

ارایه یک مدل ترکیبی در پیش بینی بار در بازار برق تجدیدساختار یافته

سید جلال سید شنوا^۱، علی قاسمی^{۲*}، حسین شایقی^۱، مهدی نوشیار^۱

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

^۲دانشگاه آزاد اسلامی واحد اردبیل، باشگاه پژوهشگران جوان و نخبگان، اردبیل، ایران

*ghasemi.agm@gmail.com

چکیده: با سمت‌گیری و تغییر ساختار بازار برق از بازار انحصاری دولتی به بازار رقابتی که در آن میزان تقاضاً توسعه نیروهای بازار تعیین می‌شود، نیاز به طراحی مدلی کارا و مناسب به گونه‌ای که ریسک شرکت در بازار رقابتی برای فعالان بازار برق را در جهت افزایش سودهای آنها کاهش دهد، اهمیت ویژه‌ای یافته است. برای مدل‌سازی و پیش‌بینی بار در بازار رقابتی باید خصوصیات این کالا از جمله فصلی بودن تقاضاً را در نظر گرفت. مدل ایجاد شده در صورتی که بتواند با ایجاد رابطه‌ای از داده‌های قبلی، کمترین خطای پیش‌بینی را داشته باشد، موثرتر و کارآمدتر خواهد بود. در مدل‌های کلاسیک ارایه شده در مساله پیش‌بینی بار در بازار 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 انتگریزه دستیابی به کمترین خطای پیش‌بینی و برطرف کردن نواقص روش‌های قبلی، از روشی ترکیبی شبکه عصبی بهبود یافته مبتنی بر ساختار غیر خطی برای آموزش و یادگیری بهتر بر روی مقادیر گذشته بار و استفاده از آن برای اطلاعات آینده و از ایده ترکیبی کلونی مصنوعی زنبور عسل در یافتن بهترین وزن‌ها و بایاس‌ها برای حداقل کردن مربعات خطای پیش‌بینی بهره گرفته شده است. همچنین به منظور مرتب‌سازی داده‌ها و در نظر گرفتن عدم قطعیت در انتخاب بهترین داده‌ها از روش پیشنهادی انتخاباتی با در نظر گرفتن معیار آنتروپی بهره گرفته شده است. به منظور نشان دادن کارایی روش پیشنهادی در حل مساله پیش‌بینی بار در بازار برق در مقایسه با سایر روش‌های اخیر انجام گرفته در این زمینه، از بازار واقعی موجود نیوانگلند استفاده شده است. نتایج نشان از دقت بالا و خطای کمتر در پیش‌بینی می‌دهد. همچنین الگوریتم هوشمند ارایه شده قابلیت جستجوی محلی و نهایی آن به طور قابل ملاحظه‌ای بهبود یافته است.

واژه‌های کلیدی: پیش‌بینی بار، الگوریتم عصبی فازی، الگوریتم کلونی مصنوعی زنبور عسل، بازار برق، عدم قطعیت.

تاریخ ارسال مقاله : ۱۳۹۱/۷/۲۵

تاریخ پذیرش مقاله : ۱۳۹۲/۰۳/۰۱

نام نویسنده‌ی مسئول : علی قاسمی

نشانی نویسنده‌ی مسئول : اردبیل، انتهای خیابان دانشگاه، دانشگاه محقق اردبیلی، گروه برق-قدرت.

۱- مقدمه

برنامه‌ریزی دقیق در تهیه، تولید و مصرف خواهد داشت و اگر موارد ذیل در تولید و مصرف این نوع انرژی در نظر گرفته نشود، در آینده با مشکلات و خسارت‌های جبران ناپذیری روبرو خواهیم شد. موارد فوق نشان دهنده اهمیت برنامه‌ریزی دراز مدت و جامع تولید انرژی الکتریکی می‌باشند. یک مدیریت صحیح انرژی الکتریکی موقعی امکان پذیر خواهد بود که مدیران ارشد، یک دید روشی و مبتنی بر تئوری‌های دقیق از روند آتی تقاضای این انرژی را داشته باشند [۲].

یکی از عناصر کلیدی در مدیریت و تصمیم‌گیری، پیش‌بینی پارامترها و متغیرهای لازم در یک محدوده سیستمی می‌باشد.

با توجه به اهمیت موضوع، تاکنون روش‌های متعددی در این زمینه ارایه شده است که می‌توان آنها را در دو دسته تقسیم‌بندی نمود. در دسته اول مبتنی بر روش سری زمانی و دسته دوم براساس شبکه هوشمند مصنوعی می‌باشد. در هر دو دسته 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]، خودرگرسیون جمعی میانگین متحرک [۳]، خودرگرسیون واریانس شرطی [۴]، روش ترکیبی خودرگرسیون جمعی میانگین متحرک و خود رگرسیون واریانس شرطی [۵]، و رشد سالیانه و همبستگی [۶] اشاره نمود. اگر چه این روش‌ها بخاطر سادگی در پیاده‌سازی و خطی بودن مورد توجه قرار گرفته‌اند اما در سیستم غیرخطی کارایی کافی نداشته و خطای پیش‌بینی را به طور چشمگیری افزایش می‌دهند.

در دسته روش‌های هوشمند و ساختارهای بهبود یافته آن، به کمک مدل غیرخطی سعی در آموزش بهتر شبکه داشته تا بتوان کمترین خطای حاصل را ایجاد نمود. در شبکه عصبی مصنوعی که می‌توان از آن به عنوان برآزارشگر اطلاعات اشاره نمود، براساس شبکه عصبی انسان در یادگیری مدلسازی شده است. به عبارتی دیگر یک شبکه عصبی مدلی از نمونه‌های عصبی مغز می‌باشد. در راستای استفاده از این الگو، مقالات متعددی در زمینه پیش‌بینی انجام گرفته است. در مرجع [۷] از روش شبکه عصبی به پیش‌بینی بار در بازار برق پرداخته شده است. در جهت کاهش خطای حاصل از پیش‌بینی و افزایش قابلیت‌های شبکه عصبی، در مرجع [۸] مدلی جدید در معماری یادگیری شبکه عصبی به کمک تابع تبدیل موجک ارائه گشته است. در مرجع [۹] از مدل سری زمانی و شبکه عصبی که در حقیقت از ترکیب دو سیستم خطی و غیر خطی بدست 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) می‌باشد. به منظور افزایش قابلیت یادگیری شبکه عصبی در مرجع [۱۰] از یک روش ترکیبی فازی-عصبی تحت عنوان نروفازی استفاده شده است. در

