

پیش بینی میان مدت و کوتاه مدت بار با بکارگیری شبکه های عصبی راف و الگوریتم بهینه سازی جهش ملخ

محمد فردوسیان^۱، حمدی عبدی^۲، شهرام کریمی^۳، سعید خراطی^۴

تاریخ دریافت: ۱۳۹۹/۰۱/۰۹

تاریخ پذیرش: ۱۳۹۹/۰۷/۱۵

چکیده

با افزایش جمعیت و رشد جوامع صنعتی تغییرات بار مصرفی در شبکه های قدرت غیر قابل اجتناب بوده و لازم است میزان بار مورد نیاز شبکه، پیش بینی شود. پیش بینی بار ساعتی به صورت میان مدت می تواند معیار مناسبی برای برآورد بار و انرژی باشد. همچنین این پیش بینی الگوی خوبی برای پیش بینی کوتاه مدت بار خواهد بود. در این مقاله روش جدیدی برای پیش بینی ساعتی بار به صورت میان مدت و کوتاه مدت با استفاده از شبکه های عصبی راف و الگوریتم جهش ملخ ارائه می گردد. در این مقاله یک شبکه عصبی راف بهبود یافته ارائه شده است. شبکه های عصبی راف نوعی از ساختارهای عصبی هستند که براساس نرون های راف طراحی می شوند. یک نرون راف را می توان به صورت زوجی از نرون ها در نظر گرفت که به نرون های کران بالا و کران پایین مرسوم هستند. همانند شبکه های پرسپترون چند لایه شبکه عصبی راف نیز می تواند با استفاده از الگوریتم پس انتشار خطا مبتنی بر گرادینان نزولی آموزش داده شود. با این حال این الگوریتم دارای مشکلاتی مانند در دام افتادن در کمینه های محلی است که در این مقاله به کمک الگوریتم جهش ملخ، بر این کاستی غلبه می شود. برای شبیه سازی روش پیشنهادی در پیش بینی بار روزانه، شبکه سراسری برق دبی به منظور اعمال شبکه های عصبی راف و ترکیب آن با الگوریتم جهش ملخ ارائه می گردد که نتایج نشانگر موفقیت آمیز بودن روش های پیشنهادی می باشد.

کلید واژه ها: پیش بینی بار، شبکه های عصبی راف، الگوریتم جهش ملخ، الگوریتم ژنتیک

۱ دانشجوی دکتری، گروه برق، واحد کرمانشاه، دانشگاه آزاد اسلامی، کرمانشاه، ایران، ferdosian_m@yahoo.com

۲ دانشیار، گروه برق، دانشکده فنی و مهندسی، دانشگاه رازی، کرمانشاه، ایران، نویسنده مسئول، hamdiabdi@gmail.com

۳ استادیار، گروه برق، دانشکده فنی و مهندسی، دانشگاه رازی، کرمانشاه، ایران، shahramkarimi@razi.ac.ir

۴ استادیار، گروه برق، واحد کرمانشاه، دانشگاه آزاد اسلامی، کرمانشاه، ایران، saeed.kharraty@gmail.com

۱- مقدمه

پیش بینی بار یک فرایند مرکزی و جامع در برنامه ریزی و بهره برداری صنعت برق بوده است. روشهای زیادی در دو دهه اخیر برای حل بهینه این مسئله پیشنهاد شده اند. این روشها اغلب به لحاظ ماهیت با هم تفاوت داشته و به نظریات مختلف مهندسی و تحلیل های اقتصادی پاسخ می دهند. یکی از مراحل مهم در طراحی سیستم های توزیع انرژی الکتریکی پیش بینی بار و سیر تغییرات آن از زمان حال تا پایان سال مورد نیاز برای طراحی می باشد. پیش بینی صحیح بار علاوه بر صرفه جویی در هزینه های سرمایه گذاری، امکان برنامه ریزی زمانی مناسب جهت اجرای پروژه را نیز فراهم می نماید (طراحی دینامیک). در کشورهای پیشرفته و در حال توسعه، برنامه های اقتصادی میان مدت و بلند مدتی به منظور رسیدن به اهداف اقتصادی و اجتماعی آن کشورها طرح ریزی می شود. یکی از شاخه های برنامه های اقتصادی، پیش بینی مصرف انرژی و شاخه فرعی، پیش بینی مصرف انرژی الکتریکی است. با پیش بینی مصرف انرژی الکتریکی می توان اطلاعات کافی برای طراحی و توسعه شبکه های توزیع تهیه کرد. این پیش بینی به منظور تحلیل نیازهای آینده و برنامه ریزی درباره محل، ظرفیت و وابستگی فیدرها، پست های اصلی و پست های فرعی، مورد نیاز است. پیش بینی مصرف انرژی الکتریکی با اعمال

