

Day-ahead Electricity Price Forecasting by a New Hybrid Algorithm based on ELM, Curvelet Transform, Preprocessing System, and Modified VCS Algorithm

Mahdi Noshyar¹, Ali Ghasemi-Marzbali²

¹ Associate professor, Department of Electrical Engineering, University of Mohaghegh Ardabili, Ardabil, Iran

² Assistant professor, Department of Computer and Electrical Engineering, Mazandaran University of Science and Technology, Babol, Iran

Abstract:

Given that the price signal in the electricity market is highly volatile or otherwise uncertain, short-term forecasting is significantly affected. Since time-series methods cannot estimate such nonlinear models appropriately with high accuracy, we need to provide an efficient model. For this reason, in this paper, a new hybrid algorithm for day-ahead electricity price forecasting is proposed. In order to achieve this model, we first divide the forecasting problem into three main layers: preprocessor, training, and regulator. In the first layer, we use the curvelet transform to reduce possible noise in the price signal. Then, using the extended data selection model based on increasing correlation and decreasing redundancy, we eliminate the unnecessary data and reduce the volume of computation significantly. Then the regularized data is entered into the learning layer which is a developed Extreme Learning Machine (ELM) to obtain and extract the best pattern from the input data. Since adjusting the control parameters of the proposed ELM can maximize its ability to derive a nonlinear pattern from the price signal, a new developed Virus Colony Search (VCS) method based on the time-varying coefficients theory is proposed in the last layer. The proposed algorithm is a novel optimization method based on the function of viruses to destroy host cells and penetrate the best ones into a cell for replication. The proposed method is applied to existing real electricity markets and the results are compared based on prediction error rates and error-based criteria. The obtained results show the appropriate and acceptable performance of the proposed forecasting method.

Keywords: Hybrid Forecasting Method, Extreme Learning Machine, Curvelet Transform, Entropy, Virus Colony.

پیش‌بینی روزانه قیمت برق با روش مبتنی بر ماشین یادگیری شدید، سیستم پیش‌پردازش‌کننده و

الگوریتم بهبودیافته کلونی جستجوی ویروس

مهدی نوشیار^۱، علی قاسمی مرزبالی^۲

۱- دانشیار، دانشکده مهندسی برق و کامپیوتر - دانشگاه محقق اردبیلی - اردبیل - ایران

nooshyar@uma.ac.ir

۲- استادیار، دانشکده مهندسی برق و کامپیوتر - دانشگاه علوم و فنون مازندران - بابل - ایران

ali.ghasemi@ustmb.ac.ir

چکیده: نظر به اینکه سیگنال قیمت در بازار برق، نوسانات زیاد و عدم قطعیت فراوانی دارد، بر پیش‌بینی کوتاه‌مدت تأثیر زیادی می‌گذارد. با توجه به اینکه روش‌های مبتنی بر سری زمانی نمی‌توانند مدل‌های غیرخطی این‌چنینی را به‌صورت مناسب با دقت بالا تخمین بزنند، به ارائه مدل کارا نیاز است؛ به همین دلیل در این مقاله روش ترکیبی جدید چندمرحله‌ای برای پیش‌بینی روزانه قیمت برق پیشنهاد شده است. به‌منظور دستیابی به این الگو، ابتدا پیش‌بینی به سه لایه اصلی، پیش‌پردازش‌کننده، آموزش و تنظیم‌کننده تقسیم شده است. در لایه اول از تبدیل کرولت برای کاهش نویزهای احتمالی در سیگنال قیمت استفاده شده است. سپس با استفاده از مدل توسعه‌یافته انتخاب داده بر مبنای افزایش همبستگی و کاهش تکرار، داده‌های غیرمفید را حذف و حجم محاسبات را به‌صورت چشمگیری کاهش داده است. سپس داده‌های منظم‌شده وارد لایه یادگیری شده که به‌منظور دستیابی و استخراج بهترین الگو از داده‌های ورودی، ماشین یادگیری شدید توسعه‌یافته پیشنهاد شده است. با توجه به اینکه تنظیم پارامترهای کنترلی ماشین یادگیری پیشنهادی می‌تواند به حداکثر قابلیت آن در استخراج الگو غیرخطی از سیگنال قیمت منجر شود، در لایه آخر روش توسعه‌یافته جدیدی مبتنی بر کلونی جستجوی ویروس بر مبنای تئوری ضرایب متغیر زمانی پیشنهاد شده است. الگوریتم پیشنهادی، روش بهینه‌سازی جدید براساس عملکرد ویروس‌ها برای نابودی سلول‌های میزبان و نفوذ بهترین آن‌ها به داخل یک سلول برای تکثیر است. روش پیشنهادی بر بازارهای برق واقعی موجود، اعمال و نتایج به‌دست‌آمده براساس میزان خطای پیش‌بینی و معیارهای مبتنی بر خطا مقایسه شده‌اند. نتایج نشان می‌دهند روش پیشنهادی، کارایی مناسب و پذیرفتنی دارد.

واژه‌های کلیدی: روش ترکیبی پیش‌بینی، ماشین یادگیری شدید، تبدیل کرولت، آنتروپی، کلونی جستجوی ویروس

۱- مقدمه

برای پژوهشگران تبدیل کرده است [۱]. به عبارتی دیگر، با گسترش روزافزون دستگاه‌های الکتریکی، انگیزه استفاده بهینه از منابع، رقابت‌های اقتصادی و محدودیت‌های محیطی گرایش به بازار چندقطبی توسعه یافت و نیاز به آن سبب تشویق شرکت‌ها و بنگاه‌های اقتصادی به‌منظور سرمایه‌گذاری و مشارکت در صنعت برق شده است. این ساختار جدید سیستم قدرت، مفاهیم قدیمی را به چالش کشانده است. برای تضمین دسترسی آزاد فروشندگان و خریداران به سیستم انتقال، بهره‌برداری از سیستم انتقال

با توجه به اینکه قیمت، یکی از مهم‌ترین عوامل تعیین‌کننده در سوددهی است، پیش‌بینی قیمت را به چالشی

^۱ تاریخ ارسال مقاله: ۱۳۹۸/۰۲/۰۴

تاریخ پذیرش مقاله: ۱۳۹۸/۰۴/۲۴

نام نویسنده مسئول: مهدی نوشیار

نشانی نویسنده مسئول: ایران - اردبیل - خیابان دانشگاه - دانشگاه محقق اردبیلی - دانشکده مهندسی برق و کامپیوتر

پیش‌بینی روزانه قیمت برق با روش مبتنی بر ماشین یادگیری شدید، سیستم پیش‌پردازش‌کننده و ...

گرفته است که شامل شبکه عصبی فازی بهبودیافته الگوریتم اجتماع ذرات است. در [۱۲] روش‌های جدیدی برای پیش‌بینی بار و قیمت انرژی الکتریکی پیشنهاد شده‌اند. به‌طور کلی پیش‌بینی در سه مرحله پیش‌پردازش، انتخاب داده‌های مؤثر و پیش‌بینی انجام می‌گیرد. تبدیل موجک، یکسان‌سازی داده‌ها و جابه‌جا کردن نمونه‌های آموزش برای پیش‌پردازش و آماده‌سازی داده‌ها استفاده شده‌اند. در مرجع [۱۳] مدلی هوشمند برای پیش‌بینی قیمت تسویه بازار با استفاده از شبکه عصبی مصنوعی پرسپترون چند لایه، بر پایه مدل هیبریدی ژنتیک و رقابت استعماری ارائه شده است.

در مرجع [۱۴] روشی ترکیبی برای ایجاد فواصل پیش‌بینی قیمت‌های تسویه بازار با فرمول‌بندی دو مرحله‌ای پیشنهاد شده است. در گام نخست، پیش‌بینی‌های نقطه‌ای و عدم قطعیت‌های موجود در مدل ارائه می‌شوند که در آن از روش‌های پیش‌پردازش داده‌ها، الگوریتم آموزشی جدید شبکه‌های عصبی، یعنی ماشین یادگیری مفرط، روش خود راه‌اندازی و ساختاری مجتمع استفاده شده است. در مرحله دوم، ابتدا با استفاده از برآورد حداکثر احتمال و روش کاهش شیب سنتی، واریانس نویز برآورد می‌شود، سپس برای بهبود نتایج آن، از الگوریتم بهینه‌سازی ازدحام ذرات برای بهینه‌سازی تابع هدف مبتنی بر فاصله پیش‌بینی استفاده می‌شود. در تکمیل استفاده از تبدیل موجک و سیستم پیش‌پردازش‌کننده در [۱۵] از روش ترکیبی تبدیل موجک و شبکه عصبی آموزش‌دیده با الگوریتم خفاش استفاده شده است. در مرجع [۱۶] با روش ترکیبی مبتنی بر فیلتر داده‌های ورودی و تأثیر فصل‌ها و روش سری زمانی، قیمت را پیش‌بینی کرده است. در مرجع [۱۷] با روش کوچک‌ترین مربعات بردار پشتیبان و ARIMA قیمت را پیش‌بینی کرده است.

