

پیش‌بینی قیمت برق با تأکید بر جهش‌های قیمت با استفاده از ترکیب شبکه عصبی-فازی با الگوریتم بهینه ازدحام ذرات

علی ناظمی^{۱*}، سیاب ممی‌پور^۱، سلمان رحیمی^۲

۱. استادیار دانشکده اقتصاد دانشگاه خوارزمی تهران

۲. کارشناس ارشد مهندسی صنایع دانشکده اقتصاد دانشگاه خوارزمی تهران

(تاریخ دریافت: ۹۵/۰۹/۳۰، تاریخ دریافت روایت اصلاح‌شده: ۹۷/۰۱/۰۶، تاریخ تصویب: ۹۷/۰۲/۰۶)

چکیده

پس از تجدید ساختار بازار برق، مطالعات بسیاری به منظور افزایش کارایی سیستم قدرت و سوددهی سرمایه‌گذاران، به‌ویژه در بحث طراحی سیستم‌های جدید و قیمت انرژی انجام شد. سود سرمایه‌گذاری می‌تواند با بستن قراردادهای بهتر یا پیشنهاددهی قیمت مناسب برای خرید و فروش انرژی الکتریکی افزایش یابد. به طوری که برای رسیدن به این موارد باید قیمت برق به‌طور دقیق پیش‌بینی شود. هدف اصلی این پژوهش، پیش‌بینی قیمت برق در بازار ایران به کمک ترکیب شبکه‌های عصبی-فازی با الگوریتم بهینه ازدحام ذرات است. در این پژوهش، قیمت‌های گذشته، بار گذشته، بار پیش‌بینی‌شده، روزهای کاری و غیرکاری، ساعات روز و تمییز فصول سال ۱۳۹۴ مهم‌ترین فاکتورهای تأثیرگذار در پیش‌بینی به‌شمار می‌آیند. مدل ترکیبی از روش‌های ARIMA، شبکه عصبی شعاعی پایه، شبکه عصبی-فازی و ترکیب شبکه عصبی-فازی با الگوریتم ژنتیک دقت بالاتری دارد. در ادامه مقاله، برای بهبود و افزایش دقت پیش‌بینی، به پردازش نوسانات قیمت پرداخته شد. نتایج شبیه‌سازی نشان می‌دهد پیش‌بینی قیمت برق با استفاده از روش پردازش قیمت، دقت بهتری دارد.

واژه‌های کلیدی: الگوریتم ازدحام ذرات، پیش‌بینی، جهش‌های قیمت، شبکه‌های عصبی-فازی.

مقدمه

صنعت برق، از شاخص‌های اثرگذار بر وضعیت اقتصادی، اجتماعی، سیاسی، فرهنگی و رفاهی جامعه به‌شمار می‌رود. این صنعت سال‌ها به‌عنوان خدمتی عمومی تلقی می‌شد و به همین دلیل، انحصاری و غیررقابتی بود، اما امروزه دیگر چنین نیست. صنایع برق دنیا در دو دهه گذشته با تغییر ساختار بنیادینی همراه شده‌اند که این تغییرات به تجدید ساختار مشهورند. تجدید ساختار در صنعت برق با اهداف و انگیزه‌هایی از قبیل ایجاد محیط رقابتی و جلوگیری از انحصار، حق انتخاب برای مشتریان، شفافیت هزینه‌ها، تبعیت از قوانین بین‌المللی، شرایط و پروتکل‌های منطقه‌ای و ... همراه بوده است. در بسیاری از کشورها از جمله ایران، رقابت تنها در سطح عمده‌فروشی است و مصرف‌کنندگان نهایی برق همچنان با قیمت‌های ثابت که دولت‌ها تعیین می‌کنند مواجه هستند. برق ویژگی‌هایی دارد که آن را از سایر کالاها متمایز می‌کند؛ برای مثال به‌صورت اقتصادی

قابلیت ذخیره‌سازی ندارد و تراکم انتقال ممکن است از تبادل آزادانه توان میان نواحی کنترل جلوگیری کند؛ بنابراین قیمت برق بسیار ناپایدار است و در واقع در میان تمامی کالاها بی‌ثبات‌ترین آن‌ها محسوب می‌شود [۱].

تولیدکنندگان و خریداران برای تبادل برق تولیدی و موردنیاز خود در بازار رقابت می‌کنند و قیمت‌های پیشنهادی خود را در ساعات مختلف به بهره‌بردار بازار ارائه می‌دهند. قیمت‌های نقدی همراه با تغییرات زیاد و ریسک که در بازار رقابتی تعیین می‌شود، رفتار فعالان بازار را تغییر می‌دهد؛ از این‌رو پیش‌بینی قیمت‌ها برای تولیدکنندگان و مصرف‌کنندگان برق جهت برنامه‌ریزی آتی سرمایه‌گذاری و بهره‌برداری و مدیریت ریسک ناشی از تغییرات گسترده قیمت، ضروری است.

پیش‌بینی کوتاه‌مدت قیمت برق یکی از فعالیت‌های اساسی و حیاتی در بازارهای برق و اساس افزایش سود شرکت‌کنندگان در بازار است. به‌منظور رقابت در بازار و

استنتاج مددانی، همچنین ۲۴ گام برای پیش‌بینی قیمت ۲۴ ساعت آینده استفاده شده است.

شربواستاوا و پانی‌گراهی [۶] به بررسی عملکرد تکنیک شبکه عصبی به نام ELM در مسئله پیش‌بینی قیمت پرداختند. در این مدل، برای بهبود پیش‌بینی و قابلیت اطمینان، ELM با روش موجک ادغام شده و روشی ترکیبی به نام WELM ارائه شده است. همچنین ویژگی‌های منحصربه‌فرد هریک از تکنیک‌ها برای گرفتن الگوهای گوناگون داده‌ها ترکیب شده‌اند. این مدل با استفاده از داده‌های بازارهای مختلف ارزیابی شده است که نتایج آن نشان می‌دهد مدل پیشنهادشده، مناسب‌ترین تکنیک برای پیش‌بینی قیمت است.

شفیع‌خواه و همکاران [۷] از روشی ترکیبی بر پایه WT، ARIMA و RBFN برای پیش‌بینی قیمت برق استفاده کردند. روش Wavelet-ARIMA برای تجزیه و تحلیل بخش خطی مسئله پیش‌بینی قیمت و از شبکه RBFN برای تصحیح بخش غیرخطی استفاده شد. پژوهشگران در بخش تجربی مطالعه، از داده‌های کشور اسپانیا استفاده کردند. نتایج پیش‌بینی مدل معرفی شده با مدل‌های مشابه، مؤید دقت بیشتر در برآورد قیمت‌هاست.

یونگ و همکاران [۸] از شبیه‌سازی مبتنی بر عامل به منظور پیش‌بینی قیمت برق بازار نیوزلند استفاده کردند. متغیرهای ورودی به منظور پیش‌بینی شامل قیمت‌های تاریخی، تقاضا و هزینه سوخت است.

کلس و همکاران [۹] به پیش‌بینی قیمت برق روز بعد با استفاده از شبکه عصبی پرداختند. آن‌ها از الگوریتم‌های خوشه‌بندی برای انتخاب ورودی‌های مدل استفاده کردند که نتایج آن کارایی خوبی داشت.

