

پیش‌بینی قیمت انرژی الکتریکی در روز پیش با استفاده از یک الگوریتم هوشمند مبتنی بر استخراج ویژگی

علی‌اکبر عبدوس^۱، استادیار

۱- دانشکده مهندسی برق و کامپیوتر - دانشگاه صنعتی نوشیروانی بابل - بابل - ایران - a.abdoos@nit.ac.ir

چکیده: تجدید ساختار در سیستم‌های قدرت سبب شده است که پیش‌بینی قیمت انرژی الکتریکی یکی از چالش‌های مهم در پیش روی شرکت‌کنندگان بازار برق باشد. پیش‌بینی دقیق قیمت انرژی الکتریکی می‌تواند به تولیدکنندگان و مصرف‌کنندگان کمک نماید تا تصمیم‌گیری بهتری به منظور افزایش سود خود داشته‌باشند. در این مقاله با استفاده از اطلاعات مربوط به قیمت و میزان مصرف انرژی در روزهای گذشته، قیمت انرژی الکتریکی برای ۲۴ ساعت آینده پیش‌بینی می‌شود. الگوریتم هوشمند پیشنهادی از طریق سه مرحله مهم تحقق می‌یابد: ۱- مرحله پیش‌پردازش، ۲- مرحله انتخاب ویژگی و ۳- مرحله پیش‌بینی. در ابتدا، سیگنال‌های قیمت مربوط به روزهای گذشته با استفاده از تبدیل موجک تجربی به موده‌های مختلفی تجزیه می‌گردد. سپس در مرحله دوم، روش انتخاب ویژگی مبتنی بر اطلاعات متقابل به منظور بهبود عملکرد ماشین یادگیری بر روی داده‌های ورودی اعمال می‌گردد. در مرحله سوم، به منظور پیش‌بینی قیمت انرژی در ساعات روز پیشرو، رگرسیون بردار پشتیبان با استفاده از ویژگی‌های برتر انتخاب‌شده، آموزش داده می‌شود. عملکرد الگوریتم ارائه‌شده با استفاده از داده‌های واقعی مربوط به دو بازار برق Pennsylvania New-Jersey Maryland (PJM) و Operator del Mercado Ibérico de Energía-Polo Español (OMEL) مورد ارزیابی قرار می‌گیرد.

واژه‌های کلیدی: پیش‌بینی قیمت، تبدیل موجک تجربی، رگرسیون بردار پشتیبان، انتخاب ویژگی، اطلاعات متقابل.

Day-Ahead Electricity Price Forecasting Using an Intelligent Algorithm Based on Feature Selection

A. A. Abdoos¹, Assistant Professor

1- Faculty of Electrical and Computer Engineering, Babol Noshirvani University of Technology, Babol, Iran, Email: a.abdoos@nit.ac.ir

Abstract: Restructuring in power systems has caused electricity price forecasting became one of the most important challenges facing electricity market participants. The precise electricity price forecasting helps both consumers and producers to make better decision in order to maximize their benefit. In this paper, the historical data of electricity price and energy consumption are utilized for prediction of electricity price for the next 24 hours. The proposed intelligent algorithm is realized through three main steps: 1- preprocessing step, 2- feature selection and 3- forecasting step. At first, the price signal is decomposed to different modes by using Empirical Wavelet Transform (EWT). Afterward, in the second step, the feature selection method based on mutual information is applied on input data to improve the performance of forecasting engine. In the third step, for day-ahead hourly electricity price forecasting, the Support Vector Regression (SVR) is trained by selected features. The performance of the proposed algorithm is evaluated using real data of two electricity markets i.e. Pennsylvania New-Jersey Maryland (PJM) and Operator del Mercado Ibérico de Energía-Polo Español (OMIE).

Keywords: Price forecasting, empirical wavelet transform (EWT), support vector regression (SVR), feature selection, mutual information.

تاریخ ارسال مقاله: ۱۳۹۶/۰۴/۱۷

تاریخ اصلاح مقاله: ۱۳۹۶/۰۸/۱۳

تاریخ پذیرش مقاله: ۱۳۹۶/۱۰/۱۱

نام نویسنده مسئول: علی‌اکبر عبدوس

نشانی نویسنده مسئول: ایران - بابل - خیابان شریعتی - دانشگاه صنعتی نوشیروانی بابل - دانشکده مهندسی برق و کامپیوتر...

۱- مقدمه

دسترسی به اطلاعات دقیق در سیستم‌های قدرت تجدید ساختار یافته از اهمیت بسزایی برخوردار می‌باشد. یکی از اطلاعات مهم، قیمت انرژی الکتریکی می‌باشد که به تولیدکنندگان و مصرف‌کنندگان کمک زیادی در جهت اتخاذ تصمیمات بهینه می‌نماید. در این محیط، انرژی الکتریکی به‌عنوان یک کالا در نظر گرفته می‌شود که در بازارهای حوضچه و یا دوجانبه مبادله می‌گردد. در صورت عدم در نظر گرفتن محدودیت‌های خطوط انتقال، قیمت‌های حاشیه‌ای محلی^۱ با قیمت تسویه بازار یکسان خواهد بود ولی قیمت‌های حاشیه‌ای محلی با توجه به محدودیت‌های انتقال، در باس‌های مختلف متفاوت می‌باشد. قیمت انرژی الکتریکی در یک باس به پارامترهای مختلفی بستگی دارد از جمله میزان مصرف، دسترسی به منابع مختلف تولید انرژی و غیره [۴-۱].

در سالیان اخیر روش‌های مختلفی به‌منظور پیش‌بینی قیمت انرژی الکتریکی ارائه شده است که به دو گروه مهم طبقه‌بندی می‌شوند: ۱- روش‌های مبتنی بر مدل‌های سری زمانی و ۲- روش‌های هوشمند. در گروه اول مدل‌های سری زمانی ایستا مانند AR^2 [۵]، رگرسیون دینامیکی^۲ و تابع تبدیل^۳ [۶]، $ARIMA$ [۷]، $ARMA$ [۸] و مدل‌های سری زمانی نایستا مانند $GARCH$ [۹] ارائه شده‌اند؛ اما اکثر مدل‌های تخمین سری زمانی، خطی هستند درحالی‌که قیمت انرژی الکتریکی تابعی غیرخطی و پیچیده می‌باشد؛ بنابراین ممکن است روند تغییرات قیمت توسط تکنیک‌های مبتنی بر تخمین سری زمانی به‌درستی تشخیص داده نشود.

در روش‌های هوشمند، سیگنال قیمت انرژی الکتریکی توسط یک ماشین یادگیری تخمین زده می‌شود. ماشین‌های یادگیری شامل انواع مختلف شبکه‌های عصبی مصنوعی مانند شبکه پیش‌خور [۱۶-۱۰]، پایه شعاعی [۱۷] و بازگشتی [۱۸]، شبکه‌های فازی عصبی [۲۳-۱۹]، شبکه عصبی مبتنی بر تبدیل موجک [۲۴] و رگرسیون بردار پشتیبان [۲۷-۲۵] می‌باشند. در واقع با استفاده از داده‌های سری زمانی مربوط به ساعات گذشته، الگوریتم‌های هوشمند قادر به استخراج روابط پیچیده و تخمین میزان قیمت انرژی در ساعات آینده خواهند بود. عیب مهم شبکه‌های عصبی مصنوعی این است که به‌منظور تعیین ساختار بهینه آن، پارامترهای شبکه مانند تعداد لایه‌ها و تعداد نرون‌های هر لایه و توابع تحریک باید با روش‌های سعی و خطا تعیین شوند. همچنین سیستم‌های فازی نیاز به قواعد پیچیده به‌منظور شناسایی الگوهای آموزشی دارند.

در برخی از روش‌های هوشمند به‌منظور افزایش دقت پیش‌بینی، سیگنال‌های سری زمانی توسط ابزارهای آنالیز سیگنال مانند تبدیل موجک^۴ [۳۲-۲۷]، تجزیه مودی تجربی^۵ [۳۳] و تجزیه مودی متغیر^۶ [۳۴] به چندین سطح تجزیه می‌گردد. تبدیل موجک با استفاده از فیلترهای مختلفی می‌تواند سیگنال‌ها را در چند مرحله به سطح تقریب و جزئیات تجزیه نماید. عیب مهم تبدیل موجک این است که برای دست یافتن به ساختار بهینه، باید فیلترها و سطوح تجزیه مختلفی مورد بررسی

قرار گیرند. تجزیه مودی تجربی نیز سیگنال‌ها را به سطوح مختلفی تجزیه می‌کند ولی تعداد این سطوح بستگی به محتویات فرکانسی دارد [۳۳]. در تجزیه مودی متغیر [۳۴] با یافتن مقادیر بهینه فرکانس‌های مرکزی و پهنای باند متناظر با آن، سیگنال اصلی به کمک فیلتر تعیین شده به سطوح مختلفی تجزیه می‌گردد. تجزیه مودی متغیر دارای پارامترهای مختلفی می‌باشد که مقادیر آن بر روی عملکرد این تبدیل تأثیر بسزایی دارد. در روش تحلیل مؤلفه اساسی^{۱۱} تغییرات ناگهانی سیگنال قیمت به‌درستی پیش‌بینی نمی‌گردد زیرا این روش بر مبنای تغییرات هموار سیگنال شکل گرفته است [۱۱].

در برخی از روش‌های ذکر شده، داده‌های سری زمانی قیمت بدون آنالیز سیگنال به‌کار گرفته شده است. همچنین در برخی دیگر حذف داده‌های زائد با استفاده از روش انتخاب ویژگی مورد توجه قرار نگرفته است. در این مقاله یک الگوریتم هوشمند مبتنی بر انتخاب ویژگی به‌منظور پیش‌بینی قیمت انرژی الکتریکی در بازارهای برق ارائه می‌گردد. در روش پیشنهادی، داده‌های قیمت و میزان مصرف انرژی الکتریکی در ساعات گذشته برای پیش‌بینی قیمت در ۲۴ ساعت آینده به‌کار گرفته می‌شود. این الگوریتم از سه مرحله مهم تشکیل شده است: ۱- مرحله پیش‌پردازش، ۲- مرحله انتخاب ویژگی و ۳- مرحله پیش‌بینی. از آنجایی که سری زمانی مربوط به قیمت انرژی الکتریکی یک سیگنال نایستا می‌باشد، در مرحله اول به کمک تبدیل موجک تجربی^{۱۲} [۳۵] به چندین سیگنال تجزیه می‌گردد تا کار پیش‌بینی سیگنال‌های تجزیه‌شده با دقت بیشتری انجام پذیرد. در مرحله دوم به‌منظور کاهش حجم محاسبات و افزایش دقت ماشین یادگیری، ویژگی‌های برتر توسط روش اطلاعات متقابل^{۱۳} انتخاب می‌گردد [۳۶]. برخلاف روش همبستگی [۱۴، ۱۶، ۱۸، ۲۴]، این روش انتخاب ویژگی قادر است وابستگی خطی و غیرخطی بین داده‌ها را مشخص نماید. در مرحله سوم، رگرسیون بردار پشتیبان به‌منظور پیش‌بینی قیمت ساعات آینده توسط ویژگی‌های انتخاب شده، آموزش داده می‌شود. رگرسیون ماشین پشتیبان قادر است که از طریق حل یک مسئله بهینه‌سازی، رابطه غیرخطی ماتریس ورودی و خروجی را مشخص نماید [۳۷، ۳۸]. در انتها عملکرد الگوریتم ارائه شده با استفاده از داده‌های مربوط به دو بازار برق مختلف مورد ارزیابی قرار می‌گیرد [۳۹، ۴۰]. مزایای روش ارائه شده عبارتند از:

- تجزیه سری زمانی قیمت به چندین سیگنال با محتویات فرکانسی مشخص باعث افزایش دقت الگوریتم می‌گردد.
- برخلاف تبدیل موجک استاندارد، تبدیل موجک تجربی نیاز به آزمایش موجک‌های مادر و سطوح تجزیه مختلفی ندارد.
- حذف ویژگی‌های زائد با استفاده از روش انتخاب ویژگی مبتنی بر اطلاعات متقابل، باعث کاهش حجم محاسبات و افزایش دقت ماشین یادگیری می‌گردد.
- الگوریتم هوشمند ارائه شده می‌تواند برای پیش‌بینی قیمت انرژی در بازارهای برق مختلف به‌کار گرفته شود.

