



Technovations of Electrical Engineering in Green Energy System

Research Article

(2023) 2(1):117-139

A Hybrid Method for Long-Term Demand Forecasting in the Electrical Energy Supply Chain of Basic Metal Production Industries in the Presence of Incomplete Data

Sepehr Moalem¹, *PhD Student*, Roya M.P. Ahari¹, *Assistant Professor*, Ghazanfar Shahgholian^{2,3}, *Associate Professor*, Majid Moazzami^{2,3}, *Associate Professor*, Seyed Mohammad Kazemi¹, *Assistant Professor*

¹ Industrial Engineering Department, Najafabad Branch, Islamic Azad University, Najafabad, Iran

² Department of Electrical Engineering, Najafabad Branch, Islamic Azad University, Najafabad, Iran

³ Smart Microgrid Research Center, Najafabad Branch, Islamic Azad University, Najafabad, Iran

Abstract:

The economic growth of any country has a lot to do with the infrastructure of the electrical energy supply chain and the ability to access it at low cost. Increasing the resilience of the electric energy supply chain in order to be able to respond to the real time demand of high-consumption and strategic consumers is a challenge that will not be possible without considering long-term demand forecasting and integrated development planning of this chain. This paper presents a long-term demand forecasting approach in the electrical energy supply chain of Isfahan's Espidan iron stone industries. This approach is a combination of wavelet transform, long short-term memory (LSTM) network and finally integrating the results with data-mining technique based on machine learning. The company studied in this research is one of the main suppliers of raw materials in the supply chain of basic metal production industries and one of the ten energy-intensive industries in the electrical energy supply chain of Isfahan province. The only information available from this company is the daily time series signal of the historical electrical energy demand of this industry in a period of 40 months. The data in the studied time series is interrupted so that only 50% of the data has a value and the remaining 50% is zero. This lack of data and the impossibility of access to supplementary data and effective features for forecasting has reduced the density of data and the possibility of long-term demand forecasting faces more problems than continuous time series. The used statistical analysis showed that the annual and seasonal data do not follow the normal distribution and have high distortion and heterogeneity. The proposed method and its results have been compared with other available approaches. The results of 10 iterations of extreme learning machine methods show that the RELM technique with a high confidence level of 95% is more effective than other machine learning methods and has more accurate results.

Keywords: Wavelet transform, Long short-term memory, Regulated extreme learning machine, Long-term forecasting, Electrical energy supply chain, Mean absolute percentage error.

Received: 26 October 2022

Revised: 18 December 2022

Accepted: 08 January 2023

Corresponding Author: Dr. Roya M.P. Ahari, roya.ahari@gmail.com

DOI: <http://dx.doi.org/teeges.2023.1974408.1051>



یک روش ترکیبی پیش‌بینی بلندمدت تقاضا در زنجیره تامین انرژی الکتریکی صنایع تولید فلزات اساسی در حضور داده‌های ناقص

سپهر معلم^۱، دانشجوی دکتری، رویا محمدعلی پور اهری^۱، استادیار، غضنفر شاهقلیان^۲، دانشیار، مجید معظمی^۳، دانشیار، سید محمد کاظمی^۱، استادیار

۱- دانشکده مهندسی صنایع، واحد نجف‌آباد، دانشگاه آزاد اسلامی، نجف‌آباد، ایران

۲- دانشکده مهندسی برق، واحد نجف‌آباد، دانشگاه آزاد اسلامی، نجف‌آباد، ایران

۳- مرکز تحقیقات ریزشبکه‌های هوشمند، واحد نجف‌آباد، دانشگاه آزاد اسلامی، نجف‌آباد، ایران

چکیده: رشد اقتصادی هر کشوری ارتباط زیادی با زیرساخت‌های زنجیره تامین انرژی الکتریکی و قابلیت دسترسی کم‌هزینه به آن دارد. بالا بردن تاب‌آوری زنجیره تامین انرژی الکتریکی جهت قابلیت پاسخگویی به تقاضای لحظه‌ای مشترکین پرمصرف و استراتژیک چالشی است که بدون در نظر گرفتن پیش‌بینی بلندمدت تقاضا و برنامه‌ریزی توسعه یکپارچه این زنجیره ممکن نخواهد بود. در این مقاله یک رویکرد پیش‌بینی بلندمدت تقاضا در زنجیره تامین انرژی الکتریکی صنایع سنگ آهن اسپیدان اصفهان با استفاده از ترکیب تبدیل موجک، شبکه عصبی مبتنی بر یادگیری عمیق (LSTM) و در نهایت ادغام نتایج با تکنیک داده‌کاوی مبتنی بر ماشین یادگیری شدید تنظیم شده پیشنهاد شده است. شرکت مورد مطالعه در این تحقیق از تامین‌کنندگان اصلی مواد اولیه در زنجیره تامین صنایع تولید فلزات اساسی و یکی از ده صنعت انرژی‌بر در زنجیره تامین انرژی الکتریکی استان اصفهان است. تنها اطلاعات موجود و در دسترس از این شرکت سری زمانی سیگنال تقاضای تاریخی انرژی الکتریکی این صنعت در یک بازه زمانی ۴۰ ماهه و به صورت ۲۴ ساعته می‌باشد. داده‌ها در سری زمانی مورد مطالعه منقطع است به طوری که فقط ۵۰ درصد از داده‌ها دارای مقدار و ۵۰ درصد مابقی صفر می‌باشد. این نقصان داده و عدم امکان دسترسی به داده‌های مکمل و ویژگی‌های مؤثر جهت پیش‌بینی باعث کاهش تراکم داده‌ها شده و امکان پیش‌بینی تقاضای بلندمدت را نسبت به سری‌های زمانی پیوسته با مشکلات بیشتری روبرو می‌کند. آنالیز آماری بکار رفته نشان داد که داده‌های سالانه و فصلی از توزیع نرمال پیروی نمی‌کند و دارای تورش و ناهمگونی بالایی می‌باشد. روش پیشنهادی و نتایج حاصل از آن با سایر روش‌های موجود مورد مقایسه قرار گرفته است. نتایج حاصل از ۱۰ تکرار روش‌های ماشین یادگیری شدید نشان می‌دهد که تکنیک (RELM) با سطح اطمینان بالای ۹۵٪ از سایر روش‌های یادگیری ماشین مؤثرتر و نتایج دقیق‌تری دارد.

واژه‌های کلیدی: تبدیل موجک، حافظه کوتاه مدت بلند، ماشین یادگیری شدید تنظیم شده، پیش‌بینی بلند مدت، زنجیره تامین انرژی الکتریکی، میانگین مطلق درصد خطا.


تاریخ ارسال مقاله: ۱۴۰۱/۰۸/۰۴

تاریخ بازنگری مقاله: ۱۴۰۱/۰۹/۲۷

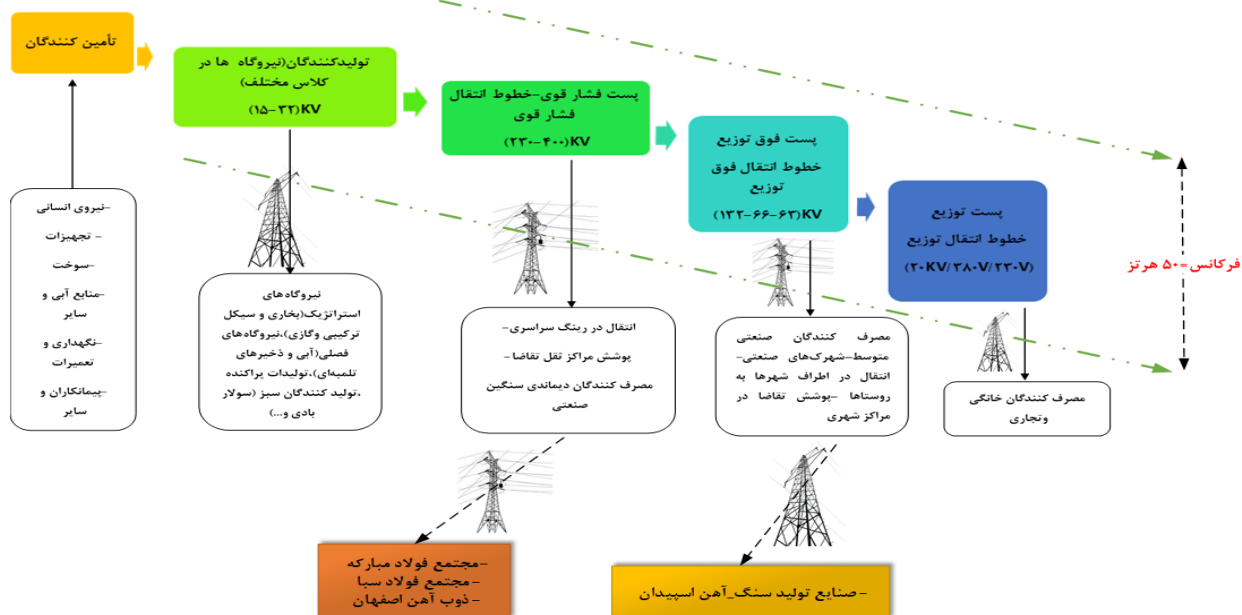
تاریخ پذیرش مقاله: ۱۴۰۱/۱۰/۱۸

نویسنده‌ی مسئول: دکتر رویا محمدعلی پور اهری، roya.ahari@gmail.com

DOI: <http://dx.doi.org/10.30486/teeges.2023.1974408.1051>



تلاش محققان و پژوهشگران در زمینه زنجیره تأمین در طی سال‌های گذشته، در پی یکپارچه شدن فرآیندها و کاهش هزینه صنایع و نهادهای تجاری و صنعتی مختلف و در جهت رقابتی شدن و چابک شدن تراکنش‌ها و فعالیت‌های مرتبط تمرکز یافته است. در این زمان و با توجه به عصر صنعتی و فرا صنعتی پیش‌رو، کشورها جهت انجام تولیدات، ارائه خدمات و پاسخگویی موثر به نیازهای بازار رقابتی نیازمند استفاده بیشتر از انرژی الکتریکی هستند بطوریکه می‌توان گفت تفوق اقتصادی یک کشور با مدیریت مصرف بهینه انرژی الکتریکی به منظور تأمین تقاضای مصرف‌کنندگان مختلف بخصوص در بخش تولیدکنندگان صنعتی رابطه مستقیم دارد. بعبارتی زنجیره تأمین انرژی الکتریکی^۱ به عنوان یک زنجیره تأمین کلان انرژی علاوه بر تأمین مصارف مسکونی و تجاری پاسخگوی هزاران زنجیره تأمین محصولات صنعتی و تجاری جهت تغذیه بهنگام و بی‌درنگ انرژی مورد نیاز آنها می‌باشد. نوسانات تقاضا می‌تواند چالش‌های مختلفی را برای بهره‌برداران مختلف در هر سطح از زنجیره تأمین انرژی الکتریکی ایجاد نماید. وجه تمایز زنجیره تأمین انرژی الکتریکی با سایر زنجیره‌های تأمین، عدم قابلیت ذخیره‌سازی انرژی الکتریکی در مقیاس وسیع به رغم سایر زنجیره‌های تأمین می‌باشد. نوسانات شدید تقاضا باعث ایجاد ناهماهنگی بین ترافیک تولید و مصرف شده و در نهایت باعث عملکرد حفاظت‌های فرکانسی و فروپاشی سطح به سطح در زنجیره تأمین انرژی الکتریکی می‌گردد. از طرفی زنجیره تأمین انرژی الکتریکی جهت پاسخگویی به تقاضای رو به افزایش خود با مشکلاتی نظیر کیفیت انتقال انرژی الکتریکی، قابلیت اطمینان، ذخایر ناکافی و حجم تولید و ذخیره در چرخش محدود روبرو بوده و هرگونه اختلال در این زنجیره می‌تواند هر یک از سطوح شامل تولیدکنندگان، خطوط انتقال و بخش‌های مختلف توزیع انرژی را با چالش‌های فراوان و در نهایت خارج شدن واحدهای تولید نیروگاهی از شبکه و خاموشی‌های گسترده روبرو کند. وجود این اختلالات علاوه بر ایجاد وقفه در انتقال انرژی الکتریکی و ضرر و زیان‌های کلان بر واحدهای نیروگاهی و خدماتی انرژی الکتریکی باعث توقف چرخ‌های کارخانجات و صنایع وابسته به انرژی الکتریکی، بالا رفتن هزینه‌های پس‌افت و تأخیر در انجام تعهدات و ایجاد نارضایتی از طرف مشتریان و بازارهای هدف شده و منافع کلیه ذینفعان سایر زنجیره‌های تأمین را به خطر می‌اندازد. این شرایط در مورد پیش‌بینی‌های تقاضای واحدهای صنعتی مادر با تقاضای بالا نظیر صنایع تولید فلزات اساسی که تولیدات متنوع آنها بعنوان خوراک و تغذیه ورودی سایر زنجیره‌های تأمین می‌باشد از اهمیت ویژه‌ای برخوردار است. همچنین نتایج پیش‌بینی تقاضا بیش از حد واقع یا کمتر از حد نیاز باعث ناکارآمدی انرژی الکتریکی شده و منجر به افزایش هزینه‌های بهره‌برداری و زیان مالی و عملیاتی بسیاری می‌گردد. شکل (۱) زنجیره تأمین انرژی الکتریکی، سطوح مختلف انتقال انرژی و زنجیره تأمین خدمات در سطوح مختلف ولتاژ، مطابق با شبکه انرژی الکتریکی ایران را نشان می‌دهد.