یانگ و همکاران [۱۰] به پیش‌بینی قیمت برق با ترکیب تبدیل موجک و ARMA مبتنی بر ماشین یادگیری سریع با هسته غیرخطی برای بازار روز بعد پرداختند. آن‌ها در این پژوهش از تبدیل موجک برای تحلیل داده‌ها و شبیه‌سازی و ارزیابی مدل ترکیبی از سه بازار پنسیلوانیا-نیوجرسی-مریلند (PJM)، استرالیا و بازار برق اسپانیا استفاده کردند.

هدف این پژوهش پیش‌بینی قیمت متوسط موزون ساعتی روز بعد در بازار برق ایران با در نظر گرفتن نوسانات

به‌دست آوردن سهم بازار، پیش‌بینی قیمت ابزاری ارزشمند برای پیشنهاد قیمت و مصون ماندن از نوسانات قیمت در بازارهای برق است که شرکت‌کنندگان در بازار استفاده می‌کنند.

پیشینه پژوهش

آزودو و واله [۲] از شبکه‌های عصبی مصنوعی به منظور یافتن قیمت بازار برای یک دوره زمانی استفاده کردند. در این پژوهش، از داده‌های تاریخی برای آموزش شبکه‌های عصبی استفاده شده است که تعداد آن‌ها به تعداد خوشه‌های یافت‌شده در داده‌های تاریخی بستگی دارد. به منظور یافتن تعداد خوشه‌ها، از روش خوشه‌بندی K-means استفاده شد. یکی از مزایای این روش در پژوهش حاضر این است که هیچ‌گونه فرض آماری در مورد توزیع احتمال داده‌های تاریخی ندارد. همچنین استفاده از این روش، به شبکه‌های عصبی اجازه یادگیری مؤثرتر از داده‌های تاریخی را می‌دهد. در پژوهش هو و همکاران [۳] عوامل مؤثر بر قیمت برق و مدل‌های گوناگون مانند ANN، ARIMA و LSSVM معرفی و مقایسه شده‌اند. در این پژوهش، برای مدل‌های مختلف پیش‌بینی ورودی‌های گوناگون مدنظر قرار گرفت که تأثیر مهم بر پیش‌بینی قیمت برق دارند. همچنین مشخص شد رویکرد سری‌های زمانی مانند ARIMA و مدل مارکوف مخفی (HMM)، داده‌های تاریخی مثل بار، قیمت و هزینه سوخت را تجزیه و تحلیل می‌کند. شبکه‌های مصنوعی نیز انعطاف‌پذیری بسیاری دارند و عوامل بیشتری مانند وضعیت آب‌وهوا، هزینه عملیاتی واحد، محدودیت‌های سیستم و... را در نظر می‌گیرند. ورونین و همکاران [۴] سری‌های زمانی قیمت روزانه برق را در دو لایه رفتار طبیعی و رفتار نوسانی تجزیه و تحلیل کرده‌اند. دو تکنیک مختلف پیش‌پردازش داده برای پردازش روند و فصلی بودن در سری‌های زمانی اعمال شده و مدل ARIMA به منظور دریافت رابطه خطی میان محدوده نرمال سری‌های قیمت و متغیر توضیحی کاربرد دارد. مدل GRACH برای مشخص کردن ویژگی‌های باقیمانده، و شبکه عصبی برای ترکیب پیش‌بینی مدل ARIMA و GRACH با قیمت‌های تاریخی و داده‌های تقاضا برای تولید محدوده نرمال نهایی پیش‌بینی استفاده شده است. راثو و سارادا [۵] مدلی را برای پیش‌بینی ساعتی قیمت در بازار برق به کمک تکنیک منطق فازی بر پایه رویکرد روزهای مشابه پیشنهاد کرده‌اند. در این مدل از روش

تاکاگی و سوگنو^۳ در سال ۱۹۸۵ ارائه داد. در این مدل (ANFIS) هدف یافتن تابع f این است که بتوان آن را به جای تابع اصلی f استفاده کرد. در نتیجه پیش‌بینی متغیر خروجی \hat{f} به ازای متغیر ورودی $X = (x_1, x_2, x_3, \dots, x_n)$ مقدار حقیقی y نزدیک باشد. مجموعه m تایی از داده‌های چند ورودی و یک خروجی به صورت رابطه زیر است:

$$y_i = f(x_{i1}, x_{i2}, \dots, x_{im}), i = 1, 2, 3, \dots, m \quad (1)$$

اکنون باید به تعیین ساختار برای ANFIS به منظور کاهش تفاوت میان مقادیر خروجی و مقادیر پیش‌بینی شده توجه کرد که می‌توان آن را به صورت زیر در نظر گرفت:

$$\min \sum_{i=1}^m [\hat{f}(x_{i1}, x_{i2}, x_{i3}, \dots, x_{im}) - y_i]^2 \quad (2)$$

در این روش از مدل فازی سوگنو (TSK) برای تقریب تابع f با \hat{f} از m بردار شامل n ورودی و خروجی $(x_i, y_i); (i = 1, 2, 3, \dots, m)$ استفاده شد.

برای بیان توضیحی ساده از فرایند ANFIS می‌توان سیستم استنباط فازی را با دو ورودی x, y و یک خروجی f و قواعد اگر-آنگاه (مقدم-تالی) مربوط را نیز با توجه به شکل ۱ در نظر گرفت.


$$\text{If } x \text{ is } A_1 \text{ and } y \text{ is } B_1 \text{ Then } f_1 = p_1x + q_1y + r_1 \quad (3)$$

$$\text{If } x \text{ is } A_2 \text{ and } y \text{ is } B_2 \text{ Then } f_2 = p_2x + q_2y + r_2 \quad (4)$$

قیمت برق است. وجه تمایز این پژوهش با پژوهش‌های گذشته، در نوع مدل استفاده‌شده برای پیش‌بینی، متغیرهای ورودی و مدل‌سازی آن‌ها، همچنین توجه به نوسانات قیمت برق است که در ادامه به جزئیات آن‌ها می‌پردازیم.

سیستم استنباط عصبی-فازی تطبیقی^۱

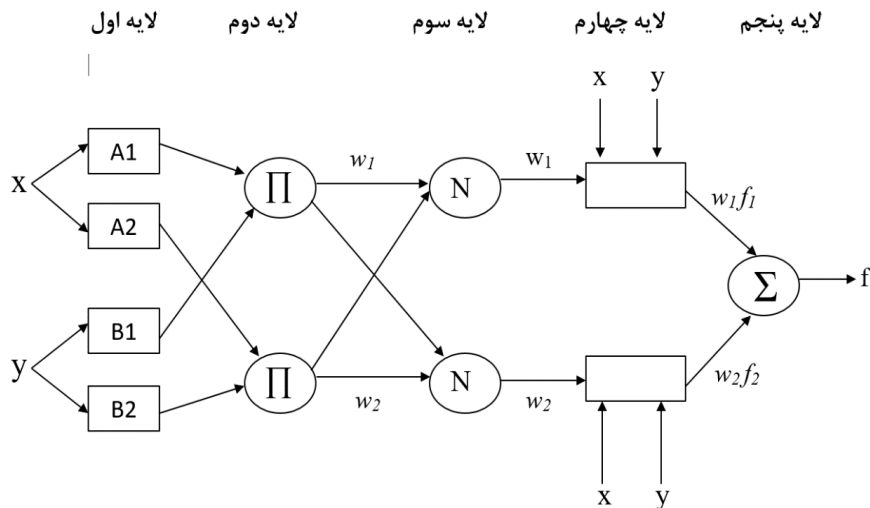
سیستم‌های استنباط فازی پس از ارائه نظریه مجموعه‌های فازی به منظور توصیف سیستم‌های پیچیده شکل گرفت که امروزه به ابزاری قدرتمند برای مدل‌سازی عدم قطعیت‌ها و عدم صراحت‌ها در دنیای واقعی در قالب روابط ریاضی تبدیل شده است. این سیستم‌ها رفتار پدیده‌ای را در قالب قواعد «اگر-آنگاه» و با استفاده از دانش خبره و داده‌های نمونه‌گیری‌شده مدل‌سازی می‌کنند. روش ایجاد قواعد و انتخاب پارامترهای توابع عضویت مسئله‌ای مهم در سیستم‌های استنباط فازی است که به درک پدیده مورد نظر و تجربه نیاز دارد. از سوی دیگر، شبکه‌های عصبی این قابلیت را دارند که از پدیده‌های مورد نظر آموزش ببینند و ساختار جفت‌های ورودی و خروجی را مرتب کنند؛ بنابراین با توجه به این شرایط، جانگ^۲ در سال ۱۹۹۳ در مقاله‌ای با عنوان «سیستم استنباط عصبی-فازی تطبیقی» مدل سیستم استنباط عصبی-فازی تطبیقی را براساس نظریه مجموعه‌های فازی و نیز با الهام از الگوی ارائه‌شده



