبکه‌های تلفن همراه Telekom -SLOVENIJE متصل می‌شوند. در SUNSEED، به خصوص ارتباط برای گره‌های WAMS-SPM² به این معنی است که برای انجام الگوریتم تخمین حالت با یک دیدگاه دقیق نسبت به وضعیت شبکه قدرت، اطلاعات مرتبط با اکثر نودهای SPM باید در حدود ۱ ثانیه بعد از زمان اندازه‌گیری در دسترس باشند. به هنگام ایجاد اختلال در مسیر ارتباطی (به عنوان مثال با خرابی تجهیزات و یا قطع فیبر نوری) پایش لحظه‌ای شبکه قدرت در صورتی به خطر خواهد افتاد که مکانیزم ارتباطی تنها به یک تکنولوژی واحد وابسته باشد. در SUNSEED امکان بهره‌برداری از تکنولوژی‌های ارتباطی چندگانه برای ارتقاء تاب‌آوری مسیر ارتباطی بین گره‌های WAMS و شبکه مرکزی (که اندازه‌گیری‌های بلادرنگ در آن جمع‌آوری می‌شوند) مورد بررسی قرار گرفته‌اند. مطالعات بر روی فن‌آوری‌های LTE، WiFi، و 3G- UMTS/ HSDPA صورت گرفته‌اند.

۲-۲-۲- مدل سیستم

در شکل ۹ یک تجهیز M2M که نیازمند ارتباطی قابل اطمینان با یک میزبان نهایی خاص (به عنوان مثال، یک دستگاه کنترل، اندازه‌گیری، وضعیت و پیام هشدار دهنده به یک واحد کنترل) است، نشان داده شده است.



شکل ۹. یک تجهیز M2M و مسیرهای ارتباطی آن با نود انتهایی (Remote Host)

تجهیز M2M دارای N رابط ارتباطی (سیمی و بیسیم) برای رسیدن به میزبان نهایی است. برخی از تکنولوژی‌ها اغلب مستقل هستند در حالی که ارتباطات سلولی که یک ایستگاه مبنا را به اشتراک می‌گذارند (مانند 3G، LTE) ممکن است درجه بالاتری از خرابی همزمان داشته باشند.

¹ WAMS: Wide Area Measurement System

² SPM: Synchro Phasor Measurement

۳-۲-۲- روش‌های ارسال داده‌ها

در این پروژه، سه روش جهت ارسال داده‌ها ارائه شده است که گام‌های مقدماتی برای استفاده هوشمندانه از سیستم‌های مخابراتی مختلف و در دسترس را برمی‌دارد [2]. موضوع Multi-Connectivity خود در این اواخر توجه پژوهشگران را جذب کرده است.

۱-۲-۲-۳ ارسال یکسان داده‌ها^۱

این یک روش ساده برای افزایش قابلیت اطمینان است که در آن فرستنده یک کپی کامل از داده را از طریق هر یک از رابط‌های موجود ارسال می‌کند. از آنجا که تنها یک نسخه در گیرنده مورد نیاز است تا پیام را رمزگشایی کند، این امر باعث می‌شود که ارتباط قابل اطمینانی صورت گیرد، ولی در عین حال این استراتژی به منابعی به اندازه N برابر بیشتر از یک انتقال سنتی نیاز دارد.

۲-۲-۳-۲ استفاده از k عدد از N داده ارسال^۲

به جای فرستادن یک نسخه کامل از داده‌ها در هر رابط، این امکان وجود دارد که تنها یک بخش از داده در هر رابط ارسال شود و در نهایت به نحو مناسبی آنها با یکدیگر ادغام شوند. به این ترتیب قابلیت تعامل مابین ضریب اطمینان و تأخیر را می‌توان ایجاد نمود. این امر را می‌توان به صورت k -out of- N و یا ضریب‌دهی انجام داد؛ که در این بخش به معرفی روش اول می‌پردازیم.

در روش k -out of- N ، از طریق تقسیم‌سازی این امکان وجود دارد که بسته‌های داده‌ای به اندازه مساوی را از پیام اولیه تولید نمود و در N مسیر ارسال نمود، به طوری که گیرنده پس از دریافت بسته‌های تولیدی و ادغام k عدد از آنها قادر خواهد بود تا با موفقیت پیام را رمزگشایی کند. این استراتژی اجازه می‌دهد قابلیت اطمینان و تأخیر را با یکدیگر تعامل نمود، چرا که داده‌های تولید شده بزرگتر در نهایت منجر به قابلیت اطمینان بالاتر اما زمان انتقال طولانی‌تر می‌شوند، در حالیکه داده‌های تولید شده کوچکتر، حفاظت از خطای کمتری را نسبت به زمان انتقال کوتاه‌تر ارایه می‌دهند.


۳-۲-۳-۳ روش ضریب‌دهی^۳

هدف از این روش تقسیم بسته‌ها در میان واسط‌ها به طوری است که اندازه بسته‌های ایجاد شده براساس یک هدف خاص بهینه شده‌است. این هدف می‌تواند برای به حداقل رساندن تأخیر انتقال کلی مورد انتظار یا حداکثرسازی قابلیت اطمینان برای یک محدودیت تأخیر داده‌شده باشد. نحوه عملکرد سه روش فوق‌الذکر در شکل ۱۰ نشان داده شده‌اند.

¹ Cloning


² k -out of- N

³ Weighted



شکل ۱۰. ارسال داده‌ها از طریق روش‌های مختلف: (a) ارسال یکسان (Cloning). (b) k-out of-N. (c) ضریب‌دهی (Weighted)

نتایج بدست آمده از طریق این سه روش در شکل زیر نشان داده شده است [۲]:



شکل ۱۱. نتایج بدست آمده از اعمال Multi-Connectivity: رابطه ضرایب اطمینان ($F(x)$) بر اساس تأخیر

همانطور که در شکل ۱۱ نشان داده شده است، ارسال اطلاعات از طریق یک فیبر نوری به همراه حداکثر دو اتصال بیسیم ($C1, C2$) صورت گرفته است که این اتصالات بیسیم شامل سیستم‌های LTE, GPRS, EDGE, HSDPA می‌شوند. منحنی‌های زرد رنگ (که از روش cloning استفاده می‌کنند و طبیعتاً بیشترین پهنای باند را اشغال می‌کنند)، می‌توانند بیشترین ضرایب اطمینان ارسال اطلاعات را به نمایش بگذارند.


از سوی دیگر در منحنی‌های بنفش (که از ادغام k -عدد اتصال از N -عدد مورد استفاده بهره‌گیری می‌کنند و روش ایشان نسبتاً ساده و بدون بهینه‌سازی خاصی است)، کمترین بهبود را در مقایسه با روش‌های دیگر نشان می‌دهند. سومین روش، که مقدار ارسال اطلاعات بر روی اتصالات را از روی روابط ریاضی بهینه می‌کند (و جزئیات آن در [۲] به صورت مبسوط آمده است)، هرچند که پهنای باندی معادل با پهنای باند روش k -out-of- N را اشغال می‌کند، ولی عملکردی بسیار بهتر از آن را ارائه می‌دهد.

۳-۲- پروژه SMARTEREMC2

هدف این پروژه که نام خود را از عبارت "Smarter Grid: Empowering SG Market ACTors through ICT" گرفته است، توسعه ابزارهای ICT جهت پشتیبانی از ادغام مشتریان و سرویس‌های پاسخ بار DR^1 و همینطور پشتیبانی از تولید پراکنده از طریق نیروگاه‌های مجازی است. به مدت دو سال از ۲۰۱۵ تا ۲۰۱۷ و با بودجه‌ای بالغ بر ۳.۸ میلیون یورو صورت گرفته است. با بررسی مدارک این پروژه ملاحظه گردید که در بخشی از آن یک سیستم MIMO برای انجام ارتباطات مورد نیاز در شبکه هوشمند ارائه شده است که در این بخش به آن خواهیم پرداخت [1]–[3]]. نظر به اینکه هوش مصنوعی دارای کاربرد موثر در سیستم‌های مبتنی بر M-MIMO می‌باشد (و در مرحله ۲ این پروژه به صورت مبسوط به آن پرداخته خواهد شد)، این بخش از پروژه ایشان در حوزه توجه ما قرار می‌گیرد.

M-MIMO مزایای ارایه نرخ‌های بالاتر داده، افزایش ضریب اطمینان و Throughput سیستم را دارد در حالی که استفاده از تعداد زیادی از آنتن‌ها در عمل می‌تواند پیچیدگی سیستم و مصرف انرژی را افزایش دهد؛ به عنوان مثال به چندین زنجیره بخش رادیویی (RF) و واحدهای تخمین کانال نیاز خواهد بود. برای مرتفع کردن این مشکلات، روش پیشنهادی ایشان مبتنی بر انتخاب آنتن^۲ است و به این ترتیب تعداد زنجیره‌های رادیویی کمتر از تعداد آنتن‌ها است که به طبع آن، پیچیدگی سخت‌افزاری و هزینه پیاده‌سازی کاهش خواهد یافت.

M-MIMO را می‌توان در شبکه‌های NAN^3 و یا WAN^4 مورد استفاده قرار داد که در این پروژه فقط برای NAN در نظر گرفته شده است. روش ارائه شده به این صورت است که ابتدا با در نظر گرفتن همبستگی کانال و یک مدل توان واقع گرایانه، یک تقریب مجانبی^۵ برای تابع کارایی انرژی EE^6 سیستم به دست می‌آورند. سپس با استفاده از این تقریب یک طرح انتخاب آنتن جدید پیشنهاد می‌شود که باعث بیشینه شدن مقدار EE براساس آمار طولانی مدت کانال می‌شود. مدلی که ایشان برای سیستم خود در نظر گرفته‌اند به صورت زیر است:



شکل ۱۲. به کارگیری Massive-MIMO در شبکه‌های NAN مورد استفاده در شبکه‌های هوشمند

¹ Demand Response

² Antenna Selection

³ Neighbourhood Area Network


⁴ Wide Area Network

⁵ Asymptotic

⁶ Energy Efficiency


الگوریتم ارائه شده توسط ایشان بدینگونه است که برای سیستم M-MIMO ای متشکل از N آنتن و K واحد DAP^1 با انجام محاسبات لازم و با در نظر گرفتن مقدار خیلی زیاد برای N ، کارایی انرژی را مطابق با $EE = KR_m/P_{tot}$ محاسبه می‌کنند (که عبارت است از کل توان مصرفی در استگاه مرکزی و R_m نیز برابر است با نرخ داده قابل حصول از DAP شماره m). گفتنی است که R_m از طریق فرمولی که تابعی از مقادیر ماتریس کانل مابین DAP ها و M-MIMO در ایستگاه مرکزی BS^2 قابل محاسبه است. در ادامه با استفاده از یک روش تکرارشونده، پس از محاسبه مقادیر EE_m و یافتن آنتنی که دارای بیشترین مقدار این پارامتر می‌شود، و به تبع آن انتخاب آن آنتن و حذفش از روابط ماتریسی، به انتخاب بهترین آنتن‌ها و به تعداد N_t دست می‌یابند.

جزئیات بیشتر سیستم مورد نظر برای انجام عملیات انتخاب آنتن در شکل ۱۳ دیده می‌شود.



شکل ۱۳. سیستم مورد استفاده برای پیاده‌سازی الگوریتم انتخاب آنتن

همچنین همانطور که در [۴-۱] بیان شده است، ملاحظات مربوط به کاهش ادوات سخت‌افزاری در سیستم‌های ارتباطی آینده بسیار حائز اهمیت هستند و روش‌های دیگری نظیر [۵] نیز در این اواخر ارائه شده‌اند. نتایج اعمال این الگوریتم انتخاب آنتن‌ها، در شکل ۱۴ برای دو سناریو با ضرایب همبستگی $\phi = 0.2, 0.6$ میان آنتن‌ها نشان داده شده است.



شکل ۱۴. نتایج اعمال الگوریتم انتخاب آنتن (LASS) بر مقدار کارایی انرژی (EE)؛ ضرایب همبستگی $\phi = 0.2, 0.6$

¹ Data Aggregation Point

² Base Station

همانطور که در شکل فوق نشان داده شده است، الگوریتم انتخاب آنتن (LASS) اولاً در شرایط سخت‌تر (وجود ضرایب همبستگی بالاتر میان آنتن‌ها) بهبود عملکرد بالاتری را از خود نشان می‌دهد. ثانیاً در یک گستره وسیعی، عملکرد بسیار بهتری را در مقایسه با استفاده کامل از تمام آنتن‌ها را دارا می‌باشد؛ به عنوان مثال با استفاده از حدوداً ۱۶ آنتن، مقدار کارایی انرژی آن (EE) برابر با زمانی است که از تمامی ۲۵۶ آنتن موجود در سیستم استفاده شود. به این ترتیب در هنگام پیاده‌سازی، می‌توان از ۲۴۰ بخش لازم در قسمت رادیویی سیستم (نظیر زنجیرهای RF، تقویت‌کننده‌ها و ...) صرف نظر نمود؛ که به نوبه خود یک بهینه‌سازی بسیار قابل توجهی به ویژه در خصوص هزینه تمام شده می‌باشد.

۴-۲- پروژۀ دانشگاهی

یک پروژه در دانشگاه Alabama و با حمایت مرکز تحقیقات نیروی هوایی آمریکا در خصوص ساخت سخت‌افزاری یک نمونه آزمایشگاهی برای پیاده‌سازی روش‌های یادگیری عمیق ماشین (و انتقال یادگیری) برای سیستم‌های رادیوشناختی صورت گرفته است که در این بخش به توضیح آن خواهیم پرداخت [6]. توضیح اینکه اگرچه این پروژه برای استفاده در صنعت برق مورد استفاده قرار نگرفته است، ولی به علت اینکه روش‌های یادگیری ماشینی عمیق، تقویتی و انتقالی را بر روی یک سیستم رادیوشناختی پیاده‌سازی نموده است، نمونه مناسبی برای بحث مورد نظر ما است، چراکه امکان استفاده در کاربردهایی در صنعت برق (که در فصل پیشین بیان شدند) را که از ارتباطات رادیوشناختی بهره می‌جویند را دارا است.

۱-۴-۲- پروژه در یک نگاه

در این پروژه یک نمونه آزمایشی از شبکه رادیویی شناختی (CRN^1) در زمان واقعی^۲ با استفاده از USRP³ و رادیو GNU برای نشان دادن استفاده از روش‌های یادگیری ماشین نظیر یادگیری تقویتی (RL^4) و انتقال یادگیری (TL^5) جهت انجام تصمیم‌گیری‌های مورد نیاز در تعویض طیف^۶ پیاده‌سازی شده است. با در نظر گرفتن وضعیت کانال (بیکار یا اشغال شده) و شرایط کانال (از نظر میزان خطای بسته)، نود فرستنده عمل تعویض طیف مبتنی بر یادگیری ماشینی را انجام می‌دهد. در روش یادگیری تقویت‌شده، تعداد مشاهدات مورد نیاز از شبکه برای دستیابی به تصمیمات بهینه به دلیل وجود محیط پیچیده CRN ، بسیار زیاد است. هنگامی که یک نود شرایط جدید کانال را تجربه می‌کند، روند یادگیری از ابتدا شروع می‌شود. برای کاهش رخداد این مسئله، یک روش دستیابی به طیف مبتنی بر TL اجرا شده است که در آن نودها را قادر می‌سازد تا از نودهای همسایه خود برای یادگیری و بهبود عملکرد خود بهره بجوید.

به این ترتیب که در روش TL ، نود فعال شده ابتدا یک نود خبره^۷ در شبکه را جستجو می‌کند. در صورت یافته شدن یک نود خبره، نود مورد نظر برای تصمیم‌گیری در مورد دستیابی به طیف خود، جدول Q را از گره خبره درخواست می‌کند. همچنین در صورت عدم یافتن یک گره خبره، نود مورد نظر به تنهایی و با استفاده از روش یادگیری تقویتی شروع به یادگیری استراتژی تعویض طیف خواهد نمود.

¹ Cognitive Radio Network

² Real Time

³ Universal Software Radio Peripheral

⁴ Reinforcement Learning

⁵ Transfer Learning

⁶ Spectrum Handoff

⁷ Expert Node

نتایج به دست آمده از این پروژه مبین اینستکه دستیابی به طیف مبتنی بر یادگیری ماشین در دراز مدت بهتر عمل می‌کند و به طور مؤثری از طیف قابل دسترس استفاده می‌کند. علاوه بر این، روش TL برای دستیابی به یک راه حل بهینه، در مقایسه با یادگیری تقویتی، به تعداد کمتری از انتقال بسته‌ها نیاز دارد.

۲-۴-۲- بخش‌های اصلی پروژه

این پروژه از دو قسمت اصلی به شرح زیر تشکیل شده است:

(۱) ایجاد یک بستر آزمون برای یک شبکه مبتنی بر CR: با استفاده از USRP، رادیو GNU و آنتن جهت‌دار یک بستر آزمون برای انتقال داده‌های مالتی‌مدیا ایجاد شده است. کارکردهای حس طیف SS^1 ، تعویض طیف و دیگر موارد مرتبط با CRN را با استفاده از سری ۲۱۰ USRP پیاده‌سازی شده‌اند. بخش‌های مخابراتی نیز با استفاده از Python و C++ در محیط GNU Radio ایجاد شده‌اند. همچنین بخش‌های یادگیری ماشین نیز در بخش GNU Radio پیاده‌سازی گشته‌اند.

(۲) تعویض طیف با استفاده از روش مبتنی بر انتقال یادگیری: هنگامی که یک گره^۲ جدید به شبکه وارد می‌شود و نود خبره‌ای را پیدا نمی‌کند، از RL برای یادگیری استفاده می‌کند. روش استفاده شده برای انجام RL در این پروژه، Q-Learning است که برای تعویض مناسب طیف استفاده می‌شود. در هنگام وجود گره خبره در سیستم، جهت ارتقاء سرعت عملیات یادگیری، اطلاعات مورد نیاز (که به صورت Q-table هستند)، جهت انجام TL از گره خبره به گره جدید منتقل می‌شوند. متد مورد استفاده برای TL نیز، روش Docitive است.

نکته قابل توجه در این پروژه این است که علیرغم کارهای قبلی که یادگیری تقویتی در مراجع مختلف نظیر: [۷-۹] برای رادیو شناختی مورد استفاده قرار گرفته بودند، برای اولین بار روش انتقال یادگیری پیاده‌سازی گردیده است.

۲-۴-۳- نحوه پیاده‌سازی

پیاده‌سازی در دو بخش برای نودهای عادی (که RL را انجام می‌دهند) و در حضور گره‌های خبره (که TL انجام می‌دهند) صورت گرفته است. در ادامه به توضیح هریک به صورت مجزا می‌پردازیم:

۲-۴-۳-۱ پیاده‌سازی RL

RL [10] یک روش شناخته شده بدون نظارت^۳ یادگیری ماشینی است که نودها را قادر به یادگیری مستقل^۴ در یک محیط CRN می‌نماید. RL را می‌توان به صورت یک چندتایی^۵ (S, A, T, R) در نظر گرفت که S عبارت است از مجموعه متاهی از حالت‌های گره؛ A عبارت است از مجموعه متاهی از کنش‌های^۶ موجود برای یک گره در هر یک از حالت‌های آن؛ T مبین

¹ Spectrum Sensing

² Node

³ Unsupervised

⁴ Autonomously

⁵ Tuple

⁶ Action

احتمال انتقال بین دو حالت (از s_i به s_j) در نتیجه کنش $a \in A$ است: $R(s_j | s_i, a)$ ؛ نیز مقدار جایزه^۱ است که در هنگام اعمال کنش a بر حالت s مشاهده می‌شود و با $R(s, a)$ نمایش داده می‌شود. سیاست بهینه در خصوص اعمال کنش‌ها نیز با $\pi(s, a)$ نشان داده می‌شود.

با توجه به مقدمه فوق در این پروژه و در کاربرد مورد نظر، پارامترها به صورت زیر تعریف شده‌اند:


(۱) مجموعه حالت‌ها، S : در زمان تکرار^۲ t ، حالتی را که نود مشاهده می‌کند عبارت است از: $\{\xi_t, \phi_t\}$ که در آن ξ_t عبارت است از شرایط کانال^۳ بر اساس نرخ خطای پکت (PER^۴) و ϕ_t عبارت است از وضعیت کانال^۵، مبنی بر اینکه اشغال و یا آزاد است.

(۲) مجموعه کنش‌ها، A : کنش‌های در نظر گرفته شده برای انجام تعویض طیف عبارتند از: الف) ماندن در کانال فعلی و ارسال اطلاعات در همین کانال. ب) تعویض طیف و انتقال به یک کانال خالی بر اساس رخدادهای کاربر اصلی (PU^۶) و یا بدتر شدن شرایط کانال فعلی.

(۳) جایزه، R : در صورت خوب بودن شرایط کانال و اعمال کنش ارسال داده‌ها (a_1)، جایزه در نظر گرفته شده مقدار ۱۰ است؛ در صورت بد بودن شرایط کانال و اعمال کنش تعویض طیف (a_2)، جایزه در نظر گرفته شده مقدار ۵ است؛ در سایر ترکیبات شرایط و اعمال کنش‌ها، جایزه ۵- است که مبین عدم رضایت از کنش اعمال شده بر روی حالت مورد نظر است.

(۴) احتمال انتقال^۷ T : به علت تغییرات زیاد در کانال، این مقدار نامشخص است. با توجه به عبارات فوق، الگوریتم پیاده‌شده نیز Q-Learning است که از حوزه مورد نظر این بخش از پروژه خارج است و در فصل‌های آتی به آن خواهیم پرداخت.

در شکل ۱۵ بلوک دیاگرام نحوه انجام الگوریتم یادگیری تقویتی برای تعویض طیف مشاهده می‌شود.



شکل ۱۵. نحوه عملکرد یادگیری تقویتی در خصوص تعویض کانال [۶]

¹ Reward

² Iteration

³ Channel Condition

⁴ Packet Error Rate


⁵ Channel Status

⁶ Primary User


⁷ Transition Probability

۲-۴-۳-۲ پیاده‌سازی TL

در شکل ۱۵ و شکل ۱۶ نحوه پیاده‌سازی TL و بخش‌های سخت‌افزاری و نرم‌افزاری آن مشاهده می‌شوند




شکل ۱۶. نحوه عملکرد انتقال یادگیری و نقش نود خبره در خصوص تعویض کانال [۶]



شکل ۱۷. پیاده‌سازی بخش‌های مختلف سخت‌افزاری و نرم‌افزاری سیستم [۶]

نتایج پیاده‌سازی روش RL به همراه TL (که از گره خبره استفاده می‌کند)، برای سیستم رادیوشناختگر و مقایسه آن با روش سنتی Greedy و همینطور روش RL به صورت تنها (که هر گره به صورت خودآموز فرایند یادگیری را طی می‌کند)، در شکل ۱۸ نشان داده شده است.



شکل ۱۸. نتایج بدست آمده از پیاده‌سازی روش یادگیری تقویتی و انتقال یادگیری (با استفاده از گره خبره) در مقایسه با روش سنتی Greedy در یک سیستم رادیوشناختگر [۶]

همانگونه که در قسمت‌های قبل بیان شد، حداکثر مقدار جایزه در نظر گرفته شده در این الگوریتم، که مبین بهترین انتخاب‌ها است، عدد ۱۰ می‌باشد؛ از اینرو هرچه سریع‌تر رسیدن به این مقدار نشان از بهتر بودن عملکرد روش دارد. با توجه به نتایج منعکس در شکل ۱۸، روش Expert learning (که تلفیقی از RL و TL بوده)، بهترین عملکرد را از خود نشان می‌دهد و از روش RL تنها که گره‌ها باید به صورت خودآموز فرایند یادگیری را طی نمایند، بسیار سریع‌تر به نقطه بهینه دست می‌یابد. همچنین این روش از تکنیک سنتی Greedy نیز عملکرد بهتری را نشان می‌دهد [۶].

۲-۵- جمع‌بندی فصل ۲

در این فصل پروژه‌های مختلفی در دنیا که مبادرت به هوشمندسازی واحدهای ارتباطی خود نموده بودند و بالقوه باعث بهبود عملکرد همتایانشان در شبکه‌های هوشمند برق خواهند شد، مورد بررسی قرار گرفتند. نظر به جدید بودن استفاده از روش‌های هوش مصنوعی در سیستم‌های ارتباطی و بالطبع آن استفاده این سیستم‌ها در صنعت برق، انتظار ما بر این بود که پروژه‌های زیادی در این سطح پیدا نشوند که در هنگام جستجوی این موضوع، همین امر بر ما روشن‌تر گردید. با اینحال مواردی در صنعت و دانشگاه یافت شد که در این فصل به آنها پرداختیم و هرکدام از آنها می‌توانند در بخش‌های مختلف شبکه‌های هوشمند برق مورد استفاده قرار گیرند و باعث ارتقاء عملکرد آنها شوند. جمع‌بندی ما به شرح زیر می‌باشد:

اولین پروژه به نام SunSeed بود که در قالب پروژه‌های اتحادیه اروپا انجام گرفته است که هدف اصلی آن همگرایی استفاده از زیرساخت‌های مخابراتی اپراتورهای معمولی و مورد استفاده در صنعت برق است. در بخشی از این پروژه به توانایی و قابلیت استفاده همزمان از سیستم‌های ارتباطی مختلف مخابراتی نظیر HSDPA, LTE, WiFi پرداخته شده است؛ و روش‌های مختلفی (هرچند نه خیلی پیشرفته و هوشمندانه) ارائه و مورد بررسی قرار گرفتند. این استفاده همزمان باعث بهبود چشمگیر ضریب اطمینان عملکرد سیستم خواهد شد؛ امری که در سامانه‌های قرائت مورد استفاده در شبکه‌های هوشمند برق‌رسانی بسیار کاربرد خواهد داشت. البته این استفاده توانمند از روش‌های ارتباطی مختلف باعث افزایش تأخیر در سیستم خواهد شد و این موضوع نیز در این پروژه مورد مطالعه قرار گرفته است.

پروژه دوم به نام SmartEMC2 بود که آن نیز در اتحادیه اروپا صورت گرفته بود که هدف آن توسعه ابزارهای ICT جهت پشتیبانی از ادغام مشتریان و سرویس‌های Demand Response و همینطور پشتیبانی از تولید پراکنده از طریق نیروگاه‌های مجازی است. در بخشی از این پروژه استفاده از سیستم‌های Massive-MIMO و کاربرد آن در صنعت برق پیشنهاد شده است که جهت کاهش تعداد زنجیره‌های رادیویی کمتر از تعداد آنتن‌ها و بالطبع آن، کاهش پیچیدگی سخت‌افزاری و قیمت روشی بر اساس انتخاب آنتن (Antenna Selection) ارائه و مورد بررسی قرار گرفته است. استفاده از هوش مصنوعی در واحدهای M-MIMO موضوعی است که در مرحله بعدی این پروژه بیشتر مورد توجه قرار خواهد گرفت.

الگوریتم ارائه شده در این پروژه برای قرائت داده‌های تولیدی در کنتورهای برق هستند و از ابتدا برای سامانه‌های مورد نیاز در شبکه‌های هوشمند در نظر گرفته شده‌اند. از اینرو با استفاده از این روش امکان بهبود عملکرد گیرنده‌های مورد نیاز علاوه بر کاهش قیمت‌ها و مشکلات پیاده‌سازی سیستم را می‌توان توانم‌ها مهیا نمود.

در نهایت پروژه‌ای انجام شده در دانشگاه Alabama آمریکا مورد بررسی قرار گرفت که در آن الگوریتم‌های یادگیری تقویتی و انتقال یادگیری به صورت آزمایشگاهی برای یک سیستم رادیوشناختی پیاده‌سازی به صورت نرم‌افزاری و سخت‌افزاری پیاده‌سازی شده بود. نظر به آزمایشگاهی بودن این پروژه، کاربرد مورد استفاده برای انتقال فایل‌های ویدیویی بود، ولی اصول مورد توجه قرار گرفته در آن می‌تواند در شبکه‌های هوشمند برق که از رادیو شناختی استفاده می‌کنند نیز به راحتی مورد استفاده قرار گیرند. در فصل یک توضیحات مبسوطی در خصوص امکان استفاده از سیستم‌های رادیوشناختی در بخش‌های شبکه هوشمند برق ارائه شد. در این پروژه نیز نحوه پیاده‌سازی روش‌های پیشرفته یادگیری ماشینی (نظیر یادگیری تقویتی و انتقال یادگیری) برای اینگونه سیستم‌های شناختگر ارائه گردید. به این ترتیب در صورت استفاده از سیستم‌های رادیوشناختی در صنعت برق، می‌توان از روش‌های مطرحه در این فصل عملکرد آنها را ارتقاء داد.

در نهایت انتظار می‌رود که با پیشرفت تحقیقات دانشگاهی و بالطبع آن، تحقیقات کاربردی و علی‌الخصوص در صنعت برق، تعداد اینگونه پروژه‌ها که از سیستم‌های ارتباطی هوشمند استفاده می‌کنند نیز افزایش یابد.

مراجع فصل ۲

- [1] Čedomir Stefanović ; Petar Popovski ; Ljupčo Jorgušeski ; Radovan Serbec , "SUNSEED - An evolutionary path to smart grid comms over converged telco and energy provider networks", *4th International Conference on Wireless Communications, Vehicular Technology, Information Theory and Aerospace & Electronic Systems (VITAE)*, May 2014
- [2] Jimmy J. Nielsen ; Petar Popovski , "Latency analysis of systems with multiple interfaces for ultra-reliable M2M communication", *2016 IEEE 17th International Workshop on Signal Processing Advances in Wireless Communications (SPAWC)*
- [3] Jing Jiang ; Hongjian Sun ; Wei-Yu Chiu, "Energy efficient massive MIMO system design for smart grid communications", *2016 IEEE International Conference on Communications Workshops (ICC)*, Year: 2016
- [4] Khaled B. Letaief, Wei Chen, Yuanming Shi, Jun Zhang, and Ying-Jun Angela Zhang, "The Roadmap to 6G: AI Empowered Wireless Networks", *IEEE Communications Magazine*, August 2019, pp. 84-90
- [5] X. Yu, J. Zhang, and K. B. Letaief, "A Hardware-Efficient Analog Network Structure for Hybrid Precoding in Millimeter Wave Systems," *IEEE J. Sel. Topics Signal Process.*, vol. 12, May 2018, pp. 282–97.
- [6] Koushik A.M.a, Elizabeth Bentleyb, Fei Hua, Sunil Kumar, "A hardware testbed for learning-based spectrum handoff in cognitive radio networks", *Journal of Network and Computer Applications* 106 (2018) 68–77
- [7] Elsayed, M.H., Mohamed, A., 2015. Distributed interference management using Q-learning in cognitive femtocell networks: New USRP-based implementation. *Proceedings of the 7th IEEE International Conference New Technologies, Mobility and Security (NTMS)*, pp. 1–5.
- [8] Anil, R., Danyamol, R., Gawande, H., Gandhiraj, R., 2014. "Machine learning plugins for GNU Radio companion", *IEEE International Conference Green Computing Communication and Electrical Engineering (ICGCCEE)*, pp. 1–5.
- [9] Ren, Y., Dmochowski, P., Komisarczuk, P., 2010. Analysis and implementation of reinforcement learning on a GNR Radio cognitive radio platform. *5th IEEE International Conference Cognitive Radio Oriented Wireless Networks & Communications (CROWNCOM)*, pp. 1–6.
- [10] Sutton, R.S., Barto, A.G., 1998. Reinforcement Learning: An Introduction 1. MIT Press, Cambridge.

فصل ۳. بررسی کاربردهای هوش مصنوعی در لایه فیزیکی

۱-۳- مقدمه

به طور کلی، هوش مصنوعی یک پارادایم محاسباتی است که ماشین‌ها را مجهز به هوش می‌کند؛ با این هدف که به آنها بیاموزد تا چگونه کار کنند، عکس‌العمل نشان دهند و به صورت انسان‌ها رفتار کنند. بسیاری از روش‌ها همچون یادگیری ماشینی، سیستم‌های خبره و الگوریتم‌های تکاملی تحت این چتر وسیع قرار می‌گیرند. در پروژه ما نیز هدف اولیه بر روش‌های هوش مصنوعی که در سیستم‌های ارتباطی کاربرد دارند است؛ ولی با بررسی‌هایی که به تدریج در این خصوص صورت گرفت، ملاحظه شد که برخی از انواع این روش‌ها به دلایل مختلفی بیشتر مورد توجه و مورد استفاده قرار گرفته‌اند. به خصوص ملاحظه شد که روش‌های یادگیری ماشینی کاربرد بسیار پیدا کرده‌اند.

ویژگی بارز روش‌های یادگیری این است که با استفاده از داده‌ها، می‌توانند فرایندهای یادگیری را طی نمایند و سپس بدون نیاز به مدل‌سازی خاصی، کارکردهای مناسبی برای انجام امور با ارزشی همچون تصمیم‌گیری را داشته باشند.

روش‌های یادگیری ماشینی را می‌توان از یکسو به صورت کلی به سه قسمت دسته‌بندی نمود: روش‌های هدایتی، روش‌های غیرهدایتی و روش‌های تقویتی. از سویی دیگر روش‌های یادگیری عمیق وجود دارند که از عملکرد سیستم‌های عصبی موجودات زنده الگوبرداری می‌نمایند؛ که این روش‌ها می‌توانند با هریک از سه دسته روش‌های یادگیری فوق‌الذکر ادغام شوند. بر اساس مطالعات صورت گرفته، که نتایج آنها به تدریج در این فصل و فصل‌های آتی گزارش خواهند آمد، ملاحظه خواهد شد که این روش‌های یادگیری ماشینی سهم زیادی از روش‌های کلی هوش مصنوعی را در کاربرد برای سیستم‌های ارتباطی به خود اختصاص داده‌اند.

این فصل به لایه فیزیکی و کاربردهای AI در آن می‌پردازد و مطالب آن در چهار بخش کلی به شرح زیر ارائه شده‌اند: در بخش اول مروری بر مزایای استفاده از تکنیک‌های یادگیری ماشینی در مخابرات بی‌سیم با تمرکز بر لایه فیزیکی صورت می‌گیرد. همچنین چالش‌های به کارگیری این روش‌ها در این لایه بیان می‌شوند.

در بخش دوم مروری بر روش‌های یادگیری عمیق به عنوان جزئی مهم از روش‌های یادگیری ماشینی خواهد داشت. در بخش سوم کاربرد روش‌های ML بر روی یکی از مهمترین عملیات صورت گرفته در لایه فیزیکی به نام AMC، که بطور گسترده در سیستم‌های مخابراتی بی‌سیم و سیمی جهت سازگاری با تغییرات کانال مورد استفاده قرار می‌گیرد، بررسی می‌شود. AMC می‌تواند با تنظیم مدولاسیون و نرخ کدگذاری مطابق با شرایط کانال به سیستم‌های مخابراتی برای دستیابی به بازدهی طیفی بهتر و برقراری توازن بین نرخ داده بالاتر و قابلیت اطمینان بیشتر کمک کند. در این خصوص روش‌های یادگیری هدایت‌شده و تقویتی مورد بررسی قرار گرفته‌اند.

یکی از چالش‌های سیستم‌های مخابراتی بی‌سیم تأمین ضریب اطمینان و نرخ بالا در حضور تداخل بین‌سیگنالی می‌باشد. تداخل بین‌سیگنالی به علت چندمسیرگی انتشار سیگنال در محیط مخابراتی ایجاد می‌شود. حذف تداخل بین‌سیگنالی در مخابرات بی‌سیم توسط زیرسیستم‌هایی با نام یکسان‌ساز انجام می‌شود. یکسان‌سازهای تطبیقی برای فراگیری مشخصات متغیر با زمان کانال بی‌سیم توسط تکنیک‌های ML در بخش چهارم ارائه و بررسی شده‌اند.

۲-۳- شبکه‌های بی‌سیم مبتنی بر هوش مصنوعی^۱

نیاز به شبکه‌های بی‌سیم هوشمند ایجاب می‌نماید که به منظور دستیابی به یک الگوی داده محور، هر بخش از شبکه مجهز به قابلیت‌های هوش مصنوعی گردد، به گونه‌ای که در آن گره‌های شبکه بر اساس تجربیات به دست آمده از پردازش داده‌های گذشته، قادر به تعیین بهترین خط مشی باشند. از یک طرف، این امر تا آنجا که به طراحی و عملکرد شبکه مربوط است، به وضوح

¹ Artificial Intelligence-Based Wireless Networks

باعث کاهش اتکا به مدل‌های ریاضی شده ولی از طرف دیگر، دلالت بر رد کامل رویکردها و مدل‌های ریاضی محور سنتی ندارد. به عبارت دیگر، به نظر می‌رسد استفاده از تلفیقی از تکنیک‌های مبتنی بر مدل و مبتنی بر هوش مصنوعی، مناسب‌ترین راه حل بوده و در شبکه‌های بی‌سیم آینده، ترکیبی از این دو رویکرد استفاده خواهد شد.

به منظور توسعه شبکه‌های بی‌سیم هوشمند، می‌توان از چارچوب یادگیری ماشین^۱ و به طور خاص از تکنیک یادگیری عمیق^۲ استفاده نمود. یادگیری ماشین با فراهم آوردن تکنیک‌های متعدد، کامپیوتر را قادر می‌سازد تا توانایی یادگیری از داده را داشته باشد، بدون آنکه مستقیماً برای آن برنامه‌ریزی شده باشد. یادگیری ماشین مفهوم جدیدی برای سیستم‌های مخابراتی تلقی نمی‌گردد و در واقع رویکردهای متعددی مبتنی بر تکنیک‌های یادگیری ماشین به منظور کمک به طراحی و بهره‌برداری از سیستم‌های ارتباطی پیشنهاد شده و توسعه یافته است. به عنوان مثال می‌توان به تکنیک‌هایی نظیر ماشین‌های بردار پشتیبانی^۳، درخت تصمیم‌گیری^۴، شبکه‌های بیز^۵، الگوریتم‌های ژنتیکی^۶، یادگیری مبتنی بر قانون^۷ و غیره اشاره نمود.

یادگیری عمیق نیز یکی از تکنیک‌های یادگیری ماشین است که فرایند یادگیری را با تهیه اطلاعات از طریق شبکه‌های عصبی مصنوعی (ANN^۸)، پیاده‌سازی می‌نماید. در این راستا، از عوامل اصلی دخیل در برتری یادگیری عمیق نسبت به دیگر روش‌های یادگیری ماشین، استفاده از شبکه‌های عصبی مصنوعی است، خصوصاً زمانی که حجم بالایی از داده در دسترس باشد. در نتیجه، یادگیری عمیق از تکنیک‌های پیشرو در یادگیری ماشین بوده و در زمینه‌های متعددی نظیر طبقه‌بندی تصویر^۹، تشخیص متن^{۱۰}، تشخیص گفتار^{۱۱}، صدا و پردازش زبان^{۱۲}، روباتیک^{۱۳} و غیره مورد استفاده قرار می‌گیرد. با این وجود، مبحث استفاده از این تکنیک در شبکه‌های مخابراتی به تازگی مطرح شده و هنوز پتانسیل بسیاری در استفاده از آن در شبکه‌های مخابراتی وجود دارد که می‌بایست به آن پرداخته شود. همان‌گونه که قبلاً نیز بیان شد، این امر عمدتاً به این دلیل است که برخلاف سایر زمینه‌های علمی، گرایش مهندسان مخابرات در طراحی سیستم به مدل‌های ریاضی سنتی بوده و در نتیجه ضرورت چندان در استفاده از روش‌های داده محور وجود نداشته است. اما با توجه به پیشرفت‌های حاصل شده اخیر، در آینده نزدیک نیاز به استفاده از تکنیک‌های یادگیری عمیق در شبکه‌های مخابراتی وجود خواهد داشت. به بیان دقیق‌تر:

- به منظور استفاده هرچه بیشتر از تکنیک‌های یادگیری عمیق، لازم است داده‌های کلان مورد پردازش قرار گیرند. در حال حاضر، با توجه به افزایش نمایی دستگاه‌های بی‌سیم، حجم قابل توجهی از داده نیز تولید خواهد شد.
- علاوه بر این، پیشرفت‌های جدید در ظرفیت محاسباتی، امکان اجرای الگوریتم‌های بزرگ‌تر و پیچیده‌تر با سرعت بالا نیز فراهم شده است. به طور خاص، می‌توان از واحدهای پردازش گرافیکی (GPU)^{۱۴} به منظور اجرای الگوریتم‌های یادگیری عمیق استفاده نمود که سرعت آنها بسار بیشتر از تراشه‌های پردازنده سنتی است.

¹ Machine Learning

² Deep Learning

³ Support Vector Machines

⁴ Decision Trees

⁵ Bayesian Networks

⁶ Genetic Algorithms

⁷ Rule-based Learning

⁸ Artificial Neural Networks

⁹ Image Classification

¹⁰ Text Recognition

¹¹ Speech Recognition

¹² Audio and Language Processing

¹³ Robotics

¹⁴ Graphics Processing Units

اخیراً چندین شرکت پیشرو در زمینه ارتباطات از راه دور^۱، پشتیبانی خود از بکارگیری تکنیک‌های یادگیری عمیق در ارتباطات را اعلام نموده‌اند. علاوه بر این، قدم‌های اولیه به سمت استانداردسازی سیستم‌های مخابراتی بی‌سیم هوشمند نیز برداشته شده است. موسسه استاندارد ارتباطات از راه دور اروپا (ETSI)^۲، گروهی با عنوان "Experiential Network Intelligence" و با هدف تعریف "معماری مدیریت شبکه شناختی" راه‌اندازی نموده است که قادر به استفاده از تکنیک‌های هوش مصنوعی و سیاست‌های context-aware بوده تا بتواند بر طبق تغییرات نیازهای کاربر، عوامل محیطی و اهداف کسب و کار، شیوه ارائه خدمات خود را تنظیم نماید. این اولین قدم به سمت سیستمی است که بتواند از تجربیات گذشته آموخته و دانش خود را برای بهبود شیوه عملکرد در آینده ارتقاء دهد. این امر همچنین به اپراتورها در خودکارسازی فرایندهای نظارت و پیکربندی کمک می‌نماید. در نتیجه موجب کاهش هزینه‌های عملیاتی بهبود در استفاده و نگهداری از شبکه‌ها می‌گردد.

به طور مشابه، طرحی توسط اتحادیه بین‌المللی مخابرات (ITU)^۳ به منظور استانداردسازی استفاده از یادگیری ماشین در شبکه‌های بی‌سیم آینده مطرح شده است که هدف اصلی آن مشخص نمودن چارچوب معماری یادگیری ماشین در شبکه‌های آینده است. در این طرح، تعریف یکپارچه‌سازی قابلیت‌های یادگیری ماشین در معماری شبکه‌های موبایل آینده و همچنین تکنیک‌های مدیریت شبکه در محیط‌های بی‌سیم آینده آورده شده است.

به طور خاص، "ITU-T Y.3172" که یک چارچوب معماری برای یادگیری ماشین در شبکه‌های آینده شامل IMT-2020 است^۴، به تازگی به تایید رسیده و یک جز مهم دیگر برای اتخاذ یادگیری ماشین به منظور راه‌اندازی و بهینه‌سازی شبکه‌های بی‌سیم را تشکیل می‌دهد.

از سوی دیگر، به منظور تحقق دیدگاه شبکه‌های بی‌سیم مبتنی بر هوش مصنوعی، چالش‌هایی نیز وجود دارد که می‌بایست بر آنها غلبه نمود. در این میان، به عنوان دو چالش اساسی و مرتبط می‌توان به موارد زیر اشاره نمود:

- اکتساب داده - همان‌گونه که قبلاً نیز عنوان کرد، به منظور استفاده حداکثری از الگوریتم‌های یادگیری عمیق، حجم زیادی از داده موردنیاز است. امروزه این امر با توجه به نرخ بالای تولید داده قابل دستیابی است. اما چالش اصلی در جمع‌آوری داده‌های لازم با استفاده از روشی عملی و مقرون به صرفه است.
- یکپارچه‌سازی هوش مصنوعی با شبکه‌های ارتباطی - با وجود آنکه کاملاً واضح است که شبکه‌های ارتباطی آینده متکی به تکنیک‌های هوش مصنوعی هستند، اما چگونگی ادغام شبکه‌های عصبی مصنوعی (ANN)^۴ در معماری شبکه‌های ارتباطی مشخص نیست.

همچنین می‌بایست به این نکته توجه شود که یادگیری ماشین نه تنها برای شبکه‌های ارتباطی بی‌سیم، بلکه برای فن‌آوری‌های ارتباطی نوظهور که به عنوان مکمل رویکردهای سنتی بی‌سیم در سناریوهای خاص مورد بررسی قرار می‌گیرند نیز حایز اهمیت است [۱].

¹ Telecommunication Companies

² European Telecommunications Standards Institute

³ International Telecommunication Union

⁴ Artificial Neural Networks

۳-۳- مروری بر یادگیری ماشین در لایه فیزیکی

مهمترین کارکرد یادگیری ماشین توانمندسازی کامپیوترها در یادگیری الگو و انجام کارهای مشخصی مانند طبقه‌بندی و پیش‌بینی بدون یک برنامه‌ریزی مشخص می‌باشد؛ که از طریق یادگیری الگوریتم از روی تعداد متناهی داده‌ی در دسترس انجام می‌گیرد. درحالی‌که ایده اولیه یادگیری ماشین به سال ۱۹۵۰ برمی‌گردد، در سال‌های اخیر توجه بسیار زیادی به این مبحث شده است که به دلیل در دسترس بودن کامپیوترهای قدرتمند و داده‌های اولیه و پیشرفت در تئوری الگوریتم یادگیری می‌باشد. موفقیت‌های یادگیری ماشین مدرن به دلیل بازدهی چشمگیر یادگیری عمیق^۱ به اشکال شبکه‌های عصبی عمیق^۲ (DNNs)، یادگیری عمیق تقویتی^۳ (DRL)، شبکه‌های مولد تخصصی^۴ (GANs) می‌باشد. این ابزارها باعث پیشرفت‌های بسیاری در کاربردهایی همچون رانندگی خودکار، بازاریابی، رباتیک، ... می‌باشد [۲]. پیشرفت این روش‌ها در کاربردهای عملی و با توجه به این که عملکرد آنها در موارد بسیاری بهتر از روش‌های مرسوم می‌باشد، انگیزه لازم جهت بکارگیری آنها در طیف وسیعی از کاربردها را فراهم آورده است. اگرچه فعالیت یادگیری ماشین در مخابرات بی‌سیم در حال رشد سریع صعودی می‌باشد، برخی محققان بر تأثیر آن در سیستم‌های عملی مشکوک هستند و نتایج آن در سیستم‌ها و استانداردها در حال بررسی است. قبل از آنکه به چالش‌های به کارگیری یادگیری ماشین در مخابرات بی‌سیم بپردازیم این سؤال مطرح می‌گردد "آیا یادگیری ماشین کاملاً یک طرح جدید است که می‌تواند آینده سیستم‌های مخابراتی را تغییر دهد یا یک تکنیک متفاوتی در سیستم‌های مخابراتی است". ارتباط زیادی بین یادگیری ماشین و تئوری ارسال و ذخیره داده وجود دارد. آشکارسازی سمبول^۵ و دنباله^۶ که هسته سیستم‌های مخابراتی می‌باشند به عنوان مسأله عمومی طبقه‌بندی^۷ در نظر گرفته می‌شود. آنتروپی شانون^۸ و اطلاعات متقابل^۹ بصورت گسترده در یادگیری ماشین به عنوان هدف در نظر گرفته می‌شود. کوانتیزیشن برداری یک ابزار کلیدی برای کدینگ منبع و نرخ اعوجاج می‌باشد و به عنوان خوشه‌بندی^{۱۰} k-means که یک روش یادگیری ماشین غیرهدایتی^{۱۱} می‌باشد، شناخته شده است. عمل تخمین کانال در سیستم یادگیری خطی با استفاده از پایلوت‌های ارسال شده، یک مدل هدایت‌شده^{۱۲} است. البته برخی تفاوت‌های کلیدی بین یادگیری ماشین و سیستم‌های مخابراتی بی‌سیم وجود دارد؛ از جمله آن (۱) در مخابرات، باتوجه به کانال و سیستم مدلی که از قوانین لایه فیزیکی تبعیت می‌کنند، رفتار سیستم قابل انتظار می‌باشد و (۲) کنترل کاملی برچگونگی و زمان ارسال وجود دارد. یک جنبه‌ی مهم یادگیری ماشین وابستگی ذاتی آن به داده است. از آنجاییکه امروزه ما به داده‌های زیادی دسترسی داریم بنابراین بیش از پیش می‌توانیم به داده برای نتیجه‌گیری و طراحی سیستم تکیه کنیم. روش متکی بر مدل در سیستم‌های مخابراتی بسیار موفق بوده و جواب‌گوی نیاز روزافزون برای ارسال با کیفیت بهتر و تأخیر کمتر است. با این وجود هرچه ما به سمت پیاده‌سازی شبکه بی‌سیم نسل پنجم می‌رویم، سناریوهای زیادی وجود دارد که مدل استفاده شده در سیستم مرسوم بحث برانگیز است. برای مثال

¹ Deep Learning

² Deep Neural Networks

³ Deep Reinforcement Learning

⁴ Generative Adversarial Networks

⁵ Symbol

⁶ Sequence

⁷ Classification

⁸ Shannon Entropy

⁹ Mutual Information

¹⁰ Clustering

¹¹ Unsupervised

¹² Supervised

در حالت برش شبکه^۱ و کلاس‌های سرویس چندگانه^۲، تداخلات^۳ می‌توانند بطور بسیار زیادی ناپیوسته^۴ و با توزیع غیرگوسی^۵ شوند. مشکلاتی از این دست، اهمیت استفاده از راه‌حلی‌هایی با ساختاریافتگی کمتر و مقاوم در برابر ناسازگاری مدلی را گوشزد می‌کنند. تکنیک‌های یادگیری ماشین مدرن می‌توانند به طراحی سیستم‌های مخابراتی بی‌سیم و پروتکل‌ها مورد نیاز کمک کند. این کمک می‌تواند در عرصه‌هایی همچون پیش‌بینی ترافیک شبکه و رفتار کاربران، تهدید امنیتی، بهبود عملکرد شبکه و تأمین بهتر منابع صورت پذیرد [2].

در ادامه ابتدا به چالش‌های بکارگیری یادگیری ماشین در مخابرات بیسیم خواهیم پرداخت. سپس چند مورد از موارد به کارگیری آن در لایه فیزیکی را بررسی خواهیم نمود.

۱-۳-۳- چالش‌های استفاده از ابزار یادگیری ماشین در مخابرات بی‌سیم

یک چالش بزرگ در استفاده از مدل‌های وابسته به داده در طراحی سیستم‌های مخابراتی، طبیعت "جعبه سیاه"^۶ بودن الگوریتم‌های یادگیری ماشین و عدم تضمین عملکرد می‌باشد. درحالی‌که مهندسان مخابرات عادت به تأمین گارانتی برای پارامترهای مختلفی نظیر احتمال خطای عملکرد، سطح تداخل، تأخیر و ... دارند. البته باید توجه داشت که دقت موجود در مقدار این گارانتی‌ها متکی بر دقت مدل عواملی همچون ترافیک، کانال سیستم و ... می‌باشد. به عنوان مثال، مدل کانال همیشه تقریبی می‌باشد و کانال حقیقی بصورت دینامیکی متحول می‌گردد و این بدلیل تأثیرات همه انواع عوامل غیرخطی است. در مقابل روش وابسته به داده نیاز به سیستم مدل دقیق ندارد و بر اساس داده می‌تواند مدل سیستم بهینه را به دست آورد. مزیت این روش این است که مستقیماً می‌تواند حتی کانال‌های غیرخطی ناشناخته را فقط بر اساس داده، معکوس کند. این مسأله که کدام روش، بر اساس مدل تقریبی پیچیده یا براساس مدل الگوریتم جعبه سیاه یادگیری ماشین، قابل اعتمادتر می‌باشد هنوز روشن نشده است. این انتظار می‌رود که مدل براساس یادگیری ماشین وقتی مؤثر است که یک مدل دقیق براساس مسأله مورد علاقه موجود نباشد. فهمیدن دلایل شکست و موفقیت روش یادگیری ماشین باتوجه به جنبه جعبه سیاه بودن DNN ها یک چالش تحقیقاتی است که درحال بررسی می‌باشد. همچنین مسأله گارانتی یکنواختی عملکرد در میان کاربران به طوریکه آن‌ها براساس نوع وسیله و موقعیت مکانی و پروتکل مورد استفاده دچار خطا نگردند، یک چالش مهم در سیستم مخابراتی آینده است.

چالش دیگر استفاده از ابزار یادگیری ماشین وابسته به داده برای سیستم مخابراتی بی‌سیم، کمبود داده‌ی در دسترس می‌باشد. در بسیاری از کاربردهای مخابرات بی‌سیم، داده استاندارد موجود نمی‌باشد. هرچند در صورت وجود چنین داده‌ای این سوال پیش می‌آید که آیا یک داده موفق در یک شبکه می‌تواند در دیگر شبکه‌ها نیز موفق باشد؟. کانال‌های بی‌سیم بطور بسیار زیادی غیرایستا هستند و بصورت آفلاین بر روی داده‌های عمومی فراگرفته می‌شوند که ممکن است نتایج راضی کننده‌ای در محیط بی‌سیم مختلف دست ندهد. گفته شده است که یادگیری آنلاین مدل موجود برای تنظیم آن بر سناریو فعلی نیاز می‌باشد. به عبارت دیگر وقتی یک مدل دقیق موجود است می‌توان داده را بر طبق آن تولید نمود سپس عملیات فراگیری را انجام داد. در این حالت می‌توان گفت که الگوریتم یادگیری ماشین عملکرد بهتری نسبت به روش مرسوم موجود با پیچیدگی یکسان دارد.

مسأله دیگری در استفاده از تکنیک‌های یادگیری ماشین در شبکه مخابراتی بی‌سیم وجود دارد، محدودیت منابع محاسباتی و حافظه موجود برای بسیاری از وسایل بی‌سیم و ترمینال‌ها با پیچیدگی کم در لبه شبکه است. همچنین مقدار داده در سمت کاربران یک سیستم مخابراتی و توانایی یادگیری آن معمولاً محدود است. روش موجود برای غلبه بر این محدودیت‌ها در سیستم‌های

¹ Network Slicing

² Multiple Service Classes

³ Interference

⁴ Non-Stationary

⁵ On-Gaussian

⁶ Black Box

بی‌سیم استفاده از محاسبات ابر است؛ که در آن همه داده‌های در دسترس در سیستم‌های بی‌سیم به واحدهای ابر منتقل می‌گردند و الگوریتم یادگیری ماشین قدرتمند می‌تواند بطور یکجا از تمامی داده‌های موجود استفاده بکند. مشکلی که در این راه حل وجود دارد انتقال داده به واحد پردازنده مرکزی شبکه با استفاده از انرژی و پهنای باند محدود و ایجاد تغییر در شبکه است. بنابراین به راه‌هایی برای یادگیری غیرمتمرکز در دستگاه بی‌سیم نیاز است. عملکرد یادگیری غیرمتمرکز و تصمیم‌گیری، توسط مقدار داده‌ای که بین دستگاه‌های یادگیری جریان دارد و مقدار نویزی که اطلاعات سیستم محلی را مختل می‌کند، محدود می‌گردد.

۲-۳-۳- بکارگیری یادگیری ماشین در آشکارسازی و دیکدینگ

آشکارسازی داده در کانال نویزی که از ارکان هر سیستم مخابراتی می‌باشد را می‌توان به صورت یک مسأله طبقه‌بندی در نظر گرفت. روش متداول مورد استفاده در سیستم‌های آشکارساز امروزی وابسته به مدل ریاضی برای توصیف کانال مخابراتی است. معمولاً عمل آشکارسازی با استفاده از کانال تخمین زده شده توسط پایلوت‌های ارسالی در گیرنده انجام می‌شود؛ که این امر موجب عملکرد غیربهینه آشکارساز در حضور خطای تخمین می‌گردد. بکارگیری یک الگوریتم یادگیری ماشین می‌تواند عملکرد بهتری نسبت به روش مرسوم داشته باشد. به عنوان مثال در مرجع [۳] از یک شبکه عصبی بازگشتی^۱ (RNN) در حضور تداخل بین سمبولی^۲ (ISI) استفاده کرده است؛ فراگیری این آشکارساز براساس داده جمع‌آوری شده از کانال مخابراتی مولکولی صورت می‌گیرد. آن‌ها نشان داده‌اند که در حضور خطای تخمین کانال، آشکارساز براساس NN بسیار بهتر از آشکارساز مرسوم عمل می‌کند. مرجع [۴] کانال MIMO با ورودی دودویی را مورد بررسی قرار داده است. با افزایش هرچه بیشتر تعداد کاربران و آنتن‌ها، آشکارساز ML^۳ بهینه بدلیل پیچیدگی محاسباتی زیاد غیرعملی می‌گردد و در عوض ایشان آشکارساز DNN را پیشنهاد کرده‌اند. نتایج نشان داده است که دیکدر DNN عملکرد قابل ملاحظه‌ای در مقایسه با دیکدر ML دارد درحالی که سرعت آن ۳۰ برابر بیش‌تر است. مرجع [۵] مسأله آشکارسازی داده بر روی کانالی با مدل معلوم ولی گیرنده‌ای فاقد اطلاعات وضعیت کانال (CSI^۴) را در نظر می‌گیرد. دیکدر DNN فراگرفته شده است تا سمبل داده را از سیگنال دریافتی تخمین بزند. DNN مورد بررسی از یک لایه ورودی و سه لایه پنهانی و یک لایه خروجی تشکیل شده است بطوریکه با روشی اکتشافی^۵، تعدادی نرون‌ها در هر لایه انتخاب شده است. تابع (ReLU^۶) به عنوان تابع فعال‌سازی در همه لایه‌ها بجز لایه خروجی استفاده شده است؛ در لایه خارجی نیز تابع Sigmoid برای نگاشت خروجی به بازه [0,1] استفاده می‌شود. نتایج عددی چندین نکته جالب توجه را نشان می‌دهد: اول اینکه در صورت وجود مقدار کافی از پایلوت‌ها، نرخ خطای بیت در دیکدر DNN با نرخ گیرنده MMSE یکسان است. ولی تحت شرایط غیرایده‌آل مانند کم‌بودن تعداد پایلوت‌ها، غیرخطی بودن نویز و فقدان پیشوند چرخشی^۷، دیکدر DNN عملکرد بسیار بهتری از دیکدر مرسوم دارد. می‌توان گفت روش DNN راه حل‌های ساده و قابل اعتمادی ارائه می‌دهد که می‌تواند در برابر عوامل غیرخطی مختلف بطور مقاوم عمل کند.

هرچند تمامی کارهای ذکر شده بر آشکارسازی سمبول ورودی تمرکز دارند، DNN‌ها می‌توانند برای آشکارسازی سمبول کدشده نیز بکار روند. کدگشایی کلمات کد از یک کانال معین یک مسأله طبقه‌بندی می‌باشد. تعداد کلاس‌ها برای مسأله طبقه‌بندی سیگنال دریافتی بصورت نمایی با طول کلمه کد رابطه مستقیم دارد. بنابراین بیشتر روش‌های کنونی برای کدگشایی کانال مبتنی بر DNN از یک DNN در ساختار دیکدر موجود بهره می‌برند. برای مثال [۶] از یک NN برای فراگیری وزن‌هایی که باید به

¹ Recurrent NN

² Inter-Symbol Interference

³ Maximum Likelihood

⁴ Channel State Information

⁵ Heuristic

⁶ Rectified Linear Unit

⁷ Cyclic Prefix

گراف Tanner از یک الگوریتم BP^1 ملحق شود استفاده می‌کند. در [۷] بهبود عملکرد دیکد کردن مرحله‌ای مرسوم برای کدهای قطبی با کامل کردن بخش‌های آن با دیکدر NN مطرح شده است. آن‌ها دیکدر را به زیربلوک‌ها تقسیم می‌کنند که هر کدام از آن‌ها با دیکدر NN جایگزین می‌شوند و نتایج این دیکدرها به دیکدر BP منتقل می‌گردد. این عملیات اجازه کنترل فراگیری پیچیدگی با تنظیم تعداد زیربلوک‌ها را می‌دهد. یک دیکدر کانال کامل براساس DNN در مرجع [۸] در نظر گرفته شده است که در آن فراگیری دیکدر NN برای دو نوع کد: تصادفی^۲ و کد قطبی^۳ در نظر گرفته شده است. درحالی که کد قطبی عملکردی نزدیک به دیکدر MAP^4 دارد، عملکرد کد تصادفی فاصله بزرگتری با MAP دارد. هرچند با افزایش تعداد مراحل فراگیری، این فاصله می‌تواند کمتر گردد. همچنین به این نکته اشاره می‌کند که وقتی داده دارای ساختار باشد، NN بهترین عملکرد را دارد. این مقاله نشان داده است که دیکدر NN می‌تواند کلمات کدی که قبلاً ندیده است را نیز کدگشایی کند. در واقع دیکدر NN می‌تواند ساختار الگوریتم دیکد را فراگیرد که البته این امر برای کدهای تصادفی که فاقد ساختار هستند، امکان‌پذیر نمی‌باشد.

۳-۳-۳- یادگیری عمیق برای تخمین کانال و بازخورد اطلاعات کانال

دانستن اطلاعات کانال در سیستم‌های بی‌سیم ضروری است. در سمت گیرنده، اطلاعات کانال اجازه آشکارسازی هم‌دوس^۵ و کدگشایی را می‌دهد. تخمین کانال در گیرنده با ارسال داده‌های پایلوت توسط فرستنده انجام می‌شود. علاوه بر گیرنده، دانستن اطلاعات کانال در سمت فرستنده، به خصوص در سیستم‌های MIMO، مهم می‌باشد. طرح تقسیم دوسویه زمانی^۶، اطلاعات کانال توسط ویژگی هم‌پاسخی سیستم در سمت فرستنده به دست می‌آید. درحالی که در طرح تقسیم دوسویه فرکانسی^۷ اطلاعات کانال توسط بازخورد در اختیار گیرنده قرار می‌گیرد. به منظور کاهش منابعی که به بازخورد اطلاعات اختصاص داده می‌شود فشرده‌سازی کانال تخمین زده شده در سمت گیرنده تا حد امکان ضروری است. در حالی که مطالعات آشکارسازی و کدگشایی جزو مسائل طبقه‌بندی هستند، تخمین کانال یک مسئله رگرسیون و فشرده‌سازی اطلاعات کانال یک مسأله خوشه‌بندی غیرهدایتی می‌باشد. در ادامه مروری از استفاده DNN جهت انجام تخمین کانال و فشرده‌سازی اطلاعات کانال صورت می‌گیرد.

۳-۳-۴- تخمین کانال

در مرجع [۹] نویسندگان مدل کانال را بصورت شرطی برحسب پارامترهای داده شده توزیع گوسی در نظر گرفته اند. این پارامترها تصادفی هستند و توزیع آنها توسط فراگیری از طریق داده بدست می‌آید. تخمین گر MMSE در این مدل می‌تواند به عنوان تخمین‌گر خطی در نظر گرفته شود. در روش ایشان با برداری نمودن تخمین گر MMSE، آن را بصورت NN با دو لایه خطی متصل به یک تابع فعال غیرخطی مدل می‌کنند. این لایه‌ها توسط الگوریتم SGD^8 و نیز MSE به عنوان تابع اتلاف قابل فراگیری هستند. نتایج شبیه‌سازی نشان داده اند تخمین‌گر NN عملکرد بهتری نسبت به تخمین‌گرهای مرسوم و با پیچیدگی کم دارد. مرجع [۱۰] از تکنیک براساس شبکه‌های عصبی کانولوشن^۹ (CNN) برای تخمین کانال استفاده می‌کند و نشان داده شده است که عملکرد یکسانی با تخمین‌گر ایده آل MMSE که دارای اطلاعات کامل کانال است، دارد.

¹ Belief Propagation

² Random Code

³ Polar Code

⁴ Maximum APosteriori

⁵ Coherent

⁶ Time Division Duplex (TDD)

⁷ Frequency Division Duplex (FDD)

⁸ Stochastic Gradient Descent

⁹ Convolutional Neural Networks

۵-۳-۳- فشرده سازی اطلاعات کانال

در اختیار داشتن اطلاعات دقیق در سمت فرستنده می‌تواند بصورت چشمگیری عملکرد سیستم مخابراتی بی‌سیم را بهبود دهد؛ برای مثال با پرهیز از ارسال اطلاعات در کانال ضعیف و یا استفاده در شکل‌دهی پرتو. در سیستم تقسیم زمانی فرکانسی فرستنده برای داشتن اطلاعات کانال به گرفتن بازخورد از سمت گیرنده وابسته است. بمنظور محدود نمودن مقدار منابعی که صرف بازخورد اطلاعات کانال می‌گردد، طراحی الگوریتم فشرده سازی که کانال تخمین زده با دقت بالا را با صرف منابع محدود به فرستنده برساند از اهمیت زیادی برخوردار است. تخمین کانال در سیستم MIMO بسیار مهم است، زیرا نیاز به اطلاعات دقیق از کانال در لینک فروسو دارد. این درحالی است که به دلیل تعداد بسیار زیادی آنتن بالاسری ناشی از بازخورد کانال زیاد است. از آنجاییکه فشرده سازی CSI یک حالت خاصی از مسأله فشرده سازی داده است در اینجا چگونگی استفاده از تکنیک ML برای فشرده سازی داده ارائه می‌شود. فشرده سازی یک مسأله اساسی در تئوری اطلاعات و تئوری کدینگ می‌باشد و تلاش تحقیقاتی زیادی برای تولید الگوریتم فشرده سازی بهینه برای منابع اطلاعاتی مختلفی مانند تصویر و صدا و ویدئو انجام شده است و استانداردهای فشرده سازی شاخصی مانند MP3, JPEG, MPEG ایجاد شده‌اند. در اکثر مواقع الگوریتم پیشنهادی سعی می‌کند از ماهیت تنک بودن منبع اطلاعات برای ایجاد تغییر بهره‌برداری کند. اگرچه این تکنیک‌ها در طول دهه‌ها تحقیق و پیشرفت بطور زیادی تکمیل شده و عموماً عملکرد خوبی دارند، امروزه پیشرفت چشمگیری در بهره‌برداری از DNN برای فشرده سازی در همه این حوزه‌های داده مشاهده می‌گردد؛ بطوریکه نتایج نشان از برتری این تکنیک بر تکنیک‌های موجود قبلی است. بخش اصلی اکثر این روش‌های پیاده سازی‌ها ساختار خود رمزنگار^۱ (AEN) است. AEN یک جفت از NN است که از کدگذار و کدگشا تشکیل شده است. خروجی دیکدر لایه گلوگاه^۲ (BL) امیده می‌شود. دو شبکه بصورت مشترک فراگیری می‌شوند بطوریکه داده ورودی در خروجی دیکدر تولید گردد. BL بعد کمتری از داده ورودی دارد و همچنین اطلاعات ضروری برای بازسازی داده ورودی را داراست و می‌توان آن را به عنوان فشرده سیگنال ورودی دانست. AEN در ML برای استخراج مشخصه‌های اصلی استفاده می‌گردد. این یک روش یادگیری غیرهدایتی است. ویژگی اصلی AEN برای فشرده سازی در این است نیاز به دانستن توزیع داده ندارد ولی در عوض می‌تواند اطلاعات ضروری آن را استخراج کند. علاوه بر آن AEN را می‌توان برای منبع اطلاعات بهینه کرد. این درحالی است که تکنیک‌های استاندارد فشرده سازی تصویر الگوریتم یکسانی را برای همه نوع تصویر بکار می‌گیرد. این فشرده سازی براساس AEN به ویژه برای فشرده سازی بازخورد CSI جذاب می‌باشد؛ زیرا مشخص نمودن ویژگی‌های ماتریس کانال بدلیل همبستگی بین کانال‌ها می‌تواند مشکل باشد. الگوریتم فشرده سازی AEN در مرجع [۱۱] مطالعه و نشان داده شده است که در مقایسه با تکنیک‌های مرسوم فشرده سازی می‌تواند بهبود چشمگیری در بازدهی فشرده سازی ایجاد کند. با فرض هم‌پاسخی کانال، نویسندگان [۱۲] از CSI در لینک فراسو به عنوان اطلاعات همبسته اضافی برای بهبود بیشتر بازدهی فشرده سازی استفاده کرده‌اند. کارهای ذکر شده بر کاهش بعد تمرکز دارند و بصورت مستقیم به مسأله فشرده سازی که مربوط به نمایش دودویی CSI بازخورد شده است، نپرداخته‌اند. خروجی هر AEN یک عدد حقیقی است که قبل از بازخورد شدن به سمت گیرنده نیاز به کوانتیزه شدن دارد. در عمل کوانتایزر ۳۲ بیتی دقت کافی را در سیستم ایجاد می‌کند. راه‌حل جایگزین استفاده همزمان از کوانتایزر و AEN در عملیات ML است. هرچند که به دلیل مشتق‌ناپذیر بودن عملیات کوانتیزیشن، این روش کمی چالش‌آور است. روش‌های متعددی برای فشرده سازی تصویر برای غلبه مشکلات موجود پیشنهاد شده است. مرجع [۱۳] کوانتیزیشن را با نویز جمع‌شونده با توزیع گوسی جایگزین می‌کند و تابع باینری‌کننده آماری در مرجع [۱۴] استفاده شده است. در مرجع [۱۵] کوانتیزیشن به همراه فشرده سازی CSI در نظر گرفته شده است و هردو با هم توسط ML فراگرفته شده‌اند. در خروجی کوانتایزر از کدینگ آنتروپی مانند الگوریتم استاندارد در فشرده سازی تصویر برای فشرده سازی بیشتر استفاده و این منجر به بهبود بازدهی فشرده سازی شده است.

¹ Autoencoder

² Bottleneck Layer

۳-۴- مروری بر روش‌های یادگیری ماشینی و یادگیری عمیق مورد استفاده در سیستم‌های ارتباطی

۳-۴-۱- یادگیری عمیق و یادگیری ماشینی

مفهوم یادگیری ماشینی به تکنیک‌هایی مبتنی بر الگوریتم اشاره دارد که قادر به انجام یک کار معین بدون اجرای یک برنامه کامپیوتری ثابت است. در واقع، به منظور حل مسئله با استفاده از تکنیک‌های یادگیری ماشینی، از روش پردازش داده‌های در دسترس و یادگیری تدریجی از آن‌ها استفاده می‌گردد. در این میان، طیف گسترده‌ای از مسائل با استفاده از تکنیک‌های موجود در یادگیری ماشینی قابل حل است.

به طور کلی، تکنیک‌های یادگیری ماشینی با استفاده از دانش و داده موجود (مجموعه داده آموزشی)^۱ به رفع مسائلی می‌پردازد که هیچ روش برنامه‌نویسی صریح و یا عملی برای آنها وجود نداشته باشد. از جمله این مسائل می‌توان به مواردی نظیر طبقه‌بندی، رگرسیون، بازشناسی الگو، ترجمه خودکار زبان، تشخیص ناهنجاری و غیره اشاره نمود. به منظور ارزیابی کارایی الگوریتم‌های یادگیری ماشینی نیز می‌توان از معیارهای ارزیابی نظیر خطای میانگین مربع (MSE)^۲ یا توابع cross-entropy استفاده نمود.

بسته به اطلاعات موجود در مجموعه داده آموزشی، الگوریتم‌های یادگیری ماشینی به دو دسته زیر تقسیم‌بندی می‌شوند:

- یادگیری بدون نظارت^۳ - یادگیری بر روی داده‌های بدون برچسب و برای یافتن الگوهای پنهان در این داده‌ها انجام می‌شود.
- یادگیری نظارت شده^۴ - یادگیری بر مبنای داده‌های برچسب‌گذاری شده صورت می‌گیرد. به بیان دیگر، مجموعه داده آموزشی با فراهم آوردن مثال‌هایی به آموزش نحوه رفتار الگوریتم به هنگام مواجهه با ورودی‌های جدید و خاص می‌پردازد.

در هر دو روش یادگیری بدون نظارت و یادگیری نظارتی، مجموعه داده موجود ثابت بوده و سناریویی مدل‌سازی می‌شود که در آن الگوریتم مستقیماً با محیطی که در آن فعالیت می‌کند، تعامل ندارد. در این میان، یادگیری تقویتی^۵، الگویی در یادگیری ماشینی است که در طبقه‌بندی ذکر شده قرار نمی‌گیرد. رویکرد اصلی در یادگیری تقویتی بدین گونه است که یک حلقه بازخورد^۶ میان الگوریتم و محیط فعال شده و به الگوریتم اجازه می‌دهد تا روی یک مجموعه داده‌ای که در طول زمان و در نتیجه تعامل با محیط اطراف تغییر می‌نماید، کار کند. علاوه بر این، ادغام یادگیری تقویتی با ابزارهای یادگیری عمیق موجب پیدایش مفهوم یادگیری تقویتی عمیق^۷ شده است که در ادامه گزارش با جزئیات بیشتر مورد بررسی قرار خواهد گرفت [۸].

۳-۴-۱-۱- بیش‌برازش^۸ و کم‌برازش^۹

¹ Training Set

² Mean Squared Error

³ Unsupervised Learning

⁴ Supervised Learning

⁵ Reinforcement Learning

⁶ Feedback Loop

⁷ Deep Reinforcement Learning


⁸ Overfitting

⁹ Underfitting

تمامی الگوریتم‌های یادگیری ماشین بر روی یک مجموعه داده آموزشی^۱ با تعدادی ویژگی کار می‌کنند. در یادگیری نظارت شده هر ویژگی ورودی با خروجی مطلوب مربوطه همراه است. به عبارت دیگر، داده برچسب‌گذاری شده است. با وجود این اطلاعات که جزء اطلاعات ضروری به منظور پیکربندی الگوریتم یادگیری محسوب می‌گردد، چالش اصلی در الگوریتم‌های یادگیری ماشین، اجرای بهینه الگوریتم بر روی داده‌های دیده نشده و یا جدید است. این بدان معناست که الگوریتم می‌بایست قادر به درک یک قاعده کلی از مجموعه داده آموزشی و سپس تولید خروجی مطلوب باشد که از این امر به عنوان قابلیت تعمیم^۲ الگوریتم یاد می‌شود. در واقع، هدف اصلی در الگوریتم‌های یادگیری ماشین این است که الگوریتم به خوبی به ورودی‌های جدید تعمیم داده شود. به منظور ارزیابی قابلیت تعمیم، بعد از طراحی الگوریتم به عنوان نتیجه فاز آموزش، عملکرد آن بر روی مجموعه جدیدی از ورودی‌های مختلف تست می‌شود، که مجموعه تست^۳ نامیده می‌شود. میزان خطای اندازه‌گیری شده بر روی مجموعه داده تست، خطای تعمیم یا خطای تست نامیده می‌شود. به طور مشابه، خطای ارزیابی شده بر روی مجموعه داده آموزشی، خطای آموزش نامیده می‌شود. واضح است که خطای تعمیم مورد انتظار بزرگتر از خطای آموزش مورد انتظار بوده و فاصله میان این دو، شکاف تعمیم^۴ نامیده می‌شود. بنابراین، به حداقل رساندن خطای آموزش را می‌توان به عنوان یک شرط لازم ولی ناکافی برای دستیابی به یک خطای تعمیم پایین در نظر گرفت. در ادامه دو حالت ممکن برای یک الگوریتم یادگیری ماشین، آورده شده است:

- کم‌برازش زمانی رخ می‌دهد که الگوریتم قادر به ایجاد خطای پایین بر روی مجموعه داده آموزشی نباشد.
- بیش‌برازش زمانی رخ می‌دهد که الگوریتم قادر به ایجاد شکاف کوچک میان خطای آموزش و خطای تست نباشد.

فاکتور کنترل کننده بروز کم‌برازش و یا بیش‌برازش، "ظرفیت"^۵ الگوریتم نامیده می‌شود. به عبارت دیگر، ظرفیت یک الگوریتم مرتبط با درجات آزادی یا پارامترهایی است که به هنگام طراحی الگوریتم، انتخاب می‌شوند. اگر الگوریتم به اندازه کافی پارامتر آزاد نداشته باشد، در نتیجه درجه آزادی کافی برای بدست آوردن ساختار مجموعه آموزشی را نخواهد داشت و مدل دچار کم‌برازش می‌شود. اما این بدان معنا نیست که افزایش پارامترهای آزاد همشیه منجر به عملکرد بهتر خواهد شد. اگر الگوریتم درجه بالایی از آزادی داشته باشد، ساختار مجموعه آموزشی را به خوبی یاد خواهد گرفت و ویژگی‌های خاص را که مختص مجموعه آموزشی بوده ولی قابل تعمیم نیستند، حفظ خواهد نمود. در نتیجه، به منظور به حداقل رساندن شکاف تعمیم می‌بایست یک ظرفیت بهینه برای الگوریتم یادگیری ماشین در نظر گرفته شود. در شکل ۱۹ نوع رفتار الگوریتم در مقابل خطای آموزش و تست و نیز ظرفیت الگوریتم نشان داده شده است [۱].



شکل ۱۹. رفتارهای نوعی از خطاهای آموزش و تست

¹ Training Set

² Generalization

³ Test Set

⁴ Generalization Gap

⁵ Capacity

۲-۱-۴-۳ هاپیر پارامترها و مجموعه اعتبار سنجی

در مدل‌های یادگیری ماشین، دو نوع پارامتر وجود دارد:

- **پارامترهای مدل:** پارامترهایی هستند که می‌بایست با استفاده از مجموعه داده آموزشی تعیین شوند. به این پارامترها، پارامترهای *fitted* نیز گفته می‌شود.
- **هاپیر پارامترها:** پارامترهایی قابل تنظیم هستند که می‌بایست به منظور دستیابی به مدلی با عملکرد بهینه تنظیم شوند.

در نتیجه، علاوه بر پارامترهایی که در طول فرایند آموزش، بهینه‌سازی می‌شوند، پارامترهای دیگری با عنوان هاپیر پارامترها وجود دارند که مستقیماً در طول فاز آموزش تعیین نشده و صرفاً به منظور بهینه نمودن عملکرد مدل مورد استفاده قرار می‌گیرند. تاثیر مستقیم این پارامترها بر روی ظرفیت مدل است. در واقع، اگر پارامتری که بر روی ظرفیت مدل تاثیر می‌گذارد، تنها بر اساس مجموعه آموزشی تنظیم شود، نتیجه آن به حداقل رساندن خطای آموزش تا حد امکان خواهد بود. همان‌گونه که قبلاً عنوان گردید، این امر سبب کاهش قابلیت تعمیم مدل و بروز بیش‌برازش خواهد شد.

به عنوان مثال، شبکه‌های عصبی مصنوعی از چندین گره تشکیل شده که در آن رابطه ورودی-خروجی بر اساس مفاهیمی نظیر وزن‌ها و ترم‌های بایاس تعریف شده و این‌ها، پارامترهایی هستند که در طول فرایند آموزش تنظیم می‌گردند. از طرف دیگر، تعداد کل گره‌های شبکه و روشی که گره‌ها به یکدیگر متصل می‌شوند، همان هاپیر پارامترها هستند که در طول فرایند آموزش، ثابت در نظر گرفته می‌شوند. در شبکه‌های عصبی مصنوعی، تعداد گره‌ها مستقیماً با ظرفیت شبکه مرتبط است. چرا که تعداد گره‌های بالا به درجات آزادی بیشتر اشاره دارد. بنابراین، اگر تعداد گره‌ها تنها بر اساس مجموعه داده آموزشی بهینه‌سازی گردد، نتیجه مطلوب، افزایش تعداد گره‌ها تا حد امکان خواهد بود که بیش‌برازش را به همراه خواهد داشت.

از سوی دیگر، به منظور تنظیم هاپیر پارامترها، امکان استفاده از مجموعه داده‌ای تست نیز وجود ندارد، زیرا تمامی انتخاب‌های مربوط به طراحی الگوریتم باید مستقل از مجموعه داده‌هایی باشد که برای ارزیابی عملکرد الگوریتم بکار می‌رود. در غیر این صورت، برآورد خطای تعمیم نادرست خواهد بود. این امر نشان دهنده آن است که به منظور تنظیم هاپیر پارامترها، به مجموعه داده‌های سوم نیاز است. این مجموعه داده، مجموعه اعتبارسنجی نامیده شده و به طور معمول با تقسیم داده‌های آموزشی به مجموعه آموزشی و مجموعه اعتبارسنجی به دست می‌آید.


در این حالت، فرایند آموزش برخی از مقادیر هاپیر پارامترها را اصلاح نموده و پارامترهای شبکه را تنها براساس مجموعه آموزشی بهینه می‌سازد. سپس، از طریق مجموعه اعتبارسنجی، یک تخمین از خطای تعمیم با توجه به پیکربندی هاپیر پارامترها به دست می‌آید. این روش برای پیکربندی‌های مختلف هاپیر پارامترها به منظور شناسایی بهترین مدل مورد استفاده تکرار می‌شود. بعد از تنظیم پارامترها و هاپیر پارامترها، خطای تعمیم واقعی با استفاده از مجموعه تست محاسبه می‌شود [۱].

۳-۱-۴-۳ فراتر از یادگیری ماشین کلاسیک

چالش اصلی یادگیری ماشین، یادگیری شیوه تعمیم در پاسخ به ورودی‌های جدید و نادیده است. به منظور کاهش خطای تعمیم^۱، می‌توان الگوریتم را بر روی حجم بالاتری از داده‌ها آموزش داد. به عبارت دیگر، افزایش اندازه مجموعه آموزشی قطعاً مفید خواهد بود، اما محدودیت‌هایی نیز در زمینه محاسبه و ظرفیت ذخیره‌سازی نسبت به داده‌ای که می‌بایست پردازش شود، به وجود خواهد آورد. در نتیجه، یکی از مولفه‌های اصلی یادگیری ماشین، عملکرد الگوریتم‌های مختلف به عنوان تابعی از اندازه

¹ Generalization Error

مجموعه داده آموزشی است. در این میان، همانگونه که در شکل ۲۰ نشان داده شده است، با افزایش ابعاد داده‌های آموزشی، استفاده از رویکرد یادگیری عمیق می‌تواند موجب بهبود عملکرد با سرعتی بسیار سریع‌تر نسبت به دیگر تکنیک‌های یادگیری ماشین شود.



شکل ۲۰. مقایسه یادگیری عمیق با دیگر الگوریتم‌های کلاسیک [۱]

در اینجا منظور از ابعاد داده آموزشی، به طور مستقیم اندازه داده آموزشی نبوده، بلکه به تعداد ویژگی‌هایی (n) که هر عنصر X را در مجموعه ورودی‌های ممکن X توصیف می‌کند، اشاره دارد. با این حال واضح است که با افزایش n ، به نمونه‌های آموزشی بیشتری جهت یادگیری ساختار X و کاهش خطای تعمیم نیاز است. الگوریتم‌های متداول یادگیری ماشین به منظور کاهش ابعاد داده‌ای از روش‌هایی نظیر شناسایی ویژگی‌های مرتبط با مسئله موردنظر و حذف ویژگی‌های نامرتبط استفاده می‌نمایند. یادگیری عمیق رویکرد کاملاً متفاوتی در این ارتباط دارد. فرض اصلی در این رویکرد بر این امر است که داده‌ها با ترکیب عوامل با یک نظم سلسله مراتبی تولید شده‌اند و یک روش یادگیری را قادر به درک خودکار ساختار توزیع زیرین و استخراج مستقیم ویژگی‌های مهم به منظور رسیدن به هدف است را توسعه می‌دهد. به عبارت دیگر، یادگیری عمیق با فراهم آوردن امکان درک ساختار توزیع زیرین بدون نیاز به فرضیات خاص، استفاده از الگوریتم‌هایی با هدف عمومی‌تر را امکان‌پذیر می‌سازد. این پیشرفت‌ها به لطف استفاده از شبکه‌های عصبی مصنوعی (ANN)^۱ است که ابزارهای لازم به منظور استفاده در یادگیری عمیق و اجرای فرایند یادگیری را تشکیل می‌دهند [۱].


۲-۴-۳- یادگیری تقویتی

یادگیری تقویتی گونه‌ای از روش‌های یادگیری ماشین است که یک عامل^۲ را قادر به یادگیری در محیطی تعاملی با استفاده از آزمون و خطاها و استفاده از بازخوردهای اعمال و تجربیات خود می‌سازد. اگرچه هم یادگیری نظارت شده و هم یادگیری تقویتی از نداشت بین ورودی و خروجی استفاده می‌کنند، اما در یادگیری تقویتی که در آن بازخوردهای فراهم شده برای عامل مجموعه صحیحی از اعمال جهت انجام دادن یک وظیفه هستند، بر خلاف یادگیری نظارت شده از پاداش‌ها و تنبیه‌ها به عنوان سیگنال‌هایی برای رفتار مثبت و منفی بهره برده می‌شود.

^۱ Artificial Neural Networks

^۲ Agent

علاوه بر این، یادگیری تقویتی در مقایسه با یادگیری نظارت نشده دارای اهداف متفاوتی است. هدف در یادگیری نظارت نشده پیدا کردن مشابهت‌ها و تفاوت‌های بین نقاط داده محسوب می‌شود و این در حالی است که در یادگیری تقویتی هدف پیدا کردن مدل داده مناسبی است که پاداش انباره‌ای کل^۱ را برای عامل پیشینه می‌کند. شکل ۲۱ ایده اصلی و عناصر درگیر در یک مدل یادگیری تقویتی را نشان می‌دهد.



شکل ۲۱. مدل یادگیری تقویتی

برخی از اصطلاحاتی که عناصر یک مساله یادگیری تقویتی را تشریح می‌کنند، عبارتند از:

- محیط^۲: جهان فیزیکی که عامل در آن عمل می‌کند.
- حالت^۳: موقعیت کنونی عامل
- پاداش^۴: بازخورد از محیط
- سیاست^۵: روشی برای نگاشت حالت عامل به عمل
- ارزش^۶: پاداش آینده که یک عامل با اقدام به یک عمل در یک حالت خاص به آن دست می‌یابد.

به عنوان مثال، یادگیری Q یکی از الگوریتم‌های یادگیری تقویتی است که به دنبال یافتن مناسب‌ترین اقدام در وضعیت حاضر است. به عبارت دیگر، یادگیری Q با یادگیری یک تابع اقدام/مقدار، سیاست مشخصی را برای انجام حرکات مختلف در وضعیت‌های مختلف دنبال می‌کند. یکی از نقاط قوت این روش، توانایی یادگیری تابع مذکور بدون داشتن مدل معینی از محیط می‌باشد. در این الگوریتم، مدل مسئله از یک عامل، وضعیت‌ها و مجموعه‌ای از کنش^۷ (a) اقدامات برای هر وضعیت تشکیل شده است. با هر اقدام، عامل از یک وضعیت به وضعیت بعدی حرکت کرده و در هر وضعیت پاداشی به عامل تعلق می‌گیرد. هدف اصلی عامل، به حداکثر رساندن کل پاداش دریافتی خود است. این کار با یادگیری اقدام بهینه برای هر وضعیت انجام می‌گردد. الگوریتم دارای تابعی است که ترکیب کنش-حالت را محاسبه می‌نماید.

¹ Total Cumulative Reward

² Environment


³ State

⁴ Reward

⁵ Policy

⁶ Value

⁷ Actions



شکل ۲۲. فرایند الگوریتم یادگیری Q

همان‌گونه که در شکل ۲۲ نشان داده شده است، قبل از شروع یادگیری، Q مقدار ثابتی را که توسط طراح انتخاب شده است، برمی‌گرداند. سپس هر بار که به عامل پاداش داده می‌شود، مقادیر جدیدی برای هر ترکیب کنش-حالت محاسبه می‌گردد. هسته الگوریتم از یک بروز رسانی تکراری ساده تشکیل شده است. به این ترتیب که بر اساس اطلاعات جدید مقادیر قبلی اصلاح می‌گردد.

در واقع، Q-learning نوعی از یادگیری تقویتی بدون مدل است که بر پایه برنامه‌ریزی پویای اتفاقی عمل می‌کند. در یادگیری Q به جای انجام یک نگاهت از حالت‌ها به مقادیر حالت‌ها، نگاهتی از زوج کنش-حالت به مقادیری که Q-value نامیده می‌شوند، صورت می‌پذیرد [۱].

۳-۴-۲-۱ فرایند تصمیم‌گیری مارکوف

همانگونه که ذکر شد، روش RL می‌تواند با تئوری MDP بیان گردد. چهار المان کلیدی در مساله MDP وجود دارد: مجموعه حالت S، عملیات A، تابع انتقال P و پاداش R است. $S = \{s_1, s_2, \dots, s_n\}$ مجموعه n حالت ممکن که تغییرات پویای محیط را توصیف می‌کنند، $A = \{a_1, a_2, \dots, a_n\}$ بیانگر مجموعه m عملیات ممکن است. $P: S \times A \times S \rightarrow [0, 1]$ تابع احتمال انتقال است که $P(s, a, s')$ احتمال انتقال از S به $s' \in S$ با عمل $a \in A$ می‌باشد و R تابع پاداش است، بطوریکه $R(s, a)$ تابع پاداش در حالت S وقتی عمل a انجام می‌شود. در ادامه فرایند مشابه انجام و پاداش‌های پی در پی $R_{k+1}, R_{k+2}, R_{k+3}, \dots$ از محیط دریافت می‌شود. در مرحله kام پردازش یادگیری، عمل $a_k \in A$ در حالت $s_k \in S$ انجام می‌شود که قبل از انتقال به $s_{k+1} \in S$ با احتمال $P(s_k, a_k, s_{k+1})$ ، پاداش $R_k(s_k, a_k)$ توسط محیط داده می‌شود. در اینجا هدف پیدا کردن خط مشی π که رفتار مپ کردن از حالت‌ها به عمل را بصورت $\pi: S \rightarrow A$ نشان می‌دهد. با در نظر گرفتن $\pi(s)$ به عنوان عمل انجام شده در حالت S م است و پاداش جمعی یک تابع مرتبط با مقادیر حالت‌ها می‌باشد، که به صورت زیر محاسبه می‌گردد:

$$\begin{aligned}
 V^\pi(s) &= \sum_{k=0}^{\infty} \gamma^k R_k(s_k, \pi(s_k) | s_0 = s) \\
 &= R(s, \pi(s)) + \gamma \sum_{s' \in S} P(s' | s, \pi(s)) V^\pi(s')
 \end{aligned}$$

که $0 \leq \gamma \leq 1$ ضریب وزن‌دهی به پاداش جمعی است. بطوریکه برای $\gamma \leq 1$ پاداش آینده کمتر قابل پیش‌بینی و اعتماد می‌گردد و بنابراین پاداش آینده کم‌اهمیت‌تر از پاداش کنونی می‌گردد. در اینجا هدف پیدا کردن خط‌مشی $\pi^*(s) \in A$ برای بیشینه‌نمودن پاداش جمعی می‌باشد. درواقع مساله هدف بصورت $V^*(s) = \max_{\pi} V^\pi(s)$ است.

۲-۴-۳-۲ پردازش تصمیم‌گیری مارکوف

در مدل MDP، از دو روش تکرار خطمشی^۱ و برنامه‌ریزی پویا با تکرار ارزش^۲ دو روش شناخته شده برای بدست آوردن خط مشی بهینه هستند. این دو روش به دانش اولیه از تغییرات محیط که به سختی می‌توان آن را در عمل تخمین زد، نیاز دارند. به عبارت دیگر به سختی می‌توان اطلاعات اولیه $R(s, a)$ و $P(s, a, s')$ را در سناریو AMC بدست آورد. در این حالت کشف رابطه حالت-عمل-پاداش نیاز به جستجو در محیط دارد. در این خصوص Q-learning یک تکنیک مناسب به دلیل سادگی و هزینه محاسباتی کم استفاده می‌شود. در این روش از تابع Q^* برای مشخص کردن خطمشی استفاده می‌شود. Q-function آمادگی برای انجام عمل a در حالت s می‌باشد. از یک حالت شروع می‌کند و برطبق پاداش‌ها مقادیر را جمع می‌زند. تابع Q به صورت زیر تعریف می‌گردد:

$$Q^*(s, a) = E \left(\sum_{k=0}^{\infty} \gamma^k R_k | s_0 = s, a_0 = a \right)$$

تابع بهینه Q بصورت $Q^*(s, a) = \max_{\pi} Q^{\pi}(s, a)$ تعریف شده است. بر طبق اصل بهینگی Bellman از سیاست آزمندانه^۴ برای حل آن استفاده می‌شود. این سیاست بدین صورت است که یک عمل با بیشینه مقدار Q در هر حالت انتخاب می‌گردد. بدین صورت که خطمشی بهینه عمل a با بیشینه مقدار $Q^*(s, a)$ انجام می‌شود. که بصورت زیر تعریف می‌گردد:

$$\pi^*(s) = \max_{a \in A} Q^*(s, a)$$

علاوه بر آن $Q^*(s, a)$ با استفاده از حالت کنونی s و عمل a و حالت بعدی s' و پاداش R بروز رسانی می‌گردد. فرمول بروز رسانی بصورت زیر می‌باشد:

$$Q(s, a) \leftarrow Q(s, a) + \alpha [R + \gamma \max_a Q(s', a) - Q(s, a)]$$

که در آن α نرخ یادگیری است.

۳-۴-۳-۳ یادگیری عمیق با استفاده از شبکه‌های عصبی مصنوعی

همان‌گونه که عنوان گردید، شبکه‌های عصبی مصنوعی به دلیل توانایی آن‌ها در یادگیری مستقیم از داده مشاهده شده، روابط ورودی - خروجی پیچیده و ساختارهای آماری، از عناصر اصلی در یادگیری عمیق محسوب می‌گردند. شبکه‌های عصبی مصنوعی، بصورت سلسله مراتبی در لایه‌های واحدهای پردازش اولیه که نورون نامیده می‌شوند، تشکیل می‌گردند. به بیان جزئی‌تر، شبکه‌های عصبی مصنوعی این‌گونه تعریف می‌شوند:

- یک لایه ورودی که داده‌های ورودی را به بقیه شبکه ارسال می‌کند.
- یک یا چند لایه پنهان که داده‌های ورودی را پردازش می‌کنند.
- یک لایه خروجی که قبل از خروج داده‌ها، پردازش نهایی را روی آنها اعمال می‌نماید.
- مقادیر وزن‌ها و بایاس^۵ که قدرت اتصالات بین نورون‌ها را مدل می‌کنند.

¹ Policy Iteration

² Value Iteration Dynamic Programming

³ Q-Function (State-Action Value function)


⁴ Greedy

⁵ Bias

اگر این شبکه تنها یک لایه مخفی داشته باشد، به عنوان یک شبکه کم عمق^۱ شناخته می‌شود، در حالی که اگر بیش از یک لایه مخفی داشته باشد، به عنوان یک شبکه عمیق^۲ معرفی می‌گردد. از آنجایی که شبکه‌های عمیق معمولاً به تعداد کمتری از نورون‌ها برای رسیدن به یک دقت معین نیاز دارند، نسبت به شبکه‌های کم عمق برتری دارند. قیاس میان شبکه‌های عصبی مصنوعی و شبکه‌های عصبی طبیعی نیز به دلیل استفاده از همین معماری‌های عمیق است که در آن همانند مغز انسان، چندین نورون اطلاعات را پردازش و سپس نتیجه را گسترش می‌دهند. طبقه‌بندی کلی شبکه‌های عصبی مصنوعی مبتنی بر چگونگی جریان اطلاعات از ورودی به خروجی است. به طور مشخص می‌توان به مواردی که در ادامه آورده شده است، اشاره نمود [۱].

۱-۳-۴-۳ شبکه‌های عصبی feed-forward

در شبکه‌های عصبی feed-forward هر نورون فقط به نورون‌های لایه بعدی خود متصل می‌شود و در نتیجه داده‌های ورودی از لایه ورودی به لایه خروجی تنها می‌توانند رو به جلو حرکت نموده و حلقه‌های بازخورد^۳ مجاز نمی‌باشند.



شکل ۲۳. ساختار کلی شبکه عصبی feed-forward

همان‌گونه که در شکل ۲۳ نشان داده شده است، برداری ورودی X با n بعد و از طریق نورون‌های لایه ورودی به شبکه تزریق می‌شود. سپس از لایه‌های پنهان موجود در شبکه عبور کرده و در نهایت خروجی از طریق نورون‌های لایه خروجی بازیابی می‌شود [۸].

۲-۳-۴-۳ شبکه عصبی کانولوشن^۴

شبکه‌های عصبی کانولوشن زیرمجموعه‌ای از شبکه‌های عصبی بازخورد به جلو^۵ هستند که ابزار اصلی در پردازش تصویر به شمار آمده و به طور کلی به منظور پردازش داده با ساختار فضایی^۶ به کار می‌روند. به عبارت دیگر، شبکه عصبی کانولوشن، یک الگوریتم یادگیری عمیق است که تصویر ورودی را دریافت و به هر یک از اشیا/جنبه‌های موجود در تصویر درجه‌ای از میزان

¹ Shallow Network

² Deep Network


³ Feedback Loops

⁴ Convolutional

⁵ Feed-Forward (FF)

⁶ Spatial Structure


اهمیت شامل وزن‌های قابل یادگیری و بایاس تخصیص می‌دهد و قادر به متمایزسازی آن‌ها از یکدیگر است. الگوریتم ConvNet در مقایسه با دیگر الگوریتم‌های دسته‌بندی به پیش‌پردازش^۱ کمتری نیاز است. جزء اصلی این شبکه، عملیات سه بعدی کانولوشن است. شکل ۲۴، یک 3D-convolution در شبکه‌های عصبی کانولوشن را نشان می‌دهد. داده ورودی به شکل یک ماتریس $N \times N \times N_c$ آورده شده است که توسط ماتریس اسلایدینگ $F \times F \times N_c$ فیلتر شده و ماتریس خروجی $N-F+1 \times N-F+1$ حاصل می‌شود [۱].



شکل ۲۴. 3D-convolution در شبکه‌های عصبی کانولوشن [۱]

۳-۴-۳-۳ شبکه‌های عصبی بازگشتی^۲

همان‌گونه که در شکل ۲۵ نشان داده شده است، شبکه‌های عصبی هستند که در ساختار آنها یال‌های بازگشت کننده وجود دارد و در نتیجه امکان وجود دور یا به عبارتی دیگر حلقه‌های بازخورد مجاز بوده و خروجی نورون می‌تواند ورودی همان نورون و همچنین نورون‌های دیگر در همان لایه یا یک لایه قبلی باشد. به عبارت دیگر، شبکه‌های عصبی بازگشتی، بر روی توالی زمانی از داده‌ها با نمونه‌های هم‌بسته^۳ طراحی شده‌اند. تفاوت اصلی آنها با شبکه‌های عصبی FF در این است که اطلاعات تنها رو به جلو انتشار نیافته و همان‌گونه که مطرح شد، امکان وجود حلقه یا لوپ نیز وجود دارد. همچنین شبکه‌های عصبی بازگشتی به دلیل داشتن یال بازگشتی در ساختار خود، قدرت حافظه‌ای داشته و برای پردازش داده‌های متوالی^۴ مناسب هستند. منظور از داده‌های متوالی، داده‌هایی است که مقدار فعلی آنها به مقادیر قبلی وابسته است.



شکل ۲۵. شبکه عصبی بازگشتی

¹ Preprocessing

² Recurrent

³ Correlated

⁴ Sequential Data

در قالب این دو دسته‌بندی مطرح شده (شبکه عصبی FF و شبکه عصبی بازگشتی)، چندین معماری برای شبکه‌های عصبی وجود دارد. به عنوان مثال می‌توان به شبکه‌های عصبی مفهومی (CNN)^۱، اشاره نمود که به طور گسترده‌ای در پردازش تصویر و تشخیص الگو مورد استفاده قرار می‌گیرد. با توجه به ناملموس بودن تفاوت میان معماری‌های مختلف شبکه‌های عصبی و از آنجایی که انواع مختلفی از لایه‌ها می‌توانند در یک شبکه عصبی وجود داشته باشند، در نتیجه طبقه‌بندی را می‌توان با در نظر گرفتن انواع لایه‌ها در ساخت شبکه عصبی مصنوعی انجام داد [۱]. معمول‌ترین انواع لایه‌ها عبارتند از [۱]:

- لایه تمام‌متصل^۲: این لایه، یک لایه معمول بکار رفته در شبکه‌های عصبی بازخورد روبه‌جلو بوده و مبتنی بر این امر است که هر نورون یک لایه، یک ورودی از تمامی نورون‌های لایه قبلی دریافت می‌نماید و به تمامی نورون‌های لایه بعدی نیز متصل می‌شود. داده ورودی، ابتدا به صورت خطی پردازش شده، سپس به صورت غیر خطی در شبکه حرکت نموده و در نهایت به لایه بعدی انتشار می‌یابد.
- لایه کانولوشن: این لایه یکی دیگر از لایه‌هایی است که در شبکه‌های عصبی FF و به طور خاص‌تر در شبکه‌های عصبی مفهومی مورد استفاده قرار می‌گیرد. مشابه با لایه تمام‌متصل، ورودی توسط یک عملیات خطی با عنوان کانولوشن فیلتر شده، به صورت غیرخطی در شبکه حرکت نموده و در نهایت نتیجه را رو به جلو هدایت می‌نماید. با این حال نیازی نیست که هر نورون به تمامی نورون‌های لایه بعدی خود متصل شود.
- لایه pooling: این لایه معمولاً در شبکه‌های عصبی مفهومی به کار می‌رود که با تقسیم داده ورودی به چندین بلوک و انتخاب حداکثر تعداد مولفه از هر بلوک یا محاسبه میانگین مولفه‌ها در هر بلوک عمل می‌نماید.
- لایه بازگشت: این لایه یک لایه معمول در شبکه‌های عصبی بازگشتی محسوب می‌گردد. در این لایه، بعد از اجرای ترکیبی از داده‌های ورودی و حرکت آن به صورت غیرخطی، خروجی تنها رو به جلو انتشار نیافته، بلکه یک حلقه بازخورد نیز وجود دارد.

۴-۳-۴ آموزش شبکه‌های عصبی

آموزش شبکه‌های عصبی فرآیند تنظیم پارامترها در قالب یک روش یادگیری نظارت شده به منظور یادگیری یک رابطه ورودی-خروجی مطلوب است. هدف اصلی در آموزش شبکه‌های عصبی، کاهش خطای آموزش تا زمانی است که خطای تعمیم ارزیابی شده بر روی مجموعه اعتبارسنجی به میزانی کمتر از آستانه موردنظر برسد. از جمله برخی از متدهای آموزشی (مختص شبکه‌های عصبی روبه‌جلو)، می‌توان به موارد نظیر الگوریتم انتشار رو به عقب، SGD، Momentum for SGD، Nesterov، Momentum for SGD، الگوریتم AdaGrad، الگوریتم RMSProp و الگوریتم Adam اشاره نمود [۱].

به عنوان مثال، اصل یادگیری در شبکه‌های عصبی با تکرار یا همان iteration انجام می‌شود. این بدان معناست که چندین مرتبه داده‌های یک مجموعه داده به الگوریتم تزریق شده و این الگوریتم با کم و زیاد کردن وزن‌ها و انحراف‌ها، می‌تواند تفاوت‌ها را در داده‌های آموزشی تشخیص دهد. بنابراین، پایه‌ی یادگیری در شبکه‌های عصبی تکرار است. یکی از روش‌های بسیار پرکاربرد برای تکرار در شبکه‌های عصبی روش پس انتشار خطا است. در این روش، دو مرحله در هر تکرار وجود دارد. مرحله‌ی اول حرکت رو به جلو است که با ضرب داده‌های ورودی در وزن‌ها و سپس جمع آن با انحراف انجام می‌شود. سرانجام در همان مرحله‌ی اول یک خروجی (متفاوت با خروجی واقعی) حاصل می‌شود. در اینجا مقدار خطا در مرحله‌ی FF توسط تابع ضرر^۳ مشخص می‌شود. پس از مشخص شدن خطای الگوریتم با توجه به وزن‌ها و انحراف‌ها، مرحله‌ی دوم در یک تکرار آغاز می‌شود. در این مرحله می‌توان به عقب بازگشته و وزن‌ها و انحراف‌ها را به‌هنگام‌سازی نمود. یعنی وزن‌ها و انحراف‌ها را به شکلی تغییر داد که در تکرار

¹ Convolutional Neural Networks

² Fully-Connected

³ Loss Function

بعدی نتیجه‌ای نزدیک‌تر به خروجی واقعی و با خطای کمتر را تولید کنند. این تکرار رو به جلو و رو به عقب آنقدر انجام می‌شود تا خروجی شبکه برای تمامی داده‌های آموزشی به نزدیک‌ترین مقدار واقعی خود (یعنی مقداری که توسط داده‌های آموزشی در اختیار است) برسد. به این ترتیب الگوریتم آموزش دیده و می‌توان از آن برای داده‌های جدید و مشاهده نشده استفاده نمود.


۳-۴-۳-۵ یادگیری تقویتی عمیق

یادگیری تقویتی عمیق تلفیقی از یادگیری عمیق و یادگیری تقویتی است. چارچوب یادگیری تقویتی مستقیماً با یادگیری عمیق مرتبط نیست، بلکه یک رویکرد متفاوت در یادگیری ماشین است که فرآیند یادگیری را به روشی سازگار اجرایی می‌نماید. این امر در تعامل با محیط و اتخاذ اقدامات و سپس دریافت بازخورد از نتایج اقدامات صورت می‌پذیرد.

با این وجود، اخیراً مشاهده شده است که می‌توان از یادگیری عمیق به منظور بهبود و تسهیل پیاده‌سازی تکنیک‌های یادگیری تقویتی استفاده نمود. این امر سبب پیوند متقابل این دو چارچوب در یادگیری ماشین شده و در نهایت منجر به توسعه چارچوب یادگیری تقویتی عمیق شده است.

یادگیری تقویتی عمیق، انقلابی در زمینه هوش مصنوعی است و نشان‌دهنده گامی به سوی ایجاد سیستم‌های مستقل با سطحی بالاتر از درک دنیای بصری است. در حال حاضر، یادگیری عمیق یادگیری تقویتی را قادر می‌سازد تا به مشکلاتی که در گذشته قابل حل نبودند، بپردازد [۶].

یادگیری تقویتی عمیق به دلیل قابلیت یادگیری سطوح مختلف انتزاعی از داده‌ها، در کارهای پیچیده‌ای که دانش قبلی به نسبت کمی در زمینه آن وجود دارد، بسیار موفق عمل می‌کند. از جمله کاربردهای یادگیری تقویتی عمیق (شکل ۲۶) می‌توان به رباتیک، ماشین‌های خودران، اقتصاد، شبکه‌های هوشمند انرژی، بازی‌های ویدیویی و غیره اشاره نمود. به عنوان مثال در رباتیک، ربات‌ها با استفاده از تکنیک‌های یادگیری تقویتی عمیق قادر به یادگیری مستقیم از ورودی‌های دوربین در دنیای واقعی خواهد بود.




شکل ۲۶. کاربردهای مختلف یادگیری تقویتی عمیق

با این وجود، بررسی موثر محیط یا توانایی تعمیم یک رفتار مناسب در محیطی متفاوت، کار چندان ساده‌ای نیست. به همین دلیل، الگوریتم‌های متعددی در حوزه یادگیری تقویتی عمیق ارائه شده است. از جمله متدهای مبتنی بر مقدار برای یادگیری تقویتی

عمیق می‌توان به مواردی نظیر Q-learning، Fitted Q-learning، Deep Q-Networks، Double DQN، ساختار Dueling network و .. اشاره نمود [۱].

۳-۴-۳-۶ تاکشایی عمیق

یکی از مسائل موجود در شبکه‌های عصبی مصنوعی، مشخص نمودن تعداد نورون‌ها و لایه‌های مورد استفاده است. با این حال، در برخی موارد با استفاده از تکنیکی به نام تاکشایی^۱ عمیق، امکان انطباق تکرارهای موجود در الگوریتم‌های تکراری با تعداد لایه‌های شبکه عصبی مصنوعی وجود دارد. این امر، یک روش سیستماتیک به منظور مشخص نمودن هایپرپارامترهای شبکه عصبی مصنوعی که تعداد معینی از تکرارهای الگوریتم‌های بازگشتی را اجرا می‌کنند، فراهم می‌نماید.



شکل ۲۷. unfolding عمیق

همان‌گونه که در شکل ۲۷ نشان داده شده است، تعداد $k+1$ تکرار از یک الگوریتم تکراری روی k لایه پنهان و نیز بر روی لایه خروجی یک شبکه عصبی مصنوعی قرار می‌گیرد. خروجی هر لایه برابر با خروجی تولید شده توسط یک تکرار الگوریتم است، و خروجی لایه آخر برابر با خروجی آخرین تکرار الگوریتم است.

به عبارت دیگر، ایده اصلی تاکشایی عمیق را می‌توان در ارتباط میان ورودی-خروجی در یک شبکه عصبی در نظر گرفت. در این روش، الگوریتم تکراری با نداشت هر تکرار بر روی یک لایه از شبکه عصبی مصنوعی به عنوان ورودی شروع شده، k را در خروجی k امین لایه پنهان محاسبه نموده و در نهایت y را به عنوان خروجی تولید می‌کند. دو نکته اصلی که در ارتباط با این الگوریتم می‌بایست در نظر گرفته شود، عبارتند از:

- در مقایسه با شبکه‌های عصبی مصنوعی معمولی، تعداد گره‌ها و لایه‌ها در تاکشایی عمیق به وسیله الگوریتم ویژه‌ای (unfolded) مشخص می‌گردد. در این الگوریتم، تعداد لایه‌ها با توجه به تعداد تکرارهای الگوریتم مشخص شده و تعداد گره‌ها در هر لایه توسط اندازه بردارهای ورودی و خروجی مشخص می‌گردد.
- مزیت اصلی الگوریتم تاکشایی نسبت به یک شبکه عصبی مصنوعی در این است که پارامترهای الگوریتم به جای اینکه توسط روش‌های مرسوم تنظیم شوند توسط ANN تعیین می‌شوند. علاوه بر این، زمانی که پارامترها تعیین می‌شوند، ANN را می‌توان به طور مستقیم به عنوان یک جایگزین و پیاده‌سازی کارآمد الگوریتم تکراری برای محاسبه خروجی براساس پارامترهای انتخاب شده مورد استفاده قرار داد [۱].

۳-۴-۳-۷ یادگیری انتقال عمیق

¹ Unfolding

در یادگیری عمیق، یادگیری انتقال تکنیکی است که به موجب آن ابتدا یک مدل شبکه عصبی بر روی مسئله‌ای مشابه با مسئله‌ای که قرار است حل شود، آموزش داده می‌شود. سپس یک یا چند لایه از مدل آموزش‌دیده در مدل آموزش‌دیده جدید و بر روی مسئله موردنظر، مورد استفاده قرار می‌گیرند.

به عبارت دیگر، یادگیری انتقال عمیق یک چارچوب جدید دیگر است که یادگیری عمیق را با یکی دیگر از چارچوب‌های یادگیری ماشین، یعنی یادگیری انتقال ترکیب می‌نماید. به معنای وسیع‌تر، یادگیری انتقال، نحوه انتقال دانش در یک زمینه خاص برای اجرای یک کار معین به زمینه‌ای متفاوت، اما مرتبط و به منظور اجرای یک کار دیگر را مورد بررسی قرار می‌دهد. چهار مولفه اصلی در یک مسئله یادگیری انتقال عبارتند از:

- یک وظیفه به عنوان منبع^۱ که همان وظیفه اصلی است که به منظور انتقال دانش ایجاد شده است.
- یک دامنه به عنوان دامنه منبع^۲ که همان دامنه‌ای است که وظیفه منبع در آن اجرا می‌شود.
- یک وظیفه به عنوان هدف^۳ که همان وظیفه جدیدی است که با توجه به دانش انتقال یافته اجرا می‌شود.
- یک دامنه به عنوان دامنه هدف^۴ که همان دامنه جدیدی است که وظیفه هدف می‌بایست در آن اجرا شود.

به طور کلی می‌توان از یادگیری انتقال به منظور تسهیل پیاده‌سازی الگوریتم‌های یادگیری عمیق، به ویژه با کاهش میزان داده‌های به‌دست‌آمده برای آموزش و اهداف اعتبارسنجی، استفاده نمود. در این قسمت توجه به این نکته لازم است که همان‌گونه که قبلاً نیز عنوان گردید، در دسترس بودن مقادیر زیاد داده، پیش‌نیاز اصلی به منظور عملکرد بهتر یادگیری عمیق نسبت به دیگر روش‌های یادگیری ماشین است، اما در زمینه شبکه‌های ارتباطی بی‌سیم، دستیابی به مقدار زیاد داده‌ها می‌تواند بسیار پرهزینه بوده و یا در کل عملی نباشد. در این موارد، یادگیری انتقال می‌تواند با انتقال دانش از سایر سناریوهای مرتبط که در آن کسب داده‌ها قبلاً انجام شده‌است، مورد استفاده قرار گیرد.

با وجود جدید بودن این رویکرد، تکنیک‌های بسیاری برای یادگیری انتقال عمیق در مقالات و یافته‌های علمی ارائه شده است. چهار کلاس اصلی در تکنیک‌های یادگیری عمیق عبارتند از:

- یادگیری انتقال مبتنی بر نمونه^۵
- یادگیری انتقال مبتنی بر نگاشت^۶
- یادگیری انتقال مبتنی بر شبکه^۷
- یادگیری انتقال مبتنی بر رقابت^۸

به عنوان مثال، در رویکرد یادگیری انتقال مبتنی بر نمونه، فرض بر این است که داده‌های مربوط به هر دو حوزه منبع و هدف وجود دارد. سپس، ایده اصلی در استفاده از هر دو مجموعه داده برای انجام وظیفه‌ای است که به عنوان هدف در نظر گرفته شده است. این امر با تخصیص وزن متفاوت به هر نمونه از منبع و داده‌های هدف صورت می‌پذیرد. درغیراینصورت، داده از دامنه منبع به منظور تقویت داده از دامنه هدف مورد استفاده قرار می‌گیرد. اما می‌بایست به منظور اطمینان از اینکه در طول فرآیند آموزش نمونه‌های مختص دامنه منبع، کم و یا بدون اهمیت در نظر گرفته شده‌اند، وزن‌دهی متفاوتی صورت گیرد. بعد از مرحله وزن‌دهی

¹ Source Task

² Source Domain

³ Target Task

⁴ Target Domain

⁵ Instance-based Transfer Learning

⁶ Mapping-based Transfer Learning

⁷ Network-based Transfer Learning

⁸ Adversarial-based Transfer Learning

مجدد، مجموعه داده تقویت شده توسط هر الگوریتم آموزشی سنتی به عنوان یک مجموعه داده آموزشی برای وظیفه‌ای که به عنوان هدف در نظر گرفته شده است، محسوب می‌گردد.

در این روش، نیازی به داده برچسب‌گذاری شده وجود نداشته، به این معنا که زمانی که مجموعه داده جدید ساخته شود، می‌تواند در هر روش یادگیری ماشین مورد استفاده قرار گیرد. با این حال، تا آنجایی که آموزش یک شبکه عصبی مورد توجه است، لازم است که مجموعه داده آموزشی به منظور اجرای الگوریتم‌های آموزشی موجود برچسب‌گذاری شده باشد. اخیراً، فواید استفاده از یادگیری انتقال مبتنی بر نمونه، در ارتباط با الگوریتم آموزشی AdaBoost، به اثبات رسیده‌است که می‌تواند در مسائل طبقه‌بندی و رگرسیون مورد استفاده قرار گیرد [۱].

۵-۳- یادگیری ماشین در مدولاسیون و کدگذاری

مدولاسیون و کدگذاری تطبیقی (AMC^1) بطور گسترده در سیستم‌های مخابراتی بی‌سیم و سیمی برای سازگاری با تغییرات کانال مورد استفاده قرار می‌گیرد. AMC می‌تواند به سیستم مخابراتی برای دستیابی به بازدهی طیفی بهتر و چالش بین نرخ داده بالاتر و قابلیت اطمینان بیشتر با تنظیم مدولاسیون و نرخ کدگذاری مطابق با شرایط کانال کمک کند. از آنجایی که کانال‌های بی‌سیم معمولاً بیشتر از کانال‌های سیمی متغیر با زمان هستند، در بیشتر استانداردهای مرتبط با مخابرات بی‌سیم مانند استانداردهای Wi-Fi (IEEE 802.11n و IEEE 802.11ac) استفاده از AMC برای بهبود بازدهی طیفی برای برآوردن نیاز کاربران مطرح شده است. برای بهبود بیشتر بازدهی طیفی و اطمینان، طرح AMC با تکنیک MIMO و OFDM ترکیب گشته است. بدلیل پیچیدگی سناریوهای عملی و طبیعت تغییرپذیر بودن با زمان، سیستم مخابرات بی‌سیم (مانند شبکه بی‌سیم 802.11n) سازگاری لینک‌ها و پیکربندی لایه‌های فیزیکی در پیاده‌سازهای عملی دشوار می‌باشد. در نتیجه پیکربندی بهینه لایه فیزیکی به سختی در عمل بدست می‌آید و ساخت طرح AMC نامتناسب با ساختار کانال منجر به تنزل عملکرد سیستم می‌گردد. علاوه بر آن، وقتی طرح AMC با سیستم MIMO و OFDM ترکیب شود، مدل اثر مشترک مدولاسیون OFDM، کدینگ مرسوم و پردازشات MIMO بسیار چالش برانگیز می‌باشد. یکی از این دلایل این می‌باشد که در سیستم‌های عملی، نقص‌های مختلفی مانند اعوجاج غیرخطی تقویت کننده توان، خطای کوانتیزیشن تبدیل آنالوگ به دیجیتال، نویز جمع شونده غیرگوسی، در سیستم وجود دارد. در این حالت مدل سازی دقیق از یک سیستم مخابراتی کامل دشوار می‌باشد. دلیل دیگر آن این است که در طراحی سیستم‌های مخابراتی به راحتی می‌توان پردازش سیگنال را به چندین بلوک جدا از هم که هر یک کار مخصوص جداگانه ای دارد، تقسیم نمود. بنابراین بهینه سازی این اجزا بصورت مشترک باعث سیستم پیچیده از نظر محاسباتی می‌گردد. بنابر دلایل گفته شده، پیاده سازی AMC موجود، یا بخاطر تقریب‌های مدلی غیردقیق و یا با داشتن جدول‌های بزرگ، مشکل می‌باشد. برای کاهش هزینه محاسباتی و همچنین پرهیز از تقریب‌های غیرکاربردی مانند تقریب گوسی توزیع‌های غیرگوسی، به یک روش دقیق برای طراحی AMC که با مدل‌های ریاضی با تقریب‌های کم امکان‌پذیر باشد، نیاز داریم. به عبارت دیگر یادگیری ماشین توانایی بهینه‌سازی مشترک بلوک‌ها با استفاده از فریم‌های غیرخطی یکنواخت را دارد. بنابراین گزینه خوبی برای بهینه‌سازی سیستم مخابرات بی‌سیم استفاده‌کننده از AMC با پیاده‌سازی سخت‌افزاری مشخص روی کانال بی‌سیم است. براساس این مشاهدات، در این بخش ما از تکنیک‌های ML در سیستم مخابرات بی‌سیم با AMC که سازگاری با تغییرات کانال را دارد استفاده می‌کنیم. در اینجا دو طرح AMC براساس ML برای سیستم MIMO و OFDM معرفی شده‌اند: یک روش یادگیری هدایت شده و یک روش یادگیری تقویتی.

۱-۵-۳- یادگیری ماشین در AMC

روش یادگیری هدایتی^۲ (SL) مزیت‌های زیادی جهت استفاده در AMC دارد. یکی از این مزیت‌ها این است که در طول مدت زمان کارکرد شبکه مخابراتی، مجموعه داده‌ها می‌تواند بصورت آنلاین بروزرسانی شود. همچنین مجموعه داده زیادی شامل^۳ CRC، اطلاعات وضعیت کانال (CSI) و MCS^۴ وجود دارد که می‌تواند برای فراگیری AMC در شبکه بی‌سیم مورد استفاده قرار گیرند. علاوه بر این، نقص‌های عملیاتی که در روش‌های مبتنی بر مدل مانند تقویت کننده غیرخطی و اجزای مداری آنالوگ با وضوح محدود که اغلب تقریب زده و یا نادیده گرفته می‌شوند، در تکنیک‌های SL پذیرفته شده‌اند. یکی از کمبودهای

¹ Adaptive Modulation and Coding

² Supervised Learning

³ Cyclic Redundancy Checks

⁴ Modulation and Coding Scheme

SL این می‌باشد که داده نمونه‌برداری شده به ندرت ارائه دقیقی از تمام شرایطی که سیگنال ممکن است تجربه کند (مانند رفتار غیرخطی تقویت کننده و تغییرات زمانی کانال مخابرات بی سیم و توزیع غیرگوسی نویز و تداخل) را به دست می‌دهد. بنابراین SL ممکن است به دلیل مشخصه‌های متغیر و جمع‌آوری غیرعملی مقدار زیادی داده برای یادگیری آنلاین ناشدنی باشد. برخلاف آن روش‌های یادگیری تقویتی و فرایندهای تصمیم‌گیری مارکوف (MDP) توانایی یادگیری مستقیم از محیط را دارند. بنابراین راه‌حل‌های موردنیاز برای یادگیری آنلاین سیستم‌های مخابراتی را تامین می‌کنند. [۱۶] روش RL برای مخابرات بی سیم معرفی نموده است و [۱۷] روش Q-learning برای انتخاب بهترین MCS در SNR را مطرح می‌کند. اگرچه فراگیری غیرهدایتی مانند PCA^۱ در [۱۸] برای کاهش ابعاد مشخصه مطرح شده است، تصمیم نهایی آن با کمک الگوریتم K-نزدیکترین همسایه (k-NN^۲) که یک روش SL می‌باشد انجام می‌گردد. یک دلیل آن این است که اساساً یادگیری غیرهدایتی برای پردازش داده مناسب است ولی برای امور نیازمند به تصمیم‌گیری مانند AMC مناسب نیست. با در نظر گرفتن SL، بیش‌ترین الگوریتم‌های استفاده شده شامل SVM^۳، درخت تصمیم‌گیری (DT^۴)، k-NN، شبکه‌های عصبی و غیره می‌باشد. تمام این الگوریتم‌ها به داده‌های برچسب‌دار نیاز دارند. در بخش‌های بعدی دو روش k-NN و SVM را به عنوان دو نمونه برای نشان دادن کاربردهای SL در AMC و همچنین استفاده از Q-learning برای RL در AMC ارائه و بررسی شده‌اند. در این بررسی‌ها از پارامترها و مشخصه‌های استاندارد IEEE 802.11n که پروتکل Wi-Fi در سیستم MIMO-OFDM می‌باشد، استفاده شده است. در ادامه ابتدا مروری بر طرح AMC در استاندارد IEEE 802.11n و جزئیاتی درباره انواع مدولاسیون و نرخ کدینگ در این استاندارد صورت می‌گیرد.