۲- ابزارهای به کار گرفته شده

۲-۱- تبدیل موجک تجربی

تبدیل موجک تجربی یک ابزار قدرتمند در زمینه پردازش سیگنال می‌باشد که قادر به تجزیه سیگنال به مودهای مختلف می‌باشد. در این روش تعداد بهینه مودها بر اساس بیشینه‌های طیف دامنه به‌دست‌آمده از تبدیل فوریه تعیین می‌گردد. موجک‌های تجربی به‌صورت فیلترهای میان‌گذر در نظر گرفته می‌شوند. تعداد موج‌های تجزیه به مشخصات سیگنال و محتویات هارمونیک آن بستگی دارد. می‌توان تبدیل موجک تجربی $W_f^\varepsilon(n, t)$ را به همان فرم استاندارد تبدیل موجک به‌صورت زیر تعریف کرد. ضرایب جزئیات از ضرب داخلی سیگنال اصلی در موجک‌های تجربی به‌دست می‌آیند [۳۵]:

$$W_f^\varepsilon(n, t) = \langle f, \psi_n \rangle = \int f(\tau) \overline{\psi_n(\tau - t)} d\tau \quad (1)$$

$$= (\hat{f}(\omega) \widehat{\psi}_n(\omega))^\vee \quad (2)$$

و ضرایب تقریب از ضرب داخلی سیگنال در تابع مقیاس به‌دست می‌آید:

$$W_f^\varepsilon(0, t) = \langle f, \phi_n \rangle = \int f(\tau) \overline{\phi_n(\tau - t)} d\tau \quad (3)$$

$$= (\hat{f}(\omega) \widehat{\phi}_n(\omega))^\vee \quad (4)$$

که در آن $\widehat{\psi}_n(\omega)$ و $\widehat{\phi}_n(\omega)$ به‌صورت زیر تعریف می‌گردد [۳۵]:

$$\widehat{\phi}_n(\omega) = \begin{cases} 1 & \text{if } |\omega| \leq (1 - \gamma)\omega_n \\ \cos \left[\frac{\pi}{2} \beta \left(\frac{1}{2\gamma\omega_n} (|\omega| - (1 - \gamma)\omega_n) \right) \right] & \\ 0 & \text{otherwise} \end{cases} \quad (5)$$

$$\widehat{\psi}_n(\omega) = \begin{cases} 1 & \text{if } (1 + \gamma)\omega_n \leq |\omega| \leq (1 - \gamma)\omega_{n+1} \\ \cos \left[\frac{\pi}{2} \beta \left(\frac{1}{2\gamma\omega_{n+1}} (|\omega| - (1 - \gamma)\omega_{n+1}) \right) \right] & \\ \text{if } (1 - \gamma)\omega_{n+1} \leq |\omega| \leq (1 + \gamma)\omega_{n+1} & \\ \sin \left[\frac{\pi}{2} \beta \left(\frac{1}{2\gamma\omega_{n+1}} (|\omega| - (1 - \gamma)\omega_n) \right) \right] & \\ \text{if } (1 - \gamma)\omega_{n+1} \leq |\omega| \leq (1 + \gamma)\omega_n & \\ 0 & \text{otherwise} \end{cases} \quad (6)$$

تابع $\beta(x)$ یک تابع دلخواه بین صفر و یک می‌باشد که باید شرایط زیر را ارضاء نماید:

$$\beta(x) = \begin{cases} 0 & \text{if } x \leq 0 \\ \beta(x) + \beta(1 - x) = 1 & \forall x \in [0, 1] \\ 1 & \text{if } x \geq 1 \end{cases} \quad (7)$$

توابعی زیادی در شرط بالا صدق می‌نمایند؛ اما در بسیاری از مراجع به‌صورت زیر انتخاب می‌گردد [۳۵]:

$$\beta(x) = x^4(35 - 84x + 70x^2 - 20x^3) \quad (8)$$

تابع اصلی $f(t)$ به‌صورت زیر دوباره بازمی‌آید [۳۵]:

$$f(t) = W_f^\varepsilon(0, t) * \phi_1(t) + \sum_{n=1}^N W_f^\varepsilon(n, t) * \psi_n(t) \quad (9)$$

$$= \left(\widehat{W}_f^\varepsilon(0, \omega) \widehat{\phi}_1(\omega) + \sum_{n=1}^N \widehat{W}_f^\varepsilon(n, \omega) \widehat{\psi}_n(\omega) \right)^\vee \quad (10)$$

مودهای تجربی f_k به‌صورت زیر تعریف می‌شود:

$$f_0(t) = W_f^\varepsilon(0, t) * \phi_1(t) \quad (11)$$

$$f_k(t) = \sum_{n=1}^N W_f^\varepsilon(k, t) * \psi_k(t) \quad (12)$$

۲-۲- رگرسیون بردار پشتیبان

در رگرسیون به‌وسیله بردار پشتیبان، رابطه بین ورودی x و خروجی y تخمین زده می‌شود. برخلاف مسائل شناسایی الگو که خروجی مطلوب به‌صورت گسسته (صفر و یک) می‌باشد، در مسائل رگرسیون خروجی به‌صورت اعداد حقیقی می‌باشد. برای انجام رگرسیون فرض می‌شود که l جفت داده آموزشی برای فرایند یادگیری بین ورودی و خروجی به‌شرح زیر باشد [۳۷]:

$$D = \{[x(i)], [y(i)] \in R^n \times R, \quad i = 1, \dots, l\} \quad (13)$$

که شامل l جفت $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$ می‌باشد که ورودی‌های بردارهای n بعدی $x \in R^n$ و جواب‌های سیستم تک‌بعدی $y \in R$ ، به‌صورت اعداد حقیقی می‌باشند. در ابتدا فرض بر آن است که رابطه بین ورودی و خروجی توسط یک تابع تقریب زده می‌شود، سپس یک ابرصفحه خطی رگرسیون به‌صورت زیر در نظر گرفته می‌شود.

$$f(X, W) = W^T X + b \quad (14)$$

در مورد رگرسیون ماشین بردار پشتیبان، از خطای اندازه‌گیری به‌جای محاسبه حاشیه در طبقه‌بندی‌کننده استفاده می‌شود. مهم‌ترین تفاوت نسبت به رگرسیون کلاسیک استفاده از توابع جدید خطا می‌باشد. تابع خطای خطی وینیک با ناحیه غیر حساس ε به‌صورت زیر تعریف می‌شود [۳۷، ۳۸]:

$$E(x, y, f) = |y - f(x, w)|_\varepsilon = \begin{cases} 0 & \text{if } |y - f(x, w)| \leq \varepsilon \\ |y - f(x, w)| - \varepsilon, & \text{otherwise} \end{cases} \quad (15)$$

$$e(x, y, f) = \max(0, |y - f(x, w)| - \varepsilon) \quad (16)$$

بنابراین اگر تفاوت بین مقدار پیش‌بینی شده $f(x_i, w)$ و اندازه‌گیری شده y_i کمتر از ε باشد، خطا صفر است. خطای کلی محاسبه شده توسط تابع وینیک بدین‌صورت محاسبه می‌گردد:

$$R_{emp}^\varepsilon(w, b) = \frac{1}{l} \sum_{i=1}^l |y_i - W^T X_i - b|_\varepsilon \quad (17)$$

مانند مسائل طبقه‌بندی، میزان ریسک کلی و نرم w یعنی $|w|$ به‌طور هم‌زمان کمینه می‌گردد؛ بنابراین یک ابرصفحه رگرسیون خطی یعنی $f(x, w) = W^T x + b$ با کمینه‌کردن رابطه زیر به‌دست می‌آید [۳۷، ۳۸]:

$$R = 1/2 (|W|)^2 + C \sum_{i=1}^l |y_i - f(x_i, w)|_\varepsilon \quad (18)$$

همچنین برای داده‌های خارج از ε خواهیم داشت:

$$e(x, y, f) = \max(0, |y - f(x, w)| - \varepsilon) \quad \text{بیشتر از } \varepsilon$$

$$|y - f(X, W)| - \varepsilon = \xi^* \quad \text{کمتر از } \varepsilon$$

بنابراین با در نظر گرفتن تساوی بالا، حداقل‌سازی ریسک به‌صورت زیر به‌دست می‌آید:

محاسبه می‌گردد؛ در روش اطلاعات متقابل، وابستگی غیرخطی داده‌ها نیز مدنظر قرار می‌گیرد. کمیت M بیانگر میزان وابستگی دو متغیر تصادفی خطی یا غیرخطی می‌باشند. به عبارت دیگر مقدار M بیانگر آن است که چه مقدار از اطلاعات متغیر X می‌تواند از متغیر Y به دست آید. متغیر تصادفی X دارای مقادیر گسسته می‌باشد که عدم قطعیت آن با آنتروپی $H(X)$ نشان داده می‌شود [۳۶].

$$H(X) = - \sum_{i=1}^n P(x_i) \log_2 P(x_i) \quad (23)$$

که در آن $P(x_i)$ احتمال متغیر تصادفی گسسته با مقادیر x_1, x_2, \dots, x_n می‌باشد. آنتروپی مشترک $H(X, Y)$ دو متغیر تصادفی گسسته X و Y با توزیع احتمال متقابل $P(X, Y)$ به صورت زیر تعریف می‌شود [۳۶]:

$$H(X, Y) = - \sum_{i=1}^n \sum_{j=1}^m P(x_i, y_j) \log_2 P(x_i, y_j) \quad (24)$$