شکل ۱. روال استدلال فازی سوگنوی مرتبه اول

توابع عضویت دیگری به منظور استدلال فازی در ANFIS استفاده کرد. ساختار سیستم استنباط عصبی-فازی تطبیقی در شکل ۲ آمده که از ۵ لایه تشکیل شده است:

شکل ۱ روال استدلال در چنین سیستمی را برای مدل سوگنوی درجه اول (F یک چندجمله‌ای درجه یک) نشان می‌دهد. در این شکل، توابع عضویت A و B به صورت مثلثی ارائه شده است. با وجود این می‌توان از



شکل ۲. ساختار سیستم استنباط عصبی-فازی تطبیقی

میزان توان برانگیختگی هر قانون با استفاده از معیار تعلق هر ورودی به توابع عضویت مربوط به دست می‌آید. رابطه ۷ خروجی این لایه را نشان می‌دهد.

$$Q_{r,i} = w_i = \mu_{A_i}(x) \mu_{B_i}(y), \quad i=1,2 \quad (7)$$

لایه سوم (لایه نرمال‌سازی): در این لایه توان برانگیختگی یک قانون در مقایسه با تمام قوانین در این لایه نرمالیزه می‌شود. گره‌های این لایه نیز از نوع گره‌های ثابت هستند که با N نشان داده شده‌اند. گره i ام در این لایه توان برانگیختگی قاعده i ام را به مجموع توان‌های برانگیختگی محاسبه می‌کند. رابطه ۸ خروجی این لایه را نشان می‌دهد.

$$Q_{r,i} = \bar{w}_i = \frac{w_i}{w_1 + w_2} \quad i=1,2 \quad (8)$$

لایه چهارم (لایه غیرفازی‌سازی): این لایه محل ترکیب متغیرهای ورودی براساس توان انتشار آن‌هاست. هر گره i در این لایه، تطبیقی است و خروجی هر گره در آن حاصلضرب توان برانگیختگی نرمالیزه‌شده در تابع خطی از متغیرهای ورودی است که با تابع زیر مشخص می‌شود.

$$Q_{r,i} = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i) \quad (9)$$

لایه اول (لایه ورودی و خروجی توابع عضویت): در این لایه، x، y متغیر ورودی به گره i و A و B اسامی متغیرهای زبانی منطبق با این گره هستند. هر گره که در این لایه قرار دارد، تطبیقی و نشان‌دهنده تابع عضویت است. همچنین به عنوان واحد حافظه به کار گرفته می‌شود. در این گره، پارامترهای توابع عضویت به عنوان پارامترهای آموزش‌پذیر بخش مقدم شناخته می‌شوند.

$$Q_{1,i} = \mu_{A_i}(x) \quad \text{for } i=1,2 \quad (5)$$

$$Q_{1,i} = \mu_{B_{i-2}}(y) \quad \text{for } i=3,4 \quad (6)$$

رابطه‌های ۵ و ۶، خروجی لایه اول با گره i ام ($Q_{1,i}$) را نشان می‌دهند که i درجه عضویت مجموعه فازی است. پارامترهای توابع عضویت در مرحله یادگیری سیستم با میانگین الگوریتم پس‌انتشار خطا به‌روز می‌شوند. همچنین میزان انتشار هریک از قوانین در کل سیستم به کمک ضریب انتشار مشخص می‌شود که ترکیبی از متغیرهای ورودی در سطح زبانی گوناگون است و حاصلضرب میانگین مقدار عضویت را به دست می‌آورد.

لایه دوم (لایه قوانین): گره‌ها در این لایه با نام Π ، گره‌های قوانین شناخته می‌شوند که خروجی آن‌ها حاصلضرب جبری ورودی‌های گره است. در این لایه،

رابطه ۹ خروجی این لایه را نشان می‌دهد.
 لایه پنجم: تنها گره این لایه، گره‌ای ثابت است که با Σ نشان داده شده است. در این گره، خروجی نهایی به صورت جمع مقادیر ورودی محاسبه می‌شود. به طوری که $\bar{w}_i f_i$ خروجی گره i ام در لایه چهارم است. در رابطه ۱۰ خروجی این لایه آمده است [۱۱].

رابطه ۹ خروجی این لایه را نشان می‌دهد.
 لایه پنجم: تنها گره این لایه، گره‌ای ثابت است که با Σ نشان داده شده است. در این گره، خروجی نهایی به صورت جمع مقادیر ورودی محاسبه می‌شود. به طوری که $\bar{w}_i f_i$ خروجی گره i ام در لایه چهارم است. در رابطه ۱۰ خروجی این لایه آمده است [۱۱].

$$Q_{\Delta,i} = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (10)$$

الگوریتم بهینه‌سازی ازدحام ذرات^۴


این الگوریتم را کندی و ابرهات^۵ در سال ۱۹۹۵ مطرح کردند. انبوه ذرات، الگوریتمی تکاملی برای بهینه‌سازی توابع غیرخطی است که مبنای رفتار اجتماعی حیوانات (مانند حرکت دسته‌جمعی پرندگان و ماهی‌ها) به شمار می‌آید. به این صورت که دسته‌ای از ذرات (به‌عنوان متغیرهای مسئله بهینه‌سازی) در محیط جست‌وجو پخش می‌شوند. واضح است برخی ذرات موقعیت بهتری از ذرات دیگر خواهند داشت. در نتیجه براساس رفتار ذرات هجومی، موقعیت دیگر ذرات در عین حال که موقعیت ذرات برتر نیز در حال تغییر است، به ذرات برتر می‌رسد. در این روش، تغییر موقعیت هر ذره براساس تجربه خود در حرکات قبلی و تجربه ذرات همسایه صورت می‌گیرد. در واقع هر ذره از برتری یا عدم برتری خود به ذرات همسایه و نسبت به کل گروه آگاه است [۱۲]. پارامترهای الگوریتم بهینه‌سازی ازدحام ذرات به صورت زیر تعریف می‌شود [۱۳]:

توده ذرات^۶: n ذره که ابتدا به صورت اتفاقی حرکت می‌کنند و تابع را به سوی پاسخ بهینه رهنمود می‌کنند. همچنین هر ذره به صورت تصادفی در توده حرکت می‌کند. این توده ذرات به صورت زیر در نظر گرفته می‌شود:

$$\text{Pop}(t) = \{x_1(t), x_2(t), \dots, x_n(t)\} \quad (11)$$

پارامتر بهترین موقعیت هر ذره $(Pbest)^7$: بهترین موقعیتی است که تاکنون ذره موفق شده است به آن دست یابد.

