

مدل سازی سیستم چند ورودی چند خروجی برای پیش بینی همزمان قیمت و بار در شبکه

هوشمند با اعمال مدیریت بار

حسین شایقی^۱، علی قاسمی^۲

۱- استاد، دانشکده مهندسی برق- دانشگاه محقق اردبیلی- اردبیل- ایران

hshayeghi@gmail.com

۲- دانشجوی دکتری، دانشکده مهندسی برق- دانشگاه محقق اردبیلی- اردبیل- ایران

ghasemi.agm@gmail.com

چکیده: در این مقاله، یک مدل چند ورودی چند خروجی پیش بین کننده برای پیش بینی همزمان قیمت و بار ارائه شده است. روش پیشنهادی از چهار بخش تشکیل شده، بخش اول از تبدیل موجک گسسته برای ریزسازی سیگنال اصلی با حفظ اطلاعات بارزش، بخش دوم از مدل الگوریتم انتخابی فاز برای انتخاب بهترین داده ها با بیشترین ارتباط و کمترین تکرار و بخش سوم که یک موتور پیش بینی کننده بر اساس سیستم چند ورودی چند خروجی شبکه بردار پشتیبان مبتنی بر کوچکترین مربعات و نهایتاً بخش چهارم با توجه به تابعی هدفی متشکل از خطای ناشی از پیش بینی و روش بهبود یافته کلونی مصنوعی زنبور عسل به تنظیم شاخص های شبکه بردار پشتیبان پیشنهادی می پردازد. در روش بهبود یافته کلونی مصنوعی زنبور عسل از دو عملکرد، یکی در جستجوی محلی به کمک تابع لجستیک و دیگری برای جستجوی کلی الگوریتم که بر اساس هدایت ذرات مبتنی بر جهت یابی بهترین پاسخ در آن تکرار، بهره می برد. همچنین، تأثیر مدیریت بار در پیک زدایی و بهبود ضریب بار به شکل یک مسئله بهینه سازی مورد بحث و بررسی قرار گرفته است. روش پیشنهادی بر روی بازارهای مختلف اعمال و نتایج حاصله براساس معیارهای مبتنی بر خطای پیش بینی مورد بررسی و تحلیل قرار گرفته که نشان از عملکرد قابل قبول روش پیشنهادی دارد.

واژه های کلیدی: پیش بینی همزمان قیمت و بار، الگوریتم بهبود یافته زنبور عسل، تبدیل موجک گسسته، شبکه هوشمند.

۱- مقدمه

نیاز صنایع روبروست، بلکه از طرفی حداقل سازی و کاهش اثراتی که بشر بر روی محیط در ارتباط با تولید این انرژی دارد نیز یکی دیگر از موارد مورد توجه است و شبکه هوشمند راه حلی برای این چالش می باشد که سود و بازده بسیار زیادی دارد [۱]. به عبارتی شبکه هوشمند، سامانه قدرتی است که بیشترین استفاده از رایانه و فناوری ارتباطات را برای رسیدن به دو هدف اساسی انجام می دهد. یکی از اهداف اصلی فراهم کردن اطلاعات الگوی مصرف انرژی مصرف کنندگان است و هدف بعدی دستیابی به سامانه قدرتی با قابلیت اطمینان، کیفیت توان بالا، بهبود کارایی سامانه با کاهش تلفات سامانه و استفاده بهتر از منابع پراکنده است [۲ و ۳].

بحثی که به تازگی در شبکه های برق مطرح شده، هوشمندسازی شبکه های برق است. بازار برق امروزی نه تنها با فراهم کردن منابع برای برآورده سازی انرژی مورد تقاضا صنایع مواجه است، بلکه افزایش رفاه، قابلیت اطمینان و کاهش هزینه ها را در روبروی خود می بیند. صنعت برق، نه تنها با فراهم کردن منابع برای برآورده کردن انرژی مورد


^۱ تاریخ ارسال مقاله: ۱۳۹۳/۱۰/۲۶

تاریخ پذیرش مقاله: ۱۳۹۴/۱۰/۰۸

نام نویسنده مسئول: حسین شایقی

نشانی نویسنده مسئول: ایران - اردبیل - انتهای خیابان دانشگاه

دانشگاه محقق اردبیلی - دانشکده مهندسی برق و کامپیوتر



شکل (۱): نمایش کلی از ارتباطات در شبکه هوشمند [۲]

شرکت‌ها برای برآورد هزینه و درآمد از آینده نیازمند مدل‌هایی کارا برای پیش‌بینی قیمت و بار هستند. در پی استفاده از شبکه‌های هوشمند، روش‌های تکمیلی و ترکیبی متعددی از آن‌ها برای پیش‌بینی شکل گرفته است؛ که هدف از این پژوهش‌ها ارایه راهکاری مطمئن‌تر و کارآمدتر است. در مفهومی بهتر، با نگاهی اجمالی به این مقالات اهمیت موضوع بیش از پیش نمایان خواهد شد [۵ و ۴].

در حال حاضر روش‌های متنوعی از روش سری‌های زمانی برای پیش‌بینی بار و قیمت برق استفاده می‌شوند که از این بین می‌توان به رگرسیون دینامیکی و تابع تبدیل [۶ و ۷]، خودرگرسیون جمعی میانگین متحرک [۸]، خود رگرسیون واریانس شرطی [۹]، روش ترکیبی خودرگرسیون جمعی میانگین متحرک و خود رگرسیون واریانس شرطی [۱۰]، روش ترکیبی تبدیل موجک و خودرگرسیون جمعی میانگین متحرک [۱۱] و روش خود رگرسیون واریانس شرطی تعمیم یافته [۱۲] اشاره کرد.

در مرجع [۱۳] از روش شبکه عصبی به پیش‌بینی قیمت تسویه بازار برق انگلستان پرداخته شده است. در جهت

به طور خلاصه ساختار شبکه‌های هوشمند در شکل (۱) نشان داده شده است. در گذشته، لزوم سرمایه‌گذاری‌های کلان در زمینه تولید، انتقال و توزیع برق، وجود انحصار دولتی برای این صنعت را توجیه می‌کرد؛ اما امروزه با توجه به تجدید ساختار یافتن و در پی آن، هوشمندسازی شبکه و با توجه به اهمیت سیستم‌های قدرت در زمینه تولید، انتقال و توزیع برق و توسعه روزافزون این سیستم‌ها، طراحان و برنامه‌ریزان سیستم‌های قدرت را با مشکلات گوناگونی مواجه کرده است. از جمله این مسائل اطلاع از اتفاقات آینده در سیستم (مانند افزایش یا کاهش متعارف و یا ناگهانی میزان مصرف برق یا بار) برای انجام طراحی و برنامه‌ریزی آینده سیستم است. همچنین، مباحث اقتصادی مانند میزان سوددهی و یا پیش‌بینی هزینه‌های مورد نیاز به قیمت آینده برق نیز وابسته است.

با در نظر گرفتن این اهداف، هر یک از شرکت‌کنندگان باید به دنبال برنامه‌ریزی مدون و دقیق برای آینده خود باشند و با توجه به بحث‌های یاد شده کاملاً مشهود است که

شده است. در این روش داده‌های قیمت و بار به شکل همزمان پیش بینی می‌شوند و اختلاف بین مقدار پیش بینی و سیگنال واقعی به شکل فازی تبدیل شده و نهایت مجموع دو طبقه آموزش به پیش بینی نهایی قیمت و بار منجر شده است.

با وجود کارهای انجام گرفته، همچنان ارایه روشی کارآمدتر در شبکه هوشمند نیاز اساسی است. در این مقاله، به مدل‌سازی سیستم چند ورودی چند خروجی شبکه بردار پشتیبان مبتنی بر کوچک‌ترین مربعات به عنوان یک موتور پیش بین کننده پرداخته شده است. در این مدل تقابل بین سیگنال‌های قیمت و بار به شکل کامل در نظر گرفته شده است. همچنین، برای انتخاب بهترین داده‌های ورودی و کاهش ابعاد آن‌ها که سبب کاهش محاسبات و خطای آموزش در سیستم یادگیری می‌شود، مفهوم فازی-آنتروپی بهره گرفته شده است که عدم قطعیت‌ها به شکل بهتری اعمال می‌شود. از سوی دیگر، برای انتخاب بهترین ضرایب کنترلی در شبکه بردار پشتیبان پیشنهادی، از مدل توسعه یافته کلونی مصنوعی زنبور عسل بهره گرفته شده است. از این نظر، دو عملگر یکی مبتنی بر سیستم لجستیک برای تقویت جستجوی محلی و دیگری مبتنی بر حفظ اطلاعات از طریق بهترین جواب در هر مرحله برای تقویت جستجوی کلی ارایه شده است. در نهایت، استفاده از دو بازار واقعی و اطلاعات دسترس آزاد از نکات بارز این مقاله است. به عبارتی دیگر، کوشش شده است بدترین روزهای هفته برای ارزیابی در نظر گرفته شود.

