پژوهشگاه نیرو

NRI-ER-886-UPEPN01-00-F

ارائه مدلی برای پیش‌بینی بار طولانی‌مدت و میان‌مدت بر مبنای یادگیری عمیق با درنظرگرفتن منابع عدم قطعیت



مدیرپروژه: گروه اقتصاد برق و انرژی

واحد مجری: دکتر کیومرث حیدری

۱۴۰۱

DOI: 10.30503/nripress.2020.147



ارائه مدلی برای پیش‌بینی بار طولانی‌مدت و میان‌مدت بر مبنای یادگیری عمیق با درنظرگرفتن منابع عدم قطعیت

مدیرپروژه: دکتر معصومه رستم نیاکان کلهری

گروه پژوهشی پشتیبان:

گروه اقتصاد برق و انرژی

همکاران پروژه:

مجری: دکتر کیومرث حیدری

ناظر علمی: دکتر مسعود حسنی مرزونی

محقق: دکتر مصباح‌الدین سلامی

واحد مجری:

گروه اقتصاد و انرژی

انتشارات پژوهشگاه نیرو

۱۴۰۱

کد ثبت گزارش:NRI-ER-886-UPEPN01-00-F

DOI: 10.30503/nripress.2020.147

ایران. وزارت نیرو. پژوهشگاه نیرو. گروه پژوهشی اقتصاد و انرژی

ارائه مدلی برای پیش‌بینی بار طولانی‌مدت و میان‌مدت بر مبنای یادگیری عمیق با درنظرگرفتن منابع عدم قطعیت/ مدیرپروژه: کیومرث حیدری، نام. ویراستار: سیما حسینی ماکان. کارفرما: پژوهشگاه نیرو ، ۱۴۰۱.

۸۵ ص.: مصور، نمودار، جدول

۱. سلامی، مصباح‌الدین، همکار پروژه؛ ۲. حیدری، کیومرث، مدیر واحد مجری؛ ۳. نام گروه پژوهشی پشتیبان: گروه پژوهشی اقتصاد برق و انرژی. ۴. محور تقاضای انرژی.

انتشارات پژوهشگاه نیرو

گروه پژوهشی اقتصاد و انرژی

کلیه حقوق معنوی اثر متعلق به پدیدآورندگان، کلیه حقوق مادی متعلق به پژوهشگاه نیرو و نشر مطالب در حدود متعارف، با ذکر منبع بلامانع است.

نشانی: **تهران، شهرک‌غرب، انتهای بلوار شهیددادمان، پژوهشگاه نیرو، کدپستی: ۱۴۶۸۶۱۳۱۱۳**

تلفن: ۹-۸۸۰۷۹۴۰۱

نمابر: ۸۸۰۷۸۲۹۶

وبگاه: www.nri.ac.ir

پست الکترونیک انتشارات: publications@nri.ac.ir

فرم تعهدنامه اصالت اثر

متعهد می‌شوم که مطالب مندرج در این گزارش حاصل کار پژوهشی اینجانب مصباح‌الدین سلامی، محقق پسادکتری پروژه ارائه مدلی برای پیش‌بینی بار طولانی‌مدت و میان‌مدت بر مبنای یادگیری عمیق با درنظرگرفتن منابع عدم قطعیت و همکاران به‌شرح زیر است و دستاوردهای پژوهشی دیگران که در این پژوهش از آن‌ها استفاده شده است مطابق مقررات، در دستِ ارجاع قرار گرفته و در فهرست منابع ذکر گردیده است.

■ گزارش حاصل انجام همه مراحل پروژه است.

DOI: 10.30503/nripress.2020.147

فهرست مطالب

مقدمه ۹
۱- اهداف و ضروریت‌های تحقیق ۲
مقدمه فصل اول ۱۲
۱-۱- معرفی مسئله ۱۵
۱-۲- مرور ادبیات ۲۰
۱-۳- نتیجه‌گیری ۲۵
۲- مرور ادبیات تحقیق و معرفی پارامترهای ورودی مسئله ۲۶
مقدمه فصل دوم ۲۷
۲-۱- مرور ادبیات ۲۷
۲-۲- پایگاه داده‌های به‌کاررفته در تحقیق ۳۵
۲-۳- پیش‌پردازش داده‌ها ۳۶
۲-۴- نرمال‌سازی ۳۷
۲-۵- جدول نهایی پارامترها و متغیرها ۴۰
۲-۶- نتیجه‌گیری ۴۱
۳- ساختار و اجزای مدل پیشنهادی ۴۳
مقدمه فصل اول ۴۴
۳-۱- مدل‌های موجود ۴۴
۳-۲- اجزای مدل ۴۶

DOI: 10.30503/nripress.2020.147:

۳-۳- ساختار مدل ترکیبی ۶۰
۳-۴- نتیجه‌گیری..... ۶۳
۴- نتایج اجرای مدل..... ۶۳
مقدمه فصل چهارم ۶۴
۴-۱- معیار سنجش خطا ۶۵
۴-۲- نتایج اجرای مدل هدف و مقایسه با دیگر مدل‌ها ۶۵
۴-۳- اعتبارسنجی ۷۸
نتیجه‌گیری ۸۰
فهرست منابع ۸۱

فهرست نمودارها و شکل‌ها

شکل ۱. فلوچارت محل قرارگیری مدل هدف در دسته مدل‌های پیش‌بینی بار ۲۳
شکل ۲. دسته پارامترهای به‌کاررفته در مدل‌های پیش‌بینی بار ۲۷
شکل ۳. تجزیه سه‌مرحله‌ای متغیر تقاضای بار الکتریسیته ۵۰
شکل ۴. ساختار شبکه عصبی پس انتشار با تبدیل موجک ۵۲
شکل۵. ترکیب سه‌مرحله‌ای متغیر تقاضای بار الکتریسیته ۵۵
شکل ۶. **Proposed Model Diagram** ۶۱
شکل ۷. داده‌های تاریخی مصرف بار الکتریکی ۶۶
شکل ۸. بهینه‌سازی تعداد سیگنال و نحوه تقسیم‌بندی سیگنال **EMD** توسط **WOA** ۶۸
شکل ۹. انتخاب ویژگی‌ها توسط مدل **PCA** ۶۹
شکل ۱۰. بهینه‌سازی **RMSE** در طول اجرا (**a**) **LSTM** (**b**) **WTBPNN-EHO** ۷۳

DOI: 10.30503/nripress.2020.147:

شکل ۱۱. مقایسه مقدار استاندارد خطای مدل هدف با دیگر مدل‌های موجود در **a**) بهار **b**) تابستان **c**) پاییز **d**) زمستان سال ۲۰۱۲ برای برق منطقه‌ای تهران ۷۷

شکل ۱۲. مقایسه مقدار **MAPE** مدل هدف با مدل‌های موجود در سال ۲۰۱۲ تا ۲۰۱۵ برای برق منطقه‌ای تهران ۷۸

فهرست جدول‌ها

جدول ۱. برخی از مدل‌های پیش‌بینی تقاضای بار الکتریکی ۲۰

جدول۲. پارامترهای مختلف ورودی به مدل پیشنهاددادهشده در تحقیقات گذشته ۳۲

جدول ۳. پارامترها و متغیر معرفی‌شده برای تحقیق ۴۰

جدول ۴. مقایسه عملکرد مدل هدف با مدل‌های موجود بر اساس معیارهای سنجش خطا در سال ۲۰۱۲ ..... ۷۴

جدول ۵. **Wilcoxon signed-rank test** ۷۵

DOI: 10.30503/nripress.2020.147:

مقدمه

ایران در زمینهٔ تمام انرژی‌ها از نفت و گاز تا انرژی‌های تجدیدپذیر و هیدروژن، از ظرفیتی شگفت‌انگیز برخوردار است. در بحث عملکرد، میان وضعیت فعلی و سطح آینده‌نگری با آنچه ایدئال کشور است، فاصله زیادی وجود دارد. به‌عبارتی، آینده انرژی مسئله‌ای است که در ایران به آن کمتر پرداخته می‌شود و به همین خاطر هنوز میان پتانسیل‌ها و عملکرد ما با وجود فرصت محدودی که در اختیار داریم، شکاف عظیمی قرار دارد. یکی از اقدامات مؤثر در جهت پرکردن این شکاف برنامه‌ریزی صحیح زنجیره تأمین انرژی است. برنامه‌ریزی صحیح زنجیره تأمین انرژی از تولید بیش از اندازه انرژی و یا کمبود انرژی جلوگیری می‌نماید و یک تعادل صحیح بین تولیدکننده و مصرف‌کننده ایجاد می‌نماید. یکی از مهم‌ترین پارامترهایی که به برنامه‌ریزان این حوزه می‌تواند کمک شایانی نماید، پیش‌بینی صحیح و با دقت بالا میزان تقاضای بار الکتریکی است. میزان تقاضا، خود وابسته به پارامترهای دیگری از جمله میزان دمای هوا، رطوبت و در یک نگاه کلان‌تر و بلندمدت‌تر به پارامترهای اقتصادی و اجتماعی مانند تولید ناخالص ملی، نرخ رشد جمعیت، ضریب شهرنشینی، توسعه صنایع و کشاورزی و غیره است؛ لذا در محور تقاضای انرژی در ادامه پروژه‌های انجام‌شده یا در دستِ اجرا، پروژه‌ای با هدف پیش‌بینی میان‌مدت و بلندمدت تقاضای بار الکتریکی بر اساس مدل‌های یادگیری عمیق، تعریف گردد تا بتوان از این مدل در آینده برنامه‌ریزی‌های زنجیره تأمین برق استفاده کرد.

DOI: 10.30503/nripress.2020.147:

فصل اول

اهداف و ضرورت‌های تحقیق

DOI: 10.30503/nripress.2020.147:

مقدمه

یکی از مهم‌ترین دغدغه‌های کنونی جهان انرژی است. توسعه فناوری‌ها و گسترش صنایع موجب شده است که جوامع بیش از پیش به انرژی‌های فسیلی و همچنین برق محتاج شوند. شاید اغراق نباشد اگر بگوییم بدون انرژی زندگی برای انسان‌ها بسیار سخت و دشوار و در شرایطی ناممکن می‌باشد. از سوی دیگر با توجه به رشد فزاینده جمعیت در سرتاسر جهان، نقش و جایگاه انرژی در دنیای امروز به‌شدت افزایش پیدا کرده است و در آینده نیز صدچندان می‌گردد.

با افزایش رشد جمعیت (به‌خصوص در کشورهای در حال توسعه) رسیدن به منابع انرژی به‌مقدار لازم، روزبه‌روز مشکل‌تر می‌شود و این میزان رشد تقاضای انرژی، خیلی سریع بوده است؛ بنابراین انتظار می‌رود این تقاضا همچنان افزایش یابد. با چنین رشد جمعیتی، زمینه برای رقابت‌های بزرگ همراه با فرصت‌های بزرگ برای ابتکار، سازش با محیط و نوآوری انسان‌ها فراهم شده است.

در کشور ما نیز، روند مصرف برق کشور در طول ۱۵سال آینده با متغیرهای تولید ناخالص داخلی، جمعیت، دما، نوع روزهای هفته و برق‌های منطقه‌ای بررسی شده است. در سناریوهای رشد اقتصادی ۴درصد و ۸درصد به‌ترتیب پیک بار مردادماه در کشور به‌ترتیب به ۱۰۵۰۰۰ و ۱۲۳۰۰۰ مگاوات تقریب زده شده است. از دلایل عمده این روند می‌توان افزایش مصرف برق در بخش خانگی و صنعت هم‌زمان با توسعه و رشد اقتصادی کشور را نام برد.[۱]

به‌منظور هرگونه سیاست‌گذاری دقیق و کارآمد در بخش انرژی علاوه بر اطلاع دقیق از وضعیت منابع انرژی و روش‌های تأمین انرژی، باید اشراف دقیق و کاملی نسبت به وضعیت مصرف انرژی و نرخ تغییرات آن داشت؛ اگر سیاست‌ها و برنامه‌های بخش انرژی تنها با نگاه به منابع انرژی و راهکارهای تأمین انرژی و نیز سایر اهداف کلان تعیین‌شده و بدون نگاه به وضعیت کنونی مصرف انرژی و پیش‌بینی در خصوص آینده آن تدوین شوند، قطعاً در عمل با شکست مواجه خواهند شد؛ چراکه مجری سیاست‌ها خود را در یک زمین‌بازی متناقض مشاهده خواهد کرد؛ جایی که سیاست‌ها و برنامه‌های کلان او را به‌سمتی هدایت کرده است؛ در حالی که واقعیت‌ها و تقاضا او را مجبور به اقدامات دیگری می‌کنند.

رشد صنعتی و توسعه اقتصادی تا حد زیادی به مقدار و سطح استفاده کارآمد از حامل‌های انرژی ارتباط دارد. ارتباط میان رشد اقتصادی و مصرف انرژی متأثر از عوامل متعددی از جمله قیمت حامل‌های انرژی، وقایع اجتماعی مختلف نظیر انقلاب، جنگ، تحریم‌های اقتصادی، شوک‌های نفتی و... است. مطابق با آخرین آمار از میزان عرضه و تقاضای انرژی در ایران، میزان مصرف انرژی در کشور بیشتر از استانداردهای جهانی است. از طرفی امکان صرفه‌جویی در مصرف سالانه انرژی با ظرفیتی معادل ۵۰۰ میلیون بشکه معادل نفت خام وجود دارد. بررسی‌ها نشان می‌دهد در سال ۱۳۹۶ ترکیب سبد مصرف نهایی کشور شامل ۵۶/۰۲درصد گاز طبیعی، ۳۱/۸۸درصد فراورده‌های نفتی، ۱۱/۰۹درصد برق و حدود یک درصد نیز زغال‌سنگ و انرژی تجدیدپذیر بوده است. [۲]

DOI: 10.30503/nripress.2020.147:

مقدار اتلاف تبدیلات و اتلافات ناشی از انتقال و توزیع در زنجیره تأمین انرژی در سال ۱۳۹۶، ۵/ ۴۸۸ میلیون بشکه معادل نفت خام است که از این مقدار ۹/ ۳۳۵ میلیون بشکه معادل نفت خام مربوط به تلفات بخش نیروگاهی است. مقدار تلفات نیروگاهی در حقیقت معادل ۷۶/ ۶۸درصد از کل بخش تبدیلات و تلفات است؛ اما به‌لحاظ سهم بخش‌های مختلف از مصرف انرژی و غیرانرژی در ایران، ارزیابی‌ها بیانگر این نکته است که بخش خانگی، صنعت و حمل‌ونقل در سال ۱۳۹۶ به‌ترتیب با ۲۸، ۲۵ و ۲۴درصد بیشترین سهم را در بین بخش‌های مختلف از مصرف انرژی به خود اختصاص داده‌اند. در ضمن طی ۱۰ سال اخیر سهم بخش صنعت در سبد مصرف نهایی از ۲۳ به ۲۵درصد افزایش پیدا کرده و نیز سهم بخش خانگی از ۳۰ به ۲۸درصد کاهش یافته است. [۲]

روند کل مصرف برق کشور در طول یک دهه گذشته نشان می‌دهد، مصرف نهایی سالانه برق در ایران از ۱۶۱۴۴۵ گیگاوات ساعت در سال ۱۳۸۷ به ۲۵۵۰۲۶ گیگاوات ساعت در سال ۱۳۹۶ رسیده که در واقع نشان‌دهنده نرخ رشد متوسط سالانه ۵/۲۵درصدی و نیز رشد ۵۷/۹۶درصدی در طول این دوره است. بخش‌های خانگی و صنعت بیشترین سهم را از کل مصرف انرژی الکتریکی در کشور دارند و به‌عنوان مثال در سال ۱۳۹۶ بخش خانگی و صنعت به‌ترتیب ۳۲/۷ و ۳۳درصد از کل مصرف انرژی الکتریکی را به خود اختصاص می‌دهند.؛ اگرچه بزرگ‌ترین مصرف‌کننده‌های برق در دوره در دستِ بررسی بخش خانگی و صنعت هستند؛ اما طی این دوره، رشد مصرف این حامل انرژی در بخش‌های حمل‌ونقل و کشاورزی بیشتر از سایر بخش‌ها بوده است. رشد ۸۳/۹۲درصدی مصرف برق در بخش کشاورزی عمدتاً به‌دلیل جایگزینی این حامل به‌جای نفت سفید (نصب پمپ‌های برقی) و رشد ۹۳/۸۶درصدی مصرف برق در بخش حمل‌ونقل به‌دلیل راه‌اندازی خطوط مترو در کلان‌شهرها بوده است. در ارتباط با رشد بی‌رویه مصرف برق در بخش صنعت علل عمده عبارت‌اند از: قدیمی‌بودن فناوری‌های به‌کاررفته در واحدهای مصرف‌کننده، پایین‌بودن قیمت انرژی، سرمایه‌گذاری نکردن در وسایل و تجهیزات به‌منظور افزایش بهره‌وری که در حقیقت این موضوع برای صاحبان صنایع دارای توجیه اقتصادی نیست، وجود انحصارهای دولتی و حمایت دولت از تولیدکننده دولتی و نبود بازار رقابتی و کندی واگذاری بخش دولتی به خصوصی است. [۳]

بنابراین با توجه به افزایش تقاضا، علاوه بر توسعه زیرساخت‌های لازم برای تولید، انتقال و توزیع برق، نیاز به برنامه‌ریزی دقیق زنجیره برق حیاتی می‌باشد. با توجه به نقش انرژی به‌عنوان یکی از نهاده‌های اصلی تولید، هرگونه تصمیم‌گیری در این زمینه اقتصاد کشورها را تحت‌تأثیر قرار می‌دهد. بر این مبنا، تصمیم‌گیری دربارۀ آن نیازمند اطلاع از شرایط عرضه و تقاضای انرژی و پیش‌بینی و برآورد روند آن‌ها در کنار تغییرات تکنولوژیک در عرضه، تبدیل و مصرف انرژی است. این امر یک برنامه‌ریزی جامع، گسترده و پیچیده را نیازمند است که از آن با عنوان برنامه‌ریزی انرژی یاد می‌شود. گسترش شایسته توجه روش‌های ریاضی و تکنیک‌های محاسبه در کنار سرعت روزافزون پیشرفت‌های سخت‌افزاری و نرم‌افزاری رایانه‌ای و گسترش روش‌های جمع‌آوری آمار که به افزایش کمیت و کیفیت آمار و داده‌های دنیای واقع منجر شده است، ابزارهای مناسبی را در زمینۀ برنامه‌ریزی انرژی فراهم آورده و به بهبود آن‌ها کمک شایانی نموده

DOI: 10.30503/nripress.2020.147:

است. با توجه به اینکه ایران سهم چشمگیری از منابع انرژی دنیا را در اختیار دارد؛ ولی با توجه به روند مصرف حامل‌های انرژی در مقایسه با استانداردهای جهانی و پایین‌بودن نرخ بازده انرژی در کشور، برنامه‌ریزی انرژی در سطح ملی و محلی از الزامات سیاست‌گذاری بخش انرژی می‌باشد. برنامه‌ریزی زنجیره برق شامل برنامه‌ریزی تولید، انتقال و توزیع آن می‌باشد که پیش‌نیاز آن پیش‌بینی با دقت بالا برخی از متغیرهای کلیدی این زنجیره است. یکی از مهم‌ترین متغیرهای کلیدی، میزان مصرف بار الکتریکی است. پیش‌بینی میزان مصرف برق در یک زنجیره سبب خواهد شد که این شبکه دچار کمبود برق یا تولید بیش از اندازه برق نشود و به‌تبع آن از هزینه‌های گزافی که در اثر تولید این میزان اضافی بار یا کمبود بار در شبکه ایجاد می‌کند جلوگیری شود. برای پیش‌بینی با دقت بالا این متغیر می‌توان از داده‌های تاریخی که مشخص‌کننده نحوه رفتار مصرف‌کنندگان در گذشته می‌باشد، برای پیش‌بینی رفتار آن‌ها در آینده استفاده کرد. به‌طور کلی توانایی ما جهت استخراج ارزش اقتصادی و اجتماعی از داده‌های جدید و موجود به عوامل مختلفی بستگی دارد. به‌طور کلی کار داده‌ها نیازمند ابزارها و مهارت‌های جدید است. اطلاعات به‌اندازه‌ای زیاد هستند که نمی‌توان آن‌ها را در یک کامپیوتر قرار داد تا به‌کمک ابزارهای آماری و بانک‌های اطلاعاتی سنتی با آن‌ها کار کرد یا به‌کمک نرم‌افزارهای گرافیکی استاندارد آن‌ها را ارائه کرد. کمبود نیروی انسانی متخصص و ماهر یکی از مهم‌ترین چالش‌های موجود به‌منظور بهره‌برداری از فرصت‌های ایجادشده توسط داده‌ها است. شاید به همین دلیل باشد که علم داده (Data Science) که تلفیقی از علوم اجتماعی، علم آمار، علم اطلاعات و علوم کامپیوتر است طراحی شده اس . امروزه بنگاه‌های کسب‌وکار نسبت به دهه‌های گذشته دارای توان بیشتری جهت دستیابی، تجمیع و تولید ارزش از داده می‌باشند. سازمان‌ها با این سؤال مواجه هستند که چگونه می‌توان از داده استفاده مؤثرتری را داشت و از آن در جهت تولید ارزش در سازمان خود استفاده کرد. استفاده از داده محدود به داده تولیدشده در سازمان نمی‌گردد و می‌توان از سایر داده‌های مرتبط و در دسترس نیز استفاده کرد. در صنعت برق نیز با توجه به واقعیت تغییر ساختار صنعت برق و همچنین تغییر الگوهای مصرف، شاهد آن هستیم که همه‌روزه حجم زیادی از داده‌های تاریخی که ناشی از عملکرد بخش‌های مختلف صنعت برق است، در پایگاه داده‌های بازار برق ایران در حال ذخیره‌سازی می‌باشد. تقاضای بار الکتریکی یکی از مهم‌ترین و اصلی‌ترین وظایف مدیر بازار برق است که زمینه را برای پیشنهاد انواع مدل‌های ابتکاری، فراابتکاری یا مجموعی از مدل‌های پیش‌بینی آماری ایجاد کرده است. همچنین انواعی از مدل‌های پیشرفته‌تر که در آن از مفاهیم شبکه عصبی استفاده شده است، در طی سالیان گذشته پیشنهاد شده است. بی‌شک پیش‌بینی دقیق‌تر متغیرهایی مانند عرضه و تقاضای برق و در نتیجه آن قیمت برق می‌تواند صرفه‌جویی‌های عظیمی را ایجاد نماید؛ بنابراین در این تحقیق ما به‌دنبال ارائه روشی جدید و هوشمند جهت پیش‌بینی تقاضای بار الکتریکی در زنجیره تأمین برق هستیم تا بتوانیم به برنامه‌ریزی صحیح‌تر این زنجیره کمک کرده و هزینه‌های گزاف تحمیلی در اثر پیش‌بینی غلط و در نتیجه برنامه‌ریزی نامناسب را کاهش دهیم.

۱-۱- معرفی مسئله

DOI: 10.30503/nripress.2020.147:

مسئله برنامه‌ریزی و بهره‌برداری میان‌مدت و بلندمدت سیستم‌های قدرت بر پایه پیش‌بینی تقاضا و همچنین ظرفیت تولید/انتقال می‌باشند. علی‌رغم اهمیت دقت پیش‌بینی طولانی‌مدت بار برای مسئله توسعه تولید و انتقال، در تحقیقات به این موضوع زیاد پرداخته نشده است.

در پیش‌بینی میان‌مدت و طولانی‌مدت بار، به‌دلیل وابستگی آن به پارامترهای اقتصادی نظیر GDP و جمعیت و همچنین تنوع قیمت و توسعه تکنولوژیکی مسئله ای پیچیده است. [۴]

در [۵] چالش‌های پیش‌بینی طولانی‌مدت بار به سه گروه تقسیم شده‌اند:

- ۱. محدوده (چه فاکتورهای فنی و اقتصادی باید در نظر گرفته شوند.)؛ ۲. مقیاس زمانی؛ ۳. عدم قطعیت.

در [۶] جنبه‌های مختلف حائز اهمیت در پیش‌بینی طولانی‌مدت بار عنوان گردیده‌اند. این جنبه‌ها عبارت‌اند از:

- **فاکتورهای اقتصاد کلان**: تقاضای آینده انرژی (یعنی مصرف انرژی در آینده مانند انرژی الکتریکی) نتیجه نیاز به "خدمات انرژی"[۱] به‌معنای خدمتی است که با مصرف یک نوع سوخت فراهم می‌شود است، نه مصرف خود سوخت. یک مثال تقاضای گرمایش در یک ساختمان است، نه سوختی که برای گرمایش آن ساختمان استفاده می‌شود. [۷]

  تقاضای آینده برای خدمات انرژی ارتباطی نزدیک با توسعه جمعیت و GDP دارد. با افزایش جمعیت مصرف انرژی افزایش می‌یابد. همچنین درآمدهای بیشتر، سایز و امکانات ساختمان‌ها را افزایش می‌دهد و از طرفی با افزایش درآمد لوازمی با کارایی بهتری به‌لحاظ مصرف انرژی توسط مصرف‌کنندگان استفاده می‌شوند.

  مطالعات مختلفی فاکتورهای GDP، جمعیت و قیمت برق و فاکتورهای اقتصادی را به‌عنوان عوامل تأثیرگذار بر پیش‌بینی طولانی‌مدت بار استفاده نموده‌اند. اغلب روش‌های تحلیل رگرسیونی اقتصادسنجی را برای پیش‌بینی سالیانه تقاضای انرژی الکتریکی استفاده نموده‌اند. غالباً تقاضا به بخش‌های مختلف (خانگی، تجاری و صنعتی) تقسیم شده است. همچنین در این مطالعات غالباً بار پیک (روزانه، ماهیانه یا ساعتی) بدون ارائه اطلاعاتی اضافی استخراج گردیده است.

- **توسعه تکنولوژی**: توسعه تکنولوژی بر طراحی سیستم‌های انرژی و همچنین تقاضای کاربر نهایی تأثیرگذار است. تأثیر تغییراتی نظیر برقی‌سازی بر میزان تقاضا از جنبه‌های درخور توجه برآورد تقاضا به شمار می‌رود. heat-pumpها، وسایل نقلیه برقی، PVها و ذخیره‌سازهای انرژی در این گروه قرار دارند.

[۱] *energy services*

DOI: 10.30503/nripress.2020.147:

- **انعطاف‌پذیری**: وجود ابزارهای مترینگ جدید شرکت‌های توزیع را قادر به ثبت و مانیتور مصرف به‌صورت دقیقه‌ای می‌کند. چنین داده‌هایی می‌توانند به تشریح پروفیل مصرف برق با جزئیات بیشتر کمک کنند؛ به‌عنوان مثال تحلیل الگوهای بار به تصمیم‌گیران این امکان را می‌دهد که تعرفه‌هایی متنوع‌تر وضع کنند. در مناطقی با پتانسیل بالا برای انرژی خورشیدی و بادی، تغییر به مصرف کمتر انرژی فسیلی ایجاب می‌کند که سیستم از حالت تقاضامحور[۲] به‌سمت تولید[۳]محور حرکت کند. در آینده برنامه پاسخ بار[۴] برای ایجاد تعادل در بار به‌وسیلهٔ منعطف‌نمودن مصرف بیشتر استفاده خواهد شد. [۸]

برای پیش‌بینی بار در آینده و پتانسیل انعطاف‌پذیری آن باید اطلاعاتی در ارتباط با پروفیل بار در سکتورهای مختلف در دسترس باشد؛ چراکه برخی از آن‌ها قابلیت انعطاف بیشتری دارند.

پیش‌بینی دقیق‌تر بار نیازمند متدهایی برای بخش‌بندی الگوهای مصرف، لینک‌کردن الگوهای بار با مصرف‌کنندگان، طبقه‌بندی تجاری و صنعتی و همچنین شناسایی تغییر تدریجی الگوهای بار در طول زمان می‌باشیم. چنین اقداماتی نیازمند جمع‌آوری داده‌های با حجم بالا مربوط به فیدرهای مختلف از شرکت‌های توزیع می‌باشد که در حال انجام برای تعریف پروژه‌ای مفصل‌تر در آینده می‌باشد.