پارامتر بهترین موقعیت تمام ذرات $(Gbest)^8$: بهترین موقعیتی است که ذره تاکنون در میان جمعیت ذرات داشته است.



شکل ۳. نمایش مسیر حرکت ذرات هجومی

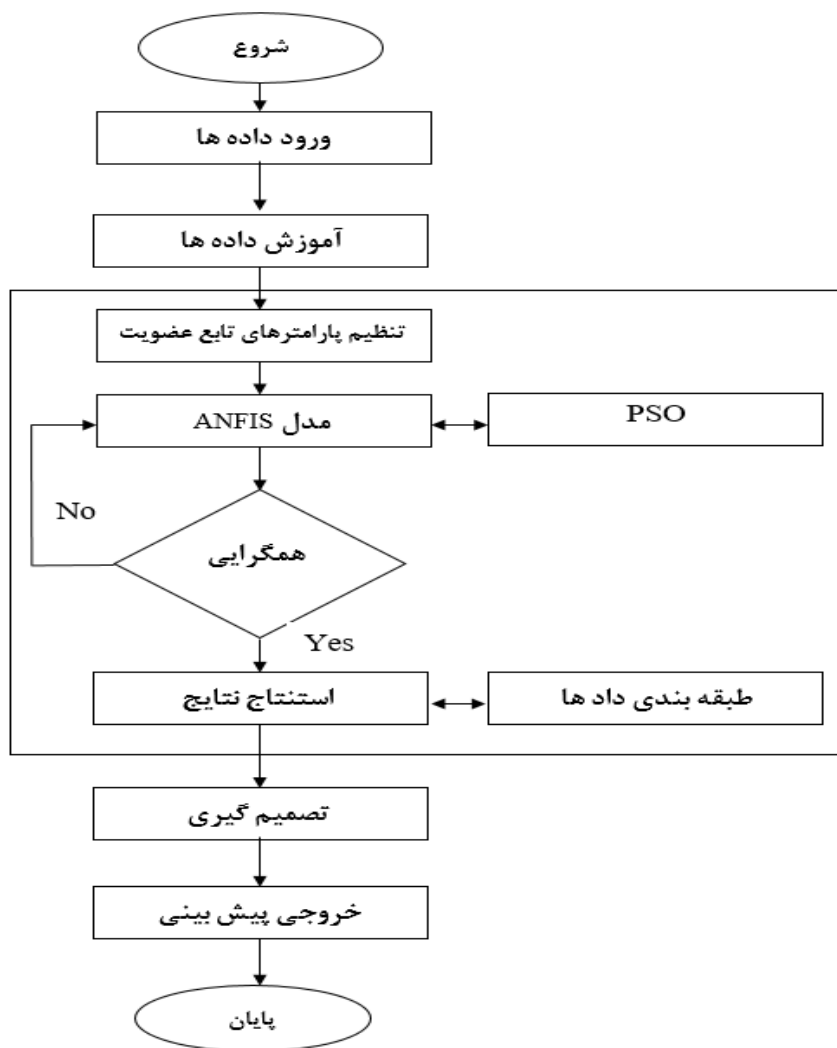
مسیر حرکت ذره i ام در شکل ۳ نشان آمده است. براین اساس موقعیت ذره در لحظه بعد با استفاده از دو پارامتر $Pbest$ و $Gbest$ به دست می‌آید. سومین ذره عامل مؤثر در موقعیت آینده ذره سرعت قبلی ذره است. این سه عامل در مجموع موقعیت آینده ذره را تشکیل می‌دهند. به عبارت دیگر:

$$X_i(t+1) = X_i(t) + V_{i,j}(t+1) \quad (12)$$

که در آن $V_{i,j}(t)$ سرعت ذره i ام که بعد m را دارد، در لحظه t ماست مقدار سرعت (نرخ تغییر موقعیت از لحظه t تا لحظه $t+1$ برای بعد j ام ذره ماست) از رابطه زیر به دست می‌آید:

$$V_{ij}(t+1) = w \cdot V_{ij}(t) + c_1 \cdot r_1 (Pbest_{ij} - X_{ij}) + c_2 \cdot r_2 (Gbest_{ij} - X_{ij}) \quad (13)$$

$$V_{ij}^{min} \leq V_{ij} \leq V_{ij}^{max} \quad (14)$$



شکل ۴. فلوچارت ترکیب شبکه‌های عصبی-فازی به کمک الگوریتم بهینه ذرات

ایجاد ساختار بهینه شبکه عصبی به کمک الگوریتم بهینه ذرات از دحام ذرات صورت بگیرد.

طراحی مدل

عوامل مؤثر بر رفتارهای قیمت به‌طور کلی به گروه‌های ساختاری، رفتاری، عملیاتی، تاریخی و عوامل خارجی تقسیم می‌شوند، اما این طبقات لزوماً جدا نیستند و با یکدیگر هم‌پوشانی دارند. اگاروال و همکاران با بررسی مطالعات در حوزه شکل‌گیری قیمت در بازار برق، متغیرهایی را که در برآورد قیمت برق استفاده می‌شوند، به‌صورت زیر دسته‌بندی کرده‌اند [۱۴].

در این پژوهش، از متغیرهای جدول ۲ استفاده شد که در ادامه به توضیح آن‌ها می‌پردازیم.

ترکیب شبکه عصبی-فازی با الگوریتم بهینه ازدحام ذرات

شناسایی و ایجاد ساختار مناسب برای سیستم‌های عصبی-فازی پیش از شروع آموزش آن در شبکه عصبی، امری ضروری و در دستیابی به نتایج نهایی بسیار اثرگذار است. ایجاد ساختاری مناسب برای سیستم عصبی-فازی به سلیقه و تجربه پژوهشگر بسیار وابسته است. در مواقعی ممکن است ساختار ایجادشده چندان بهینه نباشد و امکان بهره‌مندی از ساختارهای بهتر از آن وجود داشته باشد؛ از این‌رو در این مطالعه از ترکیب الگوریتم بهینه ذرات و سیستم عصبی-فازی استفاده می‌کنیم که فلوچارت آن در شکل ۴ رسم شده است تا شناسایی و

قیمت

مهم‌ترین متغیر در این پژوهش، قیمت است که قیمت تسویه بازار و قیمت متوسط موزون را شامل می‌شود. در این پژوهش، از قیمت متوسط موزون به‌عنوان متغیر ورودی استفاده شد؛ زیرا قیمت تسویه بازار به‌منظور تعیین برندگان و بازندگان بازار است. درحالی‌که قیمت متوسط موزون برای بررسی وضعیت بازار کاربرد دارد؛ بنابراین با توجه به اینکه روند گذشته متغیر بهترین متغیر توضیحی برای رفتار آن به‌شمار می‌آید، قیمت‌های متوسط موزون گذشته یکی از متغیرهای ورودی است.

