نشریه علمی- پژوهشی کیفیت و بهره وری صنعت برق ایران
Iranian Electric Industry Journal
Of Quality And Productivity

سال دوم شماره سوم بهار و تابستان ۱۳۹۲
Vol 2 –No.3 Spring and Summer

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]

[۱]دانشکده مهندسی برق-کامپیوتر، دانشگاه محقق اردبیلی، اردبیل، ایران
[۲]دانشگاه 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 تقاضا توسط 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 سودهی آنها کاهش دهد، اهمیت ویژه‌ای یافته است. برای مدلسازی و پیش‌بینی بار در بازار رقابتی باید خصوصیات این کالا از جمله فصلی بودن تقاضا 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 پیش بینی بار در بازار برق با تنوع تعداد متغیرهای ورودی و عدم پیروی متغیرها از یک مدل سری مشخص، خطای ناشی از پیش بینی افزایش خواهد یافت. در این مقاله با انگیزه 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 پیش بینی می‌دهد. همچنین الگوریتم هوشمند ارایه شده قابلیت جستجوی محلی و نهایی آن به طور قابل ملاحظه‌ای بهبود یافته است.

واژه های کلیدی: پیش بینی 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.

Archive of SID
www.SID.ir

۱- مقدمه

امروزه بازار برق بیش از پیش به همکاری با سایر بازارها از جمله بازار سوخت، خدمات جانبی و آلودگی می‌پردازد. بنابراین تصمیم‌گیری برای فعالان بازار در جهت افزایش سودهی به مراتب پیچیده‌تر شده است. موفقیت در بازار رقابتی برق تجدید ساختار یافته امروزی مستلزم داشتن مهارت قابل قبول درکار تخمین براساس معیارهای علمی می‌باشد. عوامل بازار انرژی از میزان کسب سود حاصل از قراردادهای بلندمدت تحویل 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 برده باشند. در راستای تحقق این هدف، شرکت‌های تولیدی یا مصرفی انرژی، در جهت بهبود دقت پیش‌بینی کارهائی 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 فروشنده را انتخاب کنند. با تأمین سرویس بهتر و انرژی ارزانتر، مشتریان بیشتری جذب می‌شوند که این کار سود بیشتری عاید فروشنده می‌نماید و از طرفی مشتریان نیز منافع بیشتری می‌برند. فروشندگان یا تأمین‌کنندگان انرژی نمایندگانی هستند که انرژی را به مشتری می فروشند هر چند که ممکن است آنها تولید کننده نباشند، اما سهم تولید نیروگاههارا بخرند. این ساختار جدید سیستم قدرت، مفاهیم قدیمی را به چالش کشانده است. در گذشته تمرکز تحقیقات روی فرمول‌سازی برخی محدودیت‌های عملی از قبیل دامنهٔ ولتاژ شین‌ها، محدودیت‌های تولید، ظرفیت خطوط انتقال، محدودیت‌های احتمالی، ملاحظات محیطی و مسائلی ازاین قبیل بود. جهت تضمین دسترسی آزاد فروشندگان و خریداران به سیستم انتقال، بهره‌برداری از سیستم انتقال مستلزم مستقل بودن بخش مدیریتی ازسهام بازار است. بهره‌برداران مستقل سیستم نقش هماهنگ‌ساز مرکزی را ایفا می‌کنند و با فراهم کردن امنیت و قابلیت اطمینان سیستم درجهٔ کیفیت و امنیت سیستم را تضمین می‌نمایند [۱]. از میان انواع انرژی‌ها در جهان، انرژی الکتریکی خصوصیات منحصر به فرد دارد که از جمله می توان به موارد زیر اشاره کرد: الف) این انرژی به صورت وسیع قابل ذخیره‌سازی نیست، ب) بازده سرمایه‌گذاری در رابطه با انرژی الکتریکی زمان‌بر می‌باشد (به خصوص در کشورهای جهان سوم که عمده 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 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 روشن و مبتنی بر تئوری‌های دقیق از روند آتی تقاضای این انرژی را داشته باشند [۲]. یکی از عناصر کلیدی در مدیریت و تصمیم گیری، 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 می توان به رگراسیون دینامیکی و تابع تبدیل [۲]، خودرگرسیون جمعی میانگین متحرک* [۳]، خود رگرسیون 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 روش ها بخاطر سادگی در پیاده‌سازی و خطی بودن مورد توجه قرار گرفته‌اند اما در سیستم غیرخطی کارایی کافی نداشته و خطای پیش بینی 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 پردازشگر اطلاعات اشاره نمود، براساس شبکه عصبی انسان در یادگیری مدلسازی شده است. به عبارتی دیگر یک شبکه عصبی مدلی از نرون‌های عصبی مغز می‌باشد. در راستای استفاده از این الگو، مقالات متعددی در زمینه پیش بینی انجام گرفته است. در مرجع [۷] از روش شبکه عصبی به پیش بینی 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 داده های 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

* Auto regressive integrated moving average model (ARIMA)
† Generalized Auto Regressive Conditional Heteroskedasticity (GARCH)