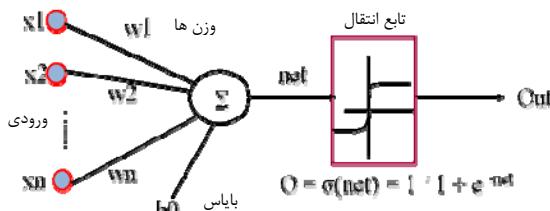
امروزه بازار برق بیش از پیش به همکاری با سایر بازارها از جمله بازار سوخت، خدمات جانبی و الودگی می‌پردازد. بنابراین تصمیم‌گیری برای فعالان بازار در جهت افزایش سودهای به مرتب پیچیده‌تر شده است. موفقیت در بازار رقابتی برق تجدید ساختار یافته امروزی مستلزم داشتن مهارت قابل قبول در کار تعمیم براساس معیارهای علمی می‌باشد. عوامل بازار انرژی از میزان کسب سود حاصل از قراردادهای بلندمدت تحويل انرژی در آینده مطمئن نیستند زیرا ممکن است میزان تولید، تقاضا و نرخ رایج نسبت به فرضیات زمان عقد قرارداد تغییر نماید. در نتیجه معامله‌گران انرژی زمانی بهتر عمل می‌نمایند که پیش‌بینی دقیقتری بکار بردند. در راستای تحقق این هدف، شرکت‌های تولیدی یا مصرفی انرژی، در جهت بهبود دقت پیش‌بینی کارهای را شروع کرده‌اند. به عبارتی دیگر، با گسترش روز افزون سیستم‌های الکتریکی، انگیزه استفاده بهینه از منابع، رقابت‌های اقتصادی و محدودیت‌های محیطی گرایش به بازار چند قطبی توسعه یافت و نیاز به آن سبب تشویق شرکت‌ها و بنگاه‌های اقتصادی به منظور سرمایه‌گذاری و مشارکت در صنعت برق شده است. در سیستم بازار برق چند قطبی، مشتریان می‌توانند فروشندۀ را انتخاب کنند. با تأمین سرویس بهتر و انرژی ارزانتر، مشتریان بیشتری جذب می‌شوند که این کار سود بیشتری عاید فروشندۀ می‌نماید و از طرفی مشتریان نیز منافع بیشتری می‌برند. فروشندگان یا تأمین‌کنندگان انرژی نمایندگانی هستند که انرژی را به مشتری می‌فروشند هر چند که ممکن است آنها تولید کننده نباشند، اما سهم تولید نیروگاههای بخوبی این ساختار جدید سیستم قدرت، مفاهیم قدیمی را به چالش کشانده است. در گذشته تمرکز تحقیقات روی فرمول‌سازی برخی محدودیت‌های عملی از قبیل دامنه ولتاژ شین‌ها، محدودیت‌های تولید، ظرفیت خطوط انتقال، محدودیت‌های احتمالی، ملاحظات محیطی و مسائلی ازین قبیل بود. جهت تضمین دسترسی آزاد فروشندگان و خریداران به سیستم انتقال، بهره‌برداری از سیستم انتقال مستلزم مستقل بودن بخش مدیریتی از سهام بازار است. بهره‌برداران مستقل سیستم نقش هماهنگ‌ساز مرکزی را ایفا می‌کنند و با فراهم کردن امنیت و قابلیت اطمینان سیستم درجه کیفیت و امنیت سیستم را تضمین می‌نمایند [۱]. از میان انواع انرژی‌ها در جهان، انرژی الکتریکی خصوصیات منحصر به فرد دارد که از جمله می‌توان به موارد زیر اشاره کرد: (الف) این انرژی به صورت وسیع قابل ذخیره‌سازی نیست، (ب) بازده سرمایه‌گذاری در رابطه با انرژی الکتریکی زمان بر می‌باشد (به) خصوص در کشورهای جهان سوم که عمدۀ تجهیزات مورد نیاز را از کشورهای پیشرفته تهیه می‌کنند) و اگر فرض جایگزینی تدریجی این نوع انرژی را به جای انرژیهای فسیلی به لحاظ خصوصیات مثبت آن به شرایط فوق اضافه کنیم به این نتیجه خواهیم رسید که انرژی الکتریکی به عنوان یک انرژی کلیدی در سطح جهان نیاز به مدیریت و

* Auto regressive integrated moving average model (ARIMA)

[†] Generalized Auto Regressive Conditional Heteroskedasticity (GARCH)

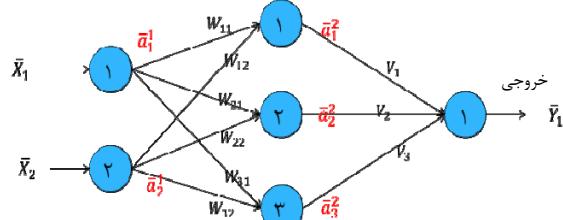
۲- شبکه عصبی

در این قسمت به توضیح مختصری از شبکه عصبی اختصاص داده شده است. اولین کوشش‌ها در شبیه‌سازی با استفاده از یک مدل منطقی توسط مک‌کلوک و والتر پیتر انجام گرفت که امروزه بلوک اصلی سازنده اکثر شبکه‌های عصبی مصنوعی است. این مدل فرضیه‌هایی در مورد عملکرد نورون‌ها ارائه می‌کند. شبکه عصبی بکار گرفته شده در این مقاله، شبکه پرسپترون‌های چند لایه از نوع شبکه‌های عصبی پیشخور می‌باشد. یک پرسپترون، برداری از ورودی‌ها با مقادیر حقیقی را گرفته و یک ترکیب خطی از آنها را محاسبه می‌کند. شکل ۱ سیستم پرسپترون بکار گرفته شده برای شبکه عصبی بهبود یافته را نشان می‌دهد. [۱۲] واحدهای هر لایه ممکن است ورودی‌های یکسانی را بین خودشان تقسیم کنند در حالی که به یکدیگر متصل نباشند. عموماً واحدهای لایه ورودی جهت انتقال الگوهای ورودی به بقیه شبکه و بدون انجام هیچگونه پردازشی ایفای نقش می‌کنند.



شکل ۱. شبکه پرسپترون بهبود یافته

اطلاعات بوسیله واحدهای لایه‌های مخفی و خروجی پردازش می‌شوند. شکل ۲ معماری یک مدل شبکه عصبی پیش خور سه لایه را نشان می‌دهد.



شکل ۲. شبکه عصبی پیشخور ۳ لایه با یک لایه مخفی

۳- شبکه عصبی-فازی تطبیقی

ترکیب شبکه عصبی با منطق فازی برای استخراج بهترین رابطه بین واحدهای ورودی و خروجی، سبب افزایش کارایی ساختار شبکه عصبی در یادگیری بر روی داده‌های بار در بازار برق می‌شود. به عبارتی دیگر، استفاده از قواعد فازی سبب افزایش کارایی شبکه عصبی در یادگیری و استخراج جواب قطعی و هوشمندانه و اجتناب از محاسبات پیچیده در سیستم‌های مورد مطالعه می‌شود. به عبارتی ادغام این دو شبکه سبب افزایش انعطاف پذیری و کارآمدی شبکه عصبی می‌شود. شکل ۳ نحوه مدل‌سازی نرون-فازی را نشان می‌دهد. در حقیقت یک نرون فازی n ورودی وزن دار ($w_i, x_i, i=1, \dots, N$) و M خروجی را دارد است تمامی

حقیقت این روش اصلاحی بر روش‌های مبتنی بر شبکه عصبی و سری‌های زمانی بوده است.