از سوی دیگر، مصرف بهینه، کنترل و گسترش بیشتر انرژی‌های تجدیدپذیر همیشه یکی از مهم‌ترین مباحث برای جوامع در کاهش هزینه‌ها و افزایش قابلیت سیستم بوده است. شبکه هوشمند با ایجاد ارتباط دو طرفه بین اجزای شبکه و مشترکان، بازیابی خودکار، کاهش تلفات و استفاده بهینه از تجهیزات و ظرفیت‌ها به مدیریت مؤثر شبکه یاری می‌رساند [۲۱ و ۲۲]. بنابراین، یکی از مهم‌ترین اهداف برای شبکه هوشمند، ارایه مدیریت بار برای کم کردن پیک بار و متعادل‌سازی آن است. با اعمال این روش می‌توان پیش‌بینی بهتر و دقیق‌تری برای سیستم ارایه کرد. در این مقاله، کوشش شده است تا موضوع مدیریت بار به عنوان عاملی

کاهش خطای حاصل از پیش‌بینی و افزایش قابلیت‌های شبکه عصبی، در مرجع [۱۴] مدلی جدید در معماری یادگیری شبکه عصبی به کمک تابع تبدیل به گزین موجک ارایه شده است. در مرجع [۱۵] از مدل سری زمانی و شبکه عصبی که از ترکیب دو سیستم خطی و غیرخطی به دست آمده است، کوشش در ایجاد رابطه‌ای مناسب بین داده‌های ورودی برای کاهش خطای پیش‌بینی انجام گرفته است. یکی از نقاط ضعف شبکه عصبی عدم تصمیم‌گیری آن در داده‌های منطقی (logic) است. به منظور افزایش قابلیت یادگیری شبکه عصبی در مرجع [۱۶] از یک روش ترکیبی فازی-عصبی استفاده شده است. به عبارتی دیگر، این روش اصلاحی بر روش‌های مبتنی بر شبکه عصبی و سری‌های زمانی بوده است. در [۱۷] از روش پانل هم‌انباشتگی و فیلتر ذرات برای پیش‌بینی قیمت روز بعد بهره گرفته شده است. در حقیقت این مدل ترکیبی از دو مرحله است که در قسمت اول پانل هم‌انباشتگی با بهره‌گیری از اطلاعات دینامیکی بین زمان و ویژگی‌های فردی مناطق متصل در سیستم، ابزار قدرتمند پیش‌بینی برای قیمت برق را فراهم می‌کند. در مرحله دوم فیلتر ذرات به موفقیت‌های قابل توجهی در ردیابی برنامه‌های کاربردی مربوط به سیگنال‌های غیر نرمال و سیستم‌های غیرخطی دامن خواهد زد.

در مرجع [۱۸] از یک روش ترکیبی مبتنی سری زمانی و شبکه بردار پشتیبان به پیش‌بینی قیمت کرن در بازار پرداخته است. در مرجع [۱۹] از روش ترکیبی مبتنی بر تبدیل موجک، شبکه عصبی بهبودیافته و منطق فازی بهره گرفته شده است. در این روش‌ها تنها به پیش‌بینی قیمت یا بار پرداخته شده است. در مرجع [۲۰] پیش‌بینی بار روزانه به کمک روش چند لایه پرسپترون در مرحله اول ایجاد شده است. سپس، در مرحله دوم فرض شده است که مقدار قیمت برق در روز بعد شناخته شده و تغییرات قیمت برق بر اساس اطلاعات روز قبل آن قابل حصول است. در ادامه سیستم فازی برای تعیین رابطه بین قیمت و بار استفاده شده است. در انتها، الگوی تشخیص داده شده برای تعیین بار روز بعد و اصلاح پیش‌بینی اولیه آن به کار گرفته می‌شود. در مرجع [۴] از سیستم چند ورودی چند خروجی بهره گرفته

برای پیش بینی در نظر گرفته شود. ویژگی های این عامل در جدول (۱) آورده شده است.

جدول (۱): مزایای مدیریت بار برای سیستم هوشمند

۱- کارآمدتر کردن شبکه انتقال
۲- بازیابی سریع تر شبکه در اثر اختلالات
۳- کاهش هزینه ها برای عملکرد و مدیریت از سوی تولیدکننده و در پی آن، کاهش هزینه اقتصادی برای مصرف کننده
۴- جمع آوری گسترده از منابع تولید انرژی تجدیدپذیر
۵- بهبود امنیت شبکه

۲-۱- پیش پردازش اطلاعات

در این قسمت، ابتدا به کمک تبدیل موجک گسسته سیگنال های بار و قیمت به زیرمجموعه های متناظر تقسیم و سپس، به کمک روش آنتروپی فازی بهترین داده ها انتخاب می شوند.

الف) تبدیل موجک گسسته

در ایده پردازش سیگنال هدف پردازشگر این است که سیگنال اولیه را در یک حوزه خاص مثل موجک برده و در آن حیطه روی اطلاعات سیگنال به وسیله آستانه گیری، پردازش مورد نظر را انجام داده و دوباره به حیطه زمان برگردد که بازگشت دوباره به حوزه زمان با یک تبدیل معکوس انجام می شود. به شکل عادی، در تجزیه سیگنال مناسب است تا اغتشاش ها را متمایز کنیم، چون سیگنال های تجزیه شده در مقیاس های پایین تر (فرکانس های بالاتر) مکان یابی زمانی بالا دارند [۲۳]. به بیان دیگر تجزیه سیگنال مقیاس بالا ضروری نیست زیرا آن مکان یابی زمانی ضعیفی را می دهد. فرض کنید که یک نوع تبدیل موجک مادر خاص با L ضریب فیلتر داریم، $h(n)$ و $g(n)$ که به ترتیب یک خانواده از توابع موجک $\phi(t)$ و توابع مقیاس $\psi(t)$ تشکیل می دهند. بطوری که:

$$\phi(t) = \sqrt{2} \sum_n h(n) \Phi(2t - n) \quad (۱)$$

$$\Psi(t) = \sqrt{2} \sum_n g(n) \Psi(2t - n) \quad (۲)$$

در نتیجه فرآیند آشکارسازی مجموعه ای از فرآیندهای کانولوشن در مقیاس متناظر است. در مقیاس یک سیگنال قدرت الکتریکی $c_0(n)$ با N نقطه نمونه برداری به دو سیگنال دیگر تجزیه شده است. $c_1(n)$ و $d_1(n)$ به شکل زیر تعریف می شوند:

$$c_1(n) = \sum_k h(k - 2n) c_0(k) \quad (۳)$$

$$d_1(n) = \sum_k g(k - 2n) c_0(k) \quad (۴)$$

سیگنال $c_1(n)$ مدل هموار شده از سیگنال اصلی $c_0(n)$ است درحالی که $d_1(n)$ مدل جزئیات سیگنال اصلی

همچنین در این مقاله، مدیریت بار به یک مسأله بهینه سازی تبدیل شده و از روش کلونی مصنوعی زنبور عسل حل شده است. با استفاده از این بخش توانسته ایم پروفیل بار در طول یک روز را بهبود بخشیده و توزیع نرمال بهتری از بار ایجاد کنیم.

۲-۲ فرمول بندی پیشنهادی برای پیش بینی

همان طور که در بخش های قبلی اشاره شد، روش پیشنهادی از ابزارهای مختلفی تشکیل شده است که در این قسمت کوشش شده است تا با جزئیات بیشتری معرفی شوند. از لحاظ عملکرد، روش پیش بینی پیشنهادی می تواند در سه گام اساسی تقسیم و معرفی شود.

گام اول: پیش پردازش اطلاعات

در این قسمت تبدیل موجک گسسته و الگوریتم انتخاباتی فازی پیشنهادی برای ریزسازی سیگنال اصلی و حذف اغتشاش های ناخواسته معرفی می شوند.

گام دوم: آموزش - پیش بینی

شبکه بردار پشتیبان مبتنی بر کم ترین مربع خطا در ساختار چند ورودی چند خروجی و الگوریتم بهبود یافته کلونی مصنوعی زنبور عسل در این بخش قرار می گیرند.

گام سوم: تعیین خطای پیش بینی

معیارهای حاصل از پیش بینی و محاسبه خطای پیش بینی بیان می شود. در حقیقت، این بخش اعتبارسنجی و بیان میزان دقت روش پیشنهادی در پیش بینی همزمان قیمت و بار است.


نحوه ارتباط بین این گام ها در بخش ۴ با ارایه

استفاده هستند و یا اینکه بار اطلاعاتی چندانی ندارند. حذف نکردن این ویژگی‌ها مشکلی از لحاظ اطلاعاتی ایجاد نمی‌کند؛ ولی بار محاسباتی را برای کاربرد مورد نظر بالا می‌برد؛ و علاوه بر این باعث می‌شود که اطلاعات غیرمفید زیادی به همراه داده‌های مفید ذخیره شود. پیدا شدن یک زیرمجموعه بهینه از مجموعه ویژگی‌ها، به شکل مستقیم با انتخاب تابع ارزیابی بستگی دارد. زیرا اگر تابع ارزیابی به زیرمجموعه ویژگی یک مقدار نامناسب نسبت دهد، این زیرمجموعه هیچ‌گاه به عنوان زیرمجموعه بهینه انتخاب نمی‌شود. توابع ارزیابی را می‌توان به روش‌های مختلفی دسته‌بندی کرد که توضیحات جامع‌تر از آن در [۲۵] بیان شده است. از این میان روش‌های مبتنی بر آنتروپی کارایی بهتری از خود نشان داده‌اند [۲۶]. این روش بر اساس میزان آنتروپی تا عدم قطعیت به انتخاب بهترین داده‌ها می‌پردازد که عدم قطعیت یک مسئله غیرقابل انکار در سیگنال‌های قیمت و بار است. ولی در شبکه هوشمند با افزایش شاخص‌ها عدم قطعیت شکل پیچیده‌تری به خود می‌گیرد که ممکن است روش‌های مبتنی بر آنتروپی کلاسیک گاهی دچار ضعف در انتخاب بهترین داده‌ها شوند. از این رو در این مقاله از الگوریتم انتخاباتی فازی بهره گرفته شده است.