۱-۱-۵-۳ در IEEE 802.11n

در اینجا به طور خلاصه به MCS در استاندارد IEEE 802.11n می‌پردازیم. بخشی از مشخصات MCS در جدول ۱ نشان داده شده است. بطوریکه MCS_i بیانگر i امین MCS و Nss بیانگر تعداد جریان‌های فضایی که همزمان از طریق لینک‌های هوایی در گیرنده-فرستنده IEEE 801.11n استفاده می‌شود، می‌باشد. در این جدول نسبت تعداد بیت‌های اطلاعات به تعداد بیت‌های کدشده به عنوان نرخ کد^۵ شناخته شده است. نوع مدولاسیون و نرخ کدگذاری، نرخ داده سیستم را با تعداد بیت بر ثانیه (bps) مشخص می‌کند. در عمل وقتی کانال مخابراتی متغیر با زمان می‌باشد، سیستم با استفاده از MCS مناسب می‌تواند با شرایط مخابراتی موجود سازگار گردد و بهترین MCS را برای چالش بین نرخ داده و اطمینان ارتباط فراهم سازد؛ هرچند که مشخص کردن MCS نزدیک به بهینه براساس کانال بی سیم متغیر با زمان کار آسانی نیست. در ادامه AMC براساس روش‌های SL و RL بررسی شده‌اند.

جدول ۲. لیست مدولاسیون و کدینگ مطرح شده در IEEE 802.11n.

^۱ Principal Component Analysis

^۲ k-Nearest Neighbour

^۳ Support Vector Machines

^۴ Decision Tree

^۵ Coding Rate

MCS_i	Nss	Modulation type	Coding rate	Date rate (Mbps)
0	1	BPSK	1/2	6.5
1	1	QPSK	1/2	13
2	1	QPSK	3/4	19.5
3	1	16QAM	1/2	26
4	1	16QAM	3/4	39
5	1	64QAM	2/3	52
6	1	64QAM	3/4	58.5
7	1	64QAM	5/6	65
8	2	BPSK	1/2	13
9	2	QPSK	1/2	26
10	2	QPSK	3/4	39
11	2	16QAM	1/2	52
12	2	16QAM	3/4	78
13	2	64QAM	2/3	104
14	2	64QAM	3/4	117
15	2	64QAM	5/6	130

۲-۵-۳- AMC با کمک یادگیری هدایتی (SL)

الگوریتم SL بوسیله داده فراگیری تابع مرجع را تولید می‌کند که برای نگاشت نمونه‌های جدید بکار می‌رود. در SL داده فراگیری برچسب دار توسط یک مجموعه نمونه برای فراگیری که هر یک شامل ورودی و مقدار خروجی مطلوب می‌باشد برای تولید تابع مرجع استفاده شده است. این انتظار می‌رود که یک کلاس از داده برچسب‌دار می‌تواند برای مورد‌های ناشناخته توسط الگوریتم‌های یادگیری مورد استفاده قرار گیرند. بنابراین الگوریتم یادگیری توانایی سازگاری با شرایط نامشخص با استفاده از داده فراگیری به طور هوشمند و منطقی را دارد. در SL الگوریتم‌های یادگیری که بیشترین استفاده را داشته شامل SVM, k-NN, DT و شبکه‌های عصبی می‌باشد. در ادامه روشهای k-NN و SVM به عنوان دو نمونه از SL در طرح AMC توضیح داده شده‌اند.

۱-۲-۵-۳ AMC با استفاده از k-NN

با هدف بیشینه‌سازی گذردهی^۱ با قید یک نرخ خطای بسته (PER^۲) مفروض، مکانیزم تنظیم لینک مبتنی بر AMC نیاز دارد تا مجموعه‌ای از ویژگی‌های خاص را جهت تعیین پارامترهای نزدیک به بهینه AMC (مدولاسیون و نرخ کدگذاری که در جدول ۱ آمده‌اند) داشته باشد. PER می‌تواند به عنوان معیار اندازه‌گیری عملکرد برای مشخص‌سازی اندیس MCS عمل کند؛ که بصورت زیر تعریف می‌شود:

$$i^* = \operatorname{argmax}_i \{R_i : PER_i \leq PER_{target}\},$$

در آن i^* اندیس MCS نزدیک به بهینه می‌باشد که با حل مسأله بهینه‌سازی بدست می‌آید. R_i نرخ داده است که MCS_i استفاده شده باشد و PER_i متناظر با آن است. اگر PER_i بزرگترین PER باشد که کوچکتر و یا مساوی با PER_{target}

¹ Throughput

² Packet Error Rate

باشد، آنگاه MCS_0 برای ارسال داده انتخاب می‌گردد. اگر AMC براساس k-NN در نظر گرفته شود، آنگاه مسأله بهینه‌سازی قبلی به مسأله طبقه‌بندی تبدیل می‌گردد که در آن از الگوریتم k-NN استفاده شده است. k-NN یک الگوریتم SL غیرپارامتری است که می‌تواند برای مسائل رگرسیون و طبقه‌بندی مورد استفاده قرار گیرد.

تحلیل عملکرد روش k-NN-Assisted AMC

در سیستم مخابرات بی‌سیم IEEE 802.11n براساس MIMO-OFDM با N_t تعداد آنتن ارسالی و N_r آنتن دریافتی، بعد از اعمال تبدیل فوریه گسسته، سیگنال دریافتی در زیرحامل n ام می‌تواند بصورت زیر بیان شود:

$$y_n = \sqrt{E_s} H_n x_n + v_n$$

که در آن N سایز DFT و تعداد زیرحامل‌ها می‌باشد، x_n بردار سمبل ارسالی و $v_n \sim CN(0, N_0 I)$ بردار نویز گوسی جمع‌شونده مختلط است. H_n ماتریس کانال زیرحامل n ام با سایز $N_r \times N_t$ و E_s انرژی سیگنال دریافتی می‌باشد. جهت تحلیل کانال بی‌سیم H_n تحت بلوک‌های محوشوندگی شبه‌ایستا فرض شده است؛ بدین معنی که حالت کانال در طول همه سمبل‌های OFDM یک بسته ثابت باقی می‌ماند، اما برای بسته‌های متفاوت مستقل می‌باشد. بسته‌ها با طول ثابت (۱۲۸ بیت)، همزمانی ایده‌آل^۱، یکسان‌سازی خطی (ZF^۲) از دیگر فرض‌های دیگر در این بررسی است. در این الگوریتم ابتدا نیاز به استخراج مجموعه مشخصه‌ها و سپس محاسبه فاصله بین ورودی و داده‌های فراگیری برای تعیین تعداد k نزدیک‌ترین همسایه وجود دارد. در سمت گیرنده معیار کیفیت اتصال (LQM^۳) براساس توصیف عملکرد لینک می‌تواند برحسب E_s, N_0 و H_n محاسبه گردد. N_s تعداد جریان‌های فضایی و بصورت $N_s \leq \min \{N_t, N_r\}$ و برای هر جریان $a \in \{1, \dots, N_s\}$ ، SNR هر زیرحامل $n \in \{1, \dots, N\}$ بصورت زیر است:

$$\gamma[a, n] = \frac{E_s}{N_0 \sum_{a'=1}^{N_s} |[\mathbf{G}_{ZF}[n]]_{a,a'}|^2}$$

که در آن $\mathbf{G}_{ZF} = (\mathbf{H}_n)^\dagger = (\mathbf{H}_n^H \mathbf{H}_n)^{-1} \mathbf{H}_n^H$ می‌باشد. برای هر زیرحامل مشخصه از روی SNR هر جریان به دست می‌آید. برای ساده‌سازی سیستم، AMC بجای هر زیرحامل، هر بسته یک جستجو مشخصه ایجاد می‌کند. بنابراین هر زیرحامل از یک بسته MCS یکسانی برطبق جستجو مشخصه بکار می‌گیرد. در ادامه شرایطهای محوشدگی یکسان فرکانس^۴ و محوشدگی فرکانس گزین^۵ بحث شده‌اند، زیرا استخراج مشخصه از یک بسته برای این دو کانال متفاوت است. برای ارسال بر روی کانال محوشدگی یکسان فرکانس همه زیرحامل‌ها کانال یکسانی را تجربه می‌کنند؛ بنابراین متوسط SNR روی همه زیرحامل‌ها برای استخراج مجموعه مشخصه استفاده می‌شوند. بر طبق معادله داده شده برای SNR مجموعه مشخصه یک‌بعدی برای MCS 0 و 7 و دو بعدی برای MCS 8-15 موجود است. بنابراین MCS پیشنهادی از روی این دو مجموعه مشخصه بدست می‌آید و MCS با بالاترین نرخ انتخاب می‌گردد. برای ارسال بر روی محوشدگی انتخابگر فرکانس، متوسط‌گیری روی زیرحامل‌ها نمی‌تواند تغییرات کانال را نشان دهد و فضای مشخصه مجموعه فراگیری شامل ماتریس کانال و انرژی سیگنال و تغییرات نویز است، که فضای مشخصه با ابعاد بالا را مشخص می‌کنند. در [۱۸] به منظور کاهش ابعاد فضای مشخصه، روش مرتبه‌بندی زیرحامل‌ها بیان شده است.

¹ Perfect Synchronization

² Zero Force

³ Link Quality Metric

⁴ Frequency-Flat Fading

⁵ Frequency-Selective Fading

۳-۵-۲-۲ AMC مبتنی بر SVM

k-NN می‌تواند موجب سازگاری سیستم با تغییرات کانال و بهبود عملکرد آن گردد. اگرچه مشابه الگوریتم‌های SL مرسوم این روش نمی‌تواند مرزهای گروه‌ها را بطور دقیق مشخص کند و همچنین دارای پیچیدگی محاسباتی بالا و نیازمند یک پایگاه داده بزرگ و آفلاین است؛ بنابراین نمی‌تواند بازده بالایی در AMC داشته باشد. برای روشن‌سازی بیشتر، روش‌های مرسوم از پایگاه داده آفلاین استفاده می‌کنند و معمولاً اندازه آنها برای پیاده‌سازی آفلاین AMC بسیار بزرگ می‌باشد. از آنجاییکه مقدار زیادی داده برای کاهش واریانس PER و بهبود دقت تخمین نیاز است، چگونگی کاهش PER توجه زیادی بخود جلب کرده است. [۱۸] طرح AMC آفلاین را مطرح کرده است که می‌تواند به AMC سریع با استفاده از SVM¹ دست یابد.

تحلیل عملکرد سیستم AMC مبتنی بر SVM

در الگوریتم SVM از پارامتر فریم مانند شکست یا موفقیت آن و حالت کنونی کانال برای فراگیری طبقه کننده SVM استفاده می‌کند [۱۹]. الگوریتم AMC آفلاین و سریع براساس SVM در مقایسه با الگوریتم‌های AMC براساس طبقه‌بندی نزدیک‌ترین همسایه، می‌تواند به عملکرد یکسان با حافظه و پردازش کمتر دست یابد و همچنین پیچیدگی محاسباتی بسیار کمتری دارد. این الگوریتم برای بهبود بیشتر عملکرد از تابع کرنل برای ساخت مرزهای غیرخطی، انتخاب مجموعه داده‌ی فراگیری مناسب و مجموعه مشخصه برای تعادل عملکرد و پیچیدگی بهره می‌برد.

الگوریتم SVM حاشیه بین کلاس‌های متفاوت در مجموعه داده فراگیری را ماکزیمم می‌کند. به هنگام استفاده از SVM در AMC، محدوده هر کلاس مطابق با شکست یا موفقیت ارسال تشکیل می‌گردد. معمولاً کلاس شکست و موفقیت بترتیب با -1 و +1 نشان داده می‌شوند. برای مجموعه مشخصه $x \in R^p$ بطوریکه p تعداد بعدهای بردار مشخصه و R مجموعه اعداد حقیقی می‌باشد و محدوده SVM با تابع ارجاع $h(x) = w^T \phi(x) + b$ تعیین می‌گردد که در آن b بایاس مرز و w بردار خطی و $\phi(x)$ تابع مشخصه SVM می‌باشد و بر روی مجموعه مشخصه برای تولید مجموعه مشخصه SVM اجرا می‌گردد. نتایج تابع ارجاع به عنوان ورودی تابع تفکیک کننده $g(x)$ که بصورت $g(x) = 1$ برای $x \geq 0$ و $g(x) = -1$ برای $x \leq 0$ می‌باشد، در نظر گرفته می‌شود. هر SVM یک طبقه‌بندی دودویی انجام می‌دهد. بنابراین به تعداد μ از SVM برای مشخص کردن تعداد μ کلاس مدولاسیون و کدینگ بکار می‌رود. طبقه‌بندی کننده‌ها بصورت یک-دربرابر-هیچ (OVN²) تعریف می‌شوند؛ بدین صورت که اگر در طبقه بندی کننده m ام شرط $PER(m, x) \leq F$ برقرار نگردد، آنگاه هیچ کلاسی انتخاب نمی‌شود و فریم کدشده با MCS_i و تعیین شده به عنوان ارسال موفق توسط طبقه‌بندی کننده آن را اجبار به انتخاب MCS_i می‌کند. در غیر این صورت وقتی ارسال فریم ناموفق باشد طبقه‌بندی کننده ناچار به انتخاب هیچ کلاس MCS_i می‌شود؛ بنابراین MCS مناسب برای ارسال فریم از μ کلاس MCS بعد از بکارگیری μ طبقه کننده OVN انتخاب می‌گردد. طبقه‌بندی کننده OVN نمی‌تواند جوابگوی شرط PER باشد. تابع تفکیک کننده با رگرسیون PER با تابع رگرسیون به ترتیب با کلاس‌های متفاوت MCS جایگزین شدند. بنابراین برای محاسبه احتمال هر کلاس تابع رگرسیون بصورت $r_m: R \rightarrow [0, 1]$ که برحسب m متفاوت هستند تعریف می‌گردد. بنابراین الگوریتم براساس SVM برای AMC آفلاین برای طبقه‌بندی مجموعه مشخصه متفاوت با طبقه‌بندی کننده دو مرحله‌ای: طبقه بندی کننده OVN و تابع رگرسیون استفاده می‌شود.


۳-۵-۲-۳ شبیه‌سازی و نتیجه‌گیری

¹ Support Vector Machine


² One-Verus-None

در این بخش به توضیح نتایج ارائه شده در [۱۹] می‌پردازیم. برای شبیه‌سازی پهنای باند کانال 20 MHz و تعداد آنتن‌های گیرنده و فرستنده برابر ۲ در نظر گرفته شده‌اند. تعداد کلاس‌های موجود MCS برابر ۱۶ می‌باشد. طول فریم برابر ۱۲۸ بایت و شرط PER برابر 0.1 است. در شبیه‌سازی سنکرون‌سازی و تخمین کانال در گیرنده بطور دقیق انجام می‌شوند و الگوریتم ZF برای یکسان‌سازی صورت می‌گیرد. علاوه بر آن الگوریتم AMC براساس SVM با کرنل گوسی و خطی و $k=10$ با k -NN انجام می‌شود. بازه SNR بین 0-30dB است؛ کانال گوسی و فرکانس‌گزین فرض شده است.

در شکل ۲۸ رابطه بین نرخ داده و متوسط SNR نشان شده است. درحالی که در شکل ۲۹ نتایج PER برای SNR های مختلف نشان داده شده است. از مقایسه این دو نمودار مشاهده می‌شود که SL-AMC می‌تواند با استفاده از داده برچسب‌دار در برقراری مصالحه بین نرخ داده و قابلیت اطمینان بالا کمک کند. با افزایش N نرخ داده و همینطور PER افزایش می‌یابند. وقتی N کوچک و SNR زیاد است، الگوریتم SVM-AMC به نرخ داده بیشتری نسبت به k -NN دست می‌یابد؛ بنابراین با استفاده از کرنل خطی می‌توان عملکرد رضایت‌بخشی برای سیستم تأمین کرد و نیاز به هزینه بیشتر برای به کارگیری کرنل گوسی نیست. قابل ذکر است که عملکرد k -NN-AMC عمیقاً به انتخاب داده‌های نمونه‌برداری شده و مقدار k بستگی دارد. به این ترتیب در مقایسه با SVM-AMC، استحکام k -NN کمتر است.



شکل ۲۸. نرخ متوسط براساس SNR متوسط برای کانال های متفاوت.



شکل ۲۹. PER براساس SNR متوسط برای کانال‌های متفاوت.

۳-۵-۳- پیاده‌سازی AMC با استفاده از یادگیری تقویتی (RL)

در این بخش الگوریتم RL معرفی و چگونگی کاربرد آن در AMC توضیح داده شده است. همانطور که قبلاً اشاره شد، برخلاف روش SL، روش RL می‌تواند مستقیماً با محیط تعامل کند. بدین معنی که عمل خود را مطابق با تعاملش با محیط انجام می‌دهد. روش RL نیاز به تعلیم‌دهنده خارجی ندارد، زیرا نمونه‌های فراگیری توسط تعامل با محیط فراگرفته می‌شوند. وقتی از روش RL در AMC استفاده می‌گردد، بهترین مدولاسیون و کدینگ با استفاده از تجربه قبلی از حالت کانال و به صورت زمان-واقعی و با کمترین مفروضات درباره سناریو مخابراتی بدست می‌آید. مطابق با آن، با هدف پیشینه‌سازی بازدهی طیفی، یک فرایند تصمیم‌گیری مارکوف (MDP^1) برای تصمیم‌گیری برای مدولاسیون و کدینگ استفاده می‌گردد. نکته قابل توجه اینکه در RL-AMC به فراگیری آفلاین نیاز نمی‌باشد؛ زیرا در آن صورت نیاز به در نظر گرفتن همه شرایط فیزیکی ممکن ارسال خواهد بود. بنابراین این نوع AMC می‌تواند سرویس سازگارتری نسبت به SL-AMC فراهم کند.

۳-۵-۳-۱ حالت-عمل-پاداش در یادگیری تقویتی

با استفاده از پردازش مارکوف، سیستم ML-AMC می‌تواند براساس حالت‌های محیط و پاداش بطور پیوسته با تغییرات کانال سازگار گردد. در زیر جزئیات بیشتری در مورد عمل، حالت و پاداش داده شده است:

- (۱) عمل (Action): هدف از AMC پیشینه‌سازی نرخ برای حالت داده شده بوسیله تنظیم مدولاسیون و کدینگ می‌باشد. در پروتکل عملی مانند IEEE 802.11n، تعداد محدودی از مدولاسیون و کدینگ وجود دارد. که هریک به عنوان یک عمل شناخته شده اند و طرح بهینه براساس تجربه‌های پیشین، قبل از ارسال بسته داده انتخاب می‌گردد.
- (۲) حالت (State): ایجاد لینک توانایی جمع‌آوری اطلاعات از محیط مانند حالت قبلی و کنونی کانال، مشخصه‌های استخراجی شبکه را دارد. با این شرط که ارزش حالت متعلق به یک مجموعه محدود است، مقادیر SNR در رنج -20dB تا -2dB با پله‌های 1dB

¹ Markov decision process

برای پرهیز از تعداد بی نهایت حالت در نظر گرفته شده است. در هر حالت s ، یک عمل از یک مجموعه محدود انتخاب و عمل‌های متفاوت به پاداش‌های مورد انتظار متفاوت منجر می‌شود. از آنجاییکه لینک کانال متغیر با زمان می‌باشد، برای تجسم سازگاری real-time روش RL، مقدار $Q(s, a)$ بطور پیوسته بروزرسانی می‌گردد. برای بیشینه سازی نرخ قابل دسترسی، باید MCS بهینه برای حالت کانال داده شده بدست آید.

۳) پاداش (Reward): جهت مؤثر بودن استفاده از RL در مسائل عملی، تابع پاداش R باید بدرستی تعیین گردد. با داشتن سناریوی تطبیق لینک، نرخ بدست آمده با استفاده از عمل a در حالت s برای تعیین پاداش R استفاده می‌شود؛ و بصورت زیر تعریف می‌شود:

$$R(s, a) = \log_2(M_a) \rho_a [1 - \text{PER}(s, a)]$$

که در آن M_a بیانگر مرتبه مدولاسیون عمل a ، ρ_a نرخ کدینگ وقتی عمل a انجام می‌شود. با استفاده از بخش CRC در هر بسته، گیرنده می‌تواند بسته‌های خطا دار را مشخص کند و PER می‌تواند با استفاده از اندازه‌گیری بسته خطا تخمین زده شود. این اطلاعات سپس به فرستنده ارسال می‌شوند تا الگوریتم یادگیری که وظیفه افزایش بازدهی طیفی را بر عهده دارد، بروزرسانی شود.

۲-۳-۵-۳ شبیه‌سازی و تحلیل عملکرد RL-AMC

در شبیه‌سازی ترکیب مدولاسیون و کدینگ $m=8$ با $N_{ss} = 1$ فرض شده است. همچنین نرخ فراگیری برای الگوریتم Q-learning برابر با $\alpha = 0.4$ و $\tau = 0.4$ برای روش انتخاب عمل بر اساس Softmax^۱ می‌باشد. در شکل ۳۰ و ۴ اثر تنظیم پارامترها شامل نرخ یادگیری و پارامتر softmax بر روی همگرایی رفتار الگوریتم نشان داده شده‌اند. برای مشخص کردن تفاوت بین سیاست‌های مورد استفاده در RL و مدولاسیون و کدینگ‌های مختلف برای یک SNR مفروض، MSE برای کل فریم‌ها محاسبه می‌شود. شکل ۳۰ نشان می‌دهد که هرچه پارامتر softmax کوچکتر باشد، سرعت همگرایی بیشتر می‌گردد. دلیل آن این است که برای $\tau = 0$ عملی با مقدار Q بیشتر ترجیح داده می‌شود. اگرچه τ کوچک بدلیل زود تمام شدن پروسه یادگیری منجر به عملکرد بد سیستم گردد. همچنین در شکل ۳۱ مشاهده می‌گردد که وقتی نرخ یادگیری بالاتر است پاداش آنی بیشتری نسبت به پاداش تجمعی بدست می‌آید و نرخ یادگیری بهینه برای هر سیستم خاص متفاوت است. همچنین عملکرد سیستم RL با روش جدول مراجعه‌ای^۲ که با RawBER برای تطبیق اتصال^۳ نیز شناخته شده است، مقایسه می‌شود. در نگاشت RawBER احتمال خطای بیت کد نشده در هر زیرحامل برای محاسبه LQM استفاده شده است.


در جدول مراجعه‌ای مقادیر Q برای همه جفت حالت-عمل‌های ممکن ذخیره می‌شوند. مشکل روش جدول مراجعه‌ای این است که نیازمند مقدار زیادی حافظه و زمان شبیه‌سازی برای هر سناریو می‌باشد. بنابراین یک نوع داده‌ی تولید شده نمی‌تواند همه شرایط ممکن را پوشش دهد و در نتیجه جدول مراجعه‌ای می‌تواند منجر به راه حل غیربهینه شود. با در نظر گرفتن سناریویی که در آن SNR کانال بصورت ایده‌آل بدست می‌آید، شکل ۳۲ نشان می‌دهد که بازدهی طیفی تابعی از متوسط SNR در این سناریو است. مشاهده می‌گردد که روش RL در مقایسه با روش جدول مراجعه‌ای به نرخ کمتری دست می‌یابد، چراکه این روش در کانال خاصی بهینه گشته است؛ درحالیکه RL به تدریج با محیط سازگار می‌گردد. در مقابل در شکل ۳۳ وقتی SNR کانال نمی‌تواند بصورت ایده‌آل در سناریوهای مرسوم در سیستم‌های مخابراتی عملی بدلیل خطای تخمین به دست آید، طرح RL مطرح شده می‌تواند از روش جدول مراجعه‌ای پیشی بگیرد. این بدین دلیل می‌باشد که RL توانایی یادگیری از محیط و سازگاری با آن را دارد، درحالیکه روش جدول مراجعه‌ای برای محیط خاص بهینه می‌گردد. علاوه بر آن، RL می‌تواند در حالت آنالین عمل کند،

¹ Softmax Action-selection


² Lookup Table

³ Link Adaptation


بنابراین نیاز به شبیه‌سازی اضافی برای سازگاری با سناریوهای متفاوت ندارد. از مشاهده نتایج شبیه‌سازی و تحلیل‌ها می‌توان مشاهده نمود که RL می‌تواند یک راه حل قابل اطمینان برای مسأله AMC باشد. در این روش بیشینه‌سازی بازدهی طیفی به عنوان مسأله MDP در نظر گرفته می‌شود و میانگین SNR برای مشخص کردن حالت کانال لینک رادیویی استفاده می‌گردد. رابطه بین مقادیر SNR و طرح مدولاسیون و کدینگ با استفاده از Q-learning برای حل مسأله MDP مشخص می‌گردد. از نتایج شبیه‌سازی می‌توان مشاهده نمود که RL-AMC می‌تواند برای پیاده‌سازی آنلاین لینک رادیویی بکار رود زیرا در این روش نیازی به فراگیری آفلاین نیست. همچنین این روش سازگار با تغییرات محیط رادیویی است. بنابراین با کمک RL، AMC می‌تواند بصورت پویا پارامترها را تنظیم کند و به کاربران سرویسی با بازدهی بالاتر و مطمئن تر ارائه دهد.




شکل ۳۰. تاثیر پارامتر τ بر همگرایی الگوریتم RL برای $\alpha = 0.4$.



شکل ۳۱. تاثیر نرخ α بر همگرایی الگوریتم RL برای $\tau = 0.4$.



شکل ۳۲. متوسط بازدهی طیفی جدول ارجاعی و RL برای کانال AWGN با تخمین ایده آل SNR.



شکل ۳۳. متوسط بازدهی طیفی lookup table و RL برای کانال AWGN با تخمین غیر ایده آل SNR.

۴-۵-۳- جمع‌بندی بکارگیری ML برای AMC

در این فصل سه روش AMC مبتنی بر یادگیری ماشینی برای مخابرات بی‌سیم برای تنظیم با تغییرات کانال با تقریب‌های مدل کمتر و دقت بیشتر نسبت به AMC مرسوم بیان شده است. دو روش از این روش‌ها مبتنی بر SL می‌باشد و دیگری توسط RL پیاده‌سازی شده است. نکته قابل توجه اینکه اگرچه الگوریتم‌های SL مانند SVM، k-NN و غیره موجود می‌باشند ولی این الگوریتم‌ها مکانیزم عملکرد مشابه همچون نیاز به داده برچسب‌دار و تقلید طبقه‌بندی‌کننده برای انجام فراگیری دارند. بنابراین بدون از دست رفتن عمومیت، نمونه‌های k-NN و SVM برای نشان دادن کاربرد SL در AMC بکار گرفته شدند. برای روش RL در AMC، از Q-learning بدلیل استفاده گسترده‌اش بخاطر دقت زیاد، استفاده شده است. برای تأیید کاربرد و مؤثر بودن الگوریتم‌های فراگیری برای AMC، شبیه‌سازی با پارامترهای موجود در استاندارد IEEE 802.11n برای

مقایسه ML-AMC با الگوریتم‌های مرسوم انجام شده است. قابل ذکر است که SL-AMC مناسب برای سناریویی که نمونه‌های فراگیری نمایانگر همه شرایطی که فرستنده ممکن است تجربه کند می‌باشد. برخلاف آن الگوریتم RL می‌تواند بطور مستقیم از تعامل با محیط فراگیری گردد و به تدریج به عملکرد رضایت‌بخش با فراگیری غیرآفلاین، آنگونه در SL نیاز است، دست یابد. بنابراین این دو نوع مکانیزم یادگیری می‌توانند مطابق با فراگیری آفلاین و آنلاین براساس درخواست کاربران در سناریوهای مختلف انتخاب شوند.

با استفاده از فراگیری و آموزش روش AMC مبتنی بر ML اطمینان زیادی در سیستم مخابرات بی‌سیم ایجاد می‌کند. تحقیقات آینده می‌تواند شامل ترکیب RL و SL باشد بطوریکه سیستم ML-AMC را بهبود دهد و به مبادله بهتری بین پیچیدگی و عملکرد سیستم با هدف تأمین سرویس دهی بهتر کاربران دست یابد.

۳-۶- یادگیری ماشین در یکسان سازی کانال

یکی از چالش‌های فنی بکارگیری سیستم‌های مخابراتی بی‌سیم برای تأمین سرویس کاربران تأمین ضریب اطمینان و نرخ بالای داده در حضور تداخل بین‌سیگنالی می‌باشد. تداخل بین‌سیگنالی به علت انتشار سیگنال در مسیرهای مختلف در محیط مخابراتی ایجاد می‌شود. چالش فنی دیگر، حذف آشفتگی‌های غیرخطی ایجاد شده توسط نقص سخت‌افزاری در فرستنده/گیرنده^۱ است. در مخابرات بی‌سیم، حذف تداخل بین‌سیگنالی توسط یکسان‌سازی^۲ انجام می‌شود. یکسان‌سازهای متفاوتی برای حذف تداخلات بین‌سیگنالی و بهبود اطمینان بکار می‌روند. یکی از آن‌ها یکسان‌ساز تطبیقی^۳ می‌باشد که برای یادگیری مشخصات متغیر با زمان کانال بی‌سیم مطرح شده است. یکسان‌ساز تطبیقی بطور معمول از دو فاز یادگیری^۴ و ردگیری^۵ تشکیل شده است. در طول فاز یادگیری یک دنباله داده برای اجرای تنظیمات درست در گیرنده از سمت فرستنده به گیرنده ارسال می‌گردد. پس از فاز یادگیری، ارسال داده اصلی صورت می‌گیرد. در طول زمان این فاز، یکسان‌ساز تطبیقی کانال را تخمین می‌زند و با استفاده از اطلاعات بدست آمده ضرایب فیلتر را بروز رسانی می‌کنند، بطوریکه با محیط مخابراتی متغیر با زمان مناسب گردد. روش‌های یکسان‌سازی معمولاً به دو دسته خطی و غیرخطی تقسیم می‌گردند. ZF^6 و $MMSE^7$ جزو خانواده یکسان‌سازهای خطی و با بیشترین کاربرد هستند. یکسان‌سازهای غیرخطی توانایی بالاتری نسبت به حالت خطی دارند ولی با پیچیدگی بیشتر. بطور معمول سه روش غیرخطی موجود است: $MLSE^{10}$ ، $MLSD^9$ ، DFE^8 . در بین این سه، $MLSE$ از این جهت که احتمال خطای دنباله^{۱۱} را کمینه می‌کند، عملکرد بهینه‌ای دارد. اگرچه پیچیدگی آن با افزایش تعداد تب‌های پاسخ ضربه‌ی کانال افزایش می‌یابد. یکسان‌سازهای مرسوم سیگنال دریافتی را دیکانوالو^{۱۲} می‌کنند تا آشفتگی‌های ایجاد شده توسط کانال را برطرف نماید. در مجموع، ترکیب یکسان‌سازهای مرسوم و کانال یک تابع تاخیر ایده‌آل است.

پیچیدگی این یکسان‌سازها وابسته به کانال می‌باشد و ممکن است در بعضی محیط‌های مخابراتی، بسیار بالا باشد. برای کاهش هزینه محاسباتی یکسان‌سازهای مرسوم، یکسان‌سازهایی براساس یادگیری ماشین مطرح شده‌اند. در این یکسان‌سازها هر

¹ Transceiver

² Equalizer

³ Adaptive Equalizer

⁴ Training

⁵ Tracking

⁶ Zero Forcing

⁷ Minimum Mean Square Error

⁸ Decision Feedback Equalizer

⁹ Maximum Likelihood Symbol Detection

¹⁰ Maximum Likelihood Sequence Estimation

¹¹ Sequence

¹² Deconvolve

کلاس با یک خروجی ممکن از الفبای سمبول‌ها و مرزهای غیرخطی مشخص در فضای با ابعاد بالاتر مشخص می‌گردند. پیچیدگی این یکسان‌سازها به تعداد سمبول‌ها و سائز فضا مربوط ولی به تعداد CIR^1 s وابسته نمی‌باشد. از دیگر مزایای آن هوشمندی و توانایی پردازش سیگنال تطبیقی آن می‌باشد که آن را برای عمل در محیط‌های بی‌سیم متغیر با زمان توانمند می‌کند. تمرکز این بخش بر استفاده از شبکه‌های عصبی مبتنی بر یادگیری عمیق برای اینگونه یکسان‌سازها است.

۱-۶-۳- مروری بر یکسان‌سازی مبتنی بر شبکه‌های عصبی

با بهره‌برداری از ویژگی‌های غیرخطی شبکه‌های عصبی، ایکوالیزیشن مبتنی بر شبکه‌های عصبی، توانایی استخراج مشخصات کلیدی کانال مخابراتی و مقابله هوشمند با تداخل بین سمبلی (ISI^2) را با کمک الگوریتم‌های مورد استفاده در شبکه‌های عصبی شامل: MLP^3 ، $FLANN^4$ ، $SCRFNN^5$ ، RNN^6 ، DL^7 ، ELM^8 و غیره می‌باشد. در این بخش مروری بر جزئیات بر موارد فوق‌الشاره خواهد شد.

۱-۶-۱-۱ یکسان‌سازی مبتنی بر شبکه‌های عصبی چندلایه پرسپترون

یکسان‌سازی کانال به عنوان یک مسأله طبقه‌بندی در نظر گرفته می‌شود. در [۲۰] یکسان‌ساز با استفاده از NN براساس MLP برای مقابله با ISI در کانال خطی با نویز سفید گوسی مطرح شده است. در این یکسان‌ساز تابع Sigmoid استفاده شده در لایه آخر خروجی را به محدوده $[-1, 1]$ نگاشت می‌کند. بنابراین جایگزینی این تابع با توابع دیگر، برای سیگنال با دامنه متفاوت مانند سیگنال PAM⁹ می‌باشد. معمولاً یکسان‌ساز MLP با یادگیری هدایتی صورت می‌گیرد. همانند الگوریتم‌های ML مطرح شده قبلی، به مقدار زیادی داده ورودی-خروجی برای یادگیری یکسان‌ساز قبل از استفاده آن در مرحله آشکارسازی داده، نیاز است. در مقابل در یکسان‌سازی بدون دید، داده‌ای برای یادگیری در دسترس نمی‌باشد. یکسان‌سازی کانال براساس MLP با بهره‌برداری از احتمالات مرتبه بالا در [۲۱] استفاده شده است. در [۲۲] نشان داده شده است که یک یکسان‌ساز بدون دید توانایی دست‌یابی سریع به نرخ همگرایی و میانگین مربعات خطای کوچکتر در مقایسه با یکسان‌ساز براساس MLP اصلی با استفاده از یادگیری داده را دارد.

۱-۶-۱-۲ یکسان‌ساز مبتنی بر FLANN

به علت تک‌لایه‌ای بودن FLANN، پیچیدگی محاسباتی کمی دارد و برای پیاده‌سازی آسان است [۲۳]. در مقایسه با MLP، FLANN هیچ لایه نهانی ندارد ولی نگاشت مورد استفاده در آن غیرخطی است. بخاطر سادگی پیاده‌سازی FLANN، از جنبه تحقیقاتی توجه زیادی را به خود جذب کرده و برای یکسان‌سازی کانال استفاده شده است. در یکسان‌ساز مبتنی بر FLANN

¹ Channel Impulse Response

² Inter-Symbol Interference

³ Multi-Layer Perceptron

⁴ Functional Link Artificial Neural Network (NN)

⁵ Self-Constructing Recurrent Fuzzy NN

⁶ Recurrent Neural Network

⁷ Deep Learning

⁸ Extreme Learning Machines

⁹ Pulse Amplitude Modulation

گسترده‌ی عملکرد با کمک توابع متعامد هندسی^۱ انجام می‌شود. این یکسان‌سازها عملکرد بهتری را نسبت به یکسان‌ساز براساس MLP دارند؛ گرچه ضعف آن افزایش پیچیدگی در BER^2 پایین می‌باشد.

۳-۶-۱-۳ یکسان‌ساز مبتنی بر RBFN

RBF در ابتدا به عنوان جایگزینی برای تابع Sigmoidal معرفی شده است و می‌تواند برای جادادن داده در یک فضای چند بعدی استفاده شود. در این یکسان‌سازها سیگنال دریافتی برطبق مرکز بردارهای دریافتی است. در مقایسه با MLSE، این یکسان‌سازها با داشتن پیچیدگی کمتر محاسباتی، عملکرد بهتری در کانال رایلی^۳ متغیر با زمان از خود نشان می‌دهند. برای بهبود مسائل عملی بصورت بهینه‌تر و بهبود بیشتر عملکرد، یکسان‌ساز مبتنی بر RBF از سیستم‌های فازی-عصبی براساس الگوریتم یادگیری مفرط فازی^۴ استفاده می‌کند. این بدان دلیل می‌باشد که الگوریتم گفته‌شده نیازی به یک مجموعه داده کامل برای فراگیری ندارد؛ داده‌ها می‌توانند به شکل بلوک‌های کوچک در طول فرایند یادگیری مورد استفاده قرار گیرند. بنابراین در مقایسه با الگوریتم یادگیری دسته‌ای^۵ به یک مجموعه داده جدید برای فراگیری دوباره نیاز ندارد.

۳-۶-۱-۴ یکسان‌سازهای RNN

RNN می‌تواند به آسانی عکس یک سیستم با حافظه محدود پیاده‌سازی گردد؛ بنابراین می‌تواند یک فیلتر غیرخطی با حافظه بی‌نهایت را مدل نماید؛ بنابراین RNN توانایی مؤثر در حذف تداخلات ناشی از کانال‌ها را دارد. RNNها در سناریوهای مختلف برای یکسان‌سازی کانال استفاده شده‌اند.

نویسندگان [۲۴] یک یکسان‌ساز RNN را مطرح نمودند که می‌تواند در دو وضعیت فراگرفته^۶ و بدون دید^۷ عمل کنند. یکسان‌ساز نام‌برده شده مناسب برای هر دو کانال مخابراتی خطی و غیرخطی است. نتایج مطالعات و شبیه‌سازی نشان داده‌اند از بعضی جنبه‌های خاص این یکسان‌سازها عملکرد بهتری نسبت به یکسان‌سازهای خطی مرسوم دارند. در [۲۵] علاوه بر RNN از CNN برای یکسان‌سازی کانال برای مقابله با آشفتگی غیرخطی کانال و تغییرات موقت سیگنال رادیویی استفاده می‌شود. در شبکه CNN-RNN ابتدا سیگنال‌های رادیویی از زیرشبکه CNN و سپس از زیرشبکه RNN عبور می‌کنند. با استفاده از CNN، از مرحله قبلی می‌توان در مرحله فعلی بهره‌برداری کرد و RNN با استفاده از حافظه LSTM^۸ توانایی فراگیری وابستگی‌های موقت را دارد.

۳-۶-۱-۵ یکسان‌سازهای مبتنی بر SCRFNN

شبکه‌های عصبی-فازی (FNN^۹) از هردو خاصیت تفسیر مناسب منطق فازی و توانایی بالای ML بهره می‌گیرند. این شبکه‌ها توانایی تشکیل محدوده غیرخطی برحسب سیگنال دریافتی را دارند. یکسان‌ساز FNN می‌تواند به بازدهی بالا در حذف ISI دست یابد. این یکسان‌ساز توانایی تشکیل محدوده تصمیم‌گیری مستقیماً بر طبق سیگنال دریافتی و بدون نیاز به اطلاعات

¹ Orthogonal Trigonometric

² Bit Error Rate

³ Rayleigh

⁴ Fuzzy Extreme Learning

⁵ Batch

⁶ Trained

⁷ Blind

⁸ Long Short-Term Memory

⁹ Fuzzy NN

کانال را دارد. SCRFNN ترکیبی از RNN و FNN – خودساخته^۱ می‌باشد. در فرایند یادگیری آنلاین، فراگیری پارامتر براساس روش GD با کمک روش تطبیق دلتا^۲ و ساختار یادگیری تقسیم‌بندی فضای سیگنال ورودی می‌باشد. پارامترها و ساختار SCRFNNs می‌تواند خودبخودی بطور همزمان تنظیم شوند. یکسان‌ساز DFE که از نوع سریع FSCFN استفاده می‌کند، نوع دیگری از یکسان‌ساز می‌باشد که در مقایسه با SCRFNN دارای عملکرد BER، هزینه کمتر سخت‌افزار و پیچیدگی کمتر می‌باشد.

۳-۶-۱-۶ یکسان‌سازهای مبتنی بر یادگیری عمیق (DL)

لایه‌های نهانی DNN باعث توانایی بسیار زیاد آن شده است [۲۶]. این مرجع با کمک DL و با استفاده از MLP در یکسان‌ساز کانال و کدگذاری، نشان داده است که تحت شرایط مختلف کانال مانند انتخاب‌گر از نظر فرکانسی و متغیر با زمان، عملکرد مقاومی دارد. در [۲۷] ساختار DNN برای بازیابی سمبول داده در سیستم OFDM استفاده شده است. همچنین نشان داده شده است که اگرچه DNN با استفاده از داده‌ی تولیدشده از مدل کانالی مشخص فراگرفته شده است، یکسان‌ساز مبتنی بر DNN عملکرد مقاومی در هنگامی که کانال فاز تست متفاوت با کانال فاز فراگیری است، دارد.

۳-۶-۱-۷ یکسان‌سازهای مبتنی بر ELM

ELMها توانایی فراگیری دقیق ضرایب مورد نیاز در الگوریتم‌های مربوطه را دارد. این نوع شبکه عصبی با بازخورد روبه‌جلو، اجازه دستیابی به عملکرد دلخواه با پارامترهای ثابت لایه‌های نهانی را می‌دهد. محققان در مخابرات بی‌سیم با استفاده از ELM به طراحی یکسان‌ساز کانال برای حذف ISI و بهبود عملکرد سیستم پرداخته‌اند. در [۲۸] با بهره‌گیری از دقت و بازدهی فراگیری آن، نشان داده شده است که یکسان‌ساز مبتنی بر ELM توانایی همگرایی سریع در ارسال بسته کوتاه با استفاده از QAM را دارد. عموماً وقتی یکسان‌ساز مبتنی بر شبکه‌های عصبی بدرستی فراگرفته شده باشد، می‌تواند بطور هوشمندانه ISI را حذف کند و بصورت چشمگیری قابلیت اطمینان مخابره را بهبود دهد. یکسان‌ساز مبتنی بر شبکه‌های عصبی باید ویژگی‌های کلیدی کانال مخابراتی را با فراگیری استخراج کند که مسائلی نظیر همگرایی، پیچیدگی محاسباتی و بازدهی طیفی دخیل می‌شوند. برای این امر، تکنیک‌های SVM^۳ و GPR^۴ برای یکسان‌سازی کانال در مخابرات بی‌سیم معرفی شده‌اند که در ادامه به آنها خواهیم پرداخت.

۳-۶-۱-۸ یکسان‌سازهای مبتنی بر SVM و GPR

تئوری Cover بیان می‌کند با احتمال بسیار زیادی ایجاد ابرهای داده جدا شونده با تصویر نمودن فضای نمونه P به فضای مشخصه F با ابعاد بیشتر توسط نگاشت غیرخطی وجود دارد. برطبق این تئوری SVM بطور غیرخطی نگاشت ضرب داخلی داده در فضای نمونه از طریق کرنل از ابرصفحه^۵ بهینه برای جداسازی ابر داده در فضای مشخصه استفاده می‌کند [۲۹]. یکسان‌ساز SVM نیاز به دنباله فراگیری بلند دارد که موجب پیچیدگی بالایی می‌باشد. برای حل اینگونه مسائل، یکسان‌ساز غیرخطی کانال مبتنی بر GPR مطرح شده است. در مقایسه با این روش، الگوریتم GPR دارای مزیت بهینه‌سازی ابرپارامترهای کرنل براساس ML^۶ می‌باشد. این موجب بهبود چشمگیر عملکرد یکسان‌ساز GPR در مقایسه با یکسان‌ساز SVM می‌گردد.

¹ Self-Constructing FNN

² Delta Adaptation

³ Support Vector Machine

⁴ Gaussian processes for regression

⁵ Hyperplane

⁶ Maximum Likelihood

برخلاف آن هنگام استفاده از مجموعه داده بلند، عملکرد یکسان‌ساز SVM به یکسان‌ساز GPR نزدیک است. برای بهبود بیشتر عملکرد یکسان‌ساز GPR، [۳۰] یکسان‌سازی غیرخطی کانال را با $LDPC^1$ ترکیب نموده است.

۲-۶-۳- آشکارسازی و یکسان‌سازی براساس شبکه‌های عصبی


در این بخش به مدل اصلی شبکه‌های عصبی روبه‌جلو یعنی MLP می‌پردازیم. سپس براساس MLP و DL، راه حل DNN برای پیاده‌سازی یکسان‌ساز کانال مطرح شده است. در انتها نیز یکسان‌سازها براساس انواع متفاوت DNN بطور مختصر شرح داده شده‌اند.

۱-۲-۶-۳ مدل چندلایه پرسپترون

عموماً NNها نیاز به فراگیری مجموعه بزرگی از داده برای استخراج مشخصه‌های کلیدی دارند. پروسه یادگیری معمولاً توسط الگوریتم GD پیاده‌سازی می‌گردد که در هر مرحله، از انتشار روبه‌جلو و روبه‌عقب استفاده می‌کند. در این قسمت اصول MLP به همراه روش‌های فراگیری داده ارائه می‌شوند.

۲-۲-۶-۳ ساختار تعمیم‌یافته MLP


عموماً یک گره عصبی همانطور که در شکل ۳۴ نمایش داده شده است واحد اصلی شبکه MLP می‌باشد. اگر $x_1, x_2, \dots, x_n$ ورودی شبکه باشد آنگاه گره خروجی بصورت $y = f(\sum w_i x_i + b_i)$ می‌باشد. بطوریکه w_i ضریب ورودی x_i ، b_i متغیر بایاس و $f(\cdot)$ یک تابع غیرخطی که تابع فعال‌سازی^۲ نامیده می‌شود، می‌باشد. انتخاب‌های متفاوتی برای تابع فعال‌سازی وجود دارند؛ از جمله تابع sigmoid، تابع tanh و تابع ReLu. ساختار عمومی MLP در شکل ۳۵ نمایش داده شده است. بطوریکه چندین گره عصبی لایه‌های مختلف از جمله ورودی، پنهان و خروجی را تشکیل داده‌اند. لایه‌های بین لایه ورودی و لایه خروجی، لایه‌های پنهانی نامیده می‌شوند. لایه ورودی برای وارد نمودن متغیرهای ورودی و لایه خروجی برای خروج نتایج محاسباتی می‌باشد.



شکل ۳۴. گره عصبی.

¹ Low Density Parity Check Codes

² Activation Function



شکل ۳۵. یک مثال از مدل MLP.

تابع اتلاف برای مجموعه فراگیری M نمونه بصورت زیر تعریف می‌گردد:

$$L_2(Y, \hat{Y}) = \frac{1}{M} \sum_{m=1}^M \|y^{(m)} - \hat{y}^{(m)}\|^2$$

بطوریکه $y^{(m)}$ و $\hat{y}^{(m)}$ به ترتیب خروجی واقعی و خروجی دلخواه برای سمبل m می‌باشد. در MLP معمولاً فرایند یادگیری با کمک الگوریتم GD^۱ و بعضی الگوریتم‌های دیگر انجام می‌شود که در زیر به بعضی از آنها اشاره شده است.

۳-۶-۲-۳ الگوریتم Gradient Descent (GD)

ایده اصلی الگوریتم GD استفاده از مشتق تابع هدف برای بروزرسانی متغیرهای تصمیم‌گیری بطوریکه مقدار تابع هدف کاهش بیابد، می‌باشد. برای مثال با فرض تابع حقیقی $r(x)$ و مشتق آن $r'(x)$ و ϵ عدد مثبت کوچک، بطوریکه $|r'(x)| > 0$ آنگاه $r(x - \epsilon \cdot \text{sign}(r'(x)))$ کمتر از $r(x)$ می‌باشد. به عبارت دیگر تغییر کوچک در متغیر x با استفاده از مشتق‌گیری موجب کاهش مقدار تابع هدف می‌گردد. متغیر x بصورت $\hat{x} = x - \epsilon \cdot \text{sign}(r'(x))$ بطور مکرر بروزرسانی می‌شود تا به مقدار کمینه تابع هدف و مقدار ورودی متناظر آن برسد. در یادگیری MLP، تابع هدف تابع اتلاف می‌باشد. متغیرها شامل ضرایب و بایاس در هر لایه می‌باشند. در الگوریتم GD هزینه محاسبه مشتق جزئی متناسب با تعداد نمونه‌ها (M) می‌باشد که در صورت بزرگ بودن مجموعه داده، بسیار پرهزینه می‌باشد. برای کاهش پیچیدگی، الگوریتم SGD^۲ بعنوان جایگزین برای الگوریتم GD مطرح شده است. در الگوریتم SGD به تعداد M' نمونه بصورت یکنواخت انتخاب شده است که معمولاً بسیار کوچکتر از M می‌باشد. اگرچه پیدا کردن کمینه مطلق در زمان مناسب گارانتی نشده است، مدل‌های ML با الگوریتم GD می‌توانند بخوبی کار کنند. مشکل الگوریتم SGD امکان قرارگیری آن در نقطه کمینه محلی می‌باشد. اما این الگوریتم می‌تواند با سرعت بسیار زیادی مقدار تابع اتلاف را برای کاربردهای عملی، به اندازه کافی کوچک سازد.

۳-۶-۲-۴ انتشار رو به جلو و روبه عقب^۳

¹ Gradient Descent

² Stochastic Gradient Descent

³ Forward and Backward Propagation

در هر مرحله از الگوریتم GD، برای محاسبه تابع اتلاف از انتشار روبه جلو استفاده شده است. درحالی که انتشار روبه عقب برای محاسبه مشتق‌های جزئی بکار می‌رود. با در نظر گرفتن الگوریتم SGD با پارامتر M' تابع اتلاف بصورت زیر نوشته می‌شود:

$$L_2(Y, \hat{Y}) = \frac{1}{M'} \sum_{m=1}^{M'} (y^{(m)} - \hat{y}^{(m)})^2$$

با شروع از لایه ورودی در فرایندهای انتشار روبه جلو، عملیات خطی و فعال سازی، لایه به لایه تا انتها انجام می‌شود. در آخر، خروجی MLP بعد از عملیات در لایه آخر توسط تابع اتلاف ایجاد می‌شود. ولی در انتشار عقب‌رو از لایه آخر شروع و پردازش لایه به لایه تا لایه اول انجام می‌شود. از قانون زنجیره‌ای نیز برای محاسبه مشتق جزئی در همه لایه‌ها استفاده می‌گردد.


۳-۶-۳- یکسان سازهای مبتنی بر شبکه‌های عصبی یادگیری عمیق (DNN)

هرچه MLP عمیق‌تر گردد، بدین معنی که تعداد لایه‌های نهانی آن زیاد گردد، توانایی آن برای فراگیری توابع پیچیده مانند تابع ضربه کانال متغییر با زمان بیشتر می‌گردد. در ادامه این بخش به عملکرد DL مبتنی بر MLP پرداخته می‌شود.


۳-۶-۳-۱ مدل سیستم و ساختار شبکه

با معرفی تعداد بیشتری لایه‌های نهان کاملاً بهم متصل، MLP به DNN تکامل یافت که ساختار آن در شکل ۳۶ نشان داده شده است. DNN می‌تواند برای انجام کارهای مختلفی فراگیری شود. برای مثال وقتی برای بازیابی سیگنال عبوری از کانال با اعوجاج استفاده می‌شود می‌تواند مشخصه‌های کانال را فراگیرد و تابع مورد استفاده در یکسان ساز را تقریب بزند و سیگنال دریافتی را به سیگنال دلخواه نزدیک کند.

ساختار یک سیستم مخابراتی تعمیم یافته با یکسان ساز کانال مبتنی بر DNN در شکل ۳۷ نشان داده شده است. در سمت فرستنده پیام کد شده و کلمه کد مدولاسیون مشخص باند پایه، مدوله شده‌اند. سپس سمبل مدوله شده از طریق کانال بی سیم فرستاده می‌شود؛ بطوریکه اعوجاج متفاوتی را ممکن است تجربه کند. در سمت گیرنده، یکسان ساز مبتنی بر DNN برای مقابله با اعوجاج کانال قبل از دمدولاسیون و دیکدینگ استفاده شده است. در شکل ۳۷، DNN قبل از پیاده سازی آنلاین مانند کاربردهای زمان واقعی، بصورت آفلاین فراگرفته شده است. توجه شود که در مرحله پیاده سازی آنلاین، این یکسان ساز می‌تواند سیگنال دلخواه را بدون داشتن تخمین دقیق کانال بازسازی کند.



شکل ۳۶. ساختار DNN.



شکل ۳۷. سیستم مدل برای یک یکسان‌ساز براساس DNN.

۲-۳-۶-۳-۲ فراگیری شبکه

یکسان‌سازی کانال مبتنی بر DNN در حالت هدایت‌شده، نیاز به فراگیری با استفاده از مقدار زیادی داده خروجی/ورودی دارد. فراگیری آنلاین برای یکسان‌ساز کانال مبتنی بر MLP‌های با سایز کوچک مناسب است، بطوریکه از پایلوت ارسالی برای تنظیم پارامترهای کانال استفاده می‌کند. اما در حالت کلی فراگیری آنلاین برای DNN‌ها مناسب نمی‌باشد، زیرا تعداد پارامترهای زیادی باید در DNN تعیین شوند. بنابراین نیاز به داده زیاد و زمان فراگیری زیادی برای روش مبتنی بر DNN نیاز است که می‌تواند در مجموع عملکرد یکسان‌سازی را تنزل دهد. در مجموع برای مقابله با ضررهای فراگیری آنلاین، DNNs بطور معمول بصورت آفلاین فراگیری می‌شود. بعد از فراگیری درست، DNN‌ها می‌توانند با بازدهی بالا و بدون نیاز به فراگیری آنلاین و زمانبر، سیگنال دریافتی را بازسازی کنند. یکی از مزایای فراگیری آفلاین در DNN‌ها این است که برخلاف تعداد زیادی از وظایف ML که تأمین مجموعه بزرگی از داده برای آن مشکل است، در صورت مشخص بودن مدل کانال و دیگر پارامترهای آن، داده موردنیاز برای فراگیری یکسان‌ساز DNN می‌تواند مستقیماً به کمک شبیه‌سازی تولید شود. بصورت جزئی، در هر مرحله یک پیام تصادفی (m) تولید و مطابق آن کدکننده، کد ورد c را از کتاب کد انتخاب می‌کند. سپس با استفاده از مدولاسیون دنباله سمبل s تولید می‌شود که از کانال مخابرات بی‌سیم که بصورت یک جعبه سیاه مدل می‌شود، عبور می‌کند. در سمت گیرنده، خروجی r از کانال مطابق با دنباله سمبل ارسالی آن با همدیگر یک برچسب هدایت‌کننده^۱ برای تشکیل یک نمونه فراگیری را می‌دهند. به این ترتیب نمونه‌های فراگیری توسط مدل‌سازی و شبیه‌سازی تولید می‌شوند و این مجموعه داده بزرگ می‌تواند برای فراگیری یکسان‌ساز DNN استفاده شود. همانگونه که در شکل ۳۷ نشان داده شده است، در مرحله فراگیری آفلاین، DNN برای کمینه‌سازی اختلاف بین سمبل ارسالی s و سمبل تخمین‌زده s' آموزش داده می‌شود. تابع اتلاف برای DNN بصورت زیر تعریف می‌گردد:


$$L_2(s, \hat{s}) = \frac{1}{M'} \sum_{m=1}^{M'} \|s^{(m)} - \hat{s}^{(m)}\|^2,$$

اصلی‌ترین نگرانی در بکارگیری فراگیری آفلاین این است که کانال استفاده شده برای تولید داده با کانال واقعی متفاوت می‌باشد. اگرچه نتایج شبیه‌سازی نشان می‌دهد که تغییرات کانال استفاده‌شده برای تولید داده معمولاً تأثیر اندکی بر تنزل عملکرد آشکارسازی داده دارد.


۲-۳-۶-۳-۳ یکسان‌ساز مبتنی بر CNN

¹ Supervising Label

CNN یک نوع شبکه عصبی برای پردازش داده با توپولوژی شبکه‌ای می‌باشد. CNN بجای استفاده از لایه‌های کامل به هم پیوسته مانند لایه‌ها در MLP، از لایه‌های کانولوشن^۱ استفاده می‌کند. همانگونه که در شکل ۳۸ و شکل ۳۹ نشان داده شده است، سه مرحله‌ی کانولوشن، آشکارسازی و pooling برای پیاده‌سازی عملیات کانولوشن بکار رفته است. یکسان‌ساز CNN از نقطه نظر جریان داده مشابه با یکسان‌ساز DNN می‌باشد و همچنین مجموعه داده مورد نیاز براساس مدل کانال و پارامترهای آن تولید می‌شوند. با مدل سیستم و تابع هدف یکسان، یکسان‌ساز CNN می‌تواند مانند یکسان‌ساز DNN فراگیری شود. مخصوصاً تابع اتلاف و SGD با انتشار جلو رو / عقب‌رو می‌تواند برای دستیابی به پارامترهای مناسب شبکه تنظیم گردند.



شکل ۳۸. یک لایه convolutional مرسوم.



شکل ۳۹. ساختار CNN.

۴-۳-۶-۳ یکسان‌ساز مبتنی بر RNN

شبکه‌های عصبی بازگشتی (RNN) شکل دیگری از شبکه عصبی می‌باشند که برای پردازش‌های یک‌بعدی داده، توانمند هستند. در RNN، خروجی کنونی یک گره پنهان نه تنها به ورودی کنونی مربوط است بلکه به خروجی قبلی خود نیز وابسته می‌باشد. به عبارت دیگر RNN دارای حافظه است و همین امر آن‌ها را برای مدل‌سازی فیلتر IIR^2 مناسب می‌گرداند. این ویژگی برای کارکرد RNN‌ها در یکسان‌سازی کانال مهم می‌باشد. شکل ۴۰ یک RNN با سه لایه پنهانی را نشان می‌دهد که در آن گره عصبی بصورت دایره نمایش داده شده‌اند. در این شکل در بخش راست آن نسخه تانشرده^۳ و در بخش چپ آن نسخه تانشرده^۴ گراف محاسباتی برای شبکه RNN می‌باشد. RNN می‌تواند مانند روش‌های یکسان‌سازهای مبتنی بر DNN و


¹ Convolutional

² Infinite Impulse Response

³ Unfolded

⁴ Folded

CNN همانطور که در بخش های قبلی توضیح داده شده است، فراگیری شود. بطور خلاصه، با کمک شبکه عصبی، یکسان‌سازها توانایی استخراج ویژگی‌های کانال‌های مخابراتی و کاهش ISI بطور هوشمند را دارند. ویژگی‌های RNN و CNN آن را برای طراحی یکسان‌ساز مناسب کرده است به همین دلیل از CNN و RNN بطور گسترده‌ای برای حذف ISI و دست یابی به مخابرات مطمئن استفاده می‌شود.




شکل ۴۰. ساختار یک RNN: گراف تا شده و تا نشده.

۴-۶-۳- عملکرد سیستم OFDM با استفاده از یکسان‌سازی مبتنی بر شبکه عصبی

در این بخش ما عملکرد یک سیستم OFDM را مورد بررسی قرار می‌دهیم که از تکنیک DL شامل CNN و DNN برای یکسان‌سازی کانال استفاده می‌کند. در ادامه سیستم مدل و ساختار شبکه برای این بررسی آورده شده است.

۴-۶-۴-۱ مدل سیستم و ساختار شبکه

شکل ۱۴ ساختار یک سیستم OFDM به همراه یکسان‌ساز شبکه عصبی را نمایش می‌دهد.




شکل ۴۱. سیستم مدل برای OFDM با یکسان‌ساز براساس DNN و CNN.

۳-۴-۴-۲ ساختار شبکه DNN و CNN

شکل ۱۵ ساختار خاصی از DNN برای سیستم OFDM نشان می‌دهد، که از ۶ لایه تشکیل شده است که ۴ لایه آن لایه نهانی می‌باشند و (ELU^1) نام دارند. ELU تابع فعال‌سازی^۲ در همه لایه‌ها بجز لایه آخر است و بصورت زیر تعریف می‌شود:


$$f(a, x) = f_{ELU}(a, x) = \begin{cases} a(e^x - 1) & x < 0 \\ x, & x \geq 0 \end{cases}$$

که در آن a ثابت می‌باشد. در لایه آخر همانطور که در شکل نشان داده شده است از تابع $\tanh$ برای نگاشت خروجی لایه آخر نهانی به بازه $[-1, 1]$ استفاده شده است.



شکل ۴۲. ساختار شبکه DNN برای سیستم OFDM.

یک سیستم OFDM به همراه یکسان‌ساز CNN در شکل ۱۶ که از یک CNN با ساختاری ۹ لایه بهره می‌برد را نشان می‌دهد. لایه کانولوشن یک‌بعدی در اولین لایه مخفی برای استخراج ویژگی‌های سمبل OFDM دریافتی استفاده می‌شود. برای بهبود عملکرد و پایداری CNN، نرمال‌سازی دسته‌ای در لایه‌های نهانی برای نرمالیزه کردن خروجی استفاده می‌شود. لایه flatten برای مسطح کردن ورودی و بدون تأثیر بر اندازه‌ی دسته (batch) استفاده شده است. سپس دو زیرسیستم تشکیل شده از لایه‌های کاملاً متصل به هم و تابع فعال‌سازی ELU و نرمالیزه کردن دسته قرار دارد و در انتها از تابع فعال‌سازی $\tanh$ در لایه آخر برای استخراج داده استفاده شده است.



شکل ۴۳. ساختار شبکه CNN برای سیستم OFDM.

۳-۴-۴-۳ فراگیری آفلاین و پیاده‌سازی آنلاین

برای دستیابی به شبکه عصبی مؤثر در یکسان‌سازی، دو مرحله نیاز است: فراگیری آفلاین و پیاده‌سازی آنلاین. در مرحله فراگیری آفلاین، داده موردنیاز برای فراگیری، با استفاده از شبیه‌سازی سیستم براساس مدل کانال بدست می‌آید. برای هر شبیه‌سازی یک دنباله داده تصادفی تولید و بعد از مدوله‌شدن در ترکیب با دنباله سمبل‌های پیلوت، بصورت فریم‌های OFDM گروه-بندی و سمبل ارسالی s را تشکیل می‌دهند. کانال استفاده شده در فراگیری مطابق با مدل کانال حاصل از اندازه‌گیری عملی

¹ Exponential Linear Unit

² Activation Function

می‌باشد. بعد از عبور از اعوجاج‌های کانال، سیگنال دریافتی r از بلوک پیلوت و بلوک داده یک فریم به‌همراه سمبل ارسالی s به عنوان ورودی و خروجی مورد انتظار در فراگیری استفاده می‌شود. همانگونه که قبلاً ذکر شد، NN با هدف کمینه‌سازی اختلاف بین سمبل خروجی NN با سمبل هدف، فراگیری می‌شود. تابع اتلاف در این سیستم بصورت زیر است:

$$L_2(\hat{s}, s) = \|\hat{s} - s\|_2$$

که در آن s سمبل ارسالی و $\hat{s}$ سمبل خروجی NN مطابق با سمبل ارسالی است.


۴-۴-۳ نتایج شبیه‌سازی و تحلیل

در این بخش نتایج مربوط به عملکرد BER برای سیستم OFDM با یکسان‌ساز مبتنی بر DNN یا CNN آورده شده است [۳۲]. عملکرد BER برای این یکسان‌سازها با روش‌های مرسوم LS و MMSE مقایسه شده‌اند. در اینجا سیستم OFDM با ۶۴ زیرحامل و ۶۴ پیلوت و ۱۶ CP فرض شده است. مدولاسیون 4-QAM و کانال ریلی تک‌مسیره با مؤلفه‌های حقیقی و موهومی هریک با میانگین صفر و واریانس ۰.۵ در نظر گرفته شده است. همچنین مدل‌های EPA¹ در نظر گرفته شده است [۳۱] که در آن تعداد مسیرها برابر با ۷ و بیشترین تأخیر ۹ برابر دوره نمونه‌برداری می‌باشد. علاوه بر آن سیستم ETU² با تعداد ۹ مسیر و بیشینه تأخیر ۱۶ برابر دوره نمونه‌برداری در نظر گرفته شده‌اند. در شکل ۴۴ نرخ خطای بیت برای سیستم OFDM براساس یکسان‌سازهای CNN و DNN با سیستم براساس یکسان‌سازهای مرسوم MMSE و LS و با فرض کانال ریلی تک‌مسیره، مقایسه شده‌اند. در این شکل نشان داده شده است که روش LS بدترین عملکرد را در میان ۴ یکسان‌ساز دیگر دارد و از اطلاعات آماری کانال که برای یکسان‌سازی کانال مفید می‌باشد، بهره‌برداری نمی‌کند. بر خلاف آن، روش MMSE بدلیل استفاده از اطلاعات آماری مرتبه دوم کانال عملکرد بهتری نسبت به LS دارد. می‌توان مشاهده نمود که هر دو یکسان‌ساز براساس DNN و CNN عملکرد بهتری نسبت به روش‌های MMSE و LS در SNRهای پایین و متوسط دارند. اگرچه در SNRهای بالا یکسان‌ساز MMSE عملکرد بهتری نسبت به یکسان‌سازهای DNN و CNN دارد. همچنین یکسان‌ساز CNN نرخ خطای بیت کمتری نسبت به یکسان‌ساز DNN دارد و این بدلیل بهره‌گیری از مشخصات CNN که اطلاعات حوزه زمان سیگنال و کانال بیشتری را استخراج می‌کند، حاصل گردیده است.


در شکل ۴۵ کانال انتخابگر فرکانسی در نظر گرفته شده است. همچنین در شکل ۴۶ عملکرد BER سیستم OFDM بر روی کانال مخابراتی با مدل EPA و ETU به ترتیب در نظر گرفته شده است. همانگونه که مشاهده می‌گردد یکسان‌ساز DNN و CNN نرخ خطای بیت بهتری نسبت به روش‌های MMSE و LS در محدوده SNR اصلی و در هر دو کانال‌های ETU و EPA دارد. در SNRهای پایین، نرخ خطای بیت برای یکسان‌ساز DNN کمی کمتر یا تقریباً برابر با یکسان‌ساز CNN می‌باشد. این درحالی است که در SNR بالا نرخ خطای بیت برای یکسان‌ساز CNN بهتر از DNN می‌باشد. مشاهدات نشان می‌دهند که یکسان‌ساز DNN برای مقابله با انتخابگر بودن فرکانسی کانال، مناسب هستند. همچنین یکسان‌ساز CNN معمولاً نسبت به یکسان‌ساز DNN سریع‌تر همگرا می‌شود.

¹ Extended Pedestrian A model


² Extended Typical Urban model



شکل ۴۴. نرخ خطای بیت سیستم OFDM با یکسان‌ساز DNN, CNN, LS, and MMSE وقتی در کانال رایلی تک مسیره مخابره می‌کند [۳۲]



شکل ۴۵. نرخ خطای بیت سیستم OFDM با یکسان‌ساز DNN, CNN, LS, and MMSE وقتی در کانال رایلی بی‌سیم EPA مخابره می‌کند [32]



شکل ۴۶. نرخ خطای بیت سیستم OFDM با یکسان‌ساز LS, DNN, CNN, and MMSE وقتی در کانال انتخابگر فرکانسی ETU مخابره می‌کند [۳۲]

۵-۶-۳- جمع‌بندی یادگیری ماشین در یکسان‌سازی کانال

در این بخش ساختار شبکه‌های عصبی و روش‌های فراگیری مختلف برای پاسخ دهی به مسائل یکسان‌سازی کانال مورد بررسی قرار گرفت و چندین الگوریتم برای این شبکه‌ها بیان شدند. همچنین دو یکسان‌ساز ML (یکسان‌ساز DNN و یکسان‌ساز CNN) ارائه شدند و عملکرد آن‌ها با دو یکسان‌ساز مرسوم: LS و MMSE مقایسه و مورد بررسی قرار گرفتند. بررسی‌ها نشان دادند که برخلاف روش‌های آشکارسازی و یکسان‌سازی مرسوم، در روش‌های یکسان‌ساز ML نیاز به محاسبه اطلاعات آماری کانال نمی‌باشد. همچنین نرخ خطای بیت سیستم OFDM با استفاده از یکسان‌ساز براساس ML معمولاً بهتر از نرخ سیستم با یکسان‌ساز براساس LS و MMSE مرسوم (مستقل از نوع کانال از نظر انتخابگر فرکانس) می‌باشد. این بدین معنی است که یکسان‌ساز ML توانایی بالایی در یادگیری و تحلیل ویژگی‌های پیچیده کانال بی‌سیم و مقابله با ISI دارد. یکسان‌ساز NN بدلیل عدم نیاز به اطلاعات قبلی برای ساختار و مشخصه‌های کانال بی‌سیم، کاندید مناسبی برای یکسان‌سازی در سیستم‌های مخابراتی بی‌سیم آینده با نرخ داده بالا است.

۷-۳- جمع‌بندی فصل ۳

در این فصل به کاربردهای روش‌های یادگیری ماشینی در لایه فیزیکی سیستم‌های ارتباطی پرداخته شد. در بخش اول مروری بر یادگیری ماشین و چالش‌های آن در لایه فیزیکی شبکه مخابراتی صورت گرفت. مسائل مختلف موجود در مخابرات بی‌سیم که از ابزارهای یادگیری ماشین در پاسخ‌گویی به آن بهره گرفته شده‌اند، ارائه گردیدند. بیشتر این مسائل در مواقعی رخ می‌دهند که مدل دقیقی از سیستم در دسترس نمی‌باشد و یا در صورت وجود مدل دقیق، بدست آوردن جواب بهینه بسیار پیچیده است. در این صورت روش‌های مرسوم مبتنی بر مدل پاسخگوی این مشکلات نمی‌باشند و روش‌های یادگیری ماشینی می‌توانند مؤثر باشند.

بخش دوم به ارتقاء عملکرد AMC با کمک روشهای ML اختصاص داده شد. AMC می‌تواند منجر به بازدهی طیفی بهتر و ایجاد توازن بین نرخ داده بالاتر و قابلیت اطمینان بیشتر شود. مکانیزم آن نیز بر اساس تنظیم مدولاسیون و نرخ کدگذاری بر حسب شرایط کانال در سیستم مخابراتی بی‌سیم می‌باشد. برای این امر سه روش ML-AMC ارائه شدند. دو روش از آنها مبتنی بر SL و سومی مبتنی بر RL می‌باشد. الگوریتم‌های k-NN و SVM برای نشان دادن کاربرد SL در AMC بکار رفتند. برای روش RL در AMC، نیز الگوریتم Q-learning انتخاب شده است. برای تأیید کاربرد و مؤثر بودن الگوریتم‌های فراگیری برای AMC، شبیه‌سازی با پارامترهای موجود در استاندارد IEEE 802.11n برای مقایسه ML-AMC با الگوریتم‌های مرسوم، انجام شده است. الگوریتم SL مناسب برای سناریویی که نمونه‌های فراگیری نمایانگر همه شرایطی که فرستنده ممکن است تجربه کند، است؛ درحالی‌که الگوریتم RL می‌تواند بطور مستقیم از تعامل با محیط فراگیری شود. این دو الگوریتم می‌توانند مطابق با فراگیری آفلاین و یا آنلاین و براساس درخواست کاربران در سناریوهای مختلف انتخاب شوند. AMC با استفاده از الگوریتم RL قادر به ایجاد ضریب اطمینان بالایی در سیستم‌های مخابرات بی‌سیم می‌باشد. تحقیقات آینده می‌تواند شامل ترکیب RL و SL باشد، بطوریکه سیستم ML-AMC را بهبود بخشد و توازن بین پیچیدگی و عملکرد سیستم با هدف تأمین سرویس دهی بهتر کاربران ایجاد نماید.

در بخش سوم ساختار شبکه‌های عصبی و روش‌های فراگیری مختلف برای یکسان‌سازی کانال مورد بررسی قرار گرفت و الگوریتم‌های مرتبط با آن بیان شدند. یکسان‌سازهای مبتنی بر DNN و CNN ارائه شدند و عملکرد آنها با دو یکسان‌ساز مرسوم LS و MMSE مقایسه قرار گرفتند. نتایج شبیه‌سازی نشان دادند که نرخ خطای بیت سیستم OFDM با استفاده از یکسان‌ساز ML معمولاً بهتر از عملکرد آن با یکسان‌سازهای مرسوم مانند LS و MMSE (و مستقل از نوع کانال از نظر انتخاب‌گر بودن فرکانس) می‌باشد و توانایی بالایی در یادگیری و تحلیل ویژگی‌های پیچیده کانال بی‌سیم و مقابله با ISI دارد. بدین ترتیب یکسان‌ساز مبتنی بر NN بدلیل عدم نیاز به اطلاعات قبلی برای ساختار و مشخصه‌های کانال بی‌سیم، کاندید مناسبی برای یکسان‌ساز در سیستم‌های مخابراتی بی‌سیم آینده با نرخ داده بالا است.

مراجع فصل ۳

- [1] A. Zappone, M. Di Renzo and M. Debbah, "Wireless Networks Design in the Era of Deep Learning: Model-Based, AI-Based, or Both?," in IEEE Transactions on Communications, vol. 67, no. 10, pp. 7331-7376, Oct. 2019, doi: 10.1109/TCOMM.2019.2924010.
- [2] Gündüz, Deniz, et al. "Machine learning in the air." IEEE Journal on Selected Areas in Communications 37.10 (2019): 2184-2199.
- [3] N. Farsad and A. Goldsmith, "Neural network detection of data sequences in communication systems," IEEE Trans. Signal Process., vol. 66, no. 21, pp. 5663–5678, Nov. 2018.
- [4] N. Samuel, T. Diskin, and A. Wiesel, "Deep MIMO detection," 2017, arXiv:1706.01151. [Online]. Available: <https://arxiv.org/pdf/1706.01151.pdf>
- [5] H. Ye, G. Y. Li, and B.-H. Juang, "Power of deep learning for channel estimation and signal detection in OFDM systems," IEEE Wireless Commun. Lett., vol. 7, no. 1, pp. 114–117, Feb. 2018.
- [6] E. Nachmani Y. Be'ery, and D. Burshtein, "Learning to decode linear codes using deep learning," in Proc. Allerton Conf. Commun., Control, Comput. (Allerton), 2016, pp. 341–346.
- [7] S. Cammerer, T. Gruber, J. Hoydis, and S. ten Brink, "Scaling deep learning-based decoding of polar codes via partitioning," 2017. arXiv: 1702.06901. [Online]. Available: <https://arxiv.org/abs/1702.06901>.
- [8] T. Gruber, S. Cammerer, J. Hoydis, and S. ten Brink, "On deep learning-based channel decoding," in Proc. Conf. Inf. Sci. Syst. (CISS), 2017, pp. 1–6.
- [9] D. Neumann, T. Wiese, and W. Utschick, "Learning the MMSE channel estimator," IEEE Trans. Signal Process., vol. 66, no. 11, pp. 2905–2917, Jan. 2018.
- [10] M. Soltani, V. Pourahmadi, A. Mirzaei, and H. Sheikhzadeh, "Deep learning-based channel estimation," IEEE Commun. Lett., vol. 23, no. 4, pp. 652–655, Apr. 2019.
- [11] T. Wang, C.-K. Wen, S. Jin, and G. Y. Li, "Deep learning-based CSI feedback approach for time-varying massive MIMO channels," IEEE Wireless Commun. Lett., vol. 8, no. 2, pp. 416–419, Apr. 2019.
- [12] Z. Liu, L. Zhang, and Z. Ding, "Exploiting bi-directional channel reciprocity in deep learning for low rate massive MIMO CSI feedback," IEEE Wireless Commun. Lett., vol. 8, no. 3, pp. 889–892, Jun. 2019.
- [13] J. Ballé, V. Laparra, and E. P. Simoncelli, "End-to-end optimized image compression," in Proc. Int. Conf. Learn. Represent. (ICLR), Apr. 2017, pp. 1–27.

- [14] G. Toderici et al., "Variable rate image compression with recurrent neural networks," in Proc. Int. Conf. Learn. Represent. (ICLR), 2016.
- [15] Q. Yang, M. B. Mashhadi, and D. Gündüz, "Deep convolutional compression for massive MIMO CSI feedback," in Proc. IEEE Int. Workshop Mach. Learn. Signal Process. (MLSP), 2019.
- [16] C. Jiang, H. Zhang, Y. Ren, Z. Han, K. Chen, and L. Hanzo. Machine learning paradigms for next-generation wireless networks. IEEE Wireless Communications, 24(2):98–105, April 2017.
- [17] J. P. Leite, P. H. P. deCarvalho, and R. D. Vieira. A flexible frame work based on reinforcement learning for adaptive modulation and coding in OFDM wireless systems. In 2012 IEEE Wireless Communications and Networking Conference (WCNC), pages 809–814, April 2012.
- [18] R. C. Daniels, C. Caramanis, and R. W. Heath Jr. A supervised learning approach to adaptation in practical MIMO-OFDM wireless systems. In IEEE GLOBE COM 2008-2008 IEEE Global Telecommunications Conference, pages 1–5, Nov 2008.
- [19] R. Daniels and R. W. Heath. Online adaptive modulation and coding with support vector machines. In 2010 European Wireless Conference (EW), pages 718–724, April 2010.
- [20] G. J. Gibson, S. Siu, and C. F. N. Cowan. Application of multi layer perceptrons as adaptive channel equalisers. In Adaptive Systems in Control and Signal Processing, pages 573–578, 1989.
- [21] C. You and D. Hong. Nonlinear blind equalization schemes using complex valued multilayer feed forward neural networks. IEEE Transactions on Neural Networks, 9(6):1442–1455, 1998.
- [22] D. R. Guha and S. K. Patra. ISI and burst noise interference minimization using wilcoxon generalized radial basis function equalizer. In 2009 Fifth International Conference on MEMS NANO, and Smart Systems, pages 89–92, 2009.
- [23] J. C. Patra, W. C. Chin, P. K. Meher, and G. Chakraborty. Legendre-FLANN based non linear channel equalization in wireless communication system. In IEEE International Conference on Systems, Man and Cybernetics, pages 1826–1831, 2008.
- [24] G. Kechriotis, E. Zervas, and E. S. Manolakos. Using recurrent neural networks for adaptive communication channel equalization. IEEE Transactions on Neural Networks, 5(2):267–278, 1994.
- [25] Y. Li, M. Chen, Y. Yang, M. Zhou, and C. Wang. Convolutional recurrent neural network based channel equalization: An experimental study. In 2017 23rd Asia Pacific Conference on Communications (APCC), pages 1–6, 2017.
- [26] H. Ye and G. Y. Li. Initial results on deep learning for joint channel equalization and decoding. In 2017 IEEE 86th Vehicular Technology Conference (VTC-Fall), pages 1–5, 2017.

- [27] H. Ye, G. Y. Li, and B. Juang. Power of deep learning for channel estimation and signal detection in OFDM systems. *IEEE Wireless Communications Letters*, 7(1):114–117, 2018.
- [28] R. Yang, L. Yang, J. Zhang, C. Sun, W. Cong, and S. Zhu. Blind equalization of QAM signals via extreme learning machine. In 2018 Tenth International Conference on Advanced Computational Intelligence (ICACI), pages 34–39, 2018.
- [29] D. J. Sebald and J. A. Bucklew. Support vector machine techniques for non linear equalization. *IEEE Transactions on Signal Processing*, 48(11): 3217–3226, 2000.
- [30] P. M. Olmos, J. J. Murillo-Fuentes, and F. Perez-Cruz. Joint nonlinear channel equalization and soft LDPC decoding with Gaussian processes. *IEEE Transactions on Signal Processing*, 58(3): 1183–1192, 2010.
- [31] 3GPP. Evolved Universal Terrestrial Radio Access (EUTRA); Base Station (BS) radio transmission and reception. Technical Specification (TS) 36.104, 3rd Generation Partnership Project (3GPP), 032017. URL www.3gpp.org. Version 14.3.0.
- [32] FA-LONG Luo, "Machine Learning for future wireless communications", IEEE Press, Wiley, 2020

فصل ۴

بررسی کاربردهای هوش مصنوعی در استفاده از طیف فرکانسی و رادیو شناختی

۱-۴- مقدمه

یک ویژگی اصلی در هر وسیله رادیوشناختی قابلیت خود برنامه‌ریزی یا یادگیری خودکار می‌باشد. [۱] ادوات رادیوشناختی را وسایل بی‌سیم با قدرت تحلیل پیش‌بینی می‌کند که به طور خاص برای استفاده بهینه از پهنای باند الکترومغناطیسی و ارتباطات قابل اطمینان به کار می‌روند. برای انجام وظایف، یک رادیو شناختگر باید از محیط فرکانس رادیویی (RF) خود آگاه باشد به گونه‌ای که محیط اطراف خود را حس کرده و همه فعالیت‌های RF را شناسایی کند. روش‌های زیادی برای حس کردن پهنای باند در دهه اخیر ارائه شده‌اند که مبتنی بر فیلتر تطبیق شده، آشکارسازی انرژی، آشکارسازی ایستایی چرخشی^۱، آشکارسازی موجک^۲ و آشکارسازی کواریانس^۳ هستند. علاوه بر این روش‌ها، روش‌های مشارکتی^۴ نیز وجود دارند [۲].


علاوه بر آگاهی از محیط اطراف، برای رادیو شناختی بودن باید یک رادیو شناختگر به قابلیت یادگیری و استدلال نیز مجهز باشد. این قابلیت‌ها در یک موتور شناختی که هسته یک رادیوشناختگر می‌باشد، تعبیه شده است. این موتور وظیفه هدایت فعالیت‌های رادیو شناختگر با استفاده از الگوریتم‌های یادگیری ماشین را به عهده دارد.

به طور کلی زمانی یادگیری ضروری است که اثرات دقیق ورودی‌ها بر روی خروجی‌های یک سیستم مفروض، شناخته شده نباشند [۳]. برای مثال در مخابرات بی‌سیم، کانال‌های بی‌سیم ایده‌آل نیستند و ممکن است عدم قطعیت داشته باشند. اگر کاهش احتمال رخداد خطا در لینک مخابراتی با استفاده از کاهش نرخ کدگذاری^۵ مدنظر باشد، روش‌های یادگیری ماشین می‌توانند برای تخمین مشخصات کانال بی‌سیم مورد استفاده قرار گیرند. در این صورت نرخ کدگذاری خاصی برای رسیدن به احتمال خطای مشخصی تعیین می‌شود. البته این مساله ساده‌ای است و در شبکه‌های رادیوشناختی با افزایش درجات آزادی به دلیل معرفی رادیو نرم‌افزاری، مساله بسیار پیچیده‌تر خواهد شد. در این حالت چندین پارامتر و راهبرد از جمله توان ارسالی، نوع کدگذاری، نوع مدولاسیون، الگوریتم حس کردن، پروتکل ارتباطی، راهبرد حس کردن و غیره باید به صورت همزمان تنظیم شوند. حتی این مساله با وجود شبکه‌های رادیو شناختی ناهمگون نیز پیچیده‌تر می‌شود، زیرا در این صورت یک رادیو شناختگر نه تنها باید خود را با محیط اطراف تطبیق دهد بلکه باید فعالیت‌هایش را با دیگر رادیوهای موجود در شبکه نیز مدیریت کند.

یک رادیو شناختگر به عنوان یک وسیله هوشمند بی‌سیم تعریف می‌شود. هوشمندی دارای سه شرط است: (۱) ادراک^۶ (۲) یادگیری (۳) استدلال^۷ [۴]. ادراک، قابلیت حس کردن محیط و مراحل داخلی برای جمع‌آوری اطلاعات است. یادگیری، قابلیت تبدیل اطلاعات جمع‌آوری شده به دانش با استفاده از روش‌های دسته‌بندی و تعمیم نظریه‌ها است. در مرحله استدلال نیز این دانش برای رسیدن به اهداف خاصی مورد استفاده قرار می‌گیرد. درمورد ادوات رادیوشناختی، ادراک از طریق اندازه‌گیری‌هایی که از طیف فرکانسی صورت می‌گیرد، بدست می‌آید. پس از جمع‌آوری مشاهدات حسی از محیط اطراف، رادیو شناختگر با دسته‌بندی و قرار دادن مشاهدات در گروه‌های مناسب، دانش را بدست آورده و یاد می‌گیرد. در انتها نیز سعی می‌کند از دانش بدست آمده برای رسیدن به اهدافش استفاده نماید. این مشخصات ابتدا توسط Mitola به عنوان چرخه شناخت^۸ تعریف شد [۵]. یک نمونه

Cyclostationary detection^۱Wavelet detection^۲Covariance detection^۳Cooperative methods^۴Coding^۵Perception^۶Reasoning^۷Cognition Cycle^۸

از چرخه شناخت برای CRهای خودکار که به آنها رادیوبات^۱ گفته می‌شود در شکل ۴۷ نشان داده شده است [۶]. همان‌طور که ملاحظه می‌شود آن‌ها می‌توانند با مشاهده نتایج عملکرد خود روی خروجی از عملکرد قبلی خود یاد بگیرند. خروجی یادگیری می‌تواند برای بروزرسانی حس کردن (مشاهدات) و راهبرد دسترسی کانال (تصمیم) در کاربردهای دسترسی پویا به طیف (DSA^۲) مورد استفاده قرار گیرد.



شکل ۴۷. چرخه شناخت برای یک رادیوبات [۶]

در ادامه ابتدا به چالش‌هایی که در مسائل رادیو شناختی وجود دارد اشاره شده و یک دسته‌بندی از مسائل یادگیری ماشین در حوزه CR ارائه شده است. همچنین روش‌های مختلف هوش مصنوعی که در حوزه CR می‌توانند مورد استفاده قرار گیرند به همراه مثالی از کاربرد آن‌ها معرفی شده و مزایا و معایب این روش‌ها با یکدیگر مقایسه شده‌اند. به نظر می‌رسد به دلیل نیاز به تصمیم‌گیری و همچنین پویا بودن و عدم قطعیت موجود در دسترسی به طیف در شبکه‌های رادیو شناختی روش‌های مبتنی بر یادگیری تقویتی برای حل این مسائل مناسب‌تر هستند. همچنین به دلیل گستردگی این شبکه‌ها و زیاد شدن وضعیت‌های مساله، ترکیبی از یادگیری تقویتی و یادگیری عمیق به نام DQL معرفی شده که زمان رسیدن به راهبرد بهینه را در این مسائل کاهش می‌دهد و در عین حال دقت مناسبی نیز دارد. از میان مسائلی که در شبکه‌های مخابراتی وجود دارد، دسترسی پویا به پهنای باند در شبکه‌های رادیو شناختی از اهمیت بیشتری برخوردار می‌باشد که به طور مفصلی به آن پرداخته خواهد شد. همچنین به مسائل دیگری چون همکاری با کاربر متصل شده به شبکه و کنترل نرخ داده نیز اشاره مختصری می‌شود.

۴-۲- چالش‌های یادگیری ماشین در رادیو شناختی

برخی از چالش‌ها که مختص کاربردهای رادیو شناختی هستند به دلیل طبیعت رادیو شناختگرها و محیط عملکرد آن‌هاست. اولاً، به دلیل مشاهدات دارای نویز و خطاهای عملیات حس کردن، رادیو شناختگرها تنها می‌توانند مشاهدات جزئی از متغیرهای حالتشان را داشته باشند و مساله یادگیری به یک فرآیند یادگیری در یک محیط مشاهدات جزئی تبدیل می‌شود. ثانیاً، رادیو شناختگرها در شبکه‌های رادیو شناختی سعی می‌کنند به طور همزمان یاد بگیرند و رفتارشان را بهینه کنند. در نتیجه مساله به طور ذاتی، یک فرآیند یادگیری چند کاربره^۳ است. همچنین ممکن است که فرآیند یادگیری به صورت مشارکتی یا غیر مشارکتی باشد یا هر رادیو شناختگر به صورت کامل یا جزئی از فعالیت دیگر کاربران رادیو شناختی در شبکه اطلاع داشته باشد. در

^۱ Radiobot


^۲ Dynamic Spectrum Access
Multi-agent^۳

صورت مشاهدات جزئی، رادیوشناختگر ممکن است از الگوریتم‌های یادگیری خاصی برای تخمین عملکرد دیگر گره‌ها در شبکه قبل از انتخاب اقدام مناسب استفاده کند.

ثالثاً، روش‌های یادگیری خودکاری برای قادر ساختن رادیوشناختگرها به یادگیری بر اساس رفتار خود در یک محیط ناشناخته RF مورد نیاز است. بر خلاف کاربران بی‌سیم دارای مجوز، از یک رادیوشناختگر واقعی انتظار می‌رود در هر باند فرکانسی، در هر زمان و در هر مکانی قابلیت فعالیت داشته باشد [۶]. در نتیجه ممکن است یک رادیوشناختگر هیچ دانشی از محیط عملکردی RF مانند سطوح نویز یا اختلال، توزیع نویز و ترافیک کاربران نداشته باشد. به جای آن باید از الگوریتم‌های یادگیری خودکاری استفاده کند که طبیعت محیط و اجزای آن را نشان دهد.

۳-۴- انواع نمونه‌های یادگیری ماشین

همان‌طور که در شکل ۴۸ نشان داده شده است به طور کلی می‌توان روش‌های یادگیری ماشین را به دو دسته هدایت‌شده^۱ و غیرهدایت‌شده^۲ تقسیم‌بندی نمود. یادگیری غیر هدایت شده به خصوص برای رادیو شناختگرهایی که در محیط‌های RF ناشناخته فعالیت می‌کنند مناسب است. در این حالت الگوریتم‌های یادگیری غیرهدایت شده خودکار اجازه جستجوی مشخصات محیط و عملکرد خود تطبیقی را بدون داشتن اطلاعات قبلی می‌دهند. با این حال اگر رادیو شناختگر اطلاعاتی در مورد محیط داشته باشد می‌تواند از این دانش توسط روش‌های یادگیری هدایت شده استفاده کند. برای مثال اگر مشخصات یک شکل موج سیگنال مشخص برای رادیوشناختگر قبل از عملیاتش شناخته شده باشد، الگوریتم‌های یادگیری می‌توانند به آشکارسازی سیگنال‌هایی با آن مشخصات کمک کنند.



شکل ۴۸. روش‌های عمومی یادگیری ماشین [۷]


^۱Supervised

^۲Unsupervised

در [۸] یادگیری هدایت‌شده و غیرهدایت‌شده به ترتیب با عناوین یادگیری با هدایت^۱ و تقویت^۲ شناخته می‌شوند. نوع سوم نیز یادگیری تقلیدی^۳ نام دارد که در آن هر کاربر از مشاهده عملکرد کاربران مشابه یاد می‌گیرد. همچنین نشان داده شده است که عملکرد یک یادگیرنده توسط روش یادگیری و محیط عملکردی تحت تأثیر قرار می‌گیرد. در نتیجه برای یادگیری بهینه باید رادپوشناختگر مساله یادگیری را با بهترین روش یادگیری منطبق کند. در نتیجه یک معماری رادپوشناختی مؤثر باید توانایی سوئیچ کردن بین روش‌های مختلف یادگیری را متناسب با نیازها، اطلاعات در دسترس و مشخصات محیط داشته باشد.

۴-۴- انواع مسائل یادگیری در رادپوشناختی

در شکل ۴۹ انواع روش‌های یادگیری که برای اهداف مختلفی در رادپوشناختی مورد استفاده قرار می‌گیرند در یک نمودار درختی دسته‌بندی شده‌اند. به‌طور کلی می‌توان مسائل یادگیری در رادپوشناختی را به دو دسته کلی مسائل تصمیم‌گیری^۴ و دسته-بندی^۵ تقسیم نمود. مسائل دسته‌بندی معمولاً برای حس کردن طیف فرکانسی و مسائل تصمیم‌گیری برای تعیین راهبرد حس طیف فرکانسی، کنترل توان یا مدولاسیون بهینه مورد استفاده قرار می‌گیرند.



شکل ۴۹. انواع مسائل یادگیری و الگوریتم‌های یادگیری متناظر در رادپوشناختی [۷]

روش‌های دسته‌بندی خود به دو دسته هدایت‌شده و غیرهدایت‌شده تقسیم می‌شوند. دو نمونه از الگوریتم‌های معروف هدایت‌شده ANN^۶ و SVM^۷ هستند. الگوریتم ANN بر اساس به حداقل رساندن ریسک تجربی است و برای این کار نیاز به اطلاعات

^۱ Instruction

^۲ Reinforcement

^۳ Imitation

^۴ Decision-making

^۵ Feature classification

^۶ Artifical Neural Network

^۷ Support Vector Machin

قبلی از توزیع فرآیند مشاهده شده دارد. با این حال SVM براساس حداقل ریسک ساختاری است و عملکرد بهتری برای نمونه‌های یادگیری کوچک دارد که از مشکل overfitting جلوگیری می‌نماید.

برای مثال اگر مجموعه‌ای از داده‌های یادگیری را به صورت $\{(x_1, y_1), \dots, (x_N, y_N)\}$ در نظر گرفته شود که $x_i \in X$ و $y_i \in Y$ باشد، هدف الگوریتم یادگیری هدایت‌شده ANN یافتن تابع $g: X \rightarrow Y$ می‌باشد به گونه‌ای که تابع ریسک تجربی $R(g)$ به حداقل برسد. این تابع به صورت زیر تعریف می‌شود:

$$R(g) = R_{emp}(g) = \frac{1}{N} \sum_{i=1}^N L(y_i, g(x_i))$$

در حقیقت الگوریتم ANN تابع g را به گونه‌ای پیدا می‌کند که به بهترین حالت به داده‌ها منطبق شود. حال اگر فضای این تابع و مجموعه داده‌های یادگیری خیلی بزرگ یا خیلی کوچک باشد تابع $R(g)$ دارای اختلاف زیادی با داده‌ها خواهد بود که به این مساله overfitting گفته می‌شود. برای حل این مشکل حداقل ریسک ساختاری استفاده می‌شود که یک ترم تنظیم‌کننده نیز به فرآیند بهینه‌سازی اضافه می‌کند. در این صورت تابع ریسک به صورت $R(g) = R_{emp}(g) + \lambda C(g)$ خواهد بود که در آن λ ضریبی است که واریانس و جابجایی را کنترل می‌کند و $C(g)$ تابع جریمه است [۹].

در مقابل روش‌های هدایت‌شده، روش‌های غیرهدایت‌شده به داده‌های نشان‌دار نیازی ندارند و به دو دسته پارامتری و غیرپارامتری تقسیم می‌شوند. دسته‌بندی‌کننده‌های غیرهدایت‌شده پارامتری شامل K-means و GMM^۱ هستند که نیاز به اطلاعات قبلی از تعداد دسته‌ها یا خوشه‌ها دارند. روش‌های غیرپارامتری نیازی به اطلاع از تعداد دسته‌ها ندارند و می‌توانند این تعداد را خودشان از روی داده مشاهده‌شده تخمین بزنند که برای مثال می‌توان به روش DPMM^۲ اشاره نمود.

یکی دیگر از وظایف اصلی که به طور گسترده در کاربردهای رادیوشناختی مورد بررسی قرار گرفته است، انجام تصمیم‌گیری است. مسائل تصمیم‌گیری خود می‌توانند به دو دسته سیاست‌گذاری^۳ و قوانین تصمیم‌گیری^۴ تقسیم شوند. مسائل سیاست‌گذاری را می‌توان در دو گروه متمرکز و غیرمتمرکز دسته‌بندی نمود. در مسائل سیاست‌گذاری یک مسئول یک مجموعه‌ای عملیاتی را در مدت زمان مشخصی تعیین می‌کند و در حقیقت سیاست بهینه را تعریف می‌کند. در یک سناریوی متمرکز با حالت مارکوف^۵، الگوریتم‌های یادگیری تقویتی^۶ (RL) می‌توانند برای راه‌حل بهینه بدون اطلاعات قبلی از احتمالات انتقال به کار روند. در محیط‌های غیرمارکوف، تصمیم بهینه بر اساس الگوریتم جستجوی سیاست تدریجی می‌تواند حاصل شود. از طرف دیگر برای سناریوهای چندکاربره، تئوری بازی پیشنهاد می‌شود که ذات توزیع شده محیط و روابط بین کاربران را در برمی‌گیرد. با فرض حالت مارکوف، سیستم می‌تواند به صورت یک بازی مارکوف (یا یک بازی تصادفی^۷) مدل شود. در نهایت، قوانین تصمیم‌گیری دسته‌ای دیگر را شکل می‌دهند که در آن‌ها مسائل تست نظریه‌ها برای مدل‌های مشاهده‌ی مشخصی می‌تواند فرمول‌بندی شود. در هنگام وجود عدم قطعیت در مورد مدل مورد مشاهده، روش‌های یادگیری برای پیاده‌سازی یک قانون تصمیم‌گیری می‌توانند به کار روند.

^۱Gaussian mixture model

^۲Diraclet process mixture model

^۳Policy-making

^۴Decision rules

^۵Markov state

^۶Reinforcement learning

^۷Stochastic game

۴-۵- مروری بر روش‌های هوش مصنوعی مورد استفاده در رادیوشناختی

در این بخش ابتدا مروری بر روش‌های متداول هوش مصنوعی و با تأکید بر روش‌های یادگیری و به همراه ارائه نمونه‌هایی از کاربردهای آن‌ها در رادیوشناختی صورت می‌گیرد. سپس معایب و مزایای این روش‌ها مورد مقایسه قرار می‌گیرند.

۴-۵-۱- منطق فازی

منطق فازی در دهه ۶۰ میلادی برای حل و مدل کردن عدم قطعیت، عدم دقت و موارد گنگ و نامفهوم با استفاده از مدل‌های ریاضی و تجربی ارائه شد. متغیرها در منطق فازی به دو مقدار درست یا نادرست محدود نیستند. یک المان فازی دارای یک درجه از عضویت یا سازگاری با تأیید یا نفی آن است. منطق فازی می‌تواند: (۱) با گرفتن تعدادی متغیر فازی به عنوان ورودی و ایجاد یک تصمیم با استفاده از قوانین اگر-آنگاه، به استدلال تقریبی در سیستم کمک کند. (۲) قادر به تصمیم‌سازی در شرایط عدم قطعیت با پیش‌بینی تبعات آن است. (۳) از تجربیات قدیمی یاد بگیرد و (۴) از تعمیم آن برای تطبیق با شرایط جدید استفاده کند. به طور عمومی، ورودی سیستم‌های استنباط فازی (FIS) ^۱ نیاز است تا به سطوح یا درجه‌هایی مانند کم، متوسط و زیاد دسته‌بندی شوند. این سیستم‌ها با استفاده از قوانین شرطی، خروجی سیستم را تعیین می‌کنند [۱۰].

در [۱۱] از منطق فازی برای تعیین روش مناسب برای آشکارسازی پهنای باند در دسترس استفاده شده است. چهار پارامتر ورودی برای انتخاب روش حس پهنای باند در نظر گرفته شده است که عبارتند از: (۱) احتمال مورد نیاز برای آشکارسازی (۲) سیگنال به نویز عملی (۳) زمان در دسترس برای انجام آشکارسازی (۴) اطلاعات قبلی. همچنین خروجی‌ها عبارتند از: (۱) آشکارسازی انرژی (۲) آشکارسازی همسانی (۳) آشکارسازی مشخصات (۴) فیلتر تطبیق شده (۵) آشکارسازی انرژی مشارکتی. ابتدا ورودی‌ها با استفاده از توابع عضویتی مثل کم، متوسط و زیاد از مقادیر قابل اندازه‌گیری به متغیرهای زبان فازی تبدیل می‌شوند. سپس طبق قوانین شرطی مقادیر فازی پارامترهای ورودی روشی را برای آشکارسازی طیف فرکانسی در دسترس تعیین می‌کنند.

۴-۵-۲- الگوریتم ژنتیک (GA)^۲

الگوریتم ژنتیک از کار فریدبرگ^۳ در سال ۱۹۵۸ نشأت گرفته که سعی داشت یادگیری را با جهشی در برنامه‌های کوچک فورترن^۴ ایجاد کند. در نتیجه با یک سری جهش‌های کوچک مناسب در برنامه کدهای یک ماشین، یک فرد می‌تواند برنامه‌ای تولید کند که عملکرد مناسبی برای هر وظیفه خاص ساده داشته باشد. الگوریتم‌های ژنتیک به صورت ساده فضا را برای پیدا کردن یک المان یا راه‌حل هدف جستجو می‌کنند تا تابع شایستگی به حداکثر مقدار خود برسد. این کار با تغییر تعدادی از راه‌حل‌ها یا کروموزوم‌ها به سمت راه‌حل‌های بهتر صورت می‌گیرد. کروموزوم‌ها به صورت یک رشته از اعداد باینری در نظر گرفته می‌شوند. این رشته هنگامی که سیستم پارامترهای بیشتری را استفاده می‌نماید رشد می‌کند. جستجو به جای پردازش بر روی یک راه‌حل به صورت موازی انجام می‌شود زیرا هر المان می‌تواند به صورت یک جستجوی مجزا دیده شود. یک موتور بر مبنای الگوریتم ژنتیک می‌تواند پردازش هوشمند، تصمیم‌سازی و یادگیری را در رادیو شناختگرها فراهم نماید.

^۱Fuzzy Inference System

^۲Genetic Algorithm

^۳Friedberg

^۴FORTAN

در [۱۲] الگوریتم‌های ژنتیکی برای بهبود عملکرد سیستم برای حل مسائل چند هدفه به کار رفته است که هدف آن حداقل نمودن نرخ بیت و توان و حداکثر نمودن نرخ انتقال است. برخی از متغیرهای عملکردی شامل فرکانس، توان انتقالی، نوع مدولاسیون به صورت کروموزوم کد شده‌اند. نتایج نشان می‌دهد که اطلاعات مربوط به دوره‌های قبلی رادیوشناختی از محیط می‌تواند به کاهش زمان همگرایی روش GA کمک کند.

۳-۵-۴- شبکه عصبی مصنوعی (ANN)^۱

شبکه عصبی مصنوعی اطلاعات را از نرون‌های مجاور دریافت می‌کند و خروجی را متناسب با وزن‌ها و توابع فعال‌سازی تولید می‌کند. وزن‌های تطبیقی می‌تواند قدرت ارتباط بین نرون‌ها را نشان دهد. برای تکمیل فرآیند یادگیری نیاز است تا وزن‌های تطبیقی به گونه‌ای تنظیم شود که خروجی شبکه شبیه خروجی مطلوب باشد. شبکه‌های عصبی در رادیوشناختی برای یادگیری از محیط و اتخاذ تصمیم به منظور بهبود کیفیت خدمات سیستم‌های مخابراتی مورد استفاده قرار گرفته‌اند.

در [۱۳] یک مرور کلی بر روش‌های اصلی حس کردن طیف فرکانسی انجام شده و یک روش آشکارسازی دسته‌بندی مدولاسیون خودکار نیز ارائه شده است. ایده اصلی بر پایه این واقعیت است که کاربر ثانویه اطلاعات قبلی از نوع سیگنال کاربر اولیه ندارد و فرض نشده که بتواند گره‌های پنهان را تشخیص دهد. در نتیجه یک دسته‌بندی‌کننده دیجیتال مبتنی بر ANN ایجاد شده که به کاربر اجازه می‌دهد همه اشکال سیگنال‌های رادیویی کاربر اولیه را اعم از ضعیف، قوی، شناخته شده و ناشناخته را آشکار نماید.

۴-۵-۴- تئوری بازی‌ها

اولین بحث در مورد تئوری بازی‌ها در مقاله نوشته شده توسط جیمز والدگریو^۲ در سال ۱۷۱۳ بوجود آمد. تئوری بازی به عنوان یک روش تصمیم‌گیری مورد استفاده قرار می‌گیرد که چندین بازیگر باید انتخاب‌هایی را داشته باشند و به تبع آن نظر بقیه بازیگران را تغییر می‌دهند. هر بازیگر با توجه به اعمال قبلیش که بر مبنای اعمال انتخاب شده توسط دیگر بازیگران در مراحل قبلی بازی بود، تصمیم می‌گیرد. در رادیوشناختی، شبکه‌های رادیوشناختی بازیگران بازی هستند. اعمال بازی، تنظیم پارامترهای RF مانند توان ارسالی و انتخاب کانال است. این کارها توسط شبکه رادیوشناختی بر پایه مشاهدات بدست آمده از محیط مانند در دسترس بودن کانال، کیفیت کانال و تداخل اتخاذ می‌شوند. در نتیجه هر شبکه رادیوشناختی از اعمال گذشته‌اش یاد می‌گیرد، اعمال اتخاذ شده توسط دیگر شبکه‌های رادیوشناختی را مشاهده می‌کند و متناسب با آن اعمالش را ارتقاء می‌بخشد [۱۴، ۱۵].

در [۱۶] مدل‌سازی تخصیص منابع به شبکه‌های رادیو شناختی adhoc با استفاده از تئوری بازی معرفی شده و دو سناریوی مربوط به حضور یا عدم حضور مشارکت با استفاده از تئوری بازی مقایسه شده‌اند. همچنین کاربرد تئوری بازی در دیگر لایه‌های مخابراتی و جهت‌گیری آینده تئوری بازی در رادیوشناختی مورد توجه قرار گرفته است. نتایج نشان می‌دهند که تئوری بازی می‌تواند برای طراحی یک الگوریتم توزیع‌شده موثر در رادیوشناختی adhoc مورد استفاده قرار گیرد.

۵-۵-۴- SVM^۳

SVMها مدل‌های یادگیری هدایت شده‌ای هستند که برای دسته‌بندی و تحلیل رگرسیون به کار می‌روند. همان‌طور که در شکل ۵۰ نشان داده شده است در مرحله یادگیری، SVM از داده یادگیری برای ترسیم حدودی برای جداسازی دسته‌ها استفاده


^۱ Artificial Neural Network (ANN)

^۲ James Waldegrave

^۳ Support Vector Machine

می‌کند. سپس هر داده جدیدی بر اساس این حدود، سازگاری یا فاصله بین دسته و داده دسته‌بندی می‌شود. با توجه به مجموعه‌ای از نمونه‌های آموزشی، که هر یک به دو دسته مجزا تعلق دارند، یک الگوریتم یادگیری SVM مدلی را به عنوان دسته‌بندی‌کننده خطی دودویی غیراحتمالی^۱ ارائه می‌دهد. البته در حالت کلی داده‌ها می‌توانند به صورت بردارهای p بعدی باشند (حاوی لیستی از p عدد باشند). یک مدل SVM نمایشی از نمونه‌های آموزشی به عنوان نقاطی از فضا است به گونه‌ای که نمونه‌های نگاشت شده را بتوان در دسته‌های جداگانه با یک شکاف واضح و تا حد ممکن گسترده، تقسیم نمود. سپس نمونه‌های جدید در همان فضا ترسیم می‌شوند و پیش‌بینی می‌شود که براساس طرفی از شکاف که روی آن قرار می‌گیرند، به کدام دسته تعلق دارند. در فضای داده‌های p بعدی، داده‌ها توسط صفحات $p-1$ بعدی از یکدیگر جدا می‌شوند. یک حالت منطقی برای این صفحات جدا کننده به این صورت است که این صفحه بتواند از نزدیک‌ترین داده، بیشترین فاصله را داشته باشد که به آن صفحه با بیشترین فاصله^۲ گفته می‌شود. در صورتی که ابعاد داده دوی بعدی باشد این صفحه نیز به خط تبدیل می‌شود که در شکل ۵۰ نشان داده شده است. هر چه فاصله‌ای که بین دو دسته ایجاد می‌شود بیشتر باشد، خطای تعمیم دسته‌بندی نیز کاهش می‌یابد. گرچه مساله در فضای متناهی تعریف می‌شود اما جداسازی به صورت خطی در بسیاری از مواقع قابل پیاده‌سازی نیست. به همین دلیل نیز فضای متناهی چند بعدی به یک فضای با ابعاد بیشتر نگاشت می‌شود تا جداسازی در آن فضا آسان‌تر انجام شود. همان‌طور که در شکل ۵۱ نشان داده شده است، این کار توسط تابع kernel انجام می‌شود.

علاوه بر دسته‌بندی‌کننده‌های خطی، SVMها می‌توانند به عنوان دسته‌بندی‌کننده‌های غیرخطی موثری نیز به کار روند. در این حالت با استفاده از روشی به نام kernel ، داده‌ها به یک فضای با ابعاد بزرگ‌تر نگاشت می‌شوند. در [۱۷] از SVM برای اضافه کردن یک طراحی یادگیری به موتور رادیو شناختی استفاده شده است. مدل ارائه شده بر مبنای نرخ خطای بیت (BER)، SNR و نوع مدولاسیون است. برای داده یادگیری سه کانال مدل در نظر گرفته شده است: مدل محوشدگی^۳ تخت، مدل محوشدگی عمیق و مدل بدون محوشدگی. هنگامی که مدل ساخته شد، داده با گرفتن BER، SNR و نرخ داده به عنوان ورودی مورد بررسی قرار می‌گیرد.




شکل ۵۰. روش SVM داده‌های یادگیری را با تعیین خطی که بیشترین جداسازی را بین دو طرف ایجاد می‌کند به دو دسته تقسیم کرده است.

^۱Non-probabilistic binary linear classifier

^۲Maximum-margin hyperplane

^۳Fading




شکل ۵۱. نگاشت نقاط با استفاده از kernel

۴-۵-۶- یادگیری تقویتی (RL)

این روش به کاربر اجازه می‌دهد تا رفتارش را در تعامل با محیط ارتقاء دهد. این نوع از یادگیری می‌تواند توسط کاربران به منظور یادگیری خودکار و غیرهدایت شده به کار رود. در این مورد تنها منبع یادگیری بازخورد دریافتی یک کاربر از محیط بعد از اجرای یک عمل است. دو مشخصه روش RL عبارتند از سعی و خطا^۱ و پاداش یا تأخیر^۲. با استفاده از سعی و خطا فرض می‌شود که یک کاربر هیچ اطلاع قبلی از محیط ندارد و به صورت کور یک سری از اعمال را انجام داده تا محیط را جستجو کند. پاداش با تأخیر بازخوردی است که یک کاربر پس از اتخاذ عملی از محیط اطراف دریافت می‌کند. این پاداش‌ها می‌تواند مثبت یا منفی باشند که نشان‌دهنده خوب یا بد بودن عمل است. هدف کاربر به حداکثر رساندن این پاداش‌ها برای بهره‌برداری از سیستم است. همان‌طور که در شکل ۵۲ ملاحظه می‌شود، یک چرخه شناخت برای رادیو شناختگرها در [۱۸] تعریف شده است. کاربر در لحظه t یک مشاهده o_t در وضعیت s_t دریافت می‌کند. این مشاهده با پاداش تاخیری $r_t(s_{t-1}, a_{t-1})$ که حاصل عمل a_{t-1} در وضعیت s_{t-1} است ترکیب می‌شود تا کاربر بتواند عمل a_t را در زمان t اتخاذ کند. به این ترتیب وضعیت از s_t به s_{t+1} تغییر می‌کند و پاداش $r_{t+1}(s_t, a_t)$ تولید می‌شود. در این‌جا کاربر غیرفعال نیست بلکه می‌تواند وضعیت سیستم را با عمل‌هایی که اتخاذ می‌کند تغییر دهد و می‌تواند محیط را به سمت وضعیت مطلوب سوق دهد تا بیشترین پاداش را دریافت نماید.

^۱Try and error

^۲Delayed reward



شکل ۵۲. چرخه یادگیری تقویتی

در [۱۹] این روش یادگیری روی گره‌های کاربر ثانویه برای حس کردن طیف فرکانسی، آشکارسازی سیگنال کاربر اولیه و تصمیمات انتقال در شبکه‌های رادیوشناختی مورد استفاده قرار گرفته است. کاربر ثانویه انتقالات کاربر اولیه را یاد می‌گیرد تا به صورت پویا فضاهای خالی طیف را پر کند.

در [۲۰] به مساله مصرف زیاد توان به دلیل ارتباطات بین کاربران رادیوشناختی پرداخته شده است. با استفاده از روش کنترل توان جدید که مبتنی بر RL است نیاز به اشتراک‌گذاری اطلاعات مربوط به تداخل و استراتژی توان هر یک از ادوات CR حذف شده است. در این حالت محدودیت‌های تداخلی توسط شبکه اعمال شده و کاربران CR در طی مراحل تکراری در به حداکثر رساندن اهداف خود با یکدیگر به رقابت می‌پردازند.

۷-۵-۴- حرکت دسته جمعی زنبورها (ABC)^۱

حرکت دسته جمعی زنبورها (ABC) در سال ۲۰۰۵ توسط درویس کارابوگا^۲ معرفی شد که از رفتار هوشمندانه زنبورهای عسل نشأت گرفته بود. در [۲۱] این روش به عنوان یک روش ابتکاری تعریف شده که دارای مزایای حافظه، چند مشخصه، جستجوی محلی و مکانیزم ارتقاء راه حل می‌باشد. در مدل ABC، کلونی از سه نوع زنبور تشکیل شده است: کارگر، ناظر^۳ و دیده‌بان^۴. هدف، تعیین محل‌های بهترین منابع غذایی است. زنبورهای کارگر به دنبال منابع غذایی می‌گردند. اگر مقدار نктار از یک منبع جدید از آنچه در حافظه آن‌ها وجود دارد بیشتر بود، آن‌ها محل جدید را در حافظه ثبت کرده و محل قبلی را فراموش می‌کنند. یافتن محل یک منبع غذایی یک مساله بهینه‌سازی و مقدار نکتار، مقدار کمی راه حل است.

^۱Artificial Bee Colony (ABC)

^۲Dervis Karaboga

^۳Onlooker

^۴Scout

در [۲۲] عملکرد ABC در بهینه‌سازی پارامترهای رادیو شناختی مورد مطالعه قرار گرفته است. پارامترهای کنترلی در نظر گرفته شده توان ارسالی و نوع مدولاسیون (BPSK, QPSK, QAM) بودند. همچنین در این مقاله عملکرد ABC با الگوریتم ژنتیک و روش PSO^۱ در زمینه مشخصات همگرایی، انطباق بهینه و زمان محاسبات مورد بررسی قرار گرفته است.


۸-۵-۴- استدلال موردی (CBR)^۲

مفهوم CBR توسط LI D.Xu معرفی شد که بر پایه مسائل و راه‌حل آن‌ها در گذشته است تا بتواند مسائل مشابه فعلی را حل کند. سیستم‌های CBR یک پایگاه داده از موقعیت‌های گذشته، مسائل، راه‌حل‌ها و اثرات آن‌ها می‌سازند. در این روش مسائل جدید با پیدا کردن مواردی در حافظه که بیشترین شباهت را به مساله فعلی دارند و به کاربردن راه‌حل آن‌ها برای حل مساله فعلی، حل می‌شوند [۲۳]. علاوه بر این، یک روش CBR موثر و دارای اهداف چندگانه به منظور حل مشکل نیاز به فضای حافظه زیاد در [۲۴] ارائه شده است.

در [۲۵] روش CBR برای مدیریت لینک، تعادل ترافیک شبکه و بازدهی سیستم مناسب به کار رفته است. هر مورد شامل مسأله، یک راه‌حل و نتایج مربوط به آن می‌شود که رادیوشناختگر را در استفاده بهتر از اطلاعات ورودی، تصمیمات قبلی و تبعات آن کمک می‌کند.

۹-۵-۴- درخت تصمیم‌گیری^۳

این روش یادگیری از یک درخت تصمیم‌گیری برای ایجاد یک مدل استفاده می‌کند که مقدار دسته هدف^۴ را بر پایه تعدادی از متغیرهای ورودی پیش‌بینی می‌کند. یک درخت تصمیم‌گیری ساختار مشابه یک فلوچارت دارد که هر گره یک مشخصه است و همان‌طور که در شکل ۵۳ نشان داده شده است بالاترین گره، گره ریشه می‌باشد. هر شاخه به عنوان خروجی یک تست است و هر گره برگ یک برچسب دسته دارد [۲۶].



شکل ۵۳. ساختار درخت تصمیم‌گیری

^۱ Particle Swarm Optimization

^۲ Case-based reasoning (CBR)

^۳ Decision tree

^۴ Target class

در [۲۷] با استفاده از یادگیری درخت تصمیم‌گیری دستورالعملی برای حس کردن طیف فرکانسی پهن‌بند به صورت بهینه بدست آمده است. گره ریشه نقطه شروع است و گره برگ، کانال انتخابی در هر مرحله است. در هر گره، یک استراتژی طبق قوانین مشخص برای ایجاد گره بچه، انتخاب شده و یک شاخه ساخته شده است. در انتهای برگ‌های درخت روش حس کردن می‌تواند رو به عقب به سمت ریشه دنبال شود.

در [۲۸] درخت تصمیم‌گیری برای مسیریابی رادیو شناختی مورد استفاده قرار گرفته است به گونه‌ای که گره‌ها می‌توانند از محیط اطرافشان یاد بگیرند و پارمترها و تصمیماتشان را متناسب با آن تطبیق دهند. بنابراین یک ارسال کننده از درخت تصمیم‌گیری برای انتخاب مناسب‌ترین و مطمئن‌ترین هاب مجاور استفاده خواهد کرد.

۱۰-۵-۴-۱۰-۱ انتروپی^۱

انتروپی در مقاله شانون^۲ با "عنوان یک تئوری ریاضی مخبرات" در سال ۱۹۴۸ معرفی شد. انتروپی یک مقیاس از عدم قطعیت در یک متغیر تصادفی است. همچنین انتروپی به صورت یک اندازه لگاریتمی از نرخ انتقال اطلاعات در یک پیام خاص تعریف می‌شود [۲۹]. به عنوان نمونه این روش برای بهبود عملکرد حس کردن طیف فرکانسی و قابلیت اطمینان در یک محیط پهن‌بند و اشتراکی مورد استفاده قرار گرفته است. تخمین انتروپی در هر یک از زیرکانال‌ها اعمال شده و کاربران رادیو شناختی مشکوک حذف شده‌اند [۳۰].

۱۱-۵-۴-۱۱-۱ Bayesian روش

شبکه‌های Bayesian مدل‌های احتمالی گرافیکی هستند که بر مبنای تعاملات بین گره‌های مختلف تشکیل می‌شوند و می‌توانند برای یادگیری از هر کدام از گره‌های شبکه به کار روند. این شبکه‌ها اگر برای تشکیل دیاگرام‌های تأثیر^۳ به کار روند می‌توانند در فرآیند تصمیم‌گیری نقش داشته باشند [۳۱]. در [۳۲] یک یادگیری تداخل رادیو شناختی و موتور تصمیم‌گیری بر پایه شبکه‌های Bayesian ارائه شده است. در این مقاله با استفاده از مدل‌های احتمالی بدست آمده از شبکه‌های Bayesian و الگوریتم درخت اتصال^۴، تداخل مدل شده است. همچنین مدل CR برای بهینه‌سازی پارامترهای رادیویی به منظور تضمین کیفیت خدمات برای کاربران نیز توسط نویسندگان ارائه گردیده است.

۱۲-۵-۴-۱۲-۱ مدل مارکوف^۵

مدل مارکوف برای مدل کردن فرآیندهای تصادفی است که در طول زمان از یک مرحله به مرحله دیگری تغییر می‌کنند. فرآیند تصادفی بدون حافظه است و مراحل آتی تنها به مرحله فعلی وابسته هستند [۳۳]. در مدل‌های مارکوف، مراحل برای مشاهده‌کننده مشهود و قابل دید است اما در مدل‌های مارکوف پنهان^۶ (HMM) بعضی از مراحل پنهان شده یا به وضوح قابل مشاهده نیست [۳۴].

^۱Entropy

^۲Shannon

^۳Influence Diagram

^۴Junction Tree Algorithm

^۵Markov Model

^۶Hidden Markov Model (HMM)

در [۳۵] از HMM برای جداسازی منابع کور به منظور تشخیص فضاهای خالی طیف استفاده شده است. با استفاده از مدل مارکوف پنهان، یک موتور رادیوشناختی، فریم بعدی حس کردن کاربر اولیه را پیش‌بینی می‌کند. در [۳۶] مسأله خارج شدن از طیف^۱ در شبکه‌های رادیوشناختی بر پایه مدل مارکوف پنهان بررسی شده است. این مسأله زمانی رخ می‌دهد که نیاز است یک کاربر ثانویه به یک کانال خالی جدید منتقل شده تا کاربر اولیه از کانال خالی شده استفاده کند و در عین حال ارتباط کاربر ثانویه قطع نشود. در نتیجه لازم است تا کاربر ثانویه رفتار کاربر اولیه را بررسی کرده و رفتار آینده آن‌ها را پیش‌بینی نماید.

۱۳-۵-۴- سیستم‌های چند کاربره (MAS)^۲

سیستم‌های چند کاربره توسط جاکوئس فربر^۳ به عنوان یک واحد هوشمند نسبت به محیط پیرامون، قادر به عمل کردن مبتنی بر تجربه و دارای ارتباطات مستقل معرفی شدند. این سیستم‌ها شامل محیط، اجسام، کاربران و ارتباطات مختلف بین این واحدها می‌شوند. همچنین کاربردهایی در حل مسائل در دنیای مجازی دارند [۳۷].

در [۳۸] یک روش جدید برای حل مسأله خارج شدن از طیف در حوزه رادیوشناختی ارائه شده است. این روش به رادیوشناختگرها اجازه می‌دهد تا همیشه به کانالی سوئیچ کنند که بهترین شرایط را توسط استفاده از مذاکرات سیستم چند کاربره پیشنهاد می‌دهد. در این روش رادیوشناختگرهای سیار و کاربران اولیه به عنوان کاربران سیستم چند کاربره شناخته می‌شوند که روی قیمت‌ها و پهنای باند با یکدیگر مذاکره می‌کنند تا هر کدام منفعت خود را حداکثر نمایند.

۱۴-۵-۴- مقایسه روش‌های هوش مصنوعی مورد استفاده در رادیوشناختی

در جدول ۳ مزایا و معایب روش‌های مطرح شده در این بخش آورده شده است.