- **تحلیل تقاضا به‌تفکیک بخش‌های مختلف مصرف**: در نهایت این کاربران نهایی هستند که برق را مصرف می‌کنند و روندها و اولویت‌ها در بخش‌های مختلف بازار مصرف برق را مشخص می‌کند. توسعه فعلی تکنولوژی و انعطاف‌پذیری منابع بیشتر مصرف کاربران نهایی را بر ساختمان‌ها و حمل‌ونقل متمرکز می‌کند؛ [۶] اگر ترجیحات انواع مصرف‌کنندگان را بدانیم می‌توانیم با توجه به عواملی نظیر نفوذ تکنولوژی رفتار آینده آن‌ها را پیش‌بینی کنیم. سطح جزئیات لازم برای پیش‌بینی تابعی از نوع مطالعه است. می‌توان تفکیک را بر اساس سکتور (خانگی، صنعتی، تجاری و حمل‌ونقل)، سرویس انرژی (روشنایی، گرمایشی، وسایل الکتریکی خانگی[۵] (نظیر یخچال، ماشین لباس‌شویی و...)) و/یا تکنولوژی انجام داد. در بسیاری از مطالعات بر مبنای فاکتورهای اقتصاد کلان، چهار بخش اقتصادی مهم در نظر گرفته می‌شود: صنعتی، حمل‌ونقل، تجاری و خانگی. به‌لحاظ آماری، این نوع تفکیک برای برآورد تقاضای سالیانه مناسب است. تفکیک بر اساس سکتور می‌تواند در سطح

[۲] *demand-driven*

[۳] *production-driven*

[۴] *demand-response*

DOI: 10.30503/nripress.2020.147:

بعدی به نوع سرویس انرژی نیز تفکیک گردد؛ به‌عنوان مثال تقاضای گرمایشی یک ساختمان می‌تواند با انواع سرویس‌های انرژی تأمین شود؛ اما ماشین ظرف‌شویی یا لباس‌شویی تنها به برق نیاز دارند؛ بنابراین پیش‌بینی تقاضا برای سرویس انرژی یک سری اطلاعات راجع به پتانسیل‌های جایگزینی سوخت‌ها به ما می‌دهد.

تفکیک تقاضا به این بخش‌ها نیاز به داده‌هایی با جزئیات بالا دارد. در این مطالعه، تقاضا به بخش‌های خانگی (خانگی، تجاری، کشاورزی، صنایع کوچک) صنعتی تقسیم می‌گردد.

- **تغییرات کوتاه‌مدت**: عدم قطعیت کوتاه‌مدت با عدم قطعیت مربوط به دوره زمانی تصمیم‌های عملیاتی مرتبط است؛ بنابراین عدم قطعیت کوتاه‌مدت، دوره‌های زمانی کوتاه‌تر مانند روز، ساعت، هفته یا حتی فصل را شامل می‌شود. منبع این عدم قطعیت معمولاً به نوسانات آب‌وهوا و منابع تجدیدپذیر باز می‌گردد که موجب نوسان در قیمت برق می‌گردد.

در برنامه‌ریزی طولانی‌مدت در بخش برق، جهت اخذ تصمیمات روباست بهتر است این مسئله را در نظر بگیریم که در برنامه‌ریزی عملیاتی طولانی‌مدت حتماً عدم قطعیت وجود دارد. هنگامی که فقط یک پروفیل بار قطعی به‌عنوان ورودی مسئله برنامه‌ریزی استفاده شود، مدل نتایج درستی متناسب با عدم قطعیت کوتاه‌مدت ایجاد نمی‌کند. [۶]

در این مطالعه بر اساس سناریوهای مختلف پارامترهای ورودی، پروفیل بار پیش‌بینی خواهد شد که به‌عنوان ورودی مسئله برنامه‌ریزی انرژی به کار خواهد رفت.

- **تفکیک زمانی:** در هنگام پیش‌بینی بار، استفاده از مدل‌هایی که زمان پیک را شناسایی می‌کنند اهمیت دارند؛ چراکه بار ممکن است به ساعاتی قبل یا بعد منتقل شود یا حتی در بدترین حالت چند ساعت جابه‌جا شود. در [۷] تأکید شده است هنگامی که منابع تجدیدپذیر در مسئله برنامه‌ریزی انرژی مدل می‌شوند، ساعت پیک فاکتوری مهم است؛ چراکه بی‌توجهی به نوسانات تولید و مصرف ممکن است تخمینی بیش از واقعیت ایجاد کنند.

با توجه به توضیحات فوق لازم است از مدل‌های مبتنی بر هوش مصنوعی استفاده کرد تا بتوان روند ارتباط بین پارامترهای کلان اجتماعی یا اقتصادی و همچنین پارامترهای مربوط به آب‌وهوا را با میزان تقاضای بار الکتریکی پیدا کرده و از این الگوی ارتباط برای پیش‌بینی‌های آتی استفاده کرد، پیشنهاد داده شود.

در این تحقیق در نظر گرفته شده است که از تکنیک‌های یادگیری عمیق برای یافتن روند ارتباطی بین پارامترها و متغیر تقاضای بار الکتریکی استفاده کرد.

DOI: 10.30503/nripress.2020.147:

یک زیرشاخه از یادگیری ماشین و بر مبنای مجموعه‌ای از الگوریتم‌ها است که در تلاش‌اند تا مفاهیم انتزاعی سطح بالا در دادگان را مدل نمایند که این فرایند را با استفاده از یک گراف عمیق که دارای چندین لایه پردازشی متشکل از چندین لایه تبدیلات خطی و غیرخطی هستند، مدل می‌کنند. به‌بیان دیگر پایهٔ آن بر یادگیری نمایش دانش و ویژگی‌ها در لایه‌های مدل است.

انگیزه نخستین در به‌وجودآمدن این ساختار یادگیری از راه بررسی ساختار عصبی در مغز انسان الهام گرفته شده است که در آن یاخته‌های عصبی با فرستادن پیام به یکدیگر درک را امکان‌پذیر می‌کنند. بسته به فرض‌های گوناگون دربارهٔ نحوه اتصال این یاخته‌های عصبی، مدل‌ها و ساختارهای مختلفی در این حوزه پیشنهاد و بررسی شده‌اند؛ هرچند که این مدل‌ها به‌صورت طبیعی در مغز انسان وجود ندارد و مغز انسان پیچیدگی‌های بیشتری را دارا است. این مدل‌ها نظیر شبکه عصبی عمیق، شبکه عصبی هم‌گشتی، شبکه باور عمیق و... پیشرفت‌های خوبی را در حوزه‌های پردازش زبان‌های طبیعی، پردازش تصویر ایجاد کرده‌اند. [۹]

یادگیری عمیق زیرشاخه‌ای از یادگیری ماشین است که از لایه‌های متعدد تبدیلات خطی به‌منظور پردازش سیگنال‌های حسی مانند صدا و تصویر استفاده می‌کند. ماشین در این روش هر مفهوم پیچیده را به مفاهیم ساده‌تری تقسیم می‌کند و با ادامهٔ این روند به مفاهیم پایه‌ای می‌رسد که قادر به تصمیم‌گیری برای آن‌ها است و بدین ترتیب نیازی به نظارت کامل انسان برای مشخص‌کردن اطلاعات لازم ماشین در هر لحظه نیست. موضوعی که در یادگیری عمیق اهمیت زیادی دارد، نحوهٔ ارائهٔ اطلاعات است. ارائه‌دادن اطلاعات به ماشین باید به‌شیوه‌ای باشد که ماشین در کمترین زمان اطلاعات کلیدی که می‌تواند با استناد به آن‌ها تصمیم بگیرد را دریافت کند. هنگام طراحی الگوریتم‌های یادگیری عمیق می‌بایست به عوامل دگرگونی [۶] که اطلاعات مشاهده‌شده را توضیح می‌دهند توجه کنیم، این عوامل معمولاً عوامل درخور مشاهده‌ای نیستند، بلکه عواملی هستند که بر روی دستهٔ مشاهده‌پذیر تأثیرگذار بوده یا زادهٔ ساختارهای ذهنی انسان برای ساده‌ترکردن مسائل هستند؛ برای مثال در هنگام پردازش گفتار عوامل دگرگونی می‌توانند لهجهٔ گوینده، سن یا جنسیت او باشند. در هنگام پردازش تصویر یک ماشین، میزان درخشش خورشید یک عامل دگرگونی است. یکی از مشکلات هوش مصنوعی تأثیر زیاد عوامل دگرگونی بر روی اطلاعات دریافتی است؛ برای مثال بسیاری از پیکسل‌های دریافتی از یک ماشین قرمز در شب ممکن است سیاه دیده بشوند. برای حل این مشکلات بعضاً به درک بالای اطلاعات (در حدود انسان) نیازمندیم و در واقع گاهی یافتن نحوهٔ مناسب نمایش اطلاعات به‌اندازهٔ خود مسئله سخت و زمان‌بر است. [۱۰]

۲-۱- مرور ادبیات

[۶] *factors of variation*

DOI: 10.30503/nripress.2020.147:

یکی از زمینه‌های تحقیقات علمی حوزه انرژی، مدل‌های برنامه‌ریزی انرژی (EPMs) است که به پیش‌بینی متغیرهایی مانند سرعت باد [۱۱]، میزان انتشار گاز CO_2 [۱۲]، میزان تولید زغال‌سنگ [۱۳]، میزان تقاضای گاز طبیعی [۱۴]، قیمت برق [۱۵]، میزان تابش خورشیدی [۱۶] و غیره پرداخته شده است. از جمله مهم‌ترین و پرکاربردترین متغیرهای در دستِ بررسی در این زمینه، متغیر تقاضای انرژی الکتریکی می‌باشد [۱۷]. هرچقدر دقت در پیش‌بینی بار الکتریسیته بیشتر باشد، کنترل تولید، توزیع و انتقال برق یا همچنین قیمت‌گذاری برق با دقت بالاتری انجام خواهد گرفت [۱۸]. مدل‌های پیش‌بینی بار الکتریسیته از حیث دوره زمانی پیش‌بینی، به چهار دسته کلی پیش‌بینی بسیار کوتاه‌مدت (کمتر از یک ساعت) مانند مدل ذکرشده در منبع [۱۹]، کوتاه‌مدت (یک ساعت تا یک ماه) مانند رفرنس [۲۰]، میان‌مدت (یک ماه تا یک سال) مانند مدل ذکرشده در منبع [۲۱] و بلندمدت (بیش از یک سال) [۲۲] تقسیم‌بندی می‌شود. برخی از مدل‌های پیش‌بینی بار الکتریسیته در مقاله مروری [۱۸] در بین سایر مدل‌های برنامه‌ریزی انرژی در جدول ۱ آمده است.

Objectives / Methods	Energy Demand	Energy Supply	Renewable energy	GHG emissions	Energy economic	Socio economic	Energy and electricity price	Load forecasting	Planning and/or Policy analysis	Performance	Model development	Total	%
SVM	■	–	■	–	■	–	■	■	–	–	■	6	8.8%
Decision tree	■	–	■	–	–	–	–	■	–	–	–	3	4.4%
ANN	■	■	■	■	■	–	■	■	–	■	■	9	13.2%
Abductive networks	■	–	–	–	–	–	–	–	–	–	–	1	1.5%
Grey prediction	■	■	■	■	–	■	■	■	–	–	–	7	10.3%
Fuzzy logic	■	–	■	–	–	–	■	■	■	■	–	6	8.8%
Expert system	■	–	–	–	–	–	–	■	–	–	–	2	2.9%
GA	■	–	–	■	–	–	–	■	■	–	■	5	7.4%
ABCO	–	–	–	■	–	–	–	■	–	–	–	2	2.9%
ACO	■	■	■	■	–	–	–	■	■	–	–	6	8.8%
PSO	■	–	■	■	–	–	■	■	■	–	–	6	8.8%
GSA	■	–	■	–	–	–	–	■	–	–	–	3	4.4%
CAS	–	–	–	–	–	–	–	■	–	–	–	1	1.5%
DE	–	–	–	–	–	–	–	■	–	–	■	2	2.9%
HS	■	–	–	–	–	–	–	–	–	–	–	1	1.5%
EA	–	–	–	–	–	–	–	■	–	–	–	1	1.5%
MA	–	–	–	–	–	–	–	■	–	–	–	1	1.5%
IA	–	–	–	–	–	–	–	■	–	–	–	1	1.5%
SA	–	–	■	–	–	–	–	■	–	–	–	2	2.9%
FA	–	–	–	–	–	–	–	■	–	–	–	1	1.5%
CSA	–	–	–	–	–	–	■	–	–	–	–	1	1.5%
NLP	■	–	–	–	–	–	–	–	–	–	–	1	1.5%
Number of methods	13	3	9	6	2	1	6	18	4	2	4		
Number of models	169	5	59	17	5	1	29	162	4	3	12		
Percentage of model (%)	36.3%	1.1%	12.7%	3.6%	1.1%	0.2%	6.2%	34.8%	0.9%	0.6%	2.6%		

جدول ۱. برخی از مدل‌های پیش‌بینی تقاضای بار الکتریکی

در پیش‌بینی میان‌مدت و بلندمدت بار الکتریکی که هدف این تحقیق می‌باشد، مدل‌های متنوعی پیشنهاد شده است. این مدل‌ها را می‌توان به سه دسته کلی، مدل‌های مبتنی بر روش‌های آماری، مدل‌های مبتنی بر هوش مصنوعی و مدل‌های ترکیبی تقسیم‌بندی کرد. در دسته مدل‌های پیش‌بینی مبتنی بر روش‌های آماری، مدل‌هایی مانند linear

DOI: 10.30503/nripress.2020.147:

regression [۱۹]، ARIMA [۲۰]، lifting scheme and ARIMA، SARMAX[۷] [۲۱]، SARFIMA[۸] [۲۲]، kalman filtering[۲۳]، MILP [۲۴]، ارائه شده است. این مدل‌ها در تشخیص روندهای غیرخطی به‌شدت دچار خطا می‌شوند و تنها مناسب برای سری‌های خطی هستند [۲۵]. دسته دوم از مدل‌ها شامل استفاده از هوش مصنوعی در پیش‌بینی کوتاه‌مدت بار الکتریکی است. در این دسته از روش‌هایی مانند شبکه عصبی مصنوعی [۲۶]،SVM[۹] [۲۷]، SVR[۱۰] [۲۸]، منطق فازی [۲۹]، مدل LMB-NN [۳۰]، RFEM-GKR [۳۱]، GBDTKDE [۳۲]، استفاده شده است. برتری این الگوریتم‌ها به‌واسطه استفاده از الگوریتم‌های هوش مصنوعی و شناسایی الگوهای متنوع‌تری از داده‌ها، در برخی از تحقیقات گذشته ثابت شده است [۳۲-۳۳]. این دسته از مقالات در ادامه روند توسعه خود با برخی از الگوریتم‌های فراابتکاری برای تعیین اوزان شبکه عصبی و در جهت بهبود عملکرد آن‌ها ترکیب شده‌اند؛ برای مثال از مدل‌هایی مانند [۳۵] GABPNN[۱۱]، PSOBPNN[۱۲] [۳۶]، ADEBPNN[۱۳] [۳۷]، GRNN[۱۴] [۳۸] ، RBFNN[۱۵] [۳۹] استفاده شده است. این دسته از مدل‌ها نیز با مشکلاتی از قبیل Overtraining و گیرافتادن جواب نهایی در بهینه‌های محلی همراه هستند و با کوچک‌ترین خطا در تعریف تابع هدف، تنظیم پارامترهای مدل یا جواب اولیه نامناسب با خطا همراه خواهند بود. به‌علاوه اینکه این دسته از مدل‌ها داده‌ها را با وجود مؤلفه‌های خطی و غیرخطی، هم‌زمان با هم و با یک مدل مشترک تحلیل می‌نمایند. دسته سوم، مدل‌های ترکیبی می‌باشند. در این دسته از مدل‌ها، داده‌ها توسط روش‌های تجزیه سیگنال به مؤلفه‌های خطی و غیرخطی تجزیه می‌شوند و هر مؤلفه با مدل مناسب خود تحلیل می‌شوند. [۴۰] در این مدل‌ها مؤلفه‌های خطی توسط روش‌های آماری و مؤلفه‌های غیرخطی توسط انواع شبکه‌های عصبی توسعه‌یافته تحلیل می‌شوند و در نهایت نتایج تحلیل این مؤلفه‌ها برای پیش‌بینی مقدار نهایی بار الکتریسیته با یکدیگر جمع می‌شوند. تجزیه داده‌ها به مؤلفه‌های خطی و غیرخطی در مقالات گذشته با روش‌های مختلفی صورت گرفته است. Li و همکاران [۴۱] داده‌ها را توسط تبدیل موجک به مؤلفه‌های خود تجزیه

[۷] *Seasonal Autoregressive Integrate Moving Average*

[۸] *Regressive Fractionally Integrated Moving Average*

[۹] *support vector machine*

[۱۰] *support vector regression*

[۱۱] *genetic algorithm back propagation neural network*

[۱۲] *particle swarm optimization back propagation neural network*

[۱۳] *adaptive differential evolution back propagation neural network*

[۱۴] *general regression neural network*

[۱۵] *radical basis function neural network*

DOI: 10.30503/nripress.2020.147:

کرده‌اند و سپس آن را با مدل‌هایی مانند EELM [۴۲][۱۶] و MABC [۱۷] [۴۳] تحلیل کرده‌اند. به‌دلیل اینکه تبدیل موجک در تشخیص فرکانس‌های لحظه‌ای توانایی پایینی دارد و با تمامی انواع سری داده‌ها هم‌خوانی ندارد، در ادامه روند تحقیقات از روش EMD برای تجزیه داده‌ها استفاده شده است که عملکرد بهتری دارد؛ برای مثال Fan و همکاران [۴۴] از این روش در ترکیب SVR استفاده کرده‌اند که دقت بیشتری را در پیش‌بینی به همراه داشته است یا در تحقیقات [۴۵-۴۶] از ترکیب این روش با مدل‌هایی مانند BEMD[۱۸] یا KELM[۱۹] استفاده شده است. بهبود این مدل‌ها می‌تواند شامل توسعه هریک از اجزای این مدل مانند: توسعه شبکه عصبی، توسعه الگوریتم‌های فراابتکاری برای تعیین اوزان، استفاده از مدل‌های تحلیل خطی قوی‌تر و همچنین توسعه الگوریتم‌های قوی‌تر در تجزیه سیگنال‌ها باشد؛ برای مثال مدل ترکیبی IEMDAW[۲۰] [۴۷] مثالی از یک الگوریتم ترکیبی با توسعه روش‌های تجزیه سیگنال می‌باشد. در روند دیگری از تحقیقات اخیر در زمینهٔ پیش‌بینی کوتاه‌مدت بار الکتریسیته، از روش‌های نوین برای انتخاب ویژگی استفاده شده است؛ برای مثال Yang و همکاران از [۴۸] مدل ACF-LSSVM[۲۱] را برای انتخاب ویژگی‌های ورودی استفاده کرده‌اند یا در تحقیق Ghadimi و همکاران [۴۹] از مدل TM[۲۲] در انتخاب ویژگی استفاده شده است. دیگر تحقیقات انجام‌شده شامل مدل OGA[۲۳] توسط Jiang و همکاران [۵۰] و مدل DFS[۲۴] توسط Jiang و همکاران [۵۱]می‌باشد. هدف در این تحقیق دنبال‌کردن روند توسعه مدل‌های ترکیبی است؛ به‌گونه‌ای که با استفاده از یک روش جدید اقدام به انتخاب بهترین داده‌ها و همچنین انتخاب سطح شکست سیگنال کرده و سپس با استفاده از یکی از روش‌های تجزیه سیگنال، سری زمانی داده‌های تاریخی بار الکتریسیته را تجزیه کرده و سپس با استفاده از دو شبکه عصبی به‌صورت موازی اقدام به تحلیل داده‌ها نماییم؛ بنابراین بر طبق بررسی‌های صورت‌گرفته جایگاه تحقیقات ما همانند شکل ۱ در استفاده از مدل‌های ترکیبی در پیش‌بینی میان‌مدت و بلندمدت بار الکتریسیته می‌باشد.

[۱۶] *evolutionary extreme learning machine*

[۱۷] *modified artificial bee colony*

[۱۸] *bivariate empirical mode decomposition*

[۱۹] *Extreme Learning Machine with Kernel*

[۲۰] *Improved empirical mode decomposition-ARIMA-Wavelet-Neural network-fruit fly optimization*

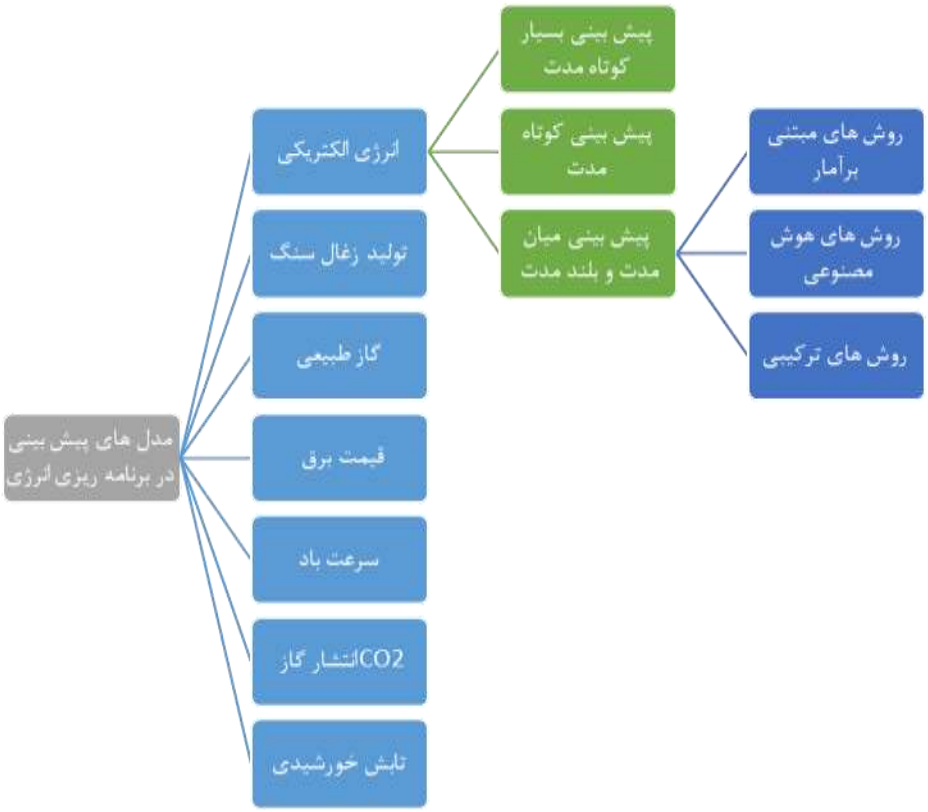
[۲۱] *Auto correlation function least squares support vector machines*

[۲۲] *transductive model*

[۲۳] *orthogonal greedy algorithm*

[۲۴] *date-framework strategy*

DOI: 10.30503/nripress.2020.147:



شکل ۱. فلوچارت محل قرارگیری مدل هدف در دسته مدل‌های پیش‌بینی بار [۵۲]

DOI: 10.30503/nripress.2020.147:

۳-۱- نتیجه‌گیری

پیش‌بینی تقاضای انرژی الکتریکی به‌عنوان یکی از مهم‌ترین متغیرهای لازم برای برنامه‌ریزی انرژی مطرح می‌شود. به همین دلیل تحقیقات متعددی در جهت طراحی مدل‌هایی برای این موضوع صورت می‌گیرد. در این میان، مجموعه‌ای از مدل‌هایی با هدف پیش‌بینی در بازه زمانی هفته، ماه و سال طراحی شده است که به مدل‌های پیش‌بینی تقاضای بار الکتریکی میان‌مدت و بلندمدت مشهور می‌باشند. در این مدل‌ها علاوه بر درنظرگرفتن پارامترهایی مانند دما یا رطوبت، پارامترهای کلان‌تر مانند جمعیت، تولید ناخالص ملی و غیره نیز در نظر گرفته شده و از داده‌های تاریخی آن‌ها برای بیشترکردن دقت پیش‌بینی‌ها و یافتن روابط غیرخطی میان پارامترها استفاده می‌شود. به‌دلیل اینکه سری‌های زمانی تقاضای انرژی الکتریکی و نحوه ارتباط آن‌ها با پارامترهای ورودی از روابط پیچیده و غیرخطی تبعیت می‌کند، لازم است الگوریتم‌های فراابتکاری و مدل‌های مبتنی بر یادگیری ماشین برای شناخت روابط بین داده‌ها و پیش‌بینی دقیق‌تر استفاده نمود.

به همین خاطر در ادامه این تحقیق ، با توسعه مدل‌های ترکیبی (که روش‌های به‌نسبت به‌روزتر و بادقت‌تری در پیش‌بینی این متغیر می‌باشند) و با درنظرگرفتن پارامترهای مناسب ورودی، ساختاری جدید برای پیش‌بینی میان‌مدت و بلندمدت تقاضای بار الکتریکی طراحی و اجرا می‌گردد. بدیهی است که رسیدن به دقت بیشتر در پیش‌بینی متغیر تقاضای بار الکتریکی در مقایسه با مدل‌های پیشنهادداده‌شده، هدف مدل پیشنهادی می‌باشد که ساختار آن در ادامه فرایند این تحقیق بر اساس روند مقالات عنوان‌شده در مرور ادبیات شکل خواهد گرفت.

DOI: 10.30503/nripress.2020.147:

فصل دوم

مرور ادبیات تحقیق

و معرفی پارامترهای ورودی مسئله

DOI: 10.30503/nripress.2020.147:

مقدمه

در فصل اول به تبیین اهداف، ضرورت‌ها و نیازهای موجود در زنجیره تأمین برق اشاره شد و عنوان گردید که اگر بخواهیم این زنجیره را به‌شکل صحیح برنامه‌ریزی و مدیریت نماییم باید متغیرهای مهم و تأثیرگذار بر آن را با بالاترین دقت پیش‌بینی نماییم. پیش‌بینی با دقت بالا متغیرها و به‌تبع آن برنامه‌ریزی بسیار دقیق این شبکه می‌تواند از تولید بار مازاد در شبکه یا کمبود بار در آن و در نتیجه هزینه‌های گزاف تحمیلی بر آن جلوگیری نماید. پیش‌بینی تقاضای بار الکتریکی به‌عنوان یکی از مهم‌ترین متغیرهای لازم برای برنامه‌ریزی شبکه می‌باشد. به همین دلیل تحقیقات متعددی در جهت طراحی مدل‌هایی برای پیش‌بینی آن صورت گرفته است. در این میان، مجموعه‌ای از مدل‌هایی با هدف پیش‌بینی در بازه زمانی هفته و ماه و سال طراحی شده است که به مدل‌های پیش‌بینی تقاضای بار الکتریکی میان‌مدت و بلندمدت مشهور می‌باشند. در این مدل‌ها علاوه بر درنظرگرفتن پارامترهایی مانند دما یا رطوبت، پارامترهای کلان‌تر مانند جمعیت، تولید ناخالص ملی و غیره نیز در پیش‌بینی‌ها در نظر گرفته شده و از داده‌های تاریخی آن‌ها برای بیشترکردن دقت پیش‌بینی‌ها و یافتن روابط غیرخطی میان پارامترها استفاده می‌شود. به‌دلیل اینکه سری‌های زمانی تقاضای بار و نحوه ارتباط آن‌ها با پارامترهای ورودی از روابط معمولاً پیچیده و غیرخطی تبعیت می‌کند، لازم است الگوریتم‌های فراابتکاری و مدل‌های مبتنی بر یادگیری ماشین برای شناخت روابط بین داده‌ها و پیش‌بینی دقیق‌تر استفاده کرد.

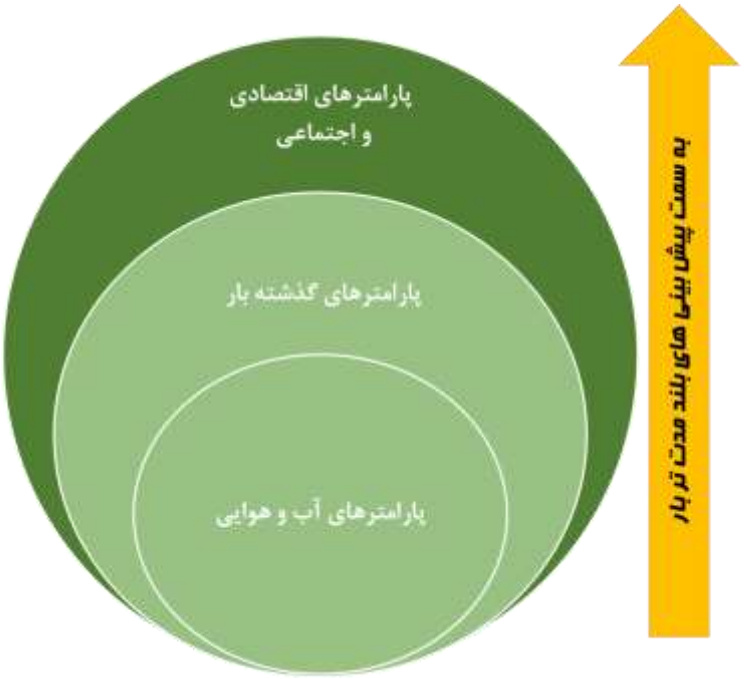
در این فصل ابتدا به مرور ادبیات مرتبط با انتخاب پارامترهای ورودی به مدل‌های پیش‌بینی تقاضای بار الکتریکی پرداخته خواهد شد و بر اساس تحقیقات گذشته، دسته‌بندی برای آن‌ها پیشنهاد داده شده و نحوه ارتباط آن‌ها با دوره‌های زمانی پیش‌بینی شرح داده خواهد شد؛ سپس پایگاه داده‌های استفاده‌شده در این تحقیق معرفی می‌گردد. بعد از آن روش‌های به‌کاررفته برای پیش‌پردازش داده‌ها معرفی و جدول نهایی پارامترها و متغیر و جدول مربوطه معرفی می‌گردد. در نهایت نتیجه‌گیری نهایی مطرح خواهد شد.