قوانین فازی، مبتنی بر هر روشی که ایجاد شود، از اهمیت زیادی در پیاده‌سازی و بهینه‌سازی سیستم‌ها برخوردار است. استفاده از دانش بشری در تولید قوانین فازی، اگر چه مزیت خوانایی و نزدیکی به تخصص تجربی دارد، اما در همه سیستم‌ها قابل پیاده‌سازی نیست. استفاده از خروجی‌های یک سیستم که شامل یک سری داده است، از آنجا که بر پایه کارکرد صحیح سیستم ایجاد شده، با درصد بالایی قابل اعتماد است. در مقاله حاضر، با استفاده از خروجی‌های سیستم و به واسطه تولید یک درخت تصمیم‌گیری، قوانین فازی استخراج می‌شود. در حقیقت پیمایش درخت تصمیم‌گیری به تولید قوانین منجر شده و این قوانین، فازی و در نهایت، بهینه می‌شوند. درخت تصمیم‌ارایه شده، در مقایسه با پیاده‌سازی‌های پیشین، جدید بوده و به عنوان یک راه حل جدید در کلاسه‌بندی نیز قابل ارایه است [۲۷].

فرض کنید، معیار آنتروپی $H(X)$ برای مجموعه اعداد


است که به شکل ضرایب تبدیل موجک می‌باشند.



شکل ۲. تبدیل موجک و تابع مقیاس برای توابع دایبچیز

توابع دایبچیز^۲ که با علامت dbN نشان داده می‌شوند، عبارت ریاضی صریحی نداشته و از چند جمله‌ای‌های ریاضی به دست می‌آیند که در این مقاله، به عنوان تبدیل مادر موجک به کار گرفته شده‌اند [۲۴]. در این تابع N نشان‌دهنده مرتبه موجک بوده و برخی از پژوهشگران از $2N$ به جای N استفاده می‌کنند. بیشتر این موجک‌ها نامتقارن بوده و نامنظمی آن‌ها با افزایش مرتبه‌شان، افزایش می‌یابد. در شکل (۲) موجک و تابع مقیاس $db4$ نشان داده شده است.

همچنین، در روش پیشنهادی نحوه جداسازی و بازسازی داده‌ها $db4$ در حالت فیلتر بالاگذر و پایین گذر به صورت شکل (۳) است.



شکل (۳): نحوه فیلترسازی داده‌ها در حالت جداسازی و

بازسازی

ب) الگوریتم انتخاباتی فازی

مسئله انتخاب ویژگی، یکی از مسائلی است که در مبحث یادگیری ماشین و همچنین، شناسایی آماری الگو مطرح است. این مسئله در بسیاری از کاربردها (مانند طبقه‌بندی) اهمیت زیادی دارد، زیرا در این کاربردها تعداد زیادی ویژگی وجود دارد که بسیاری از آن‌ها یا بدون

معنای این شرط این است که مجموع تعلق هر نمونه به C خوشه باید برابر ۱ باشد. با استفاده از شرط بالا و کمینه کردن تابع هدف خواهیم داشت:

$$v_i = \frac{\sum_{k=1}^n u_{ik}^m x_k}{\sum_{k=1}^n u_{ik}^m} \quad (9)$$

$$u_{ik} = \frac{1}{\sum_{j=1}^c \left(\frac{d_{ik}}{d_{jk}} \right)^{2/(m-1)}} \quad (10)$$

در نهایت، مراحل الگوریتم می‌تواند به شکل زیر بیان شود:

۱. مقداردهی اولیه برای c ، m و U^0 . خوشه‌های اولیه حدس زده شوند.

۲. مراکز خوشه‌ها محاسبه شوند (محاسبه v_i ‌ها).

۳. ماتریس تعلق از روی خوشه‌های محاسبه‌شده در ۲ محاسبه شود

۴. اگر $\|U^{l+1} - U^l\| \leq \varepsilon$ الگوریتم خاتمه می‌یابد، در غیر این صورت به مرحله ۲ رفته می‌شود.

پس از محاسبات بالا دسته‌هایی از اعداد به مرکزیت v_i خواهیم داشت که هر کدام از دسته‌ها بر حسب الگویی مناسب به شکل x_i نرمالیزه می‌شوند. اگر این سیستم بین x_i از یک الگو با بقیه الگوها بررسی شود، در این صورت همبستگی میان آن‌ها بر حسب فازی به دست خواهد آمد. با این روش پیشنهادی به جای استفاده از تابع احتمالاتی برای یک مجموعه خاص مجموعه فازی خواهیم داشت که بیانگر تمام اعضای فازی در تمامی مجموعه‌هاست. به عبارتی دیگر، به جای تابع احتمالاتی یک درجه تطبیقی فازی خواهیم داشت که آنتروپی فازی به شکل زیر تعریف می‌شود:

$$FH_c = \sum_{c=1}^C \left(- \frac{\sum_{x_d \in C} u_c(x_d)}{\sum_{x_d \in C} u_c(x_d)} \log \left(\frac{\sum_{x_d \in C} u_c(x_d)}{\sum_{x_d \in C} u_c(x_d)} \right) \right) \quad (11)$$

در فرمول بالا ویژگی هر دسته C به کل مجموعه فازی در تمامی دسته‌ها C بررسی می‌شود. ضریب پشت لگاریتم

نامنظم X بر اساس توزیع احتمالاتی $P(X)$ به شکل زیر قابل بیان است:

$$H(X) = - \int P(X) \log_2(P(X)) dX \quad (5)$$

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 شکل زیر قابل بازنویسی خواهد بود:

$$H(X) = - \sum_{i=1}^n P(X_i) \log_2(P(X_i)) \quad (6)$$

بر اساس دو رابطه (۵) و (۶) آنتروپی بیشتر یک مقدار از عدم قطعیت را در نظر می‌گیرد. در روشی مشابه با فرمول‌های قبل، در این الگوریتم نمونه‌ها به C خوشه که از قبل تعداد مشخصی دارد تقسیم می‌شوند. در الگوریتم خوشه‌بندی C میانگین فازی، تابع هدف به شکل فرمول (۷) است:

$$J = \sum_{i=1}^c \sum_{k=1}^n u_{ik}^m d_{ik}^2 = \sum_{i=1}^c \sum_{k=1}^n u_{ik}^m \|x_{ik} - v_i\|^2 \quad (7)$$

در فرمول بالا m یک عدد حقیقی بزرگ‌تر از ۱ است که در بیشتر موارد برای m عدد ۲ انتخاب می‌شود. X_{ik} نمونه k ام است و V_i نماینده یا مرکز خوشه i ام است. U_{ik} میزان تعلق نمونه i ام در خوشه k ام را نشان می‌دهد. علامت $\|*\|$ میزان تشابه (فاصله) نمونه با (از) مرکز خوشه است که می‌توان از هر تابعی که بیانگر تشابه نمونه و مرکز خوشه باشد، استفاده کرد. از روی U_{ik} می‌توان یک ماتریس U تعریف کرد که دارای c سطر و n ستون است و مؤلفه‌های آن هر مقداری بین صفر تا ۱ را می‌توانند اختیار کنند. اگر تمامی مؤلفه‌های ماتریس U به شکل صفر و ۱ باشند، الگوریتم مشابه C میانگین کلاسیک خواهد بود. با اینکه مؤلفه‌های ماتریس U می‌توانند هر مقداری بین صفر تا ۱ را اختیار کنند اما مجموع مؤلفه‌های هر یک از ستون‌ها باید برابر ۱ باشد و داریم:

$$\sum_{i=1}^c u_{ik} = 1, \forall k = 1, \dots, n \quad (8)$$

به عنوان درجه فازی تطبیقی است.

فرمول (۱۴) تابع خطای وپنیک است [۲۹]. در معادله بالا هنگامی که $\varepsilon = 0$ ، تابع کرنال به شکل مجزا برای هر سیگنال تعریف می شود اما وقتی $\varepsilon > 0$ باشد، یک ارتباط بین دو سیگنال قیمت و بار در مدل پیش بینی ایجاد خواهد کرد. با جایگزینی معادلات (۱۳) و (۱۴) در معادله (۱۲) یک تابع غیرخطی خواهیم داشت که برای حل آن از روش IRWLS بهره گرفته ایم. به علت ماهیت غیرخطی معادله ایجاد شده حل آن به شکل مستقیم امکان پذیر نخواهد بود [۳۰]. حال با توجه به گسترش سری تیلور خواهیم داشت:

$$L_P(W, b) = \frac{1}{2} \sum_{j=1}^B (\|W^j\|^2 + \frac{1}{2} \sum_{i=1}^n L(v_i^\ell + \frac{dL(v)(e_i^\ell)^T}{dv v_i^\ell} \Big|_{v_i^\ell} [e_i - e_i^\ell])) \quad (15)$$

که

$$\begin{cases} v_i^\ell = \|e_i^\ell\| = \sqrt{(e_i^\ell)^T e_i^\ell} \\ (e_i^\ell)^T = y_i^T - \phi^T(x_i) W^\ell - (b^\ell)^T \\ \forall W \in R^H \times R^B, b \in R^B \text{ when } W = W^\ell \text{ and } b = b^\ell \\ \text{then, } L_P(W^\ell, b^\ell) = L_P(W^\ell, b^\ell) \\ \nabla L_P(W^\ell, b^\ell) = \nabla L_P(W^\ell, b^\ell) L_P(W^\ell, b^\ell) \leq L_P(W, b) \end{cases} \quad (16)$$