حساسیت قیمت برق به قیمت ساعات قبل

برای محاسبه حساسیت قیمت برق به قیمت ساعات قبل، از ضریب خودهم‌بستگی^{۱۳} استفاده می‌کنیم. این ضریب به ازای پارامتر زمانی T برای سری زمانی زیر تعریف می‌شود:

$$R_{xx} = \sum_{t \in Z} x(t)x(t-T) \quad (15)$$


برای محاسبه ضریب خودهم‌بستگی قیمت یک ساعت با ساعت قبلی می‌توان قیمت‌های یک هفته را انتخاب کرد و هم‌بستگی قیمت یک ساعت را با ۱۶۸ ساعت قبل آن یافت. نتایج این امر در شکل ۵ آمده است.

جدول ۱. عوامل مؤثر بر پیش‌بینی

دسته‌بندی عوامل	متغیر مورد استفاده
مشخصه‌های بازار	بار تاریخی، نرخ بار سیستم، واردات و صادرات، مازاد یا کمبود ظرفیت مقدار رزرو، محدودیت‌های سیستم و فناوری تولیدی، مقدار تعادلی بازار به‌صورت تاریخی
عدم قطعیت غیرراهبردی	پیش‌بینی بار پیش‌بینی رزرو، دما و آب‌وهوا، قیمت نفت و گاز و سوخت مورد استفاده
عدم قطعیت تصادفی	نرخ خروج تولید، اطلاعات بازار، شاخص ازدحام
شاخص‌های رفتاری	قیمت‌های تاریخی
تأثیرات موقت	کشش تقاضا راهبرد پیشنهاددهی تولیدکننده، شاخص جهش قیمت، دوره تسویه قیمت، تمییز روز و ماه روزهای تعطیل، تغییر ساعت، فصل، تمییز زمستان و تابستان

جدول ۲. دسته‌بندی متغیرهای ورودی

شماره	متغیر ورودی	ویژگی
۱	قیمت تاریخی	شاخص‌های رفتاری
۲	بار تاریخی	مشخصه‌های بازار
۳	بار پیش‌بینی‌شده	عدم قطعیت غیرراهبردی
۴	روزهای هفته، ساعات روز، تمییز فصول	تأثیرات موقت



شکل ۵. هم‌بستگی قیمت یک ساعت با ساعات قبل

ساعت‌ها به یکدیگر شبیه هستند.

زمان

از متغیرهایی که می‌توان آن را شاخصی برای مدل‌سازی الگوی رفتاری مصرف‌کنندگان مطرح کرد زمان است. به دلیل میزان مصرف متفاوت برق در ساعات مختلف روز، متغیر «ساعت روز» را با مقادیر ۱ تا ۲۴ در نظر می‌گیریم. همچنین به منظور تمایز میان روزهای کاری و روزهای تعطیل، متغیر «روز هفته» را به صورت زیر تعریف می‌کنیم.

شنبه (روز بعد از تعطیل)؛

یکشنبه تا چهارشنبه؛

پنجشنبه (روز قبل از تعطیل عادی)؛

جمعه (تعطیل عادی).

به هریک از الگوهای طبقه‌بندی شده فوق، اعداد ۱ تا ۴ را نسبت دادیم؛ برای روز شنبه عدد ۱، روزهای یکشنبه تا چهارشنبه عدد ۲، روز پنجشنبه عدد ۳ و روز جمعه عدد ۴ را در نظر گرفتیم. به روزهای خاص تعطیل که با مناسبت‌های مذهبی و ملی تلاقی دارد (مانند روز جمعه) عدد ۴ را نسبت دادیم؛ زیرا منحنی بار این روزها به منحنی بار روز جمعه عادی نزدیک‌تر است. با توجه به مطالب بالا، فهرستی از متغیرهای ورودی مدل ترکیبی در جدول ۳ آمده است.

با توجه به شکل ۵، مجموعه زیر بیشترین وابستگی

قیمت یک ساعت را با ساعات قبل آن نشان می‌دهد.

$$\left\{ P_{h-1}, P_{h-24}, P_{h-25}, P_{h-48}, P_{h-49}, P_{h-72}, P_{h-96}, \right. \\ \left. P_{h-120}, P_{h-144}, P_{h-168} \right\}$$

بار

ورودی دیگر که در مدل‌سازی قیمت برق مدنظر قرار می‌گیرد تقاضاست؛ بنابراین از داده‌های تاریخی بار و بار پیش‌بینی شده به عنوان ورودی در مدل‌سازی استفاده شده است.

حساسیت قیمت برق به بار


برای محاسبه حساسیت قیمت یک ساعت به بار، از ضریب همبستگی متقابل^{۱۴} استفاده شده است که به صورت زیر تعریف می‌شود:

$$R_{xy} = \sum_{t \in Z} x(t)y(t-\tau) \quad (16)$$

شکل ۶، همبستگی قیمت یک ساعت را با بار ۱۶۸ ساعت قبل نشان می‌دهد. قیمت هر ساعت همبستگی بسیاری با مجموعه زیر از بارها دارد.

$$\left\{ L_h, L_{h-24}, L_{h-25}, L_{h-48}, L_{h-49}, L_{h-72}, L_{h-96}, \right. \\ \left. L_{h-120}, L_{h-144} \right\}$$

بر اساس شکل‌های ۵ و ۶، قیمت یک ساعت از شبانه‌روز بیشترین وابستگی را با قیمت و بار در همان ساعت در روزهای قبل دارد؛ زیرا رفتار قیمت و بار این



شکل ۶. همبستگی قیمت یک ساعت با بار ساعات قبل

جدول ۳. فهرست متغیرهای ورودی مدل PSO-ANFIS

شماره	متغیر	شماره	متغیر	شماره	متغیر
۱	ساعات روز	۸	قیمت متوسط ۳ روز قبل	۱۵	بار محقق شده ۲۵ ساعت قبل
۲	روزهای هفته	۹	قیمت متوسط ۱ هفته قبل	۱۶	بار محقق شده ۴۸ ساعت قبل
۳	قیمت متوسط ۱ ساعت قبل	۱۰	قیمت متوسط ۲ هفته قبل	۱۷	بار محقق شده ۴۹ ساعت قبل
۴	قیمت متوسط ۲۴ ساعت قبل	۱۱	قیمت متوسط هفته قبل	۱۸	بار محقق شده ۳ روز قبل
۵	قیمت متوسط ۲۵ ساعت قبل	۱۲	بار پیش‌بینی شده	۱۹	بار محقق شده ۱ هفته قبل
۶	قیمت متوسط ۴۸ ساعت قبل	۱۳	بار محقق شده ۱ ساعت قبل	۲۰	بار محقق شده ۲ هفته قبل
۷	قیمت متوسط ۴۹ ساعت قبل	۱۴	بار محقق شده ۲۴ ساعت قبل	۲۱	بار محقق شده ۳ هفته قبل

پیش‌پردازش داده‌ها

در مرحله پیش‌پردازش، از عملیات گوناگون ریاضی مانند نرمال‌کردن و رتبه‌بندی کردن داده‌ها استفاده می‌شود. در این پژوهش به منظور پیش‌پردازش داده‌ها از روش نرمال‌سازی استفاده شد که در رابطه ۱۷ آمده است. به کمک این روش مقدار واقعی ورودی‌ها و خروجی‌ها به بازه ۰ تا ۱ تبدیل می‌شود.

$$x_n = \frac{x_r - x_{min}}{x_{max} - x_{min}} \quad (17)$$

در رابطه فوق x_r ، x_{min} و x_{max} به ترتیب نشان‌دهنده مقادیر واقعی، نرمال‌شده، حداکثر و حداقل داده‌های بررسی شده هستند. نرمالیزه کردن داده‌ها سبب تسهیل فرایند آموزش شبکه‌های عصبی می‌شود و به کارکرد تابع تحریک کمک می‌کند. از سوی دیگر موجب می‌شود ورودی‌هایی با مقادیر بیشتر، بر ورودی‌هایی با مقادیر کوچک مانند روزهای هفته تأثیرگذار نباشند و تقارن ورودی‌های تابع محرک نیز حفظ شود.