۱-۲- مرور ادبیات

همان طور که در مرور ادبیات فصل اول عنوان شد، مدل‌های پیش‌بینی تقاضای بار الکتریکی از حیث نوع ساختار مدل به مدل‌های آماری، مدل‌های غیرخطی و مدل‌های ترکیبی تقسیم‌بندی می‌شوند. [53] علاوه بر این دسته‌بندی، این مدل‌ها همچنین بر اساس دوره زمانی پیش‌بینی به مدل‌های بسیار کوتاه‌مدت که به پیش‌بینی‌های کمتر از یک ساعت، مدل‌های کوتاه‌مدت که به دوره‌های زمانی بین یک ساعت تا یک روز، مدل‌های پیش‌بینی میان‌مدت که به دوره‌های بین یک روز تا یک ماه و دوره‌های بلندمدت که به پیش‌بینی بار در دوره یک ماه و بیشتر می‌باشد، تقسیم‌بندی می‌شوند. [54] در تحقیقات گذشته سه نوع مدل ساختاری عنوان شده، در پیش‌بینی دوره‌های زمانی مختلف ارائه شده است؛ بنابراین وجه تمایز بین مدل‌های پیش‌بینی برای دوره‌های زمانی مختلف نه در ساختار آن بلکه در

DOI: 10.30503/nripress.2020.147:

پارامترهای ورودی به مدل می‌باشد. بدیهی است هرچقدر طول دوره‌های زمانی پیش‌بینی طولانی‌تر باشد، علاوه بر پارامترهای رایجی مانند دما و رطوبت، پارامترهایی با مفاهیم اقتصادی یا اجتماعی که در سیکل‌های بلندمدت‌تر تغییرات محسوس‌تری دارد نیز بر تقاضای بار الکتریکی اثرگذار می‌باشند. [55] با توجه به مسئله تعریف‌شده که برای پیش‌بینی‌های میان‌مدت و بلندمدت می‌باشد، می‌توان از پارامترهای به‌کاررفته در مقالات برای پیش‌بینی‌های میان‌مدت و بلندمدت استفاده کرد تا پیش‌بینی‌ها با دقت بالاتری صورت بگیرد. شکل ۱ نمای کلی از نحوه استفاده از دسته‌بندی پارامترهای مختلف در مدل‌ها را بر اساس دوره زمانی پیش‌بینی به نمایش می‌گذارد.



شکل ۲. دسته پارامترهای به‌کاررفته در مدل‌های پیش‌بینی بار

با توجه به اینکه در روند تحقیقات گذشته، قسمتی از ساختار مدل ارائه‌شده برای انتخاب بهترین پارامترهای ورودی در نظر گرفته شده است و روش‌های درنظرگرفته‌شده برای انتخاب پارامتر سبب افزایش دقت در پیش‌بینی‌ها می‌شود؛ بنابراین در روند تحقیقات ارائه‌شده دسته‌ای از مرتبط‌ترین پارامترها برای ورود به مدل پیشنهاد می‌گردد و سپس مدل با توجه به دارابودن مکانیزمی هوشمند، اقدام به انتخاب بهترین آن‌ها برای ورود به قسمت پردازش مدل می‌نماید. از جمله مدل‌هایی که دارای مکانیزمی برای انتخاب پارامتر می‌باشد می‌توان به مدل‌های Kim و همکاران [56] با استفاده از مکانیزم S2S[۲۵]، Dai و همکاران [57] با استفاده از روش MRMR[۲۶]، Ahmad و همکاران [58] از روش GKR-

[۲۵] *Sequence to sequence*

[۲۶] *Minimal redundancy maximal relevance*

DOI: 10.30503/nripress.2020.147:

RFE [۲۷]، Ghadimi و همکاران [59] از روش RNN[۲۸]، Yang و همکاران [60] از روش AFLSSVM-GWA [۲۹]، Suryanarayana و همکاران [61] از روش Regression اشاره کرد. در این تحقیق نیز از منطق تحقیقات گذشته الگوبرداری شده و با پیشنهاد روشی برای انتخاب پارامتر، بهترین آن‌ها برای ورود به قسمت پردازش که همان شبکه‌های عصبی در این تحقیق می‌باشد، استفاده خواهد شد. به‌طور کلی پارامترهای پیشنهادی در این مسئله را می‌توان در سه دسته کلی تقسیم‌بندی کرد: ۱– پارامترهای مربوط به شرایط آب‌وهوا؛ ۲– پارامترهای مرتبط به داده‌های سیکل‌های زمانی گذشته مصرف بار؛ ۳– پارامترهای مرتبط به داده‌های اقتصادی و اجتماعی کشور که در ذیل هریک از آن‌ها به‌تفکیک بررسی شده است:

۱-۱-۲- پارامترهای مربوط به شرایط آب‌وهوا

برق به‌عنوان یکی از فراگیرترین خدمات دولتی شناخته شده است. در شرایط فعلی صنعت برق بیش از ۲۶ میلیون مشترک خانگی دارد که سالانه حدود یک میلیون مشترک خانگی به آن اضافه می‌شود. طی سال‌های ۱۳۸۲ تا ۱۴۰۰ متوسط نرخ رشد سالانه تعداد مشترکین خانگی برابر با ۵,۱درصد بوده است و میزان رشد سالانه فروش انرژی برق به بخش خانگی طی همین دوره به‌میزان ۵,۴درصد افزایش یافته است. سهم بخش خانگی از فروش برق در سال ۱۳۹۳ برابر با ۳۲,۴ می‌باشد. [29] یکی از عوامل مهم و برون‌زای تأثیرگذار بر تقاضای برق، تغییرات دمای هوا می‌باشد؛ اگرچه تغییرات دمای هوا پیش‌بینی‌پذیر نیست؛ اما تغییرات ناگهانی آن همانند یک شوک بر مصرف برق تأثیرگذار خواهد بود؛ بنابراین در صورتی که گرمای هوا به‌صورت ناگهانی زیاد شود، شکاف بین عرضه و تقاضای برق افزایش می‌یابد و در این صورت تأمین برق بخشی از مشترکین با مشکل مواجه خواهد شد. به‌عبارتی دیگر تغییرات شدید در دمای آب‌وهوا باعث ایجاد نااطمینانی در تقاضا می‌گردد؛ بنابراین شناخت نوع و میزان رابطه بین مصرف برق و درجه‌حرارت برای مدیریت بخش تقاضای برق از اهمیت زیادی برخوردار است. نتایج تحقیقات محققانی مانند مدل Vaccaro و همکاران [62] در مدل D-LiSSA[۳۰]، Yin و همکاران [63] در مدل MTSS[۳۱]، Gao و همکاران [64] در مدل LSTNet [۳۲]، Eskandari و همکاران [65] در مدل CNNs [۳۳]، Gao و همکاران [66] در مدل SVM-

[۲۷] *Gaussian Kernel regression model with random feature expansion*

[۲۸] *Recurrent neural network*

[۲۹] *Autocorrelation Function Least Squares Support Vector Machines Grey Wolf Optimization Algorithm*

[۳۰] *deep autoencoder with localized stochastic sensitivity*

[۳۱] *Multi-temporal-spatial-scale*

[۳۲] *Long-and short-term time series network*

[۳۳] *Convolutional neural networks*

DOI: 10.30503/nripress.2020.147:

RFRM [۳۴]، Dong و همکاران [67] در مدل DDBN [۳۵]، Lin و همکاران [68] در مدل MNN-SARF[۳۶]، Hu و همکاران [69] در مدل MEA-RVLFN[۳۷] نشان می‌دهد بین دمای هوا و مصرف برق رابطه مستقیمی وجود دارد؛ به‌گونه‌ای که یک درصد در افزایش میانگین دمای ماهانه، باعث می‌شود مصرف برق به‌طور متوسط ۰,۳۷درصد افزایش یابد؛ بنابراین در این تحقیق نیز از پارامتر دمای آب‌وهوا به‌عنوان یکی از ورودی‌های مهم اثرگذار بر مصرف برق استفاده خواهد شد.

۲-۱-۲- پارامترهای مرتبط به داده‌های سیکل‌های زمانی گذشته مصرف بار

یک دسته از پارامترهایی که می‌توان از آن‌ها برای پیش‌بینی بار تقاضای بار الکتریکی استفاده کرد، داده‌های تاریخی بار تقاضای بار الکتریکی است؛ بنابراین می‌توان داده‌های هر دوره زمانی را با داده‌های بیشترین مصرف در روز یا بیشترین مصرف در شب و همچنین میزان مصرف در شب یا روز را با هم در نظر گرفت و بدین صورت با استفاده از الگوریتم‌های هوشمند به‌دنبال یافتن روابطی بین آن‌ها گشت و از رابطه به‌دست‌آمده برای پیش‌بینی مقادیر بار در آینده استفاده کرد. وجود مناسبت‌های مختلف سیاسی و اجتماعی یا انواع تعطیلات رسمی یا رویدادهایی که در روزهایی خاص از ایام سال اتفاق می‌افتد و نمی‌توان آن‌ها را به‌عنوان یک پارامتر با داده‌های کمی در مدل وارد کرد را از تأثیری که در مقدار بار الکتریکی در طول شب یا روز یا میزان ماکزیمم مصرف در روز یا شب می‌گذارد را در پیش‌بینی دوره‌های آتی استفاده نمود. در مرور مقالات گذشته می‌توان به مدل ASTLF [۳۸] توسط Bellahsen و همکاران [70]، SMN[۳۹] توسط Wu و همکاران [71]، FTS-BP[۴۰] توسط Li و همکاران [72]، TgDLF[۴۱] توسط Chen و همکاران [73]، DDM[۴۲] توسط Wang و همکاران [74]، AGRU[۴۳] توسط Wang و همکاران [75]،

[۳۴] *Support vector machine- random forest regression method*

[۳۵] *distributed deep belief networks*

[۳۶] *modified neural network with selected auto-regressive features*

[۳۷] *multimodal evolutionary algorithm and random vector functional link network-based ensemble learning*

[۳۸] *Aggregated short-term load forecasting*

[۳۹] *single multiplicative neuron model*

[۴۰] *Fuzzy time series back propagation*

[۴۱] *Theory-guided deep-learning for electrical load forecasting*

[۴۲] *adaptive decomposition method*

[۴۳] *Advantage of gated recurrent unit*

DOI: 10.30503/nripress.2020.147:

XGB-LGBM-MLP[۴۴] توسط Masoudi و همکاران [76]، LSTM-NN[۴۵] توسط Memarzadeh و همکاران [77] که از این دسته از پارامترها استفاده کرده است اشاره کرد که در آن‌ها از مقادیر پیک مصرف بار و یا مقادیر بار در دورهای متنوع گذشته استفاده شده است؛ لذا در این تحقیق نیز از داده‌های تاریخی بار استفاده خواهد شد.

۳-۱-۲- پارامترهای مرتبط به داده‌های اقتصادی و اجتماعی کشور

دستیابی به رشد چشمگیر اقتصادی کشورها به‌عنوان یکی از مهم‌ترین شاخص‌های کلان اقتصادی موضوعی است که همواره نظر اقتصاددانان و سیاست‌گذاران را به خود جلب کرده است. در این میان انرژی به‌عنوان یکی از مهم‌ترین عوامل تولید نقش مؤثری را در افزایش تولید داخلی ایفا می‌کند. رشد مصرف انرژی و میزان انرژی بری تولید در فرایند صنعتی‌شدن ابتدا دارای روند صعودی است و بعد از رسیدن به سطح معینی از توسعه نزولی خواهد بود این کاهش شدت انرژی عمدتاً به‌دلیل جایگزینی انرژی با سایر نهادهای تولید، بهبود فناوری، تغییر ترکیب انرژی از منابع باکیفیت مانند انرژی برق به‌جای منابع با کیفیت پایین‌تر و تغییر ترکیب کالاهای تولیدی می‌باشد. اقبال عمومی جهان به‌سمت انرژی‌های با کیفیت مرغوب‌تر مانند برق موجب رشد شایان توجهی در مصرف این‌گونه از انرژی‌ها شده است؛ چنانچه بر اساس آمارهای ارائه‌شده رشد مصرف انرژی برق تا سال ۲۰۳۰ به‌طور متوسط سالانه ۲٫۷درصد پیش‌بینی می‌شود. در این میان کشورهای صادرکننده نفت که جایگاه ویژه‌ای را در تأمین منابع انرژی در بازارهای داخلی و نیز بین‌المللی دارا هستند و به‌دلیل برخورداری از تنوع انرژی فراوان سعی دارند با جایگزینی منابع انرژی به‌طریقی مدیریت مصرف و تقاضا را اعمال نماید. در این میان انرژی‌های جایگزین، برق بیشترین تنوع مصرف را دارد و با کاهش هزینه در سرمایه‌گذاری صنایع باعث رشد و توسعه صنعتی می‌شود و به‌دلیل کارایی طبیعی و پاکی و نقل‌وانتقال آسان استفاده بیشتر از آن همواره شایسته توجه کشورها بوده است. [30] نقش انرژی برق در توسعه اقتصادی از آن جهت است که علاوه بر افزایش بهره‌وری عوامل تولید موجب بهبود سطح استانداردهای زندگی نیز خواهد شد مصرف سرانه برق در کشورهای صادرکننده نفت در حال توسعه بسیار پایین‌تر از مصرف سرانه کشورهای توسعه‌یافته یا متوسط سرانه مصرف جهان می‌باشد؛ ولی برای کشورهای خاورمیانه رشد متوسط مصرف سالانه مصرف برق طی دوره ۱۹۷۲ تا ۲۰۲۰ حدود ۳٫۱دهم می‌باشد که به‌مراتب بیشتر از متوسط همین رقم در کشورهای توسعه‌یافته است. روند روبه‌رشد مذکور به‌علت ورود کالاهای جدید الکتریکی و وابستگی بخش‌های مختلف انرژی از جمله حمل‌ونقل، صنعت و تا حدودی کشاورزی به این نوع از انرژی می‌باشد نتایج تجربی رابطه علی بلندمدت از رشد اقتصادی به‌سمت رشد مصرف برق را در این کشورها تأیید می‌کند. در واقع به‌دلیل کاربردهای فراوان برق در بخش‌های صنعتی، خانگی، کشاورزی، تجاری و حمل‌ونقل انتظار می‌رود که افزایش رشد اقتصادی و توسعه صنعتی در بلندمدت به رشد مصرف بیشتر برق منجر شود.

[۴۴] *Extreme Gradient Boosting machine -Light Gradient Boosting Machine- Multi-Layer Perceptron*

[۴۵] *Long short-term memory – Neural Network*

DOI: 10.30503/nripress.2020.147:

همچنین پارامترهای اجتماعی که مهم‌ترین آن‌ها جمعیت می‌باشد بر رشد مصرف برق در میان‌مدت و بلندمدت اثرگذار می‌باشد. این واقعیت در تحقیقات گذشته مانند LMB-NN[۴۶] توسط Ahmad و همکاران [78]، NPK-NNM[۴۷] توسط Ahmad و همکاران [79]،TB-GPR-MLR[۴۸] توسط Chen و همکاران [80] عنوان شده است. با توجه به نحوه ارتباط بین پارامترهای اقتصادی و اجتماعی و تقاضای برق، برای پیش‌بینی‌های میان‌مدت و بلندمدت لازم است از این دسته از پارامترها نیز استفاده کرد؛ لذا در این مدل از پارامتر تولید ناخالص ملی و جمعیت به‌عنوان پارامترهای تأثیرگذار در مصرف برق برای پیش‌بینی استفاده شده است. جدول ۱ پارامترهای مختلف ورودی به مدل پیشنهاددادهشده را در تحقیقات عنوان‌شده برای پیش‌بینی متغیر تقاضای بار الکتریکی به نمایش گذاشته است.

جدول۲. پارامترهای مختلف ورودی به مدل پیشنهاددادهشده در تحقیقات گذشته

ردیف	مدل	دمای هوا	رطوبت	سرعت باد	تولید ناخالص ملی	جمعیت	قیمت برق	داده‌های تاریخی بار
۱	S2S [4]	✓						
۲	MRMR [5]	✓					✓	✓
۳	GKR-RFE [6]	✓	✓	✓				
۴	RNN [7]	✓						✓
۵	AFLSSVM-GWA [8]	✓						✓
6	Regression [9]	✓	✓					✓
7	D-LiSSA [10]	✓	✓					✓

[۴۶] *Levenberg–Marquardt backpropagation neural network*

[۴۷] *non-parametric based k-Neural Network*

[۴۸] *tree bagger-Gaussian process regression- multiple linear regression*

DOI: 10.30503/nripress.2020.147:

✓							MTSS [11]	8
✓	✓					✓	LSTNet [12]	9
✓	✓					✓	CNNs [13]	10
	✓					✓	SVM-RFRM [14]	11
		✓	✓		✓	✓	DDBN [15]	12
✓	✓					✓	MNN-SARF [16]	13
✓	✓				✓	✓	MEA-RVLFN [17]	14
					✓	✓	ASTLF [18]	15
		✓	✓			✓	SMN [19]	16
✓		✓	✓			✓	FTS-BP [20]	17
✓		✓			✓	✓	TgDLF [21]	18
✓	✓	✓				✓	DDM [22]	19
	✓		✓				AGRU [23]	20

DOI: 10.30503/nripress.2020.147:

21	XGB-LGBM-MLP [24]	✓						✓
22	LSTM-NN [25]	✓	✓					
23	LMB-NN [26]	✓	✓				✓	
24	NPK-NNM [27]				✓	✓		
25	TB-GPR-MLR [28]	✓			✓			

۲-۲- پایگاه داده‌های به‌کاررفته در تحقیق

در این تحقیق از سه پایگاه داده‌ای استفاده شده است. داده‌های مرتبط با شرایط آب‌وهوا و همچنین داده‌های تاریخی مصرف بار از پایگاه داده‌های مصرف برق موجود در پژوهشگاه نیرو استخراج شده است. همچنین برای داده‌های اقتصادی و اجتماعی از پایگاه داده‌های مرکز آمار ایران به نشانی https://www.amar.org.ir و از پایگاه داده‌های بانک مرکزی ایران به نشانی https://www.cbi.ir استفاده شده است.

۲-۳- پیش‌پردازش داده‌ها

شروع هر نوع کار و عملیاتی در مرحله اول، دارای یک سری مقدمات و پیش‌نیازها است. استفاده از داده‌ها نیز از این قانون مستثنا نبوده و نیازمند آماده‌سازی و پردازش‌های مقدماتی است. در علم داده‌کاوی، تمامی داده‌هایی که برای هدف مدنظر استفاده خواهند شد، باید پیش از شروع پردازش با استفاده از روش‌هایی، آماده و تنظیم و یا به‌اصطلاح پیش‌پردازش (Preprocess) شوند. مرحله آماده‌سازی داده‌ها قبل از پردازش را، پیش‌پردازش (Preprocessing) می‌گویند. پیش‌پردازش نقشی اساسی در روند پردازش داده‌ها و نتایج حاصل از آن‌ها ایفا می‌کند. برای پیش‌پردازش داده‌ها مراحل و ابزارهای مختلفی وجود دارند. برخی از مهم‌ترین مواردی که طی فرایند پیش‌پردازش داده‌ها باید به آن‌ها پرداخته شود، در ادامه بیان شده‌اند.

DOI: 10.30503/nripress.2020.147:

۱-۳-۲- پیش‌پردازش داده‌ها: داده‌های ناموجود

در برخی مدل ها ، ممکن است بعضی از ویژگی‌های مربوط به یک یا چند نمونه، فاقد مقادیر معتبر باشند. این امر می‌تواند دلایل مختلفی داشته باشد، از جمله نویزی (Noise) بودن داده‌های ثبت‌شده، عدم ثبت یا نامعتبربودن مقدار آن. این داده‌ها را داده‌های ناموجود (Missing Data or Null Data) داده‌های گم‌شده، می‌نامند. برای پردازش مجموعه‌داده‌هایی که دچار چالش داده ناموجود هستند، باید راهکاری برای تعیین مقادیر داده‌های ناموجود یافت. روش‌های گوناگونی برای مدیریت داده‌های ناموجود وجود دارند که در ذیل به چند نمونه از آن‌ها اشاره شده است.

- **حذف نمونه:**در این روش، تمام نمونه‌هایی (Sample) که دارای مقدار ویژگی ناموجود هستند، به‌کلی از مجموعه‌داده حذف شده و در روند پردازش استفاده نمی‌شوند. این روش بیشتر در مواردی به کار می‌رود که تعداد نمونه‌های موجود، بسیار زیاد است یا ویژگی جاافتاده، مربوط به برچسب دسته است؛ اما در حالت کلی، این روش به‌دلیل حذف داده‌های موجود، روش مناسبی نبوده و زیاد استفاده نمی‌شود.
- **پرکردن دستی:**در این روش، مقادیری که هنگام آماده‌سازی مجموعه‌داده، جا افتاده یا نادرست ثبت شده‌اند، به‌صورت دستی پر می‌شوند. این روش زمانی امکان‌پذیر است که منبع جمع‌آوری داده‌ها در دسترس باشد؛ در عین حال، به‌دلیل زمان‌گیربودن این راهکار، در مواقعی که سایز مجموعه‌داده بزرگ است یا تعداد داده‌های مفقود زیاد هستند، مقرون‌به‌صرفه نبوده و عملاً استفاده از این روش ناممکن است.
- **استفاده از یک مقدار ثابت:** در این روش تمام مقادیر ناموجود در مجموعه‌داده، با یک مقدار ثابت و ازپیش‌تعیین‌شده پر می‌شوند. این روش از دقت بالایی برخوردار نیست؛ به‌ویژه اگر تعداد داده‌های ناموجود زیاد باشد، ممکن است این مقدار ثابت جای‌گذاری‌شده، اطلاعات معنادار اشتباهی را به داده‌ها اضافه کند که در روند پردازش تأثیرگذار باشد؛ مثلاً اگر تعداد زیادی از داده‌های مربوط به یک ویژگی (Feature)، در مجموعه‌داده ناموجود باشند، ثبت یک مقدار ثابت برای تمامی نمونه‌هایی که مقدارشان موجود نیست، می‌تواند در روند یک پردازش، دسته‌بند را دچار اشتباه کند.
- **استفاده از مقدار میانگین ویژگی:**در این روش برای هر ویژگی، مقدار میانگین، با استفاده از نمونه‌هایی که مقادیرشان معلوم است محاسبه شده و برای جای‌گذاری مقادیر مربوط به آن ویژگی به کار می‌رود.
- **استفاده از مقدار میانگین ویژگی به‌تفکیک دسته:**این روش مشابه روش قبلی است، با این تفاوت که مقدار میانگین، برای نمونه‌های هر دسته، به‌صورت جداگانه محاسبه می‌شود. میانگین‌های به‌دست‌آمده برای هر دسته، جهت پرکردن داده‌های ناموجود نمونه‌های متعلق به همان دسته استفاده می‌شوند. این روش در مقایسه با روش قبلی کارایی بیشتری دارد.

DOI: 10.30503/nripress.2020.147:

- **استفاده از محتمل‌ترین مقدار:** اساس این روش فراوانی مقادیر موجود در هر ویژگی است. در این روش، فراوانی مقادیر ظاهرشده در هر ویژگی به دست می‌آیند و مقداری که بیشترین فراوانی را در بین مقادیر دارد به‌عنوان مقدار جایگزین انتخاب می‌شود. این مقدار منتخب، جایگزین داده‌های مفقود در آن ویژگی می‌شود.
- **طراحی پیش‌بینی‌کننده:** بهترین و دقیق‌ترین روش برای پرکردن داده‌های ناموجود در یک مجموعه‌داده، طراحی یک پیش‌بینی‌کننده است. در این روش یک پیش‌بینی‌کننده، متناسب با ماهیت داده‌ها انتخاب و طراحی می‌شود تا مقادیر داده‌های گمشده مربوط به یک ویژگی را بر اساس سایر ویژگی‌ها تخمین بزند.

۲-۳-۲- پیش‌پردازش داده‌ها: تحلیل داده‌های پرت

در برخی مدل ها ، ممکن است به‌دلایلی، مقادیری در مجموعه‌داده ظاهر شوند که تفاوت زیاد و نامعمولی با سایر مقادیر موجود در مجموعه داشته باشند، این داده‌ها را داده‌های پرت می‌گویند. در واقع منظور از داده‌های پرت، داده‌ها یا نمونه‌هایی هستند که با رفتار کلی یا مدل مجموعه کل داده‌ها شباهت نداشته و از آن تبعیت نمی‌کنند؛ به‌عنوان مثال در مجموعه‌داده مربوط به قد افراد مؤنث که بازه قدی آن‌ها بین ۱۵۰ تا ۱۷۵ سانتی‌متر است، قد ۲۰۵ سانتی‌متر، یک داده پرت محسوب می‌شود. آنالیز و مدیریت داده‌های پرت یکی از مهم‌ترین مراحل پیش‌پردازش داده‌ها محسوب می‌شود؛ زیرا این داده‌ها می‌توانند عملکرد الگوریتم‌ها و دسته‌بندهای (Classifier) به‌کاررفته را دچار مشکل کنند؛ بنابراین بایستی تا حد ممکن، تأثیر داده‌های پرت را کاهش داد. روش‌های مختلفی برای شناسایی و مدیریت این داده‌ها وجود دارد که در ادامه به چند روش ساده اشاره شده است.

- **حذف:** ساده‌ترین روش مدیریت داده‌های پرت، حذف آن‌ها است. برای این منظور ابتدا لازم است داده‌های پرت شناسایی شوند. روش متداولی که استفاده می‌شود، به این صورت است که ابتدا بازه‌ای را که داده‌ها در آن قرار دارند مشخص می‌کنند؛ سپس تعداد معینی از داده‌های بالا و پایین این بازه را به‌عنوان داده پرت در نظر گرفته و آن‌ها را از مجموعه‌داده حذف می‌کنند.
- **جای‌گذاری با میانگین:** یک روش دیگر که در مقایسه با روش قبلی دقت مناسب‌تری دارد، استفاده از مقدار میانگین داده‌ها است. در این روش، عمل مشخص‌کردن داده‌های پرت به‌روشی که در بالا ذکر شد، بر اساس بازه داده‌ها مشخص می‌شود؛ اما تفاوتی که با روش قبلی دارد این است که به‌جای حذف داده‌های پرت، مقدار میانگین مربوط به داده‌های غیرپرت را به دست آورده و آن را جایگزین داده‌های پرت می‌کند. با این کار تمامی داده‌ها در یک بازه مشخص و معقول قرار می‌گیرند؛ البته این روش، مشکل (سوگیری) (Bias) در داده‌ها را به دنبال دارد.

۲-۴- نرمال‌سازی داده‌ها

DOI: 10.30503/nripress.2020.147:

نرمال‌سازی داده‌ها از جمله مهم‌ترین مراحل پیش‌پردازش در علم داده‌کاوی است. در توضیح اهمیت نرمال‌سازی، تصور کنید بازه مربوط به مقادیر دو ویژگی، تفاوت عمده‌ای نسبت به یکدیگر داشته باشند؛ به‌عنوان مثال فرض کنید بازه مربوط به یکی از ویژگی‌ها بازه [۱ , ۰] و بازه مربوط به ویژگی دیگری از همین مجموعه‌داده، [۵۰۰ , ۱] باشد، در چنین شرایطی واضح است که هنگام استفاده از معیارهایی که مبتنی بر فاصله هستند، ویژگی با بازه کوچک‌تر عملاً تأثیر محسوسی در محاسبات نخواهد داشت. با توجه به این توضیحات، برای دستیابی به نتایج دقیق‌تر، لازم است که بازه مربوط به ویژگی‌های مختلف، به‌نحوی با یکدیگر یکسان یا نزدیک شوند. برای این منظور از روش‌های نرمال‌سازی استفاده می‌شود. روش‌های مختلفی برای نرمال‌سازی وجود دارد که در مقالات و تحقیقات استفاده می‌شود. در ادامه به چند نمونه از متداول‌ترین روش‌های نرمال‌سازی اشاره شده است.

۲-۴-۱- نرمال‌سازی مین-ماکس (Min-Max)

در این روش ساده، هر مجموعه‌ای از داده‌ها به بازه‌ای دل‌خواه که کمترین و بیشترین مقدار آن از قبل مشخص است نگاشت می‌شود. در این روش می‌توان هر بازه دل‌خواه را تنها با یک تبدیل ساده، به بازه‌ای جدید نگاشت کرد. فرض کنید قرار است ویژگی ، از مجموعه‌داده که در بازه بین min_A تا max_A قرار دارد، به بازه جدید new_Min تا new_Max نگاشت شود. برای این منظور، هر مقدار اولیه مانند v در بازه اولیه، طبق رابطه زیر به‌مقدار جدید v' در بازه جدید تبدیل خواهد شد:

$$v' = (v - min_A)\frac{new\ Max - new\ Min}{Max\ A - Min\ A} + (new\ Min) \qquad (1)$$

۲-۴-۲- نرمال‌سازی نمره زد (Z-Score)

یکی دیگر از پرکاربردترین و مهم‌ترین روش‌های نرمال‌سازی روش نمره زد (Z-Score) است. پایه این روش برخلاف روش مین-ماکس، بر اساس میانگین و انحراف معیار داده‌ها است. ویژگی A را در نظر بگیرید، فرض کنیدm ، میانگین داده‌ها و σ نشانگر انحراف معیار آن‌ها است. با این مفروضات، مقادیر جدید برای این مجموعه‌داده، بر اساس مقدار میانگین و انحراف معیار، با استفاده از رابطه زیر محاسبه می‌شوند:

$$v' = \frac{v - M}{\sigma} \qquad (2)$$

شایان توجه است که فارغ از بازه اولیه مجموعه‌داده در دستِ بررسی، مقدار میانگین داده‌های حاصل از نرمال‌سازی به‌روش Z-Scor ، همواره برابر با صفر و انحراف معیار آن‌ها عدد یک خواهد بود.