حال با گسترش معادله درجه دو خواهیم داشت:

$$L_P(W, b) = \frac{1}{2} \sum_{j=1}^B (\|W^j\|^2 + \frac{C}{2} \left(\sum_{i=1}^n L(v_i^\ell + \frac{dL(v)}{dv} \Big|_{v_i^\ell} \frac{v_i^2 - (v_i^\ell)^2}{2v_i^\ell} \right)) \quad (17)$$

$$= \frac{1}{2} \sum_{j=1}^B \|W^j\|^2 + \frac{1}{2} \sum_{i=1}^n \zeta_i v_i^2 + SC$$

که در عبارت بالا، SC مقدار ثابت برای گسترش بالاست و معادله خطای وپنیک به شکل زیر قابل بیان خواهد شد:

$$\zeta_i = \frac{C}{v_i^\ell} \frac{dL(v)}{dv} \Big|_{v_i^\ell} = \begin{cases} 0, & v_i^\ell < \varepsilon \\ \frac{2C(v_i^\ell - \varepsilon)}{v_i^\ell}, & v_i^\ell \geq \varepsilon \end{cases} \quad (18)$$

برای حل معادله بالا به کمک روش IRWLS به شکل زیر عمل می کنیم:

گام اول: قرار دادن مقادیر اولیه برای $W^\ell = 0, b^\ell = 0$ و $\ell = 0$ و در نتیجه آن محاسبه مقادیرهای اولیه u_i^ℓ

۲-۲- آموزش - پیش بینی

این قسمت از دو ابزار مهم که به عنوان قلب تپنده سیستم پیش بینی است، تشکیل شده است که در ادامه به معرفی آن ها پرداخته می شود.

الف) سیستم چند ورودی چند خروجی مبتنی بر شبکه بردار پشتیبان با کم ترین مربعات خطا

در حالت کلی ماشین بردار پشتیبان (SVM)، یک روشی یادگیری است که به شکل موفقیت آمیزی در بسیاری از حوزه های دنیای واقعی اعمال شده است [۲۶]. استفاده از روش های بهینه سازی، نقش مهمی در یافتن راه حل (پاسخ) برای SVM دارد. SVM در واقع ریشه در کمینه کردن ریسک ساختاری دارد. قانون حد بزرگ در SVM ها، پیچیدگی تابع کلاس را محدود می کند و این حقیقت را بیان می دارد که برای برخی توابع، حد بزرگ با بعد کوچک تری مرتبط است. بر اساس نیازهای مختلف در سرعت آموزش، محدودیت حافظه و دقت متغیرهای بهینه سازی می توان از روش های مختلف بهینه سازی استفاده کرد. همان گونه که بیان شده است هدف از این بخش مدل سازی سیستم چند ورودی چند خروجی است. بنابراین، سایر اطلاعات در مورد شبکه بردار پشتیبان در مرجع [۲۸] آورده شده است. فرض کنید مجموعه ورودی $x_i = [x_{i1} : \dots : x_{id}]$; $i = 1, \dots, n$ برای سیگنال های قیمت و بار با خروجی وابسته y_i در اختیار داشته باشیم. بنابراین، بر اساس کم کردن خطای آموزش و توابع وزنی مورد نظر خواهیم داشت:

$$L_P \min_{(W, b, e)} = \frac{1}{2} \sum_{j=1}^B \|W^j\|^2 + \frac{1}{2} \gamma \sum_{i=1}^n L(\|e_i\|) \quad (19)$$

که

$$W = [w^1, \dots, w^B], b = \begin{bmatrix} b^1 \\ \vdots \\ b^B \end{bmatrix}, \|e_i\| = \sqrt{e_i^T e_i^T} \quad (20)$$

$$e_i^T = y_i^T - \phi^T(x_i) W - b^T,$$

$$L(\|e\|) = \begin{cases} 0, & \|e\| < \varepsilon \\ \|\|e\|^2 - 2\|e\|\varepsilon + \varepsilon^2\|, & \|e\| > \varepsilon \end{cases} \quad (21)$$

صفحات مقاله و پرداختن به اصل مسأله پیشنهادی مقاله،
جزئیات بیشتر در مورد الگوریتم استاندارد زنبور عسل در
[۳۱] قابل مطالعه است.

معمولاً با انتخاب مناسب شاخص‌های سیستم
غیرخطی می‌توان آن‌ها را به رفتار آشوب گونه مجبور
کرد. سیستم آشوب گونه با شروع از یک نقطه از فضای
حالت ناحیه مشخصی را جستجو می‌کند، بدون اینکه از
نقطه‌ای دو بار عبور کند. محدوده این ناحیه با استفاده از
شاخص‌های سیستم تعیین می‌شود. از ویژگی‌های دیگر
سیستم‌های آشوب گونه وابستگی چگونگی جستجوی آن‌ها
در محدوده مشخص به شرایط اولیه است. در این مقاله،
از این ویژگی‌های سیستم آشوب گونه برای یافتن وزن‌های
آشوب گونه مطلوب استفاده شده است. تابع لجستیک یک
تابع غیرخطی و دارای یک شاخص کنترل است. در این
تابع در هر لحظه خروجی لحظه بعد از رابطه‌ای زیر به
دست می‌آید:

$$x(k+1) = Ax(k)(1-x(k)) \quad (24)$$

که در آن $x(k)$ حالت سیستم در تکرار k و A
شاخص دوشاخه‌شدگی آن است. دینامیک این تابع به
شدت به شاخص A وابسته است؛ به طوری که با تغییر A
این تابع از خود انواع رفتارها (از پیرویک تا آشوب
گونه) را نشان می‌دهد (شکل ۴). با قرار دادن $A = 4$
تابع لجستیک از خود رفتار آشوب گونه نشان می‌دهد.
از دیدگاه فرمول‌بندی، ضرایب آشوبناک متناسب با محدوده
تعیین شده و تعداد متغیر (Ng) ، تولید می‌شوند:

$$\begin{aligned} X_{cls}^0 &= [X_{cls,0}^1, X_{cls,0}^2, \dots, X_{cls,0}^{Ng}]_{1 \times Ng} \\ cx_0 &= [cx_0^1, cx_0^2, \dots, cx_0^{Ng}], \\ cx_0^j &= \frac{X_{cls,0}^j - X_{j,\min}}{X_{j,\max} - X_{j,\min}}, j = 1, 2, \dots, Ng \end{aligned} \quad (25)$$

برای این معادله خواهیم داشت:

$$\begin{aligned} X_{cls}^i &= [X_{cls,i}^1, X_{cls,i}^2, \dots, X_{cls,i}^{Ng}]_{1 \times Ng}, i = 1, 2, \dots, N_{chaos} \\ x_{cls,i}^j &= cx_{i-1}^j (X_{j,\max} - X_{j,\min}) + X_{j,\min}, j = 1, 2, \dots, Ng \end{aligned} \quad (26)$$

در رابطه بالا X_{cls}^0 مکان به دست آمده اولیه برای

α_i .
گام دوم: مرتب‌سازی وزن‌ها و بایاس‌های به دست آمده
از (۱۷) به شکل یک بردار:

$$P^\ell = \begin{bmatrix} W^s - W^\ell \\ (b^s - b^\ell)^T \end{bmatrix} \quad (19)$$

گام سوم: محاسبه جواب‌های بعدی:

$$\begin{bmatrix} W^{\ell+1} \\ (b^{\ell+1})^T \end{bmatrix} = \begin{bmatrix} W^\ell \\ (b^\ell)^T \end{bmatrix} + \gamma^\ell \quad (20)$$

که در معادله بالا γ^ℓ متناظر با تکرارهای برنامه به
دست می‌آید و در ابتدا برابر با ۱ است.

گام چهارم: محاسبه مقدارهای اولیه $u_i^{\ell+1}$ و α_i و
افزودن به تکرارهای آموزش $\ell = \ell + 1$ ، در صورتی که
شرط خاتمه که میزان خطای جواب نهایی است، برقرار شد
اتمام برنامه در غیر این صورت رفتن به گام دوم.

همان گونه که در گام دوم مشخص شده است به دست
آوردن W^s و b^s غیرقابل اجتناب است که برای ساده‌سازی
می‌توان از تساوی گرادیانت با صفر به شکل زیر بهره
گرفت:

$$\begin{aligned} \nabla_{W^j} L_P^s &= W^j - \sum_i \Phi(x_i) \alpha_i (y_{ii} - \Phi^T(x_i) W^j - b^j) = 0 \\ \nabla_{b^j} L_P^s &= -\sum_i \alpha_i (y_{ii} - \Phi^T(x_i) W^j - b^j) = 0 \end{aligned} \quad (21)$$

$j = 1, 2, \dots, B$

با خطی‌سازی جواب‌ها به شکل ماتریس داریم:

$$\begin{bmatrix} I + \Phi^T \Omega_a \Phi & \Phi^T a \\ a^T \Phi & 1^T a \end{bmatrix} \begin{bmatrix} W^j \\ b^j \end{bmatrix} = \begin{bmatrix} \Phi^T \Omega_a y^i \\ a^T y^i \end{bmatrix} \quad (22)$$

$$\begin{aligned} \Phi &= \begin{bmatrix} \Phi^T(x_1) \\ \vdots \\ \Phi^T(x_n) \end{bmatrix}, \alpha = \begin{bmatrix} \alpha_1 \\ \vdots \\ \alpha_n \end{bmatrix}, (\Omega_a)_{ij} = \alpha_i \delta(i-j), \\ y^i &= [y_{1j} \quad \dots \quad y_{nj}], j = 1, 2, \dots, B \end{aligned} \quad (23)$$

ب) الگوریتم بهبودیافته کلونی مصنوعی زنبور عسل
این الگوریتم نخستین بار توسط آقای کارابوگا ارایه
شده که تا به حال مقالات متنوعی در زمینه‌های مهندسی،
پزشکی و غیره منتشر شده است. به علت کاهش تعداد

تکاملی، به تنظیم شاخص‌های کمتری نیاز دارد.