در این مقاله با انگیزه دستیابی به کمترین خطای پیش‌بینی و برطرف کردن نواقص روش‌های قبلی از جمله خطی‌سازی و عدم پیروی با دقت مناسب از الگوی غیرخطی، عدم استخراج داده‌های بارزش، افزایش حجم محاسبات با افزایش تعداد داده‌های ورودی و غیره، روشی ترکیبی مبتنی بر بخش پیش‌پردازش‌کننده، یادگیری و الگوریتم تنظیم‌کننده کلونی جستجوی ویروس [۱۹] پیشنهاد

مستلزم مستقل بودن بخش مدیریتی از سهام بازار است [۲]. از میان انواع انرژی‌ها در جهان، انرژی الکتریکی خصوصیات منحصر به فرد دارد؛ از جمله: الف) این انرژی به‌صورت وسیع ذخیره‌سازی نمی‌شود؛ ب) بازده سرمایه‌گذاری در رابطه با انرژی الکتریکی زمان‌بر است. موارد یاد شده نشان‌دهنده اهمیت برنامه‌ریزی درازمدت و جامع تولید انرژی الکتریکی‌اند [۳]. برای پیش‌بینی قیمت برق در بازار برق روش‌های مختلفی وجود دارند که این روش‌ها، در ظاهر متفاوت ولی در اساس عملکرد یکسانی دارند.

این روش‌ها در دو دسته روش‌های مبتنی بر سری‌های زمانی و روش‌های یادگیری یا هوش مصنوعی دسته‌بندی می‌شوند. به‌منظور کوتاه‌کردن معرفی روش‌های کلاسیک، در مراجع [۴-۵] مروری جامع بر روش‌های کلاسیک شامل روش میانگین‌گیری وزن‌دار متغیر، رگرسیون خطی، مدل تابع تبدیل، فیلتر kalman، مدل فضایی حالت و تکنیک‌های توالی زمان ارائه شده است. در مدل‌های کلاسیک ارائه شده در مسئله پیش‌بینی قیمت یا بار در بازار برق با تنوع تعداد متغیرهای ورودی و پیروی نکردن متغیرها از مدل سری مشخص، خطای ناشی از پیش‌بینی افزایش خواهد یافت؛ به همین دلیل از روش‌های مبتنی بر هوش مصنوعی و ترکیبی استفاده می‌شود. در این دسته به موارد زیر اشاره می‌شود. در مرجع [۶] مسئله فصلی بودن روزانه و هفتگی قیمت برق در پیش‌بینی قیمت برق با در نظر گرفتن شبکه عصبی غیرخطی با ورودی‌های مشابه پیشنهاد شده است. در مرجع [۷] مدل جدیدی براساس شبکه بردار پشتیبان و الگوریتم جستجوی فاخته برای پیش‌بینی قیمت ارائه شده است. در مرجع [۸] از مدل سری زمانی و شبکه عصبی که از ترکیب دو سیستم خطی و غیرخطی به دست آمده است، سعی در ایجاد رابطه‌ای مناسب بین داده‌های ورودی برای کاهش خطای پیش‌بینی انجام گرفته است. به‌منظور افزایش قابلیت یادگیری شبکه عصبی در مرجع [۹] از روش ترکیبی فازی-عصبی استفاده شده است. در [۱۰] از روش پانل هم‌انباشتگی و فیلتر ذرات برای پیش‌بینی قیمت روز بعد بهره گرفته شده است. در [۱۱] پیش‌بینی کوتاه‌مدت قیمت در بازارهای مختلف برق، با ارائه دو مدل پیشنهادی صورت

$$C^{D,O}(j,l,k) = \frac{1}{n^2} \sum_{n_1, n_2 \in R_{j,l}} \{ \hat{f}[n_1, n_2] U_{j,l}^{0}[n_1, n_2] e^{2\pi i (\frac{k_1 n_1}{R_{1,j}} + \frac{k_2 n_2}{R_{2,j}})} \} \quad (1)$$

که اندیس های D و O به ترتیب معرف دیجیتال و بیش نمونه برداری اند. اندیس های j و l به ترتیب نشان دهنده ناحیه تقسیم، زاویه و مقیاس کرولت مادرند. n_1 و n_2 تعداد نمونه ها در هر گوشه در فضای مورد مطالعه اند. n تعداد کل نمونه ها است. $U_{j,l}^0$ نشان دهنده حد بالایی نمونه برداری است. $R_{j,l}$ یک شکل چهار گوشه با ابعاد $R_{1,j} \times R_{2,j}$ و شامل متوازی اضلاع $P_{j,l}$ است. اگر فرض شود $R_{1,j}$ و $R_{2,j}$ تقسیم کننده یک سیگنال با اندازه n باشند، آنگاه ضرایب $C^{D,O}(j,l,k)$ به کمک کانولوشن گسسته از کرولت و سیگنال $f(t_1, t_2)$ به دست می آیند. در روش wrapping $R_{1,j}$ و $R_{2,j}$ با ضرایب $L_{1,j}$ و $L_{2,j}$ از متوازی اضلاع $P_{j,l}$ جایگزین می شوند. براساس این توضیحات نمونه ها به صورت زیر بیان می شوند:

$$n'_1 = n_1 + m_1 L_{1,j} \quad (2)$$

$$n'_2 = n_2 + m_2 L_{2,j} \quad (3)$$

m_1 و m_2 تعداد تقسیمات ایجاد شده در هر نمونه اند که براساس تبدیل معکوس با آرایه های warpping هستند:

$$C^D(j,l,k) = \frac{1}{n^2} \sum_{n_1=0}^{L_{1,j}-1} \sum_{n_2=0}^{L_{2,j}-1} \{ W(U_{j,l}^0, \hat{f}) [n_1, n_2] e^{2\pi i (\frac{k_1 n_1}{L_{1,j}} + \frac{k_2 n_2}{L_{2,j}})} \} \quad (4)$$

که $W(U_{j,l}^0, \hat{f})$ تابعی کرنل برحسب تخمین حد بالایی است. با توجه به اینکه با تغییر علامت گذاری روش wrapping تأثیری روی ضرایب آن نخواهد داشت، با بازنویسی فرمول یاد شده خواهیم داشت:

$$C^D(j,l,k) = \frac{1}{n^2} \sum_{n_1=-\frac{n}{2}}^{\frac{n}{2}-1} \sum_{n_2=0}^{\frac{n}{2}-1} \{ U_{j,l}^0 [n_1, n_2] \hat{f}[n_1, n_2] e^{2\pi i (\frac{k_1 n_1}{L_{1,j}} + \frac{k_2 n_2}{L_{2,j}})} \} \quad (5)$$

شده است. در بخش نخست، از تبدیل کرولت برای حذف نویز و مدل انتخاباتی توسعه یافته برای انتخاب بارزترین داده استفاده شده و در بخش دوم از ماشین یادگیری شدید (ELM) برای استخراج الگو بهره گرفته شده است [۱۸]. در نهایت، با توجه به تابع هدف متشکل از خطای ناشی از پیش بینی و روش بهبود یافته کلونی جستجوی ویروس، پارامترهای ELM تنظیم شده اند.

۲- مدل پیش بینی کننده پیشنهادی

در این بخش ابزارهای به کار گرفته شده برای پیش بینی قیمت در قالب یک الگوریتم ترکیبی به تفکیک توضیح داده می شود.