با وجود کارهای انجام گرفته همچنان فقدان یک تکنیک مناسب برای مرتب سازی داده‌های ورودی در آنها نمایان می‌باشد. به منظور بهبود این نقطه ضعف از الگوریتم انتخاباتی برای مرتب‌سازی داده‌ها بهره گرفته شده است تا بهترین گزینه‌ها با پیشترین همبستگی برای آموزش وارد شبکه عصبی شوند. همچنین در این مقاله با درنظر گرفتن جنبه‌های مشبت روش‌های انجام گرفته و به منظور کاهش خطای ناشی از نوسانات غیرخطی داده‌های ورودی از عدم قطعیت استفاده شده است. این عمل قابلیت شبکه عصبی در آموزش و یادگیری را افزایش می‌دهد. یکی از مهمترین نقاط ضعف شبکه عصبی تنظیم مناسب پارامترهای آن می‌باشد. در کارهای انجام گرفته شده با روش‌های هوشمند از جمله ژنتیک و اجتماع ذرات می‌توان اهمیت ترکیب شبکه عصبی و روش‌های هوشمند را درک نمود [۱۱]. اما این روش‌ها دارای نقاط ضعف در جستجوی محلی و کلی بوده که تنظیم مناسب پارامترهای شبکه عصبی به کمک آنها به خوبی انجام نخواهد گرفت. به همین دلیل نیاز به یک روش هوشمند مناسب پیش از پیش احساب می‌شود. یکی از الگوریتم‌های جدید در زمینه بهبود سازی روش کلونی مصنوعی زنبور عسل می‌باشد. الگوریتم کلونی مصنوعی زنبور عسل بر مبنای یافتن بهترین منبع غذایی به کمک زنبورهای جستجوگر عمل می‌نماید و برخلاف سایر الگوریتم‌های مبتنی بر گروه ذرات دارای هویت است. در این مقاله به منظور آموزش بهتر شبکه عصبی و کاهش تابع برآزندگی یعنی حداقل کردن متوسط خطای خروجی، از الگوریتم کلونی مصنوعی زنبور عسل بهره گرفته شده است. از آنجا که اطلاعات به صورت بی نظم در فضای جستجو قرار دارند، بهره‌گیری از این تکنیک به طور قابل ملاحظه‌ای سرعت همگرایی، دقیق یافتن در جواب نهایی، قرار نگرفتن در نقاط محلی، انحراف معیار کم و مقاوم بودن را به همراه خواهد داشت. روش پیشنهادی بر روی بازار نیوانگلند به عنوان سیستم واقعی با اطلاعات موجود، موردنی بحث و بررسی قرار گرفته است. مهمترین ویژگی این مقاله را می‌توان در ارائه الگوریتم انتخاباتی با در نظر گرفتن عدم قطعیت به منظور تعیین بهترین ورودی‌ها، بکارگیری روش کلونی مصنوعی زنبور عسل به منظور افزایش قابلیت جستجو در فضای مطالعه و بهره‌گیری از شبکه عصبی-فازی تطبیقی در آموزش و یادگیری ساختار غیرخطی اطلاعات ورودی دانست. برای ارزیابی روش پیشنهادی از معیارهای مختلفی استفاده شده است. نتایج نشان از کارایی مناسب این الگوریتم پیشنهادی در پیش بینی بار در دوره‌های تعریف شده می‌باشد.

در ادامه این مقاله در بخش‌های زیر پیگیری خواهد شد: در بخش ۲ به معروفی الگوریتم پیشنهادی و در بخش ۳ به نحوه و مدل‌سازی پیش بینی بار در بازار برق و در بخش ۴ به شبیه‌سازی و در نهایت در بخش ۵ به نتیجه گیری اختصاص داده شده است.

لایه چهارم، گره های نتیجه: در این لایه خارجی هر گره برابر است

با:

$$o_i^3 = \bar{\omega}_i f_i = \bar{\omega}_i (p_i x_1 + q_i x_2 + r_i) \quad (4)$$

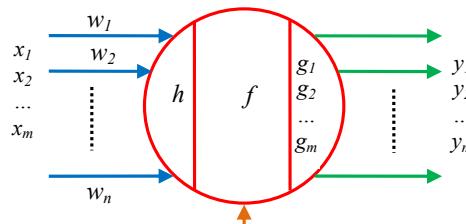
مجموع $\{S_2\} = \{p_i, q_i, r_i\}$ پارامترهای متعاقب نماید می شوند.

لایه پنجم، گره های خروجی: در این لایه هر گره مقدار خروجی نهایی را به صورت زیر محاسبه می نماید (تعداد گره ها برابر تعداد خروجی هاست):

$$o_i^5 = \sum_{i=1}^n \bar{\omega}_i f_i \quad (5)$$

در مدل عصبی-فازی زمانی عمل شبیه‌سازی به درستی انجام شده که مجموعه پارامترهای تطبیقی S_1 و مجموعه پارامترهای متعاقب S_2 طوری تخمین زده شوند که مقدار تابع خطای مدل در بخش آموزش و آزمایش به حداقل برسد. تعداد و نوع ورودی ها و همچنین شکل تابع عضویت از عوامل تاثیرگذار بر مدل نروفازی می باشد.

ورودی ها و وزن ها مقادیر حقیقی بوده و خروجی ها نیز مقادیر حقیقی مشتبی بر بازه $(0,1)$ هستند، که در حقیقت بیانگر یک مقدار عضویت در مفهوم فازی هستند. به عبارتی دیگر، این سیستم میزان مالکیت برای ورودی های مختلف را نشان می دهد.



شکل ۳. ساختار نرون-فازی

روابط حاکم بر روی سیستم نرون-فازی با در نظر گرفتن تابع اجتماعی Z با ورودی خالص h خروجی شبکه g و تابع فعالیت f به صورت زیر مدل می شود.

$$\begin{aligned} Z &= h[\omega_1 x_1, \dots, \omega_n x_n] \\ S &= f[Z - t] \end{aligned} \quad (1)$$

ترکیب سیستم های فازی که مبتنی بر قواعد منطقی بوده و روش شبکه های عصبی مصنوعی که توان استخراج دانش از اطلاعات عددی را دارد، منجر به ارائه سیستم استنتاج تطبیقی فازی-عصبی شده است. اگر خروجی هر لایه بصورت O_i^j باشد (i : این گره از l ، ساختار مدل از پنج لایه بشرح زیر تشکیل می شود):

لایه اول: پس از اینکه داده های ورودی بصورت ماتریسی (y, x) وارد سیستم شدند در این لایه با استفاده از تابع عضویت عمل فازی سازی انجام می شود. تابع عضویت مورد مطالعه برای این مقاله برای استخراج مجموعه های فازی به صورت زیر قابل بیان می باشد:

$$\mu_{A_i} = \frac{1}{1 + \left(\frac{x - c_i}{a_i} \right)^{2b_i}} \quad (2)$$

x : مقدار ورودی به گره i و مجموعه $S_i = \{a_i, b_i, c_i\}$ پارامترهای تطبیقی نماید می شوند.

لایه دوم، گره های قاعده: هر گره در این لایه درجه فعالیت یک قانون را محاسبه می کند.

