

پیش‌بینی قیمت روزانه برق با شبکه عصبی بهبودیافته مبتنی بر تبدیل موجک و روش آشوبناک جستجوی گرانشی

حسین شایقی^۱، استاد، علی قاسمی^۲، دانشجوی دکتری

۱ و ۲ - دانشکده مهندسی برق - دانشگاه محقق اردبیلی - اردبیل - ایران

1-hshayeghi@gmail.com, 2-ghasemi.agm@gmail.com

چکیده: با سمت‌گیری و تغییر ساختار بازار برق از بازار انحصاری دولتی به بازار رقابتی که در آن قیمت توسط نیروهای بازار تعیین می‌شود، نیاز به طراحی مدلی کارا و مناسب به‌گونه‌ای که ریسک شرکت در بازار رقابتی برای فعالان بازار برق را در جهت افزایش سوددهی آن‌ها کاهش دهد، اهمیت ویژه‌ای یافته است. برای مدل‌سازی و پیش‌بینی قیمت برق در بازار رقابتی باید خصوصیات این کالا از جمله عدم قابلیت ذخیره‌سازی، کم‌کشش بودن و فصلی بودن تقاضا را در نظر گرفت. مدل ایجادشده در صورتی که بتواند با ایجاد رابطه‌ای از داده‌های قبلی، کم‌ترین خطای پیش‌بینی را داشته باشد، مؤثرتر و کارآمدتر خواهد بود. در مدل‌های کلاسیک ارائه‌شده در مسئله پیش‌بینی قیمت برق با تنوع تعداد متغیرهای ورودی و عدم پیروی متغیرها از یک مدل سری مشخص، خطای ناشی از پیش‌بینی افزایش خواهد یافت. در این مقاله با انگیزه دست‌یابی به کم‌ترین خطای پیش‌بینی و برطرف کردن نواقص روش‌های قبلی، از روشی ترکیبی تبدیل موجک برای کم کردن نوسانات در داده‌های ورودی و به‌منظور افزایش دقت پیش‌بینی از شبکه عصبی بهبودیافته مبتنی بر ساختار غیرخطی برای آموزش و یادگیری بهتر بر روی مقادیر گذشته قیمت برق و استفاده از آن برای اطلاعات آینده و از ایده ترکیبی جدید نظریه آشوب با فن جستجوی گرانشی سعی در یافتن بهترین وزن‌ها و بایاس‌ها برای حداقل کردن مربعات خطای پیش‌بینی بهره گرفته شده است. به‌منظور نشان دادن کارایی روش پیشنهادی در حل مسئله پیش‌بینی قیمت بازار برق در مقایسه با سایر روش‌های اخیر انجام‌گرفته در این زمینه، از داده‌های بازارهای واقعی مانند اسپانیا و ایران استفاده شده است. نتایج نشان از دقت بالا و خطای کم‌تر در پیش‌بینی می‌دهد. همچنین قابلیت جستجوی محلی و نهایی الگوریتم هوشمند ارائه‌شده در تنظیم وزن‌ها و بایاس‌های شبکه عصبی به‌طور قابل‌ملاحظه‌ای بهبود یافته است.

واژه‌های کلیدی: پیش‌بینی قیمت، الگوریتم بهبود جستجوی گرانشی، تبدیل موجک، نظریه آشوب.

Day-Ahead electricity price forecasting using WT, ANN and Chaotic gravitational search model

H. Shayeghi¹, Professor, A. Ghasemi², Ph.D. student

1& 2-Technical Engineering Department, University of Mohaghegh Ardabili, Ardabil, Iran

1-hshayeghi@gmail.com, 2-ghasemi.agm@gmail.com

Abstract: With the deregulation of electric power systems, market participants are facing an important task of bidding energy to an Independent System Operator (ISO). Modeling and electricity prices forecasting in competitive market relative with its characteristics such as inability to store, non-stationary and time variant behavior and seasonality violation should be considered. A model with more accuracy and less error will be more efficient which a price forecast with a less prediction errors, yields maximum profits for market players. To achieve more accurate and robust price forecast, in this paper, a new hybrid forecast technique based on Wavelet Transforms (WT), feature selection technique, Artificial Neural Network (ANN) and Gravitational Search Algorithm (GSA) combined with Chaotic Local Search (CLS) model is proposed for day-ahead electricity price forecasting. The feature selection method is an improved version of the Mutual Information (MI) technique. The superiority of this proposed method is examined by using the data acquired from the Iran and market clearing price (MCP) of Spanish market. Empirical results show that the proposed method performs better than some of the other price forecast methods. Also, the exploitation and exploration of the proposed intelligent algorithm for tuning weight and bias parameters of ANN is improved.

Keywords: Price forecasting, modified gravitational search algorithm, wavelet transforms, chaos theory.

تاریخ ارسال مقاله: ۱۳۹۳/۰۳/۱۰

تاریخ اصلاح مقاله: ۱۳۹۳/۰۵/۳۱

تاریخ پذیرش مقاله: ۱۳۹۳/۰۶/۲۷

نام نویسنده مسئول: حسین شایقی

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

۱- مقدمه

می‌توان از آن به‌عنوان پردازشگر اطلاعات اشاره نمود، بر اساس شبکه عصبی انسان در یادگیری مدل‌سازی شده است. به‌عبارتی دیگر یک شبکه عصبی مدلی از نرون‌های عصبی مغز است. در راستای استفاده از این الگو، مقالات متعددی در زمینه پیش‌بینی انجام گرفته است. در مرجع [۸] از روش شبکه عصبی به پیش‌بینی قیمت تسویه بازار برق انگلستان پرداخته شده است. در جهت کاهش خطای حاصل از پیش‌بینی و افزایش قابلیت‌های شبکه عصبی، در مرجع [۹] مدلی جدید در معماری یادگیری شبکه عصبی به کمک تابع تبدیل به‌گزینه موجک ارائه گشته است. در مرجع [۱۰] از مدل سری زمانی و شبکه عصبی که در حقیقت از ترکیب دو سیستم خطی و غیرخطی به دست آمده است، سعی در ایجاد رابطه‌ای مناسب بین داده‌های ورودی در جهت کاهش خطای پیش‌بینی انجام گرفته است. یکی از نقاط ضعف شبکه عصبی عدم تصمیم‌گیری آن در داده‌های لاجیک (منطقی) است. به‌منظور افزایش قابلیت یادگیری شبکه عصبی در مرجع [۱۱] از یک روش ترکیبی فازی-عصبی تحت عنوان نرو فازی استفاده شده است. در حقیقت این روش اصلاحی بر روش‌های مبتنی بر شبکه عصبی و سری‌های زمانی بوده است.

با وجود کارهای انجام‌گرفته همچنان فقدان یک تکنیک مناسب برای مرتب‌سازی داده‌های ورودی در آن‌ها نمایان است. به‌منظور بهبود این نقطه‌ضعف از الگوریتم انتخاباتی برای مرتب‌سازی داده‌ها بهره گرفته شده است تا بهترین گزینه‌ها با بیش‌ترین همبستگی برای آموزش وارد شبکه عصبی شوند. همچنین در این مقاله با در نظر گرفتن جنبه‌های مثبت روش‌های انجام‌گرفته و به‌منظور کاهش خطای ناشی از نوسانات غیرخطی داده‌های ورودی از تبدیل موجک بهره گرفته شده است. با به‌کارگیری تبدیل موجک، داده‌ها می‌توانند در چند بخش مجزا تقسیم‌شده که هر بخش می‌تواند بر اساس یک سری زمانی قابل توجیه باشد. این عمل قابلیت شبکه عصبی در آموزش و یادگیری را افزایش می‌دهد. به‌عبارتی دیگر، وضوح چندگانه در زمان و فرکانس که توسط تبدیل موجک فراهم می‌شود اجازه پیش‌بینی دقیق و درعین حال نگاه‌داری آسان‌تر اطلاعات را فراهم می‌سازد.