Archive of SID

www.SID.ir

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 بیشترین همبستگی برای آموزش وارد شبکه عصبی شوند. همچنین در این مقاله با درنظر گرفتن جنبه‌های مثبت 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 بیش از پیش احساس می‌شود. یکی از الگوریتم‌های جدید در زمینه بهینه‌سازی 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 الگوریتم های 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 فضا جستجو قرار دارند، بهره‌گیری از این تکنیک به طور قابل ملاحظه‌ای سرعت همگرایی، دقت 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، مورد 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 فضا مورد مطالعه و بهره گیری از شبکه عصبی-فازی تطبیقی در آموزش و یادگیری ساختار غیرخطی اطلاعات ورودی دانست. برای ارزیابی روش پیشنهای از معیارهای مختلفی استفاده شده است. نتایج نشان از کارایی مناسب این الگوریتم پیشنهادی در پیش بینی بار در دوره‌های تعریف شده می باشد.

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

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 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 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 پریستون بکار گرفته شده برای شبکه عصبی بهبود یافته را نشان می‌دهد [۱۲]. واحدهای هر لایه ممکن است ورودیهای یکسانی را بین خودشان تقسیم کنند درحالی که به یکدیگر متصل نباشند. عموماً واحدهای لایه ورودی جهت انتقال الگوهای ورودی به بقیه شبکه و بدون انجام هیچگونه پردازشی ایفای نقش می‌کنند.

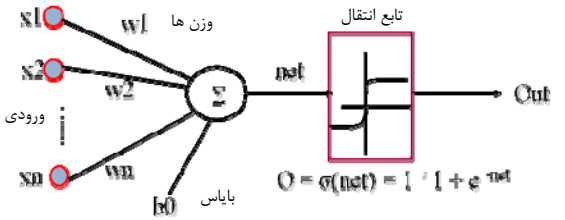

شکل ۱. شبکه پریستون بهبود یافته

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

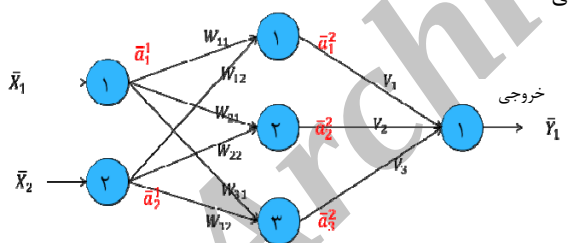

شکل ۲. شبکه عصبی پیشخور ۳ لایه با یک لایه مخفی

۳- شبکه عصبی-فازی تطبیقی

ترکیب شبکه عصبی با منطق فازی برای استخراج بهترین رابطه بین داده‌های 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 $(w_i, x_i, i=1,...,N)$ و M خروجی را داراست تمامی

Archive of SID

www.SID.ir

ورودی‌ها و وزن‌ها مقادیر حقیقی بوده و خروجی‌ها نیز مقادیر حقیقی مثبتی بر بازه (۰،۱) هستند، که در حقیقت بیانگر یک مقدار عضویت در مفهوم فازی هستند. به عبارتی دیگر، این سیستم میزان مالکیت برای ورودی‌های مختلف را نشان می‌دهد.

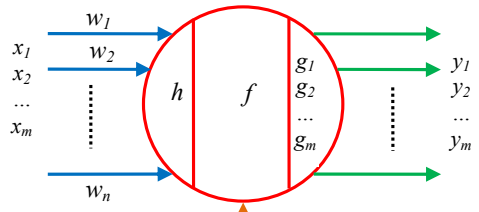

شکل ۳. ساختار نرون-فازی

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

$$\begin{aligned} Z &= h[\omega_1 x_1,...,\omega_n x_n] \\ S &= f[Z-t] \\ Y_j &= g[S] \quad for \quad j=1,...,M \end{aligned} \qquad (۱)$$

ترکیب سیستم‌های فازی که مبتنی بر قواعد منطقی بوده و روش شبکه‌های عصبی مصنوعی که توان استخراج دانش از اطلاعات عددی را دارد، منجر به ارائه سیستم استنتاج تطبیقی فازی–عصبی شده است. اگر خروجی هرلایه بصورت O_i^lباشد (i امین گره از l)، ساختار مدل از پنج لایه بشرح زیرتشکیل می شود:

لایه اول: پس از اینکه داده های ورودی بصورت ماتریسی (y,x) وارد سیستم شدند در این لایه با استفاده از توابع عضویت عمل فازی‌سازی انجام می‌شود. تابع عضویت مورد مطالعه برای این مقاله برای استخراج مجموعه‌های فازی به صورت زیر قابل بیان می‌باشد:

$$\mu_{A_i} = \frac{1}{1+\left(\frac{x-c_i}{a_i}\right)^{2b_i}} \qquad (۲)$$

x: مقدار ورودی به گره i و مجموعه $s_1=\{a_i,b_i,c_i\}$ پارامترهای تطبیقی نامیده می‌شوند.