شکل (۱): زنجیره تأمین انرژی الکتریکی و سطوح سه‌گانه ولتاژ در خطوط انتقال انرژی الکتریکی ایران



همانگونه که در شکل (۱) مشخص شده است سطوح انتقال انرژی الکتریکی بر حسب ولتاژ در ایران در سه سطح پایه‌ریزی و طراحی گردیده است. سطح اول شامل ولتاژهای ۴۰۰-۲۳۰ کیلوولت، سطح دوم شامل ولتاژهای ۱۳۲-۶۳ کیلوولت و سطح سوم شامل ولتاژهای ۳۳-۲۰ کیلو ولت می‌باشد. هر سطح وظیفه انتقال انرژی مورد نظر را برای مصرف‌کنندگان تحت تغذیه خود و تأمین نیازهای سایر سطوح را بر عهده دارد. صنعت مورد مطالعه در این تحقیق در ذیل سطح دوم این زنجیره و تحت سطح ولتاژ ۶۳ کیلوولت تغذیه می‌گردد. شکل (۱) مسیر تغذیه و سطوح مختلف ولتاژ، سطوح انتقال انرژی الکتریکی و مصرف‌کنندگان ذیل این زنجیره را با رژیم‌های مختلف تقاضا نشان می‌دهد.

۱-۱- ادبیات موضوع

یکی از موارد مهم در پیش‌بینی تقاضا در زنجیره تأمین انرژی الکتریکی، دوره زمانی پیش‌بینی می‌باشد. این مورد از آن جهت حائز اهمیت است که تکنیک‌های به کار رفته، داده‌های مورد نظر و دقت نتایج و خروجی مطلوب در هر دوره متفاوت بوده و پیش‌بینی بر اساس هر یک از ادوار زمانی مطرح شده، تکنیک‌ها و الگوهای متناسب خود را می‌طلبد. از این جهت پیش‌بینی تقاضای الکتریکی با در نظر گرفتن افق زمانی پیش‌بینی به سه دوره‌ی کوتاه مدت، میان مدت و بلند مدت دسته‌بندی می‌گردد. از طرفی تقاضا و استفاده از انرژی الکتریکی با توجه به آمارهای سال‌های گذشته در سطح جهانی افزایش یافته است و این در حالی است که فرآیند تولید، انتقال و توزیع انرژی الکتریکی هنوز پیچیده و پرهزینه می‌باشد [۱]. از طرفی قیمت برق طی سال‌های گذشته همچنان در نوسان بوده و از این جهت نوسانات مکرر و عدم امکان تأمین انرژی مورد نیاز صنایع مختلف ضررهای مالی جبران‌ناپذیری را بر زنجیره‌های تأمین‌بلادرنگ و پویا (نظیر زنجیره تأمین انرژی الکتریکی و صنعت فولاد) و کلیه ذینفعان موجود در ذیل این زنجیره‌ها تحمیل خواهد کرد [۲].

در مرجع [۳] روشی برای انتخاب ویژگی‌ها برای آموزش مدل‌های پیش‌بینی تقاضا و قیمت برق ارائه شده است. معیارهای نظری اطلاعات جدیدی برای اندازه‌گیری افزونگی و هم‌افزایی در میان ویژگی‌ها در بین مجموعه‌ای از کاندیداهای ورودی را پیشنهاد داده‌اند. کارایی روش انتخاب ویژگی پیشنهادی با استفاده از تقاضای واقعی و داده‌های قیمت واحد پایش بازار^۲ و بازارهای برق اسپانیا و یک شرکت برق در نیویورک و به صورت هفتگی (کوتاه مدت) ارزیابی می‌شود. در مطالعه [۴] روشی شامل چهار بخش برای پیش‌بینی تقاضا و قیمت انرژی الکتریکی به‌عنوان متغیرهای اصلی در زنجیره تأمین و خدمات انرژی الکتریکی پیشنهاد شده است. در ابتدا از تبدیل مویک گسسته برای تفکیک سیگنال اصلی با حفظ اطلاعات با ارزش استفاده شده و در ادامه از مدل الگوریتم انتخاب فازی برای انتخاب بهترین داده‌ها با بیشترین ارتباط و کمترین تکرار بهره گرفته شده است. روند ارزیابی نتایج مدل با استفاده از اطلاعات موجود در بازار برق نیوانگلند در سال ۲۰۰۸ به صورت کوتاه مدت در دوره‌ای ۲۴ ساعته (روزانه) و هفتگی ۱۶۸ ساعته در هفته اول از دو ماه متفاوت مورد بررسی واقع شده است. الگوریتم بهینه‌سازی توده ذرات^۳ یکی از روش‌هایی است که برای به‌دست آوردن مقادیر بهینه ماشین‌های بردار پشتیبان در ساختن مدل پیش‌بینی تقاضای انرژی الکتریکی کاربرد فراوانی داشته است. در این مطالعه با ترکیب حداقل مربع ماشین بردار پشتیبان و بهینه‌سازی ازدحام ذرات یک سیستم پیش‌بینی تقاضای انرژی الکتریکی در بازار رقابتی برق این زنجیره معرفی گردیده است. همچنین از تکنیک‌های داده‌کاوی برای کشف الگوهای معنی‌دار استفاده شده تا میزان یادگیری را تنظیم کند. در این تحقیق داده‌های جزیره پنگ هو در تایوان مورد استفاده قرار گرفته است تا عملکرد شبکه پیشنهادی را نشان دهد [۵]. نتیجه‌گیری نشان می‌دهد که می‌توان از روش ترکیب حداقل مربع ماشین بردار پشتیبان و بهینه‌سازی ازدحام ذرات برای بهینه‌سازی و دستیابی به عملکرد بهتر استفاده کرد. در مقاله‌ای دیگر یک روش برای توزیع پیش‌بینی تقاضای یک زنجیره تأمین انرژی الکتریکی ارائه شده که هدف آن ارائه بسیار دقیق پیش‌بینی تقاضای کوتاه مدت با وضوح بالا مبتنی بر رگرسیون بردار پشتیبان^۴ و یک روش بهینه‌سازی پارامترهای ترکیبی دو مرحله‌ای می‌باشد. داده‌های بکار رفته در این تحقیق با استفاده از پروفیل بار و داده‌های ساعتی بوده و شامل افق زمانی کوتاه مدت می‌گردد [۶]. در مقاله‌ای دیگر یک روش پیش‌بینی ترکیبی برای انرژی باد بر اساس آزمون سطح شیب‌دار و پشتیبانی ارتوگونال ماشین بردار پشتیبان^۵ معرفی شده است. اثربخشی این روش با اطلاعات سه نیروگاه بادی در چین مورد آزمایش قرار گرفته و در نهایت به مقایسه نتایج با سایر روش‌های مرتبط پرداخته شده است [۷]. مقاله [۸] راهکاری ارائه می‌دهد که روش میانگین رگرسیون چندکی را به‌صورت چشمگیری گسترش داده و از تجزیه و تحلیل مولفه‌های اصلی برای خودکارسازی روند انتخاب از میان مجموعه‌ای بزرگ از مدل‌های پیش‌بینی که برای محاسبه در دسترس هستند بهره می‌برد. این روش برای قیمت‌گذاری بهای برق در ساعات مختلف و در زنجیره خدمات انرژی الکتریکی در سطوح مختلف از طریق داده‌ها بسیار کارآمد است. داده‌های مورد استفاده



از شبکه پنسیلوانیا- نیوجرسی- مرلند و مرکز داده‌های اقلیمی ملی برای شهر نیویورک بدست آمده است. در مقاله [۹] روشی برای تولید پیش‌بینی بار احتمالی با انجام میانگین رگرسیون کمی در مجموعه‌ای از پیش‌بینی‌های نقطه‌ای خاوه‌ری^۶ پیشنهاد شده است. رویکرد پیشنهادی و نتایج قابل تکرار برای جامعه مورد مطالعه جهت پیش‌بینی تقاضا، با استفاده از داده‌های عمومی در دسترس از مسابقات پیش‌بینی جهانی انرژی در سال ۲۰۱۴ و به صورت هفتگی (میان مدت) مورد ارزیابی قرار گرفته است. در مطالعه [۱۰] یک روش ترکیبی پیش‌بینی بار کوتاه‌مدت با استفاده از ماشین بردار پشتیبان و فیلتر کالمن و استفاده از الگوریتم خفاش^۷ برای به‌دست آوردن مقادیر بهینه پارامترها استفاده شده است. مطالعات موردی عددی در مورد پیش‌بینی بار یک پست در جنوب چین نشان می‌دهد که مدل پیش‌بینی ترکیبی پیشنهاد شده نسبت به سایر روش‌های پیش‌بینی بهتر عمل می‌کند و به طور مؤثر دقت پیش‌بینی را بهبود می‌بخشد [۱۱]. در مقاله [۱۲] ابتدا یک شبکه توپولوژیکی روز-به-روز^۸ برای یافتن شباهت میان روزها ساخته می‌شود. سپس الگوریتم پیاده‌روی تصادفی همراه با شروع مجدد^۹ روی شبکه تولید شده در مرحله قبل اعمال می‌گردد تا از این طریق مجموعه آموزش تولید شده و با استفاده از مدل رگرسیون ماشین بردار پشتیبان مدل پیش‌بینی آموزش داده شود. داده‌های منتخب به صورت روزانه بوده و چند منبع از جمله داده‌های آب و هوا، ویژگی‌های فصلی، تقویمی، تعطیلات و نرخ رشد بار و عوامل غالب که باعث تغییر تقاضا می‌شوند استفاده گردیده است. در مقاله [۱۳] تمرکز روی پیش‌بینی تقاضا در سطح سوم زنجیره تأمین انرژی الکتریکی و تقاضای خانگی بوده و از شبکه‌های عصبی مبتنی بر یادگیری عمیق برای پیش‌بینی بار خانوارها با ایجاد یک حوضچه عمیق از شبکه‌های عصبی استفاده شده است. در نهایت روش بر روی پلتفرم یادگیری عمیق^{۱۰} توسعه یافته و سپس روی ۹۲۰ مشتری مجهز به سیستم هوشمند اندازه‌گیری در کشور ایرلند آزمایش شده است. در مقاله [۱۴] به پیش‌بینی تقاضای مشترکان مسکونی در سطح سوم زنجیره تأمین انرژی الکتریکی و در یک افق زمانی کوتاه مدت با استفاده از شبکه عصبی پرداخته شده است. بر این اساس یک چهارچوب مبتنی بر شبکه عصبی حافظه کوتاه مدت-بلند^{۱۱} پیشنهاد شده که بر روی مجموعه‌ای از داده‌های کنتور هوشمند مسکونی در دسترس، آزمایش شده‌اند. عملکرد ارائه شده به طور جامع با معیارهای مختلف در زمینه پیش‌بینی بار مقایسه شده و نتایج نشان داده است روش پیشنهادی از عملکرد بهتری نسبت به سایر الگوریتم‌های رقیب برخوردار است.

تمرکز مطالعه انجام شده در مقاله [۱۵] بر بهبود شبکه عصبی مبتنی بر رگرسیون چندکی است. در این مطالعه پیش‌بینی‌های احتمالاتی بار در دوره‌های زمانی کوتاه مدت مختلف ارائه شده است. برای مطالعه موردی انجام شده در این مقاله از مجموعه داده‌های بار الکتریکی ساعتی از سال ۲۰۰۵ تا ۲۰۱۱ و داده‌های ساعتی دمای اندازه‌گیری شده توسط ۲۵ ایستگاه هواشناسی (۲۰۰۱-۲۰۱۱) استفاده شده است. پیش‌بینی تقاضای پیک روزانه ابزاری اساسی برای تصمیم‌گیری و برنامه‌ریزی جهت عملکرد سیستم‌های تحت تغذیه در سطوح مختلف زنجیره تأمین انرژی الکتریکی است. در مقاله [۱۶] تخمین چگالی کرنل و روش میانگین وفقی برای جمع‌آوری پروفیل و چگالی تقاضا به کار گرفته شده است و از اتوانکدرهای متصل به هم برای پیش‌بینی کمیت‌های نامشخص انرژی الکتریکی بهره گرفته شده است. در این روش توان‌های مناطقی که در همسایگی یکدیگرند برای تخمین تقاضای مناطق وسیع‌تر با روشی مبتنی بر خوشه‌بندی پروفیل درخواست با یکدیگر جمع می‌شوند.