یکی از مهم‌ترین نقاط ضعف شبکه عصبی تنظیم مناسب پارامترهای آن است. در کارهای انجام‌گرفته شده با روش‌های هوشمند از جمله ژنتیک و اجتماع ذرات می‌توان اهمیت ترکیب شبکه عصبی و روش‌های هوشمند را درک نمود. اما این روش‌ها دارای نقاط ضعف در جستجوی محلی و کلی بوده که تنظیم مناسب پارامترهای شبکه عصبی به کمک آن‌ها به‌خوبی انجام نخواهد گرفت. به همین دلیل نیاز به یک روش هوشمند مناسب بیش‌ازپیش احساس می‌شود. یکی از الگوریتم‌های جدید در زمینه بهینه‌سازی روش جستجوی گرانشی است. الگوریتم جستجوی گرانشی بر مبنای قانون گرانش عمل می‌نماید و برخلاف سایر الگوریتم‌های مبتنی بر گروه ذرات دارای هویت است. یکی دیگر از قابلیت‌های الگوریتم جستجوی گرانشی افزایش قابلیت جستجوی آن در ترکیب شدن با سایر روش‌ها است. در این مقاله

امروزه بازار برق بیش‌ازپیش به همکاری با سایر بازارها از جمله بازار سوخت، خدمات جانبی و آلودگی می‌پردازد. بنابراین تصمیم‌گیری برای فعالان بازار در جهت افزایش سودهای به‌مراتب پیچیده‌تر شده است. درحالی‌که در بازار سنتی یا انحصار دولتی، قیمت برق به‌صورت دستوری و تابع هزینه‌های عرضه و سیاست‌های صنعتی و اجتماعی دولت‌ها تعیین می‌شد به‌گونه‌ای که انگیزه برای افزایش رقابت کاهش می‌یافت. در پی تجدید ساختار بازار برق در بسیاری از کشورها، قیمت در بازار رقابتی و متأثر از نیروهای بازار و از طریق اثر متقابل توابع پیچیده عرضه و تقاضای برق تعیین می‌گردد. 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 می‌نمایند. قیمت‌های نقدی همراه با تغییرات زیاد و ریسک که در بازار رقابتی تعیین می‌شود، رفتار فعالان بازار برق را تغییر خواهد داد و لذا پیش‌بینی قیمت‌ها برای تولیدکنندگان و مصرف‌کنندگان برق جهت برنامه‌ریزی آتی، سرمایه‌گذاری و بهره‌برداری و مدیریت ریسک ناشی از تغییرات گسترده قیمت ضروری هست. همچنین در ضرورت این امر می‌توان به عدم ذخیره‌سازی آن اشاره نمود که در نتیجه نوسانات تقاضا (این نوسانات به شرایط آب و هوایی، فعالیت‌های اقتصادی، تعطیلات، جشن‌ها، روزهای کاری و روزهای غیر کاری و ... بستگی دارد) موجب نوسانات شدید قیمت برای این کالا می‌شود. برای پیش‌بینی صحیح قیمت‌های ارائه‌شده در بازار برق باید این ویژگی‌ها را لحاظ نمود و از ابزارهای مدل‌سازی لازم برای در نظر گرفتن این خصوصیات استفاده نمود [۱].

با توجه به اهمیت موضوع، تاکنون روش‌های متعددی در این زمینه ارائه شده است که می‌توان آن‌ها را در دودسته تقسیم‌بندی نمود. در دسته اول مبتنی بر روش سری زمانی و دسته دوم مبتنی بر سیستم یادگیری یا هوش مصنوعی است. در هر دودسته با توجه به افزایش قابلیت آن‌ها، بهبودهای مختلفی در جهت کاهش خطای پیش‌بینی قیمت برق انجام گرفته است. در روش سری زمانی می‌توان به رگرسیون دینامیکی و تابع تبدیل [۲]، خود رگرسیون جمعی میانگین متحرک [۳]، خود رگرسیون واریانس شرطی [۴]، روش ترکیبی خود رگرسیون جمعی میانگین متحرک و خود رگرسیون واریانس شرطی [۵]، روش ترکیبی تبدیل موجک و خود رگرسیون جمعی میانگین متحرک [۶] و روش خود رگرسیون واریانس شرطی تعمیم‌یافته [۷] اشاره نمود. اگرچه این روش‌ها به خاطر سادگی در پیاده‌سازی و خطی بودن موردتوجه قرار گرفته‌اند اما در سیستم غیرخطی کارایی کافی نداشته و خطای پیش‌بینی را به‌طور چشمگیری افزایش می‌دهند.

در دسته روش‌های هوشمند و ساختارهای بهبودیافته آن، به کمک مدل غیرخطی سعی در آموزش بهتر شبکه داشته تا بتوان کمترین خطای حاصل را ایجاد نمود. در شبکه عصبی مصنوعی که

۲-۱- پیش‌پردازش اطلاعات

الف) تبدیل موجک گسسته

این آنالیز به‌عنوان یک ابزار عددی می‌تواند مانند تبدیل سری فوریه تا حد زیادی از پیچیدگی محاسبات بزرگ‌مقیاس بکاهد، بدین ترتیب که با تغییر هموار ضریب، ماتریس‌های متراممکن را به شکل دسته‌های از سری که به سرعت و دقت قابل‌محاسبه باشند، تبدیل می‌نماید. راحتی و سادگی این آنالیز باعث حرکت این تابع به سمت مسئله پیش‌بینی شده است. تبدیل موجک دارای دو نوع متعارف گسسته و پیوسته است. تبدیل موجک پیوسته را می‌توان به‌صورت مجموع حاصل‌ضرب سیگنال اصلی در موجک‌های تغییر مقیاس یافته و انتقال داده‌شده در زمان نمایش داد. در صورت استفاده از تبدیل موجک پیوسته، حجم اطلاعات بسیار زیاد می‌شود؛ زیرا باید برای مقیاس‌های مختلف در طول زمان از سیگنال انتگرال‌گیری نمود. بنابراین، حجم اطلاعات و بار محاسباتی بسیار زیاد می‌شود. ضمناً، در برخی از موارد ممکن است به یک تابع غیر تحلیلی برخورد کنیم که امکان انتگرال‌گیری از آن وجود نداشته باشد یا اینکه انتگرال جواب خاصی نداشته باشد. به همین دلیل استفاده از تبدیل موجک گسسته مناسب‌تر است. چراکه یک مسئله پیش‌بینی دارای ابعاد فراوانی بوده و گاهی حل ماتریس‌های حاصل از این داده‌های ورودی به‌راحتی قابل آنالیز نیست. این تبدیل ویژگی‌های بسیار مناسبی را ارائه می‌دهد که از جمله آن‌ها می‌توان به موارد زیر اشاره نمود.

۱) به‌اندازه‌ی کافی اطلاعات موردنیاز را برای تحلیل و بررسی موج اصلی ارائه می‌دهد.

۲) حجم بار محاسباتی موردنیاز را به‌طور قابل‌ملاحظه کاهش می‌دهد.

۳) می‌توان توسط آن سیگنال اصلی را در فرکانس‌های مختلف و با وضوح‌های کاملاً متفاوت بررسی و تحلیل نمود.

در ادامه به مدل‌سازی این تابع تبدیل در هیبرید شدن با شبکه عصبی به‌منظور افزایش کارایی شبکه در پیش‌بینی می‌پردازیم. فرض کنید $\psi(t)$ به‌عنوان یک تابع مربع انتگرال به‌صورت $\psi(t) \in L^2(R)$ و تابع بسط فوریه $\hat{\psi}(t)$ به‌صورت زیر بیان شود:

$$\int_R \frac{|\hat{\psi}(\omega)|^2}{|\omega|} d\omega < +\infty \quad (1)$$

که در این معادله $\psi(t)$ به‌عنوان تابع موجک بیان می‌شود. که این تابع به‌صورت زیر بیان می‌شود:

$$\psi_{a,b}(t) = \frac{1}{\sqrt{|a|}} \psi\left(\frac{t-b}{a}\right) \quad , a, b \in R; a \neq 0 \quad (2)$$

با در نظر گرفتن تابع بالا به‌عنوان یک شبکه سری از داده‌ها، a و b به‌عنوان ضرایب آن‌ها شناخته می‌شوند. در این حالت با در نظر گرفتن $f(t) \in L^2(R)$ به‌عنوان یک تابع بر اساس تبدیل موجک، این تابع به‌صورت زیر قابل تفکیک است:

به‌منظور آموزش بهتر شبکه عصبی و کاهش تابع برازندگی یعنی حداقل کردن متوسط خطای خروجی، از الگوریتم جستجوی گرانشی مبتنی بر نظریه آشوب بهره گرفته شده است. از آنجاکه اطلاعات به‌صورت بی‌نظم در فضا جستجو قرار دارند، بهره‌گیری از این تکنیک به‌طور قابل‌ملاحظه‌ای سرعت همگرایی، دقت یافتن در جواب نهایی، قرار نگرفتن در نقاط محلی، انحراف معیار کم و مقاوم بودن را به همراه خواهد داشت. به‌عبارتی‌دیگر، دلیل منطقی برای استفاده از جستجوی آشوب را می‌توان در ساختار غیرخطی اطلاعات ورودی (قیمت برق) دانست. روش پیشنهادی بر روی بازار برق اسپانیا و ایران به‌عنوان سیستم‌های واقعی با اطلاعات موجود، مورد بحث و بررسی قرار گرفته است. مهم‌ترین ویژگی این مقاله را می‌توان در ارائه تبدیل موجک برای دسته‌بندی اطلاعات ورودی، استفاده از الگوریتم انتخاباتی با در نظر گرفتن عدم قطعیت به‌منظور تعیین بهترین ورودی‌ها و ارائه روش آشوبناک به‌منظور افزایش قابلیت جستجو در فضا مورد مطالعه، دانست.