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

لایه سوم،گره‌های 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 می‌کند.

$$o_i^3 = \bar{\omega}_i = \frac{\omega_i}{\sum_i^n \omega_i} \qquad (۳)$$

$\overline{w_i}$: درجه فعالیت نرمال شده قانون i ام

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

$$o_i^3 = \bar{\omega}_i f_i = \bar{\omega}_i (p_i x_1 + q_i x_2 + r_i) \qquad (۴)$$

مجموع $S_2=\{p_i,q_i,r_i\}$ پارامترهای متعاقب نامیده 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):

$$o_i^5 = \sum_{i=1}^{n} \bar{\omega}_i f_i \qquad (۵)$$

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 ورودی‌ها و همچنین شکل تابع عضویت از عوامل تاثیرگذار بر مدل نروفازی می‌باشد.

۴- روش انتخاباتی با درنظر گرفتن عدم قطعیت

برای روش‌های پیش‌بینی به کمک شبکه عصبی یکی از مهمترین مراحل انتخاب مولفه‌های ورودی است. در این مرحله باید تصمیم‌گیری شود که کدام دسته از متغیرهای ورودی سیستم دارای بیشترین ارزش در پیش‌بینی می‌باشند [۱۳]. روش بکارگرفته در این مقاله استفاده از الگوریتم انتخاباتی برای تعیین بهترین زیر مجموعه به عنوان ورودی برای مساله پیش بینی می‌باشد. به این منظور، معیار آنتروپی $H(X)$ برای مجموعه اعداد نامنظم X براساس توزیع احتمالاتی $P(X)$ به صورت زیر قابل بیان می‌باشد:

$$H(X) = -\int P(X)\log_2(P(X))dX \qquad (۶)$$

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

$$H(X) = -\sum_{i=1}^{n} P(X_i)\log_2(P(X_i)) \qquad (۷)$$

براساس دو رابطه (۶) و (۷) آنتروپی اغلب یک مقدار از عدم قطعیت را در نظر می‌گیرد. به منظور شفاف شدن بحث، فرض نمایید 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 اصلا وجود ندارد در این صورت $[P(X=D)=0, P(X=\bar{D})=1]$ در نتیجه آنتروپی برابر با صفر می‌باشد. 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. بطور کلی اگر هر یک N بیماری دارای احتمال $[P(X)=1/N]$ باشد در این صورت $H(X)$ دارای بیشترین مقدار $log_2(N)$ می‌باشد. برای تعمیم این بحث، مجموع آنتروپی با دو عضو X و Y بصورت زیر قابل بیان خواهد بود:

Archive of SID

www.SID.ir

$$H(X,Y) = -\sum_{i=1}^{n}\sum_{j=1}^{m} P(X_i,Y_j)\log_2\left(P(X_i,Y_j)\right) \quad (۸)$$

با در نظر گرفتن عدم قطعیت برای یک سرای از داده ها، مقدار عدم قطعیت سایر متغیرها بصورت زیر تعریف می شوند:

$$H(Y/X) = \sum_{i=1}^{n} P(X_i)H(Y/X=X_i) =$$
$$-\sum_{i=1}^{n} P(X_i)\sum_{j=1}^{m} P(Y_j/X_i)\log_2\left(P(Y_j/X_i)\right) = \quad (۹)$$
$$-\sum_{i=1}^{n}\sum_{j=1}^{m} P(X_i,Y_j)\log_2\left(P(Y_j/X_i)\right)$$

بنابراین مقدار کل آنتروپی به صورت زیر قابل بیان می‌باشد:

$$H(X,Y) = H(X) + H(Y/X) = H(Y) + H(X/Y) \quad (۱۰)$$

به منظور مرتب‌سازی داده‌ها روش تقابلی به صورت فرموله می‌شود:

$$MI(X,Y) = \sum_{i=1}^{n}\sum_{j=1}^{m} P(X_i,Y_j)\log_2\left(\frac{P(X_i,Y_j)}{P(X_i)P(Y_j)}\right) \quad (۱۱)$$

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

$$MI(X,Y) = H(X) - H(X/Y) \quad (۱۲)$$
$$MI(X,Y) = H(Y) - H(Y/X) \quad (۱۳)$$
$$MI(X,Y) = H(X) + H(Y) - H(X,Y) \quad (۱۴)$$
$$MI(X,Y) = MI(Y,X) \quad (۱۵)$$
$$MI(X,X) = H(X) \quad (۱۶)$$

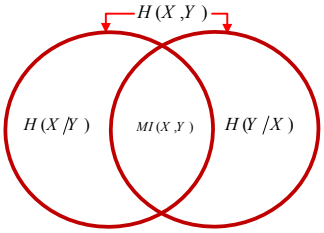

شکل ۴. توزیع و انتخاب براساس تابع تقابلی

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 $Y_1, Y_2, \ldots, Y_N$ 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 داوطلب برای پیش‌بینی می‌باشد. به عنوان مثال برای پیش بینی قیمت با تعداد کاندید ۲۰۰ ساعت قبل که به صورت $(P_{h-1}, P_{h-2}, \ldots, P_{h-200})$ تعریف شده است نیاز به $h\text{-}24, h\text{-}48, h\text{-}72, \ldots, h\text{-}192$ ساعت قبل داریم.

