

# پیش‌بینی کوتاه‌مدت تقاضای بار با استفاده از تجزیه سیگنال به مؤلفه ذاتی، تبدیل موجک و رگرسیون بردار پشتیبان

روح‌الله کشوری، مریم ایمانی\* و محسن پارسا مقدم  
دانشکده مهندسی برق و کامپیوتر، دانشگاه تربیت مدرس، تهران، ایران

## چکیده

پیش‌بینی کوتاه‌مدت بار الکتریکی نقش مهمی در طراحی و بهره‌برداری از سیستم‌های قدرت ایفا می‌کند. با توجه به ماهیت سری زمانی بار الکتریکی کوتاه‌مدت، پیش‌بینی دقیق بار بسیار چالش‌برانگیز است. در این مقاله، روشی برای پیش‌بینی بار کوتاه‌مدت پیشنهاد شده است. در مرحله نخست توابع مد ذاتی (IMFها) منحنی بار با استفاده از روش تجزیه مد تجربی (EMD) استخراج می‌شوند. باقی‌مانده سیگنال که حاوی نوفه است در این مرحله دور ریخته می‌شود تا سیگنال به‌نسبه تمیزی حاصل شود. در مرحله دوم هر IMF با استفاده از تبدیل موجک تجزیه می‌شود تا زیردنباله‌های آن حاصل شود. هر زیردنباله حاوی اطلاعات و جزئیات متفاوتی است که می‌تواند به بهبود دقت پیش‌بینی کمک کند. در مرحله سوم زیردنباله‌های به‌دست‌آمده تجمیع شده و در نهایت به‌وسیله رگرسیون بردار پشتیبان (SVR) جهت پیش‌گویی استفاده می‌شوند. روش پیشنهادی بر روی دو مجموعه داده لهستان و کانادا و با چهار معیار خطای میانگین مربعات (MSE) ریشه میانگین مربعات خطا (RMSE)، میانگین درصد مطلق خطا (MAPE) و میانگین خطای مطلق (MAE) مورد ارزیابی قرار گرفت. یافته‌ها نشان می‌دهد که خطای پیش‌بینی بار برای مجموعه داده لهستان با معیار  $MSE$  برابر 0.0012، با معیار  $RMSE$  برابر 0.0342 با معیار  $MAPE$  برابر 2.9771، با معیار  $MAE$  برابر 0.0044 و برای مجموعه داده کانادا با معیار  $MSE$  برابر  $5.0969e-07$ ، با معیار  $RMSE$  برابر  $7.1393e-04$  با معیار  $MAPE$  برابر 0.9571 و با معیار  $MAE$  برابر  $2624e-04$  است. از مقایسه روش پیشنهادی نسبت به سایر روش‌های رقیب، نتایج بهتری از نظر میزان خطا مشاهده شده است.

واژگان کلیدی: پیش‌بینی بار کوتاه‌مدت، تقاضای بار، تجزیه مؤلفه ذاتی، تبدیل موجک، رگرسیون بردار پشتیبان

## Short Term Load Forecasting Using Empirical Mode Decomposition, Wavelet Transform and Support Vector Regression

Ruhollah Keshvari, Maryam Imani\* & Mohsen Parsa Moghaddam

Faculty of Electrical and Computer Engineering, Tarbiat Modares University, Tehran, Iran

### Abstract

The Short-term forecasting of electric load plays an important role in designing and operation of power systems. Due to the nature of the short-term electric load time series (nonlinear, non-constant, and non-seasonal), accurate prediction of the load is very challenging. In this article, a method for short-term daily and hourly load forecasting is proposed. In this method, in the first step, the intrinsic mode functions (IMFs) of the Electric load curve, which are a group of average and pseudo-periodic average signals, are extracted by using the empirical mode decomposition (EMD) method, which is a non-linear and non-constant time-frequency method. For this purpose, the maximum and minimum points of the signal are determined, and then, in one cycle, the difference between the average curve of the upper and lower envelope is calculated with it. This continues until the result falls below a threshold value, and then, the rest of the signal which contains noise is discarded to get a relatively clean signal. In the second

\* Corresponding author

\* نویسنده عهده‌دار مکاتبات



step, we need to obtain the sub-sequences of each IMF. So, we use the wavelet transform. The wavelet transform is a kind of transform that is used to decompose a continuous signal into its frequency components, and the resolution of each component is equal to its scale. Each subsequence contains different information and details that can help the improvement of the prediction accuracy. In the third step, the obtained subsequences are aggregated and finally used for prediction by Support Vector Regression (SVR). Support vector regression is a type of supervised learning system that is used for both grouping and estimating the fitting function of data in regression problems so that the least error occurs in the grouping of data or in the fitting function. The purpose of the proposed method is to reduce the error for daily and hourly load prediction. In this method, two datasets of Poland and Canada have been experimented. With four criteria of mean square error (MSE), root mean square error (RMSE), average absolute percentage error (MAPE) and mean absolute error (MAE), the results are evaluated. The findings show that the load prediction error for the Polish data set are as follows: MSE equal to 0.0012, RMSE equal to 0.0342, MAPE equal to 2.9771, and MAE equal to 0.0044. For Canadian data set, the results are as follows: MSE equal to 5.0969e-07, RMSE equal to 7.1393e-04, MAPE criterion equal to 0.9571, and the MAE criterion equal to 2624e-04. Comparison of the proposed method with other competing methods show that better results are achieved by the proposed method in term of the error rate.

**Keywords:** Short-term electrical load forecasting, Electricity demand, empirical mode decomposition, wavelet transform, support vector regression

کوتاه‌مدت، برای زمان کوتاه همچون بار ساعتی را استفاده می‌شود. زمان پیش‌بینی بار ممکن است ساعتی، چندساعت، روزانه، هفتگی، ماهیانه و یا فصلی باشد. برآورد بار کوتاه‌مدت در بهره‌برداری سیستم‌های قدرت نقش اساسی ایفا می‌کند [7,8]. پیش‌بینی بار میان مدت در بازه حداکثر پنج ساله انجام می‌شود. این پیش‌بینی‌ها برای تصمیم‌گیری‌های میان‌مدت مانند تعیین سیاست‌ها و تصمیم‌گیری‌های میان‌مدت و یا حتی تعیین ظرفیت و مکان پست‌ها مورد استفاده قرار می‌گیرد. پیش‌بینی بار بلندمدت جهت تصمیم‌گیری‌های کلان مدیریتی نظیر تعیین حجم سرمایه‌گذاری‌ها در تهیه برنامه‌های بلندمدت آینده مورد استفاده است. پیش‌بینی بار بلندمدت در شبکه‌های توزیع برای دوره‌های ده الی پانزده سال انجام می‌شود [7,9]. با توجه به ماهیت غیرخطی، غیر ثابت و غیر فصلی بودن سری زمانی بار الکتریکی کوتاه‌مدت، پیش‌بینی دقیق بار بسیار چالش برانگیز است [9].

در نتیجه، اساس هر تصمیم‌گیری مبتنی بر اطلاعات قبلی است و هرچه این اطلاعات کامل‌تر و دقیق‌تر باشد تصمیم‌گیری راحت‌تر و کم‌اشتباه‌تر می‌شود. پیش‌بینی صحیح بار علاوه بر صرفه‌جویی در هزینه‌های سرمایه‌گذاری، امکان برنامه‌ریزی برای توسعه نیروگاه‌ها و شبکه‌های انتقال و توزیع را فراهم می‌آورد. هدف از این مقاله پیشنهاد روشی جهت افزایش دقت پیش‌بینی بار کوتاه‌مدت با بهره‌گیری از تجزیه مد تجربی<sup>5</sup>، تجزیه موجک<sup>6</sup> و رگرسیون بردار پشتیبان<sup>7</sup> است.

## ۱- مقدمه

کمیبود انرژی و توسعه شبکه‌های هوشمند توجه زیادی در عصر حاضر به خود جلب کرده است [2,1]. از میان صنایع، صنعت برق از صنایع زیربنایی یک کشور و رکنی بسیار مهم در رشد و پیشرفت جوامع امروزی دارد و با توسعه و رشد جمعیت، میزان تقاضا برای مصرف انرژی الکتریکی رو به افزایش است [3]. بیش‌ترین درصد تقاضای مصرف انرژی الکتریکی را بخش مسکونی ۲۱٪ تا ۲۲٪، بازرگانی، صنعتی و حمل و نقل دارند [4]. با توجه به اینکه هدف اصلی شبکه‌های توزیع برق پاسخ‌گویی به این تقاضا با کیفیت مطلوب است و از سویی بار سیستم پارامتری است که به‌طور تقریبی تمام عملکرد سیستم را تحت تأثیر قرار می‌دهد؛ بنابراین مساله پیش‌بینی بار در تمامی بخش‌های صنعت برق اعم از تولید، انتقال و توزیع همواره به‌عنوان یکی از فاکتورهای اساسی در طراحی و بهره‌برداری آنها بوده است [5]. همچنین با پیش‌بینی برق مصرفی می‌توان اطلاعات کافی را برای طراحی و توسعه شبکه‌های توزیع تهیه کرد. این پیش‌بینی به‌منظور تحلیل نیازهای آینده مورد نیاز است. پیش‌بینی بار<sup>۱</sup> به معنی تعیین مقدار توان مصرفی بار در سال‌های آینده بر مبنای تخمین بار است. با در نظر گرفتن این جنبه‌های مهم، روش‌های بسیاری برای پیش‌بینی بار در طول سال‌ها به کار گرفته شده است تا نتایج دقیق‌تری برای برنامه ریزی کارآمد به‌دست آورد، ولی با این وجود، موضوع پیش‌بینی بار هنوز یک مساله چالش برانگیز است [6].