که در آن $H(X, Y)$ بیانگر آنتروپی کلی متغیرهای تصادفی X و Y می‌باشد. آنتروپی شرطی دلالت دارد بر کاهش عدم قطعیت یک متغیر در زمانی که متغیر دیگر رخ داده است. با فرض اینکه متغیر Y مشخص باشد، آنتروپی شرطی $H(X|Y)$ برای متغیر X به شرط رخداد Y به صورت زیر محاسبه می‌گردد [۳۶]:

$$H(X|Y) = - \sum_{i=1}^n P(x_i, Y) \log_2 P(x_i, Y) \\ = - \sum_{i=1}^n \sum_{j=1}^m P(x_i|y_j) \log_2 P(x_i|y_j) \quad (25)$$

که در آن $P(x_i|y_j)$ احتمال شرطی رخداد x_i به شرط رخداد y_j می‌باشد. معادله فوق دلالت بر این نکته دارد که برای توصیف متغیر X نیاز به اطلاعات بیشتری نیست به شرط آنکه Y مشخص باشد. در صورتی که $H(X|Y) = H(X)$ باشد، دانستن Y کمکی به رخداد X نمی‌کند. بنابراین اطلاعات متقابل بیانگر مقدار همبستگی بین دو متغیر خواهد بود. مقدار اطلاعات متقابل با معیار $MI(X, Y)$ مشخص می‌شود و به صورت زیر تعریف می‌گردد [۳۶]:

$$MI(X, Y) = - \sum_{i=1}^n \sum_{j=1}^m P(x_i, y_j) \log_2 \left(\frac{P(x_i, y_j)}{P(x_i)P(y_j)} \right) \quad (26)$$

اگر مقدار $MI(X, Y)$ خیلی بزرگ باشد بدان معنی است که X و Y به یکدیگر به شدت وابسته هستند و برعکس مقادیر کوچک میزان همبستگی اطلاعات، نشانگر وابستگی کم داده‌ها می‌باشد. در صورتی که دو متغیر کاملاً مستقل باشند، $P(x_i, y_j) = P(x_i)P(y_j)$ که در این صورت، $MI(X, Y) = 0$ خواهد شد.

۳- الگوریتم ارائه شده

همان‌طور که در شکل (۱) نشان داده شده است، الگوریتم هوشمند ارائه شده از طریق سه مرحله مهم پیاده‌سازی می‌گردد. در مرحله اول سیگنال‌های سری زمانی شامل داده‌های مربوط به قیمت انرژی در ۵۰ روز گذشته توسط تبدیل موجک تجربی به مودهای مختلفی تجزیه

$$R_{W, \xi, \xi^*} = \left[\frac{1}{2} \|W\|^2 + C \left(\sum_{i=1}^l \xi_i + \sum_{i=1}^l \xi_i^* \right) \right] \quad (19)$$

$$y_i - W^T X_i - b \leq \varepsilon + \xi_i, \quad i = 1, \dots, l \quad (20)$$

$$W^T X_i + b - y_i \leq \varepsilon + \xi_i^*, \quad i = 1, \dots, l \quad (21)$$

$$\xi_i \geq 0, \xi_i^* \geq 0, \quad i = 1, \dots, l \quad (22)$$

که ξ_i و ξ_i^* متغیرهای کمکی مثبت برای اندازه‌گیری حدود بالا و پایین ε می‌باشند.

باید توجه نمود که ثابت C بر روی خطای تقریب و نرم بردار وزن اثر می‌گذارد و توسط کاربر انتخاب می‌گردد. افزایش C افزایش خطا و کوچک‌تر شدن ξ_i و ξ_i^* را در پی دارد که این عمل منجر به کاهش خطای تقریب و افزایش نرم W یعنی $\|W\|$ می‌گردد؛ اما افزایش $\|W\|$ تعمیم‌پذیری مدل را به مخاطره می‌اندازد. پارامتر دیگری که باید توسط کاربر تعیین گردد، سایز مجرای ε می‌باشد. انتخاب ε از C آسان‌تر است و به صورت حداکثر مجاز یا درصد مطلوبی از مقادیر خروجی y_i تعیین می‌گردد. مسئله بهینه‌سازی با قیود فوق را می‌توان با استفاده از متغیرهای لاگرانژ به صورت زیر بیان نمود [۳۷، ۳۸].

همان ایده اولیه در طراحی ماشین‌های بردار پشتیبان برای ایجاد تابع رگرسیون غیرخطی به کار می‌رود. در ابتدا نگاشت بردارهای ورودی $x \in R^n$ به بردارهای $\Phi(x)$ با فضای ویژگی با ابعاد بزرگ‌تر f انجام می‌گیرد؛ که Φ نشانگر نگاشت $R^n \rightarrow R^f$ می‌باشد. پس از آن مسئله رگرسیون خطی در این فضای ویژگی حل می‌شود. المان‌های فضای ورودی (فضای X) با مؤلفه‌های X_i و المان‌های فضای ویژگی $\Phi(x)$ توسط $\Phi(x)$ نمایش داده می‌شود. با انجام این نگاشت، در فضای Φ الگوریتم آموزشی قادر به یافتن ابرصفحه رگرسیون خطی با به کارگیری روابط ارائه شده برای ماشین بردار رگرسیون خطی باشد. همچنین انتظار خواهیم داشت جواب خطی برای فضای ویژگی F در این روش به حل یک مسئله شبیه‌سازی مرتبه دو با قیود نامساوی در فضای ویژگی منجر گردد. جواب به دست آمده برای ابرصفحه رگرسیون $f = W^T \Phi(x) + b$ یک ابرسطح رگرسیون غیرخطی در فضای ورودی اصلی ایجاد خواهد نمود. معمول‌ترین توابع کرنل، توابع چندجمله‌ای و تابع پایه شعاعی می‌باشد. پارامترهای آموزشی کمی در ساختار ماشین‌های بردار پشتیبان برای رگرسیون وجود دارد که متداول‌ترین آن‌ها، ناحیه غیرحساس ε ، پارامتر جریمه C و پارامترهای مربوط به تابع کرنل می‌باشند که تمامی این سه پارامتر باید توسط کاربر مشخص گردد. برخلاف مسئله طبقه‌بندی، برای داده‌هایی که آلوده به نویز نیستند، پارامتر جریمه را می‌توان بی‌نهایت انتخاب کرد و مدل رگرسیون تنها توسط تغییر پارامترهای ناحیه غیرحساس ε و پارامترهای مربوط به تابع کرنل کنترل گردد [۳۷، ۳۸].

۲-۳- انتخاب ویژگی مبتنی بر اطلاعات متقابل

روش اطلاعات متقابل یک روش انتخاب ویژگی است که در آن ویژگی‌های برتر بر اساس وابستگی داده‌ها انتخاب می‌گردند. برخلاف بسیاری از روش‌های انتخاب ویژگی که همبستگی خطی بین داده‌ها

گرفته شود. انتخاب مقدار آستانه کم باعث افزایش تعداد ویژگی‌های انتخاب‌شده می‌گردد که می‌تواند باعث افزایش محاسبات و کاهش دقت پیش‌بینی گردد. از طرف دیگر مقدار آستانه بزرگ‌تر باعث کاهش تعداد ویژگی‌های انتخاب‌شده می‌شود که در این صورت ممکن است اطلاعات کافی به منظور آموزش سیستم هوشمند فراهم نگردد؛ بنابراین یک مقدار بهینه می‌تواند باعث افزایش دقت پیش‌بینی گردد. از آنجایی که پیش‌بینی موده‌های تجزیه‌شده به‌طور جداگانه انجام می‌گیرد، مقدار آستانه برای هر مود به‌طور مجزا تعیین می‌شود. در جدول (۱) تعداد ویژگی‌های انتخاب‌شده برای مقادیر مختلف آستانه مشخص شده است. این جدول نشان می‌دهد که با کاهش مقدار آستانه، تعداد ویژگی‌های انتخاب‌شده افزایش می‌یابد. تغییرات جهشی به‌وجودآمده در تعداد ویژگی‌های انتخاب‌شده به‌عنوان یک معیار مناسب به منظور انتخاب مقادیر آستانه مناسب مدنظر قرار می‌گردد.

در جدول (۱)، مقادیر بهینه که در آن جهش ناگهانی در تعداد ویژگی‌های انتخاب‌شده رخ می‌دهد، مشخص شده است. مقدار آستانه بهینه برای موده‌های اول، دوم، سوم و چهارم به ترتیب برابر با ۰/۲، ۰/۴، ۰/۲۵ و ۰/۳۵ می‌باشد. در مرحله سوم، ویژگی‌های انتخاب‌شده برای هر یک از موده‌های تجزیه‌شده به‌عنوان ورودی رگرسیون بردار پشتیبان در نظر گرفته می‌شود. به منظور پیش‌بینی انرژی در ساعات آینده، با استفاده از داده‌های ساعات گذشته و بر اساس ویژگی‌های انتخاب‌شده، بردارهای ورودی برای هر مود به‌طور جداگانه تشکیل می‌گردد. این بردار به‌عنوان ورودی ابزار رگرسیون بردار پشتیبان آموزش‌داده‌شده اعمال می‌گردد و هر یک از مودها به‌طور جداگانه تخمین زده می‌شود. سپس با درنمائی کردن مقادیر پیش‌بینی‌شده و تجمیع آن‌ها مقدار قیمت انرژی برای ساعت آینده پیش‌بینی می‌شود. این روند برای قیمت انرژی در ۲۳ ساعت دیگر تکرار می‌گردد تا قیمت انرژی روز آینده به‌طور کامل پیش‌بینی گردد. در این مقاله به منظور محاسبه خطای پیش‌بینی از دو معیار میانگین قدرمطلق خطا^{۱۴} (MAE) و میانگین درصدی قدرمطلق خطا^{۱۵} (MAPE) استفاده می‌گردد که به‌صورت زیر محاسبه می‌گردد:

$$MAE = \frac{1}{N} \sum_{i=1}^N |P_{i,act} - P_{i,for}| \quad (27)$$


$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{P_{i,act} - P_{i,for}}{P_{i,act}} \right| \times 100 \quad (28)$$

که در آن، $P_{i,act}$ و $P_{i,for}$ به ترتیب بیانگر مقدار واقعی و پیش‌بینی‌شده قیمت انرژی الکتریکی می‌باشد و N نشان‌دهنده تعداد نمونه‌های پیش‌بینی است.


می‌گردد. لذا سری زمانی موردنظر برای ایجاد ماتریس آموزش دارای ۱۲۰۰ نمونه می‌باشد. هر یک از موده‌های تجزیه‌شده شامل محدوده فرکانسی مشخصی می‌باشد. شکل (۲) نمونه‌ای از سیگنال‌های تجزیه‌شده به موده‌های مختلف را برای سری زمانی قیمت مربوط به ۵۰ روز متوالی سال ۲۰۱۵ در بازار PJM نشان می‌دهد. همان‌طور که مشاهده می‌شود مود ۱ شامل فرکانس‌های پایین می‌باشد که از تغییرات هموارتری برخوردار است. از طرف دیگر، موده‌های مرتبه بالاتر دارای فرکانس‌های بالاتری می‌باشند که نشان‌دهنده تغییرات شدیدتر سیگنال‌های قیمت می‌باشند. به این ترتیب پیش‌بینی تغییرات سیگنال قیمت در مراحل مختلفی با استفاده از موده‌های به‌دست‌آمده انجام می‌شود که منجر به افزایش دقت الگوریتم ارائه‌شده می‌گردد.