۲-۱- تبدیل کرولت

تبدیل کرولت یک عضو جدید خانواده تبدیل چند مقیاسی است که در سال های اخیر برای بهبود ضعف های تبدیل های قدیمی چندمقیاسی مانند تبدیل موجک، توسعه و ارائه شده است. از نظر مفهوم تبدیل کرولت یک هرم چندمقیاسی با تعداد زیادی جهت و موقعیت ها در هر مقیاس طول و المان های سوزن شکل در مقیاس خوب است که این هرم از نوع غیراستاندارد است [۲۰]. ویولت ها تبدیل فوریه را با استفاده از پایه ای عمومی می کنند که نمایش دهنده مکان و فضای فرکانس است. برای سیگنال های دو یا سه بعدی، تبدیل موجک با استفاده از توابع پایه ای که جهت را محلی می کنند، بیشتر به پیش می رود. تبدیل کرولت با سایر تبدیل های موجک دارای جهت از نظر تغییر یافتن درجه محلی با مقیاس، تفاوت دارد و به طور خاص، توابع پایه مقیاس کوچک، برآمدگی بیشتری دارند [۲۱]. در تئوری این تبدیل، دو روش برای به دست آوردن ضرایب آن وجود دارد: الف) تبدیل فوریه سریع و ب) روش wrapping که براساس نتایج به دست آمده از سایر مقالات، روش دوم کارآمدتر است. در این روش ضرایب تبدیل کرولت به صورت زیر بیان می شوند:

پیش‌بینی روزانه قیمت برق با روش مبتنی بر ماشین یادگیری شدید، سیستم پیش‌پردازش‌کننده و ...

$$f(x) = h(x)\beta = \sum_{i=1}^L \beta_i h_i(a_i, b_i, x), \quad (8)$$

$$x, a_i \in \mathbb{R}^2, b_i \in \mathbb{R}$$

که $h_i(x)$ در واقع فضای d بعدی ورودی (x) را به یک فضای L بعدی نگاشت می‌کند و a_i و b_i به ترتیب پارامترهای تولیدی تصادفی برای i امین گره اند. بین لایه نهان و لایه خروجی وزن β_i وجود دارد. ادعا می‌شود اگر نگاشت مناسب در لایه نهان انتخاب شود، هر تابعی با این مدل تخمین زده می‌شود. L بیان‌کننده تعداد کل تابع‌های تعریف‌شده برای تخمین است. برای یک مسئله دسته‌بندی دودسته‌ای تابع تصمیم‌گیر برای این مدل به صورت زیر است:

$$f(x) = \text{sign}(h(x)\beta) \quad (9)$$

برخلاف روش‌های معمول یادگیری مدل ELM، نه تنها سعی می‌کند خطای داده‌های آموزش را حداقل کند، سعی دارد نرم وزن‌های خروجی را نیز حداقل کند. بر اساس تئوری بارلت^۲ برای SLFN-ها کاهش نرم وزن‌ها در کنار کاهش خطای آموزش به تعمیم‌پذیری بهتری می‌رسد؛ بنابراین تابع هدف ELM به صورت زیر فرموله می‌شود؛ این تابع در کاهش خطای آموزش و نرم وزن‌های خروجی سعی دارد:

$$\text{Minimize } \|\|H\beta - T\|^2 + \|\|\beta\| \quad (10)$$

که T ماتریس هدف $[t_1, t_2, \dots, t_N]^T$ ، نماد $\|\cdot\|$ نشان‌دهنده نرم استاندارد و H ماتریس لایه نهان است و به صورت زیر تعریف می‌شوند:

$$H = \begin{bmatrix} h(x_1) \\ \vdots \\ h(x_N) \end{bmatrix} = \begin{bmatrix} G(a_1, b_1, x_1) & \dots & G(a_L, b_L, x_L) \\ \vdots & & \vdots \\ G(a_1, b_1, x_N) & \dots & G(a_L, b_L, x_N) \end{bmatrix} \quad (11)$$

که، $G(a_i, b_i, x_i)$ نشان‌دهنده ارتباط بین آمین متغیر و ضرایب وزنی آن است. همان‌طور که مشاهده می‌شود حداقل کردن $\|\|\beta\|$ در واقع معادل حداکثرکردن فاصله حاشیه دو دسته در دسته‌بندی دو دسته‌ای یعنی حداکثرکردن $\|\|\beta\|^{-1}$ است. به منظور بهبود و توسعه مدل یادگیری و دورماندن از نگاشت که گاهی برای طراح مشخص نیست،

حال با در نظر گرفتن کرولت مادر در مقیاس j و زاویه l با معادله:

$$\phi_{j,l}^D(x) = \frac{1}{4\pi^2} \int e^{i(x,w)} \mathcal{U}_{j,l}^D(w) dw \quad (6)$$

و $\phi_{j,l}^D$ مشخص‌کننده دوره‌بندی آن روی مربع واحد $[0, 1]^2$ است:

$$\phi_{j,l}^D(x_1, x_2) = \sum_{m_1 \in \mathbb{Z}} \sum_{m_2 \in \mathbb{Z}} \phi_{j,l}^D(x_1 + m_1, x_2 + m_2) \quad (7)$$

که در رابطه یادشده، x نشان‌دهنده متغیر در یک بعد است. بر اساس توضیحات ریاضی گفته‌شده از تبدیل کرولت، در گام‌های زیر نحوه جداسازی و بازسازی یک سیگنال نمونه بر اساس تبدیل کرولت بیان شده است:

گام اول: استفاده از تبدیل فوریه برای سیگنال ورودی. گام دوم: کرولت برای اساس محور چرخش n و مقیاس s به دست می‌آید.

گام سوم: تقسیم تبدیل فوریه به مجموعه‌های کوچک. گام چهارم: هر زیرمجموعه به صورت یک محور ترجمه می‌شود.

گام پنجم: استفاده از روش warp برای تفکیک. گام ششم: استفاده از روش معکوس FFT برای آرایه‌های که از ضرایب تبدیل کرولت به دست آمدند. گام هفتم: استفاده از بخش ترجمه برای بازسازی سیگنال اولیه.

۲-۲- ماشین یادگیری شدید

در حالت کلی ماشین یادگیری شدید (ELM)، روش یادگیری است که به صورت موفقیت‌آمیزی در بسیاری از حوزه‌های دنیای واقعی اعمال شده است [۲۲]. این مدل با هدف ارائه یک مدل یکپارچه است که همه روش‌های مطرح‌شده در ماشین پشتیبان بردار که در ابتدا با نام ELM مطرح نشده‌اند، در بر می‌گیرد. مدل ELM در ابتدا برای شبکه‌های تعمیم‌یافته فیدفوروارد با تک لایه مخفی^۱ (SLFN) پیشنهاد شد، سپس برای SLFN-های تعمیم‌یافته گسترش داده شد. تابع خروجی SLFN-های تعمیم‌یافته به صورت زیر است:

مجموع آنتروپی با دو عضو X و Y به صورت زیر بیان می‌شود:

$$H(X, Y) = -\sum_{i=1}^n \sum_{j=1}^m P(X_i, Y_j) \log_2(P(X_i, Y_j)) \quad (16)$$

به منظور کوتاه کردن این بحث، سایر روابط مربوطه از مرجع [۲۳] پیگیری می‌شوند. با مرتب سازی روابط مربوطه، در نهایت، روش تقابلی به صورت زیر فرموله می‌شود:

$$MI(X, Y) = \sum_{i=1}^n \sum_{j=1}^m P(X_i, Y_j) \log_2 \left(\frac{P(X_i, Y_j)}{P(X_i)P(Y_j)} \right) \quad (17)$$

مقدار عددی بزرگ برای فرمول یادشده نشان از همبستگی بالا بین دو عضو X و Y است و برعکس. برای بهبود چنین اهدافی، روش‌های مختلفی ارائه شده‌اند [۲۴]. در این روش‌ها برای دو متغیر x_i و x_j و بهترین کلاس یا زیرمجموعه C از مجموعه S سعی می‌کنند وابستگی بین داده‌ها در هر ستون حداقل و با کلاس C حداکثر شود؛ برای نمونه، با اصلاح و توسعه فرمول یادشده براساس نرمال سازی داده‌ها، رابطه زیر ارائه شده است:

$$MMI = \arg \max_{X \in X-S} (MI(C; x_i) - \beta \sum_{X_S \in S} \frac{MI(C; x_S)}{H(x_S)} MI(x_i; x_S)) \quad (18)$$

که هدف انتخاب داده با بیشترین مقدار $MI(X_k, S; Y)$ است. $MI(X_k, S; Y)$ براساس میزان پیچیدگی جایگزین $(MI(X, X_j; Y))$ شده است تا به ایجاد دسته بندی S به انتخاب داده بپردازد؛ بنابراین، یک داده کاندید شده X_j مناسب خواهد بود. اگر $MI(X_k, X_j; Y)$ مقدار بزرگی داشته باشد، به صورت خاص، $(MI(X_k, X_j; Y))$ مقدار کمی خواهد داشت. اگر X_k دارای اطلاعات مشابه با کلاس Y داشته باشد یا اینکه اطلاعات جدیدی در خود نداشته باشد، ممکن است برخی از داده‌ها با مقدار کم $(MI(X_k, X_j; Y))$ دارای وابستگی بیشتری در مقایسه با داده‌های تکراری باشند.