جدول ۳. مزایا و معایب روش‌های یادگیری مختلف مورد استفاده در رادیوشناختی

روش یادگیری	مزایای روش	معایب روش
شبکه عصبی	• قابلیت تطبیق با تغییرات کوچک • قابلیت پیاده‌سازی با تعداد نمونه‌های کوچک • کاهش پیچیدگی	• نیاز به برچسب‌های داده آموزشی • تعمیم ضعیف • overfitting
SVM	• قابلیت تعمیم • مقاوم بودن نسبت به نویز و داده‌های خارج از محدوده	• نیاز به برچسب‌های داده آموزشی و دانش قبلی نسبت به سیستم • پیچیدگی روش در مسائل بزرگ
الگوریتم ژنتیک	• بهینه‌سازی چند هدفه	• نیاز به دانش قبلی نسبت به سیستم و تابع شایستگی مناسب • پیچیدگی روش در مسائل بزرگ

^۱Spectrum handoff

^۲Multi-agent system

^۳Jacques Ferber

	• پیکربندی پویای رادیو شناختگر بر مبنای تغییرات محیط	
تئوری بازی	• کاهش پیچیدگی تطبیق • ارائه راه‌حلهایی برای سیستم‌های چند کاربره	• نیاز به دانش قبلی نسبت به سیستم و داده آموزشی برچسب دار
تقویتی	• یادگیری به صورت خودکار با استفاده از بازخورد • خود تطبیقی تدریجی به صورت بلادرنگ	• نیاز به فازهای یادگیری راهبردها
منطق فازی	• سادگی • تصمیم‌گیری بر اساس قوانین	• نیاز به استخراج قوانین • دقت بستگی به این قوانین دارد.
انتروپی	• مدل آماری	• نیاز به دانش قبلی از سیستم
درخت تصمیم‌گیری	• سادگی • تصمیم‌گیری براساس شاخه‌های درخت	• نیاز به دانش قبلی از سیستم • ممکن است با overfitting مواجه باشد • نیاز به داده آموزشی برچسب دار
کلونی مصنوعی زنبورها	• جستجوی موازی برای راه‌حل‌ها	• نیاز به دانش قبلی از سیستم • نیاز به تابع شایستگی
Bayesian	• مدل احتمالی	• نیاز به دانش قبلی از سیستم • ممکن است با پیچیدگی محاسباتی روبرو باشد.
مدل مارکوف	• مدل آماری	• نیاز به دانش قبلی از سیستم • ممکن است با پیچیدگی محاسباتی روبرو باشد.
استدلال موردی	• پیدا کردن راه‌حل قابل قبول برپایه موارد موجود که در پایگاه داده وجود دارد.	• جستجوی پیچیده در پایگاه داده‌های بزرگ • نیازمند به موارد از قبل تعیین شده و موارد مشابه • انتشار اشتباهات

۴-۶- کاربرد هوش مصنوعی در دسترسی به طیف فرکانسی، شبکه و کنترل نرخ ارسال داده

شبکه‌های جدید مانند اینترنت اشیاء امروزه بیشتر غیرمتمرکز شده‌اند و ذاتاً به سمت شبکه‌های بدون زیرساخت پیش رفته‌اند. در چنین شبکه‌هایی، اجزای شبکه مانند حسگرها و کاربران نیاز به اتخاذ تصمیم‌های مستقل نظیر انتخاب ایستگاه پایه دارند تا

به اهداف اختصاصی خود نظیر حداکثر انتقال دست یابند. با این حال، این کار می‌تواند به دلیل پویا بودن و عدم قطعیت وضعیت شبکه چالشی باشد. الگوریتم‌های یادگیری مانند DQL با یادگیری و بدست آوردن دانش در مورد شبکه‌ها، اجزای شبکه را قادر می‌سازند تا تصمیم‌های خود را به صورت بهینه اتخاذ کنند. نظر به اهمیت و کاربردهای روزافزون این روش، در این بخش به مروری بر کاربردهای آن جهت دسترسی به طیف فرکانسی، شبکه و نرخ ارسال داده پرداخته می‌شود [۳۹]. به نظر می‌رسد از بین این سه مورد کاربرد، دو مورد اول و به خصوص دسترسی پویا به طیف فرکانسی بیشتر در شبکه‌های رادیو شناختی حائز اهمیت است.

• دسترسی پویا به پهنای باند (DSA)

دسترسی پویا به پهنای باند به کاربران اجازه می‌دهد به منظور حداکثر نمودن نرخ انتقالشان به صورت محلی کانال‌ها را انتخاب کنند. با این حال ممکن است کاربران دید کاملی نسبت به سیستم (برای مثال وضعیت کانال‌ها) نداشته باشند. در نتیجه DQL می‌تواند به عنوان یک وسیله مناسب برای دسترسی پویا به پهنای باند مورد استفاده قرار گیرد.

• ارتباط با کاربر متصل شده^۱ و دسترسی به پهنای باند

ارتباط با کاربر، به منظور تعیین اینکه کدام کاربر به کدام ایستگاه پایه اختصاص یابد پیاده‌سازی شده است. مسائل مربوط به ارتباط با کاربر متصل شده و دسترسی پهنای باند در [۴۰] و [۴۱] مورد مطالعه قرار گرفته است. با این حال این مسائل معمولاً ترکیبی و غیرمحدب^۲ هستند که نیاز به اطلاعات نسبتاً کامل و دقیقی از شبکه دارند تا به استراتژی بهینه دست یابند. روش DQL قادر است راه‌حل‌های غیرمتمرکز و مؤثری را برای این مسائل فراهم نماید.

• کنترل نرخ تطبیقی

کنترل نرخ تطبیقی مربوط به کنترل نرخ بیت یا داده در محیط‌های پویا و غیرقابل پیش‌بینی مانند DASH^۳ می‌باشد. چنین سیستمی به مشتریان یا کاربران اجازه می‌دهد به صورت مستقل قسمت‌های ویدیویی را با نرخ بیت‌های متفاوت برای دانلود انتخاب کنند. هدف کاربر حداکثر نمودن QoE^۴ است. روش یادگیری DQL می‌تواند به جای یک برنامه پویا که پیچیدگی بالا و نیاز به اطلاعات کاملی دارد برای حل مؤثر مسأله به کار برده شود.

۱-۶-۴- دسترسی پویا به پهنای باند

در زمینه تحقیقات بر روی رادیو شناختی، یک فرض استاندارد این است که کاربران ثانویه کانال‌های آزاد را که توسط کاربران اولیه استفاده نشده‌اند، مورد جستجو قرار می‌دهند. در حالی که در مقالات عموماً مدل یک کانال ساده و مستقل در نظر گرفته می‌شود، اما در عمل تداخل سیگنال‌های خارجی در شبکه‌های بی‌سیم می‌تواند کانال‌ها را به یکدیگر وابسته نماید و طراحی الگوریتم‌های جدید برای دسترسی پویا به کانال‌های چندگانه باید بتواند این چالش را حل نماید. مسأله دسترسی پویا به کانال‌های چندگانه به طور وسیعی مورد مطالعه قرار گرفته است اما برخلاف بسیاری از مسائل تصمیم‌گیری همچون دست‌به‌دست کردن و

^۱ Joint User Association

^۲ Non-convex

^۳ Dynamic Adaptive Streaming over HTTP

^۴ Quality of Experience

اختصاص توان که به صورت مسائل تصمیم‌گیری مارکوف (MDP) مدل می‌شوند، به صورت مسائل مارکوف با قابلیت مشاهده جزئی (POMDP) مدل می‌شوند. به این صورت که کانال‌ها به صورت زنجیره‌های مارکوف دو حالت در نظر گرفته شده و کاربر در یک بازه زمانی تنها می‌تواند کانالی را که انتخاب کرده است حس کند و مشاهده کاملی از سیستم در دسترس وجود ندارد. پیدا کردن یک سیاست دسترسی به کانال بهینه نیازمند زمان و حافظه زیادی است. هنگامی که کانال‌ها مستقل هستند و به صورت یکنواخت توزیع شده‌اند، نشان داده شده است که تحت شرایطی سیاست Myopic می‌تواند بهینه باشد [۴۱]، اما برای عملکرد این روش برای حالتی که کانال‌ها همبستگی دارند یا توزیع‌های متفاوتی را دنبال می‌کنند، تضمینی وجود ندارد. در سال‌های اخیر بعضی از کارها با تمرکز بر روی مسائل عملی و پیچیده‌تر شروع شده است که در آن‌ها آمار سیستم نامعلوم است و کانال‌ها همبسته هستند. Q-learning به عنوان یک روش مستقل از مدل بسیار مورد استفاده قرار گرفته است زیرا می‌تواند سیاست را مستقیماً با استفاده از یادگیری استخراج نماید. از آنجایی که مسأله در این‌جا یک مسأله مشاهده جزئی است فضای حالت بزرگی که شکل می‌گیرد استفاده از جداول جستجوی^۱ ساده برای بروزکردن مقادیر Q را غیرممکن می‌سازد. برای این منظور یادگیری تقویتی شامل Q-learning با روش‌های یادگیری ماشین پیشرفته ترکیب شده است تا بتواند مسائلی با ابعاد بزرگ را حل کند. در سال ۲۰۱۳ Google DeepMind از یک شبکه عصبی عمیق برای حل محدودیت روش جداول جستجوی قدیمی استفاده کرد تا بتواند مقادیر Q را تخمین بزند. با استفاده از این روش که DQN نامیده شد کاربر می‌تواند راهبرد یا سیاست را از مشاهداتش یاد بگیرد. روش DQN می‌تواند برای سیستم‌های بزرگ به کار رود و یک سیاست خوب و حتی بهینه را از مشاهدات قبلی (تاریخی) بدون نیاز به دانستن مشخصات پویای سیستم پیدا کند. در [۴۲] روشی برای دسترسی پویا به کانال یک حسگر بر مبنای DQL برای اینترنت اشیاء ارائه شده است. در هر بازه زمانی، حسگر یکی از M کانال را برای ارسال بسته خود انتخاب می‌کند. وضعیت کانال می‌تواند در صورت تداخل اندک معادل انتقال موفق یا در صورت تداخل بالا معادل انتقال ناموفق باشد. به دلیل اینکه حسگر تنها کانال را پس از انتخاب آن می‌شناسد، مسأله بهینه‌سازی تصمیم حسگر می‌تواند به عنوان یک POMDP فرمول‌بندی شود. عمل حسگر انتخاب یکی از M کانال می‌باشد. هنگامی که حسگر یک کانال با تداخل کم را انتخاب می‌کند یک پاداش مثبت دریافت می‌کند و در صورت برعکس یک پاداش منفی دریافت می‌نماید. هدف انتخاب یک سیاست بهینه‌سازی برای به حداکثر رساندن پاداش‌های حسگر در طول بازه‌های زمانی می‌باشد. سپس یک DQN با استفاده از FNN با پاسخ تجربی برای پیدا کردن سیاست بهینه به کار برده شده است. ورودی DQN، یک وضعیت حسگر است که ترکیبی از اعمال و مشاهدات (پاداش‌ها) در دوره‌های زمانی گذشته می‌باشد. خروجی شامل مقادیر Q مربوط به عمل‌ها می‌باشد. برای به تعادل رساندن جستجوی مقادیر بهینه Q فعلی با جستجوی مقادیر بهتر، سیاست $\epsilon - greedy$ برای مکانیزم انتخاب عمل به کار رفته است. نتایج شبیه‌سازی بر اساس داده حقیقی نشان می‌دهد که روش ارائه شده می‌تواند بدون اطلاع کامل از سیستم، به میانگین پاداشی نزدیک به سیاست Myopic دست پیدا کند.

برای این که نشان داده شود یادگیری تقویتی چگونه برای دسترسی و تخصیص کانال به کار می‌رود و چه پارامترها و مقادیری برای آن در نظر گرفته می‌شود مثالی از مرجع [۴۲] در ادامه توضیح داده شده است. برای مدل کردن همبستگی بین کانال‌ها، کل سیستم به صورت یک زنجیره مارکوف با 2^N حالت در نظر گرفته می‌شود. فضای حالت زنجیره مارکوف به صورت $S = \{s_1, s_2, \dots, s_{2^N}\}$ تعریف می‌شود. هر حالت s_i که $i \in \{1, 2, \dots, 2^N\}$ باشد یک بردار به طول N به صورت $[s_{i1}, \dots, s_{iN}]$ است که در آن s_{ik} یک نمایش دودویی از کانال k است. در حالتی که کانال خوب باشد مقدار k برابر 1 و در حالتی که بد باشد برابر 0 است. تغییر حالت زنجیره مارکوف با P نشان داده می‌شود. از آنجایی که کاربر تنها یک کانال را در ابتدای یک بازه زمانی حس می‌کند، حالت‌های کامل همه کانال‌ها قابل مشاهده نیست. با این حال کاربر می‌تواند توزیعی را برای حالت‌های سیستم با توجه به تصمیماتش برای حس کردن و مشاهداتش درک کند. در نتیجه دسترسی پویا به کانال‌های چندگانه یک مسأله POMDP خواهد بود. فرض کنید $\Omega(t) = [\omega_{s_1}(t), \dots, \omega_{s_{2^N}}(t)]$ بردار باور کاربر باشد که در آن $\omega_{s_i}(t)$

^۱ Look-up table


احتمال شرطی است که با وجود همه تصمیمات و مشاهدات قبلی سیستم در وضعیت s_t باشد. عمل حس کردن $a(t) \in \{1, \dots, N\}$ نشان می‌دهد که در بازه زمانی t کدام کانال مورد حس کردن قرار گیرد و وضعیت کانال $a(t)$ به صورت $o(t) \in \{0, 1\}$ خواهد بود. بر اساس این مشاهده، کاربر می‌تواند بردار باور را در بازه زمانی t بروزرسانی نماید که به صورت $\hat{\Omega}(t) = [\hat{o}_{s_1}(t), \dots, \hat{o}_{s_N}(t)]$ نشان داده می‌شود. با استفاده از ترکیب بردار باور بروز شده $\hat{\Omega}(t)$ برای بازه زمانی t با ماتریس انتقال سیستم P بردار باور برای بازه زمانی $t+1$ می‌تواند به صورت $\Omega(t+1) = \hat{\Omega}(t)P$ باشد. یک سیاست یا راهبرد حس کردن $\pi: \Omega(t) \rightarrow a(t)$ یک تابع است که بردار باور $\Omega(t)$ را به عمل حس کردن $a(t)$ در بازه زمانی t نگاشت می‌نماید. در نتیجه پاداش دراز مدت در طول زمان بینهایت به صورت زیر خواهد بود:

$$E_{\pi} \left[\sum_{t=1}^{\infty} \gamma^{t-1} R_{\pi(\Omega(t))}(t) | \Omega(1) \right]$$

که در آن $\pi(\Omega(t))$ عمل حس کردن کانال در زمان t با استفاده از بردار باور $\Omega(t)$ است و $R_{\pi(\Omega(t))}(t)$ نیز پاداش متناظر با این عمل است. γ نیز ضریبی است که مقداری بین صفر و یک دارد. هدف پیدا کردن یک سیاست حس کردن است که بتواند پاداش تجمعی در طول زمان را حداکثر نماید.

[۴۲] می‌تواند به عنوان یک کار پیشرو در استفاده از DQL برای دسترسی کانال محسوب شود. با این حال، DQL سیاست یادگرفته شده را در طول دوره‌های زمانی دنبال می‌کند و یادگیری یک سیاست مناسب را متوقف می‌نماید. محیط‌های اینترنت اشیا واقعی پویا هستند و لازم است تا DQN در DQL دوباره بازآموزی شود. یک طرح DQL بهینه در [۴۲] ارائه شده که می‌تواند پاداش‌های جمع‌شونده از سیاست فعلی را برای هر دوره ارزیابی کند. هنگامی که پاداش از یک حد آستانه مشخص شده کم‌تر شود، DQN برای پیدا کردن یک سیاست خوب جدید بازآموزی می‌شود. نتایج شبیه‌سازی نشان می‌دهد که هنگامی که وضعیت‌های کانال تغییر می‌کند، DQL بهینه می‌تواند تغییر را آشکارسازی کرده و بازآموزی را برای بدست آوردن پاداش بالا شروع کند.

مدل‌هایی که اشاره شد تنها به یک حسگر محدود بودند. در [۴۳] سناریویی با چند حسگر را مد نظر قرار داده و استفاده از DQL برای انتخاب کانال مشترک و ارسال بسته بررسی شده است. همان‌طور که در شکل ۵۴ نشان داده شده است یک حسگر به عنوان رله، بسته‌های دریافت شده از حسگرهای مجاور را به دریافت‌کننده^۱ ارسال می‌کند. این حسگر مجهز به یک بافر برای ذخیره بسته‌های دریافت شده است. در هر بازه زمانی، حسگر یک دسته از کانال‌ها را برای ارسال بسته انتخاب می‌کند تا نسبت تعداد بسته ارسالی به توان ارسالی که بهره تعریف می‌شود، حداکثر گردد.



شکل ۵۴. انتخاب کانال مشترک و ارسال بسته در اینترنت اشیا

^۱Sink

همانند [۴۲] مسأله حسگر می‌تواند به عنوان یک MDP فرمول‌بندی شود. عملی که باید انجام شود انتخاب یک دسته از کانال‌ها، تعداد بسته‌های ارسالی روی کانال‌ها و یک نوع مدولاسیون است. برای جلوگیری از تلفات بسته، وضعیت به صورت ترکیبی از وضعیت بافر و وضعیت کانال تعریف شده است. سپس MDP توسط DQL حل شده که ورودی، وضعیت و خروجی، انتخاب عمل است. DQL از کدگذار خودکار پشته‌ای^۱ برای کاهش محاسبات زیاد و ذخیره در فاز Q-learning استفاده می‌کند. اثبات شده که تابع بهره حسگر محدود است که می‌تواند همگرایی الگوریتم را تضمین نماید. همان‌طور که در نتایج شبیه‌سازی آمده است، طرح ارائه شده پس از چندین تکرار همگرا می‌شود. همچنین این روش بهره سیستم را نسبت به انتخاب عمل تصادفی به طور قابل ملاحظه‌ای بهبود می‌بخشد. با این حال با افزایش نرخ رسید بسته، بهره سیستم در طرح ارائه شده کاهش می‌یابد و حسگر نیاز دارد تا توان بیشتری را برای ارسال همه بسته‌ها مصرف کند.

مصرف توان بالاتر (به دلیل محدودیت انرژی) منجر به عملکرد ضعیف حسگر و کوتاه‌تر شدن عمر سیستم اینترنت اشیاء می‌شود. مسأله دسترسی به کانال در یک سیستم اینترنت اشیاء مجهز به استحصال انرژی^۲ در [۴۴] مورد بررسی قرار گرفته است. مدل از یک ایستگاه پایه و حسگرهای مبتنی بر استحصال انرژی تشکیل شده است. با این حال، ممکن است به دلیل عدم قطعیت دسترسی به انرژی در حسگرها تخصیص کانال غیرمؤثر باشد. برای مثال، کانالی که به حسگری با انرژی در دسترس پایین تخصیص داده شده، ممکن است به طور کامل نتواند مورد استفاده قرار گیرد زیرا حسگر نمی‌تواند بعداً ارتباط برقرار کند. بنابراین مسأله ایستگاه پایه، پیش‌بینی وضعیت‌های باتری حسگرها و انتخاب کانال برای دست یافتن به حداکثر نرخ انتقال کل است. از آنجایی که حسگرها در یک ناحیه جغرافیایی به صورت تصادفی پراکنده شده‌اند، اطلاعات کامل آماری از پویایی‌های سیستم شامل وضعیت‌های باتری و کانال‌ها ممکن است در دسترس نباشد. در نتیجه از DQL برای حل مسأله ایستگاه پایه استفاده شده است. DQL از یک DQN استفاده می‌کند که از دو لایه شبکه عصبی بر پایه LSTM تشکیل شده است. لایه اول وضعیت‌های پیش‌بینی شده باتری حسگرها را تولید کرده و لایه دوم از وضعیت‌های پیش‌بینی شده به همراه اطلاعات وضعیت کانال^۳ (CSI) برای تعیین سیاست دسترسی به کانال استفاده می‌کند. فضای حالت شامل (۱) تاریخچه برنامه دسترسی به کانال (۲) تاریخچه اطلاعات باتری پیش‌بینی شده (۳) تاریخچه اطلاعات واقعی باتری (۴) CSI فعلی حسگرها. فضای عمل شامل همه دسته‌های حسگری است که برای دسترسی کانال انتخاب می‌شوند و پاداش نیز اختلاف بین نرخ کل انتقال و مقدار خطای پیش‌بینی شده است. همان‌طور که در نتایج شبیه‌سازی نشان داده شده است، طرح پیشنهادی سیاست بدبینانه را پیاده کرده و مقدار خطای پیش‌بینی باتری نزدیک به صفر بوده است.

در [۴۲] و [۴۴] طرح‌ها بر روی حداکثر نرخ انتقال متمرکز بودند. در سیستم‌های اینترنت اشیائی نظیر مخابرات ماشین به ماشین^۴ (V2V)، تأخیر نیز به دلیل جابجایی فرستنده و گیرنده V2V و کاربردهای مهمی که در ایمنی ترافیک دارد باید مورد نظر قرار گیرد. یکی از مسائل هر فرستنده V2V، انتخاب یک کانال و یک سطح انتقال توان برای حداکثر نمودن ظرفیتش تحت یک محدودیت تأخیر می‌باشد. با در نظر گرفتن یک شبکه غیرمتمرکز، یک DQN برای اتخاذ تصمیم‌های بهینه در [۴۵] ارائه شده است. مدل شامل فرستنده‌های V2V است که یک دسته از کانال‌ها را به اشتراک می‌گذارند. عمل هر کدام از فرستنده‌های V2V شامل انتخاب کانال‌ها و سطوح انتقال توان است. پاداش تابع ظرفیت فرستنده V2V و تأخیر است. وضعیت مشاهده شده توسط فرستنده V2V شامل (۱) CSI لحظه‌ای از لینک V2V مربوطه (۲) تداخل لینک V2V در بازه زمانی قبلی (۳) کانال‌های انتخاب شده توسط همسایگان فرستنده V2V در بازه زمانی قبلی و (۴) زمان باقی مانده برای رسیدن به محدودیت تأخیر است. وضعیت همچنین یک ورودی DQN است. خروجی شامل مقادیر Q مربوط به عمل‌ها می‌باشد. همان‌طور که در نتایج شبیه‌سازی

^۱Stacked autoencoder^۲Energy harvesting^۳Channel State Information (CSI)^۴Vehicle-to-Vehicle (V2V)

نشان داده شده است زمانی که با تنظیم پویای توان و انتخاب کانال، لینک V2V در حال از بین بردن محدودیت تأخیر بود، طرح ارائه شده در مقایسه با تخصیصی کانال تصادفی، بیشتر محدودیت تأخیر را رعایت کرده است.

برای کاهش هزینه پهنای باند، سیستم‌های اینترنت اشیاء معمولاً از کانال‌های بدون مجوز استفاده می‌کنند. با این حال ممکن است این کار باعث ایجاد تداخل با شبکه‌ها موجود مانند WLAN‌ها شود. در [۴۶] از DQN برای مدیریت دسترسی پویا به کانال و تداخل به صورت مشترک استفاده شده است. مدل شامل ایستگاه‌های پایه کوچک^۱ (SBS) است که کانال‌های بدون مجوز را در شبکه LTE به اشتراک می‌گذارند. در هر بازه زمانی، SBS یکی از کانال‌ها را برای انتقال بسته‌اش انتخاب می‌کند. با این حال ممکن است ترافیک WLAN روی کانال انتخاب شده وجود داشته باشد و به همین دلیل SBS با یک احتمال به کانال انتخاب شده دسترسی پیدا می‌کند. عمل‌های SBS شامل انتخاب کانال و احتمال دسترسی به کانال می‌شود. مساله SBS تعیین بردار عمل برای حداکثر نمودن انتقال کل و بهره‌وری خود بر روی همه کانال‌ها و بازه‌های زمانی است. مساله تخصیص کانال می‌تواند به صورت یک بازی بدون همکاری^۲ (غیر تعاونی) فرمول‌بندی شده و DQN با استفاده از LSTM می‌تواند برای حل بازی به کار برده شود. ورودی DQN تاریخ ترافیک SBS ها و WLAN روی کانال‌هاست. خروجی نیز شامل بردارهای عمل پیش‌بینی شده SBS است. ثابت شده است که تابع بهره هر SBS محدب است و در نتیجه الگوریتم مبتنی بر DQN به موازنه Nash برای بازی همگرا می‌شود. نتایج شبیه‌سازی بر پایه داده‌های [۴۷] نشان می‌دهد که روش پیشنهادی می‌تواند متوسط انتقال را تا 28% نسبت به Q-learning استاندارد بهبود بخشد. همچنین این روش از خراب شدن عملکرد WLAN نیز جلوگیری می‌کند. با این حال، این روش نیازمند همزمانی بین SBS ها و WLAN که در شبکه‌های واقعی چالشی است.

در زمینه شبکه سلولی مشابه، در [۴۸] به مساله دسترسی پویا به پهنای باند برای چندین کاربر که K کانال را به اشتراک می‌گذارند بررسی شده است. در یک بازه زمانی، کاربر یک کانال را با یک احتمال دسترسی مشخص انتخاب می‌کند یا انتخاب می‌کند که اصلاً انتقالی انجام ندهد. وضعیت تاریخچه عمل‌های کاربر و مشاهدات محلی آن است و استراتژی کاربر نگاشت از تاریخچه به احتمال دسترسی است. مساله کاربر پیدا کردن یک بردار از استراتژی‌ها (سیاست‌ها) در طول بازه‌های زمانی برای به حداکثر رساندن نرخ داده دارای تخفیف برای کاربر می‌باشد. این مساله با آموزش یک DQN حل شده است. ورودی DQN شامل عمل‌های قبلی و مشاهدات مربوطه است. خروجی نیز شامل مقادیر تخمین زده شده از Q عمل‌ها می‌باشد. برای جلوگیری از خطای تخمین در Q-learning از DDQN استفاده شده است [۴۹]. علاوه بر این، برای بهبود تخمین مقادیر Q، dueling DQN نیز به کار رفته است [۵۰]. همانند [۴۶] دسترسی تصادفی به چندین کانال با استفاده از بازی بدون همکاری مدل شده است. همان‌طور که در [۴۸] اثبات شده است، بازی دارای یک موازنه کامل زیربازی است. توجه داشته باشید که برخی از کاربران می‌توانند احتمال دسترسی شان را بالا ببرند تا نرخ انتقالشان افزایش یابد. این نکته باعث می‌شود که نقطه تعادل غیرمؤثر باشد و فضای استراتژی کاربران برای جلوگیری از این وضعیت محدود می‌شود. در نتایج نشان داده شده است که روش ارائه شده می‌تواند به نرخ انتقال کانالی دو برابر روش slotted-Aloha دست پیدا کند. دلیل این امر این است که در روش ارائه شده هر کاربر تنها از مشاهدات محلی خود بدون هدایت آنالین یا حس نمودن حامل یاد می‌گیرد. با این حال، روش ارائه شده نیاز به یک واحد مرکزی دارد که ممکن است با به روزرسانی مستمر یادگیری، تبادل پیام را افزایش دهد.

در مدل‌های قبلی، تعداد کاربران در همه بازه‌های زمانی ثابت است و رسیدن کاربر جدید در نظر گرفته نشده است. در [۵۱] تخصیص کانال به کاربران جدید در سیستم ماهواره‌ای چند-بیمه بررسی شده است. سیستم ماهواره‌ای دارای یک الگوی تشعشعی است که به چندین بیم تقسیم می‌شود و هر یک خدماتی را به کاربران زمینی ارائه می‌دهند. سیستم دارای یک دسته کانال است. اگر کانال قابل دسترسی ایجاد شود، سیستم یک کانال به کاربر جدید اختصاص می‌دهد؛ در این صورت، سرویس رضایت‌بخش خواهد بود و در غیر این صورت سرویس قطع است. مساله‌ی سیستم پیدا کردن یک تصمیم اختصاص کانال برای به حداقل رساندن احتمال

^۱Small Base Station

^۲Non-cooperative

قطع بودن سرویس برای کاربر جدید در طول بازه‌های زمانی و بدون ایجاد اختلال برای کاربران فعلی است. این مسأله با استفاده از DQN قابل حل است و نتایج نشان می‌دهد که الگوریتم DQN پس از تعدادی مرحله‌ی آموزش همگرا می‌شود. همچنین با تخصیص کانال‌های در دسترس به کاربران جدید، ترافیک سیستم تا ۲۴٪ نسبت به تخصیص کانال ثابت، بهبود می‌یابد. با این حال با افزایش تعداد کاربران حاضر، تعداد کانال‌های در دسترس کم می‌شود یا به صفر می‌رسد. در نتیجه تصمیم‌های تخصیص کانال پویا در روش ارائه شده بی‌معنی خواهد بود و تفاوت بین عملکرد دو روش غیرقابل توجه می‌شود.

۲-۶-۴- ارتباط با کاربر متصل شده و دسترسی به طیف

مسائل ارتباط با کاربر متصل شده و دسترسی به طیف معمولاً غیر محدب هستند. روش DQL می‌تواند راه‌حل‌های توزیع شده‌ای را فراهم کند و در نتیجه به طور موثر بدون نیاز به اطلاعات کامل و دقیق از شبکه برای حل این مسائل به کار برده شود. در [۵۲] شبکه HetNet مورد بررسی قرار گرفته که از چندین کاربر و ایستگاه پایه شامل ایستگاه‌های پایه ماکرو و فمتو، تشکیل شده است. ایستگاه‌های پایه یک دسته از کانال‌های عمود بر هم را به اشتراک گذاشته و کاربران به صورت تصادفی در شبکه قرار داده می‌شوند. مسأله برای هر یک از کاربران انتخاب یک ایستگاه پایه و یک کانال برای حداکثر نمودن نرخ داده خود است به طوری که نسبت سیگنال به نویز تداخل پالس^۱ (SINR) برای کاربر بیش از حداقل نیاز کیفیت خدمات (QoS) باشد. برای حل این مسأله از DQL استفاده شده که فضای حالت آن یک بردار شامل حالت‌های QoS همه کاربران (فضای کلی) می‌باشد. در هر بازه زمانی کاربر یک عمل را انجام می‌دهد. اگر QoS مورد تأیید باشد کاربر خدمات را دریافت می‌کند که به معنی پاداش خواهد بود. در غیر این صورت یک پاداش منفی خواهد گرفت که هزینه انتخاب این عمل است. توجه شود که پاداش جمع شده یک کاربر به عمل دیگر کاربران نیز بستگی دارد، در نتیجه مسأله کاربر می‌تواند به صورت یک MDP تعریف شود. مشابه [۴۲]، DDQN و dueling DQL برای یادگیری سیاست بهینه یک کاربر یعنی انتخاب‌های کانال و ایستگاه مشترک برای به حداکثر رساندن پاداش جمع شونده‌اش استفاده شده است.

روشی که در [۵۲] ارائه شد، اولین کاری بود که از DQL برای مسأله ارتباط با کاربر متصل شده و دسترسی به طیف استفاده شد. با توجه به این روش در [۵۳] روشی برای مسأله ارتباط با کاربر متصل شده، دسترسی طیف و ذخیره محتوا^۲ ارائه شده است. مدل شبکه، یک شبکه LTE است که از UAVها برای سرویس دهی به کاربران زمینی استفاده می‌کند. UAVها به واحدهای ذخیره انرژی مجهز هستند و می‌توانند به عنوان ایستگاه‌ها LTE قابل ذخیره سازی عمل کنند. UAVها می‌توانند به باندهای دارای مجوز و بدون مجوز در شبکه دسترسی داشته باشند. آنها توسط یک سرور بر پایه ابر کنترل می‌شوند و انتقال اطلاعات از ابر به UAVها با استفاده از باندهای سلولی دارای مجوز صورت می‌گیرد. مسأله هر UAV عبارتست از: (۱) ارتباط با کاربر بهینه (۲) نشان‌دهنده‌های تخصیص پهنای باند روی باندهای دارای مجوز (۳) نشان‌دهنده‌های بازه زمانی روی باند بدون مجوز (۴) یک دسته از محتواهای معروف که کاربران می‌توانند درخواست کنند تا تعداد کاربران با یک صف پایدار به حداکثر برسد و کاربران با تاخیر ارسال محتوی راضی باشند.

مسأله UAVها ترکیبی و غیرمحدب است و DQL می‌تواند برای حل آن مورد استفاده قرار گیرد. UAVها اطلاعی از درخواست‌های محتوای کاربران ندارند و بنابراین روش LSM^۳ [۵۴] برای پیش‌بینی توزیع درخواست محتوی کاربران و تخصیص منابع عملکردی به کار رفته است. پیش‌بینی توزیع درخواست محتوی بر روی ابری بر اساس یک الگوریتم پیش‌بینی مبتنی بر LSM پیاده شده است. با بدست آوردن توزیع‌های درخواست، هر یک از UAVها از یک الگوریتم یادگیری مبتنی بر LSM برای پیدا کردن ارتباط با کاربران بهینه استفاده می‌کند. ورودی الگوریتم یادگیری مبتنی بر LSM از عمل‌هایی (روش‌های ارتباط

¹ Signal-to-Interference-pulse-Noise Ratio

²Content Cashing

Liquid State Machine^۳

کاربر-UAV) تشکیل شده است که دیگر UAVها اتخاذ می‌کنند و خروجی شامل تعداد کاربران با صف‌های پایدار است که مربوط به عمل‌هایی است که یک UAV خاص می‌تواند انجام دهد. بعد از اینکه ارتباط با کاربر انجام شد، ذخیره محتوای بهینه بر پایه نتایج تئوری دوم در [۵۵] تعیین می‌شود و تخصیص طیف بهینه با استفاده از برنامه ریزی خطی انجام می‌گیرد. بر اساس تئوری گوردن^۱ [۵۶] روش DQL ارائه شده با احتمال یک همگرا می‌شود. نتایج شبیه‌سازی با استفاده از داده درخواست محتوای از [۵۷] نشان می‌دهد که روش DQL ارائه شده بعد از ۴۰۰ تکرار همگرا می‌شود. در مقایسه با Q-learning، این روش همگرایی را ۳۳٪ بهبود می‌بخشد. علاوه بر این تعداد کاربران با صف‌های پایدار را نیز ۵۰٪ نسبت به Q-learning بدون ذخیره سازی افزایش می‌دهد. مسلماً بازدهی انرژی برای UAVها دارای اهمیت است و استفاده از DQL برای یک مساله ارتباط با کاربر متصل شده، دسترسی به طیف و تخصیص توان نیاز به بررسی دارد.

۷-۴- جمع‌بندی فصل ۴

در این فصل به دسته‌بندی روش‌های مختلف هوش مصنوعی و یادگیری ماشین در رادیو شناختی پرداخته شد. این روش‌ها را می‌توان به دو دسته کلی دسته‌بندی و تصمیم‌گیری تقسیم نمود. گرچه در مورد هر یک از روش‌های کاربرد و معروف توضیحات کلی داده شده است تأکید بیشتر بر روی یادگیری تقویتی می‌باشد. همچنین روش‌های مختلف از لحاظ کاربرد و مزایا و معایب با یکدیگر مورد مقایسه قرار گرفته‌اند.

در ادامه به مساله دسترسی به طیف فرکانسی و شبکه پرداخته شد که به عنوان یک مساله تصمیم‌گیری مارکوف با مشاهده‌پذیری جزئی تعریف می‌شود. از آنجایی که این مسائل دارای فضا حالت گسترده‌ای هستند روش‌های Q-learning با روش‌های یادگیری تقویتی و یادگیری عمیق ترکیب شده و روش DQL را برای این نوع مسائل ارائه می‌شود. مساله دسترسی پویا به شبکه را می‌توان به مسائل دسترسی پویا به پهنای باند، همکاری با کاربر متصل شده و کنترل نرخ داده تقسیم نمود. مثال‌هایی نیز از دو مورد اول و نحوه استفاده از DQL برای حل آن‌ها آورده شده است.

^۱Gordon's Theorem

مراجع فصل ۴

- [1] S. Haykin, "Cognitive radio: brain-empowered wireless communications," *IEEE journal on selected areas in communications*, vol. 23, pp. 201-220, 2005.
- [2] T. Yucek and H. Arslan, "A survey of spectrum sensing algorithms for cognitive radio applications," *IEEE communications surveys & tutorials*, vol. 11, pp. 116-130, 2009.
- [3] C. Clancy, J. Hecker, E. Stuntebeck, and T. O'Shea, "Applications of machine learning to cognitive radio networks," *IEEE Wireless Communications*, vol. 14, pp. 47-52, 2007.
- [4] R. S. Michalski, "Learning and cognition," 1995.
- [5] J. Mitola and G. Q. Maguire, "Cognitive radio: making software radios more personal," *IEEE personal communications*, vol. 6, pp. 13-18, 1999.
- [6] S. Jayaweera and C. Christodoulou, "Radiobots: Architecture, algorithms and realtime reconfigurable antenna designs for autonomous, self-learning future cognitive radios," 2011.
- [7] M. Bkassiny, Y. Li, and S. K. Jayaweera, "A survey on machine-learning techniques in cognitive radios," *IEEE Communications Surveys & Tutorials*, vol. 15, pp. 1136-1159, 2012.
- [8] F. Dandurand and T. R. Shultz, "Connectionist models of reinforcement, imitation, and instruction in learning to solve complex problems," *IEEE Transactions on Autonomous Mental Development*, vol. 1, pp. 110-121, 2009.
- [9] V. N. Vapnik, "The Nature of Statistical Learning Theory," *New York: Springer*, 1995.
- [10] L. A. Zadeh, "Fuzzy sets," *Information and control*, vol. 8, pp. 338-353, 1965.
- [11] M. Matinmikko, J. Del Ser, T. Rauma, and M. Mustonen, "Fuzzy-logic based framework for spectrum availability assessment in cognitive radio systems," *IEEE Journal on selected areas in communications*, vol. 31, pp. 2173-2184, 2013.
- [12] S. Chen, T. R. Newman, J. B. Evans, and A. M. Wyglinski, "Genetic algorithm-based optimization for cognitive radio networks," in *2010 IEEE Sarnoff Symposium*, 2010, pp. 1-6.
- [13] J. J. Popoola and R. van Olst, "Application of neural network for sensing primary radio signals in a cognitive radio environment," in *IEEE Africon'11*, 2011, pp. 1-6.
- [14] Z. Han, D. Niyato, W. Saad, T. Başar, and A. Hjørungnes, *Game theory in wireless and communication networks: theory, models, and applications*: Cambridge university press, 2012.
- [15] D. Bellhouse, "The problem of Waldegrave," *Electronic Journal for the History of Probability and Statistics*, vol. 3, pp. 1-12, 2007.
- [16] O. B. Abdulghfoor, M. Ismail, and R. Nordin, "Application of game theory to underlay ad-hoc cognitive radio networks: An overview," in *2013 IEEE International Conference on Space Science and Communication (IconSpace)*, 2013, pp. 296-301.
- [17] Y. Huang, H. Jiang, H. Hu, and Y. Yao, "Design of learning engine based on support vector machine in cognitive radio," in *2009 International Conference on Computational Intelligence and Software Engineering*, 2009, pp. 1-4.
- [18] K.-L. A. Yau, P. Komisarczuk, and P. D. Teal, "Applications of reinforcement learning to cognitive radio networks," in *2010 IEEE International Conference on Communications Workshops*, 2010, pp. 1-6.
- [19] S. Arunthavanathan, S. Kandeepan, and R. J. Evans, "Reinforcement learning based secondary user transmissions in cognitive radio networks," in *2013 IEEE GLOBECOM workshops (gc wkshps)*, 2013, pp. 374-379.

- [20] P. Zhou, Y. Chang, and J. A. Copeland, "Reinforcement learning for repeated power control game in cognitive radio networks," *IEEE Journal on Selected Areas in Communications*, vol. 30, pp. 54-69, 2011.
- [21] M. Rout, U. M. Mohapatra, B. Majhi, and R. Mahapatra, "An artificial bee colony algorithm based efficient prediction model for stock market indices," in *2012 World Congress on Information and Communication Technologies*, 2012, pp. 750-754.
- [22] P. M. Pradhan, "Design of cognitive radio engine using artificial bee colony algorithm," in *2011 International Conference on Energy, Automation and Signal*, 2011, pp. 1-4.
- [23] J. Kolodner, *Case-based reasoning*: Morgan Kaufmann, 2014.
- [24] K.-S. Huang, C.-H. Lin, and P.-A. Hsiung, "A space-efficient and multi-objective case-based reasoning in cognitive radio," 2010.
- [25] D. Ali, J.-M. J. Park, and A. Amanna, "A feature partitioning approach to casebased reasoning in cognitive radios," in *8th International Conference on Cognitive Radio Oriented Wireless Networks*, 2013, pp. 288-293.
- [26] S. R. Safavian and D. Landgrebe, "A survey of decision tree classifier methodology," *IEEE transactions on systems, man, and cybernetics*, vol. 21, pp. 660-674, 1991.
- [27] H. Han, J.-l. Wang, Q.-h. Wu, and Y.-z. Huang, "Optimal wideband spectrum sensing order based on decision-making tree in cognitive radio," in *2010 International Conference on Wireless Communications & Signal Processing (WCSP)*, 2010, pp. 1-5.
- [28] S. Soltani and M. W. Mutka, "A decision tree cognitive routing scheme for cognitive radio mesh networks," *Wireless Communications and Mobile Computing*, vol. 15, pp. 1405-1417, 2015.
- [29] C. E. Shannon, "A mathematical theory of communication," *Bell system technical journal*, vol. 27, pp. 379-423, 1948.
- [30] S. Srinu, S. L. Sabat, and S. K. Udgate, "Reliable cooperative wideband spectrum sensing based on entropy estimation," in *2012 6th International Conference on Signal Processing and Communication Systems*, 2012, pp. 1-5.
- [31] Y. Cao, "Study of the bayesian networks," in *2010 International Conference on E-Health Networking Digital Ecosystems and Technologies (EDT)*, 2010, pp. 172-174.
- [32] Y. Huang, J. Wang, and H. Jiang, "Modeling of learning inference and decision-making engine in cognitive radio," in *2010 Second International Conference on Networks Security, Wireless Communications and Trusted Computing*, 2010, pp. 258-261.
- [33] W.-K. Ching, X. Huang, M. K. Ng, and T.-K. Siu, *Markov chains: models, algorithms and applications* vol. 189: Springer Science & Business Media, 2013.
- [34] A. M. Fraser, *Hidden Markov models and dynamical systems* vol. 107: Siam, 2008.
- [35] A. Mukherjee, S. Maiti, and A. Datta, "Spectrum sensing for cognitive radio using blind source separation and hidden Markov model," in *2014 Fourth International Conference on Advanced Computing & Communication Technologies*, 2014, pp. 409-414.
- [36] C. Pham, N. H. Tran, C. T. Do, S. I. Moon, and C. S. Hong, "Spectrum handoff model based on hidden markov model in cognitive radio networks," in *The International Conference on Information Networking 2014 (ICOIN2014)*, 2014, pp. 406-411.
- [37] J. Ferber and G. Weiss, *Multi-agent systems: an introduction to distributed artificial intelligence* vol. 1: Addison-Wesley Reading, 1999.
- [38] E. Trigui, M. Esseghir, and L. Merghem-Boulahia, "Multi-agent systems negotiation approach for handoff in mobile cognitive radio networks," in *2012 5th International Conference on New Technologies, Mobility and Security (NTMS)*, 2012, pp. 1-5.
- [39] N. C. Luong, D. T. Hoang, S. Gong, D. Niyato, P. Wang, Y.-C. Liang, *et al.*, "Applications of deep reinforcement learning in communications and networking: A survey," *IEEE Communications Surveys & Tutorials*, vol. 21, pp. 3133-3174, 2019.

- [40] D. Fooladivanda and C. Rosenberg, "Joint resource allocation and user association for heterogeneous wireless cellular networks," *IEEE Transactions on Wireless Communications*, vol. 12, pp. 248-257, 2012.
- [41] Y. Lin, W. Bao, W. Yu, and B. Liang, "Optimizing user association and spectrum allocation in HetNets: A utility perspective," *IEEE Journal on Selected Areas in Communications*, vol. 33, pp. 1025-1039, 2015.
- [42] S. Wang, H. Liu, P. H. Gomes, and B. Krishnamachari, "Deep reinforcement learning for dynamic multichannel access in wireless networks," *IEEE Transactions on Cognitive Communications and Networking*, vol. 4, pp. 257-265, 2018.
- [43] J. Zhu, Y. Song, D. Jiang, and H. Song, "A new deep-Q-learning-based transmission scheduling mechanism for the cognitive Internet of Things," *IEEE Internet of Things Journal*, vol. 5, pp. 2375-2385, 2017.
- [44] M. Chu, H. Li, X. Liao, and S. Cui, "Reinforcement learning-based multiaccess control and battery prediction with energy harvesting in IoT systems," *IEEE Internet of Things Journal*, vol. 6, pp. 2009-2020, 2018.
- [45] H. Ye, G. Y. Li, and B.-H. F. Juang, "Deep reinforcement learning based resource allocation for V2V communications," *IEEE Transactions on Vehicular Technology*, vol. 68, pp. 3163-3173, 2019.
- [46] U. Challita, L. Dong, and W. Saad, "Proactive resource management in LTE-U systems: A deep learning perspective," *arXiv preprint arXiv:1702.07031*, 2017.
- [47] M. Balazinska and P. Castro, "Ibm watson research center," *CRAWCAD*, Feb, 2003.
- [48] O. Naparstek and K. Cohen, "Deep multi-user reinforcement learning for dynamic spectrum access in multichannel wireless networks," in *GLOBECOM 2017-2017 IEEE Global Communications Conference*, 2017, pp. 1-7.
- [49] H. V. Hasselt, "Double Q-learning," in *Advances in neural information processing systems*, 2010, pp. 2613-2621.
- [50] Z. Wang, T. Schaul, M. Hessel, H. Van Hasselt, M. Lanctot, and N. De Freitas, "Dueling network architectures for deep reinforcement learning," *arXiv preprint arXiv:1511.06581*, 2015.
- [51] S. Liu, X. Hu, and W. Wang, "Deep reinforcement learning based dynamic channel allocation algorithm in multibeam satellite systems," *IEEE Access*, vol. 6, pp. 15733-15742, 2018.
- [52] N. Zhao, Y.-C. Liang, D. Niyato, Y. Pei, and Y. Jiang, "Deep reinforcement learning for user association and resource allocation in heterogeneous networks," in *2018 IEEE Global Communications Conference (GLOBECOM)*, 2018, pp. 1-6.
- [53] M. Chen, W. Saad, and C. Yin, "Liquid state machine learning for resource allocation in a network of cache-enabled LTE-U UAVs," in *GLOBECOM 2017-2017 IEEE Global Communications Conference*, 2017, pp. 1-6.
- [54] W. Maass, "Liquid state machines: motivation, theory, and applications," in *Computability in context: computation and logic in the real world*, ed: World Scientific, 2011, pp. 275-296.
- [55] M. Chen, M. Mozaffari, W. Saad, C. Yin, M. Debbah, and C. S. Hong, "Caching in the sky: Proactive deployment of cache-enabled unmanned aerial vehicles for optimized quality-of-experience," *IEEE Journal on Selected Areas in Communications*, vol. 35, pp. 1046-1061, 2017.
- [56] I. Szita, V. Gyenes, and A. Lőrincz, "Reinforcement learning with echo state networks," in *International Conference on Artificial Neural Networks*, 2006, pp. 830-839.
- [57] "Tyoku of china network video index."

فصل ۵

بررسی ملاحظات و ابزارهای مورد نیاز طراحی سیستمی جهت بکارگیری هوش مصنوعی

۱-۵- مقدمه


دسترسی پویا به پهنای باند یکی از مشخصه‌های اصلی رادیو شناختی است که در فصل قبل مورد بررسی قرار گرفت. همچنین در آن فصل نشان داده شد که مسائل دسترسی به طیف فرکانسی را می‌توان به صورت مساله تصمیم‌گیری مارکوف با مشاهده-پذیری جزئی در نظر گرفت و با ترکیب یادگیری تقویتی و یادگیری عمیق تحت عنوان روش DQL حل نمود.

در این فصل به دو موضوع محدودیت‌های بکارگیری روش‌های هوش مصنوعی و با تأکید بر یادگیری عمیق در سیستم‌های ارتباطی هوشمند و همچنین ملزومات و ابزارهای پیاده‌سازی آن، پرداخته می‌شود. بخشی از محدودیت‌ها به پیچیدگی محاسباتی روش‌های یادگیری برمی‌گردد که به صورت نمایی با افزایش عمق یادگیری (در روش‌های یادگیری عمیق) افزایش پیدا می‌کند. برای حل این پیچیدگی محاسباتی نیاز است که سخت‌افزارهای قوی و با قابلیت پردازش بالا مورد استفاده قرار گیرند. در کنار این سخت‌افزارها، کتابخانه‌های نرم‌افزاری نیز ارائه شده‌اند که این سخت‌افزارها و الگوریتم‌های مورد استفاده در روش‌های یادگیری ماشینی را پشتیبانی می‌کنند. همچنین در صورت استفاده از سخت‌افزارها و نرم‌افزارهای ضعیف دقت این روش‌ها ممکن است کاهش یابند؛ که در این خصوص روش‌هایی ارائه شده‌اند که می‌توانند حتی با استفاده از سخت‌افزارها و نرم‌افزارهای گوشه‌های همراه (که خیلی قوی هم نیستند) نیز یادگیری عمیق را پیاده‌سازی کنند.

۲-۵- محدودیت‌های بکارگیری DL^۱ در شبکه‌های بی‌سیم

هر چند DL دارای مزایای منحصر به فردی در حل مسائل شبکه‌های موبایل می‌باشد، این روش معایبی نیز دارد که بعضاً قابلیت استفاده از آن در این حوزه را محدود می‌سازد. به طور خاص این معایب شامل موارد زیر می‌باشند:

- (۱) عموماً روش‌های DL (که شامل DQL نیز می‌باشد) نسبت به نمونه‌ها و الگوهای متخاصم آسیب‌پذیر هستند [۱، ۲]. این موارد شامل ورودی‌های ساختگی هستند که به عمد برای به اشتباه انداختن مدل‌های یادگیری ماشین توسط یک مهاجم طراحی شده‌اند. در حالی که تشخیص این نمونه‌ها از نمونه‌های اصیل دشوار است، آن‌ها می‌توانند آستانه‌های عدم تطبیق یک مدل با شباهت‌های زیاد را فعال کنند. در شکل ۵۵ یک نمونه از چنین حمله‌ای نشان داده شده است. روش DL بخصوص CNNها نسبت به این نوع حمله‌ها آسیب‌پذیر هستند. این مورد می‌تواند کاربرد DL در سیستم‌های موبایل را نیز تحت تاثیر قرار دهد. برای مثال، ممکن است هرکس از این نقص استفاده کرده و حملات سایبری ترتیب دهند که آشکارسازهای مبتنی بر DL را تضعیف کنند [۳]. ساخت مدل‌هایی که نسبت به نمونه‌های متخاصم مقاوم باشند ضروری است اما همچنان یک چالش هستند.



شکل ۵۵. یک نمونه از حمله بر روی روش یادگیری عمیق

۲) الگوریتم‌های DL جعبه‌های سیاه بزرگی هستند و دارای تفسیرپذیری کمی هستند. موفقیت اصلی آن‌ها در دقت است و به همین دلیل می‌توانند عملکرد وظایف زیادی در زمینه‌های مختلف را ارتقاء دهند. با اینحال، با اینکه DL ماشین‌ها را قادر می‌سازد تا در وظایف خاصی دارای دقت بالایی باشند، هنوز دانش محدودی از اینکه چرا NNها تصمیم‌های خاصی را می‌گیرند وجود ندارد. این باعث می‌شود قابلیت بکارگیری DL بخصوص در اقتصاد شبکه محدود شود. در نتیجه، تجارت ترجیح می‌دهد تا با استفاده از روش‌های آماری به کار خود ادامه دهد و در عین حال دقت را قربانی کند. محققان این مساله را بازسازی کرده و برای حل این محدودیت DL به تلاش ادامه می‌دهند [۴-۶].

۳) DL به میزان زیادی به داده وابسته است که در بعضی مواقع بسیار مهم‌تر از خود مدل می‌باشد. مدل‌های عمیق می‌توانند از افزایش داده آموزشی بهره بیشتری ببرند [۷]. این مساله برای شبکه‌های موبایل یک مزیت است زیرا شبکه مقادیر متنابهی داده تولید می‌نماید. با این حال جمع‌آوری داده می‌تواند هزینه‌بر و دارای ملاحظات حریم خصوصی باشد. در نتیجه ممکن است دستیابی به اطلاعات کافی برای آموزش مدل دشوار باشد. در چنین سناریوهایی ممکن است مزایای استفاده از DL سنگین‌تر از هزینه‌ها شود.

۴) DL می‌تواند نیازمند محاسبات باشد. پردازش پیشرفته موازی مانند GPU¹ها و تراشه‌های با عملکرد بالا، ارتقاء و محبوبیت DL را تقویت می‌کنند و هنوز DL به میزان زیادی وابسته به آن‌ها است. شبکه‌های عصبی عمیق معمولاً به ساختارهای پیچیده‌ای برای رسیدن به دقت عملکرد رضایتبخش نیاز دارند. با این حال زمانی که شبکه‌های عصبی روی ادوات موبایل به کار می‌روند، محدودیت‌های انرژی و ظرفیت باید در نظر گرفته شوند. شبکه‌های عصبی خیلی عمیق ممکن است برای چنین سناریوهایی مناسب نباشند و این باعث می‌شود که به طور اجتناب‌ناپذیری دقت پایین بیاید.

۵) شبکه‌های عصبی عمیق معمولاً دارای ابرپارامترهای زیادی هستند و یافتن پیکربندی بهینه آن‌ها می‌تواند دشوار باشد. برای یک لایه محرمانه تنها، نیاز است تا ابرپارامترهایی برای تعداد، شکل، گام^۲ و کشش^۳ فیلترها و همچنین ارتباطات باقی‌مانده پیکربندی شوند. تعداد این ابرپارامترها به صورت نمایی با عمق مدل رشد می‌کند و می‌تواند عملکرد آن را تحت تاثیر قرار دهد. پیدا نمودن یک دسته مناسب از ابرپارامترها می‌تواند بسیار مشکل باشد. اولین راه حل توسط پلتفرم AutoML با استفاده از معماری جستجوی عصبی پیش‌رونده [۸] فراهم شده است، اما بهر حال این روش نیز بدون هزینه نیست.

برای حل تعدادی از مشکلاتی که بر شمرده شدند، روش DL نیاز به سیستم مشخص و حمایت نرم‌افزاری دارد که در ادامه به آن‌ها پرداخته شده است.

۳-۵- بکارگیری DL در شبکه‌های موبایل

سیستم‌های جدید مخابراتی نظیر 5G به دنبال فراهم نمودن نرخ انتقال بالا و تأخیر بسیار کم خدمات مخابراتی هستند تا QoE کاربران را بهبود بخشند. پیاده‌سازی DL برای ساخت هوش مصنوعی در این سیستم‌ها، برای مواجهه با محدودیت‌ها هزینه‌بر است زیرا نرم‌افزار و سخت‌افزار قدرتمندی برای حمایت از آموزش و استنتاج در تنظیمات پیچیده مورد نیاز است. خوشبختانه، چندین ابزار در حال ظهور هستند که منجر به استفاده راحت‌تر DL در شبکه‌های موبایل می‌شوند: ۱) پردازش موازی پیشرفته ۲) سیستم‌های یادگیری ماشین توزیع شده ۳) کتابخانه‌های اختصاص داده شده به DL ۴) الگوریتم‌های بهینه‌سازی سریع، ۵)


¹ Graphical Processing Unit

² Stride

³ Dilation

پردازش مه^۱. این ابزارها یک ساختار سلسله‌مراتبی را همانند آنچه در شکل ۵۶ نشان داده شده است شکل می‌دهند. هم‌افزایی‌هایی که بین آن‌ها شکل گرفته است مسائل شبکه را برای راه‌حل‌های مبتنی بر یادگیری عمیق هموار کرده است. با استفاده از این ابزارها هنگامی که یادگیری کامل شد، استنباط‌ها در مقیاس‌های زمانی میلی‌ثانیه انجام می‌شوند. همان‌طور که مشاهده می‌شود پردازش موازی و سخت‌افزار محاسبات مه برای یادگیری عمیق نقش پایه‌ای دارند. سیستم‌های یادگیری ماشین توزیع شده می‌توانند بر اساس آن‌ها ساخته شوند تا بتوانند استفاده در مقیاس وسیع از یادگیری عمیق را پوشش دهند. کتابخانه‌های یادگیری ماشین در سطح نرم‌افزار اجرا می‌شوند تا امکان پیاده‌سازی سریع یادگیری عمیق را ممکن سازند. بهینه‌سازهای سطح بالاتر برای آموزش شبکه‌های عصبی استفاده شده تا اهداف خاصی را برآورده کنند.

روش‌ها و ابزارهایی که تسهیلگر استفاده از یادگیری عمیق در سیستم‌های موبایل می‌شوند و ویژگی‌های آنها در جدول ۴ ارائه شده‌اند.



شکل ۵۶. ابزارهای ایجادکننده یادگیری عمیق

جدول ۴. روش‌ها و ابزار تسهیلگر کننده استفاده از یادگیری عمیق در سیستم‌های مخابراتی سیار

روش	هزینه اقتصادی	مصرف انرژی	بهبود کارایی	عملکرد	زمینه
پردازش موازی پیشرفته	متوسط (سخت‌افزار)	بالا	بالا	ایجاد آموزش سریع و موازی، استنباط مدل‌های یادگیری عمیق در کاربردهای موبایل	سرورهای موبایل، ایستگاه‌های کاری
سیستم‌های یادگیری ماشین توزیع شده	زیاد (سخت‌افزار)	زیاد	زیاد	پشتیبانی از چارچوب‌های یادگیری عمیق در سیستم‌های موبایل در مراکز داده	مراکز داده توزیع شده

¹ Fog computing

کتابخانه اختصاصی یادگیری عمیق	کم (نرم افزار)	وابسته به سخت افزار	متوسط	جعبه ابزارهای سطح بالا که مهندسان شبکه را قادر به ساخت معماری‌های یادگیری عمیق با اهداف خاص می‌کنند	سرورها و ادوات موبایل
الگوریتم‌های بهینه سازی سریع	کم (نرم افزار)	وابسته به سخت افزار	متوسط	سرعت دادن و پایدار نمودن فرآیند بهینه سازی مدل	آموزش معماری‌های عمیق
پردازش مه	متوسط (سخت افزار)	کم	متوسط	پشتیبانی از پردازش یادگیری عمیق مبتنی بر لبه	ادوات موبایل

در بخش‌های آتی این فصل به صورت مشروح به هریک از موارد فوق خواهیم پرداخت.

۱-۳-۵- پردازش موازی پیشرفته

در مقایسه با مدل‌های یادگیری ماشین قدیمی، شبکه‌های عصبی عمیق به طور قابل توجهی دارای فضاهای پارامتری، خروجی‌های میانی و تعداد مقادیر گرادیانی بزرگ‌تری هستند. هر کدام از این‌ها لازم است تا در هر مرحله آموزش بروزرسانی شود که نیازمند منابع پردازشی قوی است. فرآیندهای آموزش و استنباط شامل تعداد زیادی ضرب ماتریس و دیگر عملگرها است که می‌توانند به صورت انبوهی، موازی باشند. واحدهای پردازش مرکزی (CPU) قدیمی دارای هسته‌های محدودی هستند و در نتیجه می‌توانند موازی سازی را به صورت محدودی حمایت کنند. استفاده از CPUها برای پیاده سازی یادگیری عمیق بازدهی اندکی دارد و نمی‌تواند نیازهای با تأخیر کم سیستم‌های موبایل را پاسخگو باشد. این مشکل را با استفاده از قدرت GPUها می‌توان حل نمود. GPUها در اصل برای عملکرد بالا برای بازی‌های ویدیویی و نمایش گرافیکی طراحی شده‌اند اما تکنیک‌های جدید مانند $CUDA^1$ و کتابخانه $cuDNN^2$ که توسط NVIDIA ارائه شده‌اند به این سخت افزارها انعطاف پذیری اضافه کرده و به کاربران اجازه می‌دهند تا استفاده از آن‌ها را برای اهداف خود به دلخواه تنظیم کنند. معمولاً GPUها از هزاران هسته تشکیل شده‌اند که با ضرب سریع ماتریس‌ها که برای آموزش شبکه‌های عصبی مورد نیاز است کار می‌کنند. به همین دلیل پهنای باند حافظه بیشتری نسبت به CPUها دارند و به طور چشمگیری فرآیند یادگیری را سرعت می‌بخشند. پیشرفت‌های اخیر واحدهای پردازش تنسور پیشرفته TPU^3 که توسط گوگل ارائه شده‌اند، سرعت‌های ۱۵ تا ۳۰ برابر بیشترین سرعت‌های پردازش و ۳۰ تا ۸۰ برابر بازدهی نسبت به توان را در مقایسه با CUPها و GPUها نشان می‌دهند [۹]. اخیراً شبکه‌های عصبی پراکنده (D^2NN) که کاملاً براساس مخابرات نوری هستند در [۱۰] برای مصرف توان صفر و تأخیر صفر یادگیری عمیق معرفی شده‌اند. شبکه D^2NN از چندین لایه انتقال دهنده تشکیل شده است که نقطه‌ها روی این لایه‌ها مانند نرون‌ها در شبکه عصبی عمل می‌کنند. این ساختار به منظور بهینه سازی ضرایب انتقال / انعکاس آموزش داده می‌شود که مشابه وزن‌ها در یک شبکه عصبی هستند. پس از آموزش، لایه‌های انتقال دهنده با استفاده از چاپ سه بعدی تجسم پیدا کرده و می‌توانند بعد از آن برای استنباط استفاده شوند.

همچنین تعدادی جعبه ابزار وجود دارد که می‌توانند به بهینه سازی پردازشی یادگیری عمیق در سمت سرور کمک کنند. در [۱۱] روشی مبتنی بر Hash کردن معرفی شده است که می‌تواند نیازهای محاسباتی را در پیاده سازی شبکه عمیق کاهش دهد. در [۱۲] یک روش یادگیری تقویتی استفاده شده که ماشین‌ها را قادر می‌سازد جابجایی عملیات بهینه روی سخت افزارهای ترکیبی

¹ Compute Unified Device Architecture

² CUDA Deep Neural Network

³ Tensor Processing Unit

برای شبکه‌های عصبی عمیق را یاد بگیرند. این راه‌حل توانسته به سرعت محاسباتی ۲۰٪ بهتر از طراحی‌های متخصصان انسانی برای چنین جایایی دست پیدا کند.

این مسأله حائز اهمیت است که این سیستم‌ها براحتی استفاده می‌شوند، در نتیجه مهندسان شبکه موبایل لازم نیست تا سرورهای موبایل را برای پشتیبانی از محاسبات یادگیری عمیق از ابتدا بازسازی کنند. این باعث می‌شود که پیاده‌سازی یادگیری عمیق در سیستم‌های موبایل تحقق یابد و پردازش رشته‌های داده موبایل تسریع شوند.

۲-۳-۵- سیستم‌های یادگیری ماشین توزیع شده

داده موبایل از منابع غیرهمگن (مانند ادوات موبایل، کاوشگر شبکه و غیره) جمع‌آوری شده و در مراکز داده توزیع شده ذخیره می‌شود. با افزایش حجم داده، نمی‌توان همه داده‌های موبایل را به یک مرکز داده‌ی مرکزی برای اجرای کاربردهای یادگیری عمیق انتقال داد. برای اجرای الگوریتم‌های یادگیری ماشین در مقیاس شبکه، به سیستم‌های یادگیری ماشین توزیع شده با پشتیبانی واسطه‌های مختلف (مانند سیستم عامل‌ها، زبان‌های برنامه‌نویسی، کتابخانه‌ها) نیاز است تا بتوان آموزش و ارزیابی مدل‌های عمیق را روی سرورهای توزیع شده از لحاظ جغرافیایی به طور همزمان با بازدهی بالا و سرپای کم انجام داد.

به کارگیری یادگیری عمیق با روشی توزیع شده، به ناچار چندین مشکل در سطح سیستم ایجاد می‌کند که نیازمند ویژگی‌های زیر می‌باشد:

- (۱) سازگاری: تضمین اینکه پارامترهای مدل و فرآیندهای محاسباتی در کلیه دستگاه‌ها با یکدیگر سازگار باشند.
- (۲) تحمل خطا: برخورد مؤثر با خرابی‌های تجهیزات در سیستم‌های یادگیری ماشین توزیع شده در مقیاس بزرگ.
- (۳) ارتباطات: بهینه‌سازی ارتباط بین گره‌ها در یک خوشه و جلوگیری از تراکم و شلوغی.
- (۴) ذخیره‌سازی: طراحی مکانیسم‌های مؤثر ذخیره‌سازی متناسب با محیط‌های مختلف (به عنوان مثال خوشه‌های توزیع شده، ماشین‌های منفرد، GPUها) با توجه به ورودی/خروجی و تنوع پردازش داده‌ها.
- (۵) مدیریت منابع: اختصاص بار کاری و اطمینان از این که گره‌ها با هماهنگی خوبی کار می‌کنند.
- (۶) مدل برنامه نویسی: طراحی واسطه‌های برنامه‌نویسی برای پشتیبانی از چندین زبان برنامه‌نویسی.

چندین سیستم یادگیری ماشین توزیع شده وجود دارند که یادگیری عمیق را در کاربردهای شبکه موبایل تسهیل می‌کنند. در [۱۳] یک سیستم توزیع شده به نام MLbase معرفی شده که می‌تواند الگوریتم‌های یادگیری ماشین را هوشمندانه مشخص، انتخاب، بهینه‌سازی و موازی سازد. سیستم آنها به غیرمتخصصین کمک می‌کند تا طیف گسترده‌ای از روش‌های یادگیری ماشین را به کار گیرند و امکان بهینه‌سازی و اجرای برنامه‌های ML را در سرورهای مختلف فراهم می‌کنند.

در [۱۴] یک سیستم ML توزیع شده از لحاظ جغرافیایی به نام Gaia ارائه شده که با استفاده از یک مکانیزم ارتباطی پیشرفته روی شبکه‌های گسترده، ضمن حفظ دقت الگوریتم‌های ML، تنگنای نرخ انتقال را شکسته است. این سیستم پیشنهادی بدون اینکه نیاز به تغییرات مهمی در خود الگوریتم ML داشته باشد از رابط‌های متنوع ML پشتیبانی می‌کند (به عنوان مثال TensorFlow و Caffe). همچنین این سیستم امکان استفاده از کاربردهای یادگیری عمیق پیچیده را روی شبکه‌های موبایل در مقیاس بزرگ فراهم می‌نماید.

در [۱۵] پلتفرم یادگیری ماشین در مقیاس بزرگ برای پشتیبانی از کاربردهای کلان داده^۱ ارائه شده است. معماری آن به مدل و موازی‌سازی داده مؤثری منجر می‌شود که همگام‌سازی حالت پارامتر با هزینه کم، ارتباط را امکان‌پذیر می‌سازد. در [۱۶] یک موتور گرافیکی توزیع شده برای ML به نام TUX^۲ پیشنهاد داده شده تا از بهینه‌سازی طرح‌بندی داده بین دستگاه‌ها پشتیبانی

^۱ Big data

کرده و ارتباطات بین ماشین را کاهش دهد. این سیستم عملکرد چشمگیری را از نظر زمان اجرا و همگرایی در یک مجموعه داده بزرگ با حداکثر ۶۴ میلیارد لبه نشان داده است.

۳-۳-۵- کتابخانه‌های اختصاصی یادگیری عمیق

ایجاد یک مدل یادگیری عمیق از ابتدا می‌تواند برای مهندسين پیچیده باشد زیرا این امر علاوه بر کدگذاری CUDA برای موازی‌سازی GPU، به تعریف رفتارهای پیش‌رونده و عملیات گرادین انتشار در هر لایه نیاز دارد. با افزایش محبوبیت در یادگیری عمیق، چندین کتابخانه اختصاصی این روند را ساده کرده‌اند. بیشتر این جعبه‌ابزارها قابلیت کار با چندین زبان برنامه‌نویسی را دارا هستند و با شتابگر GPU و پشتیبانی مشتق‌گیری خودکار ساخته شده‌اند. این کار نیاز به تعریف ساخته‌شده از گرادین انتشار را از بین می‌برد. در ادامه هریک از این کتابخانه‌ها و ویژگی‌های آنها توضیح داده شده‌اند:

- TensorFlow: یک کتابخانه یادگیری ماشین است که توسط گوگل ساخته شده است [۱۷]. این کتابخانه با گسترش نمودارهای محاسباتی روی CPU، GPU و حتی دستگاه‌های موبایل [۱۸]، امکان پیاده‌سازی ML در معماری‌های واحد و توزیع شده را فراهم می‌نماید. این امر اجرای سریع شبکه‌های عصبی عمیق را در هر دو سرویس ابر و مه فراهم می‌کند. اگرچه در اصل برای کاربردهای یادگیری ماشین و شبکه‌های عصبی عمیق طراحی شده است، TensorFlow برای سایر اهداف تحقیقاتی مبتنی بر داده نیز مناسب است. این نرم افزار از TensorBoard که یک ابزار پیشرفته تجسم برای کمک به کاربران در درک ساختار مدل‌ها و جریان‌های داده و انجام اشکال‌زدایی است را پشتیبانی می‌کند. مستندات و آموزش‌های دقیقی برای Python وجود دارد، در حالی که سایر زبان‌های برنامه‌نویسی مانند C، Java و Go نیز در آن پشتیبانی می‌شوند. در حال حاضر این محبوب‌ترین کتابخانه یادگیری عمیق است. همچنین چندین جعبه ابزار اختصاصی یادگیری عمیق برای ارائه رابط‌های برنامه‌نویسی سطح بالاتر از جمله Keras6، Luminoth 7 و TensorLayer، با بر ساخته شدن بر روی TensorFlow، منتشر شده‌اند [۱۹].

- Theano: یک کتابخانه Python است که اجازه می‌دهد به صورت مؤثر تعریف، بهینه‌سازی و ارزیابی محاسبات عددی شامل داده‌های چند بعدی انجام شود [۲۰]. این کتابخانه دو حالت CPU و GPU را پشتیبانی می‌کند و به کاربران این امکان را می‌دهد تا برنامه‌های خود را با ماشین‌های جداگانه پیاده‌سازی کنند. با اینحال، یادگیری Theano دشوار است و ایجاد یک شبکه عصبی با آن مستلزم صرف زمان کامپایل قابل توجهی است. اگرچه Theano دارای یک پایگاه کاربر بزرگ و یک انجمن پشتیبانی است و در برهه‌ای یکی از محبوب‌ترین ابزارهای یادگیری عمیق بود، محبوبیت آن به سرعت در حال کاهش است، زیرا ایده‌ها و ویژگی‌های اصلی آن توسط TensorFlow ارائه شده‌اند.

- Caffe(2): یک چارچوب اختصاصی یادگیری عمیق است که توسط Berkeley AI Research ساخته شده است و آخرین نسخه یعنی Caffe2، اخیراً توسط فیس‌بوک منتشر شده است [۲۱]. Caffe2 با دربرگرفتن تمام مزایای نسخه قدیمی، به یک چارچوب بسیار انعطاف‌پذیر تبدیل شده است که به کاربران این امکان را می‌دهد تا مدل‌های خود را به صورت کارآمد بسازند. همچنین امکان آموزش شبکه‌های عصبی بر روی چندین GPU در سیستم‌های توزیع شده را فراهم می‌سازد و از پیاده‌سازی‌های یادگیری عمیق در سیستم‌عامل‌های موبایل مانند iOS و Android پشتیبانی می‌کند. بنابراین، این پتانسیل را دارد که نقش مهمی در محاسبات لبه در موبایل‌های آینده داشته باشد.

- (Py)Torch: یک چارچوب محاسبات علمی با پشتیبانی گسترده برای مدل‌ها و الگوریتم‌های یادگیری ماشین است [۲۲]. در ابتدا به زبان Lua ساخته شده بود، اما بعداً توسعه دهندگان نسخه Python ارتقاء داده شده را ارائه

کردند [۲۳]. در اصل PyTorch یک جعبه ابزار سبک است که می‌تواند بر روی سیستم‌های تعبیه شده مانند تلفن‌های هوشمند اجرا شود، اما فاقد مستندات جامع است. از آنجا که ساخت شبکه‌های عصبی در PyTorch آسان است، محبوبیت این کتابخانه به سرعت در حال رشد است. همچنین مدل‌ها و ماژول‌های غنی از پیش آموزش داده شده‌ای را ارائه می‌دهد که استفاده مجدد و ترکیب آنها آسان است. PyTorch اکنون بطور رسمی توسط فیس‌بوک پشتیبانی می‌شود و عمدتاً برای اهداف تحقیقاتی به کار می‌رود.

• MXNET: یک کتابخانه یادگیری عمیق قابل انعطاف و مقیاس پذیر است که واسطه‌هایی را برای چندین زبان فراهم می‌کند (به عنوان مثال ++C, Python, Matlab, R و غیره) [۲۴]. این کتابخانه سطوح مختلفی از مدل‌های یادگیری ماشین از رگرسیون لجستیک گرفته تا GANها را پشتیبانی می‌کند. MXNET محاسبه سریع عددی را برای هر دو دستگاه واحد و اکوسیستم‌های توزیع شده فراهم می‌نماید. این کتابخانه کارکردهایی که معمولاً در یادگیری عمیق مورد استفاده قرار می‌گیرند را به توابع سطح بالا گره می‌زند به گونه‌ای که شبکه‌های عصبی استاندارد بدون تلاش برنامه نویسی قابل توجهی به راحتی ساخته می‌شوند. با اینحال، یادگیری نحوه کار با این جعبه ابزار در بازه زمانی کوتاه دشوار است، از این رو تعداد کاربرانی که این کتابخانه را ترجیح می‌دهند نسبتاً اندک است. MXNET چارچوب یادگیری عمیق رسمی در آمازون می‌باشد.

همچنین علیرغم محبوبیت کمتر، کتابخانه‌های یادگیری عمیق بسیار عالی دیگری مانند CNTK، DeepLearning4j، Blocks، Glue و Lasagne وجود دارند که در سیستم‌های تلفن همراه نیز قابل استفاده هستند. انتخاب بین آنها با توجه به کاربردهای خاص متفاوت است. برای مبتدیان هوش مصنوعی که قصد دارند از یادگیری عمیق برای حوزه شبکه استفاده کنند، PyTorch گزینه خوبی است، زیرا ساختن شبکه‌های عصبی در این محیط به راحتی انجام می‌شود و کتابخانه برای GPUها به خوبی بهینه شده است. از طرف دیگر، اگر برای افرادی که فعالیت‌های پیشرفته و پیاده‌سازی گسترده را دنبال می‌کنند، ممکن است Tensorflow انتخاب بهتری باشد، زیرا به خوبی تثبیت شده است و از نگهداری خوبی برخوردار می‌باشد و آزمون بسیاری از پروژه‌های صنعتی Google را پشت سر گذاشته است. در جدول ۵ خلاصه‌ای از کتابخانه‌ها و مزایا و معایب هر یک ارائه شده است.

جدول ۵. خلاصه و مقایسه کتابخانه‌های نرم‌افزاری یادگیری عمیق

کتابخانه	محبوبیت	پشتیبانی توسط موبایل	معایب	مزایا	رابط در دسترس	زبان سطح پایین	کتابخانه
Karas, TensorLayer, Laminoth	زیاد	بلی	۱- مشکل برای عیب‌یابی ۲- سنگینی بسته ۳- مشکل برای ورود مبتدیان	۱- جامعه بزرگ کاربران ۲- دارای راهنمای مناسب ۳- عملکرد جامع ۴- فراهم کردن ابزار تجسم ۵- پشتیبانی از چندین رابط ۶- فراهم کردن آموزش توزیع شده و ایجاد مدل	Python, Java, C, C++, Go	C++	TensorFlow
Karas, Blocks, Lasagne	کم	خیر	۱- مشکل برای یادگیری ۲- زمان زیاد کامپایل ۳- دیگر نگهداری نمی‌شود.	۱- انعطاف پذیری ۲- سرعت اجرای خوب	Python	Python	Theano

Cafee(2)	C++	Python , Matlab	۱- زمان اجرای سریع ۲- پشتیبانی از چندین پلتفرم	۱- پایگاه کاربری کوچک ۲- راهنمای ساده	بلی	متوسط	-
(Py)Troch	Lua, C++	Lua, Python , C, C++	۱- آسانی در ساخت مدل ۲- انعطاف پذیر ۳- دارای راهنمای مناسب ۴- اشکال‌یابی آسان ۵- دسترسی به مدل‌های آموزش داده شده زیاد ۶- موای سازی داده اعلامی	۱- دارای منابع محدود ۲- عدم ارائه مدل ۳- عدم ابزار تجسم	بلی	زیاد	-
MXNET	C++	C++, Python , Matlab , R	۱- سبکی ۲- بهینه شده از لحاظ حافظه ۳- آموزش سریع ۴- ارائه مدل ساده ۵- مقایسه پذیری بالا	۱- پایگاه کاربری کوچک ۲- مشکل برای یادگیری	بلی	کم	Gluon

۴-۳-۵- الگوریتم‌های سریع مورد استفاده در بهینه‌سازی

توابع هدفی که در یادگیری عمیق بهینه می‌شوند معمولاً پیچیده هستند، زیرا شامل تعداد بسیار زیادی از توابع احتمال مبتنی بر داده هستند. با افزایش عمق مدل، چنین توابعی معمولاً دارای ویژگی‌هایی با غیرمحدب بودن زیاد، چندین مینیمم محلی، نقاط بحرانی و نقاط زینی هستند. در این حالت، الگوریتم‌های مرسوم ^۱ (SGD) از نظر همگرایی آهسته هستند، که باعث می‌شود کاربرد آنها در سیستم‌های موبایل دارای محدودیت تأخیر، محدود شود. برای غلبه بر این مشکل و تثبیت روند بهینه‌سازی، بسیاری از الگوریتم‌ها SGD سنتی را تکامل بخشیده و به مدل‌های شبکه عصبی اجازه می‌دهند تا سریعتر برای برنامه‌های موبایل آموزش داده شوند. اصول اصلی در پس‌زمینه این بهینه‌سازها خلاصه شده و در جدول ۶ مقایسه‌ای بین آنها انجام شده است. در ادامه جزئیات عملکرد آنها مورد بررسی قرار می‌گیرد.

۱-۴-۳-۵ الگوریتم‌های SGD با سرعت یادگیری ثابت

در [۲۵] نوعی از بهینه ساز SGD با ممان نستروف^۲ ارائه شده که گرادینان‌ها را پس از اعمال سرعت فعلی ارزیابی می‌کند. این روش همگرایی سریع‌تری را هنگام بهینه سازی توابع محدب نشان می‌دهد. روش دیگر Adagrad است که یادگیری تطبیقی را برای مدل سازی پارامترها با توجه به فرکانس بروزرسانی آنها اجرا می‌کند. این روش برای پردازش داده های کمیاب مناسب است و به طور قابل توجهی از SGD از لحاظ استحکام بهتر می‌باشد [۲۶]. Adadelta الگوریتم سنتی Adagrad را بهبود می بخشد و این امکان را بوجود می‌آورد تا سریعتر همگرا شود و به یک نرخ یادگیری کلی وابسته نیست [۲۷]. RMSprop روشی مبتنی بر SGD است که توسط G. Hinton معرفی شده است. RMSprop نرخ یادگیری را به یک تقریب نمایی از متوسط گرادینان‌ها تقسیم می‌کند و نیازی به تعیین نرخ یادگیری برای هر مرحله آموزشی ندارد [۲۸].

۲-۴-۳-۵ الگوریتم‌های SGD با سرعت یادگیری تطبیقی

¹ Stochastic Gradient Descent

^۲ Nesterov's momentum

در یک بهینه‌ساز با سرعت یادگیری تطبیقی به نام Adam پیشنهاد شده که ممان را با استفاده از ممان مرتبه اول گرادیان می‌سازد. این الگوریتم از نظر همگرایی سریع، بسیار مقاوم به ساختارهای مدل است و اگر کسی نتواند تصمیم بگیرد که از کدام الگوریتم استفاده کند، اولین انتخاب در نظر گرفته می‌شود. با ترکیب ممان در Adam، Nadam محدودیت‌های قوی‌تری برای گرادیان‌ها اعمال می‌کند، که همگرایی سریع‌تر را ممکن می‌نماید [۲۹].

۳-۴-۵ دیگر بهینه‌سازها

در [۳۰] نشان داده شده است که فرایند بهینه‌سازی را می‌توان حتی به صورت پویا نیز فرا گرفت. کاهش گرادیان به عنوان یک مسأله یادگیری قابل آموزش تلقی شده که توانایی تعمیم خوبی در آموزش شبکه عصبی را از خود نشان می‌دهد. در [۳۱] الگوریتم آموزشی متناسب با سیستم‌های توزیع شده پیشنهاد داده شده است. در فرآیند آموزش مقادیر شناور گرادیان به صورت ۱-، ۰ و ۱+ کوانتیزه شده، که به لحاظ تئوری به ۲۰ برابر ارتباطات گرادیانی کمتری بین گره‌ها نیاز دارند. نویسندگان اثبات می‌کنند که این مکانیسم تقریب گرادیان اجازه می‌دهد تا تابع هدف با احتمال ۱ به نقطه بهینه همگرا گردد و در آزمایش‌های آنها فقط ۲٪ کاهش دقت در آموزش روی میانگین GoogleLeNet مشاهده می‌شود [۳۲]. در [۳۳] از یک مکانیسم خصوصی دیفرانسیلی برای مقایسه گرادیان‌های آموزشی و اعتبارسنجی به منظور استفاده مجدد از نمونه‌ها و تازه نگه داشتن آنها، استفاده شده است. این می‌تواند مساله overfitting حین آموزش را به طور چشمگیری کاهش دهد. در جدول ۶ الگوریتم‌های بهینه‌سازی خلاصه شده و مورد مقایسه با یکدیگر قرار گرفته‌اند.

جدول ۶. خلاصه‌سازی و مقایسه مزایا و معایب الگوریتم‌های بهینه‌سازی

معایب	مزایا	ایده اصلی	الگوریتم بهینه‌سازی
۱- نیاز به تنظیم نرخ کلی یادگیری ۲- الگوریتم ممکن است در نقاط مینیمم محلی ماندگار شود. ۳- کند در همگرایی ۴- غیر پایدار	آسانی پیاده‌سازی	گرادیان دسته‌های کوچک ^۱ را به طور تکراری محاسبه کرده و پارامترها را به روز می‌کند	SGD
نیاز به تنظیم یک نرخ یادگیری	۱- پایداری ۲- یادگیری سریع‌تر ۳- می‌تواند از مینیمم‌های محلی فرار کند.	ممانی را برای حفظ آخرین جهت گرادیان برای بروزرسانی بعدی معرفی می‌کند	ممان نستروف
۱- نیاز به تعیین یک نرخ کلی یادگیری ۲- گرادیان‌ها به تنظیم‌کننده حساس هستند.	۱- نرخ یادگیری متناسب با هر پارامتر ۲- مدیریت خوب گرادیان‌های پراکنده	اعمال نرخ یادگیری مختلف برای پارامترهای مختلف	Adagard
امکان ماندن در یک مینیمم محلی	۱- متکی به نرخ یادگیری کلی نیست.	ارتقای Adagard با اعمال یک نرخ یادگیری خودسازگار	Adadelata

^۱ Mini-batch

		۲- سرعت همگرایی بالاتر ۳- دارای ابرپارامترهای کمتر برای تنظیم	
RMSprop	استفاده از مجذور مجموع مربعات (RMS) به عنوان یک محدودیت نرخ یادگیری	۱- نرخ یادگیری متناسب با هر پارامتر ۲- نرخ یادگیری کاهش پیدا نمی‌کند. ۳- در آموزش RNN خوب عمل می‌کند.	۱- نیاز به تعیین نرخ کلی یادگیری ۲- در مدیریت گرادین‌های پراکنده خوب عمل نمی‌کند.
Adam	از یک مکانیسم ممان برای ذخیره یک میانگین باکاهش نمایی از گرادین‌های گذشته استفاده می‌کند.	۱- نرخ یادگیری متناسب با هر پارامتر ۲- مدیریت خوب گرادین‌های پراکنده و مسائل غیر ایستا ۳- بهینه شده از لحاظ حافظه ۴- همگرایی سریع	ممکن است در حین اجرا ناپایدار گردد.
Nadam	استفاده از گرادین‌های تسریع شده نستروف در Adam	خوب عمل کردن در آموزش RNN	-
یادگیری بهینه‌سازی	مساله بهینه‌سازی به عنوان یک مساله یادگیری با استفاده از RNN تلقی می‌شود.	نیازی به طراحی یادگیری به صورت دستی ندارد.	نیاز به RNN اضافی برای یادگیری در بهینه‌ساز دارد.
یادگیری کوانتیزه	گرادین‌ها را به 0، 1 و -1 کوانتیزه می‌کند.	۱- مناسب برای یادگیری توزیع شده ۲- بهینه شده از لحاظ حافظه	از دست دادن دقت یادگیری
کاهش گرادین پایدار	استفاده از یک مکانیسم خصوصی تفاضلی برای مقایسه گرادین‌های آموزش و معتبر به منظور استفاده مجدد از نمونه‌ها و تازه نگه‌داشتن آن‌ها	۱- پایداری بیشتر ۲- overfitting کمتر ۳- همگرایی سریع‌تر نسبت به SGD	تنها برای توابع محدب معتبر است.

۵-۳-۵- پردازش مه

الگوی محاسبه مه، فرصتی جدید برای اجرای یادگیری عمیق در سیستم‌های موبایل ارائه می‌دهد. پردازش مه به مجموعه تکنیک‌هایی اطلاق می‌شود که امکان استفاده از برنامه‌ها یا ذخیره داده‌ها در لبه شبکه‌ها [۳۴] به عنوان مثال، روی دستگاه‌های تلفن همراه مجزا را دارند. این امر سربار ارتباطات، ترافیک داده، تأخیر طرف کاربر و بارهای محاسباتی سمت سرور را کاهش می‌دهد [۳۵، ۳۶]. تعریف رسمی محاسبات مه در [۳۷] آورده شده است، به این صورت که تعداد زیادی دستگاه ناهمگن (بی سیم و گاهی اوقات خودکار) پراکنده و غیرمتمرکز [که] ارتباط برقرار می‌کنند و به طور بالقوه بین آنها و شبکه همکاری وجود دارد تا بتوانند وظایف ذخیره‌سازی و پردازشی را بدون دخالت اشخاص ثالث انجام دهند. به بیان دقیق‌تر، می‌تواند به تلفن‌های هوشمند، دستگاه‌های پوشیدنی و وسایل نقلیه‌ای اطلاق شود که داده‌ها را ذخیره، تجزیه و تحلیل و تبادل می‌کنند تا بار ابر را کاهش داده و کارهای حساس به تأخیر بیشتری را انجام دهند. از آنجا که محاسبات مه شامل استقرار در لبه است، دستگاه‌های شرکت‌کننده

معمولاً دارای منبع محاسبات و توان باتری محدودی هستند. بنابراین، سخت افزار و نرم افزار ویژه‌ای برای اجرای یادگیری عمیق مورد نیاز است که در ادامه به آن پرداخته می‌شود.

۶-۳-۵- سخت افزار

پژوهش‌هایی صورت گرفته است که تلاش می‌کنند محاسبات یادگیری عمیق را از طرف ابر به سمت دستگاه‌های تلفن همراه منتقل کنند [۳۸]. به عنوان مثال در [۳۹] یک پردازشگر سیار به نام شبکه عصبی neXt ایجاد شده که اجرای شبکه‌های عصبی عمیق را در دستگاه‌های تلفن همراه تسریع می‌کند، در حالی که مصرف انرژی کم را حفظ می‌نماید. در [۴۰] یک پردازنده یادگیری عمیق قابل برنامه‌ریزی با توان پایین برای استفاده از هوش موبایل در دستگاه‌های لبه معرفی شده است. سخت افزار آن فقط ۲۸۸ میکرووات توان مصرف می‌کند اما به بازدهی 374 GOPS/W دست می‌یابد. یک تراشه سیناپس عصبی^۱ به نام TrueNorth توسط IBM پیشنهاد شده است [۴۱]. راه حل آنها به دنبال پشتیبانی برنامه‌های فشرده محاسباتی بر روی دستگاه‌های تلفن همراه دارای باتری است. Qualcomm یک موتور پردازش عصبی Snapdragon را معرفی کرده است تا بتواند بهینه‌سازی محاسبات یادگیری عمیق را متناسب با دستگاه‌های تلفن همراه انجام دهد. Movidius با همکاری نزدیک با گوگل، یک چارچوب محاسبات شبکه عصبی تعبیه شده ایجاد کرده است که اجازه می‌دهد یادگیری عمیق با سفارش کاربر در لبه شبکه‌های تلفن همراه به کار گرفته شود. محصولات آنها می‌توانند در حالی که با نیازهای بسیار کم مصرف کار می‌کنند، به کارایی کافی در زمان اجرا برسند. این برنامه همچنین از چهارچوب‌های مختلف مانند TensorFlow و Caffe پشتیبانی می‌کند و انعطاف بیشتری را در انتخاب میان ابزارها برای کاربران فراهم می‌نماید. اخیراً هواوی به طور رسمی Kirin 970 را به عنوان یک سیستم محاسبات هوش مصنوعی موبایل روی تراشه معرفی کرده است. این چارچوب ابتکاری آنها شامل واحدهای اختصاصی پردازش عصبی (NPU)^۲ است که محاسبات شبکه عصبی را بطور چشمگیری تسریع می‌کند و امکان طبقه‌بندی ۲۰۰۰ تصویر در ثانیه در دستگاه‌های تلفن همراه را فراهم می‌سازد.

۷-۳-۵- نرم افزار

گذشته از این پیشرفت‌های سخت‌افزاری، پلتفرم‌های نرم‌افزاری نیز وجود دارند که به دنبال بهینه‌سازی یادگیری عمیق در دستگاه‌های موبایل هستند [۴۲]. این پلتفرم‌ها در جدول ۷ با هم مقایسه شده‌اند. علاوه بر نسخه موبایل TensorFlow و Caffe، Tencent یک چارچوب استنتاج شبکه عصبی سبک با کارایی بالا و متناسب با پلتفرم‌های تلفن همراه را منتشر کرد که به پردازش واحد پردازنده متکی است. این جعبه ابزار عملکرد بهتری نسبت به تمام پلتفرم‌های منبع باز مبتنی بر CPU از نظر سرعت استنتاج دارد. اپل Core ML یک چارچوب یادگیری ماشین خصوصی را برای تسهیل پیاده‌سازی یادگیری عمیق موبایل روی iOS 11 ایجاد کرده است. این امر کمک شایانی به توسعه‌دهندگانی که مایل به استقرار مدل‌های ML در تجهیزات اپل هستند، می‌نماید. در پژوهشی دیگر، یک چارچوب یادگیری عمیق به نام DeepSense که به پردازش داده‌های مربوط به سنجش تلفن همراه اختصاص داده شده ایجاد شده است، که یک جعبه ابزار عمومی یادگیری ماشین را فراهم می‌کند و دارای طیف گسترده‌ای از برنامه‌های لبه است. این چارچوب از مصرف انرژی متوسط و تأخیر کمی برخوردار است، بنابراین برای استفاده روی تلفن‌های هوشمند مناسب است. تکنیک‌ها و جعبه ابزارهای ذکر شده در بالا، بکارگیری شیوه‌های یادگیری عمیق در برنامه‌های کاربردی شبکه تلفن همراه را امکان‌پذیر می‌سازند.

^۱ Neurosynaptic

^۲ Neural Processing Unit

جدول ۷. مقایسه و جمع‌بندی پلتفرم‌های یادگیری عمیق موبایل

منبع باز بودن	سازگاری با موبایل	اندازه کد	سرعت	سخت‌افزار پشتیبانی‌کننده	سازنده	پلتفرم
بلی	متوسط	متوسط	کند	CPU	گوگل	TensorFlow
بلی	متوسط	بزرگ	کند	CPU	فیسبوک	Caffe
بلی	خوب	کوچک	متوسط	CPU	Tencent	ncnn
خیر	فقط iOS11	کوچک	سریع	CPU/GPU	اپل	Core ML
خیر	متوسط	غیر مشخص	متوسط	CPU	Yao و همکاران	DeepSense

۴-۵- جمع‌بندی فصل ۵

در این فصل با تاکید بر روش یادگیری عمیق، به محدودیت‌هایی که پیش روی آن است و همچنین روش‌هایی که برای پیاده‌سازی آن به کار می‌روند پرداخته شد. برخی از محدودیت‌ها مربوط به نوع و حجم داده است؛ برای مثال ممکن است برخی از داده‌ها بتوانند یادگیری عمیق را سردرگم کرده و منجر به نتایج غلطی شوند یا حجم داده به میزان کافی نبوده و مدل درستی تشکیل نگیرد. محدودیت‌های دیگر ناشی از پیچیدگی یادگیری عمیق است که هم نیاز به سخت‌افزار و نرم‌افزارهای قوی دارد و هم با افزایش عمق یادگیری تعداد پارامترها و حجم محاسبات پردازشی افزایش یافته و تفسیرپذیری و قابلیت درک پاسخ مشکل‌تر می‌شود.

برای پیاده‌سازی یادگیری عمیق به سخت‌افزارها و نرم‌افزارهای قویی برای پردازش نیاز است ولی تکنولوژی‌های سخت‌افزاری و نرم‌افزاری جدیدی نیز برای پیاده‌سازی این روش بر روی گوشی‌های همراه ارائه شده‌اند. می‌توان گفت دو سخت‌افزار به کار رفته در پردازش موازی و پردازش مه به عنوان زیربنا برای پردازش‌های یادگیری عمیق بر روی گوشی‌های همراه به کار می‌روند. سیستم‌های یادگیری ماشین توزیع شده بر روی این سخت‌افزارها قابل پیاده‌سازی هستند. این سیستم‌ها زمانی که داده‌ها از منابع مختلفی جمع‌آوری می‌شوند و به اصلاح سیستم ناهمگن است بسیار مفید می‌باشند.

همچنین به منظور افزایش سرعت همگرایی الگوریتم‌های مرسوم در یادگیری عمیق، الگوریتم‌های بهینه‌سازی سریعی معرفی شده‌اند. کتابخانه‌های اختصاصی نیز با فراهم نمودن مدل‌های پیچیده که طراحی آن‌ها از ابتدا می‌تواند وقت گیر باشد، پیاده‌سازی یادگیری عمیق را تسریع می‌کنند. الگوریتم‌های یادگیری سریع به همراه کتابخانه‌های اختصاصی و پلتفرم‌های یادگیری عمیق از جمله روش‌های نرم‌افزاری هستند که بر روی سخت‌افزارهای اشاره شده در بالا، اجرا می‌شوند. این روش‌ها نشان داده‌اند که یادگیری عمیق بر روی گوشی‌های همراه نیز قابل پیاده‌سازی است و کارهای تحقیقاتی بر روی این زمینه همچنان ادامه دارد.

مراجع فصل ۵

- [1] V. Behzadan and A. Munir, "Vulnerability of deep reinforcement learning to policy induction attacks," in *International Conference on Machine Learning and Data Mining in Pattern Recognition*, 2017, pp. 262-275.
- [2] A. Nguyen, J. Yosinski, and J. Clune, "Deep neural networks are easily fooled: High confidence predictions for unrecognizable images," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2015, pp. 427-436.
- [3] P. Madani and N. Vljajic, "Robustness of deep autoencoder in intrusion detection under adversarial contamination," in *Proceedings of the 5th Annual Symposium and Bootcamp on Hot Topics in the Science of Security*, 2018, pp. 1-8.
- [4] D. Bau, B. Zhou, A. Khosla, A. Oliva, and A. Torralba, "Network dissection: Quantifying interpretability of deep visual representations," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2017, pp. 6541-6549.
- [5] S. Chakraborty, R. Tomsett, R. Raghavendra, D. Harborne, M. Alzantot, F. Cerutti, et al., "Interpretability of deep learning models: a survey of results," in *2017 IEEE SmartWorld, Ubiquitous Intelligence & Computing, Advanced & Trusted Computed, Scalable Computing & Communications, Cloud & Big Data Computing, Internet of People and Smart City Innovation (SmartWorld/SCALCOM/UIC/ATC/CBDCom/IOP/SCI)*, 2017, pp. 1-6.
- [6] M. Wu, M. C. Hughes, S. Parbhoo, M. Zazzi, V. Roth, and F. Doshi-Velez, "Beyond sparsity: Tree regularization of deep models for interpretability," in *Thirty-Second AAAI Conference on Artificial Intelligence*, 2018.
- [7] L. Perez and J. Wang, "The effectiveness of data augmentation in image classification using deep learning," *arXiv preprint arXiv:1712.04621*, 2017.
- [8] C. Liu, B. Zoph, M. Neumann, J. Shlens, W. Hua, L.-J. Li, et al., "Progressive neural architecture search," in *Proceedings of the European Conference on Computer Vision (ECCV)*, 2018, pp. 19-34.
- [9] N. P. Jouppi, C. Young, N. Patil, D. Patterson, G. Agrawal, R. Bajwa, et al., "In-datacenter performance analysis of a tensor processing unit," in *Proceedings of the 44th Annual International Symposium on Computer Architecture*, 2017, pp. 1-12.
- [10] X. Lin, Y. Rivenson, N. T. Yardimci, M. Veli, Y. Luo, M. Jarrahi, et al., "All-optical machine learning using diffractive deep neural networks," *Science*, vol. 361, pp. 1004-1008, 2018.
- [11] R. Spring and A. Shrivastava, "Scalable and sustainable deep learning via randomized hashing," in *Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 2017, pp. 445-454.
- [12] A. Mirhoseini, H. Pham, Q. V. Le, B. Steiner, R. Larsen, Y. Zhou, et al., "Device placement optimization with reinforcement learning," in *Proceedings of the 34th International Conference on Machine Learning-Volume 70*, 2017, pp. 2430-2439.
- [13] T. Kraska, A. Talwalkar, J. C. Duchi, R. Griffith, M. J. Franklin, and M. I. Jordan, "MLbase: A Distributed Machine-learning System," in *Cidr*, 2013, pp. 2-1.
- [14] K. Hsieh, A. Harlap, N. Vijaykumar, D. Konomis, G. R. Ganger, P. B. Gibbons, et al., "Gaia: Geo-distributed machine learning approaching {LAN} speeds," in *14th {USENIX} Symposium on Networked Systems Design and Implementation ({NSDI} 17)*, 2017, pp. 629-647.

- [15] E. P. Xing, Q. Ho, W. Dai, J. K. Kim, J. Wei, S. Lee, *et al.*, "Petuum: A new platform for distributed machine learning on big data," *IEEE Transactions on Big Data*, vol. 1, pp. 49-67, 2015.
- [16] W. Xiao, J. Xue, Y. Miao, Z. Li, C. Chen, M. Wu, *et al.*, "Tux²: Distributed Graph Computation for Machine Learning," in *14th {USENIX} Symposium on Networked Systems Design and Implementation ({NSDI} 17)*, 2017, pp. 669-682.
- [17] M. Abadi, P. Barham, J. Chen, Z. Chen, A. Davis, J. Dean, *et al.*, "Tensorflow: A system for large-scale machine learning," in *12th {USENIX} Symposium on Operating Systems Design and Implementation ({OSDI} 16)*, 2016, pp. 265-283.
- [18] M. Alzantot, Y. Wang, Z. Ren, and M. B. Srivastava, "Rstensorflow: Gpu enabled tensorflow for deep learning on commodity android devices," in *Proceedings of the 1st International Workshop on Deep Learning for Mobile Systems and Applications*, 2017, pp. 7-12.
- [19] H. Dong, A. Supratak, L. Mai, F. Liu, A. Oehmichen, S. Yu, *et al.*, "Tensorlayer: a versatile library for efficient deep learning development," in *Proceedings of the 25th ACM international conference on Multimedia*, 2017, pp. 1201-1204.
- [20] T. T. D. Team, R. Al-Rfou, G. Alain, A. Almahairi, C. Angermueller, D. Bahdanau, *et al.*, "Theano: A Python framework for fast computation of mathematical expressions," *arXiv preprint arXiv:1605.02688*, 2016.
- [21] Y. Jia, E. Shelhamer, J. Donahue, S. Karayev, J. Long, R. Girshick, *et al.*, "Caffe: Convolutional architecture for fast feature embedding," in *Proceedings of the 22nd ACM international conference on Multimedia*, 2014, pp. 675-678.
- [22] R. Collobert, K. Kavukcuoglu, and C. Farabet, "Torch7: A matlab-like environment for machine learning," in *BigLearn, NIPS workshop*, 2011.
- [23] A. Paszke, S. Gross, S. Chintala, G. Chanan, E. Yang, Z. DeVito, *et al.*, "Automatic differentiation in pytorch," 2017.
- [24] T. Chen, M. Li, Y. Li, M. Lin, N. Wang, M. Wang, *et al.*, "Mxnet: A flexible and efficient machine learning library for heterogeneous distributed systems," *arXiv preprint arXiv:1512.01274*, 2015.
- [25] I. Sutskever, J. Martens, G. Dahl, and G. Hinton, "On the importance of initialization and momentum in deep learning," in *International conference on machine learning*, 2013, pp. 1139-1147.
- [26] J. Dean, G. Corrado, R. Monga, K. Chen, M. Devin, M. Mao, *et al.*, "Large scale distributed deep networks," in *Advances in neural information processing systems*, 2012, pp. 1223-1231.
- [27] M. D. Zeiler, "Adadelata: an adaptive learning rate method," *arXiv preprint arXiv:1212.5701*, 2012.
- [28] S. Ruder, "An overview of gradient descent optimization algorithms," *arXiv preprint arXiv:1609.04747*, 2016.
- [29] T. Dozat, "Incorporating nesterov momentum into adam," 2016.
- [30] M. Andrychowicz, M. Denil, S. Gomez, M. W. Hoffman, D. Pfau, T. Schaul, *et al.*, "Learning to learn by gradient descent by gradient descent," in *Advances in neural information processing systems*, 2016, pp. 3981-3989.
- [31] W. Wen, C. Xu, F. Yan, C. Wu, Y. Wang, Y. Chen, *et al.*, "Terngrad: Ternary gradients to reduce communication in distributed deep learning," in *Advances in neural information processing systems*, 2017, pp. 1509-1519.
- [32] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, *et al.*, "Going deeper with convolutions," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2015, pp. 1-9.

- [33] Y. Zhou, S. Chen, and A. Banerjee, "Stable Gradient Descent," in *UAI*, 2018, pp. 766-775.
- [34] F. Bonomi, R. Milito, P. Natarajan, and J. Zhu, "Fog computing: A platform for internet of things and analytics," in *Big data and internet of things: A roadmap for smart environments*, ed: Springer, 2014, pp. 169-186.
- [35] J. Mao, X. Chen, K. W. Nixon, C. Krieger, and Y. Chen, "Modnn: Local distributed mobile computing system for deep neural network," in *Design, Automation & Test in Europe Conference & Exhibition (DATE), 2017*, 2017, pp. 1396-1401.
- [36] M. Mukherjee, L. Shu, and D. Wang, "Survey of fog computing: Fundamental, network applications, and research challenges," *IEEE Communications Surveys & Tutorials*, vol. 20, pp. 1826-1857, 2018.
- [37] L. M. Vaquero and L. Roderio-Merino, "Finding your way in the fog: Towards a comprehensive definition of fog computing," *ACM SIGCOMM Computer Communication Review*, vol. 44, pp. 27-32, 2014.
- [38] V. Sze, Y.-H. Chen, T.-J. Yang, and J. S. Emer, "Efficient processing of deep neural networks: A tutorial and survey," *Proceedings of the IEEE*, vol. 105, pp. 2295-2329, 2017.
- [39] V. Gokhale, J. Jin, A. Dundar, B. Martini, and E. Culurciello, "A 240 g-ops/s mobile coprocessor for deep neural networks," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops*, 2014, pp. 682-687.
- [40] S. Bang, J. Wang, Z. Li, C. Gao, Y. Kim, Q. Dong, et al., "14.7 a 288 μ w programmable deep-learning processor with 270kb on-chip weight storage using non-uniform memory hierarchy for mobile intelligence," in *2017 IEEE International Solid-State Circuits Conference (ISSCC)*, 2017, pp. 250-251.
- [41] F. Akopyan, "Design and tool flow of ibm's truenorth: An ultra-low power programmable neurosynaptic chip with 1 million neurons," in *Proceedings of the 2016 on International Symposium on Physical Design*, 2016, pp. 59-60.
- [42] S. S. Latifi Oskouei, H. Golestani, M. Hashemi, and S. Ghiasi, "Cnndroid: Gpu-accelerated execution of trained deep convolutional neural networks on android," in *Proceedings of the 24th ACM international conference on Multimedia*, 2016, pp. 1201-1205.

جمع‌بندی مرحله اول

در این گزارش که مرتبط با مرحله اول پروژه "آینده پژوهی در خصوص سیستم‌های ارتباطی هوشمند و کاربرد آنها در صنعت برق" است در ۵ فصل به ارائه مطالعات اولیه و تطبیقی پرداخته شد.

در فصل اول روش‌های رادیوشناختی و رادیونرم‌افزار و کاربردهای آن در بخش‌های مختلف صنعت برق مورد مطالعه و بررسی قرار گرفتند. در این فصل پس از معرفی شبکه‌های رادیوشناختی و شبکه هوشمند برق، کاربردهای موجود و بالقوه اینگونه روش‌های شناختی در شبکه برق هوشمند به صورت مبسوط مورد بررسی قرار گرفتند. از دیگر موضوعات مورد مطالعه، معماری شبکه هوشمند برق مبتنی بر رادیوشناختی، روش‌های حس پهنای باند و پروتکل‌های دسترسی به کانال بودند.

فصل دوم به ارائه و بررسی پروژه‌های انجام شده در دنیا که به هوشمندسازی سیستم‌های ارتباطی خود پرداخته‌اند و قابلیت بکارگیری در صنعت برق دارند، معطوف بود. در این فصل دو پروژه صنعتی به نام‌های SunSeed و SmartEMC2 که در اتحادیه اروپا و معطوف به صنعت برق بوده‌اند، و نیز یک پروژه دانشگاهی که در دانشگاه Alabama و با پشتیبانی پژوهشگاه نیروی هوایی آمریکا صورت گرفته است، مورد بررسی قرار گرفتند. این پروژه دانشگاهی یک نمونه آزمایشگاهی از رادیوشناختی را که از چند روش پیشرفته یادگیری ماشینی بهره می‌برد را پیاده‌سازی نموده است. روش ایشان می‌تواند یک مورد مناسب و دارای قابلیت در کاربردهای صنعتی منجمله صنعت برق باشد که از رادیوشناختی استفاده می‌کنند. در پروژه SunSeed چند روش مبتنی بر ارتباطات چندگانه را ارائه و مورد بررسی قرار داده بود که باعث ارتقاء عملکرد ارتباطات سیستم‌های اندازه‌گیری مورد نیاز در شبکه‌های هوشمند می‌شود و ضرایب اطمینان ارتباطات را بهبود می‌بخشد. در پروژه SmartEMC2 نیز یک روش انتخاب آنتن در سیستم‌های Massive-MIMO و برای استفاده در شبکه‌های هوشمند برق ارائه گردیده است؛ به این ترتیب که با انتخاب زیرمجموعه‌ای از آنتن‌های موجود در سیستم، می‌توان به ارتقاء عملکرد، کاهش هزینه‌های سخت‌افزاری و سادگی پیاده‌سازی در واحدهای مرکزی قرائت اطلاعات در شبکه‌های هوشمند دست یافت. در پروژه سوم که در دانشگاه Alabama صورت گرفته است، چند روش یادگیری ماشینی برای یک سیستم رادیوشناختگر ارائه و پیاده‌سازی شده است، که با آزمایشات صورت گرفته، نشان داده شده است که این روش‌ها باعث ارتقاء عملکرد می‌شوند. به این ترتیب، همانگونه که بر اساس مطالعات و بررسی‌های صورت گرفته در فصل اول نشان داده شد، در کثیری از کاربردهای موجود در شبکه‌های هوشمند که رادیوشناختی می‌تواند نقش مثبتی ارائه نماید و به طبع آن این روش‌های یادگیری ماشینی می‌توانند یک گام دیگر به بهبود عملکرد سیستم‌های شبکه‌های هوشمند کمک کنند.

در فصل سوم ابتدا یک مروری کلی بر روش‌های یادگیری ماشینی و البته با یک نگاه عمومی بر آن دسته که تاکنون در سیستم‌های ارتباطی که دارای کاربرد بوده‌اند، صورت گرفت. در ادامه نتایج مرتبط با مطالعات و بررسی روش‌های AI مورد استفاده در لایه فیزیکی ارائه شدند. در این خصوص به چالش‌های بکارگیری روش‌های یادگیری ماشینی در سیستم‌های ارتباطی پرداخته شد و سپس چند کاربرد از این روش‌ها در مکانیزم‌های موجود در لایه فیزیکی همچون مدولاسیون و کدینگ تطبیقی و انواع مختلف یکسان‌سازها به صورت عمیق مورد بررسی قرار گرفته‌اند. با بررسی نتایج تحقیقات نشان داده شد که در بسیاری موارد، روش‌های یادگیری ماشینی متکی بر داده می‌توانند نسبت به روش‌های سنتی متکی بر مدل‌های سیستمی کارکردی بهتر داشته باشند.

در فصل چهارم به بررسی کاربردهای AI در استفاده از طیف فرکانسی پرداخته شد که در واقع ادامه‌ای بر مطالب ارائه شده در فصل اول بود. در این فصل ابتدا به چالش‌هایی که در مسائل رادیوشناختی وجود دارد اشاره شد و یک دسته‌بندی از مسائل یادگیری ماشینی در این حوزه ارائه گردید. همچنین روش‌های مختلف هوش مصنوعی که در حوزه CR می‌توانند مورد استفاده قرار گیرند به همراه مثالی از کاربرد آن‌ها معرفی شدند و مزایا و معایب این روش‌ها با یکدیگر مقایسه گردیدند. با بررسی‌های صورت گرفته ملاحظه گردید که به دلیل نیاز به تصمیم‌گیری و همچنین پویا بودن و عدم قطعیت موجود در دسترسی به طیف در شبکه‌های رادیوشناختی، روش‌های مبتنی بر یادگیری تقویتی برای حل این مسائل مناسب‌تر می‌باشند. همچنین به دلیل گستردگی

این شبکه‌ها و زیاد شدن وضعیت‌های مسأله، ترکیبی از یادگیری تقویتی و یادگیری عمیق معرفی شد که زمان رسیدن به راهبرد بهینه را در این مسائل کاهش می‌دهد و در عین حال دقت مناسبی نیز دارد. از میان مسائلی که در شبکه‌های مخابراتی وجود دارد، دسترسی پویا به پهنای باند در شبکه‌های رادیو شناختی از اهمیت بیشتری برخوردار است که در این فصل به طور مبسوط به آن پرداخته شد. همچنین به مسائل دیگری چون همکاری با کاربر متصل شده به شبکه و کنترل نرخ داده نیز اشاره مختصری گردید. موضوع مورد بررسی در فصل پنجم ملاحظات و ابزارهای مورد نیاز طراحی سیستمی جهت بکارگیری AI بود. در این فصل به دو موضوع محدودیت‌های بکارگیری روش‌های هوش مصنوعی و با تأکید بر یادگیری عمیق در سیستم‌های ارتباطی هوشمند و همچنین ملزومات و ابزارهای پیاده‌سازی آن، پرداخته شد. بخشی از محدودیت‌ها به پیچیدگی محاسباتی روش‌های یادگیری برمی‌گردد که برای حل آن نیاز است که سخت‌افزارهای قوی و با قابلیت پردازش بالا مورد استفاده قرار گیرند. در کنار این سخت‌افزارها، کتابخانه‌های نرم‌افزاری نیز ارائه شدند که این سخت‌افزارها و الگوریتم‌های مورد استفاده در روش‌های یادگیری ماشینی را پشتیبانی می‌کنند. همچنین در صورت استفاده از سخت‌افزارها و نرم‌افزارهای ضعیف، دقت این روش‌ها ممکن است کاهش یابد؛ که در این خصوص روش‌هایی ارائه گردیدند که می‌توانند حتی با استفاده از سخت‌افزارها و نرم‌افزارهای نه چندان قوی هم یادگیری ماشینی را پیاده‌سازی کنند.

با مطالعات صورت گرفته در این بخش از پروژه علاوه بر گردآوری دانش و ایجاد دید روشن‌تر نسبت به نحوه بکارگیری روش‌های هوش مصنوعی در سیستم‌های ارتباطی و چالش‌های آن، ملاحظه گردید که این روش‌ها بویژه یادگیری ماشینی کاربردهای وسیعی در بخش‌های مختلف سیستم‌های ارتباطی دارند. در مراحل آتی پروژه بخش‌های دیگری از سیستم‌های ارتباطی و نحوه نقش‌آفرینی روش‌های هوش مصنوعی مورد مطالع و بررسی قرار خواهند گرفت.

مرحله دوم. مطالعات مقدماتی و تطبیقی

مقدمه مرحله دوم

در مرحله اول پروژه در مورد رادیو شناختی و کاربرد آن در صنعت برق به طور مفصل بحث گردید و اشاره شد که برای رادیو شناختی نیاز به حس کردن طیف فرکانسی، جمع‌آوری داده در مرکز کنترل و اعمال الگوریتم‌های هوش مصنوعی برای پردازش و اتخاذ تصمیم مناسب است. علاوه بر این به دسته‌بندی روش‌های مختلف هوش مصنوعی پرداخته شد و با ذکر مثال‌هایی، کاربردهای آن‌ها در شبکه‌های مخابراتی مورد بررسی قرار گرفت. دسته‌بندی‌هایی که در مورد بکارگیری هوش مصنوعی در شبکه‌های مخابراتی در فصل قبل ارائه شدند بیشتر جنبه کاربردی و عملی داشتند، اما در فصول بعدی سعی بر آن است که استفاده از هوش مصنوعی در شبکه‌های مخابراتی بر اساس لایه‌های شبکه تقسیم‌بندی شوند. در یک سیستم مخابراتی لایه‌های مختلفی از جمله، لایه فیزیکی، لایه MAC و لایه شبکه وجود دارند. لایه فیزیکی که در این فصل مورد مطالعه قرار می‌گیرد، بستری است که سیگنال‌های حامل به انتقال داده‌ها و اطلاعات در آن می‌پردازند و شامل خطوط سیمی، فیبر نوری و واسط هوایی است. البته در فصل قبل نیز کاربردهایی از هوش مصنوعی در لایه فیزیکی نظیر تخصیص کانال و اتصال کاربر جدید به ایستگاه پایه مورد بررسی قرار گرفتند که بیشتر جنبه مخابرات سیستمی دارند. در فصل ۶ تاکید بیشتر بر روی مخابرات میدان و موج و جنبه الکترومغناطیسی مخابرات است. در سیستم‌های مخابراتی بی‌سیم در لایه فیزیکی، امواج الکترومغناطیسی مسئولیت انتقال داده‌ها را به عهده دارند و این امواج توسط آنتن‌های فرستنده و گیرنده در فضا منتشر می‌شوند. قبل از آنتن نیز کنترل‌کننده و مدارهای الکترونیکی و تقویت‌کننده‌های توان وظیفه سیگنال دهی به آنتن را بر عهده دارند.

یکی از چالش‌هایی که امروزه سیستم‌های مخابرات بی‌سیم با زیاد شدن تعداد کاربران و همچنین تعداد حسگرها با آن مواجه هستند، افزایش ظرفیت و بهبود کیفیت خدمات مورد نیاز کاربران می‌باشد. یکی از راه‌های افزایش ظرفیت استفاده از پهنای باند بیشتر بوده است که با توجه به فناوری‌های امروزی که در اختیار بخش تجاری و صنعتی هستند این پهنای باند محدود است. همان‌طور که در مرحله قبل نیز اشاره شد، رادیو شناختی به این مساله اشاره دارد که میزان استفاده کاربر از پهنای باند اختصاص داده شده بازدهی کمی دارد و این پهنای باند را می‌توان در مواقعی با حفظ اولویت کاربران، بین کاربران دیگر نیز به اشتراک گذاشت. همگام با رشد شبکه‌های مخابراتی، صنعت برق نیز به سمت شبکه هوشمند برق پیش می‌رود که در آن حسگرها و کنتورهای زیادی برای پایش و کنترل شبکه وجود دارد و اطلاعات به صورت بلادرنگ به بخش مدیریت شبکه ارسال می‌شوند تا تصمیمات بهینه‌ای برای اجزای شبکه گرفته شود. این تصمیمات منجر به صادر شدن دستورات کنترلی می‌گردد که به کنتورها و کلیدها بازمی‌گردد. با زیاد شدن تعداد حسگرها و کنتورها، فناوری‌هایی نظیر رادیو شناختی، سیستم‌های سایبر-فیزیکی و همچنین اینترنت اشیاء صنعتی می‌توانند در پیاده‌سازی ارتباطات موثر در صنعت مفید باشند که در انتهای فصل ۷ این گزارش به طور مفصل‌تری مورد بررسی قرار می‌گیرند.

انواع روش‌های تسهیم نیز همانند تسهیم زمانی، تسهیم فرکانسی، تسهیم کد و غیره می‌توانند در افزایش تعداد کاربران کمک کنند. یکی از این تسهیم‌ها، تسهیم فضایی است که در آن فرکانس‌ها و کانال‌های مشابه می‌تواند در بیم‌های جداگانه آنتن فرستنده، مورد استفاده مجدد قرار بگیرند. در مخابرات سلولی نسل چهارم، فضا به سه قسمت تقسیم شده و برای هر قسمت یک آنتن آرایه‌ای با ۱۲۰ درجه انحراف نسبت به دیگر آنتن‌ها مورد استفاده قرار گرفته است. آنتن‌های آرایه‌ای بهره بالایی دارند و می‌توانند امکان چرخش بیم را فراهم کنند به طوری که آنتن آرایه‌ای در بالای دکل مخابراتی قرار گرفته و بیم آنتن با زاویه‌ای نسبت به سطح زمین تنظیم می‌شود.

در نسل جدید آنتن‌های آرایه‌ای که آنتن‌های MIMO انبوه نامیده می‌شوند تعداد بسیار زیادی آنتن واحد در کنار یکدیگر قرار گرفته و آنتن می‌تواند بیم‌های مختلفی در جهات مختلف فضایی ایجاد کند. استفاده از تعداد آنتن بالا باعث می‌شود که بیم باریکی تولید شود و امکان تمرکز بر روی یک کاربر به عنوان هدف فراهم می‌گردد که به نوبه خود می‌تواند در مصرف توان نیز صرفه جویی نماید.

یکی دیگر از چالش‌هایی که انتشار امواج در مخابرات پهن باند و استفاده از فرکانس‌های بالا با آن مواجه است وضعیت کانال می‌باشد که به صورت تصادفی به حضور اجسام متحرک و ثابت وابسته است و در خیلی از موارد این موانع قابل پیش‌بینی نیستند. حضور این موانع باعث می‌شود که جلوی دید مستقیم آنتن فرستنده و گیرنده در فرکانس بالا گرفته شود و ارتباط با اختلال مواجه گردد. یکی از راهکارهای ارائه شده استفاده از صفحات بزرگی است که همانند آنتن‌های MIMO انبوه دارای المان‌های بازتابی بسیار زیادی هستند، منتها بر خلاف این آنتن‌ها، تغذیه جداگانه ندارند بلکه از امواجی که به آن‌ها تابیده می‌شود تغذیه می‌شوند. هر یک از این المان‌های بازتابی دارای عناصر کنترل‌پذیری نظیر دیود، میکروسوئیچ، و رکتور، ترانزیستور و غیره است که توسط یک کنترل‌کننده تنظیم می‌شوند. متغیرهایی که توسط کنترل‌کننده تغییر می‌کنند دامنه و فاز موج بازتاب شده از المان‌های بازتابی است. به این ترتیب این صفحات می‌توانند موج تابیده شده را در زاویه دلخواه بازتاب دهند و به سمت هدف ارسال کنند. در نتیجه یک مسیر جایگزین به جای مسیر دید مستقیم ایجاد می‌شود و با جمع شدن سیگنال دید مستقیم و سیگنال بازتاب شده، سیگنال دریافتی در گیرنده تقویت و یا حتی تضعیف می‌گردد.

در فصل ۶ ابتدا به معرفی این صفحات هوشمند بازتابی پرداخته شده و مبانی عملکرد آن از نظر تئوری میدان و امواج مورد بررسی قرار گرفته است. در ادامه به کاربردهای آن و تفاوت آن با دیگر فناوری‌های مشابه نظیر آنتن‌های MIMO و MIMO انبوه اشاره می‌شود. همچنین به روش‌های پیاده‌سازی و چالش‌های مرتبط با آن نیز پرداخته شده است.

در فصل ۷ آنتن‌های MIMO انبوه معرفی شده و به تفاوت آن با آنتن‌های MIMO معمولی اشاره شده است. در ادامه مزایا و چالش‌های این آنتن‌ها بیان شده و به استفاده از روش‌های هوش مصنوعی مانند شبکه‌های عصبی در طراحی و شکل‌دهی بیم این آنتن‌ها پرداخته شده است. در انتها نیز به کاربردهای مخابراتی و صنعتی که می‌توان از آن‌ها استفاده نمود اشاره گردیده است.


فصل ٦

مطالعه و بررسی صفحات هوشمند LIS

۱-۶- مقدمه

از آنجاکه شبکه‌های ارتباطی 5G اکنون در حال تجاری شدن هستند، فناوری‌های ارتباطی مربوط به نسل بعدی یعنی 6G نیز برای دستیابی به انتقال سریع‌تر و مطمئن‌تر داده‌ها مورد بررسی قرار خواهند گرفت. در بین این فناوری‌ها، سطوح بازتاب‌دهنده هوشمند^۱ (RIS) اخیراً مورد توجه بسیاری از دانشگاه‌ها و صنعت قرار گرفته‌اند. در نوامبر سال ۲۰۱۸، شرکت مخابراتی ژاپنی NTT DoCoMo و یک استارت‌آپ راداری هوشمند به نام MetaWave استفاده از این فناوری برای برقراری ارتباط داده در باند ۲۸ گیگاهرتزی را ارائه دادند.

یک سطح بازتاب‌دهنده هوشمند از آرایه‌ای از واحدهای RIS تشکیل شده است، که هر یک از آن‌ها به‌طور مستقل می‌تواند تغییراتی در سیگنال تابشی به وجود آورد [۱]. تغییر به‌طور کلی ممکن است مربوط به فاز، دامنه، فرکانس و یا حتی قطبش باشد. تا به امروز، در اکثر مطالعات [۲-۶] تغییرات به صورت تغییر فاز در سیگنال تابشی در نظر گرفته شده است، به‌طوری که یک RIS هیچ توانی برای انتقال مصرف نمی‌کند. در اصل، RIS هوشمندانه محیط بی‌سیم را برای کمک به انتقال بین فرستنده و گیرنده، هنگامی که ارتباطات مستقیم از کیفیت بدی برخوردار است، بهبود می‌بخشد. مکان‌های نمونه برای قرار دادن RIS ها دیوارها، نمای ساختمان و سقف هستند [۷]. شکل ۵۷ یک نمونه ارتباطات به کمک RIS بین یک ایستگاه پایه^۲ و یک کاربر تلفن همراه، یک وسیله پرنده بدون سرنشین^۳ (پهپاد)، یک وسیله نقلیه هوشمند یا هر ترمینال دیگر را نشان می‌دهد، جایی که یک درخت خط دید را مسدود کرده است.