ارزیابی مدل ترکیبی طراحی شده

به منظور ارزیابی و دقت پیش‌بینی، از سه روش اندازه‌گیری میانگین مربعات خطا^{۱۵}، جذر میانگین مربعات خطا^{۱۶} و درصد خطای مطلق میانگین^{۱۷} استفاده شد.

✓ میانگین مربعات خطا

$$MSE = \frac{1}{N} \sum_{h=1}^N (\hat{P}_h - P_h)^2 \quad (18)$$

✓ جذر میانگین مربعات خطا

$$RMSE = \frac{1}{N} \sqrt{\sum_{h=1}^N (\hat{P}_h - P_h)^2} \quad (19)$$

✓ درصد خطای مطلق میانگین

$$MAPE = \frac{100}{N} \sum_{h=1}^N \frac{|\hat{P}_h - P_h|}{\bar{P}} \quad (20)$$

$$\bar{P} = \frac{1}{N} \sum_{h=1}^N P_h \quad (21)$$

که در آن N ، تعداد دوره‌های پیش‌بینی، \bar{P} متوسط قیمت از ساعات پیش‌بینی شده، \hat{P}_h قیمت پیش‌بینی شده ساعت h ام و P_h قیمت واقعی ساعت h ام است.

نتایج شبیه‌سازی

در این بخش با استفاده از داده‌های واقعی بازار برق ایران و مدل ترکیبی طراحی شده، قیمت متوسط موزون ساعتی روز بعد پیش‌بینی می‌شود. در این شبیه‌سازی، ۷۰ درصد داده‌ها برای آموزش و بقیه برای تست در نظر گرفته شده‌اند. همچنین ۵۰ ذره برای الگوریتم انبوه ذرات و ۱۰۰۰ تکرار برای شبیه‌سازی مدنظر است. در این پژوهش از بار و قیمت متوسط موزون ساعتی بازار برق ایران در سال ۱۳۹۴ استفاده شد.

جدول ۴. ارزیابی مدل ترکیبی طراحی شده برای کل داده‌ها

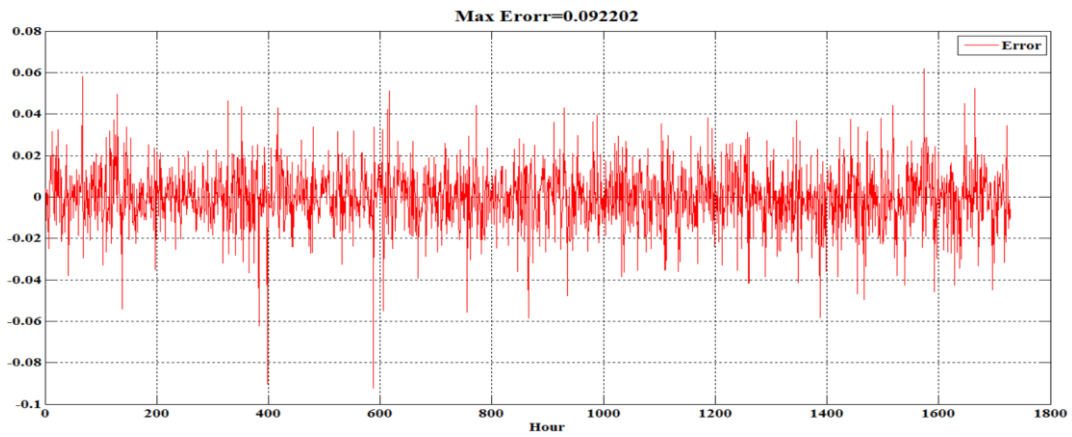
فصل	MSE	RMSE	MAPE (درصد)
بهار	۰/۰۰۰۲۱۳	۰/۰۱۴۵	۱/۴۶۱
تابستان	۰/۰۰۰۷۹۳	۰/۰۲۸۱	۲/۳۲۸
پاییز	۰/۰۰۰۴۵۴	۰/۰۲۱۳	۲/۶۸۷
زمستان	۰/۰۰۱۲۷۲	۰/۰۳۵۷	۴/۶۸۲

جدول ۵. ارزیابی مدل ترکیبی طراحی شده برای داده‌های آموزش


فصل	MSE	RMSE	MAPE (درصد)
بهار	۰/۰۰۰۲۰۵	۰/۰۱۴۳	۱/۴۲۸
تابستان	۰/۰۰۰۷۳۵	۰/۰۲۷۱	۲/۲۱۸
پاییز	۰/۰۰۰۴۶۲	۰/۰۲۱۵	۲/۶۲۸
زمستان	۰/۰۰۱۲۱۸	۰/۰۳۴۹	۴/۶۷۴

جدول ۶. ارزیابی مدل ترکیبی طراحی شده برای داده‌های تست

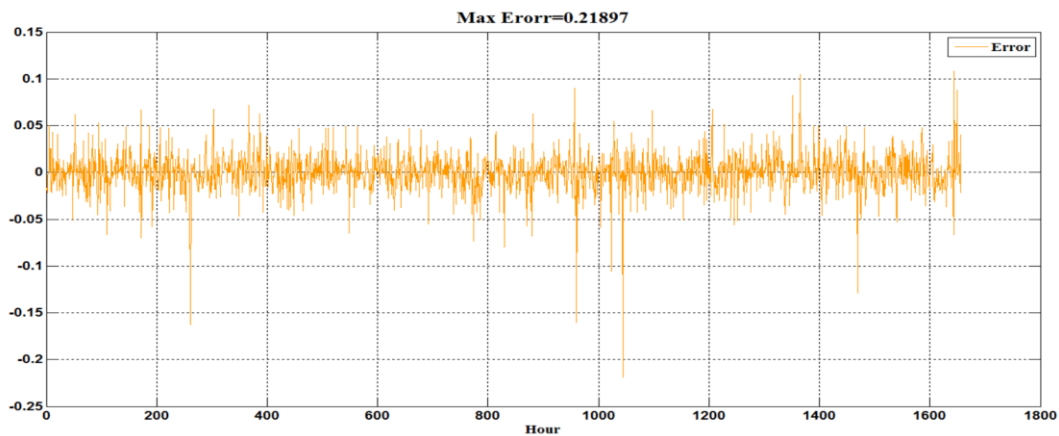
فصل	MSE	RMSE	MAPE (درصد)
بهار	۰/۰۰۰۲۲۴	۰/۰۱۵۰	۱/۵۳۸
تابستان	۰/۰۰۰۹۲۸	۰/۰۳۰۵	۲/۵۹۰
پاییز	۰/۰۰۰۴۳۶	۰/۰۲۰۹	۲/۸۱۹
زمستان	۰/۰۰۱۳۹۶	۰/۰۳۷۳	۴/۷۰۰