از مدل مبتنی بر کرنل استفاده می‌شود. در این حالت، کرنل ELM به صورت زیر تعریف می‌شود:

$$\Omega_{ELM} = HH^T : \Omega_{ELM} i, j = h(x_i) \cdot h(x_j) = K(x_i, x_j) \quad (12)$$

$$f(x) = h(x)H^T \left(\frac{I}{C} + HH^T \right)^{-1} T = \begin{bmatrix} K(x, x_1) \\ \vdots \\ K(x, x_N) \end{bmatrix}^T \left(\frac{I}{C} + \Omega_{ELM} \right)^{-1} T \quad (13)$$

که، نماد T نشان دهنده ترانهاده یک بردار، $K(x_i, x_j)$ بیان کننده ارتباط بین دو متغیر x_i و x_j بر حسب تابعی از K است. پارامتر I ماتریس تشخیص از ابعاد مناسب است. $C \in R^+$ پارامتر تنظیم کننده است.

۲-۳- سیستم پیش پردازش کننده در انتخاب بهترین داده‌ها

یکی از مهم ترین مراحل در روش های پیش بینی، انتخاب مؤلفه های ورودی مناسب است. در این مرحله باید تصمیم گیری شود کدام دسته از متغیرهای ورودی سیستم بیشترین ارزش را در پیش بینی دارد. روش به کارگرفته در این مقاله استفاده از الگوریتم انتخاباتی برای تعیین بهترین زیرمجموعه به عنوان ورودی برای مسئله پیش بینی است [۲۳]. به این منظور، معیار آنتروپی $H(X)$ برای مجموعه اعداد نامنظم X براساس توزیع احتمالاتی $P(X)$ به صورت زیر بیان می‌شود:

$$H(X) = -\int P(X) \log_2(P(X)) dX \quad (14)$$

اگر مقادیر X_1, X_2, \dots, X_n مقادیر تصادفی ورودی با تابع احتمالاتی $P(X_1), P(X_2), \dots, P(X_n)$ تعریف شوند، $H(X)$ به صورت زیر بازنویسی می‌شود:

$$H(X) = -\sum_{i=1}^n P(X_i) \log_2(P(X_i)) \quad (15)$$

براساس دو رابطه یادشده آنتروپی، بیشتر یک مقدار از عدم قطعیت را در نظر می‌گیرد. در این صورت $H(X)$ دارای بیشترین مقدار $\log_2(N)$ است. برای تعمیم این بحث،

پیش‌بینی روزانه قیمت برق با روش مبتنی بر ماشین یادگیری شدید، سیستم پیش‌پردازش‌کننده و ...

دارد که به تدریج با افزایش تکرار برنامه به سمت نوسانات پایین تر سوق پیدا می‌کند و هدایت بهتری به سمت جواب بهینه نهایی ایجاد می‌کند. همچنین (G_{best}^g, τ) تضمین‌کننده تولید جواب های بهتر براساس هدایت جواب نهایی دارد که با بردار $(r_1.G_{best}^g - r_2.V_{pop_i})$ جهت‌گیری می‌کند. یکی از نقاط ضعف روش پیشنهادی ضرایب تصادفی r_1 و r_2 هستند که تضمین‌کننده جستجوی صحیح نیستند؛ به همین منظور فرمول یادشده به صورت زیر پیشنهاد شده است:

$$V_{pop_i} = Gaussian(G_{best}^g, \tau) + \chi_{ij} \phi_{ij} \times (r_1.G_{best}^g - r_2.V_{pop_i}) \quad (20)$$

ضریب χ_{ij} به صورت خودتطبیقی در هر تکرار به روزسانی می‌شود. اگر χ_{ij} مقدار عددی کوچکی داشته باشد، آنگاه $\chi_{ij} \phi_{ij}$ کوچک خواهد بود و جستجوی محلی تقویت می‌شود و برعکس با مقدار بزرگ χ_{ij} به طبع $\chi_{ij} \phi_{ij}$ عدد بزرگی خواهد شد که سبب بهبود جستجوی کلی است. برای انتخاب بهترین مقدار برای χ_{ij} از دو آستانه‌گیری $t_1 < 0$ و $t_2 > 0$ و دو متغیر b_1 در محدوده $(0, t_1)$ و b_2 در محدوده $(0, t_2)$ استفاده می‌شود که به صورت $\chi_{1j} = 2^{b_1}$ و $\chi_{2j} = 2^{b_2}$ تعریف می‌شوند؛ در نتیجه دو بردار جمعیت با ضرایب χ_{1j} و χ_{2j} تولید می‌شوند. وقتی مقدار آستانه $t_1 < 0$ باشد، b_1 منفی خواهد بود و با توجه به رابطه χ_{1j} ، مقدار این پارامتر، کوچک‌تر و در نتیجه جستجوی محلی تقویت می‌شود.

تأثیرپذیری سلول میزبان

هنگامی که یک سلول آلوده می‌شود، ساختمان داخلی آن با ویروس، تخریب و تا زمانی ادامه می‌یابد که به مرگ سلول منجر شود. این رفتار به بهترین نحو با مدل CMA-ES مبتنی بر ماتریس کوواریانس با گام‌های زیر مدل می‌شود:

گام اول: به روزسانی Hpop با رابطه:

$$H_{pop_i}^g = X_{mean}^g + \sigma_i^g \times N_i(0, C^g) \quad (21)$$

۲-۴- الگوریتم بهبودیافته کلونی جستجوی

ویروس

در این بخش، روش پیشنهادی براساس مدل ریاضیات بیان شده است. برای جزئیات بیشتر به مرجع [۱۹] مراجعه شود.

• تطبیق‌سازی با مدل‌های ریاضی

الگوریتم جستجوی ویروس شامل سه استراتژی است: (۱) روش پیاده روی گوسین برای مدل‌کردن انتشار ویروس؛ (۲) روش ماتریس کوواریانس CMA-ES برای مدل‌کردن آسیب‌دیدگی سلول میزبان و (۳) استراتژی تکامل برای مقابله سیستم ایمنی با ویروس. به صورت دقیق‌تر، استراتژی اول برای بهبود بخش بازشناختی یا استخراج و استراتژی دوم برای بهبود رفتار اجتماعی یا جستجو و استراتژی سوم برای تکمیل نقاط ضعف دو حالت قبل به کار گرفته می‌شوند. در قسمت سوم با حذف ویروس‌های ضعیف و ارتقای ویروس‌های قوی دو بخش قبلی بهبود می‌یابند.

• انتشار ویروس

روش پیاده روی گوسی، روش مناسب برای مدل‌کردن این رفتار و دوری‌گزیدن از جواب بهینه محلی است که با رابطه زیر فرموله می‌شود:

$$V_{pop_i} = Gaussian(G_{best}^g, \tau) + (r_1.G_{best}^g - r_2.V_{pop_i}) \quad (19)$$

که i شاخص انتخاب تصادفی از مجموعه $\{1, 2, \dots, N\}$ است که N تعداد کل جمعیت است. G_{best}^g بهترین جواب تولیدشده در تکرار g و r_1 و r_2 دو متغیر تصادفی بین ۰ و ۱ است. برای پارامتر گوسین، انحراف معیار l با رابطه $(V_{pop_i} - G_{best}^g) / g \cdot \log(g)$ به دست می‌آید. در فرمول یادشده جهت بردار $(r_1.G_{best}^g - r_2.V_{pop_i})$ برای دوری‌گزیدن از نقاط محلی است که V_{pop_i} بیان‌کننده i امین مکان از کل جمعیت V_{pop_i} است. همچنین برای بهبود عملکرد جستجوی محلی، $\log(g) / g$ در نظر گرفته شده است. این ضریب در تکرارهای اولیه مقدار نوسانات بالاتری

که $d_{\sigma} = 1 + C_{\sigma} + 2\max\{0, (\sqrt{\gamma_w - 1} / \sqrt{N - 1}) - 1\}$ معمولاً نزدیک به ۱ و C_{γ} است که C_{γ} مطابق با رابطه زیر عمل می‌کند:

$$C_1 = \frac{1}{\gamma_w} \left((1 - \frac{1}{\gamma_w}) \min\{1, \frac{2\gamma_w - 1}{(N + 2)^2 + \gamma_w}\} + \frac{1}{\gamma_w} \frac{2}{(N + \sqrt{2})^2} \right), \quad C_{\gamma} = (\gamma_w - 1)C_1 \quad (28)$$

که $0 \leq C_{\gamma} \leq 1$ نرخ به‌روزرسانی برای ماتریس کوواریانس C است.