شکل ۵۷. ارتباطات بین یک ایستگاه پایه و کاربر موبایل، پرنده بدون سرنشین و خودرو هوشمند با استفاده از سطح بازتابنده هوشمند [۸]

مفهوم RIS را می‌توان در ارتباط با فناوری چند ورودی چند خروجی در نظر گرفت که در آن از آرایه‌های بزرگی از آنتن‌ها برای بهبود کارایی طیف و انرژی استفاده می‌شود. از این رو پیش‌بینی می‌شود RIS نقش مهمی را در شبکه‌های ارتباطی 6G شبیه به نقش Massive MIMO 2.0 در شبکه‌های 5G ایفا کند. بنابراین، RIS می‌تواند برای دستیابی به Massive MIMO 2.0 استفاده شود [۹]. آنچه RIS را از Massive MIMO متمایز می‌کند این است که RIS ها محیط انتشار بی‌سیم را برای ارتباطات تنظیم می‌کنند [۱۰]. در [۱۰] اولین تحلیل در مورد قابلیت انتقال اطلاعات RIS ارائه شده است. نویسندگان اثبات

¹ Reflecting Intelligent Surface (RIS)

² Base station

³ Unmanned Aerial Vehicle (UAV)

می‌کنند ظرفیتی که می‌توان در هر مترمربع مساحت به دست آورد، دارای یک رابطه خطی با میانگین قدرت انتقال است، در صورتی که با استفاده از Massive MIMO، این رابطه لگاریتمی است. علاوه بر Massive MIMO، سایر فناوری‌های موجود نیز در مطالعات اخیر با RIS مقایسه شده‌اند که شامل ارتباطات بازتابی [۱۱]، ارتباط موج میلی‌متری [۱۲] و شبکه‌های با تراکم بسیار بالا^۱ [۱۳] می‌باشند. با این حال، این فناوری‌ها محیط بی‌سیم را کنترل نمی‌کنند و به‌طور معمول انرژی زیادی مصرف می‌نمایند.

علاوه بر RIS، اخیراً مفاهیم مشابه دیگری نیز در مقالات ارائه شده است که گه‌گاه به‌جای یکدیگر نیز به‌کاربرده می‌شوند. این اسامی شامل موارد زیر است:

- سطح هوشمند بزرگ^۲ (LIS) که برای تجزیه و تحلیل تقریبی با فرض ابعاد بی‌نهایت برای سطح یا تعداد بسیار زیادی آنتن ترجیح داده می‌شود. شایان ذکر است که سطح حتی می‌تواند به‌جای اینکه منفعلانه سیگنال‌ها را از ایستگاه‌های پایه بازتاب دهد، در واقع سیگنال‌ها را به‌صورت فعال منتقل می‌کند [۱۴-۱۷].
- فراسطح بزرگ^۳ (LIM) و متاسطح قابل برنامه‌ریزی و پیکربندی که در آن‌ها پیشوند متا از یک الگوی فلزی به نام متا اتم ناشی می‌شود که با استفاده از آن سطحی با مشخصات خاصی طراحی می‌شود در سطوح طبیعی با آن خاصیت وجود ندارند [۱۸، ۱۹].
- آرایه‌های بازتابی هوشمند^۴ که به‌جای اینکه برای انتقال مورد استفاده قرار گیرند مانند روش تقویت و ارسال یا رمزگشایی و ارسال در فناوری MIMO، بر عملکرد بازتابی سطح مشابه عملکرد RIS تأکید می‌کنند [۲۰، ۲۱].
- سطح هوشمند قابل پیکربندی^۵ که در آن قابلیت پیکربندی به معنی تنظیم زاویه بازتاب (با استفاده از نرم‌افزار) به‌گونه‌ای است که مستقل از زاویه تابش باشد [۵، ۲۲].
- سطح مبتنی بر نرم‌افزار^۶ یا متاسطح مبتنی بر نرم‌افزار^۷ که از تعریف رادیونرم‌افزاری اقتباس شده‌اند و برهمکنش سطح و موج تابشی در آن‌ها را به‌صورت مبتنی بر نرم‌افزار در نظر می‌گیرند [۲۳، ۲۴].
- سطح غیرفعال^۸ یا آینه غیرفعال که در آن‌ها از بازتاب غیرفعال به‌جای مصرف توان برای انتقال استفاده می‌شود [۲۵، ۲۶].

به نظر می‌رسد مفهوم RIS و همچنین مفاهیمی که در بالا به آن اشاره شد همگی زیر مجموعه عنوان کلی‌تر LIS هستند که هم شامل صفحات بازتابی هوشمند و هم صفحات دارای المان‌های فعال می‌باشد. در نتیجه در ادامه این گزارش در بسیاری از موارد از این واژه به جای RIS استفاده شده است. در این فصل ابتدا به موارد کاربرد LIS و همچنین فناوری‌های مشابه با LIS و تفاوت آن با این فناوری‌ها پرداخته شده است. در ادامه عملکرد LIS‌ها از نظر تئوری امواج الکترومغناطیسی مورد بررسی قرار گرفته و نحوه ساخت و پیاده‌سازی آن‌ها شرح داده شده است. در انتها نیز به چالش‌های پیش روی این فناوری اشاره شده است.

¹Ultra-dense network

²Large Intelligent Surface (LIS)

³Large Intelligent metasurface (LIM)


⁴Smart Reflect-arrays

⁵ Reconfigurable Intelligent Surface

⁶Software-defined surface (SDS)

⁷Software-defined metasurface (SDM)

⁸Passive intelligent surface




شکل ۵۸. کاربرد RIS برای زمانی که کاربر در منطقه دید کور فرستنده قرار دارد [۷].

۲-۶- موارد کاربرد LIS

صفحات هوشمند بزرگ دارای چندین کاربرد معمول هستند که در ادامه به آن‌ها اشاره می‌شود. همان‌طور که در شکل ۵۸ نشان داده شده است کاربرد اول در زمانی است که گیرنده در نقطه کور نسبت به فرستنده قرار گرفته و ارتباط بین فرستنده و گیرنده توسط یک مانع مسدود شده است. به این ترتیب RIS می‌تواند از طریق انعکاس هوشمند سیگنال یک مسیر دیدمستقیم^۱ (LOS) مجازی بین فرستنده و گیرنده ایجاد کند و مانع را از مسیر ارتباطی بردارد. این کاربرد بخصوص برای افزایش پوشش مخابرات موج میلی‌متری که نسبت به موانع بیرونی و داخل ساختمان بسیار آسیب‌پذیر می‌باشد، مفید است.


کاربرد دوم برای حفاظت و امنیت لایه فیزیکی است که در شکل ۵۹ نشان داده شده است. این کاربرد می‌تواند دو حالت داشته باشد. یکی زمانی است که دستگاه شنود در فاصله نزدیک‌تری نسبت به کاربر قانونی (کاربر ۱) اما در مسیر متفاوتی قرار دارد و دیگری در زمانی که دستگاه شنود بین مسیر فرستنده و کاربر قانونی (کاربر ۲) قرار گرفته است. در هر حالت صفحه هوشمند می‌تواند در نزدیکی دستگاه شنود به گونه‌ای تنظیم شود که سیگنال دریافتی از فرستنده و سیگنال بازتاب‌شده از صفحه، در محل دستگاه شنود یکدیگر را خنثی کنند یعنی دارای دامنه مساوی ولی اختلاف فاز ۱۸۰ درجه باشند. به این ترتیب نشت اطلاعات به میزان قابل توجهی کاهش می‌یابد.



¹Line of sight (LOS)


شکل ۵۹. نقشی RIS در حفاظت لایه فیزیکی [۷]

کاربرد سوم که در شکل ۶۰ آورده شده است برای کاربران در لبه سلول مخابراتی استفاده می‌شود که از تلفات بالای سیگنال ایستگاه پایه اصلی و همچنین تداخل زیاد ایستگاه پایه مجاور رنج می‌برند. صفحه هوشمند می‌تواند برای بالا بردن توان سیگنال از ایستگاه پایه مورد نظر و همچنین حذف تداخل مزاحم مفید باشد. به‌طوری که سیگنال دیدمستقیم و انعکاسی از صفحه برای ایستگاه پایه اصلی یکدیگر را تقویت کنند ولی برای ایستگاه پایه مجاور یکدیگر را خنثی نمایند.



شکل ۶۰. کاربرد صفحه بزرگ هوشمند در لبه سلول مخابراتی [۷]

کاربرد چهارم مربوط به استفاده از صفحات بزرگ هوشمند به‌عنوان هاب انعکاسی است که منجر به ارتباطات دستگاه به دستگاه^۱ (D2D) انبوه شده و تداخل بین دستگاه‌ها را کاهش می‌دهد. این کاربرد به‌صورت شماتیک در شکل ۶۱ نشان داده شده است.




شکل ۶۱. مخابرات دستگاه به دستگاه انبوه [۷]

کاربرد دیگر به‌صورت استفاده از صفحات بزرگ هوشمند برای انتقال هم‌زمان اطلاعات و توان^۲ (SWIPT) برای دستگاه‌های مختلف در شبکه اینترنت اشیا است که در شکل ۶۲ نشان داده شده است. در این روش صفحه بزرگ هوشمند می‌تواند میزان

¹Device to device

²Simultaneous wireless information and power transfer

قابل توجهی از تلفات توان در مسافت زیاد را با استفاده از شکل دهی پرتو به ادوات اینترنت اشیاء جبران نموده و بازدهی انتقال توان را افزایش دهد.



شکل ۶۲. استفاده از صفحات بزرگ هوشمند برای انتقال هم‌زمان اطلاعات و توان [۷]

۳-۶- فناوری‌های مشابه LIS

برخی از فناوری‌های مرتبط دیگر مانند رله فعال^۱، مخابرات پراکندگی برگشتی^۲ و صفحات فعال بر پایه MIMO انبوه نیز مشابه فناوری LIS هستند که در اینجا تفاوت‌های اصلی و برتری‌های LIS در مقایسه با آنها بیان می‌شوند.

رله‌های فعال در مخابرات بین مبدأ و مقصد به منظور بازتولید سیگنال و انتقال مجدد آن به کار می‌روند، در صورتی که LIS هیچ ماژول فعال فرستنده‌ای (تقویت‌کننده توان) ندارد و تنها سیگنال دریافتی را به صورت یک آنتن آرایه‌ای غیرفعال بازتاب می‌دهد. همچنین رله فعال معمولاً برای حالت نیمه‌دوطرفه^۳ استفاده می‌شود که دارای بازدهی فرکانسی کمتری نسبت به LIS است که از حالت دوطرفه کامل^۴ استفاده می‌نماید. هرچند رله دوطرفه کامل نیز قابل پیاده‌سازی است، نیاز است تا با استفاده از تکنیک‌هایی، تداخل به وجود آمده خنثی شود که خود نیازمند صرف هزینه است [۷]. از منظر پیاده‌سازی نیز LIS‌ها دارای ضخامت کم، وزن سبک و شکل‌پذیر^۵ و قابل انعطاف هستند در نتیجه می‌توان به راحتی آن‌ها را روی دیوار یا سقف ساختمان‌ها نصب کرد یا از روی آن‌ها برداشت. همچنین می‌توان LIS‌ها را به گونه‌ای طراحی نمود که برای کاربران بدون تغییر در سخت‌افزار و نرم‌افزارهای وسایل ارتباطی شفاف به نظر برسند یعنی امواج به راحتی از آن‌ها عبور کنند [۲۷].

فناوری دوم، مخابرات پراکندگی برگشتی نظیر برچسب‌های RFID^۶ است. در این فناوری سیگنالی از فرستنده به سمت برچسب فرستاده می‌شود و برچسب با مدوله کردن این سیگنال، آن را به سمت فرستنده انعکاس می‌دهد. همچنین گیرنده برای دریافت و کدگذاری پیام برچسب نیاز به خنثی کردن تداخل نیز دارد. درحالی که LIS اساساً به جای ارسال اطلاعات خود، برای کمک و تسهیل لینک ارتباطی به وجود آمده به کار می‌رود و مسیر رفت سیگنال و انعکاس آن هر دو دارای اطلاعات مشابهی هستند که می‌توانند به صورت هم‌فاز در گیرنده جمع شده و توان سیگنال دریافتی را برای کدگذاری افزایش دهند [۷].

¹Active relay

²Backscatter communication

³Half-duplex

⁴Full-duplex

⁵conformal

⁶Radio frequency identification tag

یکی دیگر از تفاوت‌های LIS با دو فناوری اشاره شده در بالا، ابعاد آنتن‌های به کاررفته در این فناوری‌هاست. اندازه ابعاد آنتن LIS بسیار بزرگ‌تر از طول موج است تا بتوان آن را با یک بازتاب‌دهنده آینه‌ای مدل نمود اما ابعاد آنتن رله‌ها یا برچسب‌های پراکندگی برگشتی کوچک‌تر و قابل مقایسه با طول موج می‌باشند و بیشتر موج را پخش یا پراکنده^۱ می‌کنند [۱].

جدول ۸. مقایسه LIS با دیگر فناوری‌های مشابه

فناوری	نقش	مصرف توان	هزینه سخت-افزار	تعداد زنجیره‌های RF مورد نیاز	نوع ارتباط	مکانیسم عملکردی
LIS	تقویت کننده سیگنال و تضعیف کننده تداخل	کم	کم	۰	دوطرفه	غیرفعال، بازتابی
پراکندگی برگشتی	مبدأ و مقصد سیگنال	خیلی کم	خیلی کم	۰	دوطرفه	غیرفعال، بازتابی
رله MIMO	تقویت کننده سیگنال	زیاد	زیاد	N	دوطرفه و نیمه دوطرفه	فعال، دریافت و ارسال
Massive MIMO	مبدأ و مقصد سیگنال	خیلی زیاد	خیلی زیاد	N	دوطرفه و نیمه دوطرفه	فعال، دریافت و ارسال

همچنین صفحات هوشمند LIS با آنتن‌های MIMO انبوه که بر اساس معماری آرایه‌های فعال کار می‌کنند و دارای مکانیسم‌های فرستنده هستند متفاوت می‌باشند زیرا معماری آرایه‌ای آن‌ها غیرفعال است و به صورت بازتابی عمل می‌کنند. به دلیل اینکه تلفات در صفحات LIS بازتابی تنها ناشی از تلفات مسیر است، نسبت به فناوری‌های دیگر از نظر مصرف توان و بودجه لینک بسیار به صرفه‌تر هستند. همچنین در صورتی که یک LIS را ایده‌آل یعنی از نظر ابعاد بی‌نهایت و بدون تلفات در نظر بگیریم برای آنتن‌های فرستنده همه‌جهته^۲ قادر است تا بدون توجه به میزان توان فرستنده، نصف توان تشعشع شده در فضا را به سمت گیرنده هدایت نماید [۷].

مقایسه بین LIS، رله‌های فعال، آنتن‌های MIMO و Massive-MIMO به طور خلاصه در

جدول ۸ آورده شده است که در آن N تعداد آنتن‌های فعال است [۲۷].

۴-۶- مبانی الکترومغناطیسی LIS

همان‌طور که قبلاً اشاره شد LIS می‌تواند با انعکاس قسمتی از امواج فرستنده به سمت گیرنده، توان سیگنال دریافتی در گیرنده را کنترل نموده و آن را افزایش یا کاهش دهد. البته در مخابرات معمولی نیز امواج می‌توانند با برخورد به اجسام مختلف و همچنین زمین، از فرستنده به گیرنده منتقل شوند که این خاصیت بیشتر برای امواج مایکروویو با فرکانس کم‌تر از 6 GHz مطرح است و هر چه فرکانس بالاتر می‌رود به دلیل تلفات بالای موج در برخورد به موانع غیرفلزی امکان انتشار مجدد آن کاهش می‌یابد. به این ترتیب در فرکانس‌های بالا مانند فرکانس‌های موج میلی‌متری، ارتباطات بین فرستنده و گیرنده بیشتر به صورت دیدمستقیم


¹Diffuse

²Omnidirectional

انجام می‌گیرد. همچنین با ظهور فناوری‌های آنتن‌های آرایه‌ای نظیر MIMO انبوه امکان ایجاد بیم آنتن در جهات مختلف و چرخاندن بیم در فضا وجود دارد. در نتیجه LIS در صدد است تا در صورت وجود موانع بین فرستنده و گیرنده مسیر جایگزینی برای ایجاد ارتباط به وجود آورد.

برای توضیح عملکرد LIS از منظر مخابرات میدان و موج، ابتدا یک حالت ساده را با یک فرستنده و گیرنده در حضور LIS بر روی زمین مورد بررسی قرار می‌دهیم. می‌توان فرض نمود که آنتن گیرنده و فرستنده هر دو آنتن‌های همه‌جهتی هستند یا آنتن گیرنده یک آنتن همه‌جهتی و آنتن فرستنده نیز یک آنتن آرایه‌ای با توانایی ایجاد بیم در زوایای مختلف فضایی است. اگر دو آنتن فرستنده و گیرنده مطابق شکل ۶۳ در نظر گرفته شوند، دو مسیر برای امواج الکترومغناطیسی بین فرستنده و گیرنده می‌توان در نظر گرفت. یکی مسیر دیدمستقیم دو آنتن است که موج فاصله l را در آن طی می‌کند و دیگری مسیری است که موج پس از برخورد به LIS از فرستنده تا گیرنده فاصله $r_1 + r_2$ را می‌پیماید. برای سادگی فرض بر این است که امواج منتشرشده از فرستنده در هر دو مسیر دارای دامنه‌های یکسانی هستند. البته مقدار دامنه به بهره آنتن در آن جهت خاص و همچنین تلفات مسیر بستگی دارد که در اینجا از تلفات مسیر نیز صرف‌نظر شده است.

به این نوع تحلیل که از پرتوها به جای امواج استفاده می‌شود، تحلیل یا مدل نور هندسی^۱ گفته می‌شود که در آن فرض بر این است که اجسام بسیار بزرگ‌تر از طول موج امواج فرستنده و گیرنده هستند. بنابراین در این مسئله ابعاد LIS بسیار بزرگ‌تر از طول موج در نظر گرفته شده است.



شکل ۶۳. آنتن فرستنده و گیرنده به همراه LIS بر روی زمین [۱]

برای اینکه ابتدا یک مسئله ساده‌تر را مورد بررسی قرار دهیم فرض می‌کنیم که LIS به صورت یک صفحه فلزی بزرگ است که بر روی زمین قرار داده شده است. از آنجاکه طبق قانون اسنل^۲ زاویه انعکاس و تابش به این صفحه فلزی باید با یکدیگر برابر باشند، محل خاصی مانند نقطه G در شکل ۶۳ به دست می‌آید که LIS باید در این نقطه قرار گیرد تا موج تابشی از فرستنده به سمت LIS، به گیرنده برسد. توان دریافتی در آنتن گیرنده را می‌توان به صورت زیر محاسبه نمود:

$$P_r = \frac{\lambda P_t G_t}{4\pi R^2} A_R \quad (۱-۱)$$

که در آن P_t توان فرستنده، P_r توان دریافتی در گیرنده، G_t بهره آنتن فرستنده، R فاصله مسیر طی شده از فرستنده تا گیرنده، A_R سطح مقطع مؤثر آنتن گیرنده است. بهره آنتن معمولاً به صورت تابعی از زوایای فضایی (θ و ϕ در مختصات کروی) تعریف می‌شود و نشان‌دهنده نسبت توان در آن زاویه به توان منتشرشده در حالتی که آنتن همه‌جهتی است. سطح مؤثر آنتن گیرنده نیز با بهره آنتن گیرنده و طول موج به صورت زیر رابطه دارد:

$$A_R = \frac{\lambda G_R}{4\pi} \quad (۱-۲)$$

^۱Geometrical optic

^۲Snell's law


از ترکیب رابطه (۱-۱) و (۲-۱) می‌توان نوشت:

$$P_r = \frac{\lambda^2 P_t G_t}{(4\pi R)^2} A_R \quad (۱-۳)$$

دامنه‌های امواج یا پرتوهای در نظر گرفته شده با جذر توان موج در رابطه هستند. از آنجایی که از تلفات مسیر صرف نظر شده است و دامنه‌های هر دو پرتو نیز برای سادگی یکسان فرض شد، دو پرتو رسیده به گیرنده از دو مسیر مختلف تنها دارای یک اختلاف فاز هستند. بنابراین سیگنال دریافت شده در گیرنده را می‌توان به صورت مجموع دو سیگنال به صورت زیر نوشت:

$$r(t) = \frac{\lambda}{4\pi} \left(\frac{e^{-j\frac{2\pi l}{\lambda}}}{l} + \frac{R \times e^{-j\frac{2\pi(r_1+r_2)}{\lambda}}}{r_1+r_2} \right) x(t) \quad (۱-۴)$$

که در این رابطه R ضریب بازتاب از سطح فلزی است که می‌توان آن را با تقریب خوبی $-1 \approx R$ در نظر گرفت. همچنین جذر توان ارسالی و بهره آنتن فرستنده و گیرنده که برای هر دو مسیر یکسان فرض شده در دامنه سیگنال $x(t)$ قرار داده شده است. حال بر حسب اینکه اختلاف دو مسیر چقدر باشد این دو سیگنال می‌توانند به صورت سازنده یا مخرب با یکدیگر جمع شوند. در بدترین حالت $(r_1 + r_2 - l)/\lambda = n$ که $n = 0, 1, 2, \dots$ دو سیگنال با مضاربی از اختلاف فاز 180° در جهه با یکدیگر جمع شده و در بهترین حالت $(r_1 + r_2 - l)/\lambda = n/2$ دو سیگنال به صورت هم‌فاز در گیرنده دریافت می‌شوند. در عمل و در فرکانس‌های نه خیلی بالا (زیر 6 GHz) امواجی که از آنتن فرستنده در فضا منتشر می‌شوند هم از طریق مسیر دیدمستقیم و هم از مسیرهایی که در برخورد با اجسام دارند به آنتن گیرنده می‌رسند. در برخورد با اجسام نیز پدیده‌های مختلفی برای امواج الکترومغناطیسی رخ می‌دهد و ممکن است در اثر جذب یا عبور، بازتاب و پراکندگی، دامنه و فاز میدان پس از برخورد به جسم دچار تغییر شود. در نتیجه سیگنال‌هایی که از مسیرهای مختلف به آنتن گیرنده می‌رسند معمولاً دارای دامنه و فازهای مختلفی هستند و در صورتی که به صورت مخرب با یکدیگر جمع شوند پدیده‌ای به نام محوشدگی^۱ چندمسیره رخ می‌دهد.



شکل ۶۴. تصویری از LIS با ۲۰ المان بازتابی [۱]


در حالتی که LIS مطابق شکل ۶۴ به صورت مجموعه‌ای از المان‌های بازتابی در نظر گرفته شود، هر کدام از المان‌ها مانند یک سطح اشاره شده در بالا عمل خواهد کرد مضاف بر این که می‌تواند دامنه و فاز موج بازتابی را به صورت کنترل شده تغییر دهد. به این ترتیب سیگنال دریافتی را می‌توان به صورت زیر نوشت:

$$r(t) = \frac{\lambda}{4\pi} \left(\frac{e^{-j\frac{2\pi l}{\lambda}}}{l} + \sum_{i=1}^N \frac{R_i \times e^{-j\phi_i}}{r_{1,i} + r_{2,i}} \right) x(t) \quad (۱-۵)$$

که در آن R_i و ϕ_i دامنه و فازی هستند که المان i ام به موج تابیده شده به آن المان اضافه خواهد کرد. مجموع امواج بازتاب شده از LIS و موج دریافت شده از مسیر دیدمستقیم، در گیرنده دریافت می‌شود. خاصیتی که این آرایه از المان‌ها به وجود می‌آورند این است که با تنظیم دامنه و فازهای هر یک المان‌ها می‌تواند زاویه و فاز بیم بازتابی از LIS را تغییر داد. در حقیقت همان‌طور

¹Multipath fading

که در شکل ۶۵ نشان داده شده است LIS می‌تواند آنتن فرستنده را در محل دیگری از فضا به صورت مجازی تصویر نماید تا بیم آنتن که در برخورد با یک مانع به گیرنده نمی‌رسید بتواند از مکان مجازی با طی مسیر دیدمستقیم به گیرنده برسد. باید این نکته را نیز در نظر داشت که بیم آنتن فرستنده ممکن است به همه المان‌های LIS برخورد نداشته باشد و به اصلاح تنها بخشی از المان‌ها را روشن کند.



شکل ۶۵. عملکرد بازتابی LIS با تصویر کردن فرستنده در محلی از فضا به صورت مجازی [۲۸]


۵-۶- ساخت و پیاده‌سازی LIS

صفحات بزرگ هوشمند، صفحاتی هستند که می‌توانند مشخصات انتشاری محیط را تغییر دهند تا کیفیت سیگنال در گیرنده بهبود یابد. این صفحات از تعداد زیادی المان‌های غیرفعال و ارزان قیمت تشکیل شده‌اند که می‌توانند فاز و همچنین دامنه موجی که به آن‌ها تابیده می‌شود را تغییر دهند. در حقیقت LIS‌ها فراسطوحی هستند که به صورت انعکاس‌دهنده‌های برنامه‌ریزی‌شده عمل می‌نمایند. این فناوری برخلاف رله‌ها و شکل‌دهی پرتو در MIMO نیاز به منبع توان، پردازش پیچیده و الگوریتم‌های کد کردن و دیکد کردن ندارد. به عبارتی این سطوح رادیوهایی هستند که توابع لایه فیزیکی در آن‌ها به صورت نرم‌افزاری تعریف می‌شوند.

متاسفانه یا سطوح انتخاب‌گر فرکانس^۱، سطوحی هستند که به صورت دوبعدی از المان‌های تکرارشونده‌ای تشکیل شده‌اند و می‌توانند در مقابل موج مغناطیسی تابیده‌شده در فرکانس‌های مختلف رفتار متفاوتی داشته باشند. هنگامی که این سطوح به تنهایی به کار می‌روند در مقابل امواج الکترومغناطیسی مانند فیلترهای فضایی عمل می‌کنند. برای مثال می‌توانند در برخی از فرکانس‌ها موج تابیده‌شده را انعکاس داده و در فرکانس‌های دیگری مانند یک صفحه شفاف در مقابل موج عمل کرده و آن را خود عبور دهند. در صفحات RIS المان‌های بازتاب‌دهنده به شکل Patch‌های مربعی یا غیره بر روی یک لایه دی‌الکتریک نازک قرار دارند. در سمت دیگر لایه دی‌الکتریک یک صفحه فلزی قرار داده می‌شود. به این ترتیب موج تابیده‌شده به RIS راهی برای عبور ندارد و تقریباً همه موج بازتاب خواهد شد. المانی که بر روی لایه دی‌الکتریک قرار دارد در حقیقت فاز و دامنه سیگنال برگشتی را می‌تواند کنترل کند. فاز و دامنه موج برگشتی می‌تواند با تغییر شکل و یا اضافه کردن المان‌های فشرده به patch‌ها تغییر کند.

¹Frequency selective surface (FSS)

اضافه کردن المان‌های فشرده‌ای مانند دیودهای ^۱PIN، سوئیچ‌های ^۲MEMS، ترانزیستورهای ^۳FET، و رکتورها و غیره می‌تواند قابلیت کنترل‌پذیری و تغییر پیکربندی ^۴به سطوح RIS بدهد.



شکل ۶۶. ساختار پیاده‌سازی شده از یک LIS و المان آن [۷]

به‌عنوان نمونه همان‌طور که در شکل ۶۶ نشان داده شده است یک RIS از سه لایه و یک کنترل‌کننده تشکیل می‌شود. در لایه خارجی تعداد زیادی از المان‌های Patch بر روی لایه دی‌الکتریک که زیرلایه^۵ نامیده می‌شود چاپ شده‌اند که به‌طور مستقیم با موج در ارتباط هستند. در پشت زیرلایه یک صفحه مسی برای جلوگیری از نشت امواج قرار داده شده است. لایه آخر نیز، مورد کنترل است که وظیفه تنظیم میزان انعکاس و تغییر فاز هر المان را به عهده دارد. FPGA می‌تواند به‌عنوان کنترل‌کننده مورد استفاده قرار گیرد و به‌صورت یک درگاه برای برقراری ارتباطات و هدایت دیگر اجزای شبکه مانند ایستگاه‌های پایه، نقاط دسترسی و کاربران عمل کند. همان‌طور که در شکل ۶۶ ملاحظه می‌شود یک دیود PIN در هر المان LIS استفاده شده که توسط یک ولتاژ بایاس DC کنترل می‌شود و دیود می‌تواند بین دو حالت روشن و خاموش سوئیچ شود. در حالتی که دیود خاموش است یک خازن بین دو لایه‌ای که دیود بین آنها قرار گرفته است تشکیل می‌شود اما در حالتی که دیود روشن می‌گردد، این دو لایه به هم وصل شده و این خازن حذف می‌شود. این خازن توسط موج تابیده‌شده به LIS دیده شده و می‌تواند منجر به اختلاف فاز در موج برگشتی در دو حالت روشن و خاموش دیود شود. مدار معادل المان LIS در زمان خاموش و روشن بودن دیود در شکل ۶۷ نشان داده شده است.


¹positive-intrinsic-negative

²micro-electromechanical system

³Field-effect-transistor


⁴Reconfigurability

⁵substrate



شکل ۶۷. مدار معادل المان LIS در زمان روشن و خاموش بودن دیود [۷]

المان LIS می‌تواند به صورت اشکال مختلفی پیاده شود. برای نمونه در شکل ۶۸ المان LIS به صورت یک شکاف^۱ مربعی در نظر گرفته شده و دیود بر روی شکاف قرار داده شده است. همچنین برای روشن و خاموش نمودن دیود لازم است به یک زمین مشترک برای همه دیودها در نظر گرفته شود و اتصال دیگر حاوی سیگنال کنترلی به Patch‌های مربعی داده شود.




شکل ۶۸. LIS با المان شکاف مربعی و دیود PIN [۱]

همچنین این امکان وجود دارد که با تغییر ولتاژ کنترلی بتوان مقادیر مختلفی را به مدار معادل دیود اختصاص داد و تغییر فازهای بیشتری را ایجاد نمود. اگرچه تنظیم دامنه و فاز هر یک از المان‌های LIS می‌تواند برای کاربردهای مخابراتی مفید باشد پیاده‌سازی عملی آن هزینه‌بر خواهد بود زیرا ساخت چنین المان‌های دقیقی نیاز به طراحی پیچیده و سخت‌افزار گران‌قیمت دارد. همچنین این روش ممکن است مقیاس‌پذیر نباشد و نیاز به المان‌های بسیار زیادی داشته باشد. به عنوان مثال، برای ایجاد ۱۶ سطح از تغییر فاز در المان نشان داده شده در شکل ۶۶ به چهار عدد دیود PIN نیاز است تا در هر المان تعبیه شوند. این کار نه تنها طراحی المان را با چالش مواجه می‌کند بلکه برای کنترل این دیودها نیز به ارتباطات کنترلی بیشتری از سمت کنترل‌کننده نیاز است. در نتیجه برای LIS‌هایی که دارای تعداد زیادی المان هستند، به صرفه‌تر است که تنها تعداد محدودی تغییر فاز و دامنه داشته باشند که نیاز به تعداد کمی بیت کنترلی برای هر المان دارد. به عنوان نمونه یک بیت برای کنترل دامنه (جذب یا بازتاب) و یک بیت برای کنترل اختلاف فاز (۰ یا ۱۸۰ درجه) می‌توان به کار برد. از طرف دیگر برای اینکه بتوان کنترل بیشتری بر روی دامنه موج برگشتی داشت می‌توان از مقاومت‌های متغیر استفاده نمود که بتوان آن‌ها را با ولتاژهای کنترلی تغییر داد. به این ترتیب با توجه به مقدار مقاومت، مقداری از موج الکترومغناطیسی تابیده شده در المان LIS تلف شده و دامنه موج برگشتی کمتر از دامنه موج تابیده شده می‌شود.

¹Slot

همان‌طور که قبلاً اشاره شد علاوه بر استفاده از دیود PIN می‌توان از المان‌های کنترل‌پذیر دیگری نیز در ترکیب با سطوح انتخاب‌گر فرکانس برای پیاده‌سازی LIS‌های با قابلیت پیکربندی مجدد استفاده نمود. در شکل ۶۹ استفاده از ورکتور برای ایجاد قابلیت پیکربندی در LIS با المان patch مربعی نشان داده شده است.



شکل ۶۹. استفاده از ورکتور (خازن متغیر) برای ایجاد قابلیت پیکربندی در LIS [۱]

۶-۶- چالش‌های LIS

علاوه بر پیچیدگی‌های سخت‌افزاری که در قسمت قبل مورد بررسی قرار گرفت، چالش‌های شبکه‌های بی‌سیم مبتنی بر LIS را می‌توان به چند دسته کلی از جمله طراحی شکل‌دهی بیم غیرفعال، به دست آوردن اطلاعات کانال^۱ توسط LIS و موارد کاربرد تقسیم نمود که در ادامه در مورد هر یک توضیحاتی آورده شده است.

۱-۶-۶- شکل‌دهی بیم غیرفعال


یکی از چالش‌های شکل‌دهی بیم غیرفعال برای LIS در عمل، در سطوح ناپیوسته دامنه و تغییر فاز هر المان قرار دارد. به‌جای جستجوی کامل، یک راهکار عملی این است که در ابتدا چنین محدودیت‌هایی را حذف نمود و مسئله را با دامنه‌ها و تغییر فازهای پیوسته حل نمود. سپس مقادیر به‌دست‌آمده را با نزدیک‌ترین مقادیر گسسته جایگزین کرد. گرچه این روش می‌تواند مدت‌زمان محاسبات را کاهش دهد اما ممکن است بازدهی عملکرد را به دلیل خطای به وجود آمده در ناپیوسته کردن^۲ مقادیر از دست بدهد که البته این خطا به تعداد سطوح ناپیوستگی نیز وابسته است. همچنین برای بهبود عملکرد روش‌های بهینه‌سازی مختلف می‌توانند برای پیدا کردن مقادیر دامنه و تغییر فاز به‌صورت تکرارشونده مورد استفاده قرار گیرند.

از طرف دیگر، شکل‌دهی بیم غیرفعال در LIS به‌طور عمومی باید به همراه شکل‌دهی بیم فرستنده در المان‌های فعال شبکه نظیر ایستگاه‌های پایه و نقاط دسترسی، طراحی شود تا بتواند عملکرد شبکه را بهینه نماید. برای مثال زمانی که ارتباط ایستگاه پایه و کاربر توسط یک مانع به‌طور کامل قطع می‌شود، شکل‌دهی پرتو فرستنده می‌تواند بیم آنتن فرستنده را به سمت LIS بچرخاند تا بازتاب سیگنال به سمت گیرنده کاربر حداکثر شود. همچنین زمانی که تلفات ارتباط ایستگاه پایه و کاربر در مقابل تلفات ارتباط بازگشتی از LIS قابل مقایسه باشد، شکل‌دهی پرتو فرستنده باید به گونه‌ای باشد که موازنه‌های بین امواجی که از فرستنده به‌طور مستقیم و از LIS به‌طور بازتابی به گیرنده می‌رسند برقرار شود. در چنین حالت‌هایی دامنه بازتاب از همه المان‌های

¹Channel acquisition

²Quantization


LIS باید حداکثر باشد درحالی که فازهای هر یک باید به گونه‌ای تنظیم شوند که سیگنال بازتابی به صورت سازنده با سیگنال دیدمستقیم فرستنده جمع شود. این کنترل هم‌زمان در شکل ۷۰ نشان داده شده است.



شکل ۷۰. کنترل هم‌زمان LIS و المان‌های فعال در شبکه نظیر ایستگاه‌های پایه و نقاط دسترسی

سیستم‌های مبتنی بر LIS نه تنها از شکل‌دهی پرتو بازتابی بهره می‌برند بلکه می‌توانند تداخل‌های کانال‌های مشابه را نیز حذف نمایند. برای مثال، کاربری که به LIS نزدیک‌تر است می‌تواند نسبت به تداخل ایستگاه پایه مجاور قدرت تحمل بالاتری داشته باشد زیرا شکل‌دهی بیم LIS می‌تواند به گونه‌ای باشد که سیگنال تداخل بازتابی از LIS با سیگنال تداخلی که مستقیماً از ایستگاه پایه سلول مجاور دریافت می‌شود به صورت غیرسازنده و مخرب با یکدیگر جمع شوند تا یکدیگر را در گیرنده کاربر خنثی کنند. این روش باعث می‌شود طراحی شکل‌دهی بیم فرستنده برای ایستگاه‌های پایه مجاور انعطاف‌پذیری بیشتری داشته باشد. با همه این مزایا، طراحی شکل‌دهی پرتو فعال و غیرفعال عموماً به میزان زیادی به یکدیگر وابسته هستند و این باعث می‌شود مسائل ترکیبی آن‌ها، مسائل بهینه‌سازی پیچیده‌ای باشند. به همین دلیل برخی از روش‌های بهینه‌سازی در یک مرحله شکل‌دهی بیم را فقط در فرستنده یا گیرنده بهینه می‌کنند و پارامترهای دیگر را ثابت فرض می‌کنند و در مراحل بعدی پارامترهای ثابت در مرحله قبل بهینه شده و پارامترهای بهینه‌شده در مرحله قبل ثابت فرض می‌شوند. این مراحل تکرار شده تا همگرایی مطلوب حاصل شود. علاوه بر این، شبکه‌های بی‌سیم عموماً در کانال‌های پهن‌بندی به صورت انتخاب فرکانس کار می‌کنند. هرچند ایستگاه‌های پایه فعال می‌توانند از پردازش دیجیتال در حوزه فرکانس مانند شکل‌دهی بیم دیجیتالی یا ترکیبی (دیجیتال و آنالوگ) برای مقابله با تغییرات این کانال‌ها استفاده کنند، استفاده از پردازش سیگنال پیشرفته برای LIS‌های غیرفعال دشوار است. در نتیجه ضریب بازتاب LIS لازم است تا در همه باندهای فرکانسی بهینه شود که خود بر پیچیدگی محاسبات و بهینه‌سازی شکل‌دهی بیم فعال و غیرفعال اضافه می‌کند.


برخی نتایج جالب که در راستای به کارگیری LIS گزارش شده نشان می‌دهد که در یک سیستم تک کاربره، توان دریافتی با افزایش تعداد المان‌های بازتابی (N) تقریباً به صورت توان دوم این تعداد (N^2) توان سیگنال دریافت شده را افزایش می‌دهد به شرطی که تعداد المان‌ها زیاد باشد. به عبارت دیگر با دو برابر کردن تعداد المان‌ها، بهره توان به اندازه 6 dB بالا می‌رود. دلیل این امر این است که LIS نه تنها همانند N آنتن فعال در MIMO انبوه با شکل‌دهی بیم بازتابی توان را N برابر می‌کند بلکه به دلیل ابعاد بزرگی که دارد می‌تواند N برابر انرژی بیشتری از سیگنال ایستگاه پایه دریافت نماید. همچنین نشان داده شده است که هنگامی که تغییرات فاز با b بیت کوانتیزه می‌شوند باز هم توان با نسبت N^2 افزایش می‌یابد مضاف بر این که تلفات توان ثابتی متناسب با b ظاهر خواهد شد. در صورتی که تعداد المان‌ها زیاد باشد، مقدار این تلفات در مقابل N^2 قابل صرف‌نظر خواهد بود.



شکل ۷۱. آنتن ایستگاه پایه، LIS و کاربر تک آنتن در شبیه‌سازی [۷]


در شکل ۷۱ آنتن ایستگاه پایه با $M = 4$ آنتن، صفحه LIS با $N = 5$ المان در نظر گرفته شده‌اند. فاصله افقی ایستگاه پایه تا کاربر d است که متغیر می‌باشد و فاصله افقی ایستگاه پایه و LIS نیز $d_0 = 50 \text{ m}$ است. فرض بر این است که ارتباط غالب، ارتباط دیدمستقیم آنتن ایستگاه پایه و کاربر می‌باشد. ضریب افت مسیر 2.2 و ضریب افت ناشی از محوشدگی رایلی برای هر دو مسیر 3.2 در نظر گرفته شده است. توان نویز گیرنده نیز -80 dbm است. برای نشان دادن کارایی استفاده از LIS در شکل ۷۲ چهار حالت مختلف با یکدیگر مقایسه شده‌اند که عبارتند از:

- بهینه‌سازی همزمان بین LIS غیرفعال و المان‌های فعال [۲۷]
- حالتی که نسبت انتقال ایستگاه پایه و کاربر حداکثر باشد یعنی بیم ایستگاه پایه به سمت کاربر باشد.
- حالتی که نسبت انتقال ایستگاه پایه و LIS حداکثر باشد یعنی بیم ایستگاه پایه به سمت LIS باشد.
- حالتی که بیم ایستگاه پایه به سمت کاربر باشد و LIS حضور نداشته باشد.



شکل ۷۲. توان ارسالی ایستگاه پایه بر حسب فاصله ایستگاه پایه تا کاربر [۷]

در شکل ۷۲ با تغییر پارامتر d حداقل توان ارسالی لازم برای دستیابی به نسبت سیگنال به نویز^۱ (SNR) برابر 20 dB رسم شده است. همان‌طور که ملاحظه می‌شود در حالتی که LIS حضور ندارد، دور شدن کاربر منجر به افزایش توان ارسالی می‌گردد زیرا تلفات مسیر سیگنال بیشتر می‌شود. این مشکل با استفاده از LIS تا حدودی مرتفع می‌شود، زیرا هنگامی که کاربر به LIS نزدیک باشد به‌طور قابل ملاحظه‌ای SNR بهبود می‌یابد. می‌توان مشاهده نمود که هنگامی که کاربر در نزدیک هر کدام از ایستگاه پایه ($d = 20\text{ m}$) یا LIS ($d = 50\text{ m}$) باشد به توان ارسالی کمتری نسبت به حالتی که کاربر از هر دو دور است ($d = 40\text{ m}$) نیاز است. این نمودار به‌طور عملی کاربرد LIS به عنوان ایجاد یک نقطه داغ^۲ سیگنال در نقاط نزدیک به آن را نشان می‌دهد. علاوه بر این ملاحظه می‌شود که استفاده از شکل‌دهی بیم فعال و غیرفعال به‌طور هم‌زمان در طراحی می‌تواند به‌طور قابل ملاحظه‌ای در توان مصرفی در ایستگاه پایه صرفه‌جویی نماید. به این ترتیب یک ناحیه خالی از تداخل^۳ توسط LIS ایجاد می‌شود.



شکل ۷۳. توان ارسالی بر حسب تعداد المان‌های LIS [۷]


در شکل ۷۳ عملکرد LIS در حالی نشان داده شده است که هر کدام از المان‌ها دارای دامنه واحد هستند اما از یک تغییردهنده فاز گسسته عملی با فواصل یکسان با b بیت برای اعمال تغییر استفاده شده است. توان ارسالی بر حسب تعداد المان‌های بازتابی N در حالی رسم شده است که $d = 50\text{ m}$ است. در شکل ۷۳ چهار حالت تغییر فاز پیوسته و زمانی که تغییر فاز با دو بیت و یک بیت به صورت گسسته انجام می‌شود و همچنین حالتی که LIS وجود ندارد مقایسه شده‌اند. همان‌طور که ملاحظه می‌شود در حالت ایده‌آل که تغییر فاز پیوسته فرض شده است توان ارسالی با تغییرات N تقریباً به صورت N^2 کاهش می‌یابد. برای مثال در SNR مشابه، برای $N = 150$ به توان ارسالی 2.5 dBm در فرستنده نیاز است در حالی که این مقدار برای $N = 300$ به -3.5 dBm کاهش می‌یابد. این نتایج نشان می‌دهد که با دو برابر شدن تعداد المان‌ها به‌طور تقریبی بهره 6 dB حاصل شده است. همچنین می‌توان مشاهده نمود که با تغییرات فاز محدود نظیر $b = 1$ و $b = 2$ ، تلفات نسبت به حالت ایده‌آل بیشتر شده و نهایتاً به مقدار ثابتی همگرا می‌شود که به ترتیب برابر 0.9 dB و 3.9 dB است.

¹Signal-to-noise-ratio

²Hotspot

³Interference-free-zone

در حالت دیگری فرض شده که ایستگاه پایه در شکل ۷۱ متعلق به سلول مجاور است که باعث ایجاد تداخل می‌شود و فاصله افقی آن با کاربر $d = 50 \text{ m}$ است. برای حذف این تداخل از LIS استفاده شده است. برای سادگی تعداد آنتن ایستگاه پایه $M = 1$ و توان ارسالی آن 30 dBm در نظر گرفته شده است. در شکل ۷۴ توان تداخل دریافتی در گیرنده برای سه حالت رسم شده است. همان‌طور که ملاحظه می‌شود نسبت به حالتی که LIS وجود ندارد، تداخل حتی در صورتی که تنها تغییرات فاز تنظیم شود به میزان قابل توجهی کاهش می‌یابد. علاوه بر این در حالتی که دامنه و فاز به‌طور هم‌زمان بهینه شوند تداخل به‌طور مؤثرتری نسبت به حالتی که دامنه‌ها یکسان هستند کم خواهد شد، بخصوص زمانی که تعداد المان‌های LIS به اندازه کافی زیاد باشد. در حقیقت اضافه شدن دامنه‌های المان‌های بازتاب‌دهنده LIS درجه آزادی بیشتری برای خنثی کردن سیگنال‌های دریافتی از ایستگاه پایه مجاور در اختیار طراح قرار می‌دهد.



شکل ۷۴. توان تداخل نرمالیزه شده بر حسب تعداد المان‌های LIS [۷]

۲-۶-۶- در یافت اطلاعات وضعیت کانال در LIS

عملکردهای مختلفی که از LIS توسط شکل‌دهی بیم غیرفعال به دست می‌آید، لازمه‌اش اطلاعات دقیق از کانال‌های بین LIS و ایستگاه پایه و همچنین کاربر مرتبط است. با تنظیم LIS بر روی حالت جذب، اطلاعات وضعیت کانال (CSI) ارتباطی بین ایستگاه پایه و کاربر بدون LIS می‌تواند توسط روش‌های معمول تخمین کانال به دست آید [۲۹]. بسته به این که زنجیره‌های RF با المان‌های LIS مجهز شده باشند یا خیر، دریافت CSI بین LIS و ایستگاه پایه/کاربر می‌تواند به دو دسته کلی تقسیم شود:

- در حالت اول هرچند زنجیره‌های RF توان بالا به دلیل کاهش هزینه و صرفه‌جویی در انرژی از LIS‌ها حذف شده‌اند، هرکدام از المان‌ها می‌توانند به یک زنجیره RF گیرنده کم‌توان مجهز شوند تا بتوانند قابلیت حس کردن برای تخمین کانال را داشته باشند. به این ترتیب، کانال‌های ایستگاه پایه/کاربر تا LIS می‌تواند در LIS با استفاده

از هوش مصنوعی و یادگیری ماشین به دست آید. برای کاهش زنجیره‌های RF گیرنده در LIS، روش زیرآرایه^۱ می‌تواند مورد استفاده قرار گیرد که در آن زیرآرایه از دسته‌ای از المان‌های مجاور تشکیل شده است که به صورت افقی یا عمودی قرار گرفته‌اند و هر دسته به یک زنجیره RF گیرنده برای تخمین کانال مجهز شده است. همچنین با تنظیم زیرآرایه‌های مجاور، ضرایب انعکاس از المان‌ها می‌تواند مشابه یا متفاوت باشد.

- در حالت دیگر هنگامی که زنجیره‌های RF گیرنده در LIS نصب نشوند، LIS نمی‌تواند کانال‌های مربوط به ایستگاه پایه/کاربر را مستقیماً تخمین بزند. با این حال، یک روش حل برای این چالش شاید این باشد که به جای تخمین کانال‌های ایستگاه پایه/کاربر به صورت مجزا، کانال‌های وابسته با استفاده از الگوهای بازتابی شناخته شده از LIS (که با خاموش و روشن کردن برخی از المان‌ها ایجاد می‌شوند) تخمین زده شوند. به عنوان روش دیگر، ضرایب بازتاب شکل دهی غیرفعال بیم LIS می‌تواند از بازخورد سیگنال‌های دریافتی در ایستگاه پایه/کاربر که توسط LIS بازتاب داده شده‌اند طراحی شود. در این روش نیز نیاز نیست تا کانال‌های ایستگاه پایه/کاربر به طور مشخص و جداگانه تخمین زده شوند. برای مثال LIS می‌تواند ضرایب شکل دهی بیم بازتابی را طبق یک دفتر کد که از قبل طراحی شده است، بر اساس بازخورد ایستگاه پایه/کاربر سوئیچ کند. برای کاهش پیچیدگی و زمان مورد نیاز برای یادگیری بلادرنگ، داده‌های قبلی نیز می‌تواند مورد استفاده قرار گیرد. برای مثال در مخابرات موج میلی متری با توجه به کمبود کانال، کانال‌های LIS و کاربر معمولاً در فضا به هم وابسته‌اند و ضرایب شکل دهی بیم برای کاربرانی که محل‌های نزدیک به یکدیگر دارند مشابه هستند و با مکان به صورت به تابع نرم تغییر می‌کنند. به این ترتیب برای یک کاربر جدید ضرایب شکل دهی بیم LIS می‌تواند با استفاده از درون‌یابی موارد مربوط به مکان‌های نزدیک در زمان‌های قبل به دست آید.

۳-۶-۶- استفاده از LIS

این که چگونه از LIS در یک شبکه مخابرات بی سیم که از ترکیبی از ایستگاه‌های پایه فعال و LIS‌های غیرفعال تشکیل شده است به طور هوشمندانه استفاده کرده و عملکرد شبکه را بهینه نمود یکی از مسائل مهمی است که باید حل شود. به طور عمومی، این مسئله نیز مانند استفاده از ایستگاه‌های پایه و رله‌های فعال در شبکه‌های قدیمی بی سیم ملاحظات مختلفی دارد. از آنجایی که LIS‌ها تنها برای پوشش دهی محلی مورد استفاده قرار می‌گیرند، برد عملکردی‌شان معمولاً کوتاه‌تر از ایستگاه‌های پایه و رله‌های فعال است. این ویژگی باعث می‌شود تا LIS‌ها بدون ایجاد تداخل برای یکدیگر، با راحتی بیشتری به طور عملی مورد استفاده قرار گیرند.

از منظر بهینه‌سازی بازدهی عملکرد در یک سلول مخابراتی تنها، LIS باید در محلی قرار داشته باشد که دارای دیدمستقیم واضحی از ایستگاه پایه بوده تا سیگنال دریافتی دارای حداکثر توان برای شکل دهی بیم غیرفعال باشد. با این حال زمانی که لازم است LIS ارتباطات هم‌زمان بین ایستگاه پایه و چندین کاربر را در ناحیه تحت پوشش خود پشتیبانی نماید، چنین استراتژی سرراستی ممکن است امکان‌پذیر نباشد. زیرا یک مسیر دیدمستقیم بین LIS و ایستگاه پایه منجر به یک کانال MIMO دارای اولویت پایین^۲ می‌شود که دارای تسهیم (مالتیپلکسینگ) فضایی^۳ برای ارتباطات با چندین کاربر از طریق LIS نیست. بنابراین در عمل محل استفاده از LIS ترجیحاً جایی است که دارای مسیر دیدمستقیم قوی از ایستگاه پایه و همچنین تعداد کافی از مسیرهای غیر دیدمستقیم باشد تا بتواند یک کانال با اولویت بالای MIMO ایجاد نماید و این مصالحه را به این طریق حل نماید.

¹Sub-array

²Low-rank

³Spatial multiplexing

همچنین در استفاده از LIS باید چگالی فضایی کاربر نیز در نظر گرفته شود. برای مثال زمانی که لازم باشد در محلی با تعداد کاربران زیاد از LIS به عنوان نقطه دسترسی استفاده نمود یا در یک سلول تداخل داخل سلولی را کاهش داد و یا در ناحیه مرزی بین دو سلول تداخل ناشی از ایستگاه پایه مجاور را خنثی کرد باید به این مسئله توجه نمود.

در عمل محیط انتشار ممکن است پیچیده بوده و هر LIS می‌تواند با چندین ایستگاه پایه در ارتباط باشد. در چنین حالت‌هایی ممکن است جستجو برای پیدا کردن محل بهینه نیاز به CSI کلی در همه محل‌ها داشته باشد که در عمل به دست آوردن آن آسان نیست. روش‌های مبتنی بر دنبال کردن پرتو^۱ می‌توانند برای تخمین چنین CSI ای به کار روند اما آن‌ها از لحاظ محاسباتی سنگین و هزینه‌بر هستند و همچنین نیاز به اطلاعات دقیقی از محل دارند (برای مثال نقشه ساختمان یا طبقه برای مخابرات داخل ساختمان). در نتیجه این که چگونه به‌طور خودکار LIS با شناسایی مناسب‌ترین محل‌ها برای نصب به کار برده شود یک مسئله جدید با جذابیت عملی بسیار بالاست. یک روش امیدوارکننده برای حل این مشکل استفاده از روش‌های پیشرفته یادگیری ماشین نظیر یادگیری عمیق^۲ (DL) است. برای مثال در مرحله آموزش، می‌توان LIS ها را در محل‌های مرجع انتخاب‌شده‌ای قرار داد و پارامترهای کلیدی عملکرد را جمع‌آوری نمود. این مکان‌های LIS و پارامترهای عملکردی مربوطه سپس برای یادگیری یک شبکه عصبی مبتنی بر یادگیری عمیق به عنوان ورودی و خروجی مورد استفاده قرار می‌گیرد. سپس در مرحله به کارگیری، با پارامترهای عملکردی مطلوب به عنوان ورودی، شبکه DL آموزش داده شده برای پیش‌بینی یک دسته از مکان‌ها برای استفاده از LIS استفاده می‌شود. پس از اینکه LIS در این مکان‌ها به کار گرفته شد، پارامترهای عملکردی جدیدی می‌تواند جمع‌آوری شده تا دقت پیش‌بینی در آینده افزایش پیدا کند.

۶-۷- نتیجه‌گیری فصل ۶

با رشد روزافزون دنیای اطلاعات و ارتباطات، مخابرات بی‌سیم نقش مهمی در زندگی آینده انسان‌ها خواهد داشت. بسیاری از فناوری‌های جدید نظیر واقعیت مجازی، واقعیت افزوده، خودروهای خودران و... به پهنای باند بسیار وسیعی برای انتقال اطلاعات نیاز دارند که حتی نسل‌های جدید مخابرات بی‌سیم نظیر 5G نیز قادر به پاسخ‌گویی مناسب به آن‌ها نیست. باین حال فناوری‌های زیادی نیز معرفی شده‌اند که امید است به پیاده‌سازی نسل‌های بعدی مخابرات نظیر 6G کمک کنند.

صفحات بزرگ هوشمند که با نام‌های مختلفی نظیر صفحات بازتابی هوشمند، آنتن‌های آرایه‌ای بازتابی هوشمند و غیره نیز شناخته شوند یکی از فناوری‌هایی هستند که اخیراً برای کنترل محیط پیرامون مورد تحقیق و بررسی قرار گرفته‌اند. این صفحات می‌توانند در رنج وسیع فرکانسی از ماکروبو تا نوری برای کنترل امواج به کار روند. با ترکیب این صفحات با المان‌های قابل سوئیچ، می‌توان صفحاتی دارای قابلیت پیکربندی داشت که می‌توانند مشخصاتی از موج تابشی نظیر دامنه، فاز و پلاریزاسیون را تغییر دهند.

در سیستم‌های مخابرات بی‌سیم امروزی، محیط پیرامون و اجسام فیزیکی می‌توانند بر روی انتشار و دریافت امواج الکترومغناطیسی تأثیرگذار باشند و بسیاری از موانع سیار کنترل‌پذیر نیستند. در زمان طراحی سیستم‌های مخابرات بی‌سیم می‌توان فرستنده و گیرنده، الگوریتم‌های پردازش سیگنال و پروتکل‌های انتقال را برای تطبیق با محیط طراحی نمود. در صورتی که صفحات بزرگ هوشمند سعی دارند محیط اطراف را کنترل‌پذیر و برنامه‌پذیر کنند و به این ترتیب پوشش و بازدهی سیستم‌های مخابراتی را افزایش دهند.

این صفحات می‌توانند در سناریوهای مختلفی برای تقویت یا تضعیف سیگنال در گیرنده مورد بهره‌برداری قرار گیرند. زمانی که مانعی، مسیر دیدمستقیم بین فرستنده و گیرنده را مسدود می‌کند با استفاده از این صفحات بازتابنده مسیر جایگزینی برای رسیدن امواج ایجاد می‌شود. همچنین با ارسال امواج هم‌فاز با امواج دیدمستقیم می‌توانند باعث تقویت توان سیگنال دریافتی شوند.

¹Ray-tracing

²Deep learning

از طرف دیگر با ارسال امواجی با ۱۸۰ درجه اختلاف فاز و دامنه برابر با امواج دیدمستقیم می‌تواند توان سیگنال دریافتی را در محل‌هایی که احتمال شنود داده می‌شود تضعیف کنند و مخابرات امنی را ایجاد نمایند.

صفحات بزرگ هوشمند معمولاً دارای ابعادی بسیار بزرگ‌تر از طول موج هستند و می‌توانند به دیوارها، سقف و بر روی دکل‌ها نصب شوند. این صفحات از المان‌های بازتابی تکرارشونده‌ای در دو بعد تشکیل شده‌اند که با کنترل دامنه و فاز المان‌ها موج بازتابی را در زاویه و فاز دلخواه هدایت می‌کنند. روش‌های مختلف هوش مصنوعی و یادگیری ماشین مانند یادگیری عمیق می‌توانند در تعیین دامنه و فاز هر یک از المان‌ها در طراحی و عملکرد LIS‌ها مفید باشند. از آنجاکه این المان‌ها غیرفعال هستند می‌توانند در مصرف توان و هزینه نسبت به فناوری‌هایی مانند رله‌های فعال صرفه‌جویی کنند.

علاوه بر LIS‌های غیرفعال آنتن‌های ایستگاه پایه و رله‌های فعال نیز در سیستم مخابراتی بی‌سیم مشغول به کار هستند و نشان داده شده است که بهترین عملکرد زمانی حاصل می‌شود که شکل‌دهی بیم آنتن در المان‌های فعال و غیرفعال به صورت هم‌زمان انجام گیرد. از آنجایی که در یک سیستم مخابراتی تعداد آنتن‌های ایستگاه پایه و کاربران زیاد است بهینه‌سازی هم‌زمان المان‌های فعال و غیرفعال از چالش‌های طراحی محسوب می‌شود. همچنین به دست آوردن اطلاعات کانال‌های ایستگاه پایه و کاربران که در کانال‌هایی با فرکانس‌های مختلف در حال ارتباط هستند از دیگر چالش‌های LIS محسوب می‌شود که راهکارهایی نیز بر اساس استفاده از یادگیری عمیق برای آن داده شده است.

مراجع فصل ۱

- [1] E. Basar, M. Di Renzo, J. De Rosny, M. Debbah, M.-S. Alouini, and R. Zhang, "Wireless communications through reconfigurable intelligent surfaces," *IEEE Access*, vol. 7, pp. 116753-116773, 2019.
- [2] H. Guo, Y.-C. Liang, J. Chen, and E. G. Larsson, "Weighted sum-rate optimization for intelligent reflecting surface enhanced wireless networks," *arXiv preprint arXiv:1905.07920*, 2019.
- [3] S. Hu, F. Rusek, and O. Edfors, "The potential of using large antenna arrays on intelligent surfaces," in *2017 IEEE 85th Vehicular Technology Conference (VTC Spring)*, 2017, pp. 1-6.
- [4] S. Hu, F. Rusek, and O. Edfors, "Beyond massive MIMO: The potential of data transmission with large intelligent surfaces," *IEEE Transactions on Signal Processing*, vol. 66, pp. 2746-2758, 2018.
- [5] C. Huang, A. Zappone, G. C. Alexandropoulos, M. Debbah, and C. Yuen, "Reconfigurable intelligent surfaces for energy efficiency in wireless communication," *IEEE Transactions on Wireless Communications*, vol. 18, pp. 4157-4170, 2019.
- [6] M. Jung, W. Saad, Y. Jang, G. Kong, and S. Choi, "Performance analysis of large intelligent surfaces (LISs): Asymptotic data rate and channel hardening effects," *IEEE Transactions on Wireless Communications*, vol. 19, pp. 2052-2065, 2020.
- [7] Q. Wu and R. Zhang, "Towards smart and reconfigurable environment: Intelligent reflecting surface aided wireless network," *IEEE Communications Magazine*, 2019.
- [8] J. Zhao and Y. Liu, "A survey of intelligent reflecting surfaces (IRSs): Towards 6G wireless communication networks," *arXiv preprint arXiv:1907.04789*, 2019.
- [9] L. Sanguinetti, E. Björnson, and J. Hoydis, "Towards Massive MIMO 2.0: Understanding spatial correlation, interference suppression, and pilot contamination," *IEEE Transactions on Communications*, 2019.
- [10] C. Liaskos, S. Nie, A. Tsioliaridou, A. Pitsillides, S. Ioannidis, and I. Akyildiz, "A new wireless communication paradigm through software-controlled metasurfaces," *IEEE Communications Magazine*, vol. 56, pp. 162-169, 2018.
- [11] A. N. Parks, A. Liu, S. Gollakota, and J. R. Smith, "Turbocharging ambient backscatter communication," *ACM SIGCOMM Computer Communication Review*, vol. 44, pp. 619-630, 2014.
- [12] T. S. Rappaport, G. R. MacCartney, M. K. Samimi, and S. Sun, "Wideband millimeter-wave propagation measurements and channel models for future wireless communication system design," *IEEE Transactions on Communications*, vol. 63, pp. 3029-3056, 2015.
- [13] J. G. Andrews, X. Zhang, G. D. Durgin, and A. K. Gupta, "Are we approaching the fundamental limits of wireless network densification?," *IEEE Communications Magazine*, vol. 54, pp. 184-190, 2016.
- [14] S. Hu, F. Rusek, and O. Edfors, "Cramér-Rao lower bounds for positioning with large intelligent surfaces," in *2017 IEEE 86th Vehicular Technology Conference (VTC-Fall)*, 2017, pp. 1-6.
- [15] S. Hu, F. Rusek, and O. Edfors, "Capacity degradation with modeling hardware impairment in large intelligent surface," in *2018 IEEE Global Communications Conference (GLOBECOM)*, 2018, pp. 1-6.
- [16] M. Jung, W. Saad, Y. Jang, G. Kong, and S. Choi, "Uplink data rate in large intelligent surfaces: Asymptotic analysis under channel estimation errors," 2018.

- [17] M. Jung, W. Saad, Y. Jang, G. Kong, and S. Choi, "Reliability analysis of large intelligent surfaces (LISs): Rate distribution and outage probability," *IEEE Wireless Communications Letters*, vol. 8, pp. 1662-1666, 2019.
- [18] M. Di Renzo and J. Song, "Reflection probability in wireless networks with metasurface-coated environmental objects: an approach based on random spatial processes," *EURASIP Journal on Wireless Communications and Networking*, vol. 2019, p. 99, 2019.
- [19] Z.-Q. He and X. Yuan, "Cascaded channel estimation for large intelligent metasurface assisted massive MIMO," *IEEE Wireless Communications Letters*, 2019.
- [20] X. Tan, Z. Sun, J. M. Jornet, and D. Pados, "Increasing indoor spectrum sharing capacity using smart reflect-array," in *2016 IEEE International Conference on Communications (ICC)*, 2016, pp. 1-6.
- [21] X. Tan, Z. Sun, D. Koutsonikolas, and J. M. Jornet, "Enabling indoor mobile millimeter-wave networks based on smart reflect-arrays," in *IEEE INFOCOM 2018-IEEE Conference on Computer Communications*, 2018, pp. 270-278.
- [22] C. Huang, A. Zappone, G. C. Alexandropoulos, M. Debbah, and C. Yuen, "Large intelligent surfaces for energy efficiency in wireless communication," *arXiv preprint arXiv:1810.06934*, 2018.
- [23] E. Basar, "Reconfigurable intelligent surface-based index modulation: A new beyond MIMO paradigm for 6G," *IEEE Transactions on Communications*, vol. 68, pp. 3187-3196, 2020.
- [24] C. Liaskos, A. Tsioliaridou, S. Nie, A. Pitsillides, S. Ioannidis, and I. Akyildiz, "An interpretable neural network for configuring programmable wireless environments," in *2019 IEEE 20th International Workshop on Signal Processing Advances in Wireless Communications (SPAWC)*, 2019, pp. 1-5.
- [25] C. Huang, A. Zappone, M. Debbah, and C. Yuen, "Achievable rate maximization by passive intelligent mirrors," in *2018 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2018, pp. 3714-3718.
- [26] D. Mishra and H. Johansson, "Channel estimation and low-complexity beamforming design for passive intelligent surface assisted MISO wireless energy transfer," in *ICASSP 2019-2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2019, pp. 4659-4663.
- [27] Q. Wu and R. Zhang, "Intelligent reflecting surface enhanced wireless network via joint active and passive beamforming," *IEEE Transactions on Wireless Communications*, vol. 18, pp. 5394-5409, 2019.
- [28] W. Tang, M. Z. Chen, X. Chen, J. Y. Dai, Y. Han, M. Di Renzo, *et al.*, "Wireless communications with reconfigurable intelligent surface: Path loss modeling and experimental measurement," *arXiv preprint arXiv:1911.05326*, 2019.
- [29] L. Lu, G. Y. Li, A. L. Swindlehurst, A. Ashikhmin, and R. Zhang, "An overview of massive MIMO: Benefits and challenges," *IEEE journal of selected topics in signal processing*, vol. 8, pp. 742-758, 2014.

فصل ۷. بررسی کاربردهای شبکه‌های عصبی در سیستم‌های MIMO انبوه

۷-۱- مقدمه

MIMO یکی از روش‌های آنتن‌های چندگانه^۱ در مخابرات بی‌سیم است. روش‌های آنتن چندگانه را می‌توان به دو روش کلی تکنیک‌های متنوع سازی^۲ و تسهیم فضایی^۳ دسته‌بندی نمود. در دسته اول، سیگنال مشابهی توسط چندین آنتن دریافت می‌شود یا توسط چندین آنتن در فرستنده ارسال می‌گردد. در نتیجه باعث بالا بردن قابلیت اطمینان انتقال اطلاعات می‌شود. به این ترتیب اگر در یک ارتباط مخابراتی بی‌سیم، به‌طور هم‌زمان در گیرنده و فرستنده از چندین آنتن استفاده شود می‌تواند بهره متنوع سازی و قابلیت اطمینان را بیشتر افزایش دهد. در دسته دوم، چندین جریان داده مستقل می‌توانند به‌طور هم‌زمان ارسال شوند و سرعت انتقال اطلاعات را بالا ببرند. در روش تسهیم فضایی، حداکثر سرعت انتقال اطلاعات قابل دسترس همانند ظرفیت کانال MIMO است اما در روش متنوع سازی، سرعت انتقال بسیار کم‌تر از ظرفیت کانال MIMO است.

در مخابرات بی‌سیم کاربردهای مختلفی برای آنتن‌های چندگانه وجود دارد. با در اختیار داشتن اطلاعات وضعیت کانال در فرستنده، چندین آنتن در فرستنده می‌تواند بهره کانال به همراه شکل‌دهی بیم را فراهم نماید. فناوری MIMO با چندین آنتن در گیرنده و فرستنده معرفی شده است. صنعت مخابرات بی‌سیم امروز یک رشد طولانی‌نمایی و بدون نشانه‌ای از کاهش را به خاطر افزایش تقاضا برای ترافیک شبکه تجربه می‌کند. همین رشد نیز را نیز می‌توان برای تعداد ادوات متصل به شبکه نیز متصور بود. شبکه‌های امروزی با توجه به محدودیت‌های لایه فیزیکی در حال رسیدن به حداکثر ظرفیت خود هستند و این مسئله در مناطق پرجمعیت شهری با تراکم بالای ادوات متصل به شبکه پررنگ‌تر است. در نتیجه سؤال اصلی در شبکه‌های بی‌سیم چگونه افزایش ظرفیت کانال برای تطبیق با نیاز ترافیکی است که به صورت نمایی روبه افزایش می‌باشد. حداکثر ظرفیت یک شبکه بی‌سیم مستقیماً به ناحیه انتقال شبکه مربوط است که از ضرب سه عامل پهنای باند در دسترس، چگالی سلول و بازدهی طیف فرکانسی به دست می‌آید. در نتیجه، نرخ انتقال بالاتر با استفاده از اختصاص طیف فرکانسی بیشتر، افزایش تعداد سلول‌ها در یک ناحیه و بهبود بازدهی طیف فرکانسی می‌تواند فراهم شود. در حقیقت فناوری MIMO بازدهی طیف فرکانسی را بهبود می‌بخشد و بدون افزایش پهنای باند در دسترس، ظرفیت سیستم مخابرات بی‌سیم را افزایش می‌دهد. در مخابرات بی‌سیم، MIMO یک المان مهم در استانداردهای مخابراتی مختلف نظیر IEEE 802.11n (Wi-Fi)، IEEE 802.11ac (Wi-Fi)، Wi-MAX، 4G و LTE (4G) به شمار می‌رود. اخیراً نیز برای مخابرات PLC^۴ با سه سیم استفاده شده که قسمتی از استاندارد ITU G.hn و مشخصات Home Plug AV2 است. یک آنتن ایستگاه پایه سلولی و یک نقطه دسترسی Wi-Fi که هر دو با چندین آنتن تجهیز شده‌اند به عنوان مثالی از فناوری MIMO در زندگی روزمره در شکل ۷۵ آورده شده است.



¹Multiple antenna technique

²Diversity technique

³Spatial multiplexing

⁴Power line communication


(ب)

(الف)

شکل ۷۵. آنتن چندگانه برای الف) نقطه دسترسی و ب) ایستگاه پایه در مخابرات سلولی [۱]

۷-۲- انواع سیستم‌های چند ورودی-چند خروجی (MIMO)


به‌طور کلی می‌توان سیستم‌های MIMO را به دو دسته سیستم‌های MIMO تک کاربره و MIMO چند کاربره تقسیم‌بندی نمود. همان‌طور که در شکل ۷۶ نشان داده شده است در MIMO تک کاربره، فرستنده و گیرنده با آنتن‌های چندگانه مجهز شده‌اند. بهبود عملکردی در ناحیه پوشش‌دهی آنتن‌ها، قابلیت اطمینان ارتباط و افزایش نرخ داده می‌تواند با استفاده از روش‌هایی مانند شکل‌دهی بیم، کدینگ فضا-زمان بر پایه متنوع‌سازی^۱ و تسهیم فضایی برای چندین جریان داده اطلاعات فراهم شود. این روش‌ها همگی نمی‌توانند به‌طور کامل و به‌صورت هم‌زمان پیاده شوند و باید مصالح‌های بین آن‌ها انجام شود. برای مثال یک سوئیچ‌زنی بهینه بین متنوع‌سازی و تسهیم فضایی در شبکه LTE تعبیه شده است.



شکل ۷۶. سیستم MIMO تک کاربره [۱]

در سیستم‌های MIMO چند کاربره که در شکل ۷۷ نشان داده شده است، شرایط به میزان زیادی متفاوت از MIMO تک کاربره می‌باشد. در این حالت کانال بی‌سیم به صورت فضایی بین کاربران مختلفی به اشتراک گذاشته می‌شود. با استفاده از مشخصات (امضاها) فضایی^۲ مختلف که توسط کاربران در نقاط مختلف فضایی در آنتن‌های آرایه‌ای ایستگاه پایه القا می‌شود، ایستگاه پایه می‌تواند با کاربران مختلف به‌طور هم‌زمان ارتباط برقرار کند. در نتیجه بهبود عملکرد در نرخ داده تجمعی می‌تواند بسیار قابل توجه باشد. چالش اصلی ایجاد تداخل بین کاربران کانال مشترک^۳ است و پردازش سیگنال در MIMO چند کاربره معمولاً به‌منظور حذف تداخل بین کاربری استفاده می‌گردد. در نتیجه اطلاعات کانال‌ها در مقایسه با MIMO تک کاربره اهمیت بیشتری دارند. به‌طور کلی با استفاده از حوزه فضایی کانال‌های بی‌سیم، MIMO مزایای کلیدی زیادی نسبت به سیستم‌های تک آنتن دارد. پوشش‌دهی بهتر با استفاده از شکل‌دهی بیم و افزایش قابلیت اطمینان از طریق تسهیم فضایی و کاهش تأخیر برخی از مزایای MIMO چند کاربره نسبت به MIMO تک کاربره است.


¹Diversity-oriented spece-time coding²Spatial signitures³Co-channel usres



شکل ۷۷. سیستم‌های MIMO چند کاربره [۱]

۳-۷- MIMO انبوه


امروزه یک راه جدید برای افزایش بازدهی طیف فرکانسی، MIMO انبوه یا MIMO در مقیاس بزرگ است. در این ایده تعداد آنتن‌های ایستگاه پایه به میزان بسیار زیادی (در حدود صدها و هزاران) افزایش می‌یابد. این فناوری می‌تواند توان ارسالی را تنها روی هدف یا کاربر موردنظر متمرکز کند. در نتیجه امکان اتصال تعداد کاربران خیلی بیشتری به شبکه فراهم می‌شود و بازدهی ترافیک داده بالا می‌رود. همان‌طور که در شکل ۷۸ ملاحظه می‌شود در سیستم‌های مخابراتی امروزی 4G/LTE، حداکثر تعداد آنتن در ایستگاه پایه ۲۴۰ عدد است که ناحیه پوشش دهی به سه قسمت^۱ ۱۲۰ درجه‌ای تقسیم شده و برای کاربران مختلف در یک قسمت می‌بایست کانال‌های فرکانسی مختلفی تخصیص داده شود.



شکل ۷۸. سیستم‌های MIMO انبوه در مقابل سیستم‌های مخابراتی امروزی (LTE)

MIMO انبوه یکی از فراهم‌کنندگان زیرساخت جامعه دیجیتال آینده است و اینترنت اشیا^۲ و اینترنت مردم^۳ را به ابرها و دیگر زیرساخت‌های شبکه متصل خواهد نمود. همان‌طور که در شکل ۷۹ نشان داده شده است، پیکربندی و سناریوهای استفاده بسیار مختلفی برای آرایه‌های آنتن مورد استفاده توسط یک سیستم MIMO انبوه می‌توان متصور بود. هر آنتن واحد کوچک و فعال خواهد بود و ترجیحاً توسط باس الکترونیک دیجیتال یا نوری تغذیه می‌شود.

¹sector²Internet of Things³Internet of People




شکل ۷۹. برخی از پیکربندی آنتن‌ها و سناریوهای استفاده برای یک ایستگاه پایه MIMO انبوه [۲]

۷-۳-۱- مزایای MIMO انبوه

در این قسمت به مهم‌ترین مزایا و معایب MIMO انبوه از جمله افزایش ظرفیت و بازدهی مصرف توان، امکان استفاده از ادوات کم‌توان و با قیمت پایین در پیاده‌سازی و ساخت، کاهش تأخیر، لایه‌های متعدد دسترسی و افزایش مقاومت در برابر تداخل و جمینگ اشاره می‌شود.

۷-۳-۱-۱ افزایش ظرفیت و بازدهی مصرف توان

MIMO انبوه می‌تواند ظرفیت را ده برابر و به‌طور هم‌زمان بازدهی انرژی منتشرشده را صد برابر کند. افزایش ظرفیت ناشی از تسهیم فضایی در MIMO انبوه است. اصل پایه‌ای که افزایش چشمگیر بازدهی انرژی را ممکن می‌کند این است که با تعداد زیادی آنتن، انرژی را می‌توان با بیم بسیار تیزی بر روی نقاط کوچکی از فضا متمرکز نمود. این ویژگی بر اساس پدیده فیزیکی جمع هم‌فاز جبهه‌های موج است. به این ترتیب ایستگاه پایه با شکل دادن به بیم می‌تواند تضمین کند که همه امواج به‌صورت سازنده در محل گیرنده جمع شده و در همه مکان‌های دیگر به‌صورت غیرسازنده و خنثی‌کننده با یکدیگر جمع می‌شوند. تداخل بین گیرنده‌ها حتی می‌تواند با استفاده از روش ZF به میزان بیشتری حذف گردد، هرچند باعث هزینه بالاتر به دلیل توان ارسالی بیشتر خواهد شد. در شکل ۸۰ دو نمونه الگوی تشعشی آنتن آرایه‌ای با استفاده از شکل‌دهی بیم ZF و MTR نشان داده شده است.



شکل ۸۰. شکل‌دهی بیم و پترن تشعشعی آرایه خطی از آنتن‌ها با دو روش MRT^۱ و ZF^۲


به‌طور کمی در نمودار نشان داده شده در شکل ۸۱، مصالحه بین بازدهی انرژی و بازدهی طیف فرکانسی آورده شده است. بازدهی انرژی به‌صورت تعداد بیت‌های انتقال داده‌شده به ازای هر ژول انرژی به ازای هر گیرنده که درازای انرژی مصرف‌شده اطلاعات را دریافت کرده است و بازدهی طیف به‌صورت تعداد بیت ارسالی در هر ثانیه (نرخ اطلاعات ارسالی) به ازای مصرف یک واحد از پهنای باند تعریف شده‌اند. در این نمودار ۴ حالت مختلف زیر با یکدیگر مقایسه شده‌اند:

- یک سیستم مرجع یا یک آنتن که با یک گیرنده تنها در ارتباط است (نمودار بنفش‌رنگ)
- یک سیستم متشکل از ۱۰۰ آنتن که با یک گیرنده تنها با استفاده از شکل‌دهی بیم ارتباط برقرار می‌کند (نمودار سبزرنگ)
- یک سیستم MIMO انبوه با ۱۰۰ آنتن که به‌طور هم‌زمان به چندین گیرنده (در حدود ۴۰ آنتن) سرویس می‌دهد. نمودار قرمز رنگ مربوط به شکل‌دهی بیم MRC^۲ و آبی‌رنگ مربوط به ZF است.

جذابیت روش MRC نسبت به ZF به دلیل سادگی محاسبات و همچنین استفاده از آن به‌صورت توزیع‌شده و به‌طور مستقل در هر آنتن واحد است. این در حالی است که ZF به‌خوبی برای یک سیستم MIMO معمولی یا با ابعاد متوسط کار می‌کند ولی برای MRC این‌گونه نیست. دلیل اینکه MRC برای MIMO انبوه مناسب می‌باشد این است که با زیاد شدن تعداد آنتن‌ها، کانال‌هایی که مربوط به گیرنده‌های مختلف هستند تقریباً به‌صورت عمود بر هم درمی‌آیند.

¹Maximum ratio transmission

²Maximum ratio combining



شکل ۸۱. نمودار بازدهی انرژی به بازدهی طیف فرکانسی [۲]

نتایجی که در شکل ۸۱ نشان داده شده است بر اساس تحلیل تئوری اطلاعات می‌باشد که تداخل داخل سلولی و همچنین هزینه پهنای باند و توان را برای استفاده از پایلوت‌ها برای به دست آوردن اطلاعات وضعیت کانال در محیطی با سیار بودن بالا در نظر می‌گیرد.

۲-۱-۳ پیاده‌سازی MIMO انبوه با ادوات ارزان قیمت و توان پایین

MIMO انبوه فناوری‌ای است که قواعد بازی را با توجه به تئوری، سیستم‌ها و پیاده‌سازی تغییر می‌دهد. با MIMO انبوه، تقویت‌کننده‌های گران قیمت و بسیار خطی 50W توسط صدها تقویت‌کننده ارزان قیمت با خروجی در حدود میلی وات جایگزین می‌شوند. این فناوری برخلاف طراحی‌های آرایه‌های قدیمی است که از چند آنتن محدود که با تقویت‌کننده‌های توان بالا تغذیه می‌شدند، استفاده می‌کردند. برخی از ادوات گران قیمت و حجیم دیگر مانند کابل‌های کواکسیال بزرگ نیز می‌توانند حذف شوند (کابل‌های کواکسیال برای ایستگاه‌های پایه که بر روی دکل‌های بلند نصب می‌شوند بیش از 4 cm قطر دارند).


همچنین MIMO انبوه شروط و محدودیت‌ها روی دقت و خطی بودن هر تقویت‌کننده و زنجیره RF را کاهش می‌دهد. چیزی که در این فناوری اهمیت دارد نتیجه ترکیبی از آن‌ها است. به این ترتیب MIMO انبوه به این اصل متکی است که تعداد زیاد آنتن موجب می‌شود تا نویز، محوشدگی و خرابی سخت‌افزاری زمانی که سیگنال‌ها از تعداد زیادی آنتن در فضا با یکدیگر جمع می‌شوند به‌طور متوسط کاهش یابد. همین خاصیت که باعث افزایش انعطاف نسبت به محوشدگی می‌گردد می‌تواند سیستم را در مقابل ازکارافتادن یک یا چندین آنتن نیز مقاوم نماید.

یک سیستم MIMO انبوه درجه‌های آزادی استفاده نشده زیادی دارد. برای مثال، ۲۰۰ آنتن که به ۲۰ گیرنده در ارتباط هستند، ۱۸۰ درجه آزادی استفاده نشده دارند. این درجات آزادی می‌تواند برای شکل‌دهی به سیگنال که برای سخت‌افزار مناسب باشد به کار رود. برای مثال هر آنتن می‌تواند سیگنال را با نسبت حداکثر به میانگین^۱ خیلی کم [۳] یا حتی با پوش ثابت به قیمت افزایش کمی در کل توان تشعشعی [۴]، ارسال نماید. چنین پوش سیگنالینگ تقریباً ثابتی باعث می‌شود بتوان از تقویت‌کننده‌های بسیار ارزان قیمت و کم مصرف استفاده نمود. روش‌های استفاده شده در [۳، ۴] را نباید با روش‌های معمول شکل‌دهی بیم یا روش‌های

¹Peak-to-average ratio

شکل‌دهی بیم با دامنه برابر اشتباه گرفت. این تفاوت در شکل ۸۲ نشان داده شده است که همان‌طور که ملاحظه می‌شود دامنه سیگنال ورودی به آنتن در شکل‌دهی معمولی بیم آنتن در MIMO می‌تواند دارای محدوده بزرگی باشد، اما در MIMO انبوه، سیگنال دهی به هر آنتن با دامنه ثابت و فاز متغیر صورت می‌گیرد. کانال‌های مؤثری که MIMO انبوه می‌تواند به وجود آورد نیاز به مدولاسیون^۱ PSK را نیز از بین خواهد برد.

بهبود قابل‌توجه بازدهی مصرف انرژی، سیستم‌های MIMO را قادر می‌سازد تا بتوانند توان خروجی را تا حدود ۱۰۰ برابر نسبت به سیستم‌های کنونی کاهش دهند. این ویژگی می‌تواند اهمیت ویژه‌ای داشته باشد زیرا مصرف انرژی ایستگاه‌های پایه مخابرات سلولی در جهان رو به افزایش است. علاوه بر این، ایستگاه پایه‌ای که بتواند به میزان ۱۰۰ برابر توان کم‌تر مصرف کند می‌تواند با توربین‌های بادی یا سلول‌های خورشیدی کار کند. به این ترتیب می‌توان سیستم‌های مخابراتی را در مکان‌هایی که دسترسی به شبکه برق برای تأمین انرژی وجود ندارد راه‌اندازی نمود. مزیت دیگر کاهش انرژی پخش‌شده در فضا است که می‌تواند منجر به کاهش تداخل گردد و همچنین نگرانی‌هایی که ناشی از تأثیر تابش و در معرض امواج الکترومغناطیسی بودن وجود دارد را کم کند.



شکل ۸۲. مقایسه شکل‌دهی معمولی بیم آنتن در MIMO با ارسال با دامنه ثابت در هر آنتن در MIMO انبوه [۲]

۳-۱-۳-۷ کاهش چشمگیر تأخیر در واسطه هوایی

عملکرد مخابرات بی‌سیم به‌طور عادی با محوشدگی محدود می‌شود. محوشدگی می‌تواند قدرت سیگنال دریافت شده را در زمان‌های خاصی بسیار کوچک نماید. این پدیده زمانی رخ می‌دهد که سیگنالی که از ایستگاه پایه فرستاده می‌شود در مسیرهای مختلف دچار اختلاف فازهای مختلف شده و امواج رسیده به گیرنده به‌صورت غیرسازنده و مخرب دریافت شوند. به این دلیل است که ایجاد ارتباطات بی‌سیم با تأخیر کم، کار دشواری است. اگر گیرنده در یک نقطه دارای محوشدگی گیر بیفتد، باید صبر کند تا کانال انتشاری به گونه‌ای تغییر کند تا بتواند هر داده‌ای را دریافت کند. MIMO انبوه از تعداد زیادی آنتن شکل‌دهی بیم استفاده می‌کند تا از نقاط محوشدگی بر حذر باشد و تأخیر نمی‌تواند این سیستم‌ها را محدود نماید.

¹Phase shift keying

۷-۳-۱-۴ لایه‌های دسترسی متعدد

با استفاده از OFDM^۱ هر یک از زیرحامل‌ها در سیستم MIMO انبوه، بهره کانال مشابه خواهد داشت. هر گیرنده می‌تواند همه پهنای باند را داشته باشد و به این ترتیب بسیاری از سیگنالینگ‌های کنترلی در لایه فیزیکی مازاد خواهد بود و می‌تواند حذف شود.

۷-۳-۱-۵ افزایش مقاومت در برابر تداخل غیر عمد و جمینگ^۲ عمدی

جمینگ عمدی سیستم‌های بی‌سیم شهری یک مسئله‌ای است که در حال گسترش است و یک تهدید امنیتی سایبری است که کمتر به مردم شناسانده شده است. جمرهای ساده می‌توانند با کمتر از چند صد دلار از اینترنت خریداری شوند و جمرهایی که قبلاً کاربرد نظامی داشتند به همراه پلتفرم‌های مبتنی بر رادیو نرم‌افزاری را نیز با چند هزار دلار می‌توان در اختیار داشت. اتفاقات متعدد اخیر، بخصوص در کاربردهای امنیت عمومی، ابعاد این مسئله را نشان می‌دهد. به عنوان نمونه در اجلاس سران اروپا در گوتنبرگ سوئد در سال ۲۰۰۱، تظاهرکنندگان جمری را در آپارتمان نزدیک قرار داده بودند که در لحظات حساس اعتراض و آشوب، فرمانده ارشد نتوانست به هیچ کدام از ۷۰۰ مأمور پلیس درگیر دسترسی داشته باشد [۵].

با توجه به کمبود پهنای باند، انتشار اطلاعات بر روی فرکانس شدنی نیست و تنها راه بهبود مقاوم بودن مخابرات بی‌سیم استفاده از چندین آنتن است. MIMO انبوه درجه‌های آزادی زیادی دارد که می‌تواند برای خنثی کردن سیگنال جمری که عمدی نصب شده قرار گیرد. اگر MIMO انبوه از پیلوت ارسال (uplink) برای تخمین کانال استفاده کند، جمرهای هوشمند با استفاده از توان نسبتاً کمی می‌توانند تداخل مخربی را به وجود آورند. با این حال، پیاده‌سازی‌های هوشمندانه‌تر از تخمین کانال مشترک و دیکد کردن استفاده می‌کنند که به میزان زیادی می‌تواند این مسئله را مرتفع کند.

۷-۳-۲-۲ چالش‌های MIMO انبوه

درحالی‌که MIMO انبوه بسیاری از مشکلات در مخابرات قدیمی را حل می‌نماید اما مسائل جدیدی نیز تولید می‌کند که امروزه موضوع تحقیق و بررسی بسیاری از تحقیقات و مقالات است. در ادامه به تعدادی از این چالش‌ها اشاره می‌شود.

۷-۳-۲-۱-۱ پردازش سیگنال سریع و توزیع شده

آرایه‌های MIMO انبوه به میزان زیادی داده باند پایه تولید می‌کنند که باید مورد پردازش قرار گیرند. این پردازش باید به صورت ساده باشد و منظور از ساده، خطی یا نزدیک به خطی بودن است. به نظر می‌رسد در زمینه بهینه‌سازی الگوریتم‌ها و پیاده‌سازی آن‌ها نیاز به تحقیقات بیشتری است. به عنوان مثال برای ارتباط با گیرنده (downlink) پتانسیل زیادی برای روش‌های قبل از کد کردن^۳ وجود دارد [۶].

۷-۳-۲-۲-۲ سخت‌افزار ارزان قیمت

MIMO انبوه بر پایه استفاده از تعداد زیادی آنتن استوار است که منجر به کاهش نویز، محوشدگی و همچنین تداخل می‌گردد. در حقیقت نیاز است تا MIMO انبوه با ادوات ارزان قیمت پیاده‌سازی شود. تعداد زیاد المان‌ها باعث می‌شود که نقص و عیوب

^۱Orthogonal frequency division multiplexing

^۲jamming

^۳precoding

سخت‌افزاری نیز مانند نویز فاز و عدم تعادل I/Q بیشتر باشد. مدل‌های A/D ارزان قیمت و بهینه از نظر مصرف دارای سطوح نویز گسسته‌سازی بالاتری هستند. تقویت‌کننده‌های توان با تغییرات خطی بسیار آرام نیاز به سیگنالینگ‌های با نسبت حداکثر به میانگین پایین قبل از آنتن دارند که با وجود زیاد بودن تعداد آنتن‌های فرستنده نیز شدنی است. با استفاده از PLL‌های^۱ ارزان قیمت یا حتی اسلاتورها ممکن است نویز فاز تبدیل به یک پارامتر محدودکننده شود. با این حال چیزی که حائز اهمیت است این است که چقدر فاز بین دو نقطه از زمانی که یک سمبل پایلوت دریافت می‌شود تا زمانی که یک سمبل داده توسط هر آنتن دریافت می‌شود، تغییر می‌کند. در زمینه حل مشکل نویز فاز نیز با طراحی لایه انتقال هوشمند و الگوریتم‌های دریافت سیگنال، پتانسیل زیادی برای تحقیق وجود دارد.

۷-۳-۲-۳ مصرف توان داخلی

MIMO انبوه این پتانسیل را دارد که توان انتشاری را تا ۱۰۰۰ برابر کاهش و به طور هم‌زمان نرخ داده را به طور قابل ملاحظه‌ای افزایش دهد. با این حال، در عمل می‌بایست کل توان مصرفی با احتساب هزینه برای پردازش سیگنال باند پایه، مورد توجه قرار گیرد. در نتیجه تحقیقات بیشتری باید بر روی سخت‌افزارهای اختصاصی برای این پردازش که به صورت موازی کار کنند، انجام گیرد.

۷-۳-۲-۴ مشخصات کانال

هنگام استفاده از MIMO انبوه به جای MIMO معمولی، مشخصات اضافه‌ای از کانال وجود دارد که باید مورد توجه قرار گیرند. برای ارزیابی واقعی از عملکرد سیستم‌های MIMO لازم است مدل‌هایی در اختیار باشد که بتوانند رفتار صحیحی از کانال رادیویی را بازتاب دهند. همچنین مهم است که مدل‌های کانال پیچیده‌تری به صورت تحلیلی ایجاد شوند. چنین مدل‌هایی نباید در همه جزئیات کوچک صحیح باشند اما باید رفتار اصلی کانال را نشان دهند. برای مثال در MIMO معمولی، مدل Kronecker به طور گسترده‌ای برای مدل همبستگی کانال‌ها مورد استفاده قرار می‌گیرد. این مدل یک ارائه دقیق از واقعیت نیست اما برای برخی از تحلیل‌ها علیرغم محدودیت‌هایش مدل مفیدی است. دیدگاه مشابهی می‌تواند برای مدل کانال MIMO انبوه مورد توجه قرار گیرد.

۷-۳-۲-۵ هزینه کالیبراسیون هم‌پاسخ^۲

عملیات TDD^۳ وابسته به هم‌پاسخ بودن کانال است. معمولاً کانال مخابراتی به خودی خود هم‌پاسخ است مگر اینکه انتشار در کانال تحت تأثیر مواد مغناطیسی خاصی قرار بگیرد. با این حال، زنجیره‌های سخت‌افزاری در فرستنده و گیرنده ایستگاه پایه و کاربر ممکن است در لینک‌های بالا و پایین یکسان نباشند. کالیبراسیون زنجیره‌های سخت‌افزاری به نظر راه حل عملی برای این مشکل هستند [۷، ۸]. در [۸] کالیبراسیون هم‌پاسخ برای یک سیستم با ۶۴ آنتن با جزئیات انجام شده و نتایج پیاده‌سازی آزمایشگاهی موافقی داشته است. اینکه در MIMO انبوه این کالیبراسیون چند بار باید انجام گیرد و بهترین روش آن چیست و با توجه به منابع زمانی و فرکانسی چه هزینه‌ای در بر دارد و به چه سخت‌افزارهای کمکی برای این کار نیاز است از جمله مباحث تحقیق و بررسی در فناوری MIMO انبوه می‌باشد.

۷-۳-۲-۶ آلودگی پایلوت

^۱Phase locked loop

^۲Reciprocity

^۳Time division duplexing

به‌طور ایده‌آل، به هر کاربر در سیستم MIMO انبوه یک دنباله پایلوت متعامد^۱ در لینک بالا اختصاص داده می‌شود. باین‌حال، حداکثر تعداد دنباله‌های پایلوت متعامد که می‌تواند به وجود بیاید دارای یک حد بالایی است که از بازه زمانی هم‌فازی^۲ تقسیم بر انتشار تأخیر کانال^۳ به دست می‌آید. در [۹] برای یک سناریوی عملیاتی نمونه، حداکثر تعداد دنباله‌های پایلوت متعامد در بازه هم‌فازی به مدت 1ms در حدود ۲۰۰ تخمین زده شده است. به‌راحتی می‌توان از منابع پایلوت متعامد در یک سیستم مخابرات چند سلولی استفاده نمود. اثر استفاده مجدد از پایلوت‌ها از یک سلول به سلول دیگر و پیامدهای منفی ناشی از آن، آلودگی پایلوت نامیده می‌شود. به‌طور دقیق‌تر، زمانی که آنتن فرستنده سیگنال پایلوت دریافت شده‌اش را با دنباله پایلوت مربوط به یک کاربر مرتبط می‌کند، در حقیقت یک تخمین کانال آلوده‌شده به دست می‌آورد زیرا یک ترکیب خطی از کانال گیرنده‌های دیگری که این پایلوت را به اشتراک گذاشته‌اند دریافت می‌کند. آلودگی پایلوت پدیده‌ای است که برای MIMO معمولی نیز رخ می‌دهد ولی اثر آن برای MIMO انبوه بیشتر می‌باشد [۱۰].

۴-۷- کاربرد فناوری MIMO انبوه

فناوری MIMO انبوه ویژگی‌های مختلفی دارد از جمله بهبود ظرفیت که کاربرد این فناوری را برای مواردی که تعداد زیادی کاربر در سیستم وجود دارد یا تعداد زیادی حسگر برای جمع‌آوری داده به کار می‌رود، مفید و مؤثر می‌سازد. در ادامه به برخی از موارد کاربرد MIMO انبوه اشاره شده است.

۱-۴-۷- رادیو شناختی


تقاضا برای نرخ بالاتر داده‌های کاربر نهایی و تراکم ترافیک بالاتر، باعث ایجاد شبکه‌های 5G برای افزایش ظرفیت مربوطه شده است. سیستم‌های موج میلی‌متری^۴ با باندهای گسترده فرکانس بالا، بین ۳۰ تا ۳۰۰ گیگاهرتز، به میزان زیادی از پهنای باند دسترسی دارند تا اتصال چند گیگابیت بر ثانیه را فعال کنند. پیش‌ازاین، باند موج میلی‌متری در ۶۰ گیگاهرتز توسط استانداردهای ارتباطات محلی و شخصی مانند IEEE 802.11ad و IEEE 802.15.3c و همچنین برای زیرساخت مخابرات سلولی کوچک نیز بکار رفته است. ارتباطات موج میلی‌متری توسط پیوندهای ارتباطی کاملاً جهت‌دار تسهیل می‌شود، جایی که پرتوهای باریک می‌توانند انرژی را به سمت گیرنده‌های در نظر گرفته‌شده متمرکز کنند، نیازهای PA را کاهش داده و تداخل سایر فرستنده‌ها را خنثی نمایند. درحالی‌که ممکن است طیف موج میلی‌متری کمیاب نباشد، به دلیل ویژگی انتشار آن نیز بسیار قابل اعتماد نیست. در فرکانس موج میلی‌متری تغییرات شدید کانال به دلیل انسداد اتومبیل، درختان، مصالح ساختمانی جامد و حتی اجزای بدن انسان رخ می‌دهد. درنتیجه، یک ترکیب از فرکانس‌های پایین و بالا برای حفظ اتصال شبکه قابل اطمینان لازم و ضروری است. در شکل ۸۳ باندهای مجوز دار (آبی‌رنگ)، غیرمجاز دار و اشتراکی (سبز رنگ) و ایجادشده (بنفش رنگ) در شبکه 5G پیاده‌سازی شده در نقاط مختلف دنیا نشان داده شده است.

¹Orthogonal

²Coherence interval

³Channel delay spread

⁴mmWave



شکل ۸۳. نمایی از پهنای باند شبکه 5G [۱۲]

۲-۴-۷- کاربرد در سیستم‌های سایبر- فیزیکی^۱

سیستم سایبر- فیزیکی (CPS) یک پیوند بلادرنگ و آنی را بین دنیای فیزیکی و دنیای سایبری برقرار می‌کند و موضوع اصلی انقلاب صنعتی چهارم است که ویژگی‌های آن اتصالات بسیار زیاد (ابر اتصالات)، ابر اتوماسیون و ابر هوش می‌باشد [۱۳-۱۵]. یک کارخانه هوشمند، یک سیستم تولید هوشمند و قابل انعطاف است که محصولات موردنظر مشتری را به صورت بلادرنگ تولید می‌کند. برای افزایش رقابت‌پذیری صنایع تولیدی مبتنی بر کارخانه هوشمند، CPS به طور فعالی مورد استفاده قرار گرفته است. یک CPS برای طراحی و عملیات کارخانه هوشمند سیستم تولید سایبر- فیزیکی^۲ (CPPS) نامیده می‌شود. این سیستم داده‌های حجیم ساخت و تولید را جمع‌آوری کرده و آن را به صورت بلادرنگ تحلیل می‌کند و سپس عملیات مؤثر سیستم‌های تولید را اجرا می‌نماید. به این ترتیب به طور خودکار تغییرات سفارش‌ها را شناسایی، مسائل غیرعادی را مدیریت و خطاها را تصحیح می‌نماید. کاربرد اینترنت اشیاء در صنایع، اینترنت اشیاء صنعتی^۳ (IIoT) یا اینترنت صنعتی نامیده می‌شود [۱۶، ۱۷]. برای پیاده‌سازی CPS در سیستم‌های تولید، اینترنت اشیاء، محیطی را برای جمع‌آوری داده‌های صنعتی حجیم تولید فراهم می‌کند.

برای پیاده‌سازی اینترنت اشیاء صنعتی در CPS، فناوری‌های پایه‌ای مختلفی باید در محل حاضر باشند. ابر اتصالات از بقیه فناوری‌ها جلوتر است و بیش از ابر اتوماسیون و هوش پیشرفت کرده است. برای تضمین ابر اتصالات در CPS هم ادوات ثابت مانند حسگرها که برای تبادل اطلاعات و پایش وضعیت به کار می‌روند و هم ادوات متحرک مانند ربات‌های سیار و پهپادهای نظارتی باید به مرکز داده به وسیله فناوری بی‌سیم قدرتمندی وصل شوند. فناوری MIMO انبوه به واسطه بازدهی طیفی و همچنین بازدهی انرژی بالا در دانشگاه‌ها و صنعت بسیار مورد توجه قرار گرفته است [۹، ۱۸، ۱۹]. در این فناوری با استفاده از بالا بردن بهره کانال، این امکان به وجود می‌آید تا توان تخصیص داده‌شده، زمان‌بندی‌های و کدینگ‌های پیچیده قبل ارسال کاهش یابد. در استانداردهای 3GPP بعد از ارائه شدن نسخه ۱۳، MIMO انبوه مورد بحث قرار گرفته است [۲۰].

در سیستم‌های MIMO معمولی تقریباً از تعداد برابری آنتن در فرستنده و گیرنده استفاده می‌شد زیرا از منظر پیکربندی یک سیستم، ظرفیت کانال با تعداد برابر آنتن فرستنده و گیرنده به میزان حداکثر خود می‌رسد. با افزایش تعداد آنتن در یک سمت بهره

¹Cyber-physical system

²Cyber-physical production system

³Industrial internet of things

توان افزایش می‌یابد ولی کمک زیادی در بالابردن ظرفیت کانال نمی‌کند. اما در اینترنت اشیا، استفاده تعداد یکسانی آنتن در سمت گیرنده و فرستنده تقریباً غیرممکن است و با اینکه می‌توان تعداد آنتن را در سمت فرستنده و ایستگاه پایه افزایش داد اما تعداد آنتن گیرنده را نمی‌توان با توجه به محدودیت فضا زیاد کرد. به همین دلیل سیستم‌های چندکاربره MIMO نیز معرفی شده‌اند که داده را از مرکز داده به چندین دستگاه IoT با آنتن تکی ارسال می‌کنند. در این سیستم کدینگ‌های قبل و بعد از ارسال و زمان‌بندی و تخصیص توان حائز اهمیت زیادی است و رسیدن به بازدهی مناسب در شرایط عملی کار آسانی نیست. بر خلاف MIMO چند کاربره، تعداد آنتن‌ها در فرستنده MIMO انبوه چندین برابر ادوات و کاربرانی است که هرکدام یک آنتن دارند. به دلیل بهره کانال و تعامد بردار کانال‌ها در MIMO انبوه، کدینگ قبل و دیکدینگ بعد از ارسال، زمان‌بندی و تخصیص توان به میزان زیادی ساده‌تر می‌شود. در نتیجه MIMO انبوه می‌تواند یک نقش کلیدی در ایجاد ابر اتصالات در CPS بازی کند.

۵-۷- استفاده از هوش مصنوعی در سیستم‌های MIMO انبوه

پس از سال‌ها تحقیق و بررسی، اولین استاندارد از نسل پنجم مخابرات موبایل تجاری شده تحت عنوان پانزدهمین نسخه آزاد شده از 3GPP در ژوئن ۲۰۱۸ کامل شده است. سه عامل سیستم‌های آنتن MIMO انبوه، مخابرات موج میلی‌متری و شبکه بسیار فشرده^۱ (UDN) به عنوان عوامل تسهیل‌کننده در ایجاد و گسترش سیستم‌های نسل پنجم شناخته می‌شوند. باین‌حال مصرف توان شبکه و هزینه سخت‌افزاری چالش‌های اصلی برای پیاده‌سازی سیستم‌های عملی هستند. برای مثال در شبکه‌های UDN مصرف توان در مدارهای الکترونیکی و سیستم‌های خنک‌کننده به صورت خطی با تعداد ایستگاه‌های پایه افزایش می‌یابد. همچنین برای ایجاد ارتباطاتی با عملکرد مناسب در فرکانس‌های موج میلی‌متری بخصوص زمانی که از MIMO انبوه استفاده می‌شود نیاز به زنجیره‌های RF گران‌قیمت و همچنین پردازش سیگنال پیچیده است [۱۱].

هوش مصنوعی می‌تواند حس کردن، یادگیری و بهینه‌سازی را که از مشخصات شبکه‌های رادیو شناختی است با این تسهیل‌کننده‌ها ترکیب نماید. اتحادیه ارتباطات بین‌المللی^۲ (ITU)، نسل پنجم مخابرات را به سه دسته از سناریوهای کاربردی تقسیم نموده است که عبارت‌اند از: مخابرات سیار پهن‌بند^۳ (eMBB)، مخابرات ماشین انبوه^۴ (mMTC) و مخابرات بسیار قابل اطمینان و کم تأخیر^۵ (URLLC) [۱۲].

eMBB دسته‌ای است که برای کاربردهای با پهنای باند بالا مانند داده‌های ویدئویی حجیم یا واقعیت‌های مجازی / افزوده^۶ به کار می‌رود. mMTC برای پشتیبانی از حس کردن، پایش و اندازه‌گیری‌های مورد نیاز در اینترنت اشیا کاربرد دارد و URLLC نیز برای خدمات حساس به تأخیر مانند رانندگی خودکار و اینترنت مورد نیاز پهپادها به کار گرفته می‌شود. درحالی‌که نسل پنجم می‌تواند هرگونه از این خدمات را ارائه دهد، دسترسی رادیویی شبکه‌ها مبتنی بر هوش مصنوعی می‌تواند در مدیریت شناختی منابع مؤثر باشد.

هوش مصنوعی که در سال ۱۹۳۰ توسط تئوری ماشین تورینگ شکل گرفت و با ظهور شبکه‌های عصبی عمیق دوباره مورد استفاده قرار گرفته است در طیف وسیعی از کاربردها شامل مخابرات بی‌سیم جای خود را باز کرده است. شبکه عصبی مصنوعی^۷ (ANN) یکی از قدیمی‌ترین رویکردها برای ایجاد هوش مصنوعی است. این فناوری از توانایی موازی‌سازی و محاسبات توزیع شده مغز تقلید می‌کند.

¹Ultra-dense networks

²International Telecommunication Union

³Enhanced mobile broadband

⁴Massive machine-type communication


⁵Ultra-reliable and low latency communication

⁶Virtual/augmented reality

⁷Artificial neural network

شبکه‌های عصبی بازگشتی^۱ (RNN) به سلول‌های عصبی اجازه می‌دهند حافظه‌هایی از توالی‌های دلخواه از الگوهای ورودی را ایجاد و پردازش کنند به‌طوری‌که ارتباطات بین لایه‌ها یک حلقه را تشکیل می‌دهند. یک شبکه عصبی عمیق یا شبکه اعتقادی عمیق^۲ (DBN) از یک ساختار سلسله مراتبی با چندین ماشین بولتزمن محدود^۳ (RBM) استفاده می‌کند و از طریق یک فرایند یادگیری پی‌درپی، به‌صورت لایه به لایه کار می‌کند. RBM ها یک مدل گرافیکی بدون جهت، بدون اتصالات قابل مشاهده و پنهان را تشکیل می‌دهند. مزایای DBN در توانایی یادگیری غیرهدایتی، استنتاج سریع و انعطاف‌پذیری به دلیل ساختار چندلایه آن، نهفته است. یک شبکه عصبی حلقوی^۴ (CNN) بر روی لایه‌هایی از فیلترهای قابل آموزش حلقوی ساخته شده است که منجر به سلسله مراتبی از ویژگی‌های ترکیبی می‌شود. CNN اساساً با DBN متفاوت است. DBN به‌عنوان یک مدل تولیدی که توزیع مشترک داده‌ها و اهداف مربوطه را توصیف می‌کند رفتار می‌نماید، درحالی‌که CNN یک مدل متمایزکننده است که توزیع اهداف مشروط بر داده‌ها را توصیف می‌کند. علاقه ویژه به انواع مختلف شبکه‌های عصبی در ارتباطات بی‌سیم ناشی از این واقعیت است که آنها می‌توانند تقریب‌های غیرخطی را انجام دهند و ذاتاً بر اساس داده هدایت می‌شوند.

پیشرفت‌های اخیر در محاسبات و هوش مصنوعی محققان را در زمینه ارتباطات بی‌سیم ترغیب کرده است تا هوش مصنوعی را به‌خصوص در زمینه نسل پنجم به‌کار گیرند، که در شکل ۸۴ نشان داده شده است. یک شبکه 5G مبتنی بر AI ایستگاه‌های پایه/ابر با توانایی ایجاد یک پایگاه داده شناختی با تقسیم، پردازش و تفسیر داده‌های عملیاتی فراهم می‌کند. حجم عظیمی از داده‌های بلادرنگ توسط تعداد زیادی کاربر ایجاد می‌شود و از اطلاعات حالت کانال تا قرائت دستگاه‌های اینترنت اشیاء متغیر است. پایگاه داده‌های دریافتی و داده‌های جغرافیایی به‌دست‌آمده برای درک کاملی از محیط ساخته شده‌اند.



شکل ۸۴. سناریوهای کاربردی شبکه 5G مبتنی بر AI [۱۲]

از منظر ارتباطات انسان‌محور، رفتارهای انسانی توسط شبکه بی‌سیم مبتنی بر AI یاد گرفته می‌شوند تا ویژگی‌های شبکه را توسعه داده و خدمات مردم محوری را ایجاد کنند. از منظر ارتباطات ماشین‌محور، تجزیه و تحلیل داده‌های بزرگ برای استخراج الگوهای انبوه، به‌ویژه در لایه‌های کنترل فیزیکی (PHY) و محیط کنترل دسترسی (MAC) و فعال کردن عملیات


¹Recursive neural network

²Deep belief network

³Restricted Boltzman machine

⁴Convolutional neural network

خودسازمان‌دهی انجام می‌شود. از شبکه‌های عصبی می‌توان برای تعریف مجدد شبکه‌های ارتباطی، حل تعدادی از مشکلات طراحی غیراصولی در زمان اجرا و لایه‌های مرتبطی برای سازگاری لینک شناخت، برنامه‌ریزی منابع، طبقه‌بندی سیگنال و تشخیص سیگنال حامل استفاده کرد. یک RNN همچنین قابلیت ضبط و کاهش نواقص و غیرخطی بودن اجزای فرکانس رادیویی مانند تقویت‌کننده‌های پرتوان^۱ (HAP) را دارد که در PHY به کار رفته و می‌تواند بر عملکرد شبکه تأثیر بگذارد. CNN و DBN برای حل طیف وسیعی از کارهای لایه ارتباطی بالاتر مانند بهینه‌سازی شبکه و مدیریت منابع مناسب‌تر هستند. پیچیدگی مفهوم نسل پنجم و قدرت هوش مصنوعی امکان تفکر مجدد در ارتباطات سلولی را فراهم می‌آورند. شکل ۸۵ موارد استفاده اصلی 5G و استفاده از انواع مختلف شبکه‌های عصبی به عنوان عوامل ایجاد 5G را نشان می‌دهد. دستگاه‌های پردازش موازی گسترده مانند واحدهای پردازش گرافیکی (GPU) و واحدهای پردازش شبکه عصبی^۲ (NPU)، که می‌توانند در یک ایستگاه پایه یا ابر 5G مستقر شوند، می‌توانند تحلیل داده سنتی را انجام داده و برای یادگیری و استنتاج شبکه‌های عصبی انرژی بهینه و مقرون به صرفه‌ای مصرف کنند.



شکل ۸۵. فناوری‌های تسهیل‌کننده 5G و روش‌های مبتنی بر شبکه عصبی که می‌توانند در پیاده‌سازی آنها به کار روند. [۱۲]

MIMO انبوه به‌طور گسترده‌ای به عنوان فناوری نامزد پیشرو برای 5G شناخته می‌شود. تعداد بالای آنتن‌های ایستگاه‌های پایه نیاز به تعداد زیادی تقویت‌کننده توان (PA) (یکی به ازای هر آنتن) دارد. مشکل اصلی در تقویت‌کننده RF به عنوان مصالحه بین خطی بودن و کارایی شناخته می‌شود. تقویت‌کننده‌ها می‌توانند برای دستیابی به خطی عمل کردن مناسب ولی به قیمت از دست دادن بهره‌وری طراحی شوند. درحالی که PA های خیلی خطی، گران و از نظر مصرف توان ناکارآمد هستند، تعداد بیش از حد آنتن‌های ایستگاه پایه استفاده از اجزای ارزان قیمت را برای حفظ کل هزینه‌های سرمایه (CAPEX) و مخارج عملیاتی (OPEX) مطلوب می‌کند. از طرف دیگر، سیستم‌های ارتباطی بی‌سیم پهن باند با مصرف انرژی و عملکرد کارآمد نسبت به تغییرات غیرخطی که به انتهای سیستم RF مربوط می‌شود به‌ویژه موارد مربوط به HPA ها که بر عملکرد گیرنده و کل شبکه تأثیر می‌گذارد، آسیب‌پذیر هستند.

علاوه بر این، از آنجاکه سیستم‌های ارتباطی نسل بعدی در محیط‌های پویاتر و در طیف‌های مختلف فعالیت خواهند کرد، به محدوده دینامیکی بیشتری نیاز خواهند داشت. بنابراین، PA ها باید در عین حفظ بازده قابل قبول، مشخصات خطی دقیق‌تری را

¹High power amplifier

²Neural network processing units

رعایت کنند. بیشترین راندمان PA هنگام تغذیه مداوم، در محدوده منطقه خطی با بالاترین قدرت حاصل می‌شود. این یک راه حل ممکن برای سیگنال‌های با نسبت قدرت اوج به متوسط^۱ (PAPR) بالا نیست و برای ایستگاه‌های پایه نسل پنجم نیز واقع‌بینانه نیست. در عوض، از راه حل‌های مبتنی بر پردازش سیگنال برای ارائه یک مصالحه بهتر بین هزینه و عملکرد استفاده می‌شود. یکی از مهم‌ترین مزایای شبکه‌های عصبی، توانایی آن‌ها در استخراج، پیش‌بینی و توصیف پدیده‌های غیرخطی از مجموعه داده‌های حجیم است. از آنجاکه ANN ها می‌توانند انواع مختلفی از روابط را بین انواع ورودی‌ها و خروجی‌های مختلف مانند روابط پیچیده غیرخطی یا روابط بسیار پویا به دست آورند، برای رفع مشکلات غیرخطی در لایه فیزیکی از جمله ردیابی غیرخطی تقویت‌کننده‌های توان و تصحیح اختلال مناسب هستند.

۱-۵-۷- شکل‌دهی پرتو در MIMO انبوه با روش RNN

تکنیک‌های هوش مصنوعی برای سیستم‌های ارتباطی بی‌سیم مورد استفاده قرار گرفته است تا بتوانند به طور مؤثر مسائل غیرخطی را در لایه فیزیکی کاهش دهند. به‌ویژه، RNN ها می‌توانند خود را به خوبی انطباق دهند تا به مسائل غیرخطی RF پردازند زیرا آن‌ها اجازه می‌دهند اطلاعات تاریخی از طریق ساختار مبتنی بر حلقه ذخیره شود. این شبکه‌ها در ابتدا برای حل مشکلات برنامه‌نویسی خطی مورد استفاده قرار می‌گرفتند و الهام‌بخش تحقیقات مختلفی برای حل مشکلات غیرخطی شدند. RNN ها قادرند به طور خودکار ویژگی‌های سیستم غیرخطی که نسبت به محیط ثابت می‌باشند را استخراج نمایند و از رویکردهای سنتی در پردازش سیگنال لایه فیزیکی بهتر عمل کنند.


همان‌طور که قبلاً اشاره شد، بهره‌وری انرژی یک BS به طور قابل توجهی به بازده PA بستگی دارد. استفاده از سیستم‌های MIMO انبوه که در آن BS ها مجهز به تعداد قابل توجهی آنتن بیشتر از تعداد کاربران که به طور هم‌زمان خدمت‌رسانی می‌شوند هستند، درجه آزادی زیادی را ایجاد می‌کند. وقتی فرض تعداد کاربران مشخص می‌شود، سطح عدم قطعیت در یک ماتریس کانال دارای عدم قطعیت با افزایش تعداد آنتن‌های BS، افزایش می‌یابد. درجه آزادی‌های زیاد امکان انتخاب سیگنال‌های انتقال از فضای بزرگ‌تری را فراهم می‌کنند. هدف از ایجاد شکل‌دهی بیم با بازدهی انرژی بالا در یک سیستم MIMO انبوه، یافتن ماتریسی است که حداقل رفتار غیرخطی را در تقویت‌کننده‌های قدرت در این فضا معرفی می‌کند. این کار باعث می‌شود تا از تقویت‌کننده‌های قدرت کم‌هزینه و عملکرد آن‌ها در سطوح بالاتر انرژی برای افزایش بهره‌وری انرژی استفاده شود.

یک سیستم MIMO-OFDM انبوه با لینک پایین با M_T کاربر آنتن تکی و یک ایستگاه پایه با N_T آنتن و N_C زیرحامل^۲ را در نظر بگیرید. تعداد آنتن‌های BS به طور قابل توجهی بزرگ‌تر از تعداد کاربران است، یعنی $N_T \gg M_T$. شکل‌دهی پرتو به صورت ZF^۳ اعمال شده و نمادهای اطلاعات کاربر در BS با اطمینان از حداقل تداخل به آنتن فرستنده مناسب نگاشت می‌گردد. درجه‌های آزادی اجازه می‌دهد راه حل‌هایی انتخاب شود که بهره‌وری انرژی را به حداکثر و اثرات غیرخطی بودن تقویت‌کننده توان را به حداقل برساند. از تشابه معماری شکل‌دهی پرتو و تقویت‌کننده‌های توان در سیستم‌های MIMO چند کاربره با معماری توابع نرون‌ها در RNN، می‌توان راه حل مبتنی بر RNN به صورت نشان داده شده در شکل ۸۶ ارائه داد. یادگیری ضرایب وزنی در این راه حل به این صورت است که توابع فعال‌ساز غیرخطی در RNN ویژگی‌های غیرخطی تقویت‌کننده‌ها توان را به صورت بازگشتی یاد می‌گیرد و ضرایب نرونی را با دو شرط پیدا می‌کنند: (۱) با شکل‌دهی بیم ZF که به معنی حداقل تداخل بین کاربران مختلف است و (۲) با حداقل متوسط اعوجاج غیرخطی. RNN خواص غیرخطی آرایه تقویت‌کننده‌ها را مدل می‌کند درحالی‌که برای ارسال حداقل توان بهینه شده است و شکل‌دهی بیم ZF را نیز فراهم می‌نماید. سپس RNN سیستم مخابراتی را آگاه می‌سازد تا ضرایب شکل‌دهی بیم را تنظیم کند.

¹Peal-to-average power ratio


²subcarrier

³Zero forcing



شکل ۸۶. شکل‌دهی پرتو ZF در ایستگاه‌های پایه 5G [۱۲]

روش مبتنی بر RNN برای لینک پایین یک سیستم MIMO-OFDM با حداکثر ۱۰۰ آنتن در ایستگاه پایه و ۱۰۰ کاربر با آنتن تکی شبیه‌سازی شده است. سیگنال ارسالی بهینه و متغیرهای فعال‌سازی به‌دست‌آمده و رابطه بین پیکربندی آنتن‌ها و بازدهی انرژی در شکل ۸۷ نشان داده شده است. نتایج نشان می‌دهد که بهبود بازدهی انرژی می‌تواند تا زمانی که درجه آزادی به اندازه کافی موجود باشد حاصل شود.



شکل ۸۷. بازدهی انرژی (بر حسب Mbit/J) با شکل‌دهی بیم ZF در یک سیستم MIMO انبوه با مبتنی بر RNN [۱۲]

۶-۷- نتیجه‌گیری

در این فصل ابتدا به معرفی اجمالی در مورد آنتن‌های MIMO انبوه پرداخته و مزایای استفاده از آن‌ها بیان شد. آنتن‌های MIMO انبوه را می‌توان نسل جدیدی از آنتن‌های MIMO در نظر گرفت که به‌جای چندین آنتن محدود در فرستنده و گیرنده، دارای تعداد آنتن بسیار زیادی در طرف فرستنده و یا گیرنده هستند. داشتن چندین آنتن در سیستم‌های MIMO تک کاربره می‌تواند اثرات محوشدگی چندمسیره که باعث کاهش دامنه سیگنال در گیرنده می‌شود را کاهش دهد. در سیستم‌های MIMO

چند کاربره با ایجاد مسیرهای داده مختلف برای هر آنتن ظرفیت ارتباط افزایش می‌یابد ولی در عین حال امکان ایجاد تداخل بین آنتن‌ها نیز بیشتر خواهد بود. با ظهور سیستم‌های MIMO انبوه تعداد آنتن‌ها به میزان زیادی افزایش پیدا کرده که منجر به ایجاد یک آرایه از آنتن‌ها برای ارسال داده می‌شود و بهره آنتن آرایه‌ای با توجه به تعداد آنتن‌ها می‌تواند به میزان قابل توجهی افزایش یابد. همچنین بیم آنتن می‌تواند بسیار باریک شود و ناحیه محدودی به اندازه یک کاربر را پوشش دهد. این ویژگی باعث می‌شود که در حین ارتباط، فرستنده بر روی کاربر با بهره بالایی متمرکز شده و از لحاظ مصرف توان صرفه‌جویی خوبی صورت گرفته و تداخل نیز بسیار کم‌تر شود.

افزایش تعداد آنتن‌ها این قابلیت را به وجود می‌آورد تا با تغییر دامنه و فاز در ورودی آنتن‌های مختلف بیم آنتن قابلیت چرخش در جهات مختلف را داشته باشد و همچنین با تغذیه‌های متفاوت می‌توان روش‌های شکل‌دهی بیم مختلفی مانند ZF یا MRT به وجود آورد. هر یک از آنتن‌ها به یک تقویت‌کننده توان متصل است. هنگامی که تعداد آنتن‌های موجود در آرایه کم باشد نیاز است تا از تقویت‌کننده‌های توان بالا استفاده شود که معمولاً مشکلات به اشباع رفتن و غیرخطی بودن را دارا هستند. با افزایش تعداد آنتن و همچنین تعداد تقویت‌کننده‌ها می‌توان از تقویت‌کننده‌های کم‌توان استفاده نمود که در توان پایین و ناحیه خطی کار می‌کند و قیمت بسیار پایین‌تری نیز دارند. علاوه بر افزایش ظرفیت و بازدهی مصرف توان و همچنین پیاده‌سازی با ادوات ارزان قیمت و توان پایین که در بالا به آن‌ها اشاره شد کاهش تاخیر در کانال ارسالی و افزایش مقاومت در مقابل تداخل و جیمینگ نیز از دیگر مزایای مورد بررسی در این فصل هستند.

همانند همه سیستم‌های مخابراتی، آنتن‌های MIMO انبوه نیز دارای چالش‌هایی هستند. استفاده از الگوریتم‌های بهینه‌سازی خود نیاز به مصرف توان و همچنین پردازش‌های قدرتمندی دارد که می‌تواند به عنوان چالشی برای MIMO انبوه منظور شود. همچنین بالا بودن تعداد آنتن می‌تواند حجم زیادی را اشغال کند و به همین دلیل سعی شده برای پایین آوردن ابعاد آنتن و همچنین افزایش پهنای باند و ظرفیت از آنتن‌های MIMO انبوه در باند موج میلی‌متری بیشتر استفاده شود. از جمله چالش‌های دیگر افزایش احتمال خرابی سخت‌افزار و همچنین بالا رفتن نویز فاز، نیاز به مصرف داخلی، بدست آوردن وضعیت کانال ارتباطی، هزینه کالیبراسیون هم‌پاسخ و همچنین آلودگی پیلوت هستند که در این فصل به آن‌ها اشاره شد.

