

## Long-Term Demand Forecasting in Electrical Energy Supply Chain of Espidan Ironstone Industry Using Deep Learning and Extreme Learning Machine

Sepehr Moalem<sup>1</sup>, *PhD Student*, Roya M.P. Ahari<sup>1</sup>, *Assistant Professor*, Ghazanfar Shahgholian<sup>2,3</sup>, *Associated Professor*, Majid Moazzami<sup>2,3</sup>, *Associated Professor*, Seyed Mohammad Kazemi<sup>1,3</sup>, *Assistant Professor*

<sup>1</sup>Industrial Engineering Department, Najafabad Branch, Islamic Azad University, Najafabad, Iran

<sup>2</sup>Department of Electrical Engineering, Najafabad Branch, Islamic Azad University, Najafabad, Iran

<sup>3</sup>Smart Microgrid Research Center, Najafabad Branch, Islamic Azad University, Najafabad, Iran  
sepehrmoalem@pel.iaun.ac.ir, roya.ahari@pin.iaun.ac.ir, kazemimailbox@yahoo.com, shahgholian@iaun.ac.ir, m\_moazzami@pel.iaun.ac.ir

### Abstract

Espidan ironstone industries is one of the most consumed power industries in the electricity supply chain of Isfahan province as the second industrial hub of the country and one of the main suppliers of raw materials in the supply chain of the country's steel industry. Planning in a large-scale electricity supply chain, in a space full of uncertainty, is begin with electricity demand forecasting. In this paper, a hybrid long-term demand forecasting method in the electricity supply chain of Isfahan's ironstone industries using a combined data mining method including wavelet transform, deep learning and intensive learning machine is proposed. The used data in this study is according to the recorded information from the electrical energy demand signal of Espidan ironstone industries in a period of 40 months in the form of 24-hours. The data in a part of the study period due to the lack of production of this industry in some hours are interrupted. So that only 40% of the data had a value and the remaining, 60% were zero. This subject led to information deficiencies and increases the forecasting error up to 40% in the first step of the proposed algorithm. By completing the first step of the proposed model with intense learning machine (ELM) the forecasting error is reduced and it was possible to create an improved forecasting model for supervised training. Finally, simulation results are compared with other available approaches such as support vector machine and decision tree. The results show the improvement and reduction of error and a significant increase in the accuracy of the proposed method in long-term demand forecasting in the electricity supply chain of Espidan ironstone industries.

**Keywords:** wavelet transform, deep learning, intensive learning machine, support vector machine, decision tree, demand forecasting, electrical supply chain, mean absolute percentage error.

**Received:** 22 December 2020

**Revised:** 25 February 2021

**Accepted:** 13 March 2021

**Corresponding Author:** Dr. Roya M.A. Ahari

**Citation:** S. Moalem, R.M.P. Ahari, G. Shahgholian, M. Moazzami, S.M. Kazemi, "Long-term demand forecasting in electrical energy supply chain of Espidan ironstone industry using deep learning and extreme learning machine", Journal of Intelligent Procedures in Electrical Technology, vol. 13, no. 49, pp. 1-20, June 2022 (in Persian).

<https://dorl.net/dor/20.1001.1.23223871.1401.13.49.1.0>

مقاله پژوهشی

## پیش‌بینی بلندمدت تقاضا در "زنجیره تامین انرژی الکتریکی صنایع سنگ آهن اسپیدان" با استفاده از شبکه عصبی عمیق و ماشین یادگیری شدید

سپهر معلم<sup>۱</sup>، دانشجوی دکتری، رویا محمدعلی پوراهری<sup>۱</sup>، استادیار، غضنفر شاهقلیان<sup>۲،۳</sup>، دانشیار، مجید معظمی<sup>۲،۳</sup>، دانشیار، سید محمد کاظمی<sup>۱</sup>، استادیار

۱- دانشکده فنی و مهندسی - 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

sepehrmoalem@pel.iaun.ac.ir, roya.ahari@pin.iaun.ac.ir, kazemimailbox@yahoo.com, shahgholian@iaun.ac.ir, m\_moazzami@pel.iaun.ac.ir

**چکیده:** صنایع سنگ آهن اسپیدان یکی از صنایع پر مصرف برق در زنجیره تامین انرژی الکتریکی استان اصفهان به‌عنوان دومین قطب صنعتی کشور و یکی از تامین‌کنندگان اصلی مواد اولیه در زنجیره تامین صنایع فولاد کشور است. برنامه‌ریزی در یک زنجیره تامین انرژی الکتریکی با ابعاد بزرگ در فضائی پر از تردید و عدم قطعیت، با پیش‌بینی تقاضای انرژی الکتریکی آغاز می‌گردد. در این مقاله یک روش پیش‌بینی بلندمدت تقاضا در زنجیره تامین انرژی الکتریکی صنایع سنگ آهن اسپیدان اصفهان با استفاده از یک روش ترکیبی شامل تبدیل موجک، شبکه عصبی عمیق و تکنیک داده‌کاوی مبتنی بر ماشین یادگیری شدید پیشنهاد شده است. داده‌های مورد نظر در این مطالعه با توجه به اطلاعات ثبت شده از سیگنال تقاضای انرژی الکتریکی صنایع تولیدی سنگ آهن اسپیدان در یک بازه زمانی ۴۰ ماهه و به‌صورت ۲۴ ساعته استخراج و استفاده شده است. داده‌ها در بخشی از دوره مورد نظر ناشی از عدم تولید این صنعت در بازه مورد مطالعه منقطع بود به‌طوری‌که فقط ۴۰ درصد از داده‌ها دارای مقدار و ۶۰ درصد مابقی صفر یا ناهمگون بوده‌اند. این موضوع باعث نقص اطلاعات و بالا رفتن خطای پیش‌بینی در بخش اول الگوریتم پیشنهادی در خروجی شبکه عصبی عمیق تا ۴۰ درصد شد. جهت بهبود پیش‌بینی و کاهش خطای ایجاد شده، با تکمیل مدل پیشنهادی با ماشین یادگیری شدید، امکان ایجاد یک مدل پیش‌بینی بهبودیافته برای انجام آموزش تحت نظارت میسر گردید. در نهایت نتایج به‌دست آمده با تکنیک‌های دیگری مانند ماشین بردار پشتیبان و درخت تصمیم‌گیری مقایسه شده است. نتایج بهبود و کاهش خطا و افزایش قابل توجه دقت روش پیشنهادی در پیش‌بینی بلندمدت تقاضا در زنجیره تامین انرژی الکتریکی صنایع سنگ آهن اسپیدان را نشان می‌دهند.

**کلمات کلیدی:** تبدیل موجک، یادگیری عمیق، ماشین یادگیری شدید، ماشین بردار پشتیبان، درخت تصمیم‌گیری، پیش-بینی تقاضا، زنجیره تامین انرژی الکتریکی، میانگین درصد خطا.

تاریخ ارسال مقاله: ۱۳۹۹/۱۰/۲

تاریخ بازنگری مقاله: ۱۳۹۹/۱۲/۵

تاریخ پذیرش مقاله: ۱۳۹۹/۱۲/۲۳

## ۱- مقدمه

زنجیره تامین انرژی الکتریکی به‌عنوان شبکه تامین‌کننده چند سطحی با مقیاسی وسیع باید توانایی لازم در پاسخ‌گویی به درخواست مورد نیاز سایر متقاضیان ذیل این زنجیره تامین و همچنین زنجیره تامین انرژی الکتریکی صنایع را داشته و قادر به پاسخ‌گویی تقاضای درخواستی با کیفیت مطلوب باشد. یکی از مهم‌ترین مراحل جهت افزایش قابلیت اطمینان در زنجیره تامین مورد نظر، پیش‌بینی تقاضا و سیر تغییرات آن جهت برنامه‌ریزی استراتژیک و بلندمدت آینده است. از این رو با توجه به تنوع استفاده از انرژی الکتریکی و اهمیت استفاده از آن در به‌کارگیری و تبدیل فیزیکی کالاها جهت دستیابی به محصول نهایی در صنایع پر مصرف کشور نظیر صنایع فولاد و صنایع بالادستی و پائین‌دستی آن به‌عنوان صنایع مادر، بررسی نیازهای آینده آن‌ها جهت تامین خطوط اعتباری و برنامه‌ریزی جهت گسترش زیرساخت‌های لازم و توانایی پاسخ‌گویی بلادرنگ به نیازهای پیش رو امری اجتناب‌ناپذیر بوده و هرگونه نوسان و تاخیر در پاسخ به نیاز مشترکان علاوه بر ایجاد نوسان و اختلال در زنجیره تامین انرژی الکتریکی این مصرف‌کنندگان، باعث افزایش هزینه‌های پسا‌افت و اختلال مکرر در زنجیره تولید و خدمات صنایع مرتبط و وابسته خواهد شد [۱،۲]. در این حالت عامل نوسانات مالی پرهزینه و ایجاد ضرر و زیان برای کلیه ذی‌نفعان در سراسر زنجیره تامین کالاهای مصرفی وابسته به این صنایع می‌گردد [۳،۴].

تامین انرژی یکی از اصلی‌ترین معضلات بشر و دنیای صنعتی در عصر حاضر بوده به‌طوری‌که کشورهای مختلف دنیا به دنبال دسترسی به منابع انرژی با قابلیت اطمینان و کیفیت بالاتری هستند [۵،۶]. شایان ذکر است که انرژی الکتریکی از مهم‌ترین انرژی‌هایی است که در دنیای امروز مورد استفاده قرار می‌گیرد [۷،۸] بررسی منحنی‌های پیش‌بینی تقاضا مربوط به سال‌های اخیر رشد روزافزون تقاضا و مصارف انرژی الکتریکی را نشان می‌دهند به‌گونه‌ای که پیش‌بینی می‌شود در آینده‌ای نزدیک و با ظهور تکنولوژی‌های کاربردی و تنوع مصرف، تقاضای این انرژی با افزایش بالایی روبرو گردد [۹،۱۰]. این امر باعث گسترش و تنوع تقاضا می‌شود و تغییرات پیش‌بینی نشده تقاضا از سوی مشترکان پرمصرف نهایی، باعث بروز اختلال و ایجاد نوسان‌های شدید در زنجیره تامین انرژی الکتریکی می‌گردد که در نهایت منجر به بروز مشکلات و اختلال‌های فراوان در زنجیره تامین می‌گردد [۱۱].

بیش‌ترین تمرکز در پژوهش‌های مشابه در زمینه پیش‌بینی تقاضا، بر پیش‌بینی‌های نقطه‌ای استوار است. در مقاله [۱۲] روشی برای انتخاب ویژگی‌ها برای آموزش مدل‌های پیش‌بینی تقاضا و قیمت برق ارائه شده که علاوه بر در نظر گرفتن ارتباط بین ویژگی‌ها و تکرار داده‌های مشابه میان آن‌ها، اثر متقابل ویژگی‌ها بر یکدیگر نیز در نظر گرفته شده است. در مقاله [۱۳] روشی تشکیل شده از چهار بخش برای پیش‌بینی تقاضا و قیمت انرژی الکتریکی به‌عنوان متغیرهای اصلی در زنجیره تامین و خدمات انرژی الکتریکی پیشنهاد شده است. در ابتدا از تبدیل موجک 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. در بخش بعدی یک موتور پیش‌بینی‌کننده بر اساس سیستم چند ورودی-چند خروجی بردار پشتیبان به‌کار گرفته شده و در آخر با توجه به تابع هدف شامل خطای ناشی از پیش‌بینی و روش بهبود یافته کلونی مصنوعی زنبور عسل به تنظیم شاخص‌های شبکه بردار پشتیبان پیشنهادی پرداخته شده است. الگوریتم بهینه‌سازی توده ذرات یکی از روش‌هایی است که برای به‌دست آوردن مقادیر بهینه ماشین‌های بردار پشتیبان در ساختن مدل پیش‌بینی تقاضای انرژی الکتریکی فراوان به‌کار رفته است [۱۴،۱۵]. در مقاله [۱۶] این الگوریتم با الگوریتم بهینه‌سازی گذار شبکه ترکیب گردید. روش ارائه شده در این مرجع شامل دو بخش بود به‌طوری‌که ابتدا از الگوریتم گذار شبکه برای محدودکردن منطقه جستجو برای یافتن مقادیر بهینه استفاده می‌شود و سپس الگوریتم بهینه‌سازی توده ذرات وارد عمل شده تا در منطقه انتخاب شده مقادیر بهینه ماشین بردار پشتیبان را بیابد. همچنین از نظریه آزمون قائم‌آبرای یافتن مقادیر بهینه مدل رگرسیون بردار پشتیبان در این مطالعه استفاده شده است [۱۷]. مرجع [۱۸] روش میانگین رگرسیون چندگانه را به‌صورت چشم-گیری گسترش داده و از تجزیه و تحلیل مولفه‌های اصلی برای خودکارسازی روند انتخاب از میان مجموعه‌ای بزرگ از مدل‌های پیش‌بینی که در دسترس هستند استفاده شده است. این روش برای قیمت‌گذاری بهای برق در ساعت‌های مختلف و در زنجیره تامین خدمات انرژی الکتریکی در سطوح مختلف از طریق داده‌ها بسیار کارآمد است. یکی از روش‌های پیش‌بینی