ضریب بار به پیش بینی بار پیک تبدیل می شود تا جهت طراحی اجزاء مختلف سیستمهای تولید، انتقال و توزیع انرژی الکتریکی استفاده شود. انرژی الکتریکی در مقیاس وسیع از لحاظ اقتصادی، قابل ذخیره نمی باشد. بدین دلیل برخلاف شاخه های دیگر اقتصاد، در اقتصاد الکتریسیته باید همزمان با مصرف، انرژی تولید گردد. میزان مصرف بار الکتریکی ثابت نمی باشد، بلکه تصوری پیچیده و غیرخطی، تابعی از پارامترهای متعددی می باشد. با توجه به متغیر بودن میزان مصرف بار الکتریکی، شرکت های تولید کننده برق، موظفند با پیش بینی بار در زمان بندی های مختلف، اطلاعات مورد نیاز برای تصمیم گیریهای خود در سیستم قدرت را حاصل نمایند. دوره های پیش بینی بار به سه دسته زیر تقسیم می شوند: الف) کوتاه مدت (چند روز تا یک هفته آینده) ب) میان مدت (یکسال یا دو سال آینده) ج) دراز مدت (تا ۱۰ سال آینده). پیش بینی کوتاه مدت بار که در آن بار یک روز تا یک هفته آینده به صورت ساعتی پیش بینی می شود معیار مهمی در برنامه ریزی جهت بهره برداری از شبکه های قدرت می باشد. تعیین زمان حداکثر بار و آمادگی قبلی برای زمان های بحرانی شبکه، مطالعات پخش بار، مطالعات قابلیت اطمینان سیستم، برنامه ریزی برای سرویس شبکه و حتی بهره برداری اقتصادی از شبکه های تولید و انتقال همگی در گرو پیش بینی بار ساعتی میان

مدت می باشد. روش سنتی پیش بینی بار، استفاده از نتایج آماری می باشد [۱-۲]، لیکن در سالهای اخیر روشهای جدیدی بر اساس هوش مصنوعی ارائه گردیده است.

۱-۱. پژوهش‌های مرتبط

به منظور پیش بینی بار در کوتاه مدت تحقیقات مختلفی صورت گرفته است. استفاده از اطلاعات هواشناسی در پیش بینی بار می تواند کاربرد زیادی داشته باشد. در مرجع [۱] استفاده از اطلاعات هواشناسی با استفاده از روش رگرسیون به منظور پیش بینی بار استفاده شده است. در مرجع [۲] پیش بینی کوتاه مدت بار با برنامه ریزی خطی و نقش آن بر عملکرد امنیتی یک سیستم مدیریت انرژی بررسی شده است. سپس ماهیت بار و عوامل مختلفی که بر رفتار آن تأثیر می گذارد مورد بحث قرار گرفته است. طبقه بندی دقیق انواع روش های مدل سازی بار و تکنیک های پیش بینی در این مقاله ارائه شده است. شبکه عصبی انبساطی برای پیش بینی بارهای کوتاه مدت محسوب می شود که در این زمینه مقالات زیادی ارائه شده است. تکنیک شبکه عصبی مصنوعی (ANN^1) برای پیش بینی بار کوتاه مدت در مقاله [۳] پیشنهاد شده است که داده ها از دو سرویس در مدل سازی و پیش بینی استفاده می کند، علاوه بر این، اثربخشی ANN مدل ۲۴ ساعته بعدی در پیش بینی پروفیل بار ۲۴

ساعت در یک زمان با مدل ANN سنتی ۱ ساعته مقایسه شد است [۳].