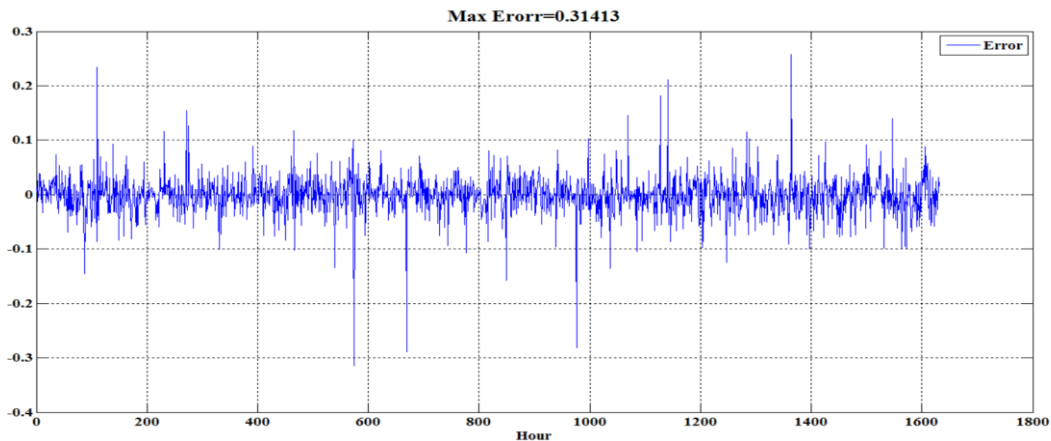
شکل ۷. سیگنال خطا برای فصل بهار



شکل ۸. سیگنال خطا برای فصل تابستان



شکل ۹. سیگنال خطا برای فصل پاییز



شکل ۱۰. سیگنال خطا برای فصل زمستان

مقایسه مدل PSO-ANFIS با دیگر روش‌ها
 برای مقایسه این مدل از روش‌های ARIMA، شبکه عصبی شعاعی پایه، شبکه عصبی-فازی و ترکیب شبکه عصبی-فازی با الگوریتم ژنتیک استفاده شد. برای متغیرهای ورودی روش‌های ذکر شده نیز جدول ۳ کاربرد داشت.

با توجه به جدول ۸، دقت روش PSO-ANFIS از روش‌های معرفی شده بیشتر است.

تأثیر جهش‌های قیمت برق در پیش‌بینی
 ضروری است در پیش‌بینی قیمت، نوسان در قیمت برق مدنظر قرار بگیرد. همچنین باید به قیمت‌هایی که در بازه‌ای از زمان در مقایسه با زمان‌های دیگر به‌طور ناگهانی تغییر می‌کنند بیشتر توجه کرد. این حالت را قیمت ضربه‌ای می‌نامند که به‌نظر می‌رسد به‌طور دقیق پیش‌بینی نمی‌شود. به هر حال می‌توان با استفاده از اطلاعات گذشته احتمال وقوع قیمت‌های ضربه‌ای را که در زمان‌های مختلف رخ می‌دهد به‌دست آورد.

شکل‌های ۷ تا ۱۰ نشان‌دهنده سیگنال‌های خطا برای هر فصل است که ماکزیمم این خطاها در جدول ۷ آمده است.

جدول ۷. ماکزیمم سیگنال خطا

فصل	بهار	تابستان	پاییز	زمستان
ماکزیمم خطا	۰/۰۹۲۲	۰/۲۹۱	۰/۲۱۹	۰/۳۱۴

لیوایز در سال ۱۹۸۲ و دلپورجیو در سال ۱۹۹۸ برای مقایسه قدرت پیش‌بینی مدل‌ها با ابزار MAPE، چهار منطقه را تعیین کردند. اگر درصد خطای مطلق میانگین کمتر از ۱۰ باشد، می‌توان قدرت پیش‌بینی مدل را دقت پیش‌بینی عالی دانست. اگر بین ۱۰ تا ۲۰ باشد پیش‌بینی خوب است. اگر در محدوده ۲۰ تا ۵۰ درصد باشد، قدرت پیش‌بینی پذیرفته است و اگر بیشتر از ۵۰ باشد، پیش‌بینی دقیق نیست؛ بنابراین با توجه به جدول‌های ۴، ۵ و ۶ درصد خطای مطلق میانگین برای هر چهار فصل کمتر از ۵ است. همچنین براساس جدول ۴ و ۵ اختلاف مقادیر خطا برای داده‌های تست و آموزش بسیار کم است که این امر کارآبودن مدل را نشان می‌دهد.

جدول ۸. مقایسه مدل PSO-ANFIS با دیگر روش‌ها (RMSE)

فصل	بهار	تابستان	پاییز	زمستان	ماکزیمم خطا
ARIMA	۰/۰۲۹	۰/۰۴۰۰	۰/۳۴۲	۰/۰۴۲۱	۰/۰۴۲۱
ANN-RBF	۰/۰۱۶۸	۰/۰۲۸۹	۰/۰۲۹۰	۰/۰۳۷۹	۰/۰۳۷۹
ANFIS	۰/۰۱۶۹	۰/۰۳۲۱	۰/۰۳۴۲	۰/۰۴۰۸	۰/۰۴۰۸
GA-ANFIS	۰/۰۱۵۲	۰/۰۲۸۲	۰/۰۲۱۶	۰/۰۳۷۰	۰/۰۳۷۰
PSO-ANFIS	۰/۰۱۴۵	۰/۰۲۸۱	۰/۰۲۱۳	۰/۰۳۵۷	۰/۰۳۵۷

معیار آن است. به کمک رابطه ۲۳ قیمت‌های ضربه‌ای کاهش می‌یابد. در جدول ۹، پیش‌بینی قیمت برق با استفاده از قیمت‌های واقعی و قیمت‌های اصلاح‌شده آمده است. در این شبیه‌سازی، از مدل ترکیبی و از متغیرهای جدول ۳ به‌عنوان ورودی مدل استفاده شده است.

جدول ۹. مقدار MAPE برای پیش‌بینی قیمت برق، قبل و بعد از اصلاح قیمت

فصل	قیمت‌های اصلاح‌نشده	قیمت‌های اصلاح‌شده
بهار	۱/۴۶۱	۱/۴۱۸
تابستان	۲/۳۲۸	۲/۲۲۸
پاییز	۲/۶۸۷	۲/۶۲۸
زمستان	۴/۶۸۲	۴/۴۰۳

با توجه به نتایج، پیش‌بینی با استفاده از قیمت‌های پردازش‌شده سبب بهبود مدل و دقت بهتر می‌شود.

نتیجه‌گیری

پس از تجدید ساختار بازار برق، تولیدکنندگان و خریداران برای تبادل برق تولیدی و موردنیاز خود در بازار رقابت می‌کنند و قیمت‌های پیشنهادی خود را در ساعات مختلف به بهره‌بردار بازار ارائه می‌دهند. قیمت‌های نقدی همراه با تغییرات زیاد و خطری که در بازار رقابتی تعیین می‌شود، رفتار فعالان بازار را تغییر می‌دهند؛ بنابراین پیش‌بینی قیمت‌ها برای تولیدکنندگان و مصرف‌کنندگان برق به‌منظور برنامه‌ریزی آتی، سرمایه‌گذاری، بهره‌برداری و مدیریت ریسک ناشی از تغییرات گسترده قیمت ضروری است. در این مقاله، برای پیش‌بینی قیمت متوسط موزون بازار برق ایران از پارامترهای قیمت‌های گذشته، بار گذشته، بار پیش‌بینی‌شده، روزهای کاری و غیرکاری، ساعات روز و تمییز فصول به‌عنوان مهم‌ترین فاکتورهای تأثیرگذار در پیش‌بینی استفاده شد. ضریب خودهم‌بستگی نیز برای تحلیل حساسیت قیمت و بار گذشته کاربرد داشت که به‌منظور انتخاب قیمت‌ها و بار تأخیری صورت گرفت.