استفاده از روش میانگین رگرسیون چندکی است که در پیش‌بینی قیمت برق مورد استفاده قرار گرفته است. بیشتر روش‌های ارائه شده در مبحث پیش‌بینی تقاضای انرژی الکتریکی به‌صورت نقطه‌ای بوده که مقدار مورد انتظار تقاضای انرژی را در هر نقطه ارائه می‌دهد. در شبکه‌های هوشمند میزان تقاضای برق افزایش یافته و کمتر از همیشه قابل پیش‌بینی است. در نتیجه، پیش‌بینی بار احتمالاتی، اطلاعات بیشتری را در مورد متغیر بودن و عدم اطمینان مقادیر تقاضا در آینده ارائه می‌دهد و برای برنامه‌ریزی و عملیات در زنجیره تامین سیستم‌های تولید و انتقال انرژی الکتریکی بسیار اهمیت دارد. این روش، یک راه‌کار عملی برای پیش‌بینی تقاضای احتمالاتی با استفاده از میانگین رگرسیون چندکی بر روی مجموعه‌ای از پیش‌بینی‌های نقطه‌ای پیشنهاد می‌کند [۱۹]. در مقاله [۲۰] روش‌هایی شامل ترکیب فزای وزن‌ها و استفاده از الگوریتم خفاش‌برای به‌دست آوردن مقادیر بهینه پارامترهای ماشین بردار پشتیبان و فیلتر کالمن با یکدیگر ترکیب شده‌اند. در مقاله [۲۱] ابتدا یک شبکه توپولوژیکی روز-به-روز<sup>۶</sup> برای یافتن شباهت میان روزها ساخته می‌شود. سپس الگوریتم پیاده‌روی تصادفی همراه با شروع مجدد<sup>۷</sup> 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. در مرجع [۲۲] تمرکز روی پیش‌بینی تقاضا در سطوح پائین زنجیره تامین انرژی الکتریکی و تقاضای خانگی بوده و از روش یادگیری عمیق استفاده شده است. در مقاله [۲۳] نیز مدل جدید دیگری بر اساس شبکه حافظه کوتاه-مدت بلند برای پیش‌بینی بار در پائین‌ترین سطح زنجیره تامین انرژی الکتریکی و در مناطق مسکونی ارائه گردیده است. در مقاله [۲۴] نیز یک شبکه عصبی مبتنی بر روشی اصلاح شده با استفاده از الگوریتم لونبرگ-مارکوارت به‌منظور پیش‌بینی تقاضا ارائه گردیده است. در مرجع [۲۵] روشی ترکیبی برای پیش‌بینی احتمالاتی تقاضای برق براساس ترکیب ماشین یادگیری شدید<sup>۸</sup> (ELM) تعمیم‌یافته، شبکه عصبی موجک و بوت‌استرپ ارائه گردیده است. مدل ارائه شده با استفاده از داده‌های منتخب استاندارد در زنجیره تامین انرژی خدمات و بازار برق استان اونتاریو و کشور استرالیا مورد تست و آزمایش قرار گرفته است. تمرکز مطالعه انجام شده در مقاله [۲۶] بر بهبود شبکه عصبی مبتنی بر رگرسیون چندکی است. در این مطالعه پیش‌بینی‌های احتمالاتی تقاضا در دوره‌های زمانی ارائه شده است. در مقاله [۲۷] یک مدل ترکیبی مبتنی بر شبکه‌های عصبی بازگشتی و روش گردش پویای زمان برای پیش‌بینی پیک تقاضای روزانه پیشنهاد شده است. الگوریتم پیشنهادی بر روی پلت فرم یادگیری عمیق<sup>۹</sup> پیاده‌سازی شده و روی مجموعه داده‌های تقاضای انرژی الکتریکی موجود در شبکه اروپایی در فن‌آوری‌های هوشمند، تست گردیده است. در مقاله [۲۸] تخمین چگالی کرنل و روش میانگین وقتی برای جمع‌آوری پروفیل و چگالی تقاضا به‌کار گرفته شده است و از رمزنگار خودکار متصل به هم برای پیش‌بینی کمیت‌های نامشخص انرژی الکتریکی بهره گرفته شده است. در این روش توان‌های مناطقی که در همسایگی هم قرار دارند برای تخمین تقاضای مناطق وسیع‌تر با روشی مبتنی بر خوشه‌بندی پروفیل درخواست با یکدیگر جمع می‌شوند. در مقاله [۲۹] یک روش داده محور مبتنی بر یادگیری عمیق برای پیش‌بینی کوتاه-مدت تقاضا ارائه شده است. در این مطالعه داده‌ها با استفاده از تبدیل جعبه کاکس<sup>۱۰</sup> مورد پردازش قرار می‌گیرند و وابستگی میان پارامترهایی چون قیمت انرژی برق، دما و تقاضا با استفاده از مدل‌های پارامتری کاپولا و محاسبه آستانه‌ای پیک تقاضا مورد تحلیل قرار گرفته‌اند. در مقاله [۳۰] روشی مبتنی بر شبکه‌های عمیق باقیمانده ارائه شده است. این روش شامل یک استراتژی دو مرحله‌ای به‌منظور بهبود قابلیت تعمیم شبکه مذکور است. همچنین به‌منظور انجام پیش‌بینی احتمالاتی تقاضای انرژی الکتریکی از روش مونت-کارلو استفاده شده است. در مقاله [۳۱] یک مدل شبکه عصبی کانولوشن چند مقیاسی با شناخت زمان پیشنهاد شده است. در ابتدا، یک مدل شبکه عصبی کانولوشن عمیق ویژگی‌های سطوح متفاوت داده‌ها را استخراج می‌کند. در مقاله [۳۲] روشی مبتنی بر شبکه‌های عصبی برای پیش‌بینی احتمالاتی تقاضای خالص در زنجیره تامین انرژی الکتریکی با در نظر گرفتن اثر تولیدات توان خورشیدی ارائه شده است.

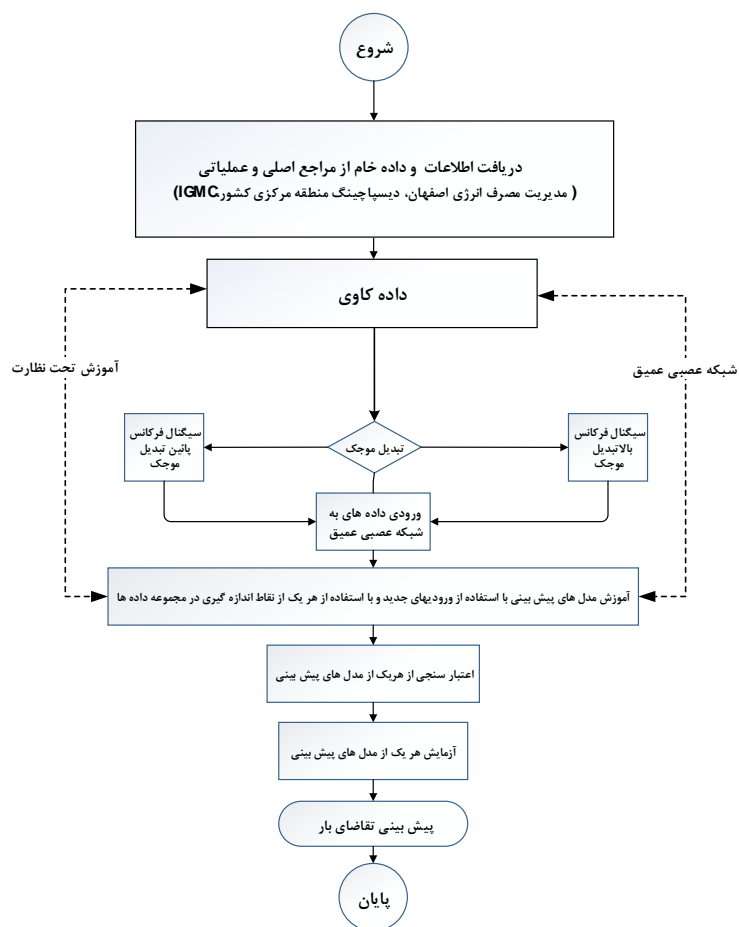
در اکثر تحقیقات ارائه شده افق زمانی پیش‌بینی تقاضای انرژی الکتریکی کوتاه-مدت است. همچنین هدف تعیین شده برآورد تقاضا در سطح مناطق مسکونی و نظیر آن بوده است. از طرفی داده‌های مورد استفاده در تحقیقات ارائه شده به‌عنوان داده‌های

ورودی عمدتاً بر اساس پایگاه‌های داده استاندارد درخواست انرژی الکتریکی منتخب جهانی و داده‌های آب هوایی و فصلی و اکثراً در آخرین سطح زنجیره تامین انرژی الکتریکی بوده و مصرف‌کنندگان با دیمانند پائین مورد مطالعه قرار گرفته‌اند.