لایه سوم، گره های متوسط: در این لایه، i امین گره نسبت درجه فعالیت قانون i ام را به مجموع درجه فعالیت کلیه قوانین به صورت زیر نرمال سازی می کند.

$$O_i^3 = \bar{\omega}_i = \frac{\omega_i}{\sum_i^n \omega_i} \quad (3)$$

w_i : درجه فعالیت نرمال شده قانون i

۴- روش انتخاباتی با درنظر گرفتن عدم قطعیت

برای روش های پیش بینی به کمک شبکه عصبی یکی از مهمترین مراحل انتخاب مولفه های ورودی است. در این مرحله باید تصمیم گیری شود که کدام دسته از متغیرهای ورودی سیستم دارای بیشترین ارزش در پیش بینی می باشند [۱۲]. روش بکار گرفته در این مقاله استفاده از الگوریتم انتخاباتی برای تعیین بهترین زیر مجموعه به عنوان ورودی برای مساله پیش بینی می باشد. به این منظور، معیار آنتروپی $H(X)$ برای مجموعه اعداد نامنظم X براساس توزیع احتمالاتی $P(X)$ به صورت زیر قابل بیان می باشد:

$$H(X) = - \int P(X) \log_2(P(X)) dX \quad (4)$$

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

بصورت زیر قابل بازنویسی خواهد بود:

$$H(X) = - \sum_{i=1}^n P(X_i) \log_2(P(X_i)) \quad (5)$$

براساس دو رابطه (۴) و (۵) آنتروپی اغلب یک مقدار از عدم قطعیت را در نظر می گیرد. به منظور شفاف شدن بحث، فرض نماید که متغیر X وجود از بیماری D را نشان می دهد. بنابراین اگر عدم قطعیت در مورد بیماری وجود نداشته باشد در این صورت $H(X) = 0$ و یا اگر وجود بیماری اصلا وجود ندارد در این صورت $[P(X = D) = 0, P(X = \bar{D}) = 1]$ در نتیجه آنتروپی برابر با صفر می باشد. اگر وجود یا عدم وجود بیماری به صورت عدم قطعیت اعمال شود در این صورت $[P(X = D) = 1, P(X = \bar{D}) = 0]$ و یا $[P(X = D) = 0.5, P(X = \bar{D}) = 0.5]$ و مقدار آنتروپی برابر با ۱ خواهد شد. بطور کلی اگر هر یک N بیماری دارای احتمال $[P(X = 1/N)]$ باشد در این صورت $H(X)$ دارای بیشترین مقدار $\log_2(N)$ می باشد. برای تعمیم این بحث، مجموع آنتروپی با دو عضو X و Y بصورت زیر قابل بیان خواهد بود:

۵- الگوریتم کلونی مصنوعی زنبور عسل

الگوریتم‌های غیر مبتنی بر فرومن عموماً برگرفته از رفتار زنبورهای عسل می‌باشد. الگوریتم کلونی زنبورهای مصنوعی یک تکنیک برای حل مسایل بهینه‌سازی می‌باشد که بر مبنای رفتار زنبورهای عسل در طبیعت می‌باشد. در این روش هر یک از زنبورها با همکاری مستقیم و اشتراک گذاشتن اطلاعات سعی در به دست آوردن بهترین جواب بر حسب قوانین احتمال می‌پردازد. هر کلونی در طبیعت از سه بخش منابع غذایی، زنبورهای کارگر و زنبورهای غیر کارگر تشکیل شده است. بیشترین وظیفه در هر کندو بر عهده زنبورهای کارگر می‌باشد که شامل: پرورش بچه‌ها، مراقبت از ملکه و زنبورهای نر، تمیز کردن کندو، تنظیم دمای کندو، جمع‌آوری شهد، گردآفرانی و... می‌باشد. زنبورهای غیر کارگر به دو دسته پیش‌آهنگ و تماشاگر تقسیم می‌شوند. زنبورهای پیش‌آهنگ محیط پیرامون را برای یافتن منابع غذایی جدید جستجو می‌کنند و زنبورهای تماشاگر در کندو منتظر رسیدن اطلاعات از سوی کارگرها می‌باشند. زنبورهای عسل از یک سیستم پیچیده برای یافتن اطلاعات در مورد محل و کیفیت منابع غذایی در بیرون کندو استفاده می‌کنند. ارتباط بین زنبورها توسط مراسمی که اصطلاحاً رقصیدن گفته می‌شود، انجام می‌گیرد. این زبان ارتباطی براساس حرکات پشت سر هم از سوی زنبور انجام می‌گیرد. این رقص که اصطلاحاً رقص چرخشی نامیده می‌شود، حاوی اطلاعات در مورد مکان و کیفیت منبع غذایی می‌باشد. در این نوع رقصیدن تعداد چرخش نمایان‌گر فاصله و مدت زمان چرخش نشان‌گر میزان کیفیت منبع غذایی می‌باشد. در این صورت زنبورهای تماشاگر در کندو با دیدن میزان چرخش، منبع با کیفیت را انتخاب می‌نمایند. الگوریتم کلونی زنبورهای مصنوعی (ABC) بر اساس میزان چرخش زنبور و حرکت زنبور تماشاگر به سمت منبع با کیفیت استوار می‌باشد [۱۴]. در ابتدا مجموعه‌ای از منابع غذایی به طور تصادفی (جواب‌های اولیه) انتخاب می‌شود سپس زنبورهای کارگر به منابع رجوع کرده و میزان شهد و کیفیت آنها را بررسی کرده و به کندو بر می‌گردند و اطلاعات خود را در اختیار زنبورهای تماشاگر قرار می‌دهند. سپس هر زنبور به محل حرکت می‌کند و بر اساس اطلاعات یک منبع در همسایگی آن اختیار می‌کند یعنی زنبور بر اساس نوع گل و میزان شهد آن تصمیم می‌گیرد که محل جدید یافت شده توسط زنبورهای پیش‌آهنگ، تمام شد به یک منبع جدید یافت شده توسط زنبورهای پیش‌آهنگ، حرکت می‌کند و این روند تا برآورده شدن نیازها تکرار می‌شود [۱۵]. نحوه کدگذاری این الگوریتم در مراحل زیر نشان داده شده است:

۱. مقدار دهی اولیه به عنوان جواب‌های اولیه X_{ij}
۲. محاسبه جواب‌های اولیه در تابع هدف
۳. تکرار اولیه cycle=1

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

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

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

بنابراین مقدار کل آنتروپی به صورت زیر قابل بیان می‌باشد:

$$H(X, Y) = H(X) + H(Y/X) = H(Y) + H(X/Y) \quad (10)$$

به منظور مرتب‌سازی داده‌ها روش تقابلی به صورت فرموله می‌شود:

$$MI(X, Y) = \sum_{i=1}^n \sum_{j=1}^m P(X_i, Y_j) \log_2 \left(\frac{P(X_i, Y_j)}{P(X_i)P(Y_j)} \right) \quad (11)$$

مقدار عددی بزرگ برای فرمول (۲۶) نشان از همبستگی بالا بین دو عضو X و Y می‌باشد و بالعکس. نحوه فرمول بندی برای روش تقابلی و آنتروپی در شکل ۴ نشان داده شده است.