۵- الگوریتم کلونی مصنوعی زنبور عسل

الگوریتم‌های غیر مبتنی بر فرومن عموما 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 می-پردازد. 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، گرده‌افشانی 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 می-کنند. ارتباط بین زنبورها توسط مراسمی که اصطلاحا رقصیدن گفته می‌شود، انجام می‌گیرد. این زبان ارتباطی برا اساس حرکات پشت سر هم از سوی زنبور انجام می‌گیرد. این رقص که اصطلاحا 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 می-نماید. 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 بماند یا به محل قبلی برود. زمانی که منبع تمام شد به یک منبع جدید یافت شده توسط زنبورهای پیش‌آهنگ، حرکت می‌کنند و این روند تا بر آورده 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

Archive of SID

www.SID.ir

۴. فراهم کردن جواب¬های جدید بر اساس یافتن منبع تغذیه جدید V_{ij} در همسایگی X_{ij} ، برای تولید جواب-های جدید از فرمول زیر استفاده می¬شود:

$$v_{ij} = x_{ij} + \phi_{ij}(x_{ij} - x_{k,j}) \quad (۱۷)$$

که در این فرمول k جواب به دست آمده در همسایگی از i و ϕ یک عدد تصادفی بین (۱،۱-) می‌باشد.

۵. انتخاب بهترین منبع یا جواب بهتر بین X_{ij} و V_{ij}.

۶. محاسبه میزان احتمال برای جواب¬های X_{ij} بر اساس فرمول زیر:

$$P_i = \frac{fit_i}{\sum_{i=1}^{SN} fit_i} \quad (۱۸)$$

در حقیقت برای به دست آوردن شایستگی جواب¬ها از فرمول زیر استفاده می¬کنیم:

$$fit_i = \begin{cases} \frac{1}{1+f_i} & f_i \geq 0 \\ 1+abs(f_i) & f_i < 0 \end{cases} \quad (۱۹)$$

جواب¬های P_i بین (۱،۱-) می¬باشد.

۷. تولید جواب¬های جدید (منابع جدید) Vi بر اساس زنبورهای تماشاگراز جواب¬های X_i و تعیین میزان احتمال آنها P_i .

۸. انتخاب بهترین جواب (پرخورترین زنبور یا بیشترین برآزندگی) بین جواب¬های X_{ij} و V_{ij}.

۹. تعیین منابع فاسد وجایگزین منابع تصادفی با آن منابع تصادفی ایجاد شده توسط زنبور پیش¬آهنگ X_i با استفاده از فرمول زیر:

$$x_{ij} = \min_j + rand(0,1) \times (\max_j - \min_j) \quad (۱۲)$$

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 زنبور عسل می‌باشد. فلوچارت الگوریتم پیشنهادی در شکل ۵ نشان داده شده است.

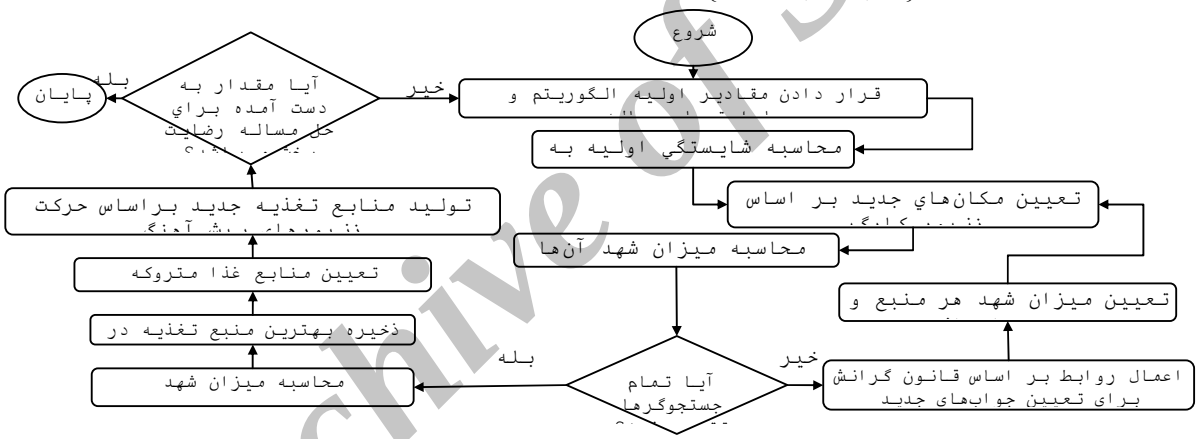

شکل ۵. فلوچارت الگوریتم کلونی مصنوعی زنبور عسل

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

در این بخش به بیان الگوی بکار گرفته برای حل مساله پیش 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 $p_h; h = 1,...,T$ قابل دسترسی باشد که در آن T معمولا بین حدود یک هفته الی چند ماه قبل را شامل می‌شود. به توجه به فرضیات گفته شده، مدل ایجاد شده در گام‌های زیر قابل پیگیری می باشد.