۱-۲- وجوه تمایز تحقیق پیش رو نسبت به مطالعات موجود

تحقیق پیش‌رو از چند جهت نسبت به سایر تحقیقات مشابه متمایز می‌باشد. اول اینکه صنعت مورد مطالعه جزو ده صنعت انرژی بر در زنجیره تولید و انتقال انرژی الکتریکی بوده و همچنین جزء بزرگترین تولیدکنندگان خوراک اصلی صنایع فلزات اساسی و تولید فولاد می‌باشد. دوم در صنعت مورد مطالعه هیچ اطلاعات تکمیلی جز سیگنال تقاضای الکتریکی تاریخی این صنعت نظیر میزان تقاضا و تولید، میزان سفارش، وضعیت موجودی و... که امکان تنوع داده‌های آماری و استخراج ویژگی‌های جدید را می‌دهند وجود نداشت. عدم داشتن پایگاه داده به روز شده، بحث رقابت‌های تجاری و محرمانگی داده‌ها باعث شد تا دسترسی به سایر اطلاعات تکمیلی ممکن نباشد. از طرفی دوره پیش‌بینی ما برغم بیشتر تحقیقات انجام شده در حوزه پیش‌بینی تقاضای انرژی الکتریکی در افق زمانی بلند مدت انجام گرفت و بر خلاف تحقیقات مشابه در افق زمانی کوتاه مدت و میان مدت نیازهای آماری تحقیق با داشتن حداقل اطلاعات روز قبل یا دوره قبل صنعت مورد مطالعه کمکی در بهبود نتایج در افق زمانی بلند مدت نمی‌کرد. از این جهت با توجه به تنگناهای موجود در عرصه اطلاعات و عدم دستیابی به آمارهای موثق و قابل استناد متناسب با بازه زمانی مورد نظر در این تحقیق سعی شد با ارائه یک روش ترکیبی قابلیت پیش‌بینی تقاضا در افق زمانی بلند مدت با حداقل داده‌ها و آمار موجود با دقت قابل قبول انجام گردد. همچنین شرایط



مطالعه ما در این تحقیق بر اساس زنجیره‌های تولید توأم و بهنگام صورت گرفته است. بطوریکه سود و زیان هر دو زنجیره تأمین انرژی الکتریکی و صنعت مورد مطالعه در گرو پایداری و قابلیت اطمینان توأم و همزمان هر دو زنجیره ممکن می‌باشد. بخش‌های مختلف تحت تغذیه زنجیره تأمین انرژی الکتریکی ارتباط تنگاتنگ با سایر زنجیره‌های تولید مختلف و بهنگام نظیر صنایع فلزات اساسی دارد که قطع انرژی الکتریکی در آنها منجر به بروز خسارت برای کوره‌های ذوب، عقب افتادن از برنامه‌ریزی تولید، هزینه‌های ناشی از عقب افتادگی سفارشات و موجودی، بازسازی تجهیزات خسارت دیده و افزایش هزینه تعمیرات و نگهداری را به دنبال دارد. بدین ترتیب دامنه خسارات و هزینه‌های موجود منافع کلیه ذی‌نفعان در صنعت برق، صنایع فلزات اساسی و صنایع مرتبط نظیر خودروسازی تا بازارهای مالی و شاخص‌های بازارهای بورس را تحت تاثیر قرار می‌دهد. همچنین تغییرات جوی، افزایش آلاینده‌های زیست محیطی، بحران آب و گسترش خشکسالی و بروز حوادث غیرمترقبه مفهوم انعطاف‌پذیری زنجیره‌های تأمین انرژی را متحول کرده است. بخصوص در حال حاضر با تجربه پاندمی کووید ۱۹ در سطح جهانی درک بهتری از ابعاد گسترده‌تر اختلالات احتمالی زنجیره‌های تأمین انرژی ناشی از عدم اطمینان ظهور نموده است. بطوریکه توجه ذینفعان به معرفی و بکارگیری سیستم‌ها و گزینه‌های استراتژیک امنیت انرژی، برنامه‌ریزی توسعه و جذب سرمایه‌گذاری با توجه به تغییرات اقلیمی، انعطاف‌پذیری زنجیره تأمین جهت مقابله با چنین اختلالاتی را همراه داشته است. روش پیشنهادی در این مقاله قابلیت خود را در پیش‌بینی تقاضا در حضور داده‌های ناقص، عدم دسترسی به داده‌های تکمیلی و ویژگی‌های مکمل را نشان می‌دهد. همچنین مقایسه نهایی انجام گرفته با سایر روش‌های به کار گرفته شده در تحقیقات مشابه قبلی قابلیت روش پیشنهادی را تأیید کرده و قابلیت تعمیم این روش را جهت تحقیقات آتی با شرایط خاص موجود و مشابه فراهم می‌کند.

سایر مطالعات انجام گرفته با متدهای مختلف با کمبود اطلاعات مرتبط روبرو نبوده و عمدتاً جهت تست روش پیشنهادی از داده‌های مسابقات جهانی یا بانک اطلاعاتی استفاده شده که دارای روند و فصلیت مشخصی هستند. حال اینکه در تحقیق حاضر تنها داده‌های در دسترس تقاضای ساعتی واقعی این صنعت در یک دوره ۲۸۰۰۰ ساعته می‌باشد. وجود نقصان و عدم وضوح بالا در داده‌های این تحقیق به گونه‌ای که حدود ۵/۵۱٪ از داده‌ها صفر بوده است. در این مطالعه زمان‌های بدون تولید و مصرف صفر در مطالعه لحاظ شده است. پیکربندی شبکه‌های عمیق جهت بدست آوردن نتایج قابل قبول از تغییرات مختلف در ساختار لایه‌ها و تنظیم ابرپارمترها و بهینه‌سازی آموزش جهت جلوگیری از بیش‌برازش^{۱۲} شبکه و بالا بردن سرعت همگرایی، استفاده شده است که از جمله تفاوت‌های مطالعه فعلی نسبت به مطالعات موجود می‌باشد.

در این مقاله با توجه به استفاده از یک الگوریتم پیش‌بینی سه مرحله‌ای و استفاده از روش‌های یادگیری ماشین، یک مطالعه آماری جامع نیز انجام گرفته است که با توجه به مسئله مورد بحث و افق زمانی بلند مدت و حضور داده‌های ناقص و طبیعت تصادفی مسئله مفهومی است که به طور کلی در مطالعات قبلی این حوزه دیده نمی‌شود. این سنجش و مطالعه آماری در بدست آوردن یک ساختار دقیق‌تر و مدل پیش‌بینی واقع‌گراتر، کمک شایانی در داشتن یک تصور صحیح‌تر و واقعی می‌کند و مطالعات برنامه‌ریزی آینده را به واقعیت نزدیک‌تر می‌کند.

تحقیق حاضر یک پیش‌بینی بلند مدت است. عمده تحقیقات انجام گرفته در دوره کوتاه مدت می‌باشد. مطالعات کوتاه مدت دارای اطلاعات و ویژگی‌های متفاوت و در دسترس بوده و با عدم قطعیت‌های کمتری روبرو می‌باشد. حال آنکه مطالعات بلند مدت بدلیل نبود آمار موثق و داده‌های کلان^{۱۳} بخصوص با داشتن فقط یک ویژگی (تقاضای ساعتی) با عدم قطعیت‌های فراوان روبرو بوده و کاهش خطا در پیش‌بینی یک پارامتر اساسی می‌باشد که در مطالعه حاضر محقق شده است.

در ادامه و در بخش ۲ به داده‌کاوی و آنالیز آماری داده‌ها پرداخته شده است و بخش ۳ به ارائه روش پیشنهادی در سه مرحله اختصاص دارد. در بخش ۴ نتایج شبیه‌سازی و تحلیل آماری نتایج و نهایتاً در بخش ۵ نتیجه‌گیری حاصله ارائه می‌گردد.

۲- بررسی محتوای داده‌ها

سری‌زمانی تقاضا تاریخی در کمپانی تولید سنگ آهن اسپیدان که هدف مورد مطالعه ما در این مقاله می‌باشد دارای نواقص زیادی می‌باشد. از حدود ۴۰ ماه داده‌های ۲۴ ساعته از ۱ فروردین ۱۳۹۶ لغایت ۳۱ خردادماه ۱۳۹۹ فقط ۵۰ درصد داده‌ها دارای مقدار بوده و ۵۰ درصد مابقی اطلاعات صفر است. همچنین دامنه نوسانات تقاضا بالا بوده و از روندی همگون پیروی نمی‌کند. از این جهت در این بخش به آنالیز آماری داده‌های مورد نظر و بررسی نتایج آن پرداخته می‌شود. تحلیل آماری روند سری زمانی تقاضای تاریخی موجود در انتخاب روش ترکیبی پیشنهادی مؤثر می‌باشد.



۱-۲- آنالیز آماری داده‌ها

با توجه به سری زمانی تقاضا، در این بخش ابتدا داده‌های موجود در هر سال در یک گروه در نظر گرفته شده و سپس تحت تست نرمال بودن قرار می‌گیرد. نتایج آمار توصیفی و تست نرمال بودن داده‌ها در جداول (۱) و (۲) ارائه گردیده است.

جدول (۱): آمار توصیفی داده‌ها

Table 1: Descriptive Statistics

	<i>N</i>	<i>Mean</i>	<i>Std. Deviation</i>	<i>Minimum</i>	<i>Maximum</i>
تقاضا در ۱۳۹۶-۹۷	8784	6.4343	11.98117	-8.00	49.00
تقاضا در ۱۳۹۷-۹۸	8784	9.4591	13.56759	.00	45.00
تقاضا در ۱۳۹۸-۹۹	8784	10.6167	14.09217	.00	48.00

جدول (۲): نتایج تست نرمال بودن داده‌ها

Table 2: Tests of Normality

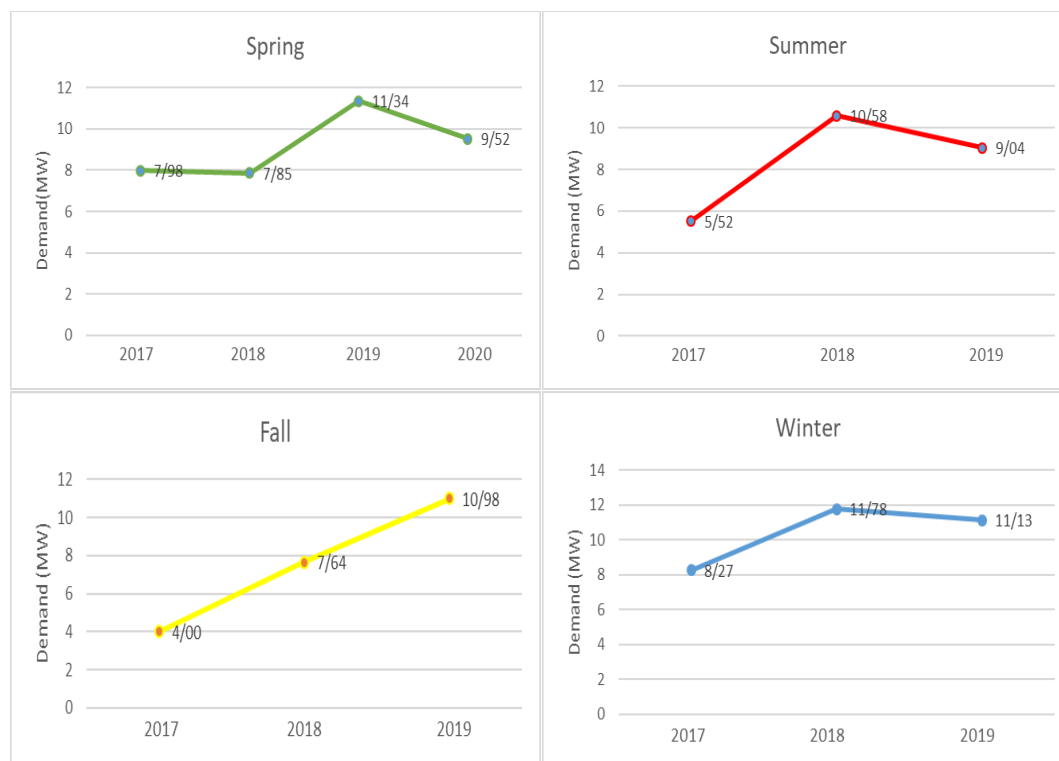
Kolmogorov-Smirnov^a

	<i>Statistic</i>	<i>df</i>	<i>Sig.</i>
تقاضا ۱۳۹۶	0.374	8784	.000
تقاضا ۱۳۹۷	0.298	8784	.000
تقاضا ۱۳۹۸	0.256	8784	.000

a. Lilliefors Significance Correction

با توجه به جدول آزمون نرمال بودن، چون سطح معنی‌داری^{۱۴} محاسبه شده کمتر از ۰/۰۵ می‌باشد بنابراین نرمال بودن توزیع سال‌های ۱۳۹۶، ۱۳۹۷، ۱۳۹۸ و ۱۳۹۹ با ۹۵ درصد اطمینان رد می‌شود.

جهت بررسی روند تغییرات تقاضا در دوره مورد نظر، نمودارهای میانگین فصلی در طی سال‌های دوره مورد مطالعه در شکل (۲) ارائه گردیده است. بدلیل ناهمگونی در طی دوره مورد مطالعه روش پیشنهادی جهت کار با داده‌هایی از این دست ارائه می‌گردد. همانگونه که در نمودارهای فصلی بهار دیده می‌شود پس از روند افزایش تقاضا در بهار ۱۳۹۸ (۲۰۱۹) روند کاهشی تقاضا در بهار ۱۳۹۹ (۲۰۲۰) و مقارن با شیوع پیک اول کووید ۱۹ در ایران می‌تواند عاملی اثرگذار بر کاهش تقاضای انرژی الکتریکی این شرکت بوده باشد.



شکل (۲): نمودارهای میانگین فصلی طی سال‌های مورد مطالعه ۱۳۹۶-۱۳۹۷-۱۳۹۸-۱۳۹۹



۳- روش پیشنهادی


موجک‌ها در تحلیل سری‌های زمانی دارای نوسانات زیاد، سیگنال‌های صوتی و تصویری و همچنین آشکار ساختن ساختارهای پیچیده کارایی دارند. تبدیل‌های ریاضی مانند تبدیل موجک برای به‌دست آوردن اطلاعات بیشتر از یک سیگنال در حوزه زمان بر روی آن سیگنال اعمال می‌شوند. از جمله قابلیت‌های اثرگذار این تبدیل توانایی نمایش طیفی- زمانی از سری زمانی مورد مطالعه بگونه‌ای است که بسیاری از اطلاعاتی که در توصیف زمانی یک سیگنال قابل مشاهده نیست، به راحتی در توصیف فرکانسی همان سیگنال قابل دسترسی می‌باشد. در خروجی تبدیل موجک سیگنال اصلی پیک تقاضا (S) در یک سطح به دو مؤلفه فرکانس پایین d_1 ^{۱۵} و فرکانس بالای a_1 ^{۱۶} تجزیه می‌شود. تبدیل موجک سیگنال زمانی $f(t)$ معمولاً به صورت زیر بیان می‌شود:

$$X_{\omega}(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} f(t) \psi^* \left((t-b)/a \right) dt \quad (1)$$

و در آن:

$$a = 2^{-j}, b = k2^{-j} \in \mathbf{R} \text{ and } a \neq 0 \quad (2)$$

(a) و (b) به ترتیب پارامترهای مقیاس و شیفت زمانی و $\psi(t)$ موجک مادر است. خانواده موجک مادر داباجیز^{۱۷} از موجک‌های متعامد بوده که برای تجزیه سیگنال تقاضای روزانه مناسب است [۱۷، ۱۸]. در روش پیشنهادی بطور مثال از موجک $Db1$ (سطح اول) برای تجزیه سیگنال زمانی پیک تقاضای روزانه استفاده شده است. اطلاعات پایگاه داده به دو پایگاه داده فرکانس پائین و فرکانس بالا تجزیه می‌شود و اطلاعات حاصل به طور جداگانه به شبکه‌های عصبی مجزا اعمال می‌شوند. در این مطالعه تجزیه سیگنال اصلی تقاضا در سطح ۱ انجام شده است. فرض می‌شود که سیگنال اصلی تقاضا (S) در سطح ۱ به دو مؤلفه فرکانس پایین (d_1) و فرکانس بالای (a_1) مشابه شکل (۳) تجزیه گردد.