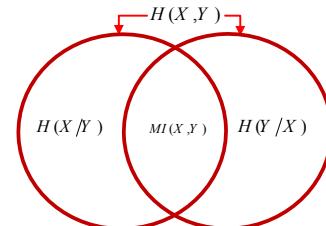
$$MI(X, Y) = H(X) - H(X/Y) \quad (12)$$

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

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

$$MI(X, Y) = MI(Y, X) \quad (15)$$

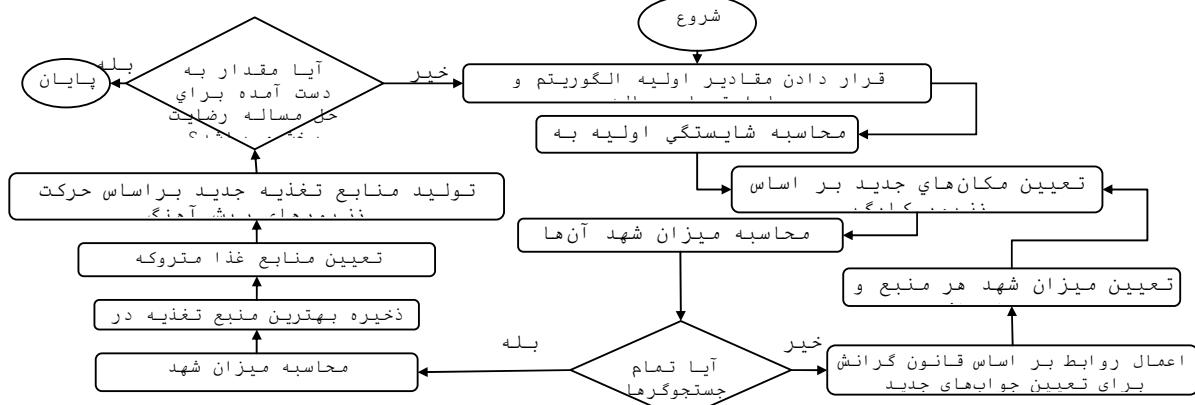
$$MI(X, X) = H(X) \quad (16)$$



شکل ۴. توزیع و انتخاب براساس تابع تقابلی

حال فرض کیم 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 براساس رابطه $MI(X, Y_m)$ با متغیر هدف X داشته باشد، X بهترین داولطب برای پیش‌بینی می‌باشد. به عنوان مثال برای $P_{h-1}, P_{h-2}, \dots, P_{h-200}$ پیش‌بینی قیمت با تعداد کاندید ۲۰۰ ساعت قبل $(P_{h-1}, P_{h-2}, \dots, P_{h-24}, P_{h-48}, P_{h-72}, \dots, P_{h-192})$ تعریف شده است نیاز به...

۴. فراهم کردن جواب‌های P_i بین (۰،۱) می‌باشد.
۷. تولید جواب‌های جدید (منابع جدید) V_{ij} بر اساس زنورهای تماشاگرای جواب‌های X_i و تعیین میزان احتمال آنها P_i .
۸. انتخاب بهترین جواب (پرخورترین زنور) با بیشترین برآزندگی بین جواب‌های X_{ij} و V_{ij} .
۹. تعیین منابع فاسد و جایگزین منابع تصادفی با آن منابع تصادفی ایجاد شده توسط زنور پیش‌آهنگ X_i با استفاده از فرمول زیر:
- $$x_{ij} = \min_j + rand(0,1) \times (\max_j - \min_j) \quad (12)$$
۱۰. ذخیره کردن بهترین جواب (منبع تغذیه با کیفیت) که تا این مرحله به دست آمده است.
۱۱. $Cycle=Cycle+1$
- تکرار تمام مراحل قبلی تا رسیدن به شرط پایان برنامه. در این مقاله شرط خاتمه تعداد تکرارهای تعریف شده برای الگوریتم کلونی مصنوعی زنور عسل می‌باشد. فلوچارت الگوریتم پیشنهادی در شکل ۵ نشان داده شده است.



شکل ۵. فلوچارت الگوریتم کلونی مصنوعی زنور عسل

گام دوم: استفاده از الگوریتم انتخاباتی پیشنهادی برای مرتب کردن داده‌ها با بیشترین همبستگی براساس معادله (۱۱)، در حقیقت در این گام بهترین داده‌ها با مقدار همبستگی بیشتر از ۰/۶ برای آموزش وارد شبکه عصبی می‌شوند.

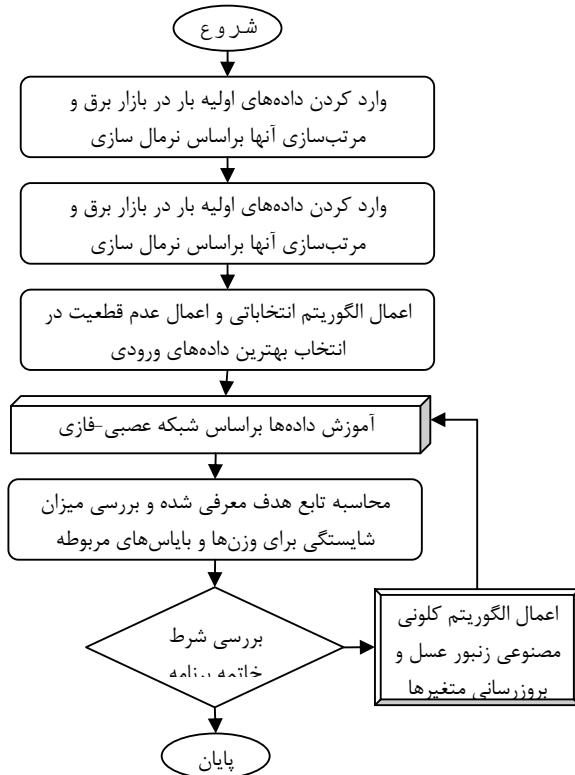
گام سوم: استفاده از شبکه عصبی برای آموزش هر بخش در جهت پیش‌بینی اطلاعات ساعتهای $T+1, \dots, T+24$ برای هر ماتریس تجزیه شده از داده‌های اولیه و انجام جمع نتایج حاصل از پیش‌بینی با یکدیگر به منظور دستیابی به اطلاعات اولیه.

گام چهارم: در این مرحله به آموزش بهتر شبکه عصبی از طریق کاهش خطای خروجی به کمک بروزرسانی وزن‌ها و بایاس‌ها پرداخته می‌شود. به عبارتی، با استفاده از الگوریتم کلونی مصنوعی زنور عسل، متغیرهای شبکه عصبی متناسب با محدوده تعیین شده و تعداد متغیر (Ng) ، تولید می‌شوند:

۶- نحوه اعمال الگوریتم پیشنهادی بر مساله بیش بینی بار در بازار برق

در این بخش به بیان الگوی بکار گرفته برای حل مساله بیش بینی بار می‌پردازیم. ابتدا فرض نمایید که پیش‌بینی برای روز d انجام می‌گیرد. همچنین فرض کنید اطلاعات گذشته سری داده‌های بار برای ۲۴ ساعت روز $d-1$ بصورت $p_h; h=1, \dots, T$ قابل دسترسی باشد که در آن T معمولاً بین حدود یک هفته الی چند ماه قبل را شامل می‌شود. به توجه به فرضیات گفته شده، مدل ایجاد شده در گام‌های زیر قبل پیگیری می‌باشد.

گام اول: ابتدا با توجه به میزان پراکندگی داده‌ها نرمالایز شده که این کار یک معیار مناسب برای سبک-سنگین کردن داده‌ها براساس میزان طول و همواری آنها می‌باشد.