• عملکرد سیستم ایمنی

براساس توضیحات یادشده، ویروس با توانایی بالاتر خود را در برابر سیستم ایمنی محافظت می‌کند و به تولید می‌پردازد. ویروس‌های ضعیف‌تر با سیستم ایمنی کشته می‌شوند؛ بنابراین گام‌های زیر برای این حرکت تکاملی پیگیری می‌شوند:

گام اول: محاسبه معیار عملکردی P_r برای جمعیت V_{pop} براساس تابع هدف سیستم مورد مطالعه:

$$Pr_{rank(i)} = \frac{N - i + 1}{N} \quad (29)$$

که N تعداد کل جمعیت V_{pop} و $rank(i)$ میانگین تابع هدف از i^{th} جمعیت V_{pop} است.

گام دوم: رشد کردن هر جمعیت به صورت انفرادی از میان جمعیت V_{pop} با رابطه:

$$\begin{cases} V_{pop_{i,j}} = V_{pop_{k,j}} - rand.(V_{pop_{h,j}} - V_{pop_{i,j}}) & \text{if } r > Pr_{rank(i)} \\ V_{pop_{i,j}} = V_{pop_{i,j}} & \text{otherwise} \end{cases} \quad (30)$$

که اندیس‌های k, i, h به صورت تصادفی از مجموعه $[1, 2, 3, \dots, N]$ انتخاب می‌شوند؛ به گونه‌ای که $i \neq h \neq k$ و $r \in [1, 2, 3, \dots, d]$ است. $rand$ و r عددهای تصادفی بین ۰ و ۱ هستند. فرمول‌های یادشده نشان می‌دهند هر جواب به تنهایی سعی در ذخیره بهترین مقدار فعلی خود برای مرحله دارند. همچنین اگر جوابی از محدوده مسئله خارج شوند، مجدد براساس محدوده بالا up_{ij} و پایین low_{ij} خود تولید می‌شود:

که $N_i(0, C^g)$ توزیع نرمال با میانگین ۰ و ماتریس کوواریانس C^g با ابعاد $D \times D$ ، g تکرار فعلی برنامه، D بعد مسئله و $\sigma^g > 0$ است. X_{mean}^g با مقدار اولیه زیر بیان

$$X_{mean}^0 = \frac{1}{N} \sum_{i=1}^N V_{pop_i} \quad (22)$$

گام دوم: بهترین بردار γ از بخش قبلی، انتخاب و بردار والدین با مرکزیت زیر در نظر گرفته می‌شود:

$$X_{mean}^{g+1} = \frac{1}{\gamma} \sum_{i=1}^{\gamma} \omega_i V_{pop_i^{best}} \mid \omega_i = \frac{\ln(\gamma + 1)}{\sum_{j=1}^{\gamma} (\ln(\gamma + 1) - \ln(j))} \quad (23)$$

که $\gamma = [N / 2]$ و w_i ضریب ترکیب و اندیس i نشان دهنده بهترین جواب در مجموعه جواب است. بر اساس این، دو مسیر حرکت تکاملی مطابق با روابط زیر وجود دارد:

$$P_{\sigma}^{g+1} = (1 - C_{\sigma}) P_{\sigma}^g + \sqrt{C_{\sigma}(2 - C_{\sigma})} \gamma_{\omega} \frac{1}{\sigma^g} (C^g)^{\frac{1}{2}} (X_{mean}^{g+1} - X_{mean}^g) \quad (24)$$

$$P_C^{g+1} = (1 - C_C) P_C^g + h_{\sigma} \sqrt{C_C(2 - C_C)} \gamma_{\omega} \frac{1}{\sigma^g} (X_{mean}^{g+1} - X_{mean}^g) \quad (25)$$

که $\gamma_w^{-1} = \sum_{i=1}^{\gamma} w_i^2 (C^g)^{-0.5}$ متقارن، مثبت و برقرارکننده شرط $(C^g)^{-1} = (C^g)^{-0.5} (C^g)^{-0.5}$ است. پارامترهای محاسباتی به صورت معمول با $h_{\sigma} = 1$ تنظیم می‌شوند؛ البته اگر رابطه $h_{\sigma} = 0$ برقرار باشد، مقدار عددی بزرگی برای عبارت $\|P_{\sigma}^{g+1}\|$ به دست خواهد آمد.

گام سوم: به‌روزرسانی اندازه σ^{g+1} و ماتریس کوواریانس C^{g+1} با:

$$\sigma^{g+1} = \sigma^g \times \exp\left(\frac{C_{\sigma}}{d_{\sigma}} \left(\frac{\|P_{\sigma}^{g+1}\|}{E|N(0,1)|} - 1\right)\right) \quad (26)$$

$$C^{g+1} = (1 - C_1 - C_{\gamma}) C^g + C_1 P_C^{g+1} (P_C^{g+1})^T + C_{\gamma} \sum_{i=1}^{\gamma} w_i \frac{(V_{pop_i^{best}} - X_{mean}^g)(V_{pop_i^{best}} - X_{mean}^g)^T}{\sigma^g} \quad (27)$$

پیش‌بینی روزانه قیمت برق با روش مبتنی بر ماشین یادگیری شدید، سیستم پیش‌پردازش‌کننده و ...

گام بهترین داده‌ها با مقدار همبستگی بیشتر از ۰/۵ برای آموزش وارد ماشین یادگیری شدید می‌شوند.

گام سوم: استفاده از ماشین یادگیری شدید برای آموزش هر بخش برای پیش‌بینی اطلاعات ساعت‌های $T+1, \dots, T+24$ برای هر ماتریس تجزیه‌شده از داده‌های اولیه و انجام جمع نتایج حاصل از پیش‌بینی با یکدیگر به منظور دستیابی به اطلاعات اولیه. مدل استخراج‌شده از تلفیق قسمت خطی و غیرخطی حاصل می‌شود.

گام چهارم: در این مرحله به آموزش بهتر ماشین یادگیری شدید غیرخطی با کاهش خطای خروجی به کمک به‌روزرسانی وزن‌ها و بایاس‌ها پرداخته می‌شود.

گام پنجم: در این قسمت با کمک تابع هدف معرفی‌شده که بر مبنای کاهش خطای خروجی است، بهینه‌سازی وزن‌ها و بایاس‌ها برای ماشین بردار پشتیبان غیرخطی به منظور آموزش بهتر آن انجام می‌گیرد. تابع هدف استفاده‌شده در این مقاله درصد خطای مطلق متوسط ($MAPE$) است که براساس تعداد روزهای مورد مطالعه (N) تعریف شده است.

گام ششم: ایجادکردن متغیرهای تعریف‌شده براساس توابع تصمیم‌گیری در الگوریتم توسعه‌یافته کلونی جستجوی ویروس.

گام هفتم: ارتقای مجموعه جواب‌های به دست آمده براساس ساختار توسعه‌یافته کلونی جستجوی ویروس.

گام هشتم: بررسی شرط خاتمه برنامه. اگر شرط خاتمه برقرار شد، برنامه تمام می‌شود؛ در غیر این صورت به گام دوم سوق می‌یابد.

شکل (۱) فلوچارت روش پیش‌بینی‌کننده پیشنهادی را نشان می‌دهد.

$$x_{ij} = low_{ij} + rand \times (up_{ij} - low_{ij}) \quad (31)$$

۲-۵- تعیین خطای پیش‌بینی

برای ارزیابی روش پیشنهادی، معیارهای مختلفی وجود دارند که در ادامه برخی از آنها بیان می‌شوند. معیار SDE برای مقایسه نتایج به صورت زیر تعریف می‌شود:

$$SDE = \sqrt{\frac{1}{N} \sum (e_h - \bar{e})^2} \quad (32)$$

که در آن، e_k خطای پیش‌بینی در ساعت h ام و e خطای متوسط در دوره تناوب پیش‌بینی است.

$$e_h = \hat{p}_h - p_h \quad (33)$$

برای مقایسه کارایی روش‌های پیش‌بینی از معیارهایی مانند $MAPE$ (میانگین قدر مطلق خطای درصدی) استفاده شده است:

$$MAPE = \frac{1}{N} \sum_{i=1}^N \frac{|P_{ACT(i)} - P_{FOR(i)}|}{P_{ACT(i)}} \quad (34)$$

که در رابطه یادشده، P_{FOR} و P_{ACT} به ترتیب مقدار واقعی و پیش‌بینی‌شده قیمت برق است.