در این مقاله تعداد موده‌های تجزیه‌شده برابر با ۴ سطح در نظر گرفته می‌شود زیرا همان‌طور که در شکل ۲ (ه) نشان داده شده است، دامنه مود پنجم بسیار ناچیز می‌باشد. لذا تجزیه به سطوح بالاتر تأثیر چندانی در دقت پیش‌بینی نخواهد داشت. ماتریس ورودی و خروجی به منظور آموزش سیستم هوشمند ارائه‌شده در شکل (۳) نشان داده شده است. ماتریس ورودی شامل داده‌های قیمت انرژی، موده‌های تجزیه‌شده قیمت انرژی و مقدار بار مصرفی می‌باشد و عناصر ماتریس خروجی قیمت انرژی مربوط به همان مود در ساعت بعدی می‌باشد. P_k تا P_{k+168} و L_k تا L_{k+168} به ترتیب مقدار قیمت انرژی و بار مصرفی را در یک هفته گذشته برای نمونه k ام نشان می‌دهد. DP_k^n تا DP_{k+168}^n نیز بیانگر مقادیر مربوط به مود n ام سیگنال قیمت در هفته گذشته برای نمونه k ام می‌باشد. در برخی از تحقیقات نشان داده شده است که انتخاب تعداد نمونه‌های زیاد برای پیش‌بینی ساعت بعد باعث کاهش دقت و عدم‌یادگیری مناسب می‌گردد [۳۶].


از طرف دیگر استفاده از نمونه‌های کم باعث می‌گردد که الگوریتم هوشمند قابلیت تعمیم‌پذیری خوبی نداشته‌باشد به‌طوری‌که فقط الگوهای آموزشی را حفظ می‌نماید. در این مقاله به منظور پیش‌بینی قیمت انرژی در ساعت بعد از داده‌های یک هفته گذشته استفاده می‌شود. با توجه به اینکه از داده‌های ۵۰ روز گذشته به منظور ایجاد بردارهای آموزشی استفاده می‌گردد، نمونه‌های آموزشی در این مقاله ۱۰۳۲ می‌باشد. به منظور جلوگیری از تأثیر نامطلوب بازه تغییرات ورودی‌های مختلف بر روی ماشین یادگیری، موده‌های تجزیه‌شده بین ۰ و ۱ نرمالیزه می‌شوند. در مرحله دوم با استفاده از روش انتخاب ویژگی مبتنی بر اطلاعات متقابل، داده‌های زائد حذف می‌شود. در بسیاری از روش‌های انتخاب ویژگی مانند روش همبستگی، تنها وابستگی خطی بین دو ویژگی در نظر گرفته می‌شود درحالی‌که در روش اطلاعات متقابل وابستگی غیرخطی بین دو ویژگی نیز در نظر گرفته می‌شود [۳۶]. بدین ترتیب حجم محاسبات موردنیاز در مرحله آموزش ماشین یادگیری تا حد زیادی کاهش می‌یابد و از طرف دیگر موجب افزایش دقت پیش‌بینی می‌گردد. به منظور انتخاب ویژگی‌های برتر با استفاده از روش اطلاعات متقابل باید یک مقدار آستانه مناسب بین صفر و یک در نظر




ب) مود دوم



ج) مود سوم

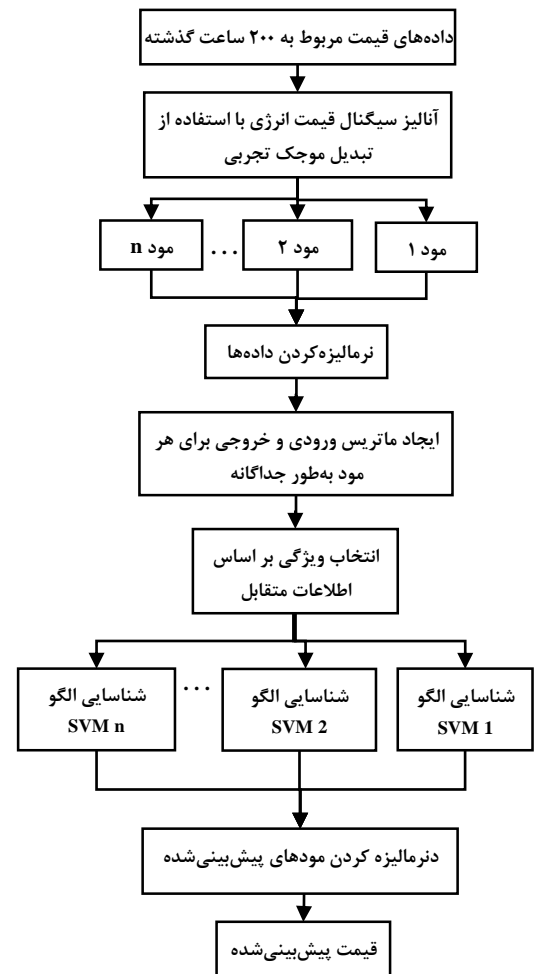


د) مود چهارم




ه) مود پنجم

شکل ۲: مودهای به‌دست‌آمده حاصل از تجزیه سیگنال قیمت ۵۰ روز متوالی در سال ۲۰۱۵ با استفاده از تبدیل موجک تجربی



شکل ۱: الگوریتم روش هوشمند ارائه‌شده به‌منظور پیش‌بینی قیمت انرژی الکتریکی



الف) مود اول

موجک گسسته (DWT) و تجزیه مودی تجربی (EMD) به‌عنوان ابزارهای آنالیز سیگنال در مرحله پیش‌پردازش به‌کار گرفته شده است. درحالی‌که ماشین بردار پشتیبان به‌عنوان ابزار رگرسیون در مرحله پیش‌بینی مورد استفاده قرار می‌گیرد. دو پارامتر تنظیم‌شونده مربوط به ماشین بردار پشتیبان یعنی C و ε به ترتیب برابر با ۱۰ و ۰/۰۰۱ و تابع کرنل از نوع چندجمله‌ای درجه دوم انتخاب می‌گردد [۲۵، ۳۸]. در تمامی روش‌های آنالیز سیگنال به‌کار گرفته‌شده، ۴ سطح تجزیه در نظر گرفته می‌شود. از طرف دیگر در روش تبدیل موجک گسسته از فیلتر دابچیز^{۱۶} که در بسیاری از تحقیقات به‌کار گرفته‌شده، به‌منظور تجزیه سیگنال استفاده می‌گردد [۳۱-۲۷]. مقدار شاخص MAPE و MAE برای ایام هفته‌های پیش‌بینی‌شده به‌طور جداگانه در جداول (۲) تا (۵) ارائه شده است. نتایج شبیه‌سازی نشان می‌دهد که روش EWT دارای دقت بالاتری نسبت به DWT و EMD می‌باشد. مقدار میانگین معیار MAE برای هفته‌های پیش‌بینی‌شده مربوط به فصول بهار، تابستان، پاییز و زمستان به ترتیب برابر با ۳/۹۱۲، ۳/۲۱۸، ۱/۱۱۹ و ۱/۲۲۴ دلار بر مگاوات ساعت می‌باشد. همچنین مقدار میانگین معیار MAPE برای هفته‌های ذکر شده به ترتیب برابر با ۸/۰۴۹، ۷/۴۴۶، ۳/۷۱۸ و ۳/۵۶۱ درصد می‌باشد. اشکال ۴ (الف) تا (د) مقدار واقعی و پیش‌بینی‌شده قیمت انرژی را برای چهار هفته از فصول مختلف نشان می‌دهد. همان‌طور که در شکل ۴ (الف) نشان داده شده است، قیمت انرژی در هفته پیش‌بینی‌شده دارای پیک‌هایی در روزهای دوم و سوم می‌باشد و در بقیه روزها تغییرات قیمت تقریباً هموار می‌باشد. مقدار پیش‌بینی‌شده قادر است که هر دو تغییرات ناگهانی و هموار را به‌خوبی دنبال نماید. شکل ۴ (ب) مقدار قیمت انرژی را برای یک هفته از تابستان نشان می‌دهد که دارای پیک‌های روزانه می‌باشد. الگوریتم ارائه‌شده قادر است که این پیک‌ها را با دقت بالایی پیش‌بینی نماید. در شکل ۴ (ج) مقدار قیمت انرژی دارای پیک‌های ناگهانی می‌باشد به‌طوری‌که تغییر انرژی در یک ساعت ممکن است به بیش از ۱۰ دلار بر مگاوات‌ساعت نیز برسد. نتایج شبیه‌سازی نشان می‌دهد که با وجود این تغییرات شدید، مقادیر پیش‌بینی‌شده به مقادیر حقیقی بسیار نزدیک می‌باشد. مقدار قیمت انرژی برای یک هفته از فصل زمستان در شکل ۴ (د) نشان داده شده است که در آن پیک‌های متوالی متعددی وجود دارد. این پیک‌های قیمت نیز با دقت بالایی توسط الگوریتم ارائه‌شده تشخیص داده می‌شوند.