۲-۴-۳- مقیاس‌گذاری اعشاری (Decimal Scaling)

DOI: 10.30503/nripress.2020.147:

مقیاس‌گذاری اعشاری نوع دیگری از روش‌های نرمال‌سازی است که در واقع منطق آن تغییر نقطه اعشار مقادیر موجود در مجموعه‌داده است. در این روش، نرمال‌سازی با استفاده از رابطه زیر انجام می‌شود:

$$v' = \frac{v}{10^j} \qquad (3)$$

که در آن، j برابر با کوچک‌ترین مقداری است که شرط زیر را فراهم کند:

$$max(|v'|) < 1 \qquad (4)$$

در روابط بالا، مشخص می‌شود که مقدار j ، کاملاً بستگی به کران‌های مربوط به بازه مجموعه‌داده اولیه دارد؛ به‌عنوان مثال اگر بازه مربوط به مقادیر یک ویژگی از مجموعه‌داده‌ها، [۹۷ , ۹۸۶-] باشد، با توجه به اینکه بزرگ‌ترین مقدار قدر مطلق این بازه، ۹۸۶ است، کوچک‌ترین مقدار j که این عدد را به اعشار کمتر از یک ببرد، ۳ است؛ بنابراین بر اساس رابطه‌ای که در بالا ارائه شد، با تقسیم تمام مقادیر اولیه به ۱۰۳، بازه داده‌های جدید، [۰/۰۹۷ , ۰/۹۸۶-] خواهد بود.

روش‌های ارائه‌شده در بالا، از مهم‌ترین مراحل پیش‌پردازش داده‌ها هستند که علاوه بر اینکه به‌عنوان مرحله‌ای مهم از مراحل داده‌کاوی و به‌منظور افزایش دقت نتایج، استفاده می‌شوند. در این تحقیق نیز از روش‌های استاندارد بالا برای پیش‌پردازش داده‌های استفاده‌شده است. این عملیات کمک خواهد کرد عملکرد مدل در هنگام تجزیه‌وتحلیل با دقت بیشتری صورت پذیرد.

۵-۲- جدول نهایی پارامترها و متغیرها

با توجه به توضیحات بخش‌های قبل، هدف از این تحقیق ارائه مدلی برای پیش‌بینی مقدار تقاضای بار الکتریکی می‌باشد؛ بنابراین تنها متغیر این مسئله متغیر تقاضای بار الکتریکی (۲۴ ساعت شبانه‌روز) ماه آینده است که به‌صورت میان‌مدت پیش‌بینی می‌گردد. پارامترهای ورودی مسئله که داده‌های تاریخی آن‌ها از پایگاه‌های داده مطرح‌شده در بخش ۳ استخراج می‌شود شامل، دمای هوا، جمعیت، تولید ناخالص ملی، داده‌های تاریخی مصرف بار الکتریکی ۲۴ ساعت شبانه‌روز در دوره‌های گذشته می‌باشد. این داده‌ها برای بازه سال‌های ۱۳۸۲ الی ۱۳۹۵ استخراج شده و در یک پایگاه داده‌ای جامع جهت ورودی به مدل استفاده می‌شود. جدول ۲ بخشی از داده‌های ورودی به مدل را به نمایش گذاشته است.

DOI: 10.30503/nripress.2020.147:

جدول ۳. پارامترها و متغیر معرفی‌شده برای تحقیق

دوره	تاریخ	مقدار بار الکتریکی مصرفی ۲۴ ساعت گذشته (مگاوات)	دمای هوا ℃	جمعیت (نفر)	تولید ناخالص ملی (ریال)
۱	۱۳۸۲/۰۱/۰۱	۸۲۳۶,۲	9	۲۳۵۳۳۳۵	۱۲۱۶۹
۲	1382/01/02	۷۳۷۲,۹	10.6	۲۳۵۳۳۳۵	۱۲۱۶۹
۳	1382/01/03	۸۲۷۶,۸	10.4	۲۳۵۳۳۳۵	۱۲۱۶۹
...	...	...	...	...	...
۱۲۷۳	1395/01/30	۱۴۲۳۲,۹	21.2	2560000	127026.7
۱۲۷۴	1395/01/31	۱۴۵۳۷	24	2560000	127026.7

۶-۲- نتیجه‌گیری

با توجه به موضوع تحقیق و با توجه به اینکه مدل در دستِ تحقیق برای پیش‌بینی‌های میان‌مدت و بلندمدت استفاده خواهد شد و با توجه به روند تحقیقات گذشته که در مقالات ارائه‌شده منعکس شده است، در این تحقیق نیز از ترکیبی از مدل‌های منعکس‌کننده شرایط آب‌وهوایی، پارامترهای دوره‌های گذشته مصرف بار و همچنین متغیرهای اقتصادی و اجتماعی انتخاب و استفاده خواهد شد. در این خصوص از پایگاه داده‌های برق موجود در پژوهشگاه و همچنین پایگاه داده‌های بانک مرکزی و مرکز آمار استفاده شده است. مشکلات موجود در داده‌های خام قبل از استفاده با به‌کارگیری روش‌های پیش‌پردازش داده‌ها جهت استفاده نهایی اصلاح گردید. متغیری که در این تحقیق پیش‌بینی خواهد شد، متغیر تقاضای بار الکتریکی (۲۴ ساعت شبانه‌روز) ماه آینده است. این متغیر که موضوع عمده تحقیقات صورت‌گرفته در حوزه برنامه‌ریزی انرژی است، زمینه را برای برنامه‌ریزی دقیق زنجیره شبکه برق ایجاد خواهد کرد. پارامترهای به‌کاررفته در این تحقیق شامل دمای هوا، جمعیت، تولید ناخالص ملی، داده‌های تاریخی مصرف بار

DOI: 10.30503/nripress.2020.147:

الکتریکی ۲۴ ساعت شبانه‌روز در دوره‌های گذشته می‌باشد. در ادامه تحقیقات اجزای مدل تعریف شده و هریک از این اجزا تشریح خواهد شد. بعد از تعریف مدل، از پارامترها و متغیر تعریف‌شده برای اجرای مدل استفاده خواهد شد.

DOI: 10.30503/nripress.2020.147:

فصل سوم

ساختار و اجزای مدل پیشنهادی

DOI: 10.30503/nripress.2020.147:

مقدمه

در فصل اول به تبیین اهداف، ضرورت‌ها و نیازهای موجود در زنجیره تأمین برق اشاره شد و عنوان گردید که اگر بخواهیم این زنجیره را به‌شکل صحیح برنامه‌ریزی و مدیریت نماییم باید متغیرهای مهم و تأثیرگذار بر آن را با بالاترین دقت پیش‌بینی نماییم. پیش‌بینی با دقت بالا متغیرها و به‌تبع آن برنامه‌ریزی بسیار دقیق این شبکه می‌تواند از تولید بار مازاد در شبکه یا کمبود بار در آن و در نتیجه هزینه‌های گزاف تحمیلی بر آن جلوگیری نماید. پیش‌بینی تقاضای بار الکتریکی به‌عنوان یکی از مهم‌ترین متغیرهای لازم برای برنامه‌ریزی شبکه می‌باشد. به همین دلیل تحقیقات متعددی در جهت طراحی مدل‌هایی برای پیش‌بینی آن صورت گرفته است. در این میان، مجموعه‌ای از مدل‌هایی با هدف پیش‌بینی در بازه زمانی هفته، ماه و سال طراحی شده است که به مدل‌های پیش‌بینی تقاضای بار الکتریکی میان‌مدت و بلندمدت مشهور می‌باشند. در این مدل‌ها علاوه بر درنظرگرفتن پارامترهایی مانند دما یا رطوبت، پارامترهای کلان‌تر مانند جمعیت، تولید ناخالص ملی و غیره نیز در پیش‌بینی‌ها در نظر گرفته شده و از داده‌های تاریخی آن‌ها برای افزایش دقت پیش‌بینی‌ها و یافتن روابط غیرخطی میان پارامترها استفاده می‌شود. به‌دلیل اینکه سری‌های زمانی تقاضای بار و نحوه ارتباط آن‌ها با پارامترهای ورودی از روابط معمولاً پیچیده و غیرخطی تبعیت می‌کند، لازم است الگوریتم‌های فراابتکاری و مدل‌های مبتنی بر یادگیری ماشین برای شناخت روابط بین داده‌ها و پیش‌بینی دقیق‌تر استفاده کرد.

در فصل دوم ابتدا به مرور ادبیات مرتبط با انتخاب پارامترهای ورودی به مدل‌های پیش‌بینی تقاضای بار الکتریکی پرداخته شد و بر اساس تحقیقات گذشته، دسته‌بندی برای آن‌ها پیشنهاد داده شده و نحوه ارتباط آن‌ها با دوره‌های زمانی پیش‌بینی شرح داده شد؛ سپس پایگاه داده‌های استفاده‌شده در این تحقیق معرفی گردید. بعد از آن روش‌های به‌کاررفته برای پیش‌پردازش داده‌ها معرفی و جدول نهایی پارامترها و متغیر و جدول مربوطه معرفی شد.

در این فصل ساختار مدل هدف بررسی خواهد شد. بدین منظور ابتدا هریک از اجزای به‌کاررفته در مدل ترکیبی به‌طور کامل تشریح و مزیت هریک از این اجزا به‌طور کامل بررسی خواهد شد؛ سپس این اجزا با هم ترکیب شده و مدل ترکیبی نهایی را ایجاد می‌نماید.

۱-۳- مدل‌های موجود

یکی از مهم‌ترین مباحث انرژی، برنامه‌ریزی زنجیره تولید و توزیع برق می‌باشد. با مدیریت صحیح این زنجیره، از تولید مقدار مازاد برق یا کمبود تولید آن در طول زنجیره برق جلوگیری می‌شود و در نتیجه هزینه‌های سنگین تحمیلی در اثر کمبود یا تولید مازاد برق را به حداقل می‌رساند. [81] یکی از متغیرهای مهم در برنامه‌ریزی شبکه برق، متغیر

DOI: 10.30503/nripress.2020.147:

تقاضای بار الکتریکی می‌باشد. هرقدر دقت در پیش‌بینی این متغیر افزایش پیدا کند، برنامه‌ریزی این شبکه در بازه‌های زمانی بسیار کوتاه‌مدت تا دوره‌های بلندمدت با دقت بیشتری انجام خواهد گرفت. [82] در زمینهٔ پیش‌بینی متغیر تقاضای بار الکتریکی، مدل‌های متنوعی ارائه شده است تا بتواند میزان تقاضای بار الکتریکی را با بیشترین دقت پیش‌بینی نماید. از حیث دوره زمان پیش‌بینی، پیش‌بینی تقاضای بار الکتریکی به دوره‌های خیلی کوتاه‌مدت، کوتاه‌مدت، میان‌مدت و بلندمدت تقسیم‌بندی می‌شود. [83] در پیش‌بینی دوره‌های میان‌مدت و بلندمدت که پیش‌بینی یک ماه و دوره‌های بلندمدت‌تر را شامل می‌شود، علاوه بر متغیرهایی مانند دما و رطوبت، متغیرهای اقتصادی و اجتماعی که در دوره‌های میان‌مدت و بلندمدت دارای تغییرات ملموس می‌باشد و این تغییرات بر میزان تقاضای بار الکتریکی نیز اثرگذار می‌باشد نیز استفاده می‌شود. [84] مدل‌های پیش‌بینی تقاضای بار الکتریکی به سه دسته کلی تقسیم‌بندی می‌شود. [85] مدل‌های مبتنی بر روش‌های آماری مانند مدل Auto Regression Integrated Moving Average (ARIMA) [86]، Autoregressive–moving-average model with exogenous inputs model (ARMAX) [87]،Linear Regression (LR) [88]، Single exponential (SE) [89]، High pass filter model with Auto Regression (HPF+AR(1)) [90]، Seasonal Auto Regression Integrated Moving Average (SARIMA) [91]، Fourier Seasonal SARIMA (F-S-SARIMA) [92]، excursive exogenous autoregressive moving average Generalized Autoregressive Conditional Heteroscedasticity (ARMAX–GARCH) [93]، Wavelet–GARCH–ARIMA [94]، Gray Model with ARIMA (GM-ARIMA) [95]، ARMA–GARCH-in-mean [96] می‌باشد که این مدل‌ها در مواجه با سیگنال‌های غیرخطی عملکرد ضعیفی دارند و قادر به شناسایی روابط پیچیده بین پارامترها و متغیر نمی‌باشند. دسته دوم مدل‌های غیرخطی می‌باشد که عملکرد بالاتری را در مواجه با انواع سیگنال‌های غیرخطی دارند از آن جمله می‌توان به مدل Power load forecasting using support vector machine and ant colony optimization(SVM-ACO) [97]، Bees Algorithm and Artificial Neural Network (BA-ANN) [98]، support vector regression with chaotic artificial bee colony algorithm (SVM-CABCA) [99]، support vector regression with differential evolution algorithm (SVM-DEA) [100]، Particle Swarm Optimization and Genetic Algorithm optimal Energy Demand Estimating (PSO–GA) [101]، Support vector machines with simulated annealing algorithms (SVM-SAN) [102]، Wavelet Particle Swarm Optimization Neural Network Simulation Optimization (Wavelet-PSO-NNs-SO) [103]، chaotic gravitational search algorithm (CGSA) [104]، Shared Subscribe Hyper Simulation Optimization (SUBHSO)[105]، اشاره کرد. این دسته از مدل‌ها به‌دلیل گیرافتادن در بهینه‌های محلی و همچنین overfitting نمی‌توانند بالاترین دقت را در پیش‌بینی‌ها حاصل نمایند. دسته سوم مدل‌های ترکیبی می‌باشد. این مدل‌ها بر مشکل روش‌های غیرخطی در گیرافتادن در بهینه محلی و همچنین over fitting غلبه می‌کنند و دقت بالاتری را نسبت به مدل‌های غیرخطی دارند [106]. در این دسته از

DOI: 10.30503/nripress.2020.147:

مدل‌ها، از ترکیب مدل‌های خطی و غیرخطی با مکانیزمی برای تجزیه سیگنال ورودی استفاده می‌شود. از آن جمله می‌توان به مدل Empirical mode decomposition Minimal Redundancy maximal fruit fly optimization general regression neural network (EMD-mRMR-FOA-GRNN) [107]، Wavelet Empirical mode decomposition Improved Grasshopper Optimisation Algorithm Neural Network and ARIMA (EMD-IGOA-ARIMA-NN) [108]، ARIMA-ANN- multiple linear regression (MLR) (ARIMA-ANN-MLR) [109]، Improved EMD ARIMA-Neural Network Fruit Fly Optimization (ARIMA-NNFOA-IEMD) [110] اشاره کرد. در این تحقیق روند توسعه مدل‌های ترکیبی دنبال شده است؛ با این تفاوت که به‌جای استفاده از دو روش آماری و غیرخطی به‌صورت موازی، از دو روش غیرخطی مبتنی بر شبکه عصبی به‌صورت موازی استفاده شده است. همچنین برای انتخاب بهترین تعداد سطوح تجزیه‌شده سیگنال توسط روش EMD و همچنین نحوه تخصیص سیگنال‌های تجزیه‌شده به دو شبکه عصبی از روش WOA استفاده شده است؛ بنابراین سیگنال ورودی توسط روش EMD تجزیه شده و پس از انتخاب بهترین پارامترها توسط روش PCA، داده‌ها توسط دو شبکه عصبی تحلیل می‌شود که یکی از آن‌ها شبکه عصبی BNN است که سیگنال تقاضای بار توسط تبدیل موجک Daubechies of order5 تجزیه شده است و اوزان آن توسط روش EHO بهینه‌سازی شده است (WTBNN-EHO) و دیگری شبکه عصبی LSTM است که می‌تواند داده‌ها را با توجه به حافظه خود به‌صورت موازی تحلیل کند؛ در نتیجه در این مقاله مدل هدف، ترکیبی از مدل‌های EMD، PCA، LSTM، WTBPNN-EHO و WOA می‌باشد. برای بررسی عملکرد این مدل، از داده‌های تاریخی مصرف بار الکتریکی و ۵ پارامتر مرتبط ذخیره‌شده در پایگاه شرکت مدیریت برق ایران در فاز بعدی استفاده خواهد شد.

۲-۳- اجزای مدل

۳-۲-۱- EMD

برای اینکه بتوانیم اطلاعات زمان-فرکانسی سیگنال را به دست آوریم، نیازمند روشی هستیم که بتواند مودهای ذاتی نهفته در سیگنال را استخراج کند. روش EMD بدین منظور ارائه شده است. در واقع روش EMD مشخص می‌کند در هر لحظه، کدام فرکانس و با چه شدتی در یک سیگنال موجود است. از این روش برای تجزیه سیگنال‌ها با هدف ازبین‌بردن اختلاط سیگنال‌ها و افزایش دقت پیش‌بینی‌ها استفاده می‌کنند. [111] در این روش مفهوم Intrinsic Mode Function (IMF) به‌صورت ذیل تعریف می‌گردد:

a) در یک سیگنال ورودی، تعداد اکسترمم‌ها برابر با تعداد نقاط صفر آن باشد یا نهایتاً به‌تعداد یک واحد متفاوت باشد.

b) انتگرال سیگنال مدنظر در بازه زمانی تعریف‌شده برابر با صفر باشد.

DOI: 10.30503/nripress.2020.147:

به‌طور خلاصه روش EMD شامل مراحل ذیل است. تشریح کامل این روش در رفرنس [112] آمده است.

۱. تعیین نقاط ماکزیمم و مینیمم محلی سیگنال ورودی؛

۲. ایجاد منحنی پوش بالا از طریق منحنی درجه ۳ بر نقاط ماکزیمم محلی؛

۳. ایجاد منحنی پوش پایین از طریق منحنی درجه ۳ بر نقاط مینیمم محلی؛

۴. میانگین‌گیری از منحنی‌های پوش بالا و پایین؛

۵. تفریق میانگین پوش بالا و پایین از سیگنال ورودی که رابطه آن در معادله 1 آمده است؛

$$h_1(x) = y_t - m_1(t) \qquad (1)$$

۶. بررسی شرط IMFبودن و معیار توقف که به‌صورت معادله 2 تعریف می‌شود؛

$$D_k = \frac{\sum_{t=0}^{T}\left|h_1^{k-1}(t) - h_1^{k}(t)\right|^2}{\sum_{t=0}^{T}\left|h_1^{k-1}(t)\right|^2} \quad (2)$$

۷. در صورت برقرارنشدن معادله 2، جای‌گذاری سیگنال حاصل از مرحله چهارم به‌جای سیگنال اصلی و ادامه فرایند از مرحله اول؛

۸. اگر معادله ۲ برقرار باشد، فرایند غربال پایان یافته و $c_1 = h_1^k(x)$ به‌عنوان اولین IMF در نظر گرفته می‌شود که در واقع مؤلفه سطح بالا سیگنال x(t) است؛

۹. باقی‌مانده به‌صورت $r_1 = y_t - c_1^k$ تعریف شده است و اگر خود شرط IMFبودن را ارضا کند، یک IMF محسوب می‌شود و در غیر این صورت اگر شرط a را داشته باشد، به‌عنوان سیگنال اولیه فرض شده و گام‌های ۱ الی ۴ تکرار می‌گردد تا IMF بعدی به دست آید.؛ اگر شرط a را نداشته باشد، به‌عنوان باقی‌مانده در نظر گرفته می‌شود؛ بنابراین سیگنال y(t) به‌صورت معادله 3 تعریف می‌گردد.

$$y_t = \sum_{n=1}^{N} h_n + r \quad (3)$$

PCA -۳-۲-۲

DOI: 10.30503/nripress.2020.147:

تحلیل مؤلفه‌های اصلی در تعریف ریاضی یک تبدیل خطی متعامد است که داده را به دستگاه مختصات جدید می‌برد؛ به‌طوری‌که بزرگ‌ترین واریانس داده بر روی اولین محور مختصات، دومین بزرگ‌ترین واریانس بر روی دومین محور مختصات قرار می‌گیرد و همین طور برای بقیه. تحلیل مؤلفه‌های اصلی می‌تواند برای کاهش ابعاد داده استفاده شود، به این ترتیب مؤلفه‌هایی از مجموعه‌داده را که بیشترین تأثیر در واریانس را دارند حفظ می‌کند. تحلیل مؤلفه اساسی همیشه روی ماتریس کوواریانس یا همبستگی اعمال می‌شود. [113]

برای ماتریس داده X^T با میانگین تجربی صفر که هر سطر یک مجموعه مشاهده و هر ستون داده‌های مربوط به یک شاخصه است، تحلیل مؤلفه‌های اصلی به‌صورت زیر تعریف می‌شود:

$$Y^T = X^T\ W = V\sum \quad (4)$$

که در آن $V\sum W^T$ تجزیه مقدارهای منفرد ماتریس X^T می‌باشد.

بر اساس تعریف ارائه‌شده از تحلیل مؤلفه‌های اصلی، هدف از این تحلیل انتقال مجموعه‌داده X با ابعاد M به داده Y با ابعاد L است؛ بنابراین فرض بر این است که ماتریس X از بردارهای $X_1.\cdots.X_N$ تشکیل شده است که هرکدام به‌صورت ستونی در ماتریس قرار داده شده است؛ بنابراین با توجه به ابعاد بردارها (M) ماتریس داده‌ها به‌صورت $M \times N$ است. نتیجه میانگین تجربی، برداری است که به‌صورت زیر به دست می‌آید:

$$u[m] = \frac{1}{N}\sum_{i=1}^{N} X[m.i] \qquad (5)$$

که به‌طور مشخص میانگین تجربی روی سطرهای ماتریس اعمال شده است؛ سپس ماتریس فاصله تا میانگین به‌صورت زیر به دست می‌آید:

$$B = X - uh \qquad (6)$$

که h برداری با اندازه $1 \times N$ با مقدار ۱ در هرکدام از درایه‌ها است. ماتریس کوواریانس C با ابعاد $M \times M$ به‌صورت زیر به دست می‌آید:

$$V^{-1}\,CV = D \qquad (7)$$

V ماتریس بردارهای ویژه و D ماتریس قطری است که درایه‌های قطر آن مقادیر ویژه هستند. آن‌چنان که مشخص است، هر مقدار ویژه متناظر با یک بردار ویژه است. به این معنا که ماتریس V ماتریسی $M \times M$ است که ستون‌های آن بردارهای ویژه می‌باشند و بردار ویژه V_q در ستون qام قرار دارد و مقدار ویژه qام یعنی درایه $\lambda_q = D_{q.q}$ تناظر با آن است. بازچینی بردارهای ویژه بر اساس اندازه مقادیر ویژه متناظر با آن‌ها صورت می‌گیرد؛ یعنی بر اساس ترتیب کاهشی مقادیر ویژه، بردارهای ویژه بازچینی می‌شوند. یعنی:

DOI: 10.30503/nripress.2020.147:

$$p \le q \ \rightarrow \lambda_p \le \lambda_q \qquad (8)$$

انتخاب زیرمجموعه‌ای از بردارهای ویژه با تحلیل مقادیر ویژه صورت می‌گیرد. زیرمجموعه نهایی با توجه به بازچینی مرحله قبل به‌صورت $V_1 . \cdots . V_L$ انتخاب می‌شود. در اینجا برای انتخاب می‌توان از انرژی تجمعی استفاده کرد که طبق آن:

$$g[m] = \sum_{q=1}^{m} \lambda_q \qquad (9)$$

انتخاب l باید به‌صورتی باشد که حداقل مقدار ممکن را داشته باشد و در عین حال g مقدار مطلوبی داشته باشد؛ به‌طور مثال می‌توان حداقل l را انتخاب کرد که:

$$g[m] \ \le S \qquad (10)$$

بنابراین خواهیم داشت:

$$W\ [p.q] = V\ [p.q]\ .p = 1. \cdots .M\ \ .\ q = 1. \cdots .l \qquad (11)$$

۳-۲-۳- WTBNN **بهینه‌سازی‌شده با** EHO

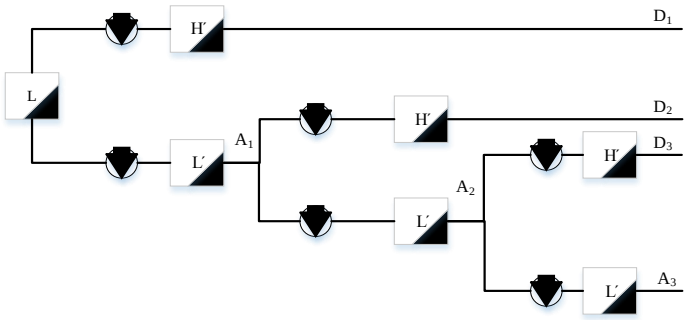
۳-۲-۳-۱- WTBPNN

BPNN روشی در یادگیری عمیق شبکه‌های عصبی مصنوعی، با بیش از یک لایه پنهان است که برای محاسبه دقیق‌تر گرادیان وزن استفاده می‌شود. این روش اغلب با بهینه‌سازی الگوریتم یادگیری و تثبیت وزن نورون‌ها با محاسبه گرادیان کاهشی تابع هزینه انجام می‌گیرد. پایهٔ یادگیری در شبکه‌های عصبی تکرار است. در این روش، در هر تکرار دو مرحله خواهیم داشت . مرحلهٔ اول حرکت روبه‌جلو (feed forward) است. با ضربِ داده‌های ورودی در وزن‌ها و سپس جمع آن با انحراف انجام می‌شود. سرانجام در همان مرحلهٔ اول به یک خروجی می‌رسد که با خروجیِ واقعی تفاوت دارد؛ سپس توسط تابع ضرر مشخص می‌شود که مرحلهٔ feed forward چه‌مقدار خطایی داشته است و بر اساس آن در مرحله دوم با بازگشت به عقب وزن لایه‌ها را اصلاح می‌کند. [114] بر طبق بسیاری از تحقیقات صورت‌گرفته در پیش‌بینی بار الکتریکی، ترکیب شبکه عصبی با تبدیلات موجک می‌تواند دقت نتایج شبکه عصبی را بهبود دهد. [115] در این گام داده‌ها قبل از ورود به شبکه عصبی توسط تبدیل موجک تجزیه می‌شود. در این تحقیق از تبدیل موجک گسسته (DWT) استفاده می‌شود که از لحاظ پیاده‌سازی بسیار ساده‌تر و بهینه‌تر است. معادله ۱۲ این تبدیل را نشان می‌دهد.

DOI: 10.30503/nripress.2020.147:

$$DWT_x\,(m.n) = 2^{-(\frac{m}{2})} \sum_{t=0}^{T-1} \int_{-\infty}^{\infty} x(t)\ \Psi\left(\frac{t-n2^m}{2^m}\right)\ dt \qquad (12)$$

که در آن t طول سیگنال $x(t)$ است. پارامترهای انتقال و مقیاس شامل مقادیر پیوسته m و n هستند، t مقدار گسسته زمان و Ψ تابع مادر تبدیل است. در این تحقیق بر اساس الگوریتم ارائه‌شده توسط Mallat و همکاران [116] که مدل Mallat Multi Resolution Analysis یا (MRA) را پیشنهاد داده است استفاده خواهد شد. این روش شامل دو مرحله تجزیه و سپس ترکیب مؤلفه‌ها است. در مرحله تجزیه سیگنال‌ها به دو مؤلفه فرکانس بالا و فرکانس پایین تجزیه می‌شود. این تجزیه می‌تواند برای مؤلفه‌های فرکانس پایین مجدداً تکرار شود. توابع مادر متعددی وجود دارد که می‌توان استفاده کرد، مانند تابع مادر Harr، Morlet، Mexican Hat، Meyer و غیره. در این مقاله بر اساس روال گذشته مقالات پیش‌بینی بار الکتریکی [117-118] از Daubechies of order 5 (db5) و در سه مرحله استفاده می‌شود. بعد از تجزیه داده‌های ورودی به مؤلفه‌های فرکانس بالا و پایین وارد شبکه عصبی می‌شود. مراحل تجزیه در شکل ۱ آمده است و روابط تجزیه مرحله‌ای آن در معادله 13 عنوان شده است. لایه‌های ورودی و پنهانی و خروجی شبکه عصبی به‌همراه توابع و ورودی و خروجی کلی شبکه در ادامه توضیح داده شده است. همچنین مدل شماتیک شبکه عصبی در شکل ۲ به نمایش گذاشته شده است.