در ادامه مقاله در بخش‌های زیر پیگیری می‌شود: بخش دوم به معرفی ابزارهای پیشنهادی، بخش سوم نحوه فلوچارت پیشنهادی بیان می‌شود. در بخش چهارم سیستم‌های مورد مطالعه و نتایج مورد بحث و بررسی قرار خواهند گرفت و نهایتاً در بخش آخر به نتیجه‌گیری اختصاص یافته است.

۲-۲ فرمول‌بندی مسئله پیش‌بینی

هر مسئله پیش‌بینی از قسمت‌های مختلفی تشکیل شده که وظایف خاص خود را خواهند داشت. در حقیقت هر بخش به‌عنوان یک ابزار پیش‌بینی موردتوجه محقق قرار می‌گیرد. به‌عبارتی‌دیگر هر بخش می‌تواند از تکنیک‌های مختلفی بهره بگیرد که در ادامه به معرفی این بخش‌های و تکنیک‌های بکار گرفته‌شده در آن می‌پردازیم:

بخش اول: پیش‌پردازش اطلاعات: در این قسمت تبدیل موجک گسسته و الگوریتم انتخاباتی پیشنهادی با جزئیات بیشتری معرفی می‌شوند.

بخش دوم: آموزش - پیش‌بینی: شبکه عصبی و الگوریتم جستجوی گرانشی بهبودیافته در این بخش قرار می‌گیرند.

بخش سوم: تعیین خطای پیش‌بینی: معیارهای حاصل از پیش‌بینی و محاسبه خطای پیش‌بینی بیان می‌شود.

درنهایت با معرفی این ابزارها و تکنیک‌ها، در بخش بعدی فلوچارت پیشنهادی و ارتباط بین آن‌ها به‌صورت مناسب‌تری بیان می‌شود.

$$H(Y/X) = \sum_{i=1}^n P(X_i) H(Y/X = X_i) =$$

$$-\sum_{i=1}^n P(X_i) \sum_{j=1}^m P(Y_j/X_i) \log_2(P(Y_j/X_i)) = \quad (10)$$

$$-\sum_{i=1}^n \sum_{j=1}^m P(X_i, Y_j) \log_2(P(Y_j/X_i))$$

بنابراین مقدار کل آنتروپی به صورت زیر قابل بیان است:

$$H(X, Y) = H(X) + H(Y/X) = H(Y) + H(X/Y) \quad (11)$$

به منظور مرتب‌سازی داده‌ها روش تقابلی به صورت فرموله می‌شود:

$$MI(X, Y) = \sum_{i=1}^n \sum_{j=1}^m P(X_i, Y_j) \log_2 \left(\frac{P(X_i, Y_j)}{P(X_i)P(Y_j)} \right) \quad (12)$$

مقدار عددی بزرگ برای فرمول (۱۲) نشان از همبستگی بالا بین دو عضو X و Y است و بالعکس. نحوه فرمول‌بندی برای روش تقابلی و آنتروپی در شکل ۱ نشان داده شده است.


$$MI(X, Y) = H(X) - H(X/Y) \quad (13)$$

$$MI(X, Y) = H(Y) - H(Y/X) \quad (14)$$

$$MI(X, Y) = H(X) + H(Y) - H(X, Y) \quad (15)$$

$$MI(X, Y) = MI(Y, X) \quad (16)$$

$$MI(X, X) = H(X) \quad (17)$$



شکل ۱: توزیع و انتخاب بر اساس تابع تقابلی

حال فرض کنیم متغیر Y میزان عدم قطعیت آن در نظر گرفته شود در این صورت اگر بین X و Y مقدار تابع تقابلی زیاد باشد می‌توان برای X هم عدم قطعیت محاسبه نمود. حال فرض کنید داده‌های ورودی به صورت Y_1, Y_2, \dots, Y_N تعریف شوند، در این صورت برای متغیر Y_m که بیش‌ترین تقابل بر اساس رابطه $MI(X, Y_m)$ با متغیر هدف X داشته باشد، X بهترین داوطلب برای پیش‌بینی است. به عنوان مثال برای پیش‌بینی قیمت با تعداد کاندید ۲۰۰ ساعت قبل که به صورت $(P_{h-1}, P_{h-2}, \dots, P_{h-200})$ تعریف شده است نیاز به $h-24, h-48, h-72, \dots, h-192$ ساعت قبل داریم.

۲-۲- آموزش و پیش‌بینی

این قسمت از شبکه عصبی و الگوریتم هوشمند جستجوی گرانشی تشکیل شده است. که در ادامه به معرفی هر یک از این ابزارها خواهیم پرداخت.

$$W_f(a, b) = \langle f, \psi_{a,b} \rangle = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{+\infty} f(t) \psi\left(\frac{t-b}{a}\right) dt \quad (3)$$

با دوباره نویسی توابع فوق خواهیم داشت:

$$f(t) = C_{\psi}^{-1} \iint_{-\infty}^{+\infty} W_f(a, b) \psi\left(\frac{t-b}{a}\right) \frac{da db}{a^2} \quad (4)$$

در این توابع قیدشده در بالا تابع $\psi(t)$ نقش قسمت مشاهده‌گر را بازی می‌نماید که باید در قید زیر برقرار شود:

$$\int_{-\infty}^{+\infty} \psi(t) dt < \infty \quad (5)$$

$$\int_{-\infty}^{+\infty} \psi(t) dt = 0 \quad (6)$$

ب) سیستم پیش‌پردازش کننده در انتخاب بهترین داده‌ها

برای روش‌های پیش‌بینی به کمک شبکه عصبی یکی از مهم‌ترین مراحل انتخاب مؤلفه‌های ورودی است. در این مرحله باید تصمیم‌گیری شود که کدام دسته از متغیرهای ورودی سیستم دارای بیش‌ترین ارزش در پیش‌بینی می‌باشند. روش به کار گرفته شده در این مقاله استفاده از الگوریتم انتخاباتی برای تعیین بهترین زیرمجموعه به عنوان ورودی برای مسئله پیش‌بینی است [۱۲]. به این منظور، معیار آنتروپی $H(X)$ برای مجموعه اعداد نامنظم X بر اساس توزیع احتمالاتی $P(X)$ به صورت زیر قابل بیان است:

$$H(X) = -\sum P(X) \log_2(P(X)) \quad (7)$$

اگر مقادیر X_1, X_2, \dots, X_n به عنوان مقادیر تصادفی ورودی با تابع احتمالاتی $P(X_1), P(X_2), \dots, P(X_n)$ تعریف شوند، در این صورت $H(X)$ به صورت زیر قابل بازنویسی خواهد بود:

$$H(X) = -\sum_{i=1}^n P(X_i) \log_2(P(X_i)) \quad (8)$$


بر اساس دو رابطه (۷) و (۸) آنتروپی اغلب یک مقدار از عدم قطعیت را در نظر می‌گیرد. به منظور شفاف شدن بحث، فرض نمایم که متغیر X وجود از بیماری D را نشان می‌دهد. بنابراین اگر عدم قطعیت در مورد بیماری وجود نداشته باشد در این صورت $[P(X=D)=1, P(X=\bar{D})=0]$ و یا اگر بیماری اصلاً وجود ندارد در این صورت $[P(X=D)=0, P(X=\bar{D})=1]$ در نتیجه آنتروپی برابر با صفر است. اگر وجود یا عدم وجود بیماری به صورت عدم قطعیت اعمال شود در این صورت $[P(X=D)=P(X=\bar{D})=0.5]$ و مقدار آنتروپی برابر با ۱ خواهد شد. به طور کلی اگر هر یک N بیماری دارای احتمال $[P(X)=1/N]$ باشد در این صورت $H(X)$ دارای بیش‌ترین مقدار $\log_2(N)$ است. برای تعمیم این بحث، مجموع آنتروپی با دو عضو X و Y به صورت زیر قابل بیان خواهد بود:

$$H(X, Y) = -\sum_{i=1}^n \sum_{j=1}^m P(X_i, Y_j) \log_2(P(X_i, Y_j)) \quad (9)$$

با در نظر گرفتن عدم قطعیت برای یک سرای از داده‌ها، مقدار عدم قطعیت سایر متغیرها به صورت زیر تعریف می‌شوند:

الف) الگوریتم جستجوی گرانشی

الگوریتم جستجوی گرانشی یک الگوریتم وابسته به هوش جمعی و بدون حافظه است. این الگوریتم بهینه‌سازی با الگوبرداری از قوانین جاذبه و حرکت عوامل در یک سیستم مصنوعی در زمان گسسته طراحی شده است که در آن، فضای سیستم همان محدوده تعریف مسئله است. بر طبق قانون گرانش هر جرم، محل و وضعیت اجرام دیگر را از طریق جاذبه گرانشی درک می‌کند که در شکل ۲ نمایش داده شده است. بنابراین از این نیرو می‌توان برای تبادل اطلاعات استفاده نمود.