پیش‌بینی بار را می‌توان به سه سطح کوتاه‌مدت<sup>۲</sup>، میان‌مدت<sup>۳</sup> و بلندمدت<sup>۴</sup> تقسیم کرد [2]. پیش‌بینی بار

<sup>3</sup> medium-term load forecasting(MTLF)

<sup>4</sup> long-term load forecasting(LTLF)

<sup>5</sup> Empirical Mode Decomposition

<sup>6</sup> Wavelet Transform

<sup>7</sup> Support vector machine (SVR)

<sup>1</sup> Load Forecasting

<sup>2</sup> Short-term load forecasting(STLF)

## ۲- کارهای مرتبط

برای تخمین انرژی الکتریکی، می‌توان رویکردهای گوناگونی چون شبکه‌های عصبی مصنوعی [10]، فازی [11]، تبدیل موجک [12]، رگرسیون [13] و رگرسیون بردار پشتیبان [15، 14، 2] را نام برد. همچنین از روش‌های ترکیبی مانند الگوریتم‌های درخت رده‌بندی و رگرسیون (C&RT)، شبکه عصبی و رگرسیون [2] اشاره کرد.

در سال‌های اخیر بیش‌تر مطالعات برای پیش‌بینی بار روی شبکه عصبی متمرکز شده‌اند؛ زیرا شبکه‌های عصبی محلی مانند عصبی پرسپترون [16] می‌توانند هر عملکرد غیرخطی را تقریب بزنند و همچنین می‌توانند برای مدل‌های پیچیده و سری‌های زمانی نتایج معقولی به‌دست آورند [9]. مطالعات انجام‌شده در زمینه پیش‌بینی بار، بیشتر مربوط به پیش‌بینی بار کوتاه‌مدت است. از این دسته می‌توان به موارد زیر اشاره کرد:

در مطالعه [2] از ترکیب رگرسیون بردار پشتیبان (SVR) و LSTM<sup>1</sup> استفاده شده است. در این پژوهش علاوه بر استفاده از بار الکتریکی از مشخصات دما نیز استفاده شده است. در مطالعه [9] به پیش‌بینی بار کوتاه‌مدت با استفاده از شبکه عصبی RNN<sup>2</sup> پرداخته شده است. نتایج نشان می‌دهد که شبکه RNN، که مبتنی بر LSTM است، قادر به پیش‌بینی دقیق سری زمانی بار الکتریکی پیچیده با افق پیش‌بینی طولانی است. از مشکلات این روش، می‌توان به طراحی ساختار مناسب شبکه و آموزش آن با تعداد نمونه‌های آموزشی کافی نام برد.

در مطالعه [14] هدف پیش‌بینی تقاضای بار با استفاده از روش ترکیبی الگوریتم‌های تجزیه سیگنال به مؤلفه‌های ذاتی و رگرسیون بردار پشتیبان است. از روش پیشنهادی، برای تجزیه مؤلفه‌های ذاتی به‌عنوان یک مرحله رفع نوفه در داده‌های آموزش استفاده می‌کند و سپس از SVR برای پیش‌بینی استفاده شده است. آزمایش‌ها بر روی مجموعه‌داده بار الکتریکی از کشور لهستان انجام شده و روش پیشنهادی با الگوریتم SVR با استفاده از بردارهای ویژگی مختلف مقایسه شده است. نتایج نشان می‌دهد که الگوریتم پیشنهادی از الگوریتم SVR و الگوریتم denoised-SVR دارای خطای کمتری در پیش‌بینی بار الکتریکی است. از جمله چالش‌های این دسته از روش‌ها، استخراج اطلاعات کافی از دنباله بار برای تغذیه به SVR جهت پیش‌گویی بار است.

در مطالعه [17] به پیش‌بینی بار کوتاه‌مدت با استفاده از شبکه عصبی عمیق<sup>3</sup> پرداخته شده است. در این پژوهش برای پیاده‌سازی از پلتفرم Tensor-flow و توابع سیگموئید، ReLU<sup>4</sup> و ELU<sup>5</sup> استفاده شده و مجموعه‌داده ۹۰ روزه بازار ایبری برای پیش‌بینی در نظر گرفته شده است. طبق نتایج، شبکه با تابع ReLU نتایج بهتری نسبت به سایر توابع نشان می‌دهد. دقت این مدل هنوز برای داده‌های بزرگتر مورد ارزیابی قرار نگرفته است. تعیین عمق مناسب شبکه با توجه به محتوی داده در دسترس، از جمله چالش‌های روش‌های مبتنی بر یادگیری عمیق است.

در مطالعه [18] برای پیش‌بینی بار از ماشین بردار پشتیبان استفاده شده و برای تنظیم پارامترها از الگوریتم بهینه‌سازی گرگ خاکستری استفاده شده است. نتایج تجربی نشان می‌دهد که این یک روش مؤثر است که می‌تواند دقت پیش‌بینی را به طرز چشم‌گیری بهبود بخشد.

در مطالعه [19] پیش‌بینی با استفاده از شبکه عصبی مصنوعی و الگوریتم‌های داده‌کاوی انجام شده است. مجموعه‌داده مورد استفاده کشور فرانسه است. در این پژوهش ابتدا به خوشه‌بندی با استفاده از الگوریتم K - means برای استخراج ویژگی و سپس به کلاس‌بندی با الگوریتم‌های Naïve Bayes و k - Nearest Neighbors برای کلاس داده‌های روزانه پرداخته شده است. در این روش عملکرد سیستم برای پیش‌بینی بار کوتاه مدت بالا رفته است. از مشکلات این روش انتخاب مناسب خوشه‌ها برای ورود به طبقه‌بند است. در مطالعه [20] به پیش‌بینی بار کوتاه‌مدت با استفاده از ماشین بردار پشتیبان و SSA<sup>6</sup> پرداخته شده است. برای انتخاب پارامترها از الگوریتم بهینه‌سازی فاخته استفاده شده است. برای ارزیابی این مدل از مجموعه‌داده نیم ساعت New South Wales استفاده شده است. نتایج تجربی نشان می‌دهد که مدل پیشنهادی می‌تواند پیش‌بینی بار الکتریکی دقیق‌تر در مقایسه با مدل‌های مورد بحث ارائه دهد.

در مطالعه [21] یک پیش‌بینی مصرف برق به نام SVR-LSTM پیشنهاد شده است. روش پیشنهادی بر روی یک مجموعه‌داده از بارهای ساعتی در مگابایت آزمایش شده است. این روش نتایج بهتری نسبت به SVR و LSTM نشان داده است. تنظیم مناسب پارامترها در SVR و LSTM از اهمیت به‌سزایی برخوردار است.

<sup>3</sup> Deep Neural Networks (DNN)

<sup>4</sup> Rectifier linear unit (ReLU)

<sup>5</sup> Exponential linear unit (ELU)

<sup>6</sup> singular spectrum analysis (SSA)

<sup>1</sup> long short-term memory (LSTM)

<sup>2</sup> Recurrent Neural Network (RNN)

بیشتری از اطلاعات مفید جهت پیش‌گویی بار را فراهم می‌آورد؛ در نهایت، زیردنباله جمع‌شده به‌وسیله رگرسیون بردار پشتیبان (SVR) جهت پیش‌بینی بار استفاده می‌شود. توضیحات هر بخش با جزئیات بیشتر در ادامه ارائه شده است.

### ۳-۱- تجزیه سیگنال به مؤلفه‌های ذاتی (EMD)

تجزیه مؤلفه به سیگنال‌های ذاتی یک روش تحلیلی و کارآمد غیر خطی و غیر ثابت فرکانس داده‌های زمانی است که توسط هوانگ و همکاران معرفی شده است. این روش براساس این فرض ساده است که هر سیگنال از زیرمجموعه‌های مختلف تشکیل شده است. سری‌های زمانی غیرخطی و غیرثابت می‌توانند به گروهی از سیگنال‌های میانگین متوسط و شبه‌تناوبی تقسیم شوند، جایی که هر یک از مؤلفه‌ها IMF نامیده می‌شوند [14]. مراحل الگوریتم EMD عبارتند از: مرحله نخست: تعیین نقاط بیشینه و کمینه محلی سیگنال ورودی؛ مرحله دوم: ایجاد منحنی پوش بالا از طریق برازش منحنی درجه سه بر نقاط بیشینه محلی و ایجاد منحنی پوش پایین از طریق برازش منحنی درجه سه بر نقاط کمینه محلی؛ مرحله سوم: میانگین‌گیری از منحنی‌های پوش بالا و پایین؛ مرحله چهارم: تفریق میانگین پوش بالا و پایین ( $m_k(t)$ ) از سیگنال ورودی  $x(t)$  که در رابطه (۱) آورده شده است:

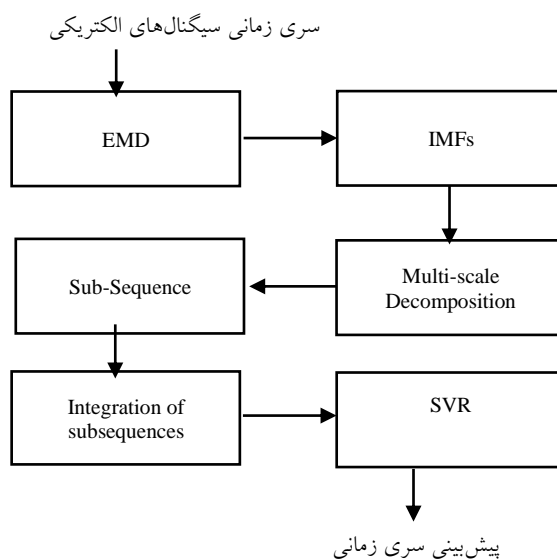
$$h_k(t) = x(t) - m_k(t) \quad (1)$$

مرحله پنجم: بررسی ارضای شرط توقف، مرحله ششم: در صورت نداشتن شرط توقف، جای‌گذاری سیگنال حاصل از مرحله چهارم به جای سیگنال اصلی و ادامه فرایند از مرحله نخست؛ مرحله هفتم: اگر شرط مرحله برقرار باشد فرایند پایان یافته و  $c_1 = h_1^k$  به‌عنوان نخستین IMF در نظر گرفته می‌شود. IMF ابتدایی در واقع مؤلفه فرکانس بالای سیگنال  $x(t)$  است. مرحله هشتم: باقی‌مانده به‌صورت  $r_1 = x(t) - c_1^k$  تعریف شده و اگر خود، شرط IMF بودن را برآورده کند، یک IMF محسوب شده و در غیر این‌صورت اگر شرط الف (تعداد بیشینه و کمینه‌ها برابر یا بیشتر تعداد صفرها باشد) را داشته باشد، به‌عنوان سیگنال اولیه، فرض شده و گام‌های یک الی چهارم، تکرار می‌شود تا IMF بعدی به‌دست آید و اگر این شرط را نداشته باشد به‌عنوان باقی‌مانده I در نظر گرفته می‌شود. باقی‌مانده را می‌توان به شکل رابطه (۲) تعریف کرد.

از بررسی کارهای پیشین می‌توان دریافت که SVR و شبکه LSTM دو روش کارا برای استخراج ویژگی و پیش‌گویی بار هستند. همچنین برای تنظیم پارامترهای SVR از الگوریتم‌های بهینه‌سازی مناسب می‌توان استفاده کرد. استفاده از روش‌های ترکیبی مانند تجزیه سیگنال به مؤلفه ذاتی نیز به‌کار برده شده که از آن برای پیش‌بینی بار روزانه استفاده شده است. براساس کارهای انجام‌شده در این پژوهش سعی شده است روشی ارائه شود که از ترکیب روش‌های دیگر مانند تبدیل موجک برای استخراج اطلاعات بیشتر جهت افزایش کارایی بهره گرفته شود. همچنین کارایی مناسب برای پیش‌بینی بار ساعتی و روزانه داشته باشد.

### ۳- روش پیشنهادی پژوهش

روش پیشنهادی این پژوهش در شکل (۱) آورده شده است.



(شکل-۱): روش پیشنهادی پیش‌گویی بار  
(Figure-1): Proposed load forecasting method

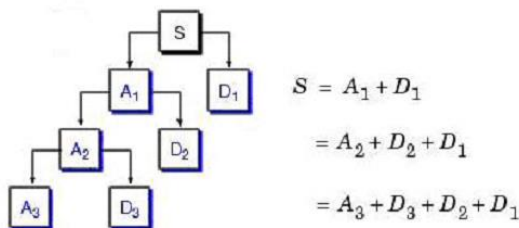
همان‌طور که در شکل نشان داده شده، ابتدا سری زمانی بار الکتریکی به‌وسیله الگوریتم تجزیه مد ذاتی (EMD) به مؤلفه‌های توابع مد ذاتی ( $IMF^1$ ) تجزیه و باقی‌مانده آن که حاوی نوفه است، دور انداخته می‌شود. در مرحله بعدی هر IMF به‌وسیله تبدیل موجک چندمقیاسه به زیردنباله‌های تجزیه می‌شود. هر زیرمؤلفه از IMF دارای مقیاس متفاوت و حاوی جزئیات با ارزشی از منحنی بار است. ادغام و تجمیع این زیردنباله‌ها در کنار هم، حجم

<sup>1</sup> Intrinsic mode function (IMF)

این ایده منجر به ابداع تبدیل گسسته موجک (DWT) شده است [22,23]. شکل گسسته تابع موجک به صورت رابطه (۵) است:

$$\Psi_{j,k}(t) = \frac{1}{\sqrt{|s_0^j|}} \Psi\left(\frac{t-k\tau_0 s_0^j}{s_0^j}\right) \quad (5)$$

که در آن  $\Psi_{j,k}$  تابع موجک به ازای مقادیر معین  $k$  و  $j$  (اعداد صحیح)،  $t$  زمان،  $(s > 1)$  پارامتر ثابت اتساع،  $\tau_0$  پارامتر ثابت انتقال زمان بوده و وابسته به  $s_0$  است. در روش DWT مقادیر پارامترهای مقیاس و انتقال توان‌هایی از ۲ در نظر گرفته می‌شود. در اصطلاح به این پارامترها، پارامترهای انتقال و اتساع دوتایی<sup>۶</sup> گفته می‌شود. اعمال این روش بر روی سیگنال باعث می‌شود اجزای فرکانس بالا و پایین تجزیه شود که محتوای فرکانس پایین سیگنال تقریب آن را با  $A$  و محتوای فرکانس بالا یا جزئیات آن را با  $D$  نمایش می‌دهیم [22]. هر سیگنال را می‌توان به روش گسسته و پیوسته در چند مرحله تجزیه کرد که در شکل (۲) آورده شده است.



(شکل-۲): تجزیه سیگنال گسسته به تقریب و جزئیات

(Figure-2): Signal decomposition to approximation and details

همان‌طور که شکل بالا نشان می‌دهد، سیگنال ابتدا به سیگنال تقریب و جزئیات تجزیه می‌شود؛ سپس در مرحله بعد سیگنال تقریب است که به‌عنوان سیگنال پایه در نظر گرفته شده و دوباره به سیگنال‌هایی از تقریب و جزئیات تجزیه می‌شود. این روال تا عمق مورد نظر ادامه می‌یابد. در واقع این سیگنال تقریب است که در هر مرحله به اجزای فرکانس بالا و پایین تجزیه شود.

### ۳-۳- رگرسیون بردار پشتیبان

رگرسیون بردار پشتیبان از طبقه‌بند ماشین بردار پشتیبان اقتباس شده است. ماشین بردار پشتیبان یک نوع سیستم یادگیری نظارت شده است که هم برای گروه‌بندی و هم برای تخمین و برآورد تابع برازش داده‌ها در مسائل

<sup>6</sup> Dyadic

$$r_i = x(t) - c_i^k \quad (2)$$

در معادله بالا  $x(t)$  مقدار داده اصلی و  $c_i^k$  مقدار آمین IMF تولید شده است؛ بنابراین در واقع سیگنال اصلی ما مجموع IMFها به علاوه باقی‌مانده که در رابطه (۳) نشان داده شده است.

$$x(t) = \sum_{i=1}^n h_i(t) + r(t) \quad (3)$$

در معادله بالا  $x(t)$  مقدار داده اصلی است؛ هر کدام از  $h_i^k$  ها مقدار آمین IMF و  $r(t)$  مؤلفه باقی‌مانده را نشان می‌دهد و  $n$  تعداد IMFها است.

### ۳-۲- تبدیل موجک

تبدیل موجک از دسته‌ای از توابع ریاضی برای تجزیه سیگنال پیوسته به مؤلفه‌های فرکانسی آن به‌کار می‌رود. رزولوشن هر مؤلفه برابر با مقیاس آن است. تبدیل موجک، تجزیه یک تابع بر مبنای توابع موجک است؛ بنابراین تبدیل موجک به‌عنوان یک تبدیل ریاضیاتی (مانند تبدیل فوریه) برای تشخیص اطلاعاتی که در سری زمانی یا سیگنال نهفته است، استفاده می‌شود. موجک‌ها بر مبنای دو عمل اصلی قرار دارند: انتقال<sup>۱</sup> و پهن‌شدگی<sup>۲</sup>. تبدیل موجک به دو نوع پیوسته<sup>۳</sup> و گسسته<sup>۴</sup> تقسیم می‌شود. تبدیل پیوسته موجک یک سیگنال  $x(t)$  به‌صورت رابطه (۴) تعریف می‌شود:

$$CWT_x^\Psi = \frac{1}{\sqrt{|s|}} \int_{-\infty}^{+\infty} x(t) \Psi^*\left(\frac{t-\tau}{s}\right) dt \quad (4)$$

که در آن  $\Psi$  تابع موجک،  $(s > 1)$  پارامتر مقیاس یا اتساع<sup>۵</sup>،  $\tau$  پارامتر انتقال زمان،  $t$  زمان و علامت نشان‌دهنده مزدوج مختلط است. روش CWT، سیگنال را به‌وسیله تعداد بی‌شمار و نامحدودی از پارامترهای مقیاس و انتقال تجزیه می‌کند. در این روش پارامترهای مقیاس و انتقال به‌صورت پیوسته تغییر می‌کنند؛ از این‌رو محاسبه ضرایب موجک برای همه مقیاس‌های ممکن، علاوه‌بر تولید حجم زیادی از اطلاعات، نیاز به کوششی قابل ملاحظه دارد. آشکارا مشخص است در روش CWT مقدار زیادی اطلاعات اضافی تولید می‌شود. اما می‌توان با استفاده از زیرنمونه‌هایی CWT ویژگی‌های کلیدی تبدیل را حفظ کرد.