شکل ۳. تجزیه سه‌مرحله‌ای متغیر تقاضای بار الکتریسیته

$$L = A_1+D_1$$
$$= D_1+D_2+A_2 \qquad (۱۳)$$
$$= D_1+D_2+D_3+A_3$$

- لایه ورودی: مقدار rامین گره لایه اول از ضرب مقدار ورودی X_i در وزن بردار W_{ir} و با اعمال تابع F به‌صورت مقدار X'_r محاسبه می‌شود:

$$X'_r = F\,(\sum_{i=1}^{m} W_{ir}\,X_i\,) \qquad \forall r = 1.\ldots.p \qquad (14)$$

DOI: 10.30503/nripress.2020.147:

- لایه پنهانی: مقدار sامین گره لایه دوم از مجموع ضرب مقدار ورودی از گره لایه اول X'_r در وزن بردار U_{rs} و با اعمال تابع F' به‌صورت مقدار X''_s محاسبه می‌شود:

$$X''_s = F'\left(\sum_{r=1}^{P} U_{rs}\, X'_r\right) \quad \forall s = 1.\ldots.q \qquad (15)$$

- لایه خروجی: مقدار oامین گره لایه خروجی از مجموع ضرب مقدار ورودی از لایه دوم X''_s در وزن بردار V_{so} و با اعمال تابع F'' به‌صورت مقدار y_o محاسبه می‌شود. این لایه همان مقادیر تجزیه‌شده مقدار بار الکتریکی است:

$$y_o = F''\left(\sum_{s=1}^{q} V_{so} \quad \hat{X}_s\right) \quad \forall o = 1.\ldots.4 \quad (16)$$

- لایه ورودی: مقدار rامین گره لایه اول از ضرب مقدار ورودی X_i در وزن بردار W_{ir} و با اعمال تابع F به‌صورت مقدار X'_r محاسبه می‌شود:

$$X'_r = F\left(\sum_{i=1}^{m} W_{ir}\, X_i\right) \qquad \forall r = 1.\ldots.p \qquad (17)$$

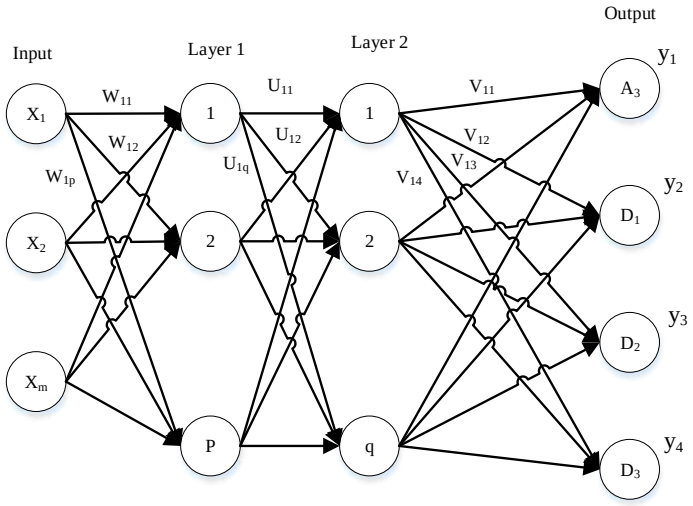
- لایه پنهانی: مقدار sامین گره لایه دوم از مجموع ضرب مقدار ورودی از گره لایه اول X'_r در وزن بردار U_{rs} و با اعمال تابع F' به‌صورت مقدار X''_s محاسبه می‌شود:

$$X''_s = F'\left(\sum_{r=1}^{P} U_{rs}\, X'_r\right) \quad \forall s = 1.\ldots.q \qquad (18)$$

- لایه خروجی: مقدار oامین گره لایه خروجی از مجموع ضرب مقدار ورودی از لایه دوم X''_s در وزن بردار V_{so} و با اعمال تابع F'' به‌صورت مقدار y_o محاسبه می‌شود. این لایه همان مقادیر تجزیه‌شده مقدار بار الکتریکی است:

$$y_o = F''\left(\sum_{s=1}^{q} V_{so} \quad \hat{X}_s\right) \quad \forall o = 1.\ldots.4 \quad (19)$$

DOI: 10.30503/nripress.2020.147:



شکل ۴. ساختار شبکه عصبی پس انتشار با تبدیل موجک

EHO -۳-۲-۳-۲

در طبیعت فیل‌ها به‌صورت گروهی زندگی می‌کنند و ساختار اجتماعی پیچیده‌ای متشکل از نر و ماده دارند. یک گروه از فیل‌ها چندین خانواده و قبیله دارند که تحت رهبری یک فیل قرار می‌گیرند. یک خانواده از یک یا چند فیل ماده و چندین فیل نابالغ تشکیل می‌شود. [119] زندگی فیل‌ها تحت‌تأثیر دو عملگر به‌عنوان یک روش بهینه‌سازی چندمنظوره استفاده می‌شود که بدین منظور می‌توان از سه قانون کلی زیر بهره برد:

۱– هر جمعیت یا گروه از فیل‌ها از چند خانواده تشکیل شده است که هر خانواده را تعداد ثابتی از فیل‌ها تشکیل می‌دهند؛

۲– در هر نسل تعداد ثابتی از فیل‌ها خانواده خود را ترک می‌کنند و به‌دور از خانواده خود زندگی می‌کنند؛

۳– در هر خانواده فیل‌ها تحت رهبری یک رهبر یا سرگروه زندگی می‌کنند.

عملگرهای این الگوریتم به دو حالت ذیل است:

- *عملگر به‌روزرسانی قبیله*

فیل‌ها در هر قبیله تحت سرپرستی یک سرگروه قرار دارند؛ بنابراین موقعیت بعدی هر فیل در قبیله c_i تحت‌تأثیر سرگروه قبیله c_i قرار دارد؛ بنابراین برای $j-$امین فیل در قبیله c_i داریم:

$$x_{new,c_i,j} = x_{c_i,j} + \alpha \times \left(x_{best,c_i} - x_{c_i,j} \right) \times r \qquad (20)$$

DOI: 10.30503/nripress.2020.147:

که در آن $x_{new,c_i,j}$ و $x_{c_i,j}$ به‌ترتیب موقعیت جدید و قبلی $j-$ امین فیل در قبیله c_i، $\alpha = [0.1]$ یک ضریب مقیاس که میزان تأثیرگذاری سرپرست گروه را در به‌روزرسانی بقیه اعضا نشان می‌دهد و r یک عدد تصادفی بین ۰ و ۱ می‌باشد. $x_{best\ ,c_i}$ همان سرپرست قبیله است که در واقع مناسب‌ترین پاسخ در حل مسئله بهینه‌سازی می‌باشد. سرپرست قبیله یا همان مناسب‌ترین فیل در هر قبیله نمی‌تواند طبق معادله ۲۱ موقعیت خود را به‌روز نموده و از رابطه .... استفاده می‌کند.

$$x_{new,c_i,j} = \beta \times x_{center,c_i} \qquad (21)$$

که در آن $\beta = [0.1]$ یک ضریب مقیاس که میزان تأثیرگذاری x_{center,c_i}را در $x_{new,c_i,j}$ نشان می‌دهد. طبق معادله ۲۲ مشخص است که $x_{new,c_i,j}$ با استفاده از اطلاعات موجود از تمامی فیل‌ها در قبیله c_i به دست آمده است. در واقع مرکز قبیله c_i است که برای یک مسئله بعدی می‌تواند از طریق رابطه زیر محاسبه شود.

$$x_{center,c_i} = \frac{1}{n_{c_i}} \times \sum_{j=1}^{n_{c_i}} x_{c_i,j,d} \qquad (22)$$

که در آن $1 \le d \le D$ نشان‌دهنده $d-$ امین بعد است. n_{c_i} نشان‌دهنده تعداد فیل‌ها در قبیله c_i و $x_{c_i,j,d}$ نشان‌دهنده $d-$ امین بعد از فیل $x_{c_i,j,d}$ می‌باشد.

- عملگر جدایی

در هر قبیله از فیل‌ها، فیل‌های نر وقتی که به سن بلوغ می‌رسند خانواده خود را ترک نموده و به زندگی در تنهایی ادامه می‌دهند. این جدایی به‌عنوان عملگر جدایی برای الگوریتم گروهی فیل‌ها مدل شده و در حل مسائل بهینه‌سازی به کار می‌رود. به‌منظور افزایش و بهبود توانایی قدرتِ جست‌وجو در این الگوریتم یک راه‌حل با کمترین مقدار تابع شایستگی را می‌توان به‌صورت معادله ۲۳ در هر نسل به‌روزرسانی نمود.

$$x_{worst,c_i} = x_{min} + (x_{max} - x_{min} + 1) \times r \qquad (23)$$

در رابطه فوق x_{max} و x_{min} به‌ترتیب کران بالا و پایین موقعیت فیل‌ها در قبیله c_i، x_{worst,c_i} بدترین موقعیتی که یک فیل می‌تواند در قبیله داشته باشد و r یک عدد تصادفی بین صفر و یک را نشان می‌دهد.

WTBNN- EHO **-۳-۲-۳-۳**

در مقالات گذشته در بهینه‌سازی اوزان شبکه عصبی از الگوریتم‌های متاهیورستیک مانند GA، PSO، DE، ACO و... استفاده شده است. در این مقاله از الگوریتم پیشرفته EHO برای بهینه‌سازی اوزان شبکه عصبی استفاده شده

DOI: 10.30503/nripress.2020.147:

است. این الگوریتم در مقایسه با دیگر الگوریتم‌های متاهیورستیک، دقت بیشتری را در رسیدن به جواب‌های بهینه دارد. مراحل بهینه‌سازی اوزان شبکه عصبی شامل گام‌های ذیل است:

- تنظیم پارامترهای الگوریتم شامل تعداد تکرارهای الگوریتم و اندازه جمعیت که باید بهینه‌سازی شود.
- تعریف مقدار تابع برازش که در این مسئله مقدار تابع برازش برابر با ضریب همبستگی در نظر گرفته می‌شود که در معادله ۲۴ بیان شده است.

$$1 - P\,(X.Y) = 1 - \frac{cov(X.Y)}{\sqrt{var(X)var(Y)}} \qquad (24)$$

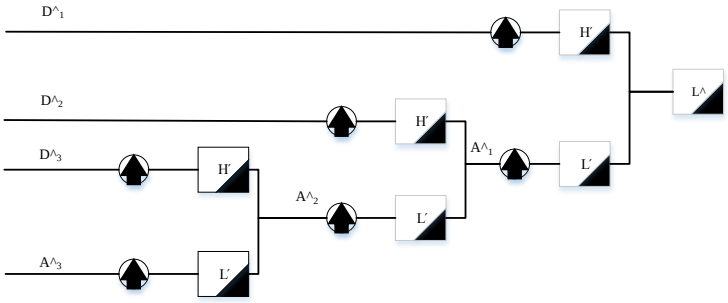
- تولید مختصات اولیه برای جمعیت - برای این کار بازه حرکت برای x_i^t به‌صورت معادله ۲۵ تعریف می‌شود که به‌صورت گسسته است؛ لذا مختصات اولیه به‌صورت رابطه ۲۶ تعریف می‌گردد.

$$D_{x_{c_i,j}} = \left[min\left(x_{c_i,j}\right).max(x_{c_i,j})\right] \quad (25)$$

$$x_{c_i,j}{}^0 = Rand\left(D_{x_{c_i,j}}\right) \quad (26)$$

- ضابطه حرکت جمعیت در هر مرحله به‌صورت روابط ۲۱ و ۲۲ تعیین می‌گردد. تولید جواب‌های جدید تا زمان برقراری شرایط توقف ادامه پیدا می‌کند.

بعد از تعیین اوزان شبکه عصبی و آموزش و تست شبکه عصبی، پیش‌بینی مقدار تقاضای بار الکتریکی توسط شبکه عصبی صورت می‌گیرد و مؤلفه‌های پیش‌بینی‌شده $\widehat{D_1}$، $\widehat{D_2}$، $\widehat{D_3}$ و $\widehat{A_3}$ توسط شبکه عصبی حاصل می‌شود. در ادامه این مقادیر برای محاسبه $\widehat{S_t}$ با یکدیگر جمع می‌شوند. شکل 3 نمایانگر ترکیب سیگنال‌ها برای محاسبه مقدار نهایی پیش‌بینی بار الکتریکی است.



شکل۵. ترکیب سه‌مرحله‌ای متغیر تقاضای بار الکتریسیته

مقدار تابع هدف در اجرای شبکه عصبی، مینیمم‌کردن تابع برازش ذیل برای داده‌های آزمایش می‌باشد:

$$f_t = \frac{1}{N}\sum_{t=1}^{N}(S_t - \widehat{S}_t)^2 \qquad (27)$$

DOI: 10.30503/nripress.2020.147:

که در آن ϑ_t مقدار واقعی بار الکتریکی در زمان t و $\widehat{\vartheta_t}$ مقدار پیش‌بینی‌شده بار الکتریکی در زمان t و f_t مقدار تابع برازش است. در این الگوریتم لازم است پارامترهایی مانند معیار توقف الگوریتم و معیارهای اختصاصی شبکه عصبی شامل تعداد لایه‌ها، تعداد گره‌ها، تنظیم گردد. همچنین لازم است پارامترهای الگوریتم EHO مانند اندازه جمعیت، بازه تغییرات $x_{c_{i,j}}$ تعیین شود. پارامترهای تبدیل موجک شامل مقادیر m و n نیز نیاز به تعیین مقدار دارند.

LSTM -۳-۲-۴

نوع خاصی از شبکه‌های عصبی بازگشتی است که برای حل مشکل گرادیان شبکه‌های عصبی بازگشتی پس‌انتشار مطرح شده است. این شبکه‌ها برای حذف ضرب‌های متوالی ماتریسی از یک سلول حافظه که دارای فیدبک با بهره است، استفاده می‌کنند. [121] این شبکه دارای اجزای مختلفی است که عبارت‌اند از:

- بلوک ورودی: رابطه اعمال‌شده در این بلوک به‌صورت معادله ۲۸ است.

$$Z_t = g\,(\,W_z\,x_t + R_z\,y_{t-1} + \,b_z\,) \qquad (28)$$

در رابطه بالا x_t، y_{t-1}، b_z و g ورودی در لحظه ، خروجی در لحظه $t-1$، بایاس و تابع فعال‌ساز هستند. ابعاد وزن‌ها در این بلوک دل‌خواه است.

- گیت ورودی: این گیت به این دلیل به وجود آمده است که در خواندن ورودی‌ها کنترل داشته باشیم و میزان خواندن در ورودی را کنترل کنیم. رابطه اعمال‌شده در این بلوک به‌صورت معادله ۲۹ است.

$$i_t = \sigma\,(\,W_i\,x_t + R_i\,y_{t-1} + p_i\,\odot c_{t-1} + b_z\,) \qquad (29)$$

در رابطه بالا x_t, y_{t-1}, b_z و σ به‌ترتیب ورودی در لحظه t، خروجی در لحظه $t-1$، بایاس، سلول حافظه در $t-1$ و تابع فعال‌ساز هستند. پارامتری که به‌وسیلهٔ آن بر روی مقدار خواندن سلول حافظه کنترل داریم p_i است.

- سلول حافظه: همان گونه که در شکل مشخص است این سلول دارای یک فیدبک به خودش است. رابطه این سلول به‌صورت زیر است.

$$c_t = z_t\,\odot i_t + c_{t-1}\,\odot f_t \qquad (30)$$

در رابطه ۳۰ ، i_t، z_t، c_{t-1} ، f_t خروجی گیت ورودی در لحظه t، خروجی بلوک ورودی در لحظه t، سلول حافظه در $t-1$ و خروجی گیت پاک‌کننده هستند. تمام نوآوری LSTM مربوط به این سلول است. برای کنترل‌کردن مقدار خواندن، نوشتن و پاک‌کردن این سلول ۳ گیت قرار داده شده است.

DOI: 10.30503/nripress.2020.147:

- گیت پاک‌کننده: رابطه اعمال‌شده در این گیت به‌صورت زیر است.

$$f_t = \sigma\left(W_f\, x_t + R_f\, y_{t-1} + p_f \odot c_{t-1} + b_f\right) \qquad (31)$$

در رابطه بالا x_t, y_{t-1}, b_f و σ ورودی در لحظه t، خروجی در لحظه $t-$ ، بایاس، سلول حافظه در $t-1$ و تابع فعال‌سازی هستند. پارامتری که به‌وسیلهٔ آن بر روی مقدار پاک‌شدن سلول حافظه کنترل داریم p_f است.

- بلوک خروجی: رابطه اعمال‌شده در این بلوک به‌صورت زیر است.

$$y_t + h(c_t) \odot o_t \qquad (32)$$

در رابطه بالا o_t c_t, خروجی گیت خروجی و مقدار سلول حافظه در لحظه t است. در شبکه‌های عصبی بازگشتی خروجی تابعی از حالت بود؛ ولی در LSTM خروجی تابعی از مقدار سلول حافظه است.

- گیت خروجی: رابطه اعمال‌شده در این بلوک به‌صورت زیر است.

$$o_t = \sigma\left(W_o\, x_t + R_o\, y_{t-1} + p_o \odot c_t + b_o\right) \qquad (33)$$

در رابطه بالا y_{t-1}, b_o, c_t, x_t و σ ورودی در لحظه t، خروجی در لحظه $t-1$، بایاس، سلول حافظه در t و تابع فعال‌ساز هستند. پارامتری که به‌وسیلهٔ آن بر روی مقدار خواندن سلول حافظه کنترل داریم p_o است.

همان طور که در روابط مشخص است ماتریس‌ها اجازه خروج از توابع فعالیت را ندارد و به همین دلیل ضرب‌های متوالی ماتریسی رخ نمی‌دهد و ضرب‌های متوالی برای پارامترهایی رخ می‌دهد که ضرب آن‌ها به‌صورت نقطه‌ای است.

WOA -۳-۲-۵

الگوریتم بهینه‌سازی نهنگ یا Whale Optimization Algorithm به‌اختصار (WOA) یکی از جدیدترین الگوریتم‌های فراابتکاری به شمار می‌رود که در سال ۲۰۱۶ ارائه شده است [123] و در حوزه هوش ازدحامی (Swarm Intelligence) جای می‌گیرد. در این الگوریتم از روش شکار تور حبابی که توسط نهنگ‌های گوژپشت انجام می‌شود الهام گرفته شده است. نهنگ‌های گوژپشت می‌توانند مکان شکار را شناسایی کرده و آن‌ها را محاصره کنند. از آنجایی که مکان طراحی بهینه در فضای جست‌وجو از راه قیاس شناخته نمی‌شود، الگوریتم WOA فرض می‌کند که بهترین راه‌حل نامزد حال حاضر، شکار هدف بوده و یا نزدیک به حالت مطلوب است. بعد از اینکه بهترین عامل جست‌وجو

DOI: 10.30503/nripress.2020.147:

شناسایی شد، عوامل دیگر جست‌وجو سعی می‌کنند تا مکان خود را نسبت به بهترین عامل جست‌وجو، به‌روزرسانی کنند. این رفتار از طریق معادلات زیر بیان شده است:

$$\vec{D} = \left[\overrightarrow{C}.\ \overrightarrow{X^*}(t) - \overrightarrow{X}(t)\right] \quad (34)$$

$$\overrightarrow{X}(t+1) = \overrightarrow{X^*}(t) - \overrightarrow{A}.\overrightarrow{D} \quad (35)$$

که در آن t تکرار جاری را نشان می‌دهد، A و C بردارهای ضرایب، X^* بردار مکان بهترین راه‌حل به‌دست‌آمده در حال حاضر و X بردار مکان است. لازم به ذکر است که در صورت وجود راه‌حل بهتر، X^* در هر تکرار باید به‌روز شود. بردار A و C به‌صورت زیر محاسبه می‌گردد:

$$\vec{A} = 2\,\vec{a}.\vec{r} - \vec{a} \quad (36)$$

$$\vec{C} = 2\,\vec{r} \quad (37)$$

که a به‌صورت خطی از مقدار ۲ تا ۰ و در طی تکرارها کاهش می‌یابد (در هر دو فاز اکتشاف و استخراج) و r بردار تصادفی در فاصله ۰ تا ۱ است. جهت مدل‌سازی ریاضی رفتار حباب تور نهنگ‌های گوژپشت، ۲ روش به‌صورت زیر طراحی شده است:

- *مکانیزم محاصرهٔ انقباضی:* این رفتار از طریق افزایش مقدار a در رابطه (۳) حاصل می‌شود. که محدوده نوسان Aبه‌وسیلهٔ a کاهش می‌یابد. به‌عبارت دیگر، A مقداری تصادفی در فاصله a تا -a است و a در طی تکرارها، از مقدار ۲ تا ۰ کاهش می‌یابد. با انتخاب مقادیر تصادفی A در فاصلهٔ ۱ تا ۱-، می‌توان مکان جدید عامل جست‌وجو را در هر کجا بین مکان اصلی عامل و مکان بهترین عامل کنونی، تعریف کرد.
- *مکان در حال به‌روزرسانی مارپیچی:* این روش در ابتدا فاصله بین نهنگ قرار گرفته در مختصات X^* و Y طعمه موجود در X^* و Y^* را محاسبه می‌کند. معادله‌ای مارپیچی بین موقعیت نهنگ و طعمه ایجاد می‌شود تا حرکت حلزونی‌شکل نهنگ گوژپشت را تقلید کند:

$$\overrightarrow{X}(t+1) = \overrightarrow{D'}.e^{bl}.cos(2\pi l) + \overrightarrow{X^*}(t) - \overrightarrow{A}.\overrightarrow{D} \quad (38)$$

در این رابطه،

$$\overrightarrow{D'} = \left|\overrightarrow{X^*}(t) - \overrightarrow{X}(t)\right| \quad (39)$$

بوده و به‌فاصله ۱امین نهنگ تا طعمه اشاره دارد (بهترین راه‌حل به‌دست‌آمده تا اینجا)، b ثابتی برای تعریف شکل مارپیچ لگاریتمی است و عددی تصادفی بین ۱ تا ۱- می‌باشد. لازم به ذکر است که نهنگ گوژپشت، حول طعمه در امتداد یک دایره انقباضی و هم‌زمان در مسیر مارپیچی‌شکلی به شنا در می‌آید. جهت مدل‌سازی این رفتار هم‌زمان،

DOI: 10.30503/nripress.2020.147:

فرض شده است که نهنگ با احتمال ۵۰درصد از بین مکانیزم محاصرهٔ انقباضی یا مدل مارپیچی یکی را انتخاب می‌کند تا موقعیت نهنگ‌ها در طول بهینه‌سازی به‌روزرسانی شود. مدل ریاضی بدین صورت است:

$$\overrightarrow{X}(t+1)\begin{cases}\overrightarrow{X^*}(t)-\overrightarrow{A}.\overrightarrow{D} & if\ p<0.5\\ \overrightarrow{D'}.e^{bl}.cos(2\pi l)+\overrightarrow{X^*}(t) & if\ p\geq 0.5\end{cases} \quad (40)$$

که در آن P عددی تصادفی بین ۰ تا ۱ است. علاوه بر روش حباب تور، نهنگ‌های گوژپشت به‌صورت تصادفی به‌دنبال طعمه می‌گردند.

روشی مشابه بر مبنای واریاسیون بردار A را می‌توان جهت جست‌وجوی شکار (اکتشاف) به کار گرفت. در حقیقت، نهنگ‌های گوژپشت، بر طبق مکان یکدیگر، به‌صورت تصادفی به جست‌وجو می‌پردازند؛ بنابراین بردار A را با مقادیر تصادفی بزرگ‌تر از او یا کمتر از ۱- به کار گرفته شده است تا عامل جست‌وجو را مجبور به دورشدن از نهنگ مرجع کند. برخلاف فاز استخراج، جهت به‌روزرسانی موقعیت عامل جست‌وجو در فاز اکتشاف به‌جای استفاده از داده‌های بهترین عامل جست‌وجو، از انتخاب تصادفی عامل بهره برده شده است. این مکانیزم به‌همراه A>۱ بر اکتشاف تأکید دارند و به الگوریتم WOA اجازه می‌دهند تا جست‌وجویی سرتاسری را به انجام رساند. مدل ریاضی به‌صورت زیر است:

$$\overrightarrow{D'}=\left|\vec{C}.\vec{X}_{rand}(t)-\overrightarrow{X}(t)\right| \quad (41)$$

$$\overrightarrow{X}(t+1)=\vec{X}_{rand}(t)-\overrightarrow{A}.\overrightarrow{D} \quad (42)$$

در این معادله، X_{rand} بردار موقعیت تصادفی انتخاب‌شده (نهنگ تصادفی) از جمعیت جاری است. الگوریتم WOA با مجموعه‌ای از راه‌حل‌های تصادفی شروع به کار می‌کند. در هر تکرار، عوامل جست‌وجوی موقعیت خود را با توجه به عامل جست‌وجویی که تصادفی انتخاب شده و با بهترین راه‌حل به‌دست‌آمدهٔ جاری، به‌روزرسانی می‌کنند. پارامتر a جهت فراهم‌آوردن اکتشاف و استخراج، به‌ترتیب از مقدار ۲ تا ۰ کاهش می‌یابد. یک عامل جست‌وجوی تصادفی در حالت $|A|>۱$ انتخاب می‌شود؛ این در حالی است که بهترین راه‌حل زمانی انتخاب می‌شود که جهت به‌روزرسانی موقعیت عوامل جست‌وجو، $|A|<۱$ باشد. بسته به مقدار p، الگوریتم WOA این قابلیت را دارد تا بین حرکت دایروی یا مارپیچی یکی را انتخاب کند. در نهایت، الگوریتم WOA با ارضای شرایط خاتمه، پایان می‌پذیرد.