شکل ۲: نحوه وارد شدن متقابل نیروها از سوی اجرام بر یکدیگر

از بهینه‌یاب طراحی شده، می‌توان برای حل مسئله بهینه‌سازی که در آن هر جواب مسئله به صورت یک موقعیت در فضا قابل تعریف است و میزان شباهت آن با سایر جواب‌های مسئله به صورت یک فاصله قابل بیان باشد، استفاده نمود. میزان اجرام با توجه به تابع هدف تعیین می‌شوند [۱۳]. در این الگوریتم، جرم عامل‌ها با توجه به تابع هدف تأمین می‌شوند. در یک سیستم با n جرم، موقعیت هر جرم، نقطه‌ای از فضا است که جوابی از مسئله است که موقعیت جرم نام با X_i نشان داده شده و به صورت زیر قابل بیان است:

$$X_i = (x_i^1, \dots, x_i^d, \dots, x_i^n) \quad (18)$$

در رابطه بالا n بعد مسئله و همچنین x_i^d بعد d از جرم نام است. در این سیستم، به جرم i در زمان t و در جهت بعد d نیرویی به مقدار $F_{ij}^d(t)$ وارد می‌شود. اندازه این نیرو از رابطه زیر قابل محاسبه است:

$$F_{ij}^d(t) = G(t) \frac{M_{pi}(t) \times M_{qj}(t)}{R_{ij}(t) + \epsilon} (x_j^d(t) - x_i^d(t)) \quad (19)$$

در رابطه بالا، جرم گرانشی فعال جرم j ، جرم گرانشی غیرفعال جرم i است که هر دوی آن‌ها در الگوریتم ذکر شده یکسان و برابر M در نظر گرفته شده‌اند؛ و $G(t)$ ثابت گرانش در زمان t فاصله مابین دو جرم نام و نام و یک عدد خیلی کوچک است. ثابت گرانش، یک پارامتر مناسب برای کنترل توانایی‌های جستجو و بهره‌وری به شمار می‌آید که با رابطه زیر بیان می‌شود:

$$G(t) = G_0 e^{-\frac{at}{T}} \quad (20)$$

که در رابطه بالا α و G_0 ضرایب کنترلی الگوریتم و T بیانگر طول عمر سیستم است نیروی وارد بر جرم نام در زمان t طبق رابطه (۲۱) برابر است با مجموع تمام نیروهایی که سایر جرم‌های سیستم بر این جرم

وارد می‌کنند در این رابطه $rand_j$ یک عدد تصادفی با توزیع یکنواخت در بازه (۰،۱) بوده که برای حفظ خصوصیت تصادفی بودن در نظر گرفته شده است.

$$F_i^d(t) = \sum_{j=1, j \neq i}^N rand_j F_{ij}^d(t) \quad (21)$$

همچنین، هر یک از جرم‌ها دارای سرعت و شتاب است که هر کدام از آن‌ها به ترتیب در معادله (۵) نشان داده شده است. با توجه به قانون دوم نیوتن، هر جرم در جهت بعد d شتابی می‌گیرد که با نیروی وارد بر جرم در آن بعد، تقسیم بر جرم اینرسی آن که در رابطه (۲۱) بیان شده است، متناسب است از طرف دیگر سرعت هر عامل در زمان برابر است با مجموع ضریبی از سرعت فعلی و شتاب عامل که طبق رابطه (۲۳) بیان می‌شود.

$$v_i^d(t+1) = rand \times v_i^d(t) + a_i^d(t) \quad (22)$$

$$a_i^d(t) = \frac{F_i^d(t)}{M_i(t)} \quad (23)$$

زمانی که شتاب و سرعت هر جرم محاسبه شد موقعیت جدید عامل نام در بعد d محاسبه می‌گردد.

$$x_i^d(t+1) = x_i^d(t) + v_i^d(t+1) \quad (24)$$

موقعیت‌های جدید به عنوان مکان اجرام جدید در فضای جستجو در نظر گرفته می‌شوند، که وزن اجرام جدید به وسیله معادلات زیر نرمالیزه خواهند گشت:

$$m_i(t) = \frac{fit_i(t) - worst(t)}{best(t) - worst(t)} \quad (25)$$

$$M_i(t) = m_i(t) / \sum_{j=1}^N m_j(t) \quad (26)$$

که در معادله فوق $fit_i(t)$ نمایانگر میزان برآزندگی جرم عامل نام در زمان t ، $worst(t)$ و $best(t)$ به ترتیب بیانگر میزان شایستگی بدترین و بهترین عامل جمعیت در زمان هستند که اندازه آن‌ها در مسائل کمینه‌یابی با استفاده از روابط زیر قابل محاسبه است:

$$worst(t) = \max\{fit_i(t)\} \quad (27)$$


$$best(t) = \min\{fit_i(t)\} \quad (28)$$

ب) الگوریتم آشوبناک جستجوی گرانشی

یکی از ایده‌های جدید در حل مسائل پیچیده با توابع غیرخطی استفاده از روش جستجوی آشوبناک در روش‌های هوشمند به منظور افزایش قابلیت‌های الگوریتم هوشمند است. روش آشوبناک یک روش مبتنی بر توابع غیرخطی و غیرمحدب است که امروزه بیش از پیش مورد توجه قرار گرفته است. در این مقاله به بررسی روش‌های آشوبناک انجام گرفته در مقالات منتشر شده و روش آشوبناک پیشنهادی در حل مسئله پیش‌بینی قیمت برق پرداخته می‌شود. مدل‌های انجام گرفته شده در سه بخش زیر قابل پیگیری است:


مدل اول (CGSA1): یکی از مهم‌ترین و ساده‌ترین مدل‌های به کار گرفته شده در مقالات استفاده از مدل لجستیک [۱۴] برای

واحدهای لایه ورودی جهت انتقال الگوهای ورودی به بقیه شبکه و بدون انجام هیچ‌گونه پردازشی ایفای نقش می‌کنند.



شکل ۳: شبکه پرسپترون بهبود یافته

اطلاعات به‌وسیله واحدهای لایه‌های مخفی و خروجی پردازش می‌شوند. شکل ۴ معماری یک مدل شبکه عصبی پیش‌خور سه لایه را نشان می‌دهد.



شکل ۴: شبکه عصبی پیش‌خور سه لایه با یک لایه مخفی

۳-۲- تعیین خطای پیش‌بینی

برای ارزیابی روش پیشنهادی معیارهای مختلفی وجود دارد که در ادامه برخی از آن‌ها بیان می‌شوند. معیار SDE برای مقایسه نتایج به‌صورت زیر قابل تعریف است:

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

که در آن، e_k خطای پیش‌بینی در ساعت h م 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 قدرمطلق خطای درصدی) و یا MAE و قدرمطلق درصد خطای روزانه DMAPE استفاده شده است که با روابط زیر تعریف می‌گردند:

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

$$MAE = \frac{1}{N} \sum_{i=1}^N |L_{ACT(i)} - L_{FOR(i)}| \quad (35)$$

$$DMAPE = \frac{1}{24} \sum_{t=1}^{24} \frac{|L_{ACT,t} - L_{FOR,t}|}{\frac{1}{24} \sum_{t=1}^{24} L_{ACT,t}} \quad (36)$$

افزایش قابلیت جستجوی محلی و نهایی سیستم است. فرمول ریاضی برای یک مسئله d بعدی بر اساس مدل لجستیک به‌صورت زیر بیان می‌شود:

$$c_d^{s+1} = \mu_d^s (1 - c_d^s), 0 \leq c_0 \leq 1 \quad (29)$$

که در آن، s برابر با ۰، ۱ و ... بوده و ضریب لجستیک (μ) برابر با ۴ است. c ذره آشوبناک در مرحله k ام است.