## ۲- روش پیش‌بینی پیشنهادی مبتنی بر تبدیل موجک، شبکه عصبی عمیق و ماشین یادگیری شدید

در این مقاله یک روش پیش‌بینی بلندمدت تقاضای انرژی الکتریکی در صنایع تولید سنگ آهن اسپیدان به‌عنوان یکی از ۱۰ صنعت انرژی بر در زنجیره تامین انرژی الکتریکی استان اصفهان پیشنهاد شده است. این روش ترکیبی هوشمند، مبتنی بر تبدیل موجک<sup>۱</sup>[۳۳]، شبکه عصبی عمیق [۳۴]<sup>۲</sup> و ترکیب آن با متدهای داده‌کاوی مبتنی بر ماشین یادگیری شدید [۳۵] است. داده‌های مورد استفاده در این مطالعه شامل داده‌های ۲۴ ساعته روزانه در یک دوره ۴۰ ماهه از ۱ فروردین ۱۳۹۶ الی ۳۱ تیر ۱۳۹۹ است. هر چند نواقص موجود در سیگنال داده‌های در دسترس شرایط روش پیش‌بینی را به سمتی جدید سوق داد، لیکن نواقص موجود در داده‌ها و عدم وجود داده‌های مناسب با طول سیگنال مشابه داده‌های واقعی تقاضا و عدم دسترسی به داده‌های متفاوت، نوآوری و ایجاد مسیری جدید جهت دستیابی به خطای قابل قبول را در افق زمانی بلند مدت فراهم نمود. از وجوه تمایز این تحقیق با سایر تحقیقات مشابه می‌توان به حداقل داده‌های لازم و تنها سابقه سیگنال تقاضا در دوره مورد نظر، نقص اطلاعات موجود در سری زمانی داده‌های در دسترس و منقطع بودن آن اشاره نمود. با توجه به این نکته که فرآیند پیش‌بینی تقاضا در یک افق زمانی بلندمدت انجام گرفته و همچنین داده‌ها از کمترین عدم وضوح لازم برخوردار بودند، وجود تغییرات شدید و ناگهانی در مصرف ساعتی باعث شد تا طول سری زمانی یکسان نبوده و مشکلات پیش‌رو بیشتر گردد. در ادامه نتایج به‌دست آمده با روش‌های دیگری مانند ماشین بردار پشتیبان<sup>۳</sup>، درخت تصمیم‌گیری<sup>۴</sup> با داده‌های مشابه مورد مقایسه قرار گرفته است. نتایج شبیه‌سازی حاصل از روش پیشنهادی نشانگر توانایی قابل توجه روش به کار رفته در پیش‌بینی بلند مدت تقاضا در زنجیره تامین صنایع تولید سنگ آهن اسپیدان با خطای بسیار مناسب و قابل قبول است. کاوش جدید جهت ایجاد راه‌کاری موثر و قابل قبول در این زمینه از نقاط قوت تحقیق پیش‌رو است. روندنمای روش پیشنهادی در شکل (۱) نشان داده شده است. در ابتدا داده‌های خام، برگرفته از ثبات‌های<sup>۵</sup> مستقر در شبکه سراسری انرژی الکتریکی کشور و حوزه منطقه‌ای اصفهان به‌عنوان زنجیره تامین انرژی الکتریکی صنعت مورد مطالعه در این تحقیق در افق زمانی مورد نظر جمع‌آوری می‌گردد. پس از انجام فرآیند پیش‌پردازش، داده‌ها به‌صورت تصادفی به دو زیرمجموعه آموزش معادل ۸۰ درصد کل داده‌ها و زیرمجموعه معادل ۲۰ درصد داده‌ها برای تست، ارزیابی مدل و پیش‌بینی بلندمدت انرژی الکتریکی تقسیم می‌گردد. اگر در طول فرآیند آموزش مدل‌ها به‌جای یادگیری رابطه بین ورودی و خروجی مطلوب فقط داده‌ها را حفظ کنند، در این صورت پدیده بیش‌برازش داده اتفاق می‌افتد و مدل جدید قابلیت تعمیم برای داده‌های جدید را نخواهد داشت. لازم به ذکر است داده‌های آزمایش به هیچ‌عنوان در پایگاه داده آموزش قرار ندارند. در ادامه داده‌ها به‌عنوان ورودی به تبدیل موجک یک سطحی وارد شده و به دو طیف سیگنال فرکانس بالا<sup>۶</sup>  $d1^6$  و فرکانس پائین<sup>۷</sup>  $a1^7$  تجزیه می‌گردد. در بخش اول الگوریتم پیشنهادی داده‌های تجزیه شده از خروجی تبدیل موجک ورودی شبکه‌های یادگیری عمیق را تامین می‌کند و شبکه‌ها تحت آموزش، پیش‌بینی و ارزیابی قرار می‌گیرند. به‌دلیل فقدان اطلاعات و نواقص موجود در سری زمانی داده‌های صنعت تحت مطالعه و با توجه به درصد بالای خطا در مرحله اول، در بخش دوم با استفاده از خروجی تبدیل موجک و دو شبکه یادگیری عمیق، داده‌ها وارد مرحله آموزش نظارت شده با تاخیر قرار می‌گیرند. جزئیات بخش دوم روش پیشنهادی به تفصیل در ادامه بیان می‌گردد. نتایج خروجی این بخش تحت یک ماتریس با دو ویژگی به‌عنوان ورودی شبکه‌های جدید یادگیری عمیق آموزش دیده وارد شده و پس از پیش‌بینی، مورد تست و ارزیابی قرار می‌گیرند. در بخش سوم خروجی نهایی شبکه‌های جدید یادگیری عمیق آموزش دیده در بخش دوم به‌عنوان ورودی ماشین یادگیری شدید<sup>۸</sup> که ابزاری قدرتمند در کار با داده‌های خارج از دسترس و ناقص است، در نظر گرفته می‌شود. خروجی این شبکه هدف نهایی پیش‌بینی تقاضا در الگوریتم پیشنهادی است.

## ۲-۱- داده‌کاوی و بررسی محتوای داده‌ها



شکل (۱): روند نمای روش ترکیبی پیشنهادی  
Figure (1): The proposed method flowchart

سیگنال تقاضا در صنایع تولید سنگ آهن اسپیدان دارای کمبودهای زیادی است به طوری که از حدود ۴۰ ماه داده‌های ۲۴ ساعته فقط ۴۰ درصد داده‌ها دارای مقدار بوده و بقیه اطلاعات صفر و یا منفی است. بنابراین داده‌هایی که طول آن یکسان با طول سری زمانی مورد نظر باشد وجود ندارد و امکان ایجاد رابطه بین ورودی و خروجی<sup>۹</sup> در شبکه‌های عصبی معمولی ممکن نیست. کمبودهای موجود در تک ویژگی موجود در روند پیش‌بینی، تحقیق مورد نظر را به سمت پیشنهاد یک روش ترکیبی سه مرحله‌ای جهت حصول برآورد تقاضا با خطائی قابل قبول سوق داد.

## ۲-۲- پیش-پردازش داده‌ها

همان‌گونه که در شکل‌های (۲-الف) و (۲-ب) نشان داده شده سیگنال اصلی تقاضای صنعت مورد مطالعه به دلیل عدم تولید در ۶۰ درصد از بازه زمانی مورد نظر ناقص و ناهمگون است. در شکل (۳) وضعیت سیگنال اصلی پس از حذف مقادیر ناهمگون و صفر ارائه گردیده و نشان می‌دهد که حدود ۴۰ درصد از داده‌ها معادل ۱۲۰۰۰ ساعت دارای مقادیر غیر صفر هستند. بسیاری از اطلاعاتی که در توصیف زمانی یک سیگنال قابل مشاهده نیستند، به راحتی در توصیف فرکانسی همان سیگنال قابل دسترسی هستند. تبدیل‌های ریاضی مانند تبدیل موجک برای به دست آوردن اطلاعات بیشتر از یک سیگنال در حوزه زمان بر روی آن سیگنال اعمال می‌شوند. در عمل، سری زمانی تقاضای انرژی الکتریکی دارای اطلاعات نامنظم بوده که ناشی از تغییرات رفتاری پیک تقاضا، تغییرات سطح تقاضا و شیب تغییرات پیک تقاضا است [۳۶]. اگرچه مولفه‌های فرکانس بالا رفتاری جهشی و نویزی دارند، مولفه فرکانس پایین یک الگوی شفاف و مشابه سیگنال تقاضای اصلی ارائه می‌دهد که تا

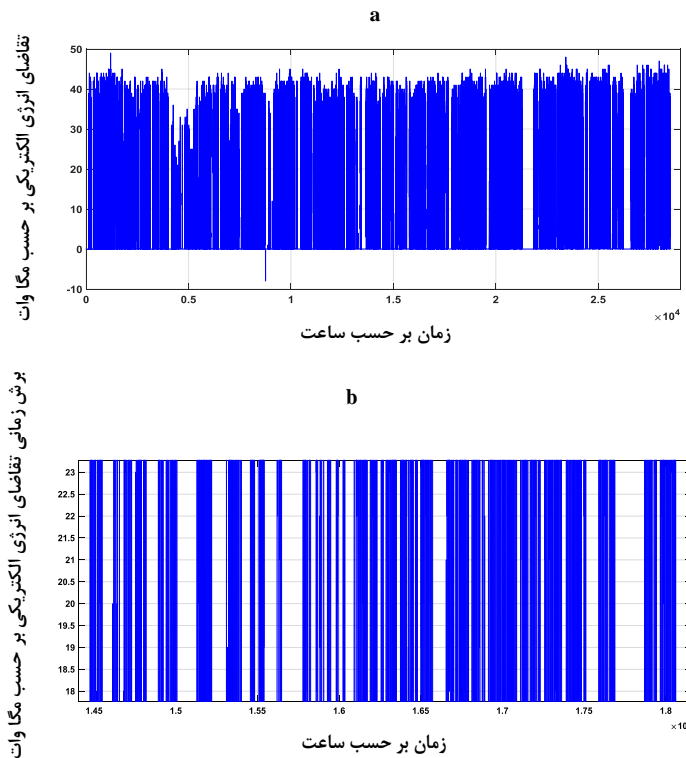
حدودی هموارتر از سیگنال اصلی تقاضا است. در خروجی تبدیل موجک سیگنال اصلی پیک تقاضا S در یک سطح به دو مولفه فرکانس پایین  $a_1$  و فرکانس بالای  $d_1$  تجزیه می‌شود. تبدیل موجک سیگنال زمانی  $f(t)$  معمولاً به صورت زیر بیان می‌شود:

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

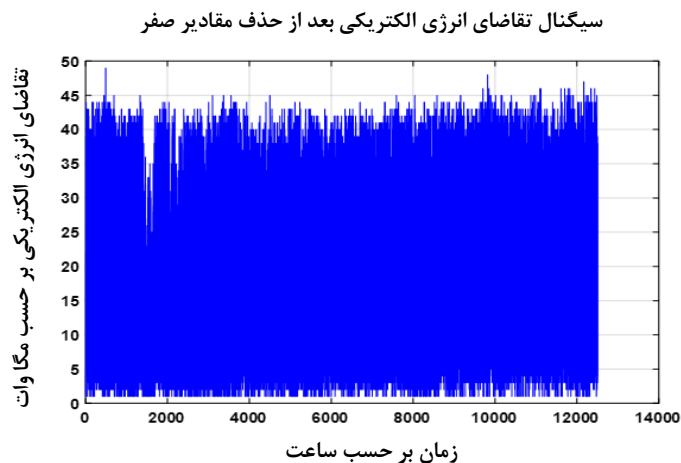
که در آن:

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

a و b به ترتیب پارامترهای مقیاس و شیفت زمانی و  $\psi(t)$  موجک مادر هستند [۳۷]. خانواده موجک مادر داباجیز<sup>۱</sup> (Db) از موجک‌های متعامدند که برای تجزیه سیگنال تقاضای روزانه مناسب هستند [۳۸].



شکل (۲): سیگنال تقاضای انرژی الکتریکی و برش زمانی تقاضای انرژی الکتریکی منقطع صنایع تولید سنگ آهن اسپیدان  
Figure (2): (a): Electricity demand signal and (b): Time cut of intermittent electricity demand of Espidan ironstone production industries

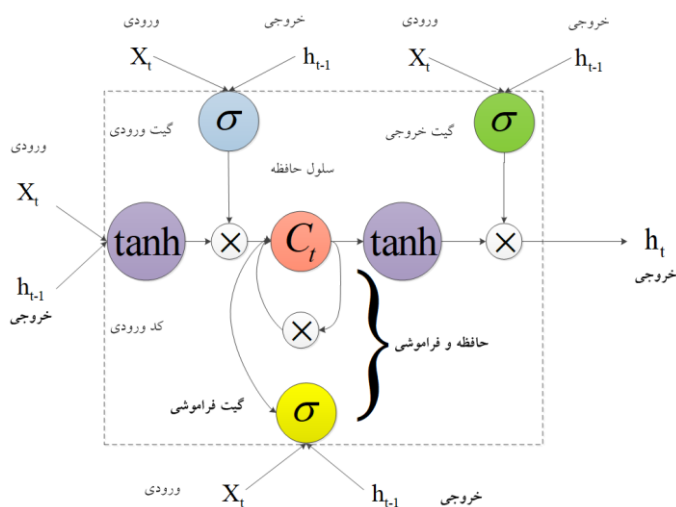


شکل (۳): سیگنال تقاضای انرژی الکتریکی صنایع تولید سنگ آهن اسپیدان پس از حذف مقادیر صفر  
Figure (3): Electrical energy demand signal of Espidan ironstone production industries after elimination of heterogeneous zero values