۳-۳- ساختار مدل ترکیبی

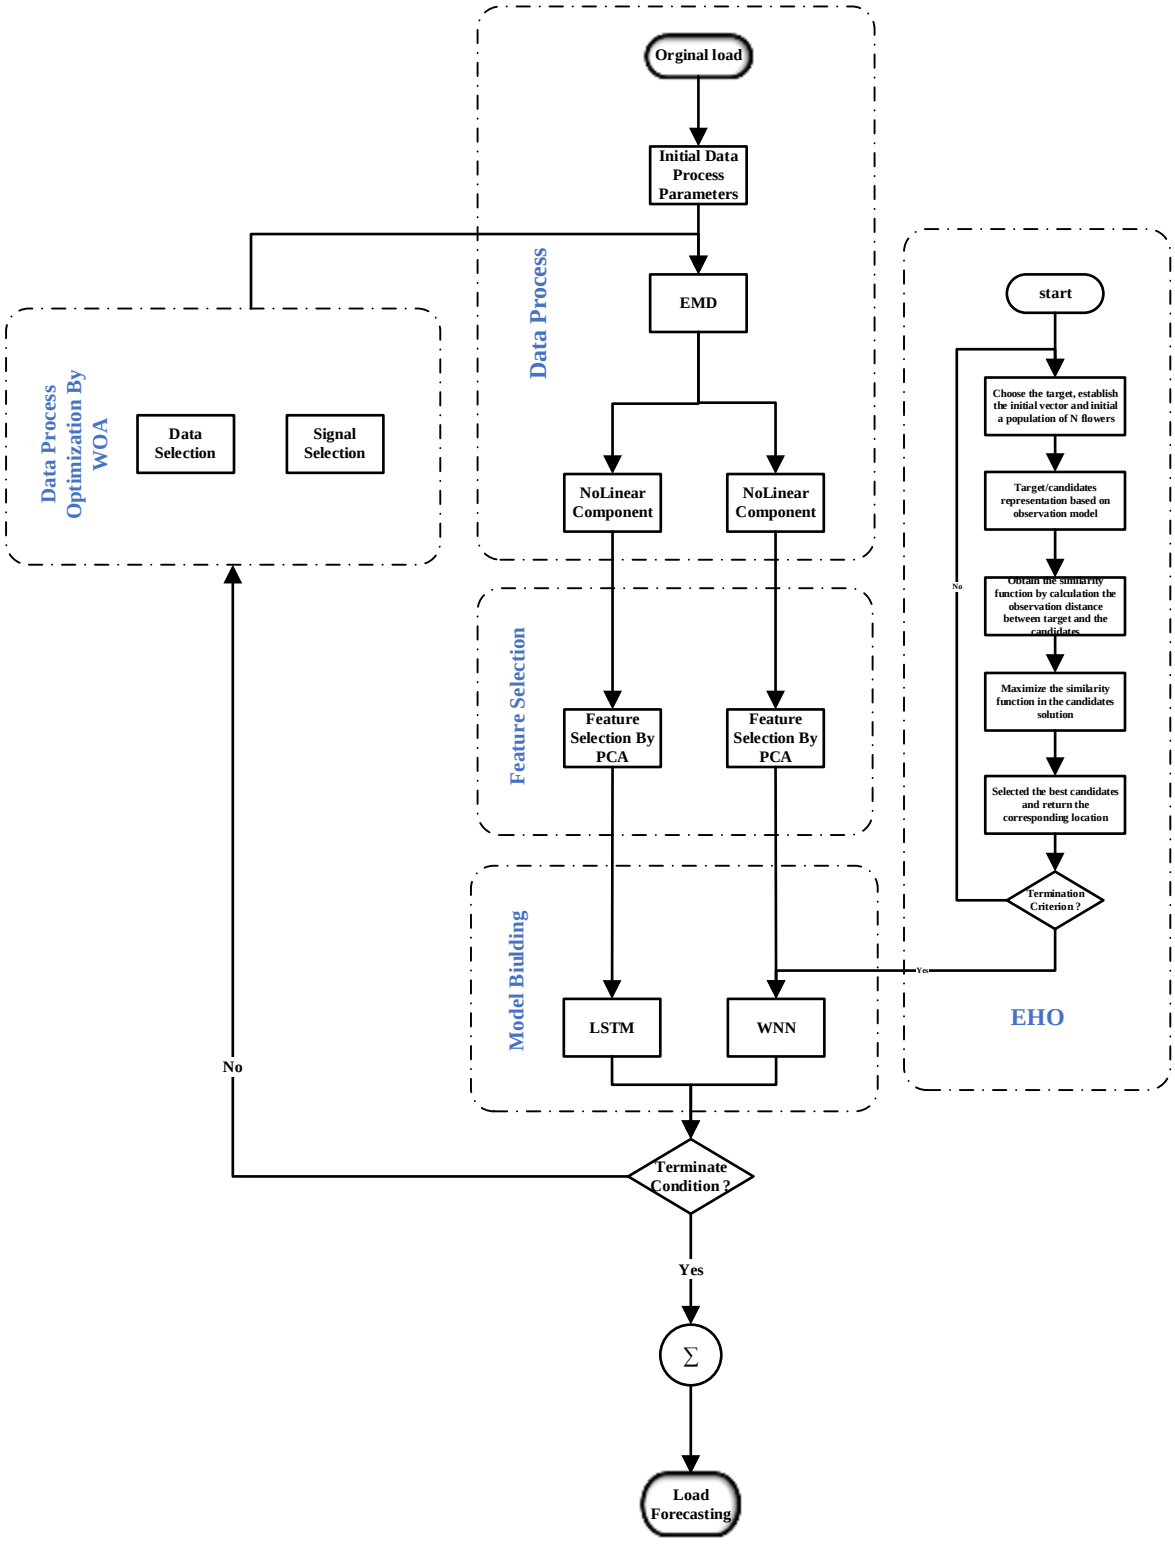
مدل هدف به‌صورت موازی از دو شبکه عصبی WTBNN بهینه‌سازی‌شده توسط روش EHO و LSTM جهت پیش‌بینی تقاضای بار الکتریکی استفاده کرده است. داده‌ها قبل از ورود به شبکه‌های عصبی توسط روش EMD تجزیه شده و پارامترهای ورودی به شبکه عصبی از طریق روش PCA انتخاب می‌گردند. برای بهینه‌سازی تعداد تجزیه سیگنال و نحوه تخصیص سیگنال‌ها به شبکه‌های عصبی از روش WOA استفاده می‌شود. نتایج تحلیل شبکه‌های

DOI: 10.30503/nripress.2020.147:

عصبی با یکدیگر تجمیع می‌گردد. دیاگرام مدل هدف در شکل ۴ آمده است و مراحل اجرای مدل در ذیل در ۷ مرحله به‌ترتیب عنوان شده است:

I. داده‌های تاریخی تقاضای بار الکتریکی توسط روش EMD به سیگنال‌های زیرمجموعه خود تقسیم‌بندی می‌شود؛
II. بهترین پارامترها توسط الگوریتم PCA انتخاب می‌گردد؛
III. تعیین مقدار اولیه تصادفی برای انتخاب بهترین تعداد تجزیه سیگنال توسط روش EMD و همچنین نحوه تخصیص سیگنال‌های تجزیه‌شده به دو شبکه عصبی؛
IV. ورود دسته سیگنال‌های تعیین‌شده به WTNN-EHO؛
V. ورود دسته سیگنال‌های تعیین‌شده به LSTM؛
VI. تعیین مقادیر تجزیه سیگنال و همچنین نحوه اختصاص سطوح سیگنال به شبکه‌های عصبی توسط الگوریتم WOA؛
VII. نتایج حاصل از پیش‌بینی توسط دو شبکه عصبی جهت پیش‌بینی مقدار نهایی تقاضای بار الکتریکی با هم جمع می‌شوند.

DOI: 10.30503/nripress.2020.147:



شکل ۶. Proposed Model Diagram

۴-۳- نتیجه‌گیری

DOI: 10.30503/nripress.2020.147:

در این گزارش ساختار مدل ترکیبی پیش‌بینی میان‌مدت و بلندمدت بار الکتریکی پیشنهاد داده شد. قبل از آن هریک از اجزای مدل پیشنهاددادهشده بررسی و معرفی شد. این ساختار بر پایهٔ نتایج مقالات قبلی معرفی‌شده در بخش مرور ادبیات ایجاد شد. این ساختار از دو روش هوش مصنوعی و با استفاده از مکانیزمی برای انتخاب هوشمند تعداد تجزیه سیگنال و همچنین روشی برای انتخاب پارامترها تشکیل شده است که انتظار می‌رود دقت بالاتری را در پیش‌بینی متغیر مصرف بار الکتریکی حاصل نماید. در گزارش فاز بعدی با تعریف شاخص‌های سنجش خطا، عملکرد مدل هدف و مدل‌های موجود در پیش‌بینی تقاضای بار الکتریکی با یکدیگر مقایسه می‌شود. همچنین برای اعتبارسنجی مدل هدف، با انتخاب مجموعه‌ای از داده‌های تاریخی مصرف بار الکتریکی، اعتبار مدل هدف با مدل‌های موجود مقایسه خواهد شد.

فصل چهارم

نتایج اجرای مدل

DOI: 10.30503/nripress.2020.147:

مقدمه

در فصل اول به تبیین اهداف، ضرورت‌ها و نیازهای موجود در زنجیره تأمین برق اشاره شد و عنوان گردید که اگر بخواهیم این زنجیره را به‌شکل صحیح برنامه‌ریزی و مدیریت نماییم باید متغیرهای مهم و تأثیرگذار بر آن را با بالاترین دقت پیش‌بینی نماییم. پیش‌بینی بسیار دقیق متغیرها و به‌تبع آن برنامه‌ریزی بسیار دقیق این شبکه می‌تواند از تولید بار مازاد در شبکه یا کمبود بار در آن و در نتیجه هزینه‌های گزاف تحمیلی بر آن جلوگیری نماید. پیش‌بینی تقاضای بار الکتریکی به‌عنوان یکی از مهم‌ترین متغیرهای لازم برای برنامه‌ریزی شبکه می‌باشد. به همین دلیل تحقیقات متعددی در جهت طراحی مدل‌هایی برای پیش‌بینی آن صورت گرفته است. در این میان، مجموعه‌ای از مدل‌هایی با هدف پیش‌بینی در بازه زمانی هفته، ماه و سال طراحی شده است که به مدل‌های پیش‌بینی تقاضای بار الکتریکی میان‌مدت و بلندمدت مشهور می‌باشند. در این مدل‌ها علاوه بر د نظرگرفتن پارامترهایی مانند دما یا رطوبت، پارامترهای کلان‌تر مانند جمعیت، تولید ناخالص ملی و غیره نیز در پیش‌بینی‌ها در نظر گرفته شده و از داده‌های تاریخی آن‌ها برای افزایش دقت پیش‌بینی‌ها و یافتن روابط غیرخطی میان پارامترها استفاده می‌شود. به‌دلیل اینکه سری‌های زمانی تقاضای بار و نحوه ارتباط آن‌ها با پارامترهای ورودی از روابط معمولاً پیچیده و غیرخطی تبعیت می‌کند، لازم است الگوریتم‌های فراابتکاری و مدل‌های مبتنی بر یادگیری ماشین برای شناخت روابط بین داده‌ها و پیش‌بینی دقیق‌تر استفاده کرد.

در فصل دوم ابتدا به مرور ادبیات مرتبط با انتخاب پارامترهای ورودی به مدل‌های پیش‌بینی تقاضای بار الکتریکی پرداخته شد و بر اساس تحقیقات گذشته، دسته‌بندی برای آن‌ها پیشنهاد داده شده است و نحوه ارتباط آن‌ها با دوره‌های زمانی پیش‌بینی شرح داده شد. سپس پایگاه داده‌های استفاده‌شده در این گزارش معرفی گردید. بعد از آن روش‌های به‌کاررفته برای پیش‌پردازش داده‌ها معرفی و جدول نهایی پارامترها و متغیر و جدول مربوطه معرفی شد.

در فصل سوم ساختار مدل هدف بررسی شد. بدین منظور ابتدا هریک از اجزای به‌کاررفته در مدل ترکیبی به‌طور کامل تشریح و مزیت هریک از این اجزا به‌طور کامل بررسی شد. سپس این اجزا با هم ترکیب شده و مدل ترکیبی نهایی را ایجاد نمود. در نهایت گام‌های مدل ترکیبی نیز توضیح داده شد.

در این فصل مدل تشریح‌شده در فصل قبلی که توسط نرم‌افزار متلب ۲۰۱۶ کدنویسی شده است برای داده‌های مربوط به پارامترهای تعریف‌شده و همچنین داده‌های تاریخی مصرف بار اجرا خواهد شد و نتایج آن در قالب نمودار جهت مقایسه میزان خطا نمایش داده خواهد شد. همچنین برای بررسی عملکرد مدل، نتایج آن با دیگر مدل‌های موجود بر پایه LSTM مقایسه خواهد شد و از معیارهای خطا برای اندازه‌گیری میزان خطا استفاده خواهد شد. همچنین اعتبارسنجی مدل برای بررسی معتبربودن مدل برای داده‌های مختلف و در شرایط متفاوت نیز ارائه خواهد شد.

DOI: 10.30503/nripress.2020.147:

۴-۱- معیارهای سنجش خطا

برای مقایسه نحوه عملکرد مدل هدف با مدل‌های دیگر و ارزیابی میزان بهبود در پیش‌بینی‌ها از بین روش‌های پیشنهادداده‌شده در رفرنس‌های [1] از روش Mean Absolute Percent Error (MAPE) در معادله ۱، Mean Absolute Error (MAE) در معادله ۲ و Root Mean Square Error (RMSE) در معادله ۳ استفاده شده است. این روابط برای مقایسه عملکرد مدل هدف و مدل‌های موجود در بخش ۲,۳ استفاده شده است.

$$MAPE = \frac{1}{N}\sum_{t=1}^{N}\left|\frac{\vartheta_t - \widehat{\vartheta_t}}{\vartheta_t}\right| \quad (1)$$

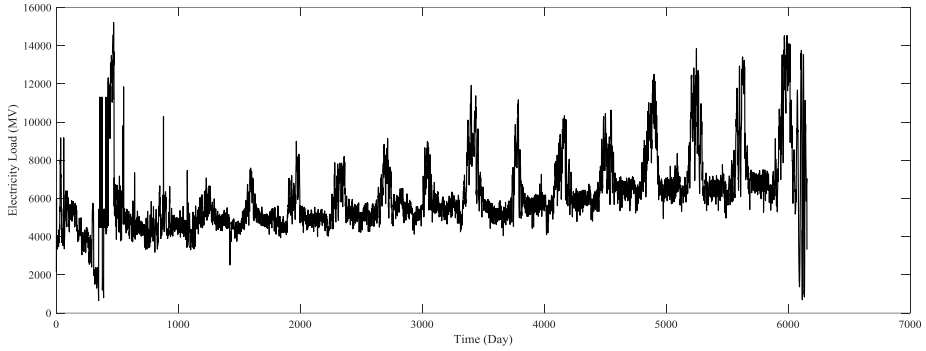
$$MAE = \frac{1}{N}\sum_{t=1}^{N}\left|\vartheta_t - \widehat{\vartheta_t}\right| \quad (2)$$

$$RMSE = \frac{1}{N}\sqrt{\sum_{t=1}^{N}\left(\vartheta_t - \widehat{\vartheta_t}\right)^2} \quad (3)$$

۴-۲- نتایج اجرای مدل هدف و مقایسه با دیگر مدل‌ها

برای سنجش دقت مدل هدف، این مدل را با مدل‌های ترکیبی مبتنی بر یادگیری عمیق SARIMA-LSTM، NN-LSTM، SAM-LSTM و CNN-LSTM مقایسه می‌شود. مدل‌ها با انتخاب بهترین پارامترها از بین پارامترهای *جمعیت*، *دمای هوا*، *داده‌های تاریخی بار الکتریکی در دوره‌های قبل*، *رطوبت* و *پیک مصرف برق در روز* استفاده شده است. داده‌های تاریخی مربوط به تقاضای بار الکتریکی و پارامترهای معرفی‌شده، از پایگاه داده‌های شبکه برق ایران (IGMC) استفاده شده است. این پایگاه داده توسط شرکت مدیریت برق ایران که هدفش کنترل بازار برق در ایران می‌باشد، ایجاد شده است که هم‌زمان به ذخیره‌سازی داده‌های مربوط به تقاضای بار الکتریکی و پارامترهای معرفی‌شده می‌پردازد. سیگنال داده‌های تاریخی مصرف بار الکتریکی به‌صورت شکل ۲ می‌باشد. این داده‌ها مربوط به برق منطقه‌ای تهران می‌باشد.

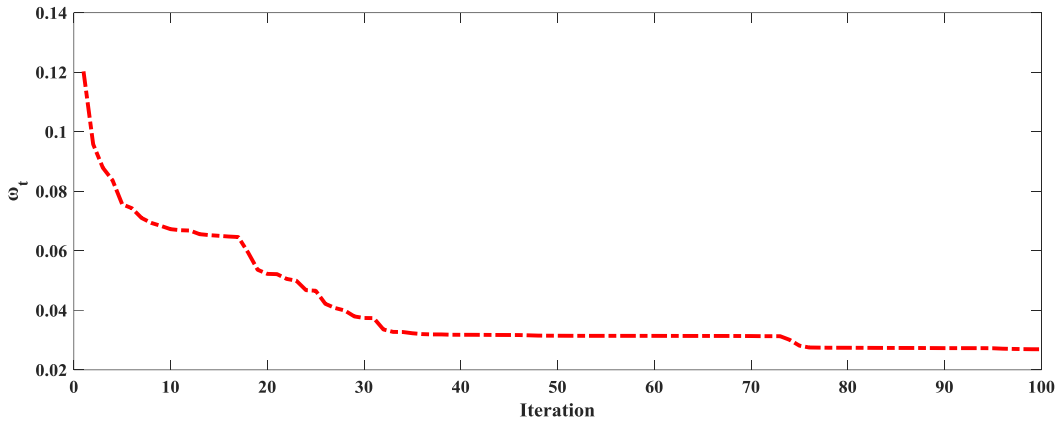
DOI: 10.30503/nripress.2020.147:

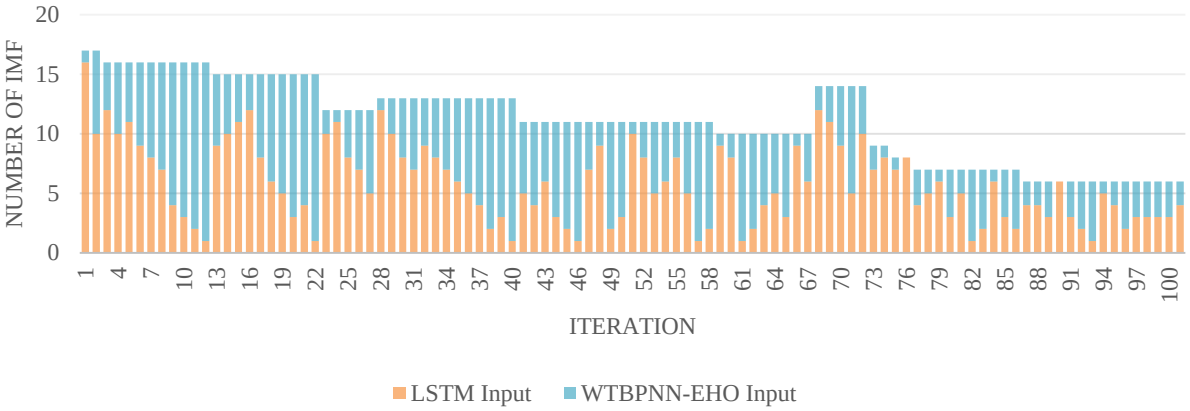


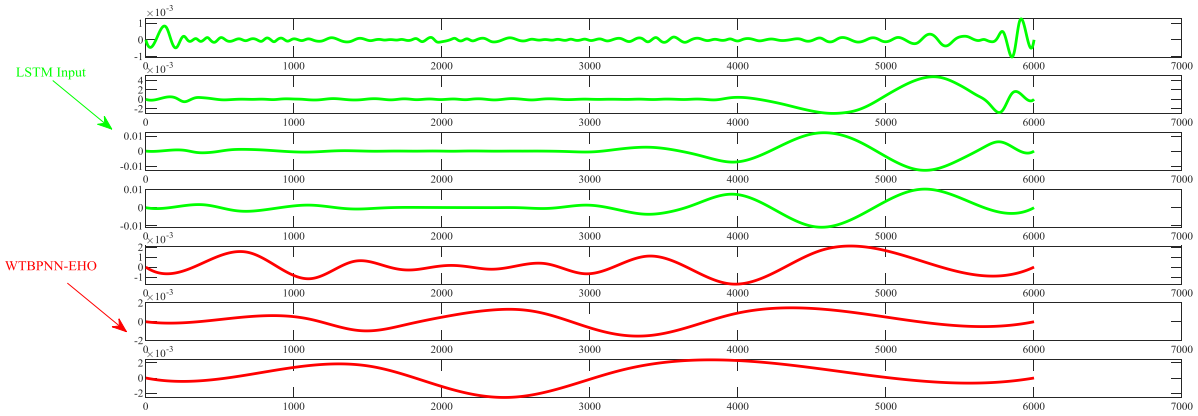
شکل ۷. داده‌های تاریخی مصرف بار الکتریکی

در این گزارش برای مثال نحوه عملکرد مدل هدف برای پیش‌بینی تقاضای بار الکتریکی در روز 10 ژانویه ۲۰۱۲ در شبکه برق ایران بررسی شده است. شکل ۳ نحوه تجزیه سیگنال داده‌های تاریخی تقاضای بار الکتریکی را توسط روش EMD در تکرارهای مختلف WOA نمایش می‌دهد.

DOI: 10.30503/nripress.2020.147:



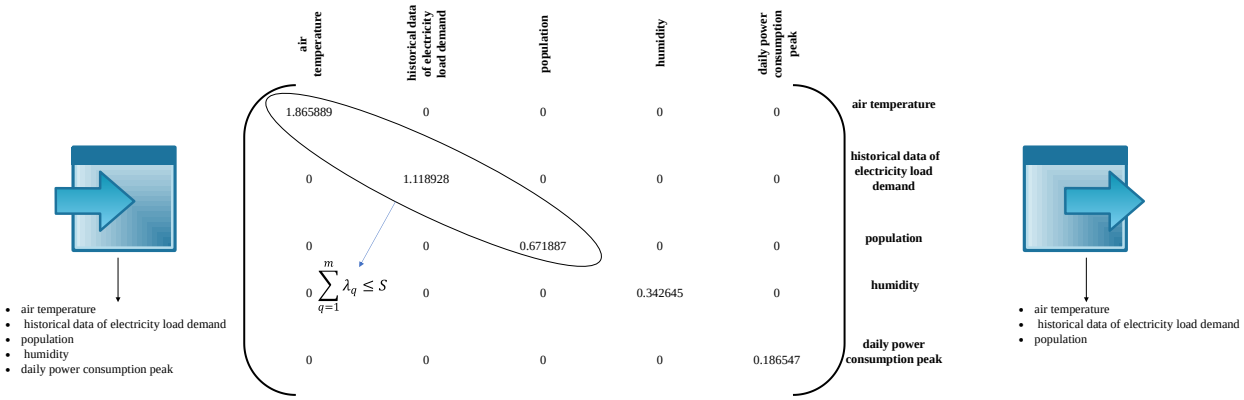




شکل ۸. بهینه‌سازی تعداد سیگنال و نحوه تقسیم‌بندی سیگنال EMD توسط WOA

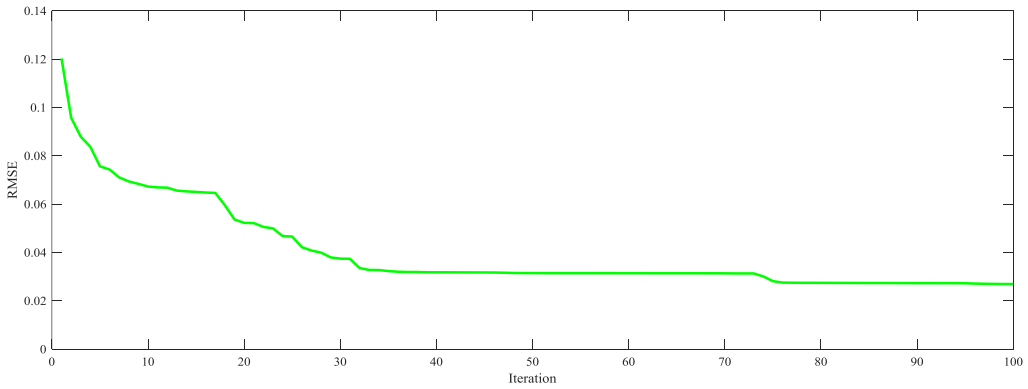
DOI: 10.30503/nripress.2020.147:

انتخاب ویژگی‌ها نیز توسط مدل PCA صورت می‌گیرد که نحوه عملکرد مدل در شکل ۴ به نمایش گذاشته شده است.



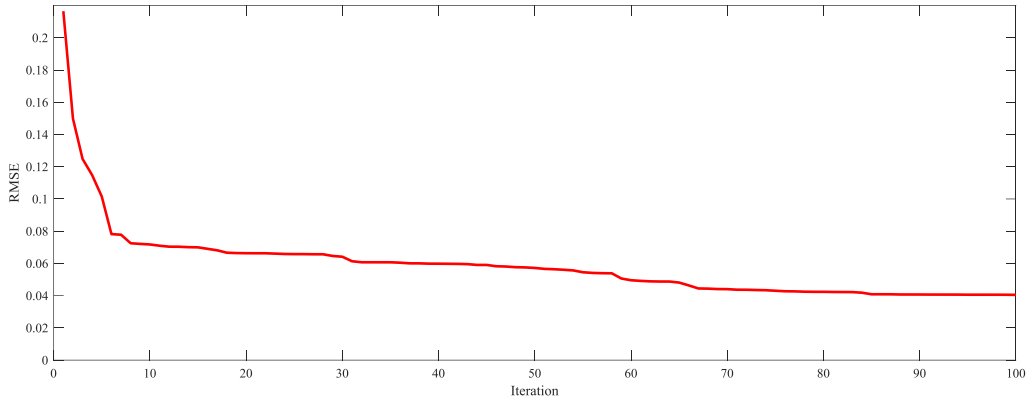
شکل ۹. انتخاب ویژگی‌ها توسط مدل PCA

گام‌های 3 و ۴ بخش ۱ برای پیش‌بینی مقدار بار مصرفی به‌صورت شماتیک در شکل ۵ به نمایش گذاشته شده است.



(a)

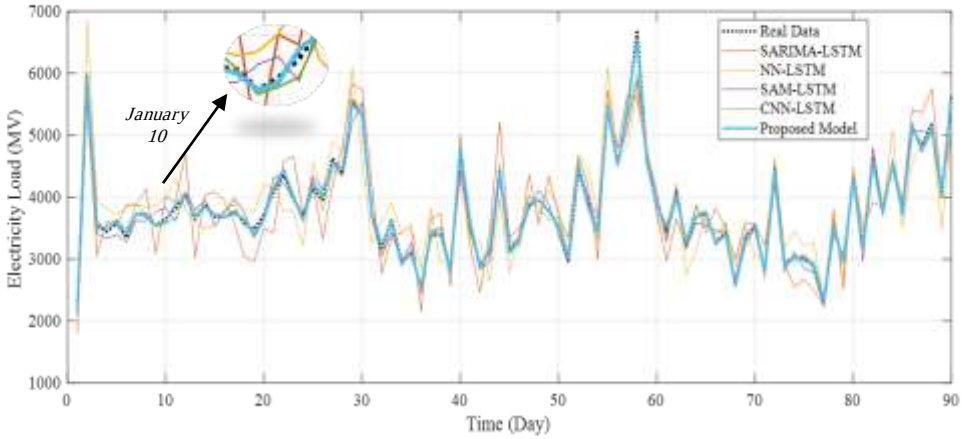
DOI: 10.30503/nripress.2020.147:



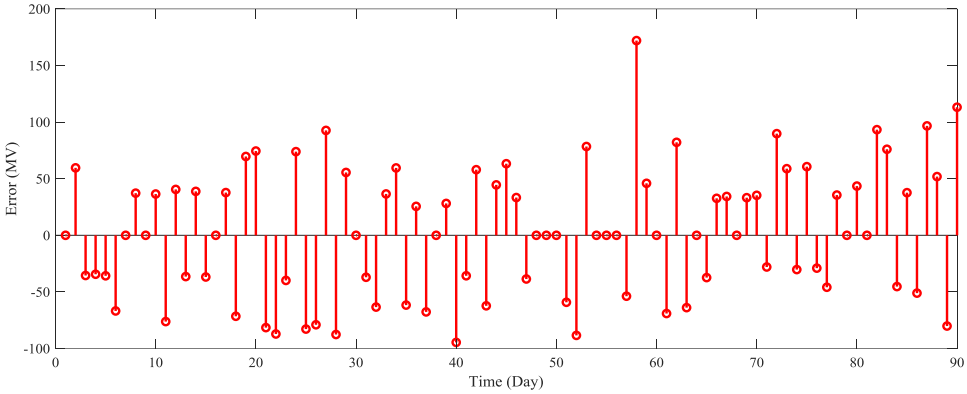
(b)

شکل ۱۰. بهینه‌سازی RMSE در طول اجرا (a WTBPNN-EHO (b LSTM

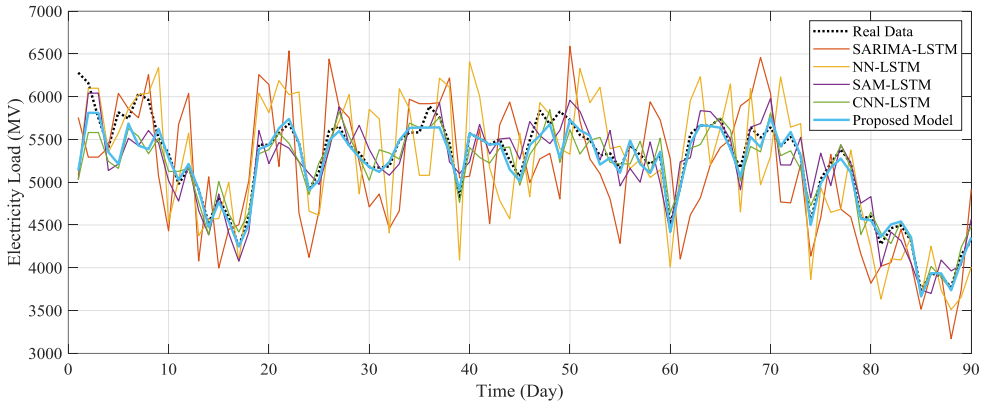
نتایج حاصل از پیش‌بینی میان‌مدت و بلندمدت بار الکتریکی در روز ۱۰ ژانویه سال ۲۰۱۲ توسط مدل هدف و چهار مدل موجود عنوان‌شده، در شکل ۵ قسمت a به نمایش گذاشته شده است. در این نمودار مقدار واقعی تقاضای بار الکتریکی در این روز برابر با ۳۶۴۷ و مقادیر پیش‌بینی‌شده توسط الگوریتم‌های SARIMA-LSTM، NN-LSTM، SAM-LSTM و CNN-LSTM و مدل هدف به‌ترتیب برابر با ۴۰۱۱، ۳۹۷۴، ۳۸۲۹، ۳۵۷۴ و ۳۶۱۰ مگاوات است. همچنین در شکل ۱۲ مابقی روزهای سال ۲۰۱۲ توسط مدل هدف و مدل‌های موجود به نمایش گذاشته شده است.