<sup>1</sup> Dilation

<sup>2</sup> Dilation

<sup>3</sup> Countinous Wavelet Transform

<sup>4</sup> Discrete Wavelet Transform

<sup>5</sup> Dilatation Parameter



رگرسیون به کار می‌رود، به طوری که کمترین خطا در گروه‌بندی داده‌ها یا تابع برازش رخ دهد. این روش بر مبنای تئوری یادگیری آماری استوار است که از اصل کمینه‌سازی خطای ساختاری بهره می‌جوید و موجب یک جواب بهینه کلی می‌شود [2,15]. برای پیاده‌سازی رگرسیون بردار پشتیبان داده‌ها طبق رابطه (۶) نشان داده می‌شود:

رگرسیون به کار می‌رود، به طوری که کمترین خطا در گروه‌بندی داده‌ها یا تابع برازش رخ دهد. این روش بر مبنای تئوری یادگیری آماری استوار است که از اصل کمینه‌سازی خطای ساختاری بهره می‌جوید و موجب یک جواب بهینه کلی می‌شود [2,15]. برای پیاده‌سازی رگرسیون بردار پشتیبان داده‌ها طبق رابطه (۶) نشان داده می‌شود:

$$\min \frac{1}{2} \sum_i \sum_j (\alpha_i^+ - \alpha_i^-) (\alpha_j^+ - \alpha_j^-) x_i^T x_j - \sum_i (\alpha_i^+ - \alpha_i^-) t_i + \sum_i (\alpha_i^+ - \alpha_i^-) \varepsilon \quad (13)$$

$$SVR = \{x_i, t_i\} \quad \forall x_i \in R^m, t_i \in R \quad (6)$$

$$s.t. \sum_i (\alpha_i^+ - \alpha_i^-) = 0, \quad 0 \leq \alpha_i^+ \leq C, \quad 0 \leq \alpha_i^- \leq C \quad (14)$$

که  $x_i$  ها ورودی‌ها که می‌تواند  $m$  بعد داشته باشد و  $t_i$  هدف است. از رابطه (۷) می‌توانیم  $SVR$  را طبق رگرسیون تعریف کنیم:

مجموع بردار پشتیبان نیز با استفاده از مقدار  $\alpha_i^+$  و  $\alpha_i^-$  قابل محاسبه است که باید حاصل ضرب این مقدار برابر صفر باشد و در نتیجه طبق رابطه (۱۵) خواهیم داشت.

$$t_i \approx y_i = w^T x_i + b \quad \forall i = 1, 2, \dots, N \quad (7)$$

تابع جریمه آن طبق رابطه (۹) تعریف می‌شود:

$$S = \{i | 0 \leq \alpha_i^+ + \alpha_i^- \leq C\} \quad (15)$$

$$0 \leq \alpha_i^+ \leq C, \quad \alpha_i^- = 0 \rightarrow t_i = y_i + \varepsilon$$

$$0 \leq \alpha_i^- \leq C, \quad \alpha_i^+ = 0 \rightarrow t_i = y_i - \varepsilon$$

$$t_i = y_i + \text{sign}(\alpha_i^+ - \alpha_i^-) \varepsilon \quad i \in S$$

$$t_i = w^T x_i + b + \text{sign}(\alpha_i^+ - \alpha_i^-) \varepsilon$$

$$b = -w^T x_i + t_i - \text{sign}(\alpha_i^+ - \alpha_i^-) \varepsilon$$

$$L_\varepsilon(t_i, y_i) = \begin{cases} 0 & |t_i - y_i| \leq \varepsilon \\ R^+ & \text{other} \end{cases} \quad (8)$$

که  $L_\varepsilon$  تابع جریمه است و برای به دست آوردن خروجی مطلوب باید بین بازه مثبت و منفی  $\varepsilon$  طبق رابطه (۱۰) تعریف شود:

در نهایت اگر  $\{x_i, t_i\}$  ورودی  $\forall i = 1, 2, \dots, N$  و خروجی برابر  $y_i = w^T x_i + b$  باشد، خواهیم داشت:

$$\aleph_i = |t_i - y_i| - \varepsilon \quad (9)$$

$$w = \sum_i (\alpha_i^+ - \alpha_i^-) x_i \quad (16)$$

$$b = \frac{1}{|S|} \sum_{i \in S} [t_i - w^T x_i - \text{Sing}(\alpha_i^+ - \alpha_i^-) \varepsilon] \quad (17)$$

در رابطه بالا  $y_i$  خروجی مطلوب شبکه است؛ در نهایت برای تابع جریمه خواهیم داشت:

در رگرسیون بردار پشتیبان از یک تابع هسته یا کرنل استفاده می‌شود. در رابطه  $y = wx + b$  که معادل با  $\sum_i (\alpha_i^+ - \alpha_i^-) x_i^T x_i + b$  است، با جایگزین تابع هسته (کرنل)، رابطه (۱۸) شکل می‌گیرد:

$$L_\varepsilon(t_i, y_i) = \begin{cases} 0 & |t_i - y_i| \leq \varepsilon \\ |t_i - y_i| - \varepsilon & \text{other} \end{cases} \quad (10)$$

برای همه داده‌ها باید رابطه (۱۲) (ریسک عملیاتی) کمینه شود:

$$y = \sum_i (\alpha_i^+ - \alpha_i^-) K(x_i, x) + b \quad (18)$$

$$R_{emp} = \frac{1}{N} \sum_{i=1}^N L_\varepsilon(t_i, y_i) \quad (11)$$

بنابراین در حالت کلی تابع هدف از رابطه (۱۳) به دست خواهد آمد:

توابع پایه خطی، سیگموئید، چندجمله‌ای و شعاعی (RBF) رایج‌ترین هسته‌ها هستند. با توجه به کارایی محاسباتی RBF طی سال‌ها، این هسته به یکی از بهترین هسته‌ها شناخته شده و در این مطالعه نیز از این هسته که در معادله (۱۹) نشان داده شده است، استفاده می‌شود:

$$\min \frac{1}{2} w^T w + C \sum_{i=1}^N (\aleph_i^+ + \aleph_i^-) \quad (12)$$

$$s.t. -t_i + y_i + \varepsilon + \aleph_i^+ \geq 0 \quad \forall i$$

$$t_i - y_i + \varepsilon + \aleph_i^- \geq 0 \quad \forall i$$

$$\aleph_i^+ \geq 0 \quad \forall i$$

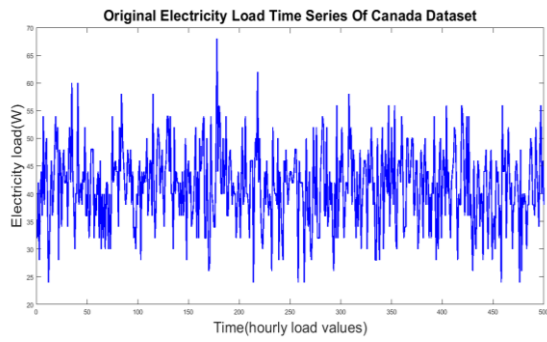
$$\aleph_i^- \geq 0 \quad \forall i$$

$$K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right) \quad (19)$$

در معادله بالا  $\sigma$  عرض RBF است؛ بنابراین چون تابع کرنل غیر خطی است، خواهیم داشت:

در رابطه بالا مقدار  $C$  یک عدد ثابت می‌باشد. حال اگر برای روابط بالا فرم دوگانه آن را در نظر بگیریم برای  $t_i - y_i + \varepsilon + \aleph_i^+ - t_i + y_i + \varepsilon + \aleph_i^- \geq 0$  برای  $\alpha_i^+$  ضریب

$$b = \frac{1}{|S|} \sum_{i \in S} [t_i - \sum_i (\alpha_i^+ - \alpha_i^-) K(x_i, x) - \text{Sing}(\alpha_i^+ - \alpha_i^-) \varepsilon] \quad (20)$$



(شکل-۴): مجموعه داده AMPds  
(Figure-4): AMPds data set

تعاریف دقیق این مجموعه داده‌ها در جدول (۱) آورده شده است.