- دارای قابلیت فرار از حداقل محلی است.
- به آسانی با عملیات ابتدایی ریاضی و منطقی پیاده‌سازی و برنامه‌ریزی می‌شود.
- برای توابع هدف با ماهیت تصادفی می‌تواند به‌کاربرده شود، مشابه حالتی که یکی از متغیرهای بهینه‌سازی تصادفی باشد.

نحوه کدگذاری این الگوریتم در مراحل زیر نشان داده شده است:

۱. مقداردهی اولیه به عنوان جواب‌های اولیه X_{ij}
۲. محاسبه جواب‌های اولیه در تابع هدف
۳. تکرار اولیه $cycle=1$
۴. فراهم کردن جواب‌های جدید بر اساس معادله (۲۸).
۵. انتخاب بهترین منبع یا جواب بهتر بین X_{ij} و V_{ij} .
۶. محاسبه میزان احتمال برای جواب‌های X_{ij} بر اساس فرمول زیر:

$$P_i = \frac{fit_i}{\sum_{i=1}^{SN} fit_i} \quad (29)$$

در حقیقت برای به دست آوردن شایستگی جواب‌ها از فرمول زیر استفاده می‌کنیم:

$$fit_i = \begin{cases} \frac{1}{1+f_i}, & f_i \geq 0 \\ 1+|f_i|, & f_i < 0 \end{cases} \quad (30)$$

جواب‌های P_i بین (۱، -۱) می‌باشد.

۷. تولید جواب‌های جدید (منابع جدید) V_i بر اساس زنبورهای تماشاگر از جواب‌های X_i و تعیین میزان احتمال آن‌ها P_i

۸. انتخاب بهترین جواب (پرخورترین زنبور) بین جواب‌های X_{ij} و V_{ij} .

۹. تعیین منابع فاسد و جایگزین منابع تصادفی با آن منابع تصادفی ایجادشده توسط زنبور پیش‌آهنگ X_i با استفاده از فرمول زیر:

$$x_{ij} = \min_j + rand(0,1) \times (\max_j - \min_j) \quad (31)$$

۱۰. ذخیره کردن بهترین جواب (منبع تغذیه باکیفیت) که


متغیر آشوب است. $X_{j,\max}$ و $X_{j,\min}$ به ترتیب مقدار پایین و بالایی برای متغیر آشوبناک و N_{chaos} تعداد متغیرهای آشوبناک می‌باشد.

از سویی دیگر، مطالعه و بررسی بر روی الگوریتم اجتماع ذرات نشان می‌دهد هنگامی که ذرات به کمک gbest هدایت می‌شوند جستجوی کلی بهتری خواهند داشت. در الگوریتم کلونی زنبور عسل جستجو بر اساس زنبورهای جستجوگر انجام می‌گیرد و از بهترین جواب به دست آمده در هر مرحله بهره‌ای گرفته نمی‌شود. ضریب اجتماعی این الگوریتم در جستجو بررسی نشده است. با تکیه بر این اصل، معادله استاندارد الگوریتم کلونی زنبور عسل (۲۷) به معادله (۲۸) تغییر می‌یابد.

$$V_{ij} = x_{ij} + \phi_{ij}(x_{ij} - x_{k,j}) \quad (27)$$

$$V_{ij} = x_{ij} + \phi_{ij}(x_{ij} - x_{k,j}) + \lambda_{ij}(g_{best i} - x_{ij}) \quad (28)$$

که در معادلات بالا ϕ_{ij} و λ_{ij} به اعداد تصادفی بین (۱، -۱) می‌باشند. همچنین، نحوه هدایت ذرات به شکل گرافیکی در شکل (۵) آورده شده است.



شکل (۵): نمودار دوشاخه شدگی تابع لجستیک به ازای تغییر شاخص A


در مقایسه با سایر روش‌های بهینه‌سازی مشابه، روش بهبودیافته پیشنهادی دارای مزایای کلیدی زیر است:

- این روش بر خلاف بسیاری از روش‌های سنتی نیازی به مشتق‌گیری ندارد.
- دارای حساسیت کمتری نسبت به ماهیت تابع هدف است، یعنی تحذب یا پیوستگی دارد.
- بر خلاف بسیاری دیگر از روش‌های محاسبات

تا این مرحله به دست آمده است.

Cycle=Cycle+1

تکرار تمام مراحل قبلی تا رسیدن به شرط پایان برنامه.



شکل (۵): جهت‌گیری ذرات در الگوریتم بهبودیافته زنبور عسل برای جستجوی کلی

۲-۳- تعیین خطای پیش‌بینی

برای ارزیابی روش پیشنهادی معیارهای مختلفی وجود دارد که در این مقاله به شکل زیر بیان می‌شوند. معیار SDE برای مقایسه نتایج به شکل 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 ام و e خطای متوسط در دوره تناوب پیش‌بینی است.

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

برای مقایسه کارایی روش‌های پیش‌بینی از معیار MAPE (میانگین قدر مطلق خطای درصدی) استفاده شده است که به شکل زیر تعریف می‌شود.


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

شایان ذکر است توابع معیار بالا هم برای قیمت و هم برای بار به کار گرفته می‌شود.

۳- مدیریت بار پیشنهادی

استفاده از انرژی الکتریکی باعث شده که این انرژی در

مقایسه با سایر منابع انرژی مورد توجه واقع شود، محدودیت منابع اولیه قابل تبدیل به انرژی الکتریکی، هزینه زیاد تولید و پایین بودن راندمان فرآیند تبدیل دست اندر کاران امور انرژی الکتریکی را به سیاست‌های بهینه برای تعادل عرضه و تقاضا ملزم می‌کند. از لحاظ اقتصادی مدیریت بار سبب بهبود پروفیل بار و کاهش پیک‌های ناگهانی می‌شود. برای درک بهتر مسأله فرض کنید که قیمت بار در ساعت t برابر با p_t است و در لحظه $t+1$ برابر با B_{pt} است. در اینجا ضریب B می‌تواند افزایش فراوانی داشته باشد که سبب می‌شود مصرف‌کننده با کمی افزایش بار مصرفی خود قیمت زیادی پرداخت کند. حال اگر این مشتری بتواند در ساعات دیگر مقدار مصرف خود را تغییر دهد تا در لحظه پیک به تقاضای بیشتر منجر نشود، در نتیجه می‌تواند هزینه کلی خود را پرداخت کند. این تغییرات در شکل (۶) برای یک نمودار عرضه و تقاضا مشخص شده است.



شکل (۶): تغییرات قیمت با اعمال مدیریت بار برای مصرف‌کننده

در بحث مدل‌سازی مدیریت بار کوشش می‌شود تا بار دارای توزیع نرمال یکنواخت باشد. اگر توزیع بار مطابق با شکل (۷) تفسیر شود سه ناحیه کاری خواهیم داشت که با محدوده‌های مبتنی بر امید ریاضی و واریانس تعریف می‌شوند. از لحاظ مدیریت بار حالت‌های زیر متداول‌ترین روش‌ها برای انجام این منظور هستند:


الف) پر کردن دره‌ها یا افت بارها

یعنی در زمان‌هایی که مصرف کمتر است کوشش در افزایش آن داشته باشیم:

نکته مهم در رابطه با موارد بالا این است که استفاده از آن‌ها سبب بهبود ضریب بار می‌شود. با اجتماع‌سازی داده‌ها در ناحیه یک می‌توان ضریب بار بهتری داشت. بنابراین، ضریب بار می‌تواند یک تابع هدف مناسب برای این منظور باشد. اگر λ مین بار مورد نظر در دوره زمانی h به شکل D_i^h معرفی شود، طبق تعریف ضریب بار، نسبت انرژی مصرف‌شده در یک دوره زمانی معین به انرژی که می‌توانست مصرف شود اگر بار شبکه در تمامی طول زمان یاد شده برابر با حداکثر بار بود به عبارت دیگر متوسط بار مصرفی به حداکثر بار مصرفی به شکل:

$$LF = \frac{E}{P_{\max}} = \frac{\sum_{i=1}^N \sum_{h=1}^T D_i^h \times t_h}{\sum_{j=1}^T t_j}, \begin{cases} i \in \{1, 2, \dots, N\} \\ h \in \{1, 2, \dots, T\} \end{cases} \quad (40)$$

که در آن E انرژی مصرفی در دوره زمانی T و $P_{\max}$ حداکثر بار در آن دوره و T دوره زمانی مورد نظر است که می‌تواند روز، هفته، ماه و یا سال باشد. حال هر قدر این ضریب به واحد نزدیک شود، یعنی فاصله بین متوسط بار و حداکثر بار کمتر شده و این به معنای استفاده بهتر از تأسیسات موجود است و منحنی تغییرات بار به سمت یکنواخت تر شدن میل نموده است و توزیع بار در طول زمان بهتر شده است.