۳- ساختار روش پیش‌بینی‌کننده پیشنهادی

در این بخش الگوی به‌کاررفته برای حل مسئله پیش‌بینی روزانه قیمت بیان شده است. ابتدا فرض کنید پیش‌بینی برای روز d انجام می‌گیرد و اطلاعات گذشته سری داده‌های قیمت برای ۲۴ ساعت روز $d-1$ به صورت $p_h; h=1, \dots, T$ دسترس پذیرند که در آن T معمولاً بین حدود یک هفته الی چند ماه قبل را شامل می‌شود. با توجه به فرضیات گفته‌شده خواهیم داشت:


گام اول: ابتدا با توجه به تابع تبدیل کرولت سیگنال، به زیربخش‌های مربوطه، تبدیل و نویزهای آن گرفته می‌شود. به کمک این تبدیل، الگوپذیری سیگنال اولیه حفظ می‌شود.

گام دوم: استفاده از الگوریتم انتخاباتی پیشنهادی برای مرتب‌کردن داده‌ها با بیشترین همبستگی، درحقیقت در این

سراسری و محلی به سختی انجام شود و در صورتی که الگوریتم های توانایی پرش بین دو ناحیه نداشته باشند، امکان قرارگیری در نقاط محلی افزایش خواهد یافت. فرمول بندی ریاضی این تابع به صورت زیر است [۲۵]:

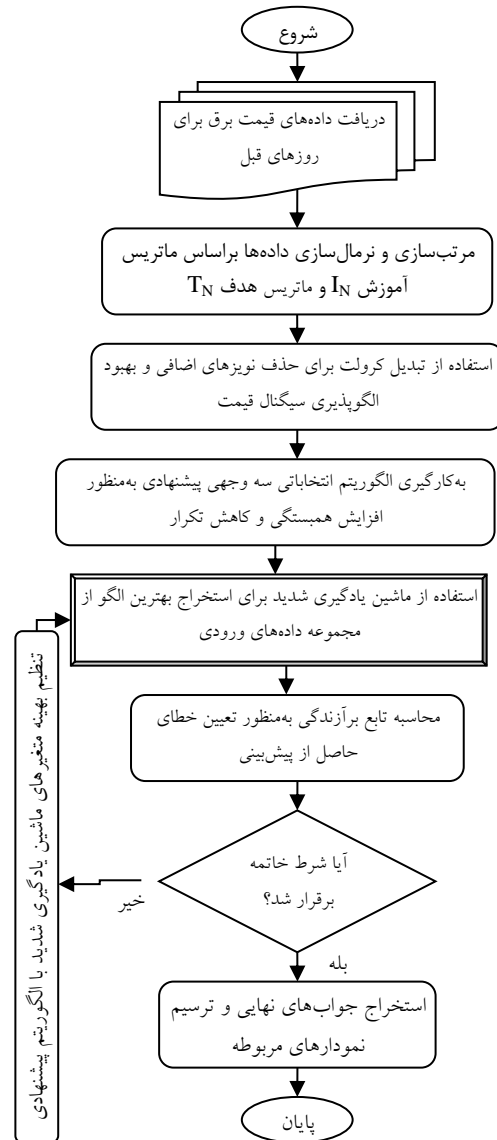
$$f(x_1, x_2) = -0.0001(|\sin(x_1) \sin(x_2)| \exp(|100 - \frac{\sqrt{x_1^2 + x_2^2}}{\pi}| + 1))^{0.1} \quad (35)$$

برای مقایسه بهتر، بهترین ضرایب از سایر مقالات استخراج شده است و تنها تعداد جمعیت اولیه یکسان برای آنها در نظر گرفته شده است.



شکل (۲): ترسیم ۳ بعدی از تابع آزمون Cross-in-Tray

شکل (۳)، نتیجه میانگین همگرایی الگوریتم پیشنهادی به ازای ۲۰ بار اجرای مختلف را نشان می دهد. همان گونه که در شکل مشخص است روش پیشنهادی، سرعت و دقت بالایی در یافتن جواب نهایی دارد. به منظور سخت تر شدن شرایط جستجو محدوده [-۱۰۰، ۱۰۰]، تعداد جمعیت ۲۰، تعداد متغیر ۱۰۰ و تعداد تکرار برنامه ۵۰ در نظر گرفته شد. همچنین شکل (۴)، نحوه توزیع و پراکندگی برای ۲۰ تکرار را نشان می دهد. نزدیکی جواب های به دست آمده از الگوریتم پیشنهادی نشان از مقاوم بودن و کارایی زیاد آن دارد. همچنین نشان می دهد روش پیشنهادی دارای انحراف معیار بسیار کوچکی است.



شکل (۱): فلوجارت الگوریتم پیشنهادی برای پیش بینی قیمت برق

۴- نتایج شبیه سازی


۴-۱- بررسی الگوریتم VCS پیشنهادی

در این بخش، عملکرد روش توسعه یافته پیشنهادی براساس معیارهای مختلفی با سایر روش های بهینه سازی مقایسه می شود. هدف این بخش، تعیین ضرایب مناسب الگوریتم و نشان دادن برتری این روش و دلیل انتخاب آن است. تابع آزمون مورد مطالعه (Cross-in-Tray) برای این بخش یک تابع دو بعدی مطابق شکل ۲ است. با توجه به شکل، صفحات متعامد و متقاطع سبب می شوند جستجوی


پیش‌بینی روزانه قیمت برق با روش مبتنی بر ماشین یادگیری شدید، سیستم پیش‌پردازش‌کننده و ...

شکل (۴): ترسیم box به منظور نشان دادن پراکندگی جستجو در ۵۰ تکرار و به ازای ۲۰ اجرای مختلف

در انتهای این بخش به منظور مقایسه عملکرد الگوریتم پیشنهادی در مقایسه با سایر الگوریتم‌ها معرفی شده در سال‌های اخیر، مقایسه‌ای براساس میزان کمینه، بیشینه و میانگین در جدول (۱) ارائه شده است. مقایسه روش پیشنهادی این مقاله با روش‌های PSO, SSO, GWO و PFA انجام شده است. برای کوتاه کردن تعداد صفحات و روابط ریاضی، کلیه توابع معرفی شده در جدول (۱) از مرجع [۲۶] گرفته شده‌اند. خواننده محترم برای بررسی و دریافت روابط ریاضی به این مرجع مراجعه کند.



شکل (۳): نتیجه میانگین همگرایی الگوریتم پیشنهادی به ازای ۲۰ اجرای مختلف

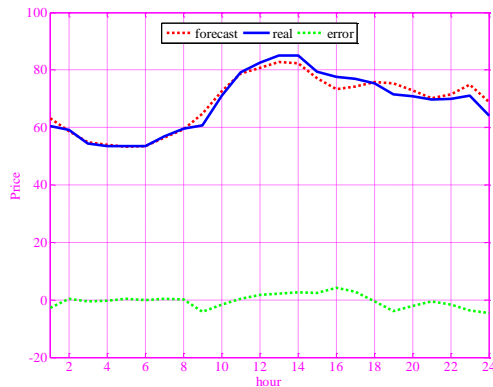


جدول (۱): مقایسه براساس معیارهای استاتیکی برای الگوریتم‌های بهینه‌سازی مختلف و توابع با ابعاد ۱۰ متغیره