## ۳-۲- آموزش و به‌کارگیری مدل‌های پیش‌بینی

### ۳-۲-۱- آموزش شبکه‌های عصبی یادگیری عمیق در بخش اول

یکی از شبکه‌های عصبی که به‌طور وسیعی در پیش‌بینی سری‌های زمانی مورد استفاده قرار می‌گیرد شبکه عصبی عمیق است. کاربرد این شبکه‌ها در محاسبه توابع غیرخطی و مدل‌سازی داده‌ها با تعداد پارامترهای کمتر عملکرد بالایی را نشان داده است. همچنین شبکه‌های عصبی عمیق از مدل‌سازی ریاضی و روش‌های پیچیده برای پردازش داده‌ها استفاده کرده و در نتیجه الگوهای پنهان داده را به خوبی می‌یابند. شکل (۴) ساختار معماری یک واحد شبکه عصبی یادگیری عمیق را نشان می‌دهد. این شبکه روشی برای آموزش عمیق است و هدف اصلی ارائه این روش جلوگیری از صفر شدن گرادیان در روش کاهش گرادیان است که در زمان آموزش یک مدل شبکه عصبی با استفاده از الگوریتم پس‌انتشار رخ می‌دهد. با از بین رفتن شیب، در مرحله آموزش بیش‌برازش داده‌ها رخ می‌دهد و چنین مدلی توانایی تعمیم در زمان آزمایش را ندارد. در شبکه عصبی عمیق هر نورون در لایه مخفی یک سلول حافظه است و یک لبه بازگشتی دارد که به خود نورون متصل می‌شود. این لبه دارای وزنی برابر با یک است که باعث حفظ شیب در مرحله آموزش می‌شود. این شبکه دارای پنج واحد اصلی شامل بلوک حافظه، سلول‌های حافظه، واحد دریافت ورودی‌ها، واحد خروجی‌ها و بلوک فراموشی است. سلول‌های حافظه بازگشتی خطی دارند که با عنوان (CEC) شناخته می‌شوند. سیگنال‌های فعال‌سازی و خطا توسط CEC در شبکه به گردش در می‌آیند که باعث می‌شود این بخش مانند یک واحد ذخیره‌سازی کوتاه‌مدت عمل کند. واحدهای ورودی، خروجی و فراموشی آموزش داده می‌شوند تا تصمیم بگیرند که کدام اطلاعات باید در واحد حافظه ذخیره شوند و در چه بازه زمانی و در چه زمانی اطلاعات ذخیره شده خوانده شوند. تابع هدف E با استفاده از تابع کاهش گرادیان و وزن‌های  $W_{lm}$  به‌روزرسانی می‌شود.



شکل (۴): معماری یک واحد شبکه عصبی عمیق

Figure (4): A deep neural network unit architecture

وزن‌ها با استفاده از  $\Delta W_{lm}$  که با استفاده از نرخ آموزش  $\alpha$  و شیب منفی تابع هدف E به‌دست می‌آید، به‌روز می‌شوند. وزن‌های واحد خروجی با استفاده از روش استاندارد پس‌انتشار به‌صورت زیر به‌روز رسانی می‌شود [۳۹]:

$$\Delta w_{km}(t) = \delta_k(t) y_m(t-1) \quad (3)$$

$$\delta_k(t) = -\frac{\partial E(t)}{\partial z_k(t)} \quad (4)$$

بر اساس مقادیر هدف  $t_k$ ، تابع هدف، مربعات خطا است:

$$\delta_k(t) = f'_k(z_k(t)) e_k(t) \quad (5)$$

$$e_k(t) = t_k(t) - y_k(t) \quad (6)$$



وزن‌های یونیت منبع برای اتصال به گیت خروجی تغییر می‌کند که این وزن‌ها نیز با استفاده از روش پس‌انتشار و با استفاده از رابطه زیر به دست می‌آیند:

$$\Delta w_{out_j m}(t) = \alpha \delta_{out_j}(t) y_m(t) \quad (7)$$

خطای وضعیت داخلی با استفاده از  $e_s$  نشان داده می‌شود و برای هر یک از سلول‌های حافظه محاسبه می‌گردد:

$$e_s(t) = y_{out_j}(t) \left( \sum_k w_{kc_j} \delta_k(t) \right) \quad (8)$$

روابط مذکور عملیات‌های گذر به جلو، گذر به عقب و فرآیند آموزش یک واحد شبکه را توصیف می‌نمایند. تعداد زیادی از واحدها به صورت سری به یکدیگر متصل می‌شوند تا شبکه عصبی عمیق تشکیل شود به طوری که خروجی یک واحد ورودی واحد بعدی خواهد بود. با حذف مقادیر صفر و ناهمگون از سیگنال تقاضای موجود، هدف ما پیش‌بینی تقاضای زمان‌هائی است که صنایع تولید سنگ آهن اسپیدان در حال تولید هستند. شبکه‌های عصبی عمیق به کار رفته در این مرحله آموزش می‌بینند تا بتوانند مقادیر تقاضای سیگنال فرکانس بالا و فرکانس پائین را پیش‌بینی نمایند. در نهایت با استفاده از عکس تبدیل موجک<sup>۲</sup> سیگنال‌های پیش‌بینی خروجی از شبکه عصبی عمیق در هر دو طیف فرکانس بالا و پائین جمع شده و سیگنال جدید پیش‌بینی شده S تولید و خطای RMSE و MAPE مربوط به این مرحله محاسبه می‌گردد.

### ۲-۳-۲- آموزش شبکه‌های عصبی عمیق در بخش دوم

با توجه به بالا بودن خطای حاصله در پیش‌بینی بخش قبل، آموزش تحت نظارت و پیش‌بینی داده‌ها جهت ایجاد دو شبکه پیش‌بینی‌کننده داده‌های فرکانس بالا و پائین اقدام می‌شود. ویژگی به کار رفته در این بخش بر این اصل استوار است که داده‌های خروجی از تبدیل موجک با همان روال موجود در بخش قبل به عنوان ورودی دو شبکه عصبی عمیق تحت آموزش نظارت شده قرار می‌گیرند. ورودی‌ها و خروجی‌های این دو شبکه در این بخش با یک تاخیر یک ساعته وارد می‌گردند به طوری که از نقطه a در ساعت یک بتوانند نقطه b در ساعت ۲ را پیش‌بینی نمایند. هدف ما در این مرحله، تولید یک شبکه عصبی پیش-بینی‌کننده با تاخیر یک ساعته است. ایجاد تاخیر با توجه به این نکته که داده‌های در دسترس منحصر به سیگنال مصرفی تقاضا آن هم به شکل ناقص بوده و همچنین نداشتن اطلاعات و ویژگی‌هائی با طول سیگنال مشابه با سیگنال تقاضا، با هدف امکان بازسازی سابقه تقاضا و داشتن الگوی تقاضا در ساعت قبل جهت یک برآورد قابل قبول با خطای پائین و برای ساعت بعد انجام می‌گردد. هدف ما در این مرحله تولید یک شبکه عصبی عمیق پیش‌بینی‌کننده جدید است. به عبارتی شبکه‌های مورد نظر در این مرحله آموزش می‌بینند تا با استفاده از سابقه تقاضای انرژی در ساعت قبل تقاضا را در ساعت بعد پیش‌بینی نمایند. شبکه‌های عصبی مورد نظر این بخش و در این مرحله برای آموزش به کار برده شده و به دنبال پیش‌بینی تقاضا نیستند. در واقع داشتن حداقل اطلاعات و نداشتن هیچ‌گونه سیگنال یا ویژگی متناسب با سیگنال تقاضا، مزیت و نوآوری این تحقیق در تخمین و پیش‌بینی تقاضای بلند مدت انرژی الکتریکی است. حال یکبار دیگر داده‌های ورودی را بدون هیچ‌گونه تاخیر ساعتی وارد شبکه‌های آموزش دیده بالا نموده تا بر اساس آموزش تحت نظارت خود اقدام به پیش‌بینی خروجی نمایند. خروجی ناشی از دو شبکه آموزش دیده با داده‌های ورودی بدون تاخیر منجر به تولید ماتریس دو سطری با داده‌های خروجی ناشی از شبکه فرکانس بالای Td1 و شبکه فرکانس پائین T<sub>a1</sub> می‌گردد. ماتریس جدید با داشتن دو ویژگی بعنوان ورودی یک شبکه جدید عصبی عمیق وارد شده و در خروجی خود سری زمانی پیش‌بینی تقاضای انرژی الکتریکی<sup>۵</sup> اصلی مورد نظر را ارائه می‌دهد. نتایج حاصل از شبکه مورد نظر همانند بخش قبل با ۲۰ درصد داده‌های موجود در بخش تست پایگاه داده، مورد ارزیابی و اعتبار سنجی قرار می‌گیرد.

### ۲-۳-۳- ماشین یادگیری شدید جهت کار با داده‌های خارج از محدوده ELM<sup>۶</sup>

به دلیل کمبود موجود در داده‌ها، عدم یکسان بودن طول داده و همچنین تغییرات شدید و ناگهانی در تقاضای ساعتی موجود در سیگنال مورد نظر در بخش قبل، در این قسمت از روش ماشین یادگیری شدید استفاده شده و مسیر آموزش مدل جدید،

مورد ارزیابی و سنجش خطای مجدد قرار می‌گیرد. به این ترتیب خروجی بخش دوم به عنوان ورودی شبکه آموزش تحت یادگیری شدید جدید و خروجی آن نیز سری زمانی پیش‌بینی شده تقاضا از بخش دوم است. مراحل تست، ارزیابی و اعتبار سنجی در این مرحله نیز تکرار می‌گردد. ماشین یادگیری شدید برای نخستین بار توسط هوانگ و همکارانش [۴۰] از طریق ساختن یک لایه مخفی با استفاده از شبکه عصبی پیش‌خور (SLFN) پیشنهاد شد. ویژگی اصلی ماشین یادگیری شدید مقاردهی اولیه تصادفی به وزن‌ها (W) و بایاس‌های (b) شبکه عصبی است. بنابراین تنها لازم است تا برای بهینه‌سازی وزن-های متصل به لایه خروجی از الگوریتم‌های زمان‌بری مانند الگوریتم پس انتشار (BP) استفاده کرد. با ظهور داده‌های با ابعاد بالا و با کاربردهای مختلفی مانند بازبازی اطلاعات، طبقه‌بندی خودکار متن و بیوانفورماتیک، انتخاب ویژگی در داده‌کاوی و یادگیری ماشین اهمیت بیشتری پیدا کرده است [۴۱]. در آموزش تحت نظارت نمونه‌های آموزش به‌عنوان ورودی‌ها و مقدار خروجی مطلوب به‌عنوان هدف یا خروجی انتخاب می‌گردند. در این بخش ساختار ماشین یادگیری شدید در مد رگرسیون چند متغییره خطی بررسی می‌شود. فرض کنید مجموعه داده‌هایی شامل N نمونه آموزشی به شکل زیر در دسترس است:

$$\{(x_i, y_i)\}_{i=1}^N, x_i \in \mathbb{R}^n, y_i \in \mathbb{R} \quad (9)$$

در رابطه فوق  $x_i \in \mathbb{R}^n$  ورودی مدل و  $y_i \in \mathbb{R}$  خروجی مطلوب (هدف) مدل است. 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 مدل کرد [۴۲]:

$$\sum_{i=1}^L \beta_i g(w_i \cdot x_j + b_i) = y_j, j=1, 2, \dots, N \quad (10)$$

که در آن المان‌های بردار وزن عبارتند از:

$$w_i = [w_{i1}, w_{i2}, \dots, w_{in}]^T \quad (11)$$

این المان‌ها به‌صورت تصادفی انتخاب شده که به نورون i ام از لایه ورودی و لایه مخفی متصل است،  $b_i$  مقدار تصادفی بایاس است که به گره i ام در لایه مخفی متصل است.  $\beta_i$  وزنی است که به نورون i ام در لایه مخفی و لایه خروجی متصل است.  $W_i \cdot X_i$  حاصل ضرب داخلی بردار وزن و ماتریس ورودی است و تابع فعالیت لایه خروجی خطی انتخاب شده است. N معادله فوق را می‌توان به‌صورت فشرده زیر نوشت:

$$\begin{cases} H \times \beta = y \\ \beta = [\beta_1, \beta_2, \dots, \beta_L]^T \\ y = [y_1, y_2, \dots, y_N]^T \end{cases} \quad (12)$$

$$H(w_1, \dots, w_L, x_1, \dots, x_N, b_1, \dots, b_L) = \begin{bmatrix} g(w_1 \cdot x_1 + b_1) & \dots & g(w_L \cdot x_1 + b_L) \\ \vdots & \dots & \vdots \\ g(w_1 \cdot x_N + b_1) & \dots & g(w_L \cdot x_N + b_L) \end{bmatrix}_{N \times L} \quad (13)$$