شکل (۸): روش‌های مختلف برای مدیریت بار در یک

مصرف‌کننده [۲۲]

$$[\uparrow p_3] \Leftrightarrow [\text{load addition}] \quad (35)$$

ب) انتقال بارها

در این حالت کوشش می‌شود با انتقال ساعات اوج به ساعات‌های دیگر، پروفیل بار را بهبود بخشند:

$$[\uparrow p_3 \cap \uparrow p_2] \Leftrightarrow [\downarrow p_1] \quad (36)$$

ج) حذف پیک

کوشش می‌شود تا ساعات پیک به شکل مستقیم کمتر شود:

$$[\downarrow p_1] \Leftrightarrow [\text{load removal}] \quad (37)$$

د) حفظ انرژی

کوشش می‌شود تا میزان بار مصرفی در کل ساعات کاهش یابد:


$$[\downarrow p_1 \cap \downarrow p_3 \cap \downarrow p_2] \Leftrightarrow [\text{load removal}] \quad (38)$$

ه) ایجاد کردن بار

هنگامی که بخواهند مقدار متوسط بار افزایش یابد از این حالت بهره می‌برند.

$$[\uparrow p_1 \cap \uparrow p_3 \cap \uparrow p_2] \Leftrightarrow [\text{load addition}] \quad (39)$$

به علت ایجاد تصویری بهتر برای خواننده، موارد الف تا ه در شکل (۸) نشان داده شده است.



شکل (۷): توزیع نرمال پروفیل بار، ناحیه ۱ با تابع احتمالاتی

P_1 و محدوده $I_1 = [(\mu - \sigma)(\mu + \sigma)]$ ، ناحیه دو با تابع

احتمالاتی P_2 و محدوده

$I_2 = [(\mu - 2\sigma)(\mu - \sigma), (\mu + \sigma)(\mu + 2\sigma)]$ و ناحیه سه با

تابع احتمالاتی P_3 و محدوده

$$I_3 = [(\mu - 3\sigma)(\mu - 2\sigma), (\mu + 2\sigma)(\mu + 3\sigma)]$$

۴- اعمال الگوریتم پیشنهادی بر مسأله

پیش بینی

در این بخش به بیان الگوی به کار گرفته برای حل مسأله پیش بینی همزمان قیمت و بار روزانه می پردازیم. ابتدا فرض کنید که پیش بینی برای روز d انجام می گیرد. همچنین، فرض کنید اطلاعات گذشته سری داده های قیمت یا بار برای 24 ساعت روز $d-1$ به شکل $p_h; h=1, \dots, T$ ($d_h; h=1, \dots, T$) قابل دسترسی باشد که در آن T معمولاً بین حدود یک هفته تا چند ماه قبل را شامل می شود. به توجه به فرضیات گفته شده، مدل ایجاد شده در گام های زیر قابل پیگیری است.

گام اول: ابتدا با توجه به تابع تبدیل موجک داده های ورودی به چند زیر بخش (سری) تقسیم می شوند. تابع تبدیل موجک یک معیار مناسب برای سبک- سنگین کردن داده ها بر اساس میزان طول و همواری آنهاست. تابع تبدیل موجک داده های ورودی ($p_h; d_h; h=1, \dots, T$) را به چهار سری مجزا (a_h, b_h, c_h, d_h) تقسیم کرده که هر بخش به طور جداگانه وارد الگوریتم انتخاباتی فازی می شوند. سه سری a_h, b_h, c_h به عنوان ماتریس جزییات با تطبیق کمتر و d_h ماتریس تخمین بوده که مهم ترین نقش در تابع تبدیل را بر عهده دارد. بنابراین، تقسیم بندی ماتریس در چهار بخش مجزا به شکل زیر فرمول بندی می شود:

$$W(p_h, d_h) = \{a_h, b_h, c_h, d_h; h=1, \dots, T\} \quad (41)$$

گام دوم: با استفاده از آنالوژی فازی زیرمجموعه های استخراج شده از تبدیل موجک وارد این مرحله می شوند. در این قسمت بر اساس رابطه (۱۱) میزان همبستگی داده ها برچسب گذاری می شود و با انتخاب آستانه مناسب بهترین آن ها وارد مرحله بعدی می شوند.

گام سوم: استفاده از مدل چند ورودی چند خروجی بردار پشتیبان مبتنی بر کم ترین مربعات خطا برای پیش بینی

اطلاعات ساعت های $T+1, \dots, T+24$ برای هر سری تجزیه شده از داده های اولیه و جمع نتایج حاصل از پیش بینی با یکدیگر به منظور دستیابی به پیش بینی نهایی تا این مرحله.

گام چهارم: حال با توجه به خطای حاصل از پیش بینی میزان عملکرد شبکه بردار پشتیبان اعتبارسنجی می شود. نتایج حاصل از این اعتبارسنجی به استفاده از الگوریتم بهبود یافته کلونی مصنوعی زنبور عسل برای کم کردن خطای حاصل از پیش بینی منجر می شود.

گام پنجم: در این قسمت با کمک تابع هدف معرفی شده که بر مبنای کاهش خطای خروجی است، بهینه کردن وزن ها و بایاس ها برای شبکه بردار پشتیبان به منظور آموزش بهتر آن انجام می گیرد. تابع هدف مورد استفاده در این مقاله درصد خطای مطلق متوسط (MAPE) است که بر اساس تعداد روزهای مورد مطالعه (N) به شکل زیر فرمول بندی می شود:

$$MAPE = \frac{1}{N} \left(\sum_{i=1}^N \left(\frac{P_{act_i} - P_{for_i}}{P_{act_i}} + \frac{L_{act_i} - L_{for_i}}{L_{act_i}} \right) \right) \quad (42)$$

گام ششم: ایجاد کردن متغیرهای تعریف شده بر اساس توابع تصمیم گیری در الگوریتم بهبود یافته کلونی مصنوعی زنبور عسل.

گام هفتم: ارتقا جواب های به دست آمده تا این مرحله و به دست آوردن جواب های جدید بر اساس روابط در جستجوی محلی و کلی.

گام هشتم: بررسی شرط خاتمه برنامه. اگر شرط برنامه برقرار شده است نتایج منتشر شود در غیر این صورت رفتن به گام دوم.

شکل (۹) فلوچارت الگوریتم پیشنهادی را برای حل مسأله پیش بینی نشان می دهد.

۵- نتایج شبیه سازی

۵-۱- بررسی الگوریتم پیشنهادی

همان گونه که می دانیم با تعیین ضرایب مناسب علاوه بر ساختار داخلی خود الگوریتم، می توان جواب های بهتری به دست آورد. به منظور تعیین بهترین ضرایب تنظیمی در الگوریتم پیشنهادی آزمایش های مختلف بر روی توابع آزمون مختلف انجام گرفته است و بر اساس آن بهترین ضرایب انتخابی در جدول (۲) آورده شده است. همچنین، به منظور نشان دادن برتری روش پیشنهادی و علت انتخاب آن در حل مسأله توزیع اقتصادی توان، مقایسه با سایر روش ها از جمله الگوریتم استاندارد کلونی مصنوعی زنبور عسل انجام گرفته است.

جدول (۲): شاخص های الگوریتم پیشنهادی

مقدار	شاخص
۶۰	تعداد جمعیت
۱۰۰	Limit
۱۰	تعداد اجرا
۲۰۰۰	تعداد تکرار برنامه
10^{-20}	خطای مورد نظر

بهترین ضرایب انتخاب شده برای الگوریتم استاندارد کلونی مصنوعی زنبور عسل از مرجع [۳۱] گرفته شده است. در این صورت می توان قضاوت و مقایسه منصفانه ای بین این دو الگوریتم داشته باشیم. به عبارتی با این عمل هر دو الگوریتم از حداکثر قابلیت جستجوی خود بهره خواهند گرفت. تابع مورد مطالعه تابع نامقید سینوسی یا راسریگین است. این تابع بر اساس به کارگیری تابع کلی در آن، دارای نقاط محلی بسیار زیادی است. بنابراین، یکی از بهترین

توابع برای بررسی کارایی الگوریتم های جدید می باشد. روابط این تابع در معادله (۴۳) داده شده است. با در نظر گرفتن شاخص های مسأله به شکل $(-a, a)$ که در آن a یک عدد صحیح است، جواب بهینه مطلق صفر خواهد شد. در این شبیه سازی برای یافتن نقطه کمینه مطلق با اعمال محدوده ای به شاخص های مسأله، درصد پیچیده تر شدن حل مسأله شده ایم.

$$f(x_1, x_2) = -ae^{-b\sqrt{\frac{\sum_{i=1}^2 x_i^2}{n}}} - e^{\frac{\sum_{i=1}^2 \cos(c \cdot x_i)}{n}} + a + e \quad (43)$$

$a=20, b=0.2, c=2 \times \pi, -20 \leq x_i \leq 20, i=1,2$


به منظور آشنایی با ساختار این تابع و نشان دادن مینیمم های محلی، ترسیم سه محوری آن در شکل (۱۰) نشان داده شده است.