از آنجایی که نوع ماشین یادگیری بر روی نتایج به‌دست‌آمده تأثیر بسزایی دارد، نتایج شبیه‌سازی برای دیگر ماشین‌های یادگیری از جمله شبکه عصبی مصنوعی و ماشین یادگیری بی‌نهایت در جداول (۶) تا (۹) برای هفته‌های ذکر شده از فصول مختلف سال ارائه شده است. مقدار خطای MAPE و MAE برای چهار هفته موردنظر با در نظر گرفتن ماشین‌های یادگیری فوق به‌منظور پیش‌بینی قیمت انرژی ساعات آینده محاسبه شده است. در این بخش از روش EWT در مرحله پیش‌پردازش به‌منظور آنالیز سیگنال‌های سری زمانی مربوط به قیمت انرژی الکتریکی استفاده می‌شود. شبکه عصبی به‌کار گرفته‌شده دارای سه لایه می‌باشد

$$P = \begin{bmatrix} \begin{bmatrix} P_1 \\ \vdots \\ P_{168} \end{bmatrix} & \begin{bmatrix} P_2 \\ \vdots \\ P_{169} \end{bmatrix} & \dots & \begin{bmatrix} P_k \\ \vdots \\ P_{k+168} \end{bmatrix} \\ \begin{bmatrix} DP_1^n \\ \vdots \\ DP_{168}^n \end{bmatrix} & \begin{bmatrix} DP_2^n \\ \vdots \\ DP_{169}^n \end{bmatrix} & \dots & \begin{bmatrix} DP_k^n \\ \vdots \\ DP_{k+168}^n \end{bmatrix} \\ \begin{bmatrix} L_1 \\ \vdots \\ L_{168} \end{bmatrix} & \begin{bmatrix} L_1 \\ \vdots \\ L_{169} \end{bmatrix} & \dots & \begin{bmatrix} L_k \\ \vdots \\ L_{k+168} \end{bmatrix} \end{bmatrix}$$

(الف) ماتریس ورودی
 $T = [P_{169} \ P_{170} \dots \ P_{k+169}]$
 (ب) ماتریس خروجی

شکل ۳: ماتریس‌های آموزشی

جدول ۱: تأثیر مقدار آستانه بر روی تعداد ویژگی‌های انتخاب‌شده برای

مودهای مختلف							
مود اول		مود دوم		مود سوم		مود چهارم	
مقدار شاخص	تعداد ویژگی‌ها	مقدار شاخص	تعداد ویژگی‌ها	مقدار شاخص	تعداد ویژگی‌ها	مقدار شاخص	تعداد ویژگی‌ها
۱	۱	۱	۱	۱	۱	۱	۱
۰/۷۲	۲	۰/۷۹	۲	۰/۷۱	۵	۰/۸۸	۶
۰/۵۳	۳	۰/۷۵	۱۰	۰/۶۳	۶	۰/۷۳	۹
۰/۳۸	۴	۰/۶۶	۱۳	۰/۵۵	۷	۰/۶۳	۱۲
۰/۲۶	۲۵	۰/۶۴	۱۴	۰/۵۰	۱۱	۰/۵۳	۱۵
۰/۲۹	۵۱	۰/۵۶	۲۳	۰/۴۵	۱۲	۰/۴۶	۱۸
۰/۲۵	۵۲	۰/۴۷	۲۴	۰/۴	۲۴	۰/۴۲	۲۱
۰/۲	۵۳	۰/۴۶	۲۶	۰/۳۵	۳۸	۰/۳۸	۲۴
۰/۱۹	۲۰۱	۰/۴۴	۳۴	۰/۳	۴۲	۰/۳۵	۲۷
۰/۱۵	۳۱۲	۰/۴۳	۳۵	۰/۲۵	۵۶	۰/۳	۱۱۶
۰/۱۲	۴۰۳	۰/۴۰	۳۶	۰/۲	۱۶۵	۰/۲۵	۱۷۳
۰/۱	۴۵۰	۰/۳۷	۱۵۸	۰/۱	۲۲۵	۰/۱	۱۸۴

۴- نتایج شبیه‌سازی

۴-۱- بازار PJM

به‌منظور ارزیابی عملکرد روش پیشنهادی، اطلاعات مربوط به قیمت انرژی الکتریکی در بازار برق PJM در سال ۲۰۱۵ مورد استفاده قرار می‌گیرد [۳۹]. PJM یکی از بزرگ‌ترین بازارهای انرژی الکتریکی در دنیا می‌باشد که شامل چندین ایالت است. بیش از ۹۰۰ شرکت تولیدی با ظرفیت تولید ۱۸۳/۶ گیگاوات عضو بازار PJM هستند که به ۶۱ میلیون مصرف‌کننده خدمات‌رسانی می‌کنند. این بازار با دارا بودن ۱۳۷۶ منبع، ۱۰۰۶۷۰ کیلومتر خطوط انتقال و ۶۰۳۸ پست فشارقوی بیش از ۷۹۱ تراوات ساعت انرژی را در سال فوق مبادله کرده است.

به‌منظور بررسی تأثیر مرحله پیش‌پردازش بر روی دقت روش ارائه‌شده، نتایج شبیه‌سازی‌ها برای یک هفته از فصول مختلف با در نظر گرفتن روش‌های آنالیز مختلف انجام شده است. در این بخش مقدار قیمت انرژی در هفته سوم ماه‌های آوریل، آگوست، نوامبر و فوریه پیش‌بینی می‌گردد. روش‌های تبدیل موجک تجربی (EWT)، تبدیل

جدول ۲: خطای پیش‌بینی برای فصل بهار با در نظر گرفتن ابزارهای آنالیز سیگنال مختلف

EMD		DWT		EWT		تجزیه
MAPE	MAE	MAPE	MAE	MAPE	MAE	معیار خطا
۹/۵۱۵	۴/۱۷۰	۱۰/۸۹۶	۴/۷۷۵	۸/۴۲۸	۳/۶۹۴	دوشنبه
۱۵/۸۳۷	۱۱/۸۸۹	۱۳/۷۲۹	۱۰/۳۰۶	۱۰/۶۱۶	۷/۹۷۰	سه‌شنبه
۱۷/۵۳۱	۱۰/۴۶۳	۱۴/۵۱۶	۸/۶۶۴	۱۰/۸۱۷	۶/۴۵۶	چهارشنبه
۱۱/۹۵۷	۵/۱۴۷	۹/۴۸۶	۴/۰۸۳	۴/۵۳۷	۱/۹۵۳	پنجشنبه
۱۰/۳۰۶	۴/۴۲۶	۱۱/۳۱۰	۴/۸۵۷	۴/۷۴۳	۲/۰۳۷	جمعه
۱۵/۴۶۵	۶/۱۹۷	۹/۱۴۳	۳/۶۶۴	۷/۷۷۸	۳/۱۱۷	شنبه
۱۳/۳۸۸	۴/۷۶۸	۱۱/۹۰۷	۴/۲۴۰	۶/۰۶۹	۲/۱۶۱	یکشنبه
۱۳/۸۳۱	۶/۷۲۳	۱۱/۹۲۹	۵/۷۹۹	۸/۰۴۹	۳/۹۱۲	خطای هفته

جدول ۳: خطای پیش‌بینی برای فصل تابستان با در نظر گرفتن ابزارهای آنالیز سیگنال مختلف


EMD		DWT		EWT		تجزیه
MAPE	MAE	MAPE	MAE	MAPE	MAE	معیار خطا
۷/۷۳۰	۲/۰۳۶	۱۰/۱۹۶	۲/۶۸۵	۵/۲۱۲	۱/۳۷۲	دوشنبه
۶/۴۷۱	۲/۷۴۷	۱۰/۸۸۹	۴/۶۲۲	۴/۷۱۴	۲/۰۰۱	سه‌شنبه
۷/۶۹۰	۴/۱۳۴	۱۵/۳۲۸	۸/۲۳۹	۸/۷۳۰	۴/۶۹۲	چهارشنبه
۱۲/۴۷۴	۸/۰۳۸	۵۹/۳۸۵	۲۸/۲۰۴	۱۲/۸۷۱	۸/۲۹۴	پنجشنبه
۱۴/۲۲۵	۶/۶۲۶	۱۶/۰۴۱	۷/۴۷۱	۵/۲۹۸	۲/۴۶۷	جمعه
۶/۵۵۷	۲/۴۷۰	۱۴/۶۳۵	۵/۵۱۳	۵/۴۹۹	۲/۰۷۱	شنبه
۱۶/۰۵۱	۵/۰۱۹	۱۷/۱۷۷	۵/۳۷۱	۵/۱۹۴	۱/۶۲۴	یکشنبه
۱۰/۲۷۱	۴/۴۳۸	۲/۸۳۷	۱۰/۳۰۱	۷/۴۴۶	۳/۲۱۸	خطای هفته

جدول ۴: خطای پیش‌بینی برای فصل پاییز با در نظر گرفتن ابزارهای آنالیز سیگنال مختلف


EMD		DWT		EWT		تجزیه
MAPE	MAE	MAPE	MAE	MAPE	MAE	معیار خطا
۴/۵۸۲	۱/۱۹۶	۷/۸۵۰	۲/۰۴۹	۴/۶۴۸	۱/۲۱۳	دوشنبه
۴/۸۹۴	۱/۵۲۱	۸/۹۹۴	۲/۷۹۴	۲/۷۸۵	۰/۸۶۵	سه‌شنبه
۴/۶۲۳	۱/۴۲۸	۷/۱۰۲	۲/۱۹۴	۳/۴۴۸	۱/۰۶۵	چهارشنبه
۷/۳۱۹	۲/۳۵۹	۷/۳۶۲	۲/۳۷۳	۳/۵۲۲	۱/۱۳۵	پنجشنبه
۹/۵۴۷	۳/۰۴۷	۵/۶۹۷	۱/۸۱۸	۴/۷۷۸	۱/۵۲۵	جمعه
۶/۸۶۱	۲/۰۰۹	۶/۷۲۱	۱/۹۶۸	۳/۲۵۲	۰/۹۵۲	شنبه
۵/۲۰۱	۱/۵۱۵	۷/۰۵۱	۲/۰۵۳	۳/۶۹۳	۱/۰۷۶	یکشنبه
۶/۲۰۸	۱/۸۶۸	۷/۲۴۱	۲/۱۷۹	۳/۷۱۸	۱/۱۱۹	خطای هفته

نتایج شبیه‌سازی نشان می‌دهد که میانگین خطای MAE برای شبکه عصبی مصنوعی، ماشین یادگیری بی‌نهایت و رگرسیون بردار پشتیبان به ترتیب برابر با ۲/۳۶۸، ۲/۹۶۳ و ۸/۹۸ دلار بر مگاوات‌ساعت می‌باشد. همچنین مقدار میانگین خطای MAPE برای روش‌های ذکر شده فوق به ترتیب برابر با ۵/۶۹۳، ۷/۰۶۵ و ۱۹/۶۹۲ درصد می‌باشد.


که تعداد نرون‌های آن در هر لایه به ترتیب برابر با ۵۰، ۲۵ و ۱ می‌باشد. تابع محرک نیز در تمامی لایه‌ها برابر با سیگموئید لگاریتمی می‌باشد [۱۰]. در ماشین بردار بی‌نهایت نیز تعداد نرون‌ها با توجه به رابطه داده‌شده در مرجع [۳۲]، برابر با ۱۵ تعیین می‌گردد و تابع محرک آن نیز از نوع سیگموئید لگاریتمی می‌باشد. پارامترهای تنظیمی ماشین بردار پشتیبان یعنی C و ε به ترتیب برابر با ۱۰ و ۰/۰۰۰۱ و تابع کرنل نیز از نوع چندجمله‌ای درجه دوم می‌باشد.