با بررسی روابط فوق می‌توان دریافت که تمامی پارامترها به غیر از وزن خروجی  $\beta$  در مدل ماشین یادگیری شدید ثابت هستند. بنابراین هدف یافتن حلی برای بردار وزن خروجی با استفاده از رابطه خطی (۱۱) است. اگرچه در بسیاری از موارد H یک ماتریس مربعی نیست، در نتیجه برداری مانند  $\beta$  وجود ندارد تا در رابطه (۱۱) صدق کند. روش مرسوم برای حل این مشکل یافتن کوچک‌ترین مربعات بهینه  $\hat{\beta}$  با مینیمم کردن تابع خطای متناظر با آن است:

$$\min \|y - H\beta\|_2^2 \quad (14)$$

در نتیجه حل بهینه با توجه به حداقل نرم  $l_2$  به فرم زیر بیان می‌شود:

$$\hat{\beta} = H^\dagger y \quad (15)$$

$H^\dagger$  ماتریس معکوس تعمیم‌یافته مور-پنروز<sup>۹</sup> از ماتریس لایه مخفی به لایه خروجی یعنی H است. از آنجا که تعداد نمونه‌های آموزشی به‌طور معمول بیشتر از تعداد نورون‌های لایه مخفی ( $N > L$ ) است رابطه (۱۴) را می‌توان به شکل زیر بازنویسی کرد:

$$\hat{\beta} = (H^T H)^{-1} H^T y \quad (16)$$

## ۲-۴- میانگین مربعات خطا

الگوریتم کوچکترین میانگین مربعات نمونه‌ای از آموزش تحت نظارت است که در آن قوانین یادگیری با مجموعه‌ای از نمونه‌های صحیح تعیین می‌شوند [۴۳].

$$\{p_1, t_1\}, \{p_2, t_2\}, \dots, \{p_q, t_q\} \quad (17)$$

$p_q$  و  $T_q$  به ترتیب ورودی شبکه و هدف متناسب با آن است. با اعمال هر ورودی به شبکه، خروجی شبکه با هدف مقایسه می‌شود. الگوریتم کوچکترین میانگین مربعات، وزن‌ها و بایاس شبکه را برای مینیمم کردن میانگین مربعات خطا تنظیم می‌کند. خطا برابر با تفاضل خروجی مطلوب شبکه از خروجی آن است.

## ۲-۵- الگوریتم دستیابی به کوچکترین میانگین مربعات خطا

اگر بتوان مقادیر آماری  $R$  و  $h$  را محاسبه کرد، می‌توان به‌طور مستقیم مینیمم را تعیین کرد. اگر به‌دست آوردن  $R^{-1}$  سخت یا طولانی باشد، می‌توان از روش کاهش گرادیان، گرادیان را محاسبه نمود. معمولاً محاسبه  $h$  و  $R$  ساده نیست. به این دلیل از تقریب روش بیشترین کاهش گرادیان به شکلی استفاده می‌شود که در آن گرادیان تخمین زده شود. عنصر کلیدی نظریه ویدرو-هوف تخمین میانگین مربعات خطای تابع  $F(x)$  است [۴۴].

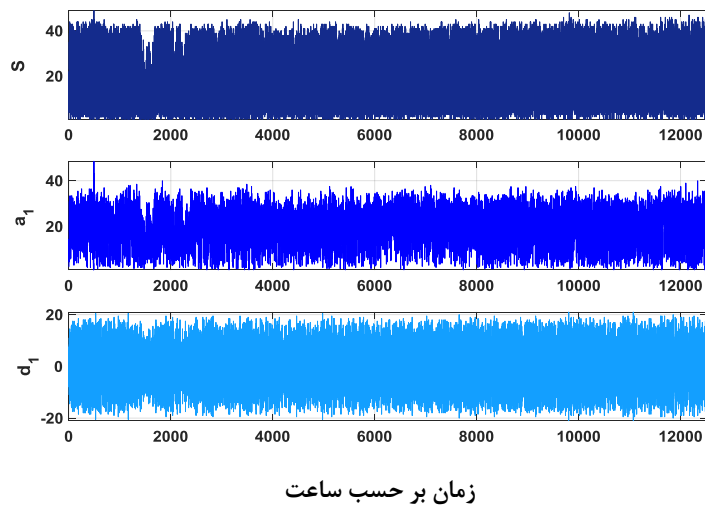
## ۲-۶- ارزیابی مدل‌های پیش‌بینی

برای ارزیابی مدل‌های پیش‌بینی از معیارهایی جهت سنجش چگونگی عملکرد مدل استفاده می‌شود. این معیارها در حقیقت خطای مدل‌های پیش‌بینی را ارزیابی می‌نمایند. معیارهای متداول شامل میانگین مربعات خطا (MSE)، جذر میانگین مربعات خطا (RMSE)، میانگین خطای مطلق (MAE)، میانگین قدر مطلق درصد خطا (PE) هستند. این معیارها هرچه مقدار عددی کوچک‌تری داشته باشد نتیجه مطلوب‌تر است.

## ۳- نتایج شبیه‌سازی


همان‌گونه که در قسمت‌های قبل اشاره گردید، داده‌هائی که قابلیت ورود به فرآیند مورد نظر را داشته و منجر به نتایج قابل قبول و موجه باشند در اقلیت هستند. بنابراین جهت دستیابی به نتایج قابل قبول و حداقل خطا و همچنین جهت دستیابی به اهداف قابل قبول در فرآیند تحقیق مورد نظر، همان‌گونه که در بخش‌های قبل بیان شد از روشی هوشمند و ترکیبی مبتنی بر تبدیل موجک، شبکه‌های عصبی یادگیری عمیق، آموزش نظارت شده و ماشین یادگیری شدید استفاده شد. در این قسمت نتایج و خروجی هر بخش ارائه می‌گردد. سیگنال‌های خروجی ناشی از تبدیل موجک که در شکل (۵-الف) نشان داده شده وارد شبکه‌های عصبی تحت آموزش می‌شوند. شکل (۵-ب) مقدار خطای RMSE ناشی از شبکه یادگیری عمیق مورد تست جهت داده‌های ورودی فرکانس پائین را نشان می‌دهد. همچنین مقدار پیش‌بینی نهائی خروجی از شبکه یادگیری عمیق برای ۲۵۰۰ روز و خطای حاصل از فرآیند پیش‌بینی و مقدار RMSE جهت داده‌های ورودی فرکانس پائین  $a_1$  در شکل (۶-الف) ارائه گردیده است.

**a** خروجی تبدیل موجک و تبدیل به طیف فرکانس بالا و پائین



زمان بر حسب ساعت

**b** فرآیند آموزش

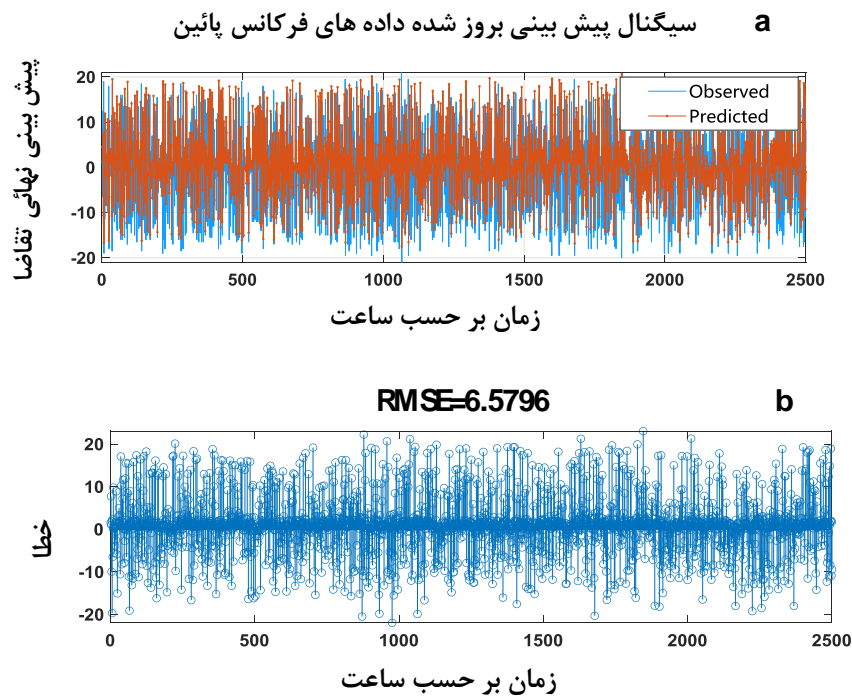


شکل (۵): آموزش ناشی از شبکه عصبی عمیق مورد نظر جهت داده های ورودی فرکانس پائین

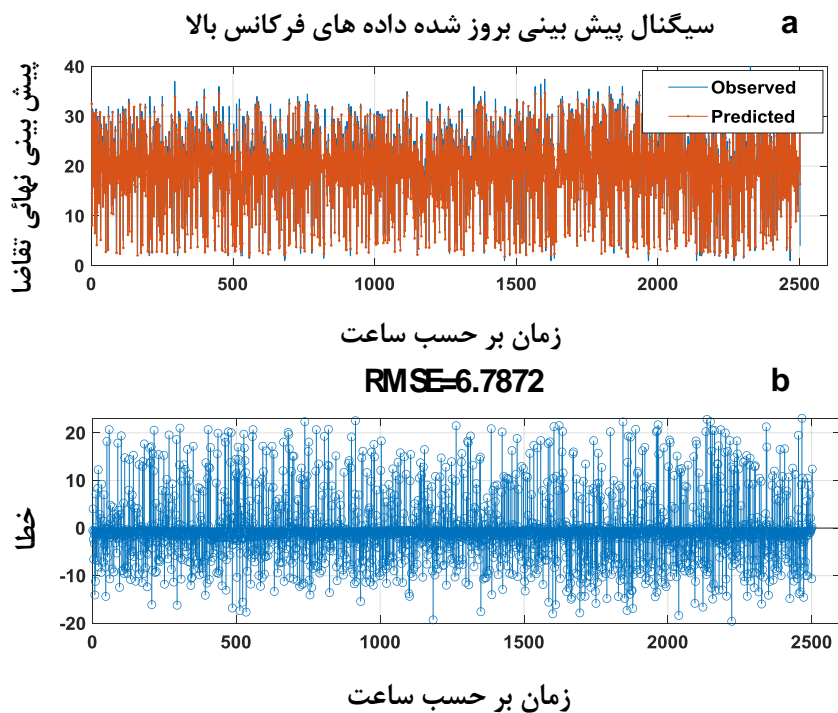
Figure (5): (a): Output signals of wavelet decomposition and (b): deep learning neural network training process for low frequency input data

شکل (۶-ب) محدوده خطای به دست آمده در این مرحله را که حدود ۴۰ درصد بوده و مقدار RMSE در محدوده ۶/۵۷۹۶ است را نشان می‌دهد. علیرغم این که در تکرارهای مکرر آموزش مدل، مقدار RMSE کاهش یافته، ولی فرآیند آموزش انجام گرفته به دلیل فقدان اطلاعات و ضعف سیگنال اصلی دارای خطای بالایی است. کلیه فرآیندهای مذکور برای ورود طیف فرکانس بالا خروجی تبدیل موجک تکرار گردید و نتایج آن در شکل‌های (۷-الف) و (۷-ب) نشان داده شده است. شکل (۸) مقدار خطای RMSE آموزش ناشی از شبکه عصبی عمیق برای داده‌های ورودی فرکانس بالا را نشان می‌دهد. فرآیند پیش‌بینی اولیه در این بخش که با استفاده از یک ویژگی انجام گرفته برای هر کدام از سیگنال‌های  $a_1$  و  $d_1$  که شکل آنها نشان داده شد، به ترتیب مقادیر ۶/۵۷ و ۶/۷۸ را داشته که سیگنال مجموع آن ( $S$ ) خطای بالاتر از ۱۳ را نشان می‌دهد. در این مرحله با وجود خطای خارج از محدوده و غیر قابل قبول در پیش‌بینی انجام شده در بخش قبل، با استفاده از فرآیند جدید مبتنی بر آموزش تحت نظارت شبکه عصبی یادگیری عمیق اقدام به آموزش مدل‌های پیش‌بینی با تاخیر یک ساعته شده است.