شبیه سازی برای این تابع در دو حالت انجام گرفته است. در حالت اول تعداد متغیرهای بهینه سازی برابر با ۱۰ است. نحوه همگرایی برای دو الگوریتم پیشنهادی و استاندارد در شکل (۱۱) و جدول (۳) نشان داده شده است. همان گونه که از شکل ها و نتایج به دست آمده در جدول (۵) برای انحراف معیار مشخص است، روش پیشنهادی به مراتب بهتر عمل کرده است. همچنین، همگرایی با تکرارهای کمتر نشان از سرعت بهتر این الگوریتم است. در این مقایسه سه روش مورد نظر است،

الف) الگوریتم استاندارد زنبور عسل (ABC)

ب) الگوریتم استاندارد زنبور عسل مبتنی بر تابع لجستیک (CABC)


ج) الگوریتم بهبود یافته پیشنهادی (MABC)




شکل (۹): ساختار کلی سیستم پیش بینی ارایه شده و مدیریت بار

۵-۲- بازار برق استرالیا

با توجه به پژوهش‌های انجام گرفته در گذشته، تولید نیروی برق استرالیا به طور مستقل توسط ایالت‌های آن انجام می‌گرفت. در طول دهه ۱۹۹۰ بازار ملی الکتریسیته توسعه یافت. با این حال، تمام ایالت‌ها در این بازار الکتریسیته ملی مشارکت نکردند. همچنین، رقابت خرده‌فروشی معرفی شد ولی هر یک از ایالت‌ها ترتیبات متفاوت و برنامه‌های زمانی مختلفی برای این مورد ارایه کردند. ایالت ویکتوریا، نخستین ایالت در زمینه اصلاحات صنعت برق استرالیا بود. در اکتبر ۱۹۹۳، کمیسیون دولتی الکتریسیته ایالت ویکتوریا به طور عمودی به ۳ بخش تفکیک شد: تولید، توزیع و انتقال. یک سال بعد، صنعت الکتریسیته به منظور خصوصی‌سازی دوباره تجدید ساختار و بخش تولید به ۵ شرکت تقسیم شد. این در حالی بود که ۲۹ شرکت قدیمی توزیع برق در ۵ شرکت ادغام شدند که مرکب از کارکردهای خرده‌فروشی و خطوط توزیعی بود. در دسامبر ۹۴، بزرگ‌ترین مشتریان که بالای ۵ مگاوات تقاضا داشتند، امکان انتخاب عرضه‌کننده را پیدا کردند. در طی سال‌های اخیر، باقیمانده ایالات استرالیا به جز ایالت تاسمانیا بازارهایشان را تا حدودی باز کرده‌اند. با این حال برنامه ایالت تاسمانیا در اکتبر ۲۰۰۳ باز کردن جزئی بازارش است. ایالت‌های استرالیا نگرششان در این زمینه فرق دارد ولی تمامی آن‌ها بازگشایی تدریجی بازارشان را انتخاب کرده‌اند. برخی ایالت‌ها از قبیل (ویکتوریا، New South Wales و South Australia) قبلاً به طور کامل بازارشان را باز کرده‌اند و برخی دیگر یا هنوز تصمیم برای باز کردن کامل بازارشان نگرفته‌اند. به علت اهمیت این بازار، New South Wales به عنوان یک ایالت از این بازار برای پیش‌بینی انتخاب شده است [۳۲]. نحوه اتصالات توزیع برق این ایالت در شکل (۱۲) نشان داده شده است. اطلاعات این بازار برای سال ۲۰۱۰ است. نتایج حاصل از روش پیشنهادی با مقاله [۴] مقایسه شده است. برای شبیه‌سازی دو ماه به عنوان آموزش و هفته اول ماه سوم به عنوان معیار مقایسه در نظر گرفته شده است.



شکل (۱۰): ترسیم سه محوری تابع آکلی




شکل (۱۱): همگرایی روش پیشنهادی برای تابع نمونه استاندارد

جدول (۳): مقایسه بین الگوریتم‌های بهینه‌سازی پیشنهادی

نتایج	الگوریتم	محدوده	تعداد متغیر	معیار مقایسه
2.61e-13	ABC	[-3,3]	10	انحراف معیار
0.00	CABC			
0.00	MABC			
2.54e-13	ABC	[-3,3]	10	میانگین
4.03e-14	CABC			
0.00	MABC			
>2000	ABC	[-3,3]	10	تکرار همگرایی
<2000	CABC			
<1000	MABC			
1.928	ABC	[-100,100]	1000	انحراف معیار
1.338	CABC			
0.034	MABC			
29.96	ABC	[-100,100]	1000	میانگین
21.87	CABC			
17.70	MABC			
>3000	ABC	[-100,100]	1000	تکرار همگرایی
<2500	CABC			
<2000	MABC			

۱۰۲ مدل سازی سیستم چند ورودی چند خروجی برای پیش بینی همزمان قیمت و بار در شبکه هوشمند با اعمال مدیریت بار



شکل (۱۲): نحوه اتصالات توزیع برق ایالت New South Wales (NSW) در بازار برق استرالیا [۳۲]

جدول (۴): مقدار معیار میانگین قدر مطلق خطای درصدی برای ایالت NSW در بازار برق استرالیا

Month	Daily forecasting				Weekly forecasting	
	Demand		Price		Demand	Price
	Ref. [4]	Proposed method	Ref. [4]	Proposed method	Proposed method	
Mar.	2.54	2.28	9.85	7.05	6.14	8.57
Jun.	2.27	2.24	15.70	14.38	6.36	15.9
Sep.	2.61	2.60	7.75	7.05	6.85	8.84
Dec.	1.81	1.79	6.76	6.52	7.03	7.29
Mean	2.31	2.22	10.01	8.75	6.59	10.2

با وجود هیئت رئیسه، اجرا قوانین و بهره‌برداری بازار برق توسط شرکت شبکه ملی که اعضای آن نمایندگان تولیدکنندگان و شرکت‌های توزیع بودند انجام می‌شد. فقدان حمایت‌های نهاد قانون‌گذار برای توسعه واحد پایش و مقاومت اعضای شرکت شبکه ملی در مقابل قوانین، اصلاح سیاست‌ها را بسیار کند می‌کرد. به این ترتیب، بازار پول انگلستان قیمت‌های بالایی را در دهه ۹۰ تجربه کرد. در نتیجه ارتقای توانایی نهادهای قانون‌گذار، هر دو نقش قانون‌گذاری و پایش بازار به نهاد جدید قانون‌گذار برق واگذار شد. هم اکنون بازار برق نیو انگلند به عنوان یک بازار برق معتبر در مقالات معتبر مختلف، بحث و بررسی می‌شود. به منظور ارزیابی روش پیشنهادی اطلاعات این بازار در سال ۲۰۰۸ انتخاب شد که وبسایت [۳۳]

مقایسه نتایج به دست آمده از روش پیشنهادی در این مقاله و روش مرجع [۴] در جدول (۴) آورده شده است. برای مقایسه از معیار معرفی شده (۳۴) بهره گرفته شده است. بر اساس جدول (۴)، مشخص است که روش پیشنهادی دقت و قابلیت بالاتری در پیش‌بینی همزمان قیمت و بار دارد. همچنین، برای نشان دادن این نکته، شکل (۱۳) نتیجه پیش‌بینی ۱۶۸ ساعت را نشان می‌دهد. همان‌گونه که از شکل مشخص است روش پیشنهادی قابلیت اطمینان بالا در مسأله پیش‌بینی قیمت و بار در ساختار همزمان دارد.

۵-۲- بازار برق نیوانگلند

از ابتدای راه اندازی بازار پول انگلستان در سال ۱۹۹۰،


همچنین، نمودار پراکنش ماتریسی شکل (۱۶) در دوره ۲۴ ساعته برای بازار برق نیوانگلند میزان پراکندگی و دقت پیش‌بینی را بیان می‌کند.

جدول (۵) نتیجه پیش‌بینی قیمت و بار را در ماه‌های مختلف نشان می‌دهد. دو ماه برای آموزش و هفته اول ماه بعدی به عنوان ارزیابی در نظر گرفته شده است. نتایج پیاده‌سازی بیانگر این است که استفاده از این روش می‌تواند به صرفه جویی زیادی در هزینه های شرکت در بازار بیانجامد.


قابل‌دسترسی است. مقدار MAPE به دست آمده در دوره زمانی ۲۴ ساعته برای سیگنال‌های قیمت و بار برابر با $4/09$ و $4/30$ درصد است. این مقدار برای پیش‌بینی دقت مناسبی بوده که نشان از قابلیت بالای روش پیشنهادی دارد. همچنین، روند پیش‌بینی برای دوره زمانی ۲۴ ساعته در شکل (۱۴) آورده شده است. همچنین، برای یک دوره طولانی یک هفته‌ای، روند پیش‌بینی برای سیگنال‌های قیمت و بار در شکل (۱۵) آورده شده است. مقدار MAPE به دست آمده در دوره زمانی ۱۶۸ ساعته برای سیگنال‌های قیمت و بار برابر با $7/33$ و $6/07$ درصد است.

جدول (۵): مقدار میانگین قدر مطلق خطای درصدی برای بازار برق نیوانگلند

Month	Demand			Price		
	Without (FMI+DWT)	Without (FMI)	Complete method	Without (FMI+DWT)	Without (FMI)	Complete method
March	10.64	7.84	4.09	12.61	8.64	4.30
June	12.43	6.53	4.12	12.01	6.05	4.27
September	11.85	6.94	3.98	11.59	7.03	4.15
December	14.67	7.53	4.25	10.83	6.85	3.76
Mean	12.39	7.21	4.11	11.70	7.14	4.12



شکل (۱۳): روند پیش‌بینی قسمت و بار برای دو ماه اول سال ۲۰۱۰




شکل (۱۵): روند پیش‌بینی قیمت و بار در بازار برق نیوانگلند دوره ۱۶۸ ساعته

۱۰۴ مدل سازی سیستم چند ورودی چند خروجی برای پیش بینی همزمان قیمت و بار در شبکه هوشمند با اعمال مدیریت بار

بار سبب می شود تا مطابق شکل (۷) توزیعی با تجمع بیشتر برای یک داشته باشیم.


همان گونه که تحلیل های انجام گرفته نشان داده است، روش پیشنهادی قابلیت مناسبی برای پیش بینی تغییرات بار دارد که می تواند نکته اتکایی برای مصرف کننده برای بهبود پروفیل بار خود باشد. توزیع بار با در نظر گرفتن مدیریت بار و بدن در نظر گرفتن مدیریت بار در شکل (۱۷) آورده شده است. همان گونه که اشاره شد تجمع بیشتر در ناحیه ۱ در شکل (۳) نشان از بهبود پروفیل بار و ضریب بار دارد.