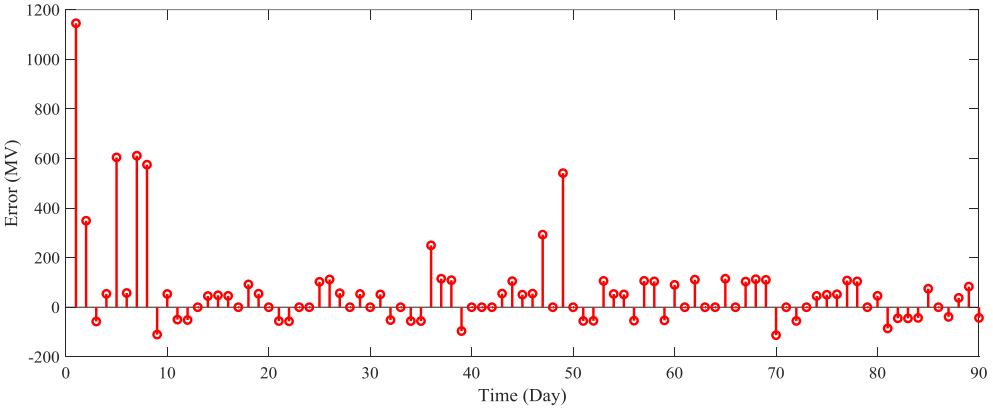


DOI: 10.30503/nripress.2020.147:



(a)



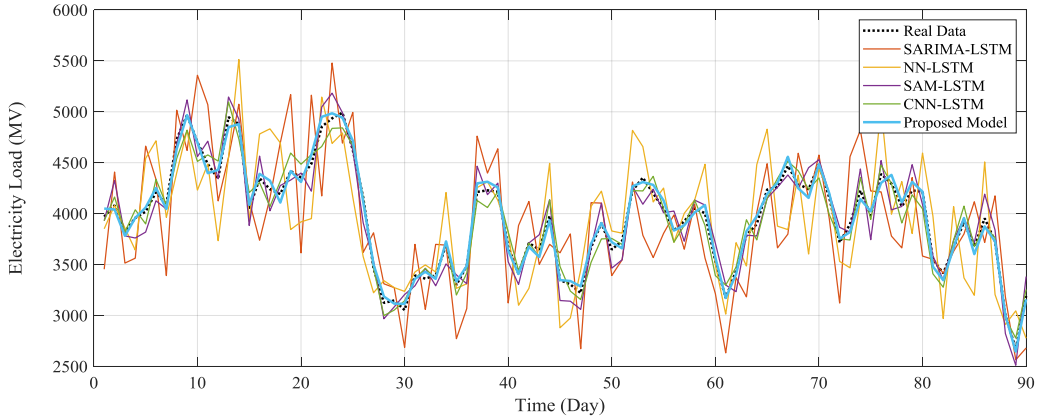


(b)

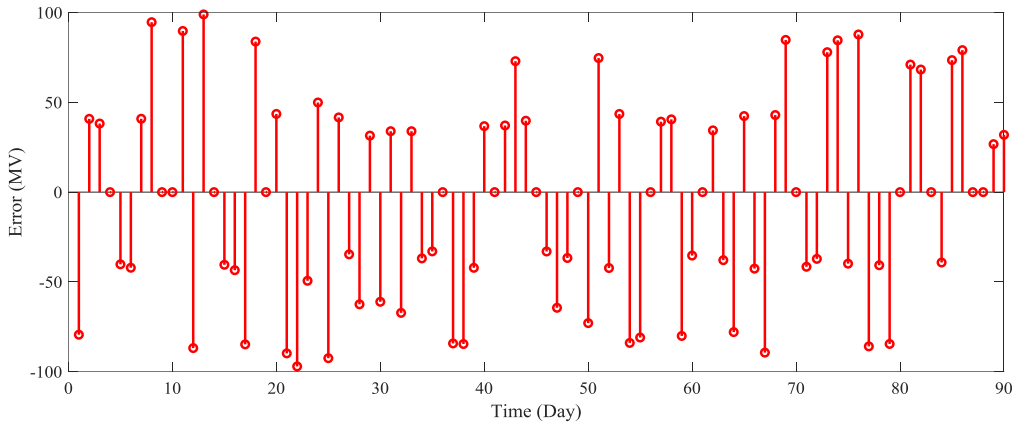
DOI: 10.30503/nripress.2020.147:



(c)



DOI: 10.30503/nripress.2020.147:



(d)

شکل ۱۱. مقایسه مقدار پیش‌بینی تقاضای بار الکتریکی مدل هدف با دیگر مدل‌های موجود به‌همراه مقدار خطای مدل هدف در a) بهار؛ b) تابستان؛ c) پاییز؛ d) زمستان سال ۲۰۱۲.

همچنین نتایج شاخص‌های عملکرد تعریف‌شده در بخش۱,۳ برای مدل‌های تحت‌بررسی، جهت مقایسه در جدول ۱ به نمایش گذاشته شده است.

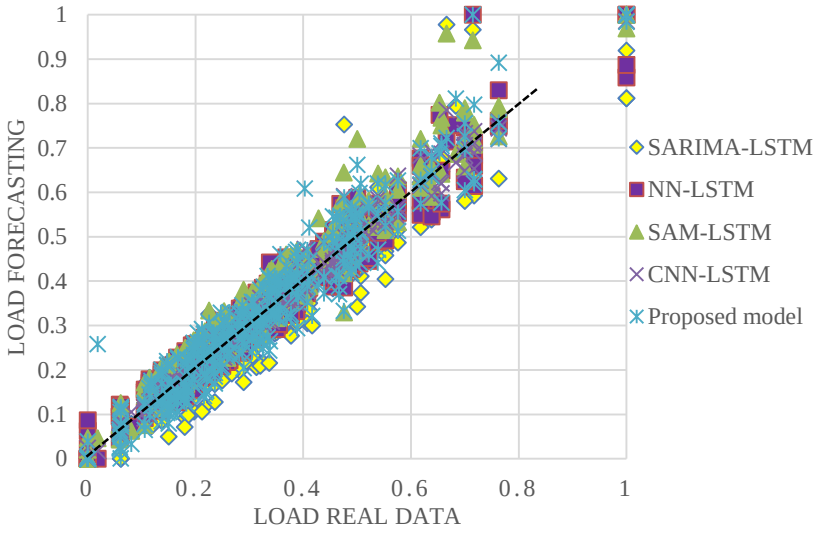
جدول ۴. مقایسه عملکرد مدل هدف با مدل‌های موجود بر اساس معیارهای سنجش خطا در سال ۲۰۱۲

Model	Criterion	Jan.	Feb.	Mar.	Apr.	May.	Jun.	Jul.	Aug.	Sep.	Oct.	Nov.	Dec.	Average
SARIMA-LSTM	MAPE (%)	0.099	0.096	0.096	0.107	0.100	0.098	0.092	0.102	0.096	0.101	0.096	0.099	۰.۰۹۸
	MAE(MW)	326.71	346.57	329.45	335.88	368.81	347.83	326.88	307.63	354.21	327.16	353.98	325.72	337.57
	RMSE	40.12	43.61	41.31	41.98	44.49	44.74	40.05	38.23	43.38	40.39	43.88	40.51	41.89
NN-LSTM	MAPE (%)	0.074	0.079	0.075	0.082	0.087	0.086	0.072	0.070	0.078	0.080	0.078	0.074	۰.۰۷۸
	MAE(MW)	284.46	284.43	303.93	286.30	316.48	339.61	333.27	270.79	266.57	295.62	300.93	295.07	298.12
	RMSE	36.24	35.95	37.47	35.68	38.80	40.73	40.83	33.09	33.87	35.94	35.90	35.79	36.69
SAM-LSTM	MAPE (%)	0.042	0.045	0.043	0.042	0.044	0.041	0.044	0.045	0.045	0.037	0.042	0.042	۰.۰۴۳
	MAE(MW)	118.69	133.17	124.61	121.54	129.83	117.82	126.26	132.61	133.83	103.10	125.95	122.63	124.17

DOI: 10.30503/nripress.2020.147:

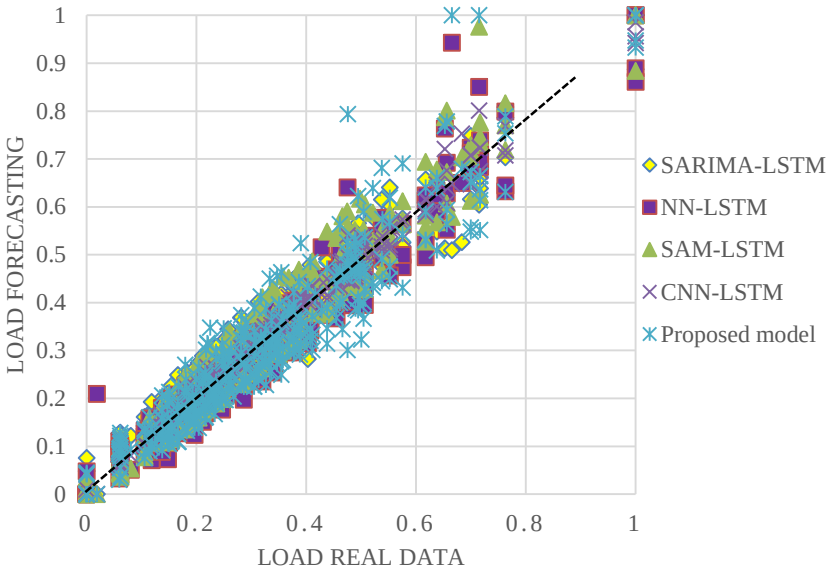
	RMSE	14.68	16.12	15.42	15.11	15.51	14.79	15.45	16.24	16.32	13.13	15.62	15.23	15.30
CNN-LSTM	MAPE (%)	0.029	0.032	0.034	0.032	0.031	0.032	0.033	0.031	0.032	0.031	0.029	0.032	۰.۰۳۲
	MAE(MW)	88.05	73.31	82.92	91.42	81.70	78.98	85.96	88.26	81.43	86.11	82.33	82.48	83.58
	RMSE	10.65	9.36	10.42	11.42	10.22	9.99	10.87	11.05	10.42	11.03	10.62	10.36	10.53
Proposed model	MAPE (%)	0.0298	0.0304	0.0289	0.0284	0.0286	0.0298	0.0284	0.0288	0.0271	0.0288	0.0288	0.0301	۰.۰۲۹
	MAE(MW)	48.85	51.12	44.65	44.29	44.20	48.85	43.65	45.41	37.73	45.63	45.64	49.50	45.79
	RMSE	6.00	6.34	5.74	5.76	5.78	6.01	5.60	5.81	5.20	5.76	5.86	6.13	5.83

برای مقایسه نحوه عملکرد مدل‌ها در پیش‌بینی‌ها از نمودار استاندارد خطا برای مقادیر واقعی و پیش‌بینی‌ها در سال ۲۰۱۲ استفاده شده است که در شکل ۷ به نمایش گذاشته شده است.

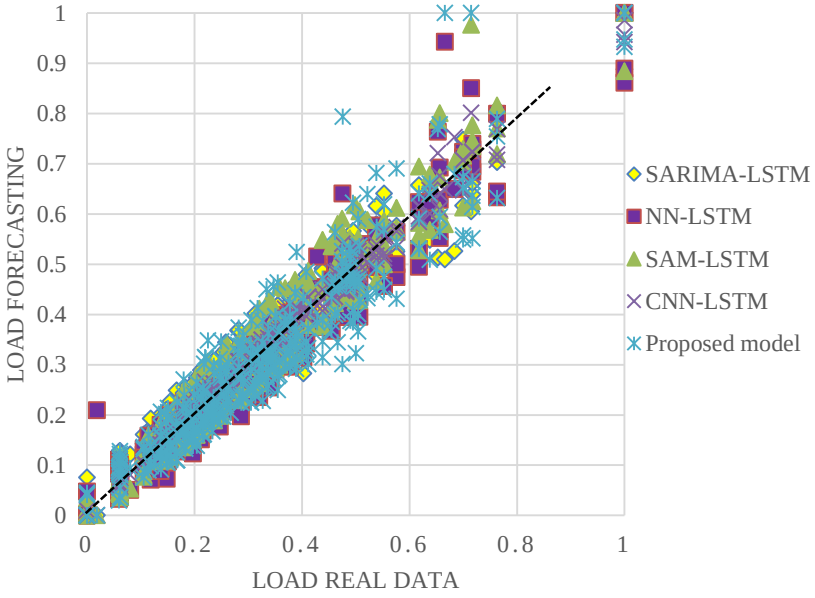


(a)

DOI: 10.30503/nripress.2020.147:

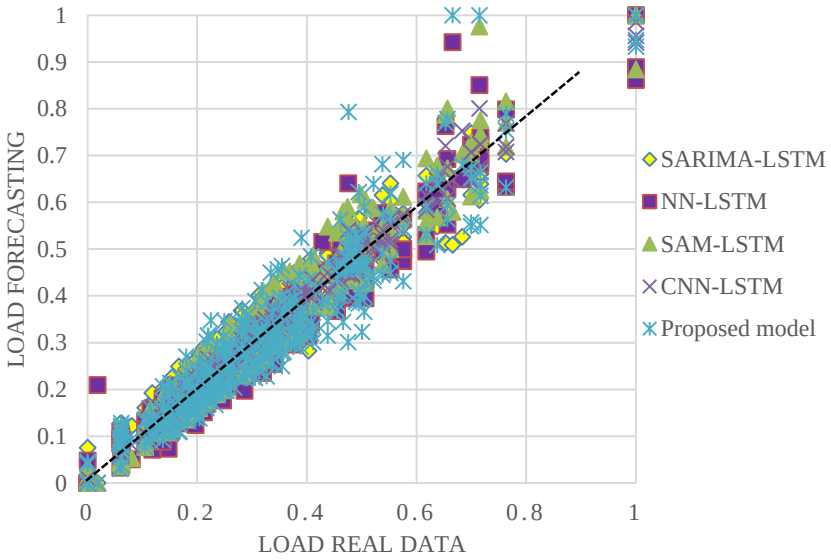


(b)



(c)

DOI: 10.30503/nripress.2020.147:

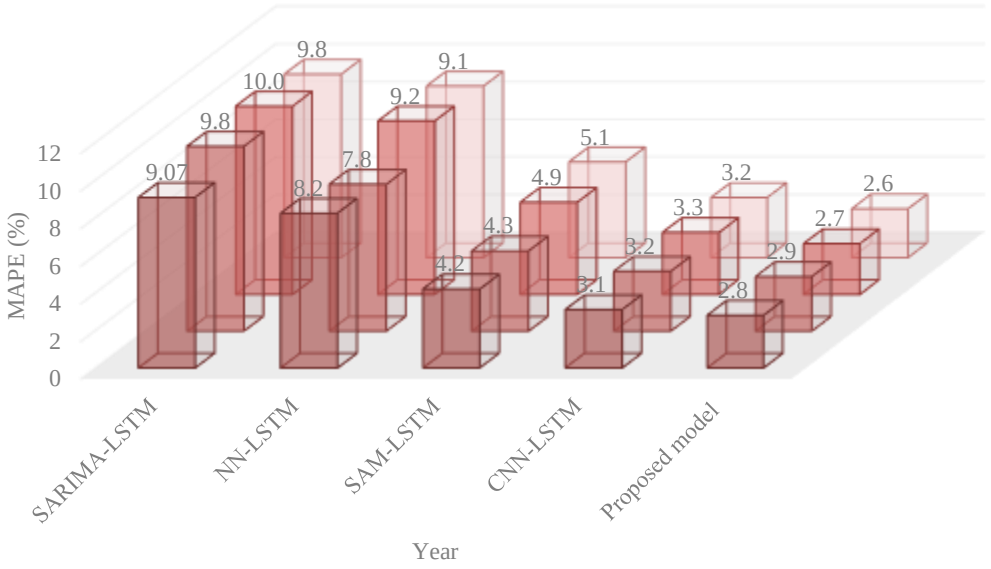


(d)

شکل ۱۲. مقایسه مقدار استاندارد خطای مدل هدف با دیگر مدل‌های موجود در a) بهار؛ b) تابستان؛ c) پاییز؛ d) زمستان سال ۲۰۱۲ برای برق منطقه‌ای تهران.

نتایج اجرای مدل هدف با دیگر مدل‌های موجود بر اساس شاخص MAPE که به‌طور متوسط برای سال ۲۰۱۲ در جدول ۱ محاسبه شده است نشان می‌دهد، مدل هدف نسبت به الگوریتم SARIMA-LSTM به‌میزان ۰٫۰۶۹درصد بهبود دارد. این بهبود نسبت به مدل NN-LSTM به‌میزان ۰٫۰۴۹درصد، نسبت به مدل SAM-LSTM به‌میزان ۰٫۰۱۴درصد و نسبت به CNN-LSTM ۰٫۰۰۳درصد بهبود داشته است. مدل هدف این تحلیل‌ها به‌صورت مشابه برای سال‌های 2017 تا 2019 نیز انجام گرفته است که نتایج نشان‌دهنده حفظ بهبود ایجادشده توسط مدل هدف، برای داده‌های مربوط به سه سال دیگر است. نتایج میانگین شاخص MAPE برای چهار سال تحت‌بررسی در شکل ۸ به نمایش گذاشته شده است.

DOI: 10.30503/nripress.2020.147:



شکل ۱۳. مقایسه مقدار MAPE مدل هدف با مدل‌های موجود در سال ۲۰۱۲ تا ۲۰۱۵ برای برق منطقه‌ای تهران

۳-۴- اعتبارسنجی مدل هدف

با درنظرگرفتن زوج‌های تصادفی با اندازه نمونه n، تعداد مقدارها با توجه به زوج‌بودن نمونه‌ها برابر با $2n$ خواهد بود. مشاهدات زوجی را نیز برحسب مؤلفه‌ها، به‌صورت $x_{1,i}$ و $x_{2,i}$ با توجه به $i = 1,2, \dots, n$ نشان می‌دهیم. در اینجا هدف از انجام آزمون فرض آماری، تعیین تفاوت در بین دو زوج‌ها است. به این ترتیب (Null Hypothesis) را یکسان‌بودن مقدارها در بین زوج‌ها در نظر گرفته و (Alternative Hypothesis) را هم وجود اختلاف در بین زوج‌ها محسوب می‌کنیم. [2] با توجه به این موضوعات، مراحل انجام آزمون مطابق با روش ویلکاکسون به‌صورت گام‌های ذیل است:

I. برای همه مشاهدات قدر مطلق اختلاف بین زوج‌ها $\left|x_{2,i} - x_{1,i}\right|$ به‌ازای $i = 1,2, \dots, n$ را محاسبه و علامت (مثبت یا منفی‌بودن) این اختلاف $sgn\left(x_{2,i} - x_{1,i}\right)$ مشخص می‌شود.

II. زوج‌هایی که مقدار تابع علامت برایشان صفر است از تحلیل خارج می‌شوند. به این ترتیب n_r را تعداد زوج‌های باقی‌مانده در نظر می‌گیریم؛ البته در مواقعی که اندازه نمونه خیلی کوچک باشد، برای آنکه تعداد مشاهدات کاهش نیابد می‌توان زوج‌هایی با این شرط را فقط در یکی از گروه‌های مقدار مثبت یا منفی ثبت کرد.

DOI: 10.30503/nripress.2020.147:

III. مقدارهای حاصل از قدر مطلق اختلاف‌ها یعنی $|x_{2,i} - x_{1,i}|$ را از کوچک به بزرگ مرتب می‌کنیم.

IV. رتبه‌های مربوط به قدر مطلق اختلاف‌ها را به دست می‌آوریم. واضح است که ممکن است رتبه‌های گره‌دار نیز برای بعضی از مقدارها به دست آید. در این حالت میانگین رتبه‌ها را برای چنین مشاهداتی در نظر می‌گیریم. به کوچک‌ترین مقدار اختلاف، رتبه ۱ داده شده و رتبه اختلاف برای زوج i را R_i نشان می‌دهیم.

V. آماره W را مطابق با معادله ۴۸ محاسبه می‌کنیم.

$$W = \sum_{i=1}^{n_r} [sgn\,(x_{2,i} - x_{1,i})\,.\,R_i\,] \qquad (48)$$

- آنچه که در معادله ۴۹ محاسبه شد به مجموع رتبه‌های علامت‌دار معروف است. تحت فرض صفر، توزیع احتمالی W پیچیده است؛ ولی میانگین آن برابر با صفر و واریانس آن نیز برابر با معادله ۴۹ است.

$$\sigma_w^2 = \frac{n_r\,(\,n_r + 1)(2n_r + 1)}{24} \qquad (49)$$

با وجود جدول‌های استاندارد این روش، اگر $|W| < W_{\alpha,nr}$ باشد، فرض صفر رد خواهد شد. نتایج جدول ۲ نشان‌دهنده معتبربودن نتایج مدل هدف در مقایسه با مدل‌های قبلی می‌باشد.

جدول ۵. Wilcoxon signed-rank test

Compared Model	Wilcoxon signed-rank test	
	=0.025, W=2α	=0.05, W=3α
SARIMA-LSTM	0	0
NN-LSTM	2	2
SAM-LSTM	3	3
CNN-LSTM	2	2

نتیجه‌گیری

DOI: 10.30503/nripress.2020.147:

برای برنامه‌ریزی دقیق زنجیره تأمین برق نیازمند پیش‌بینی‌های جدید متغیرهای کلیدی این حوزه است. یکی از مهم‌ترین این متغیرها، متغیر تقاضای بار الکتریکی می‌باشد که زمینهٔ بسیاری از آخرین تحقیقات صورت‌گرفته در حوزه برنامه‌ریزی انرژی می‌باشد. هدف از این تحقیق پیش‌بینی با بیشترین دقت این متغیر با استفاده از داده‌های تاریخی و همچنین با استفاده از روش‌های مبتنی بر هوش مصنوعی می‌باشد. در این تحقیق بر اساس مرور ادبیات صورت‌گرفته، از بین روش‌های موجود، از روش ترکیبی مبتنی بر یادگیری عمیق برای پیش‌بینی تقاضای بار الکتریکی استفاده شده است. داده‌های تاریخی مصرف بار الکتریکی توسط روش EMD به سیگنال‌های زیرمجموعه خود تجزیه می‌شود. در این مدل از مکانیزم هوشمندی با استفاده از روش WOA برای انتخاب بهترین تعداد سطوح تجزیه سیگنال توسط روش EMD و همچنین نحوه تقسیم‌بندی ورود سیگنال‌های تجزیه‌شده به هریک از دو شبکه عصبی استفاده شده است. از بین پارامترهای موجود در پایگاه داده‌ای، بهترین پارامترهای موجود که دقت بسیاری را در جواب نهایی ایجاد می‌کنند توسط روش PCA انتخاب می‌شوند. برای افزایش دقت مقادیر پیش‌بینی متغیر تقاضای بار الکتریکی از روش WTBPNN-EHO که مؤلفه‌های ورودی آن توسط روش تجزیه موجک تجزیه و اوزان آن توسط روش EHO بهینه‌سازی شده و روش LSTM به‌صورت موازی استفاده شد. نتایج خروجی هریک از دو شبکه عصبی با هم جمع می‌شود تا مقدار پیش‌بینی نهایی بار الکتریکی حاصل گردد. عملکرد این مدل، بر اساس داده‌های شبکه برق ایران با دیگر مدل‌های موجود مقایسه شد که نتایج نشان‌دهنده بهبود در دقت پیش‌بینی میان‌مدت و بلندمدت تقاضای بار الکتریکی توسط مدل هدف است. این پیش‌بینی‌ها نشان‌دهنده دقت در پیش‌بینی متغیر تقاضای بار الکتریکی در حدود ۳درصد می‌باشد. این پیش‌بینی‌ها برای سال ۲۰۱۲ الی ۲۰۱۵ نیز تکرار شده است. این نتایج از بهترین نتایج حاصل از روش ترکیبی CNN-LSTM در حدود ۱درصد بهبود یافته است. برای اعتبارسنجی نتایج از روش Wilcoxon signed-rank test استفاده شده است که نشان‌دهنده معتبربودن نتایج در تکرارهای بعدی صورت گرفته است. برای ادامه روند تحقیقات پیشنهاد می‌گردد علاوه بر انتخاب مکانیزمی برای انتخاب Featureها، روشی برای انتخاب فاکتورها نیز در این ساختار در نظر گرفته شود. همچنین پیشنهاد می‌گردد روشی هوشمند برای بهینه‌سازی پارامترهای شبکه‌های عصبی به‌صورت هم‌زمان در نظر گرفته شود.

فهرست منابع

۱. گزارش پروژه برنامه‌ریزی توسعه تولید در طراحی ساختار کلان راهبری شبکه برق ایران. طرح کلان راهبری شبکه برق ایران. پژوهشگاه نیرو. ۱۳۹۹.

۲. بررسی رابطه بین مصرف برق، قیمت برق و رشد اقتصادی در ایران، پژوهش‌ها و سیاست‌های اقتصادی، پاییز ۱۳۹۰, دوره ۱۹, شماره ۵۹ از صفحه ۱۷۵ تا صفحه ۱۹۹.

DOI: 10.30503/nripress.2020.147:

۳. فتحی‌پور, فریبا, سعیدی مهرآباد, محمد, شکوری گنجوی, حامد. (۱۳۹۸). 'مسئله برنامه‌ریزی انرژی پایدار مبتنی بر رویکرد تصادفی p- استوار', نشریه پژوهش‌های مهندسی صنایع در سیستم‌های تولید, ۷)۱۴(, pp. (۱-۱۱ :doi . ۲۰۱۹,۱۷۸۰۸,۱۸۰۹/ier.۱۰,۲۲۰۸۴.

4. Saeed Sepasi, Ehsan Reihani, Abdul M. Howlader, Leon R. Roose, Marc M. Matsuura. Very short term load forecasting of a distribution system with high PV penetration. Renewable Energy, Volume 106, June 2017, Pages 142-148.
5. Tanveer Ahmad, Huanxin Chen. Short and medium-term forecasting of cooling and heating load demand in building environment with data-mining based approaches. Energy and Buildings, Volume 166, 1 May 2018, Pages 460-476.
6. Matteo De Felice, Andrea Alessandri, Franco Catalano. Seasonal climate forecasts for medium-term electricity demand forecasting. Applied Energy, Volume 137, 1 January 2015, Pages 435-444
7. Danladi Ali, Michael Yohanna, M.I. Puwu, B.M. Garkida. Long-term load forecast modelling using a fuzzy logic approach. Pacific Science Review A: Natural Science and Engineering; 2016, 18(2). 123-127
8. Cheng-Ming Lee, Chia-Nan Ko, Short-term load forecasting using lifting scheme and ARIMA models, Expert Systems with Applications,Volume 38, Issue 5, 2011, Pages 5902-5911.
9. S. Trabelsi, Z. Elouedi, K. Mellouil, Pruning belief decision tree methods in averaging and conjunctive approaches, International Journal of Approximate Reasoning, Volume 46, Issue 3, 568–595, 2007.
10. M. Galar , A. Fernández, E. Barrenechea, H. Bustince , F. Herrera, Ordering-based pruning for improving the performance of ensembles of classifiers in the framework of imbalanced datasets, Information Sciences, Volume 354, 1 August 2016, Pages 178–196.
11. H. Zhao, X. Li, A cost sensitive decision tree algorithm based on weighted class distribution with batch deleting attribute mechanism, Information Sciences, Volume 378, 1, 303–316, 2017.
12. L. Breiman, J. Friedman, R. Olshen, C. Stone.Classification and Regression Trees. Wadsworth International Group, 1984.
13. Erasmo Cadenas, Wilfrido Rivera, Wind speed forecasting in the South Coast of Oaxaca, México, Renewable Energy, Volume 32, Issue 12, 2007, Pages 2116-2128.
14. Hsiao-Tien Pao, Hsin-Chia Fu, Cheng-Lung Tseng,Forecasting of CO2 emissions, energy consumption and economic growth in China using an improved grey model,Energy, Volume 40, Issue 1, 2012,Pages 400-409.

DOI: 10.30503/nripress.2020.147:

15. S Gonzales Chavez, J Xiberta Bernat, H Llaneza Coalla, Forecasting of energy production and consumption in Asturias (northern Spain), Energy, Volume 24, Issue 3, 1999, Pages 183-198,

16. Lon-Mu Liu, Maw-Wen Lin, Forecasting residential consumption of natural gas using monthly and quarterly time series, International Journal of Forecasting, Volume 7, Issue 1, 1991, Pages 3-16,

17. Nicholas Bowden, James E. Payne,Short term forecasting of electricity prices for MISO hubs: Evidence from ARIMA-EGARCH models,Energy Economics,Volume 30, Issue 6,2008,Pages 3186-3197.

18. Gordon Reikard, Predicting solar radiation at high resolutions: A comparison of time series forecasts, Solar Energy, Volume 83, Issue 3, 2009, Pages 342-349.
19. Kumar Biswajit Debnath, Monjur Mourshed . Forecasting methods in energy planning models. Renewable and Sustainable Energy Reviews, Volume 88, May 2018, Pages 297-325.

20. Xin Fu, Xiao-Jun Zeng, Pengpeng Feng, Xiuwen Cai, Clustering-based short-term load forecasting for residential electricity under the increasing-block pricing tariffs in China, Energy, Volume 165, Part B, 2018, Pages 76-89.

21. Song, Hyun Ah, and Soo-Young Lee. "Hierarchical Representation Using NMF." Neural Information Processing. Springer Berlin Heidelberg, 2013.
22. Olshausen, Bruno A. "Emergence of simple-cell receptive field properties by learning a sparse code for natural images." Nature 381.6583 (1996): 607-609.
23. Grzegorz Dudek, Pattern-based local linear regression models for short-term load forecasting, Electric Power Systems Research,Volume 130, 2016,Pages 139-14.
24. Niematallah Elamin, Mototsugu Fukushige, Modeling and forecasting hourly electricity demand by SARMAX with interactions, Energy, Volume 165, Part B, 2018,Pages 257-268.

25. Agostino Tarsitano, Ilaria L. Amerise, Short-term load forecasting using a two-stage sARMAX model, Energy,Volume 133, 2017, Pages 108-114.