شکل (۳): تجزیه موجک در سطح ۱

در این مقاله داده‌هایی که طول آن یکسان با طول سری زمانی مورد نظر باشد وجود نداشت. از این جهت امکان ایجاد رابطه بین ورودی و خروجی^{۱۸} در شبکه‌های عصبی معمولی ممکن نبود. نقایص موجود در تک ویژگی^{۱۹} موجود یا همان سری زمانی تقاضای تاریخی در دسترس در روند پیش‌بینی، تحقیق مورد نظر را به سمت استفاده از شبکه‌های عصبی عمیق و بهره‌گیری از توانمندی آنها متمایل نمود. شبکه حافظه کوتاه- مدت طولانی روشی برای آموزش عمیق است که برای اولین بار در سال ۱۹۹۷ توسط هاکریتز و همکارانش ارائه شده است [۱۹]. هدف اصلی ارائه این روش جلوگیری از صفر شدن گرادیان در روش شیب نزولی است که در زمان آموزش یک مدل شبکه عصبی با استفاده از الگوریتم پس‌انتشار^{۲۰} رخ می‌دهد. بطوریکه با از بین رفتن شیب، در مرحله آموزش بیش‌برازش داده^{۲۱} رخ داده و مدل مورد نظر توانایی تعمیم در زمان آزمایش را نخواهد داشت.

در شبکه حافظه کوتاه- مدت طولانی هر نورون در لایه مخفی یک سلول حافظه است و یک لبه بازگشتی دارد که به خود نورون متصل می‌شود. وزن این لبه برابر با ۱ بوده و باعث حفظ شیب در مرحله آموزش می‌گردد. شکل (۴) ساختار یک واحد شبکه عصبی حافظه کوتاه- مدت طولانی را نمایش می‌دهد.

شبکه عمیق (LSTM) شامل پنج واحد اصلی است. بلوک حافظه، سلول‌های مربوط به حافظه، دروازه مربوط به دریافت ورودی‌ها، دروازه واحدهای خروجی و در نهایت بلوک فرآموشی بخش‌های اصلی ساختار این نوع شبکه می‌باشد. سلول‌های حافظه، دارای واحدهای بازگشتی خطی هستند که با عنوان (CEC)^{۲۲} شناخته می‌شود. سیگنال‌های مربوط به فعال‌سازی و خطا توسط (CEC) در شبکه به گردش درآمده و موجب می‌شود این واحد بعنوان یک واحد ذخیره‌سازی کوتاه مدت عمل کند.





شکل (۴): ساختار واحد LSTM

واحدهای ورودی، خروجی و فرآموشی آموزش داده می‌شوند تا تصمیم بگیرند که کدام اطلاعات باید در واحد حافظه ذخیره شده و در چه زمانی این اطلاعات ذخیره شده خوانده شود. همچنین جریان ورودی‌های جدید به سلول‌ها با استفاده از سلول ورودی انجام می‌گیرد. سلول‌های خروجی تصمیم‌گیری زیر را بر عهده دارند:

- ۱- گسترش زمان برای مقدار عددی درون سلول که قرار است در فعال‌سازی واحد خروجی و گیت فراموشی به کار گرفته شود.
- ۲- محدوده زمانی حفظ مقادیر سلول‌ها.
- ۳- مشخص نمودن زمان فرآموشی مقادیر در سلول‌های حافظه.

شبکه مورد نظر تمامی واحدها را در بازه زمانی $t = 0, 1, 2, 3, \dots$ به روزرسانی کرده و سیگنال‌های خطا را برای تمامی وزن‌ها محاسبه می‌کند. از این عملکرد واحدها به عنوان گذر رو به جلو و از محاسبه سیگنال خطا به عنوان گذر رو به عقب یاد می‌گردد.

۱-۳- گذر به جلو

در روابط ارائه شده در ذیل این بخش، عملیات گذر رو به جلو در شبکه حافظه کوتاه-مدت طولانی ارائه گردیده است. بلوک‌های حافظه با z و همچنین سلول‌های حافظه موجود در هر بلوک z_j (شامل S_j سلول) با v مشخص گردیده است. C_j^v سلول v ام از بلوک حافظه z_j ام می‌باشد. وزن بین یونیت m ام و l ام و محدوده مقدار m برای واحدهای مبدأ متغیر است. زمانی که فعال‌سازی واحد مبدأ $y_m(t-1)$ مربوط به واحد ورودی است، آخرین ورودی خارجی $y_m(t)$ مورد استفاده قرار خواهد گرفت. محاسبه خروجی y_c از سلول حافظه مبتنی بر وضعیت سلول‌های استفاده شده اخیر S_c و چهار منبع ورودی است. ورودی سلول‌ها Z_c ، ورودی گیت‌های ورودی Z_{in} ، ورودی گیت‌های فرآموشی Z_o است و ورودی گیت‌های خروجی Z_{out} می‌باشد [۲۰]. با توجه به موارد ارائه شده در ادامه توضیحات زیر ارائه می‌گردد:

۱- ورودی: ورودی خالص هر سلول برای هر بار گذر رو به جلو با رابطه زیر قابل محاسبه است:

$$z_{C_j^v}(t) = \sum_m w_{C_j^v m} y_m(t-1) \quad (3)$$

بعد از محاسبه ورودی خالص، کد ورودی یا تابع تبدیل g روی رابطه فوق اعمال می‌گردد. تابع زیگموئید f_{in} برای محاسبه مقادیر فعال‌سازی گیت‌های ورودی بلوک حافظه مورد استفاده و به صورت زیر قرار می‌گیرد.

$$y_{in_j}(t) = f_{in_j}(Z_{in_j}(t)) \quad (4)$$

$$Z_{in_j}(t) = \sum_m w_{in_j m} y_m(t-1) \quad (5)$$





در ادامه حاصل Z_{in} و $Z_{C_j^v}(t)$ محاسبه می‌گردد. مقدار فعال‌سازی گیت‌های ورودی y_{in} در تمامی سلول‌های بلوک حافظه ضرب شده تا الگوهای فعالیت در حافظه ذخیره گردد. در فرآیند آموزش گیت ورودی ذخیره کردن اطلاعات مهم در بلوک حافظه را با در نظر گرفتن ($y_{in} \approx 1$) و حذف ورودی‌های بی‌ربط را با در نظر گرفتن ($y_{in} \approx 0$) آموزش دیده و فرا می‌گیرد.

۲- وضعیت سلول: در شروع فرآیند، وضعیت S_C از یک سلول حافظه C ، برابر با صفر در نظر گرفته می‌شود. همچنین در طول آموزش CEC بخشی از مقادیری را که در گیت فراموشی باقی‌مانده است جمع‌آوری می‌کند. فعالیت گیت فراموشی در بلوک حافظه به صورت زیر محاسبه می‌گردد:

$$y_{\phi_j}(t) = f_{\phi_j}(z_{\phi_j}(t)) \quad (6)$$

$$z_{\phi_j}(t) = \sum_m w_{\phi_{jm}} y_m(t-1) \quad (7)$$

f_{ϕ} نشان می‌دهد تابع زیگموئید در محدوده $[0, 1]$ است. همچنین وضعیت جدید سلول با استفاده از رابطه زیر محاسبه می‌گردد:

$$S_{C_j^v}(t) = y_{\phi_j}(t) S_{C_j^v}(t-1) + y_{in_j}(t) g(z_{C_j^v}(t)), \quad S_{C_j^v}(0) = 0 \quad (8)$$

زمانی که دروازه فراموشی باز است ($y_{in} \approx 1$) بوده و مقدار عددی در واحد CEC در گردش می‌باشد. هنگامی که گیت ورودی در حال یادگیری و ذخیره کردن اطلاعات در سلول حافظه است، دروازه فراموشی نیز در حال یادگیری مدت زمان محدود کردن هر یک از اطلاعات می‌باشد. بعد از قدیمی شدن اطلاعات، دروازه فراموشی آن را پاک کرده و حالت سلول حافظه را به صفر تنظیم می‌نماید. این روش مانع از نزدیک شدن حالت سلول به بی‌نهایت شده و امکان ذخیره اطلاعات جدید بدون دخالت عملیات قبلی فراهم می‌گردد.

۳- خروجی: خروجی سلول y_C حاصل ضرب وضعیت سلول S_C در فعالیت گیت خروجی y_{out} سلول حافظه بوده و به صورت زیر می‌باشد:

$$y_{C_j^v}(t) = y_{out_j}(t) S_{C_j^v}(t) \quad (9)$$

مراحل عملیات گذر به جلو شبکه با استفاده از معادلات فوق بیان می‌گردد. در ادامه فرآیند عملیات گذر به عقب ارائه می‌شود.

۳-۲- گذر به عقب

در این مرحله تابع هدف E با استفاده از تابع شیب نزولی و وزن‌های w_{im} به‌روزرسانی می‌گردد. وزن‌ها با استفاده از Δw_{im} که با استفاده از نرخ آموزش α و شیب منفی تابع هدف E به دست می‌آید، به روز می‌گردد. همچنین وزن‌های واحد خروجی با استفاده از روش استاندارد پس‌انتشار و به صورت زیر به روزرسانی می‌گردد [۲۰، ۱۹]:

$$\Delta w_{km}(t) = \alpha \delta_k(t) y_m(t-1) \quad (10)$$

$$\delta_k(t) = - \frac{\partial E(t)}{\partial z_k(t)} \quad (11)$$

در ادامه و بر اساس مقادیر هدف t_k تابع هدف، مربعات خطا به صورت زیر ارائه می‌گردد:

$$\delta_k(t) = f'_k(z_k(t)) e_k(t) \quad (12)$$

$$e_k(t) = t_k(t) - y_k(t) \quad (13)$$

سپس وزن‌های یونیت منبع برای اتصال به گیت خروجی تغییر می‌کند. این وزن‌ها نیز با استفاده از روش پس‌انتشار و به صورت زیر به دست می‌آید:

$$\Delta w_{out_j m}(t) = \alpha \delta_{out_j}(t) y_m(t) \quad (14)$$



خطای وضعیت داخلی با استفاده از $e_{S_{c_j}}$ نمایش داده شده و برای هر یک از سلول‌های حافظه محاسبه می‌گردد:

$$e_{S_{c_j}}(t) = y_{out_j}(t) \left(\sum_k w_{kc_j} \delta_k(t) \right) \quad (15)$$

روابط ارائه شده عملیات گذر به جلو، گذر به عقب و فرآیند آموزش یک واحد شبکه عصبی عمیق را توصیف می‌نماید.

۳-۳- بهینه‌سازی

بهینه‌سازها، الگوریتم‌هایی هستند که از طریق به هنگام‌سازی وزن‌ها در شبکه سعی در به حداقل رساندن تابع زیان (خطا) دارند. عبارتی همان هدف اصلی ما از آموزش شبکه‌ها برای مسئله مورد نظر هستند که سعی داریم، وزن‌های شبکه به گونه‌ای تنظیم شود تا شبکه‌ها توانایی یادگیری را بدست آورند. انتخاب الگوریتم بهینه‌سازی مناسب نقش مهمی در سرعت همگرایی شبکه خواهد داشت. در این مقاله از روش برآورد تکانه تطبیقی استفاده شده است که روند این الگوریتم در ادامه آورده شده است.

۳-۳-۱- برآورد تکانه تطبیقی (ADAM) ۲۳

برآورد تکانه تطبیقی روشی جهت محاسبه نرخ یادگیری تطبیقی برای هر پارامتر می‌باشد. این الگوریتم از مزایای الگوریتم‌های آداگراد^{۲۴} و آر-ام-اس پراپ^{۲۵} بهره می‌برد و میانگین فروپاشی نمایی از گرادیان‌های گذشته را در v_t ذخیره می‌کند. همچنین الگوریتم آدام میانگین تکانه‌ای دوم گرادیان را در m_t ذخیره می‌کند. m_t و v_t به ترتیب مقادیر میانگین و واریانس غیرمتمرکز بوده و به شرح زیر می‌باشند [۲۱]:

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) \cdot g_t \quad (16)$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) \cdot g_t^2 \quad (17)$$

همچنین الگوریتم آدام میانگین‌های تحرک نمایی گرادیان و گرادیان مربع را توسط معادلات زیر کنترل می‌کند:

$$\hat{m} = \frac{m_t}{1 - \beta_1^t} \quad (18)$$

$$\hat{v} = \frac{v_t}{1 - \beta_2^t} \quad (19)$$

که در آن ابرپارامترهایی با مقادیر $\beta_1, \beta_2 \in [0, 1]$ بوده و معادله نهایی بهنگام‌سازی به صورت زیر می‌باشد:


$$w_{t+1} = w_t - \frac{\eta}{\sqrt{\hat{v}_t}} \odot \hat{m}_t \quad (20)$$

الگوریتم آدام از سایر روش‌های تطبیقی بهتر عمل می‌کند و خیلی سریع همگرا می‌شود. همچنین بر سایر مشکلات همانند فروپاشی نرخ یادگیری، واریانس بالا در بهنگام‌سازی و همگرایی آهسته که سایر الگوریتم‌های بهینه‌سازی غلبه کرده‌اند، غلبه می‌کند [۲۲، ۲۳].