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.

گام دوم: استفاده از الگوریتم انتخاباتی پیشنهای 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 $T+1,...,T+24$ 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 زنبور عسل، متغیرهای شبکه عصبی متناسب با محدوده تعیین شده و تعداد متغیر (Ng)، تولید می‌شوند:

Archive of SID

www.SID.ir

$$X_{cls}^{0} = [X_{cls,0}^{1}, X_{cls,0}^{2}, ..., X_{cls,0}^{Ng}]_{1\times N_g}$$
$$cx_0 = [cx_0^1, cx_0^2, ..., cx_0^{Ng}] \quad (۱۳)$$
$$cx_0^j = \frac{X_{cls,0}^{j} - P_{j,\min}}{P_{j,\max} - P_{j,\min}}, j = 1,2,...,Ng$$

برای این معادله خواهیم داشت:

$$X_{cls}^{i} = [X_{cls,i}^{1}, X_{cls,i}^{2}, ..., X_{cls,i}^{Ng}]_{1\times N_g}, i = 1,2,...,N_{bee} \quad (۱۵)$$
$$x_{cls,i}^{j} = cx_{i-1}^{j} \times (P_{j,\max} - P_{j,\min}) + P_{j,\min}, j = 1,2,...,N_g$$

در رابطه بالا X_{cls}^{0} مکان بدست آمده اولیه برای الگوریتم پیشنهادی می‌باشد. $P_{j,\min}$ و $P_{j,\max}$ 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:

$$MAPE = \frac{100}{N}\sum_{h=1}^{N}\frac{|\hat{p}_h - p_h|}{\bar{p}} \quad (۱۶)$$

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 می دهد.

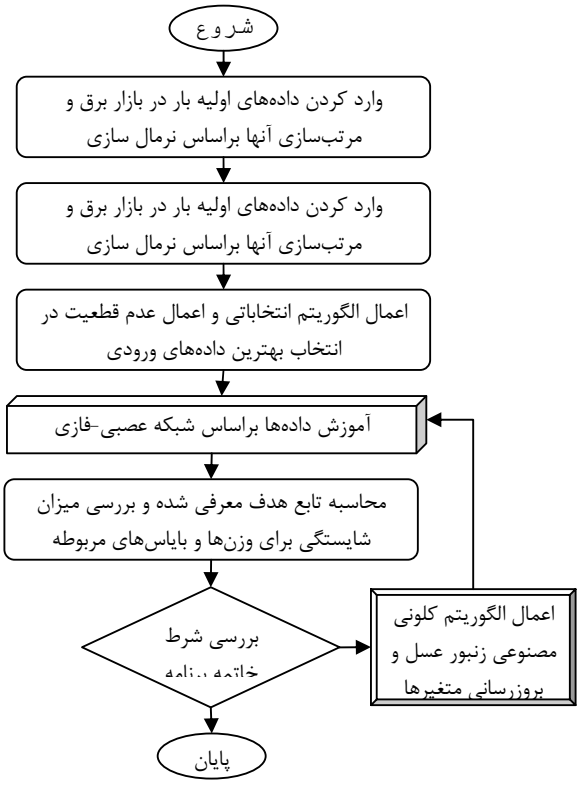

شکل ۶. ساختار کلی سیستم پیش بینی ارائه شده

۷- بررسی و بحث روی سیستم مورد مطالعه

به منظور شبیه 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 CPU 2.53GHZ، RAM 4 GB و سیستم پردازشگر Intel Core Duo Processor 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 ماتریس مشاده‌گر دارای ۱۲۰۰ عضو می‌باشد. این ورودی به صورت زیر مجموعه *h-1, h-168, h-24 h-144, h-169, h-25, h-48* تعریف می‌شوند. برای کاهش 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 ۳/۵۴ می‌باشد. معیار SDE برای مقایسه نتایج بصورت زیر قابل تعریف می‌باشد:

Archive of SID

www.SID.ir

$$SDE = \sqrt{\frac{1}{N}\sum (e_h - \bar{e})^2} \quad (۱۷)$$

که در آن، e_k خطای پیش‌بینی در ساعت hام و e خطای متوسط در پریود پیش‌بینی است.