(جدول-۱): توصیف مجموعه داده

(Table-1): Description of the data set

عنوان	نوع	تعداد داده آموزشی	تعداد داده آزمایشی	نوع بار	واحد بار
Poland	تقاضای بار	1400	201	بار روزانه	مگا وات
AMPds	تقاضای بار	500		بار ساعتی	وات

#### ۴-۲- معیار ارزیابی

مقایسه نتایج حاصل با استفاده معیار خطای میانگین مربعات (MSE)<sup>۲</sup>، ریشه میانگین مربعات خطا (RMSE)<sup>۳</sup>، میانگین درصد مطلق خطا (MAPE)<sup>۴</sup> و میانگین خطای مطلق (MAE)<sup>۵</sup> صورت می‌گیرد و نحوه محاسبه این معیارها در روابط (۲۱)، (۲۲)، (۲۳) و (۲۴) نشان داده شده است. MSE انحراف پیش‌بینی از داده‌های واقعی را اندازه‌گیری می‌کند:

$$MSE = \frac{1}{n} \sum_{i=1}^n (P_i - A_i)^2 \quad (21)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (P_i - A_i)^2} \quad (22)$$

$$MAPE = \frac{100}{n} \sum_{i=1}^n \frac{|(P_i - A_i)|}{P_i} \quad (23)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |(P_i - A_i)| \quad (24)$$

که در معادلات بالا  $A_i$  مقدار واقعی،  $P_i$  مقدار پیش‌گویی شده و  $n$  تعداد نمونه‌ها است.

<sup>2</sup> mean square error (MSE)

<sup>3</sup> Root Mean Squared Error (RMSE)

<sup>4</sup> absolute percent error (MAPE)

<sup>5</sup> Mean Absolute Error (MAE)

اگر به جای کرنل  $K(x_i, x_j)$  مقدار  $h_{ij}$  قرار دهیم و مقدار  $\alpha$  یک ماتریس به صورت  $\alpha = \begin{bmatrix} \alpha^+ \\ \alpha^- \end{bmatrix}$  باشد کرنل طبق رابطه زیر محاسبه می‌شود:

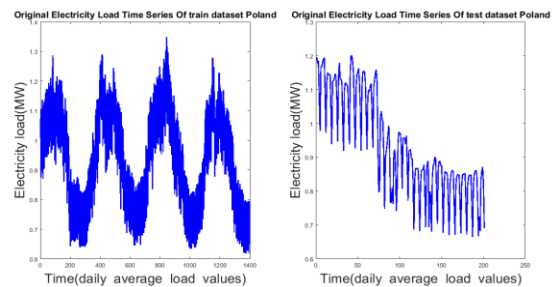
$$H = [h_{ij}] \quad h_{ij} \in R^{n \times n} \rightarrow \gamma = \begin{pmatrix} H & -H \\ H & H \end{pmatrix} \quad (21)$$

#### ۴- ارزیابی و نتایج

در این مقاله محیط شبیه‌سازی با نرم‌افزار MATLAB R2015a برای مدل‌سازی استفاده شده و رایانه برای شبیه‌سازی دارای پردازنده مرکزی اینتل سری i3-2350 و دارای حافظه ۴ گیگ و ۵۱۱ گیگا بایت هارد است.

#### ۴-۱- مجموعه داده

تاکنون پژوهش‌های زیادی در زمینه پیش‌بینی بار الکتریکی انجام شده است و بسته به هدف، الگوریتم‌های پیش‌بینی در داده‌های یک شهر خاص مقایسه شده‌اند. در این مقاله از مجموعه بار الکتریکی که حاوی مقادیر متوسط بار روزانه از لهستان<sup>۱</sup> است، استفاده می‌شود. این مجموعه داده شامل ۱۴۰۰ رکورد آموزشی و ۲۰۱ رکورد آزمایشی است و مصرف روزانه را نشان می‌دهد. جمع‌آوری داده‌ها از سال ۱۹۹۰ تا ۱۹۹۵ بوده است. دلیل استفاده از این مجموعه داده، به دست آوردن مقایسه دقیق بین مدل‌های پیش‌بینی برای برنامه‌های واقعی است. شکل (۳) داده‌های آموزشی و آزمایشی این مجموعه داده را نشان می‌دهد.



(شکل-۳): مجموعه داده آموزشی و آزمایشی لهستان

(Figure-3): educational and experimental Poland data set

برای بررسی کارایی روش پیشنهادی از مجموعه داده دیگری به نام AMPds نیز استفاده شده است. این مجموعه داده متعلق به کشور کانادا و شامل داده‌های ساعتی بار الکتریکی است که از سال ۱۹۸۱ تا ۲۰۰۱ جمع‌آوری شده‌اند. شکل (۴)، (۴)، نمونه از سیگنال، مجموعه داده AMPds را نشان داده است.

<sup>1</sup> <http://research.ics.aalto.fi/eiml/datasets.shtml>

در مرحله ابتدایی روش پیشنهادی روی مجموعه داده لهستان به طور کامل بیان و سپس برای ارزیابی بیشتر نتایج روی مجموعه داده کانادا بیان می شود. باید مؤلفه های ذاتی سیگنال استخراج شود. از الگوریتم EMD برای استخراج این ویژگی ها (مؤلفه های IMF) که به صورت توام حذف نوفه را نیز انجام می دهد، استفاده می شود. مقایسه اجزای EMD برای هر مؤلفه سیگنال در جدول (۲) آورده شده است. در این جدول کمینه، بیشینه و میانگین مقادیر سیگنال ها گزارش شده است.

(جدول-۲): اطلاعات آماری مقایسه اجزای EMD برای

استخراج ویژگی ها (مؤلفه های IMF)

(Table-2): Statistical information of EMD Components for Extracting the Features (IMF Components)

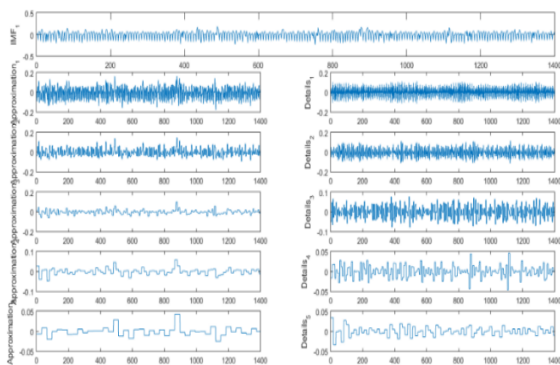
	کمترین	بیشترین	میانگین
Dataset	0.6477	1.0733	0.9681
IMF1	-0.2340	0.1843	-3.3830e-04
IMF2	-0.1260	0.1431	-8.4406e-04
IMF3	-0.0975	0.1263	0.0072
IMF4	-0.1955	0.2593	-0.0277
IMF5	-0.1387	0.1535	-0.0051
IMF6	-0.0525	0.1284	0.0290
IMF7	0.6477	1.0733	0.9681

همان طور که جدول بالا نشان می دهد، سیگنال های تولید شده با استفاده از الگوریتم EMD هفت مؤلفه IMF هستند و در این جدول اطلاعات آماری مربوط به کم ترین، متوسط و بیشینه مقدار هر IMF بیان شده است.

نتیجه الگوریتم EMD برای استخراج IMF ها در

شکل (۵) نشان داده شده است.

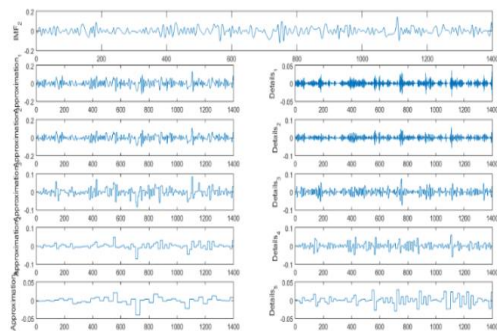
همان طور که در شکل بالا مشخص است، در بالای تصویر سیگنال اصلی و بقیه هفت IMF استخراج شده را نشان می دهد. نتیجه این مرحله استخراج هفت IMF است. در مرحله بعدی، از تبدیل موجک برای تجزیه هر مؤلفه IMF به زیردنباله های از سیگنال های تقریب و جزئیات استفاده شده است. در نتیجه، جزئیات بیشتری از هر IMF استخراج می شود. نتایج آزمایش ها نشان می دهد که برای داشتن ضریب خطای پیش بینی بار کمتر استفاده از تبدیل موجک DWT تا عمق پنج مناسب است و با افزایش تعداد عمق سیگنال ها از دست رفته و به صورت خطی می شود. در شکل های (۶ تا ۱۲)، سیگنال های تقریب و جزئیات مربوط به هر IMF نشان داده شده است.



(شکل-۶): تقریب و جزئیات مربوط به IMF1

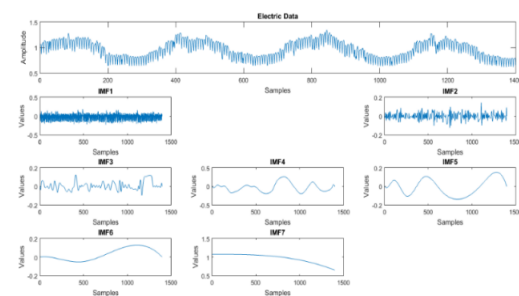
(Figure-6): Approximation and details related to IMF1

همان طور که شکل بالا نشان می دهد ضرایب تقریب نشان دهنده خروجی فیلتر پایین گذر (فیلتر میانگین گیر) در تبدیل موجک گسسته و ضرایب جزئیات نشان دهنده خروجی فیلتر بالاگذر (فیلتر مشتق گیر) در تبدیل موجک گسسته هستند. با استفاده از تبدیل موجک به عمق ۵، ۵ سیگنال تقریب و پنج سیگنال جزئیات تولید شده که در مجموع ۱۰ سیگنال برای هر IMF خواهیم داشت.