۳-۴- ماشین یادگیری شدید^{۲۶}

با ظهور داده‌های با ابعاد بالا و با کاربردهای مختلف مانند بازیابی اطلاعات، طبقه‌بندی خودکار متن و بیوانفورماتیک، انتخاب ویژگی در داده‌کاوی و یادگیری ماشین اهمیت بیشتری پیدا کرده است [۲۴]. در ادامه ساختار ماشین یادگیری شدید در فرم رگرسیون بررسی می‌گردد. بدین جهت فرض شده که مجموعه داده‌هایی شامل N نمونه آموزشی به شکل زیر در دسترس باشند:

$$\left\{ (x_i, y_i) \right\}_{i=1}^N, \quad x_i \in \mathbb{R}^n, \quad y_i \in \mathbb{R} \quad (21)$$





در رابطه فوق $x_i \in \mathbb{R}^n$ ورودی مدل و $y_i \in \mathbb{R}$ خروجی مطلوب یا هدف یا 27 مدل می‌باشند. با فرض اینکه مدل بتواند به بهترین شکل ممکن رابطه میان ورودی و خروجی را توصیف کند، ماشین یادگیری شدید با تعداد L نورون در لایه مخفی و تابع فعال‌سازی $g(x)$ را می‌توان به شکل زیر مدل‌سازی نمود:

$$\sum_{i=1}^L \beta_i g(w_i \cdot x_j + b_i) = y_j, \quad j = 1, 2, \dots, N \quad (22)$$

المان‌های بردار وزن $w_i = [w_{i1}, w_{i2}, \dots, w_{in}]^T$ به صورت تصادفی انتخاب شده و به نورون i ام از لایه‌ی ورودی و لایه مخفی متصل می‌باشند. همچنین b_i مقدار تصادفی بایاس بوده که به گره i ام در لایه مخفی متصل است. همچنین β_i وزنی است که به نورون i ام در لایه مخفی و لایه خروجی متصل است. $w_i \cdot x_j$ حاصل ضرب داخلی بردار وزن و ماتریس ورودی است و تابع فعال‌ساز لایه خروجی خطی انتخاب می‌گردد. بدین ترتیب N معادله فوق را می‌توان به صورت فشرده شده زیر ارائه کرد:

$$H \beta = y, \quad \beta = [\beta_1, \beta_2, \dots, \beta_L]^T, \quad y = [y_1, y_2, \dots, y_N]^T \quad (23)$$

$$H(w_1, \dots, w_L, x_1, \dots, x_N, b_1, \dots, b_L) = \begin{bmatrix} g(w_1 \cdot x_1 + b_1) & \dots & g(w_L \cdot x_1 + b_L) \\ \vdots & \dots & \vdots \\ g(w_1 \cdot x_N + b_1) & \dots & g(w_L \cdot x_N + b_L) \end{bmatrix}_{N \times L} \quad (24)$$

با بررسی روابط فوق می‌توان دریافت که تمامی پارامترها به غیر از وزن خروجی β در مدل ماشین یادگیری شدید ثابت است. از این روی هدف یافتن راه‌حلی برای بردار وزن خروجی با استفاده از رابطه خطی (۲۳) است.

اگرچه در بسیاری از موارد H یک ماتریس مربعی نیست، در نتیجه برداری مانند β وجود ندارد تا در رابطه (۲۳) صدق کند. در این مواقع روش مرسوم برای حل این مشکل یافتن کوچکترین مربعات بهینه $\hat{\beta}$ با مینیمم کردن تابع خطای متناظر با آن می‌باشد [۲۴]:

$$\min \|y - H \beta\|_2^2 \quad (25)$$

حال حل بهینه با توجه به حداقل نرم ℓ_2 به شکل زیر خواهد بود:

$$\hat{\beta} = H^\dagger y \quad (26)$$

H^\dagger ماتریس معکوس تعمیم‌یافته مور-پنروز 28 از سمت ماتریس لایه مخفی به سمت لایه خروجی یعنی H می‌باشد. از آنجا که تعداد نمونه‌های آموزشی به طور معمول بیشتر از تعداد نورون‌های لایه مخفی ($N > L$) است رابطه (۲۶) را می‌توان به شکل زیر بازنویسی کرد [۲۴]:

$$\hat{\beta} = (H^T H)^{-1} H^T y \quad (27)$$

۳-۵- ماشین یادگیری شدید تنظیم شده (RELM) 29

ضروری‌ترین بخش ماشین یادگیری شدید مینیمم کردن خطای آموزش است. هر چند این کار ممکن است موجب بیش‌برازش شبکه گشته و دقت پیش‌بینی را تحت تأثیر قرار دهد. طبق نظریه بارلت 30 [۲۵] برای شبکه‌های عصبی پیش-خور هرچه نرم وزن‌ها و خطای آموزش کوچک‌تر گردد، عملکرد تعمیمی شبکه بهتر خواهد بود. به عبارت دیگر یک مدل ماشین یادگیری شدید با توانایی تعمیم خوب عملکرد خوبی در ارتباط با خطای آموزش و نرم وزن‌های خروجی خواهد داشت. تناسب بین خطای آموزش و نرم وزن‌های خروجی با استفاده از پارامتر تنظیمی C قابلیت کنترل دارد. در مقایسه با مدل ماشین یادگیری شدید معمولی، این مدل که ماشین یادگیری شدید تنظیم شده نام گرفته معمولاً عملکرد تعمیمی بهتری را از خود بروز می‌دهد.

ویژگی اصلی این مدل متفاوت از مدل ماشین یادگیری شدید است. این ویژگی مینیمم کردن همزمان خطای آموزش و نرم وزن‌های خروجی با یک پارامتر تنظیمی و به شکل زیر می‌باشد:

$$\min_{\beta} C \|y - H \beta\|_2^2 + \|\beta\|_2^2 \quad (28)$$



می توان رابطه فوق را به شکل یک مسأله بهینه‌سازی و به شکل زیر مطرح نمود:

$$\min_{\beta} C \|e\|_2^2 + \|\beta\|_2^2 \quad \text{subject to } y - H\beta = e \quad (29)$$

در این حالت تابع لاگرانژ رابطه فوق به صورت زیر می‌باشد:

$$L(\beta, e, \lambda) = C \|e\|_2^2 + \|\beta\|_2^2 + \lambda^T (y - H\beta - e) \quad (30)$$

در رابطه فوق بردار $e = [e_1, e_2, \dots, e_N]^T$ شامل N خطای محاسبه شده در مرحله آموزش است. λ یک بردار ستونی شامل ضرایب لاگرانژ می‌باشد. طبق نظریه کاروش-کان-تاکر^{۳۱} شرط بهینگی بصورت زیر خواهد بود:

$$\begin{cases} \frac{\partial L}{\partial \beta} = 0 \Rightarrow 2\beta - H^T \lambda = 0 \\ \frac{\partial L}{\partial e} = 0 \Rightarrow 2Ce - \lambda = 0 \\ \frac{\partial L}{\partial \lambda} = 0 \Rightarrow y - H\beta - e = 0 \end{cases} \quad (31)$$

و منتج به حل زیر برای پارامتر β می‌شود:

$$\hat{\beta} = \left(H^T H + \frac{I}{C} \right)^{-1} H^T y \quad (32)$$


در مواقعی که تعداد نمونه‌های آموزش از تعداد نورون‌های لایه مخفی بیشتر باشد، راه حلی جایگزین با محاسبات کمتر به شکل زیر وجود دارد:

$$\hat{\beta} = H^T \left(HH^T + \frac{I}{C} \right)^{-1} y \quad (33)$$

۳-۶- فلوجارت روش پیشنهادی

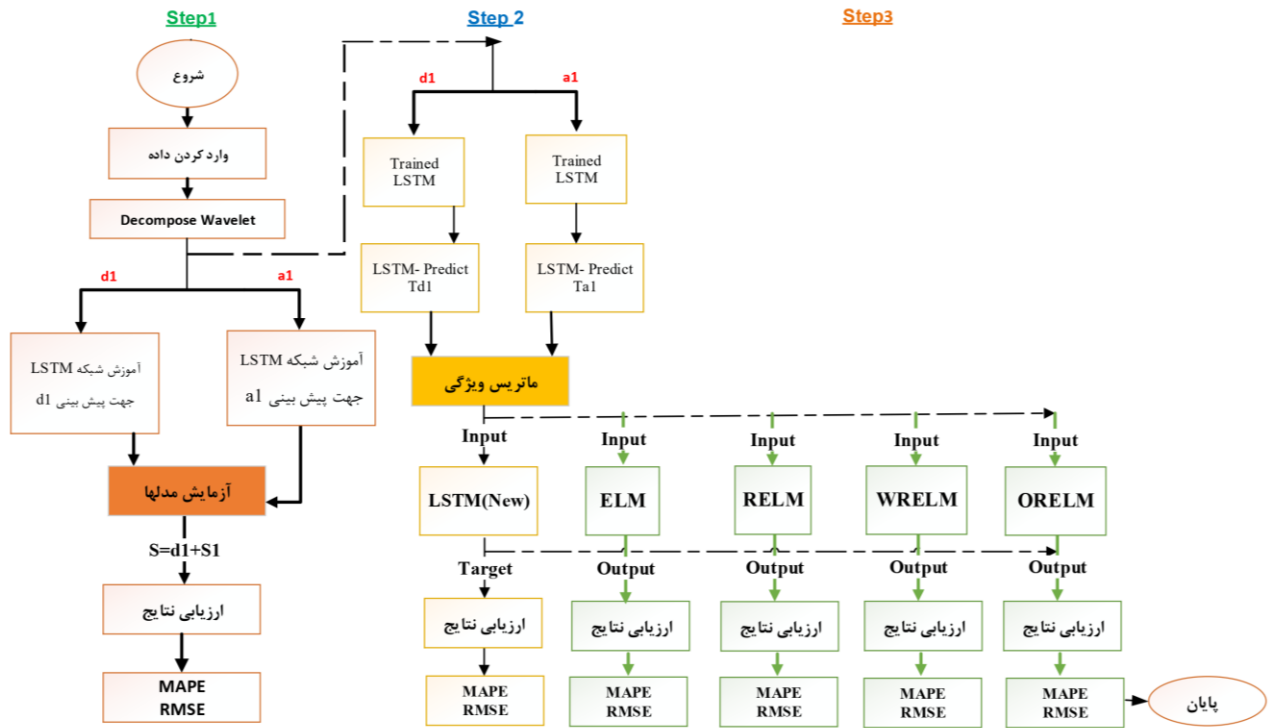
همانطور که قبلاً اشاره شد، از وجوه تمایز این مقاله با سایر تحقیقات مشابه می‌توان به حداقل داده‌های لازم و موجود بودن تنها ویژگی سابقه سیگنال تقاضا در دوره مورد نظر، نقص اطلاعات موجود در سری زمانی داده‌ها و عدم دستیابی به داده‌های مکمل اشاره کرد. با توجه به این نکته که فرآیند پیش‌بینی تقاضا در یک افق زمانی بلندمدت انجام می‌گیرد و همچنین داده‌ها از کمترین عدم وضوح لازم برخوردار می‌باشند، وجود تغییرات شدید و ناگهانی در مصرف ساعتی باعث شد تا طول سری زمانی یکسان نبوده و مشکلات پیش‌رو نسبت به سایر سری‌های زمانی بدون قطعی و دارای ویژگی‌های تکمیلی دشوارتر گردد. هنگامی که دسترسی به همه متغیرهایی که ممکن است به پیش‌بینی سری‌های زمانی مانند تقاضای الکتریکی کمک کنند وجود نداشته و داده‌ها در مقیاس کلان وجود دارد، پیش‌بینی با استفاده از شبکه‌های عصبی کم‌عمق معمولی دشوار است و معمولاً با دقت کم همراه می‌باشد. دستیابی به دقت قابل قبول نیاز به ترکیبی از تکنیک‌ها و ادغام یادگیری عمیق با روش‌های مرسوم نظیر ماشین بردار پشتیبان^{۳۲} و یادگیری نظارت شده^{۳۳} دارد. علاوه، در بیشتر مواقع استفاده از روش‌هایی مانند ماشین بردار پشتیبان یا درختان رگرسیون برای پیش‌بینی سری‌های زمانی غیرممکن است زیرا این روش‌ها نمی‌توانند الگوی موجود در سری‌های زمانی پیچیده را بیاموزند و عدم توانایی تعمیم در پیش‌بینی با داده‌های جدید وجود خواهد داشت. همچنین استفاده از داده‌های با وضوح پائین مانند سری‌های زمانی برای ساخت مدل‌های پیش‌بینی با دقت بالا نیاز به یک رویکرد قدرتمند دارد. به منظور نشان دادن اثربخشی روش پیشنهادی، سری زمانی تقاضا مربوط به شرکت اسپیدان و روش‌های فوق‌الذکر برای آموزش و آزمایش مدل‌های پیش‌بینی با استفاده از روش پیشنهادی در این مقاله استفاده شده که در فلوجارت شکل (۵) و در سه مرحله ارائه گردیده است.