$$e_h = \hat{p}_h - p_h \quad (۱۸)$$

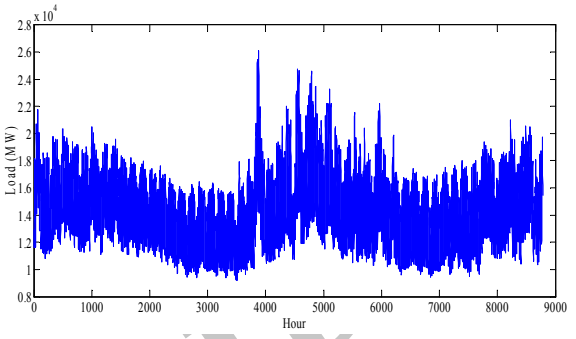

شکل ۷. تغییرات بار ساعتی برای بازار نیوانگلند

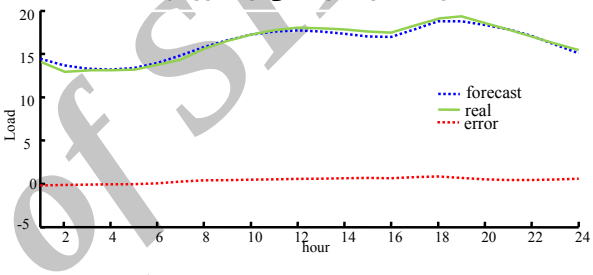

شکل ۸. نتایج شبیه سازی برای سیستم نیوانگلند

الگوریتم پیشنهادی دارای کارایی بالا، سرعت مناسب و دقت بالا می‌باشد. برای نشان دادن کارایی روش پیشنهادی از معیارهایی مانند *MAPE* (میانگین قدرمطلق خطای درصدی) ویا *MAE* و قدرمطلق درصد خطای روزانه *DMAPE* استفاده شده است که با روابط زیر تعریف می‌گردند.

$$MAPE = \frac{1}{N}\sum_{i=1}^{N}\frac{|L_{ACT(i)} - L_{FOR(i)}|}{L_{ACT(i)}} \quad (۱۹)$$

$$MAE = \frac{1}{N}\sum_{i=1}^{N}|L_{ACT(i)} - L_{FOR(i)}| \quad (۲۰)$$

$$DMAPE = \frac{\frac{1}{24}\sum_{t=1}^{24}|L_{ACT_t} - L_{FOR_t}|}{\frac{1}{24}\sum_{t=1}^{24}L_{ACT_t}} \quad (۲۱)$$

که در رابطه بالا، L_{FOR} و L_{ACT} به ترتیب مقدار پیش‌بینی شده و مقدار واقعی هستند. مقدار بدست آمده برای معیارهای *MAPE*، *MAE* و *DMAPE* به ترتیب ۰/۷۶، ۰/۸۹ و ۰/۳۴ می باشد. نتایج بدست امده نشان از کارایی و دقت مناسب برای مساله پیش بینی را به همراه دارد. به منظور نشان دادن کارایی بالای روش پیشنهادی، دوره زمانی را در یک سال افزایش داده یه به عبارتی پیش بینی بلند مدت انجام می‌دهیم. شکل ۹ تغییرات پیش بینی بار و مقدار پیش بینی شده توسط روش پیشنهادی را نشان می دهد. شکل ۱۰ نحوه تغییرات خطا و معیار های مورد نظر را نشان می دهد. که در آن MAPE برابر با 1.57% و MAE برابر با 236.43 MWh و MAPE هفتگی برابر با 1.55% می باشد.