پس از مزایا و معایب به کاربردهای این فناوری پرداخته شده است. در کل شبکه‌های بسیار متراکم، فناوری موج میلی‌متری و آنتن‌های MIMO انبوه به عنوان سه فناوری تسهیل‌کننده برای پیاده‌سازی فناوری 5G شناخته می‌شوند. علاوه بر فناوری 5G، استفاده در رادیو شناختی، سیستم‌های سایبر- فیزیکی و اینترنت اشیاء صنعتی نیز در این فصل مورد بررسی قرار گرفته‌اند. MIMO انبوه در کاربردهای صنعتی مانند اینترنت اشیاء صنعتی که نیاز به تعداد زیادی حسگر یا کنتور هست نیز می‌تواند کاربرد داشته باشد. به همین دلیل این آنتن‌ها می‌توانند به راحتی در شبکه برق هوشمند که در آن حسگرهای زیادی برای پایش و کنترل شبکه وجود دارد و نیازمند پهنای باند زیادی برای انتقال برخی از داده‌های جمع‌آوری شده است و به مخابراتی قابل اطمینان و با تأخیر کم نیاز دارد، مورد استفاده قرار گیرند.

مسلماً هنگامی که هوش مصنوعی با آنتن‌های MIMO انبوه ترکیب شود می‌تواند عملکرد آن‌ها را بهبود بخشد و پارامترهای مجهول را به صورت بهینه پیدا کند. دامنه و فاز که از هر تقویت‌کننده به سمت هر یک از آنتن‌های واحد می‌رود دو متغیر هر آنتن محسوب می‌شود که با توجه به تعداد بالای آنتن‌های واحد در آنتن آرایه‌ای MIMO انبوه، تعداد متغیرها به شدت افزایش می‌یابد. اندازه این متغیرها وابسته به موقعیت کاربران، تراکم آن‌ها، وضعیت کانال‌ها و پهنای باند در دسترس و پارامترهای مختلف دیگری است. بنابراین نیاز است تا ابتدا محیط و کاربران پایش شده و پس از جمع‌آوری داده و پردازش، هر یک از تقویت‌کننده‌ها برای تولید سیگنالی با دامنه و فاز مناسب تنظیم شوند. به این ترتیب استفاده از الگوریتم‌های هوش مصنوعی و روش‌های یادگیری ماشین که قابلیت یادگیری و تصمیم‌گیری مناسب را در مدت زمان قابل قبولی فراهم می‌کنند، می‌توانند در پردازش‌های سیستمی مورد استفاده قرار گیرند. برای نمونه می‌توان به شبکه‌های عصبی بازگشتی، یادگیری عمیق و DQL اشاره نمود که برای سیستمی با حالت‌های زیاد به کار رفته و زمان پاسخ‌دهی مناسبی دارند.

مراجع فصل ۷

- [1] S. Deshpande, "Appendix B: Introduction to MIMO and Massive MIMO," *Fundamentals of Network Planning and Optimisation 2G/3G/4G: Evolution to 5G*, pp. 325-335, 2018.
- [2] E. G. Larsson, O. Edfors, F. Tufvesson, and T. L. Marzetta, "Massive MIMO for next generation wireless systems," *IEEE communications magazine*, vol. 52, pp. 186-195, 2014.
- [3] C. Studer and E. G. Larsson, "PAR-aware large-scale multi-user MIMO-OFDM downlink," *IEEE Journal on Selected Areas in Communications*, vol. 31, pp. 303-313, 2013.
- [4] S. K. Mohammed and E. G. Larsson, "Per-antenna constant envelope precoding for large multi-user MIMO systems," *IEEE Transactions on Communications*, vol. 61, pp. 1059-1071, 2013.
- [5] P. Stenumgaard, D. Persson, E. G. Larsson, and K. Wiklundh, "An early-warning service for emerging communication problems in security and safety applications," *IEEE Communications Magazine*, vol. 51, pp. 186-192, 2013.
- [6] J. Zhang, X. Yuan, and L. Ping, "Hermitian precoding for distributed MIMO systems with individual channel state information," *IEEE Journal on Selected Areas in Communications*, vol. 31, pp. 241-250, 2013.
- [7] F. Kaltenberger, H. Jiang, M. Guillaud, and R. Knopp, "Relative channel reciprocity calibration in MIMO/TDD systems," in *2010 Future Network & Mobile Summit*, 2010, pp. 1-10.
- [8] C. Shepard, H. Yu, N. Anand, E. Li, T. Marzetta, R. Yang, *et al.*, "Argos: Practical many-antenna base stations," in *Proceedings of the 18th annual international conference on Mobile computing and networking*, 2012, pp. 53-64.
- [9] T. L. Marzetta, "Noncooperative cellular wireless with unlimited numbers of base station antennas," *IEEE transactions on wireless communications*, vol. 9, pp. 3590-3600, 2010.
- [10] J. Hoydis, S. Ten Brink, and M. Debbah, "Massive MIMO in the UL/DL of cellular networks: How many antennas do we need?," *IEEE Journal on selected Areas in Communications*, vol. 31, pp. 160-171, 2013.
- [11] Q. Wu and R. Zhang, "Intelligent reflecting surface enhanced wireless network via joint active and passive beamforming," *IEEE Transactions on Wireless Communications*, vol. 18, pp. 5394-5409, 2019.
- [12] M. Yao, M. Sohul, V. Marojevic, and J. H. Reed, "Artificial intelligence defined 5G radio access networks," *IEEE Communications Magazine*, vol. 57, pp. 14-20, 2019.
- [13] E. A. Lee, "Cyber physical systems: Design challenges," in *2008 11th IEEE International Symposium on Object and Component-Oriented Real-Time Distributed Computing (ISORC)*, 2008, pp. 363-369.
- [14] R. Rajkumar, I. Lee, L. Sha, and J. Stankovic, "Cyber-physical systems: the next computing revolution," in *Design automation conference*, 2010, pp. 731-736.
- [15] W. Wolf, "Cyber-physical systems," *Computer*, pp. 88-89, 2009.
- [16] F. G. Brundu, E. Patti, A. Osello, M. Del Giudice, N. Rapetti, A. Krylovskiy, *et al.*, "IoT software infrastructure for energy management and simulation in smart cities," *IEEE Transactions on Industrial Informatics*, vol. 13, pp. 832-840, 2016.
- [17] L. Da Xu, W. He, and S. Li, "Internet of things in industries: A survey," *IEEE Transactions on industrial informatics*, vol. 10, pp. 2233-2243, 2014.

- [18] E. Björnson, E. G. Larsson, and T. L. Marzetta, "Massive MIMO: Ten myths and one critical question," *IEEE Communications Magazine*, vol. 54, pp. 114-123, 2016.
- [19] T. L. Marzetta, "Massive MIMO: an introduction," *Bell Labs Technical Journal*, vol. 20, pp. 11-22, 2015.
- [20] H. Ji, Y. Kim, J. Lee, E. Onggosanusi, Y. Nam, J. Zhang, *et al.*, "Overview of full-dimension MIMO in LTE-advanced pro," *IEEE Communications Magazine*, vol. 55, pp. 176-184, 2016.

مرحله سوم. بررسی بکارگیری هوش مصنوعی در لایه‌های MAC و شبکه

مقدمه مرحله سوم

مطالب مرتبط با مرحله سوم پروژه در دو فصل ارائه شده است و مطالعات و بررسی‌های مرتبط با به کارگیری روش‌های هوش مصنوعی و یادگیری ماشین برای لایه‌های کنترل دسترسی به محیط (MAC^1) و شبکه را در بر می‌گیرد. فصل ۸ به اهمیت کاربرد روش‌های AI در لایه MAC و چالش‌های مرتبط با آن خواهد پرداخت. با ظهور فناوری‌های جدید و افزایش پیچیدگی‌های روزافزون به سیستم‌ها نیاز به پروتکل‌های انعطاف‌پذیر و قابل تطبیق با شرایط به سرعت متغیر محیط هست. طراحی پروتکل‌های جدید با استفاده از روش‌های سنتی زمانبر بوده و به دانش تخصصی نیاز دارد. تکنیک‌های یادگیری ماشین قابلیت یادگیری از محیط و انطباق با شرایط محیطی را به صورت خودکار و بدون دخالت مستقیم انسانی را فراهم می‌آورند. این امر به ویژه برای طراحی لایه MAC مورد استفاده در شبکه‌های حسگری و اینترنت اشیاء که نقش پررنگی در کاربردهای صنعتی منجمله شبکه هوشمند برق دارند، اهمیت دارد. در این فصل چند روش پیشنهاد شده در مقالات و مراجع مختلف مورد بررسی قرار خواهند گرفت.

فصل ۹ به بررسی به کارگیری روش‌های AI برای لایه شبکه می‌پردازد. در این فصل ابتدا به اهمیت به کارگیری این روش‌های نوین پرداخته خواهد شد و سپس یک معماری مناسب برای ایجاد ارتباط مابین AI و شبکه که چالش‌های مورد نظر را مرتفع می‌کند، مورد بررسی قرار خواهد گرفت. چند روش پیشنهادی در مراجع نیز به صورت مبسوط‌تری مورد مطالعه و بررسی قرار می‌گیرند.

¹ Medium Access Control

فصل ۸. بررسی عملکرد هوش مصنوعی در لایه MAC سیستم‌های ارتباطی

۱-۸- مقدمه

با ظهور فناوری‌های جدید به مشخصات متفاوتی از دستگاه‌ها و همچنین پروتکل‌های شبکه با عملکرد بالا و پیچیده نیاز هست. همچنین تغییرات در فناوری‌های لایه فیزیکی به سرعت موجب افت عملکرد پروتکل‌های معمول می‌گردد. با ظهور اینترنت اشیاء، رشد شبکه‌های حسگر بی‌سیم^۱ بصورت توانی گردیده است. این بدان دلیل است که این شبکه‌ها محیطی برای اینترنت اشیاء برای درک محیط واقعی بوجود می‌آورند. معمولاً یک شبکه حسگر بی‌سیم بصورت خودکار تنظیم می‌گردد و از تعداد زیادی گره که توانایی حس و پردازش داده از طریق مخابرات چندمسیره را دارد تشکیل شده است. طول عمر یک WSN بدلیل سختی در جایگزینی گره و بازشارژ آن معمولاً به بازدهی انرژی وابسته است. یک پروتکل MAC بخوبی طراحی شده درحالیکه مصرف انرژی را کمینه می‌کند نیاز به اطمینان در ارسال موفق نیز دارد. افزایش تعداد گره‌های WSN منجر به افت عملکرد لایه MAC می‌گردد.

از آنجاییکه پروتکل‌های موجود انعطاف‌پذیری محدود و در نتیجه عملکرد زیربهبینه تحت سناریوها و شرایط متفاوت شبکه دارند، بنابراین جایگزینی این طراحی دستی و کم‌بازده با طراحی پربازده و انعطاف‌پذیر که بطور هوشمند توانایی سازگاری با نیازها و شرایط متفاوت شبکه را داشته باشد بسیار مطلوب است. طراحی پروتکل‌های جدید فرایندی زمانبر است و به دانش ویژه که فراگیری آن آسان نیست نیاز دارد. مخصوصاً این محدودیت در حوزه شبکه مدرن یعنی پروتکل IEEE 802.11 که در برطرف کردن نیازها و شرایط برای بهبودی شبکه بطور پیوسته درحال تکامل یافتن است، وجود دارد. همچنین به محض طراحی این پروتکل، کمبود سازگاری و انعطاف‌پذیری با تغییرات محیط حس می‌گردد. این بدان دلیل است که سناریوهای موقتی مشخصه متغیر و ناپایستا دارند. تغییرات شبکه آنقدر سریع است که هیچ مکانیزم دستی نمی‌تواند آن را به دقت دنبال کند. در دسترس بودن حسگرهای کم‌توان و ارزان موجب اتصال تعداد بسیار زیادی دستگاه متصل به اینترنت می‌گردد. این امر موجب تولید ترافیک از رادیوهای ناهمگون می‌شود که از پروتکل‌های MAC و استانداردهای متفاوتی پیروی می‌کنند که موجب ظهور تکنولوژی‌ها و کاربردهای متنوع می‌گردد و مقابله با آن نیازمند استفاده از پروتکل‌های MAC پیچیده‌ای است. مصرف انرژی، تأخیر مخابراتی گیرنده به فرستنده، جیتر و نرخ ارسال داده‌ها از پارامترهای اولیه مشخص‌کننده عملکرد لایه MAC در سیستم‌های مخابراتی هستند. بهینه‌سازی این پارامترها از اهداف اصلی طراحان شبکه برای کاهش تأخیر، بهینه‌سازی طول عمر شبکه و بهبود زمان‌بندی بسته‌ها است.

تکنیک یادگیری ماشین کنونی قابلیت در ایجاد استراتژی‌های برای رفع این نیازها دارد که خارج از توانایی‌های انسانی است. هدف از الگوریتم یادگیری ماشین ایجاد یک سیستم خودکار که توانایی سازگاری با محیط واقعی را دارد، است. با داشتن شبکه و شرایط محیطی متفاوت، طراحی پروتکل MAC پربازده و انعطاف‌پذیر که با شرایط متفاوت ممکن مناسب باشد یک چالش است به ویژه در هنگامی که شرایط در دسترس نباشد و یا از پیش دانسته نباشد.


در این فصل نتایج حاصل از مطالعات و بررسی‌های صورت‌گرفته بر روی استفاده از تکنیک‌های یادگیری متفاوت برای بهینه‌سازی طراحی پروتکل MAC نظیر DeepMAC, ALOHA-QIR, RL-MAC، منطق فازی و ... ارائه شده‌اند.

۲-۸- روش DeepMAC

به کارگیری روش یادگیری عمیق برای طراحی پروتکل‌های سیستم‌های مخابراتی موجب پرهیز از استفاده از روش‌های دستی برای تنظیم پارامترهای دخیل در عملکرد پروتکل‌ها می‌گردد. به دلیل محدودیت منابع و تعداد زیاد دستگاه متصل به کانال، مطلوب است که پروتکل MAC زمان تلف‌شده به دلیل برخورد و تبادل پیام کنترلی را کمینه سازد. در مراجع [1, 2] روش یادگیری

¹ Wireless Sensor Network (WSN)


تقویتی عمیق برای طراحی بهینه و ارزیابی پروتکل‌های شبکه مطرح شده است. در حالیکه روش‌های قبلی بر تنظیم فقط یکی از پارامترهای پروتکل می‌پردازند، نوآوری اصلی این کار در تجزیه پروتکل به مجموعه‌ای از پارامترها به طوریکه هرکدام یکی از عملکردهای اصلی پروتکل را نشان می‌دهند، است. این مجموعه پارامترها به عنوان ورودی DRL برای طراحی بهینه پروتکل بکار می‌روند، بطوریکه در سناریوهای مختلف پارامترهای مهم پروتکل بهینه می‌گردند. هر یک از این پارامترها بلوک سازنده پروتکل هستند. این روش می‌تواند موجب بهبود و اصلاح اجزای تشکیل دهنده پروتکل شود که به طبع آن به بهبود عملکرد و طراحی کلی پروتکل کمک می‌کند. در مقاله ایشان چارچوب Deep MAC که در آن پروتکل‌های MAC به یک مجموعه بلوک در سیستم WLANs ۸۰۲-۱۱ تجزیه و با استفاده از روش DRL بهینه می‌شوند، ارزیابی و تحلیل گردیده است. برای مثال در شکل ۸۸، ورودی DRL شامل هدف مخابرات و بلوک‌های سازنده پروتکل‌ها و اندازه‌گیری‌ها و پیکربندی شبکه است. براساس این ورودی‌ها DRL می‌تواند فراگیرد که کدام بلوک‌های سازنده پروتکل باید موجود باشند و کدام یک باید حذف گردند.



شکل ۸۸. عملکرد DRL [2]

از آنجاییکه شرایط شبکه متغیر هستند، بنابراین ضروری است که پروتکل MAC مقیاس‌پذیر و قابل تنظیم با تغییرات شبکه بوسیله تبادل تعداد پیام کنترلی کم یا بدون تبادل پیام باشد. شکل ۲ چهارچوب DeepMAC و بخش‌های اصلی آن برای بهینه‌سازی پروتکل‌های MAC مخابرات بی‌سیم را نشان می‌دهد. همانطور که گفته شد یک پروتکل شبکه به چندین لایه تجزیه می‌شود، بطوریکه هر لایه از یک مجموعه بلوک که هرکدام عملکرد خاصی دارند تشکیل شده است. مجموعه این بلوک‌ها و تعاملشان با یکدیگر رفتار کلی پروتکل شبکه را تشکیل می‌دهند. DeepMAC از یادگیری تقویتی با معماری عمیق برای فراگیری بهترین مجموعه از بلوک‌های پروتکل در سناریوهای مختلف استفاده می‌کند. در DeepMAC از یک عامل فراگیری مرکزی برای طراحی پروتکل MAC 802.11 استفاده شده است. این مرکز در عمل در یک گره بزرگ قرار می‌گیرد و بطور متناوب مدلش را بروز می‌گرداند. بدین معنی که بلوک‌های MAC و پارامترهای مورد استفاده در دیگر گره‌ها در شبکه را مشخص می‌کند. مشخصه‌های اصلی DeepMAC به ترتیب تابع پاداش، حالت و عمل، محیط فراگیری و معماری عامل DRL می‌باشند. در تابع پاداش طراحان به مشخص کردن هدف مخابره مطابق با نحوه بکارگیری و نوع دستگاه در محیط‌های مختلف نیاز دارند؛ برای مثال در دستگاه‌های IoT با باتری محدود هدف طراح پیشینه‌سازی نرخ ارسال داده با کمینه‌سازی انرژی مصرفی است. حالت، یک بردار برای نمایش عددی بلوک‌های سازنده پروتکل و یک پیشینه از مقادیر نرخ انتقال متوسط لینک است و عمل در این چهارچوب انتخاب حالت بعدی به طوریکه پاداش پیشینه گردد، است. طراحان به مشخص کردن محیط شبکه که در آن سیستم DeepMAC بهینه گردد نیاز دارند، که در چهارچوب DRL به محیط فراگیری بازخورد می‌شود. در معماری عامل DRL شبکه عصبی از سه لایه نهان و یک لایه خارجی تشکیل شده است. در لایه‌های نهانی از تابع فعالیت ReLU استفاده می‌گردد. همانطور که در شکل ۸۹ نشان داده شده است، در پروتکل‌های شبکه بعضی از بلوک‌های توابع به یکدیگر وابسته‌اند. کنترلرهای منطقی در

این چهارچوب برای (۱) دنباله بلوک‌های عملیاتی (۲) وابستگی آنها به یکدیگر (۳) قواعد تعامل بین بلوک‌ها برای اطمینان از طراحی درست پروتکل‌ها طراحی شده‌اند. هر پروتکل می‌تواند بصورت یک گراف جهت‌دار مدل گردد که در آن بلوک‌ها برابر رئوس و تعامل بین بلوک‌ها برابر یال است.



شکل ۸۹. چهارچوب Deep MAC [2]

تعامل‌ها از خصوصیات لایه فیزیکی و لایه MAC بدست می‌آیند. دو نوع وابستگی بین بلوک‌ها وجود دارد: شرطی و دائمی. همانطور که در شکل ۲ نشان داده شده است، وابستگی بلوک NAV^1 (که مکانیزمی برای حس کردن کانال CS^2 - به صورت مجازی و جهت کاهش اتلاف انرژی است) به بلوک RTS/CTS^3 بصورت شرطی است. دو روش برای تنظیم پارامترهای NAV موجود است (۱) با رزرو اطلاعات توزیع شده در بخش $duration$ از RTS/CTS (۲) با اطلاعات تأمین شده در هر فریم آدرس داده شده. بنابراین در این چهارچوب اگر بلوک RTS/CTS موجود باشد آنگاه بلوک NAV براساس این بلوک است؛ در غیر اینصورت براساس روش بعدی تنظیم می‌گردد. هر بلوک سازنده به عنوان یک واحد در نظر گرفته می‌شود و عامل DRL بر موجود بودن یا نبودن آن بلوک در طراحی پروتکل تصمیم می‌گیرد. به عنوان مثال، وقتی مکانیزم ACK فعال شده است آنگاه DRL براساس توپولوژی شبکه، مکانیزم ACK تأخیری یا فوری را انتخاب می‌کند.

۱-۲-۸- بررسی نتایج

در [2]، بر اساس مدل شبکه (سیم / بی‌سیم)، تعداد گره‌های فعال (۵ / ۲۰)، میزان بار (کم / زیاد) و مقدار نویز، ۸ سناریو در نظر گرفته شده‌اند که پس از اجرای الگوریتم مورد نظر، بلوک‌های خاصی انتخاب و استفاده شده‌اند. نتیجه کار در **Error!** **Reference source not found.** آورده شده است.

¹ Network Allocation Vector (NAV)


² Carrier Sense

³ Request To Send / Clear To Send (RTS/CTS)

نتایج به دست آمده با انتظار شهودی نیز مطابقت دارد: در سناریوهایی که مقدار بار بالا است و یا نویز وجود دارد (۲، ۴، ۶، ۸) واحدهای ACK و Backoff انتخاب شده‌اند ولی در شرایط کم باری و بی‌نویزی (۱، ۳) این دو واحد از سیستم حذف شده‌اند. در عمل نیز چنین انتخابی درست است، چراکه وجود این دو واحد باعث بالا رفتن میزان بالاسری و تأخیر می‌شود، در صورتیکه برای شرایطی با بار کم و بدون نویز، مقدار تصادمات بسته‌ها کم بوده و نیازی به این دو مکانیزم جبران‌کننده نیست؛ ملاحظه می‌شود که انتخاب مناسبی صورت گرفته است. نتایج برخی از شبیه‌سازی‌ها جهت مقایسه عملکرد DeepMAC با روش CSMA/CA¹ در شکل ۹۰ (برای ترافیک پایین (a) و بالا (b)) آورده شده است.

جدول ۹. انتخاب بلوکهای سازنده لایه MAC پس از اجرای الگوریتم یادگیری ماشینی [2]

Scenario	Network Model	Nodes	Load	Noise	Selected Components by RL
1	Wired	5	Low	No	CW, Carrier Sensing
2	Wired	5	Low	Yes	ACK, Backoff, CW
3	Wireless	5	Low	No	Carrier Sense
4	Wireless	5	Low	Yes	Backoff, Carrier Sensing
5	Wired	20	High	No	ACK, Carrier Sensing
6	Wired	20	High	Yes	ACK, Backoff, CW
7	Wireless	20	High	No	ACK, Backoff
8	Wireless	20	High	Yes	ACK, Backoff



شکل ۹۰. مقایسه عملکرد DeepMAC با روش CSMA/CA [2]

۳-۸- پیاده‌سازی یادگیری Q-بر روی ALOHA

در این قسمت به بررسی استفاده از یادگیری Q (Q-learning) برای کاهش برخورد و ارسال دوباره و همچنین بهبود نرخ و بازدهی انرژی در روش مشهور ALOHA پرداخته می‌شود. پروتکل ALOHA-QIR که ترکیبی از پروتکل Slotted-ALOHA و یادگیری Q-است، پیشنهاد شده است [3]. در این اواخر این روش برای شبکه‌های حسگری به کار رفته در زیر آب توسعه یافته و مورد استفاده قرار گرفته است [4 و 5]. روش ALOHA دارای مزیت‌های سادگی، تأخیر و پیچیدگی کم است اما

¹ Carrier Sense Multiple Access/Collision Avoidance

از برخورد در استراتژی‌های ارسال بدون دید رنج میبرد. یادگیری-Q با استفاده از تجربه‌های قبلی می‌تواند به گره‌ها به یک هوشمندی خاص برای دسترسی به شیار با احتمال برخورد کم کمک کند. در طول ارسال داده، گیرنده توسط فرستنده از شیار آینده برای ارسال باخبر می‌گردد. بنابراین گیرنده می‌تواند در شیارهای دیگر رادیو خود را برای ذخیره انرژی خاموش کند. در مقایسه با Slotted-ALOHA این تکنیک می‌تواند به بهبود چشمگیر در نرخ ارسال داده، تأخیر و بازدهی طیفی برسد. این پروتکل شامل سه بخش به ترتیب یادگیری-Q و Informed Receiving (IR)، و بسته‌های پینگ است. در بخش یادگیری-Q هر گره یک مقدار Q منحصر به فرد برای هر شیار دارد و این مقدار ارجحیت برای انتخاب شیار را مشخص می‌کند. مقدار Q در گره i و شیار k بصورت $Q(i, k)$ نمایش داده می‌شود و مقدار Q نیز بصورت زیر بروزرسانی می‌گردد:

$$Q_{t+1}(i, k) = Q_t(i, k) + \alpha(r - Q_t(i, k))$$

در عبارت بالا α نرخ فراگیری و r پاداش فعلی است. اگر ارسال موفق باشد پاداش برابر 1+ و اگر ارسال موفق نباشد پاداش برابر با 1- است. شیار با مقدار Q بالاتر برای انتخاب ارجحیت دارد و اگر چندین شیار دارای مقدار Q برابر باشند آنگاه شیار به صورت تصادفی انتخاب می‌گردد. طول فریم N است و مقدار بهینه آن به توپولوژی شبکه بستگی دارد. بخش دریافت آگاهانه (IR^1) برای ذخیره انرژی است. از آنجاییکه در طول دوره فراگیری گره‌ها برای پیدا کردن شیار بهینه به شیارهای متفاوت می‌پردازند² و نیاز به گوش دادن کامل برای پرهیز از ازدست دادن اطلاعات در جهش قبلی دارند، برای حل مسأله انرژی در WSN پیام IR برای تغییر گره به مد خواب به منظور پرهیز از گوش‌دهی بیکار³ و بیش‌گوش‌دهی⁴ به کار می‌رود. IR برای آگاه کردن گیرنده از آخرین وضعیت فرستنده استفاده می‌شود. در واقع وقتی یک گره روشن می‌شود، در طول دوره زمان گوش فرا می‌دهد و منتظر بسته از فرستنده بالقوه می‌ماند. بسته پینگ برای آگاه کردن مداوم گیرنده از ارسال موفق و خاموش کردن رادیو تحت ترافیک کم به کار می‌رود. وقتی یک گره به شیار ترجیح داده شده خود می‌رسد و داده‌ای برای ارسال ندارد، یک بسته پینگ می‌فرستد. گیرنده به محض دریافت این بسته، یک تصدیق⁵ ارسال می‌کند و رادیو را تا شیار بعدی خاموش می‌کند. تأخیری که بسته پینگ ایجاد می‌کند متناسب با عکس ترافیک است. این بسته اگرچه انرژی و منابع کانال بیشتری مصرف می‌کند اما از گوش‌دهی بیکار در شیار خالی پرهیز می‌کند و مانع از گوش دادن کامل گره، وقتی که فرستنده قصد جهش به شیار ارجح را ندارد، می‌گردد.

مزیت این تکنیک بدین صورت است که بعد از فراگیری، نرخ بهینه گشته و تأخیر و اتلاف انرژی کم شده است. عیب آن نیز در این است که در هنگام بهینه نبودن اندازه فریم، نرخ ارسال داده‌ها بدلیل برخورد بالا کاهش می‌یابد. به دلیل کوچک‌تر بودن سایز فریم از اندازه بهینه آن، سیستم نمی‌تواند به حالت پایدار خود برسد و به دلیل برخورد بالا و ارسال دوباره، تأخیر سیستم بالا است. همچنین انرژی مصرفی تحت ترافیک کم به دلیل استفاده از بسته پینگ بالا است؛ زیرا در این حالت سیستم تعداد زیادی بسته پینگ بجای بسته داده به سمت گیرنده ارسال می‌کند.

در ادامه به ارائه نتایج مرتبط با مقایسه روش Aloha-QIR (که نسخه پیاده‌سازی شده Aloha با استفاده از یادگیری-Q است) با روش سنتی Slotted-Aloha پرداخته می‌شود. پارامترهای شبیه‌سازی در جدول ۱۰ آمده‌اند.

جدول ۱۰. پارامترهای شبیه‌سازی برای روش ALOHA-QIR [3]

پارامتر	مقدار
نرخ بیت	۲۵۰ Kbits/s
طول بسته داده	۱۴۴ Bits

¹ Informed Receiving

² Hopping


³ Idle Listening

⁴ Overhearing

⁵ Acknowledgment

طول بسته ACK	۲۰ bits
طول بسته ping	۲۸ bits
طول شیار	۱۱۰۰ bits
توان ارسال	۵۱ mW
توان دریافت	۴۸ mW
بازه تداخل	۳۰ m
بازه دریافت	۱۵ m
طول شبیه‌سازی	5×10^6 slots

در شکل ۹۱ عملکرد نرخ ALOHA-QIR با مقادیر متفاوت N به همراه ALOHA-BEB برحسب ترافیک نشان داده شده است. "عقبگرد نمایی دودویی" (BEB^1) یک استراتژی برای ارسال دوباره slotted-ALOHA است. همانطور که مشاهده می‌گردد نرخ بطور خطی با افزایش ترافیک افزایش می‌یابد (که حاکی از آن است که همه داده تولید شده ارسال گشته اند) تا اینکه به یک حد مشخصی برسد. ALOHA-QIR با فریم سایز $N=100$ بهینه است و بیشینه نرخ حدود 0.47 ارلنگ^۲ را دارد که دو برابر نرخ ALOHA-BEB است. طول فریم از پارامترهای مهم ALOHA-QIR است. اگر طول کمتر از مقدار بهینه باشد آنگاه بعضی از گره‌ها باید شیارهای خاص خود را انتخاب کنند درحالی‌که باید با بقیه سهیم شود که موجب برخورد می‌گردد. درحالی‌که N بزرگتر از مقدار بهینه باشد سیستم می‌تواند به یک حالت ثبات بدون برخوردی برسد اما بعضی از شیارها بدون استفاده میمانند که موجب هدر رفتن ظرفیت کانال می‌گردد. بنابراین، ALOHA-QIR با سایز ۸۰ و ۱۲۰ نرخ کمتر از 0.47 ارلنگ دارد.




شکل ۹۱. مقایسه مقدار گذردهی تحت ترافیک مختلف [3]

شکل ۹۲ عملکرد تأخیر انتها به انتها را نشان می‌دهد. ALOHA-QIR با سایز $N=100$ تأخیر را زیر ۱ ثانیه تحت ترافیک‌های مختلف نمایش می‌دهد. ALOHA-QIR با سایز $N=120$ تأخیر بیشتری به دلیل اندازه بزرگتر فریم دارد و همچنین این پروتکل با سایز $N=80$ تأخیر بسیار بیشتری دارد و آن بدلیل برخورد بیشتر و ارسال دوباره است. ALOHA-BEB کمترین تأخیر را دارد و آن بدین دلیل است که در حالت ترافیک کم، یک بسته را بعد از تولید در شیار بعدی ارسال می‌کند و نیاز به منتظر ماندن برای شیار دیگری ندارد.


¹ Binary Exponential Backoff

² Erlang



شکل ۹۲. تأخیر برحسب ترافیک [3]


شکل ۹۳ بازدهی انرژی سیستم را نشان می‌دهد. همانطور که مشاهده می‌گردد ALOHA-QIR با سایز فریم 100 و ۱۲۰ انرژی بر بیت یکسانی را تجربه می‌کند، زیرا تقریباً بطور کامل از برخورد پرهیز می‌کند و به یک زمان‌بندی درست دست می‌یابد. هزینه انرژی بیشتر در ترافیک کم بدلیل ارسال بسته Ping است. زیرا گره‌ها در ترافیک کم، بسته ping بیشتری نسبت به داده ارسال می‌کنند. ALOHA-QIR با سایز فریم 80 هزینه انرژی بیشتری مصرف می‌کند و آن بدلیل برخورد بیشتر و ارسال دوباره است که منجر به مصرف انرژی بیشتر برای گوش فرادادن می‌گردد. ALOHA-BEB بیشترین مصرف انرژی را دارد و آن بدلیل مصرف هزینه انرژی بالا ناشی از گوش فرادادن است.



شکل ۹۳. هزینه انرژی برحسب نرخ بیت [3]

شکل ۹۴ هزینه انرژی بر ثانیه را برای ۴ حالت نشان می‌دهد. همانطور که میدانیم هزینه انرژی ALOHA-QIR با سایز فریم ۱۰۰ و ۱۲۰ غالباً صرف داده گشته است. بنابراین هزینه انرژی آن بصورت خطی با ترافیک افزایش می‌یابد. برای $N=80$ ،

عمل‌گوش‌دادن انرژی بیشتری را در ترافیک کم مصرف می‌کند درحالی‌که برای ترافیک زیاد، ارسال دوباره و برخورد غالب هزینه انرژی را تشکیل می‌دهد و موجب بالا رفتن اتلاف انرژی می‌شود.



شکل ۹۴. هزینه انرژی بر ثانیه برحسب ترافیک [3]

استاندارد IEEE 802.15.4 برای تعیین مشخصات لایه MAC و PHY بکار می‌رود. پروتکل CSMA/CA پروتکل لایه MAC تعریف شده در این استاندارد است. تکنیک سوم به حل مسائل WSNs در تأخیر پیام، افزایش عمر باتری ندهای حسگر، بهبود کیفیت سرویس، قابلیت اعتماد در ارسال پیام می‌پردازد. منطق فازی در CSMA/CA برای بهبود تأخیر شبکه بکار رفته است.

۴-۸- روش RL-MAC

در این روش [6] هدف بهینه‌سازی سیستم WSN از نظر نرخ، تأخیر و بازدهی انرژی است. در RL-MAC گره‌ها بطور فعال از شرایط بقیه گره‌ها باخبر می‌شوند و بنابراین بازدهی کل شبکه بهبود می‌یابد. ایده اصلی به کار رفته در این است که ابتدا یک ساختار متکی بر فریم و مشابه پروتکل‌های معروف به کاررفته در شبکه‌های حسگری یعنی S-MAC [7] و T-MAC [8] را مورد استفاده قرار می‌دهد و سپس با استفاده از روش‌های یادگیری ماشینی، مقدار چرخه کاری (DC^1) و مدت زمان فعال بودن^۲ را بر اساس میزان ترافیک تولید شده در گره‌ها و همچنین ترافیک ورودی داده از سوی دیگر گره‌ها را بهینه می‌کند. نظر به اهمیت مقدار چرخه کاری و تأثیر مستقیم آن بر معیار مهمی همچون مصرف انرژی، این موضوع همچنان مد نظر پژوهشگران است. در [9] به کارگیری روش‌های ماشینی در تنظیم چرخه کاری به صورت مبسوط‌تری مورد توجه و بررسی قرار گرفته است. در ادامه ایده اصلی و پایه ارائه می‌شود. در شکل ۹۵ چگونگی تقسیم زمان به فریم‌ها و هر فریم به اسلات زمانی نشان داده شده است. طول اسلات براساس پهنای باند کانال و طول بسته داده مشخص می‌گردد. در ابتدای هر فریم، عامل RL، که وظیفه موتور پروتکل MAC را انجام می‌دهد، بصورت دینامیک اسلات‌هایی را به عنوان زمان فعال در نظر می‌گیرد. در زمان فعال، هر

¹ Duty Cycle

² Active Time

گره به کانال گوش می‌سپارد و سعی بر تبادل بسته با همسایگانش دارد. وقتی زمان فعال تمام می‌شود، هر گره عمل ارسال و دریافت داده را متوقف ساخته و وارد حالت خواب می‌گردد. در این پروتکل چند مکانیزم به شرح زیر به کار گرفته شده‌اند:

(۱) رزرو کردن زمان فعال بودن (ATR^1)

(۲) صورت‌بندی تابع پاداش


(۳) پرهیز از زود به خواب رفتگی^۲

(۴) الگوریتم یادگیری-Q

(۵) پرهیز از تصادم^۳ و بیش‌گوش‌دهی^۴

با استفاده از این مکانیزم‌ها می‌توان در ترافیک بالا به گذردهی بیشتری نسبت به روش CSMA استاندارد دست یافت؛ چراکه RL-MAC در ترافیک بالا از چرخه‌کاری بالاتری استفاده می‌کند. همچنین می‌تواند بیش از ۵۰٪ انرژی را ذخیره کند. عیب این تکنیک نیز طول دوره فراگیری آن است.

مقایسه عملکرد RL-MAC با روش‌های متعارف S-MAC و T-MAC در خصوص مقادیر گذردهی و کارایی انرژی در شکل ۹۶ و شکل ۹۷ نشان داده شده‌اند.




شکل ۹۵. ساختار فریم در پروتکل RL-MAC. چرخه‌کاری انطباقی جهت بهینه‌سازی گذردهی و مصرف انرژی [4]

¹ Active time reservation


² Early sleeping avoidance

³ Collision

⁴ Overhearing



شکل ۹۶. مقایسه میزان گذردهی RL-MAC با روش‌های S-MAC و T-MAC [4]



شکل ۹۷. مقایسه میزان کارایی انرژی RL-MAC با روش‌های S-MAC و T-MAC [4]

۵-۸- مروری بر چند روش متفرقه در خصوص ارتقاء لایه MAC

ارتقاء عملکرد لایه MAC از طرق روش‌های مختلفی صورت می‌گیرد که همگی آنها را نمی‌توان در یک گزارش مورد مطالعه و بررسی قرار داد. در این بخش مروری مختصر بر ایده‌هایی که در مقالات مختلف ارائه شده‌اند ارائه خواهد شد تا خواننده محترم با آنها آشنایی یابد و در صورت لزوم و بسته به کاربردی که دارد، از آنها ایده گرفته و به کار بندد.

۱-۵-۸- ارتقاء عملکرد با ترکیب روش‌های سنتی MAC

علاوه بر استفاده از یادگیری ماشینی جهت بهینه کردن پارامترهای دخیل در پروتکل‌های متعارف، یک رویکرد دیگر در این زمینه، استفاده بهینه از ترکیبی از پروتکل‌های مختلف است. در مرجع [10] پیشنهاد شده است که مسائلی همچون استفاده بهتر از محیط انتقال می‌توانند با طراحی تکنولوژی دسترسی به محیط و بکارگیری ترکیب دو تکنولوژی مرسوم لایه MAC (TDMA)

و CSMA) پاسخ داده شوند. که این مهم با استفاده از تکنولوژی یادگیری تقویتی قابل دستیابی است. در این مقاله تکنولوژی یادگیری تقویتی با عبور از مرحله فراگیری با استفاده از پارامترهای داده شده باید توانایی انتخاب یکی از این دو فناوری دستیابی به محیط (CSMA و TDMA) با بازدهی بالاتر را داشته باشد؛ بطوریکه جابجایی این دو مدل با توجه به شرایط کانال، با فرض بالا نگه داشتن عملکرد شبکه، امکان پذیر باشد.

به صورت خلاصه روش پیشنهادی ایشان بدین گونه است که [10 و 11]:

(۱) گره‌ها بر اساس فاصله‌شان تا نقطه جمع‌آور (Sink) داده‌ها به چند زیر مجموعه تقسیم می‌شوند. همچنین ایشان از پیش‌بینی مکان گره‌ها نیز استفاده می‌کنند.

(۲) تمام گره‌ها در هر مجموعه برای ارسال داده‌ها با یکدیگر رقابت نموده و از روش CSMA/CA استفاده می‌کنند. هر زیرمجموعه نیز با استفاده از TDMA برای ارسال داده‌ها به مرکز تجمع داده‌ها استفاده می‌کنند.

(۳) اختصاص شیارها در هر دو TDMA و CDMA نیز متکی بر مکانیزم یادگیری ماشینی است.

این تکنیک بهره‌برداری از کانال را بهبود می‌دهد و برای وقتی که تعداد گره‌ها زیاد و احتمال برخورد مطابق با آن زیاد است، مناسب گزارش داده شده است.

۲-۵-۸- یادگیری ماشین در لایه MAC چندکاربره^۱

در مرجع [12] مساله دسترسی دینامیک برای استفاده بهینه از شبکه در شبکه‌های چند کاناله بی‌سیم در نظر گرفته شده است. این مساله با افزایش نیاز به مخابرات بی‌سیم و کاهش طیف مطرح شده است. در ابتدای هر بازه زمانی فرستنده یک بسته را با احتمال معینی ارسال می‌کند و در انتهای آن هر کاربر که بسته داده ارسال کرده است یک تصدیق از عدم موفقیت یا موفقیت آن دریافت می‌کند. هدف، دسترسی چندین کاربر به طیف است که کارکرد معینی از شبکه را در حالت توزیع شده^۲ پیشینه سازد. یافتن راه حل بهینه برای مساله دسترسی به طیف بدلیل بزرگ بودن فضای حالت و اطلاع جزئی از حالت‌ها پیچیده است. برای مقابله با این مساله الگوریتم دسترسی به طیف براساس DRL چندکاربره مطرح شده است. نتایج حاکی از عملکرد قوی این الگوریتم است.

۳-۵-۸- یادگیری تقویتی عمیق در طراحی MAC

در مرجع [13] از یادگیری تقویتی عمیق در پروتکل MAC در شبکه مخابرات بی‌سیم استفاده شده است که با نام (DLMA^۳) معرفی شده است. هدف از این کار بهترین اشتراک‌گذاری طیف بین شبکه‌های مختلف در محیط‌های مختلف، بدون دانش اولیه و با استفاده از یادگیری ماشین است. در روش ایشان مساله به اشتراک‌گذاری بازه زمانی بین چندین شبکه از نظر زمانی شیاربندی شده^۴ با بکارگیری پروتکل‌های متفاوت MAC در نظر گرفته شده است. یکی از پروتکل‌های MAC استفاده شده DLMA و دو تای دیگر ALOHA و TDMA می‌باشند. گره‌هایی که از پروتکل‌های DLMA استفاده می‌کنند از دو پروتکل MAC، TDMA و ALOHA اطلاعی ندارند. با نظارت بر محیط و عملیات انجام شده و پاداش‌های کسب شده، گره دارای DLMA می‌تواند راهکار همزیستی بهینه با گره‌های TDMA و ALOHA را فراگیرد.

¹ Multiuser MAC

² Distributed

³ Deep-reinforcement learning multiple access

⁴ Time-Slotted

۴-۵-۸- طراحی MAC با استفاده از مدل مارکوف

در مرجع [14] مساله دسترسی دینامیک به کانال چندگانه در نظر گرفته شده است؛ بطوریکه چندین کانال همبسته از یک مدل مارکوف مشترک ناشناس پیروی می‌کنند. یک کاربر در هر بازه زمانی یک کانال را برای ارسال داده و دریافت تصدیق از عدم موفقیت یا موفقیت آن انتخاب می‌کند. هدف پیدا کردن خط مشی است که پاداش مورد انتظار را در بلند مدت بیشینه کند. مسأله بصورت $POMDP^1$ با تغییرات نامعلوم سیستم فرموله شده است. برای غلبه بر تغییرات نامعلوم سیستم، روش یادگیری تقویتی بکار رفته است و DQN^2 با فضای حالت بزرگ و بدون دانش قبلی از اطلاعات آماری سیستم پیاده‌سازی شده است. مطالعات تحلیلی برخط‌مشی بهینه برای کانال با مدل ثابت با تغییرات شناخته‌شده سیستم از طریق شبیه‌سازی نشان داده است که DQN بدون دانستن تغییرات سیستم می‌تواند به عملکرد بهینه یکسانی دست یابد. این طرح برای سناریوهای عملی و عمومی و وقتی کانال‌ها همبسته و اطلاعات آماری سیستم نامشخص است، کاربرد دارد.

۶-۸- طراحی لایه MAC با استفاده از هوش مصنوعی محلی^۳

در مرجع [15] بکارگیری از یادگیری ماشین براساس هوش مصنوعی برای بهینه‌سازی پارامترهای دخیل در پروتکل با استفاده از یادگیری محلی مطرح شده است. مصرف انرژی، تأخیر انتها به انتها مخابراتی، تأخیر جیت و نرخ ارسال بسته^۴ و مخابرات از پارامترهای اولیه هستند که عملکرد لایه MAC مورد استفاده در مخابرات بی‌سیم را مشخص می‌کنند. بهینه‌سازی این پارامترها از اهداف طراحان شبکه است. در این مقاله استفاده از یادگیری ماشین براساس هوش مصنوعی به منظور بهبود پارامترهای نامبرده ارائه شده است. محققان و طراحان شبکه بی‌سیم پروتکل MAC بسیاری مانند BMA , $SMAC$ TDMA و غیره استفاده می‌کنند. AI با بکارگیری پروتکل‌های $TDMA$, $Bit Map Assisted (BMA)$ و $SMAC^5$ و تنظیم پارامترهای این پروتکل‌ها، بهترین پروتکل تنظیم‌شده برحسب شرایط شبکه را به دست می‌دهد. عملکرد شبکه تحت شرایط مختلف آن ارزیابی شده و نشان داده که مصرف انرژی شبکه آن ۳۰٪ بهبود می‌یابد و طول عمر شبکه را نیز افزایش می‌دهد. همچنین نشان داده شده است که با تغییر تعداد گره‌ها سیستم همچنان عملکرد خوبی دارد و برای شبکه با هر سائزی مناسب است. پروتکل‌های یادگیری برای ترکیب‌های متفاوت حالت شبکه تست شده‌اند. پارامترهای استفاده شده در جدول ۱۱ ارائه شده‌اند.

تأخیر انتها به انتها، انرژی مورد نیاز، نسبت ارسال بسته پروتکل ارائه شده با پروتکل‌های BMA TDMA و $SMAC$ مقایسه شده‌اند. در شکل ۹۸ مقایسه انرژی مصرفی پروتکل‌های مختلف آورده شده است. همانطور که مشاهده می‌گردد، پروتکل $TDMA$ بیشترین مصرف انرژی و پروتکل براساس هوش مصنوعی کمترین میزان انرژی را در شبکه مخابراتی مصرف می‌کند. در شکل ۹۹ مقایسه تأخیر پروتکل‌های متفاوت آورده شده است. تأخیر از روند مشابه با مصرف انرژی پیروی می‌کند و سرعت کلی پروتکل MAC با استفاده از هوش مصنوعی بهبود می‌یابد. بهبود سرعت، پاسخ سریعتر سیستم و نرخ گذردهی را در مقایسه با دیگر پروتکل‌های MAC گارانتی می‌کند. همچنین PDR در مقایسه با $SMAC$ و BMA بهبود یافته است و عملکرد مشابهی با $TDMA$ دارد. این بدان علت است که $TDMA$ پروتکلی با پیچیدگی کم است و کمترین نرخ اتلاف بسته‌ها را دارد. الگوریتم بر اساس هوش مصنوعی بر مسئله تلفات بسته‌ها در BMA و $SMAC$ فائق آمده است و به عملکردی مشابه با $TDMA$ دست یافته است. مقایسه میزان گذردهی نیز در شکل ۱۰۰ نشان داده شده است.

جدول ۱۱. پارامترهای شبیه‌سازی. [15]

¹ Partially Observable Markov Decision Process


² Deep Q-network

³ Localized AI


⁴ Packet Delivery Ratio(PDR)

⁵ Sensor-MAC

پارامتر	مقدار
الگوریتم مسیریابی	AODV ¹
تعداد گره‌ها	۳۰ تا ۱۰۰
نوع شبکه	MANET
صف	Priority drop tail
ابعاد شبکه	300m*300m
نوع مک	802.11
تعداد مخابره	1-10




شکل ۹۸. مقایسه عملکرد انرژی براساس تعداد مخابرات برای تعداد ۳۰ گره [15]



شکل ۹۹. مقایسه تاخیر براساس تعداد مخابرات برای تعداد ۳۰ گره [15]

¹ Ad-hoc On-demand Distance Vector




شکل ۱۰. مقایسه عملکرد نرخ ارسال بسته براساس تعداد مخابرات برای تعداد ۳۰ گره [15]

۷-۸- استفاده از منطق فازی در ارتقاء عملکرد لایه MAC

در این بخش به دو کاربرد از منطق فازی جهت ارتقاء عملکرد لایه MAC پرداخته می‌شود.


۱-۷-۸- استفاده از منطق فازی جهت بهبود تأخیر در سیستم

شکل ۱۰۱ سیستم منطق فازی را نشان می‌دهد. طول صف و نرخ ترافیک دو ورودی این سیستم می‌باشند [16 و 17]. ورودی می‌تواند در یک بازه بزرگ تغییر کند که این موجب سازگاری بهتر شبکه با تغییرات محیط می‌گردد. در این کار یک روش جدید پربازده برای افزایش کیفیت سرویس و بهینه سازی مصرف انرژی در سیستم WSNs ارائه شده است. الگوریتم منطق فازی با میزان تراکم و اتلاف بسته‌ها سروکار دارد. روش پیشنهاد شده برای کاهش احتمال اتلاف بسته‌ها با مدیریت منابع بصورت پربازده و با درنظر گرفتن مشخصات آماری طراحی شده است.




شکل ۱۰۱. سیستم منطق فازی با ورودی نرخ ترافیک و طول صف [16]

از مزایای این تکنیک نرخ بالاتر نسبت به CSMA/CA استاندارد است؛ زیرا در منطق فازی ناسازگاری بین بسته‌ها کمینه می‌گردد. همچنین در این سیستم مصرف انرژی شبکه و تأخیر کاهش می‌یابد و موجب افزایش گذردهی می‌شود. از معایب این تکنیک ناسازگاری با کاربردهای بسیار پویا مانند اینترنت اشیاء است که در آن گره‌ها بطور فعال وارد و خارج شبکه می‌گردند. شکل ۱۰۲ نتایج شبیه‌سازی نرخ بصورت تابعی از زمان نشان داده شده است. همانطور که مشاهده می‌گردد با استفاده از قواعد فازی میزان گذردهی بیشتر از الگوریتم پایه CSMA/CA گشته است. این بدان علت است که تعداد بسته‌ها در الگوریتم فازی کمتر از الگوریتم پایه است؛ زیرا تصادفات کمتری در این الگوریتم رخ می‌دهد. شکل ۱۰۳ تغییرات تأخیر بسته‌ها در طول دوره شبیه‌سازی را نشان می‌دهد. همانطور که مشاهده می‌گردد مقدار تأخیر در الگوریتم فازی بسیار بهتر شده است.



شکل ۱۰۲. تغییرات مقدار گذردهی برحسب زمان [16]




شکل ۱۰۳. میزان متوسط تأخیر برحسب زمان [16]

۲-۷-۸- استفاده از منطق فازی بر روی روش CSMA/CA

پروتکل استاندارد IEEE 802.15.4 مورد استفاده در WSNs مزایای زیادی از جمله مصرف کمتر توان دارد، که محیط صنعتی نیز استفاده می‌گردد. اگرچه، بسیاری از محققان بعضی کمبودهای آن را مشخص کرده اند یک روش. از جمله در الگوریتم

CSMA/CA که کنترل دست یابی به محیط را انجام می‌دهد، یک روش مبنی بر درگیری^۱ است و در نتیجه یک روش غیر قطعی است. کنترلر منطق فازی می‌تواند پارامترهای CW^2 و BE^3 از پروتکل CSMA/CA را بهبود ببخشد [18,16]. پارامترهای CW و BE برطبق میزان کار و گذردهی تنظیم می‌شوند. تکنیک فازی در IEEE 802.15.4 بطور اساسی با امنیت، تحرک و مدیریت مصرف انرژی سروکار دارد. تکنیک قبلی و این تکنیک در پیاده سازی fuzzy تقریباً مشابه‌اند. یکی از تفاوت‌های اصلی آن، ورودی دو سیستم است و دیگری تعداد توابع عضویت^۴. در تکنیک قبلی هدف بهبود انرژی، گذردهی و تأخیر بود درحالی‌که در این تکنیک هدف بهبود CW و BE در پروتکل IEEE 802.15.4 است. شکل ۱۰۴ سیستم منطق فازی با ورودی بار کاری و گذردهی را نشان می‌دهد.



شکل ۱۰۴. سیستم منطق فازی با ورودی میزان بار کاری و گذردهی [18]

۸-۸- استفاده از شبکه‌های عصبی بر روی CSMA

در [19] الگوریتم MLP در WSN براساس CSMA در مقابله با حمله عدم سرویس (DOS^5) بکار رفته است. MLP امنیت WSN را با چک کردن پارامترها و با بستن لایه MAC و لایه فیزیکی مربوط به گره حسگر وقتی خروجی MLP از مقدار حدی بیشتر می‌گردد، ارتقا می‌دهد. MLP با استفاده از الگوریتم‌های پخش‌انتشار^۶ و بهینه‌سازی ازدحام ذرات (PSO^7) فراگیری می‌گردد. از مزایای این تکنیک می‌توان به این اشاره کرد که مصرف توان وقتی مقدار حدی برابر با ۰.۸ کاهش می‌یابد. این بدان دلیل است که گره‌ها در هنگام حمله DOS خاموش می‌گردند. از معایب آن می‌توان به زمان محاسبه PSO در هنگام فراگیری اشاره نمود.

¹ Contention-based

² Contention Window

³ Backoff Exponent

⁴ Membership

⁵ Denial Of Service

⁶ Back Propagation

⁷ Particle Swarm Optimization

۸-۹- مقایسه چند روش ML-MAC

در جدول ۵ بطور جمع‌بندی مقایسه‌ای میان برخی از تکنیک‌های نامبرده شده در بالا آورده شده است [16]. در این جدول چهار معیار اصلی در ارزیابی عملکرد لایه MAC، یعنی تأخیر، مصرف انرژی، کارایی انرژی و گذردهی مد نظر قرار گرفته‌اند و اینکه هر کدام از این روش‌ها بر کدامیک از این معیارها تأثیر دارند، با علامت * مشخص شده است.

جدول ۵. مقایسه روش‌های مختلف MAC که از یادگیری ماشین استفاده می‌کنند [16]

مبتنی بر پروتکل MAC	تأخیر	مصرف انرژی	کارایی انرژی	گذردهی	
ALOHA	*		*	*	ALOHA-QIR [3]
SMAC, TMAC			*	*	RL-MAC [4]
CSMA/CA		*		*	منطق فازی [17]
CSMA/CA	*	*		*	منطق فازی [18]
CSMA			*	*	شبکه عصبی [19]

۸-۱۰- کاربردها در صنعت برق

اینترنت اشیاء و شبکه‌های حسگری کاربردهای متعددی در صنعت برق منجمله در هوشمندسازی خانه‌ها (و ساختمان‌ها)، کنترل کنتورهای هوشمند در سامانه‌های AMR¹ و زیرساخت اندازه‌گیری پیشرفته (AMI²) و پایش خطوط برق و ایستگاه‌ها دارند. به علت رشد روزافزون این ادوات و اتصال آنها به شبکه‌های ارتباطی، عملکرد مکانیزم اتصال آنها به شبکه (که از وظایف لایه MAC است) اهمیت زیادی پیدا می‌کند. یکی از معیارهایی که مستقیماً تحت تأثیر قرار می‌گیرد و به وضوح قابل اندازه‌گیری است، میزان مصرف انرژی در هریک از این حسگرها است. یک طراحی خوب برای لایه MAC، تا حد زیادی از وقوع تصادمات در هنگام ارسال بسته‌های داده‌ها می‌کاهد که همین امر موجب عدم نیاز به بازارسالی بسته‌ها و صرفه‌جویی در مصرف انرژی می‌شود. همچنین با یک طراحی هوشمندانه و کاهش مقدار چرخه‌کاری تا حد ممکن (که در عمل به معنی طولانی کردن مدت زمان خواب برای گره‌ها است)، می‌توان مصرف انرژی در گره‌ها را کاهش داد. این کاهش مصرف انرژی علاوه بر اینکه به خودی خود مطلوب است، دارای تبعات مثبت دیگری همچون کاهش هزینه‌ها و زحمات مرتبط با پشتیبانی‌های لجستیکی است؛ به این ترتیب که، به عنوان مثال باتری‌های تعبیه شده در کنتورهای قرائت گاز، به جای نیاز به تعویض پس از هر ۵ سال را می‌توان به صورت میانگین پس از هر ۱۰ سال انجام داد. همین موضوع تعویض باتری را می‌توان برای ادوات هوشمند هر ساختمان مد نظر قرار داد.

¹ Automatic Meter Reading

² Advanced Metering Infrastructure

ارتقاء عملکرد MAC و تأثیر آن بر سیستم را می‌توان از زاویه‌ای دیگر نیز نگریست؛ به این ترتیب که برای یک QoS مفروض، می‌توان تعداد گره‌ها را برای یک بخش از شبکه افزایش داد (چراکه تصادفات بسته‌ها و ... بهبود یافته‌اند). همچنین توجه شود که به صورت کلی می‌توان صنعت برق را یک مثال از کاربردهای صنعتی در نظر گرفت و از هر کاربرد صنعتی که از ارتقاء عملکرد لایه MAC منتفع می‌شود، ایده گرفت و آنرا برای این صنعت بومی‌سازی نمود. نکته مهمی که در این فصل مورد توجه قرار گرفت این بود که نحوه به کارگیری روش‌های AI در مکانیزم‌های پایه‌ای مورد استفاده در لایه MAC (همچون ALOHA، CSMA و Sensor-MAC) مورد بررسی قرار گرفت. این مکانیزم‌ها در کثیری از استانداردها همچون Zigbee، WiMAX و Wifi مورد استفاده قرار می‌گیرند و روش‌های جدید MAC نوعاً (و یا به نحوی از انحاء) بر آنها متکی هستند. به این ترتیب هرگونه ارتقاء عملکرد این روش‌های پایه‌ای به صورت مستقیم در عملکرد کثیری از لایه‌های MAC تأثیر خواهند گذاشت.

به عنوان یک کاربرد عینی در شبکه برق، در فصل اول این پروژه به استفاده از رادیوشناختگر در قسمت‌های مختلف شبکه هوشمند برق پرداخته شد. در این خصوص مراجع [20-22] طراحی‌های مختلفی از لایه‌های MAC جهت به کارگیری در صنعت برق ارائه داده‌اند که متکی بر روش پایه‌ای CSMA/CA هستند؛ و همانطور که در بالا بیان شد، روش‌های AI می‌توانند موجب ارتقاء عملکرد آنها و به طبع آن باعث ارتقاء عملکرد زیرسیستم مورد استفاده در صنعت برق شوند.

همچنین می‌توان به پروژه اروپایی SunSeed که در فصل اول این گزارش مورد بررسی قرار گرفت اشاره نمود. در این پروژه موضوع ارتباطات چندگانه (Multi-Connectivity) برای بهبود ضریب اطمینان ارسال داده‌ها ارائه شده است؛ هرچند در گزارش‌های انتشار یافته این پروژه اشاره مستقیمی در خصوص طراحی لایه MAC نشده است و مطالعات آنها به شبیه‌سازی‌ها و معطوف به ارتباطات چندگانه هستند، ولی در هنگام پیاده‌سازی روش ایشان در عمل، طراحی لایه MAC با اهمیت می‌شود، چراکه هر لینک ارتباطی از نوع مشخصی از طراحی لایه MAC استفاده می‌کند و به این ترتیب مدیریت این روش‌های مختلف نیازمند یک مکانیزم پیچیده‌تر و ارتقاء یافته‌تر است.

۱۱-۸- جمع‌بندی فصل ۸

در این فصل ابتدا از دلیل نیاز به پروتکل‌های MAC منعطف و چگونگی پاسخ‌دهی به این نیاز با استفاده از روش‌های مطرح در حوزه هوش مصنوعی صحبت شد. کارایی لایه MAC در شبکه‌های حسگری و همینطور اینترنت اشیاء از اهمیت بالایی برخوردار است. این موضوع برای کاربردهای صنعتی و به ویژه کاربردهای صنعت برق از اهمیت ویژه‌ای برخوردار است؛ چراکه شبکه‌های حسگری در جای‌جای صنعت برق مورد استفاده هستند و هرگونه بهبود در عملکرد آنها باعث بهبود افزایش راندمان کلی سیستم خواهد شد.

مطالعات این مرحله نشان می‌دهد که سه رویکرد اصلی برای بهبود عملکرد لایه MAC وجود دارند: (۱) ترکیبی هوشمندانه از روش‌های MAC پیشین. (۲) ارتقاء عملکرد برخی از روش‌های پیشین MAC با بهینه‌سازی پویاس پارامترهای دخیل در آنها. (۳) طراحی پروتکل‌های جدید با استفاده هوشمندانه و گزینشگر از برخی از اجزای عملکردی روش‌های پیشین.

در این فصل، تعدادی از مقالات که روش‌های استفاده از هوش مصنوعی در لایه MAC را برای کاربردهای صنعتی مورد توجه قرار می‌دهند مطالعه و بررسی شدند. از میان این روش‌ها، ALOHA-QIR که مبتنی بر روش معمول و پرکاربرد ALOHA است، یادگیری Q برای بهینه‌سازی پارامترهای دخیل در عملکرد این روش سنتی را به کار می‌گیرد. پیچیدگی کم و کنترل تأخیر از ویژگی‌های این روش است؛ در عین سادگی به دو برابر بیشینه نرخ در Slotted-ALOHA دست می‌یابد و تأخیر انتهایی‌اتنها و بازدهی انرژی را نیز بهبود می‌دهد. DeepMAC رویکردی عمیق‌تر را اتخاذ می‌کند و سعی در طراحی پروتکل‌های جدید و با استفاده هوشمندانه و گزینشگر از اجزای قدیمی‌تر پروتکل‌ها، به ساختارهایی جدید دست می‌یابد. در دو زیربخش گزارش (۵ و ۶)، روش‌های ترکیبی از لایه‌های MAC قدیمی مورد توجه قرار گرفته‌اند. استفاده از شبکه‌های عصبی و منطق فازی نیز

(که درصدد بهینه‌سازی پارامترهای دخیل در عملکرد لایه‌های MAC قدیمی هستند) نیز در بخش‌های دیگر این فصل مورد اشاره و بررسی قرار گرفتند. مطمئناً برخی از این روش‌ها قابلیت پیاده‌سازی در شبکه‌های حسگری و کاربرد در صنعت را دارند. در انتهای فصل نیز کاربردهای مطالب بیان شده در صنعت برق به صورت مبسوطی مطرح گردیدند.

مراجع فصل ۸

1. H. B. Pasandi and T. Nadeem, "MAC Protocol Design Optimization Using Deep Learning," *2020 International Conference on Artificial Intelligence in Information and Communication (ICAIIIC)*, Fukuoka, Japan, 2020, pp. 709-715.
2. H. B. Pasandi and T. Nadeem, "Challenges and Limitations in Automating the Design of MAC Protocols Using Machine-Learning," *2019 International Conference on Artificial Intelligence in Information and Communication (ICAIIIC)*, Okinawa, Japan, 2019, pp. 107-112.
3. Yi Chu, Paul D. Mitchell and David Grace, "ALOHA and Q-Learning Based Medium Access," in *IEEE, Paris, France, 2012*.
4. S. H. Park, P. D. Mitchell and D. Grace, "Reinforcement Learning Based MAC Protocol (UW-ALOHA-Q) for Underwater Acoustic Sensor Networks," in *IEEE Access*, vol. 7, pp. 165531-165542, 2019.
5. S. H. Park, P. D. Mitchell and D. Grace, "Performance of the ALOHA-Q MAC Protocol for Underwater Acoustic Networks," *2018 International Conference on Computing, Electronics & Communications Engineering (iCCECE)*, Southend, United Kingdom, 2018, pp. 189-194.
6. Z. Liu and I. Elhanany, "RL-MAC: a reinforcement learning based MAC protocol for wireless sensor networks", *International Journal of Sensor Networks*, vol. 1, no. 34, p. 117, 2006.
7. Wei Ye, J. Heidemann and D. Estrin, "Medium access control with coordinated adaptive sleeping for wireless sensor networks," in *IEEE/ACM Transactions on Networking*, vol. 12, no. 3, pp. 493-506, June 2004, doi: 10.1109/TNET.2004.828953.
8. Dam, T.V. and Langendoen, K. (2003) 'An adaptive energyefficient mac protocol for wireless sensor networks', *SenSys '03: Proceedings of the first International Conference on Embedded Networked Sensor Systems*, New York, NY: ACM Press, pp.171-180.
9. B. Trinh, L. Murphy and G. Muntean, "A Reinforcement Learning-Based Duty Cycle Adjustment Technique in Wireless Multimedia Sensor Networks," in *IEEE Access*, vol. 8, pp. 58774-58787, 2020.
10. Mostafa Korashy, Machine Learning for Computer Communications (Survey), [Research Report] University of Quebec, 2018. hal-02089517
11. X. Yang, L. Wang, J. Su, and Y. Gong, "Hybrid mac protocol design for mobile wireless sensors networks", *IEEE Sensors Letters*, vol. 2, no. 2, pp. 1-4, 2018.
12. O. Naparstek and K. Cohen," Deep multi-user reinforcement learning for distributed dynamic spectrum access", *IEEE Transactions on Wireless Communications*, 18(1):310-323, 2018.

13. S. Wang, H. Liu, P. H. Gomes, and B. Krishnamachari, "Deep reinforcement learning for dynamic multichannel access in wireless networks", *IEEE Transactions on Cognitive Communications and Networking*, 4(2):257–265, 2018.
14. Y. Yu, T. Wang, and S. C. Liew, "Deep-reinforcement learning multiple access for heterogeneous wireless networks", *IEEE Journal on Selected Areas in Communications*, 37(6):1277–1290, 2019.
15. S. S. Ponde, S. S. Lomte, "Optimizing MAC Layer Performance based on Machine learning with Localized AI", *International Journal of Scientific & Engineering Research*, Vol. 9, Issue 5, May-2018.
16. N. Zuriatunadhirah binti Zubir, A. F. Ramli and H. Basarudin, "Optimization of wireless sensor networks MAC protocols using machine learning; a survey," *International Conference on Engineering Technology and Technopreneurship (ICE2T)*, Kuala Lumpur, 2017.
17. Imen Bouazzi, Jamila Bhar, Mohamed Atri, "Priority-based queuing and transmission rate management using a fuzzy" *ICT Express*, vol. 3, no. 2, pp. 101-105, 2017.
18. Mario Collotta, Arcangelo Lo Cascio, Giovanni Pau and Gianfranco Scat'a, "A Fuzzy Controller to improve CSMA/CA performance in IEEE 802.15.4", *IEEE*, Cagliari, Italy, 2013.
19. R. Kulkarni and G. Venayagamoorthy, "Neural network based secure media access control protocol for wireless sensor networks", *International Joint Conference on Neural Networks*, 2009.
20. G. A. Shah, V. C. Gungor, and O. B. Akan, "A cross-layer design for QoS support in cognitive radio sensor networks for smart grid applications," in 2012 IEEE International Conference on Communications (ICC), 2012, pp. 1378-1382.
21. [86] G. A. Shah, V. C. Gungor, and O. B. Akan, "A cross-layer QoS-aware communication framework in cognitive radio sensor networks for smart grid applications," *IEEE Transactions on Industrial Informatics*, vol. 9, pp. 1477-1485, 2013.
22. [87] A. Aijaz, S. Ping, M. R. Akhavan, and A.-H. Aghvami, "CRB-MAC: A receiver-based MAC protocol for cognitive radio equipped smart grid sensor networks," *IEEE Sensors Journal*, vol. 14, pp. 4325-4333, 2014.

فصل ۹

مطالعه و بررسی به کارگیری AI در لایه شبکه

۹-۱- مقدمه

انتظار می‌رود که شبکه‌های داده در آینده نزدیک دارای رشد ترافیکی زیاد و معماری بسیار پیچیده‌ای باشند. شبکه‌های مدرن امروزی مانند اینترنت اشیاء و شبکه دستگاه‌های هوایی بدون سرنشین به سمت خودکار شدن پیش می‌روند. در این شبکه‌ها نیاز به تصمیم‌گیری برای بهینه‌سازی عملکرد تحت شرایط نامطمئن محیط عملکردی وجود دارد. روش‌های یادگیری ماشین و به ویژه یادگیری تقویتی قادر به توانمندسازی شبکه برای بدست آوردن سیاست بهینه شامل تصمیم و عمل با حالت داده شده برای فضاهای حالت و عمل کوچک هستند. اگرچه وقتی شبکه‌ها بزرگ و پیچیده می‌گردند، آنگاه یادگیری تقویتی ممکن است قادر به پیدا نمودن سیاست بهینه در زمان منطقی نباشد. از این رو یادگیری تقویتی عمیق برای غلبه بر محدودیت‌ها توسعه یافته است و می‌تواند راهی برای بهینه‌سازی شبکه‌های پیچیده باشد. بنابراین کنترلگر شبکه قادر خواهد بود تا مسائل پیچیده و غیر محدب مانند اتصال کاربران و برای دستیابی به راه‌حلی بدون اطلاعات کامل و دقیق از شبکه را حل نماید. به کارگیری این روش امکان بدست آوردن اطلاعات محیط ارتباطی و شبکه را ایجاد می‌کند. با استفاده از این نوع یادگیری، یک کاربر می‌تواند سیاست بهینه برای انتخاب کانال و ایستگاه پایه و بارگیری اطلاعات را بکار گیرد. یادگیری تقویتی عمیق امکان تصمیم‌گیری خودکار را فراهم می‌کند و توسط این روش، شبکه قادر به نظارت و فراگیری سیاست بهینه با کمترین تبادل اطلاعات در بین کاربران است؛ بنابراین نه تنها میزان تأخیر را بهبود می‌دهد بلکه امنیت و مقاومت شبکه را نیز ارتقاء می‌بخشد. همچنین یادگیری تقویتی عمیق می‌تواند سرعت یادگیری را بخصوص در مسائل با فضای حالت و عمل بزرگ، بصورت چشمگیری بهبود دهد. بدین گونه در سیستم‌هایی با مقیاس بزرگ مانند اینترنت اشیاء با هزاران دستگاه متصل، یادگیری تقویتی عمیق عملکرد کنترل تخصیص کاربران و دستیابی به طیف و توان ارسالی را بهبود می‌بخشد.

پیچیدگی‌های موجود در شبکه‌های امروزی باعث می‌شود تا راهبردهای سنتی کنترل ترافیک شبکه (NTC1) تا حد زیادی ناکارآمد و حتی بی‌اثر شوند. با الهام از آخرین دستاوردهای هوش مصنوعی و قدرت آن برای پرداختن به مشکلات بزرگ و پیچیده، متخصصین شبکه شروع به بررسی استفاده از هوش مصنوعی در این زمینه کرده‌اند. اگرچه پژوهش‌های اولیه در این حوزه انجام شده‌است، اما به علت پراکندگی و یا محدود بودن دیدگاه، از ارائه یک دیدگاه جامع و راهکار روشمند قاصرند.

در این فصل کاربردهای روش‌های یادگیری ماشینی در شبکه‌های ارتباطی مورد مطالعه و بررسی قرار خواهند گرفت. ابتدا پس از معرفی و بررسی چالش‌ها و فرصت‌های استفاده از روش‌های هوش مصنوعی در کنترل ترافیک شبکه، به ارائه معماری و مکانیزم‌هایی پرداخته می‌شود که این امر را محقق می‌سازند. در ادامه به کاربردهای یادگیری ماشین در شبکه‌های نرم‌افزار محور خواهیم پرداخت. به کارگیری شبکه‌های عصبی در شبکه‌های ناهمگون و اینترنت اشیاء دیگر مبحثی است که مطالعه و بررسی می‌شود. در انتها نیز نحوه تخصیص منابع در شبکه و بهبود مدل‌های شبکه با استفاده از روش‌های یادگیری ماشین مورد بررسی قرار می‌گیرند.

۹-۲- به کارگیری هوش مصنوعی در کنترل ترافیک شبکه

مهندسی ترافیک در شبکه‌های ارتباطی معطوف به بهینه نمودن بهره‌وری شبکه (NUM)^۲ است که با بهینه‌سازی مسیر برای ارسال داده ترافیک و با در دسترس بودن یک مجموعه از جریان‌های داده از منبع به سمت مقصد انجام می‌شود. حل موضوعات مرتبط با NUM مرسوم معمولاً براساس مدل صورت می‌گیرند. با رشد فناوری مخابرات بی‌سیم پیچیدگی و دینامیک شبکه بیشتر شده است و همین امر، قابلیت پیش‌بینی، مدل کردن و کنترل آن را سخت‌تر کرده است. بهینه‌سازی مسیر یکی از

¹ Network Traffic Control

² Network Utility Maximization (NUM)

مسائل اصلی در مهندسی ترافیک است. با به کارگیری روش یادگیری ماشینی تقویتی عمیق، عامل DQL از طریق تعامل با محیط شبکه و از طریق کنترل کننده شبکه مسیر بهینه بین منبع به مقصد را تعیین می‌کند. عامل DQL با تطبیق پیکربندی مسیر با شرایط ترافیکی جاری موجب کاهش تأخیر شبکه می‌گردد. همچنین عامل DQL بخوبی فراگیری شده می‌تواند پیکربندی مسیر نزدیک به بهینه را در یک مرحله انجام دهد و نیز می‌تواند کنترل شبکه را بصورت زمان حقیقی صورت دهد. از آنجاییکه روش‌های مرسوم نیاز به مراحل زیادی در بهینه‌سازی پیکربندی مسیر دارند روش پیشنهادی جذاب است. با یادگیری دینامیک محیط شبکه، عامل DQL می‌تواند کاربرد شبکه را برحسب نرخ انتها به انتها و تأخیر بیشینه سازد. سه سؤال اصلی در خصوص به کارگیری AI در کنترل شبکه ایجاد می‌شوند که عبارتند از: لزوم، سودمندی و قابلیت تحقق که در ادامه به هریک خواهیم پرداخت [11].

۱-۲-۹- لزوم

قوانین قدیمی مورد استفاده در NTC بر پایه مدل سازی شبکه و برخی مفروضات ساخته شده‌اند. با ظهور ارتباطات نسل پنجم، مقیاس و پیچیدگی شبکه به میزان قابل توجهی افزایش می‌یابد و مجموعه‌ای از مشکلات را بوجود می‌آورد که با استفاده از این روش‌های قدیمی به آسانی قابل برطرف نمی‌باشند. در مقابل، روش‌های مبتنی بر هوش مصنوعی نیازی به ساخت مدل‌ها ندارند و به این ترتیب آنها را به عنوان گزینه‌های امیدبخش در استراتژی NTC مطرح می‌کنند.

۲-۲-۹- سودمندی

از یک سو، سیستم‌های NTC با توجه به درک متخصصان انسانی از عملیات و توپولوژی شبکه‌ها ابداع شده‌اند؛ حتی اگر این روش‌ها بهینه نیز باشند، ممکن است تنها در محدوده تخصص انسان‌ها و نه در دنیای فیزیکی باشند. از سوی دیگر، در روش‌های مبتنی بر قاعده، قواعد از پیش تعیین شده برای سناریوهای خاص ممکن است در رسیدن به عملکرد مطلوب تحت سناریوهای نزدیک اما متفاوت شکست بخورند [2].

در صورتیکه استراتژی‌های مبتنی بر هوش مصنوعی از تجربیات گذشته و یا محیط واقعی استفاده می‌کنند و بنابراین قابلیت بیشتری برای پیشی گرفتن از روش‌های مبتنی بر تخصص انسانی دارند و می‌توانند در صورت لزوم خود را با شرایط جدید منطبق نمایند.

۳-۲-۹- قابلیت تحقق

به کارگیری روش‌های یادگیری ماشین و یادگیری عمیق نیازمند منابع محاسباتی بسیار بالایی هستند که معمولاً از راه دور و توسط سرورهای ابری ارائه می‌شوند. با این حال، بسیاری از برنامه‌های شبکه نسبت به تأخیرهای زمانی بسیار حساس هستند و نمی‌توانند زمان انتقال اضافی را تحمل کنند. علاوه بر این، متخصصین شبکه هنوز با مشکلاتی از جمله فقدان داده‌های برچسب‌دار با پویایی بالا مواجه هستند؛ که این امر هزینه‌های هنگفتی را برای ایجاد خطاها تحمیل می‌کند [3]. خوشبختانه، انتظار می‌رود که این نگرانی‌ها به تدریج با استفاده از فن‌آوری‌هایی مانند محاسبات لبه، شبکه‌های نرم‌افزارمحور (SDN¹)، مجازی سازی توابع شبکه (NFV²) و بُرش شبکه (NS³) حل شوند. در نتیجه، AI-NTC می‌تواند به عنوان یک گزینه امکان‌پذیر مطرح شود.

¹ Software Defined Network

² Network Function Virtualization

³ Network Slicing

۳-۹- ایجاد ارتباط مابین AI و NTC

برای ایجاد ارتباط مابین AI و NTC باید توجه داشت که از یک سو از میان روش‌های موجود در AI، یادگیری تقویتی از اهمیت ویژه‌ای در میان مقالات برخوردار است؛ چراکه این روش با تعامل با محیط می‌تواند فرایند یادگیری را طی نماید (توجه نمایید مطابق آنچه در مطالب مرحله اول این پروژه بیان شد، روش‌های یادگیری تقویتی از سه بخش فضای حالت، فضای کنش‌ها و پاداش‌ها تشکیل می‌شود). از سوی دیگر برای درک موقعیت NTC در یک شبکه نیاز است تا ابتدا با مفهومی بزرگتر با نام مهندسی ترافیک (TE^1) آشنا شد. TE شامل عملکردهای اندازه‌گیری شبکه و مدیریت شبکه می‌شود. مدیریت شبکه نیز شامل NTC و کنترل پیکربندی شبکه است. ارتباط مابین این واحدها در شکل ۱۰۵ نشان داده شده است.

زیربخش "اندازه‌گیری پارامترهای شبکه (NPM^2)" مهم‌ترین جزء از بخش "اندازه‌گیری شبکه" است. NPM نیز متشکل از اجزایی با نام‌های "پارامترهای ترافیک شبکه" و "پارامترهای عملکرد شبکه" است؛ که اولی مبین سرعت عبور بسته‌ها از عناصر شبکه (NE^3) و دیگری شامل پارامترهایی نظیر تأخیر، نرخ گذردهی، بهره‌برداری از پهنای باند، نرخ اتلاف بسته‌ها و ... است. مجموعه این پارامترها فضای حالت در یادگیری تقویتی را تشکیل می‌دهند.


NTC دارای دو جنبه اهداف و تکنیک‌ها است. اهداف شامل کاهش تأخیر، بیشینه کردن بهره‌برداری، بهبود کارایی انرژی و ... می‌شود که می‌توانند پاداش‌های مورد استفاده در یادگیری تقویتی را تشکیل دهند. جنبه دوم تکنیک‌ها هستند که با پیاده‌سازی آنها می‌توان به اهداف دلخواه دست یافت. این تکنیک‌ها شامل هفت دسته: کنترل ارسال، محدودسازی نرخ، همگامی بسته‌ها، متعادل‌سازی بار، اولویت‌بندی، مسیرهای چندگانه و زمانبندی هستند. هر دسته نیز می‌تواند به زیردسته‌های مختلفی [1] تقسیم شوند (شکل ۱۰۶). این روش‌ها فضای کنش‌ها در یادگیری تقویتی را ایجاد می‌کنند.

به این ترتیب و با توصیفات بیان‌شده، ارتباط روشی مابین بخش‌های عملکردی کنترل ترافیک شبکه و یادگیری تقویتی ایجاد می‌شود.


¹ Traffic Engineering

² Network Parameters Measurement

³ Network Elements



شکل ۱۰۵. ارتباط مابین اطلاعات حوزه‌های شبکه و هوش مصنوعی [1]



شکل ۱۰۶. تفکیک تکنیک‌های مورد استفاده در NTC [1]

۴-۹- نحوه به کارگیری AI-NTC

ارزیابی AI-NTC توسط شبیه‌سازی‌های کامپیوتری قادر به توصیف عملکرد آنها در یک سیستم واقعی نیست؛ چراکه با این شبیه‌سازی‌ها نمی‌توان تمام رخداد‌های به وقوع پیوسته در عمل را پوشش داد. در یک سیستم واقعی با چالش‌های مختلفی به شرح زیر روبرو خواهیم شد:

- (۱) همگرایی آموزش برای RL می‌تواند به دلیل تأخیر در پاداش بسیار آهسته صورت بگیرد. به همین دلیل تکلیف مسئولیت کنترل عملکردها قبل از پایداری RL نامشخص است.
 - (۲) روش‌های یادگیری عمیق (DL) به منابع متنابهی از پردازنده‌های موازی نیاز دارند که معمولاً توسط سرورهای از راه دور ابری^۱ پشتیبانی می‌شوند؛ ولی این دور بودن به قیمت افزایش زمان انتقال تمام می‌شود که برای بسیاری از برنامه‌های حساس به تأخیر کاربردی شبکه قابل قبول نیست. محل قرارگیری موتورهای AI چالشی است که باید پاسخ داده شود.
 - (۳) عملکرد شبکه‌ها الزاماً باید با ضریب اطمینان بسیار بالایی انجام پذیرند؛ در صورتیکه روش‌های متکی بر یادگیری ماشین مبتنی بر بهترین سعی^۲ هستند و تضمینی در کیفیت عملکرد را ارائه نمی‌دهند. اطمینان اپراتورها از سپردن کارهای حیاتی شبکه به این روش‌ها جای سؤال دارد.
- البته در برابر چالش‌های فوق، با پیشرفت‌های صورت گرفته در حوزه‌های هوش مصنوعی و شبکه، فرصتهایی نیز برای مقابله با چالش‌های فوق به وجود آمده‌اند:

- (۱) در حوزه AI روش‌های جدیدی برای آموزش‌دهی بدون نظارت (UL^۳) ایجاد شده‌اند که در شرایط فقدان داده‌های لازم برای فراگیری، می‌توانند کار کنند. در این زمینه می‌توان به یادگیری تقلیدی (IL^۴)، انتقال یادگیری (TL^۵) و شبکه مولد مجادله‌ای (GAN^۶) اشاره کرد که ایده اصلی در آنها به ترتیب یادگیری از طریق ارائه، یادگیری از طریق انتقال دانش و ایجاد یک مجموعه از داده‌های جدید بر پایه یک مجموعه مفروض است. این روش‌های فراگیری می‌توانند باعث افزایش سرعت فرایند یادگیری و یا غنابخشیدن به مجموعه آنها شوند.
- (۲) با فراگیری محاسبات لبه، عناصر شبکه نیز به مرور ارتقاء و بروزرسانی خواهند شد و امید می‌رود که سخت‌افزار آنها نیز مجهز به پردازنده‌های گرافیکی (GPU) و سایر منابع محاسباتی پیشرفته بشوند؛ و به این ترتیب زمینه برای پیاده‌سازی هرچه بهتر روش‌های DL مهیا خواهد شد.
- (۳) با مطرح شدن SDN, NFV و NS در شبکه‌های جدید، فرصت‌های زیادی برای فعال‌سازی AI-NTC پدیدار می‌شود. از یک سو NFV و NS می‌توانند یک بلوک از منابع سخت‌افزاری عناصر شبکه واقع در لبه را برای استفاده در AI مجازی‌سازی نمایند و از سویی دیگر با استفاده از SDN، امکان پایش سیستم در زمان واقعی فراهم می‌آید تا در صورت لزوم، عملکرد NE ها تغییر داده شوند.

¹ Remote cloud servers

² Best Effort

³ Unsupervised Learning


⁴ Imitation learning

⁵ Transfer learning

⁶ Generative adversarial network

۵-۹- ارائه یک معماری جهت پیاده‌سازی AI-NTC

با توجه به فرصت‌های ایجاد شده (و بیان شده در بخش قبلی)، در [1] یک معماری جهت پیاده‌سازی AI-NTC به صورت حلقه-بسته در شکل ۱۰۷ ارائه شده است. مکانیزم عملکرد در دو بخش انجام می‌شود: پیش‌فراگیری آفلاین و اجرای برخط. در فاز پیش‌یادگیری به یک شبیه‌ساز نیاز هست تا طراحان سیستم بتوانند ساختارهای مختلف DRL را ارزیابی کنند. البته این شبیه‌ساز برای فراگیری مورد استفاده قرار نمی‌گیرد؛ فاز یادگیری به صورت برخط و بدون مداخله انسانی صورت می‌گیرد. GAN نیز برای توسعه مجموعه داده‌های موجود مورد استفاده قرار می‌گیرد تا فرایند فراگیری برخط را تسهیل کند. در مرحله اجرای برخط، ابتدا تمامی NE ها با روش‌های متعارف NTC و با دستورات کنترلرهای SDN بارگزاری می‌شوند. به این ترتیب شبکه می‌تواند عملکرد نرمال خود را داشته باشد و به این ترتیب چالش شماره ۱ (در بخش قبل) مرتفع می‌شود. سپس با استفاده از NFV و NS، NE های مجهز به منابع پر قدرت، مدل‌های از پیش آموزش داده شده را فعال می‌کنند که این امر در راستای برطرف کردن چالش ۲ است. پس از این، عامل مجازی با استفاده از IL قادر به یادگیری استراتژی کنترل قدیمی خواهد بود. پس از طی مدتی از فرایند یادگیری و با رسیدن عامل‌ها به یک حد آستانه از عملکرد، آنها کنترلر SDN را آگاه می‌کنند تا کارکردهای NTC را بر عهده بگیرند و به این ترتیب تعامل برخط با محیط و در شرایط واقعی برقرار می‌شود. پس از این مرحله، DRL مورد استفاده قرار خواهد گرفت و انتظار می‌رود که عملکرد بهتری نسبت به روش‌های قدیمی را ارائه نماید. با تمام این احوال، اگر کنترلر SDN تنزل عملکردی را مشاهده نماید، به NE های آسیب‌پذیر فرمان می‌دهد تا از اجرای DRL دست بکشند و روش‌های قدیمی خود را اجرا نمایند. این NE ها دوباره به فاز یادگیری برمی‌گردند تا دوباره بتوانند به عملکرد برخط برگردند. با این مکانیزم حفاظتی، چالش شماره ۳ در خصوص ضریب اطمینان عملکرد نیز مرتفع می‌شود.



شکل ۱۰۷. معماری پیشنهادی برای پیاده‌سازی AI-NTC [1]

۹-۶- یادگیری ماشینی در کنترل ترافیک شبکه‌های نرم‌افزار محور

در شبکه‌های SDN کنترل ترافیک بصورت متمرکز صورت می‌گیرد. انجام کنترل ترافیک بسیار مهم و برای بهینه‌سازی کیفیت تجربه (QoE^1) چالش‌برانگیز است. مدل کردن و کنترل ترافیک بدلیل آنکه روش‌ها براساس محیط عملکرد شبکه هستند، پیچیده و دینامیک می‌باشند. در این اواخر با الهام‌گیری از پیشرفت‌های اخیر هوش مصنوعی، مکانیزم کنترل ترافیک چندرسانه‌ای با بهره‌گیری از یادگیری تقویتی عمیق (DRL)^۲ صورت پذیرفته است [4]. نتایج حاکی از آن است که مکانیزم مطرح شده، توانایی کنترل ترافیک چندرسانه‌ای بطور مستقیم از تجربه و بدون ارجاع به مدل ریاضی را دارد.

ترافیک چندرسانه‌ای که ترکیبی از صدا، تصویر و ویدئو است، بخش مهمی از شبکه آینده را تشکیل می‌دهد. ترافیک چندرسانه‌ای بدلیل وابسته بودن به چندین معیار مانند تأخیر، پهنای باند، جیتر، نرخ اتلاف و غیره، چالش‌های بزرگی را برای تأمین‌کننده‌های سرویس^۳ و مدیریت شبکه^۴ ایجاد می‌کند. مطالعه مکانیزم‌های کنترل ترافیک براساس SDN برای بهینه‌سازی

¹ Quality of Experience

² Deep Reinforcement Learning(DRL)

³ Service Providers

⁴ Network administrators

QoE ترافیک چندرسانه‌ای از اهمیت حیاتی برخوردار است و تاکنون کارهای نسبتاً اندکی برای بهینه‌سازی QoE در این شبکه‌ها انجام شده است.

کنترل ترافیک مرسوم معمولاً از طریق یک مسأله بهینه‌سازی صورت می‌گیرد. فرموله کردن یک مدل ریاضی خوب که قابل حل باشد و توانایی تطبیق با محیط را داشته باشد از اهمیت بالایی برای فراگیری راه‌حل مناسب برخوردار است؛ هرچند این نوع از کنترل ترافیک برای تطبیق سریع با تغییرات شبکه محدودیت‌هایی دارد. علاوه بر این، شبکه‌های مدرن بسیار پیچیده‌اند و مدل کردن دقیق شبکه سخت است که این باعث عملکرد نامطلوبی در بهینه‌سازی QoE در ترافیک چندرسانه‌ای می‌شود. یک الگوریتم بر مبنای هوش مصنوعی مزیت چشمگیری در حل این نوع مسائل دارد. یادگیری تقویتی عمیق توانایی یادگیری از تجربه‌های خود از تعامل با محیط برای دست یابی به استراتژی موفقیت‌آمیز که منجر به پاداش‌های بزرگ بلند مدت می‌گردد را داراست. برای ترافیک چندرسانه‌ای، گارانتی QoE یکی از مسائل بسیار مهم در مقایسه با ترافیک دیگر است. چندین معیار بر مقدار QoE بصورت مستقیم تأثیر می‌گذارند. تحقیقاتی اندکی وجود دارند که راه‌حل‌های مبنی بر DRL را برای بهینه‌سازی QoE را در شبکه‌ها در نظر گرفته‌اند [4]. در مقایسه با شبکه Q عمیق (DQN)^۱ که یک روش مبتنی بر DRL است، روش گرادیان قطعی عمیق^۲ (DDPG) مزیت توانایی حل مسائل کنترلی دینامیک و پیوسته را دارد. از آنجاییکه DDPG سرعت همگرایی را در مقایسه با روش‌های مرسوم بهبود می‌دهد، این روش برای حل مسائل کنترل ترافیک انتخاب شده است.

SDN با تخصیص دینامیک منابع شبکه توانایی کنترل QoE ترافیک را دارد. SDN از بخش‌های مختلفی مانند کنترل‌کننده ترافیک^۳، شبکه مجهز به SDN^۴، مشتری^۵ و تامین‌کننده‌های چندرسانه‌ای^۶ تشکیل شده است. کنترل‌کننده ترافیک مسئولیت تخصیص مسیر و پهنای باند و برقراری مسیر را برعهده دارد. شبکه مجهز به SDN شامل یک مجموعه از دستگاه‌های مبتنی بر SDN است. با SDN می‌توان از چندین مسیر برای ارسال ترافیک در یک سرویس چندرسانه‌ای استفاده نمود. مشتری یک ناظر است که یک عکس‌العمل به عنوان بازخورد در سرویس‌های چندرسانه‌ای را انجام می‌دهد. سرویس‌دهنده چندرسانه‌ای مسئول سرویس‌های چندرسانه‌ای مختلف که در شبکه ارسال می‌شوند است. معیارهای مختلف در کنترل ترافیک به ترتیب QoE، تعادل بار^۷، عدالت^۸، گزردهی و تأخیر هستند.

روش‌های کنترل ترافیک به دو دسته اصلی طبقه‌بندی می‌گردند: کنترل استاتیک و کنترل دینامیک. مسیریابی چندمسیره با هزینه یکسان استاتیک^۹ و کنترل ترافیک براساس ذخیره^{۱۰} دو روش معروف کنترل ترافیک استاتیک هستند. روش‌های دینامیک دارای ضوابط گوناگونی هستند و توانایی کنترل دینامیک جریان‌ها را با مشاهده وضعیت شبکه و جریان‌های داده را دارند. پیشینه-سازی بهره‌برداری شبکه^{۱۱} یکی از روش‌های کنترل ترافیک دینامیک با هدف پیشینه‌سازی بهره‌برداری شبکه یعنی عدالت و گزردهی است. کنترل ترافیک مبتنی بر هوش مصنوعی روش برنامه‌ریزی هوشمند و مبتنی بر یادگیری را تأمین می‌کند. برخلاف تکنیک‌های بهینه‌سازی مبتنی بر مدل کنترل دینامیک، کنترل ترافیک مبتنی بر هوش مصنوعی می‌تواند کنترل شبکه را توسط تجربه‌اش و به جای مدل ریاضی صورت دهد. مشخص است که روش‌های استاتیک و روش‌های دینامیک بهینه‌سازی براساس مدل به یک یا دو معیار برای ساخت مدل کنترل ترافیک نیاز دارند. همچنین این روش‌ها در حمایت از بهینه‌سازی QoE ناموفق

¹ Deep Q-Network(DQN)

² Deep Deterministic Policy Gradient(DDPG)

³ Traffic Dispatcher(Controller)

⁴ SDN-Enabled Network

⁵ Clients(Customers)

⁶ Multimedia Providers

⁷ Load balance

⁸ Fairness

⁹ Static Equal-cost Multi-path(SECMP)

¹⁰ Reservation-based control traffic

¹¹ Network Utility Maximization(NUM)

بوده‌اند؛ زیرا کنترل ترافیک برای ایجاد رضایت زمان-حقیقی^۱ کاربران دشوار است. روش‌های استاتیک برای ترافیک دینامیک طراحی نشده‌اند و از همین رو آنها از نظر ماتریس ترافیک غیرقابل پیش‌بینی^۲ (UTM)، آمیزه‌ای از جریان‌های متفاوت با نیازمندی مختلف^۳ (MVR) و ترافیک انفجاری^۴ (TB) دارای محدودیت هستند. روش‌های دینامیک بهینه‌سازی مدل محور وابسته به داشتن مدل‌های دقیق و قابل حل از نظر ریاضی هستند که کاربرد آنها را در شبکه‌های مبتنی بر MVR، UTM و TB محدود می‌کند. از آنجاییکه در روش‌های دینامیک مبتنی بر هوش مصنوعی کنترل ترافیک بدون مدل انجام می‌گیرد، آنها توانایی تعامل با شبکه‌های پیچیده با رفتار غیرقابل پیش‌بینی و الگوهای مختلط ترافیک را دارند.

۱-۶-۹- استفاده از DRL در شبکه نرم‌افزار محور

در این بخش طراحی کنترل ترافیک چندرسانه‌ای در SDN با هدف بهینه‌سازی QoE و با استفاده از DRL بیان شده است [4]. کنترل ترافیک چندرسانه‌ای یک مسأله پیوسته است؛ زیرا فضای عمل آن شامل تخصیص پهنای باند به هر جریان (که یک متغیر پیوسته است) می‌شود. همانطور که در شکل ۱۰۸ مشاهده می‌گردد در DDGP دو نوع شبکه موجود است؛ یکی شبکه اولیه و دیگری شبکه هدف. شبکه اولیه خود متشکل از دو شبکه عصبی عمیق به نام‌های شبکه بازیگر^۵ و شبکه منتقد^۶ است. در شبکه بازیگر ورودی شبکه عصبی، حالت و خروجی، عمل است. شبکه منتقد عملکرد شبکه بازیگر را تحلیل می‌کند و مقدار نقد^۷ بعنوان راهنما در بروزرسانی شبکه بازیگر مورد استفاده قرار می‌گیرد. شبکه هدف نیز مقدار هدف را برای فراگیری شبکه منتقد تولید می‌کند.

¹ Real-time

² Unpredictable traffic matrix(UTM)


³ Mix of various flow with different requirements(MVR)

⁴ Traffic burstiness(TB)

⁵ Actor Network(Actor_P)

⁶ Critic Network(Critic_P)

⁷ Critic value



شکل ۱۰۸. کنترل ترافیک چندرسانه‌ای مبتنی بر DRL (a. معماری (b. بروزرسانی شبکه اولیه با DDPG). [4]

در این شبکه حالت تغییر یافته^۱ (که از قواعد انتقال حالت پیروی می‌کند) به عنوان ورودی و مقدار هدف، خروجی است. همچنین مولفه‌های متناظری با شبکه اولیه دارد و شامل شبکه بازیگر^۲ و شبکه منتقد^۳ است. مهمترین تفاوت میان شبکه اولیه و شبکه هدف ورودی‌های این دو شبکه هستند؛ در شبکه هدف ورودی، حالت تغییر یافته است نه حالت کنونی. همچنین دارای زیر شبکه ارزیابی کننده QoE نیز هست که این شبکه برای تخمین میانگین نمره رأی^۴ (MOS) بکار می‌رود. تأخیر، جیتر، نرخ اتلاف بسته، پهنای باند تخصیص داده شده و نوع جریان به عنوان ورودی این شبکه عصبی در نظر گرفته می‌شوند؛ زیرا اینها پارامترهای مهمی هستند که بطور مستقیم بر QoE شبکه تأثیر می‌گذارند. خروجی این شبکه نیز مقدار تقریبی MOS است.

شبکه اولیه، شبکه هدف و شبکه ارزیاب QoE سه بخش مهم از DRL هستند که برای کنترل ترافیک چند رسانه‌ای بکار می‌روند. شبکه عصبی عمیق در این شبکه‌ها معرفی شده است و پارامترهای آن برحسب یادگیری بروزرسانی می‌گردند. در هر پله زمانی Actor_P و Critic_P با نمونه‌برداری از دسته کوچک^۵ از بافر بازپخش^۶ بروزرسانی می‌گردند. با بروزرسانی شبکه، کنترلر فرا می‌گیرد چگونه برای فراگیری بیشینه پاداش، عمل کند.

شبیه‌سازی‌های مختلفی برای ارزیابی عملکرد معماری مبتنی بر DRL انجام شده است. شکل ۱۰۹ مقدار میانگین نمره رای برحسب تعداد جریان برای روش‌های متفاوت کنترل ترافیک را نشان می‌دهد. توپولوژی INDIA35 برای شبیه‌سازی استفاده شده است که یک توپولوژی شبکه شناخته شده در SNDlib است. این، یک شبکه با ۳۵ گره و ۸۰ لینک با ظرفیت تصادفی تولید شده بین 15MB/s تا 25MB/s است. همانطور که مشاهده می‌گردد DRL عملکرد بهتری برحسب میانگین نمره رای نسبت به بقیه دارد. این بدان دلیل است که دو روش دیگر فقط تخصیص پهنای باند را در کنترل ترافیک در نظر گرفته‌اند. همانطور که در این شکل مشاهده می‌شود میانگین نمره رای با افزایش تعداد جریان‌ها کاهش می‌یابد؛ زیرا وقتی تعداد جریان بیشتری در

¹ Transformed state

² Actor_T


³ Critic_T

⁴ Mean Opinion Score (MOS)


⁵ Minibatch

⁶ Replay buffer

شبکه موجود باشد آنگاه پهنای باند تخصیص داده شده به هر جریان کاهش میابد و رقابت زیادی برای منابع شبکه مانند پهنای باند ایجاد می شود. همچنین عملکرد مکانیزم مطرح شده در توپولوژی‌های مختلف مانند INDIA35, GERMANY50 و TA2. GERMANY50 با ۵۰ گره و ۸۸ لینک و TA2 با ۶۵ گره و ۱۰۸ لینک آورده شده است. شکل ۱۱۰ نشان می دهد که عملکرد DRL نسبت به بیشینه کننده گذردهی در هر سه توپولوژی مطرح شده عملکرد بهتری دارد و بطور متوسط ۸ درصد بهبود حاصل شده است.



شکل ۱۰۹. عملکرد مقدار میانگین نمره رای با روش‌های مختلف در توپولوژی INDIA35. [4]




شکل ۱۱۰. عملکرد بهبود میانگین نمره رای با توپولوژی‌های مختلف [4]

۷-۹- استفاده از شبکه عصبی در شبکه‌های ناهمگون


کاربرد یادگیری عمیق در بهبود کنترل ترافیک شبکه ناهمگون به دلیل چالش‌های سخت موجود در کاراکتر ورودی و خروجی مناسب در الگو برای سیستم یادگیری عمیق بطوریکه طبیعت دینامیک شبکه ناهمگون و بزرگ را نشان دهد، در حال ظهور است. در این بخش کاراکتر درست ورودی و خروجی ترافیک شبکه ناهمگون و سیستم شبکه عصبی عمیق نظارت شده ارائه می شود. نتایج حاکی از آن است که سیستم یادگیری عمیق مطرح شده بطور چشمگیر عملکرد بسیار بهتری در مقایسه با استراتژی مسیریاب مرسوم یعنی OSPF¹ از نظر تأخیر سیگنال و گذردهی دارد [5].

¹ Open Shortest Path First (OSPF)

تکنیک‌های یادگیری عمیق از شبکه‌های عصبی برای یادگیری و تشخیص الگوها استفاده می‌کنند. با افزایش توان محاسباتی و پیشرفت‌های واحد پردازنده گرافیک، پردازش بسیار بزرگتر و عمیق‌تر شبکه عصبی تسهیل گردیده است. با توجه به پیشرفت‌های اخیر الگوریتم‌های یادگیری عمیق و پیشرفت در قدرت محاسبه، اکنون زمان مناسبی برای استفاده از این روش‌ها در کنترل ترافیک شبکه است. یک سناریو از شبکه و چالش مسیریابی در آن در شکل ۱۱۱ نشان داده شده است [6].



شکل ۱۱۱. سناریو شبکه و چالش مسیریابی [6]



شکل ۱۱۲. نحوه به کارگیری شبکه عصبی جهت انجام مسیریابی [6]

نحوه به کارگیری یک شبکه عصبی در سیستم جهت انجام مسیریابی در شکل ۱۱۲ نشان داده شده است. همانطور که مشاهده می‌گردد برای کنترل ترافیک شبکه الگو ترافیک مسیریاب‌ها به عنوان ورودی برای سیستم یادگیری عمیق در نظر گرفته می‌شود.

براساس این ورودی‌ها، سیستم یادگیری عمیق به تأمین خروجی دلخواه برای کنترل ترافیک شبکه به عنوان راه‌های مسیریابی شده^۱ می‌پردازد.

لایه ورودی از N واحد ورودی تشکیل شده است که N نشان دهنده تعداد مسیریاب‌ها در شبکه هدف است. از یک بردار به طول N به عنوان ورودی برای نمایش الگوی ترافیک مسیریاب‌ها در شبکه استفاده می‌شود؛ که عنصر i ام هر بردار نشان‌دهنده تعداد بسته‌های ورودی در مسیریاب i در طول دوره زمانی مشخص است. سیستم یادگیری عمیق در نظر گرفته شده دارای چندین لایه نهان است که هر کدام یک تبدیل غیرخطی از لایه قبلی را انجام می‌دهد. محققان از الگوریتم‌هایی برای شروع تصادفی وزن‌های شبکه عمیق و سپس از مجموعه داده برچسب‌دار برای فراگیری در یادگیری نظارت شده برای کاهش خطای فراگیری استفاده می‌کنند. در لایه خروجی از تابع فعال غیرخطی یکسان در لایه‌های نهان استفاده شده است. خروجی کنترل ترافیک شبکه یک مسیر است که مسیریاب‌های بعدی را در طول مسیر از مسیریاب ورودی به مقصد نشان می‌دهد. بر این اساس یک بردار به سائز N می‌تواند نمایشگر خروجی باشد بطوریکه هر یک از المان‌های آن مقدار دودویی دارد.

سیستم یادگیری عمیق پیشنهاد شده در کنترل ترافیک شبکه ناهمگون متشکل از سه فاز به ترتیب فاز اولیه، فاز فراگیری و فاز عمل یا اجرا است. در فاز اولیه هدف بدست آوردن داده مناسب برای فراگیری سیستم یادگیری عمیق است. یکی از راه‌ها استفاده از استراتژی مسیریابی مرسوم مانند OSPF برای شبیه‌سازی مخابره بین مسیریاب‌های متفاوت و تحت بار و شرایط متفاوت و ثبت الگوی ترافیک و راه‌های استفاده شده در فاز فراگیری است. روش دیگر استخراج اطلاعات ترافیک مرتبط از تعدادی مجموعه داده دسترس برای استفاده در طول فاز فراگیری است. در فاز فراگیری از فراگیری نظارت شده برای فراگیری سیستم یادگیری عمیق براساس داده جمع آوری شده در فاز اولیه استفاده می‌شود. فرض شده است که N ، تعداد مسیریاب در شبکه هسته و تعداد مسیریاب‌های داخلی برابر $N < l$ است.

خروجی الگوریتم فراگیری ماتریس وزن^۲ است. دوره فراگیری در هر یک از مسیریاب‌ها انجام می‌شود؛ هر مسیریاب نیاز به فراگیری چندین سیستم یادگیری عمیق مطابق با تعداد مسیریاب‌های مقصد^۳ دارد. از آنجاییکه تعداد مسیریاب‌های لبه در شبکه موردنظر برابر $N - l$ است و هر مسیریاب لبه نیاز به فراگیری $N - l - 1$ سیستم فراگیری عمیق دارد، دارای $N - l - 1$ مسیریاب لبه مقصد است. از طرفی دیگر، مسیریاب‌های داخلی نیاز به فراگیری $N - l$ سیستم یادگیری عمیق دارند زیرا به این تعداد مقصد وجود دارند. بنابراین نیاز به استفاده از الگوهای ترافیک و گره‌های مطابق بعدی در سیستم فراگیری عمیق پیشنهاد شده، هست. در دوره فراگیری داده برچسب‌دار به عنوان ورودی هر مسیریاب برای فراگیری سیستم یادگیری عمیق استفاده می‌شود. در هر مرحله، سیستم یادگیری عمیق قدیمی با تعداد $k - 1$ لایه‌های نهانی فراگرفته شده به عنوان ورودی برای k^{th} لایه نهانی است. بعد از این مرحله از الگوریتم انتشار روبه عقب برای تنظیم وزن‌های بین لایه‌ها و کمینه‌سازی تفاوت بین خروجی سیستم یادگیری عمیق با خروجی داده شده، استفاده می‌شود.

بعد از انجام فاز فراگیری یک مسیر، ماتریس WMS را به مسیریاب‌های لبه ارسال می‌کند. به عبارت دیگر، هر گره داخلی نیاز به ارسال $N - l$ ماتریس‌های وزن به همه مسیریاب‌های لبه دارد. با فرض اینکه: DL_{ij} بیانگر سیستم فراگیری عمیق در مسیریاب i و گره مقصد j باشد و همچنین WM_{ij} ماتریس وزن مربوط به DL_{ij} است. ماتریس‌های وزن برای ساخت سیستم یادگیری عمیق مطابق استفاده می‌گردد. در فاز اجرا از الگو ترافیک مسیریاب‌ها که با TPS نشان داده می‌شوند به همراه WM ‌ها به عنوان ورودی در الگوریتم اجرا استفاده می‌گردند. سپس هر مسیریاب DL_{ij} را برحسب WM_{ij} می‌سازد و مسیریاب بعدی را با استفاده از DL_{ij} و TPS پیش‌بینی می‌کند. این مرحله آنقدر تکرار می‌گردد تا مسیریاب بعدی پیش‌بینی شده مسیریاب j باشد. با ماتریس‌های وزن بدست آمده در هر مسیریاب لبه، سیستم فراگیری عمیق برای پیش‌بینی کل مسیر اجرا می‌گردد.


¹ Routing path

² Weight matrix(WM)


³ Destination router

برای نمایش عملکرد الگوریتم پیشنهاد شده یک مثال ساده در شکل ۱۱۳ نشان داده شده است. فرض شده است که مسیریاب R_k مشخص می‌گردد. بنابراین R_2 نیاز به اجرای سیستم فراگیری عمیق برای محاسبه کل مسیر نیاز دارد. در این میان R_2 ابتدا از سیستم فراگیری عمیق ($DL_{2,12}$) با $WM_{2,12}$ استفاده و گره بعدی R_6 را پیش‌بینی می‌کند. سپس با استفاده از $DL_{6,12}$ و $WM_{6,12}$ گره بعدی R_{10} پیش‌بینی می‌شود. و به همین منوال گره بعدی پیش‌بینی شده R_{11} است. بعد از اتمام این پروسه، R_2 مسیر کلی را بصورت $(R_2 R_{10} R_{11} R_{12})$ ارزیابی می‌کند. هر مسیریاب لبه می‌تواند کل مسیر به همه مسیریاب‌های لبه بعدی دیگر را پیش‌بینی کند و مسیر را به بسته مطابق آن متصل کند.

برتری سیستم یادگیری عمیق نسبت به استراتژی مسیریابی مرسوم مانند OSPF توسط شبیه‌سازی صورت گرفته است. فرض است که گره‌های داخلی بسته‌ها را فورواردها می‌کنند. همچنین فرض شده است که اندازه بسته‌های کنترل و داده هر دو برابر 1kb و پهنای باند آن برابر با 8Mb/s است (که عددی منطقی برای این ساختار مش‌بی‌سیم است). نرخ تولید بسته در شبکه برابر 16.32 Mb/s است. دوره زمانی انتقال سیگنال 0.25 میلی ثانیه فرض شده است. برای انتخاب تعداد لایه‌ها و تعداد واحدها در هر لایه نهان، ساختارهای یادگیری عمیق متفاوت با یکدیگر مقایسه شده‌اند.



شکل ۱۱۳. یک مثال ساده از ارسال بسته از مسیریاب R_2 به مسیریاب R_{12} . [6]



شکل ۱۱۴. مقایسه عملکرد روش OSPF و یادگیری عمیق پیشنهاد شده [6]

نتایج در شکل ۱۱۴-a آورده شده‌اند. تعداد ۱۲ ساختار که تعداد لایه‌های هریک بین ۴ تا ۶ متغیر است و تعداد واحدها در هر لایه نهانی در بازه ۱۴، ۱۶، ۱۸ و ۲۰ تغییر می‌کند، در نظر گرفته شده‌اند. مشاهده می‌گردد که وقتی تعداد واحدها در لایه‌های نهانی ثابت است، مقدار میانگین مربع خطا با افزایش تعداد لایه‌ها افزایش می‌یابد. این بیانگر آن است که تعداد ۴ لایه برای فراگیری داده کافی هستند. به عبارت دیگر تعداد لایه‌های بیشتر منجر به مسئله بیش برآزش^۱ در سناریوی در نظر گرفته شده می‌شود. از طرفی دیگر تغییر MSE با تغییر تعداد واحدها در لایه‌های نهانی عملکرد یکسانی با تغییر تعداد لایه‌ها ندارد. برای مثال برای سیستم یادگیری عمیق شامل ۴ لایه، MSE به مقدار کمینه می‌رسد وقتی تعداد واحدها در هر لایه نهان برابر ۱۶ و ۱۸ هست؛ که به معنی این است که این دو ساختار می‌توانند به عملکرد یکسانی دست یابند؛ اگرچه فراگیری با افزایش تعداد واحدها در لایه‌های نهان پیچیده‌تر می‌گردد. بنابراین تعداد ۴ لایه با ۱۶ واحد در هر لایه برای ارزیابی عملکرد شبکه در شکل ۱۱۴-b، c، d انتخاب شده است. همانطور که مشاهده می‌گردد ۳ معیار برای مقایسه عملکرد شبکه بین OSPF و طرح پیشنهاد شده در این شکل‌ها آورده شده است. در شکل ۱۱۴-b تأخیر سیگنال با روش OSPF مقایسه شده است. نتایج حاکی از آن است که تأخیر OSPF خیلی بیشتر از سیستم یادگیری پیشنهاد شده است. دلیل این تأخیر کمتر این است که در روش OSPF به همه مسیرهای برای به جریان در آوردن پیوسته اطلاعات مسیریابی به همسایه‌های خود نیاز دارد، اما در روش پیشنهادی فقط الگو ترافیک مسیریاب‌های لبه برای محاسبه کل مسیر با دقت ۹۵ درصد کافی است. بنابراین در روش یادگیری عمیق مطرح شده، فقط مسیریاب‌های لبه نیاز به تبادل الگو ترافیک در بین خود دارند و الگو ترافیکی مسیریاب‌های درونی در فاز اجرا تعیین می‌گردد. در شکل ۱۱۴-c گذردهی دو طرح مذکور با یکدیگر مقایسه شده‌اند. همانطور که مشاهده می‌شود نرخ بدست آمده توسط سیستم یادگیری عمیق پیشنهاد شده تقریباً نزدیک به متوسط نرخ تولید داده مسیریاب‌ها است و این به خاطر پرهیز از فشردگی و افت

¹ Over-fitting

بسته‌ها توسط مسیریاب‌های ارزیاب به مقصد و به علت سریع‌تر بودن از OSPF مرسوم است. شکل ۱۱۴-d روش‌های یادگیری عمیق را نشان می‌دهد که مسیر مناسب را به سرعت پیدا می‌کنند؛ بنابراین تأخیر متوسط در هر پرسش بطور چشمگیری کمتر از روش معیار OSPF است.

۸-۹- استفاده از شبکه‌های عصبی در اینترنت اشیاء

روند روبه‌رشد اتصال حسگرها و دستگاه‌های متصل به یکدیگر و به اینترنت و تشکیل یک شبکه عظیم اینترنت اشیاء^۱ چالش‌هایی را به همراه می‌آورد. برخی از این چالش‌ها عبارتند از: انجام تجزیه و تحلیل داده، حجم بالای محاسبات، توانایی ارسال داده‌ها، محدودیت در تأخیر آنها به انتها، حفظ حریم شخصی و امنیت. مدل‌های مخابراتی متمرکز امروزه ممکن است توانایی تأمین این اتصالات عظیم را نداشته باشند. بنابراین به یک معماری مخابراتی جدید مانند مدل‌های محاسباتی مه^۲ برای اتصال دستگاه‌های اینترنت اشیاء نیاز است. بدین ترتیب نحوه اختصاص منابع محاسباتی و توان برای همه دستگاه‌های IoT برای دستیابی به نرخ داده و تأخیر مورد نیاز یک چالش اساسی دیگری است [5].

ANN^۳ ها می‌توانند برای پاسخ‌دهی به بعضی از چالش‌های IoT بکار روند. سیستم IoT از ANN برای تحلیل هوشمند داده در استخراج الگو و ارتباط محتوی داده‌های ارسال شده توسط دستگاه‌های IoT بهره می‌برند. بطور مثال ANN ها می‌توانند برای کشف ارتباطات مهم بین داده‌ها برای بهبود فشرده‌سازی و بازیابی داده بکار روند. همچنین با استفاده از الگوریتم ANN در RL، دستگاه‌های IoT می‌توانند بصورت خود-سازمان^۴ عمل کنند و استراتژی‌های خود مانند انتخاب کانال را براساس محیط کاربران و مخابرات بی‌سیم انجام دهند. برای مثال یک دستگاه IoT می‌تواند از الگوریتم ANN در RL را برای انتخاب مناسب ترین باند فرکانسی برای مخابره براساس وضعیت شبکه استفاده کند. همچنین دستگاه‌های IoT می‌توانند از الگوریتم ANN برای مشخص‌سازی و دسته‌بندی داده‌های حسگرهای IoT بهره ببرند. یکی از اهداف مهم IoT بهبود کیفیت زندگی انسان‌ها و کاهش تعامل میان انسان و دستگاه IoT است؛ بنابراین ANN ها می‌توانند در پیش‌بینی رفتار کاربران برای تأمین اطلاعات دستگاه‌های IoT بکار روند. برای مثال، ANN ها می‌توانند زمان برگشت یک فرد به خانه را پیش‌بینی کنند و کنترل دستگاه‌های خانه را برعهده گیرند. استفاده از ANN ها در IoT ممکن است با چالش‌های بسیاری روبرو شود. در IoT هم انرژی و هم منابع محاسباتی محدود هستند. بنابراین مصالحه بین انرژی و نیاز محاسباتی فراگیری ANN و نیاز به یک الگوریتم یادگیری دقیق براساس ANN می‌تواند در نظر گرفته شود. همچنین در یک سیستم IoT داده جمع‌آوری شده می‌تواند دارای ساختار متفاوتی باشد و چندین خطا را شامل گردد. بنابراین وقتی داده در فراگیری ANN استفاده می‌شود، چگونگی دسته‌بندی داده و تعامل با خطاهای داده باید در نظر گرفته شود. در سیستم IoT، ANN ها می‌توانند از هزاران نوع داده برای پیش‌بینی و کنترل خودسازمان-دهی بهره ببرند. برای یک کارکرد مورد نظر داده جمع‌آوری شده از دستگاه‌های IoT ممکن است به آن کارکرد مربوط نباشند؛ بنابراین ANN باید داده مناسب را برای آن کارکرد انتخاب کند.

۹-۹- تقسیم منابع و زمان‌بندی

ظرفیت سیستم یکی از معیارهای مهم عملکرد در شبکه مخابرات بی‌سیم است. بهبود ظرفیت سیستم می‌تواند براساس بهینه‌سازی تقسیم منابع و زمان‌بندی میان چندین گره بی‌سیم انجام شود. زمان‌بندی کاربران مسئول برای اختصاص بلوک‌ها به

¹Internet of Things

² Fog computing models

³Artificial Neural Network

⁴Self-organizing manner

ایستگاه‌های پایه و کاربران گوشی با در نظر گرفتن شرایط کانال و نیازهای QoS^1 است. متوسط بازدهی طیفی کاربران عملکرد سیستم را مشخص می‌کند؛ به این ترتیب حالت سیستم، مشخص کننده بازدهی طیفی متوسط است [6]. مرجع [7] بر تخصیص منابع دینامیک در شبکه دسترسی رادیویی ابری² تمرکز نموده است و یک چهارچوب براساس DRL برای کمینه نمودن توان مصرفی درحالی که نیاز QoS کاربران را پاسخ می‌دهد، ارائه شده است. مدل سیستم از چندین RRH^3 تشکیل شده که به واحد باند پایه BBU^4 متصل هستند. بر طبق حالت سیستم عامل DQL در BBU تصمیم بر خاموش یا روشن کردن بعضی از RRH ها می‌گیرد و برای چگونگی تخصیص دهی و وزندهی برای شکل دهی پرتو در RRH ها تصمیم می‌گیرد و هدف کمینه نمودن توان مصرفی است. در روش ایشان یک چهارچوب تصمیم‌گیری دو مرحله‌ای برای کاهش ابعاد فضای عمل⁵ فرض شده است. در مرحله اول، عامل DQL یک مجموعه از RRH های فعال به وسیله یادگیری Q و $DNNS$ را مشخص می‌کند. در مرحله دوم BBU ها عمل تخصیص منابع برای RRH های فعال را با حل مسئله بهینه‌سازی محدب انجام می‌دهند. نتایج شبیه‌سازی نشان می‌دهد که این چهارچوب درحالی که به نیاز کاربران پاسخ می‌دهد و در برابر تغییرات زیاد شبکه مقاوم است، به یک ذخیره توان چشمگیری دست می‌یابد [7]. همچنین در [8] یک DRL چندهدفه مانند کنترل گر تخصیص منابع رادیویی برای مخابرات فضایی پیاده‌سازی شده است. نویسندگان در [9] با استفاده از DQL در ایستگاه‌های پایه، توانایی یادگیری سیاست کنترل توان بهینه را مطرح نموده‌اند. در طرح پیشنهادی ایشان کنش، انتخاب سطح توان و حالت تداخلی است که هر BS برای همسایه‌اش ایجاد می‌کند که هدف بیشینه نمودن نرخ داده ایستگاه‌های پایه است.

برش شبکه⁶ [10] و تابع مجازی شبکه⁷ [11] دو روش نوظهور برای تخصیص منابع در سیستم 5G برای تأمین سرویس‌های با هزینه معقول و با عملکرد بهتر می‌باشند. ساختار شبکه مانند حافظه، محاسبات و منابع رادیویی بطور قابل مقایسه‌ای ایستا هستند، درحالی که لایه بالایی تابع‌های شبکه مجازی⁸ بصورت دینامیک درخواست‌های برنامه‌های متغیر با زمان را تأمین می‌کنند. استراتژی برش شبکه در واقع برای تقسیم منابع شبکه به چندین لایه برش و مدیریت توسط سرویس‌های متفاوت و مستقل با حداقل مقدار تداخل است. روش زنجیری کردن تابع سرویس⁹ برای هماهنگ نمودن VNFs برای تأمین عملیات مورد نیاز و QoS است. در [12] طرح DRL برای QoS/QoE در سیستم 5G براساس SFC ارائه شده است. معیارهای معمول QoS به ترتیب پهنای باند، تأخیر و گذردهی می‌باشند.

مسائل تخصیص منابع و زمان‌بندی در خوشه‌بندی کامپیوتری و سیستم پایگاه داده مهم می‌باشند و معمولاً منجر به مسئله تصمیم‌گیری برخط براساس اطلاعات محیط می‌شود. نویسندگان در [13] راه‌حلی براساس DeepRm DRL برای مدیریت منابع در سیستم کامپیوتری و در [14] سیاست یکسانی برای مدیریت منابع در سیستم بی‌سیم پیشنهاد نمودند. DeepRm یک برنامه‌ریزی کننده خوشه چند منبع است که بهینه‌سازی اهداف مختلف مانند زمان اتمام را برعهده دارد. قابل ذکر است که موضوع تخصیص منابع در مرحله چهارم این پروژه به صورت مبسوطی مورد بررسی قرار خواهد گرفت.

¹ Quality of services

² Dynamic resource allocation in a cloud radio access network

³ Remote Radio Heads (RRHs)

⁴ Base Band Unit (BBU)

⁵ Action space

⁶ Network slicing

⁷ Network Function Virtualization (NFV)

⁸ Virtualized Network Functions(VNF)

⁹ Service Function Chaining(SFC)

۱۰-۹- به کارگیری یادگیری عمیق جهت بهبود مدل شبکه سلولی

در این بخش فرض می‌شود که یک نمونه مدل تحلیلی از شبکه موجود و قابل فراگیری است؛ ولی فاقد دقت کافی برای بهینه‌سازی سیستم است. همچنین شرایط به گونه‌ای است که طراحی یک مدل شبکه دقیق‌تر برای پیاده‌سازی بسیار دشوار و یا برای استفاده جهت بهینه‌سازی سیستم نامناسب است. مثال عملی مورد نظرمان، بهینه‌سازی بازدهی انرژی در یک شبکه سلولی غیرپواسونی^۱ است [15]؛ که بدلیل پیچیدگی تابع بهینه یک مساله بهینه‌سازی چالش‌برانگیز می‌شود. در اینجا برای حل این مساله یک روش مبتنی بر یادگیری انتقال عمیق^۲ مورد مطالعه و بررسی قرار می‌گیرد. این ایده سعی در بهره‌برداری از بهینه‌سازی مشترک روش مدل محور و روش داده‌محور را دارد؛ بدین صورت که ابتدا با استفاده از یک مدل تقریبی، شبکه مورد نظر طراحی می‌شود و سپس با استفاده از مقداری داده‌های تجربی، این طراحی اولیه بهینه‌سازی می‌شود.

ابتدا فرض می‌شود که مدل تقریبی سیستم دارای یک مدل پواسون است. بطور دقیق‌تر تنها عدم تطابق مدل در مدل‌سازی توزیع فضایی ایستگاه‌های پایه سلولی است و همه پارامترهای دیگر و فرضیات مدل بطور دقیق در نظر گرفته شده‌اند. مدل مفروض مدل پردازش نقطه‌ای پواسون است، درحالی‌که مدل نقطه‌ای دقیق (جهت ایجاد سهولت در بحث و بررسی) بصورت مدل گره‌ای مربع^۳ است. با توجه به اینکه مقدار بازدهی انرژی در شبکه سلولی پواسون به شکل فرمول بسته وجود دارد و قابل بهینه‌سازی نیز هست؛ بنابراین، یک مجموعه داده از مقادیر بهینه برای بازدهی انرژی به عنوان تابعی از پارامترهای سیستم به آسانی بدست می‌آید که برای فراگیری ANN تقریبی با یک دقت دلخواه می‌تواند به کار رود. همچنین فرض می‌کنیم که شبکه سلولی پیاده‌سازی شده مجهز به یک پلتفرم حسگر که می‌تواند داده‌های مختلفی را حس کرده و به شبکه گزارش دهد، است. این داده‌ها برای تولید مقادیری برای تنظیم ANN و تصحیح عدم تطابق مورد استفاده قرار می‌گیرند.