روش پیشنهادی شامل تجزیه و تحلیل موجک و تولید ماتریس پیش‌بینی با استفاده از شبکه LSTM است. در ابتدا مجموعه داده‌ها شامل داده‌های تقاضای ثبت شده ساعتی به ۳ بخش شامل زیر مجموعه‌های آموزش (۵۰٪)، اعتبارسنجی (۱۹٪) و آزمون (۳۱٪) تقسیم





می‌شود. در مرحله ۱ هر زیرمجموعه با استفاده از تبدیل موجک به بردارهای جزئیات و تقریب تجزیه می‌شود. بردارهای تجزیه شده d_1 و a_1 استاندارد شده و سپس اقدام به تولید ماتریس پیش‌بینی کننده جهت آموزش مدل‌های اولیه LSTM با تأخیر یک ساعته می‌کنند. بنابراین مدل‌ها می‌آموزند که چگونه بردارهای جزئیات بعدی و بردارهای تقریبی را تخمین بزنند. در مرحله دوم بردارهای ورودی مرحله آموزش به مدل‌های آموزش دیده وارد می‌شوند و تأخیر در خروجی مدل‌های LSTM حذف شده و اقدام به آموزش ماتریس پیش‌بینی-کننده جدید می‌گردد. در بخش سوم خروجی نهایی شبکه‌های جدید LSTM آموزش دیده در مرحله قبل به‌عنوان ورودی ماشین یادگیری شدید به عنوان ابزاری قدرتمند در کار با داده‌های خارج از دسترس قرار می‌گیرد. خروجی این شبکه هدف نهایی پیش‌بینی تقاضا در الگوریتم پیشنهادی است.



شکل (۵): روندنمای روش ترکیبی پیشنهادی چند مرحله‌ای

۷-۳- ارزیابی نتایج

به منظور ارزیابی نحوه عملکرد روش‌های پیش‌بینی، از شاخص‌های ریشه میانگین مربعات خطا^{۳۴}، ریشه میانگین مربع خطای نرمال شده^{۳۵} و میانگین خطای مطلق^{۳۶} به عنوان معیارهای ارزیابی استفاده شده است. این شاخص‌ها به صورت زیر می‌باشند:

$$MAE = \frac{1}{N_t} \sum_{i=1}^{N_t} |y_i - \hat{y}_i| \quad (34)$$

$$MSE = \frac{\sum_{i=1}^{N_t} (y_i - \hat{y}_i)^2}{N_t} \quad (35)$$

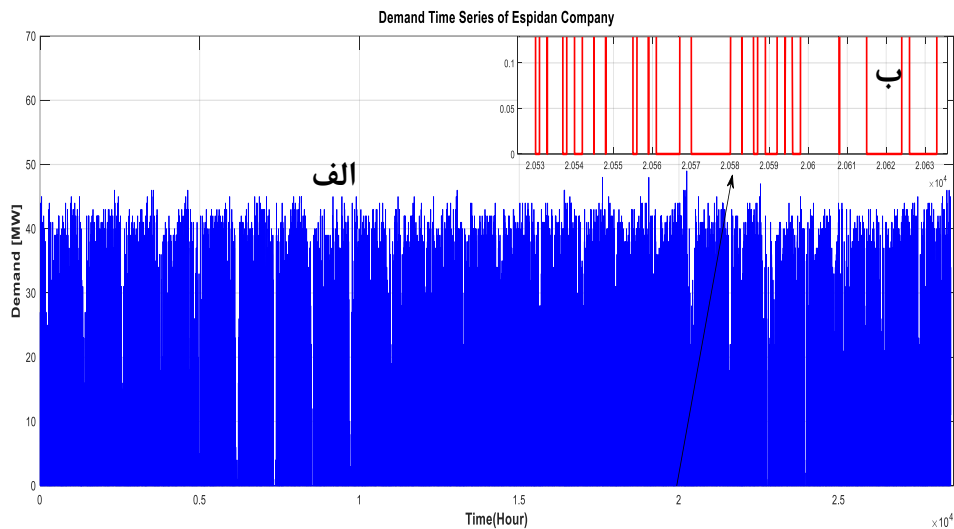
$$RMSE = \sqrt{\frac{\sum_{i=1}^{N_t} (y_i - \hat{y}_i)^2}{N_t}} \quad (36)$$

$$NRMSE = \frac{RMSE}{y_{\max} - y_{\min}} \quad (37)$$

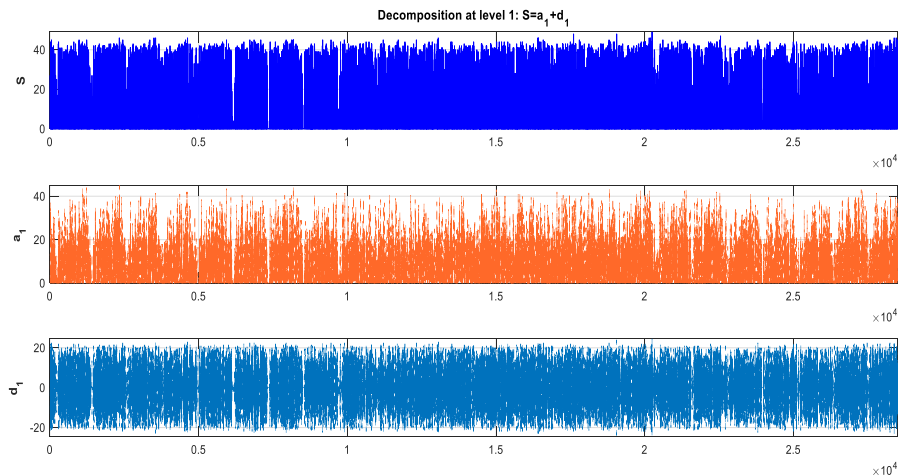


۴- نتایج شبیه‌سازی

سری زمانی تاریخی تقاضای شرکت اسپیدان در دوره مورد مطالعه در شکل (۶) نشان داده شده است. این سری زمانی شامل تقاضای ثبت شده ۱۱۸۸ روزه می‌باشد. وجود صفرهای زیاد در این سری زمانی مربوط به عدم تولید شرکت می‌باشد. اگر نقطه داده فعلی صفر باشد، این احتمال وجود دارد که پیش‌بینی در زمان بعدی صفر باشد و روند پیش‌بینی شکست بخورد. ورودی‌ها و اهداف در این مطالعه موردی با ۱ ساعت تأخیر انجام گرفته و صفرهای موجود در سری زمانی تقاضا، پیش‌بینی را دشوارتر می‌کنند. بنابراین، پیش‌بینی سری‌های زمانی از این نوع چالش بزرگی است که می‌تواند با استفاده از روش پیشنهادی در این مقاله کنترل شود. اولین قدم در روش پیشنهادی تجزیه موجک است که با استفاده از موجک داباچیز انجام شده است. تجزیه سیگنال اصلی با جزئیات و سیگنال‌های تقریب به ترتیب در شکل (۷) با d_1 و a_1 ارائه گردیده است.

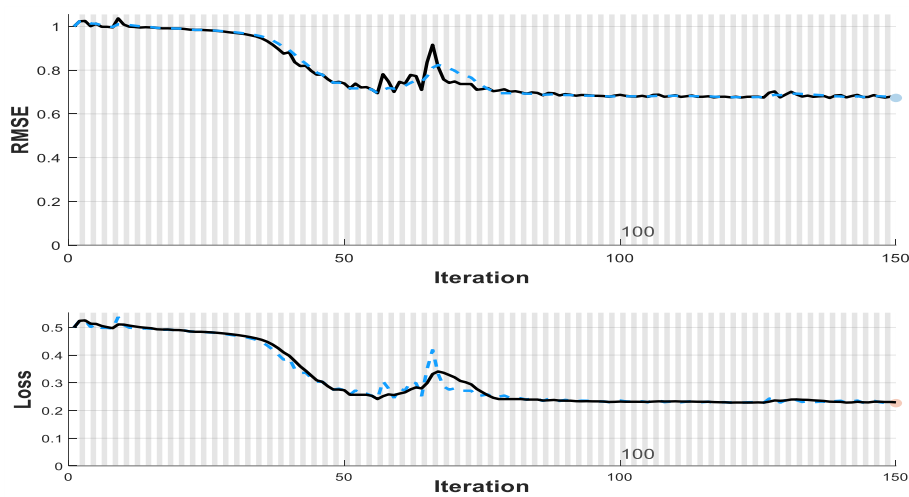


شکل (۶): (الف): سری زمانی تقاضا و (ب): برش زمانی منقطع سیگنال تقاضای انرژی الکتریکی شرکت اسپیدان در دوره مورد مطالعه

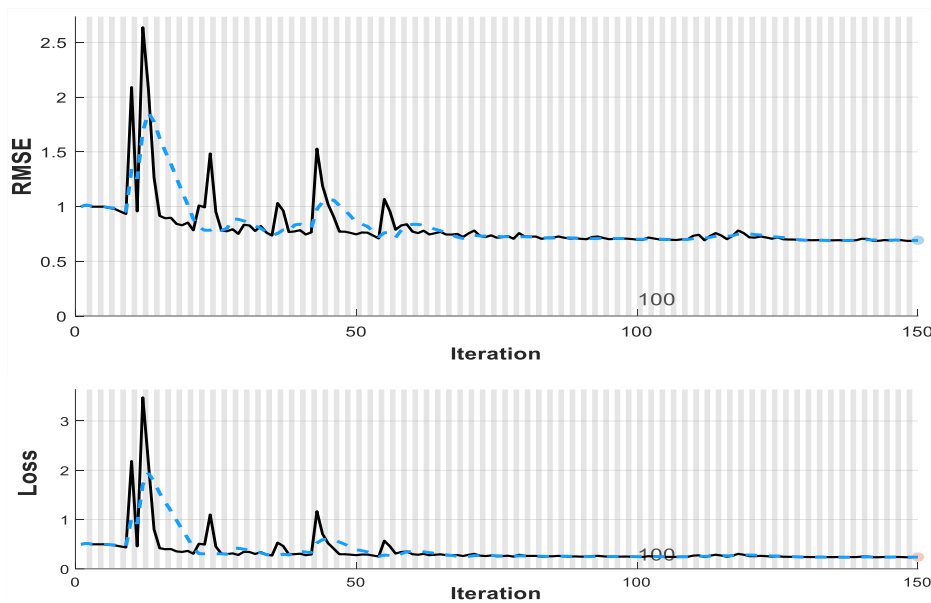


شکل (۷): تجزیه موجک با استفاده از موجک (Daubechies)

در مرحله بعدی بردار d_1 و a_1 بعنوان ورودی‌های مدل‌های LSTM با تأخیر ۱ ساعت و با استفاده از روش ADAM آموزش داده می‌شوند. روش آموزش مدل‌های d_1 و a_1 در ۱۵۰ تکرار در شکل‌های (۸) و (۹) نشان داده شده است.



شکل (۸): فرآیند آموزش مدل d_1 با استفاده از مجموعه داده EIS



شکل (۹): فرآیند آموزش مدل a_1 با استفاده از مجموعه داده EIS

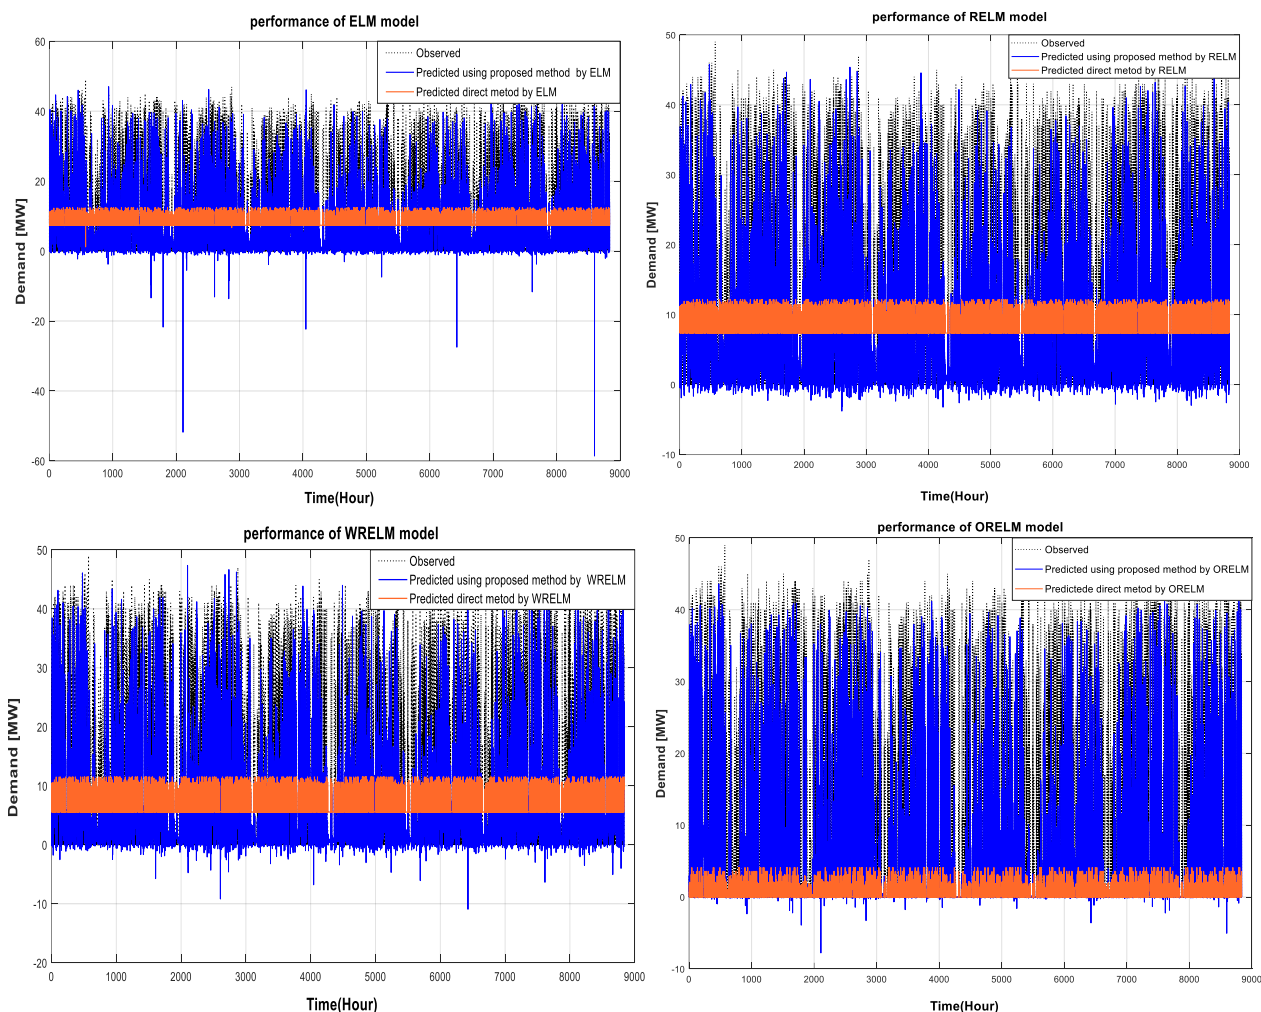
مدل‌های آموزش دیده دو ردیف ماتریس پیش‌بینی کننده جدید تولید می‌کنند که می‌تواند برای آموزش مدل پیش‌بینی بدون تأخیر استفاده شود در حالی که ورودی اصلی بردار d_1 و a_1 با تاخیر ۱ ساعته است. موتورهای پیش‌بینی با استفاده از ماتریس پیش‌بینی کننده جدید و مدل‌های ELM شامل ELM، RELM، WRELM و ORELM آموزش داده می‌شوند. در مرحله آزمایش، سیگنال‌های تجزیه شده به مدل‌های LSTM- d_1 و LSTM- a_1 برای تولید ماتریس پیش‌بینی کننده که ورودی موتور جستجو است وارد شده و خروجی‌ها که بردارهای نهایی پیش‌بینی هستند، تولید می‌شود. در جدول (۳) نتایج بدست آمده با استفاده از روش پیشنهادی ارائه گردیده است. شکل (۱۰) نتایج پیش‌بینی و عملکرد مدل پیشنهادی با استفاده از تکنیک پیشنهادی مبتنی بر ماشین یادگیری را نشان می‌دهد. نتایج نشان می‌دهد که روش پیشنهادی (P) به طور کلی نتایج را بهبود می‌بخشد، اما سیگنال‌های پیش‌بینی شده نشان می‌دهد که به جز مدل پیشنهادی، سایر مدل‌ها نمی‌توانند مستقیماً تحت سری زمانی تقاضای مورد مطالعه پیش‌بینی را انجام دهند.