برای شبیه‌سازی با استفاده از مدل ترکیبی، از داده‌های بازار برق ایران در سال ۱۳۹۴ استفاده شد. ۷۰ درصد این داده‌ها برای آموزش، بقیه برای تست و ۵۰ ذره برای الگوریتم انبوه ذرات در نظر گرفته شد.

جهش‌های قیمت در بازار برق رویدادی به‌شدت تصادفی است که می‌تواند به‌کمک قدرت بازار یا رویدادی پیش‌بینی‌نشده مانند پیشامد احتمالی برای تراکم انتقال در تولید صورت گرفته باشد. همچنین ممکن است از عوامل پیچیده شامل خاصیت فیزیکی سیستم قیمت سوخت، هزینه‌های راه‌اندازی، شرایط آب و هوایی و... تأثیر بپذیرد.

به‌منظور کاهش قیمت ضربه‌ای می‌توان از روش‌های گوناگونی استفاده کرد. یکی از روش‌ها این است که ابتدا حدی نهایی برای قیمت (P_c) تعریف شود. در ادامه اگر قیمتی بالاتر از این مقدار باشد، حذف می‌شود و P_c به‌جای آن قرار می‌گیرد، اما اگر قیمتی کمتر از P_c باشد، در محاسبات به‌کار گرفته می‌شود که به‌طور خلاصه به‌صورت زیر است:

$$P = \begin{cases} P_c & \text{if } P > P_c \\ P & \text{if } P \leq P_c \end{cases} \quad (22)$$

P : اطلاعات قیمت گذشته؛

P_c : قیمت حد نهایی انتخاب‌شده؛

\hat{P} : قیمت جدید بعد از پردازش.

این روش به‌دلیل سادگی بسیار برتر است، اما مسئله این است که قیمت‌های بالاتر از P_c حذف می‌شوند و در نتیجه نمی‌توان قیمت‌های واقعی را از قیمت‌های پیش‌بینی تشخیص داد؛ بنابراین از این روش استفاده می‌شود. ابتدا مانند قسمت بالا حد نهایی P_c قیمت انتخاب و سپس داده‌ها با روش زیر پردازش می‌شود:

$$\hat{P} = \begin{cases} P_c + P_c \left(\log \frac{P}{P_c} \right) & \text{if } P > P_c \\ P & \text{if } P \leq P_c \end{cases} \quad (23)$$

پس از آموزش و تست شبکه باید اطلاعات را به حالت اول بازگرداند که برای این کار از رابطه زیر استفاده می‌شود:

$$P_n = \begin{cases} P_f & \text{if } P_f \leq P_c \\ P_c \left(1 + \frac{P_f - P_c}{P_c} \right) & \text{if } P_f > P_c \end{cases} \quad (24)$$

P_f : قیمت پیش‌بینی‌شده؛

P_n : قیمت اصلاح‌شده.

در اینجا $P_c = \mu + \delta$ را در نظر می‌گیریم که در آن μ برابر میانگین و متوسط قیمت موزون برق و σ برابر انحراف

ژنتیک بیشتر است. همچنین با بررسی تأثیر نوسانات قیمت بر پیش‌بینی، مشخص شد پیش‌بینی با استفاده از روش پردازش قیمت دقت بیشتری دارد.

با توجه به پژوهش حاضر، دقت مدل PSO-ANFIS از روش‌های ARIMA شبکه عصبی شعاعی پایه، شبکه عصبی-فازی و ترکیب شبکه عصبی فازی با الگوریتم

منابع

1. Yamin, H., Shahidehpour, S., and Li, Z. (2004). "Adaptive Short-Term Electricity Price Forecasting Using Artificial Neural Networks in Restructured Power Markets", *Electrical Power and Energy Systems*, Vol. 26, No. 8, PP. 571-581.
2. Azevedo, F., and Vale, Z. (2006). "Forecasting Electricity Prices with Historical Statistical Information Using Neural Networks and Clustering Techniques", *Proceeding of IEEE PES Power Systems Conference and Exposition*, Georgia, USA, PP. 44-50.
3. Hu, L., Taylor, G., Wan, H., and Irving, M. (2009). "A Review of Short-Term Electricity Price Forecasting Techniques in Deregulated Electricity Markets", *Proceeding of 44th International Universities Power Engineering Conference*, Glasgow, UK, PP. 1-5.
4. Voronin, S., and Partanen, J. (2013). "Forecasting Electricity Price and Demand Using a Hybrid Approach Based on Wavelet Transform, ARIMA and Neural Networks", *International Journal of Energy Research*, Vol. 38, No. 5, PP. 626-637
5. Rao, N., and Sarada, K. (2013). "Price Estimation for Day-Ahead Electricity Market Using Fuzzy Logic", *International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering*, Vol. 2, No. 5, PP. 1940-1946.
6. Shrivastava, N., and Panigrahi, B. (2014). "A Hybrid Wavelet-ELM Based Short Term Price Forecasting for Electricity Markets", *International Journal of Electrical Power and Energy Systems*, Vol. 55, No. 1, PP. 41-50.
7. Shafie Khah, M., Parsamoghaddam, M., and Sheikh-el-Eslami, M. (2011). "Price Forecasting of Day-Ahead Electricity Markets Using a Hybrid Forecast Method", *Energy Conversion and Management*, Vol. 52, No. 5, PP. 2165-2169.
8. Young, D., Poletti, S., and Browne, O. (2014). "Can Agent-Based Models Forecast Spot Prices in Electricity Markets? Evidence from the New Zealand Electricity Market", *Energy Economics*, Vol. 45, No. 1, PP. 419-434.
9. Keles, D., Scelle, J., Paraschiv, F., and Fichtner, W. (2016). "Extended Forecast Methods for Day-Ahead Electricity Spot Prices Applying Artificial Neural Networks", *Applied Energy*, Vol. 162, No. 1, PP. 218-230.
10. Yang, Z., Ce, L., and Ce, L. (2017). "Electricity Price Forecasting by a Hybrid Model, Combining Wavelet Transform, ARMA and Kernel-Based Extreme Learning Machine Methods", *Applied Energy*, Vol. 190, No. 1, PP. 291-305.
11. Jang, J. S. R. (1993). "ANFIS: Adaptive-Network-Based Fuzzy Inference System", *IEEE Transaction On System*, Vol. 23, No. 3, PP. 665-685.
12. Clerc, M. (2006). *Particle Swarm Optimization*. British Library Cataloguing In Publication Data, London.
13. Kennedy, J., and Eberhart, R. (1995). "Particle Swarm Optimization." *Proceedings of IEEE International Conference on Neural Networks*, Perth, Australia, PP. 1942-1948.
14. Aggarwal, S., Saini, L., and Kumar, A. (2009). "Electricity price Forecasting in Deregulated Markets: A Review and Evaluation", *International Journal of Electrical Power & Energy Systems*, Vol. 31, No. 1, PP. 13-29.

واژه‌های انگلیسی به ترتیب استفاده در متن

1. Adaptive-Network-Based Fuzzy Inference System
2. J. S. R. Jang
3. Takagi-Sugeno
4. Particle Swarm Optimization
5. J. Kennedy and R. Eberhart
6. Swarm
7. The best Position of Individual
8. The best Position of Group
9. The Recognition of Individual
10. The Social Cognitive
11. Velocity
12. Inertia Weight
13. Auto Correlation
14. Cross-Correlation
15. Mean Square Error
16. Root Mean Square Error
17. Mean Absolute Percentage Error