شکل ۶. ساختار کلی سیستم پیش بینی ارائه شده

۷- بررسی و بحث روی سیستم مورد مطالعه

به منظور شیوه سازی و پیش بینی قیمت با الگوریتم پیشنهادی از سیستم نیوانگلند [۱۶] به عنوان یک بازار واقعی استفاده شده است. علت انتخاب این سیستم به خاطر واقعی بودن اطلاعات و دسترسی آن می‌باشد. برای شبیه سازی از نرم افزار مطلب ۲۰۱۱ با کامپیوتری با مشخصات RAM ۴ GB, CPU 2.53GHZ استفاده شده است. شکل ۷ تغییرات قیمت برای سیستم نیوانگلند برای کلیه ساعتهای سال ۲۰۰۸ را نشان می‌دهد. برای پیش اطلاعات ۵۰ روز قبل آن گرفته شده و بعد از آرایش دهی بر روی داده‌های ورودی ۱۳ کاندید برای آموزش وارد شبکه عصبی شده‌اند. در آموزش این داده‌ها ساتریس مشاهده‌گر دارای ۱۲۰۰ عضو می‌باشد. این ورودی به صورت زیر مجموعه $h-1, h-168, h-24, h-144, h-169, h-25, h-48$ دادن تغییرات بین داده‌ها از نرمالیزه کردن بهره گرفته‌ایم تا بتوان با نوسانات کمتری داده‌ها را برای آموزش و پیش بینی بکار برد. شکل ۸ تغییرات پیش بینی برای ۲۴ ساعت به کمک روش پیشنهادی را مشخص نموده است. همان گونه که از شکل مشخص است الگوریتم پیشنهادی دارای قابلیت بالایی در تعیین وزن‌ها و بایاس‌ها برای آموزش شبکه عصبی مورد مطالعه بوده است. میزان خطای ناشی از پیش بینی به کمک روش پیشنهادی برابر با $\frac{3}{54}$ می‌باشد. معیار SDE برای مقایسه نتایج بصورت زیر قابل تعریف می‌باشد:

$$\begin{aligned} X_{cls}^0 &= [X_{cls,0}^1, X_{cls,0}^2, \dots, X_{cls,0}^{Ng}]_{1 \times N_g} \\ cx_0 &= [cx_0^1, cx_0^2, \dots, cx_0^{Ng}] \\ cx_0^j &= \frac{X_{cls,0}^j - P_{j,\min}}{P_{j,\max} - P_{j,\min}}, j = 1, 2, \dots, Ng \end{aligned} \quad (13)$$

برای این معادله خواهیم داشت:

$$\begin{aligned} X_{cls}^i &= [X_{cls,i}^1, X_{cls,i}^2, \dots, X_{cls,i}^{Ng}]_{1 \times N_g}, i = 1, 2, \dots, N_{bee} \\ x_{cls,i}^j &= cx_{i-1}^j \times (P_{j,\max} - P_{j,\min}) + P_{j,\min}, j = 1, 2, \dots, N_g \end{aligned} \quad (15)$$

در رابطه بالا X_{cls}^0 مکان بدست آمده اولیه برای الگوریتم پیشنهادی می‌باشد. $P_{j,\max}$ و $P_{j,\min}$ به ترتیب مقدار پایین و بالایی برای متغیر مورد نظر می‌باشد. N_{bee} تعداد متغیرهای الگوریتم پیشنهادی می‌باشد.

گام پنجم: در این قسمت متغیرها براساس روابط کلونی مصنوعی زنبور عسل برای یافتن جواب‌های بهتر ارتقا می‌یابند.

گام ششم: در این بخش با کمک تابع هدف معرفی شده که بر مبنای کاهش خطای خروجی می‌باشد، بهینه کردن وزن‌ها و بایاس‌ها برای شبکه عصبی به منظور آموزش بهتر آن انجام می‌گیرد. تابع هدف مورد استفاده در این مقاله درصد خطای مطلق متوسط (MAPE) است که براساس تعداد روزهای مورد مطالعه (N) به صورت زیر قابل فرموله شدن می‌باشد:

$$MAPE = \frac{100}{N} \sum_{h=1}^N \frac{|\hat{p}_h - p_h|}{\bar{p}} \quad (16)$$

در رابطه بالا، p_h مقدار واقعی و \hat{p}_h مقدار پیش‌بینی شده می‌باشد.

گام هفتم: بررسی شرط خاتمه برنامه. اگر شرط برنامه برقرار شده است نتایج حاصله چاپ شود در غیر این صورت به گام دوم سوق یابد.

شکل ۶ فلوچارت الگوریتم پیشنهادی را برای حل مساله پیش‌بینی نشان می‌دهد.

الگوریتم پیشنهادی دارای کارایی بالا، سرعت مناسب و دقیقت بالا می‌باشد. برای نشان دادن کارایی روش پیشنهادی از معیارهای مانند $MAPE$ (میانگین قدرمطلق خطای درصدی) و یا MAE و قدرمطلق درصد خطای روزانه $DMAPE$ استفاده شده است که با روابط زیر تعریف می‌گردد.

$$MAPE = \frac{1}{N} \sum_{i=1}^N \frac{|L_{ACT(i)} - L_{FOR(i)}|}{L_{ACT(i)}} \quad (19)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |L_{ACT(i)} - L_{FOR(i)}| \quad (20)$$

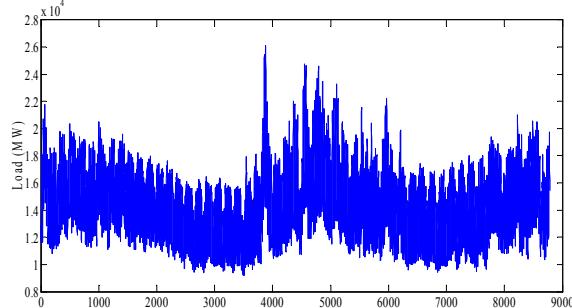
$$DMAPE = \frac{1}{24} \sum_{t=1}^{24} \frac{|L_{ACT_t} - L_{FOR_t}|}{\frac{1}{24} \sum_{t=1}^{24} L_{ACT_t}} \quad (21)$$

که در رابطه بالا، L_{ACT} و L_{FOR} به ترتیب مقدار پیش‌بینی شده و مقدار واقعی هستند. مقدار بدست آمده برای معیارهای MAE و $MAPE$ و $DMAPE$ به ترتیب $0.76/0.76/0.76$ و $0.157/0.157/0.157$ می‌باشد. نتایج بدست آمده نشان از کارایی و دقیقت مناسب برای مساله پیش‌بینی را به همراه دارد. به منظور نشان دادن کارایی بالای روش پیشنهادی، دوره زمانی را در یک سال افزایش داده یه به عبارتی پیش‌بینی بلند مدت انجام می‌دهیم. شکل ۹ تغییرات پیش‌بینی بار و مقدار پیش‌بینی شده توسط روش پیشنهادی را نشان می‌دهد. شکل ۱۰ نحوه تغییرات خطای و معیارهای مورد نظر را نشان می‌دهد. که در آن $MAPE$ برابر با 1.57% و MAE برابر با 236.43 MWh هفتگی می‌باشد.

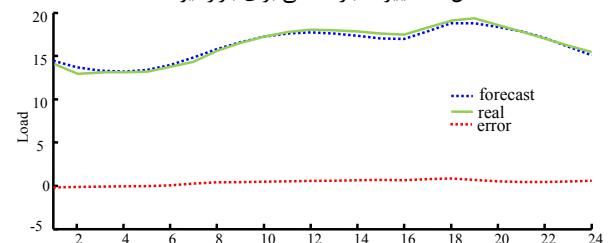
$$SDE = \sqrt{\frac{1}{N} \sum (e_k - \bar{e})^2} \quad (17)$$

که در آن، e_k خطای پیش‌بینی در ساعت k و \bar{e} خطای متوسط در پریود پیش‌بینی است.