یک روش بهبود یافته شبکه عصبی برای پیش بینی بارهای کوتاه مدت پیشنهاد شده است، همچنین یک استراتژی مناسب برای انتخاب آموزش شبکه عصبی ارائه شده است که این استراتژی از مزایای کاهش مشکل تغییرات شدید در الگوهای آب و هوایی است که مشاهدات نامناسب برای آموزش شبکه را ایجاد می کند، الگوریتم شبکه بهبود یافته عصبی، ترکیبی از اصطلاحات خطی و غیر خطی است که بار ورودی و دما را به خروجی پیش بینی بار ربط می دهد و استراتژی جستجو و الگوریتم، دقت بهبود یافته را نسبت به سایر روش ها نشان می دهد، شبیه سازی با استفاده از داده های دو سال مورد آزمایش قرار گرفت [۴]. در مقاله [۵] بررسی پنج تکنیک پیش بینی بار کوتاه مدت (تا ۲۴ ساعت) مورد استفاده قرار می گیرد که عبارتند از: رگرسیون چندگانه خطی؛ سری زمانی تصادفی؛ تحلیل آماری؛ فضای حالت و فیلتر کالمن و یک رویکرد مبتنی بر دانش. خلاصه مقایسه ای از نتایج ارائه شده برای درک سطح ذاتی سختی هر یک از این تکنیک ها مورد توجه قرار گرفته است. یک روش شبکه عصبی مصنوعی (ANN) برای پیش بینی بار کوتاه مدت یک سیستم قدرت بزرگ استفاده می شود. بار

¹ artificial neural network

دارای دو الگو متمایز است: الگوهای روز هفته و روزهای آخر هفته. الگوی روز آخر هفته شامل روزهای شنبه، یکشنبه و دوشنبه می شود. چندین ساختار ANN برای پیش بینی بار کوتاه مدت آزمایش شده اند. ورودی ANN، بارهای گذشته است و خروجی ANN، پیش بینی بار برای یک روز داده شده است. شبکه با یک یا دو لایه پنهان با ترکیب های مختلف نرون، مورد آزمایش قرار گرفت و نتایج را با توجه به خطای پیش بینی مقایسه می کند [۶]. این مقاله [۷] ارائه یک مدل پیش بینی بار کوتاه مدت بر اساس شبکه عصبی مصنوعی (ANN) برای مرکز کنترل انرژی شرکت برق عمومی یونان (PPC^2) را ارائه می دهد. این مدل می تواند پروفایل های روزانه بار را با یک زمان سر بسته یک تا هفت روز پیش بینی کند. توجه به مدل دقیق تعطیلات، تجارب به دست آمده در طول توسعه مدل در مورد انتخاب متغیرهای ورودی، ساختار ANN و مجموعه داده های آموزشی در مقاله شرح داده شده است. نتایج نشان می دهد که مدل پیش بینی بار، پیش بینی های دقیق را ارائه می دهد. یک جزء ضروری از یک مرکز کنترل جامع برای سیستم های قدرت، یک روش برای محاسبه پیش بینی های بار کوتاه مدت است. مقاله به بررسی یک سیستم پیش بینی انطباق بر اساس مقادیر مشاهده شده از تقاضای ساعتی یکپارچه می

پردازد. یک مدل توسعه یافته که دقت بالا و سادگی عملیاتی را ارائه می دهد [۸]. در مقاله [۹] روش استنتاجی فازی برای پیش بینی بار کوتاه مدت پیشنهاد می شود. روش پیشنهادی یک ساختار بهینه از استنتاج فازی ساده ایجاد می کند که خطاهای مدل و تعداد توابع عضو، برای درک رفتارهای غیرخطی بارهای کوتاه مدت نیروی برق را به حداقل می رساند. این مدل با استفاده از یک الگوریتم فراابتکاری به نام SA^3 شبیه سازی شده است.

پیش بینی بار کوتاه مدت ساختمان در عملیات روزانه ساختمان های هوشمند سبز آینده، به ویژه در شکل گیری سیستم های کنترل و ارزیابی اثرات زیست محیطی مرتبط، ضروری است. اکثر کارهای پژوهشی قبلی بر روی تکنیک های پیش بینی تمرکز کرده اند، اما در مورد ارزیابی قابلیت های عوامل تاثیرگذار مثل آب و هوا پیش بینی شده در ساعات آینده مطالعاتی انجام نشده است. این مقاله یک روش بهبود یافته برای پیش بینی بار ساختمان در ۲۴ ساعت آینده، همراه با یک روش نسخه پشتیبان تهیه می کند. کیفیت مدل تولید پیش بینی آب و هوا و روش های پیش بینی شده از طریق مطالعه موردی در مورد کاربرد در ساختمان های دانشگاهی مورد بررسی قرار گرفت. نتایج نشان داد که دقت پیش بینی بار با استفاده از داده های آب و هوایی واقعی در رکورد