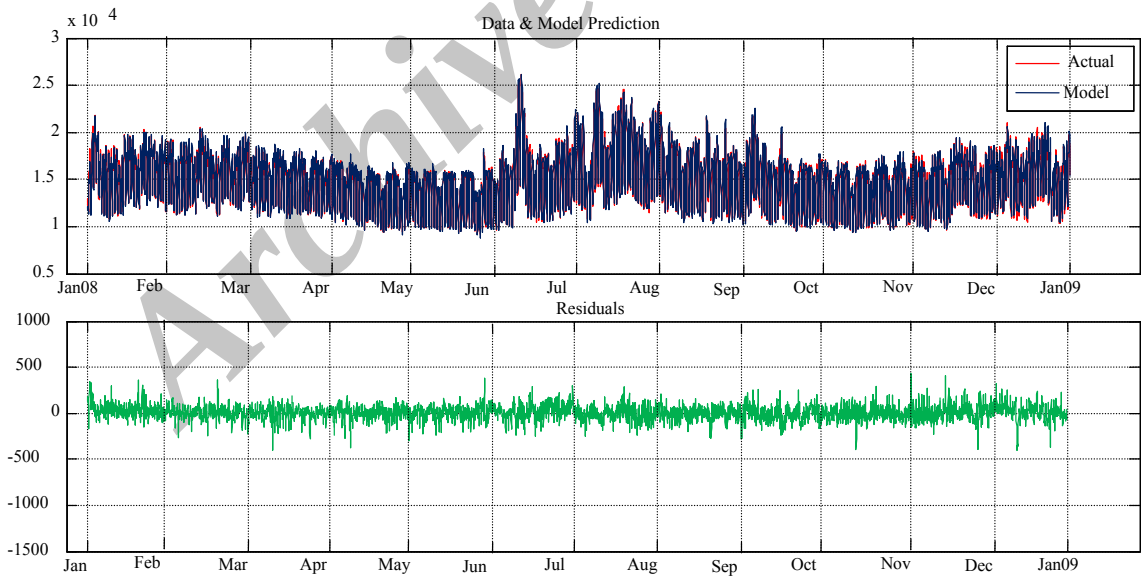

شکل ۹. نتایج حاصل از شبیه سازی برای سیستم مورد مطالعه در دوره زمانی طولانی

Archive of SID

www.SID.ir

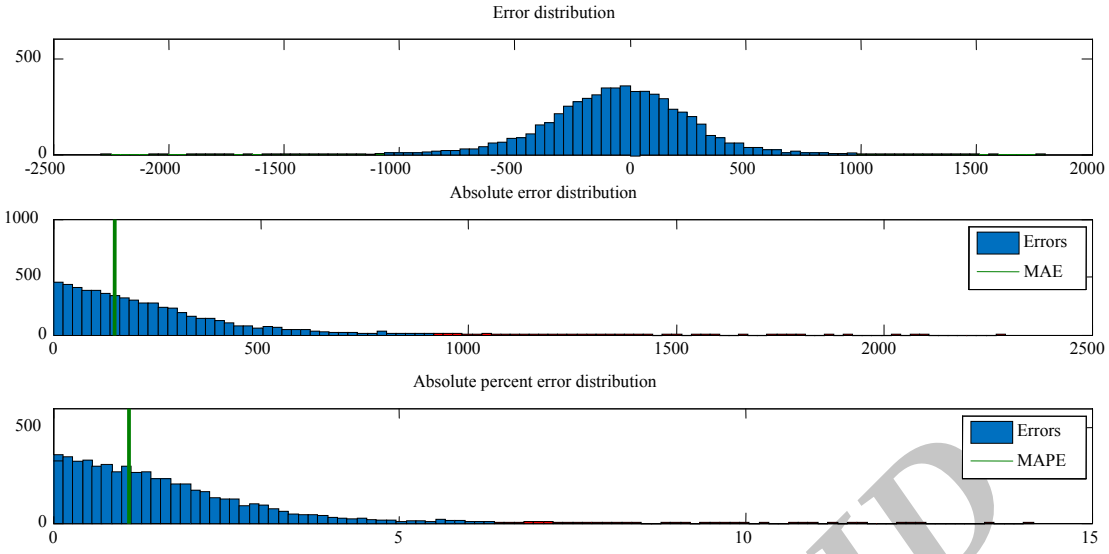

شکل ۱۰. نحوه توزیع خطا حاصل از شبیه سازی برای معیارهای معرفی شده

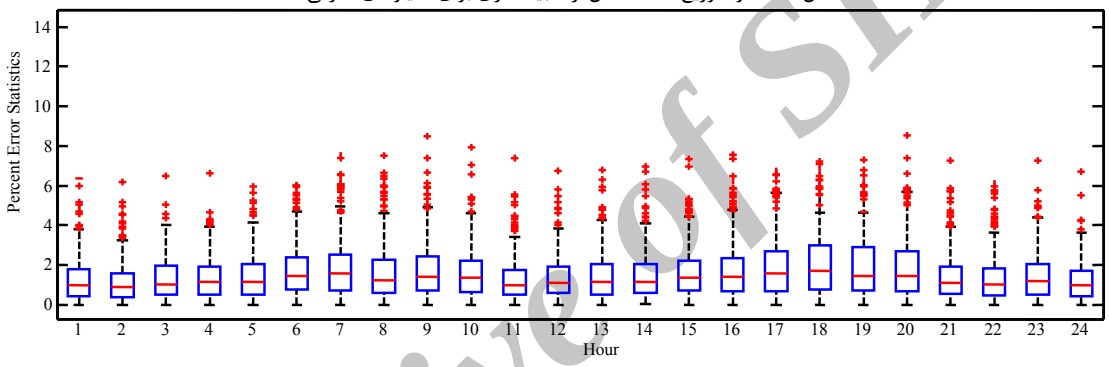

شکل ۱۱. نحوه توزیع خطای حاصل از پیش بینی برای بار ساعتی

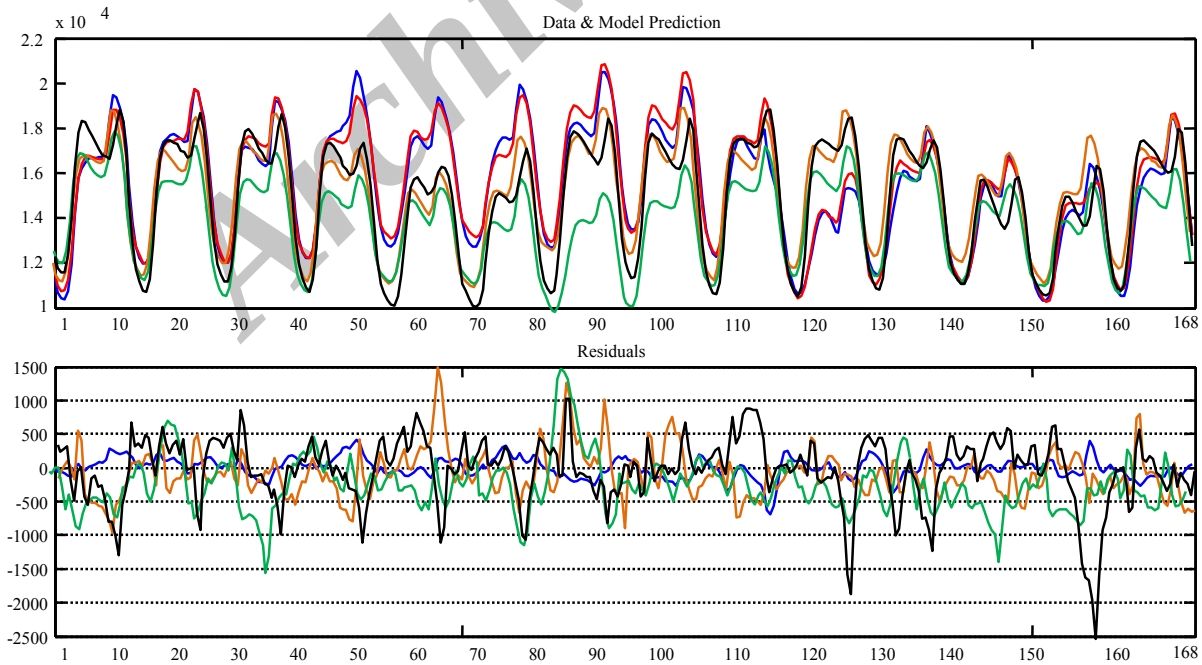

شکل ۱۲. نتایج حاصل از شبیه سازی برای هفته آخر سال: الگوریتم پیشنهادی (آبی)، شبکه عصبی (سبز)، عصبی-فازی (مشکی)، الگوریتم انتخاباتی و عصبی بهبود یافته (نارنجی) و دیتا واقعی شبکه (قرمز)

Archive of SID

www.SID.ir

شکل ۱۱ تغییرات خطای ایجاد شده در پیش بینی بار ساعتی را نشان می‌دهد. پیوستگی مناسب در محدوده کم نشان از از دقت بالای این روش پیشنهادی می‌باشد. همچنین به منظور مقایسه کارایی روش پیشنهادی انجام پیش بینی میان مدت به وسیله الگوریتم پیشنهادی، شبکه عصبی، 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 هفته اول March ۲۰۰۸ در بازار نیوانگلند 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 دقت و قابلیت بالای روش پیشنهادی می‌باشد. 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.

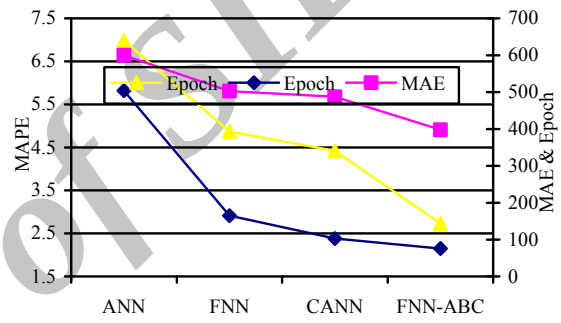

شکل ۱۳. نتایج بدست امده برای معیارهای معرفی شده در پیش بینی هفتگی

۸- نتیجه گیری