(شکل-۷): تقریب و جزئیات مربوط به IMF2

(Figure-7) Approximation and details related to IMF2



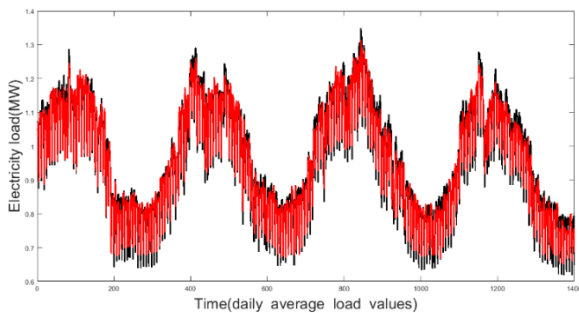
(شکل-۵): تجزیه مد ذاتی برای استخراج IMF ها

(Figure-5): Empirical Mode for extracting IMFs



شکل‌های بالا نشان‌دهنده قابلیت تبدیل موجک در تفکیک سیگنال است. ضرائب تبدیل موجک در سطوح مختلف تجزیه، متناظر با مؤلفه‌های فرکانسی مختلف موجود در هر سیگنال IMF هستند؛ همچنین برای هر سیگنال، اینکه تقریب و جزئیات در لحظه خاصی از زمان واقع شده‌اند، برای هر IMF نشان می‌دهد. این ویژگی به تبدیل موجک اجازه می‌دهد تا علاوه بر اطلاعات فرکانسی، اطلاعات زمانی را نیز به دست آورد.

در این مرحله، زیردنباله‌های تقریب و جزئیات تبدیل موجک  $DWT$  هر IMF در یک خروجی ذخیره شده که شامل هفتاد سیگنال است. در مرحله بعد با الگوریتم  $SVR$  به پیش‌بینی بار پرداخته می‌شود. در شکل ۱۳ نمودار قرمز پیش‌بینی مربوط به سری زمانی بار الکتریکی و رنگ مشکی سیگنال اصلی بار است که بر روی هم ترسیم شده‌اند.

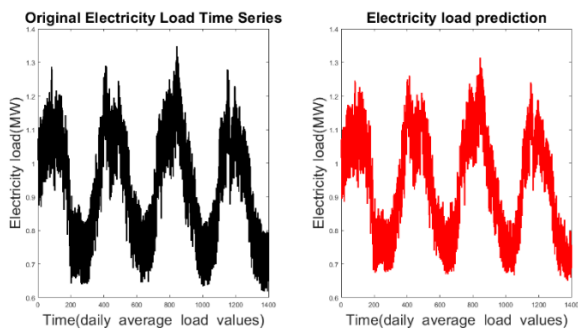


(شکل-۱۳): پیش‌بینی بار الکتریکی مجموعه داده لهستان

(Figure-13) Predicted electrical load Poland data set

همان‌طور که شکل بالا نشان می‌دهد، سیگنال پیش‌بینی شده از لحاظ ظاهری فرقی با سیگنال اصلی ندارد و خطای مدل بسیار کم است.

در شکل (۱۴) خروجی سیگنال بار پیش‌بینی شده و سیگنال اصلی به تفکیک نشان داده شده است.

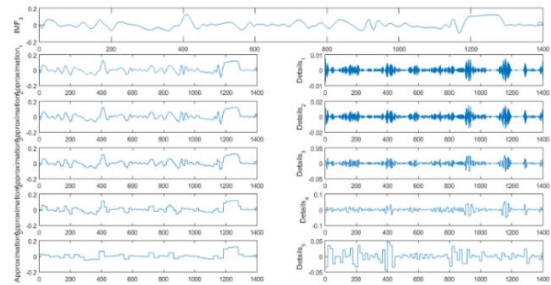


(شکل-۱۴): تفکیک پیش‌بینی بار الکتریکی و سیگنال هدف

مجموعه داده لهستان

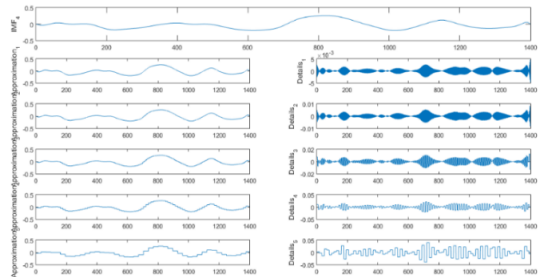
(Figure-14): Separation of predicted electrical load and

actual signal Poland data set



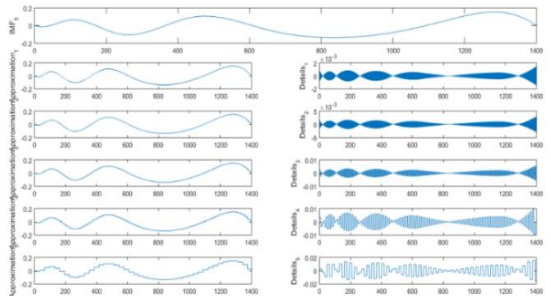
(شکل-۸): تقریب و جزئیات مربوط به IMF3

(Figure-8): Approximation and details related to IMF3



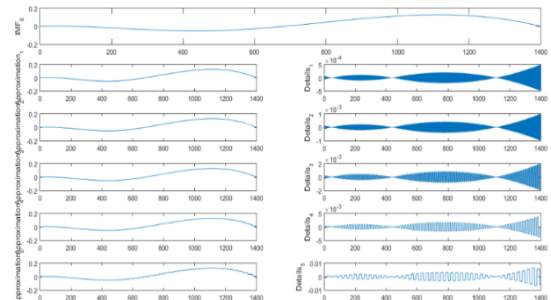
(شکل-۹): تقریب و جزئیات مربوط به IMF4

(Figure-9): Approximation and details related to IMF4



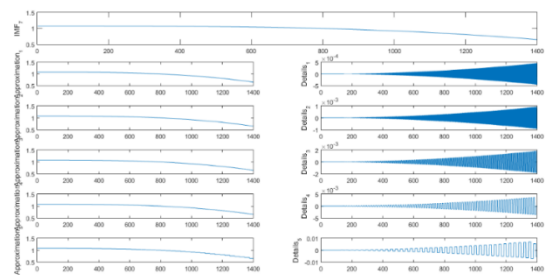
(شکل-۱۰): تقریب و جزئیات مربوط به IMF5

(Figure-10): Approximation and details related to IMF5



(شکل-۱۱): تقریب و جزئیات مربوط به IMF6

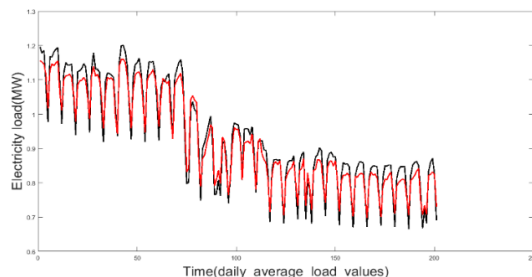
(Figure-11): Approximation and details related to IMF6



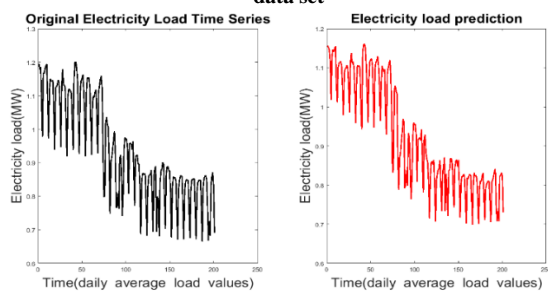
(شکل-۱۲): تقریب و جزئیات مربوط به IMF7

(Figure-12): Approximation and details related to IMF7

در شکل‌های (۱۵ و ۱۶) خروجی سیگنال بار پیش‌بینی شده و سیگنال اصلی به تفکیک برای داده‌های آزمایشی (شامل ۲۰۱ تقاضای بار) آورده شده است. تعداد IMFها که با استفاده از روش EMD استخراج شده است برابر پنج می‌باشد و بعد از تشکیل زیر دنباله‌ها با استفاده از تبدیل موجک *DWT* تعداد ۵۰ سیگنال وارد الگوریتم *SVR* می‌شود.



(شکل-۱۵): پیش‌بینی مدل پیشنهادی بار الکتریکی و سیگنال هدف برای داده‌های آزمایشی مجموعه داده لهستان  
(Figure-15): Predicted the electrical load using the proposed model and the actual load for experimented data Poland data set



(شکل-۱۶): پیش‌بینی مدل پیشنهادی بار الکتریکی برای داده‌های آزمایشی

(Figure-16): Predicted the electrical load using the proposed model for experimented data

همان‌طور که شکل بالا برای داده آزمایش مجموعه داده لهستان نشان می‌دهد، سیگنال پیش‌بینی شده از لحاظ ظاهری فرق زیادی با سیگنال اصلی ندارد و خطای مدل بسیار کم است. مقدار خطای پیش‌بینی شده از روش پیشنهادی برای داده‌های آموزش و آزمایش در جدول (۳) آورده شده است.