جدول (۳): نتایج آزمایش روش پیشنهادی (P) ELM

Model	MAE	MAPE	MSE	RMSE
ELM	1.504	7.4431	5.3106	2.3045
RELM	1.5064	7.4551	5.3181	2.3061
WRELM	1.4974	7.4105	5.3594	2.315
ORELM	1.4995	7.421	5.391	2.3219
Trim Mean	1.4968	7.4074	5.3357	2.3099



توانایی تعمیم در آزمایش مدل‌های آموزش دیده با داده‌های جدید مهمترین معیار انتخاب مدل به ویژه هنگامی است که مطالعه موردی یک سری زمانی با نوسانات شدید مورد نظر باشد. علاوه بر این، هنگامی که سری زمانی دارای نوسانات شدید است، روش پیشنهادی در این مقاله می‌تواند به عنوان یک راه حل ممکن برای بهبود دقت پیش‌بینی با افزایش توانایی تعمیم موتورهای پیش‌بینی آموزش دیده با استفاده از انواع روش‌های یادگیری ماشین مورد استفاده قرار گیرد. نتایج پیش‌بینی ارائه شده با روش‌های مستقیم ماشین یادگیری نظارت شده در جدول (۴) ارائه گردیده است و نشان می‌دهد که در مقایسه با روش پیشنهادی از دقت پائین‌تری برخوردار می‌باشند. جدول (۴) نشان می‌دهد که نتایج بدست آمده با روش پیشنهادی در مقاله حاضر و نتایج جدول (۳) بدون تردید دارای قابلیت و دقت بیشتری نسبت به سایر روش‌های مستقیم ارائه شده در جدول (۴) می‌باشد.



شکل (۱۰): نتیجه پیش‌بینی توسط تکنیک پیشنهادی مجموعه ELM و مقایسه با روش مستقیم ELM

جدول (۴): نتایج آزمایش سایر روش‌های مستقیم

Method	Option	MAE	MSE	RMSE	NRMSE
ELM	-	10.884	173.52	13.173	0.26883
RELM	-	10.883	173.46	13.17	0.26878
WRELM	-	10.27	175.85	13.261	0.27063
ORELM	-	8.8069	242.85	15.584	0.31803
SVR	KS=0.35	8.9836	227.01	15.067	0.30749
BT	-	10.758	173.65	13.178	0.26893
BGT	-	10.888	173.65	13.178	0.26893
DT	MLS=12	10.89	173.53	13.173	0.26884
LSTM	-	10.543	178.57	13.363	0.27272



۴-۱- ارزیابی آماری

با توجه به نزدیک بودن نتایج معیارهای به کار رفته جهت سنجش خطا در روش‌های یادگیری ماشین در این مطالعه و جهت دستیابی به بهترین نتیجه، از آنالیز آماری تحلیل واریانس ANOVA^{۳۷} استفاده می‌شود [۲۶]. بدین جهت نتایج خروجی ناشی از شبیه‌سازی با تکنیک یادگیری ماشین در روش پیشنهادی طی ده مرتبه تکرار در جدول (۵) ارائه گردیده است.

جدول (۵): نتایج ده تکرار تکنیک‌های یادگیری ماشین بر اساس روش پیشنهادی

شماره تکرار	روش	معیار ارزیابی				شماره تکرار	روش	معیار ارزیابی			
		MAE	MSE	RMSE	NRMSE			MAE	MSE	RMSE	NRMSE
۱	ELM	8.3428	137.56	11.729	0.23936	۶	ELM	8.3375	136.53	11.685	0.23847
	RELM	8.2466	133.05	11.535	0.2354		RELM	8.2654	133.89	11.571	0.23615
	WRELM	8.0072	138.61	11.773	0.24027		WRELM	8.0217	139.69	11.819	0.24121
	ORELM	7.7271	171.76	13.106	0.26747		ORELM	7.7365	172.12	13.119	0.26774
۲	ELM	8.2903	136.18	11.67	0.23816	۷	ELM	8.2814	136.3	11.675	0.23826
	RELM	8.2667	133.24	11.543	0.23557		RELM	8.2454	133.52	11.555	0.23582
	WRELM	8.0047	138.62	11.774	0.24028		WRELM	8.0251	139.09	11.794	0.24069
	ORELM	7.7103	168.22	12.97	0.26469		ORELM	7.6672	168.54	12.982	0.26495
۳	ELM	8.2744	135.41	11.636	0.23748	۸	ELM	10.897	173.46	13.17	0.26878
	RELM	8.2499	133.32	11.546	0.23564		RELM	10.898	173.45	13.17	0.26878
	WRELM	7.9781	138.89	11.785	0.24051		WRELM	10.284	175.66	13.254	0.27049
	ORELM	7.7383	171.85	13.109	0.26753		ORELM	8.8031	241.07	15.527	0.31687
۴	ELM	8.2435	135.54	11.642	0.23759	۹	ELM	8.3071	137.64	11.732	0.23943
	RELM	8.2693	133.42	11.551	0.23573		RELM	8.2551	133.92	11.573	0.23617
	WRELM	8.019	138.85	11.784	0.24048		WRELM	7.9978	140.36	11.847	0.24178
	ORELM	7.6834	166.67	12.91	0.26347		ORELM	7.8122	175.68	13.255	0.2705
۵	ELM	8.3111	138.31	11.761	0.24001	۱۰	ELM	8.2806	135.82	11.654	0.23784
	RELM	8.2843	133.98	11.575	0.23623		RELM	8.2585	133.11	11.537	0.23545
	WRELM	8.0375	139.04	11.792	0.24064		WRELM	7.9841	137.62	11.731	0.23941
	ORELM	7.7344	170.07	13.041	0.26614		ORELM	7.7388	170.41	13.054	0.26641

۴-۲- آزمون همگنی واریانس‌ها و آزمون واریانس میانگین‌ها (ANOVA)

از آنجا که پژوهشگر نمی‌تواند تمامی متغیرهای نامربوط را کنترل کند، سطحی از احتمال خطا را تعیین می‌کند و نتایج پژوهش خود را با آن احتمال گزارش می‌نماید. همچنین از سطح معنی‌داری پنج صدم در تصمیم‌گیری برای رد فرضیه‌ی صفر استفاده می‌شود. در بیشتر گزارش‌های پژوهشی برای گزارش معنی‌دار بودن تفاوت یا رابطه‌ی میان متغیرها از سطح معنی‌داری که معمولاً ۰/۰۵ است استفاده می‌گردد. سطح معناداری نشان‌دهنده میزان خطایی است که در رد فرضیه‌ی صفر مرتکب می‌شویم و به P-Value نیز معروف است [۲۶]. یکی از آماره‌های استنباطی برای سنجش برابری واریانس در چند جامعه مستقل، استفاده از آماره لون و اجرای آزمونی به نام آزمون لون^{۳۸} است. در بیشتر نرم‌افزارهای آماری، محاسبه و اجرای این آزمون پیش‌زمینه‌ای برای آزمون‌های دیگر محسوب می‌گردد. برای مثال در آزمون مربوط به برابری میانگین چند جامعه مستقل، فرض برابری یا نابرابری واریانس‌ها، باعث ایجاد آماره‌های مجزا با درجه‌های آزادی متفاوت برای آزمون میانگین خواهد شد. فرض صفر در آزمون لون، یکسان بودن واریانس‌ها است [۲۷].

با توجه به موارد بیان شده برای ارزیابی مدل‌های پیش‌بینی، آزمون همگنی واریانس‌ها و تست آنالیز واریانس برای روش‌های ELM، WRELM و ORELM انجام گرفت و نتایج آن در جداول (۶) تا (۹) ارائه شده است.

نتایج جدول (۶) نشان می‌دهد چون سطح معناداری از ۰/۰۵ کوچکتر است، فرض صفر رد می‌شود. یعنی در سطح اطمینان ۹۵ درصد، واریانس‌ها با هم تفاوت معناداری دارند. با توجه به این موضوع فرض برابری میانگین‌ها مورد تست قرار می‌گیرد. با توجه به نتایج جدول (۷) چون سطح معناداری از ۰/۰۵ کوچکتر است در سطح اطمینان ۹۵ درصد تفاوت معناداری بین میانگین روش‌ها وجود دارد.

حال با توجه به اینکه واریانس‌ها و میانگین‌ها با هم تفاوت معناداری دارند بنابراین با استفاده از جدول (۹) روشی که کمترین واریانس (یا انحراف معیار) را دارد، انتخاب گردیده است.



جدول (۶): آزمون همگنی واریانس‌ها

	Levene Statistic	df1	df2	Sig.
ELM	4.629	3	36	.008
RELM	4.688	3	36	.007
WRELM	4.681	3	36	.007
ORELM	4.794	3	36	.007

جدول (۷): نتایج تست ANOVA

	Sum of Squares	df	Mean Square	F	Sig.
Between Groups	134175.386	3	44725.129	1298.430	.000
ELM Within Groups	1240.040	36	34.446		
Total	135415.425	39			
Between Groups	128749.490	3	42916.497	1068.136	.000
RELM Within Groups	1446.439	36	40.179		
Total	130195.929	39			
Between Groups	139104.053	3	46368.018	1365.531	.000
WRELM Within Groups	1222.417	36	33.956		
Total	140326.470	39			
Between Groups	218886.367	3	72962.122	579.338	.000
ORELM Within Groups	4533.855	36	125.940		
Total	223420.222	39			

جدول (۸): نتایج تست مقاوم بودن برابری میانگین‌ها

	Statistic ^a	df1	df2	Sig.
ELM Brown-Forsythe	1298.430	3	9.118	.000
RELM Brown-Forsythe	1068.136	3	9.108	.000
WRELM Brown-Forsythe	1365.531	3	9.098	.000
ORELM Brown-Forsythe	579.338	3	9.026	.000

a. Asymptotically F distributed.

جدول (۹): نتایج توصیفی

	N	Mean	Std. Deviation	Std. Error	95% Confidence Interval for Mean		Minimum	Maximum
					Lower Bound	Upper Bound		
MAE	10	8.55657	.822881	.260218	7.96792	9.14522	8.244	10.897
MSE	10	140.27500	11.699715	3.699775	131.90553	148.64447	135.410	173.460
ELM RMSE	10	11.83540	.470754	.148865	11.49864	12.17216	11.636	13.170
NRMSE	10	.24154	.009609	.003039	.23466	.24841	.237	.269
Total	40	40.22713	58.925295	9.316907	21.38190	59.07235	.237	173.460
MAE	10	8.52392	.834251	.263813	7.92713	9.12071	8.245	10.898
MSE	10	137.49000	12.639540	3.996974	128.44822	146.53178	133.050	173.450
RELM RMSE	10	11.71560	.511234	.161667	11.34988	12.08132	11.535	13.170
NRMSE	10	.23909	.010435	.003300	.23163	.24656	.235	.269
Total	40	39.49215	57.778518	9.135586	21.01369	57.97062	.235	173.450
MAE	10	8.23592	.719857	.227639	7.72096	8.75088	7.978	10.284
MSE	10	142.64300	11.622832	3.675462	134.32853	150.95747	137.620	175.660
WRELM RMSE	10	11.93530	.464324	.146832	11.60314	12.26746	11.731	13.254
NRMSE	10	.24358	.009477	.002997	.23680	.25036	.239	.270
Total	40	40.76445	59.984286	9.484348	21.58054	59.94835	.239	175.660
MAE	10	7.83513	.342296	.108243	7.59027	8.07999	7.667	8.803
MSE	10	177.63900	22.428257	7.092438	161.59479	193.68321	166.670	241.070
ORELM RMSE	10	13.30730	.785820	.248498	12.74516	13.86944	12.910	15.527
NRMSE	10	.27158	.016034	.005071	.26011	.28305	.263	.317
Total	40	49.76325	75.688332	11.967376	25.55695	73.96955	.263	241.070



با توجه به جداول (۶) تا (۹) فرض برابری واریانس‌ها (آماره لون) و برابری آزمون واریانس میانگین‌ها چهار معیار RMSE، MSE، MAE و NRMSE در چهار مدل استفاده شده در سطح معناداری ۵ درصد رد می‌شود. یعنی چهار معیار با هم تفاوت معناداری دارند. همچنین چون معیارها از نوع خطا هستند، بنابراین معیاری که کمترین میانگین با کمترین واریانس را دارا می‌باشد (NRMSE) انتخاب می‌گردد. در مرحله بعد آزمون برابری واریانس و میانگین معیار NRMSE در چهار مدل استفاده شده انجام گرفته و نتایج آن در جداول (۱۰) تا (۱۳) ارائه گردیده است. همانگونه که در جدول (۱۰) مشخص است چون آزمون همگنی واریانس‌ها برای معیار NRMSE از ۰/۰۵ بزرگتر است پس فرض برابری واریانس‌ها پذیرفته می‌شود [۲۷].