در ادامه، مقدار داده تجربی مورد نیاز برای آنکه روش پیشنهاد شده به عملکرد یکسانی با روش داده‌محور دست بیابد، مورد مطالعه قرار می‌گیرد. برای این منظور در مورد هر دو روش مدل محور و داده‌محور و سپس ترکیب این دو روش براساس اصل یادگیری انتقال بحث شده است [15].

۱۰-۹-۱- بهینه‌سازی با روش مدل محور

جهت بهینه‌سازی کارایی انرژی (EE)، در مرجع [17]، یک مدل ریاضی برای فرمول‌بندی مسئله در شبکه‌های پواسونی به صورت زیر ارائه داده است:

$$EE(\lambda_{BS}) = \frac{SE(\lambda_{BS})}{P_{grid}(\lambda_{BS})}$$

که در آن، SE و P_{grid} به ترتیب عبارتند از کارایی طیف^۴ و توان مصرفی در شبکه سلولی و با استفاده از روابط زیر قابل محاسبه هستند:

$$SE(\lambda_{BS}) = B_W \log_2(1 + \gamma_D) \frac{\lambda_{BS} L(\lambda_{MT}/\lambda_{BS})}{1 + \Upsilon L(\lambda_{MT}/\lambda_{BS})} \times Q(\lambda_{BS}, P_{tx}, \lambda_{MT}/\lambda_{BS})$$

و

$$P_{grid}(\lambda_{BS}) = \lambda_{BS} P_{tx} L(\lambda_{MT}/\lambda_{BS}) + \lambda_{MT} P_{circ} + \lambda_{BS} P_{idle} (1 - L(\lambda_{MT}/\lambda_{BS}))$$

¹ non-Poisson

² Deep transfer learning

³ Square grid model

⁴ Spectral Efficiency

پارامترهای مختلفی در دو عبارت ریاضی فوق وجود دارند ولی آنچه در این بخش مورد نظر ما است، چهار پارامتر به شرح زیر هستند:

(۱) I_{BS} که مبین چگالی استقرار ایستگاه‌های پایه است. (۲) P_{tx} : توان ارسالی ایستگاه‌های پایه. (۳) P_{circ} : توان مصرفی مدارات الکترونیکی داخل ایستگاه‌های پایه است. (۴) P_{idle} : توان مصرفی در حالت بیکاری ایستگاه‌های پایه است.

در اینجا مقادیر P_{idle} و P_{circ} ثابت فرض شده‌اند و هدف یافتن مقدار بهینه چگالی استقرار ایستگاه‌های پایه برای یک مقدار داده شده از توان مصرفی (P_{tx}) است. در [17] این مسئله به صورت تحلیلی مورد بررسی قرار گرفته است و ثابت شده است که برای یک توزیع پواسونی، معادلات فوق یک جواب منحصر به فرد دارد. به این ترتیب با حل این مسئله بهینه‌سازی، جفت‌های بهینه از (P_{tx}, I_{BS}^{opt}) که در آن I_{BS}^{opt} با فرمول زیر بدست می‌آید:

$$\lambda_{BS}^{(opt)} = \arg \max_{\lambda_{BS}} \{EE(\lambda_{BS})\}$$

این زوج اعداد می‌توانند برای فراگیری یک شبکه ANN مورد استفاده قرار گیرند، به این ترتیب که P_{tx} ، مقدار ورودی و I_{BS}^{opt} مقدار خروجی آن باشند.

۹-۱۰-۲- بهینه‌سازی با روش داده‌محور

بهینه‌سازی با روش داده‌محور بر این فرض متکی است که نمی‌توان به تنهایی بر مدل تحلیلی متکی بود و بازدهی انرژی نیاز به تخمین با جمع‌آوری نمونه‌های تجربی از شبکه‌های سلولی دارد [15، 16]. روابط مورد نیاز جهت تخمین مقادیر کارایی طیف و P_{grid} و با استفاده از داده‌ها در [15] ارائه شده‌اند. روش کار بر این اساس است که هر پایانه موجود در شبکه با استفاده از سطح سیگنال دریافتی به کنترلگر شبکه گزارش می‌کند و مشخص می‌شود که آیا در منطقه تحت پوشش قرار دارد یا خیر. این امر نیز به طور خاص بر اساس اندازه‌گیری مقدار نسبت سیگنال به نویز در هنگام اتصال به شبکه و یا مقدار نسبت سیگنال به تداخل در حین ارسال داده صورت می‌گیرد (که هر دو باید از یک مقدار آستانه بالاتر باشند). برحسب تعداد ترمینال موجود در هر پوشش‌دهی، ایستگاه پایه بطور یکسان طیف موجود را میان آنها تخصیص می‌دهد و داده را با یک نرخ ثابتی ارسال می‌کند. براساس اطلاعات جمع‌آوری شده توسط تمامی پایانه‌های تلفن همراه، شناسایی ایستگاه‌های پایه که حداقل یک پایانه موبایل در سلول‌های متناظر خود دارند و برای محاسبه تعداد ترمینال‌های تلفن همراه که در هر کدام از آنها برای قرار دارند، امکان‌پذیر است. بدین ترتیب بازده طیفی را می‌توان با تجمیع نرخ همه ایستگاه‌های پایه فعال و با تقسیم کردن بر سطح شبکه تحت مورد بررسی تخمین زد.

اگر متغیرهای بهینه‌سازی توان ارسالی ایستگاه‌های پایه باشند، همه مقادیر توان ارسالی باید آزموده شوند و سپس مقدار منطبق بر بازدهی انرژی بهینه ثبت گردد و به‌طور مشابه با روش بهینه‌سازی مدل‌محور، برای فراگیری یک ANN استفاده شود. با این توصیفات، مقدار داده تجربی لازم برای فراگیری ANN ممکن است قابل چشم‌پوشی نباشد که در اینصورت تأخیر بهینه‌سازی عملکرد شبکه را تحت تأثیر قرار می‌دهد.


۳-۱۰-۹- بهینه‌سازی با یادگیری انتقال شبکه‌محور^۱

یادگیری انتقال شبکه‌محور (NBTL) راه‌حلی برای غلبه بر محدودیت‌های روش‌های مدل‌محور و داده‌محور است. ایده اصلی آن این است که ابتدا فراگیری و بهینه‌سازی توسط یک ANN با استفاده از روش مدل‌محور انجام می‌شود و سپس بهبودی بیشتر آن با استفاده از داده‌های تجربی حاصل می‌گردد. پس از به دست آوردن ANN براساس مدل اولیه و پیکربندی آن با تعداد لایه‌ها، نوروها، وزن‌ها و مقادیر بایاس، با استفاده از داده‌های تجربی، شبکه ANN ثانویه بهبود یافته و مورد بهره‌برداری قرار می‌گیرد [15].


شکل ۱۱۵ و شکل ۱۱۶ نتایج عددی جهت مقایسه سه روش پیشنهادی را ارائه می‌دهند. معماری ANN روبه جلو با لایه‌های متصل بهم و تابع فعال ReLU در نظر گرفته شده است. پیکربندی در نظر گرفته شده یک ANN با سه لایه نهان به ترتیب با تعداد گره 8, 8, 2 است. براساس نتایج نشان داده شده در این اشکال مشاهده می‌شود که روش پیشنهادی براساس یادگیری انتقال روشی مناسب و دارای نتیجه‌ای بهتر از هر دو روش مدل‌محور و داده‌محور است. در خصوص نتایج ارائه شده در شکل ۱۱۶، موارد زیر لحاظ شده‌اند:

- (۱) چگالی بهینه محاسبه شده از طریق جستجوی کامل محاسبه می‌شود.
- (۲) چگالی محاسبه شده توسط یادگیری انتقال عمیق: در آن ۳۰۰۰ نمونه تجربی در مرحله دوم آموزشی مورد استفاده قرار گرفته است.
- (۳) چگالی به دست آمده بدون آموزش انتقال و انجام آموزش با استفاده از تنها ۳۰۰۰ نمونه تجربی.
- (۴) چگالی به دست آمده بدون آموزش انتقال و انجام آموزش با استفاده از تنها ۳۰,۰۰۰ نمونه مبتنی بر مدل است.

¹ Network based transfer learning optimization



شکل ۱۱۵. نمودار MSE نسبی برحسب تعداد دوره‌های فراگیری (training Epoch). [15]




شکل ۱۱۶. مقایسه روش‌های بهینه‌سازی مدل‌محور و داده‌محور (به تنهایی) و روش یادگیری انتقال عمیق [15]

۱۱-۹- بهبود مدل مصرف توان غیردقیق توسط یادگیری انتقال عمیق

در این بخش یک مساله بهینه‌سازی مشابه با آنچه در بخش قبل آمد در نظر گرفته شده است. ولی به جای تمرکز بر روی تاثیر توزیع فضایی ایستگاه‌های پایه سلولی، توجه بر مدل مصرف توان ایستگاه‌های پایه متمرکز است. فرض شده است مدل نقطه‌ای پواسون بطور کافی برای توزیع ایستگاه‌های پایه سلولی دقیق است [15]. یک مدل برای توزیع یکنواخت P_{circ} , P_{idle} در نظر گرفته شده است، درحالی‌که مدل تجربی دارای توزیع گوسی است. که مشابه بخش قبلی P_{idle} توان در حالت P_{tx} و P_{idle} توان ارسالی و P_{circ} توان مصرفی مدارات در ایستگاه پایه هستند. مساله بهینه‌سازی که به آن پراخته شده است همچنان مشخص نمودن تراکم بهینه ایستگاه‌های پایه ولی این بار تابعی از سه توان نامبرده شده است.

پیکربندی ANN با بهترین مصالحه بین پیچیدگی و عملکرد با ۵ لایه پنهان که هریک با ۸ گره تجهیز شده‌اند و از تابع فعال ReLU استفاده می‌کنند، در نظر گرفته شده است. توجه کنید که این شبکه پیچیده‌تر از شبکه بخش قبل است، چراکه اکنون به جای یک پارامتر ورودی (P_{tx})، سه پارامتر دخیل هستند. همچنین عملکرد این معماری ANN اندکی بدتر از ANN با پیچیدگی بیشتر مانند ANN با ۱۶-۳۲-۶۴-۱۲۸ گره در هر لایه پنهان است.

نتیجه عملکرد این روش در شکل ۱۱۷ آورده شده است و باز هم مشاهده می‌شود که استفاده از روش انتقال یادگیری از هر دو روش مدل محور و داده محور کارایی بهتری دارد.



شکل ۱۱۷. مقایسه روش‌های فراگیری با مدل و با داده‌های تجربی. [15]

۱۲-۹- کاربردها در صنعت برق

زیرسیستم‌های مختلفی در صنعت برق (چه در حالت سنتی و چه برای شبکه هوشمند) وجود دارند که مقدار زیادی داده تولید می‌کنند (همچون مقادیر قرائت شده از کنتورها، مقدار ولتاژ و جریان ادوات مختلف و ...) که این داده‌ها باید با توجه به معیارهای مختلفی از QoS (همچون نرخ ارسال، ضریب اطمینان، امنیت، تأخیر و ...) به قسمت‌های مختلف ارسال شوند. این ارتباطات توسط شبکه‌های مختلف ارتباطی و در مقیاس‌های مختلف جغرافیایی و عملکردی صورت می‌گیرند. انواع مختلف شبکه با نام-های HAN¹, NAN², FAN³, WAN⁴ شناخته می‌شوند. این سیستم‌ها تعداد زیادی هستند که برای سیستم‌های سنتی در صنعت برق می‌توان به موارد زیر اشاره کرد [18]:

- سیستم مدیریت انتقال (TMS⁵). شامل زیر سیستم‌های زیر:

- SCADA⁶
- EMS⁷
- WASA&C⁸
- DFR⁹
- FACTS¹⁰
- DLR¹¹

- سیستم مدیریت توزیع (DMS¹²). شامل زیر سیستم‌های زیر:

- SCADA
- DFR
- OMS¹³
- VVWC¹⁴
- MDMS¹⁵
- DOMA¹⁶

- سیستم حفاظت از راه دور (TPS¹⁷)

- تلویزیون‌های مدار بسته (CCTV¹⁸)

¹ Home Area Network

² Neighborhood Area Network

³ Field Area Network

⁴ Wide Area Network

⁵ Transmission Management System

⁶ Supervisory Control and Data Acquisition

⁷ Energy management system

⁸ Wide area situational awareness and control

⁹ Digital Fault Recorder

¹⁰ Flexible AC Transmission System

¹¹ Dynamic Line Rating

¹² Distribution Management System

¹³ Outage management system

¹⁴ Volt, VAR, WATT Control

¹⁵ Meter Data Management System

¹⁶ Distribution Operation Model and Analysis

¹⁷ Teleprotection System

¹⁸ Closed circuit television

- مخابرات نیروهای کار (MWF^1)

در شبکه‌های هوشمند نیز زیرسیستم‌های مختلفی نظیر موارد زیر مورد استفاده هستند:

- زیرساخت پیشرفته اندازه‌گیری (AMI)

- اتوماسیون توزیع (DA^2)

- تولید توزیع شده/ پراکنده (DG^3)

- ذخیره‌سازی توزیع شده / پراکنده (DS^4)

- خودروهای برقی (EV^5)

- میکروگریدها (ریز شبکه‌ها)

- شبکه‌های خانگی (HANS)

- پاسخ بار (DR^6)

- $WASA^7$

توضیح هریک از این زیرسیستم‌ها از حوزه این گزارش خارج است و به صورت مبسوط در [18] آمده است. غرض از بیان آنها در اینجا این است که گستره زیرسیستم‌ها و اینکه تمامی آنها باید به شبکه‌های ارتباطی متصل شوند روشن شود. توجه شود که پژوهش‌های گسترده‌ای در خصوص بهبود عملکرد هریک از این زیرسیستم‌ها با استفاده از روش‌های هوش مصنوعی و یادگیری ماشینی در دست اقدام است (برای مثال مقاله [19] و مراجع ذکر شده در آن) ولی در اینجا توجه ما معطوف به ارتباطات مابین این زیر سیستم‌ها و به کارگیری روش‌های هوش مصنوعی جهت ارتقاء عملکرد آنها است. نحوه ارتباطی زیرسیستم‌های مختلف در شبکه هوشمند در شکل ۱۱۸ نشان داده شده است.

¹ Mobile Work Force

² distribution automation


³ distributed generation

⁴ distributed storage

⁵ electric vehicles

⁶ demand response

⁷ wide area situational awareness



شکل ۱۱۸. نحوه ارتباطی زیرسیستم‌های مختلف در شبکه هوشمند [18]


نکته دومی که در اینجا حائز اهمیت است، این می‌باشد که بسته به بزرگی شبکه مورد نیاز، ده‌ها و حتی هزاران مسیریاب برای تبادل داده‌ها مورد استفاده هستند. در شکل ۱۱۹ معماری شبکه مخابراتی در شبکه هوشمند برق به همراه دو نوع از مسیریاب‌ها با عنوان WR^1 و CR^2 نشان داده شده‌اند.

به این ترتیب ملاحظه می‌شود که یک شبکه بسیار بزرگ ارتباطی (و متشکل از زیر شبکه‌ها) در صنعت برق مورد استفاده قرار می‌گیرد که کنترل و بهینه‌سازی عملکرد آن بسیار پیچیده خواهد بود. روش‌های هوش مصنوعی و یادگیری ماشین که در این فصل بیان شدند گزینه‌های قابل ملاحظه‌ای برای استفاده و به کارگیری در این شبکه‌ها می‌باشند.

همچنین در خصوص استفاده از شبکه‌های نرم‌افزار محور در شبکه‌های هوشمند برق، پژوهش‌های مختلفی صورت گرفته‌اند [20-22] که روش‌های ارائه‌شده در بخش ۶-۹- گزارش می‌توانند در آنها مورد استفاده قرار گیرند.

¹ WAN Router

² Cluster Router



شکل ۱۱۹. معماری شبکه مخابراتی در شبکه هوشمند برق [18]

۱۳-۹- جمع‌بندی

در این فصل کاربردهای یادگیری ماشین جهت برطرف کردن چالش‌های موجود در شبکه‌های ارتباطی مورد مطالعه و بررسی قرار گرفتند. ابتدا موضوع ترافیک شبکه و نحوه بهبود آن با روش‌های یادگیری ماشین مورد بررسی واقع شد. سپس برای بهبود رضایت کاربران بویژه در ترافیک چندرسانه‌ای یک معماری کنترل ترافیک شبکه برای شبکه‌های SDN معرفی گردید. همچنین نتایج نشان داده است که روش پیشنهاد شده می‌تواند QoE را در مقایسه با روش‌های دیگر بطور چشم‌گیری بهبود دهد. همچنین در خصوص بازنگری روش کنترل ترافیک در شبکه ناهمگون مانند کنترل مسیریابی و عملکرد بسیار خوب روش‌های یادگیری ماشینی مطالبی ارائه گردید. به کارگیری یادگیری ماشینی در خصوص شبکه‌های ارتباطی مورد استفاده در مخابرات سلولی از دیگر موضوعات مورد بررسی بود. نشان داده شده که در شرایطی که مدل‌های تحلیلی در دست نیستند و یا اینکه از دقت کافی برخوردار نیستند، چگونه می‌توان از روش‌های متکی بر داده مدل آنها را بهبود بخشید و به کارایی‌های بالایی دست یافت. همچنین پاسخ این سؤال که کدامیک از رویکردهای مدل‌محور و یا داده‌محور بر دیگری برتری دارند، تا حدی روشن شد؛ در مثال‌های مورد بررسی بیان گردید که شرایطی پیش می‌آیند که هیچکدام به تنهایی قادر به برآوردن انتظارات نیستند، بلکه باید در کنار هم ضعف‌های یکدیگر را بپوشانند. چگونگی این تزویج در دو بخش انتهایی این فصل و با کمک روش انتقال یادگیری ماشینی مورد بحث و بررسی قرار گرفت. به طور خلاصه، روش کار بر این استوار بود که ابتدا با استفاده از مدل ناقص یک شبکه عصبی آموزش داده می‌شود و سپس با استفاده از مقادیر نسبتاً اندکی از داده‌های تجربی این شبکه اولیه مورد اصلاح و پارامترهای آن تصحیح می‌شوند. نتایج بدست‌آمده مبین این بودند که عملکرد بسیار بهتری در مقایسه با استفاده روش‌های پایه به صورت تنها را می‌توان بدست آورد.

همچنین به این نکته اشاره می‌شود که شبکه‌های حسگری دارای کاربردهای بسیار وسیعی در صنایع و همینطور در صنعت برق دارند. بهینه‌سازی عملکرد آنها در بخش‌های مختلف نظیر کنترل ترافیک، مسیریابی، شبکه‌های نرم‌افزارمحور، شبکه‌های ناهمگون و همینطور نحوه استقرار اجزاء، که در این گزارش مورد مطالعه و بررسی قرار گرفتند، می‌توانند با روش‌های یادگیری ماشینی صورت گیرد که در نهایت به ارتقاء عملکرد آنها خواهند انجامید.

در انتها نیز کاربرد این روش‌ها در شبکه‌های ارتباطی مورد استفاده در صنعت برق مورد مطالعه و بررسی قرار گرفتند.

مراجع فصل ۹

1. J. Xu and K. Wu, "Living with Artificial Intelligence: A Paradigm Shift toward Future Network Traffic Control," in *IEEE Network*, vol. 32, no. 6, pp. 92-99, Nov/Dec 2018.
2. A. Valadarsky et al., "Learning to Route," *ACM Int'l. Wksp. HotNets*, 2017, pp. 185–91.
3. M. Wang et al., "Machine Learning for Networking: Workflow, Advances, and Opportunities," *IEEE Network*, 2018.
4. X. Huang, T. Yuan, G. Qiao and Y. Ren, "Deep Reinforcement Learning for Multimedia Traffic Control in Software Defined Networking," in *IEEE Network*, vol. 32, no. 6, pp. 35-41, November/December 2018.
5. M. Chen, U. Challita, W. Saad, C. Yin and M. Debbah, "Artificial Neural Networks-Based Machine Learning for Wireless Networks: A Tutorial," in *IEEE Communications Surveys & Tutorials*, vol. 21, no. 4, pp. 3039-3071, Fourthquarter 2019.
6. N. Kato et al., "The Deep Learning Vision for Heterogeneous Network Traffic Control: Proposal, Challenges, and Future Perspective," in *IEEE Wireless Communications*, vol. 24, no. 3, pp. 146-153, June 2017, doi: 10.1109/MWC.2016.1600317WC.
7. Z. Xu, Y. Wang, J. Tang, J. Wang, and M. C. Gursoy, "A deep reinforcement learning based framework for power-efficient resource allocation in cloud rans," in *IEEE ICC*, 2017, pp. 1–6.
8. T. M. Hackett, S. G. Bilén, P. V. R. Ferreira, A. M. Wyglinski, and R. C. Reinhart, "Implementation of a space communications cognitive engine," in *Cognitive Communications for Aerospace Applications Workshop (CCAA)*, 2017, pp. 1–7.
9. Y. S. Nasir and D. Guo, "Deep reinforcement learning for distributed dynamic power allocation in wireless networks," *arXiv preprint arXiv:1808.00490*, 2018.
10. X. Foukas, G. Patounas, A. Elmokashfi, and M. K. Marina, "Network slicing in 5g: Survey and challenges," *IEEE Communications Magazine*, vol. 55, no. 5, pp. 94–100, 2017
11. B. Han, V. Gopalakrishnan, L. Ji, and S. Lee, "Network function virtualization: Challenges and opportunities for innovations," *IEEE Communications Magazine*, vol. 53, no. 2, pp. 90–97, 2015.
12. X. Chen, Z. Li, Y. Zhang, R. Long, H. Yu, X. Du, and M. Guizani, "Reinforcement learning based qos/qoe-aware service function chaining in software-driven 5g slices," *arXiv preprint arXiv:1804.02099*, 2018
13. Z. Zhao, R. Li, Q. Sun, Y. Yang, X. Chen, M. Zhao, H. Zhang et al., "Deep reinforcement learning for network slicing," *arXiv preprint arXiv:1805.06591*, 2018.
14. Y. Yang, Y. Li, K. Li, S. Zhao, R. Chen, J. Wang, and S. Ci, "Decco: Deep-learning enabled coverage and capacity optimization for massive mimo systems," *IEEE Access*, to appear.

15. Alessio Zappone, Marco Di Renzo, Mérouane Debbah, Wireless Networks Design in the Era of Deep Learning: Model-Based, AI-Based, or Both?, arXiv:1902.02647, 13 Jun 2019.
16. N. C. Luong *et al.*, "Applications of Deep Reinforcement Learning in Communications and Networking: A Survey," in *IEEE Communications Surveys & Tutorials*, vol. 21, no. 4, pp. 3133-3174, Fourthquarter 2019.
17. M. Di Renzo, A. Zappone, T. T. Lam, and M. Debbah, "Systemlevel modeling and optimization of the energy efficiency in cellular networks—a stochastic geometry framework," *IEEE Transactions on Wireless Communications*, vol. 17, no. 4, pp. 2539–2556, 2018
18. Budka, Kenneth C., Deshpande, Jayant G., Thottan, Marina, "Communication Networks for Smart Grids, Making Smart Grid Real", Book, Springer, 2014
19. D. Zhang, X. Han and C. Deng, "Review on the research and practice of deep learning and reinforcement learning in smart grids," in *CSEE Journal of Power and Energy Systems*, vol. 4, no. 3, pp. 362-370, September 2018.
20. Y. Jararweh, A. Darabseh, M. Al-Ayyoub, A. Bousselham and E. Benkhelifa, "Software Defined based smart grid architecture," *2015 IEEE/ACS 12th International Conference of Computer Systems and Applications (AICCSA)*, Marrakech, 2015, pp. 1-7.
21. N. Dorsch, F. Kurtz and C. Wietfeld, "Communications in distributed smart grid control: Software-defined vs. legacy networks," *2017 IEEE Conference on Energy Internet and Energy System Integration (EI2)*, Beijing, 2017, pp. 1-6.
22. E. G. da Silva, A. S. d. Silva, J. A. Wickboldt, P. Smith, L. Z. Granville and A. Schaeffer-Filho, "A One-Class NIDS for SDN-Based SCADA Systems," *2016 IEEE 40th Annual Computer Software and Applications Conference (COMPSAC)*, Atlanta, GA, 2016, pp. 303-312.

مرحله چهارم. هوشمندسازی مدیریت شبکه ارتباطی

مقدمه مرحله چهارم

مطالب مربوط به مرحله چهارم پروژه در سه فصل ارائه شده‌اند. این گزارش نتایج حاصل از مطالعات و بررسی‌های مرتبط با هوشمندسازی مدیریت شبکه ارتباطی را در برمی‌گیرد.

فصل ۱۰ به بررسی روش‌های به‌کارگیری AI جهت تخصیص منابع در شبکه‌های ارتباطی می‌پردازد. با توجه به این‌که اینترنت اشیاء در شبکه‌های هوشمند و صنعت برق دارای کاربردهای بسیاری است، در این فصل ابتدا به ویژگی‌های اینترنت اشیاء در صنعت برق پرداخته می‌شود. سپس چالش‌های مدیریت منابع در شبکه اینترنت اشیاء مورد بررسی قرار خواهند گرفت. در ادامه مکانیسم‌های مرسوم منابع در شبکه‌های ارتباطی مورد مطالعه قرار می‌گیرند و پس از آن به کارگیری تکنیک‌های یادگیری ماشینی و یادگیری عمیق مورد بحث و بررسی قرار خواهند گرفت. در این خصوص مرور جامعی بر روش‌های تخصیص منابع مبتنی بر یادگیری ماشینی شامل: شبکه‌های ناهمگون، کنترل توان، مدیریت طیف، شکل‌دهی پرتو و ... صورت خواهد گرفت.

فصل ۱۱ به بررسی روش‌های به‌کارگیری AI جهت ارتقاء امنیت در شبکه‌های ارتباطی می‌پردازد. بخش مهمی در خصوص هوشمندسازی شبکه‌های برق‌رسانی شامل جمع‌آوری داده‌ها و انتقال اطلاعات به واحدهای کنترلی و مدیریت شبکه است تا با تجزیه و تحلیل آن‌ها، تصمیمات بهینه اتخاذ شوند. برقراری امنیت و حفاظت از محتوی و ارسال این داده‌ها اهمیت بسیار بالایی دارد. همچنین تضمین حفظ حریم خصوصی کاربران نیز از اهمیت بالایی برخوردار است. تمرکز این فصل بر استفاده از روش‌های یادگیری ماشینی برای برقراری امنیت در شبکه‌های هوشمند است. در این فصل ابتدا انواع حملات در لایه‌های مختلف شبکه مورد مطالعه و بررسی قرار می‌گیرند. سپس کاربردهای روش‌های ماشینی برای ارتقاء امنیت شبکه مورد بررسی قرار خواهند گرفت. فصل ۱۲ به بررسی برنامه‌های کاربردی هوشمند در سطح شبکه و نقش هوش مصنوعی در ارتقاء عملکرد برنامه‌ای کاربردی که بر روی تجهیزات شبکه اجرا می‌شوند، اختصاص داده شده است. محتویات این فصل این گونه است که ابتدا به چالش‌های استفاده از روش‌های هوش مصنوعی در برنامه‌های کاربردی و رویکردهایی برای مرتفع نمودن آن‌ها پرداخته خواهد شد. سپس مروری کلی بر کاربردهای متنوعی که روش‌های یادگیری ماشینی در حوزه‌های مختلفی که داشته‌اند صورت خواهد گرفت. در ادامه توجه خاصی به بخش‌های مختلف صنعت برق و به‌ویژه شبکه‌های هوشمند معطوف شده است؛ زیرسیستم‌ها و کاربردهایی که هوش مصنوعی و روش‌های یادگیری ماشینی می‌توانند داشته باشند، به‌صورت مجزا مورد مطالعه و بررسی قرار گرفته‌اند. هرکدام از این کاربردها و حوزه‌ها در شبکه هوشمند می‌توانند مستقلاً موضوع یک پژوهش مجزا باشند.

فصل ۱۰. بررسی روش‌های به کارگیری AI جهت تخصیص منابع در شبکه‌های ارتباطی

۱-۱۰- مقدمه

در مراحل قبلی پروژه بیان شد که اینترنت اشیاء و مخابرات سلولی دارای کاربردهای بسیار در کاربردهای صنعتی و همین‌طور شبکه‌های هوشمند هستند. همچنین در خصوص به‌کارگیری اینترنت اشیاء و مخابرات سلولی ملاحظات ویژه‌ای در ارتباط با مدیریت منابع مخابراتی (نظیر پهنای باند و توان مصرفی) وجود دارند که روش‌های یادگیری ماشینی می‌توانند نقش بسزایی ایفا نمایند که در این فصل به آن‌ها پرداخته خواهد شد.

در اینترنت اشیاء با شبکه‌ای ناهمگون و وسیع که از دستگاه‌های هوشمند متصل به اینترنت تشکیل شده‌اند مواجه هستیم. در این شبکه‌ها که با مقدار زیادی از داده‌های متنوع سروکار دارند، مکانیسم‌های یادگیری ماشینی و یادگیری عمیق نقش محوری را در هوشمندسازی آن‌ها ایفاء می‌کنند. از میان مزیت‌های مختلف، این روش‌ها نقش مهمی را در آدرس‌دهی چالش‌های مدیریت منابع را نیز بر عهده دارند. در این فصل مکانیسم‌های مدیریت منابع بر اساس یادگیری ماشینی و یادگیری عمیق در شبکه اینترنت اشیاء و مخابرات بی‌سیم سلولی مورد بررسی و مطالعه قرار می‌گیرند. ابتدا مروری بر ویژگی‌های اینترنت اشیاء در صنعت برق صورت خواهد گرفت. سپس چالش‌های مدیریت منابع در شبکه اینترنت اشیاء مورد بررسی قرار گرفته و مروری بر مکانیسم‌های مرسوم مدیریت منابع در شبکه اینترنت اشیاء صورت می‌گیرد. در ادامه انگیزه تحقیق بر تکنیک‌های یادگیری ماشینی و یادگیری عمیق در مدیریت منابع این شبکه‌ها آورده شده است. در بخش اصلی فصل نیز مرور جامعی بر تکنیک‌های تخصیص منابع موجود مبتنی بر یادگیری ماشینی و یادگیری عمیق در شبکه‌های ناهمگون، کنترل توان، مدیریت طیف، مدیریت بک‌هال، مدیریت کشینگ و شکل‌دهی پرتوی آنتن‌ها انجام می‌گیرد. به‌صورت کلی، مدیریت منابع باعث ارتقاء عملکرد شبکه ارتباطی شده و به‌صورت غیرمستقیم باعث ارتقاء عملکرد سیستم کاربردی و صنعتی متکی بر آن خواهد شد.

۲-۱۰- ویژگی‌های اینترنت اشیاء در صنعت برق

ویژگی‌های شبکه برق هوشمند که شامل ادوات اینترنت اشیاء صنعتی است را می‌توان به‌صورت زیر خلاصه نمود:

۱-۱۰-۲-۱- ناهمگونی

در این شبکه تعداد زیادی دستگاه‌های مختلف با قابلیت‌ها، مشخصات و پروتکل‌های مختلف با یکدیگر در ارتباط هستند. به‌طور دقیق‌تر، دستگاه‌های مختلف می‌توانند استانداردهای مختلفی برای ارتباطات و روش‌های مختلف ارتباطی (مانند سلولی و ات‌رن‌ت) و همچنین محدودیت‌های مختلف روی منابع سخت‌افزاری داشته باشند.

۲-۱۰-۲-۲- مقیاس وسیع کاربرد و حجم بالای انتقال داده

میلیاردها وسیله از طریق اینترنت به یکدیگر متصل هستند که این حجم از تبادلات فراتر از قابلیت‌های شبکه اینترنت فعلی است. استفاده از اینترنت اشیاء در مقیاس وسیع نیز چالش‌هایی را به همراه خواهد داشت. بخشی از این چالش شامل معماری شبکه، ذخیره‌سازی ادوات هوشمند، پروتکل‌های ارتباطی مؤثر، شناسایی فعال و حفاظت در مقابل حملات مخرب، استانداردسازی فناوری‌ها و رابط‌های ادوات است.

۳-۲-۱۰- اتصالات متقابل^۱

انتظار بر این است که ادوات اینترنت اشیاء به زیرساخت‌های مخابراتی و اطلاعات جهانی از هر مکان و در هر زمانی قابل اتصال باشند. این اتصال وابسته به نوع خدمات و کاربردی است که توسط ادوات IoT ارائه می‌گردد. در بعضی از مواقع این اتصال می‌تواند محلی باشد مانند حسگرها در یک خودرو هوشمند و در بعضی از مواقع نیز برد بیشتری را شامل می‌شود مانند حالتی که خانه هوشمند از طریق شبکه موبایل به زیرساخت مدیریت هوشمند متصل می‌گردد.

۴-۲-۱۰- مخابرات در فاصله نزدیک

یکی دیگر از ویژگی‌های اینترنت اشیاء، مخابرات در فاصله نزدیک بدون نیاز به کسب مجوزهای مرکزی از ایستگاه پایه است. مخابرات دستگاه به دستگاه مشخصات مخابرات نقطه به نقطه مانند مخابرات مخصوص برد کوتاه^۲ (DSRC) و فناوری‌های مشابه را تقویت می‌کند. معماری اینترنت قدیمی بیشتر تمایل به مخابرات شبکه محور دارد درحالی که اخیراً جداسازی شبکه‌ها و خدمات باعث ایجاد مخابرات دستگاه محور و محتوا محور شده که طیف خدمات‌رسانی اینترنت اشیاء را گسترش داده است.

۵-۲-۱۰- مخابرات بسیار قابل اطمینان و کم تأخیر (URLLC)^۳

این ویژگی برای کاربردهای حائز اهمیت و بلادرنگ مانند اتوماسیون فرآیند صنعتی، جراحی از راه دور، سیستم حمل‌ونقل هوشمند و غیره لازم است که در آنها تأخیر و قابلیت اطمینان هر دو جزو شرایط اصلی عملکرد می‌باشند.

۶-۲-۱۰- مخابرات کم‌توان و کم‌هزینه

اتصالات انبوه ادوات اینترنت اشیاء نیازمند مصرف توان بسیار کم و همچنین روش‌های پیاده‌سازی بسیار کم‌هزینه هستند تا عملیات شبکه با بازدهی مناسبی انجام گیرد.

۷-۲-۱۰- خودسازمان‌یافتگی و خودترمیمی

این ویژگی‌ها برای برقراری مخابرات فوری و موقت در اینترنت اشیاء شامل موارد اضطراری و وضعیت‌های بحرانی است. در چنین مواقعی اتکا بر زیرساخت‌های مخابراتی امکان‌پذیر نیست و بنابراین شبکه‌هایی که خود سازمان‌یافته و خودترمیم هستند می‌بایست مورد استفاده قرار گیرند.

¹Inter-connectivity

²Dedicated short range communication

³Ultra-Reliable and Low Latency Communication

۸-۲-۱۰- تغییرات پویا در شبکه

معمولاً شبکه اینترنت اشیاء از تعداد دستگاه‌های زیادی تشکیل شده که نیاز به مدیریت مؤثری دارند. این دستگاه‌ها رفتاری پویا دارند. برای مثال زمان خواب/ بیداری دستگاه‌ها به کاربرد آنها، زمانی که از اینترنت استفاده می‌کند و زمانی که به‌طور مستقیم ارتباط برقرار می‌کند و غیره بستگی دارد. این مشخصات نیز باید در شبکه اینترنت اشیاء در نظر گرفته شود.

۳-۱۰- تخصیص منابع در شبکه اینترنت اشیاء

تا سال ۲۰۲۰، تخمین زده می‌شود که تعداد ۴ میلیارد از افراد متصل به اینترنت و ۲۵ میلیارد دستگاه هوشمند نیز تولید ۵۰ تریلیون گیگابایت داده کرده باشند [۱ و ۲]. در این میان، شبکه مخابرات بی‌سیم اینترنت اشیاء پتانسیل زیادی برای جهان هوشمند آینده دارد. اگرچه، گسترش اینترنت اشیاء در مقیاس بزرگ چالش‌های بسیاری به همراه دارد. بعضی از این چالش‌ها شامل طراحی معماری ذخیره‌سازی و شبکه برای دستگاه‌های هوشمند، پروتکل‌های داده مخابراتی، محافظت از دستگاه‌ها و کاربردهای اینترنت اشیاء از حمله‌ها و استانداردسازی فناوری‌ها است. از آنجایی که منابع رادیویی در اینترنت اشیاء بی‌سیم محدود هستند، مدیریت منابع در شبکه‌های عملی بسیار چالش آور است؛ به‌ویژه در حالتی که تعداد کاربران و دستگاه‌های هوشمند بسیار زیاد است. عملکرد کلی شبکه بی‌سیم وابسته به چگونگی مدیریت منابع اصلی مانند شیارهای زمانی^۱ و باندهای فرکانسی و کدهای متعامد^۲ است. همچنین در خصوص مدیریت منابع چگونگی لحاظ کردن پارامترهایی نظیر تغییرات ترافیک بار و کانال بی‌سیم در طراحی شبکه به‌منظور تأمین اتصالات میان کاربران با نیاز به کیفیت سرویس متنوع مورد نظر است. توسعه کاربردهای مؤثر مبتنی بر اینترنت اشیاء نیازمند دستیابی به بازدهی طیفی بهتر و نرخ داده بالا به همراه توجه به شخصی‌سازی سرویس‌ها خواهد بود که به‌تبع آن موضوع مدیریت منابع بااهمیت می‌شود.

۴-۱۰- مشکلات مدیریت منابع در شبکه اینترنت اشیاء

در شبکه‌های IoT مشکلاتی برای مدیریت منابع و به شرح زیر وجود دارند:

۱-۴-۱۰- دسترسی تعداد زیادی از ادوات به کانال

وقتی تعداد بسیار زیادی دستگاه به‌طور هم‌زمان به اینترنت متصل می‌گردند، کانال دچار اضافه‌بار می‌شود. بنابراین، گسترش عظیم دستگاه‌های اینترنت اشیاء چالش‌های مربوط به تراکم شبکه، معماری شبکه و ذخیره‌سازی برای دستگاه‌های هوشمند و پروتکل‌های داده مخابراتی پربازده را به وجود می‌آورد. راه‌حل‌ها برای مقابله با چالش‌های تراکم در دسترسی کانال برای دستگاه‌های اینترنت اشیاء غالباً بر اساس استفاده از احتمالات اتصال و ارجحیت دادن بین کلاس‌های متفاوت است. مدیریت منابع در شبکه اینترنت اشیاء سئولی برای حمایت از ظرفیت و اتصالات عظیم و استفاده از منابع شبکه به‌صورت پربازده به در نظر گرفتن تعادل بار و تکنیک‌های مدیریت دسترسی نیاز دارد.

¹Time Slots

² Orthogonal Codes

۲-۴-۱۰- مدیریت تداخل و تخصیص توان

در شبکه اینترنت اشیاء متراکم، مسائل مرتبط با تداخل درون- و میان- سلولی بااهمیت هستند که این امر نیازمند روش‌های تخصیص توان پیچیده و تکنیک‌های مدیریت تداخل است. بسیاری از کاربردهای اینترنت اشیاء دارای طبیعتی ناهمگن و توام با تغییراتی در توپولوژی شبکه، ترافیک و مشخصات کانال هستند. بنابراین ارسال توان متغیر و متناسب با تغییرات شرایط شبکه و کانال فیزیکی بسیار چالش‌برانگیز می‌شود.

۳-۴-۱۰- تخصیص کاربر، انتخاب سلول و مدیریت واگذاری^۱

در کاربردهای سلولی اینترنت اشیاء، دستگاه‌ها برای اتصال به اینترنت باید به یک ایستگاه پایه وصل شوند. همچنین اتصالات لزوماً نباید در لینک فروسو یا فراسو متقارن باشند (دستگاه‌های اینترنت اشیاء ممکن است به ایستگاه‌های پایه متفاوتی در لینک فراسو یا فروسو متصل گردند). این اتصالات یا انتخاب سلول بر اختصاص منابع تأثیر می‌گذارد. همچنین برای دستگاه‌های متحرک اینترنت اشیاء روش‌های مدیریت منابع نیازمند در نظر گرفتن احتمالات واگذاری در سلول‌های متفاوت هستند.

۴-۴-۱۰- همزیستی هماهنگ انسان با انسان^۲ و ترافیک اینترنت اشیاء

برای همزیستی هماهنگ بین ترافیک اینترنت اشیاء موجود با اینترنت اشیاء جدید، مدیریت منابع هوشمند به‌طوری که انواع مخابره بتوانند با یکدیگر همزیستی کنند، پراهمیت است.

۵-۴-۱۰- گسترش پوشش دهی

دستگاه‌های اینترنت اشیاء برخلاف دستگاه‌های مرسوم مانند تلفن‌ها و تبلت‌های هوشمند، دستگاه‌هایی با توان کم و همین‌طور دارای توانایی محدود در ذخیره‌سازی و انجام محاسبات هستند. این امر منجر به کاهش محدوده پوشش دهی می‌گردد. بنابراین برای گسترش پوشش دهی سرویس‌های اینترنت اشیاء به راه‌حل‌های جدیدی برای مدیریت منابع نیاز است. دستگاه‌های اینترنت اشیاء از تکنیک‌های مخابره دستگاه به دستگاه و مبتنی بر رله بهره‌برداری می‌کند. روش‌های دینامیک تخصیص منابع برای چنین سناریوهای مخابراتی مورد نیاز هستند.

۶-۴-۱۰- مدیریت انرژی

بازدهی انرژی در انجام مخابره خیلی مهم است، زیرا بیشتر حسگرها در اینترنت اشیاء دارای باتری با ظرفیت و امکانات شارژی محدود هستند. طراحی تخصیص منابع انرژی پربازده و طراحی پروتکل‌های مخابراتی برای تأمین رضایت کیفیت سرویس و حمایت در محیط دینامیک شبکه ضروری است.

¹ Hand-off

² Human-to-Human (H2H)

۷-۴-۱۰- پردازش زمان حقیقی و مخابره فوق‌العاده قابل اعتماد با تأخیر کم

کاربردهای اینترنت اشیا مانند جراحی از راه دور، امنیت عمومی و سیستم حمل و نقل هوشمند به مخابره با تأخیر کم و اتصال با اطمینان بالا نیاز دارد. این موضوع برای برخی از کاربردهای حیاتی در شبکه‌های برق‌رسانی همچون ¹TPS نیز صدق می‌کند.

۸-۴-۱۰- کیفیت سرویس ناهمگون

به دلیل اینکه شبکه‌های اینترنت اشیا از دستگاه‌های ناهمگون با توانایی‌ها و مشخصات متفاوتی با نیازمندی‌های مختلف مخابراتی تشکیل شده‌اند، برای برآوردسازی نیازهایشان منابع مخابراتی باید به صورت اختصاصی برایشان فراهم آورده شود.

۵-۱۰- محدودیت‌های تکنیک‌های مرسوم در مدیریت منابع

در تکنیک‌های مرسوم تخصیص منابع، از روش‌های بهینه‌سازی مبتنی بر اطلاعات لحظه‌ای کانال و نیازمندی کیفیت سرویس کاربران استفاده می‌شود. عموماً مسائل تخصیص منابع محذب نیستند و بنابراین راه‌حل‌های به‌دست آمده از تکنیک‌های مرسوم به صورت کلی بهینه نمی‌باشند [۲]. همچنین راه‌حل‌ها ممکن است در زمان حقیقی قابل حصول نباشند که در این صورت برای پیاده‌سازی‌های عملی به راه‌حل‌های کارا نیاز خواهد بود. علاوه بر این، در بعضی از سناریوها مسائل تخصیص منابع ممکن است از نظر ریاضی به خوبی قابل تبیین نباشند که این امر باعث ناتوانایی در فرموله کردن مسائل بهینه‌سازی می‌شود. در این حالت‌ها به روش‌های جدید تخصیص منابع نیاز است. راه‌حل‌های تخصیص منابع مبتنی بر یادگیری ماشین یک راه‌حل قابل توجه در این سناریوها هستند که قابلیت انطباق با طبیعت متغیر شبکه‌های اینترنت اشیا را دارند.

۶-۱۰- دلایل به کارگیری یادگیری ماشین برای مدیریت منابع

یادگیری ماشین به عنوان یک توانایی در استخراج دانش از داده و در نتیجه استفاده از آن دانش برای تطبیق رفتار عامل یادگیری ماشین است. تکنیک‌های یادگیری ماشین در کاربردهایی مانند طبقه‌بندی و رگرسیون بکار می‌روند. دستگاه‌های اینترنت اشیا مقدار زیادی داده تولید می‌کنند و تکنیک یادگیری ماشین می‌تواند از این داده‌ها برای توسعه راه‌حل‌های خودکار برای دستگاه‌های اینترنت اشیا بهره‌برداری کند. وقتی مقدار داده در دسترس بسیار زیاد و چندبعدی است، روش‌های یادگیری ماشینی و به ویژه یادگیری عمیق می‌تواند برای استخراج مشخصه و طبقه‌بندی استفاده گردد. یکی از تکنیک‌های یادگیری ماشین، یادگیری تقویتی است که در آن پارامترهای نامشخص و رفتار سیستم در طول زمان با آزمایش و خطا و عملیات کنترل بهینه بررسی می‌گردد. در ادامه برای تشریح اهمیت و نیازهای تکنیک یادگیری ماشین در کاربردهای مختلف اینترنت اشیا بر روی مدیریت منابع در شبکه‌های سلولی اینترنت اشیا و خانه هوشمند تمرکز شده است.

۱-۶-۱۰- تخصیص منابع در شبکه‌های اینترنت اشیا سلولی

شبکه‌های اینترنت اشیا سلولی باید از نرخ داده بسیار بالا حمایت کنند و نیاز به برقراری اتصالات پیوسته برای ارائه سرویس به دستگاه‌ها و کاربران ناهمگون با کیفیت سرویس متغیر دارند. دستگاه‌های ارسال کننده باید اتصال خودکار به ایستگاه پایه و

¹ Tele Protection Systems

دسترسی به کانال‌های فرکانسی برای به دست آوردن نسبت سیگنال به تداخل قابل قبول را پشتیبانی نمایند. همچنین، تخصیص مناسب کانال و توان برای حمایت از کاربردهای مختلف اینترنت اشیاء مورد نیاز است. بدین منظور، به دست آوردن پارامترهای شبکه مانند اطلاعات کانال و مشخصات ترافیک و نیازمندی‌های کاربران به‌ویژه در سرویس‌دهی به کاربران با تحرک زیاد چالش‌برانگیز می‌شود. همچنین، تخمین زاویه ورود و زاویه خروج در مخابرات موج میلی‌متری از اهمیت بالایی برخوردار هستند. برای پاسخ‌دهی به چالش‌های فوق‌الذکر یادگیری ماشین یک راه‌حل مناسب از نظر شبکه و کاربر است. شبکه‌های اینترنت اشیاء برای دست‌یابی به پیکربندی بهینه سیستم نیاز به دسترسی به مشخصات مختلف کاربران انسانی (از لحاظ محتوا) و کاربران ماشینی دارند. دستگاه‌های هوشمند توانایی دست‌یابی خودکار به طیف موجود با کمک یادگیری و توانایی تنظیم توان برای پرهیز از تداخل برای ذخیره انرژی را به صورت تطبیقی دارند. برای این هدف، یادگیری تقویتی عمیق به همراه رگرسیون خطی مورد استفاده قرار می‌گیرد. از آنجایی که در مخابرات موج میلی‌متری مقدار اطلاعات کانال و زاویه ورود از قبل مشخص نیستند، این پارامترها می‌توانند با استفاده از تکنیک یادگیری تقویتی و یادگیری-Q تخمین زده شوند. پیش‌بینی مکان کاربران می‌تواند با استفاده از روش‌های SVM^1 و RNN^2 انجام شود و این تخمین مکان می‌تواند برای تخصیص منابع مورد استفاده قرار بگیرد [۲]. پارامترهای به هم وابسته و مختلف سیستم مانند مکان کاربران و سرعت و محیط انتشار و تداخل درون سیستم می‌تواند برای گسترش روش‌های تخصیص منابع مبتنی بر یادگیری ماشین در نظر گرفته شوند. همچنین قابل ذکر است که تکنیک‌های بهینه‌سازی توانایی استفاده از محتوا^۳ را ندارند. از این رو استفاده از این تکنیک‌ها ممکن است به کاربرد ضعیف منابع منجر شود. همچنین روش‌های تئوری بازی^۴ اغلب ناهمگونی بازیکنان^۵ و همچنین تغییرات پویا در توپولوژی شبکه و تعداد بازیکنان برای تخصیص منابع را در نظر نمی‌گیرند.

۲-۶-۱۰- یادگیری ماشینی برای مدیریت منابع در محیط خانه هوشمند

کاربردهای خانه‌های هوشمند از جمله کاربردهای محبوب اینترنت اشیاء هستند و شامل ترکیب ناهمگونی از دستگاه‌ها مانند دوربین‌های امنیتی، اسکنرهای دستی، تبلت و حسگرهای بی‌سیم می‌شوند. همه این دستگاه‌ها به‌طور تصادفی قابلیت دسترسی به منابع شبکه و نیازمند کیفیت سرویس مخصوص به خود هستند. تکنیک‌های یادگیری ماشین مانند یادگیری-Q می‌توانند به خوبی برای دسترسی تصادفی به منابع در محیط خانه هوشمند عمل کنند؛ این بدان دلیل است که روش‌های یادگیری تقویتی توانایی تطبیق پویا با تغییرات محیط شبکه را دارند. همچنین تکنیک‌های بهینه‌سازی مرسوم و نیز مکاشفه‌ای^۶ می‌توانند از نظر محاسباتی برای اجرا بر روی حسگرهای کوچک، ارزان و با محدودیت انرژی بسیار مشکل‌دار باشند. علاوه بر این، روش‌های مرسوم تئوری بازی ممکن است به دلیل ناهمگونی دستگاه‌ها و تأخیر ناشی از به‌روزرسانی و تبادل اطلاعات، مناسب نباشند.

۳-۶-۱۰- استفاده از شبکه‌های عصبی در مدیریت منابع

مهمترین دلیل استفاده محققان از شبکه عصبی عمیق، تقریب الگوریتم‌های تخصیص منابع با پیچیدگی بالا است. برای مثال در [۳۳ و ۳۴] نشان داده شده است که یک شبکه عصبی بخوبی فراگیری شده می‌تواند با عملکرد خوبی در مقایسه با روش

¹ Support Vector Machine (SVM)

² Recurrent Neural Networks (RNN)

³ Context

⁴ Game theory

⁵ Players

⁶ Heuristic

WMMSE، زمان برای تخصیص توان را کاهش دهد. همچنین برای کاهش هزینه‌های $OPEX^1$ و $CAPEX^2$ و ساده نمودن بهینه‌سازی و پیکربندی پروسه‌های شبکه، خودسازمان‌دهی^۳ شبکه به صورت گسترده مورد مطالعه قرار گرفته است. با به کارگیری تکنیک‌های یادگیری ماشین خصوصاً یادگیری تقویتی، هر ایستگاه پایه می‌تواند تخصیص توان و پیکربندی پارامترهای واگذاری^۴ را خودش بهینه سازد. کاهش تأخیر سیگنال‌دهی دلیل دیگری در استفاده از یادگیری ماشین است. وقتی یادگیری تقویتی توزیع شده استفاده شده است، هر عامل فراگیری نیاز به اطلاعات جزئی برای تصمیم‌گیری دارد که منجر به پرهیز از تأخیر سیگنال‌دهی بالا می‌گردد. از طرف دیگر، روش‌های مرسوم نیاز به تبادل اطلاعات زیاد دارند که باعث افزایش هزینه سیگنال‌دهی می‌شود. روش‌های مرسوم و مکاشفه‌ای مبتنی بر قواعد ثابت هستند و در پرهیز از نتایج نامناسب پیش آمده قبلی، ناتوان می‌باشند.

۷-۱۰- مدیریت منابع در شبکه‌های بی‌سیم

در شبکه‌های مخابرات بی‌سیم، مدیریت منابع با هدف دستیابی به استفاده بهینه از منابع فیزیکی محدود برای پاسخ‌دهی به نیاز ترافیکی متفاوت و بهبود عملکرد سیستم انجام می‌شود. روش‌های مدیریت منابع ارائه شده در محیط‌های دانشگاهی اغلب برای شبکه‌های ایستگاه و مسائل مدل شده به صورت ریاضی طراحی شده‌اند [۳ و ۴]. در صورتی که حالت‌های شبکه‌های مخابرات بی‌سیم عملاً به صورت پویا می‌باشند که این امر منجر به بازاجرای مکرر الگوریتم‌ها با پیچیدگی بالا می‌گردد. برای پاسخ‌دهی به مشکلات گفته شده تکنیک‌های یادگیری ماشین شامل یادگیری تقویتی و شبکه‌های عصبی قابل به کارگیری هستند. به‌ویژه یادگیری تقویتی می‌تواند سیاست مناسبی برای مدیریت منابع را مبتنی بر بازخورد از محیط فراگیرد و پس‌از آن برای شبکه پویا تصمیم‌گیری‌ها را سریع انجام دهد. همچنین شبکه عصبی عمیق با داشتن توانایی بالا در انجام تقریب، عملکرد بعضی از الگوریتم‌های مدیریت منابع با پیچیدگی بالا را می‌تواند تقریب بزند و عملکردی مشابه ولی با پیچیدگی خیلی کمتر را ارائه نماید. علاوه بر این شبکه‌های عصبی می‌توانند برای یادگیری محبوبیت محتوا^۵ استفاده شوند که به استفاده کامل از منابع محدود کَش و یادگیری-Q توزیع شده به هر گره توانایی تصمیم‌گیری خودکار برای تخصیص منابع می‌بخشد. در ادامه کاربردهای یادگیری ماشین در کنترل توان، مدیریت طیف، مدیریت بک‌هال، طرح شکل‌دهی پرتو، مدیریت منابع محاسباتی و مدیریت کَش توضیح داده خواهد شد.

۸-۱۰- کنترل توان مبتنی بر یادگیری ماشین

در سناریو اشتراک‌گذاری طیفی، کنترل توان مؤثر می‌تواند تداخل بین-کاربری را کاهش دهد و بنابراین موجب افزایش نرخ گذردهی سیستم گردد. در ادامه کنترل توان مبتنی بر سه روش یادگیری تقویتی، یادگیری نظارت‌شده و یادگیری انتقال ارائه و بررسی خواهند شد.

¹ Operating expense

² Capital expense

³ Self-organizing

⁴ Handover

⁵ Static

⁶ Content popularity

۸-۱۰-۱- کنترل توان با استفاده از یادگیری تقویتی

در [۴] روش هماهنگ‌سازی تداخل بین سلولی^۱ (ICIC) مبتنی بر یادگیری-Q با ایستگاه پایه پیکو^۲ (PBS) و ایستگاه پایه ماکرو^۳ (MBS) به عنوان عامل یادگیری ارائه شده است. در حالت انجام ICIC در حوزه زمان، کنش هر PBS انتخاب مقدار بایاس برای توسعه محدوده سلول و توان ارسالی در هر بلوک منبع (RB^۴) است و کنش هر MBS فقط انتخاب توان ارسالی است. حالت هر عامل با تعدادی متغیر تعیین می‌گردد به طوری که هر کدام به شرایط SINR هر کاربر مربوط است. هزینه دریافتی هر عامل با محدودیت مجموع توان‌های ارسالی و مقدار هدف SINR برای هر کاربر سرویس داده شده تعیین می‌شود. در هر مرحله از اجرای الگوریتم، ابتدا هر PBS کنشی انتخاب می‌کند که منجر به کمترین مقدار Q می‌شود و سپس MBS کنش‌اش را به همین ترتیب انتخاب می‌کند. در حالی که برای انجام ICIC در حوزه فرکانس، تنها تفاوت در تعریف کنش یادگیری-Q است. با استفاده از یادگیری Q دسته‌های پیکو و ماکرو می‌توانند به طور خودکار و با هماهنگی اندکی عملکرد سیستم را بهبود ببخشند. در مرجع [۵] از یادگیری Q برای بهینه‌سازی توان ایستگاه‌های پایه کوچک^۵ (SBS) به منظور کاهش تداخل در RB استفاده شده است. فرایند یادگیری به گونه‌ای عمل می‌کند که هر SBS نیازی به آگاهی از رفتار دیگر SBS ها نخواهد داشت و اطلاعات مورد نیازش به صورت ضمنی در مقادیر Q منعکس خواهند شد. جهت اعمال یادگیری Q، حالت هر SBS به صورت یک متغیر دودویی در نظر گرفته می‌شود که مشخص می‌کند آیا کیفیت سرویس دهی مورد نیاز برآورده شده است یا نه و کنش عبارت خواهد بود از انتخاب یکی از مقادیر سطوح توان. وقتی کیفیت سرویس مورد نیاز برآورده شد آنگاه پاداش نرخ لحظه‌ای به دست آمده است؛ و در غیر این صورت برابر صفر می‌شود. نتایج شبیه‌سازی نشان می‌دهد که یادگیری Q می‌تواند نرخ داده مورد انتظار SBS را در طولانی مدت افزایش دهد.

سناریو مهم دیگر که نیاز به کنترل توان دارد، سناریو رادیو شناختگر است. در [۶] یادگیری Q توزیع شده برای مدیریت تداخل تولید شده توسط چندین رادیو شناختگر در گیرنده کاربران اولیه و ایستگاه‌های پایه ثانویه به عنوان عامل یادگیری انجام می‌شود. مجموعه کنش ایستگاه پایه ثانویه یک مجموعه از سطوح توان که می‌تواند با تابع هزینه برای محدود نمودن تداخل در گیرنده اولیه فراگرفته شود. علاوه بر این دو روش برای مقدار Q برای محاسبه حافظه و تأخیر بیان شده است که عبارت‌اند از روش شبکه عصبی و جدول مراجعه‌ای. نتایج شبیه‌سازی حاکی از آن است که طرح ارائه شده می‌تواند به عامل اجازه فراگیری یک سری از سیاست‌های بهینه‌سازی که موجب نگه داشتن تداخل در یک محدوده دلخواه می‌شود را بدهد. در [۷] انتخاب کانال و سطح توان جفت‌های دستگاه به دستگاه^۶ (D2D) در شبکه سلولی ناهمگون به عنوان یک بازی ناهمگون هندسی در نظر گرفته شده است. برای پرهیز از تبادل زیاد اطلاعات در میان جفت‌ها با استفاده از یادگیری Q چندعامله مرسوم، یک الگوریتم یادگیری Q خودکار مبتنی بر تخمین باور جفت‌ها در مورد استراتژی بقیه جفت‌ها توسعه یافته است. در نهایت نتایج شبیه‌سازی نشان می‌دهد که طرح ارائه شده سرعت همگرایی نرخ نسبتاً بالایی دارد و می‌تواند به عملکرد نزدیک به بهینه دست یابد.

۸-۱۰-۲- کنترل توان با استفاده از یادگیری نظارت شده

با در نظر گرفتن پیچیدگی بالای الگوریتم تخصیص توان مبتنی بر روش‌های بهینه‌سازی مرسوم، در [۸، ۹] استفاده از شبکه عصبی عمیق برای توسعه الگوریتم تخصیص توان که می‌تواند به پردازش زمان حقیقی دست یابد مطرح شده است. به ویژه متفاوت

^۱ Inter-cell interference coordination (ICIC)

^۲ Pico BS (PBS)

^۳ Macro BS (MBS)

^۴ Resource Block

^۵ Small BS (SBS)

^۶ Device to device (D2D)

از روش‌های مرسوم تقریب الگوریتم‌های مرحله‌ای به‌طوری‌که هر مرحله با یک لایه از شبکه عصبی، در [۸] شبکه عصبی متراکم برای تقریب الگوریتم $WMMSE^1$ برای کنترل توان در سناریویی با چندین جفت فرستنده-گیرنده² فرامی‌گیرند. با توجه به این که در تحقیق صورت گرفته تعداد لایه‌ها، تعداد ReLUs ها و واحدهای دودویی مورد نیاز برای دستیابی به خطای تقریبی مورد تحلیل وسیعی قرار گرفته‌اند، می‌توان نتیجه گرفت که خطای تقریب تأثیر کمی بر اندازه شبکه عصبی عمیق می‌گذارد. شبیه‌سازی‌ها نشان داده‌اند که شبکه عصبی کاملاً متصل بهم فراگرفته شده می‌تواند به عملکردی مشابه ولی با زمان محاسبات بسیار کمتر در مقایسه با اجرای الگوریتم $WMMSE$ دست یابد.

همچنین در [۹] طرح کنترل توان مبتنی بر CNN^3 برای سناریویی مشابه با سناریو موجود در [۸] توسعه یافته است. بطوریکه اطلاعات بهره کانال نرمالیزه شده ورودی CNN و خروجی، بردار تخصیص توان است. مشابه با [۸] ابتدا CNN برای تقریب $WMMSE$ مرسوم برای تضمین عملکرد پایه فراگیری می‌شود؛ سپس تابع تلفات به‌عنوان تابع بازدهی طیفی و بازدهی انرژی تنظیم می‌گردد. نتایج شبیه‌سازی نشان می‌دهد که طرح ارائه شده به عملکرد تقریباً یکسان یا کمی بهتر از نظر بازدهی انرژی و بازدهی طیفی نسبت به $WMMSE$ و با سرعت محاسباتی بالاتر دست می‌یابد.

۳-۸-۱۰- کنترل توان با استفاده از یادگیری انتقال

در شبکه‌های ناهمگون وقتی فمتو سلول‌ها⁴ منابع رادیویی یکسانی را با ماکرو سل‌ها⁵ به‌صورت مشترک استفاده می‌کنند، نیاز به کنترل توان برای محدود نمودن تداخل بر روی کاربران ماکرو سل به وجود می‌آید. البته در مواجهه با یک محیط پویا، برآوردن شرط کیفیت سرویس برای کاربران ماکرو سل در طول کل زمان عملکرد، برای فمتوسل‌ها مشکل است. در [۱۰] از یادگیری Q توزیع شده برای مدیریت تداخل بین سلولی، بطوریکه فمتوسل عامل یادگیری است، با هدف بهینه‌سازی ظرفیت و با برطرف نمودن نیاز به نرخ داده کاربران ماکرو سل استفاده شده است. به دلیل تغییرات مکرر در برنامه‌ریزی RB (یعنی بلوک منبع تخصیص داده شده به هر کاربر) از یک زمان به زمان دیگر تغییر می‌کند، تأخیر لینک بک‌هال⁶ و سیاست کنترل توان فراگرفته شده توسط فمتوسل مفید نیست و می‌تواند منجر به نقض شرط نرخ داده کاربران ماکرو سل گردد. برای مقابله با این مسئله، در این مقاله پیشنهاد شده است که ایستگاه پایه ماکرو به فمتوسل درباره RB آینده اطلاع دهند که موجب بهبود انتقال دانش کنترل توان بین محیط‌های متفاوت می‌شود. بنابراین فمتوسل‌ها می‌توانند از تداخل بر کاربران ماکرو سل پرهیز کنند. نتایج شبیه‌سازی نشان می‌دهد که این طرح می‌تواند در شبکه $OFDMA^7$ کار کند و برتر از الگوریتم کنترل توان مرسوم از نظر متوسط ظرفیت سلول‌ها است.

از مراجع [۴-۷] می‌توان دریافت که یادگیری Q توزیع شده و یادگیری مبتنی بر تخمین توان بهره‌برداری و استراتژی می‌تواند به توسعه طرح خودکار^۸ کنترل توان و خودسازمان^۹ برای شبکه‌های ناهمگون و شبکه‌های رادیو شناختگر (CRNs) کمک کند. همچنین یادگیری Q می‌تواند با استفاده از یادگیری انتقال به سازگاری بهتر با محیط پویا در شبکه‌های ناهمگون منجر شود [۶].

¹ Wavelet and weighted mean square error

² Transceiver

³ Convolutional Neural Network

⁴ Femtocells

⁵ Macrocells

⁶ Backhaul

⁷ Orthogonal frequency-division multiple access

⁸ Autonomous

⁹ Self-organizing

۹-۱۰- یادگیری ماشین برای مدیریت طیف

با افزایش شدید ترافیک داده، کمبود طیف چالش بزرگی را برای مخابرات بی‌سیم ایجاد کرده است و از این‌رو مدیریت پربازده طیف برای بهبود استفاده از طیف بسیار مورد نیاز است. در این بخش به مدیریت طیف مبتنی بر یادگیری تقویتی و یادگیری نظارت‌نشده پرداخته می‌شود.

در [۱۱] مدیریت طیف در شبکه‌های بسیار متراکم مبتنی بر امواج میلی‌متری مورد بررسی قرار گرفته است و بازاستفاده فضایی-زمانی^۱ به‌عنوان یک روش برای بهبود استفاده از طیف مطرح شده است. روش ایشان این‌گونه است که مسئله مدیریت طیف را به‌عنوان یک بازی غیرمشارکتی^۲ در میان دستگاه‌ها در نظر گرفته‌اند. برای کمک به دستگاه‌ها برای دستیابی به تعادل نش^۳ (NE^۳) بدون دسترسی به اطلاعات همگانی^۴، یک الگوریتم یادگیری Q توزیع‌شده طراحی شده است که برای دستگاه‌ها فراگیری از محیط را با استفاده از پاداش‌های انفرادی آسان می‌کند. کنش و پاداش هر دستگاه به ترتیب، انتخاب کانال و ظرفیت کانال هستند. متفاوت از یادگیری Q مرسوم (که در آن مقدار Q در هر جفت حالت-کنش مشخص می‌گردد)، مقدار Q در طرح ایشان بر روی کنش تعریف می‌گردد. بر اساس تحلیل‌های فراگیرشان، نتیجه‌گیری شده است که جفت‌شدگی کمتر در عامل‌های فراگیر، باعث افزایش سرعت همگرایی می‌شود. همچنین نتایج شبیه‌سازی نشان داده است که این طرح سریع‌تر همگرا شده، پایدارتر از مدل اولیه بوده و دارای تأخیر کمتری است. در [۱۲] مسائل چندهدفه و دسترسی به طیف در شبکه‌های ناهمگون مطالعه شده است. هدف ایشان کاهش تداخل بین گروهی در فمتوسل‌ها و تداخل فمتوسل‌ها با ایستگاه‌های پایه و با در نظر گرفتن قیود مرتبط با کیفیت سرویس است. با در نظر گرفتن عدم اطلاعات کامل از کانال و ناشناخته بودن تعداد گره‌ها مسئله فرموله شده بسیار چالش‌برانگیز می‌شود. برای حل این مسائل، روش یادگیری تقویتی مبتنی بر تخمین مشترک کاربرد^۵ و استراتژی مطرح شده است که متشکل از دو سطح است. هدف در سطح اول تعیین مقدار منبع طیف در دسترس برای فمتوسل‌ها است، درحالی‌که سطح دوم مسئولیت بهینه‌سازی انتخاب منابع را دارد. دو بهره‌گیری متفاوت برای هر سطح به نام‌های مدل نمودن طیف و انتخاب طیف طراحی شده است. با استفاده از روش بیان‌شده، نرخ سلولی بالاتر به دلیل کاهش چشمگیر در تداخلات به دست می‌آید. در [۱۳] مد مخابراتی مشترک انتخاب و تخصیص زیرکانال از جفت‌های دستگاه به دستگاه با کاربرد و استراتژی تخمین به‌صورت مشترک مبتنی بر یادگیری تقویتی در سیستم دستگاه به دستگاه در C-RAN^۶ در شکل ۱، حل شده است. در طرح پیشنهادشده، عمل هر جفت دستگاه به دستگاه از یک مد مخابراتی و یک زیرکانال تشکیل شده است. بعدازآنکه هر جفت عملش را انتخاب کرده است، اتصال RRH^۷ به‌صورت توزیع‌شده و کنترل توان انجام می‌شود. سپس هر جفت بازدهی طیفی سیستم را به‌عنوان کاربرد آبی دریافت می‌کند و مبتنی بر آن، تخمین کاربرد برای هر عمل بروزرسانی می‌شود. نتایج شبیه‌سازی نشان می‌دهد، که عملکرد نزدیک به بهینه با استفاده از تنظیمات درست پارامترهای کنترل‌کننده تعادل بین اکتشاف^۸ و بهره‌گیری^۹ به دست می‌آید.

¹Temporal-spatial

²Non-cooperative

³Nash equilibrium

⁴Global


⁵Utility

⁶Cloud Radio Access Network

⁷Remote Radio Head

⁸Exploration

⁹Exploitation



شکل ۱۲۰. لینک فراسو در سیستم دستگاه به دستگاه و سناریو C-RAN [۲۴]

علاوه بر فراگرفتن روش‌های یادگیری تقویتی کلاسیک، روش جدید یادگیری تقویتی شامل شبکه عصبی بازگشتی در [۱۴] برای مدیریت هر دو باندهای فرکانسی مجوزدار و بدون مجوز در سیستم‌های LTE-U استفاده شده است. خصوصاً، مسئله به صورت یک بازی غیرتعاونی بین ایستگاه‌های پایه کوچک و ایستگاه پایه ماکرو فرموله شده است. حل این بازی چالش‌انگیز است، زیرا هر ایستگاه پایه کوچک ممکن است اطلاعات کمی درباره شبکه، خصوصاً در سناریوهای متراکم، داشته باشد. برای دستیابی به استراتژی ترکیبی یک یادگیری تقویتی چندعامله مبتنی بر (ESN^1) پیشنهاد شده است، که به راحتی می‌تواند حالت شبکه را در طول زمان فرا بگیرد و دنبال کند. در مقایسه با روش یادگیری تقویتی مرسوم، روش پیشنهادی می‌تواند به سرعت تخصیص منابع را با مقدار کمی داده انجام دهد. در طول اجرای الگوریتم هر ایستگاه پایه نیاز به پخش اطلاعات عمل انجام گرفته و عمل بهینه دارد. نتایج شبیه‌سازی حاکی از آن است که نرخ مجموع برای ۵۰ درصد از کاربران به اندازه ۱۶۷ درصد در مقایسه با یادگیری Q بهبود یافته است.

در [۱۱] نشان داده شده است که جفت‌شدگی کمتر در عامل‌های یادگیری می‌تواند به افزایش سرعت همگرایی یادگیری تقویتی توزیع شده برای سناریو استفاده دوباره از طیف فضایی-زمانی کمک کند. در [۱۳] بازدهی طیفی نزدیک به بهینه برای سیستم D2D در C-RAN با تخمین کاربرد و استراتژی مبتنی بر یادگیری تقویتی دست می‌یابد، اگر پارامترهای تعادل استخراج و بهره‌برداری در طول زمان بیشتری شود. مرجع [۱۴] نشان می‌دهد وقتی هر ایستگاه پایه اجازه مدیریت منبع طیفی دارد، شبکه عصبی بازگشتی می‌تواند در هر ایستگاه پایه برای پیش‌بینی کاربرد استفاده شود؛ که به سیستم جهت تخصیص منابع پایدار کمک می‌کند.

۱۰-۱۰- استفاده از یادگیری ماشین در مدیریت بک‌هال

در شبکه‌های مخابرات بی‌سیم، علاوه بر مدیریت منابع مانند طیف و توان، مدیریت لینک بک‌هال متصل‌کننده ایستگاه‌های پایه ماکرو به ایستگاه پایه کوچک و متصل‌کننده ایستگاه‌های پایه کوچک به هسته شبکه برای دستیابی به عملکرد بهتر سیستم ضروری است. در ادامه این بخش مدیریت بک‌هال مبتنی بر یادگیری عمیق مورد مطالعه و بررسی قرار می‌گیرد.

¹ Eco State Network

در [۱۵] روش توسعه محدوده سلول^۱ (CRE) مبتنی بر یادگیری تقویتی پیشنهاد شده است. در این روش، حالت مشاهده شده برای ظرفیت هر سلول کوچک به عنوان مقدار نشان دهنده نقص ظرفیت بکهال، تعیین شده است، عمل مورد نیاز برای انجام مقدار بایاس CRE از یک سلول با در نظر گرفتن اینکه آیا بکهال در دسترس است یا نه انجام می شود. تعریف هزینه برای هر سلول کوچک، بیشینه سازی کاربرد ظرفیت کل بکهال با برقرار نگه داشتن شرط ظرفیت بکهال هر سلول است. یادگیری Q برای کاهش هزینه از طریق پردازش مرحله ای فراگرفته شده است، و نتایج شبیه سازی حاکی از آن است که طرح پیشنهادی تراکم بکهال را در سلول ماکرو و کیفیت سرویس کاربران را بهبود می دهد. در مرجع [۱۶]، تمرکز بر متعادل سازی بار برای بهبود استفاده از منابع بکهال توسط مقدار بایاس سیستم یادگیری از طریق الگوریتم یادگیری Q توزیع شده است. کاربرد بکهال به چندین سطح به عنوان حالت محیط که مبتنی بر آن هر ایستگاه پایه کوچک عملش را مشخص می کند که همان مقدار بایاس است. سپس، با تابع پاداش که تفاوت وزن دار بین کاربرد منبع بکهال و احتمال خروج^۲ برای هر SBS است، به هدف دستیابی تعادل بین عملکرد کاربر محور^۳ و سیستم محور^۴ یادگیری Q برای فراگیری استراتژی انتخاب مقدار بایاس استفاده شده است. نتایج شبیه سازی نشان می دهد که این الگوریتم توانایی بهینه سازی کاربرد منابع بکهال با تضمین کردن کیفیت سرویس دهی به کاربران دارد. برخلاف مراجع [۱۶، ۱۵]، در [۱۷ و ۱۸] مدیریت بکهال از نظر تئوریازی مدل شده است. مسائل با استفاده از RL مبتنی بر تخمین مشترک کاربرد و استراتژی حل می گردند. خصوصاً، مسئله مدیریت بکهال به عنوان بازی اقلیت^۵ در [۱۷] فرموله شده است. بطوریکه، ایستگاه های پایه کوچک بازیکنان هستند و باید درحالی که به نیازهای فوری پاسخ می دهند تصمیم بگیرند که آیا فایل ها را برای پیش بینی درخواست ها دانلود کنند یا خیر. به منظور تقریب تعادل Nash مخلوط یک الگوریتم مبتنی بر RL که هر ایستگاه پایه را قادر به به روز رسانی استراتژی اش مبتنی بر فقط کاربرد دریافت شده پیشنهاد شده است. برخلاف روش قبلی، الگوریتم های RL مشابه، این طرح به طور ریاضی به نقطه تعادل برای بازی فرموله شده است. در مرجع [۱۸]، کاربران ماکرو می توانند با ایستگاه پایه ماکرو با کمک ایستگاه پایه کوچک به عنوان رله، مخابره کنند. لینک بکهال بین ایستگاه های پایه کوچک و ایستگاه پایه ماکرو ناهمگون شامل بکهال باسیم و بی سیم است. رقابت میان کاربران با بازی غیر-تعاونی^۶ مدل می گردد، بطوریکه کنش های آن ها به ترتیب انتخاب توان ارسالی، SBS کمکی و پارامترهای جداکننده نرخ^۷ است. با استفاده از روش یادگیری ماشین پیشنهاد شده، تعادل همبسته بازی به دست آمده است. علاوه بر آن نشان داده شده است که روش پیشنهادی به نرخ متوسط و تأخیر بهتری برای کاربران ماکرو نسبت به مدل پایه دست می یابد.

در [۱۵] نشان داده شده است که یادگیری Q می تواند به بهبود تراکم بکهال و کیفیت سرویس دهی کاربران با تنظیم خودکار پارامترهای CRE کمک کند. در مرجع [۱۶] وقتی تعادل بین عملکرد سیستم محور و کاربر محور برقرار گشت، بازخورد پاداش به عامل یادگیری Q می تواند تفاوت وزن دار بین آن دو تعریف شود. همان طور که در [۱۷] نشان داده شده است، یادگیری مبتنی بر تخمین مشترک کاربرد و استراتژی می تواند به تعادل میان فایل های در حال دانلود درخواست داده شده در آینده و ترافیک جاری دست یابد. بر طبق [۱۸] یادگیری تقویتی توزیع شده به کاربران در انتخاب لینک های بکهال ناهمگون برای یک شبکه ناهمگون با ایستگاه پایه کوچک به عنوان رله برای ماکرو کاربران که به نرخ و تأخیر بهبود یافته منجر می شود.

¹ Cell range extension (CRE)

² Outage

³ User-centric

⁴ System-centric

⁵ Minority game

⁶ Non-cooperative game

⁷ Rate splitting parameters

۱۱-۱- مدیریت کشینگ مبتنی بر یادگیری ماشین

به دلیل زیاد شدن دستگاه‌ها و کاربردهای هوشمند مانند شبکه‌های اجتماعی، اینترنت اشیاء، سیستم مخابرات بی سیم ترافیک زیادی را در طول دو دهه پیش تجربه کرده است. علاوه بر آن، در شبکه‌های سلولی در هر ماه از سال ۲۰۲۰ تقریباً مقدار ۳۰.۶ اگزابایت داده تولید شده است. در مواجهه با این مقدار زیاد درخواست داده، الگوی کشینگ برای کاهش تأخیر و بهبود موانع ارسال در بک‌هال معرفی شده است.

۱۱-۱-۱- روش مبتنی بر یادگیری تقویتی

با در نظر گرفتن نیاز به محتوای موقتی و فضایی متفاوت در میان سلول‌های کوچک متفاوت، در [۱۹] طرح کشینگ نامتمرکز به‌روزشده بر مبنای تخمین بهره‌برداری و استراتژی مشترک یادگیری ماشین توسعه داده شده است. علاوه بر آن، با استفاده از مجموع وزن دار استراتژی کشینگ هر ایستگاه پایه کوچک و ابر یک دادوستد بین محبوبیت سرتاسری محتوا و محبوبیت سرتاسری محلی به دست خواهد آمد. در [۲۰] همچنین بر طرح کشینگ توزیع شده تمرکز شده است. متفاوت از [۱۹] ایستگاه‌های پایه با یکدیگر همکاری می‌کنند بطوریکه هر ایستگاه پایه می‌تواند از راه بک‌هال محتوا ازدست‌رفته را از دیگر ایستگاه‌های پایه به دست آورد که می‌تواند یک راه‌حل مقرون به صرفه باشد. همچنین تخلیه^۱ D2D برای بهبود کاربرد کشینگ در نظر گرفته شده است. بنابراین برای کاهش هزینه ارسال سیستم یک الگوریتم یادگیری Q توزیع شده بکار رفته است. برای هر ایستگاه پایه قراردادن محتوا به‌عنوان حالت مشاهده شده و تنظیم محتوای کشینگ به‌عنوان یک کنش در نظر گرفته شده است. همگرایی طرح ارائه شده با استفاده از مدل بازی مرحله‌ای و پی‌درپی اثبات شده است و برتری عملکرد آن از راه شبیه‌سازی نشان داده شده است.

به جای به کارگیری روش‌های مرسوم یادگیری ماشین، در [۲۱] یک چهارچوب جدید مبتنی بر یادگیری تقویتی عمیق در یک شبکه خودروهای متصل برای هماهنگ نمودن انجام محاسبات، شبکه‌سازی و منابع کشینگ مطرح شده است. عامل DRL تصمیم می‌گیرد که کدام ایستگاه پایه به خودرو تخصیص داده شود و اینکه آیا اطلاعات درخواست شده نیازمند ذخیره‌سازی در ایستگاه پایه هست یا خیر. نتایج شبیه‌سازی نشان داده است که با استفاده از یادگیری تقویتی عمیق، سیستم عملکرد بسیار بهتری نسبت به روش‌های موجود دارد. علاوه بر آن، در [۲۲] الگوریتم به‌روزرسانی کشینگ مبتنی بر معماری خاصی از یادگیری تقویتی عمیق به نام ولپرتینگر^۲ برای هر ایستگاه پایه مورد بررسی قرار داده است. فرکانس تقاضای هر فایل در طول زمان از تصمیم در حالت ورودی و عمل مبتنی بر انجام ذخیره محتوای درخواست داده شده تشکیل شده است. طرح ارائه شده با چندین روش مرسوم ذخیره‌سازی شامل اخیراً حداقل استفاده شده^۳ و حداقل مکرراً استفاده شده^۴، مقایسه شده است و نشان داده شده است که این روش هر دو نرخ کوتاه‌مدت و بلندمدت ذخیره‌سازی را افزایش می‌دهد.

¹ Offloading

² Wolpertinger


³ Least Recently Used

⁴ Least Frequently Used

۲-۱۱-۱۰- روش مبتنی بر یادگیری نظارت‌شده

به‌منظور توسعه طرح کشینگ تطابقی، روش یادگیری ماشین^۱ ELM [۲۳] برای تخمین محبوبیت محتوا^۲ بکار رفته است. بعدازآن، از برنامه‌ریزی خطی Mixed-Integer برای محاسبه گمارش محتوا^۳ استفاده شده است. همچنین، روش تقریب آماری آشفته^۴ برای کاهش تعداد گره‌ها در ELM مطرح شده است، درحالی‌که یک سطح معین از دقت پیش‌بینی را تضمین می‌کند. با استفاده از داده‌های واقعی، نشان داده شده است که طرح ارائه‌شده می‌تواند کیفیت تجربه کاربران^۵ و عملکرد شبکه را بهبود دهد. در [۲۴] بهینه‌سازی مشترک گمارش محتوا، تخصیص کاربران و موقعیت هوایی دستگاه‌های UAV^۶ با هدف حداقل سازی توان کل ارسالی UAVs ها با قید برقراری QoE کاربران را مورد مطالعه قرار گرفته است (شکل ۲). برای حل مسئله فرموله شده برای کل دوره زمان عملکرد، پیش‌بینی توزیع درخواست محتوای کاربران ضروری است. بدین منظور، شبکه حالت اکو (ESN)^۷ که یک نوع از شبکه عصبی بازگشتی (RNN) است، بکار رفته است. ورودی شبکه ESN یک بردار شامل اطلاعات کاربر مانند جنسیت و نوع دستگاه است. درحالی‌که، خروجی یک بردار احتمالاتی درخواست محتوا کاربران است. در [۲۵] با ایده‌ای مشابه با [۲۴] بهینه‌سازی محتوای کشینگ در RRHs و BBU^۸ برای شبکه دسترسی ابر رادیویی ارائه است. ابتدا، یک الگوریتم مبتنی بر ESN برای توانمندسازی BBU برای فراگیری درخواست توزیع محتوای هر کاربر و الگوی تحرک^۹ معرفی شده است، سپس یک الگوریتم تقریباً خطی برای مشخص کردن ذخیره‌سازی محتوا بکار رفته است. همچنین ظرفیت حافظه ESN برای ورودی‌های متناوب محاسبه شده است. با استفاده از شبیه‌سازی نشان داده شده است که طرح ارائه شده ظرفیت مؤثر مجموع را به‌اندازه ۲۷.۸ و ۳۰.۷ درصد، به ترتیب نسبت به ذخیره‌سازی متناوب با گروه‌بندی و بدون گروه‌بندی بهبود می‌دهد. متفاوت از [۲۳-۲۵] که در آنها پیش‌بینی مستقیم محبوبیت محتوا با استفاده از شبکه عصبی صورت می‌گیرد، در [۲۶] یک طرح با ادغام 3D-CNN برای استخراج مشخصه‌های عمومی ویدئو، استفاده از SVM برای تولید بردارهای ارائه‌دهنده ویدئو و سپس از یک مدل رگرسیون برای پیش‌بینی محبوبیت ویدئو با در نظر گرفتن بردار ارائه‌دهنده متناظر مطرح نمودند. بعد از به دست آمدن محبوبیت هر ویدئو، سهم بهینه هر ویدئو ذخیره‌شده در ایستگاه پایه برای کاهش بار بک‌هال در هر دوره زمانی به دست می‌آید. مزیت این روش در توانایی پیش‌بینی محبوبیت ویدئوهای جدید بارگذاری شده بدون نیاز به اطلاعات آماری مورد نیاز است.

^۱ Extreme Learning Machine^۲ Content popularity^۳ Content placement^۴ Perturbation stochastic approximation^۵ Quality of Experience (QoE)^۶ Unmanned aerial vehicles^۷ Echo state Network (ESN)^۸ Baseband unit^۹ Mobility pattern



شکل ۱۲۱. سیستم C-RAN توانمند شده با UAV [۲۴]

۳-۱۱-۱۰- روش مبتنی بر یادگیری انتقال

معمولاً پروفایل محبوبیت محتوا نقش مهمی را در ترسیم یک سیاست پربازده کشینگ ایفا می‌کند. اما تخمین با دقت زیاد از بالا بودن مدت‌زمان لازم برای جمع‌آوری نمونه درخواست فایل کاربران رنج می‌برد. برای غلبه بر این مشکل، در [۲۷] از ایده یادگیری انتقالی با جمع‌آوری نمونه درخواست فایل از شبکه اجتماعی در فرمول تخمین محبوبیت فایل^۱ استفاده شده است. با استفاده از تحلیل‌های نظری، زمان فراگیری برحسب تابع فاصله بین توزیع احتمال فایل‌های درخواستی و نمونه‌های حوزه منبع بیان می‌شود. همچنین، روش مبتنی بر یادگیری انتقال در [۲۸ و ۲۹] استفاده شده‌اند. به‌ویژه آنکه اگرچه فیلترکردن مشارکتی (CF)^۲ می‌تواند در تخمین ماتریس محبوبیت فایل بکار گرفته شود، ولی با مشکل تنک‌بودن داده مواجه می‌شود. بنابراین، در [۲۸] روش CF مبتنی بر یادگیری انتقال برای استخراج اطلاعات اجتماعی مشارکتی^۳ از تعامل کاربران D2D در حوزه اجتماعی پیشنهاد شده است که تخمین ماتریس محبوبیت فایل را در حوزه هدف بهبود می‌دهد. در [۲۹] یک طرح کشینگ مبتنی بر یادگیری انتقال که در هر ایستگاه کوچک انجام می‌شود، توسعه یافته است. خصوصاً از اطلاعات زمینه‌ای مانند گروه کاربران اجتماعی حاصل از تعامل D2D، قرار دادن کشینگ در هر سلول و در نظر گرفتن بار ترافیک و ظرفیت بک‌هال استفاده می‌شود. توسط شبیه‌سازی، نشان داده شده است که طرح ارائه شده می‌تواند با مشکل تنک بودن داده و شروع سرد^۴ به‌خوبی تعامل کند که منجر به بهبود چشمگیر در کیفیت سرویس‌دهی کاربران می‌شود.

از مراجع [۲۳-۲۵] دریافت می‌شود که محبوبیت محتوا با استفاده از روش‌های یادگیری نظارت‌شده مانند RNN و ELM می‌تواند به‌دقت پیش‌بینی یا تخمین زده شود که برای فرموله‌کردن مسائل مدیریت کشینگ سودمند است. علاوه‌برآن، مبتنی بر [۲۷-۲۹] اطلاعات درخواست محتوا از حوزه‌های دیگر، مانند شبکه اجتماعی می‌تواند به کاهش زمان موردنیاز در تخمین محبوبیت محتوا کمک کند. در آخر اینک وقتی به دست آوردن محبوبیت فایل دشوار باشد، یادگیری تقویتی یک راه مؤثر در بهینه‌سازی مستقیم سیاست کشینگ است.

^۱ Content popularity

^۲ Collaborative Filtering (CF)

^۳ Collaborative social behaviour information

^۴ Cold start

۱۲-۱۰- مدیریت منابع محاسباتی مبتنی بر یادگیری ماشین

در [۳۰] یک شبکه مخابرات بی سیم که سرویس‌های محاسبات موبایل لبه MEC^1 را ارائه می‌کند در نظر گرفته شده است؛ در این شبکه یک مسئله تصمیم‌گیری در مورد واگذاری محاسبات برای یک پایانه موبایل بررسی شده است که در آن چندین ایستگاه پایه برای واگذاری محاسبات در دسترس هستند. به‌ویژه، مسئله تغییرات محیط مانند کیفیت متغیربازمان کانال، ورود تکالیف و وضعیت انرژی در دستگاه موبایل را در نظر می‌گیرد. برای توسعه سیاست تصمیم‌گیری واگذاری بهینه، یک روش یادگیری مبتنی بر DQN پیشنهاد شده است که نیاز به اطلاعات کامل در مورد تغییرات شبکه ندارد و می‌تواند فضای حالت با ابعاد بزرگ را مدیریت کند. نتایج شبیه‌سازی نشان می‌دهد که طرح ارائه شده می‌تواند عملکرد واگذاری محاسبات را در مقایسه با چندین روش سنتی به‌طور چشمگیری بهبود دهد.

از مرجع [۳۰] می‌توان دریافت که DRL مبتنی بر DQN می‌تواند بدون دانستن اطلاعات شبکه و تغییرات اطلاعات کانال، برای بهینه‌سازی سیاست واگذاری محاسبات در عین مواجهه با مسئله بزرگ بودن فضای حالت، برای تهیه سرویس‌های MEC شبکه بی سیم به کار رود. اگرچه در [۳۰] فقط سناریو تک‌کاربره را در نظر می‌گیرد و جا برای انجام تحقیقات بر روی سناریوهای چندین کاربره مبتنی بر DRL وجود دارد.

۱۳-۱۰- شکل‌دهی پرتو مبتنی بر یادگیری ماشین

با در نظر گرفتن افزایش نیاز به کیفیت سرویس‌دهی و نیاز به پردازش‌های زمان حقیقی در سیستم‌های عملی، در [۳۱] یک چهارچوب تخصیص منابع مبتنی بر یادگیری نظارت‌شده برای راه‌حل تخصیص منابع بهینه و نزدیک به بهینه پیشنهاد شده است. داده مربوط به سناریوهای قبلی جمع‌آوری شده و بردار مشخصه برای هریک از آنها استخراج می‌شود. سپس، برنامه تخصیص منابع بهینه یا نزدیک بهینه با بهره‌گیری از مزیت محاسبات ابر می‌تواند به‌صورت آفلاین به دست آید. بعدازآن، بردارهای مشخصه با راه‌حل یکسان در تخصیص منابع با نمایه کلاس یکسان نام‌گذاری می‌شوند. کار باقیمانده برای مشخص‌سازی تخصیص منابع برای یک سناریو جدید عبارت است از مشخص‌سازی کلاس متناظر با بردار مشخصه و مسئله تخصیص منابع به مسئله طبقه‌بندی چندکلاسه که آن هم توسط یادگیری نظارت‌شده مدیریت می‌شود. برای درک بهتر، یک مثال با استفاده از KNN برای بهینه‌سازی تخصیص پرتو در یک سلول تنها با چندین کاربر ارائه شده است و نتایج شبیه‌سازی حاکی از بهبود در نرخ مجموع در مقایسه با آخرین روش‌ها است. اگرچه باید توجه شود که برای مقایسه تشابهات بین سناریو فعلی و سناریوهای قبلی، تأخیر ایجادشده توسط KNN وجود دارد. هنگامی که چنین تشابهاتی بتواند یک‌به‌یک محاسبه گردد و تعداد سناریوهای قبلی بزرگ باشد، این امکان وجود دارد که محیط قبل از نتیجه تخصیص پرتو توسط KNN تغییر کرده باشد که منجر به عملکرد ضعیف آن می‌شود. بنابراین، طبقه‌بندی‌کننده با پیچیدگی کم و با تأخیر پاسخ‌دهی کم برای شکل‌دهی پرتو مبتنی بر یادگیری ماشین برای تنظیم مناسب با اطلاعات فازی متغیربازمان کاربر و اطلاعات حالت کانال، ضروری است.

همان‌طور که در [۳۱] نشان داده شده است، مدیریت منابع در شبکه بی سیم می‌تواند به یک عمل نظارت‌شده و طبقه‌بندی تبدیل گردد که مجموعه داده برچسب‌گذاری‌شده از بردارهای مشخصه نشان‌دهنده سناریوهای مختلف و کلاس‌های متناظر تشکیل شده است. بردارهای مشخصه متعلق به یک کلاس یکسان متناظر با راه‌حل تخصیص منابع یکسان هستند. سپس تکنیک‌های یادگیری ماشین متفاوت برای طبقه‌بندی می‌توانند برای مشخص کردن تخصیص منابع در سناریو جدید بکار روند. وقتی پیچیدگی الگوریتم طبقه‌بندی کم است، دستیابی به تخصیص منابع نزدیک به بهینه امکان‌پذیر است. در آخر باید توجه

¹ Mobile edge computing

شود که کلید موفقیت این چهارچوب در ساختار بردار مشخصه درست برای سناریو مخابراتی و طراحی طبقه‌بندی‌کننده چند کلاسه با پیچیدگی کم است.

۱۴-۱۰- جمع‌بندی

در شبکه اینترنت اشیاء با اتصال دستگاه‌های هوشمند با قابلیت‌های متفاوتی در پردازش، ذخیره‌سازی و توانایی مخابره مواجه هستیم. این شبکه‌ها کاربردهای فراوانی را در کاربردهای صنعتی و منجمله در شبکه هوشمند دارند. در چنین شبکه ناهمگون بزرگ، شبکه اینترنت اشیاء نیاز به مقیاس پذیری، تطبیق پذیری، بازدهی بالا، و مکانیسم‌های عادلانه در مدیریت شبکه دارد. در واقع شبکه‌های اینترنت اشیاء فقط با چالش تخصیص منابع مواجه نمی‌شوند، بلکه نیاز به تصمیم بر مدیریت منابع نیز دارد. برخلاف روش‌های مدیریت منابع مرسوم شامل بهینه‌سازی و روش‌های مکاشفه‌ای، تئوری بازی و روش‌های مشارکتی، مدل‌های یادگیری عمیق و تقویتی می‌توانند کنش‌ها را از اطلاعات زمان اجرا^۱ استنتاج کنند و خودشان را با تغییرات محیط بازفراگیری و باز تنظیم کنند. تکنیک‌های یادگیری عمیق و تقویتی نقش مؤثری برای مدیریت خودکار منابع و فرایند تصمیم‌گیری، خصوصاً برای محیط اینترنت اشیاء بزرگ، پیچیده و متغیر دارند. هر دو جامعه دانشگاهی و صنعت از یادگیری ماشین در بهبود ارتباطات استفاده می‌کنند. با توجه به کاربردهای وسیعی که اینترنت اشیاء در کاربردهای صنعتی منجمله صنعت برق دارند، در این فصل ابتدا ویژگی‌های اینترنت اشیاء در صنعت برق احصاء شدند. سپس با توجه به اهمیت مدیریت منابع در این شبکه‌ها، مشکلات روش‌های سنتی مورد مطالعه و بررسی قرار گرفتند و در ادامه انگیزه استفاده از روش‌های یادگیری ماشینی در خصوص مدیریت منابع در شبکه‌های ارتباطی بیان گردیدند. در ادامه مطالب این فصل کاربرد روش‌های یادگیری ماشینی برای انجام وظایف مختلف مدیریت منابع شامل انجام کنترل توان، مدیریت طیف، مدیریت بک‌هال، مدیریت کش، طراحی شکل‌دهنده پرتو و مدیریت منابع محاسباتی به صورت مجزا و مبسوط مورد مطالعه و بررسی قرار گرفتند.

مدیریت منابع در سیستم‌های ارتباطی باعث ارتقاء عملکرد این سیستم‌های می‌شوند و موضوعی کاملاً مخابراتی می‌باشد. هرگونه بهبود در عملکرد این سیستم‌ها، باعث بهبود عملکرد کاربردهایی که از آنها استفاده می‌کنند خواهد شد و به این ترتیب به صورت غیرمستقیم نقش حیاتی خود را ایفا خواهند کرد. به عنوان مثال مدیریت بهتر منبع طیف فرکانسی باعث خواهد شد که حسگرهای بی‌سیم که در صنعت برق وجود دارند و تعداد آنها به صورت روزافزون زیادتر می‌شود بتوانند استفاده مقرون به صرفه‌تری را از این منبع داشته باشند. با یک نگاه دیگر می‌توان موضوع را به این صورت دید که با استفاده از یک مقدار مشخص از منبع طیف فرکانسی، تعداد بسیار بیشتری از حسگرها را پشتیبانی کرد. به این ترتیب و در هر دو حالت مشاهده می‌شود که چگونه مدیریت منابع باعث ارتقاء عملکرد کاربردهای متکی بر سیستم‌های ارتباطی می‌شود. مثال دیگر، کنترل توان است که می‌تواند باعث کاهش مصرف حسگرها و در نتیجه بیشتر شدن طول عمر باتری‌های موجود در آنها شود؛ امری که باعث کاهش فعالیت‌های لجستیکی مورد نیاز هم خواهد شد. همچنین کاربرد سیستم‌های MIMO و MIMO انبوه می‌توانند کاربردهای مؤثری در پوشش‌دهی به یک گستره بزرگ جغرافیایی و شامل تعداد زیادی از حسگرها باشد. شکل‌دهی به پرتو در این سیستم‌های از اهمیت بسیار زیادی برخوردار است و از اینرو روش‌های یادگیری ماشینی که در این خصوص ارائه شده‌اند می‌توانند نقش با ارزشی را ایفا نمایند.

¹ Run-time

مراجع فصل ۱۰

1. F. Hussain, "*Internet of Things; Building Blocks and Business Models*", Springer, 2017.
2. Hussain, Fatima, Syed Ali Hassan, Rasheed Hussain, and Ekram Hossain. "Machine learning for resource management in cellular and IoT networks: Potentials, current solutions, and open challenges." *IEEE Communications Surveys & Tutorials* 22, no. 2 (2020): 1251-1275.
3. Y. Sun, M. Peng, Y. Zhou, Y. Huang and S. Mao, "Application of Machine Learning in Wireless Networks: Key Techniques and Open Issues," in *IEEE Communications Surveys & Tutorials*, vol. 21, no. 4, pp. 3072-3108, Fourthquarter 2019.
4. M. Simsek, M. Bennis, and I. Guvenc, "Learning based frequency and time-domain inter-cell interference coordination in HetNets," *IEEE Trans. Veh. Technol.*, vol. 64, no. 10, pp. 4589–4602, Oct. 2015.
5. T. Sanguanpuak, S. Guruacharya, N. Rajatheva, M. Bennis, and M. Latva-Aho, "Multi-operator spectrum sharing for small cell networks: A matching game perspective," *IEEE Trans. Wireless Commun.*, vol. 16, no. 6, pp. 3761–3774, Jun. 2017.
6. A. Galindo-Serrano and L. Giupponi, "Distributed Q-learning for aggregated interference control in cognitive radio networks," *IEEE Trans. Veh. Technol.*, vol. 59, no. 4, pp. 1823–1834, May 2010.
7. A. Asheralieva and Y. Miyanaga, "An autonomous learning-based algorithm for joint channel and power level selection by D2D pairs in heterogeneous cellular network," *IEEE Trans. Veh. Technol.*, vol. 67, no. 1, pp. 1–12, Jan. 2018.
8. H. Sun et al., "Learning to optimize: Training deep neural networks for interference management," *IEEE Trans. Signal Process.*, vol. 66, no. 20, pp. 5438–5453, Oct. 2018.
9. W. Lee, M. Kim, and D. Cho, "Deep power control: Transmit power control scheme based on convolutional neural network," *IEEE Commun. Lett.*, vol. 22, no. 6, pp. 1276–1279, Apr. 2018.
10. A. Galindo-Serrano, L. Giupponi, and G. Auer, "Distributed learning in multiuser OFDMA femtocell networks," in *Proceedings of VTC*, Yokohama, Japan, May 2011, pp. 1–6.
11. C. Fan, B. Li, C. Zhao, W. Guo, and Y. C. Liang, "Learning-based spectrum sharing and spatial reuse in mm-wave ultra dense networks," *IEEE Trans. Veh. Technol.*, vol. 67, no. 6, pp. 4954–4968, Jun. 2018.

12. G. Alnwaimi, S. Vahid, and K. Moessner, "Dynamic heterogeneous learning games for opportunistic access in LTE-based macro/femtocell deployments," *IEEE Trans. Wireless Commun.*, vol. 14, no. 4, pp. 2294–2308, Apr. 2015.
13. Y. Sun, M. Peng, and H. V. Poor, "A distributed approach to improving spectral efficiency in uplink device-to-device enabled cloud radio access networks," *IEEE Trans. Commun.*, vol. 66, no. 12, pp. 6511–6526, Dec. 2018.
14. M. Chen, W. Saad, and C. Yin, "Echo state networks for self-organizing resource allocation in LTE-U with uplink-downlink decoupling," *IEEE Trans. Wireless Commun.*, vol. 16, no. 1, pp. 3–16, Jan. 2017.
15. M. Jaber, M. Imran, R. Tafazolli, and A. Tukmanov, "An adaptive backhaul-aware cell range extension approach," in *Proceedings of ICCW*, London, UK, Jun. 2015, pp. 74–79.
16. Y. Xu, R. Yin, and G. Yu, "Adaptive biasing scheme for load balancing in backhaul constrained small cell networks," *IET Commun.*, vol. 9, no. 7, pp. 999–1005, Apr. 2015.
17. K. Hamidouche, W. Saad, M. Debbah, J. B. Song, and C. S. Hong, "The 5G cellular backhaul management dilemma: To cache or to serve," *IEEE Trans. Wireless Commun.*, vol. 16, no. 8, pp. 4866–4879, Aug. 2017.
18. S. Samarakoon, M. Bennis, W. Saad, and M. Latva-aho, "Backhaul-aware interference management in the uplink of wireless small cell networks," *IEEE Trans. Wireless Commun.*, vol. 12, no. 11, pp. 5813–5825, Nov. 2013.
19. S. Hassan, S. Samarakoon, M. Bennis, M. Latva-aho, and C. S. Hong, "Learning-based caching in cloud-aided wireless networks," *IEEE Commun. Lett.*, vol. 22, no. 1, pp. 137–140, Jan. 2018.
20. W. Wang et al., "Edge caching at base stations with device-to-device offloading," *IEEE Access*, vol. 5, pp. 6399–6410, Mar. 2017.
21. Y. He, N. Zhao, and H. Yin, "Integrated networking, caching and computing for connected vehicles: A deep reinforcement learning approach," *IEEE Trans. Veh. Technol.*, vol. 67, no. 1, pp. 44–55, Jan. 2018.
22. C. Zhong, M. Gursay, and S. Velipasalar, "A deep reinforcement learning-based framework for content caching," in *Proceedings of CISS*, Princeton, NJ, USA, Mar. 2018, pp. 1–6.

23. S. M. S. Tanzil, W. Hoiles, and V. Krishnamurthy, "Adaptive scheme for caching YouTube content in a cellular network: Machine learning approach," *IEEE Access*, vol. 5, pp. 5870–5881, Mar. 2017.
24. M. Chen et al., "Caching in the sky: Proactive deployment of cache-enabled unmanned aerial vehicles for optimized quality of experience," *IEEE J. Sel. Areas Commun.*, vol. 35, no. 5, pp. 1046–1061, May 2017.
25. M. Chen, W. Saad, C. Yin, and M. Debbah, "Echo state networks for proactive caching in cloud-based radio access networks with mobile users," *IEEE Trans. Wireless Commun.*, vol. 16, no. 6, pp. 3520–3535, Jun. 2017.
26. K. N. Doan, T. V. Nguyen, T. Q. S. Quek, and H. Shin, "Content-aware proactive caching for backhaul offloading in cellular network," *IEEE Trans. Wireless Commun.*, vol. 17, no. 5, pp. 3128–3140, May 2018.
27. B. N. Bharath, K. G. Nagananda, and H. V. Poor, "A learning-based approach to caching in heterogeneous small cell networks," *IEEE Trans. Commun.*, vol. 64, no. 4, pp. 1674–1686, Apr. 2016.
28. E. Bastug, M. Bennis, and M. Debbah, "Anticipatory caching in small cell networks: A transfer learning approach," in *Proceedings of Workshop Anticipatory Netw.*, Germany, Sep. 2014.
29. E. Bastug, M. Bennis, and M. Debbah, "A transfer learning approach for cache-enabled wireless networks," in *Proceedings of WiOpt*, Mumbai, India, May 2015, pp. 161–166.
30. X. Chen et al., "Optimized computation offloading performance in virtual edge computing systems via deep reinforcement learning," 1805.06146v1, May 2018, accessed on Jun. 15, 2018.
31. J. Wang et al., "A machine learning framework for resource allocation assisted by cloud computing," *IEEE Netw.*, vol. 32, no. 2, pp. 144–151, Apr. 2018.
32. H. Sun et al., "Learning to optimize: Training deep neural networks for interference management," *IEEE Trans. Signal Process.*, vol. 66, no. 20, pp. 5438–5453, Oct. 2018.
33. F. Tang et al., "On removing routing protocol from future wireless networks: A real-time deep learning approach for intelligent traffic control," *IEEE Wireless. Commun.*, vol. 25, no. 1, pp. 154–160, Feb. 2018.
34. W. Lee, M. Kim, and D. Cho, "Deep power control: Transmit power control scheme based on convolutional neural network," *IEEE Commun. Lett.*, vol. 22, no. 6, pp. 1276–1279, Apr. 2018.

35. J. Wang et al., “A machine learning framework for resource allocation assisted by cloud computing,” *IEEE Netw.*, vol. 32, no. 2, pp. 144–151, Apr. 2018.

فصل ۱۱. بررسی روش‌های به کارگیری AI جهت ارتقاء امنیت در شبکه‌های ارتباطی

۱-۱- مقدمه

همان‌طور که در مراحل قبلی پروژه نیز اشاره شد، شبکه برق به سمت هوشمندسازی در حرکت است و یک بخش مهم از این تحول، جمع‌آوری داده و انتقال اطلاعات به واحدهای کنترلی و مدیریت شبکه است تا با تجزیه و تحلیل داده و روش‌هایی مانند هوش مصنوعی و یادگیری ماشینی تصمیمات بهینه اتخاذ شود. بحث جمع‌آوری داده معمولاً با حضور حسگرها و کتورها در شبکه برق هوشمند انجام می‌شود که اینترنت اشیاء صنعتی می‌تواند در این زمینه بسیار یاری‌رسان باشد. این نوع اینترنت اشیاء به دلیل ویژگی‌های منحصر به فردی که دارد، نیازمند حفاظت و امنیت ویژه‌ای نیز هست. این ویژگی‌ها شامل محدودیت منابع، ناهمگونی، داده‌های حجیمی که به صورت بلادرنگ توسط حسگرها تولید می‌شوند و همین‌طور دینامیک و پویایی بسیار زیاد شبکه‌ها می‌شود. همچنین یکی از پایه‌های تجاری‌سازی فناوری اینترنت اشیاء امنیت و تضمین حفظ حریم خصوصی که به اندازه رضایت کاربر مهم و حائز اهمیت است. این واقعیت که فناوری IoT می‌تواند دیگر فناوری‌ها مانند شبکه‌های مبتنی بر نرم‌افزار^۱ (SDN)، پردازش ابری^۲ و پردازش مه^۳ را قابل پیاده‌سازی نماید باعث می‌شود تا خطر حملات مهاجمان را نیز افزایش دهد. همچنین این حملات ممکن است در لایه‌های مختلفی از شبکه رخ دهند. در ابتدا حملات مختلفی که در لایه‌های مختلف شبکه ممکن است روی دهد، مورد بررسی قرار گرفته‌اند.


از آنجایی که تعداد پارامترها برای بهینه‌سازی در چنین شبکه‌هایی بالاست و از طرفی روش‌های یادگیری ماشین و هوش مصنوعی مانند یادگیری عمیق می‌توانند در دستگاه‌های اینترنت اشیاء تعبیه شوند، این روش‌ها می‌توانند برای حل مسائل امنیتی به کار برده شوند.

شبکه‌های آتی، بیشتر به سمت توزیع شده بودن و طبیعت بدون زیرساخت حرکت می‌کنند که نسبت به حملاتی مانند DoS^۴ و حملات سایبر-فیزیکی^۵ آسیب‌پذیر هستند. اخیراً^۶ DQL به عنوان یک راه حل مؤثر برای پرهیز و جلوگیری از حملات مورد استفاده قرار گرفته است. در ادامه به تعدادی از کاربردهای DQL برای برخی موارد امنیتی اشاره شده که در طی گزارش به‌طور مفصل مورد بررسی قرار می‌گیرند [۱]:

• احراز هویت و کنترل دسترسی

احراز هویت یکی از نیازهای اولیه امنیت در اینترنت اشیاء است. کاربران می‌بایست برای استفاده از خدمات و برنامه‌های کاربردی IoT احراز هویت شوند. به‌طور معمول، برنامه‌های کاربردی و خدمات IoT بر اساس تبادل داده بین پلتفرم‌های مختلف است. داده‌ای که از ادوات IoT گرفته می‌شود، پیش‌پردازش و پردازش شده و به یک سیستم تصمیم‌گیر انتقال می‌یابد تا آن را مورد ارزیابی قرار دهد. عموماً زمانی که کاربر یا برنامه کاربردی به داده‌ای از IoT نیاز دارد باید در شبکه IoT احراز هویت شود تا این اطمینان حاصل گردد که درخواست‌کننده اجازه دسترسی لازم برای دستیابی به داده را دارد. همانند دیگر شبکه‌ها، کنترل دسترسی شبکه IoT نیز از اهمیت زیادی برخوردار است و می‌تواند با توجه به ناهمگونی شبکه، حجم شبکه، محدودیت منابع ادوات، امنیت شبکه و آسیب‌پذیری نسبت به حملات مبحثی چالشی باشد.

¹Software defined network²Cloud computing³Fog computing⁴Denial-of-Service⁵Cyber-physical⁶Deep Q-learning



شکل ۱۲۲. حمله جمینگ در شبکه رادیو شناختی [۲]

• حملات اختلال (جمینگ)^۱

همان‌طور که در شکل ۱۲۲ نشان داده شده است، در این حملات، جمرها سیگنال‌های فرکانس رادیویی (RF) با توان بالایی را ارسال می‌کنند تا باعث ایجاد تداخل در کانال‌های مخابراتی قانونی شوند و پارامتر سیگنال به تداخل و نویز^۲ SINR را در گیرنده‌های کاربران قانونی کاهش دهند. برخی روش‌های ضد جمینگ مانند پرش فرکانسی^۳ [۳] و جابجایی کاربر یعنی خارج شدن از ناحیه‌ای که جمینگ سنگینی دارد، به‌طور متداول مورد استفاده قرار می‌گیرند. با این حال، بدون آگاهی از مدل کانال رادیویی و روش‌های جمینگ، انتخاب کانال فرکانسی مناسب و همچنین چگونگی خارج شدن و جلوگیری از حمله برای کاربران، چالشی خواهد بود. DQL این امکان را برای کاربران فراهم می‌کند تا یک راهبرد بهینه را بر پایه مشاهدات قبلی‌شان یاد بگیرند و در نتیجه می‌توانند برای برطرف کردن این چالش مورد استفاده قرار گیرند.

• آشکارسازی نفوذ^۴

فیلتر ترافیک یکی از پرکاربردترین مکانیسم‌ها برای تشخیص نفوذ است که در آن تجزیه و تحلیل بسته یا تجزیه و تحلیل دسته ای برای جداسازی بسته‌های قانونی از بسته‌های مخرب انجام می‌شود. با این وجود، علیرغم تأثیر طبقه‌بندی ترافیک، تعداد مثبت‌های کاذب بیشتری که در نتیجه چنین طبقه‌بندی تولید می‌شود، باعث می‌گردد که این روش از اطمینان کمتری برخوردار باشد. از طرف دیگر، مدل‌های مبتنی بر رفتار نیز برای تشخیص نفوذ در شبکه مورد استفاده قرار می‌گیرند. در زمینه^۵ اینترنت اشیا، از هر دو روش طبقه‌بندی ترافیک و مدل‌های مبتنی بر رفتار استفاده می‌شود.

• حمله سایبر-فیزیکی

این حمله یک حمله یکپارچه است که مهاجم داده‌ها را برای تغییر سیگنال‌های کنترلی در سیستم دست‌کاری می‌کند. این حمله معمولاً در سیستم‌های خودکار مانند سیستم‌های حمل و نقل هوشمند^۵ (ITS) اتفاق می‌افتد و ریسک تصادفات در وسایل

¹Jamming

²Signal-to-interference-plus-noise ratio

³Frequency hopping

⁴Intrusion detection

⁵Intelligent transportation system

نقلیه خودکار^۱ (AV) را افزایش می‌دهد. روش DQL به AV اجازه می‌دهد تا رفتار بهینه را از مشاهدات وابسته به زمان فعالیت‌های مهاجم فراگیرند. بنابراین، DQL می‌تواند برای به دست آوردن کنترلی مقاوم و پویا نسبت به حملات به AV به کار رود.

• حفظ اتصال

این مورد به حفظ اتصال بین ربات‌ها بخصوص UAVها اختصاص دارد که مخابرات و تبادل اطلاعات بین آنها را پشتیبانی می‌کند. سیستم و محیط شبکه عموماً پویا و پیچیده است و بنابراین DQL که به ربات اجازه می‌دهد تا تصمیمات پویایی بر اساس وضعیتش اتخاذ کند می‌تواند به‌طور مؤثری برای حفظ اتصال در سیستم مورد استفاده باشد.

۲-۱۱- راهکار هوش مصنوعی برای مسائل امنیتی در اینترنت اشیاء

برای پیاده‌سازی موفق یک شبکه اینترنت اشیاء، تحلیل ریشه مسائل مربوط به برقراری امنیت و حفظ حریم شخصی حائز اهمیت است. به‌طور دقیق‌تر، واژه اینترنت اشیاء از مجموعه‌ای از فناوری‌ها ایجاد شده و مهم است که بدانیم چالش‌های امنیت در اینترنت اشیاء یک مسئله جدید است یا به‌طور ذاتی در فناوری‌های قدیمی نیز وجود داشته است. در [۴] مشابهت‌ها و تفاوت‌های مسائل امنیتی در ادوات اینترنت اشیاء و IT قدیمی مورد بررسی قرار گرفته‌اند. مهم‌ترین پارامترهایی که به آنها پرداخته شده شامل نرم‌افزار، سخت‌افزار، شبکه و کاربردها است. بر اساس این دسته‌بندی، مشابهت‌های پایه‌ای در حوزه IT قدیمی و IoT وجود دارد. با این حال مهم‌ترین مسئله در اینترنت اشیاء محدودیت منابع است که باعث می‌شود نتوان از راه‌حل‌های پیچیده امنیتی در شبکه‌های اینترنت اشیاء استفاده نمود. همچنین مسائل امنیتی در شبکه‌های اینترنت اشیاء نیازمند طراحی یکپارچه و الگوریتم‌های بهینه‌شده هستند. برای مثال، به دلیل وجود محدودیت در منابع پردازشی، ادوات اینترنت اشیاء نیازمند نسل جدیدی از رمزنگاری‌ها و الگوریتم‌های بهینه‌سازی هستند. همان‌طور که در ویژگی‌ها نیز اشاره شد، حجم بالای انتقال داده و تعداد اتصالات زیاد در شبکه اینترنت اشیاء نیازمند روش‌های حفظ امنیتی است که مقیاس‌پذیر باشند.

با توجه به ویژگی‌های اشاره‌شده در بالا، به نظر می‌رسد روش‌های هوش مصنوعی و یادگیری ماشین مانند یادگیری عمیق می‌توانند گزینه‌های مناسبی برای حل مسائل امنیتی در شبکه‌های مبتنی بر اینترنت اشیاء باشند. الگوریتم‌های یادگیری ماشین به داده‌های زیادی نیاز دارند تا بتوانند با استفاده از روش‌های ریاضی مدل‌های رفتاری با دقت مناسبی ایجاد کنند. در شبکه‌های اینترنت اشیاء حجم بالایی از داده تولید می‌شود که به‌راحتی می‌تواند برای یادگیری و پیش‌بینی رفتار آینده ادوات مورد استفاده قرار گیرد و هوش را وارد این ادوات نماید. همچنین با توجه به این که تعداد ادوات در این شبکه‌ها زیاد است و علاوه بر این موارد، پویایی نیز در اجزای شبکه وجود دارد، حالت‌هایی که ممکن است به وجود بیاید بسیار زیاد خواهد بود. در نتیجه روش‌هایی مانند DQL می‌توانند گزینه‌های مناسبی برای کاهش زمان همگرایی باشند.

از طرف دیگر استفاده از یادگیری ماشین و یادگیری عمیق در کاربردهایی نظیر اینترنت اشیاء چالش‌هایی را نیز به همراه دارد. برای مثال ایجاد یک مدل مناسب برای پردازش داده از کاربردهای مختلف IoT کار ساده‌ای نیست. همان‌طور که قبلاً هم اشاره شد ادوات اینترنت اشیاء دارای محدودیت منابع هستند و کاهش زمان پردازش و ذخیره داده در آنها بسیار حائز اهمیت است. به‌طور مشابه زیرساخت‌های مهم و کاربردهای بلادرنگ نمی‌توانند زمان زیادی منتظر الگوریتم‌های یادگیری ماشین باشند.

¹Autonomous vehicles

۱۱-۳- انواع حملات در لایه‌های مختلف

در حقیقت، اینترنت اشیاء از یک رویکرد تحول آفرین استفاده می‌کند تا برنامه‌ها و خدمات بی‌شماری را در اختیار مصرف‌کنندگان قرار دهد. واضح است که استفاده فراگیر از تعداد زیادی دستگاه، سطح حمله را افزایش می‌دهد. از طرف دیگر، این واقعیت که دستگاه‌های اینترنت اشیاء محدود به منابع هستند، باعث می‌شود استفاده از مکانیسم‌های پیچیده امنیتی در برابر حملات امکان‌پذیر نباشد. علاوه بر این، لازم به ذکر است که اینترنت اصلی برای اینترنت اشیاء طراحی نشده است. بنابراین، ایجاد امنیت اینترنت اشیاء علاوه بر مکانیسم‌های امنیتی موجود در اینترنت و فناوری‌های اساسی، ضروری است. IoT از فن‌آوری‌های ارتباطی مختلفی مانند IPv6، Zigbee، 6LoWPAN، بلوتوث، Z-Wave، WiFi و ارتباطات راه نزدیک^۱ (NFC) استفاده می‌کند. این فناوری‌های ارتباطی کاستی‌ها و محدودیت‌های خاص خود را از نظر امنیتی دارند و این محدودیت‌ها به حوزه IoT نیز منتقل می‌شود [۵]. علاوه بر این موضوعات، زیرساخت ارتباطی مبتنی بر TCP/IP مستعد چالش‌هایی مانند مقیاس‌پذیری، پیچیدگی، آدرس‌دهی، تنظیم و استفاده از منابع محدود است که امکان استفاده از آن برای شبکه‌های متنوع و ناهمگن مانند IoT را محدود می‌کند [۶]. برای این منظور، از فناوری‌های جایگزین مختلفی مانند شبکه اطلاعات محور^۲ (ICN) و شبکه مبتنی بر نرم‌افزار^۳ (SDN) استفاده شده است تا به عنوان زیرساخت‌های ارتباطی اساسی اینترنت اشیاء استفاده شود [۷]. در ادامه خلاصه‌ای از تهدیدها و حملاتی را که IoT با آن روبرو است ارائه شده است. حملات امنیتی در IoT را می‌توان به حملات فیزیکی، شبکه، انتقال، کاربرد و رمزنگاری تقسیم نمود.

۱۱-۳-۱- حمله فیزیکی

در حملات فیزیکی، مهاجمان به دستگاه‌ها دسترسی مستقیم دارند و بخش‌های مختلف دستگاه‌ها را دست‌کاری می‌کنند. برای دستیابی به دستگاه‌های فیزیکی، مهندسی اجتماعی یکی از برجسته‌ترین روش‌هایی است که در آن مهاجمین به دستگاه‌ها دسترسی پیدا می‌کنند و حمله واقعی را انجام می‌دهند که موجب آسیب‌دیدگی فیزیکی، استراق سمع، کانال‌های جانبی و سایر حملات می‌شود [۸، ۹]. علی‌رغم این واقعیت که از فناوری‌های مختلفی در لایه فیزیکی اینترنت اشیاء استفاده می‌شود، ماهیت حملات فیزیکی بیشتر شبیه و نیازمند رویکردهای مهندسی اجتماعی است. علاوه بر این، برای شروع حملات فیزیکی، مهاجمان با اهداف مختلف مانند از بین بردن فیزیکی سخت‌افزار، محدود کردن طول عمر آن، به خطر انداختن مکانیسم ارتباطی، دست‌کاری در منبع انرژی و غیره، باید در نزدیکی دستگاه‌ها/سخت‌افزار باشند. همچنین لازم به ذکر است که حملات فیزیکی ممکن است اقدام اولیه برای حملات دیگر باشد، به عنوان مثال غیرفعال کردن زنگ هشدار در خانه می‌تواند منجر به سرقت یا آسیب دیگری در محیط خانه هوشمند شود. به طور مشابه، جایگزینی حسگر با حسگر مخرب منجر به نشت داده‌های حساس می‌گردد. تزریق گره مخرب به شبکه همچنین می‌تواند باعث حمله مردی در میان^۴ شود که به مهاجم امکان می‌دهد امتیازات را افزایش داده و حملات دیگری را انجام دهد. بعلاوه، چنین دست‌کاری در دستگاه‌ها ممکن است مهاجمان را قادر به ایجاد تغییراتی در جدول‌های مسیریابی و کلیدهای امنیتی کند که بر ارتباط با لایه‌های بالایی تأثیر بگذارد [۱۰-۱۲]. سایر حملات فیزیکی شامل جَمینگ فرکانس‌های رادیویی است که ارتباط در محیط اینترنت اشیاء را مختل می‌نماید. در میان بسیاری از پیامدهای دیگر، مسدود کردن باعث عدم پذیرش سرویس در اینترنت اشیاء می‌شود و در نتیجه بر عملکرد برنامه‌های اینترنت اشیاء تأثیر منفی می‌گذارد [۱۳، ۱۴]. همان‌طور

¹Near field communication

²Information-centric network

³Software defined network

⁴Man-in-the-middle

که گفته شد، مهاجمان همچنین از روش‌های مختلف مهندسی اجتماعی برای دسترسی فیزیکی به سخت‌افزار/ دستگاه‌ها برای اهداف مختلف مانند حملاتی که قبلاً ذکر کردیم، استفاده می‌کنند [۱۵، ۱۶].