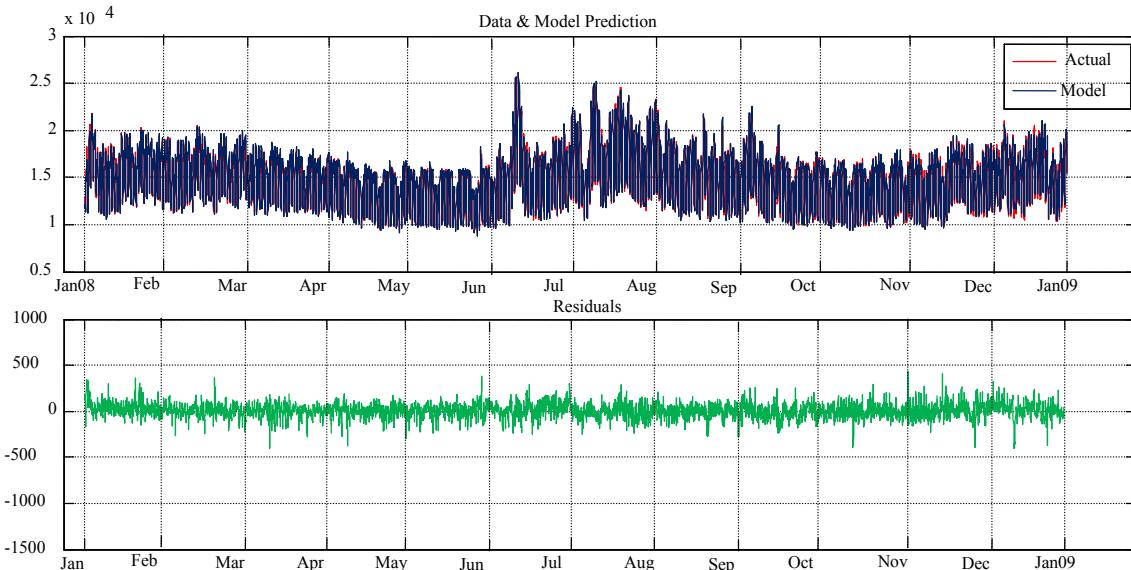
$$e_h = \hat{p}_h - p_h \quad (18)$$



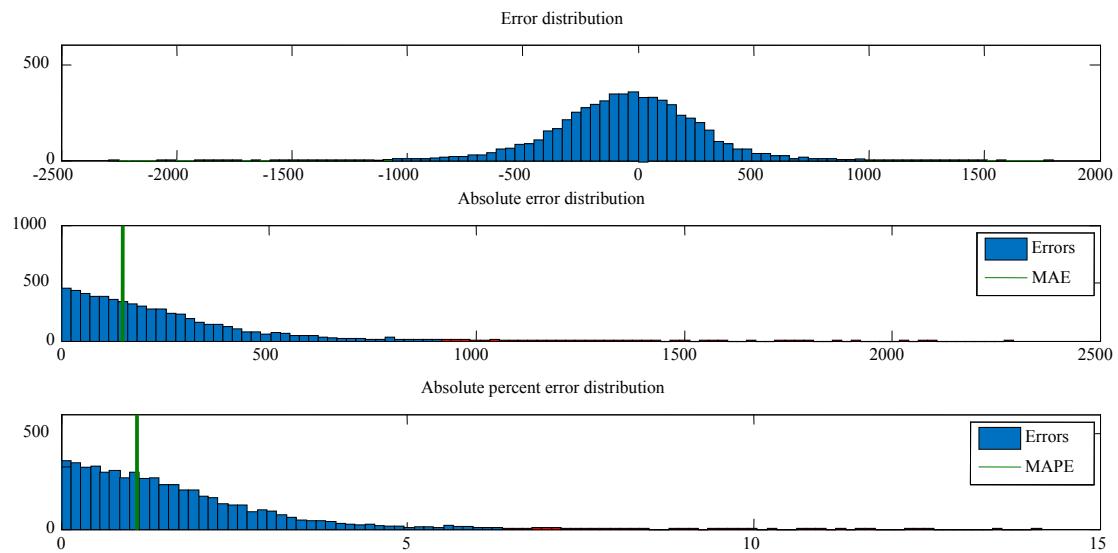
شکل ۷. تغییرات بار ساعتی برای بازار نیو انگلند



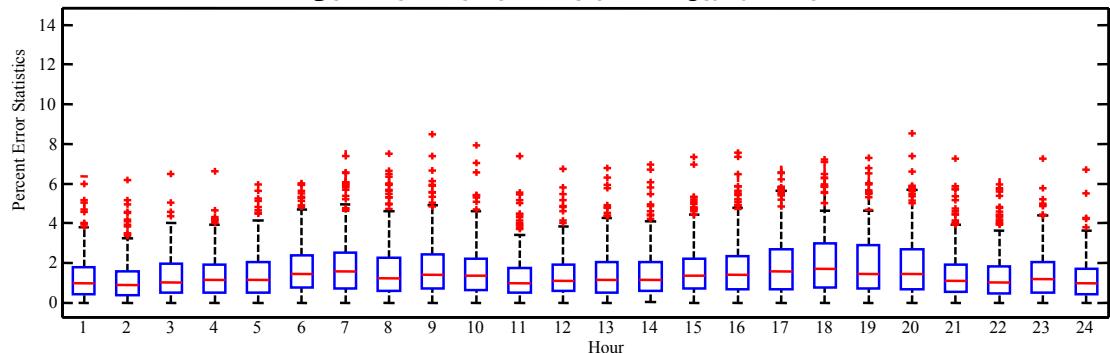
شکل ۸. نتایج شبیه سازی برای سیستم نیو انگلند



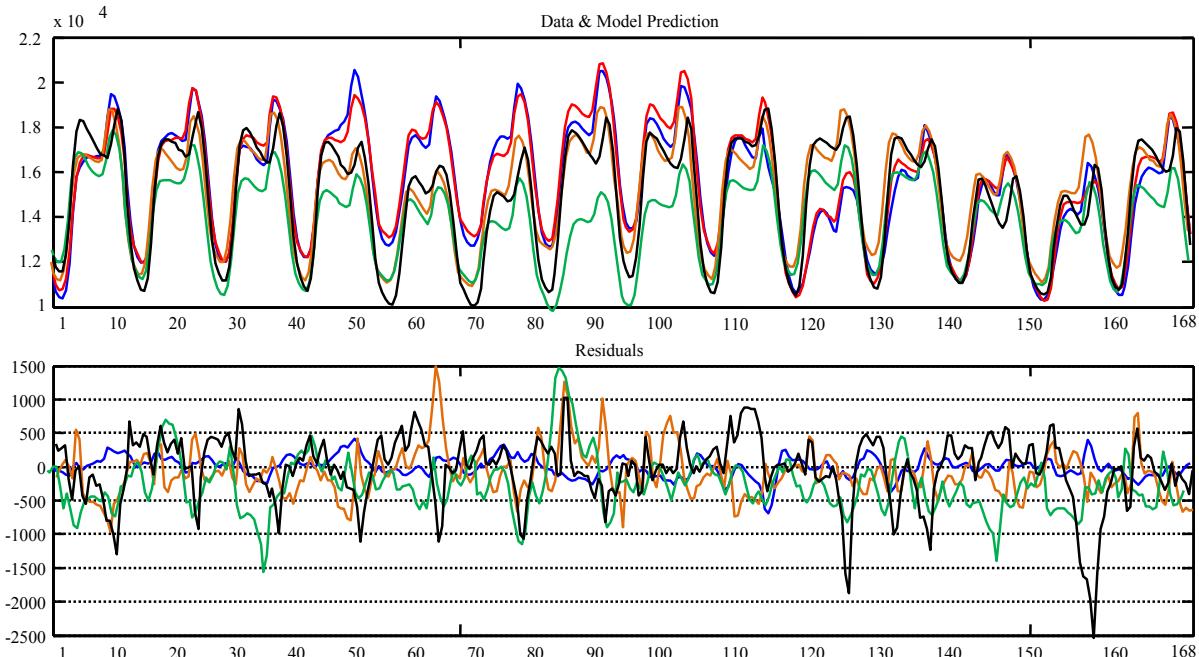
شکل ۹. نتایج حاصل از شبیه سازی برای سیستم مورد مطالعه در دوره زمانی طولانی