جدول (۱۰): آزمون همگنی واریانس‌ها

NRMSE			
Levene Statistic	df1	df2	Sig.
.348	3	36	.791

جدول (۱۱): نتایج تست ANOVA

NRMSE					
	Sum of Squares	df	Mean Square	F	Sig.
Between Groups	.007	3	.002	16.856	.000
Within Groups	.005	36	.000		
Total	.012	39			

جدول (۱۲): نتایج تست مقاوم بودن برابری میانگین‌ها

NRMSE				
	Statistic ^a	df1	df2	Sig.
Brown-Forsythe	16.856	3	28.599	.000

a. Asymptotically F distributed.

جدول (۱۳): نتایج توصیفی

NRMSE								
	N	Mean	Std. Deviation	Std. Error	95% Confidence Interval for Mean		Minimum	Maximum
					Lower Bound	Upper Bound		
ELM	10	.2415380	.00960872	.00303854	.2346643	.2484117	.23748	.26878
RELM	10	.2390940	.01043491	.00329981	.2316293	.2465587	.23540	.26878
WRELM	10	.2435760	.00947670	.00299680	.2367968	.2503552	.23941	.27049
ORELM	10	.2715770	.01603439	.00507052	.2601067	.2830473	.26347	.31687
Total	40	.2489463	.01744038	.00275757	.2433685	.2545240	.23540	.31687

با توجه به مقادیر به دست آمده در سطح معناداری ۵٪ فرض برابری واریانس‌ها پذیرفته می‌شود و فرض برابری میانگین‌ها رد می‌شود. یعنی تفاوت معناداری در مدل‌های استفاده شده وجود دارد و چون متغیر مورد نظر از نوع خطاست مدلی که کمترین میانگین را دارا می‌باشد (مدل RELM) انتخاب می‌گردد. این نتایج نشان می‌دهد استفاده از روش پیشنهادی با مدل RELM نتایج بهتری در مواجهه با مسئله پیش‌بینی بلند مدت تقاضا در زنجیره تامین انرژی الکتریکی و در حضور داده‌های ناقص ایجاد می‌کند.

۵- نتیجه‌گیری

در این مقاله یک روش پیش‌بینی بلند مدت تقاضا در زنجیره تامین انرژی الکتریکی صنایع سنگ آهن اسپیدان اصفهان با استفاده از یک روش ترکیبی از تبدیل موجک، شبکه LSTM و داده‌کاوی مبتنی بر ماشین یادگیری شدید پیشنهاد شده است. با توجه به نقصان داده‌ها و صفر بودن مقدار داده در بسیاری از ساعات سیگنال تقاضای مورد بررسی و عدم امکان دسترسی به داده‌های مکمل و ویژگی‌های مؤثر جهت پیش‌بینی استفاده از تکنیک‌های متداول امکان‌پذیر نمی‌باشد. آنالیز آماری بکار رفته نشان داد که داده‌های سالانه و فصلی از توزیع نرمال پیروی نمی‌کند. نتایج حاصل از ۱۰ تکرار روش‌های ماشین یادگیری شدید و بررسی آزمون همگنی واریانس‌ها و تست آنالیز واریانس (ANOVA)، نشان می‌دهد که استفاده از ترکیب تبدیل موجک به همراه شبکه LSTM و روش RELM با سطح اطمینان






بالای ۹۵٪ از سایر روش‌های یادگیری ماشین مؤثرتر و نتایج دقیق‌تری دارد. مقایسه نتایج روش پیشنهادی با سایر روش‌ها بیانگر قابلیت روش پیشنهادی در ارائه یک تکنیک مؤثر پیش‌بینی بلند مدت تقاضا با خطای قابل قبول در زنجیره تأمین صنایع تولید فلزات اساسی و سایر کسب و کارها در حضور نقصان داده‌ها می‌باشد.

مراجع

- [1] S. N., Emenike, and G. Falcone, "A review on energy supply chain resilience through optimization," *Renewable and Sustainable Energy Reviews*, vol. 134, pp. 110088, Dec. 2020, doi: 10.1016/j.rser.2020.110088.
- [2] A. Dedinec, S. Filiposka, A. Dedinecb, and L. Kocarev, "Deep belief network based electricity load forecasting: An analysis of Macedonian case," *Energy*, vol. 115, pp. 1688–1700, Nov. 2016 doi: 10.1016/j.energy.2016.07.090.
- [3] M. Moazzami, S. J. aldin Hosseini, H. Shahinzadeh, G. B. Gharehpetian, and J. Moradi, "SCUC Considering Loads and Wind Power Forecasting Uncertainties Using Binary Gray Wolf Optimization Method," *Majlesi Journal of Electrical Engineering*, vol. 12, no. 4, pp.15–24, Dec. 2018.
- [4] O. Abedinia, N. Amjady, and H. Zareipour, "A new feature selection technique for load and price forecast of electrical power systems," *IEEE Transactions on Power Systems*, vol. 32, no. 1, pp. 62–74, Jan. 2017, doi: 10.1109/TPWRS.2016.2556620.
- [5] W. M. Lin, C. S. Tu, R. F. Yang, and M. T. Tsai, "Particle swarm optimisation aided least-square support vector machine for load forecast with spikes," *IET Generation, Transmission & Distribution*, vol. 10, no. 5, pp. 1145–1153, Apr. 2016, doi:10.1049/iet-gtd.2015.0702.
- [6] Z. Lin, M. Chen, and Y. Ma, "The augmented lagrange multiplier method for exact recovery of corrupted low-rank matrices," *arXiv preprint arXiv*, "1009. 5055", Sep. 2010, doi: 10.48550/arXiv.1009.5055.
- [7] H. Fang, j. Ma, W. Zhang, H. Yang, F. Chen, and X. Li, "Hydraulic performance optimization of pump impeller based on a joint of particle swarm algorithm and least-squares support vector regression," *IEEE Access*, vol. 8, pp. 203645–203654, Nov. 2020, doi: 10.1109/ACCESS.2020.3036913.
- [8] P. Zeng, and M. Jin, "Peak load forecasting based on multi-source data and day-to-day topological network," *IET Generation, Transmission & Distribution*, vol. 12, no. 6, pp.1374–1381, Mar. 2018. doi: 10.1049/iet-gtd.2017.0201.
- [9] H., Shi, M. Xu, and R. Li, "Deep learning for household load forecasting-A novel pooling deep RNN," *IEEE Transactions on Smart Grid*, vol. 9, no. 5, pp. 5271–5280, Mar. 2017, doi: 10.1109/TSG.2017.2686012.
- [10] H. Jiang, Y. Zhang, E. Muljadi, J. J. Zhang, and D. W. Gao, "A short-term and high-resolution distribution system load forecasting approach using support vector regression with hybrid parameters optimization," *IEEE Transactions on Smart Grid*, vol. 9, no. 4, pp. 3341–3350, Nov. 2016, doi:10.1109/TSG.2016.2628061.
- [11] Y. Liu, Y. Sun, D. Infield, Y. Zhao, S. Han, and J. Yan, "A hybrid forecasting method for wind power ramp based on orthogonal test and support vector machine (OT-SVM)," *IEEE Transactions on Sustainable energy*, vol. 8, no. 2, pp.451–457, Aug. 2016, doi: 10.1109/TSTE.2016.2604852.
- [12] J. Nowotarski, and R. Weron, "Computing electricity spot price prediction intervals using quantile regression and forecast averaging," *Computational Statistics*, vol. 30, no. 3, pp. 791–803, 2015, doi: 10.1007/s00180-014-0523-0.





- [13] M. Rafiei, T. Niknam, J. Aghaei, M. Shafie-Khah, and J. P. S. Catalão, "Probabilistic load forecasting using an improved wavelet neural network trained by generalized extreme learning machine," *IEEE Transactions on Smart Grid*, vol. 9, no. 6, pp. 6961–6971, Feb. 2018. doi: 10.1109/TSG.2018.2807845.
- [14] W. Zhang, H. Quan, and D. Srinivasan, "An improved quantile regression neural network for probabilistic load forecasting," *IEEE Transactions on Smart Grid*, vol. 10, no. 4, pp. 4425–4434, July 2018, doi: 10.17775/CSEEJPES.2016.00080.
- [15] Q. Liu, Y. Shen, L. Wu, J. Li, L. Zhuang, and S. Wang, "A hybrid FCW-EMD and KF-BA-SVM based model for short-term load forecasting," *CSEE Journal of Power and Energy Systems*, vol. 4, no. 2, pp. 226–237, June 2018, doi: 10.17775/CSEEJPES.2016.00080.
- [16] W. Kong, Z. Y. Dong, Y. Jia, D. J. Hill, Y. Xu, and Y. Zhang, "Short-term residential load forecasting based on LSTM recurrent neural network," *IEEE Transactions on Smart Grid*, vol. 10, no. 1, pp. 841–851, Sep. 2017, doi: 10.1109/TSG.2017.2753802.
- [17] M. Moazzami, A. Khodabakhshian, and R. Hooshmand, "A new hybrid day-ahead peak load forecasting method for Iran's National Grid," *Applied Energy*, vol. 101, pp. 489–501, Jan. 2013, doi:10.1016/j.apenergy.2012.06.009.
- [18] Z. Bashir, and M. El-Hawary, "Applying wavelets to short-term load forecasting using PSO-based neural networks," *IEEE transactions on power systems*, vol. 24, no. 1, pp. 20–27, Jan. 2009, doi: 10.1109/TPWRS.2008.2008606.
- [19] R. C. Staudemeyer, and E. R. Morris, "Understanding LSTM--a tutorial into Long Short-Term Memory Recurrent Neural Networks," *arXiv preprint arXiv:1909.09586*, 2019. doi: 10.48550/arXiv.1909.09586.
- [20] S. Mujeeb, N. Javaid, M. Ilahi, Z. Wadud, F. Ishmanov, and M. K. Afzal, "Deep long short-term memory: A new price and load forecasting scheme for big data in smart cities," *Sustainability*, vol. 11, no. 4, pp. 987, 2019, doi:10.3390/su11040987.
- [21] C.J. Kumar, and M. Veerakumari, "Load forecasting of Andhra Pradesh grid using PSO, DE algorithms," *Int J Adv Res Comput Eng Technol*, 2012.
- [22] J. Duchi, E. Hazan, and Y. Singer, "Adaptive subgradient methods for online learning and stochastic optimization," *Journal of machine learning research*, vol. 12, no.7, pp.2121–2159, 2011.
- [23] T. Tieleman, and G. Hinton, "Lecture 6.5-rmsprop, coursera: Neural networks for machine learning," *University of Toronto, Technical Report*, 2012.
- [24] G.-B. Huang, Q.-Y. Zhu, and C.-K. Siew, "Extreme learning machine: theory and applications," *Neurocomputing*, vol. 70, no. 1-3, pp. 489–501, Dec. 2006, doi: 10.1016/j.neucom.2005.12.126.
- [25] P.L. Bartlett, "The sample complexity of pattern classification with neural networks: the size of the weights is more important than the size of the network," *IEEE transactions on Information Theory*, vol. 44, no. 2, pp. 525–536, Mar. 1998, doi: 10.1109/18.661502.
- [26] A. Amidi, M. GH. Vahidi Asl, "Mathematical statistics," *University Publication Center*, 1378.
- [27] K. Atashgar, "Introduction to design of experiment and tguchi metod," *Publications of Malik Ashtar University of Technology*, 1397.



-
- 1 Electricity Supply Chain
 - 2 PJM Interconnection LLC (PJM)
 - 3 Particle Swarm Optimization
 - 4 Support Vector Machin
 - 5 Ortogonal Suport Vector Mashin
 - 6 Sister Forecast
 - 7 Bat algorithm
 - 8 Day to day topological network
 - 9 Random walk with restart algorithm
 - 10 Tensor Flow
 - 11 Long short-term memory
 - 12 Over fit
 - 13 Big Data
 - 14 Significance
 - 15 Details
 - 16 Approximation
 - 17 Daubechies
 - 18 Target
 - 19 Feature
 - 20 Back propagation
 - 21 Over fit
 - 22 Constant Error Carousel
 - 23 Adaptive Moment Estimation Optimization
 - 24 Adagrad
 - 25 RmSprop
 - 26 Extra Learning Machin
 - 27 Target
 - 28 Moore-Penrose
 - 29 Regularized Extreme Learning Machine
 - 30 Bartlett's theory
 - 31 Karush–Kuhn–Tucker
 - 32 Support Vector Machin
 - 33 Extra Learning Machin
 - 34 Root-Mean-Square Error
 - 35 Normalized Root Mean Square Error
 - 36 Mean Absolute Error
 - 37 Analysis of Variance
 - 38 Levine's Test