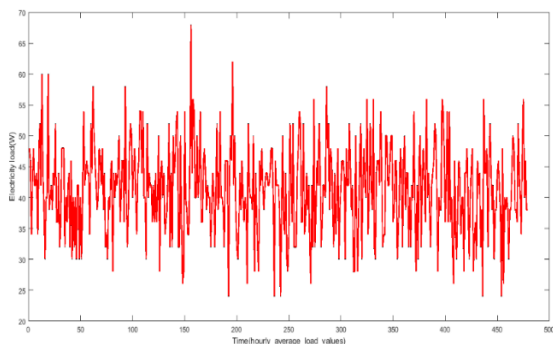
(جدول-۳): مقدار خطای پیش‌بینی شده از روش پیشنهادی برای مجموعه داده لهستان

(Table-3): The prediction error of the proposed method for experimented data

AME	MAPE	RMSE	MSE	خطا
0.0044	2.9771	0.0342	0.0012	خطای مدل برای داده آموزش
0.0155	5.0381	0.0554	0.0031	خطای مدل برای داده آزمایش

همان‌طور که ملاحظه می‌شود خطای حاصل از داده‌های آموزشی و آزمایشی بسیار به هم نزدیک و دارای مقدار کم است.

برای ارزیابی بیشتر روش پیشنهادی بر روی مجموعه داده بار ساعتی AMPds مورد ارزیابی قرار گرفت. در شکل (۱۷) نمودار قرمز پیش‌بینی مربوط به سری زمانی بار الکتریکی و رنگ مشکی سیگنال اصلی بار است که برای این مجموعه داده، در یک شکل بر روی هم ترسیم شده‌اند.

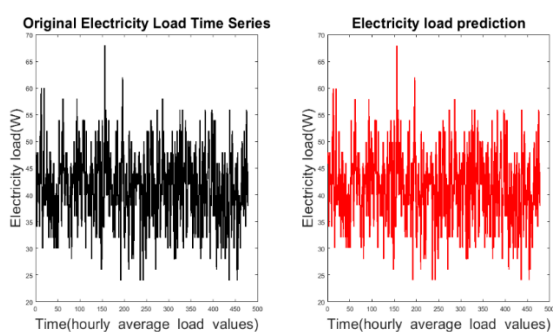


(شکل-۱۷): پیش‌بینی بار الکتریکی مجموعه داده کانادا

(Figure-17): Predicted electrical load AMPds data set

همان‌طور که شکل بالا نشان می‌دهد، سیگنال پیش‌بینی شده از لحاظ ظاهری فرقی با سیگنال اصلی ندارد و بسیار شبیه به هم هستند و خطای مدل بسیار کم است.

در شکل (۱۸) خروجی سیگنال بار پیش‌بینی شده و سیگنال اصلی برای این مجموعه داده به تفکیک نشان داده شده است.



(شکل-۱۸): تفکیک پیش‌بینی بار الکتریکی و سیگنال هدف

مجموعه داده AMPds

(Figure-18): Separation of predicted electrical load and actual signal AMPds data set

مقدار خطای پیش‌بینی شده از روش پیشنهادی برای داده‌های آموزش و آزمایش در جدول (۴) آورده شده است.

(جدول ۴-): مقدار خطای پیش‌بینی شده از روش پیشنهادی

برای مجموعه داده کانادا

(Table-4): The prediction error of the proposed method

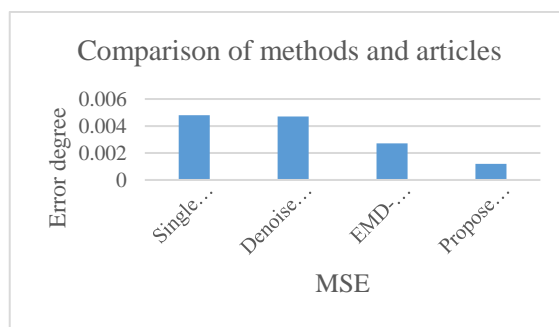
for AMPDs data set

AME	MAPE	RMSE	MSE	خطا
624e-04	0.957	7.1393e-04	5.0969e-07	خطای مدل برای داده کانادا

طبق جداول (۳ و ۴) می‌توان بیان نمود که روش پیشنهادی برای پیش‌بینی کوتاه‌مدت بار روزانه و ساعتی دارای میزان خطای کم است و سیگنال‌های پیش‌بینی شده شبیه به سیگنال اصلی هستند. روش پیشنهادی پیش‌بینی کوتاه‌مدت بار ساعتی بهتر عمل کرده است.

#### ۴-۴- مقایسه با کارهای پیشین

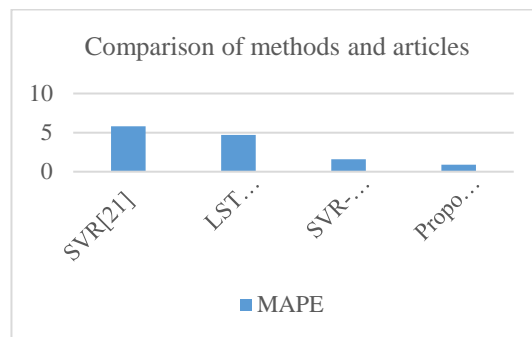
نمودار (۱) میزان خطای پیش‌بینی در این پژوهش برای مجموعه داده لهستان با تعداد داده و معیار ارزیابی یکسان آورده شده است.



(نمودار ۱-): مقایسه میزان خطای MSE

(Chart-1): Comparison of MSE values

نمودار (۲) میزان خطای پیش‌بینی در این پژوهش برای مجموعه داده کانادا با مجموعه داده و معیار ارزیابی یکسان آورده شده است.



(نمودار ۲-): مقایسه میزان خطای MAPE برای

مجموعه داده کانادا

(chart-2): Comparison of MAPE values for AMPDs data set

همان‌طور که در نمودار بالا مشخص است روش پیشنهادی این مقاله با استفاده از روش EMD برای استخراج IMF و تشکیل زیردنباله با استفاده از تبدیل موجک DWT و پیش‌بینی به‌وسیله الگوریتم SVR از بقیه روش‌های مشابه خطای کمتری حاصل کرده است. روش پیشنهادی با استخراج اطلاعات بار و حذف مؤلفه‌های نویزی با استفاده از تجزیه EMD و سپس استخراج مؤلفه‌های تقریب و جزئیات حاوی اطلاعات زمان-فرکانس با استفاده از تبدیل موجک، ویژگی‌های مناسبی را برای ورود به SVR جهت پیش‌گویی بار تولید کرد که در مقایسه با روش‌های قدرتمندی چون LSTM نیز برتری خود را نشان داد.

#### ۵- نتیجه‌گیری

صنعت برق از صنایع زیربنایی یک کشور و رکنی بسیار مهم در رشد و پیشرفت جوامع امروزی دارد و با توسعه و رشد جمعیت، میزان تقاضا برای مصرف انرژی الکتریکی رو به افزایش است. مسأله پیش‌بینی بار در تمامی بخش‌های صنعت برق اعم از تولید، انتقال و توزیع همواره به‌عنوان یکی از فاکتورهای اساسی در طراحی و بهره‌برداری آنها بوده است. همچنین با پیش‌بینی برق مصرفی می‌توان اطلاعات کافی برای طراحی و توسعه شبکه‌های توزیع را تهیه کرد. پیش‌بینی بار کوتاه‌مدت دارای اهمیت زیادی است و در بهره‌برداری سیستم‌های قدرت نقش اساسی ایفا می‌کند. با توجه به ماهیت غیرخطی، غیر ثابت و غیرفصلی بودن سری زمانی بار الکتریکی کوتاه‌مدت، پیش‌بینی دقیق بار بسیار چالش‌برانگیز است. پیش‌بینی صحیح بار کوتاه‌مدت علاوه بر صرفه‌جویی در هزینه‌های سرمایه‌گذاری، امکان برنامه‌ریزی برای توسعه نیروگاه‌ها و شبکه‌های انتقال و توزیع را فراهم می‌آورد؛ بنابراین هدف از این پژوهش پیش‌بینی کوتاه‌مدت بار با استفاده از یک روش هوشمند پیشنهادی است. طبق روش پیشنهادی، در مرحله نخست IMFها با استفاده از روش EMD استخراج شده و سپس در مرحله دوم برای هر IMF زیر دنباله‌ای با

- [4] R. Biswas, M. Robinson, and N. Fumo, "Prediction of residential building energy consumption: A neural network approach", *Elsevier, Energy*, vol. 117, no. 1, pp. 84-92, 2016.

[۵] میرشکاری، مهرداد، ابراهیمی، رضا، سیاهی، مهدی، "پیش‌بینی کوتاه مدت و میان مدت بار شبکه‌های توزیع با استفاده از شبکه عصبی بهبود یافته توسط سیستم خبره فازی"، همایش ملی مهندسی قدرت و نیروگاه‌های هسته‌ای دانشگاه آزاد اسلامی واحد بوشهر، انجمن هسته‌ای ایران، بوشهر، ایران، دوره ۱، صفحات ۱-۱۳، ۱۳۹۵.

- [5] M. Mirshakari, R. Ebrahimi, M. Siah, "Short-Term and Intermediate Forecast of Distribution Networks Using Neural Networks Improved by the Fuzzy Expert System", *First National Conference on Power Engineering and Nuclear Power Plants*, Pages 1-13, 2016.

- [6] I. Yazici, T. Leyla, and F.B. Omer, "Short Term Electricity Load Forecasting with a Nonlinear Autoregressive Neural Network with Exogenous Variables (NarxNet)", *Springer, In Industrial Engineering in the Big Data Era*, pp. 259-270, 2018.