الف) هفته سوم ماه آوریل



ب) هفته سوم از ماه آگوست



ج) هفته سوم از ماه نوامبر



د) هفته سوم از ماه فوریه

شکل ۴: قیمت واقعی و پیش‌بینی شده برای هفته‌های مربوط به فصول مختلف سال

جدول ۸: دقت پیش‌بینی برای فصل پاییز با در نظر گرفتن انواع ماشین‌های یادگیری

ELM		MLP		SVM		موتور پیش‌بینی
MAPE	MAE	MAPE	MAE	MAPE	MAE	معیار خطا
۱۴/۲۶۸	۳/۷۲۴	۶/۰۴۲	۱/۵۷۷	۴/۶۴۸	۱/۲۱۳	دوشنبه
۱۱/۶۲۱	۳/۶۱۰	۴/۴۱۴	۱/۳۷۱	۲/۷۸۵	۰/۸۶۵	سه‌شنبه
۱۰/۰۳۳	۳/۱۰۰	۳/۵۶۴	۱/۱۰۱	۳/۴۴۸	۱/۰۶۵	چهارشنبه
۱۱/۱۱۷	۳/۵۸۴	۴/۳۴۱	۱/۳۹۹	۳/۵۲۲	۱/۱۳۵	پنجشنبه
۷/۹۸۸	۲/۵۵۰	۴/۳۷۳	۱/۳۹۶	۴/۷۷۸	۱/۵۲۵	جمعه
۱۱/۲۵۸	۳/۲۹۶	۴/۳۲۶	۱/۲۶۷	۳/۲۵۲	۰/۹۵۲	شنبه
۱۱/۶۹۲	۳/۴۰۵	۴/۰۱۵	۱/۱۶۹	۳/۶۹۳	۱/۰۷۶	یکشنبه
۱۱/۰۴۸	۳/۲۲۴	۴/۴۰۶	۱/۲۶	۳/۷۱۸	۱/۱۱۹	خطای هفته

جدول ۹: دقت پیش‌بینی برای فصل زمستان با در نظر گرفتن انواع ماشین‌های یادگیری

ELM		MLP		SVM		موتور پیش‌بینی
MAPE	MAE	MAPE	MAE	MAPE	MAE	معیار خطا
۱۲/۹۷۵	۲/۸۳۵	۳/۹۳۳	۱/۱۶۸	۴/۵۲۷	۱/۳۴۴	دوشنبه
۸/۵۶۸	۲/۹۰۴	۴/۷۸۶	۱/۶۲	۲/۹۹۲	۱/۰۱۴	سه‌شنبه
۷/۸۳۸	۲/۵۷۹	۳/۱۳۲	۱/۰۳۱	۲/۴۸۷	۰/۸۱۸	چهارشنبه
۱۰/۹۵۸	۳/۷۳۷	۳/۶۰	۱/۲۵۹	۲/۹۳۷	۱/۰۰۲	پنجشنبه
۸/۴۵۸	۳/۱۹۸	۴/۱۷۱	۱/۵۷۷	۴/۵۳۱	۱/۷۱۳	جمعه
۷/۴۱۱	۲/۷۱۵	۳/۱۱۸	۱/۱۴۲	۳/۲۵۸	۱/۱۹۴	شنبه
۹/۵۷۸	۳/۳۹۹	۴/۷۱۶	۱/۶۷۴	۴/۱۶۸	۱/۴۷۹	یکشنبه
۹/۳۰۷	۳/۱۹۸	۳/۹۳۸	۱/۳۵۳	۳/۵۶۱	۱/۲۲۴	خطای هفته

۴-۲- بازار OMIE اسپانیا

بازار برق اسپانیا (OMIE) در سال ۱۹۹۸ ایجاد گردید که دارای قابلیت اتصال و تبادل انرژی به شبکه برق پرتغال و فرانسه می‌باشد. کل ظرفیت نصب‌شده در بخش تولید ۱۱۵ گیگاوات می‌باشد که ۴۷ درصد آن متعلق به انرژی‌های تجدیدپذیر، ۴۶ درصد مربوط به نیروگاه‌های سوخت فسیلی و ۷ درصد اختصاص به نیروگاه‌های اتمی دارد. حجم انرژی مبادله‌شده در سال ۲۰۱۵ حدود ۲۷۴ گیگاوات‌ساعت می‌باشد که از طریق ۱۰ شرکت تولیدی بزرگ تأمین شده است. در این بخش اطلاعات بازار اسپانیا در سال ۲۰۱۵ به‌عنوان داده‌های ورودی الگوریتم ارائه شده در نظر گرفته شده است [۴۰]. در این بازار به‌منظور بررسی تأثیر به‌کارگیری روش انتخاب ویژگی، مقادیر خطای پیش‌بینی برای یک هفته از فصول مختلف در دو حالت، با و بدون به‌کارگیری روش انتخاب ویژگی در جدول (۱۰) ارائه شده است. میزان متوسط خطای MAPE برای هفته‌های ذکرشده در جدول (۱۰) بدون انتخاب ویژگی‌های برتر ۱۱/۷۷ درصد می‌باشد در حالی که با حذف ویژگی‌های زائد، خطای پیش‌بینی به ۷/۸۸ درصد کاهش می‌یابد. نتایج شبیه‌سازی نشان می‌دهد که انتخاب ویژگی‌های برتر کمک زیادی به افزایش دقت پیش‌بینی می‌نماید. لذا در

به‌طور واضح مشاهده می‌گردد که رگرسیون بردار پشتیبان دارای کمترین خطا و بالاترین دقت پیش‌بینی می‌باشد.

جدول ۵: خطای پیش‌بینی برای فصل زمستان با در نظر گرفتن ابزارهای آنالیز سیگنال مختلف

EMD		DWT		EWT		تجزیه
MAPE	MAE	MAPE	MAE	MAPE	MAE	معیار خطا
۴/۱۳۰	۱/۲۲۶	۶/۷۵۴	۲/۰۰۶	۴/۵۲۷	۱/۳۴۴	دوشنبه
۴/۴۶۲	۱/۵۱۲	۴/۴۱۴	۱/۴۹۶	۲/۹۹۲	۱/۰۱۴	سه‌شنبه
۶/۷۵۵	۲/۲۲۳	۵/۲۷۱	۱/۷۳۴	۲/۴۸۷	۰/۸۱۸	چهارشنبه
۸/۲۶۶	۲/۸۱۹	۴/۴۶۱	۱/۵۲۱	۲/۹۳۷	۱/۰۰۲	پنجشنبه
۱/۸۶۶	۴/۴۸۷	۴/۸۷۰	۱/۸۴۱	۴/۵۳۱	۱/۷۱۳	جمعه
۷/۵۲۱	۲/۷۵۶	۶/۵۳۵	۲/۳۹۴	۳/۲۵۸	۱/۱۹۴	شنبه
۹/۷۰۲	۳/۴۴۳	۵/۴۷۱	۱/۹۴۲	۴/۱۶۸	۱/۴۷۹	یکشنبه
۷/۶۷۷	۲/۶۳۸	۵/۳۷۷	۱/۸۴۸	۳/۵۶۱	۱/۲۲۴	خطای هفته

جدول ۶: دقت پیش‌بینی برای فصل بهار با در نظر گرفتن انواع ماشین‌های یادگیری

ELM		MLP		SVM		موتور پیش‌بینی
MAPE	MAE	MAPE	MAE	MAPE	MAE	معیار خطا
۴۷/۴۵۰	۲۰/۷۹۵	۱۹/۶۲۶	۸/۶۰۱	۸/۴۲۸	۳/۶۹۴	دوشنبه
۲۰/۴۳۲	۱۵/۳۳۹	۸/۹۱۵	۶/۶۹۲	۱۰/۶۱۶	۷/۹۷۰	سه‌شنبه
۳۶/۹۱۸	۲۲/۰۳۴	۱۶/۹۱۴	۱۰/۰۹۵	۱۰/۸۱۷	۶/۴۵۶	چهارشنبه
۵۲/۱۳۴	۲۲/۴۴۱	۱۱/۸۱۱	۵/۰۸۴	۴/۵۳۷	۱/۹۵۳	پنجشنبه
۴۳/۸۵۱	۱۸/۸۳۳	۷/۵۰۳	۳/۲۲۲	۴/۷۴۳	۲/۰۳۷	جمعه
۳۸/۲۸۹	۱۵/۳۴۳	۹/۵۲۶	۳/۸۱۷	۷/۷۷۸	۳/۱۱۷	شنبه
۵۹/۴۳۲	۲۱/۱۶۶	۷/۳۹۵	۲/۶۳۴	۶/۰۶۹	۲/۱۶۱	یکشنبه
۳۹/۹۵۵	۱۹/۴۲۱	۱۱/۷۹۹	۵/۷۳۵	۸/۰۴۹	۳/۹۱۲	خطای هفته

جدول ۷: دقت پیش‌بینی برای فصل تابستان با در نظر گرفتن انواع ماشین‌های یادگیری

ELM		MLP		SVM		موتور پیش‌بینی
MAPE	MAE	MAPE	MAE	MAPE	MAE	معیار خطا
۲۹/۶۳۱	۷/۸۰۲	۵/۴۵۸	۱/۴۲۷	۵/۲۱۲	۱/۳۷۲	دوشنبه
۱۶/۳۳۳	۶/۹۲۸	۵/۱۶۵	۲/۱۹۲	۴/۷۱۴	۲/۰۰۱	سه‌شنبه
۱۸/۲۴۷	۹/۸۰۸	۵/۷۲۵	۳/۰۷۷	۸/۷۳۰	۴/۶۹۲	چهارشنبه
۱۷/۴۸۹	۱۱/۲۲۰	۱۲/۸۲۲	۸/۲۶۳	۱۲/۸۷۱	۸/۲۹۴	پنجشنبه
۱۹/۲۱۰	۸/۹۴۸	۱۱/۱۲۷	۵/۱۸۳	۵/۲۹۸	۲/۴۶۷	جمعه
۱۵/۲۵۰	۵/۷۴۵	۶/۰۴۱	۲/۲۷۶	۵/۴۹۹	۲/۰۷۱	شنبه
۱۷/۰۷۲	۵/۳۳۹	۶/۸۰۲	۲/۱۲۷	۵/۱۹۴	۱/۶۲۴	یکشنبه
۱۸/۴۶۰	۹/۹۷۷	۸/۱۱۸	۳/۵۰۸	۷/۴۴۶	۳/۲۱۸	خطای هفته

فرایند پیش‌بینی حذف داده‌های زائد می‌تواند باعث بهبود عملکرد پروسه پیش‌بینی گردد.

جدول ۱۰: تأثیر به‌کارگیری انتخاب ویژگی بر روی دقت پیش‌بینی (MAPE)

میانگین	زمان پیش‌بینی				نوع روش
	فوریه	نوامبر	آگوست	آوریل	
۷/۸۸	۷/۰۴	۵/۵۴	۱۰/۱۳	۸/۸۴	با انتخاب ویژگی
۱۱/۷۷	۱۱/۵۸	۱۰/۹۷	۱۱/۳۹	۱۳/۱۳	بدون انتخاب ویژگی

علاوه بر این، مقدار واقعی قیمت و مقدار پیش‌بینی و میزان خطا برای یک روز تعطیل و یک روز غیرتعطیل در جداول (۱۱) و (۱۲) ارائه شده است. همچنین نتایج برای روش آنالیز سیگنال با استفاده از تبدیل موجک به‌طور جداگانه نیز ارائه شده است [۲۷]. تحلیل نتایج به‌دست‌آمده نشان می‌دهد که معیار MAE برای روش تبدیل موجک برای روز تعطیل و غیرتعطیل به‌ترتیب برابر با ۱/۹۳۳ و ۰/۴۵۵ یورو بر مگاوات‌ساعت می‌باشد درحالی‌که برای روش تبدیل موجک تجربی این معیار برابر با ۱/۷۶۸ و ۰/۳۴۴ یورو بر مگاوات‌ساعت می‌باشد. لذا نوع روش آنالیز سیگنال می‌تواند بر روی دقت پیش‌بینی تأثیرگذار باشد.