خروجی‌های ناشی از شبکه یادگیری عمیق و آموزش تحت نظارت در این مرحله تحت نام ماتریس ویژگی با دو سطر  $T_{d1}$  و  $T_{a1}$  معرفی و تولید شده و در شکل (۹) نشان داده شده است. سیگنال‌های ارائه شده به عنوان ماتریس ویژگی جدید و به عنوان ورودی به شبکه یادگیری عمیق آموزش دیده وارد شده و اقدام به پیش‌بینی جدید می‌گردد. همچنین خطای مجذور میانگین مربعات خطا یا RMSE ناشی از این مرحله آموزش و ایجاد ماتریس ویژگی در نمودار شکل (۱۰) نشان داده شده است.



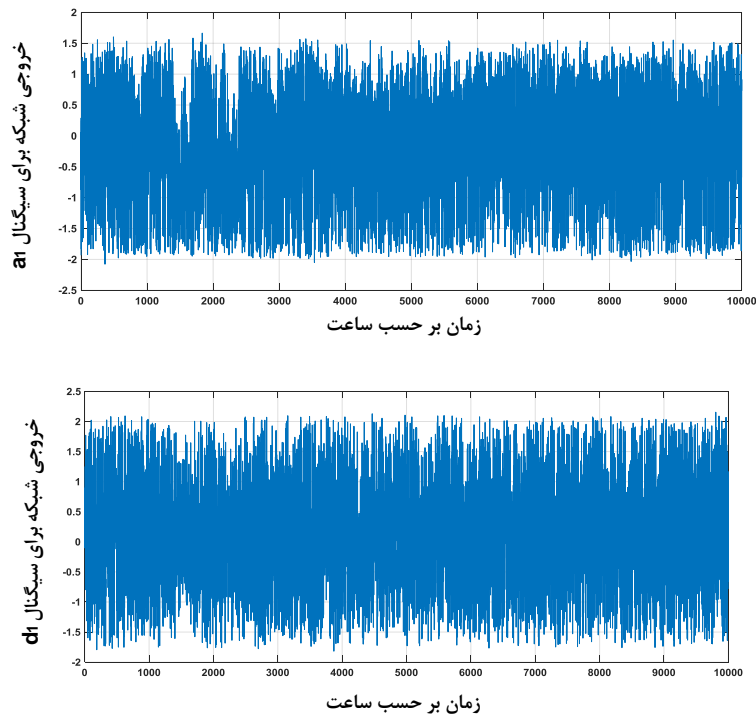
شکل (۶): پیش‌بینی نهائی خروجی از شبکه عصبی عمیق برای ۲۵۰۰ ساعت و خطای ناشی از داده‌های آموزش دیده فرکانس پائین  
Figure (6): (a): Final forecasting output of deep learning neural network for 2500 hours and (b): error of low frequency trained data



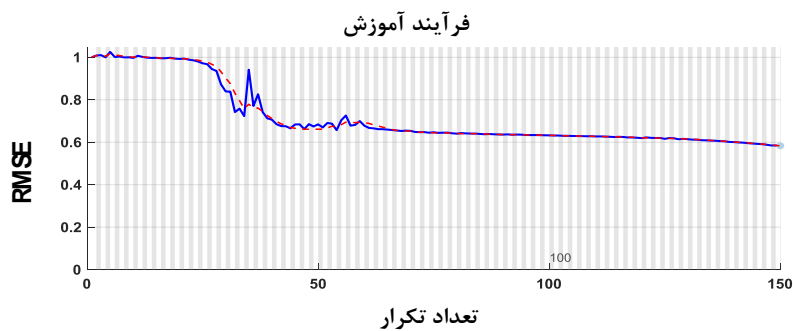
شکل (۷): پیش‌بینی نهائی خروجی از شبکه یادگیری عمیق برای ۲۵۰۰ ساعت و خطای حاصله ناشی از داده‌های آموزش دیده فرکانس بالا  
Figure (7): (a): Final forecasting output of deep learning network for 2500 hours and (b): the resulting error of high frequency trained data



شکل (۸): مقدار خطای RMSE آموزش ناشی از شبکه عصبی عمیق برای داده‌های ورودی فرکانس بالا  
Figure (8): The RMSE error amount of deep neural network training for high frequency input data



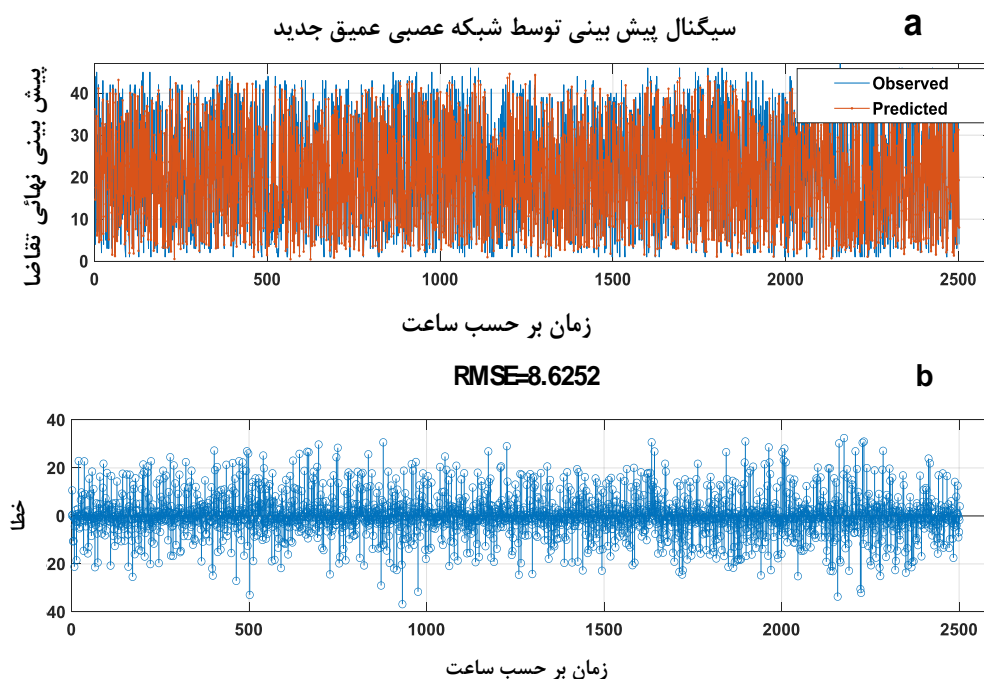
شکل (۹): سیگنال  $T_{d1}$  و  $T_{a1}$  تشکیل دهنده سطر اول و دوم ماتریس ویژگی ورودی به شبکه عصبی عمیق جدید  
Figure (9): (a): The  $T_{a1}$  signals and (b):  $T_{d1}$ , The first and second rows of the input feature matrix of new deep learning neural network



شکل (۱۰): مقدار خطای آموزش شبکه عصبی عمیق ناشی از جمع هر دو سیگنال  $T_{a1}$  و  $T_{d1}$   
Figure (10): The RMSE error amount of deep learning neural network training due to the sum of both  $T_{a1}$  and  $T_{d1}$  signals

همان‌گونه که دیده می‌شود سیر کاهش خطا بر اساس معیار RMSE در عدد ۶ همگرا و تثبیت شده است. همچنین خطای محاسبه شده در این نمودارها خطای کل و ناشی از جمع دو سیگنال  $a_1$  و  $d_1$  و مطابق رابطه  $S=a_1+d_1$  است.

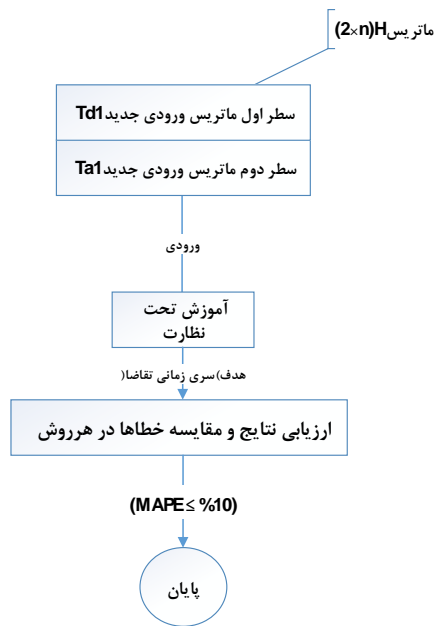
با توجه به نتایج ارائه شده می‌توان بیان نمود که روند ترکیبی به‌کار رفته در این مرحله موثر بوده و قابلیت کاهش خطای RMSE را دارد. پیش‌بینی ارائه شده توسط شبکه عصبی یادگیری عمیق جدید در این مرحله در شکل (۱۱-الف) نشان داده شده است. خطای کل (S) در شکل (۱۱-ب) و بر اساس شاخص RMSE در این مرحله به مقدار  $8/62$  کاهش یافته است. حال آنکه فرایند پیش‌بینی اولیه که بر اساس یک ویژگی انجام گرفت دارای خطای بالاتر از ۱۳ بود. مقایسه این دو خطا در این مرحله نشان می‌دهد که شبکه عصبی یادگیری عمیق جدید آموزش دیده جهت پیش‌بینی در این بخش منجر به کاهش خطای کل به مقدار ۵ واحد گشته که خود صحت روش پیشنهادی تا این مرحله را تأیید می‌نماید. همان‌گونه که در شکل (۱۱-ب) نشان داده شده مقدار RMSE محاسبه شده در پیش‌بینی نهائی برابر  $8/62$  است در حالی که MAPE این شبکه حدود ۲۸ درصد است. دلیل بالا بودن معیار خطای MAPE ناشی از کوچک بودن طول مقادیر موجود در سری زمانی فولاد اسپیدان است (صفر الی ۵۰ مگاوات) به طوری که کوچک‌ترین خطا هم MAPE بالائی را ایجاد می‌نماید. روند تغییرات RMSE در این مرحله و مقایسه آن با مقدار RMSE محاسبه شده در شبکه‌های عصبی قبل از آموزش تحت نظارت در بخش قبل نشان می‌دهد که روش آموزش تحت نظارت به‌کار رفته در شبکه عصبی یادگیری عمیق جدید باعث کاهش این شاخص از حدود ۱۴ به  $8/62$  گردیده است.



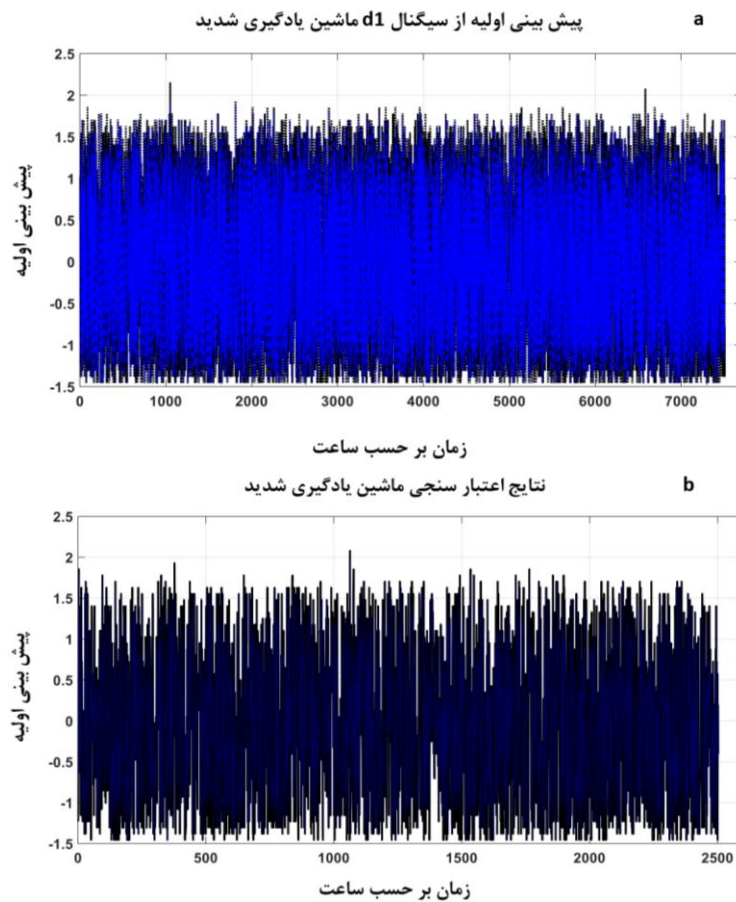
شکل (۱۱): پیش‌بینی انجام شده نهائی (Demand Time Series) توسط شبکه عصبی عمیق جدید برای دوره ۲۵۰۰ ساعته  
Figure (11): (a): Final forecasting of new deep learning neural network for 2500-hours period and (b): total error