مدل دوم (CGSA2): یکی از معادلات معتبر بر مبنای قانون آشوب، معادله تند [۱۵] بوده که به‌صورت زیر قابل فرموله‌شدن است:

$$c_{i+1}^j = \begin{cases} 2c_i^j, & \text{if } 0 < c_i^j \leq 0.5 \\ 2(1 - c_i^j), & \text{if } 0.5 < c_i^j \leq 1 \end{cases}, j = 1, 2, \dots, Ng \quad (30)$$

که در معادله فوق، c معرف ذرات آشوب در بعد z ام و تکرار نام است. Ng تعداد متغیر برای بهینه‌سازی تعریف می‌شود.

مدل سوم (CGSA3): در مدل پیشنهادی به‌منظور افزایش قابلیت جستجوی محلی و نهایی از مدل حرکت پاندول برای میراسازی بهره گرفته شده است. به عبارتی مدل پیشنهادی از دو قسمت: قسمت اول برای تقویت دامنه جستجو در فضای موردنظر و قسمت دوم میزان حرکت نوسانی برای مد داخلی جستجو است. معادله جستجوی الگوریتم پیشنهادی می‌تواند به‌صورت زیر بیان گردد:

$$cx_{i+1}^j = \begin{cases} 2cx_i^j \times (1 + \frac{g_{best}^{k-1}}{g_{best}^k}) \times \cos(2\pi \frac{g_{best}^{k-1}}{g_{best}^k}), & 0.5 < cx_i^j \leq 1 \\ \text{amplitude modulation} & \downarrow \\ 0.1cx_i^j \times (1 - \cos((1 + \frac{g_{best}^{k-1}}{g_{best}^k}))), & 0.5 < cx_i^j \leq 0 \\ \text{frequency modulation} & \downarrow \end{cases} \quad (31)$$

مقدار g_{best} بهینه به‌دست آمده در مرحله k ام است که به تعیین میزان دامنه جستجوی محلی یا نهایی می‌پردازد. در حقیقت این ضریب با توجه به مقدار به‌دست آمده در مرحله قبلی به ایجاد ضریب آشوب برای مرحله بعدی می‌انجامد. هنگامی که این مقادیر در یک محدوده قرار می‌گیرند با تغییر فرکانس جستجو، سعی در یافتن جواب بهتر می‌پردازد.

ج) شبکه عصبی

در این قسمت به توضیح مختصری از شبکه عصبی اختصاص داده شده است. اولین کوشش‌ها در شبیه‌سازی با استفاده از یک مدل منطقی توسط مک کلوک و والتر پیتز انجام گرفت که امروزه بلوک اصلی سازنده اکثر شبکه‌های عصبی مصنوعی است. این مدل فرضیه‌هایی در مورد عملکرد نورون‌ها ارائه می‌کند. شبکه عصبی به‌کارگرفته‌شده در این مقاله، شبکه پرسپترون‌های چندلایه از نوع شبکه‌های عصبی پیش‌خور است. یک پرسپترون، برداری از ورودی‌ها با مقادیر حقیقی را گرفته و یک ترکیب خطی از آن‌ها را محاسبه می‌کند. شکل ۳ سیستم پرسپترون بکارگرفته‌شده برای شبکه عصبی بهبود یافته را نشان می‌دهد [۸]. واحدهای هر لایه ممکن است ورودی‌های یکسانی را بین خودشان تقسیم کنند درحالی که به یکدیگر متصل نباشند. عموماً

گام چهارم: در این مرحله به آموزش بهتر شبکه عصبی از طریق کاهش خطای خروجی به کمک به‌روزرسانی وزن‌ها و بایاس‌ها پرداخته می‌شود. به عبارتی، ضرایب آشوبناک متناسب با محدوده تعیین‌شده و تعداد متغیر (Ng)، تولید می‌شوند:

$$X_{cls}^0 = [X_{cls,0}^1, X_{cls,0}^2, \dots, X_{cls,0}^{Ng}]_{1 \times Ng}$$

$$cx_0 = [cx_0^1, cx_0^2, \dots, cx_0^{Ng}] \quad (38)$$

$$cx_0^j = \frac{X_{cls,0}^j - X_{j,\min}}{X_{j,\max} - X_{j,\min}}, j = 1, 2, \dots, Ng$$

برای این معادله خواهیم داشت:

$$X_{cls}^i = [X_{cls,i}^1, X_{cls,i}^2, \dots, X_{cls,i}^{Ng}]_{1 \times Ng}, i = 1, 2, \dots, N_{chaos} \quad (39)$$

$$x_{cls,i}^j = cx_{i-1}^j \times (X_{j,\max} - X_{j,\min}) + X_{j,\min}, j = 1, 2, \dots, Ng$$

در رابطه بالا X_{cls}^0 مکان به‌دست‌آمده اولیه برای متغیر آشوب است. $X_{j,\max}$ و $X_{j,\min}$ به ترتیب مقدار پایین و بالایی برای متغیر آشوبناک است. N_{chaos} تعداد متغیرهای آشوبناک است.

گام پنجم: در این قسمت متغیرهای آشوبناک به‌صورت زیر ارتقاء می‌یابند:

$$cx_i = [cx_i^1, cx_i^2, \dots, cx_i^{Ng}], i = 0, 1, 2, \dots, N_{chaos}$$

$$cx_{i+1}^j = \begin{cases} 2cx_i^j \times (1 + \frac{g_{best}^{k-1}}{g_{best}^k}) \times \cos(2\pi \frac{g_{best}^{k-1}}{g_{best}^k}), 0.5 < cx_i^j \leq 1 \\ 0.1cx_i^j \times (1 - \cos((1 + \frac{g_{best}^{k-1}}{g_{best}^k}))), 0.5 < cx_i^j \leq 1 \end{cases} \quad (40)$$

$$cx_0^j = rand(0)$$

گام ششم: در این قسمت با کمک تابع هدف معرفی‌شده که بر مبنای کاهش خطای خروجی است، بهینه‌کردن وزن‌ها و بایاس‌ها برای شبکه عصبی به‌منظور آموزش بهتر آن انجام می‌گیرد. تابع هدف مورد‌استفاده در این مقاله درصد خطای مطلق متوسط ($MAPE$) است که بر اساس تعداد روزهای مورد‌مطالعه (N) به‌صورت زیر قابل فرموله‌شدن است:

$$MAPE = \frac{100}{N} \sum_{h=1}^N \frac{|\hat{p}_h - p_h|}{\bar{p}} \quad (41)$$

گام هفتم: ایجاد کردن متغیرهای تعریف‌شده بر اساس توابع تصمیم‌گیری در تابع جستجوی گرانشی.

گام هشتم: ارتقاء ذرات به‌دست‌آمده با توجه به نسبت دادن شتاب و سرعت هر ذره به کمک روابط (۲۲) الی (۲۳).


گام نهم: بررسی شرط خاتمه برنامه. اگر شرط برنامه برقرار شده است نتایج حاصله چاپ شود در غیراین‌صورت به گام دوم سوق یابد. شکل ۶ فلوجارت الگوریتم پیشنهادی برای حل مسئله پیش‌بینی در گام‌های گفته‌شده را نشان می‌دهد.

۳- نحوه اعمال الگوریتم پیشنهادی بر مسئله پیش‌بینی

در این بخش به بیان الگوی به‌کارگرفته‌شده برای حل مسئله پیش‌بینی روزانه قیمت می‌پردازیم. ابتدا فرض نماییم که پیش‌بینی برای روز d انجام می‌گیرد. همچنین فرض کنید اطلاعات گذشته سری داده‌های قیمت برای ۲۴ ساعت روز $d-1$ به‌صورت $p_h; h=1, \dots, T$ قابل دسترسی باشد که در آن معمولاً بین حدود یک هفته الی چند ماه قبل را شامل می‌شود. با توجه به فرضیات گفته‌شده، مدل ایجادشده در گام‌های زیر قابل پیگیری است.