۲-۳-۱۱- مسائل امنیتی لایه فیزیکی و لایه ارتباط داده

IoT ترکیبی از فناوری‌های مختلف ارتباطی در لایه‌های پایین‌تر پشته پروتکل TCP / IP است و بنابراین یک شبکه ناهمگن پیچیده را فراهم می‌کند. این فناوری‌ها شامل ZigBee، WSN، MANET، WiFi، RFID، NFC، و غیره می‌شود و علاوه بر این، این فناوری‌ها مسائل امنیتی خاص خود را دارند. در این بخش به نکات امنیتی در لایه‌های فیزیکی و ارتباط داده اینترنت اشیا پرداخته شده است. در مقالات زیادی در مورد مسائل امنیتی در اینترنت اشیا در لایه‌های مختلف و راه‌حل‌های موجود برای آن‌ها به‌طور مفصل بحث شده است [۱۷، ۱۸]. همان‌طور که قبلاً ذکر شد، ناهمگنی در لایه فیزیکی اینترنت اشیا وارد می‌شود و منجر به تغییرات مختلفی در لایه ارتباط داده می‌گردد. برای این منظور، مکانیسم‌های امنیتی IoT باید ناهمگونی را در لایه فیزیکی و ارتباط داده شامل شوند. بسته به فناوری زیرساخت، در لایه فیزیکی IoT، مسائل امنیتی مختلفی وجود دارد، به‌عنوان مثال در صورت وجود گره‌های حسگر، حملات فیزیکی روی گره‌های حسگر باید کاهش یابد. علاوه بر این، تشخیص خرابی در سخت‌افزار نیز از اهمیت فوق‌العاده‌ای برخوردار است و برای جلوگیری از ناهنجاری در لایه فوقانی باید از آن استفاده کرد. نفوذ، مسئله امنیت فیزیکی دیگری است که از نظر تشخیص و پیشگیری به اقدامات مقابله‌ای کارآمدی نیاز دارد. شایان‌ ذکر است که حتی برای تشخیص نفوذ در لایه‌های فوقانی، به‌عنوان مثال حمله مسیر یاب، بردارهای حمله زیادی می‌تواند وجود داشته باشد [۱۹]. از دیدگاه تشخیص خطا، تشخیص گره‌های معیوب در IoT از اهمیت زیادی برخوردار است زیرا مستقیماً بر کیفیت خدمات (QoS) برنامه IoT تأثیر می‌گذارد [۲۰، ۲۱].

هدف اصلی اینترنت اشیا فراهم آوردن زمینه مشترک برای وجود دستگاه‌های انرژی محدود برای همزیستی در لایه‌های پایین‌تر (لایه فیزیکی و ارتباطی) و ایجاد یک بستر مشترک ارتباطی برای دستگاه‌های ناهمگن است. به همین منظور، IEEE استاندارد را که تحت عنوان IEEE 802.15.4 شناخته می‌شود مجاز می‌داند تا به‌وسیله دستگاه‌های محدود امکان برقراری ارتباط مؤثر را فراهم کند [۲۲]. از آنجاکه در اینترنت اشیا، لایه‌های بالاتر از پروتکل‌های کم‌مصرف مانند 6LoWPAN و پروتکل برنامه محدود^۱ (CoAP) استفاده می‌کنند، مکانیسمی در لایه‌های پایین‌تر لازم است تا این پروتکل‌ها به‌صورت یکپارچه کار کنند. در این زمینه، استاندارد IEEE 802.15.4 اصلاحات لازم را در لایه‌های پایین‌تر برای این پروتکل‌ها فراهم می‌نماید. شایان‌ ذکر است که IEEE 802.15.4 امنیت را فقط در لایه ارتباط داده ایجاد می‌کند. لایه ارتباط داده یا لایه MAC علاوه بر اعتبارسنجی فریم‌ها، مدیریت دسترسی، مدیریت زمان و امنیت، مسئول دسترسی کانال برای دستگاه‌های مختلف نیز هست. امنیت ارائه شده توسط این استاندارد در لایه MAC نه‌تنها امنیت انتقال داده‌های سطح گره را تضمین می‌نماید بلکه امنیت لایه‌های بالایی را نیز تکمیل می‌کند. در این راستا، الگوریتم‌های رمزنگاری متقارن مانند AES ارائه شده است که هنگام اجرا روی تراشه، سریع و کارآمد هستند. بنابراین این پیاده‌سازی در سخت‌افزار IEEE 802.15.4، امنیت لایه پایین را تکمیل می‌کند [۲۳، ۲۴]. استاندارد IEEE 802.15.4 الگوریتم AES را پیاده‌سازی می‌کند و پیاده‌سازی‌های مختلفی نیز برای مقابله با محدودیت‌های منابع دستگاه‌ها پیشنهاد شده است [۲۵]. این استاندارد از حالت‌های مختلف امنیتی در لایه ارتباط داده پشتیبانی می‌کند، به‌عنوان مثال داده‌ها ممکن است فقط با بررسی یکپارچگی رمزگذاری نشوند، یا ممکن است داده‌ها به همراه بررسی یکپارچگی رمزگذاری شوند.

¹Constrained application protocol

۳-۱۱-۳- حملات لایه شبکه

در سطح شبکه، حملات در مسیریابی، تحلیل داده‌ها و ترافیک و حمله مردی در میان انجام می‌شود. علاوه بر این، حملات فریب^۱ در لایه شبکه که در آن از هویت‌های جعلی برای ایجاد توهم در شبکه استفاده می‌شود نیز امکان‌پذیر است [۲۶، ۲۷]. از طرف دیگر، نفوذ از طریق روش‌های مختلف، راهی برای حمله به سیستم فراهم می‌کند که در آن مهاجمین می‌توانند بسیاری از حملات دیگر را انجام دهند و بنابراین، امنیت شبکه برای مهار حملات در مراحل اولیه ضروری است. در لایه شبکه، مهاجم همچنین می‌تواند از یک گره فریب‌خورده استفاده کند تا بتواند از آن به‌عنوان گره جعلی استفاده کرده و یک چاله^۲ اطلاعاتی ایجاد نماید. این نوع حمله، که معمولاً با شبکه‌های حسگر و شبکه‌های موقت موبایل همراه است، در محیط اینترنت اشیا نیز به همان اندازه خطرناک می‌باشد [۲۸]. با این حملات، احتمال شروع حملات DDoS مشترک افزایش می‌یابد و در نتیجه کل شبکه اینترنت اشیا مختل می‌شود. در لایه شبکه، مهاجم می‌تواند با بمباران شبکه با ترافیکی بیش از حد توان شبکه به این هدف دست یابد. گره‌های فریب‌خورده IoT و هویت‌های جعلی عواقب فاجعه‌آمیزی بر روی شبکه خواهد داشت زیرا با چنین گره‌های جعلی (هویت‌های جعلی غیر موجود یا هویت‌های موجود فریب‌خورده) مهاجمان را قادر می‌سازد تا حملات فریب را انجام دهند که در آن گره‌های جعلی این توهم را در هسته شبکه به وجود می‌آورند که گره‌های واقعی داده ارسال می‌کنند. به‌طور خلاصه، بردارهای حمله در لایه شبکه جنبه‌های ارتباطی اینترنت اشیا را هدف قرار می‌دهند و از محدودیت‌های منابع و عدم وجود برنامه‌های پیچیده برای تأیید اعتبار و مجوز، سوءاستفاده می‌کنند.

۴-۱۱-۳- حملات لایه انتقال

لایه انتقال وظیفه تحویل فرآیند به فرآیند را بر عهده دارد، جایی که پروتکل‌های انتقال فرآیندها را قادر به تبادل داده می‌کند. در زمینه اینترنت اشیا، مسائل امنیتی سنتی لایه انتقال هنوز پابرجاست. جدی‌ترین حمله به این لایه، حمله اختلال سرویس^۳ است که شبکه را خفه می‌کند و منجر به مختل شدن خدمات برای برنامه‌ها می‌شود. شایان‌ذکر است که به دلیل ماهیت اینترنت اشیا، پروتکل‌های سنتی TCP و UDP با دستگاه‌های دارای منابع محدود، مقیاس‌پذیر نیستند و بنابراین نسخه‌های سبک پروتکل‌های انتقال در منابع [۲۹-۳۱] ارائه شده‌اند. با این حال، امنیت این پروتکل‌ها برای کاهش حملات DoS و DDoS در اینترنت اشیا از اولویت بالایی برخوردار است.

۵-۱۱-۳- حملات لایه کاربرد

برنامه‌های IoT برای مهاجمان اهداف نسبتاً پرسودی هستند زیرا حملات در سطح برنامه‌ها نسبتاً آسان انجام می‌شوند. برخی از حملات شناخته‌شده شامل حملات سرریز بافر، حملات بدافزار، اختلال خدمات، فیشینگ، استفاده از نقاط ضعف برنامه‌های کاربردی وب، حملات رمزنگاری، حملات کانال‌های جانبی و حملات مردی در میان است. سرریز بافر یکی از بردارهای حمله است که بیشتر در کاربردهای مختلف استفاده می‌شود [۳۲]. تکنیک‌های موجود برای کاهش مکانیسم سرریز بافر شامل تجزیه و تحلیل کد استاتیک و دینامیکی و سایر مکانیسم‌های پیچیده مانند اشکال‌زدایی نمادین^۴ است. با این حال، به دلیل محدودیت منابع، نمی‌توان از این روش‌ها برای اینترنت اشیا استفاده کرد. برنامه‌های اینترنت اشیا همچنین نسبت به تزریق کد مخرب در نتیجه

¹Sybil

²Sinkhole

³Denial of service attack

⁴Symbolic debugging

سرریز بافر و سایر آسیب‌پذیری‌ها مانند تزریق SQL، برنامه‌نویسی بین سابتی^۱، ارجاع شی^۲ و غیره در معرض خطر هستند. Open Security Application Security Project (OWASP) ده آسیب‌پذیری مهم را که باعث حمله‌های مختلف به برنامه‌ها می‌شود، شناسایی کرده است. آخرین لیست آسیب‌پذیری‌های یافت شده توسط OWASP در سال ۲۰۱۷ تهیه شده است. این آسیب‌پذیری‌ها منجر به حملات دیگری شده که می‌تواند راه‌اندازی شوند. برای مثال، از طریق حملات تزریق کد مخرب، مهاجم می‌تواند اطلاعات حساس را بدزدد، اطلاعات را دست‌کاری کند و سایر فعالیت‌های مخرب را نیز صورت دهد [۳۳]. علاوه، باتنت‌ها^۳ تهدیدهای جدی دیگری برای زیرساخت‌های اینترنت اشیا و برنامه‌های کاربردی هستند [۳۴]. کاهش حملاتی که از طریق باتنت‌های هوشمند انجام می‌شود یک چالش جدی برای اینترنت اشیا است زیرا این باتنت‌ها به‌طور هوشمند از طریق شبکه جستجو می‌کنند و به دنبال آسیب‌پذیری‌های شناخته‌شده می‌گردند و از آن‌ها برای شروع حملات مختلف مانند DDoS گسترده استفاده می‌کنند. همچنین لازم به ذکر است که به دلیل محدودیت منابع، پروتکل‌های رمزنگاری پیشرفته برای دستگاه‌های اینترنت اشیا عملی نیستند. به‌طور خلاصه، سطح حمله در لایه کاربرد زیرساخت IoT گسترده و از نظر محاسباتی نسبتاً گران است.

۶-۳-۱۱ - حملات چندلایه

علاوه بر حملات فوق‌الذکر، حملات چندلایه‌ای نیز وجود دارد که می‌تواند بر روی زیرساخت‌های IoT انجام شود. این حملات شامل تجزیه و تحلیل ترافیک، حملات کانال جانبی، حملات پخش مجدد، حملات مردی در میان و حملات پروتکل است. برخی از این حملات قبلاً در بخش‌های قبلی مورد بحث قرار گرفته‌اند. حملات تجزیه و تحلیل ترافیک حملاتی غیرفعال هستند که در آن مهاجمان به‌طور غیرفعال به ترافیک گوش می‌دهند و سعی می‌کنند درکی از آن پیدا کنند. کاهش این حملات بسیار دشوار است زیرا طرفین ارتباطی معمولاً تصویری از نظارت بر روند حملات خود ندارند. مهاجمان به دنبال اطلاعات جالبی در ترافیک اینترنتی مانند اطلاعات شخصی کاربران، جزئیات منطق کسب‌وکار، اعتبارنامه و سایر اطلاعاتی هستند که برای مهاجم ارزشی داشته باشد. علاوه بر این، امنیت انتقال داده نیز در اینترنت اشیا از اهمیت فوق‌العاده‌ای برخوردار است. داده‌های تولیدشده در محیط اینترنت اشیا برای تصمیم‌گیری استفاده می‌شود. بنابراین، تضمین کیفیت و سلامت داده‌ها ضروری است. سازش در امنیت داده‌ها در اینترنت اشیا، عواقب ناگواری را برای برنامه‌های اساسی ایجاد می‌کند. شایان‌ذکر است که SDN برای دستیابی به طیف وسیعی از مزایا برای برنامه‌های IoT و امنیت IoT استفاده شده است [۳۵]. عملکرد غنی ارائه شده توسط کنترل SDN، سازمان‌ها را قادر می‌سازد تا به‌طور مؤثر میلیون‌ها حسگر و چیزهای موجود در الگوی IoT را کنترل کنند. با این وجود، علی‌رغم تمام مزایای ذکرشده SDN، واسطه‌های باز در SDN، راه حملات جدیدی را به دستگاه‌ها، زیرساخت‌ها و برنامه‌های IoT که قبلاً آسیب‌پذیر بودند باز می‌کند [۳۶، ۳۷]. بنابراین، امنیت اینترنت اشیا مستقیماً به امنیت SDN نیز وابسته است.

۷-۳-۱۱ - مسائل امنیتی در اینترنت اشیا مبتنی بر ابر

یک عامل بسیار مهم دیگر برای اینترنت اشیا، محاسبات ابری است که برای پردازش داده‌های حجیم تولیدشده توسط زیرسیستم‌های اینترنت اشیا مورد استفاده قرار می‌گیرد. رعایت امنیت در اینترنت اشیا از نظر کاربران و همچنین از دیدگاه ارائه‌دهندگان خدمات از اهمیت ویژه‌ای برخوردار است [۳۸]. شایان‌ذکر است که ابر به دلایلی می‌تواند بخشی اساسی از زیرساخت اینترنت اشیا باشد و کارهایی از قبیل مدیریت داده‌های حجیم، ذخیره و پردازش مقدار زیادی از داده‌ها و تولید نتایج نهایی برای برنامه‌های مربوطه در محیط اینترنت اشیا را به عهده بگیرد. علاوه بر این، پلتفرم ابر طیف وسیعی از خدمات مانند مدیریت دستگاه،

¹Cross-site scripting

²Object referencing

³Botnet

مدیریت منابع، پردازش داده‌ها، تجزیه و تحلیل و مدیریت را فراهم می‌کند. بنابراین، تعداد دستگاه‌های اضافه شده به شبکه‌های IoT و داده‌های تولید شده توسط این دستگاه‌ها که سپس پردازش شده و ذخیره می‌شوند و توسط ابر مورد تجزیه و تحلیل قرار می‌گیرند، به ملاحظات امنیتی و حریم خصوصی مناسب، کارآمد و مقیاس پذیر نیاز دارند.

۴-۱۱- کاربردهای هوش مصنوعی در امنیت شبکه

این قسمت به بحث در مورد کاربردهای هوش مصنوعی و به خصوص روش DQL که نسبت به سایر روش‌ها جدیدتر است در حل مسائل موجود در حملات جمینگ، آشکارسازی نفوذ، حملات سایبر-فیزیکی و حفظ اتصال می‌پردازد.

۱-۴-۱۱- کاربرد هوش مصنوعی در حمله جمینگ

یک کار پیشرو در زمینه استفاده از DQL برای ضد جمینگ در [۲] آورده شده است. مدل شبکه یک شبکه رادیو شناختی^۱ (CRN) است که همان‌طور که در شکل ۱۲۲ نشان داده شده است شامل یک کاربر ثانویه، چندین کاربر اولیه و چندین جمر می‌باشد. شبکه یک دسته فرکانس برای پرش در اختیار دارد. در هر برش زمانی^۲ هر کدام از جمرها می‌تواند به صورت تصادفی یکی از کانال‌ها را برای ارسال سیگنال جمینگ انتخاب نماید و کاربر ثانویه می‌بایست عملی مناسب را بسته به وضعیت فعلی اش انتخاب کند. این عمل انتخاب یکی از کانال‌ها برای ارسال سیگنال یا ترک ناحیه برای اتصال به ایستگاه پایه دیگر است. همچنین فرض شده است که جمرها برای کاربران اولیه تداخلی ایجاد نمی‌کنند. بنابراین وضعیت فعلی کاربر ثانویه از تعداد کاربران اولیه و مقادیر گسسته SINR سیگنال کاربر ثانویه در آخرین برهه زمانی تشکیل می‌شود. مسئله کاربر ثانویه به حداکثر رساندن استفاده تخفیف‌دار در طول برهه‌های زمانی است. باید توجه داشت زمانی که کاربر ثانویه انتخاب می‌کند تا ناحیه را ترک کرده و به ایستگاه پایه دیگری متصل شود، یک هزینه جابجایی مصرف می‌شود. در نتیجه سود یا استفاده به صورت تابعی از SINR سیگنال کاربر ثانویه و هزینه جابجایی تعریف می‌شود. از آنجایی که تعداد کانال‌های فرکانسی ممکن است زیاد باشد و منجر به یک دسته عمل بزرگی شود، CNN برای DQL استفاده شده تا سیاست بهینه سریعاً یاد گرفته شود. همچنین نشان داده شده که روش DQL ارائه شده سرعت همگرایی بیشتری نسبت به الگوریتم Q-learning دارد. علاوه بر این، زمانی که سناریو با دو جمر در نظر گرفته شود، روش ارائه شده DQL با دو پارامتر SINR و هزینه جابجایی نسبت به روش پرش فرکانسی عملکرد بهتری دارد.


مدل ارائه شده در [۲] محدود به دو جمر است. هنگامی که تعداد جمرها در شبکه افزایش یابد، روش ارائه شده ممکن است مؤثر نباشد. دلیل این امر این است که برای کاربر ثانویه پیدا کردن عمل خوب هنگامی که تعداد کانال‌های مورد اختلال زیاد باشد، سخت می‌شود. همان‌طور که در [۳۹] آمده است، روش مناسب به گیرنده کاربر ثانویه اجازه می‌دهد تا محل فعلی اش را ترک نماید. از آنجایی که خارج شدن باعث هزینه جابجایی می‌شود، گیرنده به یک سیاست بهینه نیاز دارد تا در محل فعلی بماند یا آن را ترک کند تا بهره را به حداکثر رساند. در این سناریو نیز DQL مبتنی بر CNN می‌تواند برای گیرنده به منظور پیدا کردن عمل مناسب به منظور به حداکثر رساندن بهره مورد انتظار استفاده شود. در اینجا نیز بهره و وضعیت گیرنده مشابه [۲] در نظر گرفته شده است. به خصوص که وضعیت شامل SINR گسسته سیگنال اندازه گیری شده توسط گیرنده در آخرین برهه زمانی نیز هست. روش‌های ارائه شده در [۲] و [۳۹] وضعیت کاربران را بر پایه مقادیر SINR سیگنال‌ها تعریف می‌کنند. در محیط شبکه‌های بی سیم عملی، تعداد مقادیر SINR ممکن است بزرگ و حتی بینهایت باشد. علاوه بر این مقدار SINR ممکن است غیردقیق و همراه با نویز باشد. برای مقابله با تعداد وضعیت‌های بی نهایت، DQL می‌تواند از روش RCNN^۳ استفاده کند که در [۴۰] ارائه

¹Cognitive radio network

²Time slot

³Recurcive convolutional neural network

شده است. با استفاده از لایه پیش‌پردازش و لایه‌های کانولوشن بازگشتی، RCNN قادر است نویز را از محیط شبکه حذف کرده و مشخصات مفید SINR یعنی مقادیر گسسته نمونه‌های طیف که بزرگتر از یک آستانه نویز هستند را استخراج کند و پیچیدگی محاسبات را کاهش دهد. مدل شبکه و روابط مسئله که در [۴۰] مدنظر قرار گرفته است مشابه [۲] می‌باشد. با این حال، به جای استفاده مستقیم از مقادیر SINR، وضعیت کاربر ثانویه، مشخصات استخراج شده از SINR است. همچنین عمل کاربر ثانویه تنها شامل تصمیم‌گیری پرس فرکانسی است. نتایج شبیه‌سازی نشان می‌دهد که روش ارائه شده DQL مبتنی بر RCNN می‌تواند در سناریوهای جمینگ ثابت و متغیر همگرا شود در حالی که Q-learning در حالت جمینگ متغیر نمی‌تواند همگرا شود. همچنین روش ارائه شده DQL، بازدهی متوسطی نزدیک به حالت بهینه دارد یعنی روش ضد جمینگ که همه حرکات جمینگ را می‌داند. در [۴۱] به جای تصمیمات پرس فرکانسی، روشی با استفاده از DQL ارائه شده که سیاست کنترل توان بهینه را برای عملیات ضد جمینگ بهینه می‌کند. مدل استفاده شده، یک شبکه اینترنت اشیاء (IoT) است که شامل ادوات IoT و یک جمر می‌شود. جمر می‌تواند ارتباطات فرستنده را مشاهده کند و یک استراتژی جمینگ برای کاهش SINR در گیرنده انتخاب نماید. در نتیجه فرستنده عملی را انتخاب می‌کند (سطح توان ارسالی) که بهره‌اش به حداکثر برسد. در اینجا، بهره عبارت است از تفاوت بین هزینه SINR و هزینه مصرف انرژی به دلیل انتقال. باید توجه داشت که انتخاب توان ارسالی بر استراتژی جمینگ در آینده اثر می‌گذارد و در نتیجه تأثیر متقابل فرستنده و جمر می‌تواند به صورت یک MDP فرمول‌بندی گردد. فرستنده یک کاربر است و وضعیت، SINR اندازه‌گیری شده در گیرنده در آخرین برهه زمانی است. سپس DQN که از CNN استفاده می‌کند برای پیدا کردن سیاست بهینه کنترل توان فرستنده به منظور حداکثر نمودن پاداش تخفیف‌های جمع شوند که همان بهره در طول برهه‌های زمانی است، به کار برده می‌شود. نتایج شبیه‌سازی نشان می‌دهد که روش DQL ارائه شده می‌تواند در مقایسه با روش Q-learning 18.1% بهره فرستنده را تا 17.7% افزایش دهد. همچنین این روش بهره جمر را در مقایسه با روش Q-learning حدود 18.1% کاهش می‌دهد.



شکل ۱۲۳. روش ضد جمینگ با استفاده از UAV [۴۲]

برای جلوگیری از مشاهده ارتباطات توسط جمر، فرستنده می‌تواند استراتژی ارتباطات را با استفاده از رله‌هایی که دور از ناحیه جمینگ هستند تغییر دهد. این رله‌ها می‌توانند UAVها باشند [۴۲]. همان‌طور که در شکل ۱۲۳ نشان داده شده است، مدل مسئله از یک UAV یعنی یک رله، یک جمر، یک کاربر موبایل و ایستگاه پایه ارائه دهنده سرویس تشکیل شده است. کاربر

موبایل پیام‌ها را از طریق ایستگاه پایه به سرور ارسال می‌کند. در حالتی که ایستگاه پایه مورد جمینگ واقع شود، UAV به کاربر موبایل کمک می‌کند تا پیام‌ها را از طریق یک ایستگاه پایه پشتیبان به سرور بفرستد.

بسته به SINR و نرخ خطای بیت^۱ (BER) که از ایستگاه پایه دریافت می‌شود، UAV در مورد سطح توان رله تصمیم می‌گیرد تا بهره یعنی (تفاوت هزینه SINR و هزینه رله) را حداکثر نماید. سطح توان رله می‌تواند به عنوان عمل‌های UAV در نظر گرفته شود و SINR و BER نیز وضعیت‌ها (حالت‌های) آن هستند. همچنین حالت یا وضعیت بعدی که توسط UAV مشاهده می‌شود از همه وضعیت‌ها و عمل‌های قبلی مستقل است و مسئله به عنوان یک MDP فرمول‌بندی می‌شود. برای دستیابی سریع به سیاست بهینه رله برای UAV، DQL مبتنی بر CNN به کار برده شده است. نتایج شبیه‌سازی در [۴۲] نشان می‌دهد که روش DQL ارائه شده می‌تواند با تنها دویست برهه زمانی به سیاست بهینه همگرا شود که 83.3% کمتر از روش رله مبتنی بر Q-learning است [۴۳]. علاوه بر این روش DQL می‌تواند BER را نسبت به روش رله UAV مبتنی بر WoLFPHC^۲ را 46.6% کاهش دهد [۴۴].

در روش ارائه شده در [۴۲] فرض می‌شود که رله UAV به اندازه کافی از ناحیه جمینگ فاصله دارد. همان‌طور که در شکل ۱۲۳ نشان داده شده است، مهاجم می‌تواند یک UAV هک شده را نزدیک به رله UAV برای ایجاد حمله جمینگ به آن مورد استفاده قرار دهد. با فرض چنین سناریویی، در [۴۵] نشان داده شده که DQL هنوز هم می‌تواند برای حل مسئله تهاجم به کار رود. مدل سیستم بر پایه امنیت لایه فیزیکی است و شامل یک UAV و یک مهاجم می‌باشد. مهاجم از موردی که در [۴۲] در نظر گرفته شده، باهوش‌تر است. به این معنی که مهاجم کانال‌هایی را که UAV برای ارتباط با ایستگاه پایه در برهه‌های زمانی قبلی مورد استفاده قرار داده را مشاهده کرده و سطوح توان جمینگ را بر روی کانال‌های هدف انتخاب می‌کند. در نتیجه لازم است تا UAV یک سیاستی برای تخصیص توان پیدا کند یعنی سطوح توانی را بر روی کانال‌ها به گونه‌ای ارسال کند که ظرفیت امنیت ارتباطات بین UAV و ایستگاه پایه حداکثر شود. همانند [۴۲]، DQL مبتنی بر CNN به کار برده شده که UAV را قادر می‌سازد اعمالش (یعنی ارسال سطوح توان روی کانال‌ها) را بر اساس وضعیتش (یعنی سطح توان جمینگ مهاجم در آخرین برهه زمانی) انتخاب نماید. پاداش تفاوت بین ظرفیت امنیت UAV و ایستگاه پایه و هزینه مصرف توان خواهد بود.


نتایج شبیه‌سازی در [۴۵] نشان می‌دهد که DQL ارائه شده می‌تواند بهره UAV را تا 13% نسبت به روش پایه‌ای [۴۶] که از روش WoLFPHC برای جلوگیری از حمله استفاده می‌کند بهبود بخشد. همچنین نرخ ایمنی UAV یعنی احتمال اینکه UAV مورد حمله قرار بگیرد با استفاده از روش DQL ارائه شده 7% بالاتر از روش پایه است. با این حال روش DQL ارائه شده تنها بر روی یک سیستم تک UAV اعمال شده است. برای کارهای بعدی لازم است سناریوهایی با چندین UAV در نظر گرفته شوند. در چنین سناریویی انتظار می‌رود سربار محاسباتی بیشتر باشد و الگوریتم‌های DQL با چندین کاربر باید به کار گرفته شوند.

۲-۴-۱۱- کاربرد هوش مصنوعی در آشکارسازی نفوذ

چالش اصلی در پیاده‌سازی روش‌های امنیت در شبکه‌های حسگر بی‌سیم محدودیت منابع است [۴۷]. علاوه بر این برخی از روش‌های حمله با هدف تولید دانشی غیرمنتظره و اشتباه توسط معرفی مشاهدات انحرافی به شبکه انجام می‌گیرند. در شکل ۱۲۴ مفهوم کلی آشکارسازی موارد غیرعادی در سیستم پایش حسگری با استفاده از الگوریتم‌های دسته‌بندی و خوشه‌بندی یادگیری ماشین نشان داده شده است. از آنجایی که بیشتر مشاهدات در دو ناحیه قرار می‌گیرند، نقاطی که با این دو ناحیه همخوانی نداشته باشند به عنوان موارد غیرعادی تلقی می‌شوند.

¹Bit error rate

²Climbing hill



شکل ۱۲۴. آشکارسازی موارد غیرعادی در سیستم پایش با استفاده از روش‌های دسته‌بندی و خوشه‌بندی [۴۷]

الگوریتم‌های یادگیری ماشین برای آشکارسازی اندازه‌گیری‌های پرت و گمراه‌کننده مورد استفاده قرار گرفته‌اند. به‌طور هم‌زمان چندین حمله می‌تواند با استفاده از تحلیل مناسب فعالیت‌های خرابکارانه شناخته‌شده و آسیب‌پذیری‌ها آشکارسازی شود. پیشرفت‌های امنیتی در WSN با استفاده از به‌کارگیری یادگیری ماشین منجر به نتایجی که در ادامه می‌آید شده است:

- حفظ انرژی گره‌ها و افزایش چشمگیر طول عمر با جلوگیری از انتقال داده‌های پرت و گمراه‌کننده
- افزایش قابلیت اطمینان شبکه با حذف قرائت‌های اشتباه و دست‌کاری شده. به‌طور مشابه، پرهیز از کشف دانشی غیرمنتظره که تبدیل به اعمال مهم و معمولاً حساس می‌گردد.
- یادگیری برخط و جلوگیری از حملات خرابکاری و آسیب‌پذیری‌ها (بدون دخالت انسانی)

در این قسمت به مروری بر الگوریتم‌های بر مبنای یادگیری ماشین در مورد برطرف کردن مشکلات امنیتی WSN‌ها پرداخته شده و یک دسته‌بندی از این روش‌ها ارائه شده است. ستون پیش‌بینی داده‌های ازدست‌رفته این قابلیت را نشان می‌دهد که راهکار ارائه شده می‌تواند پیش‌بینی‌هایی از قرائت‌های ازدست‌رفته حسگرها را فراهم نماید.

جدول ۱۲. روش‌های آشکارسازی داده‌های خارج از محدوده در شبکه حسگر بی‌سیم با استفاده از یادگیری ماشین

اهداف	پیچیدگی	غیرمتمرکز یا متمرکز بودن	قابلیت پیش‌بینی داده ازدست‌رفته	الگوریتم یادگیری ماشین	روش‌ها

استفاده از شبکه‌های باور بیزین ^۱ [۴۸]	Bayesian	بلی	غیرمتمرکز	پایین	آشکارسازی داده پرت
استفاده از k-NN [۴۹]	k-NN	بلی	غیرمتمرکز	متوسط	آشکارسازی داده پرت توزیع شده
آشکارسازی حملات پیش‌رونده انتخابی ^۲ با استفاده از SVM [۵۰]	SVM	خیر	متمرکز	متوسط	آشکارسازی خفیه‌های سیاه و حملات پیش‌رونده انتخابی
آشکارسازی داده پرت به صورت برخط [۵۱]			متمرکز	متوسط	آشکارسازی برخط داده پرت
آشکارسازی غیرمتمرکز داده پرت با استفاده از SVM [۵۲]			غیرمتمرکز	پایین	آشکارسازی داده پرت
سیستم آشکارسازی تهاجم [۵۳]			متمرکز	بالا	آشکارسازی تهاجم با استفاده الگوریتم‌های ایمنی و SVM
آشکارسازی خطی داده پرت [۵۴]			غیرمتمرکز	متوسط	آشکارسازی داده پرت وفقی
تحلیل حملات با استفاده از SOM [۵۵]	SOM	خیر	غیرمتمرکز	متوسط	آشکارسازی رفتار غیرعادی


۳-۴-۱۱- کاربرد هوش مصنوعی در حمله سایبرفیزیکی

در سیستم‌های خودکار مانند ITS، مهاجم می‌تواند داده خطایی را در اطلاعات ارسال شده از حسگرها به AV تزریق نماید. AVهایی که اطلاعات تزریق شده را دریافت می‌کنند ممکن است فاصله ایمن بین خود و وسایل دیگر را به‌طور غیردقیقی تخمین

¹Bayesian belief networks

²Selective forward attack

بزند که باعث می‌شود خطر تصادف افزایش یابد. الگوریتم‌های امنیت مخابرات وسایل نقلیه مانند [۵۶] می‌تواند برای به حداقل رساندن تغییرات فاصله به کار برده شوند. با این حال، فرض شده که فعالیت‌های مهاجم در این الگوریتم‌ها ثابت و پایدار است و ممکن است در موارد عملی قابل استفاده نباشند. بنابراین، DQL که AVها را قادر می‌سازد تا فعالیت‌های بهینه را بر پایه مشاهدات متغیر با زمان از فعالیت‌های مهاجم یاد بگیرند می‌تواند مؤثر باشد.




شکل ۱۲۵. مدل دنبال کردن خودرو با حمله سایبر-فیزیکی [۵۸]

اولین کار با استفاده از DQL برای حمله سایبر-فیزیکی در یک ITS را می‌توان در [۵۷] یافت. این سیستم یک مدل دنبال کردن خودرو [۵۸] از شرکت General Motors است که در شکل ۱۲۵ نشان داده شده است. در این مدل، هر AV سرعت خود را بر مبنای اطلاعات اندازه‌گیری شده از نزدیک‌ترین حسگر هوشمند جاده بروز رسانی می‌کند. مهاجم سعی می‌کند تا داده اشتباه را در اطلاعات اندازه‌گیری شده وارد نماید. با این حال، مهاجم به دلیل محدودیت منابعش نمی‌تواند به اندازه‌گیری حسگرهای مختلف به طور یکسان داده اشتباه تزریق کند. در نتیجه AV می‌تواند با انتخاب برداری از وزن‌های اندازه‌گیری شده، اندازه‌گیری با خطای کمتری را انتخاب نماید. هدف مهاجم حداکثر نمودن تغییرات فاصله ایمن بین AV تا AV مجاور است در حالی که هدف AV به حداقل رساندن آن می‌باشد. تقابل مهاجم و AV شبیه یک بازی صفر-جمع^۱ است. در [۵۷] نشان داده شده که DQL می‌تواند برای یافتن استراتژی‌های متعادل به کار رود. به طور مشخص، عمل AV انتخاب یک بردار وزنی است. وضعیت آن نیز شامل عمل‌های قبلی یعنی بردارهای وزنی و مقادیر انحراف قبلی است. از آنجایی که عمل‌ها و انحراف‌ها دارای مقادیر پیوسته‌ای هستند، فضای حالت بی‌نهایت است. بنابراین واحدهای LSTM که قادرند ویژگی‌های مفید را استخراج کنند برای DQL مورد استفاده قرار گرفته‌اند تا فضای حالت را کاهش دهند. نتایج شبیه‌سازی نشان می‌دهند که با استفاده از عمل‌ها و انحراف‌های قبلی برای یادگیری عمل مهاجم، روش DQL ارائه شده می‌تواند انحراف پایدار کمتری را نسبت به روش مبتنی بر فیلتر کالمن تضمین نماید [۵۶]. علاوه بر این با استفاده از واحدهای LSTM، نتایج نشان دادند که روش DQL می‌تواند بسیار سریع‌تر از روش خط پایه^۲ همگرا شود.

^۱Zero-sum game

^۲Baseline



شکل ۱۲۶. آشکارسازی سایبرفیزیکی در سیستم‌های اینترنت اشیاء با استفاده از DQL [۵۹]

کار دیگری که از LSTM برای استخراج ویژگی‌های مفید از اطلاعات اندازه‌گیری شده به منظور شناسایی حمله سایبر-فیزیکی استفاده می‌کند در [۵۹] ارائه شده است. این مدل یک سیستم اینترنت اشیاء شامل یک ابر و یک مجموعه از دستگاه‌های اینترنت اشیاء است. همان‌طور که در شکل ۱۲۶ نشان داده شده است، ادوات IoT سیگنال‌ها را تولید و به سمت ابر ارسال می‌کنند. ابر از سیگنال‌های دریافتی برای تخمین و کنترل عملیات ادوات IoT استفاده می‌نماید. یک مهاجم می‌تواند یک حمله سایبر-فیزیکی را با دست‌کاری سیگنال خروجی مربوط به ادوات IoT به وجود آورد که باعث خطاهای کنترلی در ابر شده و عملکرد سیستم IoT را کاهش می‌دهد. برای آشکارسازی حمله، ابر از واحدهای LSTM استفاده می‌کند که مشخصات تصادفی یا ویژگی‌هایی نظیر هموار بودن، انحراف و درجه اوج^۱ سیگنال ادوات IoT را استخراج می‌کنند. ابر مشخصات را به ادوات IoT بازمی‌فرستد و ادوات IoT این ویژگی‌ها را در سیگنال‌ها قرار می‌دهند. ابر از این ویژگی‌ها برای اعتبارسنجی سیگنال‌های مربوط به ادوات IoT به منظور تشخیص حمله استفاده می‌کند.


الگوریتمی که در [۵۹] ارائه شده، نشانه‌گذاری دینامیک^۲ نامیده می‌شود که می‌تواند حمله سایبر-فیزیکی را آشکار کرده و از حملات استراق سمع نیز جلوگیری کند. با این حال، این الگوریتم به منابع محاسباتی زیادی در ابر برای اعتبارسنجی سیگنال به‌وسیله IoT نیاز دارد. در نتیجه، ابر تنها می‌تواند تعداد محدودی از ادوات آسیب‌پذیر IoT را اعتبارسنجی نماید. ابر می‌تواند با مشاهده وضعیت امنیت دستگاه‌ها، ادوات IoT آسیب‌پذیر را انتخاب کند. با این وجود، این امر ممکن است عملی نباشد زیرا ادوات IoT ممکن است وضعیت امنیتی خود را گزارش ندهند. به همین دلیل در [۶۰]، روشی با استفاده از DQL پیشنهاد شده که ابر را قادر می‌سازد با داشتن اطلاعات ناقص در مورد اینکه کدام ادوات IoT را اعتبارسنجی کند، تصمیم بگیرد. از آنجایی که ادوات IoT با داده ارزشمندتر با احتمال بیشتری مورد حمله قرار می‌گیرند، پاداش به صورت تابعی از ارزش داده‌های ادوات IoT تعریف شده است. وضعیت ابر شامل عمل‌های تهاجمی مهاجم روی ادوات IoT در برهه‌های زمانی گذشته است. اعمال مهاجم روی ادوات IoT می‌تواند توسط الگوریتم نشانه‌گذاری دینامیک به دست آید. سپس DQL از یک واحد LSTM برای پیدا کردن یک سیاست بهینه استفاده می‌کند. ورودی واحد LSTM وضعیت یا حالت ابر و خروجی آن احتمالات حمله به ادوات IoT است. با استفاده از مجموعه داده واقعی، نتایج شبیه‌سازی نشان دادند که روش DQL ارائه شده می‌تواند عملکرد ابر را 30% نسبت به حالتی که ابر ادوات IoT را با احتمال برابری انتخاب می‌کند، افزایش دهد.

¹Kurtosis

²Dynamic watermarking

۴-۴-۱۱- کاربرد هوش مصنوعی در حفظ اتصال

سیستم‌های چند رباته مانند شبکه همکاری چند UAV در بسیاری از حوزه‌ها مانند حوزه نظامی بخصوص آشکارسازی دشمن به طور گسترده‌ای مورد استفاده قرار گرفته‌اند. همان طور که در شکل ۱۲۷ نشان داده شده است، در سیستم همکاری چند UAV، اتصال بین ربات‌ها که همان UAVها هستند برای ارتباطات و تبادل اطلاعات لازم و ضروری است.



شکل ۱۲۷. حفظ اتصال یک شبکه چند UAV [۶۱]

برای حل مشکل حفظ اتصال، الگوریتم APF^1 مورد استفاده قرار می‌گیرد [۶۱]. با این حال، این الگوریتم نمی‌تواند زمانی که ربات‌ها در حال انجام مأموریت در محیط متغیر و پیچیده هستند، به طور مستقیم اعمال شود. از آنجایی که DQL اجازه می‌دهد هر ربات تصمیمات پویایی را بر مبنای وضعیت خودش اتخاذ کند، می‌تواند به صورت مؤثری در سیستم‌های چند رباته برای حفظ اتصال استفاده شود. چنین روشی در [۶۲] ارائه شده که شامل دو ربات یا UAV است که یکی هدایت‌کننده و دیگری هدایت‌شونده است. در این مدل، یک کنترل مرکزی که یک ایستگاه پایه زمینی است سرعت دنبال‌کننده را به گونه‌ای تنظیم می‌کند که دنبال‌کننده در همه زمان‌ها در محدوده برقراری ارتباط با هدایت‌کننده قرار داشته باشد. مسئله حفظ اتصال می‌تواند به صورت یک MDP فرمول‌بندی شود. عامل^۲، ایستگاه پایه است و وضعیت‌ها مکان و سرعت نسبی هدایت‌کننده نسبت به دنبال‌کننده می‌باشند. فضای عمل شامل مقادیر سرعت ممکن دنبال‌کننده می‌شود. اگر دنبال‌کننده در محدوده هدایت‌کننده قرار داشته باشد اتخاذ یک عمل یک پاداش به اندازه +1 در پی دارد و در غیر این صورت مجازاتی به اندازه -1 در پی خواهد داشت. یک DQN با استفاده از FNN، ایستگاه پایه را قادر می‌سازد تا سیاست بهینه را برای به حداکثر رساندن پاداش جمع‌شونده^۳ مورد انتظار یاد بگیرد. ورودی DQN شامل وضعیت‌های دو ربات و خروجی آن فضای عمل دنبال‌کننده است. نتایج شبیه‌سازی نشان می‌دهند که روش پیشنهادی می‌تواند اتصال بهتری را بین دو ربات نسبت به روش APF برقرار کند. با این حال، لازم است تا یک سناریوی عمومی با بیش از یک هدایت‌کننده و دنبال‌کننده نیز مورد بررسی قرار گیرد.

¹Artificial Potential Field

²Agent

³Cumulative reward

با در نظر گرفتن سناریوی عمومی، در [۶۳] راه حل حفظ اتصال بین چندین هدایت کننده و چندین دنبال کننده ارائه شده است. سیستم ربات‌ها زمانی کاملاً متصل است که هر دو رباطی با استفاده از یک لینک مستقیم یا چند لینک غیرمستقیم به یکدیگر وصل شوند. برای بیان اتصال در چنین سیستمی، مفهومی به نام اتصال جبری^۱ [۶۴] معرفی شده است که دومین مقدار ویژه کوچک ماتریس لاپلاسیان^۲ می‌باشد. سیستم ربات‌ها در صورتی متصل است که اتصال جبری سیستم مثبت باشد. بنابراین مسئله تنظیم سرعت دنبال کنندگان به گونه‌ای است که اتصال جبری در طول برهه‌های زمانی مثبت باشد. این مسئله می‌تواند به صورت یک MDP فرمول بندی شود که در آن عامل، ایستگاه پایه، وضعیت یک ترکیبی از وضعیت‌های همه ربات‌ها و عمل مجموعه‌ای از مقادیر ممکن سرعت برای دنبال کنندگان است. اگر که اتصال جبری سیستم افزایش یابد یا باقی بماند، پاداش برابر 1+ و در صورتی که اتصال جبری کاهش یابد مجازات برابر 1- خواهد بود. برای این مسئله نیز DQN مورد استفاده قرار گرفته و به دلیل فضای بزرگ عمل دنبال کنندگان شبکه عصبی بازیگر-منتقد^۳ [۶۵] به کار رفته است. نتایج شبیه سازی نشان می‌دهند که دنبال کنندگان همیشه از حرکت هدایت کنندگان تبعیت می‌کنند حتی اگر مسیر حرکت هدایت کنندگان به صورت پویا تغییر کند. با این حال روش DQN ارائه شده به دلیل حضور دنبال کنندگان بیشتر، نیاز به زمان بیشتری برای همگرا شدن نسبت به روش ارائه شده در [۶۲] دارد.

در روش‌های ارائه شده در [۶۲، ۶۳] حداقل فاصله بین هدایت کنندگان و دنبال کنندگان در نظر گرفته نشده است و در صورتی که فاصله بین آن‌ها خیلی کم باشد می‌توانند به یکدیگر برخورد کنند. در نتیجه لازم است که ایستگاه پایه حداقل فاصله بین آن‌ها را نیز تضمین نماید. همان طور که در [۶۶] ارائه شده است، یک راه حل گنجانیدن حداقل فاصله در پاداش می‌باشد. در این صورت اگر هدایت کننده به دنبال کننده بسیار نزدیک باشد، پاداش سیستم با توجه به حداقل فاصله کاهش می‌یابد. سپس با استفاده از الگوریتم DQL ارائه شده در [۶۳]، ایستگاه پایه عمل‌های مناسب مانند چرخش به راست و چپ را برای به حداکثر رساندن پاداش جمع شونده یاد می‌گیرد.

هنگامی که ایستگاه‌های پایه به صورت متراکم به کار می‌روند، UAVها یا کاربران موبایل به یک دست به دست^۴ کردن مستمر برای حفظ اتصال نیازمندند. دست به دست کردن مستمر سربار مخابراتی و مصرف انرژی کاربران موبایل را افزایش می‌دهد و در جریان‌های داده وقفه می‌اندازد. بنابراین لازم است تا نرخ دست به دست شدن در یک حد مناسب نگه داشته شود. در [۶۷] راه‌حلی برای مسئله تصمیم‌گیری دست به دست شدن در یک شبکه خیلی متراکم ارائه شده است. مدل شبکه از کاربران سیار متعدد، SBS^۵ و یک کنترل کننده مرکزی تشکیل شده است. در هر برهه زمانی، لازم است تا کاربر SBS خود را انتخاب نماید. فرآیند تصمیم‌گیری دست به دست شدن می‌تواند به عنوان یک MDP مدل شود و DQL برای پیدا کردن سیاست دست به دست شدن بهینه برای هر کاربر به منظور به حداقل رساندن تعداد اتفاقات دست به دست شدن همراه با تضمین انتقال داده به کار رود. پاداش به صورت اختلاف بین نرخ داده کاربر و انرژی مصرفی آن برای فرآیند دست به دست شدن تعریف شده است. با تراکم بالای کاربران، DQL با استفاده از A3C و LSTM برای پیدا کردن سیاست بهینه در مدت زمان آموزش کوتاه مورد استفاده قرار گرفته است. نتایج شبیه سازی نشان می‌دهند که روش DQL ارائه شده نسبت به الگوریتم UCB^۶، می‌تواند به انتقال بهتر و نرخ پایین تر دست به دست شدن در مدت زمان آموزش مشابه دست یابد.

برای بهبود قابلیت اطمینان ارتباطات بین SBSها و کاربران موبایل، SBSها باید بتوانند خرابی‌های شبکه را به طور خودکار و به صورت خود بازیابی^۷ مدیریت کنند. در [۶۸] از DQL برای تنظیمات پارامتری بهینه بر اساس مشاهدات عملکرد شبکه استفاده

¹Algebraic connectivity²Laplacian³Actor-critic⁴Handover⁵Small base station⁶Upper confidence bandit⁷Self healing

شده است. این مدل شبکه 5G شامل یک MBS است. MBS یک واحد مسئول است که خطاهای شبکه نظیر خطای ناشی از تنوع مسیر انتقال و خطاهای تغییر زاویه آنتن به خاطر وزش باد را مدیریت می‌کند. این خطاها وضعیت MBS را نشان می‌دهند که تعداد هشدارهای فعال نیز هست. بر اساس هشدارهای، MBS اعمالی را شامل (۱) فعال کردن تنوع انتقال (۲) تنظیم زاویه آنتن به حالت پیش فرض، اتخاذ می‌نماید. پاداشی که MBS دریافت می‌کند بسته به تعداد خطاهایی که رخ می‌دهد، شامل مقادیر 1-، 0 و 1+ است. DQL برای یادگیری سیاست بهینه استفاده شده و نتایج شبیه‌سازی نشان می‌دهد که روش DQL ارائه شده می‌تواند انتقالی نزدیک به روش خودبازایی مبتنی بر oracle یعنی روش UPB^۱ داشته باشد.

۵-۱۱- کاربرد هوش مصنوعی در امنیت صنعت برق

در طی چند دهه گذشته، عملیات سیستم برق به طور مداوم در حال مدرن سازی است که از آن جمله می‌توان ادغام انرژی‌های تجدیدپذیر و سیستم‌های ذخیره‌سازی (RES)، بازار آزاد، دستگاه‌های اندازه‌گیری و فناوری‌های ارتباطی متعدد را نام برد. در حالی که مدرن نمودن شبکه به میزان زیادی به توزیع انرژی ایمن‌تر، قابل اعتمادتر و پاک‌تر کمک نموده اما چالش‌های جدیدی را نیز برای امنیت و ثبات شبکه ایجاد کرده است. وابستگی بیش از حد به برنامه‌های کاربردی مدرن در شبکه برق مانند سیستم تخمین حالت، سیستم کنترل نظارتی و دستیابی به داده‌ها^۲ (SCADA) و واحد اندازه‌گیری فازوری^۳ (PMU) بر روی فناوری‌های ارتباطی باز از جمله اینترنت، شبکه‌های برق را در معرض آسیب‌پذیری‌ها و تهدیدهای مختلف قرار داده است. به عنوان یک زیرساخت مهم، عملکرد ایمن و پایدار سیستم برق معمولاً با بالاترین اولویت از سوی دولت‌ها و سرمایه‌گذاران صنعتی مورد توجه قرار می‌گیرد زیرا فعالیت‌های مختلف اجتماعی، سیاسی و اقتصادی با سیستم برق کشور بسیار مرتبط هستند. دشمنان می‌توانند به گره‌های شبکه دسترسی پیدا کرده و اندازه‌گیری‌ها و همچنین دستورات کنترلی را تغییر دهند و در نتیجه بی‌ثباتی عملیات شبکه برق، خاموشی و خسارات مالی ایجاد کنند و حتی در برخی شرایط، امنیت ملی را به خطر اندازند.

علاوه بر این، رشد فزاینده تقاضای انرژی، ورود برخی از بارهای متغیر، تغییرات عمده در توپولوژی شبکه، فشارهای رو به افزایش در خطوط انتقال و غیره به طور خطرناکی سیستم برق را به سمتی خارج از مرزهای پایداری سوق می‌دهد که چالش‌ها و مسائل بی‌ثباتی و اختلالات کیفیت برق^۴ (PQD) را بوجود می‌آورد. در سال‌های اخیر، این نگرانی‌ها در مورد بی‌ثباتی‌ها و اختلالات توجه جوامع صنعتی و دانشگاهی را به خود جلب کرده است زیرا مهمترین دلایل قطع شبکه، خسارات اقتصادی، عملکرد نامناسب و خرابی تجهیزات هستند. براساس گزارش موسسه تحقیقات برق الکتریکی^۵ (EPRI)، بحران قطع برق سالانه ۱۰۴ تا ۱۶۴ میلیارد دلار خسارت اقتصادی ایجاد می‌کند [۶۹]. در زمینه تهدیدها و اثرات اختلالات، ناامنی‌ها و ناپایداری‌ها بر روی شبکه برق مقالات زیادی وجود دارد [۷۰-۷۳]. علارقم نشان دادن عملکرد رضایتبخش در شبکه قدیمی برق، روش‌های مرسوم برای نیازهای تحلیلی شبکه برق مدرن و پیچیده از لحاظ محاسباتی سنگین، گرانبه و وقت گیر هستند. در سال‌های اخیر، از تکنیک‌های یادگیری ماشین^۶ (MLT) به طور گسترده‌ای در مدل سازی و نظارت بر کاربردهای پیچیده استفاده شده است. MLT‌های متعددی مانند شبکه عصبی مصنوعی (ANN)، درخت تصمیم‌گیری^۷ (DT)، تجزیه و تحلیل اجزای اصلی^۸ (PCA) و غیره در ظرفیت‌های مختلف شامل ارزیابی امنیت و پایداری سیستم برق ارائه شده‌اند. بر خلاف روش‌های سنتی، ثابت شده است که هنگامی که MLT‌ها در مطالعات طبقه بندی مورد استفاده قرار می‌گیرند از نظر محاسباتی قدرتمند، سیستماتیک و به میزان

¹Upper performance bound

²Supervisory Control and Data Acquisition

³Phasor Measurement Unit

⁴Power Quality Disturbances

⁵Electrical Power Research Institute

⁶Machin Learning Techniques


⁷Decision Tree

⁸Principle Component Analysis

زیادی قابل اعتماد هستند. همچنین نتایج مختلف شبیه‌سازی در کارهای تحقیقاتی سیستم برق نشان داده است که MLT توانایی یادگیری و درک ویژگی‌های تغییر بارهای مختلف، داده‌های شبکه و غیره را که مختص ماهیت پویای سیستم برق مدرن است، دارا می‌باشند.

۱-۵-۱- امنیت در صنعت برق

همان‌طور که در شکل ۱۲۸ نشان داده شده است، براساس گزارش‌های موسسه ملی استانداردها و فناوری^۱ (NIST)، هفت حوزه برای شبکه برق هوشمند تعریف شده است که شامل تولید، توزیع، انتقال، بازار برق، عملیات، ارائه‌دهندگان خدمات و مشترکین می‌شود [۷۵].



شکل ۱۲۸. ساختار شبکه برق هوشمند بر اساس استاندارد NIST [۷۴]

• بازار برق

در بسیاری از بازارهای فعلی برق، تعداد روزافزون بازیگران و تعداد پیوندهای ارتباطی آسیب پذیر، خطری برای شبکه برق می‌باشد. تعداد شرکتهای تولید، توزیع و خرده‌فروشان به طور قابل توجهی افزایش یافته است. در مدل بازار انحصاری سنتی، شبکه‌های تولید و انتقال بیشتر متعلق به یک شرکت بودند، بنابراین ارتباطات آن‌ها از طریق یک اینترنت نسبتاً امن انجام می‌شد. با این حال، گسترش نقش‌ها در شبکه‌های برق که در مدل فعلی مشاهده می‌شود، دشواری ارتباطات اینترنت را افزایش داده است. بنابراین مهاجمان می‌توانند فرصت‌های بیشتری را برای تأثیرگذاری بر مناقصه‌های انرژی و جمع‌آوری منابع انرژی توزیع شده از طریق چنین عملیات ارتقاء یافته در ارتباطات اینترنتی به دست آورند.

• عملیات

حوزه عملیات، شبکه پیچیده دستگاه‌های ارتباطی را حفظ می‌کند و بنابراین بیشترین خطر را در تمام حوزه‌ها دارد. سیستم‌های SCADA در حوزه عملیات با تمام حوزه‌های دیگر ارتباط برقرار می‌کنند، بنابراین حملات علیه شبکه SCADA می‌تواند عواقب

¹National Institute of Standards and Technology


سختی را به دنبال داشته باشد. با حمله به سیستم‌های SCADA، مهاجمان می‌توانند توزیع جریان برق را تغییر داده و برآورد وضعیت سیستم را تحت تأثیر قرار دهند. علاوه بر این، حتی ممکن است مهاجمان کنترل شبکه‌های SCADA را نیز بدست آورند و باعث خرابی‌های ویرانگر در سراسر شبکه برق شوند. خاموشی اوکراین در سال ۲۰۱۵ یکی از نمونه‌های این نوع حمله است.

• سیستم‌های تولید

مهاجمان برای ایجاد هرج و مرج، در حین کار تجهیزات به سیستم‌های تولیدی حمله می‌کنند. این نوع حمله می‌تواند باعث شود دستگاه در زمانبندی نامناسب عمل کند یا به سادگی اصلاً عمل نکند. هدف دیگر این حملات از بین بردن توازن قدرت بین طرف عرضه و تقاضا است. این وضعیت به دلیل افزایش تعداد نیروگاه‌های تجدیدپذیر بیشتر تکرار شده است [۷۶]. برخلاف نیروگاه‌های سنتی، نیروگاه‌های تجدیدپذیر به منابع انرژی در مکان‌های بسیار توزیع شده متکی هستند. به عنوان مثال، سلول‌های خورشیدی معمولاً در اطراف ساختمان‌ها یا پشت بام‌ها واقع شده‌اند، در حالی که سوخت‌های زیستی به محیط‌های خاصی مانند مزارع بستگی دارد. چنین توزیع جغرافیایی خطر حمله به اتصالات ارتباطی را افزایش می‌دهد. به علاوه، هزینه راه‌اندازی کمتر، توزیع گسترده و سهولت ساخت نیروگاه‌های تجدیدپذیر باعث می‌شود که تعداد چنین نیروگاه‌هایی بیشتر از نیروگاه‌های سنتی باشد. افزایش تولید برق تجدیدپذیر توزیع شده، تعداد تجهیزات ارتباطی را افزایش می‌دهد و این سیستم‌های تولیدی را ذاتاً در معرض حملات سایبری قرار می‌دهد.

• حوزه‌های توزیع، مشترکین و ارائه‌دهندگان خدمات

حوزه‌های توزیع، مشترکین و ارائه‌دهندگان خدمات، اهداف اصلی برای حملات حریم خصوصی هستند. سیستم‌های اطلاعاتی مشترکین، شرکت‌های واسطه، کنترل‌های هوشمند و زیرساخت نظارت پیشرفته^۱ (AMI)، زیرساخت‌های پشتیبانی جدیدی با قابلیت ارتباط دو طرفه هستند [۷۷]. همچنین وسایل نقلیه الکتریکی و خانه‌های هوشمند محصولات جدیدی هستند که مقدار زیادی داده‌های خصوصی مشترکین را جمع‌آوری می‌کنند. حملات علیه هر یک از این سیستم‌ها می‌تواند منجر به نشت اطلاعات مشتری و در نتیجه صورتحساب نادرست شود.



شکل ۱۲۹. ادوات در معرض خطر حملات سایبری در شبکه برق [۷۴]

¹Advanced Monitoring Infrastructure

شبکه برق بزرگ‌ترین سیستم ساینر-فیزیکی در جهان است. یک سیستم ساینر فیزیکی از دو نوع تجهیزات تشکیل شده است: (۱) تجهیزات ساینری و (۲) تجهیزات فیزیکی. تجهیزات فیزیکی آن دسته‌ای از قسمت‌های سیستم هستند که به طور مستقیم به جهان فیزیکی متصل می‌شوند. تجهیزات باقیمانده که از طریق ارتباطات و محیط‌های مخابراتی با دنیای فیزیکی در ارتباط هستند، تجهیزات ساینری می‌باشند. تجهیزات شبکه برق را می‌توان به طور کلی به دو دسته تجهیزات کاربرد قدرت و زیرساخت‌های پشتیبانی نیز تقسیم نمود [۷۸]. کاربردهای قدرت منظور کاربردهایی است که با جهان فیزیکی در ارتباط است و وظایف اصلی به منظور برطرف نمودن تقاضای انرژی کاربران را برعهده دارد و به عنوان بخش فیزیکی شبکه برق در نظر گرفته می‌شود مانند شبکه انتقال و توزیع، نیروگاه‌ها و غیره که کیفیت برق تامین شده برای مشترکین را حفظ می‌کنند. بخش ساینری زیرساخت پشتیبانی، عملیات روزانه در شبکه قدرت را پشتیبانی و حفظ می‌کند. این دسته شامل سیستم‌های پایش، جمع‌آوری داده، سیستم‌های پردازش و شبکه‌های مخابراتی می‌شود. در شکل ۱۲۹ تجهیزات ساینری شبکه برق که در معرض خطر حمله ساینری هستند نشان داده شده است.

۲-۵-۱۱ - مهمترین زمینه‌های امنیت و پایداری در صنعت برق

حوادث اخیر در سراسر جهان نشان داده است که شبکه برق با گستردگی جغرافیایی با بحران‌های امنیتی و پایداری مختلفی روبرو است که اقدامات جامع محافظتی و پیشگیرانه را می‌طلبد. از نظر تاریخی، اطمینان از امنیت و ثبات سیستم قدرت همیشه یک چالش بوده است و معمولاً براساس گزارشات مربوط به قطعی یا نوسان از مصرف کنندگان به اپراتورها مورد پایش قرار می‌گرفته است.

علیرغم نوآوری‌های بی‌شماری که در شبکه برق مدرن شکل گرفته است، شواهد و گزارش‌های مختلف نشان داده است که سیستم برق مدرن در سطح جهانی با تعداد بالاتری از چالش‌های امنیتی و ثبات روبرو شده است. همچنین، ادغام زیرساخت‌های متعدد اینترنت اشیا و دیگر ابزارهای پیشرفته وابسته به سیستم برق مدرن، باعث ایجاد بحران امنیت و ثبات در شبکه می‌شوند زیرا برخی از پروتکل‌ها و استانداردها در برابر حملات ساینری و نفوذ بسیار آسیب پذیر هستند. علاوه بر این، تلاش مداوم برای صنعتی شدن و همچنین ساختن شهرهای هوشمند باعث ایجاد برخی از اختلالات در سیستم برق می‌شود. افزایش تقاضای انرژی، تولید و انتقال، شبکه برق را به سمت و مرزهای پایداری عملیاتی سوق می‌دهد و عواقب آن خرابی تجهیزات، بی‌ثباتی و PQDها است.

تهدیدات شناخته شده امنیتی و پایداری شبکه برق را می‌توان به چهار دسته اصلی زیر تقسیم نمود:

- اختلالات کیفیت توان (PQD)
- تهدیدات و آسیب‌پذیری‌های شبکه SCADA
- ارزیابی پایداری گذرا^۱ (TSA)
- ارزیابی پایداری ولتاژ^۲ (VSA)

۱-۲-۵-۱۱ اختلالات کیفیت توان

اختلالات کیفیت توان را می‌توان به عنوان انحراف ناگهانی آشکار در اندازه ولتاژ/جریان، زاویه فاز و فرکانس از حد استاندارد تعریف کرد. این اختلالات بیشتر به دلیل وارد کردن بارهای غیر خطی، دستگاه‌های سوئیچینگ، یکسوسازها، اینورترها و غیره به

¹Transient Stability Assessment

²Voltage Stability Assessment

سیستم برق ایجاد می شود. همانطور که در [۷۹] توضیح داده شده است، ادغام مداوم بارهای مزاحم و RES باعث ایجاد خطرات خرابی و عملکرد نامناسب ماشین آلات در سطح تولید، انتقال و مصرف انرژی می شود. انواع اثرات PQD شامل افت ولتاژ، اعوجاج هارمونیک، قطعی، سوسو زدن و غیره است. همچنین این اثرات می توانند مشکلات جدی شامل نقص تجهیزات، طول عمر کوتاه و خرابی ها را بوجود آورند. مطابق با گزارش EPRI، از کل بحران قطع برق، مسائل مربوط به PQ تقریباً ۱۵ درصد از برآورد خسارات اقتصادی سالانه ۱۰۴ تا ۱۶۴ میلیارد دلار را تشکیل می دهد [۶۹]. بنابراین، کاهش PQD همچنان به طور گسترده ای مورد توجه جامعه تحقیقاتی سیستم قدرت قرار دارد.

۲-۲-۵-۱۱ تهدیدات و آسیب پذیری های شبکه SCADA

زیرساخت های حیاتی مانند شبکه برق، خطوط لوله انتقال نفت و گاز، توزیع آب و غیره توسط سیستم های SCADA کنترل می شوند که اجزای این سیستم ها را به عنوان یک شبکه از طریق فناوری های ICT به یکدیگر متصل می کند. همانطور که در شکل ۱۳۰ نشان داده شده است، ساختار سیستم SCADA برای شبکه برق اساساً از چهار قسمت عملیاتی اصلی تشکیل شده است [۸۰]:

- دستگاه های "میدانی" مانند حسگرها برای تشخیص وضعیت تجهیزات مورد نظر SCADA (سطح توان، فشار و غیره) و کنترل آنها طبق دستورات دریافت شده
- دستگاه های "ایستگاه های راه دور" که شامل واحدهای ترمینال راه دور^۱ (RTU) و کنترل کننده های منطقی قابل برنامه ریزی^۲ (PLC) هستند. هدف از عملکرد آنها ارسال و دریافت داده های دیجیتالی بین مراکز کنترل و دستگاه های میدانی است.
- دستگاه های کنترل مرکزی که شامل MTU^۳ هایی هستند که به ادوات ایستگاه راه دور فرمان می دهند.
- رابط بین انسان و ماشین^۴ (HMI): دستگاه هایی که داده های پردازش شده را معمولاً از طریق رابط کاربری گرافیکی به اپراتورها ارائه می دهند. با استفاده از رابط، اپراتورها می توانند فرایندهای SCADA را رصد کرده و با آنها ارتباط برقرار کنند.

از نظر تاریخی، هنگامی که سیستم های SCADA برای اولین بار مورد استفاده قرار گرفتند، تهدید عمده خرابکاری از طریق تخریب فیزیکی سخت افزار برنامه بود زیرا سیستم های قدیمی SCADA دارای شبکه های خصوصی و اختصاصی بودند که با فواصل هوایی جداکننده محافظت می شدند. با این وجود، طی دو دهه گذشته، شبکه های SCADA به دستگاه های اینترنت اشیا مجهز شده اند که گاهی اوقات از طریق کانال های باز ارتباط برقرار می کنند که به تبع شبکه ها را در معرض آسیب پذیری های متعدد و حملات سایبری مبتنی بر شبکه قرار می دهند [۸۰]. پیش بینی می شود این تهدیدها و حملات در نزدیکترین زمان با نرخ هندسی تشدید شود زیرا مهاجمان و نفوذگران زیرساخت های انرژی (که مسلماً مهمترین زیرساخت حیاتی نیز هست) را راهی سودآور برای جلب توجه می یابند. تیم پاسخ سایبری اضطراری سیستم های کنترل صنعتی (ICS-CERT) اعلام کرد که از ۲۴۵ حمله سایبری ثبت شده در زیرساخت های حیاتی در سال ۲۰۱۴، ۷۹ مورد مربوط به بخش انرژی بوده است. بر اساس انگیزه ها و علت حملات، تهدیدات و حملات SCADA را می توان به چهار دسته تقسیم بندی نمود:


¹ Remote Terminal Units

² Programmable Logic Controllers

³ Master Terminal Unit

⁴ Human Machine Interface

- داخلی / مخرب: اپراتورها، کارمندان یا پیمانکاران با انگیزه‌های عمدی باعث ایجاد فاجعه در شبکه SCADA می‌شوند که مثال شناخته شده آن حمله کرم stuxnet است که توسط یک مهندس از طریق یک درایو قابل جابجایی به سیستم وارد شده بود.
- داخلی / غیرمخرب: اپراتور مرتکب یک اشتباه تصادفی می‌شود که به زیرساخت‌های شبکه برق آسیب می‌رساند، به عنوان مثال آلوده شدن نیروگاه هسته‌ای اوهایو دیویس-بس^۱ به کرم "Slammer" در سال ۲۰۰۳ که منجر به غیرفعال شدن نیروگاه برای ساعت‌ها شد.
- خارجی / فرصت طلب: هک‌هایی که به دنبال یک چالش یا سرگرمی هستند.
- خارجی / عمدی: این می‌تواند به عنوان حمله توسط یک گروه سازمان‌یافته خارجی توصیف شود که آسیب پذیری‌های شبکه برق کشوری را هدف قرار می‌دهد مانند حمله سایبری ۲۰۱۵ به شبکه برق اوکراین که در آن هکرها به روسیه متصل بودند.



شکل ۱۳۰. معماری سیستم SCADA [۸۱]


۳-۲-۵-۱۱ ارزیابی پایداری گذرا^۲ (TSA)

وقایع مختلف مانند برخی از خاموشی‌های خاص در ایالات متحده و برخی از کشورهای اروپایی و آسیایی نشان داده است که بی‌ثباتی ناشی از RES، افزایش تقاضای انرژی و اختلالات، نیاز به ابزارهای ارتقاء یافته در نظارت بر امنیت پویای سیستم قدرت مدرن را بالا برده است. مطابق [۸۲]، ارزیابی ظرفیت یک شبکه برق برای مقاومت و نجات یافتن از یک مجموعه شرایط احتمالی

¹Ohio Davis-Besse

²Transient Stability Assessment

و غیرمترقبه به یک شرایط پایدار قابل قبول، ارزیابی امنیت پویا^۱ (DSA) نامیده می‌شود. همان‌طور که در شکل ۱۳۱ نشان داده شده است، پایداری گذرا، پایداری ولتاژ و پایداری فرکانس به عنوان دسته‌های اصلی DSA شناخته می‌شوند.



شکل ۱۳۱. دسته‌بندی ارزیابی امنیت پویا [۸۱]

ارزیابی پایداری گذرا (TSA) قضاوت تحلیلی اپراتورهای سیستم را در مورد عملکرد دینامیکی شبکه برق تحت شرایط غیرمترقبه مختلف فراهم می‌کند. همان‌طور که در [۸۳] تعریف شده است، پایداری گذرا توانایی تمام ژنراتورها برای حفظ هماهنگی پس از یک اختلال شدید مانند خرابی یا از دست دادن ناگهانی ژنراتور، بار یا سایر اجزا است. بی‌ثباتی گذرا یکی از دلایل عمده سناریوهای ناپایداری شبکه برق از جمله جزیره‌ای شدن و خاموشی‌های گسترده‌ای است که چندین سال پیش در ایران و روسیه تجربه شده است [۸۴]. اپراتورهای سیستم باید بتوانند شرایط پایداری سیستم برق را ارزیابی کنند و در صورت لزوم، اقدامات صحیحی را برای حفظ پایداری مورد نیاز برای جلوگیری از خاموشی و خرابی سازمان دهند. به طور سنتی، TSA از نظر ریاضی با حل مجموعه‌ای از معادلات جبری دیفرانسیل^۲ (DAE) غیرخطی با ابعاد بالا مطابقت دارد. روش‌های مرسوم TSA مانند شبیه سازی حوزه زمان^۳ (TDS) و روش‌های مستقیم (به عنوان مثال TEF^۴، EEAC^۵ و Lyapunov exponent) به طور گسترده‌ای در منابع مختلف ارائه شده است. به طور کلی، محدودیت اصلی این روشها، محاسبات گسترده برای ارزیابی منحنی‌های چرخش برای همه ژنراتورها، برای سطوح مختلف بار، خطاها و زمان‌های ترخیص^۶ است. بنابراین، روش‌های متداول TSA مطابق با الزامات مورد نیاز شبکه برق مدرن نیستند.

۴-۵-۱۱ ارزیابی پایداری ولتاژ

¹Dynamic Security Assessment

²Differential Algebraic Equation

³Time Domain Simulation

⁴Transient Energy Function

⁵Extended Equal-Area Criterion

⁶Clearance times

در حالی که در بحث امنیت پویای شبکه بیشتر توجه به پایداری گذرا معطوف شده است، یکی دیگر از موضوعات مهم امنیت پویا که در شبکه برق مدرن به طور فزاینده‌ای مهم است، پایداری ولتاژ می‌باشد. برخلاف پایداری گذرا که بیشتر با هماهنگی و سنکرون‌سازی ژنراتورها سروکار دارد، پایداری ولتاژ بیشتر به پویایی بار و همچنین مدیریت توان راکتیو گره خورده است [۸۵]. پایداری ولتاژ بیانگر توانایی سیستم قدرت در حفظ ولتاژهای باس در مقادیر قابل قبول پس از ایجاد اختلال در شرایط عملیاتی مشخص است [۸۶]. پروفایل ولتاژ یک شبکه برق معمولاً در یک محدوده پایدار حفظ می‌شود، اما وقتی شبکه برق با خطا یا اختلال قابل توجهی روبرو می‌شود، ممکن است چندین حادثه رخ دهد. این حوادث عبارتند از: پروفایل ولتاژ ممکن است پایداری خود را از دست بدهد و در نتیجه سرعت موتورهای القایی به شدت کاهش می‌یابد، جریان راکتیو زیادی کشیده می‌شود و در نهایت منجر به کاهش تدریجی و غیرقابل کنترل در اندازه ولتاژ می‌گردد. به غیر از خاموشی، سایر تأثیرات ناپایداری ولتاژ در شبکه شامل خارج شدن سریع ژنراتور یا عناصر انتقال و همچنین پایین آمدن سطح ولتاژ است [۷۱]. در نتیجه ممکن است خاموشی در عرض چند دقیقه ایجاد شود.

بر اساس بازه زمانی، تهدید ناپایداری ولتاژ را می‌توان به کوتاه مدت و بلند مدت تقسیم نمود [۸۷]:


- پایداری ولتاژ کوتاه مدت^۱ (STVS): مشکلات STVS در یک بازه زمانی کوتاه (چند ثانیه) پس از برطرف شدن خطا رخ می‌دهد. ناپایداری ولتاژ کوتاه مدت عمدتاً توسط ویژگی‌های دینامیکی بارهای موتور القایی پیچیده ایجاد می‌شود.
- پایداری ولتاژ بلند مدت: برخلاف STVS، بازه زمانی برای مشکلات ناپایداری ولتاژ طولانی مدت یا افت شدید، طولانی‌تر است (به طور متوسط ۰.۵-۳۰ دقیقه) مشکلات بی ثباتی ولتاژ طولانی مدت عمدتاً در سیستم برقی با بار زیاد وجود دارد. ناپایداری ولتاژ طولانی مدت بیشتر توسط تجهیزات کند، مانند ترانسفورماتورهای تغییر دهنده شیر و محدود کننده‌های جریان ایجاد می‌شود [۸۸].

پیامدهای مشکلات ناپایداری ولتاژ که در فرانسه، توکیو و اخیراً در اسرائیل تجربه شده است، اهمیت اقتصادی و اجتماعی ناپایداری ولتاژ را نشان داده است، بنابراین تجزیه و تحلیل پایداری ولتاژ به یکی از پربحث‌ترین موضوعات در دنیای تحقیقات سیستم قدرت تبدیل شده است. تجزیه و تحلیل پایداری ولتاژ شامل نظارت بر واکنش سیستم قدرت به تغییر مداوم در دینامیک ژنراتور و بار می‌باشد.

۳-۵-۱۱- روش‌های هوش مصنوعی برای شناسایی تهدیدات شبکه برق

محافظت از شبکه برق مدرن با استفاده از روش‌های مرسوم، روز به روز چالشی‌تر می‌شود. MLT و تکنیک‌های یادگیری عمیق به طور مداوم ثابت کرده‌اند که گزینه‌ای عملی هستند چراکه اهداف امنیتی مانند بازدهی بالا، سرعت مناسب اجرا و کارایی را برآورده می‌سازند. روش‌های یادگیری ماشین به طور گسترده‌ای در مقالات شبکه برق برای نظارت، تشخیص نفوذ، پیش بینی و طبقه بندی تهدیدات مختلف شبکه برق ارائه شده است. استفاده از MLTها برای مطالعات سیستم قدرت به طور کلی به چهار فاز عمده تقسیم می‌شوند: تولید مجموعه داده‌ها، پیش پردازش داده‌ها (انتخاب یا استخراج ویژگی)، بهینه‌سازی (اجباری نیست) و ارزیابی یا طبقه بندی. برای هر یک از چهار تهدید عمده در شبکه برق این چهار فاز وجود دارد که به طور مثال در شکل ۱۳۳ این مراحل برای اختلالات کیفیت توان نشان داده شده است.

¹Short Term Voltage Stability



شکل ۱۳۲. مراحل دسته‌بندی اختلالات PQD [۸۱]

در ادامه به تعدادی از روش‌های هوش مصنوعی به کار رفته برای تهدیدات مختلف در شبکه برق بدون وارد شدن به جزئیات این روش‌ها اشاره می‌شود. در جدول ۱۳ برخی از روش‌های یادگیری ماشین ارائه شده برای دسته‌بندی رویدادهای PQD خلاصه شده است.

جدول ۱۳. روش‌های یادگیری ماشین ارائه شده برای دسته‌بندی رویدادهای PQD

مرجع	روش استخراج ویژگی	الگوریتم یادگیری ماشین	روش انتخاب ویژگی / بهینه‌سازی	دقت
[۸۹]	VMD+ST	SVM	SBS/SFS/GSO	99.66%
[۹۰]	DWT+MRA	SVM	-	94%
[۹۱]	WT	PNN	ABC	99.875%
[۹۲]	WT	ELM	PSO	97.6%
[۹۳]	WPT	SVM	GA	98.33%

در جدول ۱۴ تعدادی از روش‌های مبتنی بر یادگیری ماشین در سیستم‌های آشکارسازی نفوذ (IDS) برای حفاظت سیستم SCADA آورده شده است.

جدول ۱۴. روش‌های مبتنی بر یادگیری ماشین در آشکارسازی نفوذ (IDS) برای حفاظت سیستم SCADA

مرجع	مجموعه داده استفاده شده	روش‌های پردازش داده / بهینه‌سازی	الگوریتم یادگیری ماشین	دقت
[۹۴]	بستر تست شبیه‌سازی شده	FE	FNN+LSTM	99.76%
[۸۰]	داده MSU	FE	SVM-RF	99.58%
[۹۵]	داده شبیه‌سازی شده	RBF Kernel	OCSVM	98.87%
[۹۶]	داده Cybergym و BGU	FE	HMM-ANN	-
[۹۷]	KDD99	IWP-CSO	HNA-NN	93.1%

در جدول ۱۵ نیز تعدادی از روش‌های مبتنی بر یادگیری ماشین برای کاربرد در ارزیابی پایداری گذرا (TSA) آورده شده است.

جدول ۱۵. روش‌های مبتنی بر یادگیری ماشین برای کاربرد در TSA

مرجع	سیستم تست	روش‌های پردازش داده/ بهینه‌سازی	الگوریتم یادگیری ماشین	دقت
[۹۸]	New England 68 bus	Min-max normalization	SVM	100%
[۹۹]	New England 39 bus	KFRS و الگوریتم Memeric	ELM	95.2%
[۱۰۰]	IEEE 24 bus	-	TSVMNN	86.27%
[۱۰۱]	New England 39 bus	-	یادگیری چند کرنلی بیزین	98.18%
[۱۰۲]	New England 39 bus	BinJaya FS	OS/ELM	98.24

همچنین در جدول ۱۶ تعداد از روش‌های مبتنی بر یادگیری ماشین برای ارزیابی پایداری ولتاژ (VSA) به طور خلاصه نشان داده شده است.

جدول ۱۶. روش‌های مبتنی بر یادگیری ماشین برای ارزیابی پایداری ولتاژ (VSA)

مرجع	سیستم تست	روش‌های پردازش داده/ بهینه‌سازی	الگوریتم یادگیری ماشین	دقت
[۸۷]	IEEE 9 bus و IEEE 14	-	FFBP	99.4%
[۱۰۳]	WECC system	-	FFBP	90.01%
[۱۰۴]	New England 39 bus	الگوریتم Relief	NNRW	99.2%
[۱۰۵]	IEEE 14 bus , IEEE 30 bus	K-Mean	SVM	99%
[۱۰۶]	IEEE 30 bus	CBR	PFDT	94%

۱۱-۶- جمع‌بندی

شبکه برق به عنوان بزرگ‌ترین شبکه سایبر-فیزیکی در معرض حملات سایبری قرار دارد. از آنجایی که زندگی امروزه بدون برق دچار اختلالات جدی می‌شود این حملات می‌تواند خسارت‌های جانی و مالی فراوانی داشته باشد. دو عامل در تشدید شدن این تهدیدات موثر هستند که یکی گسترده شدن شبکه برق از لحاظ جغرافیایی و دیگری اضافه شدن مشتریان، تولیدکنندگان، خرده و عمده فروشان بیشتر به این شبکه است. هر چقدر تعداد افراد و شرکت‌هایی که با شبکه برق در ارتباط هستند گسترش می‌یابد ارتباطات آنها نیز بیشتر شده و محل‌های آسیب‌پذیر برای حمله سایبری بیشتر خواهد شد. از طرفی انرژی‌های تجدیدپذیر در شبکه برق جدید بسیار مورد توجه هستند و به دلیل آلودگی‌های ناشی از سوخت‌های فسیلی و همچنین کم شدن ذخایر آنها

انرژی‌های تجدیدپذیر مورد توجه ویژه قرار گرفته است. تولید این انرژی‌ها در اقصی نقاط یک کشور ممکن است پراکنده باشد و از نیروگاه‌های بادی در دریا و نقاط مرتفع تا نیروگاه‌های خورشیدی در بیابان‌ها را می‌تواند شامل شود که بر گسترش جغرافیایی شبکه برق می‌افزاید.

در این فصل ابتدا به موارد استفاده از روش‌های هوش مصنوعی جهت ارتقاء امنیت در شبکه‌های ارتباطی و با تأکید بر شبکه‌های IoT، که کاربرد وسیعی در شبکه‌های برق هوشمند دارند، پرداخته شده است. شبکه برق هوشمند دارای ویژگی‌های منحصربه‌فردی است و شامل حسگرها و کنتورهای زیادی برای جمع‌آوری داده از بخش‌های مختلف و ارسال این اطلاعات به مراکز تصمیم‌گیری است. این حسگرها و کنتورها را می‌توان یک شبکه اینترنت اشیاء صنعتی در نظر گرفت که به دلیل وسعت زیادی که دارد شامل دستگاه‌های مخابراتی متنوع و ناهمگن است که در برد و نرخ انتقال داده با یکدیگر متفاوت هستند. در این اینترنت اشیاء صنعتی هم مخابرات برد بلند و هم مخابرات راه نزدیک کاربرد دارد. از طرفی برخی از داده‌ها همچون داده‌های اعلام قطعی یا خطر نیازمند سرعت، نرخ داده و قابلیت اطمینان بالایی هستند. همچنین پایش بلادرنگ و آنی قسمت‌های مختلف شبکه نیاز به پهنای باند زیادی دارد تا انبوهی از داده‌ها که توسط حسگرهای مختلف تولید می‌شود را به مراکز کنترلی انتقال دهد. یکی دیگر از ویژگی‌های اصلی شبکه‌های حسگر بی‌سیم و به‌طور کلی شبکه‌های اینترنت اشیاء بهره‌گیری از اجزای با مصرف توان کم و کم‌هزینه است. این محدودیت منابع باعث می‌شود بسیاری از راه‌حل‌های مسائل امنیتی قابل پیاده‌سازی در شبکه‌های دیگر به دلیل نیاز به مصرف توان بالا و انجام محاسبات پیچیده ریاضی در شبکه‌ها اینترنت اشیاء ممکن نباشد و یکی از چالش‌های مهم به حساب می‌آید. از دیگر ویژگی‌ها می‌توان به پویایی اجزای شبکه همچون ربات‌هایی که در شبکه مشغول کار هستند و همچنین تغییرات کانال‌های مخابراتی اشاره کرد.

شبکه مخابراتی در شبکه برق هوشمند همانند دیگر شبکه‌های مخابراتی از لایه‌های مختلفی چون لایه فیزیکی، لایه ارتباط داده، لایه شبکه، لایه انتقال و لایه کاربرد تشکیل شده است که احتمال حملات مختلف در هر یک از این لایه‌ها وجود دارد. در مورد هر لایه و حملاتی که ممکن است در آن صورت گیرد به‌طور مختصر پرداخته شد. علاوه بر آن به دلیل وجود شبکه‌های مختلف بی‌سیم در لایه فیزیکی و همچنین ارتباط شبکه اینترنت اشیاء با شبکه ابر یا شبکه‌های SDN مسائل امنیتی در این شبکه‌ها به شبکه اینترنت اشیاء نیز منتقل می‌شود.

حجم بالای داده‌ها و بررسی حالات مختلفی که برای حملات وجود دارد از جمله داده‌های مخرب و غیرواقعی نیاز به محاسبات زیاد و سخت‌افزارهای پیچیده‌ای دارد که بتواند این محاسبات سنگین را انجام دهد. روش‌های هوش مصنوعی از جمله DQL می‌توانند به کاهش حالات لازم برای بررسی به‌منظور رسیدن به همگرایی به سیاست بهینه مورد استفاده قرار گرفته که برای صرفه‌جویی در منابع سخت‌افزاری و زمان نیز مفید هستند. به‌طور نمونه مثال‌هایی از کاربرد هوش مصنوعی و به‌ویژه DQL در حملاتی مانند جیمینگ و سایر-فیزیکی، تشخیص و آشکارسازی نفوذ و حفظ اتصال آورده شده است.

در بخش انتهایی فصل نیز کاربرد هوش مصنوعی در امنیت صنعت برق به صورت ویژه مورد مطالعه و بررسی قرار گرفت. شبکه برق از هفت حوزه مهم تولید، توزیع، انتقال، مدیریت و کنترل، خدمات، مشترکین و بازار برق تشکیل شده که هر یک از این حوزه‌ها در درون خود و برای ارتباط با دیگر حوزه‌ها نیازمند مخابرات و برقراری ارتباطات می‌باشد. یکی از مهمترین سیستم‌های کنترلی در شبکه برق، سیستم SCADA است که می‌تواند یکی از مهمترین مقاصد مهاجمان برای ایجاد اختلال در شبکه برق باشد. از مهمترین اختلالاتی که ممکن است در شبکه رخ دهد اختلالات کیفیت توان مانند اختلال در سطح توان، ولتاژ، جریان و فرکانس است. همچنین اختلال در پایداری شبکه (پایداری ولتاژ و پایداری گذرا) نیز از مباحث مهم امروز شبکه‌های برق عنوان شده است. با افزایش روزافزون ارتباطات و حجم داده‌های مخابراتی تشخیص نفوذ و داده‌های جعلی نمی‌تواند با مکانیسم‌های قبلی شبکه برق به خوبی انجام گیرد و نیاز به روش‌هایی سریع و با دقت بالا است که حجم محاسبات زیادی نیز لازم نداشته باشند. چهار دسته اصلی از تهدیدات شناخته شده امنیتی و پایداری شبکه برق که عبارتند از اختلالات کیفیت توان (PQD)، تهدیدات و آسیب‌پذیری‌های شبکه SCADA، ارزیابی پایداری گذرا (TSA) و ارزیابی پایداری ولتاژ (VSA) ارائه گردیدند و

به صورت جداگانه مورد مطالعه و بررسی قرار گرفتند. در ادامه نیز روش‌های مختلف هوش مصنوعی برای شناسایی و مقابله با هریک از تهدیدات شبکه برق به صورت جداگانه مورد مطالعه قرار گرفتند.

مراجع فصل ۱۱

- [1] N. C. Luong, D. T. Hoang, S. Gong, D. Niyato, P. Wang, Y.-C. Liang, *et al.*, "Applications of deep reinforcement learning in communications and networking: A survey," *IEEE Communications Surveys & Tutorials*, vol. 21, pp. 3133-3174, 2019.
- [2] G. Han, L. Xiao, and H. V. Poor, "Two-dimensional anti-jamming communication based on deep reinforcement learning," in *2017 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2017, pp. 2087-2091.
- [3] P. Popovski, H. Yomo, and R. Prasad, "Strategies for adaptive frequency hopping in the unlicensed bands," *IEEE Wireless Communications*, vol. 13, pp. 60-67, 2006.
- [4] E. Fernandes, A. Rahmati, K. Eykholt, and A. Prakash, "Internet of things security research: A rehash of old ideas or new intellectual challenges?," *IEEE Security & Privacy*, vol. 15, pp. 79-84, 2017.
- [5] S. Al-Sarawi, M. Anbar, K. Alieyan, and M. Alzubaidi, "Internet of Things (IoT) communication protocols," in *2017 8th International conference on information technology (ICIT)*, 2017, pp. 685-690.
- [6] Y. Liu, Y. Kuang, Y. Xiao, and G. Xu, "SDN-based data transfer security for Internet of Things," *IEEE Internet of Things Journal*, vol. 5, pp. 257-268, 2017.
- [7] J. Chen, S. Li, H. Yu, Y. Zhang, D. Raychaudhuri, R. Ravindran, *et al.*, "Exploiting ICN for realizing service-oriented communication in IoT," *IEEE Communications Magazine*, vol. 54, pp. 24-30, 2016.
- [8] I. Andrea, C. Chrysostomou, and G. Hadjichristofi, "Internet of Things: Security vulnerabilities and challenges," in *2015 IEEE Symposium on Computers and Communication (ISCC)*, 2015, pp. 180-187.
- [9] S. Benzarti, B. Triki, and O. Korbaa, "A survey on attacks in Internet of Things based networks," in *2017 International conference on engineering & MIS (ICEMIS)*, 2017, pp. 1-7.
- [10] A. G. Finogeev and A. A. Finogeev, "Information attacks and security in wireless sensor networks of industrial SCADA systems," *Journal of Industrial Information Integration*, vol. 5, pp. 6-16, 2017.
- [11] P. Li, L. Sun, X. Fu, and L. Ning, "Security in wireless sensor networks," in *Wireless Network Security*, ed: Springer, 2013, pp. 179-227.

- [12] A. Perrig, J. Stankovic, and D. Wagner, "Security in wireless sensor networks," *Communications of the ACM*, vol. 47, pp. 53-57, 2004.
- [13] L. Hu, H. Wen, B. Wu, F. Pan, R.-F. Liao, H. Song, *et al.*, "Cooperative jamming for physical layer security enhancement in Internet of Things," *IEEE Internet of Things Journal*, vol. 5, pp. 219-228, 2017.
- [14] H. A. B. Salameh, S. Almajali, M. Ayyash, and H. Elgala, "Spectrum assignment in cognitive radio networks for internet-of-things delay-sensitive applications under jamming attacks," *IEEE Internet of Things Journal*, vol. 5, pp. 1904-1913, 2018.
- [15] H. K. Patil and R. Seshadri, "Big data security and privacy issues in healthcare," in *2014 IEEE international congress on big data*, 2014, pp. 762-765.
- [16] A.-R. Sadeghi, C. Wachsmann, and M. Waidner, "Security and privacy challenges in industrial internet of things," in *2015 52nd ACM/EDAC/IEEE Design Automation Conference (DAC)*, 2015, pp. 1-6.
- [17] J. Granjal, E. Monteiro, and J. S. Silva, "Security for the internet of things: a survey of existing protocols and open research issues," *IEEE Communications Surveys & Tutorials*, vol. 17, pp. 1294-1312, 2015.
- [18] Y. Yang, L. Wu, G. Yin, L. Li, and H. Zhao, "A survey on security and privacy issues in Internet-of-Things," *IEEE Internet of Things Journal*, vol. 4, pp. 1250-1258, 2017.
- [19] S. Raza, L. Wallgren, and T. Voigt, "SVELTE: Real-time intrusion detection in the Internet of Things," *Ad hoc networks*, vol. 11, pp. 2661-2674, 2013.
- [20] P. Jadav and V. K. Babu, "Fuzzy logic based faulty node detection in wireless sensor network," in *2017 International Conference on Communication and Signal Processing (ICCSP)*, 2017, pp. 0390-0394.
- [21] Y. Nishiguchi, A. Yano, T. Ohtani, R. Matsukura, and J. Kakuta, "IoT fault management platform with device virtualization," in *2018 IEEE 4th World Forum on Internet of Things (WF-IoT)*, 2018, pp. 257-262.
- [22] M. Khanafer, M. Guennoun, and H. T. Mouftah, "A survey of beacon-enabled IEEE 802.15. 4 MAC protocols in wireless sensor networks," *IEEE Communications Surveys & Tutorials*, vol. 16, pp. 856-876, 2013.
- [23] G. Bansod, N. Raval, and N. Pisharoty, "Implementation of a new lightweight encryption design for embedded security," *IEEE Transactions on Information Forensics and Security*, vol. 10, pp. 142-151, 2014.
- [24] C. Yicheng, Z. Xuecheng, L. Zhenglin, H. Yu, and Z. Zhaoxia, "Energy-efficient and security-optimized AES hardware design for ubiquitous computing," *Journal of Systems Engineering and Electronics*, vol. 19, pp. 652-658, 2008.
- [25] S. Oukili and S. Bri, "High speed efficient advanced encryption standard implementation," in *2017 International Symposium on Networks, Computers and Communications (ISNCC)*, 2017, pp. 1-4.
- [26] W. Dong and X. Liu, "Robust and secure time-synchronization against sybil attacks for sensor networks," *IEEE Transactions on Industrial Informatics*, vol. 11, pp. 1482-1491, 2015.
- [27] R. Hussain and H. Oh, "On secure and privacy-aware sybil attack detection in vehicular communications," *Wireless personal communications*, vol. 77, pp. 2649-2673, 2014.
- [28] G. Han, X. Li, J. Jiang, L. Shu, and J. Lloret, "Intrusion detection algorithm based on neighbor information against sinkhole attack in wireless sensor networks," *The Computer Journal*, vol. 58, pp. 1280-1292, 2015.
- [29] A. Haroon, S. Akram, M. A. Shah, and A. Wahid, "E-Lithe: A lightweight secure DTLS for IoT," in *2017 IEEE 86th Vehicular Technology Conference (VTC-Fall)*, 2017, pp. 1-5.

- [30] S. Katsikeas, K. Fysarakis, A. Miaoudakis, A. Van Bemten, I. Askoxylakis, I. Papaefstathiou, *et al.*, "Lightweight & secure industrial IoT communications via the MQ telemetry transport protocol," in *2017 IEEE Symposium on Computers and Communications (ISCC)*, 2017, pp. 1193-1200.
- [31] A. Mondal and S. Bhattacharjee, "A reliable, multi-path, connection oriented and independent transport protocol for iot networks," in *2017 9th International Conference on Communication Systems and Networks (COMSNETS)*, 2017, pp. 590-591.
- [32] T. Buddhika and S. Pallickara, "Neptune: Real time stream processing for internet of things and sensing environments," in *2016 IEEE International Parallel and Distributed Processing Symposium (IPDPS)*, 2016, pp. 1143-1152.
- [33] T. Heer, O. Garcia-Morchon, R. Hummen, S. L. Keoh, S. S. Kumar, and K. Wehrle, "Security Challenges in the IP-based Internet of Things," *Wireless Personal Communications*, vol. 61, pp. 527-542, 2011.
- [34] E. Bertino and N. Islam, "Botnets and internet of things security," *Computer*, vol. 50, pp. 76-79, 2017.
- [35] T. H. Szymanski, "Security and privacy for a green internet of things," *IT Professional*, vol. 19, pp. 34-41, 2017.
- [36] M. C. Dacier, H. König, R. Cwalinski, F. Kargl, and S. Dietrich, "Security challenges and opportunities of software-defined networking," *IEEE Security & Privacy*, vol. 15, pp. 96-100, 2017.
- [37] S. Scott-Hayward, G. O'Callaghan, and S. Sezer, "SDN security: A survey," in *2013 IEEE SDN For Future Networks and Services (SDN4FNS)*, 2013, pp. 1-7.
- [38] J. Singh, T. Pasquier, J. Bacon, H. Ko, and D. Eysers, "Twenty security considerations for cloud-supported Internet of Things," *IEEE Internet of things Journal*, vol. 3, pp. 269-284, 2015.
- [39] L. Xiao, X. Wan, W. Su, and Y. Tang, "Anti-jamming underwater transmission with mobility and learning," *IEEE Communications Letters*, vol. 22, pp. 542-545, 2018.
- [40] X. Liu, Y. Xu, L. Jia, Q. Wu, and A. Anpalagan, "Anti-jamming communications using spectrum waterfall: A deep reinforcement learning approach," *IEEE Communications Letters*, vol. 22, pp. 998-1001, 2018.
- [41] Y. Chen, Y. Li, D. Xu, and L. Xiao, "DQN-based power control for IoT transmission against jamming," in *2018 IEEE 87th Vehicular Technology Conference (VTC Spring)*, 2018, pp. 1-5.
- [42] X. Lu, L. Xiao, C. Dai, and H. Dai, "UAV-aided cellular communications with deep reinforcement learning against jamming," *arXiv preprint arXiv:1805.06628*, 2018.
- [43] L. Xiao, X. Lu, D. Xu, Y. Tang, L. Wang, and W. Zhuang, "UAV relay in VANETs against smart jamming with reinforcement learning," *IEEE Transactions on Vehicular Technology*, vol. 67, pp. 4087-4097, 2018.
- [44] S. Lv, L. Xiao, Q. Hu, X. Wang, C. Hu, and L. Sun, "Anti-jamming power control game in unmanned aerial vehicle networks," in *GLOBECOM 2017-2017 IEEE Global Communications Conference*, 2017, pp. 1-6.
- [45] L. Xiao, C. Xie, M. Min, and W. Zhuang, "User-centric view of unmanned aerial vehicle transmission against smart attacks," *IEEE Transactions on Vehicular Technology*, vol. 67, pp. 3420-3430, 2017.
- [46] M. Bowling and M. Veloso, "Multiagent learning using a variable learning rate," *Artificial Intelligence*, vol. 136, pp. 215-250, 2002.
- [47] Y. Zhang, N. Meratnia, and P. Havinga, "Outlier detection techniques for wireless sensor networks: A survey," *IEEE communications surveys & tutorials*, vol. 12, pp. 159-170, 2010.

- [48] D. Janakiram and A. Kumar, "Outlier detection in wireless sensor networks using Bayesian belief networks," in *2006 1st International Conference on Communication Systems Software & Middleware*, 2006, pp. 1-6.
- [49] J. W. Branch, C. Giannella, B. Szymanski, R. Wolff, and H. Kargupta, "In-network outlier detection in wireless sensor networks," *Knowledge and information systems*, vol. 34, pp. 23-54, 2013.
- [50] S. Kaplantzis, A. Shilton, N. Mani, and Y. A. Sekercioglu, "Detecting selective forwarding attacks in wireless sensor networks using support vector machines," in *2007 3rd International Conference on Intelligent Sensors, Sensor Networks and Information*, 2007, pp. 335-340.
- [51] Z. Yang, N. Meratnia, and P. Havinga, "An online outlier detection technique for wireless sensor networks using unsupervised quarter-sphere support vector machine," in *2008 International Conference on Intelligent Sensors, Sensor Networks and Information Processing*, 2008, pp. 151-156.
- [52] S. Rajasegarar, C. Leckie, M. Palaniswami, and J. C. Bezdek, "Quarter sphere based distributed anomaly detection in wireless sensor networks," in *2007 IEEE International Conference on Communications*, 2007, pp. 3864-3869.
- [53] Y. S. Chen, Y. S. Qin, Y. G. Xiang, J. X. Zhong, and X. L. Jiao, "Intrusion detection system based on immune algorithm and support vector machine in wireless sensor network," in *International Symposium on Information and Automation*, 2010, pp. 372-376.
- [54] Y. Zhang, N. Meratnia, and P. J. Havinga, "Distributed online outlier detection in wireless sensor networks using ellipsoidal support vector machine," *Ad hoc networks*, vol. 11, pp. 1062-1074, 2013.
- [55] T. Avram, S. Oh, and S. Hariri, "Analyzing attacks in wireless ad hoc network with self-organizing maps," in *Fifth Annual Conference on Communication Networks and Services Research (CNSR'07)*, 2007, pp. 166-175.
- [56] Y. Chen, S. Kar, and J. M. Moura, "Cyber-physical attacks with control objectives," *IEEE Transactions on Automatic Control*, vol. 63, pp. 1418-1425, 2017.
- [57] A. Ferdowsi, U. Challita, W. Saad, and N. B. Mandayam, "Robust deep reinforcement learning for security and safety in autonomous vehicle systems," in *2018 21st International Conference on Intelligent Transportation Systems (ITSC)*, 2018, pp. 307-312.
- [58] M. Brackstone and M. McDonald, "Car-following: a historical review," *Transportation Research Part F: Traffic Psychology and Behaviour*, vol. 2, pp. 181-196, 1999.
- [59] A. Ferdowsi and W. Saad, "Deep learning-based dynamic watermarking for secure signal authentication in the Internet of Things," in *2018 IEEE International Conference on Communications (ICC)*, 2018, pp. 1-6.
- [60] A. Ferdowsi and W. Saad, "Deep learning for signal authentication and security in massive internet-of-things systems," *IEEE Transactions on Communications*, vol. 67, pp. 1371-1387, 2018.
- [61] P. Vadakkepat, K. C. Tan, and W. Ming-Liang, "Evolutionary artificial potential fields and their application in real time robot path planning," in *Proceedings of the 2000 congress on evolutionary computation. CEC00 (Cat. No. 00TH8512)*, 2000, pp. 256-263.
- [62] W. Huang, Y. Wang, and X. Yi, "Deep q-learning to preserve connectivity in multi-robot systems," in *Proceedings of the 9th International Conference on Signal Processing Systems*, 2017, pp. 45-50.

- [63] W. Huang, Y. Wang, and X. Yi, "A deep reinforcement learning approach to preserve connectivity for multi-robot systems," in *2017 10th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics (CISP-BMEI)*, 2017, pp. 1-7.
- [64] H. A. Poonawala, A. C. Satici, H. Eckert, and M. W. Spong, "Collision-free formation control with decentralized connectivity preservation for nonholonomic-wheeled mobile robots," *IEEE Transactions on control of Network Systems*, vol. 2, pp. 122-130, 2014.
- [65] V. Mnih, A. P. Badia, M. Mirza, A. Graves, T. Lillicrap, T. Harley, *et al.*, "Asynchronous methods for deep reinforcement learning," in *International conference on machine learning*, 2016, pp. 1928-1937.
- [66] C. Wang, J. Wang, X. Zhang, and X. Zhang, "Autonomous navigation of UAV in large-scale unknown complex environment with deep reinforcement learning," in *2017 IEEE Global Conference on Signal and Information Processing (GlobalSIP)*, 2017, pp. 858-862.
- [67] Z. Wang, L. Li, Y. Xu, H. Tian, and S. Cui, "Handover control in wireless systems via asynchronous multiuser deep reinforcement learning," *IEEE Internet of Things Journal*, vol. 5, pp. 4296-4307, 2018.
- [68] F. B. Mismar and B. L. Evans, "Deep Q-learning for self-organizing networks fault management and radio performance improvement," in *2018 52nd asilomar conference on signals, systems, and computers*, 2018, pp. 1457-1461.
- [69] T. Chakravorti, N. Nayak, R. Bisoi, P. Dash, and L. Tripathy, "A new robust kernel ridge regression classifier for islanding and power quality disturbances in a multi distributed generation based microgrid," *Renewable Energy Focus*, vol. 28, pp. 78-99, 2019.
- [70] R. Deng, G. Xiao, R. Lu, H. Liang, and A. V. Vasilakos, "False data injection on state estimation in power systems—Attacks, impacts, and defense: A survey," *IEEE Transactions on Industrial Informatics*, vol. 13, pp. 411-423, 2016.
- [71] V. Jayasankar, N. Kamaraj, and N. Vanaja, "Estimation of voltage stability index for power system employing artificial neural network technique and TCSC placement," *Neurocomputing*, vol. 73, pp. 3005-3011, 2010.
- [72] G. Liang, J. Zhao, F. Luo, S. R. Weller, and Z. Y. Dong, "A review of false data injection attacks against modern power systems," *IEEE Transactions on Smart Grid*, vol. 8, pp. 1630-1638, 2016.
- [73] !!! INVALID CITATION !!! .
- [74] X. Huang, Z. Qin, and H. Liu, "A survey on power grid cyber security: From component-wise vulnerability assessment to system-wide impact analysis," *IEEE Access*, vol. 6, pp. 69023-69035, 2018.
- [75] F. Rahimi and A. Ipakchi, "Demand response as a market resource under the smart grid paradigm," *IEEE Transactions on smart grid*, vol. 1, pp. 82-88, 2010.
- [76] A. Purvins, I. T. Papaioannou, I. Oleinikova, and E. Tzimas, "Effects of variable renewable power on a country-scale electricity system: High penetration of hydro power plants and wind farms in electricity generation," *Energy*, vol. 43, pp. 225-236, 2012.
- [77] H. Khurana, M. Hadley, N. Lu, and D. A. Frincke, "Smart-grid security issues," *IEEE Security & Privacy*, vol. 8, pp. 81-85, 2010.
- [78] S. Sridhar, A. Hahn, and M. Govindarasu, "Cyber-physical system security for the electric power grid," *Proceedings of the IEEE*, vol. 100, pp. 210-224, 2011.

- [79] S. Wang and H. Chen, "A novel deep learning method for the classification of power quality disturbances using deep convolutional neural network," *Applied energy*, vol. 235, pp. 1126-1140, 2019.
- [80] R. L. Perez, F. Adamsky, R. Soua, and T. Engel, "Machine learning for reliable network attack detection in SCADA systems," in *2018 17th IEEE International Conference On Trust, Security And Privacy In Computing And Communications/12th IEEE International Conference On Big Data Science And Engineering (TrustCom/BigDataSE)*, 2018, pp. 633-638.
- [81] O. A. Alimi, K. Ouahada, and A. M. Abu-Mahfouz, "A review of machine learning approaches to power system security and stability," *IEEE Access*, vol. 8, pp. 113512-113531, 2020.
- [82] A. Sharifian and S. Sharifian, "A new power system transient stability assessment method based on Type-2 fuzzy neural network estimation," *International Journal of Electrical Power & Energy Systems*, vol. 64, pp. 71-87, 2015.
- [83] J. James, D. J. Hill, A. Y. Lam, J. Gu, and V. O. Li, "Intelligent time-adaptive transient stability assessment system," *IEEE Transactions on Power Systems*, vol. 33, pp. 1049-1058, 2017.
- [84] N. Amjady and S. F. Majedi, "Transient stability prediction by a hybrid intelligent system," *IEEE Transactions on Power Systems*, vol. 22, pp. 1275-1283, 2007.
- [85] S. Suliman and T. A. Rahman, "Artificial immune system based machine learning for voltage stability prediction in power system," in *2010 4th International Power Engineering and Optimization Conference (PEOCO)*, 2010, pp. 53-58.
- [86] Z. Nie, D. Yang, V. Centeno, and K. D. Jones, "A PMU-based voltage security assessment framework using hoeffding-tree-based learning," in *2017 19th International Conference on Intelligent System Application to Power Systems (ISAP)*, 2017, pp. 1-6.
- [87] H. H. Goh, Q. Chua, S. Lee, B. C. Kok, K. C. Goh, and K. Teo, "Evaluation for voltage stability indices in power system using artificial neural network," *Procedia Engineering*, vol. 118, pp. 1127-1136, 2015.
- [88] S. Johansson, *Long-term Voltage Stability in Power Systems-Alleviating the Impact of Generator Current Limiters*: Chalmers University of Technology, 1998.
- [89] A. A. Abdoos, P. K. Mianaei, and M. R. Ghadikolaei, "Combined VMD-SVM based feature selection method for classification of power quality events," *Applied Soft Computing*, vol. 38, pp. 637-646, 2016.
- [90] F. Jandan, S. Khokhar, S. A. A. Shaha, and F. Abbasi, "Recognition and classification of power quality disturbances by DWT-MRA and SVM classifier," *International Journal of Advanced Computer Science and Applications*, vol. 10, pp. 368-377, 2019.
- [91] S. Khokhar, A. A. M. Zin, A. P. Memon, and A. S. Mokhtar, "A new optimal feature selection algorithm for classification of power quality disturbances using discrete wavelet transform and probabilistic neural network," *Measurement*, vol. 95, pp. 246-259, 2017.
- [92] R. Ahila, V. Sadasivam, and K. Manimala, "An integrated PSO for parameter determination and feature selection of ELM and its application in classification of power system disturbances," *Applied Soft Computing*, vol. 32, pp. 23-37, 2015.
- [93] K. Manimala, K. Selvi, and R. Ahila, "Optimization techniques for improving power quality data mining using wavelet packet based support vector machine," *Neurocomputing*, vol. 77, pp. 36-47, 2012.
- [94] J. Gao, L. Gan, F. Buschendorf, L. Zhang, H. Liu, P. Li, *et al.*, "Omni SCADA intrusion detection using deep learning algorithms," *IEEE Internet of Things Journal*, 2020.

- [95] L. A. Maglaras and J. Jiang, "Intrusion detection in SCADA systems using machine learning techniques," in *2014 Science and Information Conference*, 2014, pp. 626-631.
- [96] M. Kalech, "Cyber-attack detection in SCADA systems using temporal pattern recognition techniques," *Computers & Security*, vol. 84, pp. 225-238, 2019.
- [97] S. Shitharth, "An enhanced optimization based algorithm for intrusion detection in SCADA network," *Computers & Security*, vol. 70, pp. 16-26, 2017.
- [98] Y. Zhou, J. Wu, Z. Yu, L. Ji, and L. Hao, "A hierarchical method for transient stability prediction of power systems using the confidence of a SVM-based ensemble classifier," *Energies*, vol. 9, p. 778, 2016.
- [99] Y. Li, G. Li, and Z. Wang, "Rule extraction based on extreme learning machine and an improved ant-miner algorithm for transient stability assessment," *Plos one*, vol. 10, p. e0130814, 2015.
- [100] A. B. Mosavi, A. Amiri, and H. Hosseini, "A learning framework for size and type independent transient stability prediction of power system using twin convolutional support vector machine," *IEEE Access*, vol. 6, pp. 69937-69947, 2018.
- [101] X. Gu and Y. Li, "Bayesian multiple kernels learning-based transient stability assessment of power systems using synchronized measurements," in *2013 IEEE Power & Energy Society General Meeting*, 2013, pp. 1-5.
- [102] Y. Li and Z. Yang, "Application of EOS-ELM with binary Jaya-based feature selection to real-time transient stability assessment using PMU data," *IEEE Access*, vol. 5, pp. 23092-23101, 2017.
- [103] V. Malbasa, C. Zheng, P.-C. Chen, T. Popovic, and M. Kezunovic, "Voltage stability prediction using active machine learning," *IEEE Transactions on Smart Grid*, vol. 8, pp. 3117-3124, 2017.
- [104] Y. Xu, R. Zhang, J. Zhao, Z. Y. Dong, D. Wang, H. Yang, *et al.*, "Assessing short-term voltage stability of electric power systems by a hierarchical intelligent system," *IEEE transactions on neural networks and learning systems*, vol. 27, pp. 1686-1696, 2015.
- [105] S. Pérez-Londoño, G. Olivar-Tost, and J. Mora-Florez, "Online determination of voltage stability weak areas for situational awareness improvement," *Electric Power Systems Research*, vol. 145, pp. 112-121, 2017.
- [106] S. Nandanwar, M. Kolhe, S. Warkad, N. Patidar, and V. Singh, "Voltage Security Assessment by Using PFDT and CBR Methods in Emerging Power System," *Energy Procedia*, vol. 144, pp. 170-181, 2018.

فصل ۱۲. بررسی برنامه‌های کاربردی هوشمند

۱-۱۲- مقدمه

در این فصل به نقش هوش مصنوعی در ارتقاء عملکرد برنامه‌های کاربردی که بر روی تجهیزات شبکه اجرا می‌شوند، پرداخته می‌شود. سه موضوع کلی در این فصل مورد بررسی قرار خواهند گرفت: (۱) استفاده از هوش مصنوعی در برنامه‌های کاربردی که در یک شبکه مورد استفاده هستند، چالش‌هایی را به همراه خواهد آورد که برای برطرف‌سازی آنها باید از تمهیداتی خاص و یا الگوریتم‌هایی ویژه و اختصاصی‌شده برای پیاده‌سازی روش‌های هوش مصنوعی بهره گرفت. (۲) فراتر از صنعت برق و به صورت عام، کاربردهای متنوعی که روش‌های هوش مصنوعی در حوزه‌های مختلف داشته‌اند مورد مطالعه قرار خواهند گرفت. (۳) به صورت خاص، برنامه‌های کاربردی و نقش هوش مصنوعی در آنها در بخش‌های مختلف صنعت برق مورد بررسی قرار می‌گیرند. با توجه به نکات فوق و اهداف مورد نظر در این فصل، مطالب ارائه شده به این صورت است که ابتدا به چالش‌های استفاده از روش‌های هوش مصنوعی در برنامه‌های کاربردی و رویکردهایی برای مرتفع نمودن آنها پرداخته خواهد شد. سپس مروری کلی بر روی کاربردهای متنوعی که روش‌های یادگیری ماشینی در حوزه‌های مختلفی که داشته‌اند خواهیم داشت. در طی این مرور جزئیات بیشتری نظیر نوع داده‌های مورد استفاده و الگوریتم‌هایی که مورد توجه بوده‌اند، مورد بررسی قرار خواهند گرفت. در ادامه گزارش، توجه خاصی به بخش‌های مختلف صنعت برق و به ویژه شبکه‌های هوشمند معطوف شده است؛ زیرسیستم‌ها و کاربردهایی که هوش مصنوعی و روش‌های یادگیری ماشینی می‌توانند داشته باشند، به صورت مجزا مورد مطالعه و بررسی قرار گرفته‌اند. هرکدام از این کاربردها و حوزه‌ها در شبکه هوشمند می‌توانند مستقلاً موضوع یک پژوهش مجزا باشند.

۲-۱۲- چالش‌ها و رویکردهای بکارگیری روش‌های هوش مصنوعی در برنامه‌های کاربردی

الگوریتم‌های AI نیازمند محاسبات بسیار زیاد هستند و از این رو در مراکز داده توسعه داده شده و مستقر گردیده‌اند. با افزایش تعداد تجهیزات هوشمند متصل به شبکه، انتظار می‌رود که تعداد زیادی از برنامه‌های کاربردی هوشمند بر روی تجهیزات قرار گرفته در لبه‌های شبکه اجرا شوند که این امر باعث تبعاتی خواهد بود. از میان این تبعات، دو مورد ظرفیت و تأخیر لینک‌های ارتباطی از گلوگاه‌های اصلی برنامه‌های کاربردی هوش مصنوعی هستند؛ این محدودیت‌ها به سه دلیل رخ می‌دهند:

- (۱) حفظ حریم شخصی: داده‌های برخی از برنامه‌های کاربردی به جای مراکز داده، نیازمند استقرار در تجهیز هستند که این موضوع خود باعث نیاز به توسعه و پیاده‌سازی روش‌های یادگیری توزیع‌شده بر روی تجهیزات می‌شود.
- (۲) محدودیت منابع: جهت غلبه بر محدودیت‌های محاسباتی موجود در تجهیزات لبه، محاسبات توزیع‌شده امکان استفاده از ادغام منابع محاسباتی و ذخیره‌سازی در تجهیزات را فراهم می‌کند؛ و داده‌های میانی منتج از محاسبات، مابین تجهیزات تبادل می‌شوند.
- (۳) وجود یک ترکیب ناهمگن از ابر، لبه و تجهیزات انتهایی یک محیط پراکنده برای فراگیری و انجام استنتاج برای الگوریتم‌های AI را فراهم می‌کند.

جهت مرتفع کردن نیازمندی‌های ارتباطی برای الگوریتم‌های توزیع‌شده هوش مصنوعی، دو راه‌حل را می‌توان بیان داشت:

(۱) فراگیری توزیع‌شده با ارتباطات کارآمد

توانایی‌هایی روبه رشد محاسباتی و ذخیره‌سازی تجهیزات فرصت‌هایی برای انجام فراگیری توزیع‌شده بر روی تجهیزات و با کمک تحلیل محلی داده‌ها را فراهم می‌آورد. اما ضریب اطمینان لینک‌های ارتباطی (مخصوصاً در ارتباطات بی‌سیم)، یک گلوگاه

مهم برای پیاده‌سازی فراگیری توزیع‌شده را ایجاد می‌کند. برای تقویت حریم خصوصی و امنیت داده‌ها، یادگیری فدرالی^۱ [۸] اجازه نگهداری داده‌ها بر روی تجهیزات را فراهم می‌آورد؛ به این ترتیب فراگیری یک مدل کلی و بر اساس داده‌های توزیع‌شده بر روی تجهیزات را امکان‌پذیر می‌نماید. با این حال، برای این روش محدودیت در میزان پهنای باند یک چالش اساسی است.


در این روش که منجر به فراگیری داده به صورت توزیع‌شده در دستگاه‌های موبایل می‌شود، یک مدل مشترک توسط به‌روزرسانی محاسبات محلی بیان شده است. همان‌طور که گفته شد، تبلت‌ها و تلفن‌ها به مقدار زیادی داده دسترسی دارند که بیشتر آن‌ها خصوصی هستند. مدل‌های فراگرفته شده توسط چنین داده‌ای می‌تواند منجر به بهبود کاربری با استفاده از هوشمندسازی گردد، اما طبیعت حساس داده‌ها به معنی وجود ریسک و مسئولیت در ذخیره‌سازی آن به‌طور متمرکز است. در واقع در این مقاله یک تکنیک یادگیری که به کاربران اجازه دستیابی به مزیت‌های مدل مشترک فراگرفته شده توسط داده، بدون نیاز به ذخیره‌سازی متمرکز آورده شده است بطوریکه در آن هر کاربر مجموعه داده فراگیری محلی دارد که هیچ‌گاه در سرور بارگذاری نشده است. در عوض، هر کاربر به‌روزرسانی مدل کلی جاری در سرور را انجام می‌دهد، و فقط این نسخه مرادده می‌شود. از آنجایی که نسخه بروز شده مخصوص بهبودی مدل جاری است، دلیلی برای ذخیره‌سازی آن‌ها بعد از به کارگیری وجود ندارد. مزیت اصلی این روش، ناهمبسته نمودن فراگیری مدل از نیاز به دسترسی مستقیم به داده فراگیری خام است. اگرچه برای کاربردهایی که هدف فراگیری با توجه به داده پایه موجود در هر کاربر مشخص می‌گردد، روش یادگیری فدرالی می‌تواند به صورت چشمگیری ریسک امنیت و حریم خصوصی را با محدود نمودن حمله فقط به دستگاه، در عوض دستگاه و ابر کاهش دهد.

۲) استنتاج توزیع‌شده با ارتباطات کارآمد

در نسل ششم، سرویس‌های هوشمند محدوده مرکزهای داده ابر تا دستگاه‌های انتهایی و دستگاه‌های اینترنت هوشمند، برای مثال، ماشین‌های خودران، هواپیماها، و ربات‌ها شامل می‌شوند. برای غلبه بر محاسبات زیاد، پهنای باند، کش، توان و شروط حوزه خصوصی در دستگاه‌های فردی، تحقیقات به سمت بیشترین استفاده از منابع محاسباتی در سراسر ابر، لبه شبکه و دستگاه‌های انتهایی از طریق محاسبات لبه موبایل^۲، رفته است [۲]. برای مثال، برای یک DNN، مشخصات اولیه می‌تواند از دستگاه‌های انتهایی استخراج گردد، سپس به دستگاه‌های محاسبه ابر و لبه برای پردازش‌های بیشتر ارسال شود. اگرچه با ناهمگونی در توانایی محاسبه و پهنای مخابراتی بین دستگاه‌های محاسبه‌کننده، تخصیص عملکردهای شبکه‌های عصبی به دستگاه‌های محاسباتی به شدت چالش‌برانگیز شده است. شکل ۱۳۳ پردازش استنتاج توزیع‌شده در دستگاه را نشان می‌دهد که در آن هر دستگاه به صورت محلی مقادیر میانه را مبنی بر تابع نگاشت با استفاده از تابع محلی محاسبه می‌کند و مقادیر میانه توسط نقطه دسترسی رادیویی مرکزی بر زده می‌شوند. پردازش استنتاج با جمع‌آوری تمامی مقادیر میانه مورد نیاز برای پیش‌بینی نتیجه انجام می‌شود. بهینه‌سازی مشترک لینک فراسو و فرسوی مخابراتی در [۳] برای برزیدن مقادیر میانه محاسبه‌شده محلی در طول دستگاه‌ها انجام شده است.

¹ Federated Learning

² Mobile Edge Computing



شکل ۱۳۳. استنتاج توزیع شده در دستگاه با روش MapReduce در مخابرات بی سیم [۴]


دستگاه‌های موبایل امروزی به داده زیادی برای یادگیری مدل‌ها دسترسی دارند، که می‌تواند تجربه کاربران دستگاه را به صورت قابل ملاحظه‌ای بهبود دهد.

۱۲-۳- بررسی برنامه‌های کاربردی هوشمند

در این بخش مروری بر برنامه‌های کاربردی که در آن‌ها از روش‌های یادگیری ماشین استفاده شده است، صورت می‌گیرد. مطالعه صورت گرفته در این بخش متکی بر مطالب ارائه شده در [۵] است که در آن یک پژوهش روشمند بر روی مقالات منتشره مابین سال‌های ۲۰۰۷ تا انتهای ۲۰۱۹ صورت گرفته است. در این مقاله به کارگیری روش‌های یادگیری ماشینی از جنبه‌های مختلف مورد بررسی قرار گرفته است. جنبه‌هایی همچون: حوزه به کارگیری روش‌های یادگیری ماشینی، نوع داده‌های جمع‌آوری شده و الگوریتم‌های مورد استفاده در یادگیری ماشینی.


۱۲-۳-۱- برنامه‌های کاربردی هوشمند در حوزه‌های مختلف

در شکل ۱۳۴ حوزه‌های به کارگیری برنامه‌های هوشمند نشان داده شده‌اند [۵]. مطابق این شکل بیشترین حوزه‌های هدف به ترتیب e-Learning با ۲۴٪ و e-Health با ۱۷٪ هستند. چیرگی e-Learning و e-Health در کاربردهای موبایل مبین این است که در مقایسه با سایر حوزه‌ها بیشترین تأثیرات اجتماعی و اقتصادی را بر روی مصرف‌کنندگان و سازمان‌ها دارند. این حوزه‌ها شرایط بهتری برای زندگی ایجاد می‌کنند. برنامه‌های کاربردی برای e-Learning امکان دسترسی به منابع مطالعاتی با کیفیت بالا و محتوای مطالعاتی متناسب با نیاز کاربران را فراهم می‌کند. کاربردهای موبایل برای e-Health بیانگر یک راه حل خلاق برای مهیا کردن سرویس‌های مراقبت از سلامت برای افراد بیشتر در کشورهای در حال توسعه است [۵].




شکل ۱۳۴. حجم مطالعات صورت گرفته در هر حوزه‌های مختلف کاربردی برنامه‌های هوشمند [۵]

شکل ۱۳۵ نشان می‌دهد که ۴۷٪ از مطالعات صورت گرفته در دانشگاه‌ها، ۳۵٪ توسط سازمان‌ها، ۱۷٪ توسط دولت‌ها و تنها ۱٪ توسط بخش صنعتی پشتیبانی مالی شده‌اند. مطابق اطلاعات شکل ۱۳۶ در طول ۴ سال آخر به‌جز دو مطالعه که در حوزه دولت می‌باشند همه تحقیقات انجام شده یا در حوزه دانشگاهی و یا در حوزه سازمان بوده‌اند. این شکل همچنین حاکی است که مطالعات انجام شده در حوزه سازمانی دارای تواتر بیشتری نسبت به حوزه دانشگاهی هست. سرمایه‌گذاری توسط سازمان‌ها نیز بر سایرین غلبه دارد.



شکل ۱۳۵. درصد مطالعات صورت گرفته در زمینه‌های مختلف [۵]



شکل ۱۳۶. توزیع مقالات انتخاب‌شده در دوره زمانی ۲۰۰۷-۲۰۱۸ برای هر زمینه تحقیق [۵]

دلیل روند رو به رشد تعداد پروژه‌های سرمایه‌گذاری‌شده توسط سازمان‌ها به این صورت است که سازمان‌ها از اهمیت فناوری‌های موبایل به‌عنوان یک راه‌حل بدیع برای توسعه نیروهای انسانی و اقتصادی آگاه شده‌اند، بنابراین در بسیاری از تحقیقات و توسعه‌های انجام‌شده در حوزه فناوری موبایل سرمایه‌گذاری می‌کنند. صنعت بیشتر به سخت‌افزار و جنبه‌های ساختاری علاقه‌مند است تا جنبه‌های مهندسی نرم‌افزار. این امر منجر به کمتر بودن میزان سرمایه‌گذاری توسط صنعت می‌گردد.