### ۳-۱- ارزیابی مدل‌های پیش‌بینی بر اساس روش ترکیبی به‌کار رفته با استفاده از ماشین یادگیری شدید

در این بخش داده‌های استفاده شده در مرحله قبل (شبکه عصبی یادگیری عمیق جدید) با روش ماشین یادگیری شدید ELM، تحت آموزش، پیش‌بینی و ارزیابی قرار داده می‌شود. ماتریس ورودی و خروجی در این مدل‌ها همان ماتریس‌های به‌کار رفته در بخش قبل است به طوری که ماتریس ویژگی دو سطری  $T_{d1}$  و  $T_{a1}$  به‌عنوان ورودی و پیش‌بینی نهائی تقاضای انجام گرفته توسط شبکه قبل به‌عنوان هدف در نظر گرفته شده و شبکه‌های مورد نظر تحت بایاس اعمال شده مورد آموزش، پیش‌بینی و ارزیابی قرار می‌گیرند. روندنمای ارائه شده در شکل (۱۲) ادامه فرایند قبل و چگونگی حرکت در این مرحله را ارائه می‌دهد. شکل (۱۳-الف) پیش‌بینی اولیه از سیگنال d1 در مرحله آموزش تکنیک ELM را نشان می‌دهد. در شکل (۱۳-ب) نتایج اعتبار سنجی توسط شبکه ELM ارائه گردیده است



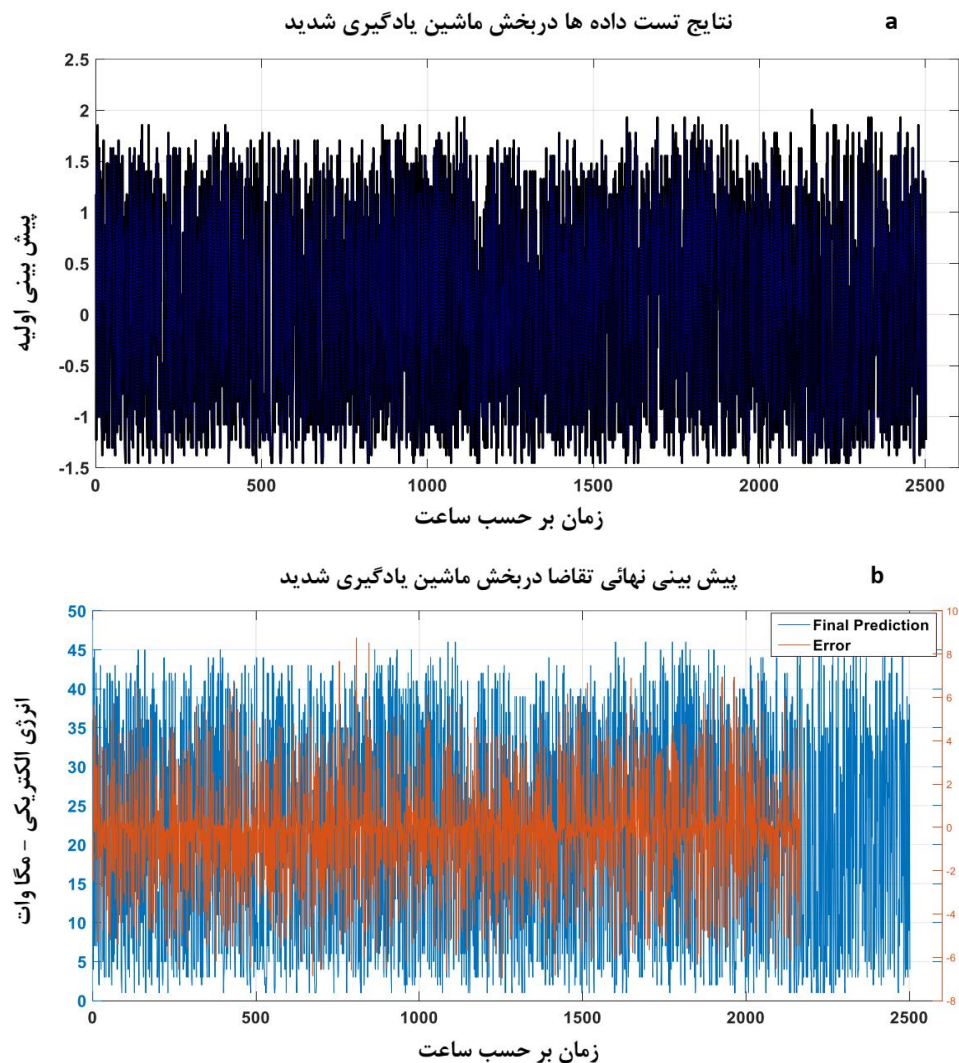
شکل (۱۲): روند نمای فرآیند ماشین یادگیری شدید ELM  
Figure (12): Extreme learning machine (ELM) process flowchart



شکل (۱۳): پاسخ به داده های آموزش در مرحله آموزش و پیش بینی اولیه از d1 توسط تکنیک ELM  
Figure (13): (a) Initial forecasting of d1 by ELM method and (b) ELM validation results



همان‌گونه که دیده می‌شود بخش سیگنال مشکی رنگ برجسته‌تر از نمودار قبل گردیده و این نشان از افزایش تغییرات می‌دهد. این مرحله اعتبار سنجی است که بهترین  $\beta$  از آن استخراج می‌گردد. در شکل (۱۴-الف) نتایج تست داده‌ها در این مرحله نشان داده شده است. شکل (۱۴-ب) پیش‌بینی نهائی تقاضا توسط روش ELM را نشان می‌دهد. در محور عمودی سمت چپ مقدار تقاضای پیش‌بینی شده و در محور سمت راست خطای این روش ارائه گردیده است.



شکل (۱۴): نتایج نهائی تست داده‌ها، تقاضای پیش‌بینی شده و خطای ناشی از تکنیک ELM

Figure (14): (a): Final results of data test and (b): forecasted demand and error of ELM method

Table (1): Comparison of the hybrid proposed method with two selected approaches

جدول (۱): مقایسه نتایج روش ترکیبی پیشنهادی با دو روش منتخب

Evaluation	Propos Hybrid Method	SVM	Decision Tree
MAE	۱/۵۰۴	۱۱/۱۷۷	۱۱/۵۵۶
MAPE	۷/۴۴۳۱	۵۵/۳۱۴	۵۷/۱۹
MSE	۵/۳۱۰۶	۱۷۱/۲۹	۱۷۱/۴۷
RMSE	۲/۳۰۴۵	۱۳/۰۸۸	۱۳/۰۹۵

در جدول (۱) ارزیابی نتایج روند پیشنهادی مورد نظر با دو روش ماشین بردار پشتیبان و درخت تصمیم‌گیری مورد مقایسه و نتایج مربوطه ارائه گردیده است. نتایج حاصله موفقیت روش پیشنهادی و عملکرد بسیار خوب آن در کاهش خطا و افزایش دقت جهت پیش‌بینی تقاضا در افق زمانی بلند مدت را نشان می‌دهد.

#### ۴- نتیجه‌گیری

در این مقاله یک روش پیش‌بینی بلند مدت تقاضای انرژی الکتریکی در صنایع تولید سنگ آهن اسپیدان ارائه شد. این صنعت علاوه بر اینکه یکی از تامین‌کنندگان اصلی صنایع فلزات اساسی ایران است، جزء ده صنعت پرمصرف در زنجیره تامین انرژی الکتریکی منطقه مرکزی کشور و استان اصفهان نیز است. وجود ذی‌نفعان متفاوت در هر دو سوی این زنجیره تامین مزید بر علت شده تا لزوم حفاظت از منافع مشترک آنها الزامی گردد به طوری که هرگونه نوسان در این بخش، کل زنجیره و صنایع پائین‌دستی و بالادستی خود را متاثر نموده و باعث زیان‌های مالی سنگین برای همه ذی‌نفعان می‌شود. بنابراین پیش‌بینی تقاضای بلند مدت این صنعت علاوه بر بالا بردن تاب‌آوری زنجیره تامین انرژی الکتریکی امکان تامین بلادرنگ تقاضای مورد نظر در افق پیش رو را فراهم می‌نماید. با توجه به نقص داده‌ها ناشی از عدم تولید و ناهمگون بودن مقادیر، در ابتدا حدود ۶۰ درصد از داده‌های دریافت شده شامل مقادیر صفر و ناهمگون در سری زمانی موجود حذف گردید. این عامل باعث شد تا سیگنال موجود به صورت منقطع و گسسته بوده و امکان استفاده از مزیت‌های نهفته در الگوی زمانی تقاضا بسیار ضعیف گردد. بنابراین جهت حصول یک دقت قابل قبول و کاهش خطا در پیش‌بینی تقاضای زنجیره تامین مورد نظر، یک روش ترکیبی سه مرحله‌ای پیشنهاد شد. در مرحله اول روش پیشنهادی خطای RMSE و شاخص ارزیابی MAPE به ترتیب برابر ۱۴ و ۲۸ درصد بود. دلیل بالا بودن معیار خطای MAPE در این مرحله بدلیل کوچک بودن طول مقادیر موجود در سری زمانی صنعت مورد نظر و تغییرات ناگهانی و شدید در تقاضا است. روند تغییرات RMSE در این مرحله و مقایسه آن با مقدار RMSE محاسبه شده در شبکه‌های آموزش عمیق تحت نظارت که در مرحله دوم انجام گرفت منجر به کاهش این شاخص از حدود ۱۴ به ۸/۶۲ گردید. در بخش سوم با استفاده از ماشین یادگیری شدید ELM، مدل تحت آموزش، ارزیابی و تست قرار گرفت. استفاده از روش ترکیبی مبتنی بر ماشین یادگیری شدید باعث کاهش خطای RMSE در محدوده ۲/۳ و MAPE در محدوده ۷/۴ گردید. در نهایت نتایج ارائه شده با داده‌های مشابه توسط دو روش ماشین بردار پشتیبان و درخت تصمیم‌گیری مقایسه شد. نتایج حاصله که در جدول (۱) ارائه گردید بیانگر قابلیت روش پیشنهادی در ارائه یک روش موثر پیش‌بینی بلند مدت تقاضا با خطای قابل قبول در شرایطی مشابه و در زنجیره تامین انرژی الکتریکی اینگونه صنایع است.

#### References

##### مراجع

- [1] M. Tan, S. Yuan, S. Li, Y. Su, H. Li, F. He, "Ultra-short-term industrial power demand forecasting using LSTM based hybrid ensemble learning", *IEEE Trans. on Power Systems*, vol. 35, no. 4, pp. 2937-2948, July 2020 (doi: 10.1109/TPWRS.2019.2963109).
- [2] M. Abdollahi, M. Moazzami, "Day-ahead coordination of vehicle-to-grid operation and wind power in security constraints unit commitment (SCUC)", *Journal of Intelligent Procedures in Electrical Technology*, vol. 6, no. 22, pp. 49-56, Summer 2015.
- [3] A. T. Eseye, M. Lehtonen, T. Tukia, S. Uimonen, R.J. Millar, "Machine learning based integrated feature selection approach for improved electricity demand forecasting in decentralized energy systems". *IEEE Access*, vol. 7, pp. 91463-91475, 2019 (doi: 10.1109/ACCESS.2019.2924685).
- [4] T. Hong, P. Pinson, Y. Wang, R. Weron, D. Yang, H. Zareipour, "Energy forecasting: A review and outlook", *IEEE Open Access Journal of Power and Energy*, vol. 7, pp. 376-388, Oct. 2020 (doi: 10.1109/OAJPE.2020.3029979).
- [5] S.H. Mozafarpour-Khoshrodi, G. Shahgholian, "Improvement of perturb and observe method for maximum power point tracking in wind energy conversion system using fuzzy controller", *Energy Equipment and Systems*, vol. 4, no. 2, pp. 111-122, Autumn 2016 (doi: 10.22059/EES.2016.23031).
- [6] H. Karimi, B. Fani, G. Shahgholian, "Coordinated protection scheme based on virtual impedance control for loop-based microgrids", *Journal of Intelligent Procedures in Electrical Technology*, vol. 12, no. 46, pp. 15-32, Summer 2021 (in Persian).