گام اول: ابتدا با توجه به تابع تبدیل موجک داده‌های ورودی به چند زیربخش (سری) تقسیم می‌شوند. در حقیقت تابع تبدیل موجک یک معیار مناسب برای سبک-سنگین کردن داده‌ها بر اساس میزان طول و همواری آن‌ها است. تابع تبدیل موجک داده‌های ورودی $(p_h; h=1, \dots, T)$ را به چهار سری مجزا (a_h, b_h, c_h, d_h) تقسیم نموده که هر بخش به‌طور جداگانه وارد شبکه عصبی می‌شوند (مطابق شکل ۵). سه سری a_h, b_h, c_h به‌عنوان ماتریس جزئیات با تطبیق کم‌تر و d_h ماتریس تخمین بوده که مهم‌ترین نقش در تابع تبدیل را بر عهده دارد. بنابراین تقسیم‌بندی ماتریس در چهار بخش مجزا به‌صورت زیر قابل فرموله‌شدن است:

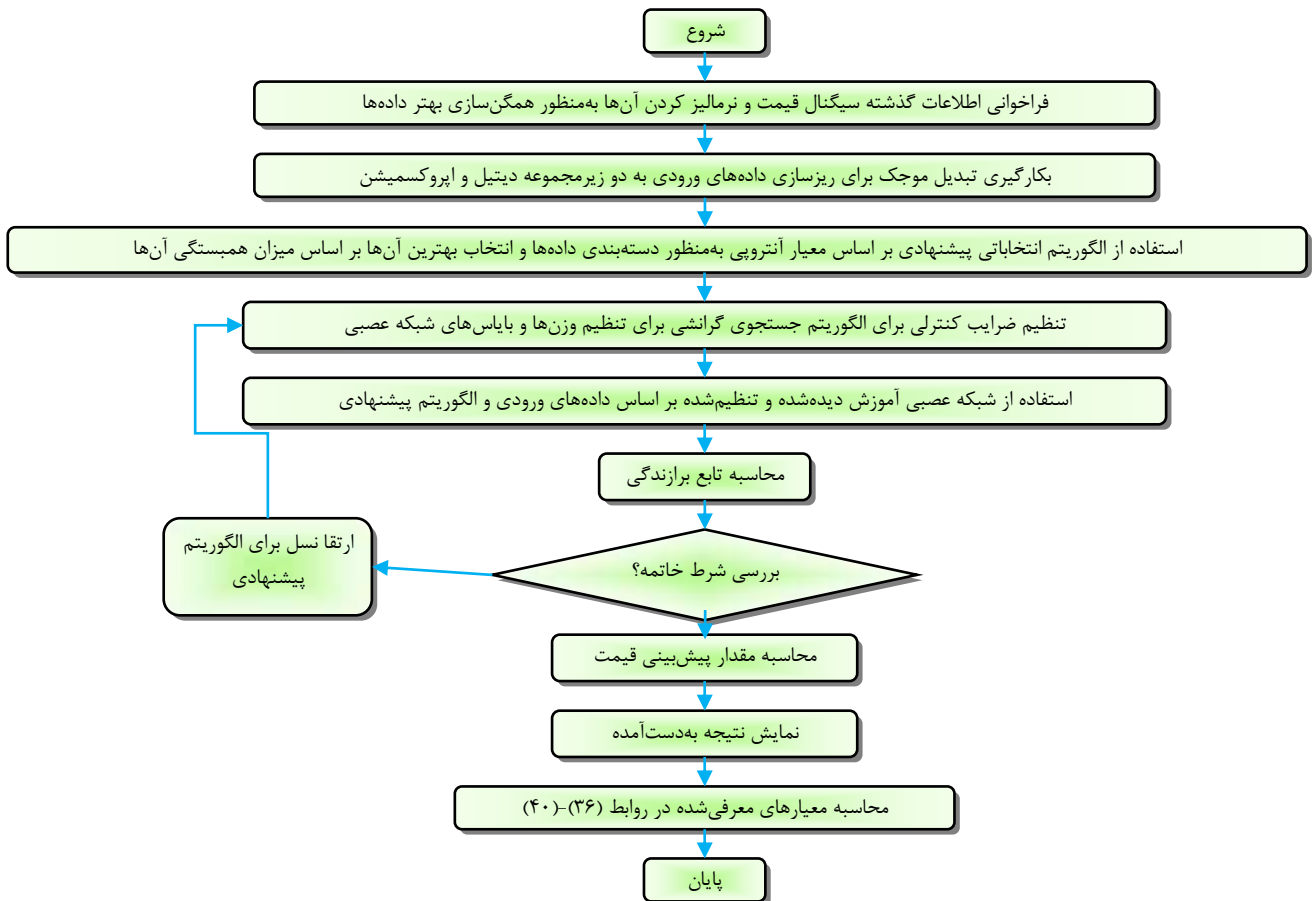
$$W(p_h; h=1, \dots, T) = \{a_h, b_h, c_h, d_h; h=1, \dots, T\} \quad (37)$$



شکل ۵: نحوه جداسازی داده‌های ورودی به کمک تبدیل موجک

گام دوم: استفاده از الگوریتم انتخاباتی برای مرتب کردن داده‌ها با بیش‌ترین همبستگی بر اساس معادله (۱۲)، در حقیقت در این گام بهترین داده‌ها با مقدار همبستگی بیش‌تر از ۰/۶ برای آموزش وارد شبکه عصبی می‌شوند.

گام سوم: استفاده از شبکه عصبی برای آموزش هر بخش در جهت پیش‌بینی اطلاعات ساعت‌های $T+1, \dots, T+24$ برای هر ماتریس تجزیه‌شده از داده‌های اولیه و انجام جمع نتایج حاصل از پیش‌بینی با یکدیگر به‌منظور دستیابی به اطلاعات اولیه.




شکل ۶: ساختار کلی سیستم پیش‌بینی ارائه‌شده در این مقاله


۱۰۰ و $G0$ برابر با ۰/۱ انتخاب شده است. مدت‌زمان اجرای برنامه برای آموزش حدوداً ۲۵ دقیقه بوده است.

۴- بررسی و بحث روی سیستم‌های مورد مطالعه

سیستم مطالعه اول: به منظور شبیه‌سازی و پیش‌بینی قیمت با الگوریتم پیشنهادی از سیستم اسپانیا [۱۶] به‌عنوان یک بازار واقعی استفاده شده است. علت انتخاب این سیستم به دلیل واقعی بودن اطلاعات و دسترسی آن است. شکل ۷-الف تغییرات قیمت برای سیستم اسپانیا برای کلیه ساعت‌های سال ۲۰۰۸ را نشان می‌دهد. برای پیش‌بینی قیمت بازار برق اسپانیا، اطلاعات ۵۰ روز قبل آن اخذ شده و بعد از آرایش‌دهی بر روی داده‌های ورودی ۷ کاندید برای آموزش وارد شبکه عصبی شده‌اند. در آموزش این داده‌ها ماتریس مشاهده‌گر دارای ۱۲۰۰ عضو است.

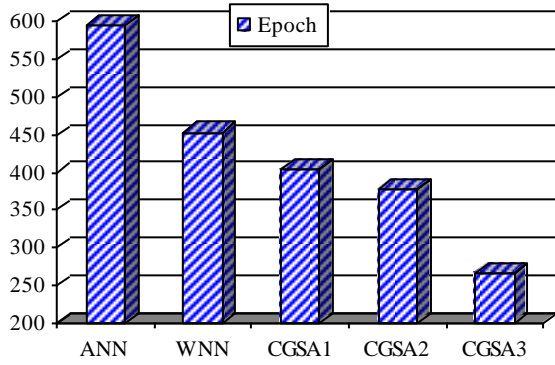


شکل ۷-الف: تغییرات قیمت ساعتی برای سال ۲۰۰۸ اسپانیا [۱۶]




شکل ۷-ب: ماتریس هدف بر اساس میزان کاندید انتخاب‌شده

این ورودی به‌صورت زیرمجموعه $h-1, h-168, h-24, h-144, h-48$ تعریف می‌شوند. به‌منظور مرتب‌سازی داده‌ها برای پیش‌بینی، ماتریس هدف بر اساس میزان زمان آستانه و داده‌های ورودی به‌صورت شکل ۷-ب تنظیم شده است. برای کاهش دادن تغییرات بین داده‌ها از نرمالیزه‌کردن بهره گرفته‌ایم تا بتوان با نوسانات کم‌تری داده‌ها را برای آموزش و پیش‌بینی به کار برد. شکل ۸ تغییرات پیش‌بینی برای ۲۴ ساعت به کمک سه روش پیش‌بینی را مشخص نموده است. همان‌گونه که از شکل مشخص است الگوریتم پیشنهادی دارای قابلیت بالاتری در تعیین وزن‌ها و بایاس‌ها برای آموزش شبکه عصبی مورد مطالعه دارا است. برای این منظور تعداد جمعیت برابر با