در پی تغییر ساختار بازار برق از بازار انحصاری دولتی به بازار رقابتی که در آن قیمت توسط نیروهای بازار تعیین می‌شود، مدلسازی و پیش‌بینی بار مورد تقاضا کاملا ریسکی و همراه با عدم قطعیت الکتریسیته تعیین شده در بازار رقابتی برای فعالان بازار برق اهمیت ویژه‌ای یافته است. برای مدلسازی و پیش در بازار رقابتی باید ویژگیهای این کالا از جمله عدم قابلیت ذخیره‌سازی، کم کشش بودن، فصلی بودن تقاضا و لزوم تعادل پیوسته‌ی عرضه و تقاضا که منجر به فراریت میزان تقاضا می‌گردد، در نظر گرفت. هدف از این مقاله حاضر، طراحی و اجرای یک مدل از الگوریتم کلونی مصنوعی زنبور عسل و شبکه عصبی بهبود یافته منطبق با منطق فازی و پیش‌بینی رفتار کوتاه مد، میان مدت و بلند مدت میزان بار در بازار برق جهانی می‌باشد. نتایج بدست آمده از شبیه سازی‌ها نشان از قابلیت بالای این الگوریتم در پیش‌بینی بهتر در مقایسه با سایر روش‌های موجود می‌باشد. همچنین نتایج مناسب بدست آمده، نشان از موفقیت الگوریتم انتخاباتی در مرتب سازی داده‌ها دارد. نتایج به دست آمده از شبیه سازی ها نشان از کارایی بالای الگوریتم ترکیبی در پیش بینی بار داشته است.

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. Amjady," 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. Amjady," 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. McMenemy," 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. Amjady, 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.

Archive of SID

www.SID.ir