جدول ۱۱: پیش‌بینی قیمت انرژی برای یک روز تعطیل در بازار OMIE

ساعت	مقدار واقعی قیمت (€/MWh)	مقدار پیش‌بینی شده			
		WT+ FS+SVR	EW+ FS+SVR	WT+ FS+SVR	EW+ FS+SVR
۱	۴۵/۵۶	۴۳/۲۴	۴۳/۷۴	۲/۳۲	۱/۸۲
۲	۴۳/۳۴	۴۳/۴۱	۴۰/۷۸	-۰/۰۷	۲/۵۶
۳	۴۰/۰۴	۳۹/۷۳	۴۰/۴۸	۰/۳۱	-۰/۴۴
۴	۳۷/۷۸	۳۷/۴۸	۳۸/۳۰	۰/۰۳	-۰/۵۲
۵	۳۶/۴۸	۳۶/۱۰	۳۸/۹۹	۰/۳۸	-۲/۵۱
۶	۳۶/۰۱	۳۵/۷۲	۳۵/۲۵	۰/۲۹	۰/۷۶
۷	۳۶/۸۳	۳۶/۶۳	۳۷/۷۰	۰/۲۰	-۰/۸۷
۸	۳۸/۰۲	۳۹/۷۷	۴۰/۳۹	-۱/۷۵	-۲/۳۷
۹	۴۰/۳۸	۴۲/۴۷	۳۹/۲۱	-۲/۰۹	۱/۱۷
۱۰	۴۳/۰۰	۴۳/۷۶	۴۱/۷۵	-۰/۷۶	۱/۲۵
۱۱	۴۱/۰۰	۴۲/۲۳	۴۱/۲۷	-۱/۲۳	-۰/۲۷
۱۲	۳۷/۵۵	۴۰/۲۷	۴۰/۱۹	-۲/۷۲	-۲/۶۴
۱۳	۳۸/۰۲	۳۹/۵۳	۴۰/۴۲	-۱/۵۱	-۲/۴۰
۱۴	۳۹/۳۰	۳۷/۷۲	۳۹/۴۷	۱/۵۸	-۰/۱۷
۱۵	۳۷/۷۷	۳۵/۷۰	۳۸/۲۹	۲/۰۷	-۰/۵۲
۱۶	۳۶/۵۰	۳۳/۴۲	۳۶/۹۸	۳/۰۸	-۰/۴۸
۱۷	۳۲/۷۵	۳۴/۱۶	۳۸/۱۲	-۱/۴۱	-۵/۳۷
۱۸	۳۲/۸۵	۳۵/۱۲	۳۷/۱۴	-۲/۲۷	-۴/۲۹
۱۹	۳۶/۸۸	۳۶/۲۰	۳۶/۸۵	۰/۶۸	۰/۰۳
۲۰	۴۱/۱۹	۳۹/۴۲	۴۰/۱۱	۱/۷۷	۱/۰۸
۲۱	۴۶/۱۹	۴۳/۴۰	۴۰/۲۵	۲/۷۹	۵/۹۴
۲۲	۴۸/۰	۴۳/۲۸	۴۷/۸۷	۴/۷۲	۰/۱۳
۲۳	۴۵/۶۸	۴۰/۴۲	۴۳/۹۹	۵/۲۶	۱/۶۹
۲۴	۴۴/۶۹	۸۶۳۷	۴۱/۵۲	۶/۸۳	۳/۱۷

جدول ۱۲: پیش‌بینی قیمت انرژی برای یک روز غیرتعطیل در بازار OMIE

ساعت	مقدار واقعی قیمت (€/MWh)	مقدار پیش‌بینی شده			
		WT+ FS+SVR	EW+ FS+SVR	WT+ FS+SVR	EW+ FS+SVR
۱	۳۸/۷۴	۴۰/۸۱	۴۱/۵۲	-۲/۰۷	-۲/۷۸
۲	۳۶/۰۰	۳۶/۰۸	۳۷/۰۶	-۰/۰۸	-۱/۰۶
۳	۳۳/۰۹	۳۳/۴۱	۳۴/۹۷	-۰/۳۲	-۱/۸۸
۴	۳۳۲/۶۰	۳۱/۳۸	۳۲/۴۴	۱/۲۲	۰/۱۶
۵	۳۲/۲۰	۳۰/۹۹	۳۴/۲۱	۱/۲۱	-۲/۰۱
۶	۳۲/۳۵	۳۱/۶۵	۳۵/۷۶	۰/۰۷	-۳/۴۱
۷	۳۶/۶۳	۳۳/۴۵	۳۶/۵۲	۳/۱۸	۰/۱۱
۸	۴۲/۳۱	۳۸/۳۸	۳۹/۷۸	۳/۹۳	۲/۵۳
۹	۴۴/۶۰	۴۱/۱۰	۳۸/۵۳	۳/۵۰	۱/۰۷
۱۰	۴۴/۶۹	۴۰/۷۲	۴۵/۹۴	۳/۹۷	-۱/۲۵
۱۱	۴۳/۹۵	۳۸/۹۱	۴۴/۴۴	۵/۰۴	-۰/۴۹
۱۲	۴۳/۹۷	۳۹/۲۲	۴۴/۱۲	۴/۷۵	-۰/۱۵
۱۳	۴۵/۵۶	۳۹/۶۵	۴۴/۷۴	۵/۹۱	۰/۸۲
۱۴	۴۶/۱۰	۳۹/۸۵	۴۴/۹۷	۶/۲۵	۱/۱۳
۱۵	۴۵/۵۶	۳۹/۳۴	۴۴/۸۳	۶/۲۲	۰/۷۳
۱۶	۴۵/۰۰	۳۸/۷۸	۴۳/۸۲	۶/۲۲	۱/۱۸
۱۷	۱۹۴۵	۳۸/۹۷	۴۲/۴۵	۶/۲۲	۲/۷۴
۱۸	۴۵/۴۷	۴۰/۲۷	۴۴/۳۰	۵/۲۰	۱/۱۷
۱۹	۴۵/۱۹	۴۲/۷۸	۴۶/۳۷	۲/۴۱	-۱/۱۸
۲۰	۴۶/۵۹	۴۷/۴۱	۴۸/۲۸	-۰/۸۲	-۱/۶۹
۲۱	۴۷/۳۶	۵۰/۲۳	۴۸/۲۱	-۲/۸۷	-۰/۸۵
۲۲	۴۸/۰۳	۵۰/۵۴	۴۸/۲۰	-۲/۵۱	-۰/۱۷
۲۳	۴۳/۹۴	۴۷/۸۲	۴۴/۴۱	-۳/۸۸	-۰/۴۷
۲۴	۴۰/۵۰	۴۵/۳۰	۴۱/۶۸	-۴/۴۸۰	-۱/۱۸

۴-۳- بررسی مقایسه‌ای نتایج

به‌منظور مقایسه الگوریتم ارائه‌شده با برخی از روش‌های هوشمند در زمینه پیش‌بینی قیمت، در جدول (۱۳) دقت نتایج گزارش شده در مقالات مختلف ارائه شده است. همان‌طور که مشاهده می‌شود در بسیاری از روش‌های ارائه‌شده از آنالیز سیگنال در مرحله پیش‌پردازش استفاده نشده است [۱۵-۱۳، ۱۸، ۱۹، ۲۴] که موجب می‌شود دقت پیش‌بینی آن‌ها کمتر از دقت به‌دست‌آمده در روش پیشنهادی در این مقاله گردد. در مرجع [۲۶] یک روش هوشمند مشابه روش پیشنهادی در این مقاله ارائه شده است با این تفاوت که در آن از تبدیل موجک استاندارد در آنالیز سیگنال استفاده شده است. نتایج گزارش شده نشان می‌دهد که خطای MAE و MAPE به‌ترتیب برابر با ۴/۴ €/MWh و ۶/۲۴٪ می‌باشد که از مقدار خطای روش ارائه‌شده در این مقاله (تبدیل موجک تجربی) یعنی ۲/۳۶ \$/MWh و ۵/۶۹۳٪ بیشتر می‌باشد. این امر وابستگی دقت پیش‌بینی به روش آنالیز سیگنال سری زمانی قیمت را نشان می‌دهد. همچنین نتایج به‌دست‌آمده نشان می‌دهد که به‌کارگیری روش‌های

مراجع

- [1] M. Shahidehpour, H. Yamin, Z. Li, *Market operations in electric power systems*, John Wiley & Sons, Inc., Publication, 2002.
- [۲] مریم رضانیان لنگرودی، سیدمازیار میرحسینی مقدم، بهنام علیزاده، «استفاده از روش یادگیری رقابتی برای قیمت‌دهی استراتژیک شرکت‌های تولید بر اساس LMP در بازار برق»، مجله مهندسی برق دانشگاه تبریز، دوره ۴۷، شماره ۲، صفحه ۵۳۷-۵۴۹، تابستان ۹۶.
- [3] R. Weron, "Electricity Price forecasting: A review of the state-of-the-art with a look into the future," *International Journal of Forecasting*, vol. 30, no. 4, pp. 1030-1081, Oct-Dec 2014.
- [4] R. Huismana, C. Huurmana, R. Mahieua, "Hourly electricity prices in day-ahead markets. *Energy Economics*," vol. 29, no. 2, pp. 240-248, March 2007.
- [5] C. P. Rodriguez, G. J. Anders, "Energy price forecasting in the Ontario competitive power system market," *IEEE Transactions on Power Systems*, vol. 19, no. 1, pp. 366-374, Feb. 2004.
- [6] G. Li, C. C. Liu, C. Mattson, J. Lawarree, "Day-ahead electricity price forecasting in a grid environment," *IEEE Transactions on Power Systems*, vol. 22, no. 1, pp. 266-274, Feb. 2007.
- [7] M. F. Anaghi, Y. Norouzi, "A model for stock price forecasting based on ARMA systems," 2nd International Conference on Advances in Computational Tools for Engineering Applications (ACTEA), 2012, 12-15 Dec, Beirut, Lebanon, 2012.
- [8] J. Contreras, R. Espinola, F. J. Nogales, A. J. Conejo, "Arma models to predict next day electricity prices," *IEEE Transactions on Power Systems*, vol. 22, no. 9, pp. 1017-1020, Sep. 2003.
- [9] H. Liu, J. Shi, "Applying ARMA-GARCH approaches to forecasting short-term electricity prices," *Energy Economics*, vol. 37, pp. 152-166, May 2013.
- [10] P. I. Panapakidis, A. S. Dagoumas, "Day-ahead electricity price forecasting via the application of artificial neural network based models," *Applied Energy*, vol. 172, pp. 132-151, 15 June 2016.
- [11] Y. Y Hong and C. P Wu, "Day-ahead electricity price forecasting using a hybrid principal component analysis network," *Energies*, vol. 5, no. 11, pp. 4711-4725, 2012.
- [12] D. Singhal, K. S. Swarup, "Electricity price forecasting using artificial neural network," *International Journal of Electrical Power & Energy Systems*, vol. 33, no. 3, pp. 550-555, March 2011.
- [13] N. Amjady, M. Hemmati, "Day-ahead price forecasting of electricity markets by a hybrid intelligent system," *International Transactions on Electrical Energy Systems*, vol. 19, no. 1, pp. 89-102, 2009.
- [14] V. Vahidinasb, S. Jadid, A. Kazemi, "Day-ahead price forecasting in restructured power systems using artificial neural networks," *Electric Power System Research*, vol. 78, no. 8, pp. 1332-1342, 2008.
- [15] N. Amjady, A. Daraeepour, F. Keynia, "Day-ahead electricity price forecasting by modified relief algorithm and hybrid neural network," *IET, Generation Transmission and Distribution*, vol. 4, no. 3, pp. 432-444, 2010.
- [16] S. Anbazhagan, N. Kumarappan, "Day-ahead deregulated electricity market price forecasting using neural network input featured by DCT," *Energy Conversion and Management*, vol. 78, pp. 711-719, 2014.