شکل (۱۷): پروفیل بار با اعمال مسأله بهینه سازی مدیریت بار


۶- نتیجه گیری

همان گونه که در این مقاله بحث شده است با هوشمندسازی شبکه برق و ایجاد ارتباطات دوطرفه میان مصرف کننده و تولیدکننده، پیش بینی قیمت و بار به شکل همزمان حقیقتی انکارناپذیر است. در حقیقت، در شبکه هوشمند باید تقابل بین آن ها لحاظ شود. در همین راستا، در مقاله حاضر به مدل سازی سیستم چند ورودی چند خروجی پرداخته شده است تا بتوان به پیش بینی مطمئن تری دست یافت. روش پیشنهادی از سیستم پیش پردازش کننده فازی، تبدیل موجک و موتور پیش بینی کننده بهره می برد. تحلیل های انجام گرفته بر روی بازارهای واقعی موجود، نشان از دقت بالا و اطمینان مناسب به این روش را در پی دارد. همچنین، در راستای بهبود پروفیل بار، مدیریت بار به شکل یک مسأله بهینه سازی تبدیل شده که هدف بهبود ضریب بار است. با اعمال مدیریت بار از نوسانات یا پیک های ناگهانی جلوگیری و سبب ایجاد پروفیل صاف تری



شکل (۱۴): روند پیش بینی قیمت و بار در بازار برق نیوانگلند

دوره ۲۴ ساعته



شکل (۱۶): نمودار پراکنش ماتریسی برای پیش بینی انجام گرفته

در دوره زمانی ۲۴ ساعته بازار نیوانگلند

۵-۳ مدیریت تقاضا بر پروفیل بار بازار

نیوانگلند

این قسمت با در نظر گرفتن مدیریت بار تلاش در بهبود تابع هدف یعنی ضریب بار و توزیع بهتر برای پروفیل بار دارد. کنترل مستقیم بار، پیک سایی، انتقال پیک و برنامه های تشویقی برای کاهش بار در ساعات پیک، بخشی از اقداماتی بوده که در این راستا انجام شده است. اکنون با ظهور مدیریت بار به ابزار جدیدتر و کارآمدتری مجهز شده است که امکان تعرفه بندی پویا، مدیریت مصرف انرژی در سمت تقاضا و یکپارچه سازی مدیریت انرژی با بازار برق و داشتن اطلاعات آنالیز و بازخوردهای لازم از سمت مصرف کننده را فراهم می سازد. در چنین شرایطی، تجهیزات مصرف کننده هوشمند، شرایط شبکه و گزینه های مختلف تعرفه ای را رصد خواهند کرد و بر این اساس در خصوص کنترل مصرف خود تصمیم خواهند گرفت. اعمال مدیریت

- "Forecasting electricity spot market prices with a k-factor GIGARCH process", Appl Energy, Vol. 86, pp. 505–510, 2009.
- [13] Hang, L., Luh, P.B., Kasiviswanathan, K., "Electricity price short term forecasting using artificial neural networks", IEEE Trans Power Syst, Vol. 20, pp. 59–66, 2005.
- [14] Jammazi, R., Aloui, C., "Crude oil price forecasting: experimental evidence from wavelet decomposition and neural network modeling", Energy Economics, Vol. 34, pp. 828–841, 2012.
- [15] Wu, L., Shahidehpour, M., "Hybrid model for day-ahead price forecasting", IEEE Transactions on Power Systems, Vol. 25, pp. 1519–1530, 2010.
- [16] Amjady, N., "Day-ahead price forecasting of electricity markets by a new fuzzy neural network", IEEE Trans Power Syst, Vol. 21, pp. 887–896, 2006.
- [17] Li, X.R., Yu, C.W., Ren, S.Y., Chiu, C.H., Meng, K., "Day-ahead electricity price forecasting based on panel cointegration and particle filter", Electric Power Systems Research, Vol. 95, pp. 66–76, 2013.
- [18] Zhu, B., Wei, Y., "Carbon price forecasting with a novel hybrid ARIMA and least squares support vector machines methodology", Omega, Vol. 41, pp. 517–524, 2013.
- [19] Lin, C. T., Chou, L. D., Chen, Y. M., Tseng, L. M., "A hybrid economic indices based short-term load forecasting system," Electrical Power and Energy Systems, Vol. 54, pp. 293–305, 2014.
- [20] Catalo, J.P.S., Pousinho, H.M.I., Mendes, V.M.F., "Short-term electricity prices forecasting in a competitive market by a hybrid intelligent approach," Energy Conversion and Management, Vol. 52, pp. 1061–1065, 2011.
- [21] Mahmoudi, N., Saha, T. K., Eghbal, M., "A new demand response scheme for electricity retailers", Electric Power Systems Research, Vol. 108, pp. 144–152, 2014.
- [22] Siano, P., "Demand response and smart grids-A survey", Renewable and Sustainable Energy Reviews, Vol. 30, pp. 461–478, 2014.
- [23] Mallat, S., Zhong, S., "Characterization of signals from multiscale edge", IEEE Trans. Pattern Anal. Machine intell., Vol. 14, pp. 710–732, 1992.
- [24] Jensen, Cour-Harbo, I., "Ripples in Mathematics", Berlin: Springer, pp. 157–160, 2011.
- [25] Dash, M., Liu, H., "Feature Selection for Classification", Intelligent Data Analysis, Vol. 1, pp. 131–156, 1997.
- [26] Shayeghi, H., Ghasemi, A., "Day-ahead می شود که در نتیجه آن از پیچیده تر شدن مدل پیش بینی کننده خواهد کاهید. در حقیقت این مقاله نشان داده است به جای اینکه به دنبال روش های پیچیده تر با حجم محاسبات بالاتر باشیم، می توان با اعمال مدیریت بار، سیگنال های بهتری داشت.
- ### مراجع
- [1] McDonald, J., "Leader or Follower: Developing the Smart Grid Business Case", IEEE Power and Energy Magazine, 2008, Issue 6.
- [2] Community Research, European Commission, "European SmartGrids Technology Platform: Vision and Strategy for Europe's Electricity Networks of the Future", Luxembourg, 2006
- [3] ABB AG, "When Grids Get Smart", Germany, 2009.
- [4] Motamedi, A., Zareipour, H., Rosehart, W. D., "Electricity Price and Demand Forecasting in Smart Grids", IEEE Trans. Smart Grid, Vol. 3, No. 2, pp. 664–674, 2012.
- [5] Amjady, N., "Short-term bus load forecasting of power systems by a new hybrid method," IEEE Trans. Power Syst., Vol. 22, No. 1, pp. 333–341, 2007.
- [6] Li, X.R., Yu, C.W., Ren, S.Y., Chiu, C.H., Men, K., "Day-ahead electricity price forecasting based on panel cointegration and particle filter", Electric Power Systems Research, Vol. 95, pp. 66–76, 2013.
- [7] Nogales, F.J., Contreras, J., Conejo, A.J., Espinola, R., "Forecasting next-day electricity prices by time series models", IEEE Trans Power Syst, Vol. 17, pp. 342–348, 2002.
- [8] Contreras, J., Espinola, R., Nogales, F.J., Conejo, A.J., "ARIMA models to predict next day electricity prices", IEEE Trans Power Syst., Vol. 18, pp. 1014–1020, 2003.
- [9] Pao, H.T., "Forecasting energy consumption in Taiwan using hybrid nonlinear models," Energy, Vol. 34, pp. 1438–1446, 2009.
- [10] Bowden, N., Payne, J.E., "Short-term forecasting of electricity prices for MISO hubs: evidence from ARIMA-EGARCH models", Energy Economics, Vol. 30, pp. 3186–3197, 2008.
- [11] Conejo, A.J., Plazas, M.A., Espinola, R., Molina, A.B., "Day-ahead electricity price forecasting using the wavelet transform and ARIMA models", IEEE Trans Power Syst., Vol. 20, pp. 1035–1042, 2005.
- [12] Diongue, A.K., Guegan, D., Vignal, B.,

- theory”, New York: Springer; 1995.
- [30] Pérez-Cruz, F., Navia-Vázquez, A., Alarcón-Diana, P. L., Artés-Rodríguez, A., “An IRWLS procedure for SVR”, in Proc. EUSIPCO, Tampere, Finland, Sept., pp.1–14, 2000.
- [31] D. Karaboga, B. Akay, “A comparative study of artificial bee colony algorithm,” *Applied Mathematics and Computation*, Vol. 214, pp. 108–132, 2009.
- [32] Australian Energy Market Operator [Online]. Available: <http://www.aemo.com.au>.
- [33] New England ISO [Online]. Available: <http://www.iso-ne.com/>.
- 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.
- [27] Lee, H. M., Chen, C. M., Chen, J. M., Jou, A. Y. L., “An efficient fuzzy classifier with feature selection based on fuzzy entropy”, *IEEE Transactions on Systems, Man, and Cybernetics-PART B: Cybernetics*, Vol. 31, pp. 426–432, 2001.
- [28] Bhadra, S., “Learning robust support vector machine classifiers with uncertain observations”, A thesis submitted for the degree of doctor of philosophy at Indian Institute of Science, 2012.
- [29] Vapnik, VN., “The nature of statistical learning

¹ Auto regressive integrated moving average model (ARIMA)

².Generalized Auto Regressive Conditional Heteroskedasticity (GARCH)