- [7] F. Keynia, G. Memarzadeh, "Short term electric load prediction based on deep neural network and wavelet transform and input selection", *Iranian Electric Industry Journal of Quality and Productivity*, vol. 8, no. 2, pp. 65-74, Autumn 2019 (in Persian).
- [8] M. Moazzami, S. J. Hosseini, H. Shahinzadeh, G. Gharehpetian, 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.
- [9] R. Ebrahimi, G. Shahgholian, B. Fani, "Fast islanding detection for distribution system including PV using multi-model decision tree algorithm", *Majlesi Journal of Electrical Engineering*, vol. 14, no. 4, pp. 29-38, Dec. 2020.
- [10] B. Fani, S. Fehrest-Sani, E. Adib, "Short-term load forecasting of distribution power system for weekdays using old data", *Journal of Intelligent Procedures in Electrical Technology*, vol. 5, no. 18, pp. 25-36, Summer 2014 (in Persian).
- [11] S. N. Emenike, G. Falcone, "A review on energy supply chain resilience through optimization", *Renewable and Sustainable Energy Reviews*, vol. 134, Paper Number: 110088, Dec. 2020 (doi: 10.1016/j.rser.2020.110088).
- [12] O. Abedinia, N. Amjadi, H. Zareipour, "A new feature selection technique for load and price forecast of electrical power systems", *IEEE Trans. on Power Systems*, vol. 32, no. 1, pp. 62-74, Jan. 2017 (doi: 10.1109/TPWRS.2016.2556620).
- [13] H. Shayeghi, A. Ghasemi, "Modeling of multi input multi output based LSSVM for electricity price and load forecasting in smart grid with considering demand side management", *Computational Intelligence in Electrical Engineering*, vol. 6, no. 4, pp. 87-106, Winter 2016 (in Persian).
- [14] W.M. Lin, C. S. Tu, R. F. Yang, M. T. Tsai, "Particle swarm optimization aided least square support vector machine for load forecast with spikes", *IET Generation, Transmission and Distribution*, vol. 10, no. 5, pp- 1145-1153, April 2016 (doi: 10.1049/iet-gtd.2015.0702).
- [15] H. Fang, J. Ma, W. Zhang, H. Yang, F. Chen, 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).
- [16] H. Jiang, Y. Zhang, E. Muljadi, J.J. Zhang, D.W. Gao, "A short-term and high-resolution distribution system load forecasting approach using support vector regression with hybrid parameters optimization", *IEEE Trans. on Smart Grid*, vol. 9, no. 4, pp. 3341-3350, July 2018 (doi: 10.1109/TSG.2016.2628061).
- [17] Y. Liu, Y. Sun, D. Infield, Y. Zhao, S. Han, J. Yan, "A hybrid forecasting method for wind power ramp based on orthogonal test and support vector machine (OT-SVM)", *IEEE Trans. on Sustainable Energy*, vol. 8, no. 2, pp- 451-457, April 2017 (doi: 10.1109/TSTE.2016.2604852).
- [18] J. Nowotarski, R. Weron, "Computing electricity spot price prediction intervals using quantile regression and forecast averaging", *Springer Computational Statistics Journal*, vol. 30, no. 3, pp- 791-803, Sept. 2015 (doi: 10.1007/s00180-014-0523-0).
- [19] B. Liu, J. Nowotarski, T. Hong, R. Weron, "Probabilistic load forecasting via quantile regression averaging on sister forecasts", *IEEE Trans. on Smart Grid*, vol. 8, no. 2, pp-730-737, March 2017 (doi: 10.1109/TSG.2015.2437877).
- [20] Q. Liu, Y. Shen, L. Wu, J. Li, L. Zhuang, 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).
- [21] P. Zeng, M. Jin, "Peak load forecasting based on multi-source data and day-to-day topological network", *IET Generation, Transmission and Distribution*, vol. 12, no. 6, pp- 1374-1381, March 2018 (doi: 10.1049/iet-gtd.2017.0201).
- [22] H. Shi, M. Xu, R. Li, "Deep learning for household load forecasting A novel pooling deep RNN", *IEEE Trans. on Smart Grid*, vol. 9, no. 5, pp. 5271-5280, Sept. 2018 (doi: 10.1109/TSG.2017.2686012).
- [23] W. Kong, Z. Y. Dong, Y. Jia, D. J. Hill, Y. Xu, Y. Zhang, "Short-term residential load forecasting based on LSTM recurrent neural network", *IEEE Trans. on Smart Grid*, vol. 10, no. 1, pp. 841-851, Jan. 2019 (doi: 10.1109/TSG.2017.2753802).
- [24] F. Y. Xu, X. Cun, M. Yan, H. Yuan, Y. Wang, L. L. Lai, "Power market load forecasting on neural network with beneficial correlated regularization", *IEEE Trans. on Industrial Informatics*, vol. 14, no. 11, pp. 5050-5059, Nov. 2018 (doi: 10.1109/TII.2017.2789297).
- [25] M. Rafiei, T. Niknam, J. Aghaei, M. Shafie Khah, J.P.S. Catalão, "Probabilistic load forecasting using an improved wavelet neural network trained by generalized extreme learning machine", *IEEE Trans. on Smart Grid*, vol. 9, no. 6, pp. 6961-6971, Nov. 2018 (doi: 10.1109/TSG.2018.2807845).
- [26] W. Zhang, H. Quan, D. Srinivasan, "An improved quantile regression neural network for probabilistic load forecasting", *IEEE Trans. on Smart Grid*, vol. 10, no. 4, pp. 4425-4434, July 2019 (doi: 10.1109/TSG.2018.2859749).

- [27] Z. Yu, Z. Niu, W. Tang, Q. Wu, "Deep learning for daily peak load forecasting— A novel gated recurrent neural network combining dynamic time warping", *IEEE Access*, vol. 7, pp. 17184–17194, Jan. 2019 (doi: 10.1109/ACCESS.2019.2895604).
- [28] C. Ye, Y. Ding, P. Wang, Z. Lin, "A data driven bottom-up approach for spatial and temporal electric load forecasting", *IEEE Trans. on Power Systems*, vol. 34, no. 3, pp. 1966–1979, May 2019 (doi: 10.1109/TPWRS.2018.2889995).
- [29] T. Ouyang, Y. He, H. Li, Z. Sun, S. Baek, "Modeling and forecasting short-term power load with copula model and deep belief network", *IEEE Trans. on Emerging Topics in Computational Intelligence*, vol. 3, no. 2, pp. 127-136, April 2019 (doi: 10.1109/TETCI.2018.2880511).
- [30] K. Chen, K. Chen, Q. Wang, Z. He, J. Hu, J. He, "Short-term load forecasting with deep residual networks", *IEEE Trans. on Smart Grid*, vol. 10, no. 4, pp. 3943-3952, July 2019 (doi: 10.1109/TSG.20-18.2844307).
- [31] Z. Deng, B. Wang, Y. Xu, T. Xu, C. Liu, Z. Zhu, "Multi-scale convolutional neural network with time-cognition for multi-step short-term load forecasting", *IEEE Access*, vol. 7, pp. 88058-88071, July 2019 (doi: 10.1109/ACCESS.2019.2926137).
- [32] Y. Wang, N. Zhang, Q. Chen, D.S. Kirschen, P. Li, Q. Xia, "Data-driven probabilistic net load forecasting with high penetration of behind-the-meter PV", *IEEE Trans. on Power Systems*, vol. 33, no. 3, pp. 3255-3264, May 2018 (doi: 10.1109/TPWRS.2017.2762599).
- [33] L. Alfieri, P.D. Falco, "Wavelet-based decompositions in probabilistic load forecasting", *IEEE Trans. on Smart Grid*, vol. 11, no. 2, pp. 1367-1376, March 2020 (doi: 10.1109/TSG.2019.2937072).
- [34] Y. Hong, Y. Zhou, Q. Li, W. Xu, X. Zheng, "A deep learning method for short-term residential load forecasting in smart grid", *IEEE Access*, vol. 8, pp. 55785-55797, 2020 (doi: 10.1109/ACCESS.2020.29-81817).
- [35] X. Luo, J. Sun, L. Wang, W. Wang, W. Zhao, J. Wu, J.H. Wang, "Short-term wind speed forecasting via stacked extreme learning machine with generalized correntropy", *IEEE Trans. on Industrial Informatics*, vol. 14, no. 11, pp. 4963-4971, Nov. 2018 (doi: 10.1109/TII.2018.2854549).
- [36] A.J.R. Reis, A.P.A. Silva, "Feature extraction via multiresolution analysis for short-term load forecasting", *IEEE Trans. on Power Systems*, vol. 20, no. 1, pp. 189-198, Jan. 2005 (doi: 10.1109/TPWRS.2004.840380).
- [37] Z.A. Bashir, M.E. El-Hawary, "Applying wavelets to short-term load forecasting using PSO-based neural networks", *IEEE Trans. on Power Systems*, vol. 24, no.1, pp. 20-27, Feb. 2009 (doi: 10.1109/TPWRS.2008-2008606).
- [38] Y. Chen, P.B. Luh, C. Guan, Y. Zhao, L.D. Michel, M.A. Coolbeth, P.B. Friedland, S.J. Rourke, "Short-term load forecasting: Similar day-based wavelet neural networks", *IEEE Trans. on Power Systems*, vol. 25, no. 1, pp. 322-330, Feb. 2010 (doi: 10.1109/TPWRS.2009.2030426).
- [39] S. Mujeeb, N. Javaid, M. Ilahi, Z. Wadud, F. Ishmanov, M. K. Afzal, "Deep long short-term memory: A new price and load forecasting scheme for big data in smart cities", *MDPI Sustainability*, vol. 11, no. 4, Feb. 2019 (doi: 10.3390/su11040987).
- [40] G. B. Huang, Q. Y. Zhu, 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).
- [41] H. Liu, E. Dougherty, J. Dy, K. Torkkola, E. Tuv, H. Peng, C. Ding, F. Long, M. Berens, L. Parsons, L. Yu, Z. Zhao, G. Forman, "Evolving feature selection", *IEEE Intelligent Systems*, vol. 20, no. 6, pp. 46–76, Dec. 2005 (doi: 10.1109/MIS.2005.105).
- [42] J. Sohrabi, M. Moazzami, "Probabilistic mid-term net load forecasting considering the effect of solar power using extreme learning machine", *Computational Intelligence in Electrical Engineering*, vol. 11, no. 2, pp. 59-72, Summer 2020 (in Persian) (doi: 10.22108/isee.2019.119079.1276).
- [43] T.M. Hagan, B.H. Demuth, M. Beale, *Neural Network Design*, PWS Publishing Company, 1996.
- [44] N. Amjady, A. Daraeepour, "Midterm demand prediction of electrical power systems using a new hybrid forecast technique", *IEEE Trans. on Power Systems*, vol. 26, no. 2, pp. 755-765, May 2011 (doi: 10.1109/TPWRS.2010.2055902).

زیر نویس‌ها:

1. Electricity supply chain
2. Particle swarm optimization
3. Grid traverse algorithm
4. Orthogonal test theory
5. Bat algorithm
6. Day to day topological network

7. Random walk with restart algorithm
8. Extreme learning machine
9. Theano
10. Box-cox
11. Wavelet decomposition
12. Deep learning
13. Support vector machine
14. Decision tree
15. Data logger
16. Approximation
17. Details
18. Extreme learning machine
19. Target
20. Feature
21. Dab chez
22. Back propagation
23. Constant error carousel
24. Compose
25. Load time series
26. Extreme learning machine
27. Single hidden layer feed-forward neural network
28. Back propagation
29. Moore-Penrose
30. Least mean squares
31. Steepest descent algorithm
32. Vidor-Hoff