شکل ۱۱: تعداد تکرارهای آموزش برنامه برای بازار برق اسپانیا




شکل ۱۲: انحراف معیار آموزش برنامه برای بازار برق اسپانیا

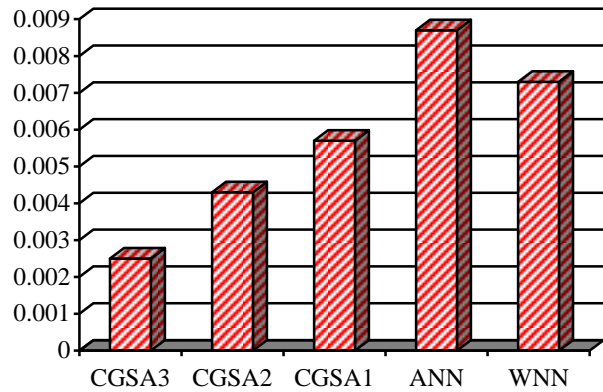
همان‌گونه که در شکل ۹ نشان داده شده است سه روش پیشنهادی به مراتب موفق‌تر از شبکه عصبی و تبدیل موجک عمل نموده‌اند. مقدار نهایی معیار SDE به‌دست‌آمده از نظریه آشوب پیشنهادی حدوداً ۵۰٪ در مقایسه با بهترین جواب به‌دست‌آمده از سایر روش‌ها، بهبود یافته است. که این نتیجه، اختلاف کمتر بین مقدار واقعی و پیش‌بینی را نشان می‌دهد. همچنین شکل‌های ۱۰ و ۱۲ این مهم را بر اساس معیارهای انحراف معیار، $MAPE$ و $DMAPE$ نتیجه می‌دهد. شکل ۱۱ نشان می‌دهد سرعت اجرای برنامه به‌طور قابل‌ملاحظه‌ای کاهش یافته است که نمایانگر انتخاب مناسب وزن‌ها و بایاس‌ها برای آموزش شبکه عصبی به کمک روش پیشنهادی است. همچنین برای مقایسه روش پیشنهادی با سایر روش‌های انجام‌گرفته در این بازار، مقایسه‌ای در جدول ۱ بر اساس معیار $MAPE$ هفتگی برای چهار هفته در بازار برق اسپانیا انجام گرفته است. روش‌های موردمقایسه در [۱۸] آورده شده است.

سیستم مطالعه دوم: سیستم مورد مطالعه بعدی، تغییرات قیمت روزانه برای بازار برق ایران در سال ۱۳۹۱ است. هدف از این بخش، طراحی و اجرای یک مدل بهبودیافته شبکه عصبی جهت تبیین و پیش‌بینی رفتار کوتاه‌مدت قیمت‌های متوسط روزانه نقدی در بازار برق کشور است. در این مرحله پیش‌بینی بعد از ایستاسازی داده‌های ورودی (حذف روند از داده‌ها و صرف‌نظر کردن داده‌هایی که متوسط طول‌موج بزرگ‌تری نسبت به داده‌های سری دارند) و تعیین بهترین

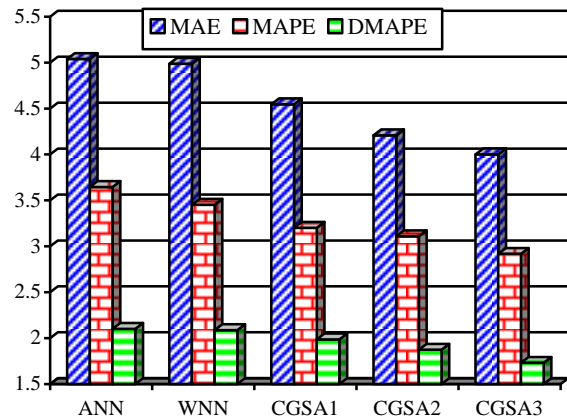
شکل ۹ مقایسه بر اساس میزان خطای ناشی از پیش‌بینی به کمک سه روش پیشنهادی را نشان می‌دهد. شکل ۱۰ مقایسه‌ای برای نتایج به‌دست‌آمده از روش‌های گفته‌شده در سیستم بازار برق اسپانیا با معیارهای معرفی شده در معادلات (۳۴) الی (۳۶) است. شکل ۱۱ تعداد epoch و شکل ۱۲ انحراف معیار به‌دست‌آمده از اجرای برنامه را نشان می‌دهد. همان‌گونه که از نتایج برمی‌آید الگوریتم پیشنهادی دارای کارایی بالا، سرعت مناسب و دقت بالا است.



شکل ۸: نتایج شبیه‌سازی برای بازار برق اسپانیا



شکل ۹: معیار SDE برای تعیین میزان خطای ناشی از شبیه‌سازی



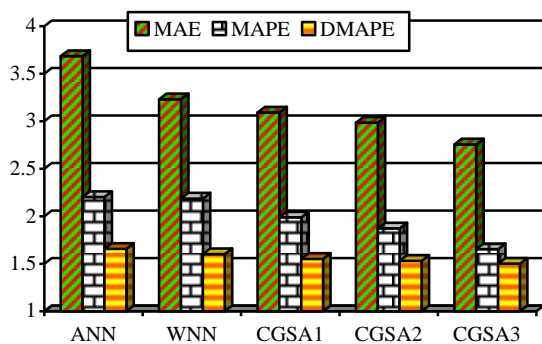
شکل ۱۰: نتایج معیارهای به‌دست‌آمده از بازار برق اسپانیا

کاهش نرخ به‌اندازه ۰/۲۵، ۰/۲۴ و ۰/۰۹ به ترتیب برای معیارهای انحراف معیار، $MAPE$ ، MAE و $DMAPE$ مشاهده نمود. تعداد تکرارهای آموزش برنامه با کمک روش پیشنهادی به تعداد ۲۲۰ رسیده است که در مقایسه با بهترین جواب از سایر روش‌ها، ۱۱۴ واحد کاهش یافته است.

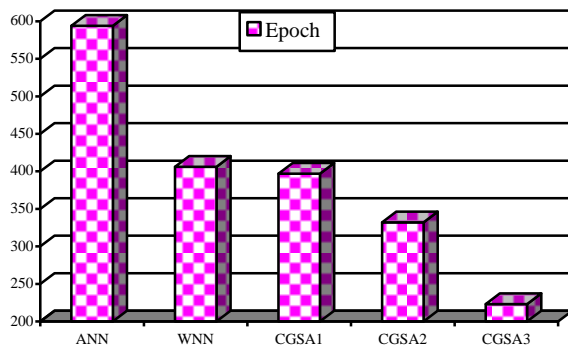
همبستگی بین ماتریس ورودی و ماتریس هدف بر اساس میزان همبستگی و الگوریتم بهبودیافته انتخاباتی به پیش‌بینی پرداخته می‌شود. داده‌های تغییرات قیمت ساعتی از ۹۱/۱/۱ الی ۹۱/۱/۳۱ در شکل ۱۳ نشان داده شده است [۱۷]. نتایج به‌دست‌آمده از شکل‌های مربوطه نشان از پیش‌بینی دقیق‌تر داشته، که این نکته را می‌توان در

جدول ۱: مقایسه بین روش پیشنهادی و سایر روش‌های ارائه‌شده بر اساس معیار $MAPE$ هفتگی برای چهار هفته در بازار برق اسپانیا


Test Week	ARIMA	Wavelet-ARIMA	FNN	NN	Mixed Model	Wavelet ARIMA RBFN	MI+CNN	Proposed
Winter	۶/۳۲	۴/۷۸	۴/۶۲	۵/۲۳	۶/۱۵	۴/۲۷	۴/۵۱	۴/۵۹۲
Spring	۶/۳۶	۵/۶۹	۵/۳۰	۵/۳۶	۴/۴۶	۴/۵۸	۴/۲۸	۴/۸۶۳
Summer	۱۳/۳۹	۱۰/۷۰	۹/۸۴	۱۱/۴۰	۱۴/۹۰	۶/۷۶	۶/۴۷	۵/۸۵۸
Fall	۱۳/۷۸	۱۱/۲۷	۱۰/۳۲	۱۳/۶۵	۱۱/۶۸	۷/۳۵	۵/۲۷	۵/۲۰۷
Average	۹/۹۶	۸/۱۱	۷/۵۲	۸/۹۱	۹/۳۰	۵/۷۴	۵/۱۳	۵/۱۳



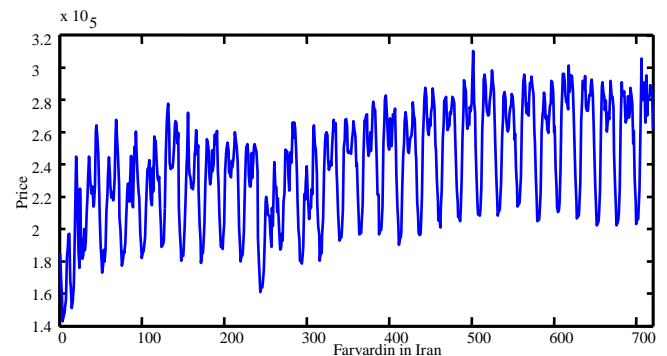
شکل ۱۵: نتایج معیارهای به‌دست‌آمده از بازار برق ایران