Method	function	Min	Max	Mean
PSO [26]	F2	$4/2447 \times 10^{-27}$	۱۰۰	۱۰
	F6	$1/0856 \times 10^{-51}$	$5/3297 \times 10^{-42}$	$2/1631 \times 10^{-43}$
	F16	۰/۰۰۰۱	۱۹۰۵/۶۳۲۸	۱۰۰۰/۵۴۵۸
	F17	$9/3888 \times 10^{-14}$	۱۲۵/۶۴۶۶	۱۵۰/۷۹۴۴
SSO [26]	F2	۰/۳۱۳۳	۲۰/۶۳۵۴	۵/۱۶۳
	F6	$2/7888 \times 10^{-15}$	$1/9618 \times 10^{-14}$	$1/2154 \times 10^{-15}$
	F16	۶۴۳۹/۹۱۹۳	۱۰۳۰۹/۳۵۹۴	۸۴۱۴/۲۱۸۷
	F17	۶۳/۱۴۵۰	۲۴۳/۳۲۰۱	۱۴۷/۱۶۱۰
GWO [26]	F2	$2/1787 \times 10^{-124}$	$3/4187 \times 10^{-117}$	$1/7713 \times 10^{-118}$
	F6	$1/1897 \times 10^{-246}$	$1/756 \times 10^{-228}$	$5/7950 \times 10^{-230}$
	F16	۹۲۷/۸۵۴۵	۲۰۴۱/۸۹۰۳	۱۴۹۸/۴۳۱۱
	F17	$1/1614 \times 10^{-80}$	$2/2596 \times 10^{-70}$	$1/4717 \times 10^{-71}$
PFA [26]	F2	$4/1003 \times 10^{-90}$	$1/5714 \times 10^{-85}$	$2/2649 \times 10^{-87}$
	F6	$8/818 \times 10^{-177}$	$6/3580 \times 10^{-163}$	$2/1199 \times 10^{-164}$
	F16	۱۱۸/۳۸۴	۸۳۰/۵۸۵۵	۴۴۹/۵۰۹۰
	F17	$9/8349 \times 10^{-40}$	$6/0344 \times 10^{-34}$	$2/1768 \times 10^{-35}$
Proposed	F2	$2/132 \times 10^{-298}$	$3/928 \times 10^{-257}$	$7/019 \times 10^{-289}$
	F6	۰/۰۰	$5/983 \times 10^{-12}$	$4/546 \times 10^{-16}$
	F16	$1/726 \times 10^{-23}$	$4/829 \times 10^{-12}$	$7/029 \times 10^{-19}$
	F17	۰/۰۰	$3/0289 \times 10^{-34}$	$7/013 \times 10^{-62}$

۴-۲- بازار برق اسپانیا

سایر روش‌های انجام‌گرفته در این بازار، مقایسه‌ای در جدول (۱) براساس معیار MAPE هفتگی برای چهار هفته در بازار برق اسپانیا انجام شده است. سایر روش‌های از مرجع [۲۸] برگرفته شده‌اند.



شکل (۵): نتایج شبیه‌سازی برای سیستم اسپانیا

همان‌گونه که اشاره شد در این مقاله، از الگوریتم پیشنهادی برای پیش‌بینی کوتاه‌مدت قیمت استفاده شده است. به‌منظور شبیه‌سازی و پیش‌بینی قیمت با الگوریتم پیشنهادی از سیستم اسپانیا [۲۷] به عنوان بازار واقعی استفاده شده است. علت انتخاب این سیستم به دلیل واقعی بودن اطلاعات و دسترسی آن است. برای پیش‌بینی سیستم اسپانیا اطلاعات ۵۰ روز قبل آن گرفته شده و بعد از آرایش دهی روی داده‌های ورودی ۷ کاندید برای آموزش وارد شبکه عصبی شده‌اند. در آموزش این داده‌ها ماتریس مشاهده گر دارای ۱۴۰۰ عضو است. شکل (۵) تغییرات پیش‌بینی برای ۲۴ ساعت به کمک روش پیشنهادی را مشخص کرده‌اند.

با توجه به شکل، الگوریتم پیشنهادی دارای پیش‌بینی قابل قبولی است. همچنین برای مقایسه روش پیشنهادی با

جدول (۱): مقایسه بین روش پیشنهادی و سایر روش‌های ارائه‌شده براساس معیار MAPE هفتگی برای چهار هفته در بازار برق اسپانیا

Test Week	ARIMA [28]	WT+ ARIMA [28]	FNN [28]	NN [28]	Mixed Model [28]	WT+ ARIMA RBFN [28]	MI+CNN [28]	Proposed
Winter	۶/۳۲	۴/۷۸	۴/۶۲	۵/۲۳	۶/۱۵	۴/۲۷	۴/۵۱	۴/۲۰۹
Spring	۶/۳۶	۵/۶۹	۵/۳۰	۵/۳۶	۴/۴۶	۴/۵۸	۴/۲۸	۴/۷۶۵
Summer	۱۳/۳۹	۱۰/۷۰	۹/۸۴	۱۱/۴۰	۱۴/۹۰	۶/۷۶	۶/۴۷	۵/۶۰۴
Fall	۱۳/۷۸	۱۱/۲۷	۱۰/۳۲	۱۳/۶۵	۱۱/۶۸	۷/۳۵	۵/۲۷	۵/۱۹۹
Average	۹/۹۶	۸/۱۱	۷/۵۲	۸/۹۱	۹/۳۰	۵/۷۴	۵/۱۳	۴/۶۹


مختلف، پیچیده‌تر شده است، الگوبرداری به مراتب سخت‌تر خواهد بود؛ در نتیجه چنین بازاری توصیف بهتری از عملکرد روش پیش‌بینی‌کننده پیشنهادی ارائه خواهد داد. به عبارتی دیگر، در این بخش از داده‌های سال ۲۰۱۸ بازار برق استرالیا بهره گرفته شده‌اند [۲۹]. با توجه به اینکه برای داده‌های این سال، مقاله‌ای وجود ندارد، نمی‌توان با سایر مقالات مقایسه کرد؛ ولی برای پوشش این جنبه، روش‌های مختلفی در این مقاله، اجرا و نتایج آنها مقایسه شده‌اند. روند انجام پیش‌بینی همانند بازار برق اسپانیا بوده است. پیش‌بینی در روز اول و هفته اول سپتامبر ۲۰۱۸ انجام گرفته است. نتیجه پیش‌بینی روزانه و هفتگی به ترتیب در شکل‌های (۶) و (۷) نشان داده شده است. حال به‌منظور مقایسه عددی،

نتایج به دست آمده نشان می‌دهند روش پیشنهادی در مقایسه با بهترین روش از مقالات دیگر (MI+CNN) ۸/۵۷٪ نتیجه بهتری داشته است. همچنین در مقایسه با بدترین روش در مقاله مدنظر (ARIMA) ۵۲/۹٪ بهبود حاصل کرده است.

۴-۳- بازار برق استرالیا


در قسمت قبل، هدف مقایسه عملکرد الگوریتم با سایر مقالات منتشرشده در زمینه پیش‌بینی قیمت و اعتبارسنجی آن بوده است. در این قسمت، عملکرد روش پیش‌بینی‌کننده پیشنهادی بر بازار برق استرالیا بررسی خواهد شد. با توجه به اینکه بازار برق امروزی با در نظر گرفتن شاخص‌های

پیش‌بینی روزانه قیمت برق با روش مبتنی بر ماشین یادگیری شدید، سیستم پیش‌پردازش‌کننده و ...



شکل (۸): نتیجه توزیع خطای حاصل از پیش‌بینی ۲۴ ساعته و

مقایسه مقدار عددی MAPE



شکل (۹): نتیجه توزیع خطای حاصل از پیش‌بینی ۱۶۸ ساعته

و مقایسه مقدار عددی MAPE


با توجه به شکل های (۸) و (۹)، روش پیشنهادی در مقایسه با دو روش دیگر توزیع باریک‌تری ایجاد کرده است؛ در نتیجه نشان از توزیع خطای کمتر در میزان پیش‌بینی قیمت دارد. همچنین تمرکز بیشتر داده‌ها در نقطه صفر تمرکز یافته است که نشان از انحراف معیار کمتر پیش‌بینی برای تمامی ساعات مورد مطالعه دارد. همچنین نتایج به‌دست‌آمده نشان می‌دهند هر یک از ابزارهای معرفی شده در پیش‌بینی، سهم چشمگیری در میزان دقت پیش‌بینی دارند؛ به گونه‌ای که بدون حضور سیستم پیش‌پردازش‌کننده خطای پیش‌بینی افزایش یافته است.

الگوریتم پیشنهادی نشان داد می‌تواند در مسائل مختلف بهینه‌سازی از نظر حجم محاسبات و میزان همگرایی، بسیار قدرتمند عمل کند.

۵- نتیجه‌گیری


در مقاله حاضر، سیستم ترکیبی جدیدی مدل‌سازی شده است. روش پیشنهادی از سیستم پیش‌پردازش‌کننده آنتروپی براساس حداکثرسازی همبستگی و حداقل‌سازی تکرار و تبدیل کرولت به منظور نوین‌گیری از سیگنال اصلی و موتور پیش‌بینی‌کننده ماشین یادگیری شدید تنظیم شده با الگوریتم توسعه‌یافته کلونی جستجوی ویروس بهره می‌برد. تحلیل‌های انجام‌گرفته روی بازارهای واقعی موجود، نشان می‌دهند این روش از دقت بالا و اطمینان مناسبی برخوردار

شکل‌های (۸) و (۹) به ترتیب میزان پراکندگی خطای پیش‌بینی و مقدار عددی به‌دست‌آمده هر سه روش را نشان می‌دهند.