انتخاب ویژگی مبتنی بر آنالیز همبستگی [۱۴، ۱۶، ۱۸، ۲۴] و Relief [۱۵] بر روی بهبود دقت نتایج تأثیرگذار است. جدول (۱۳) نشان می‌دهد که خطای MAPE برای دو روش انتخاب ویژگی ذکر شده فوق به ترتیب در حدود ۶/۵٪ و ۹/۲۳٪ می‌باشد اما نتایج به دست آمده نشان‌دهنده برتری روش انتخاب ویژگی مبتنی بر اطلاعات متقابل است به طوری که خطای MAPE گزارش شده در مرجع [۲۶] و روش ارائه شده در این مقاله به ترتیب برابر با ۶/۲۴٪ و ۵/۶۹٪ می‌باشد.

جدول ۱۳: مقایسه دقت نتایج به دست آمده با برخی از روش‌های هوشمند ارائه شده

مرجع	الگوریتم پیش‌بینی			دقت پیش‌بینی MAPE (%)
	روش آنالیز سیگنال	روش انتخاب ویژگی	روش شناسایی الگو	
[۱۳]	-	-	شبکه عصبی	۸/۲۹
[۱۴]	-	آنالیز همبستگی	شبکه عصبی	۶/۴۲
[۱۵]	-	Relief	شبکه عصبی	۹/۲۳
[۱۶]	تبدیل فوری	آنالیز همبستگی	شبکه عصبی	۶/۳۲
[۱۸]	-	آنالیز همبستگی	شبکه عصبی بازگشتی	۶/۵۵
[۱۹]	-	-	شبکه فازی عصبی	۷/۵
[۲۴]	-	آنالیز همبستگی	شبکه عصبی مبتنی بر تبدیل موجک	۶/۸۳
[۲۶]	تبدیل موجک استاندارد	اطلاعات متقابل	ماشین بردار پشتیبان	۶/۲۴
روش ارائه شده	تبدیل موجک تجربی	اطلاعات متقابل	ماشین بردار پشتیبان	۵/۶۹

۵- نتیجه‌گیری

در این مقاله یک روش ترکیبی هوشمند مبتنی بر انتخاب ویژگی جهت پیش‌بینی قیمت انرژی الکتریکی در ۲۴ ساعت آینده ارائه شده است. ارزیابی عملکرد الگوریتم ارائه شده نشان می‌دهد که دقت پیش‌بینی با در نظر گرفتن معیار MAPE برای دو بازار برق OMIE و PJM به ترتیب برابر با ۵/۶۹۳ و ۷/۸۸ درصد می‌باشد. همچنین تأثیر نوع ابزار رگرسیون بر روی دقت پیش‌بینی به طور جداگانه مورد بررسی قرار گرفته است. نتایج شبیه‌سازی نشان می‌دهد که رگرسیون بردار پشتیبان دارای عملکرد بهتری نسبت به شبکه عصبی مصنوعی و ماشین یادگیری بی‌نهایت می‌باشد. علاوه بر این نتایج به دست آمده در بازار اسپانیا نشان می‌دهد که انتخاب ویژگی‌های برتر می‌تواند در افزایش دقت پیش‌بینی تأثیر چشمگیری داشته باشد به طوری که با حذف ویژگی‌های زائد، شاخص ارزیابی MAPE به میزان ۳/۸۹ درصد کاهش می‌یابد. به منظور ادامه کار می‌توان تأثیر دیگر پارامترهای مؤثر بر روی نتایج پیش‌بینی قیمت را بررسی نمود.

- [۲۸] حسین شایقی، علی قاسمی، «پیش‌بینی قیمت روزانه برق با شبکه عصبی بهبودیافته مبتنی بر تبدیل موجک و روش آشوبناک جستجوی گرانشی»، مجله مهندسی برق دانشگاه تبریز، دوره ۴۵، شماره ۴، صفحه ۱۰۵-۱۱۷، زمستان ۹۴.
- [29] L. Xiao, W. Shao, M. Yu, J. Ma, C. Jin, "Research and application of a hybrid wavelet neural network model with the improved cuckoo search algorithm for electrical power system forecasting," *Applied Energy*, vol. 198, pp. 230-222, July 2017.
- [30] N. A. Shrivastava, B. K. Panigrahi, "A hybrid wavelet-ELM based short term price forecasting for electricity markets," *International Journal of Electrical Power & Energy Systems*, vol. 55, pp. 41-50, Feb. 2014.
- [31] N. Singh, S. R. Mohanty, R. D. Shukla, "Short term electricity price forecast based on environmentally adapted generalized neuron," *Energy*, vol. 125, pp. 127-139, April 2017.
- [32] Z. Yang, L. Ce, L. Lian, "Electricity price forecasting by a hybrid model, combining wavelet transform, ARMA and kernel-based extreme learning machine methods," *Applied Energy*, vol. 190, pp. 291-305, March 2017.
- [33] X. Qiu, P. N. Suganthan, G. A. J. Amaratunga, "Short-term electricity price forecasting with empirical mode decomposition based ensemble kernel machines," *Procedia Computer Science*, vol. 108, pp. 1308-1317, 2017.
- [34] D. Wang, H. Luo, O. Grunder, Y. Lin, H. Guo, "Multi-step ahead electricity price forecasting using a hybrid model based on two-layer decomposition technique and BP neural network optimized by firefly algorithm," *Applied Energy*, vol. 190, pp. 390-407, March 2017.
- [35] J. Gilles, "Empirical wavelet transform," *IEEE Transactions on Signal Processing*, vol. 61, no. 16, pp. 3999-4010, Aug. 2013.
- [36] N. Kwak, C. Choi, "Input feature selection for classification problems," *IEEE Transactions Neural Network*, vol. 13, no.1, pp. 143-159, 2002.
- [37] C. Cortes, V. Vapnik, "Support vector networks," *Machine Learning*, vol. 20, no. 3, pp. 273-297, Sep. 1995.
- [38] L. Wang, "Support Vector Machines: Theory and Applications," Springer, 2005.
- [39] PJM Web Site <http://www.pjm.com>, May 2017.
- [40] OMIE website <http://www.omie.es/en/home/information-company>, May 2017.
- [17] W. M. Lin, H. J. Gow, M. T. Tsai, "An enhanced radial basis function network for short-term electricity price forecasting," *Applied Energy*, vol. 87, no. 10, pp. 3226-3234, Oct. 2010.
- [18] S. Anbazhagan, N. Kumarappan, "Day-ahead deregulated electricity market price forecasting using recurrent neural network," *IEEE Systems Journal*, vol. 7, no. 4, pp. 866-872, 2013.
- [19] N. Amjady. "Day-ahead price forecasting of electricity markets by a new fuzzy neural network," *IEEE Transactions on Power Systems*, vol. 21, no. 2, pp. 887-896, 2006.
- [20] Y. Y. Hong, C. F. Lee, "A neuro-fuzzy price forecasting approach in deregulated electricity markets," *Electric Power Systems Research*, vol. 73, no. 2, pp. 151-157, Feb. 2005.
- [21] H. Mori, K. Nakano, "An Efficient Hybrid Intelligent Method, for Electricity Price Forecasting," *Procedia Computer Science*, vol. 95, pp. 287-296, 2016.
- [22] H. M. I. Pousinho, V. M. F. Mendes, J. P. S. Catalao, "Short-term electricity prices forecasting in a competitive market by a hybrid PSO-ANFIS approach," *International Journal of Electrical Power & Energy Systems*, vol. 39, no. 1, pp. 29-35, July 2012.
- [23] J. P. S. Catalao, H. M. I. Pousinho, V. M. F. Mendes, "Short-term electricity prices forecasting in a competitive market by a hybrid intelligent approach," *Energy Conversion and Management*, vol. 52, no. 2, pp. 1061-1065, Feb. 2011.
- [24] N. M. Pindoriya, S. N. Singh, S. K. Singh, "An adaptive wavelet neural network-based energy price forecasting in electricity markets," *IEEE Transactions on Power Systems*, vol. 23, no.3, pp. 1423-1432, 2008.
- [25] F. Feijoo, W. Silva, T. K. Das, "A computationally efficient electricity price forecasting model for real time energy markets," *Energy Conversion and Management*, vol. 113, pp. 27-35, April 2016.
- [26] H. Shayeghi, A. Ghasemi, "Day-ahead electricity prices forecasting by a modified CGSA technique and hybrid WT in LSSVM based scheme," *Energy Conversion and Management*, vol. 74, pp. 482-491, 2013.
- [27] J. Zhang, Z. Tan, "Day-ahead electricity price forecasting using WT, CLSSVM and EGARCH model," *International Journal of Electrical Power & Energy Systems*, vol. 45, no. 1, pp. 362-368, Feb. 2013.

زیر نویس ها

Empirical Mode Decomposition (EMD) ^۱	Locational Marginal Price (LMP) ^۱
Variational Mode Decomposition (VMD) ^{۱۱}	Auto-Regressive ^۲
Principle Component Analysis (PCA) ^{۱۱}	Dynamic Regression ^۲
Empirical Wavelet Transform (EWT) ^{۱۱}	Transfer Function ^۳
Mutual Information (MI) ^{۱۲}	Auto-Regressive Moving Average (ARMA) ^۳
Mean Absolute Error (MAE) ^{۱۳}	Auto-Regressive Integrated Moving Average (ARIMA) ^۳
Mean Absolute Percentage Error (MAPE) ^{۱۳}	Generalized Auto-Regressive Conditional Heteroskedasticity ^۴
Daubechies ^{۱۱}	(GARCH)
	Wavelet Transform (WT) ^۴