شکل ۱۶: تعداد تکرارهای آموزش برنامه برای بازار برق ایران

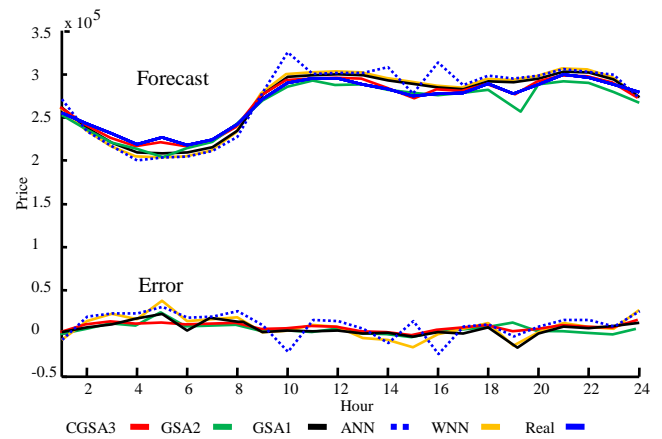


شکل ۱۷: انحراف معیار آموزش برنامه برای بازار برق ایران



شکل ۱۳: تغییرات قیمت روزانه فروردین ۱۳۹۱ [۱۷]

نتایج پیش‌بینی قیمت بر روی سیستم مورد مطالعه در شکل ۱۴ نشان داده شده است. برای نشان دادن کارایی روش پیشنهادی در کاهش خطای ناشی از پیش‌بینی، از معیارهای (۳۲) الی (۳۴) استفاده شده است. مقایسه انجام‌گرفته بر اساس این معیارها، در شکل ۱۵ آورده شده است. تعداد اجرای برنامه ۱۰ بار بوده که تعداد epoch و انحراف معیار به‌دست‌آمده در شکل‌های ۱۶ و ۱۷ نشان داده شده است. همان‌گونه که در نتایج نشان داده شده است، روش پیشنهادی به دلیل قابلیت‌های آن در ارتقاء نسل و یافتن جواب‌های بهتر در وزن‌ها و بایاس‌ها کارایی بالاتری داشته است.



شکل ۱۴: نتایج شبیه‌سازی برای بازار برق ایران در فروردین ماه ۱۳۹۱

۵- نتیجه‌گیری

در پی تغییر ساختار بازار برق از بازار انحصاری دولتی به بازار رقابتی که در آن قیمت توسط نیروهای بازار تعیین می‌شود، مدل‌سازی و پیش‌بینی قیمت برق کاملاً ریسکی و همراه با عدم قطعیت برق تعیین شده در بازار رقابتی برای فعالان بازار برق اهمیت ویژه‌ای یافته است. برای مدل‌سازی و پیش‌بینی قیمت‌های برق در بازار رقابتی باید ویژگی‌های این کالا از جمله عدم قابلیت ذخیره‌سازی، کم‌کشش بودن، فصلی بودن تقاضا و لزوم تعادل پیوسته‌ی عرضه و تقاضا که منجر به فراربت قیمت‌ها می‌گردد، در نظر گرفت. هدف از این مقاله، طراحی و اجرای یک مدل از الگوریتم جستجوی گرانشی آشوبناک و شبکه عصبی بهبود یافته با تابع تبدیل موجک جهت تبیین و پیش‌بینی رفتار کوتاه‌مدت قیمت‌های متوسط روزانه نقدی در بازار برق کشور و بازارهای جهانی است. نتایج به‌دست‌آمده از شبیه‌سازی‌ها نشان از قابلیت بالای این الگوریتم در پیش‌بینی بهتر در مقایسه با سایر روش‌های موجود است. همچنین نتایج مناسب به‌دست‌آمده، نشان از موفقیت الگوریتم انتخاباتی در مرتب‌سازی داده‌های تقسیم‌شده از تبدیل موجک است. همچنین به‌منظور غلبه کردن بر رفتار نامنظم و غیرخطی داده‌های ورودی، نظریه آشوب با معادله معرفی‌شده (۳۱) مبتنی بر تغییر فرکانس و دامنه عملکرد بسیار مناسبی داشته که در شکل‌ها و جداول قابل نتیجه‌گیری است.

مراجع

- Automation in Power Engineering, vol. 1, no. 2, pp. 136-146, 2013.
- [9] P. Mandal, A. U. Haque, U. Meng, A. K. Srivastava and R. Martinez, "A Novel Hybrid Approach Using Wavelet, Firefly Algorithm, and Fuzzy ARTMAP for Day-Ahead Electricity Price Forecasting," IEEE Transactions. on Power Systems, vol. 28, no. 2, pp. 1041-1051, 2013.
- [10] L. Wu and M. Shahidehpour, "Hybrid model for day-ahead price forecasting," IEEE Transactions. on Power Systems, vol. 25, pp. 1519-1530, 2010.
- [11] N. Amjady, "Day-ahead price forecasting of electricity markets by a new fuzzy neural network," IEEE Transactions on Power Systems, vol. 21, pp. 887-896, 2006.
- [12] N. Amjady and F. Keynia, "Day-Ahead Price Forecasting of Electricity Markets by Mutual Information Technique and Cascaded Neuro-Evolutionary Algorithm," IEEE Transactions. on Power Systems, vol. 24, no. 1, pp. 306-318, 2009.
- [13] H. Shayeghi and A. Ghasemi, "Optimal tuning of PID type stabilizer and AVR gain using GSA technique," International Journal on "Technical and Physical Problems of Engineering" vol. 4, no. 2, pp. 98-106, 2012.
- [14] B. Liu, L. Wang, and Y. H. Jin, "Improved particle swarm optimization combined with chaos," Chaos, Solitons Fractals, vol. 25, no. 5, pp. 1261-1271, 2005.
- [15] J. Cai, X. Ma, Q. Li, L. Li and H. Peng, "A multi-objective chaotic particle swarm optimization for environmental/economic dispatch," Energy Conversion and Management, vol. 50, pp. 1318-1325, 2009.
- [16] Informe de operación del sistema eléctrico. Red Eléctrica de España (REE), Madrid, Spain. [Online]. Available: http://www.ree.es/cap03/pdf/Inf_Oper_REE_9_9b.pdf.
- [17] <http://edipg.igmc.ir:8070/edipg>.
- [18] H. Shayeghi and 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.
- [1] X. R. Li, C. W. Yu, S. Y. Ren, C. H. Chiu and K. Meng, "Day-ahead electricity price forecasting based on panel cointegration and particle filter," Electric Power Systems Research, vol. 95, pp. 66-76, 2013.
- [2] F. J. Nogales, J. Contreras, A. J. Conejo and R. Espinola, "Forecasting next-day electricity prices by time series models," IEEE Transactions on Power System, vol. 17, pp. 342-348, 2002.
- [3] J. Contreras, R. Espinola, F. J. Nogales and A. J. Conejo, "ARIMA models to predict next day electricity prices," IEEE Transactions. on Power Systems, vol. 18, pp. 1014-1020, 2003.
- [4] H. T. Pao, "Forecasting energy consumption in Taiwan using hybrid nonlinear models. Energy," vol. 34, pp. 1438-1446, 2009.
- [5] N. Bowden and J. E. Payne, "Short-term forecasting of electricity prices for MISO hubs: evidence from ARIMA-EGARCH models," Energy Economics, vol. 30, pp. 3186-3197, 2008.
- [6] A. J. Conejo, M. A. Plazas, R. Espinola and A. B. Molina, "Day-ahead electricity price forecasting using the wavelet transform and ARIMA models," IEEE Transactions Power Syst, vol. 20, pp. 1035-1042, 2005.
- [7] A. K. Diongue, D. Guegan and B. Vignal, "Forecasting electricity spot market prices with a k-factor GIGARCH process," Applied Energy, vol. 86, pp. 505-510, 2009.
- [8] H. Taherian, S. I. Nazer, S. E. Razavi, S. R. Goldani, M. Farshad and M. R. Aghaebrahimi, "Application of an improved neural network using cuckoo search algorithm in short-term electricity price forecasting under competitive power markets," Journal of Operation and

زیر نویس‌ها

- ¹ Auto regressive integrated moving average model (ARIMA)
- ² Generalized Auto Regressive Conditional Heteroskedasticity (GARCH)