شکل (۶): نتایج شبیه‌سازی برای سیستم استرالیا برای دوره ۲۴

ساعته



شکل (۷): نتایج شبیه‌سازی در بازار استرالیا برای دوره ۱۶۸

ساعته

همچنین شکل‌های (۶) و (۷) به ترتیب پیش‌بینی روزانه و هفتگی را نشان داده‌اند و بیان‌کننده قابلیت بالای الگوریتم ترکیبی پیشنهادی براساس انحراف معیار دارد. به عبارتی دیگر، شکل‌ها نشان‌دهنده انتخاب مناسب وزن‌ها و بایاس‌ها برای آموزش شبکه پیشنهادی دارد. همان‌گونه که مشخص است هنگامی که الگوریتم پیش‌بینی‌کننده پیشنهادی از تمامی ابزارهای خود بهره می‌برد، نتیجه بهتری به دست می‌آورد که نشان از عملکرد صحیح هر یک از زیربخش‌های روش پیشنهادی دارد.

- [8] G. Díaz, J. Coto, J. Gómez-Aleixandre, "Prediction and explanation of the formation of the Spanish day-ahead electricity price through machine learning regression," *Applied Energy*, Vol. 239, pp. 610-625, 2019.
- [9] A. Alshejari, V. S. Kodogiannis, "Electricity price forecasting using asymmetric fuzzy neural network systems," *Int. Conference on Fuzzy Systems*, Naples, Italy, pp. 1-7, 2017.
- [10] X.R. Li, C.W. Yu, S.Y. Ren, C.H. Chiu, K. Meng, "Day-ahead electricity price forecasting based on panel cointegration and particle filter," *Electric Power Systems Research*, Vol. 95, pp. 66-76, 2013.
- [11] Y-R. Gahrooei, R. Hooshmand, "Short term electricity price forecasting by hybrid mutual information ANFIS-PSO approach," *Scientific Journal of Computational Intelligence in Electrical Engineering*, Articles in Press, 2019.
- [12] H. Shayeghi, A. Ghasemi, "Modeling of multi input multi output based LSSVM for electricity price and load forecasting in smart grid with considering demand side management," *Scientific Journal of Computational Intelligence in Electrical Engineering*, Vol. 6, No. 4, pp. 70-87, 2016.
- [13] M. R. Aghaebrahimi, H. Taherian, I. Nazer-Kakhki, M. Farshad, S. R. Goldani, ,
- [14] Short term price forecasting in electricity market considering the effect of wind units' generation," *Scientific Journal of Computational Intelligence in Electrical Engineering* , Vol. 5, No. 1, pp. 105-122, 2014.
- [15] R. Tahmasbi far, "Probabilistic prediction of electricity price using a hybrid method," *Tarbiat Modares University, Master of Science thesis*, 2015. P. M. R. Bento, J. A. N. Pombo,
- [16] M. R. A. Calado, S. J. P. S. Mariano, "A bat optimized neural network and wavelet transform approach for short-term price forecasting," *Applied Energy*, Vol. 210, pp. 88-97, 2018.
- [17] Dmitriy O. Afanasyev, Elena A. Fedorova, "On the impact of outlier filtering on the electricity price forecasting accuracy," *Applied Energy*, Vol. 236, pp. 196-210, 2019.
- [18] B. Zhu, Y. Wei, "Carbon price forecasting with a novel hybrid ARIMA and least squares support vector machines methodology," *Omega*, Vol. 41, pp. 517-524, 2013.

است. نتایج به دست آمده از شبیه سازی ها نشان می دهد این الگوریتم در پیش بینی بهتر در مقایسه با سایر روش های موجود، قابلیت بالایی دارد. همچنین نتایج مناسب به دست آمده، نشان می دهد الگوریتم انتخاباتی در مرتب سازی داده های تقسیم شده از تبدیل موجک جزئی موفق بوده است. با توجه به مدل پیشنهادی، می توان از این مدل در کارهای آتی در پیش بینی تغییرات باد استفاده کرد؛ زیرا انرژی باد عدم قطعیت فراوانی دارد؛ بنابراین تأثیرات تبدیل کرولت و انتخاب ویژگی به صورت چشمگیری نشان داده خواهد شد.

مراجع

- [1] J-L. Zhang, Y-J. Zhang, D-Z. Li, Z-F. Tan, J-F Ji, "Forecasting day-ahead electricity prices using a new integrated model," *International Journal of Electrical Power & Energy Systems*, Vol. 105, pp. 541-548, 2019.
- [2] A. Brusaferrri, M. Matteucci, P. Portolani, A. Vitali, "Bayesian deep learning based method for probabilistic forecast of day-ahead electricity prices," *Applied Energy*, Vol. 250, pp. 1158-1175, 2019.
- [3] P. Damien, R. Fuentes-García, R. H. Mena, J. Zarnikau, "Impacts of day-ahead versus real-time market prices on wholesale electricity demand in Texas," *Energy Economics*, Vol. 81, pp. 259-272, 2019.
- [4] J. Nowotarski, R. Weron, "Recent advances in electricity price forecasting: A review of probabilistic forecasting," *Renewable and sustainable energy reviews*, Vol. 81, No. 1, pp. 1548-1568, 2018.
- [5] X. Yan, Y. Ozturk, Z. Hu, Y. Song, "A review on price-driven residential demand response," *Renewable and Sustainable Energy Reviews*, Vol. 96, pp. 411-419, 2018.
- [6] G. Marcjasz, B. Uniejewski, R. Weron, "On the importance of the long-term seasonal component in day-ahead electricity price forecasting with NARX neural networks," *International Journal of Forecasting*, In press, 2018.
- [7] X. Zhang, J. Wang, Y. Gao, "A hybrid short-term electricity price forecasting framework: Cuckoo search-based feature selection with singular spectrum analysis and SVM," *Energy Economics*, Vol. 81, pp. 899-913, 2019.

- based scheme,” Energy Conversion and Management, Vol. 74, pp. 482-491, 2013.
- [25] M. Bennasar, R. Setchi, Y. Hicks, “Feature interaction maximisation,” Pattern recognition letters, Vol. 34, pp. 1630-1635, 2013.
- [26] M. Jamil, X-S. Yang, “A literature survey of benchmark functions for global optimization problems,” Int. Journal of Mathematical Modelling and Numerical Optimisation, Vol. 4, No. 2, pp. 150-194, 2013.
- [27] H. Yapici, N. Cetinkaya, “A new meta-heuristic optimizer: Pathfinder algorithm,” Applied Soft Computing Journal, In press, 2019.
- [28] Informe de operación del sistema eléctrico. Red Eléctrica de España (REE), Madrid, Spain. [Online]. Available: http://www.ree.es/cap03/pdf/Inf_Oper_REE_99b.pdf.
- [29] N. Amjady, A. Daraeepour, “Design of input vector for day-ahead price forecasting of electricity markets,” Exp Syst Appl, Vol. 36, No. 10, pp. 12281-12294, 2009.
- [30] Australian Energy Market Operator [Online]. Available: <http://www.aemo.com.au/>.
- [19] 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, 2017.
- [20] M. D. Li, H. Zhao, X. W. Weng, T. Han, “A novel nature-inspired algorithm for optimization: Virus colony search,” Advances in engineering software, Vol. 92, pp. 65-88, 2016.
- [21] P. Anandan, R.S. Sabeenian, “Fabric defect detection using discrete curvelet transform,” Procedia Computer Science, Vol. 133, pp. 1056-1065, 2018.
- [22] P. Anandan, R. S. Sabeenian, “Medical image compression using wrapping based fast discrete curvelet transform and arithmetic coding,” Circuits and systems, Vol.7 No.8, pp. 1-11, 2016.
- [23] Y.P. Zhao, Q.K. Hu, J.G. Xu, B. Li, G. Huang, Y.T. Pan, “A robust extreme learning machine for modeling a small-scale turbojet Engine,” Applied Energy, Vol. 218, pp. 22-35, 2018.
- [24] H. Shayeghi, A. Ghasemi, “Day-ahead electricity prices forecasting by a modified CGSA technique and hybrid WT in LSSVM

¹ single-hidden-layer feed-forward networks

² Bartlett’s Theory