26. Zhang M, Bao H, Yan L, Cao JP, Jian-Guang DU. Research on processing of short-term historical data of daily load based on kalman filter. Power Syst Technol 2003;10:1e9.
27. Yi Liang, Dongxiao Niu, Wei-Chiang Hong, Short Term Load Forecasting Based on Feature Extraction and Improved General Regression Neural Network model, Energy,2018, in press

28. Kouhi S, Keynia F. A new cascade NN based method to short-term load forecast in deregulated electricity market. Energy Convers Manag 2013;71 76e83.

DOI: 10.30503/nripress.2020.147:

29. Pai PF, Hong WC. Forecasting regional electricity load based on recurrent support vector machines with genetic algorithms. Elec Power Syst Res 2005;74:417e25.

30. Ghaleh khondabi,I.,Ardjmand,E.,Weckman,G.R.,Young,W.A.,2017."An overview of energy demand forecasting methods published in 2005–2015. Energy Systems 8(2), 411–447.

31. Chandra mowli,S.N., Felder,F.A.,2014. Impact of climate change on electricity systems and markets a review of models and forecasts. Sustainable Energy Technologies and Assessments5, 62–74.Retrieved. https://doi.org/10.1016/j.seta.2013.11.003.

32. Lindberg K. B., Seljom P., Madsen H., Fischere D., Korpås M., Long-term electricity load forecasting: Current and future trends. Utilities Policy, Volume 58, June 2019, Pages 102-119.

33. Grubler,A.,etal.,2012. Chapter1: energy primer. In: Global Energy Assessment (GEA) toward a Sustainable Future. International Institute for Applied Systems Analysis. Cambridge University Press, Cambridge, UK and NewYork, NY, USA, pp.99–150. And the International Institute for Applied Systems Analysis, Laxenburg, Austria. Retrieved. www.iiasa.ac.a. http://www.globalenergyassessment.org/.

34. Lund, P.D., Lindgren,J., Mikkola, J., Salpakari, J., 2015. Review of energy system flexibility measures to enable high levels of variable renewable electricity. Renew. Sustain. Energy Rev.45, 785–807.

35. Yang YL, Che JX, Li YY, Zhao YJ, Zhu SL. An incremental electric load forecasting model based on support vector regression. Energy 2017;113: 796e808.

36. Chenthur Pandian S, Duraiswamy K, Christober Asir Rajan C, Kanagaraj N. Fuzzy approach for short term load forecasting. Elec Power Syst Res 2006;76:541e8.

37. Ping-Feng Pai, Wei-Chiang Hong, Support vector machines with simulated annealing algorithms in electricity load forecasting, Energy Conversion and Management, Volume 46, Issue 17, 2005, Pages 2669-2688.

38. Abdollah Kavousi-Fard, Haidar Samet, Fatemeh Marzbani, A new hybrid Modified Firefly Algorithm and Support Vector Regression model for accurate Short Term Load Forecasting, Expert Systems with Applications,Volume 41, Issue 13, 2014, Pages 6047-6056.

39. Irani, R., & Nasimi, R. (2011). Evolving neural network using real coded genetic algorithm for permeability estimation of the reservoir. Expert Systems with Applications, 38(8), 9862–9866.

DOI: 10.30503/nripress.2020.147:

40. Zhang, J. R., Zhang, J., Lok, T. M., & Lyu, M. R. (2007). A hybrid particle swarm optimization-back-propagation algorithm for feedforward neural network training. Applied Mathematics and Computation, 185(2), 1026–1037.

41. Lin Wang, Yi Zeng, Tao Chen, Back propagation neural network with adaptive differential evolution algorithm for time series forecasting, Expert Systems with Applications, Volume 42, Issue 2, 2015, Pages 855-863,
42. Hao Wang, Wenjian Cai, Youyi Wang, Modeling of a hybrid ejector air conditioning system using artificial neural networks, Energy Conversion and Management, Volume 127, 2016, Pages 11-24.
43. Y. Le Cun, J. S. Denker, S. A. Solla.Optimal brain damage. In D. Touretzky, editor, Advances in Neural Information Processing Systems 2. Morgan Kaufmann, 1990.
44. S. A. Harp, T. Samad, A. Guha. Designing application-specific neural networks using the genetic algorithm. In D. S. Touretzky, editor, Advances in Neural Information Processing Systems II, 447–454. Morgan Kaufmann, 1990.

45. R. Jacobs. Increased rates of convergence through learning rate adaptation. Neural Networks, 1:295–307, 1988.

46. Y. Chauvin, D. Rumelhart, Backpropagation: Theory, Architectures, and Applications.Lawrence Erlbaum Assoc., 1995.

47. G. Yang, J. F. Qiao, A fast and efficient two-phase sequential learning algorithm for spatial architecture neural network, Applied Soft Computing, 25, 129–138, 2014.

48. X.Xu, G. Wang, A new method for constructing granular neural networks based on rule extraction and extreme learning machine, Pattern Recognition Letters, Volume 67, Part 2, 138-144, 2015.

49. E. Bas, V.RezanUslu, E.Egrioglu, Robust learning algorithm for multiplicative neuron model artificial neural networks, Expert Systems with Applications, Volume 56, 80-88, 2016.

50. Zadeh L.A., Fuzzy set Information and Control, 3(3), pp. 338-353, 1965.

51. Castellano G., Fanelli A., Mencar C., "A Fuzzy Clustering Approach for Mining Diagnostic Rules", in: Proceedings of IEEE Conference on Systems, Man and Cybernetics, Washington, USA, 2003.

52. A. R. Abas, Adaptive competitive learning neural networks, Egyptian Informatics Journal, Volume 14, Issue 3, Pages 183-194, 2013.

DOI: 10.30503/nripress.2020.147:

53. Kumar Biswajit Debnath, Monjur Mourshed, Forecasting methods in energy planning models, Renewable and Sustainable Energy Reviews,Volume 88, 2018, Pages 297-325, ISSN 1364-0321, https://doi.org/10.1016/j.rser.2018.02.002.

54. Priyanka Singh, Pragya Dwivedi, Integration of new evolutionary approach with artificial neural network for solving short term load forecast problem, Applied Energy, Volume 217, 2018, Pages 537-549, ISSN 0306-2619, https://doi.org/10.1016/j.apenergy.2018.02.131.

55. Tanveer Ahmad, Hongcai Zhang, Novel deep supervised ML models with feature selection approach for large-scale utilities and buildings short and medium-term load requirement forecasts, Energy, Volume 209, 2020, 118477, ISSN 0360-5442, https://doi.org/10.1016/j.energy.2020.118477.

56. Woohyun Kim, Yerim Han, Kyoung Jae Kim, Kwan-Woo Song, Electricity load forecasting using advanced feature selection and optimal deep learning model for the variable refrigerant flow systems, Energy Reports, Volume 6,2020, Pages 2604-2618, ISSN 2352-4847, https://doi.org/10.1016/j.egyr.2020.09.019.

57. Yeming Dai, Pei Zhao, A hybrid load forecasting model based on support vector machine with intelligent methods for feature selection and parameter optimization, Applied Energy, Volume 279, 2020, 115332, ISSN 0306-2619, https://doi.org/10.1016/j.apenergy.2020.115332.

58. Tanveer Ahmad, Hongcai Zhang, Novel deep supervised ML models with feature selection approach for large-scale utilities and buildings short and medium-term load requirement forecasts, Energy, Volume 209, 2020, 118477, ISSN 0360-5442, https://doi.org/10.1016/j.energy.2020.118477.

59. Noradin Ghadimi, Adel Akbarimajd, Hossein Shayeghi, Oveis Abedinia,Two stage forecast engine with feature selection technique and improved meta-heuristic algorithm for electricity load forecasting, Energy,Volume 161, 2018, Pages 130-142, ISSN 0360-5442, https://doi.org/10.1016/j.energy.2018.07.088.

DOI: 10.30503/nripress.2020.147:

60. Ailing Yang, Weide Li, Xuan Yang, Short-term electricity load forecasting based on feature selection and Least Squares Support Vector Machines, Knowledge-Based Systems, Volume 163, 2019, Pages 159-173, ISSN 0950-7051, https://doi.org/10.1016/j.knosys.2018.08.027.

61. Gowri Suryanarayana, Jesus Lago, Davy Geysen, Piotr Aleksiejuk, Christian Johansson, Thermal load forecasting in district heating networks using deep learning and advanced feature selection methods, Energy, Volume 157, 2018, Pages 141-149, ISSN 0360-5442, https://doi.org/10.1016/j.energy.2018.05.111.

62. Ting Wang, Chun Sing Lai, Wing W.Y. Ng, Keda Pan, Mingyang Zhang, Alfredo Vaccaro, Loi Lei Lai, Deep autoencoder with localized stochastic sensitivity for short-term load forecasting, International Journal of Electrical Power & Energy Systems, Volume 130, 2021, 106954, ISSN 0142-0615, https://doi.org/10.1016/j.ijepes.2021.106954.

63. Linfei Yin, Jiaxing Xie, Multi-temporal-spatial-scale temporal convolution network for short-term load forecasting of power systems, Applied Energy, Volume 283, 2021, 116328, ISSN 0306-2619, https://doi.org/10.1016/j.apenergy.2020.116328.

64. Xifeng Guo, Ye Gao, Yupeng Li, Di Zheng, Dan Shan, Short-term household load forecasting based on Long- and Short-term Time-series network, Energy Reports, Volume 7, Supplement 1, 2021, Pages 58-64, ISSN 2352-4847, https://doi.org/10.1016/j.egyr.2021.02.023.

65. Hosein Eskandari, Maryam Imani, Mohsen Parsa Moghaddam, Convolutional and recurrent neural network based model for short-term load forecasting, Electric Power Systems Research, Volume 195,2021, 107173, ISSN 0378-7796, https://doi.org/10.1016/j.epsr.2021.107173.

66. Weilin Guo, Liang Che, Mohammad Shahidehpour, Xin Wan, Machine-Learning based methods in short-term load forecasting, The Electricity Journal, Volume 34, Issue 1, 2021, 106884, ISSN 1040-6190, https://doi.org/10.1016/j.tej.2020.106884.

67. Yi Dong, Zhen Dong, Tianqiao Zhao, Zhongguo Li, Zhengtao Ding, Short term load forecasting with markovian switching distributed deep belief networks, International Journal of Electrical Power & Energy Systems, Volume 130, 2021, 106942, ISSN 0142-0615, https://doi.org/10.1016/j.ijepes.2021.106942.

DOI: 10.30503/nripress.2020.147:

68. Lechen Li, Christoph J. Meinrenken, Vijay Modi, Patricia J. Culligan, Short-term apartment-level load forecasting using a modified neural network with selected auto-regressive features, Applied Energy, Volume 287, 2021, 116509, ISSN 0306-2619, https://doi.org/10.1016/j.apenergy.2021.116509.

69. Yi Hu, Boyang Qu, Jie Wang, Jing Liang, Yanli Wang, Kunjie Yu, Yaxin Li, Kangjia Qiao, Short-term load forecasting using multimodal evolutionary algorithm and random vector functional link network based ensemble learning, Applied Energy, Volume 285, 2021,116415, ISSN 0306-2619, https://doi.org/10.1016/j.apenergy.2020.116415.

70. Amine Bellahsen, Hanane Dagdougui, Aggregated short-term load forecasting for heterogeneous buildings using machine learning with peak estimation, Energy and Buildings, Volume 237, 2021, 110742, ISSN 0378-7788, https://doi.org/10.1016/j.enbuild.2021.110742.

71. Xuedong Wu, Yaonan Wang, Yingjie Bai, Zhiyu Zhu, Aiming Xia,Online short-term load forecasting methods using hybrids of single multiplicative neuron model, particle swarm optimization variants and nonlinear filters, Energy Reports, Volume 7, 2021, Pages 683-692, ISSN 2352-4847, https://doi.org/10.1016/j.egyr.2021.01.030.

72. Chen Li, A fuzzy theory-based machine learning method for workdays and weekends short-term load forecasting, Energy and Buildings, 2021, 111072, ISSN 0378-7788, https://doi.org/10.1016/j.enbuild.2021.111072.

73. Yuntian Chen, Dongxiao Zhang, Theory-guided deep-learning for electrical load forecasting (TgDLF) via ensemble long short-term memory, Advances in Applied Energy, Volume 1, 2021, 100004, ISSN 2666-7924, https://doi.org/10.1016/j.adapen.2020.100004.

74. Yuanyuan Wang, Shanfeng Sun, Xiaoqiao Chen, Xiangjun Zeng, Yang Kong, Jun Chen, Yongsheng Guo, Tingyuan Wang, Short-term load forecasting of industrial customers based on SVMD and XGBoost, International Journal of Electrical Power & Energy Systems, Volume 129, 2021, 106830, ISSN 0142-0615, https://doi.org/10.1016/j.ijepes.2021.106830.

75. Shouxiang Wang, Xinyu Deng, Haiwen Chen, Qingyuan Shi, Di Xu, A bottom-up short-term residential load forecasting approach based on appliance characteristic analysis and multi-task learning, Electric Power Systems Research, Volume 196, 2021, 107233, ISSN 0378-7796, https://doi.org/10.1016/j.epsr.2021.107233.

76. Mohamed Massaoudi, Shady S. Refaat, Ines Chihi, Mohamed Trabelsi, Fakhreddine S. Oueslati, Haitham Abu-Rub, A novel stacked generalization ensemble-based

DOI: 10.30503/nripress.2020.147:

hybrid LGBM-XGB-MLP model for Short-Term Load Forecasting, Energy, Volume 214, 2021, 118874, ISSN 0360-5442, https://doi.org/10.1016/j.energy.2020.118874.

77. Gholamreza Memarzadeh, Farshid Keynia, Short-term electricity load and price forecasting by a new optimal LSTM-NN based prediction algorithm, Electric Power Systems Research, Volume 192, 2021, 106995, ISSN 0378-7796, https://doi.org/10.1016/j.epsr.2020.106995.

78. Tanveer Ahmad, Huanxin Chen, Jan Shair, Chengliang Xu, Deployment of data-mining short and medium-term horizon cooling load forecasting models for building energy optimization and management, International Journal of Refrigeration, Volume 98, 2019, Pages 399-409, ISSN 0140-7007, https://doi.org/10.1016/j.ijrefrig.2018.10.017.

79. Tanveer Ahmad, Hongcai Zhang, Novel deep supervised ML models with feature selection approach for large-scale utilities and buildings short and medium-term load requirement forecasts, Energy, Volume 209, 2020, 118477, ISSN 0360-5442, https://doi.org/10.1016/j.energy.2020.118477.

80. Tanveer Ahmad, Huanxin Chen, Short and medium-term forecasting of cooling and heating load demand in building environment with data-mining based approaches, Energy and Buildings, Volume 166, 2018, Pages 460-476, ISSN 0378-7788, https://doi.org/10.1016/j.enbuild.2018.01.066.

81. M. Salami, F. Movahedi Sobhani and M. Sadegh Ghazizadeh, "Evaluating Power Consumption Model and Load Deficit at Different Temperatures Using Clustering Techniques and Presenting a Strategy for Changing Production Management," 2020 IEEE Third International Conference on Data Stream Mining & Processing (DSMP), 2020, pp. 341-345, doi: 10.1109/DSMP47368.2020.9204247.

82. Salami, M., Movahedi Sobhani, F., Ghazizadeh, M. (2018). 'Multi-Objective Model for Fair Pricing of Electricity Using the Parameters from the Iran Electricity Market Big Data Analysis', International Journal of Industrial Mathematics, 10(4), pp. 359-374.

83. Kumar Biswajit Debnath, Monjur Mourshed, Forecasting methods in energy planning models, Renewable and Sustainable Energy Reviews, Volume 88, 2018, Pages 297-325, ISSN 1364-0321, https://doi.org/10.1016/j.rser.2018.02.002.

84. Gonggui Chen, Bangrui Tang, Xianjun Zeng, Ping Zhou, Peng Kang, Hongyu Long, Short-term wind speed forecasting based on long short-term memory and improved BP neural network, International Journal of Electrical Power & Energy Systems, Volume 134, 2022, 107365, ISSN 0142-0615, https://doi.org/10.1016/j.ijepes.2021.107365.

DOI: 10.30503/nripress.2020.147:

85. Zheng Zhang, Xinyu Wu, Shengli Liao, Chuntian Cheng, An ultra-short-term scheduling model for cascade hydropower regulated by multilevel dispatch centers suppressing wind power volatility, International Journal of Electrical Power & Energy Systems, Volume 134, 2022, 107467, ISSN 0142-0615, https://doi.org/10.1016/j.ijepes.2021.107467.

86. Grzegorz Dudek, Pattern-based local linear regression models for short-term load forecasting, Electric Power Systems Research,Volume 130, 2016,Pages 139-14.

87. Hsiao-Tien Pao,Comparing linear and nonlinear forecasts for Taiwan's electricity consumption, Energy, Volume 31, Issue 12, 2006, Pages 2129-2141, ISSN 0360-5442, https://doi.org/10.1016/j.energy.2005.08.010.

88. Cheng-Ming Lee, Chia-Nan Ko, Short-term load forecasting using lifting scheme and ARIMA models, Expert Systems with Applications,Volume 38, Issue 5, 2011, Pages 5902-5911.

89. E. Cadenas, O.A. Jaramillo, W. Rivera,Analysis and forecasting of wind velocity in chetumal, quintana roo, using the single exponential smoothing method, Renewable Energy, Volume 35, Issue 5, 2010, Pages 925-930, ISSN 0960-1481, https://doi.org/10.1016/j.renene.2009.10.037.

90. Samer Saab, Elie Badr, George Nasr, Univariate modeling and forecasting of energy consumption: the case of electricity in Lebanon, Energy, Volume 26, Issue 1, 2001, Pages 1-14, ISSN 0360-5442, https://doi.org/10.1016/S0360-5442(00)00049-9.

91. Suling Zhu, Jianzhou Wang, Weigang Zhao, Jujie Wang, A seasonal hybrid procedure for electricity demand forecasting in China, Applied Energy, Volume 88, Issue 11, 2011, Pages 3807-3815, ISSN 0306-2619, https://doi.org/10.1016/j.apenergy.2011.05.005.
92. Yuanyuan Wang, Jianzhou Wang, Ge Zhao, Yao Dong, Application of residual modification approach in seasonal ARIMA for electricity demand forecasting: A case study of China, Energy Policy, Volume 48, 2012, Pages 284-294, ISSN 0301-4215, https://doi.org/10.1016/j.enpol.2012.05.026.
93. Emily Hickey, David G. Loomis, Hassan Mohammadi, Forecasting hourly electricity prices using ARMAX–GARCH models: An application to MISO hubs, Energy Economics, Volume 34, Issue 1, 2012, Pages 307-315, ISSN 0140-9883, https://doi.org/10.1016/j.eneco.2011.11.011.
94. Dongxiao Niu, Yongli Wang, Desheng Dash Wu, Power load forecasting using support vector machine and ant colony optimization, Expert Systems with Applications, Volume 37, Issue 3, 2010, Pages 2531-2539, ISSN 0957-4174, https://doi.org/10.1016/j.eswa.2009.08.019.
95. M. A. Behrang, E. Assareh, M. R. Assari & A. Ghanbarzadeh (2011) Using Bees Algorithm and Artificial Neural Network to Forecast World Carbon Dioxide Emission, Energy Sources, Part A: Recovery, Utilization, and Environmental Effects, 33:19, 1747-1759, DOI: 10.1080/15567036.2010.493920.

DOI: 10.30503/nripress.2020.147:

96. Wei-Chiang Hong, Electric load forecasting by seasonal recurrent SVR (support vector regression) with chaotic artificial bee colony algorithm, Energy, Volume 36, Issue 9, 2011, Pages 5568-5578, ISSN 0360-5442, https://doi.org/10.1016/j.energy.2011.07.015.
97. Salami, M.; Movahedi Sobhani, F.; Ghazizadeh, M.S. Short-Term Forecasting of Electricity Supply and Demand by Using the Wavelet-PSO-NNs-SO Technique for Searching in Big Data of Iran's Electricity Market. Data 2018, 3, 43. https://doi.org/10.3390/data3040043
98. Fuh-Yuh Ju, Wei-Chiang Hong, Application of seasonal SVR with chaotic gravitational search algorithm in electricity forecasting, Applied Mathematical Modelling, Volume 37, Issue 23, 2013, Pages 9643-9651, ISSN 0307-904X, https://doi.org/10.1016/j.apm.2013.05.016.
99. Salami, Mesbaholdin, Sobhani, Farzad Movahedi and Ghazizadeh, Mohammad Sadegh. "Shared Subscribe Hyper Simulation Optimization (SUBHSO) Algorithm for Clustering Big Data – Using Big Databases of Iran Electricity Market" Applied Computer Systems, vol.24, no.1, 2019, pp.49-60.https://doi.org/10.2478/acss-2019-0007.
100. Xifeng Guo, Ye Gao, Yupeng Li, Di Zheng, Dan Shan, Short-term household load forecasting based on Long- and Short-term Time-series network, Energy Reports, Volume 7, Supplement 1, 2021, Pages 58-64, ISSN 2352-4847, https://doi.org/10.1016/j.egyr.2021.02.023.
101. Yi Liang, Dongxiao Niu, Wei-Chiang Hong, Short term load forecasting based on feature extraction and improved general regression neural network model, Energy, Volume 166, 2019, Pages 653-663, ISSN 0360-5442, https://doi.org/10.1016/j.energy.2018.10.119.
102. Salami, M., Sobhani, F.M. & Ghazizadeh, M.S. A hybrid short-term load forecasting model developed by factor and feature selection algorithms using improved grasshopper optimization algorithm and principal component analysis. Electr Eng 102, 437–460 (2020). https://doi.org/10.1007/s00202-019-00886-7.
103. Luis A. Díaz-Robles, Juan C. Ortega, Joshua S. Fu, Gregory D. Reed, Judith C. Chow, John G. Watson, Juan A. Moncada-Herrera, A hybrid ARIMA and artificial neural networks model to forecast particulate matter in urban areas: The case of Temuco, Chile, Atmospheric Environment, Volume 42, Issue 35, 2008, Pages 8331-8340, ISSN 1352-2310, https://doi.org/10.1016/j.atmosenv.2008.07.020.
104. Jinliang Zhang, Yi-Ming Wei, Dezhi Li, Zhongfu Tan, Jianhua Zhou, Short term electricity load forecasting using a hybrid model, Energy, Volume 158, 2018, Pages 774-781, ISSN 0360-5442, https://doi.org/10.1016/j.energy.2018.06.012.
105. Yi Wang, Dahua Gan, Mingyang Sun, Ning Zhang, Zongxiang Lu, Chongqing Kang, Probabilistic individual load forecasting using pinball loss guided LSTM, Applied Energy, Volume 235, 2019, Pages 10-20, ISSN 0306-2619, https://doi.org/10.1016/j.apenergy.2018.10.078.
106. Jiaqi Qin, Yi Zhang, Shixiong Fan, Xiaonan Hu, Yongqiang Huang, Zexin Lu, Yan Liu, Multi-task short-term reactive and active load forecasting method based on attention-LSTM model, International Journal of Electrical Power & Energy Systems,

DOI: 10.30503/nripress.2020.147:

Volume 135, 2022, 107517, ISSN 0142-0615, https://doi.org/10.1016/j.ijepes.2021.107517.

107. Gholamreza Memarzadeh, Farshid Keynia, Short-term electricity load and price forecasting by a new optimal LSTM-NN based prediction algorithm, Electric Power Systems Research, Volume 192, 2021, 106995, ISSN 0378-7796, https://doi.org/10.1016/j.epsr.2020.106995.
108. Neelam Mughees, Syed Ali Mohsin, Abdullah Mughees, Anam Mughees, Deep sequence to sequence Bi-LSTM neural networks for day-ahead peak load forecasting, Expert Systems with Applications, Volume 175, 2021, 114844, ISSN 0957-4174, https://doi.org/10.1016/j.eswa.2021.114844.
109. Ashutosh Kumar Dubey, Abhishek Kumar, Vicente García-Díaz, Arpit Kumar Sharma, Kishan Kanhaiya, Study and analysis of SARIMA and LSTM in forecasting time series data, Sustainable Energy Technologies and Assessments, Volume 47, 2021, 101474, ISSN 2213-1388, https://doi.org/10.1016/j.seta.2021.101474.
110. Xifeng Guo, Qiannan Zhao, Di Zheng, Yi Ning, Ye Gao, A short-term load forecasting model of multi-scale CNN-LSTM hybrid neural network considering the real-time electricity price, Energy Reports, Volume 6, Supplement 9, 2020, Pages 1046-1053, ISSN 2352-4847, https://doi.org/10.1016/j.egyr.2020.11.078.
111. Haixiang Zang, Ruiqi Xu, Lilin Cheng, Tao Ding, Ling Liu, Zhinong Wei, Guoqiang Sun, Residential load forecasting based on LSTM fusing self-attention mechanism with pooling, Energy, Volume 229, 2021, 120682, ISSN 0360-5442, https://doi.org/10.1016/j.energy.2021.120682.
112. M. Salami, M. R. Niakan and M. Hasani, "Electricity Load Forecasting: A New Hybrid Model Combining Wavelet Transform, Genetic Algorithm and LSTM Models," 2021 International Conference on Electrical, Computer, Communications and Mechatronics Engineering (ICECCME), 2021, pp. 1-6, doi: 10.1109/ICECCME52200.2021.9591091.
113. Aleksey V. Kychkin, Georgios C. Chasparis, Feature and model selection for day-ahead electricity-load forecasting in residential buildings, Energy and Buildings, Volume 249, 2021, 111200, ISSN 0378-7788, https://doi.org/10.1016/j.enbuild.2021.111200.
114. Noradin Ghadimi, Adel Akbarimajd, Hossein Shayeghi, Oveis Abedinia, Two stage forecast engine with feature selection technique and improved meta-heuristic algorithm for electricity load forecasting, Energy, Volume 161, 2018, Pages 130-142, ISSN 0360-5442, https://doi.org/10.1016/j.energy.2018.07.088.
115. Yeming Dai, Pei Zhao, A hybrid load forecasting model based on support vector machine with intelligent methods for feature selection and parameter optimization, Applied Energy, Volume 279, 2020, 115332, ISSN 0306-2619, https://doi.org/10.1016/j.apenergy.2020.115332.
116. Tanveer Ahmad, Hongcai Zhang, Novel deep supervised ML models with feature selection approach for large-scale utilities and buildings short and medium-term load requirement forecasts, Energy, Volume 209, 2020, 118477, ISSN 0360-5442, https://doi.org/10.1016/j.energy.2020.118477.
117. Zhongyi Hu, Yukun Bao, Raymond Chiong, Tao Xiong, Mid-term interval load forecasting using multi-output support vector regression with a memetic algorithm for

DOI: 10.30503/nripress.2020.147:

feature selection, Energy, Volume 84, 2015, Pages 419-431, ISSN 0360-5442, https://doi.org/10.1016/j.energy.2015.03.054.

118. Zhongyi Hu, Yukun Bao, Raymond Chiong, Tao Xiong, Mid-term interval load forecasting using multi-output support vector regression with a memetic algorithm for feature selection, Energy, Volume 84, 2015, Pages 419-431, ISSN 0360-5442, https://doi.org/10.1016/j.energy.2015.03.054.
119. Sungkono, Ayi S. Bahri, Dwa D. Warnana, Fernando A. Monteiro Santos, Bagus J. Santosa, Fast, simultaneous and robust VLF-EM data denoising and reconstruction via multivariate empirical mode decomposition, Computers & Geosciences, Volume 67, 2014, Pages 125-138, ISSN 0098-3004, https://doi.org/10.1016/j.cageo.2014.03.007.
120. M.A. Tawhid, A.M. Ibrahim, Solving nonlinear systems and unconstrained optimization problems by hybridizing whale optimization algorithm and flower pollination algorithm, Mathematics and Computers in Simulation, Volume 190, 2021, Pages 1342-1369, ISSN 0378-4754, https://doi.org/10.1016/j.matcom.2021.07.010.
121. Loong Chuen Lee, Abdul Aziz Jemain, On overview of PCA application strategy in processing high dimensionality forensic data, Microchemical Journal, Volume 169, 2021, 106608, ISSN 0026-265X, https://doi.org/10.1016/j.microc.2021.106608.
122. Jing Chen, Yingjiao Rong, Quanmin Zhu, Budi Chandra, Hongxiu Zhong, A generalized minimal residual based iterative back propagation algorithm for polynomial nonlinear models, Systems & Control Letters, Volume 153, 2021, 104966, ISSN 0167-6911, https://doi.org/10.1016/j.sysconle.2021.104966.
123. C.W. Dawson, R.J. Abrahart, L.M. See, HydroTest: a web-based toolbox of evaluation metrics for the standardised assessment of hydrological forecasts, Environ. Modell. Software 22 (2007) 1034–1052.
124. Dimitrios Bagkavos, Prakash N. Patil, Improving the Wilcoxon signed rank test by a kernel smooth probability integral transformation, Statistics & Probability Letters, Volume 171, 2021, 109026, ISSN 0167-7152, https://doi.org/10.1016/j.spl.2020.109026.