- [7] G.M.U. Din, and A. Marnerides, "Short term power load forecasting using deep neural networks", *IEEE. In 2017 International Conference on Computing, Networking and Communications (ICNC)*, pp. 594 – 598, 2017.

- [8] X. Zhang, and J. Wang, "A novel decomposition-ensemble model for forecasting short-term load-time series with multiple seasonal patterns", *Elsevier, Applied Soft Computing*, vol. 65, no. 1, pp. 478-494, 2018.

- [9] J. Zheng, C. Xu, Z. Zhang, and X. Li, "Electric load forecasting in smart grids using long-short-term-memory based recurrent neural network", *IEEE, In Proceedings of IEEE 51st Annual Conference on Information Sciences and System*, pp.1-6, 2017.

- [10] K. Padmakumari, K.P. Mohandas, and S. Thiruvengadam, "Long term distribution

استفاده از تبدیل موجک *DWT* تشکیل می‌شود و در مرحله آخر پیش‌بینی بار کوتاه‌مدت به وسیله الگوریتم *SVR* صورت می‌گیرد. روش پیشنهادی بر روی دو مجموعه داده لهستان و کانادا و با چهار معیار خطای میانگین مربعات (MSE) ریشه میانگین مربعات خطا (RMSE)، میانگین درصد مطلق خطا (MAPE) و میانگین خطای مطلق (MAE) مورد ارزیابی قرار گرفت. نتایج نشان می‌دهد روش پیشنهادی برای پیش‌بینی کوتاه‌مدت بار روزانه و ساعتی دارای میزان خطای کم است و سیگنال‌های پیش‌بینی‌شده شبیه به سیگنال اصلی هستند از مقایسه این روش پیشنهادی نسبت به سایر روش‌های مشابه، نتایج بهتری مشاهده شده است. آزمایش‌ها نشان می‌دهد روش پیشنهادی عملکرد مناسبی داشته است. این نشان‌دهنده قدرت ترکیب ویژگی‌های تولیدشده با *EMD*، *DWT* و سپس استفاده از روش رگرسیون *SVR* جهت پیش‌گویی بار ساعتی است که عملکرد بهتری را نسبت به الگوریتم‌های قوی مانند *LSTM* فراهم می‌کند. همچنین می‌تواند برای صنعت برق به صورت کاربردی قابل استفاده باشد.

## 6- References

## ۶- مراجع

- [1] F. Luo, Z.Y. Dong, G. Liang, J. Murata, and Z. Xu, "A distributed electricity trading system in active distribution networks based on multi-agent coalition and blockchain" *IEEE. Trans. Power Syst*, vol. 34, no. 5, pp. 4097 – 4108, 2018.
- [2] M. Imani, "Long Short-Term Memory Network and Support Vector Regression for Electrical Load Forecasting" *IEEE. In 2019 International Conference on Power Generation Systems and Renewable Energy Technologies (PGSRET)*, pp. 1-6, 2019.
- [3] M. Nawaz, J. Nadeem, U.M. Fakhar, M. Maria, I. Farwa, J. Atia, and A. Muhammad, "An Approximate Forecasting of Electricity Load and Price of a Smart Home Using Nearest Neighbor", *Springer, In Conference on Complex, Intelligent, and Software Intensive*



- [19] A.D. Coronel, C. C. Olegario, B.D. Gerardo, and R.P. Medina, "Towards An Enhanced Backpropagation Network for Short-Term Load Demand Forecasting", *Computer Science. International Journal of Electrical Engineering and Applied Sciences*, vol. 2, no. 1, pp. 65-70, 2019.
- [20] X. Zhang, and J. Wang, "A novel decomposition-ensemble model for forecasting short-term load-time series with multiple seasonal patterns", *Elsevier, Applied Soft Computing*, vol. 65, no. 1, pp. 478-494, 2018.
- [21] M. Moradzadeh, S. Zakeri, M. Shoaran, B. Mohammadi-Ivatloo, F. Mohammadi, "Short-Term Load Forecasting of Microgrid via Hybrid Support Vector Regression and Long Short-Term Memory Algorithms". *MDPI*, vol. 12, No. 17, Pp: 7076-7093, 2020.
- [22] A.J.R. Reis, and A.P.A. Silva, "Feature Extraction Via Multiresolution Analysis for short term load forecasting", *IEEE, Transactions on Power Systems*, vol. 20, no. 1, pp. 189-198, 2005.
- [23] B. Cannas, A. Fanni, L. See, and G. Sias, "Data preprocessing for river flow forecasting using neural networks: Wavelet transforms and data partitioning", *Elsevier, Physics and Chemistry of the Earth, Parts A/B/C*, vol. 31, no. 18, pp.1164-1171, 2006.
- demand forecasting using neuro fuzzy computations", *Elsevier, International Journal of Electrical Power & Energy Systems*, vol. 21, no. 5, pp. 315-322, 1999.
- [11] A. Azadeh, M. Saberi, and O. Seraj, "An integrated fuzzy regression algorithm for energy consumption estimation with non-stationary data: a case study of Iran", *Elsevier, Energy*, vol. 35, no. 6, pp. 2351-2366, 2010.
- [12] M. Imani and H. Ghassemian, "Residential Load Forecasting Using Wavelet and Collaborative Representation Transforms", *Applied Energy*, vol. 253, 113505, 2019.
- [13] A. Azadeh, S.F. Ghaderi, and S. Sohrabkhani, S. "Forecasting electrical consumption by integration of neural network, time series and ANOVA", *Elsevier, Applied Mathematics and Computation*, vol. 186, no. 2, pp. 1753-1761, 2007.
- [14] Y. Yaslan, and B. Bican, "Empirical Mode Decomposition Based Denoising Method with Support Vector Regression for Time Series Prediction: A Case Study for Electricity Load Forecasting", *Measurement*, vol. 103, no. 1, pp. 1-26, 2017.
- [15] C.N. Ko, and C.M. Lee, "Short-term load forecasting using svr (support vector regression)-based radial basis function neural network with dual extended kalman filter", *Elsevier, Energy*, vol. 49, no. 1, pp. 413-422, 2013.
- [16] S. Panigrahi, Y. Karali, and H.S. Behera, H.S, "Time series forecasting using evolutionary neural network", *International Journal of Computer Applications*, vol. 75, no. 10, pp. 13-17. 2013.
- [17] T. Hossen, S.J. Plathottam, R.K. Angamuthu, P. Ranganathan, and H. Salehfar, "Short-Term Load Forecasting Using Deep Neural Networks (DNN)", *IEEE , 2017 North American Power Symposium (NAPS)*, pp.1-6, 2017.
- [18] A. Yang, W. Li, and X. Yang, "Short-term electricity load forecasting based on feature selection and Least Squares Support Vector Machines", *Elsevier, Knowledge-Based Systems*, vol. 163, no. 1, pp. 159-173, 2019.



روح‌الله کشوری مدرک کارشناسی

خود را در رشته مهندسی برق گرایش

مخابرات در سال ۱۳۸۱ از دانشکده

مخابرات وابسته به وزارت ارتباطات و

فن‌آوری اطلاعات و مدرک کارشناسی ارشد خود را

در سال ۱۳۹۹ از دانشگاه تربیت مدرس دریافت کرده

است. زمینه‌های پژوهشی ایشان پردازش تصویر، شناسایی

الگو و شبکه‌های عصبی است.

نشانی رایانامه ایشان عبارت است از:

r.keshvari@modares.ac.ir





**مریم ایمانی** کارشناسی و کارشناسی

ارشد خود را در رشته مهندسی برق-

گرایش مخابرات از دانشگاه شاهد

دریافت کرد. وی در سال ۱۳۹۴ و

۱۳۹۵ به ترتیب دوره دکترا و پسادکترا خود را در دانشگاه

تربیت مدرس به پایان رساند. ایشان از سال ۱۳۹۶

استادیار دانشکده مهندسی برق و کامپیوتر در گروه

مخابرات دانشگاه تربیت مدرس هستند. زمینه‌های

پژوهشی مورد علاقه ایشان، شناسایی آماری الگو، پردازش

سیگنال و اطلاعات و مهندسی سنجش از دور است.

نشانی رایانامه ایشان عبارت است از:

**maryam.imani@modares.ac.ir**



**محسن پارسا** مقدم استاد مهندسی

برق (سیستم های قدرت) دانشگاه تربیت

مدرس هستند. ایشان دانش آموخته دوره

کارشناسی مهندسی برق دانشگاه شریف

در سال ۱۳۵۸ و دانش آموخته دوره

کارشناسی ارشد مهندسی برق دانشگاه صنعتی تویوهاشی

(ژاپن) در ۱۳۶۴ و دانش آموخته دوره دکترای مهندسی

برق دانشگاه توهوکو (ژاپن) در سال ۱۳۶۷ هستند.

شبکه‌های قدرت آینده، شبکه‌های هوشمند، سیستم‌های

چندحاملی انرژی، مدیریت انرژی، انرژی‌های تجدیدپذیر

در سیستم قدرت، برنامه‌ریزی و کنترل سیستم‌های

قدرت، ذخیره‌سازی انرژی الکتریکی و کاربرد علوم داده در

سیستم‌های قدرت از علاقه‌های پژوهشی ایشان است.

نشانی رایانامه ایشان عبارت است از:

**Parsa@modares.ac.ir**