شکل ۱۰. نحوه توزیع خطای حاصل از شبیه سازی برای معیارهای معرفی شده



شکل ۱۱. نحوه توزیع خطای حاصل از پیش بینی برای بار ساعتی

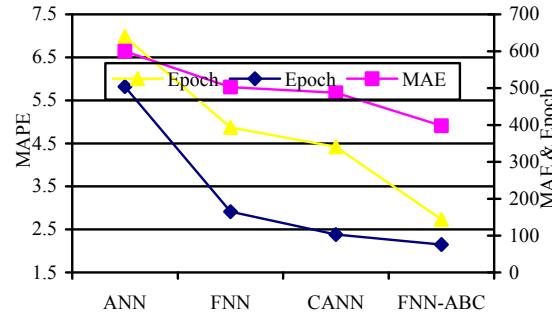


شکل ۱۲. نتایج حاصل از شبیه سازی برای هفته آخر سال: الگوریتم پیشنهادی (آی)، شبکه عصبی (سیز)، عصبی-فازی (مشکی)، الگوریتم انتخاباتی و عصبی بهبود یافته (نارنجی) و دیتا واقعی شبکه (قرمز)

مراجع

- [1] R. Hooshmand, H. Amooshahi, M. Parastegari," A hybrid intelligent algorithm based short-term load forecasting approach," Electrical Power and Energy Systems, 2013;45:313–324.
- [2] HK. Alfares, M. Nazeeruddin," Electric load forecasting: literature survey and classification of methods," Int J Syst Sci 2002;33(1):23–34.
- [3] N. Amjadi," Short-term hourly load forecasting using time-series modeling with peak load estimation capability," IEEE Trans on Power Syst, 2001;16(3):498–505.
- [4] T. Bollerslev," Generalized autoregressive conditional heteroskedasticity," J Econom, 1986;31(3):307–27.
- [5] N. Amjadi," Short-term Bus Load Forecasting of Power Systems by a New Hybrid Method," IEEE Transactions on Power Systems, 2007;22(1):333–341.
- [6] Al-Hamadi H. M and S. A. Soliman," Long Term/Mid Term Electric Load Forecasting Based on Short-term Correlation and Annual Growth," Electrical Power Systems Research, 2005;74(3):353–361.
- [7] C. Xia, J. Wang, K. McMenamy," Short, medium and long term load forecasting model and virtual load forecaster based on radial basis function neural networks," Int J Electr Power Energy Syst, 2010;32:743–50.
- [8] Y. Chen, PB. Luh, C. Guan, Y. Zhao, LD. Michel, MA. Coolbeth, et al," Short-term load forecasting: similar day-based wavelet neural networks," IEEE Trans Power Syst, 2010;25(1):322–30.
- [9] ND. Uri," Forecasting peak system load using a combined time series and econometric model," Appl Energy, 1978;4(3):219–27.
- [10] AM. Al-Kandari, SA. Soliman, ME. El-Hawary," Fuzzy short-term electric load forecasting," Int J Electr Power Energy Syst 2004;26:111–22.
- [11] M. AlRashidi, K. EL-Naggar," Long term electric load forecasting based on particle swarm optimization," Appl Energy 2010;87(1):320–6.
- [12] H. Hippert, C. Pedreira, R. Souza," Neural networks for short-term load forecasting: a review and evaluation," IEEE Trans on Power Syst, 2001;16(1):44–55.
- [13] N. Amjadi, F. Keynia," Day-Ahead Price Forecasting of Electricity Markets by Mutual Information Technique and Cascaded Neuro-Evolutionary Algorithm," IEEE Transaction on Power System, 2009;24(1):12–20.
- [14] D. Karaboga, B. Akay,"A comparative study of artificial bee colony algorithm," Applied Mathematics and Computation, 2009;21:108–132.
- [15] C. Zhang, D. Ouyang, J. Ning, An artificial bee colony approach for clustering, Expert Systems with Applications, 2010;37:4761–4767.
- [16] <http://www.iso-ne.com/>. <http://www.wsj.com>.

شکل ۱۱ تغییرات خطای ایجاد شده در پیش بینی بار ساعتی را نشان می دهد. پیوستگی مناسب در محدوده کم نشان از اذ دقیقت بالای این روش پیشنهادی می باشد. همچنین به منظور مقایسه کارایی روش پیشنهادی انجام پیش بینی مدت به وسیله الگوریتم پیشنهادی، شبکه عصبی فازی و شبکه عصبی بهبود یافته در طول یک هفته انجام گرفته است. نتایج شبیه سازی در شکل ۱۲ نشان داده شده است. شبیه سازی برای هفتة اول ۲۰۰۸ March در بازار نیوآنگلند انجام گرفته است. قسمت پایینی شکل ۱۳ میزان خطای حاصل از شبیه سازی را نشان می دهد. انحراف معیار کم برای خطای حاصل از شبیه سازی نشان از دقیقت و قابلیت بالای روش پیشنهادی می باشد. همچنان که نتایج در شکل ۱۲ به صراحت این مطلب را تایید می نماید. میزان زمان اجرای برنامه با مشخصات سیستم گفته شده برای دوره روزانه ۲۷ دقیقه، برای هفتگی ۳۴ دقیقه و برای طولانی مدت ۳۸ دقیقه بوده است.



شکل ۱۳. نتایج بدست امده برای معیارهای معرفی شده در پیش بینی هفتگی

-۸- نتیجه گیری

در پی تغییر ساختار بازار برق از بازار انحصاری دولتی به بازار رقابتی که در آن قیمت توسط نیروهای بازار تعیین می شود، مدلسازی و پیش بینی باز مردم تقاضا کاملاً ریسکی و همراه با عدم قطعیت الکترونیکی تعیین شده در بازار رقابتی برای فعلان بازار برق اهمیت ویژه ای یافته است. برای مدلسازی و پیش در بازار رقابتی باید ویژگیهای این کالا از جمله عدم قابلیت ذخیره سازی، کم کشش بودن، فصلی بودن تقاضا و لزوم تعادل پیوسته عرضه و تقاضا که منجر به فراریت میزان تقاضا می گردد، در نظر گرفت. هدف از این مقاله حاضر، طراحی و اجرای یک مدل از الگوریتم کلونی مصنوعی زنبور عسل و شبکه عصبی بهبود یافته مدت میزان بار در بازار برق جهانی می باشد. نتایج بدست آمده از شبیه سازی ها نشان از قابلیت بالای این الگوریتم در پیش بینی بهتر در مقایسه با سایر روش های موجود می باشد. همچنین نتایج مناسب بدست آمده، نشان از موفقیت الگوریتم انتخاباتی در مرتب سازی داده ها دارد. نتایج به دست آمده از شبیه سازی ها نشان از کارایی بالای الگوریتم ترکیبی در پیش بینی بار داشته است.