۲-۳-۱۲- نوع داده‌های جمع‌آوری‌شده


شکل ۱۳۷ نشان می‌دهد که داده جمع‌آوری‌شده از کاربران موبایل به ترتیب شامل داده زمینه‌ای^۱ با ۴۲ درصد، داده تعامل^۲ با ۳۳ درصد، داده پروفایل با ۱۳ درصد، داده ارجحیت^۳ با ۸ درصد و داده بازخورد با ۴ درصد است. داده زمینه‌ای و داده تعامل بیشترین داده بکار گرفته‌شده به دلیل تأمین داده پویا درباره کاربران موبایل هستند. این داده‌ها در اتخاذ تصمیم‌گیری‌های مرتبط با زمینه فعلی کاربر و با در نظر گرفتن کنش‌های قبلی او کمک‌کننده هستند.

داده‌های زمینه‌ای، اطلاعات در مورد حالت جاری کاربر نظیر: هویت، وضعیت سلامت، وضعیت ذهنی، وضعیت فیزیکی، وضعیت روان‌شناختی و ... و محیط آن شامل: مکان جغرافیایی، زمان، فعالیت جاری و ... می‌دهد. درحالی‌که داده تعاملی، اطلاعاتی در مورد کنش‌های قبلی کاربر (شامل: کلیک‌ها، تاریخچه کاربردی و ...) که کمک به پیش‌بینی عمل‌های آینده آن می‌کند، می‌دهد. داده‌های پروفایل و ارجحیت اغلب حاوی اطلاعات ایستا در مورد کاربرها هستند و به داشتن ایده اولیه در مورد کاربر، بدون در نظر گرفتن داده تعامل و زمینه‌ای که در ابتدای کاربری اپلیکیشن موبایل در دسترس نمی‌باشند، کمک می‌کنند.


¹ Context data

² Interaction data


³ Preference



شکل ۱۳۷. درصد انواع داده جمع‌آوری شده [۵]



شکل ۱۳۸. درصد انواع مدل‌های یادگیری ماشینی [۵]



شکل ۱۳۹. روند به کارگیری الگوریتم‌های یادگیری ماشینی [۵]

۴-۱۲- الگوریتم‌های مورد استفاده در یادگیری ماشینی

شکل ۱۳۸ حاکی از آن است که یادگیری نظارت‌شده بیشترین مدل یادگیری ماشین بکار رفته در مقالات انتخابی با ۷۳ درصد است، اگرچه شامل ۱۱ درصد یادگیری نظارت‌نشده، ۴ درصد یادگیری تقویتی نیز می‌باشد. همچنین ۱۱ درصد مقالات از هیچ‌کدام از تکنیک‌های یادگیری ماشین استفاده نکرده‌اند.

شکل ۱۳۹ نشان می‌دهد که هر ساله، یادگیری نظارت‌شده بیشترین مدل مورد استفاده در کاربردها است. همچنین نشان می‌دهد که هیچ کاربردی در تکنیک‌های نظارت‌نشده موجود نیست و تلاش کمی در به کارگیری یادگیری نظارت‌نشده، یادگیری تقویتی در توسعه کاربردهای هوشمند موبایل صورت گرفته است.

همچنین با توجه به اینکه یادگیری نظارت‌شده بیشترین کاربرد را داشته است، وظایف صورت گرفته با این روش به این گونه بوده است: ۶۶٪ برای طبقه‌بندی، ۱۶٪ برای خوشه‌بندی، ۱۳٪ رگرسیون و ۵٪ نیز برای وابستگی.

جدول ۱۷ تکنیک‌های استخراج داده که بیش از یک بار در مقالات انتخابی استفاده شده‌اند را بیان می‌کند. بنابراین، بیشترین تکنیک استفاده شده ANN است که در ۱۲ مورد و بعدی RBC^۱ که در ۱۱ مورد و دیگری K-means که در ۸ مورد، و درخت تصمیم‌گیری (DT^۲) و SVM هر کدام در ۶ مورد، NBC^۳ در ۵ مورد، FL^۴ و FBA^۵ هر کدام در ۴ مورد، KNN^۶، MM^۷، یادگیری Q و AR^۸ در ۳ مورد و در انتها RF^۹ و LR^{۱۰} در ۲ مورد از مطالعات.

از این نتایج این گونه می‌توان نتیجه گرفت که استفاده از مدل‌های SL (به‌ویژه برای انجام وظایف طبقه‌بندی) یک پدیده طبیعی هستند، چراکه در بسیاری از کاربردها نیاز به طبقه‌بندی کاربرها بر اساس پروفایل‌ها، ترجیحات، زمینه‌ها و یا کنش‌هایشان وجود دارد. همچنین الگوریتم‌های SL ساختارهای نسبتاً ساده‌ای دارند که با توجه به داده‌های یادگیری، مدل مناسبی را پیدا می‌کنند توسط آنها ارتباطی را مابین ورودی‌ها و خروجی‌ها ایجاد می‌کنند. همچنین الگوریتم‌های بسیاری از خانواده SL بر روی ابرها موجودند که برنامه‌های کاربردی موبایل می‌توانند از آنها استفاده کنند.

¹ Rules based classifier

² Decision Tree

³ Naive Bayesian classifier

⁴ Fuzzy logic

⁵ Frequency-based algorithm

⁶ K-nearest neighbour

⁷ Markov models

⁸ Association rules

⁹ Random forest

¹⁰ Logistic regression

در خیلی از موارد، وظایف UL در مرحله آماده‌سازی داده‌ها برای اکتشاف و یا کاهش ابعاد آنها استفاده می‌شوند. اغلب وظایف UL قبل از الگوریتم‌های SL و برای انجام وظایف پیش‌بینی استفاده می‌شوند. همچنین نیاز به مداخله بیشتر نسبت به SL در اصلاح نتایج به دست آمده دارند.

الگوریتم‌های RL در خودکارسازی بعضی وظایف با پیدا نمودن کنش مناسب در شرایط خاص و به‌ویژه در پیش‌بینی مصرف انرژی، پیش‌بینی تخصیص حافظه، و پیش‌بینی استفاده کاربری موبایل بکار رفته‌اند. همچنین به دلیل پیچیدگی‌شان نسبت به یادگیری نظارت‌شده و یادگیری نظارت‌نشده، کمتر بکار رفته‌اند.

جدول ۱۷. تکنیک‌های یادگیری ماشینی به کاررفته در مقالات [۵]

Techniques	Number of papers
ANN (artificial neural network)	12
RBC (rules-based classifier)	11
K-means	8
DT (decision tree)	6
SVM (support vector machine)	6
NBC (naïve Bayesian classifier)	5
FL (fuzzy logic)	4
FBA (frequency-based algorithm)	4
KNN (K-nearest neighbour)	3
MM (Markov models)	3
Q-learning	3
AR (association rules)	3
RF (random forest)	2
LR (logistic regression)	2

۵-۱۲- کاربردها در شبکه هوشمند

سیستم‌های قدرت سیستم‌هایی با پیچیدگی بالا هستند. توسعه شبکه‌های هوشمند و نفوذ زیاد انرژی‌های بادی و خورشیدی و مشارکت فعال مشتری‌ها موجب عملکرد این شبکه‌ها در محیط‌های پیچیده و فاقد قطعیت می‌گردد. روش‌های سنتی که متکی بر مدل‌سازی فیزیکی و محاسبه عددی هستند، در حل مشکلات این شبکه‌ها در شرایط عدم قطعیت و مشاهده جزئی^۱ با مشکل روبرو می‌شوند و نمی‌توانند نیازهای توسعه آینده شبکه‌های هوشمند را جوابگو باشند. با وجود استقرار گسترده ساختارهای قرائت-کننده پیشرفته (AMI^۲) و سامانه‌های پایش وسیع (WAMS^۳)، روش‌های یادگیری عمیق، یادگیری تقویتی و یادگیری تقویتی عمیق جزو فناوری‌های توانمند در توسعه آینده و پیشرفت شبکه‌های هوشمند هستند. این روش‌های یادگیری ماشینی می‌توانند راه‌حل‌های مؤثری برای مدیریت منابع انعطاف‌پذیر شامل پیش‌بینی بار، زمان‌بندی و ... باشند. در یک محیط پیچیده و نامعین، اطمینان از عمل‌های پایدار سیستم‌های قدرتی بزرگ از چالش‌های بزرگی است که مهندسان قدرت باید امروزه پاسخ دهند. مدل‌های فیزیکی و مدل‌های سیستم قدرتی عموماً بر طبق برخی فرضیات و ساده‌سازی‌ها ایجاد شده‌اند. در صورتی که پیچیدگی پایداری مسائل سیستم‌های قدرتی با ابهام و غیرخطی بودن همراه است که موجب عدم دقت و به تبع آن غیرقابل استفاده در عمل

^۱ Partial observability

^۲ Advanced Metering Infrastructures (AMI)

^۳ Wide Area Monitoring Systems (WAMS)

می‌گردد. الگوریتم‌های یادگیری ماشینی به‌طور چشمگیری طرح‌های کنترلی کنونی برای حل مسائل تصمیم‌گیری و کنترلی را بهبود می‌دهند. در یک شبکه هوشمند سیستم‌های نظارت‌کننده زیادی برای نظارت بر تجهیزات مختلف نصب شده‌اند. با استفاده از داده‌های به‌دست‌آمده از این سیستم‌های قرائت و با به‌کارگیری از الگوریتم‌های یادگیری عمیق، مشخصه‌های متفاوتی می‌توانند استخراج شوند؛ مشخصه‌هایی همچون رفتار غیرمعارف تجهیزات، تشخیص حملات بدخواهانه، سرقت برق و ... درواقع روش‌های یادگیری ماشینی کاربردهای بسیار وسیعی را می‌توانند در شبکه‌های هوشمند و تقریباً در همه بخش‌های فنی آن داشته باشند. در ادامه این بخش برخی از آن‌ها مورد مطالعه و بررسی قرار می‌گیرند.

۱-۵-۱۲- پیش‌بینی بار / تقاضا^۱

با نفوذ بالای استفاده از انرژی‌های خورشیدی و بادی، برنامه‌ریزی و عملکرد سیستم‌های قدرتی با چالش‌های افزایش ابهام مواجه‌اند. بنابراین پیش‌بینی دقیق میزان تقاضای انرژی در سطوح مختلف مهم است. اگرچه روش‌های زیادی برای پیش‌بینی بار الکتریکی وجود دارد ولی بیشتر آن‌ها مبتنی بر مجموعه داده‌های کوچک و بدون در نظر گرفتن حجم زیاد داده تهیه‌شده توسط کنتورهای هوشمند هستند. در [۷] سعی در بهبود دقت پیش‌بینی بار برای ISO New England با استفاده از مدل‌های آماری و هوش مصنوعی متفاوت دارد. یک شبکه عصبی روبه‌جلو در نظر گرفته شده است که در آن از تعداد لایه‌های نهان متفاوتی استفاده شده است. هرچقدر تعداد لایه‌های نهان افزایش پیدا می‌کند، دقت پیش‌بینی بهبود می‌یابد درحالی‌که زمان فراگیری طولانی‌تر می‌شود و ریسک بیش‌برازش نیز افزایش می‌یابد. نتایج آن‌ها نشان می‌دهد که تعداد ۱۰۰ لایه نهانی بهترین انتخاب است.

در نمونه‌های زیادی، راه‌حل‌های مؤثرتر با ترکیب الگوریتم یادگیری عمیق با روش‌های دیگر به دست می‌آید. در [۸] الگوریتم‌های K-Means و CNN به‌طور مشترک برای پیش‌بینی ساعتی بار الکتریکی استفاده شده‌اند. ابتدا از یک الگوریتم K-means برای خوشه‌بندی مجموعه داده که شامل بیش از ۱.۴ میلیون است استفاده می‌شود تا آن‌ها را به زیرمجموعه‌های مختلفی تقسیم کنند و سپس زیرمجموعه‌های به‌دست‌آمده برای فراگیری CNN مورد استفاده قرار می‌گیرند. در [۹] یک DNN embedded با مدل‌های Copula پارامتری برای پیش‌بینی ساعتی بار و مبتنی بر داده یک‌ساله در یک محیط شهری در تگزاس پیشنهاد شده است. نتایج آن‌ها مبین عملکردی بهتر از روش‌های متعارف SVR، ANN و ELM است. در [۱۰]، از DNN برای پیش‌بینی بار یک‌روزه بکار رفته است. یک مجموعه داده بازار Iberian و ۹۰ روزه برای فراگیری چندین ترکیب از تابع‌های فعال از هر دو یا یک لایه شبکه عصبی استفاده شده است. نتایج حاکی از آن است که ترکیب $ELU-ELU^2$ عملکرد بهتری از ترکیب‌های دیگر دارد وقتی با مقادیر $MAPE^3$ برای مجموعه داده هفته ارزیابی می‌شود و درحالی‌که برای مجموعه داده آخر هفته، ترکیب ReLU-ReLU عملکرد بهتری از ترکیب‌های دیگر دارد.

مقالات [۱۱ و ۱۲] سعی در استفاده از $CRBM^4$ و $FCRBM^5$ برای پیش‌بینی سطوح بار داشته‌اند. مقاله [۱۳] دو معماری شبکه عصبی مبتنی بر LSTM برای پیش‌بینی یک ساعت و یک دقیقه از بار پیشنهاد کرده است و نشان می‌دهد که یک معماری استاندارد LSTM نمی‌تواند با دقت یک دقیقه‌ای بار را پیش‌بینی کند؛ درحالی‌که برای معماری مبتنی بر S2S LSTM به عملکرد عالی در هر دو نمونه دست می‌یابد. در [۱۴] همان نویسندگان سعی بر استفاده از CNN برای پیش‌بینی بار در هر سطح نمودند. نتایج به‌دست‌آمده از CNN با نتایج به‌دست‌آمده از S2S مبتنی بر LSTM، FCRBM، ANN و SVM برای همان

¹ Load/demand Forecasting

² Exponential linear unit

³ Mean Absolute Percentage Error

⁴ Conditional Restricted Boltzmann Machines (CRBM)

⁵ Factored Conditional Restricted Boltzmann Machines (FCRBM)

مجموعه داده مقایسه شده است و نشان می‌دهد که CNN عملکرد بهتری از SVM دارد در حالی که نتایج قابل مقایسه با روش‌های ANN و DL تولید می‌کند. مقاله [۱۵] از DNN و تکنیک‌های یادگیری ماشین دیگر برای پیش‌بینی بار کوتاه‌مدت مبتنی بر داده کنتورهای هوشمند استفاده می‌کند. مقالات [۱۶ و ۱۷] از DBN^۱ برای پیش‌بینی بار استفاده می‌کنند. در این مراجع نشان داده شده است که همه انواع الگوریتم‌های یادگیری عمیق کاندیدهای مهم برای پیش‌بینی دقیق‌تر بار در مقایسه با روش‌های مرسوم هستند. آن‌ها می‌توانند با حجم زیاد داده حاصل از قرائت کنتورهای هوشمند و دیگر منابع داده استفاده کنند؛ هرچند عملکرد آن‌ها نیازمند انجام آزمون‌های بیشتری و با استفاده از مجموعه داده‌های متفاوت دارد.

۲-۵-۱۲- ریزشبکه‌ها

ریزشبکه‌ها مبتنی بر انرژی‌های تجدیدپذیر هستند، بنابراین برنامه‌ریزی و عملکرد آن‌ها با چالش‌هایی از ابهام به دلیل سختی در پیش‌بینی دقیق مصرف الکتریسیته و تولید انرژی تجدیدپذیر روبرو است. یادگیری عمیق، یادگیری تقویتی و یادگیری تقویتی عمیق در ایجاد راه‌حل‌هایی برای تصمیم‌گیری در ریزشبکه‌ها مفید هستند. مقاله [۱۸] از یادگیری تقویتی عمیق در کاربرد ریزشبکه‌ها در محیط‌هایی که به دلیل محدودیت در میزان داده، مشاهده جزئی وجود دارد، استفاده نموده است. برای رفع این چالش یک معماری یادگیری عمیق مخصوص برای استخراج اطلاعات از میزان مصرف گذشته و تولید سری زمانی طراحی شده است.

مدیریت انرژی یکی از مسائل اصلی برای ریزشبکه‌ها هستند. مقاله [۱۹] یک سیستم مدیریت انرژی پویا و برخط برای یک ریزشبکه با ترکیب برنامه‌ریزی پویای تطبیقی با یک یادگیری تقویتی به منظور تشخیص بهینه و نزدیک به بهینه در سیستم مدیریت انرژی پویا در هر دو مد اتصال به شبکه اصلی و عملکرد به صورت مجزا پیشنهاد نموده است. برنامه‌ریزی و عملکرد ذخیره انرژی در ریزشبکه‌ها یک مسئله مشکل است. مقالات [۲۰ و ۲۱] از یادگیری تقویتی در کنترل یک دستگاه ذخیره انرژی در یک ریزشبکه برای پیشینه‌سازی خودمصرفی انرژی تولیدشده از سیستم PV^۲ و کاهش هزینه الکتریسیته و وابستگی به شبکه داخلی استفاده نموده‌اند. در بعضی نمونه‌ها از سیستم‌های متنوع ذخیره انرژی با مشخصه عملی متفاوت به طور هم‌زمان در یک ریزشبکه برای بهبود انعطاف‌پذیری استفاده شده است. در مقاله [۲۲] یک استراتژی یادگیری عمیق برای کنترل مدت‌زمان شارژ و دشارژ سیستم‌های باتری متفاوت برای بهبود بازدهی سیستم مطرح شده است.

انتظار می‌رود که شبکه انرژی آینده نیاز به چندین ریزشبکه داشته باشد که باید با یکدیگر هماهنگ باشند؛ بنابراین وجود مدل تجاری در ریزشبکه‌ها ضروری است. یادگیری عمیق می‌تواند راه‌حل‌های مؤثری را برای این مسئله به‌ویژه در حالتی که اطلاعات کامل نیستند، ارائه دهد. مقاله [۲۳] یک چهارچوب جدید برای تجارت انرژی را با استفاده از یادگیری تقویتی در هر ریزشبکه برای انتخاب استراتژی تجارت انرژی در یک بازار مستقل ارائه نموده است تا درآمد متوسط را بیشینه نماید.

معمولاً برای ریزشبکه، تأمین‌کننده سرویس مسئولیت تهیه انرژی الکتریکی از شرکت و فروختن آن به کاربران را برعهده دارد. اگرچه هم تأمین‌کننده سرویس و هم مشتری با چالش‌هایی به دلیل ناقص بودن اطلاعات بدست‌آمده و انواع ابهامات در ریزشبکه مواجه می‌شوند. برای حل این مسئله، [۲۴] الگوریتم‌های یادگیری ماشین برای توانمندسازی هر تأمین‌کننده سرویس و مشتری بدون اطلاعات اولیه از ریزشبکه توسعه داده است. اثبات شده است که الگوریتم قیمت‌گذاری پویا مبتنی بر یادگیری تقویتی پیشنهادی بدون اطلاع از دینامیک‌های سیستم و الگوریتم مصرف انرژی می‌تواند مشتری‌ها را در تصمیم‌گیری منطقی کمک کند. به دلیل همزیستی چندین منبع انرژی متفاوت و ذینفعان متفاوت در ریزشبکه، برطرف‌سازی چالش‌های ناشی از وجود اطلاعات ناقص و مبهم ضروری هستند و یادگیری عمیق و یادگیری تقویتی یک ابزار مؤثر در مدیریت انرژی، تجارت انرژی و کنترل کاربردی در ریزشبکه‌ها است. روش‌های یادگیری عمیق و یادگیری تقویتی می‌توانند راه‌حل‌های فنی برای هماهنگی چندین ریزشبکه را تشکیل دهند.

^۱ Deep Belief Networks

^۲ Photovoltaic

۳-۵-۱۲- پاسخ بار^۱

تشخیص و پیش‌بینی انعطاف‌پذیری انرژی در طرف درخواستی برای انجام پاسخ بار ضروری هستند. قابلیت‌های اخیر کنتورهای هوشمند امکان نظارت سطح مصرف توان در سمت کاربران به صورت زمان حقیقی و تحلیل رفتار مصرفی کاربران را با روش پایش غیرمداخله‌ای بار (NILM^۲) فراهم کرده است. با استفاده از NILM مشخص می‌شود کدام وسیله استفاده شده است و چقدر توان مصرف کرده است. مقاله [۲۵] از یادگیری عمیق برای تعیین انعطاف‌پذیری بار و تأمین مراجع برای پاسخ بار به کار گرفته است. مقاله [۲۶] از RNN برای طبقه‌بندی کاربران استفاده نموده است و اثبات نموده است که الگوریتم مطرح شده می‌تواند عملکرد بهتری نسبت به روش‌های موجود داشته باشد. مقاله [۲۷] از یادگیری عمیق Q^۳ و روش گرادیان عمیق^۴ برای تصمیم‌گیری در هر دو سطح ساخت و سطح تجمیع استفاده می‌کند. نشان داده شده است که روش گرادیان عمیق عملکرد بهتری در مقایسه با یادگیری Q عمیق در برنامه‌ریزی برخط منابع انرژی در هر دو سطح دارد، اگرچه هر دو روش توانایی کمینه‌سازی هزینه انرژی یا سطح کردن پروفایل انرژی خالص را دارند.

[۲۸] از برنامه‌ریزی دینامیک تقریبی مبنی بر یادگیری Q برای حمایت از تصمیم‌گیری زمان حقیقی مشتریان استفاده می‌کند. [۲۹] از RL برای خوشه‌بندی مشتریان مبتنی بر توانایی‌شان برای ایجاد محدودیت، وقتی سیگنال‌های پاسخ درخواستی را دریافت نمودند، استفاده می‌کند. روش یادگیری تقویتی به خرده‌فروشان در تصمیم‌گیری‌شان کمک می‌کند (با در نظر گرفتن این حقیقت که بعضی از کاربردهای پاسخ‌دهنده نیاز مانند ترموستات پمپ گرما توسط گرما و آب‌وهوا تحت تأثیر قرار می‌گیرند). مقاله [۳۰] از داده‌های پیش‌بینی آب‌وهوا در یک روش شناخته‌شده یادگیری تقویتی و مرحله-Q متناسب برای حمایت از پاسخ‌دهی بار بکار گرفته است. نتایج تحقیق حاکی از آن است که توسعه مرحله-Q مطرح شده مناسب می‌تواند مرحله-Q مناسب و استاندارد را حدوداً ۲۷ درصد بهبود دهد. مشابهاً مقاله [۳۱] از یادگیری تقویتی و مرحله-Q متناسب برای تأمین یک سیاست کنترل برای کنترل‌کننده ترموستات استفاده می‌کند؛ در نتیجه کل هزینه مصرف انرژی گرم‌کننده الکتریکی به اندازه ۱۵ درصد کاهش می‌یابد. پاسخ بار ارتباط نزدیکی با مدیریت انرژی در سمت مشتری دارد. مقاله [۳۲] از یادگیری تقویتی برای تشخیص مدیریت انرژی خانه استفاده می‌کند که می‌تواند به‌طور خودکار یک سیاست برای حمایت از تصمیم‌گیری برای فروش و ذخیره‌سازی انرژی اضافی در خانه‌های هوشمند مبتنی بر داده تاریخی برای قیمت‌های انرژی، تولید انرژی، نیاز مصرف‌کنندگان و مشخصات سیستم‌های ذخیره تعیین کند. مقاله [۳۳] همچنین از الگوریتم یادگیری Q در سیستم مدیریت انرژی برای پاسخ‌دهی بار مسکونی استفاده نموده است و تأثیر قیمت‌های انرژی آینده و انتخاب دستگاه مصرفی آینده نیز در آن در نظر گرفته شده است.

مقاله [۳۴] یک فرایند تصمیم‌گیری مارکوف یگانه و ساده برای برنامه‌ریزی دستگاه‌ها و با در نظر گرفتن اینکه همه راه‌های جستجوی دستگاه‌ها فعال باشند، مطرح نموده است. در مقایسه با یادگیری-Q در سناریو خانه هوشمند، روش مطرح شده می‌تواند مشتریان را در تصمیم‌گیری سریع‌تر توانمند سازد. همچنین طراحی مکانیسم‌های جبران عادلانه برای پاسخ بار مهم و سخت هستند. [۳۵] از یک الگوریتم یادگیری عمیق برای یک برنامه پاسخ‌دهی بار برای پرداخت استفاده می‌کند. [۳۶] از یک شبکه عصبی با لایه‌های کانولوشنی با مرحله-Q مناسب در برنامه پاسخ‌دهی نیاز حقیقی با مشاهده جزئی استفاده می‌کند. قیمت‌گذاری پویا یک ابزار مؤثر برای تشویق مشتریان در شرکت در پاسخ‌دهی بار و تجارت انرژی است. اگرچه به دلیل نبود اطلاعات مورد نیاز به بار متغیر با زمان و الگوی مصرف انرژی و نوسان قیمت‌های الکتریسیته در عمده‌فروشی، پیاده‌سازی قیمت‌گذاری پویا بسیار چالش‌انگیز است. [۳۷] یک الگوریتم قیمت‌گذاری پویا و مبتنی بر یادگیری تقویتی بدون نیاز به اطلاعات کامل در مورد

¹ Demand Response (DR)² Nonintrusive Load Monitoring (NILM)³ Deep Q-learning⁴ Deep policy gradient

دینامیک‌های سیستم از پیش ارائه می‌کند. [۳۸] استفاده از الگوریتم‌های یادگیری-Q برای توسعه استراتژی‌های قیمت‌گذاری برای عامل‌های کارگزار در بازارهای شبکه‌های هوشمند مورد مطالعه قرار داده است.

۴-۵-۱۲- تشخیص نقص و خطا در تجهیزات الکتریکی

تشخیص نقص و خطا در تجهیزات الکتریکی جهت برقراری عملکردهای مطمئن در سیستم‌های قدرت بسیار مهم است. در سیستم‌های قدرت معمولی، حسگرها و سیستم‌های پایش بسیاری نصب شده‌اند و تغییرات تدریجی در سیستم تحلیل می‌شوند. به دلیل پیچیدگی داده‌های ضبط‌شده، وجود نقص‌ها نمی‌تواند در مراحل اولیه به‌آسانی تشخیص داده شوند. یادگیری عمیق جهت نظارت بر حالت سه بخش در شبکه‌های قدرت مورد استفاده قرار می‌گیرند: عایق‌ها، ترانس‌ها و خطوط انتقال. مقاله [۳۹] از CNN متمایزکننده^۱ سطح بالا برای استخراج مشخصه‌های عایق‌ها و تشخیص نقص‌هایشان بهره می‌گیرد. نتایج حاصله نشان می‌دهد که روش پیشنهاد شده می‌تواند به‌دقت ۹۳ درصد برسد.

با در نظر گرفتن اینکه داده نظارت آنالین رنگ نگاری روغن^۲ در طول نقص ترانس‌های قدرت بدون برچسب هستند و بنابراین روش‌های سنتی تشخیص اغلب در استفاده کامل از داده‌های نقص بدون برچسب عقب می‌مانند، مقاله [۳۸] یک روش طبقه‌بندی مبتنی بر یادگیری عمیق را ارائه نموده است. بر این اساس، یک روش تشخیص نقص جدید برای ترانس‌های قدرت نیز ارائه شده است که در آن داده بدون برچسب بسیاری از دستگاه‌های نظارت‌کننده برخط و تعداد کمی از داده برچسب‌دار از تحلیل گاز حل‌نشده در روغن به‌صورت کامل در فرایند یادگیری استفاده می‌شوند. نتایج حاکی از آن است که روش مطرح‌شده بهتر از سه روش مطرح شده دیگر، یعنی: مبتنی بر رادیو، شبکه عصبی و SVM است.

۵-۵-۱۲- کنترل و تحلیل سیستم‌های قدرت

تشخیص اختلال^۳، ارزیابی پایداری و کنترل شرایط اضطراری برای تضمین قابلیت اطمینان و امنیت در سیستم‌های قدرت ضروری هستند. سیستم‌های اندازه‌گیری محدوده وسیع (WAMS)^۴ حجم زیادی از داده تولید می‌کنند. بنابراین، چگونگی به دست آوردن اطلاعات مفید از این حجم داده و به‌صورت خودکار یک چالش حقیقی برای اپراتورهای سیستم است. مقاله [۴۰] از مدل چند سطحه یادگیری عمیق برای حمایت از مدیریت شرایط اضطراری در سیستم قدرت که مبتنی بر مدل مارکوف پنهان است، برای تولید داده برای بهینه‌سازی کلی استفاده می‌کند. در [۴۱] از یادگیری عمیق تقویتی برای تصمیم‌گیری در استراتژی‌های کنترل شرایط اضطراری بهره گرفته شده است. به‌ویژه CNN برای استخراج مشخصه‌ها در سیستم قدرت در طول فرایند شرایط گذرا و مدل Q دابل^۵ و مدل Q دوئل^۶ برای بهبود عملکرد از یادگیری Q و مقدار Q محاسبه شده، استفاده شده است. در سال‌های اخیر، سیستم‌های قدرت بزرگ‌تر و پیچیده‌تر گشته‌اند و عناصر جدید زیادی مانند باد، توان خورشیدی و دستگاه‌های الکتریکی در آن نفوذ کرده‌اند. این عناصر تزویج^۷ قوی و ابهام زیادی در سیستم قدرت ایجاد می‌کنند. تحت این شرایط، عملکرد روش‌های مبتنی بر مدل، که توأم با فرضیات و ساده‌سازی هستند، سؤال‌برانگیز می‌شوند. DL، RL و DRL جایگزین‌های مناسب، ارزشمند و بدون نیاز به مدل برای روش‌های مدل‌محور هستند. از سوی دیگر، از آنجایی که RL و DL مشخصات غیرقابل تفسیر دارند،

¹ Discriminative

² Oil chromatography online-monitoring

³ Disturbance

⁴ Wide Area Measurement Systems

⁵ double

⁶ dueling

⁷ Coupling

عملکرد این جعبه‌های سیاه با سؤال همراه است. برخی از پژوهشگران بر این باورند که ترکیب روش‌های مدل‌محور و داده‌محور می‌توانند عملکرد فرایندهای تحلیل و کنترل را بهبود دهند.

۶-۵-۱۲- امنیت سایبری

به کارگیری ICT در ساختار سیستم قدرت می‌تواند کیفیت نظارت و کنترل شبکه‌های هوشمند را به صورت مؤثر بهبود دهد ولی در عین حال وابسته بودن به ICT آسیب‌پذیری سیستم قدرت در برابر حملات مخرب^۱ را افزایش می‌دهد. تزریق داده نادرست (FDI)^۲ یک تهدید جدی برای سیستم‌های قدرت شده است. چگونگی حل این مسئله یک موضوع داغ در سال‌های اخیر است. مقاله [۴۲] از یادگیری-Q برای نظارت تغییرات توپولوژی و تحلیل آسیب‌پذیری شبکه‌های برق‌رسانی در حملات ترتیبی بر توپولوژی استفاده می‌کند. مقاله [۴۳] الگوریتم‌های مبتنی بر یادگیری عمیق برای تشخیص FDI و سرقت توان به صورت زمان حقیقی را پیشنهاد می‌کند. رفتارهای موقت با ابعاد زیاد حملات FDI که غیرقابل مشاهده هستند، با استفاده از CDBN^۳ برای تشخیص حملات بالقوه FDI با استفاده از اندازه‌گیری‌های زمان حقیقی، ردگیری می‌شوند. امنیت سایبری شبکه‌های هوشمند یکی از مهم‌ترین کاربردهای یادگیری تقویتی و عمیق است و به صورت مبسوط در فصل دوم همین گزارش به آن پرداخته شده است.

۷-۵-۱۲- پیش‌بینی تولید انرژی تجدیدپذیر

پیش‌بینی میزان انرژی تجدیدپذیر تولیدشده برای بهبود انضمام آن‌ها در شبکه قدرت که دارای مشخصات نامعین و متناوب هستند، بالاهمیت است. مقاله [۴۴] از شبکه‌های عصبی چندلایه در ترکیب با الگوریتم چندهدفه ژنتیک، و ELM ترکیب‌شده با k-NN، برای پیش‌بینی کوتاه‌مدت سرعت باد در شهر رژی^۴ استفاده می‌کند که با دقت خوبی همراه بوده است. روش‌های متعارف پیش‌بینی توان باد معایبی در شرایط آب و هوایی متفاوت دارند. مقاله [۴۵] از شبکه عصبی چندلایه برای پیش‌بینی باد استفاده می‌کند. این مقاله و نظایر آن نشان می‌دهند که روش‌های یادگیری عمیق به صورت فزاینده‌ای جهت پیش‌بینی میزان تولید انرژی تجدیدپذیر بکار رفته‌اند. به دلیل اینکه یادگیری عمیق دارای ویژگی‌های انعطاف‌پذیری، توانایی یادگیری خودانطباقی و نیاز کمتر به فرضیات فیزیکی دارد، انتظار می‌رود که دقت پیش‌بینی آن با افزایش منابع داده بهبود یابد.

۸-۵-۱۲- سایر کاربردها

بعضی مقالات دیگر وجود دارند که از یادگیری عمیق و یادگیری تقویتی در شاخه‌های فنی دیگری از سیستم‌های قدرت استفاده نموده‌اند. مقاله [۴۶] از RNNs برای هماهنگ نمودن پاسخ منابع توزیع‌شده انرژی (DER^۵) با شبکه قدرت بهره گرفته است. مقاله [۴۷] از یادگیری عمیق برای طبقه‌بندی کیفیت توان استفاده کرده است. [۴۸] یک روش یادگیری تقویتی مبتنی بر شبکه عصبی برای تعهد بهینه در حضور منابع انرژی خورشیدی PV پیشنهاد نموده است. مقاله [۴۹] یک مکانیسم یادگیری-Q جدید برای حمایت از کنترل بهره اتوماتیک (AGC^۶) در تصمیم‌گیری برای ترمیم معرفی نموده است. مقاله [۵۰] بر پیاده‌سازی

¹ Malicious

² False data injection (FDI)

³ Conditional deep Boltzmann machine (cDBM)

⁴ Regina in Saskatchewan, Canada

⁵ Distributed Energy Resources

⁶ Automatic Gain Control

^۱ DQL برای واکنشی نمودن بهینه‌سازی توان با متغیرهای کنترل گسسته تمرکز نموده است. نتایج حاکی از آن است که DQL در بهینه‌سازی ارسال توان واکنشی به برتری زیادتری نسبت به روش‌های RL و EV دست می‌یابد.

۶-۱۲- جمع‌بندی

در این فصل به برنامه‌های کاربردی و نقشی که روش‌های هوش مصنوعی و یادگیری ماشینی می‌توانند در بهبود آنها داشته باشند، پرداخته شد. ابتدا چالش‌های به‌کارگیری این روش‌ها در برنامه‌های کاربردی و رویکردهایی که در این زمینه وجود دارند مورد مطالعه و بررسی قرار گرفتند. در ادامه به‌کارگیری روش‌های یادگیری ماشینی در کاربردهای متنوعی که در مقالات گزارش داده شده‌اند، از جنبه‌های مختلف مورد بررسی قرار گرفت. جنبه‌هایی همچون: حوزه‌های به‌کارگیری روش‌های یادگیری ماشینی، نوع داده‌های جمع‌آوری شده برای اجرای الگوریتم‌ها و همین‌طور الگوریتم‌های مورد استفاده در یادگیری ماشینی. این اطلاعات یک شمای کلی از وضعیت استفاده روش‌های ماشینی در برنامه‌های مختلف کاربردی را به دست می‌دهد.

در بخش انتهایی نیز کاربردهای متنوعی که روش‌های یادگیری ماشینی در بخش‌های مختلف شبکه‌های هوشمند برق می‌توانند داشته باشند مورد بررسی قرار گرفت. به‌صورت خاص، کاربردهایی نظیر: پیش‌بینی بار / تقاضا، ریزش‌بکه‌ها، پاسخ بار، تشخیص نقص/خطا در تجهیزات الکتریکی، کنترل و تحلیل سیستم‌های قدرت، امنیت سایبری و پیش‌بینی تولید انرژی تجدیدپذیر مورد مطالعه و بررسی قرار گرفتند. هرکدام از این کاربردها می‌توانند به‌تنهایی موضوع یک پژوهش مستقل باشند.

¹ Dimensional Q-learning (DQL)

مراجع فصل ۱۲

1. B. McMahan et al., "Communication-Efficient Learning of Deep Networks from Decentralized Data," Proc. Int'l. Conf. Artificial Intell. Stat. (AISTATS), vol. 54, 2017, pp. 1273–82.
2. Y. Mao et al., "A Survey on Mobile Edge Computing: The Communication Perspective," IEEE Commun. Surveys Tuts., vol. 19, Fourth Qtr., 2017, pp. 2322–58.
3. K. Yang, Y. Shi, and Z. Ding, "Data Shuffling in Wireless Distributed Computing via Low-Rank Optimization," IEEE Trans. Signal Process., vol. 67, June 2019, pp. 3087–99.
4. H. Brendan McMahan, Eider Moore, Daniel Ramage, Seth Hampson, Blaise Aguera y Arcas, "Communication-Efficient Learning of Deep Networks from Decentralized Data", arXiv:1602.05629.
5. Rachad Taoufik, Idri Ali, "Intelligent Mobile Applications: A Systematic Mapping Study", Hindawi, 2020.
6. J. Bezerra, W. Bock, F. Candelon et al., Mobile Revolution: How Mobile Technologies Drive a Trillion-Dollar Impact, Boston Consulting Group, Boston, MA, USA, 2015.
7. L. Voynichka. Machine learning for the smart grid. [Online]. Available: <http://cs229.stanford.edu/proj2014/Iliana%20Voynichka,%20Machine%20Learning%20for%20the%20Smart%20Grid.pdf>.
8. X. S. Dong, L. J. Qian, and L. Huang, "Short-term load forecasting in smart grid: a combined CNN and K-means clustering approach," in IEEE International Conference on Big Data and Smart Computing (BigComp), Jeju, Korea, Feb. 13–16, 2017.
9. Y. S. He, J. H. Deng, and H. J. Li, "Short-term power load forecasting with deep belief network and copula models," in 2017 9th International Conference on Intelligent Human-Machine Systems and Cybernetics, Hangzhou, China, Aug. 26–27, 2017.
10. T. Hossen, S. J. Plathotam, R. K. Angamuthu et al., "Short-term load forecasting using deep neural networks (DNN)," presented at 2017 North American Power Symposium (NAPS). [Online]. Available: <https://engineering.und.edu/electrical/faculty/prakashranganathan/p232.pdf>.
11. V. Mnih, H. Larochelle, and G. Hinton, "Conditional restricted Boltzmann machines for structured output prediction," in Proceedings of the International Conference on Uncertainty in Artificial Intelligence, Barcelona, Spain, Jul. 14–17, 2011.
12. G. W. Taylor, G. E. Hinton, and S. T. Roweis, "Two distributed-state models for generating high-dimensional time series," Journal of Machine Learning Research, vol. 12, pp. 1025–1068, Mar. 2011.
13. D. L. Marino, K. Amarasinghe and M. Manic, "Building energy load forecasting using deep neural networks," in IECON 2016 - 42nd Annual Conference of the IEEE Industrial Electronics Society, Yokohama, Japan, Oct. 23–26, 2016.

14. K. Amarasinghe, D. L. Marino, and M. Manic, "Deep neural networks for energy load forecasting," in The 26th IEEE International Symposium on Industrial Electronics (ISIE), Edinburgh, Scotland, UK, Jun. 19–21, 2017.
15. S. Hosein and P. Hosein, "Load forecasting using deep neural networks," presented at 2017 IEEE Power & Energy Society Innovative Smart Grid Technologies Conference (ISGT). [Online]. Available: <http://www.rndrepository.com/smartgriduwi/files/smartgridcomm2016.pdf>.
16. A. Dedinec, S. Filiposka, A. Dedinec, and L. Kocarev, "Deep belief network-based electricity load forecasting: An analysis of the Macedonian case," *Energy*, vol. 115, part 3, pp. 1688–1700, Nov. 2016.
17. X. Qiu, L. Zhang, Y. Ren, P. N. Suganthan, and G. Amaratunga, "Ensemble deep learning for regression and time series forecasting," in 2014 IEEE Symposium on Computational Intelligence in Ensemble Learning (CIEL), 2014, pp. 1–6.
18. V. Francoislavet, D. Taralla, D. Ernst et al., "Deep reinforcement learning solutions for energy microgrids management," presented at European Workshop on Reinforcement Learning (EWRL 2016). [Online]. Available: <https://orbi.uliege.be/handle/2268/203831>
19. G. K. Venayagamoorthy, R. K. Sharma, P. K. Gautam et al., "Dynamic energy management system for a smart microgrid," *IEEE Transactions on Neural Networks and Learning Systems*, vol. 27, no.8, pp. 1643–1656, Aug. 2016.
20. B. V. Mbuwir, F. Ruelens, F. Spiessens et al., "Battery energy management in a microgrid using batch reinforcement learning," in International workshop of Energy-Open 2017, Enschede, the Netherlands, May 18–19, 2017.
21. B. V. Mbuwir, F. Ruelens, F. Spiessens et al. (2017, Nov.). Reinforcement learning-based battery energy management in a solar microgrid. *Energies*. [Online]. Available: <https://energy-open.nl/local/abstracts/012mbuwir.pdf>.
22. X. Qiu, T. A. Nguyen and M. L. Crow, "Heterogeneous energy storage optimization for microgrids," *IEEE Transactions on Smart Grid*, vol. 7, no.3, pp.1453–1461, May 2016.
23. H. W. Wang, T. W. Huang, X. F. Liao et al., "Reinforcement learning in energy trading game among smart microgrid," *IEEE Transactions on Industrial Electronics*, vol. 63, no.8, pp. 5109–5119, Aug. 2018.
24. B. G. Kim, Y. Zhang, M. V. D. Schaar et al., "Dynamic pricing and energy consumption scheduling with reinforcement learning," *IEEE Transactions on Smart Grid*, vol. 7, no. 5, pp. 2187–2198, Sep. 2016.
25. Pedro Paulo Marques do Nascimento, "Application of deep learning techniques on HILM," M.S. thesis, COPPE/UFRJ, Brazil, 2016.
26. K. Tornai, A. Olah, R. Drenyovszki et al., "Recurrent neural network-based user classification for smart grids," in IEEE Power & Energy Society Innovative Smart Grid Technologies Conference (ISGT), Arlington, VA, Washington D.C., 2017.

27. E. Mocanu, D. C. Mocanu, P. H. Nguyen et al., "On-line building energy optimization using deep reinforcement learning," IEEE Transactions on Smart Grid, to be published.
28. D. Li, and S. K. Jayaweera, "Machine-learning aided optimal customer decision for an interactive smart grid," IEEE Systems Journal, vol. 9, no. 4, pp.1529–1540, Dec. 2015.
29. S. Ahmed and F. Bouffard, "Building load management clusters using reinforcement learning," in 2017 8th IEEE Annual Information Technology, Electronics and Mobile Communication Conference (IEMCON), Vancouver, BC, Canada, Oct. 3–5, 2017.
30. B. J. Claessens, P. Vrancx, and F. Ruelens, "Convolutional neural networks for automatic state-time feature extraction in reinforcement learning applied to residential load control," IEEE Transactions on Smart Grid, vol. 9, no. 4, pp. 3259–3269, Jul. 2018.
31. F. Ruelens, B. J. Claessens, S. Quaiyum et al., "Reinforcement learning applied to an electric water heater: from theory to practice," IEEE Transactions on Smart Grid, vol. 9, no. 4, pp. 3792–3800, Jul. 2018.
32. H. Berlink and A. H. R. Costa, "Batch reinforcement learning for smart home energy management," in Proceedings of the Twenty-Four International Joint Conference on Artificial Intelligence (IJCAI 2015), Buenos Aires, Argentina, Jul. 25–31, 2015.
33. D. O' Neill, M. Levorato, A. Goldsmith et al., "Residential demand response using reinforcement learning," in 2010 First IEEE Conference on Smart Grid Communications (SmartGridComm), Gaithersburg, MD, USA, Oct. 4–6, 2010.
34. N. Chauhan, N. Choudhary and K. George, "A comparison of reinforcement learning based approaches to appliances scheduling," in 2016 2nd International Conference on Contemporary Computing and Informatics (IC3I), India, Dec. 14–17, 2016.
35. G. O' Brien, A. E. Gamal, and R. Rajagopal, "Shapley value estimation for compensation of participants in demand response programs," IEEE Transactions on Smart Grid, vol. 6, no. 6, pp. 2837–2844, Nov. 2015.
36. F. Ruelens, B. J. Claessens, S. Vandeal et al., "Residential demand response of thermostatically controlled loads using batch reinforcement learning," IEEE Transactions on Smart Grid, vol. 8, no.5, pp. 2149– 2159, Sep. 2017.
37. B. G. Kim, Y. Zhang, M. V. D. Schaar, and J. W. Lee, "Dynamic pricing for smart grid with reinforcement learning," 2014 IEEE Conference on Computer Communications Workshops (INFOCOM WKSHPS), Toronto, Ontario, Canada, Apr. 27–May 2, 2014.
38. P. P. Reddy and M. M. Veloso, "Strategy learning for autonomous agents in smart grid markets," Proceedings of the Twenty-Second international joint conference on Artificial Intelligence, vol. 2, pp. 1446–1451, Jul. 2011.
39. Z. B. Zhao, X. Q. Fan, G. Z. Xu et al., "Multi-patch deep features for power line insulator status classification from aerial images," IEEE International Joint Conference on Neural Networks (IJCNN), New Delhi, India, Jul. 24–29, 2016.

40. X. Z. Wang, J. Zhou, Z. L. Huang et al., "A multilevel deep learning method for big data analysis and emergency management of power system," IEEE International Conference on Big Data Analysis (ICBDA), Hangzhou, China, Mar. 12–14, 2016.
41. W. Liu, D. X. Zhang, X. Y. Wang et al., "A decision making strategy for generating unit tripping under emergency circumstances based on deep reinforcement learning," Proceedings of the CSEE, vol. 38, no. 1, pp.109–119, Jan. 2018. (in Chinese).
42. J. Yan, H. B. He, X. N. Zhong and Y. F. Tang, "Q-learning-based vulnerability analysis of smart grid against sequential topology attacks," IEEE Transactions on Information Forensics and Security, vol. 12, no. 1, pp.200–210, Jan. 2017.
43. Y. B. He, G. J. Mendis, and J. Wei, "Real-time detection of false data injection attacks in smart grid: a deep learning-based intelligent mechanism," IEEE Transactions on Smart Grid, vol. 8, no. 5, pp. 2505– 2516, Sep. 2017.
44. B. Ak, O. Fink and E. Zio, "Two machine learning approaches for short-term wind speed time-series prediction," IEEE Transactions on Neural Networks and Learning Systems, vol. 27, no.8, pp.1734–1747, Aug. 2016.
45. Y. Q. Li, C. B. Dai, T. X. Wang, Z. Zhou et al., "Separate wind power and ramp predictions based on meteorological variables and clustering method," in 2016 IEEE 6th International Conference on Power Systems (ICPS), New Delhi, India, Mar. 4–6, 2016.
46. E. M. Avila, "Artificial recurrent neural networks for the distributed control of electrical grids with photovoltaic electricity," Ph.D. thesis, ETSIT (UPM), Spain, 2016.
47. E. Balouji and O. Salor, "Classification of power quality events using deep learning on event images," in 2017 3rd International Conference on Pattern Recognition and Image Analysis (IPRIA 2017), Shahrekord, Iran, Apr. 19–20, 2017.
48. E. A. Jasmin, T. P. I. Ahamed, T. Ramani, "A function approximation approach to reinforcement learning for solving unit commitment problem with photo voltaic sources," in 2016 IEEE International Conference on Power Electronics, Drives and Energy Systems (PEDES), Trivandrum, India, Dec. 14–17, 2016.
49. M. J. Ghorbani, M. A. Choudhry, and A. Feliachi, "A multiagent design for power distribution systems automation," IEEE Transactions on Smart Grid, vol. 7, no. 1, pp. 329–339, Jan. 2016.
50. X. Y. Shang, M. S. Li, T. Y. Ji et al., "Discrete reactive power optimization considering safety margin by dimensional Q-Learning," in 2015 IEEE Innovative Smart Grid Technologies Asia (ISGT ASIA), Bangkok, Thailand, Nov. 3–6, 2015.

مرحله پنجم. جمع‌بندی و ارائه پیشنهاد برای ادامه کار

فصل ۱۳. جمع‌بندی نهایی و پیشنهاد عناوین پروژه‌هایی برای ادامه کار

۱-۱۳- مقدمه

در این فصل با توجه به مطالعات صورت گرفته در این پروژه و جهت جمع‌بندی نهایی فهرستی از فعالیت‌های پژوهشی که در آنها روش‌های یادگیری ماشینی می‌توانند در صنعت برق و شبکه هوشمند مورد استفاده قرار گیرند، در قالب تعریف پروژه ارائه شده‌اند. پس از ارائه فهرستی از پروژه‌های کاربردی و جهت برقراری پل ارتباطی مابین کاربردهای شبکه هوشمند و فناوری‌های مخابراتی فهرست کاملی از تمامی کاربردهایی که در شبکه هوشمند وجود دارند ارائه می‌شود و پس از آن فناوری‌های ارتباطی که تاکنون در این شبکه‌ها مورد استفاده قرار گرفته‌اند و همچنین به صورت مشخص، اینکه در کدامین کاربردها می‌توانند مورد بهره‌برداری قرار بگیرند بیان می‌شوند. در انتها نیز مروری بر فعالیت‌های انجام شده در این پروژه و در قالب جمع‌بندی نهایی ارائه می‌شود.

۲-۱۳- فهرست پروژه‌های پیشنهادی

۱-۲-۱۳- استفاده از رادیو شناختی در مخابرات شبکه برق کشور

همان‌طور که در فصل اول گزارش توضیح داده شده است، رادیو شناختی به مصرف بهینه پهنای باند در اختیار می‌پردازد. به این صورت که ممکن است یک پهنای باند با رعایت اولویت و حق تقدم در اختیار کاربردهای مختلفی قرار داده شود. به این ترتیب در زمان‌هایی که کاربردهای با اولویت بالا از این پهنای باند استفاده نمی‌کنند، این پهنای باند می‌تواند در اختیار کاربردهایی با اولویت پایین‌تر قرار داده شود.

شبکه برق کشور نیز مرتباً به سمت شبکه برق هوشمند حرکت می‌کند که لازمه آن قرارگیری حسگرهای بسیار زیاد در اقصای نقاط شبکه و انتقال داده جمع‌آوری شده به مراکز داده است. به این ترتیب برقراری ارتباط برای تعداد زیادی حسگر نیازمند مدیریت پهنای باند خواهد بود. پهنای باندهایی که برای برقراری ارتباط در محیط بیرون از خانه در هر کشور استفاده می‌شود ممکن است با کشورهای دیگر متفاوت باشد و بستگی به نظر سازمان تنظیم قوانین و مقررات رادیویی دارد. در نتیجه هدف از این پروژه می‌تواند شناسایی پهنای باندهای قابل استفاده و تعیین ظرفیت آن‌ها در رادیو شناختی با توجه به امکانات و زیرساخت‌های مخابراتی کشور و همچنین تجهیزات و حسگرهای مورد استفاده فعلی یا آینده باشد.

۲-۲-۱۳- استفاده از رادیو شناختی در اینترنت اشیاء خانگی

یکی از مباحثی که امروزه در دنیا به آن توجه زیادی شده، بحث خانه هوشمند است. وسایل خانگی مختلف به عنوان گره‌های شبکه اینترنت خانگی در نظر گرفته شده که با یکدیگر در ارتباط هستند. گره‌های مختلف معمولاً با یک سیستم کنترل مرکزی یا کنترلر هوشمند در ارتباط هستند که می‌تواند با استفاده از هوش مصنوعی یا یادگیری ماشین و همچنین در نظر گرفتن سلیقه و علایق افراد وسایل مختلف را مدیریت کند.

از آنجایی که دستگاه‌های مختلف ممکن است از شبکه‌های مختلف مخابراتی استفاده کرده و در باندهای مختلف فرکانسی کار کنند، صرفه‌جویی در پهنای باند و همچنین مصرف توان از نیازهای اساسی شبکه اینترنت اشیاء خانگی است. برای هر وسیله حالت‌های بسیار مختلفی در ساعات مختلف روز ممکن است وجود داشته باشد که یادگیری ماشین و روش‌های DQL می‌توانند با مشاهده رفتار اجزاء شبکه، تصمیمات بهینه‌ای را در راستای اختصاص پهنای باند و مصرف توان اتخاذ کنند.

۳-۲-۱۳- آزمون ایده در خصوص به کارگیری یادگیری ماشینی در شبکه‌های کم مصرف وسیع

در خصوص مزایا و لزوم استفاده از شبکه‌های حسگری و اینترنت اشیا در صنعت برق و همین طور شبکه هوشمند، پروژه‌های مختلفی در دنیا، چه در محیط‌های دانشگاهی و چه در بخش صنعت، و همین طور در پژوهشگاه نیرو انجام شده‌اند. جهت به کارگیری آن‌ها، شبکه‌های کم مصرف وسیع ($LPWAN^1$) یکی از گزینه‌های بارز است؛ شبکه‌هایی همچون NB-IoT, LoRA, SigFOX, ... همگی در ذیل خانواده LPWAN می‌گنجند.

شبکه‌های LPWAN کاربردهای وسیعی در انجام اندازه‌گیری‌ها در سامانه‌های انرژی (همچون گاز و برق)، خانه‌های هوشمند و ... دارند و نمونه‌هایی از آن‌ها در شهرهای مختلف ایران هم نصب شده‌اند که هم‌اکنون مورد بهره‌برداری هستند. ایجاد هرگونه بهبود در عملکرد این شبکه‌ها به صورت مستقیم به بهبود عملکرد زیرسامانه‌های مورد استفاده در آن صنعت می‌انجامد. به عنوان مثال با بهبود پروتکل‌های مورد استفاده در حسگرها، می‌توان مصرف انرژی آن‌ها را کاهش داد که منتج به افزایش طول عمر باتری‌های آن‌ها گردیده و در نهایت مقدار قابل توجهی از هزینه‌های مرتبط با انجام امور پشتیبانی و تعویض باتری‌های این حسگرها، که نوعاً در مکان‌های دور از دسترس نیز تعبیه شده‌اند، کاهش خواهد یافت. افزایش بعد مسافتی کارکردی و استفاده بهتر از طیف فرکانسی از دیگر مزایای بهبود عملکرد خواهد بود.

با توجه به مطالب فوق و همین طور در ادامه پروژه "آینده پژوهی در خصوص سیستم‌های ارتباطی هوشمند و کاربردهای آن‌ها در صنعت برق" که ارتقاء عملکرد اجزای سیستم‌های مخابراتی با استفاده از روش‌های هوش مصنوعی را مورد بررسی قرار داده بود، هدف اصلی در این پروژه معطوف به به کارگیری روش‌های یادگیری ماشینی در شبکه‌های کم مصرف وسیع و پیاده‌سازی یک نمونه و ارزیابی آن در محیط نرم‌افزاری است.

مراحل انجام پروژه به این صورت است که ابتدا مروری بر بخش‌های سیستمی موجود در شبکه‌های LPWAN که قابلیت به کارگیری روش‌های یادگیری ماشینی را دارند خواهیم داشت. سپس سابقه به کارگیری روش‌های یادگیری ماشینی در این شبکه‌ها مورد مطالعه و بررسی قرار خواهد گرفت. در ادامه به بررسی استانداردهای موجود در خصوص به کارگیری روش‌های یادگیری ماشینی در کاربردهای صنعتی پرداخته خواهد شد. سپس یکی از این شبکه‌ها انتخاب شده و عملکرد آن در حالت پیش فرض مورد ارزیابی قرار خواهد گرفت. در انتها نیز یکی از روش‌های مناسب، که در طی پروژه انتخاب خواهد شد، پیاده‌سازی شده و بهبودی عملکرد آن مورد ارزیابی قرار خواهد گرفت.

انتظار می‌رود که نتایج حاصله از انجام این پروژه که مبتنی بر اعداد و ارقام کمی (و نه محدود به توصیفات کیفی) هستند، متولیان فعال در سامانه‌های اندازه‌گیری صنعت برق (همچون کنتور هوشمند و سیستم توزیع) را ترغیب به استفاده از این روش‌ها در سیستم‌هایشان نماید. همچنین در ادامه این پروژه، مراحل دیگری همچون برپایی پایلوت‌های سخت‌افزاری و انجام آزمون در محیط‌های آزمایشگاهی و صنعتی قابل انجام خواهند بود.

۴-۲-۱۳- آزمون ایده در خصوص به کارگیری روش‌های یادگیری ماشینی در سامانه‌های MIMO انبوه و به کارگیری آن‌ها در شبکه هوشمند

سامانه‌های پیشرفته مخابراتی بخشی لاینفک در برپایی شبکه‌های هوشمند انرژی هستند. با افزایش روزافزون ادوات هوشمند و حسگرها و نیز به کارگیری اینترنت اشیا در این شبکه‌ها، میزان حجم داده‌های مبادله شده رشد بسیار چشم‌گیری پیدا خواهند

¹ Low Power Wide Area Networks

کرد که بسیاری از این تبادلات به صورت بی سیم خواهند بود. به عنوان مثال داده‌های کنتورهای هوشمند به یک ایستگاه مرکزی ارسال خواهند شد و به این ترتیب میزان عملکرد ایستگاه‌های مرکزی دریافت داده، تأثیری مستقیم بر عملکرد کلی شبکه ارتباطی داده‌ها خواهد داشت.

سامانه‌های MIMO انبوه یکی از روش‌های پیشرفته‌ای است که در مخابرات بی سیم مورد استفاده قرار می‌گیرد و هم در حوزه دانشگاهی و هم در حوزه صنعت، توجه بسیاری از پژوهشگران را به خود معطوف کرده است. استفاده از این سامانه‌ها از طریق پردازش پیشرفته سیگنال میسر می‌شود که باعث ارتقاء پارامترهای مهمی نظیر گذردهی و ضریب اطمینان در گیرنده می‌گردد. ولی پیاده‌سازی آن‌ها در عمل با چالش‌های بسیاری توأم است: میزان مصرف انرژی، تعداد بالای زنجیره‌های رادیویی، غیرخطی بودن تقویت کننده‌ها و ... که نیاز به توجه بسیار در فاز طراحی جهت رسیدن به یک کارایی بالا و در عین حال مقرون به صرفه از لحاظ اقتصادی دارد. استفاده از این سامانه‌ها در شبکه‌های هوشمند در پروژه‌های اروپایی نظیر SmartEMC2 برای قرائت داده‌های کنتورها مورد بررسی و پژوهش قرار گرفته است.

با توجه به مطالب فوق و همین‌طور در ادامه پروژه "آینده پژوهی در خصوص سیستم‌های ارتباطی هوشمند و کاربردهای آن‌ها در صنعت برق" که ارتقاء عملکرد اجزای سیستم‌های مخابراتی با استفاده از روش‌های هوش مصنوعی را مورد بررسی قرار داده بود، هدف اصلی در این پروژه معطوف به به کارگیری روش‌های یادگیری ماشینی در سامانه‌های MIMO انبوه و به کارگیری آن‌ها در شبکه هوشمند و پیاده‌سازی یک نمونه و ارزیابی آن در محیط نرم‌افزاری است. گفتنی است که این پروژه در راستای فعالیت‌های محور پژوهشی پردازش سیگنال گروه فناوری اطلاعات و ارتباطات بوده و همچنین در ارتباط با فعالیت‌های در دست اجرای یکی از پروژه‌های بهتام گروه نیز هست.

مراحل انجام پروژه به این صورت است که ابتدا سابقه به کارگیری سامانه‌های MIMO انبوه در شبکه‌های هوشمند مورد مطالعه و بررسی قرار خواهد گرفت. سپس به بررسی نحوه به کارگیری روش‌های یادگیری ماشینی در سامانه‌های MIMO انبوه پرداخته خواهد شد. در ادامه یک مدل نرم‌افزاری از به کارگیری MIMO انبوه در یک سیستم قرائت داده توسعه داده شده و عملکرد آن در حالت پیش فرض که از روش‌های مدل محور (و نه مبتنی بر یادگیری ماشینی) استفاده می‌کنند، مورد ارزیابی قرار خواهد گرفت. بخش اصلی پروژه نیز پیاده‌سازی برخی از روش‌های یادگیری ماشینی مناسب بر روی مدل توسعه داده شده و بررسی و ارزیابی عملکرد آن‌ها خواهد بود.

انتظار می‌رود که نتایج حاصله از انجام این پروژه که مبتنی بر اعداد و ارقام کمی (و نه محدود به توصیفات کیفی) هستند، متولیان فعال در سامانه‌های اندازه‌گیری صنعت برق (همچون کنتور هوشمند و سیستم توزیع) را ترغیب به استفاده از این روش‌ها در سیستم‌هایشان نماید. همچنین در ادامه این پروژه، مراحل دیگری همچون برپایی پایلوت‌های سخت‌افزاری و انجام آزمون در محیط‌های آزمایشگاهی و صنعتی قابل انجام خواهند بود.

۵-۲-۱۳- استفاده از صفحات بزرگ هوشمند در خانه هوشمند

همان‌طور که در فصل دوم گزارش که مربوط به صفحات بزرگ هوشمند و آنتن‌های MIMO انبوه است اشاره شد، صفحات بزرگ هوشمند قابلیت هدایت امواج به سمت گیرنده را دارند و می‌توانند دامنه و فاز آن‌ها را کنترل نمایند. امواجی که از فرستنده ساطع می‌شود به‌طور کلی یا از طریق دیدمستقیم و یا غیرمستقیم به گیرنده می‌رسد. در خانه هوشمند وسایل متعددی ممکن است با یکدیگر و با کنترل کننده مرکزی در ارتباط باشند. وسایل خانه هوشمند را می‌توان به دو دسته متحرک و غیر متحرک تقسیم‌بندی نمود. واضح است که برای برخی از وسایل و بخصوص وسایل متحرک ممکن است امکان برقراری ارتباط از طریق دیدمستقیم وجود نداشته باشد. امواجی منتشرشده از فرستنده در فضای خانه می‌توانند با برخورد به دیوارها یا اشیاء نیز به سمت گیرنده حرکت کرده و ارتباط را برقرار نمایند. مسئله‌ای که در اینجا حائز اهمیت است، این است که امواجی که مسیر دیدمستقیم یا مسیرهای دید

غیرمستقیم را طی می‌کنند دارای دامنه و فازهای مختلفی هستند و از آنجاکه گیرنده جمع برداری این امواج را آشکار می‌کند، قدرت سیگنال دریافت شده به دامنه و فاز امواج وابسته است.

با نصب صفحات بزرگ هوشمند خانه هوشمند می‌توان با کنترل دامنه و فاز موج‌هایی که به دیوارها و سقف خانه تابیده می‌شود، این امواج را به سمت گیرنده خاصی هدایت کرد تا سیگنال دریافت شده در محل گیرنده تقویت شود یا سیگنال را در محل گیرنده دیگری تضعیف کرد تا از بروز تداخل جلوگیری نمود. به این ترتیب در مصرف توان و انرژی نیز صرفه‌جویی بیشتری صورت می‌گیرد که هدف از ایجاد خانه هوشمند نیز دقیقاً همین امر است.

این پروژه را می‌توان با در نظر محیطی به عنوان خانه و چندین وسیله هوشمند با سناریوهای مختلفی از قبیل کاهش مصرف انرژی و افزایش بازدهی، افزایش پوشش ارتباطی در فضای خانه، کاهش تداخل و ایجاد امنیت در مقابل استراق سمع مخابراتی تعریف نمود و این اهداف را با استفاده از روش‌هایی مانند یادگیری ماشین و هوش مصنوعی بهینه کرد.

۶-۲-۱۳- استفاده از صفحات هوشمند در اینترنت اشیاء صنعتی

در صنعت برق هوشمند هدف ارتباط دوطرفه بین مصرف‌کننده و تولیدکننده به منظور بهینه‌سازی تولید و مصرف و پاسخ به تقاضا است. برای این منظور نیاز به جمع‌آوری داده از قسمت‌های مختلف شبکه برق از جمله تولید، توزیع و انتقال و مصرف‌کننده است تا این داده‌ها برای اتخاذ تصمیم به مراکز کنترلی انتقال یابد. این مراکز نیز با استفاده از روش‌های بهینه‌سازی مختلف از جمله یادگیری ماشین و هوش مصنوعی می‌توانند، تصمیماتی را به منظور عملکرد بهینه سیستم اتخاذ کرده و آن را به اجزای مختلف شبکه ابلاغ نمایند. یکی از قسمت‌های مهم که کنترل آن نیز بسیار حائز اهمیت است در مراکز تولید می‌باشند که برای جمع‌آوری داده در این محیط‌های صنعتی از اینترنت اشیاء صنعتی نیز می‌توان استفاده کرد.

از آنجایی که در اینترنت اشیاء صنعتی تعداد حسگرها می‌تواند بسیار زیاد باشد و بحث مصرف انرژی برای حسگرها از اهمیت زیادی برخوردار است، ترکیب صفحات بزرگ هوشمند می‌تواند در برقراری ارتباط مؤثر و مصرف انرژی کمک نماید. در این پروژه با توجه به ابعاد محیط و اجزایی که در محیط قرار دارند، جایابی صفحات بزرگ هوشمند نیز می‌تواند به منظور پایین آوردن مصرف توان، بهبود پوشش و کاهش تداخل صورت گیرد.

۷-۲-۱۳- استفاده از صفحات هوشمند در بخش توزیع و انتقال شهری

یکی از بخش‌های مهم از صنعت برق هوشمند بخش توزیع و انتقال است. این بخش که معمولاً بسیار گسترده است در محیط‌هایی با پراکندگی جمعیتی متفاوتی پخش شده است. در محیط‌های کم‌جمعیت یا بدون جمعیت ممکن است برای برقراری ارتباط حسگرها با یکدیگر یا حسگرها با مرکز کنترلی بتوان از فناوری‌های موجود استفاده نمود اما در محیط‌های شهری که ارتباطات مخابراتی مختلفی نیز در شهرها و خانه‌ها وجود دارد، ارتباط حسگرها می‌تواند تحت و شعاع قرار گیرد. با قرار دادن صفحات هوشمند در محیط‌های شهری می‌توان ارتباط کنتورهای خانگی و حسگرها را در محیط شهری با مصرف توان بهینه و همچنین حداقل تداخل با فناوری‌های نسل چهارم و پنجم مخابراتی پیاده‌سازی نمود.

۸-۲-۱۳- آزمون ایده در خصوص به کارگیری روش‌های یادگیری ماشینی در مسیریابی داده‌ها در شبکه‌های ارتباطی مورد استفاده در صنعت برق

در مرحله سوم این پروژه بیان شد که شبکه‌های بسیار بزرگی شامل صدها و حتی هزاران مسیریاب برای تبادل داده‌ها در صنعت برق مورد نیاز خواهد بود. به کارگیری روش‌های یادگیری ماشینی می‌تواند به یاری روش‌های سنتی که در این زمینه وجود

دارند بیاید و باعث ارتقاء عملکرد آنها در چنین شبکه‌های وسیع و پیچیده‌ای شود. با توجه به امکانات آزمایشگاهی موجود در گروه فناوری اطلاعات و ارتباطات پژوهشگاه نیرو، در این پروژه که به صورت آزمون ایده مطرح می‌شود، می‌توان برخی از روش‌های یادگیری ماشینی را در دو مرحله شبیه‌سازی کامپیوتری و پیاده‌سازی در محیط آزمایشگاهی بر روی مسیریاب‌ها و شبکه‌های مورد استفاده پیاده نمود.

۹-۲-۱۳- تشخیص حمله جمینگ به شبکه برق با استفاده از یادگیری ماشینی

در زندگی امروزه نقش برق بسیار پررنگ و غیرقابل انکار است در نتیجه از کارافتادن قسمتی از شبکه برق یا قطعی آن می‌تواند زندگی مردم را دچار اختلال نماید. یک نمونه از مواردی که باید در پدافند غیرعامل به آن توجه نمود بمب‌های الکترومغناطیسی و حملات جمینگ است. به این صورت که دشمن با استفاده از ایجاد امواج با توان بالا می‌تواند اجزایی که دارای برد الکترونیکی هستند را دچار اختلال موقت یا آسیب دائمی نماید. حسگرها یا کلیدهایی که در طول شبکه هستند می‌توانند در معرض این حمله قرار گیرند و وظیفه خود را به درستی انجام ندهند یا سیگنال اشتباهی را از وضعیت شبکه مخابره نمایند. برخی از تجهیزات و مراکز مهم را می‌توان توسط شیلدینگ و استفاده از محفظه در مقابل امواج محافظت کرد اما این کار برای همه حسگرها و دستگاه‌ها امکان پذیر نیست. از آنجایی که در شبکه برق هوشمند تعداد این حسگرها می‌تواند بسیار زیاد باشد، بررسی این که سیگنال ارسال شده از آن صحیح یا غلط است کار دشواری خواهد بود.

یکی از روش‌های بهینه برای تشخیص صحیح یا غلط بودن سیگنال‌ها استفاده از هوش مصنوعی و یادگیری ماشینی است. به این صورت که سیگنال‌های ارسالی از حسگرها در طول یک مدت از زمان ذخیره شده و یاد گرفته می‌شود. به این ترتیب با استفاده از روش‌های دسته‌بندی و در نظر گرفتن وضعیت تعداد زیادی حسگر، می‌توان حالت‌های واقعی را از حالت‌های غیرواقعی تشخیص داد.

۱۰-۲-۱۳- بررسی امنیت شبکه برق در اتصال با شبکه ابری

شبکه برق هوشمند نیازمند تحلیل و آنالیز داده‌های کلانی است که از قسمت‌های مختلف از جمله مصرف کنندگان، تولید کنندگان و بخش‌های توزیع و انتقال به مراکز داده منتقل می‌شود. به منظور تحلیل، می‌توان از شبکه‌های ابری استفاده نمود. از آنجاکه پردازش ابری به صورت مرکزی می‌تواند دارای محاسبات پیچیده سنگین و پرهزینه باشد، روش‌هایی توزیع شده مانند پردازش مه نیز می‌تواند مورد استفاده قرار گیرد. ارتباط حسگرها با شبکه ابری یا مه می‌تواند حملات این شبکه‌ها را به شبکه برق منتقل نماید. از آنجایی که حسگرهایی که در شبکه برق مورد استفاده قرار می‌گیرند باید دارای مصرف توان پایین باشند، استفاده از تجهیزات برای پیاده‌سازی الگوریتم‌های با امنیت بالا و رمزگذاری پیچیده در آنها به صرفه نیست. در نتیجه می‌توان از الگوریتم‌هایی مؤثر و بدون نیاز به محاسبات زیاد بر پایه یادگیری ماشینی در این زمینه استفاده نمود.

۱۱-۲-۱۳- به کارگیری روش‌های یادگیری ماشینی برای پیش‌بینی بار و تقاضا

با نفوذ بالای استفاده از انرژی‌های خورشیدی و بادی، برنامه‌ریزی و عملکرد سیستم‌های قدرتی با چالش‌های افزایش ابهام مواجه‌اند. بنابراین پیش‌بینی دقیق میزان تقاضای انرژی از اهمیت بالایی برخوردار است. اگرچه روش‌های زیادی برای پیش‌بینی بار الکتریکی وجود دارد ولی بیشتر آنها مبتنی بر مجموعه داده‌های کوچک و بدون در نظر گرفتن حجم زیاد داده تهیه شده توسط کتورهای هوشمند هستند. با توجه به بررسی‌های صورت گرفته در فصل سوم، مشاهده گردید که انواع مختلف الگوریتم‌های یادگیری عمیق کاندیدهای مهمی برای پیش‌بینی دقیق تر بار در مقایسه با روش‌های مرسوم هستند و می‌توانند با حجم زیاد داده

حاصل از قرائت کنتورهای هوشمند و دیگر منابع داده استفاده کنند. بررسی کامل تر روش‌های یادگیری ماشینی و سپس پیاده‌سازی آنها در عمل می‌تواند موضوع یک پروژه تحقیقاتی باشد.

۱۲-۲-۱۳- به کارگیری روش‌های یادگیری ماشینی در ریزشبکه‌ها

ریزشبکه‌ها متکی بر استفاده از انرژی‌های تجدیدپذیر هستند، بنابراین برنامه‌ریزی و عملکرد آنها با چالش‌هایی از ابهام به دلیل سختی در پیش‌بینی دقیق مصرف الکتریسیته و تولید انرژی تجدیدپذیر روبرو است. روش‌های یادگیری ماشینی می‌توانند در انجام بهتر تصمیم‌گیری‌ها در ریزشبکه‌ها مفید باشند. به‌ویژه به دلیل محدودیت در میزان داده و وجود پدیده مشاهده جزئی در محیط‌هایی که ریزشبکه‌ها عمل می‌کنند، استفاده از روش‌های یادگیری تقویتی عمیق می‌تواند بسیار کارا باشند. به‌عنوان مثال، مدیریت انرژی یکی از مسائل اصلی برای ریزشبکه‌ها است. انتظار می‌رود که یک سیستم مدیریت انرژی بتواند به‌صورت پویا و برخط قادر به برقراری یک عملکرد مناسب برای ریزشبکه‌ها در هر دو مد اتصال به شبکه اصلی و عملکرد به‌صورت مجزا باشد.

۱۳-۲-۱۳- به کارگیری روش‌های یادگیری ماشینی در پاسخ بار

تشخیص و پیش‌بینی انعطاف‌پذیری انرژی در طرف درخواستی برای انجام پاسخ بار ضروری هستند. قابلیت‌های اخیر کنتورهای هوشمند امکان نظارت سطح مصرف توان در سمت کاربران به‌صورت زمان حقیقی و تحلیل رفتار مصرفی کاربران را فراهم کرده است؛ به‌این‌ترتیب مشخص می‌شود کدام وسیله استفاده شده است و چقدر توان مصرف نموده است. روش‌های یادگیری ماشینی می‌توانند برای تعیین انعطاف‌پذیری بار، طبقه‌بندی کاربران و ... مورد استفاده قرار گیرد. در همین راستا می‌توان کنترل مستقیم بار را نیز صورت داد. با توجه به پژوهش‌هایی که تاکنون در این زمینه صورت گرفته است، موضوعات و چالش‌های مختلفی برای پیاده‌سازی پاسخ بار وجود دارند که روش‌های ماشینی می‌توانند در آنها نقش بسزایی ایفا نمایند و به‌این‌ترتیب یک موضوع تحقیقاتی نسبتاً گسترده‌ای را فراهم نمایند.

۱۴-۲-۱۴- به کارگیری روش‌های یادگیری ماشینی جهت تشخیص نقص و خطا در تجهیزات الکتریکی

تشخیص نقص/خطا در تجهیزات الکتریکی جهت برقراری عملکردهای مطمئن در سیستم‌های قدرت بسیار مهم هستند. در سیستم‌های قدرت معمولی، حسگرها و سیستم‌های پایش بسیاری نصب شده‌اند و تغییرات تدریجی در سیستم تحلیل می‌شوند. به دلیل پیچیدگی داده‌های ضبط‌شده، وجود نقص‌ها نمی‌توانند در مراحل اولیه به‌آسانی تشخیص داده شوند. روش‌های یادگیری ماشینی می‌توانند در این خصوص مورد استفاده قرار گیرند. همان‌طور که در فصل سوم بیان شد، در سه بخش از شبکه‌های قدرت سابقه تحقیقاتی وجود دارد که می‌تواند نقطه آغازین برای بررسی‌های بیشتر باشند: عایق‌ها، ترانس‌ها و خطوط انتقال.

۱۵-۲-۱۵- به کارگیری روش‌های یادگیری ماشینی در کنترل و تحلیل سیستم‌های قدرت

در سال‌های اخیر، سیستم‌های قدرت بزرگ‌تر و پیچیده‌تر گشته‌اند و عناصر جدید زیادی مانند باد، توان خورشیدی و دستگاه‌های الکتریکی در آن نفوذ کرده‌اند. این عناصر تزویج قوی و ابهام زیادی در سیستم قدرت ایجاد می‌کنند. تحت این شرایط، عملکرد روش‌های مبتنی بر مدل، که توأم با فرضیات و ساده‌سازی هستند، زیر سؤال می‌روند. تشخیص اخلاص، ارزیابی پایداری و کنترل

شرایط اضطراری برای تضمین قابلیت اطمینان و امنیت در سیستم‌های قدرت ضروری هستند. به عنوان مثال سیستم‌های اندازه‌گیری WAMS حجم زیادی از داده تولید می‌کنند که نحوه بدست آوردن اطلاعات مفید از این حجم داده و به صورت خودکار یک چالش حقیقی برای اپراتورهای سیستم است. استفاده از روش‌های یادگیری ماشینی در این خصوص می‌تواند مدنظر قرار گیرد و به صورت مبسوط در طی یک پروژه تحقیقاتی مورد بررسی بیشتر شده و پیاده‌سازی گردد.

۱۶-۲-۱۳- به کارگیری روش‌های یادگیری ماشینی در پیش‌بینی میزان تولید انرژی تجدیدپذیر

پیش‌بینی خروجی تولید انرژی تجدیدپذیر برای بهبود انضمام آن‌ها در شبکه قدرت که دارای مشخصات نامعین و متناوب هستند، با اهمیت است. به عنوان مثال در خصوص استفاده از انرژی بادی، تخمین سرعت باد بیانگر میزان تولید انرژی خواهد بود. اگرچه مقدار زیادی تحقیقات برای پیش‌بینی سرعت باد انجام شده است، با این حال روش‌های جاری پیش‌بینی توان باد معایبی در شرایط آب و هوایی متفاوت دارند. استفاده از روش‌های یادگیری ماشینی، همچون یادگیری عمیق، دارای ویژگی‌های انعطاف‌پذیری، توانایی یادگیری خودانطباقی و نیاز کمتر به فرضیات فیزیکی هستند و از این رو انتظار می‌رود که با استفاده از آن‌ها به دقت پیش‌بینی بهتری دست یافت.

۳-۱۳- کاربردهای شبکه هوشمند و نقش شبکه‌های ارتباطی در آنها

جهت تکمیل بحث، در این بخش ابتدا فهرستی از تمامی کاربردهایی که در شبکه هوشمند وجود دارند ارائه می‌شود. در ادامه فناوری‌های ارتباطی که تاکنون در این شبکه‌ها مورد استفاده قرار گرفته‌اند و همچنین به صورت مشخص، اینکه در کدامین کاربردها می‌توانند مورد بهره‌برداری قرار بگیرند بیان می‌شوند. به این ترتیب پل ارتباطی مابین کاربردهای شبکه هوشمند و فناوری‌های مخابراتی برقرار می‌شود. با استفاده از روش‌های هوش مصنوعی و یادگیری ماشینی که در این پروژه مورد مطالعه و بررسی قرار گرفتند، می‌توان ملاحظه کرد که چگونه باعث ارتقاء عملکرد واحدهای مخابراتی شده و در نتیجه در کدام بخش از شبکه هوشمند مثر ثمر واقع خواهند شد.

در قابل توجه است که از میان این فهرست، قرائت اتوماتیک داده‌های کنتور از اولویت و اهمیت بالایی در ایران برخوردار است و طی برنامه فهام توسط ساتبا پیگیری می‌شود، چراکه پس از اتمام آن راه برای پیاده‌سازی سامانه‌های دیگر همچون AMI و DR باز می‌شود.

جدول ۱۸ فهرستی از کاربردهای شبکه هوشمند و QoSهای مخابراتی آنها از لحاظ (امنیت، پهنای باند، قابلیت اطمینان و تأخیر) ارائه شده‌اند.

قابل توجه است که از میان این فهرست، قرائت اتوماتیک داده‌های کنتور از اولویت و اهمیت بالایی در ایران برخوردار است و طی برنامه فهام توسط ساتبا پیگیری می‌شود، چراکه پس از اتمام آن راه برای پیاده‌سازی سامانه‌های دیگر همچون AMI و DR باز می‌شود.

جدول ۱۸. فهرست کاربردهای شبکه هوشمند و نیازمندی‌های کیفیتی مخابراتی آنها [1]

QoS requirements of the smart grid applications (s—seconds; ms—milliseconds; h—hour/s).					
Sr.#	Applications	Security	Bandwidth	Reliability	Latency
1	Home energy management (HEM)	High	9.6–56 kb/s	99.0–99.99%	300 ms–2000 ms
2	Advanced metering infrastructure (AMI)	High	10–100 kb/s per node, 500 kb/s for backhaul	99.0–99.99%	2000 ms
2(a)	Meter reading-on-demand	High	100 bytes	>98%	<15 s
2(b)	Meter reading-scheduled manner	High	1.6 k–2.4 kb/s	>98%	<4 h
2(c)	Meter reading-collective manner	High	>=1000 kb/s	99.0%	<1 h
3	Wide-area situational awareness (WASA)	High	600–1500 kb/s	99.0%	15–200 ms
4	Demand response management (DRM)	High	14–100 kb/s per node	99.0%	500 ms–several minutes
5	Substation automation (SA)	High	9.6–56 kb/s	99%–100%	15–200 ms
6	Outage management (OM)	High	56 kb/s	99.0%	2000 ms
7	Distribution management (DM)	High	9.6–100 kb/s	99.0–99.99%	100 ms–2 s
8	Distributed generation (DG)	High	9.6–56 kb/s	99.0%	2000 ms
9	SCADA	High	56–100 kb/s	99.0%	2000–5000 ms
10	Asset management (AM)	High	56 kb/s	99.0%	2000 ms
11	Meter data management (MDM)	High	56 kb/s	99.0%	2000 ms
12	Transmission line monitoring	High	9.6–64 kb/s	99.0%	1000 ms
13	Distributed energy resources and storage	High	9.6–56 kb/s	99.0–99.99%	300 ms–2 s
14	Vehicle to grid (VG)	High	9.6–56 kb/s	99.0–99.99%	2 s–5 min
15	Electrical vehicles (EV)	High	9.6–56 kb/s	99.0–99.99%	2 s–5 min
16	Program/configuration update (FCU)	High	25–50 kb/s	>98%	<5 min–7 days
17	Firmware update (FU)	High	400 kb/s–2000 kb/s	>98%	<2 min–7 days

جدول ۱۹. فهرستی از فناوری‌های مخابراتی و کاربرد آنها در بخش‌های مختلف شبکه هوشمند [1]

Communication technologies with their specific data rates, power consumption, deployment cost, smart grid segment, distance coverage, latency and applications.								
Technology	Communication standards	Data rates	Power consumption	Deployment cost	SG segment	Distance covered	Latency	SG applications
Cellular	2G	Very low	Low	Low	HAN/NAN	Long distance	High	HA, PHEVs, DS, AMI
	2.5G	Very low	Low	Low	HAN/NAN	Long distance	High	HA, PHEVs, DS, AMI
	3G	High	Medium	Low	HAN/WAN/NAN	Long distance	High	DA, AMI
	3.5G	High	Medium	Low	HAN/WAN/NAN	Long distance	High	DA, WASA, AMI
	4G (LTE)	High	Medium	Low	HAN/WAN/NAN	Long distance	Medium	DA, WASA, DR
	LTE-Advanced	Very high	Medium	Low	HAN/WAN/NAN	Long distance	Low	WASA, SCADA
WiMAX	IEEE 802.16	Very high/High	High	Medium	HAN/WAN/NAN	Long distance	Low/Medium	DA, AMI
	IEEE 802.16j	High	High	Medium	NAN/WAN	Long distance	Medium	DA, AMI
	IEEE 802.16m	High	High	Medium	NAN/WAN	Long distance	Medium	DA, AMI, DER
Satellite	LEO	Medium	High	High	HAN/NAN/WAN	Long distance	Medium	AMI, DA, SCADA
WRAN	IEEE 802.22	Medium	Medium	Low	NAN/HAN/BAN/IAN	Long distance	Medium	PHEVs, SCADA, AMI
WiFi	IEEE 802.11	Low/Medium	Low	Low	HAN/NAN	Medium distance	Medium/High	AMI, DER, DRM
	IEEE 802.11s	Medium	Low	Low	HAN/BAN/IAN	Medium distance	Medium/High	PHEVs, AMI, HA
	IEEE 802.11n	Medium	Low	Low	HAN/BAN/IAN	Medium distance	Medium/High	PHEVs, AMI, HA
	IEEE 802.11e	Medium	Low	Low	HAN/BAN/IAN	Medium distance	Medium/High	PHEVs, AMI, HA
	DASH 7	Low/Medium	Low	Low	HAN/BAN/IAN	Low/Medium	High	AMI, DER, HA
	802.11af	Medium	Medium	Low	BAN/HAN/IAN	Medium distance	Medium	AMI, PHEVs
MBWA	IEEE 802.20	Medium	Low	Low	BAN/HAN/IAN	Medium distance	Medium/High	PHEVs, SCADA
WPAN	IEEE 802.15.4 (Zigbee)	Low	Low	Low	BAN/HAN/IAN	Short distance	Low/Medium	DER, HA, AMI
	IEEE 802.15.4g	Low	Low	Low	BAN/HAN/IAN	Short distance	Medium/High	HA
Z-wave	IEEE 802.15.4	Low	Low	Low	BAN/HAN/IAN	Short distance	High	AMI, HA
Ethernet	IEEE 802.3	High	Medium	High	BAN/HAN/IAN	Short distance	Low/Medium	AMI, HA
WBAN	IEEE 802.15.6	High/Very high	Low	Low	BAN/HAN/IAN	Short distance	High	HA
RFID	802.15	Low	Low	Low	BAN/HAN/IAN	Short distance	Low	Object identification
Bluetooth	IEEE 802.15.1	Low	Low	Low	BAN/HAN/IAN	Short distance	Low/Medium	HA, AMI
Fiber optical	Fiber	Very high	Medium	High	NAN/WAN	Long distance	Low	Core/Backhaul
DSL Cable	Digital line subscriber	High	Medium	High	NAN/HAN/WAN	Long distance	High	SCADA, AMI
PLC	Powerline communication	High	Medium	Medium/Low	NAN/HAN	Long distance	Low	AMI, DA

HAN (Home Area Network), BAN (Business Area Network), IAN (Industrial Area Network), NAN (Neighborhood Area Network), WAN (Wide Area Network) Data rate range: Very low (1 kb/s to <250 kb/s), Low (250 kb/s to 1 Mb/s), Medium (>1 Mb/s to 10 Mb/s), High (>10 Mb/s to 1 Gb/s), Very high (>1 Gb/s); Distance range: Short (1<500 m), Medium (500<5 km), Long (>5 km) Latency: Low (micro (μ) s<60 ms), Medium (60<120 ms), High (>120 ms)

در جدول ۱۹ فهرستی از فناوری‌های مخابراتی و کاربرد آنها در بخش‌های مختلف شبکه هوشمند ارائه شده است. نکته قابل توجه این است که در این گزارش تأکید بیشتر بر روی واحدهای عملیاتی در سیستم‌های مخابراتی (همچون آنتن‌ها، لایه فیزیکی، لایه MAC، لایه شبکه و ...) و نقش روش‌های هوش مصنوعی در ارتقاء عملکرد آنها بود. به این ترتیب و با توجه به اینکه هر کدام از این واحدهای عملیاتی چه نقشی را در فناوری‌های مخابراتی (همچون سولوی و ...) داشته باشند، می‌توان پی برد که چگونه باعث ارتقاء عملکرد این فناوری‌ها شده و در نهایت در کدام بخش از کاربردهای شبکه هوشمند می‌توانند نقش‌آفرین باشند. همچنین اطلاعات بیشتری در خصوص الزامات شبکه‌های مخابراتی و کاربردهای فناوری‌های مخابراتی در شبکه‌های هوشمند در پروژه‌های دیگر انجام شده در پژوهشگاه نیرو قابل دسترسی هستند. [2، 3]

۴-۱۳- مروری بر فعالیت‌های انجام شده و جمع‌بندی نهایی

سیستم‌های ارتباطی نقشی بسزا و جداناپذیر در شبکه‌های برق هوشمند دارند، از اینرو هرگونه بهبود عملکرد آنها باعث بهبود عملکرد شبکه‌های هوشمند می‌شوند. همچنین پیچیدگی‌های شبکه‌های هوشمند برق و سیستم‌های مخابراتی نوین به صورت روزافزون در حال افزایش هستند و از اینرو روش‌های سنتی در حوزه‌های مختلف نظیر تحلیل، پایش، کنترل و ... که نوعاً متکی بر ساده‌سازی‌ها و تحلیل‌های ریاضی فرم‌بسته هستند، دارای کارایی و حتی توانایی لازم برای حل مشکلات مرتبط نمی‌باشند. روش‌های مختلف هوش مصنوعی که اخیراً در حوزه‌های مختلف علوم و فناوری‌ها عملکردی خیره‌کننده را ارائه داده‌اند، راه خود را در سیستم‌های مخابراتی و شبکه هوشمند نیز باز کرده‌اند و توجه زیادی را چه در بخش دانشگاهی و چه در بخش صنعتی به خود معطوف نموده‌اند.

هدف اصلی در این پروژه بررسی و شناسایی نقش روش‌های هوش مصنوعی در بخش‌های مختلف سیستم‌های ارتباطی نوین و با نگاهی روشمند و معطوف به بخش‌ها و لایه‌های مختلف پروتکل‌های مخابراتی با نگاهی کلی به کاربردهایی که در صنعت برق و شبکه‌های هوشمند می‌توانند داشته باشند، است. نظر به گستردگی مباحث مورد بررسی و جدید بودن روش‌های بکاررفته، لازم بود که تعادل مناسبی مابین عمق بررسی و حوزه پوشش مطالب صورت بگیرد تا علاوه بر ایجاد یک دید کلی به موضوعات مختلف، یک برداشت نسبتاً عمیقی نیز بدست آید تا به خروجی مورد نظر در انتهای پروژه و تهیه لیستی از پروژه‌های مختلف (که بیشتر به صورت آزمون ایده هستند) بیانجامد.

لازم به یادآوری است نظر به انجام این پروژه در گروه پژوهشی فناوری اطلاعات و ارتباطات پژوهشگاه نیرو، یک نگاه آینده‌مدارانه در انجام آن وجود دارد و لزوماً موضوع مورد بررسی و خروجی‌های آن قابلیت استفاده در بکارگیری و برطرف‌سازی نیازهای عاجل در صنعت برق را ندارد. همچنین گفتنی است که صنعت برق متشکل از بخش‌های بسیار متنوعی از رشته‌های مختلف نظیر شیمی، مواد، قدرت، فناوری اطلاعات و ارتباطات و ... برخوردار است که در اینجا توجه اصلی به سوی مخاطبانی است که دارای تخصص فناوری اطلاعات و ارتباطات بوده و در عین حال در صنعت برق مشغول فعالیت هستند. با اینحال مطالب مورد مطالعه و بررسی قرار گرفته در این پروژه با توجه به صنعت برق نگارش شده‌اند ولی به صورت کامل در این چارچوب محدود نشده‌اند و موضوعات متنوعی در حوزه‌های دیگر مخابراتی نیز مورد بررسی قرار گرفته‌اند؛ یکی از دلایل مهم این امر این است که استفاده روش‌های هوش مصنوعی در سیستم‌های مخابراتی بسیار جدید هستند و مدتی زمان لازم خواهد بود تا برخی از آنها در صنعت برق مورد استفاده گسترده‌ای قرار گیرند. همچنین با توجه به شرح خدمات مصوب پروژه، کاربردها در صنعت برق بیشتر در فصول پایانی پروژه مورد تاکید بوده‌اند.

همچنین باید توجه کرد که نظر به بررسی تمامی لایه‌های پروتکلی و بخش‌های مخابراتی انجام شده در این پروژه، از یکسو یک نگاه مجزا و معطوف به بخش‌های مختلف سیستم‌های مخابراتی که کاربردهای مختلف و مستقلی از یکدیگر دارند وجود دارد و از سوی دیگر برای پوشش تمامی بخش‌های مختلف، این نگاه‌های جزئی در یک سیستم کلی مخابراتی صورت گرفته‌اند. این پروژه در پنج مرحله و به صورت زیر انجام شده است:

مرحله اول به مطالعات مقدماتی و تطبیقی می‌پردازد و شامل پنج زیرمرحله است. گفتنی است که هر زیرمرحله از این پروژه در یک فصل جداگانه ارائه شده است.

فصل اول به بررسی کاربرد رادیو شناختی در صنعت برق می‌پردازد. در این فصل پس از معرفی شبکه‌های رادیو شناختی و شبکه هوشمند برق، کاربردهای موجود و بالقوه اینگونه روش‌های شناختی در شبکه برق هوشمند به صورت مبسوط مورد بررسی قرار گرفتند. از دیگر موضوعات مورد مطالعه در این فصل، معماری شبکه هوشمند برق مبتنی بر رادیو شناختی، روش‌های حس پهنای باند و پروتکل‌های دسترسی به کانال بودند.

فصل دوم اختصاص به بررسی سه مورد از پروژه‌های انجام شده در دنیا در خصوص هوشمندسازی سیستم‌های ارتباطی و بکارگیری آنها در صنعت برق یافته است. در این فصل دو پروژه صنعتی به نام‌های SunSeed و SmartEMC2 که در اتحادیه

اروپا و معطوف به صنعت برق بوده‌اند، و نیز یک پروژه دانشگاهی که در دانشگاه Alabama و با پشتیبانی پژوهشگاه نیروی هوایی آمریکا صورت گرفته است، مورد بررسی قرار گرفتند. این پروژه دانشگاهی یک نمونه آزمایشگاهی از رادیوشناختی را که از چند روش پیشرفته یادگیری ماشینی بهره می‌برد را پیاده‌سازی نموده است. روش ایشان می‌تواند یک مورد مناسب و دارای قابلیت در کاربردهای صنعتی منجمله صنعت برق باشد که از رادیوشناختی استفاده می‌کنند. در پروژه SunSeed چند روش مبتنی بر ارتباطات چندگانه را ارائه و مورد بررسی قرار داده بود که باعث ارتقاء عملکرد ارتباطات سیستم‌های اندازه‌گیری مورد نیاز در شبکه‌های هوشمند می‌شود و ضرایب اطمینان ارتباطات را بهبود می‌بخشد. در پروژه SmartEMC2 نیز یک روش انتخاب آنتن در سیستم‌های Massive-MIMO و برای استفاده در شبکه‌های هوشمند برق ارائه گردیده است؛ به این ترتیب که با انتخاب زیرمجموعه‌ای از آنتن‌های موجود در سیستم، می‌توان به ارتقاء عملکرد، کاهش هزینه‌های سخت‌افزاری و سادگی پیاده‌سازی در واحدهای مرکزی قرائت اطلاعات در شبکه‌های هوشمند دست یافت. در پروژه سوم که در دانشگاه Alabama صورت گرفته است، چند روش یادگیری ماشینی برای یک سیستم رادیوشناختگر ارائه و پیاده‌سازی شده است، که با آزمایشات صورت گرفته، نشان داده شده است که این روش‌ها باعث ارتقاء عملکرد می‌شوند. به این ترتیب، همانگونه که بر اساس مطالعات و بررسی‌های صورت گرفته در فصل اول نشان داده شد، در کثیری از کاربردهای موجود در شبکه‌های هوشمند که رادیوشناختی می‌تواند نقش مثبتی ارائه نماید و به طبع آن این روش‌های یادگیری ماشینی می‌توانند یک گام دیگر به بهبود عملکرد سیستم‌های شبکه‌های هوشمند کمک کنند.

فصل سوم به مطالعه و بررسی کاربردهای هوش مصنوعی در لایه فیزیکی اختصاص داده شده است. در این فصل ابتدا یک مروری کلی بر روش‌های یادگیری ماشینی به ویژه آن دسته که تاکنون در سیستم‌های ارتباطی دارای کاربرد بوده‌اند، صورت گرفت. در ادامه نتایج مرتبط با مطالعات و بررسی روش‌های AI مورد استفاده در لایه فیزیکی ارائه شدند. پس از برشمردن چالش‌های بکارگیری روش‌های یادگیری ماشینی در سیستم‌های ارتباطی، چند کاربرد از این روش‌ها در مکانیزم‌های موجود در لایه فیزیکی همچون مدولاسیون و کدینگ تطبیقی و انواع مختلف یکسان‌سازها به صورت عمیق مورد بررسی قرار گرفته‌اند.

فصل چهارم کاربردهای هوش مصنوعی در استفاده از طیف فرکانسی و رادیوشناختی را مورد بررسی قرار می‌دهد. با بررسی‌های صورت گرفته در این فصل ملاحظه گردید که به دلیل نیاز به تصمیم‌گیری و همچنین پویا بودن و عدم قطعیت موجود در دسترسی به طیف در شبکه‌های رادیوشناختی، روش‌های مبتنی بر یادگیری تقویتی برای حل این مسائل مناسب‌تر هستند. مطالب این فصل تکمیل‌کننده مطالب فصل اول بودند و در تمامی کاربردهایی که روش‌های رادیوشناختگر می‌توانند در صنایع مختلف و منجمله صنعت برق را داشته باشند (و در فصل اول بیان گردیدند) نقش مثبتی را ایفاء نمایند.

فصل پنجم نیز ملاحظات و ابزارهای مورد نیاز طراحی سیستمی جهت بکارگیری هوش مصنوعی مورد مطالعه و بررسی قرار گرفت. جهت بکارگیری روش‌های هوش مصنوعی در کاربردهای صنعتی باید ملاحظات سیستمی و استفاده از ابزارهای مناسب را مد نظر قرار داد. از اینرو در این فصل ابتدا به دو موضوع محدودیت‌های بکارگیری روش‌های هوش مصنوعی در سیستم‌های ارتباطی هوشمند و همچنین ابزارهای مورد نیاز جهت پیاده‌سازی آن، پرداخته شد. بخشی از محدودیت‌ها به پیچیدگی محاسباتی روش‌های یادگیری برمی‌گردد که برای حل آن نیاز است که سخت‌افزارهای قوی و با قابلیت پردازش بالا مورد استفاده قرار گیرند. در کنار این سخت‌افزارها، کتابخانه‌های نرم‌افزاری نیز ارائه شدند که این سخت‌افزارها و الگوریتم‌های مورد استفاده در روش‌های یادگیری ماشینی را پشتیبانی می‌کنند. همچنین روش‌هایی ارائه گردیدند که می‌توانند حتی با استفاده از سخت‌افزارها و نرم‌افزارهای نه چندان قوی هم یادگیری ماشینی را بدون کاهش دقت مورد نظر پیاده‌سازی کنند.

در ادامه پروژه و در **مرحله دوم**، توجه خود را معطوف به بخش آنتن‌ها و کاربردهای هوش مصنوعی در آن نمودیم. فناوری MIMO انبوه ویژگی‌های مختلفی دارد از جمله بهبود ظرفیت که کاربرد این فناوری را برای مواردی که تعداد زیادی کاربر در سیستم وجود دارد یا تعداد زیادی حسگر برای جمع‌آوری داده به کار می‌رود، مفید و مؤثر می‌سازد. استفاده از اینترنت اشیاء و افزایش تعداد حسگرها و کنتورهای هوشمند که در شبکه هوشمند برق مورد استفاده قرار می‌گیرند، باعث تولید داده‌های بسیاری

می‌شوند و از همین رو فناوری MIMO انبوه می‌تواند کمک شایانی در ارتقاء عملکرد این سیستم‌ها شود. فعالیت‌های انجام شده در این مرحله در دو فصل ارائه گردیدند:

فصل ۶ به مطالعه و بررسی صفحات هوشمند (LIS) پرداخت. صفحات بزرگ هوشمند که با نام‌های مختلفی نظیر صفحات بازتابی هوشمند، آنتن‌های آرایه‌ای بازتابی هوشمند و غیره نیز شناخته شوند یکی از فناوری‌هایی هستند که اخیراً برای کنترل محیط پیرامون مورد تحقیق و بررسی قرار گرفته‌اند. این صفحات می‌توانند در رنج وسیع فرکانسی از ماکروبو تا نوری برای کنترل امواج به کار روند. با ترکیب این صفحات با المان‌های قابل سوئیچ، می‌توان صفحاتی دارای قابلیت پیکربندی داشت که می‌توانند مشخصاتی از موج تابشی نظیر دامنه، فاز و پلاریزاسیون را تغییر دهند.

در سیستم‌های مخابرات بی‌سیم امروزی، محیط پیرامون و اجسام فیزیکی می‌توانند بر روی انتشار و دریافت امواج الکترومغناطیسی تأثیرگذار باشند و بسیاری از موانع سیار کنترل‌پذیر نیستند. در زمان طراحی سیستم‌های مخابرات بی‌سیم می‌توان فرستنده و گیرنده، الگوریتم‌های پردازش سیگنال و پروتکل‌های انتقال را برای تطبیق با محیط طراحی نمود. در صورتی که صفحات بزرگ هوشمند سعی دارند محیط اطراف را کنترل‌پذیر و برنامه‌پذیر کنند و به این ترتیب پوشش و بازدهی سیستم‌های مخابراتی را افزایش دهند. صفحات بزرگ هوشمند معمولاً دارای ابعادی بسیار بزرگ‌تر از طول موج هستند و می‌توانند به دیوارها، سقف و بر روی دکل‌ها نصب شوند. این صفحات از المان‌های بازتابی تکرار شونده‌ای در دو بعد تشکیل شده‌اند که با کنترل دامنه و فاز المان‌ها موج بازتابی را در زاویه و فاز دلخواه هدایت می‌کنند. روش‌های مختلف هوش مصنوعی و یادگیری ماشین مانند یادگیری عمیق می‌توانند در تعیین دامنه و فاز هر یک از المان‌ها در طراحی و عملکرد LIS‌ها مفید باشند. از آنجاکه این المان‌ها غیرفعال هستند می‌توانند در مصرف توان و هزینه نسبت به فناوری‌هایی مانند رله‌های فعال صرفه‌جویی کنند. توجه فرمایید که موضوع صفحات هوشمند بسیار جدید بوده و مدتی طول خواهد کشید تا دارای کاربردهای گسترده صنعتی و همین‌طور در صنعت برق شود؛ با اینحال استفاده از آنها در خانه‌های هوشمند، سامانه‌های توزیع قدرت و اینترنت صنعتی اشیاء قابل تصور خواهند بود و در همین خصوص سه پروژه در بخش‌های ۵-۲-۱۳، ۶-۲-۱۳ و ۷-۲-۱۳- همین گزارش تعریف شده‌اند.

در فصل ۷ کاربردهای روش‌های هوش مصنوعی در سیستم‌های MIMO انبوه مورد مطالعه و بررسی قرار گرفتند. هنگامی که هوش مصنوعی با آنتن‌های MIMO انبوه ترکیب شود می‌تواند عملکرد آنها را بهبود بخشد و پارامترهای مجهول را به صورت بهینه پیدا کند. دامنه و فازی که از هر تقویت‌کننده به سمت هر یک از آنتن‌های واحد می‌رود دو متغیر هر آنتن محسوب می‌شود که با توجه به تعداد بالای آنتن‌های واحد در آنتن آرایه‌ای MIMO انبوه، تعداد متغیرها به شدت افزایش می‌یابد. اندازه این متغیرها وابسته به موقعیت کاربران، تراکم آنها، وضعیت کانال‌ها و پهنای باند در دسترس و پارامترهای مختلف دیگری است. بنابراین نیاز است تا ابتدا محیط و کاربران پایش شده و پس از جمع‌آوری داده و پردازش، هر یک از تقویت‌کننده‌ها برای تولید سیگنالی با دامنه و فاز مناسب تنظیم شوند. به این ترتیب استفاده از الگوریتم‌های هوش مصنوعی و روش‌های یادگیری ماشین که قابلیت یادگیری و تصمیم‌گیری مناسب را در مدت‌زمان قابل قبولی فراهم می‌کنند، می‌توانند در پردازش‌های سیستمی مورد استفاده قرار گیرند. برای نمونه می‌توان به شبکه‌های عصبی بازگشتی، یادگیری عمیق و DQL اشاره نمود که برای سیستمی با حالت‌های زیاد به کار رفته و زمان پاسخ‌دهی مناسبی دارند.

در **مرحله سوم** این پروژه کاربردهای روش‌های هوش مصنوعی در دو لایه دیگر از لایه‌های پروتکل‌های مخابراتی یعنی MAC و شبکه مورد مطالعه و بررسی قرار گرفتند. گزارش این مرحله در دو فصل ارائه شد:

فصل ۸ معطوف به لایه MAC بود که در آن ابتدا به بیان اهمیت کارایی لایه MAC در شبکه‌های حسگری و همین‌طور اینترنت اشیاء پرداخته شد. این موضوع برای کاربردهای صنعتی و به ویژه کاربردهای صنعت برق از اهمیت ویژه‌ای برخوردار است؛ چراکه شبکه‌های حسگری در جای‌جای صنعت برق مورد استفاده هستند و هرگونه بهبود در عملکرد آنها باعث بهبود افزایش راندمان کلی سیستم خواهد شد. طبق مطالعات صورت گرفته نشان داده شد که سه رویکرد اصلی برای بهبود عملکرد لایه MAC وجود دارند: (۱) ترکیبی هوشمندانه از روش‌های MAC پیشین. (۲) ارتقاء عملکرد برخی از روش‌های پیشین MAC با بهینه‌سازی

پویای پارامترهای دخیل در آنها. ۳) طراحی پروتکل‌های جدید با استفاده هوشمندانه و گزینشگر از برخی از اجزای عملکردی روش‌های پیشین.

در فصل ۹ از این مرحله کاربردهای یادگیری ماشین جهت برطرف کردن چالش‌های موجود در شبکه‌های ارتباطی مورد مطالعه و بررسی قرار گرفتند. زیرسیستم‌های مختلفی در صنعت برق (چه در حالت سنتی و چه برای شبکه هوشمند) وجود دارند که مقدار زیادی داده تولید می‌کنند (همچون مقادیر قرائت شده از کنتورها، مقدار ولتاژ و جریان ادوات مختلف و ...) که این داده‌ها باید با توجه به معیارهای مختلفی از QoS (همچون نرخ ارسال، ضریب اطمینان، امنیت، تأخیر و ...) به قسمت‌های مختلف ارسال شوند. این ارتباطات توسط شبکه‌های مختلف ارتباطی و در مقیاس‌های مختلف جغرافیایی و عملکردی صورت می‌گیرند. انواع مختلف شبکه با نام‌های HAN, NAN, FAN, WAN شناخته می‌شوند. در شبکه هوشمند می‌توان به زیرسیستم‌های ذیل اشاره نمود:

زیرساخت پیشرفته اندازه‌گیری (AMI)، اتوماسیون توزیع (DA)، تولید توزیع شده / پراکنده (DG)، ذخیره‌سازی توزیع شده / پراکنده (DS)، خودروهای برقی (EV)، میکروگریدها (ریز شبکه‌ها)، شبکه‌های خانگی (HANS)، پاسخ بار (DR)، WASA. بسته به بزرگی شبکه مورد نیاز، ده‌ها و حتی هزاران مسیریاب برای تبادل داده‌ها مورد استفاده هستند. به این ترتیب و با توجه به مدل ارائه شده در این فصل ملاحظه می‌شود که یک شبکه بسیار بزرگ ارتباطی (و متشکل از زیر شبکه‌ها) در صنعت برق مورد استفاده قرار می‌گیرد که کنترل و بهینه‌سازی عملکرد آن بسیار پیچیده خواهد بود. روش‌های هوش مصنوعی و یادگیری ماشین که در این فصل بیان شدند گزینه‌های قابل ملاحظه‌ای برای استفاده و به کارگیری در این شبکه‌ها می‌باشند. همچنین در خصوص استفاده از شبکه‌های نرم‌افزار محور در شبکه‌های هوشمند برق، پژوهش‌های مختلفی صورت گرفته‌اند که روش‌های ارائه‌شده در بخش مربوطه در این فصل از گزارش می‌توانند در آنها مورد استفاده قرار گیرند.

با توجه به موارد فوق، در این فصل ابتدا موضوع ترافیک شبکه و نحوه بهبود آن با روش‌های یادگیری ماشین مورد بررسی واقع شد. سپس برای بهبود رضایت کاربران بویژه در ترافیک چندرسانه‌ای یک معماری کنترل ترافیک شبکه برای شبکه‌های SDN معرفی گردید. همچنین در خصوص بازنگری روش کنترل ترافیک در شبکه ناهمگون مانند کنترل مسیریابی و عملکرد بسیار خوب روش‌های یادگیری ماشینی مطالبی ارائه گردید. به کارگیری یادگیری ماشینی در خصوص شبکه‌های ارتباطی مورد استفاده در مخابرات سلولی از دیگر موضوعات مورد بررسی بود. نشان داده شده که در شرایطی که مدل‌های تحلیلی در دست نیستند و یا اینکه از دقت کافی برخوردار نیستند، چگونه می‌توان از روش‌های متکی بر داده مدل آنها را بهبود بخشید و به کارایی‌های بالایی دست یافت.

اینکه کدامیک از رویکردهای مدل محور و یا داده‌محور بر دیگری برتری دارند در مثال‌های مورد بررسی در این فصل مورد بررسی قرار گرفتند و ملاحظه شد که شرایطی پیش می‌آیند که هیچکدام به تنهایی قادر به برآوردن انتظارات نیستند، بلکه باید در کنار هم ضعف‌های یکدیگر را بپوشانند. چگونگی این تزویج در دو بخش انتهایی این فصل و با کمک روش انتقال یادگیری ماشینی مورد بحث و بررسی قرار گرفت. به طور خلاصه، روش کار بر این استوار بود که ابتدا با استفاده از مدل ناقص یک شبکه عصبی آموزش داده می‌شود و سپس با استفاده از مقادیر نسبتاً اندکی از داده‌های تجربی این شبکه اولیه مورد اصلاح و پارامترهای آن تصحیح می‌شوند. نتایج بدست‌آمده مبین این بودند که عملکرد بسیار بهتری در مقایسه با استفاده روش‌های پایه به صورت تنها را می‌توان بدست آورد.

همچنین شبکه‌های حسگری دارای کاربردهای بسیار وسیعی در صنایع و همینطور در صنعت برق دارند. بهینه‌سازی عملکرد آنها در بخش‌های مختلف نظیر کنترل ترافیک، مسیریابی، شبکه‌های نرم‌افزار محور، شبکه‌های ناهمگون و همینطور نحوه استقرار اجزاء، که در این گزارش مورد مطالعه و بررسی قرار گرفتند، می‌توانند با روش‌های یادگیری ماشینی صورت گیرد که در نهایت به ارتقاء عملکرد آنها خواهند انجامید.

در **مرحله چهارم** پروژه به مطالعات و بررسی‌های مرتبط با هوشمندسازی مدیریت شبکه ارتباطی پرداخته شد. در فصول یک تا سه گزارش، که در خصوص هوشمندسازی مدیریت شبکه ارتباطی هستند، سه موضوع مورد مطالعه قرار گرفته‌اند:

فصل ۱۰ شامل بررسی روش‌های به‌کارگیری AI جهت تخصیص منابع در شبکه‌های ارتباطی می‌شود. مدیریت منابع در سیستم‌های ارتباطی باعث ارتقاء عملکرد این سیستم‌های می‌شوند و موضوعی کاملاً مخابراتی می‌باشد. هرگونه بهبود در عملکرد این سیستم‌ها، باعث بهبود عملکرد کاربردهایی که از آنها استفاده می‌کنند خواهد شد و به این ترتیب به صورت غیرمستقیم نقش حیاتی خود را ایفا خواهند کرد. به عنوان مثال مدیریت بهتر منبع طیف فرکانسی باعث خواهد شد که حسگرهای بی‌سیم که در صنعت برق وجود دارند و تعداد آنها به صورت روزافزون زیادتر می‌شود بتوانند استفاده مقرون‌به‌صرفه‌تری را از این منبع داشته باشند. با یک نگاه دیگر می‌توان موضوع را به این صورت دید که با استفاده از یک مقدار مشخص از منبع طیف فرکانسی، تعداد بسیار بیشتری از حسگرها را پشتیبانی کرد. به این ترتیب و در هر دو حالت مشاهده می‌شود که چگونه مدیریت منابع باعث ارتقاء عملکرد کاربردهای متکی بر سیستم‌های ارتباطی می‌شود. مثال دیگر، کنترل توان است که می‌تواند باعث کاهش مصرف حسگرها و در نتیجه بیشتر شدن طول عمر باتری‌های موجود در آنها شود؛ امری که باعث کاهش فعالیت‌های لجستیکی مورد نیاز هم خواهد شد. همچنین کاربرد سیستم‌های MIMO و MIMO انبوه می‌توانند کاربردهای مؤثری در پوشش‌دهی به یک گستره بزرگ جغرافیایی و شامل تعداد زیادی از حسگرها باشد. شکل‌دهی به پرتو در این سیستم‌ها از اهمیت بسیار زیادی برخوردار است و از اینرو روش‌های یادگیری ماشینی که در این خصوص ارائه شده‌اند می‌توانند نقش با ارزشی را ایفا نمایند. یادگیری ماشینی برای مدیریت منابع در محیط خانه هوشمند نیز به عنوان مثالی دیگر مورد مطالعه قرار گرفت.

با توجه به مطالب فوق و اینکه اینترنت اشیاء کاربردهای وسیعی در کاربردهای صنعتی منجمله صنعت برق دارند در این فصل ابتدا ویژگی‌های اینترنت اشیاء در صنعت برق احصاء شدند. سپس با توجه به اهمیت مدیریت منابع در این شبکه‌ها، مشکلات روش‌های سنتی مورد مطالعه و بررسی قرار گرفتند و در ادامه انگیزه استفاده از روش‌های یادگیری ماشینی در خصوص مدیریت منابع در شبکه‌های ارتباطی بیان گردیدند. در ادامه مطالب این فصل کاربرد روش‌های یادگیری ماشینی برای انجام وظایف مختلف مدیریت منابع شامل انجام کنترل توان، مدیریت طیف، مدیریت بک‌هال، مدیریت کش، طراحی شکل‌دهنده پرتو و مدیریت منابع محاسباتی به صورت مجزا و مبسوط مورد مطالعه و بررسی قرار گرفتند.

در فصل ۱۱ بررسی روش‌های به‌کارگیری AI جهت ارتقاء امنیت در شبکه‌های ارتباطی صورت گرفته است. شبکه برق به عنوان بزرگ‌ترین شبکه سایبرفیزیکی در معرض حملات سایبری قرار دارد. دو عامل در تشدید شدن این تهدیدات موثر هستند که یکی گسترده شدن شبکه برق از لحاظ جغرافیایی و دیگری اضافه شدن مشتریان، تولیدکنندگان، خرده و عمده فروشان بیشتر به این شبکه است. استفاده از منابع انرژی تجدیدپذیر نیز بر گسترش جغرافیایی شبکه برق می‌افزاید. شبکه برق هوشمند دارای ویژگی‌های منحصر به فردی است و شامل حسگرها و کنتورهای زیادی برای جمع‌آوری داده از بخش‌های مختلف و ارسال این اطلاعات به مراکز تصمیم‌گیری است. این حسگرها و کنتورها را می‌توان یک شبکه اینترنت اشیاء صنعتی در نظر گرفت که به دلیل وسعت زیادی که دارد شامل دستگاه‌های مخابراتی متنوع و ناهمگن است که در برد و نرخ انتقال داده با یکدیگر متفاوت هستند. یکی دیگر از ویژگی‌های اصلی شبکه‌های حسگر بی‌سیم و به‌طور کلی شبکه‌های اینترنت اشیاء بهره‌گیری از اجزای با مصرف توان کم و کم‌هزینه است. این محدودیت منابع باعث می‌شود بسیاری از راه‌حل‌های مسائل امنیتی قابل پیاده‌سازی در شبکه‌های دیگر به دلیل نیاز به مصرف توان بالا و انجام محاسبات پیچیده ریاضی در شبکه‌ها اینترنت اشیاء ممکن نباشد و یکی از چالش‌های مهم به حساب می‌آید. از دیگر ویژگی‌ها می‌توان به پویایی اجزای شبکه همچون ربات‌هایی که در شبکه مشغول کار هستند و همچنین تغییرات کانال‌های مخابراتی اشاره کرد. شبکه مخابراتی در شبکه برق هوشمند همانند دیگر شبکه‌های مخابراتی از لایه‌های مختلفی چون لایه فیزیکی، لایه ارتباط داده، لایه شبکه، لایه انتقال و لایه کاربرد تشکیل شده است که احتمال حملات مختلف در هر یک از این لایه‌ها وجود دارد. در ادامه در خصوص حملاتی که ممکن است در هر لایه صورت گیرد مطالعه‌ای صورت گرفت. حجم بالای داده‌ها و بررسی حالات مختلفی که برای حملات وجود دارد از جمله داده‌های مخرب و غیرواقعی نیاز به محاسبات زیاد و سخت‌افزارهای پیچیده‌ای دارد که بتواند این محاسبات سنگین را انجام دهد. روش‌های هوش مصنوعی از جمله DQL می‌توانند به کاهش حالات لازم برای بررسی به منظور رسیدن به همگرایی به سیاست بهینه مورد استفاده قرار گرفته که

برای صرفه‌جویی در منابع سخت‌افزاری و زمان نیز مفید هستند. به‌طور نمونه مثال‌هایی از کاربرد هوش مصنوعی و به‌ویژه DQL در حملاتی مانند جمینگ و سایبر-فیزیکی، تشخیص و آشکارسازی نفوذ و حفظ اتصال آورده شده است.

در بخش انتهایی فصل نیز کاربرد هوش مصنوعی در امنیت صنعت برق به صورت ویژه مورد مطالعه و بررسی قرار گرفت. شبکه برق از هفت حوزه مهم تولید، توزیع، انتقال، مدیریت و کنترل، خدمات، مشترکین و بازار برق تشکیل شده که هر یک از این حوزه‌ها در درون خود و برای ارتباط با دیگر حوزه‌ها نیازمند مخابرات و برقراری ارتباطات می‌باشد. یکی از مهمترین سیستم‌های کنترلی در شبکه برق، سیستم SCADA است که می‌تواند یکی از مهمترین مقاصد مهاجمان برای ایجاد اختلال در شبکه برق باشد. از مهمترین اختلالاتی که ممکن است در شبکه رخ دهد اختلالات کیفیت توان مانند اختلال در سطح توان، ولتاژ، جریان و فرکانس است. همچنین اختلال در پایداری شبکه (پایداری ولتاژ و پایداری گذرا) نیز از مباحث مهم امروز شبکه‌های برق عنوان شده است. با افزایش روزافزون ارتباطات و حجم داده‌های مخابراتی تشخیص نفوذ و داده‌های جعلی نمی‌تواند با مکانیسم‌های قبلی شبکه برق به خوبی انجام گیرد و نیاز به روش‌هایی سریع و با دقت بالا است که حجم محاسبات زیادی نیز لازم نداشته باشند. چهار دسته اصلی از تهدیدات شناخته شده امنیتی و پایداری شبکه برق که عبارتند از اختلالات کیفیت توان (PQD)، تهدیدات و آسیب‌پذیری‌های شبکه SCADA، ارزیابی پایداری گذرا (TSA) و ارزیابی پایداری ولتاژ (VSA) ارائه گردیدند و به صورت جداگانه مورد مطالعه و بررسی قرار گرفتند. در ادامه نیز روش‌های مختلف هوش مصنوعی برای شناسایی و مقابله با هریک از تهدیدات شبکه برق به صورت جداگانه مورد مطالعه قرار گرفتند.

فصل ۱۲ نیز شامل بررسی برنامه‌های کاربردی هوشمند در سطح شبکه می‌شود. در این فصل به نقش هوش مصنوعی در ارتقاء عملکرد برنامه‌های کاربردی که بر روی تجهیزات شبکه اجرا می‌شوند، پرداخته شد. سه موضوع کلی در این فصل مورد بررسی قرار گرفتند: ۱) استفاده از هوش مصنوعی در برنامه‌های کاربردی که در یک شبکه مورد استفاده هستند، چالش‌هایی را به همراه خواهد آورد که برای برطرف‌سازی آنها باید از تمهیداتی خاص و یا الگوریتم‌هایی ویژه و اختصاصی‌شده برای پیاده‌سازی روش‌های هوش مصنوعی بهره گرفت. ۲) فراتر از صنعت برق و به صورت عام، کاربردهای متنوعی که روش‌های هوش مصنوعی در حوزه‌های مختلف داشته‌اند مورد مطالعه قرار گرفتند. ۳) به صورت خاص، برنامه‌های مختلف کاربردی و نقش هوش مصنوعی در آنها در بخش‌های مختلف صنعت برق مورد بررسی قرار گرفتند.

در بخش سوم کاربردهای متنوعی که روش‌های یادگیری ماشینی در بخش‌های مختلف شبکه‌های هوشمند برق می‌توانند داشته باشند مورد بررسی قرار گرفت. به‌صورت خاص، کاربردهایی نظیر: پیش‌بینی بار / تقاضا، ریزش‌بکه‌ها، پاسخ بار، تشخیص نقص/خطا در تجهیزات الکتریکی، کنترل و تحلیل سیستم‌های قدرت، امنیت سایبری و پیش‌بینی تولید انرژی تجدیدپذیر مورد مطالعه و بررسی قرار گرفتند. هرکدام از این کاربردها می‌توانند به‌تنهایی موضوع یک پژوهش مستقل باشند.

مرحله پنجم در خصوص ارائه پیشنهاد برای ادامه کار و جمع‌بندی بوده و مطالب آن در فصل ۱۳ ارائه شده‌اند. با توجه به مطالعات صورت گرفته در این پروژه و جهت جمع‌بندی نهایی فهرستی از فعالیت‌های پژوهشی که در آنها روش‌های یادگیری ماشینی می‌توانند در صنعت برق و شبکه هوشمند مورد استفاده قرار گیرند، در قالب تعریف پروژه ارائه شده‌اند. همچنین جهت برقراری پل ارتباطی مابین کاربردهای شبکه هوشمند و فناوری‌های مخابراتی فهرست کاملی از تمامی کاربردهایی که در شبکه هوشمند وجود دارند ارائه گردید و پس از آن فناوری‌های ارتباطی که تاکنون در این شبکه‌ها مورد استفاده قرار گرفته‌اند و همچنین به صورت مشخص، اینکه در کدامین کاربردها می‌توانند مورد بهره‌برداری قرار بگیرند بیان شدند.

مراجع فصل ۱۳

1. Faheem, Muhammad, Syed Bilal Hussain Shah, Rizwan Aslam Butt, Basit Raza, Muhammad Anwar, Muhammad Waqar Ashraf, Md A. Ngadi, and Vehbi C. Gungor. "Smart grid communication and information technologies in the perspective of Industry 4.0: Opportunities and challenges." *Computer Science Review* 30 (2018): 1-30.
2. NBP RFI: Communications Requirements, Comments of UTC (Utilities Telecom Council), July 2010.
۳. م. مظفری‌پور، "بررسی و شناسایی سیستم‌های (LPWAN (Low Power Wide Area Network"، گزارش پروژه، پژوهشگاه نیرو، ۱۳۹۵