توان با اندازه گیری لوازم خانگی در داده های آموزشی به طور قابل توجهی افزایش داد. اثربخشی روش پیشنهاد شده از طریق مطالعات مقدماتی گسترده در یک مجموعه داده دنیای واقعی معتبر است [۱۲-۱۳].

یکی از روش های مهم مورد استفاده در فرآیند پیش بینی بار، روش سری های زمانی می باشد. این روش مجموعه ای از مشاهدات است که براساس زمان مرتب شده اند. به عبارت دیگر می توان گفت یک سری زمانی مجموعه ای از داده های آماری است که در فواصل زمانی مساوی و منظمی جمع آوری شده باشند. در تقسیم بندی کلی، سری های زمانی را به پیوسته و گسسته تقسیم بندی می کنند. یک سری زمانی را پیوسته گویند، هرگاه مشاهدات به صورت پیوسته در زمان ایجاد شده باشند. سری زمانی را گسسته گویند [۱۳] هرگاه مشاهدات فقط در زمان های معینی که معمولا به فواصل مساوی از یکدیگر قرار دارند، ثبت شده باشد تغییرات سری زمانی می تواند به علت تغییرات بعضی از عوامل زیر باشد که تعدادی از آنها طبیعی و برخی ناشی از عوامل اقتصادی و اجتماعی هستند. معمولا برای تحلیل یک سری زمانی فرض می کنیم این تغییرات نتیجه ی چهار مؤلفه اصلی هستند [۱۴]-

و یا داده های آب و هوا پیش بینی شده از مدل تولید مشخصات، بسیار مشابه است. و مدل پیش بینی آب و هوا، مناسب برای اعمال پیش بینی بار ساختمان است. علاوه بر این، مقایسه های بین مجموعه های مختلف داده های ورودی نشان داد که دقت پیش بینی از طریق فیلتر داده ها، ورود داده ها و روش های تجدید ساختار بهبود یافته است [۱۰].

در مقاله [۱۱] روشی برای پیش بینی بار سیستم توزیع پیشنهاد شده است که هدف آن ارائه پیش بینی بار بسیار دقیق و بارگذاری با وضوح بالا با استفاده از یک پیش بینی بر مبنای بردار پشتیبانی (SVR⁴) و روش بهینه سازی پارامترهای دو مرحله ای ترکیبی است. به طور خاص، به این دلیل که پروفیل های بار در سیستم های توزیع دارای انحرافات ناگهانی هستند، نرمال سازی داده ها به عنوان پیش پردازش داده های بار طراحی شده است. سپس یک مدل SVR برای داده های بار برای پیش بینی بار آینده آموزش داده می شود. برای عملکرد بهتر SVR، یک الگوریتم بهینه سازی ترکیبی دو مرحله ای برای تعیین بهترین پارامترها پیشنهاد می شود.

یک چارچوب پیش بینی مبتنی بر حافظه طولانی مدت، مبتنی بر حافظه با استفاده از توالی مصرف لوازم، پیشنهاد شده است تا به چنین مشکل فرار پردازد که نشان می دهد دقت پیش بینی را می

⁴ support vector regression

۱۵]. این اجزاء یا مؤلفه‌ها در ادامه معرفی می‌شوند یک سری زمانی مشخص، ممکن است از هر چهار جزء و یا فقط برخی از این اجزاء تشکیل شده باشد [۱۶-۱۷]. سری‌های زمانی، یکی از شاخه‌های آمار و احتمال است که در سایر رشته‌ها مانند اقتصاد، مهندسی ارتباطات، هواشناسی، مدیریت، بازاریابی و ... کاربرد فراوانی دارد [۱۸-۱۹-۲۰-۲۱].

در این مقاله سری زمانی برای پیش بینی بار استفاده می‌شود که به کمک ابزار شبکه عصبی سعی در پیش بینی بار داریم.

۱-۲. مرور کلی مقاله

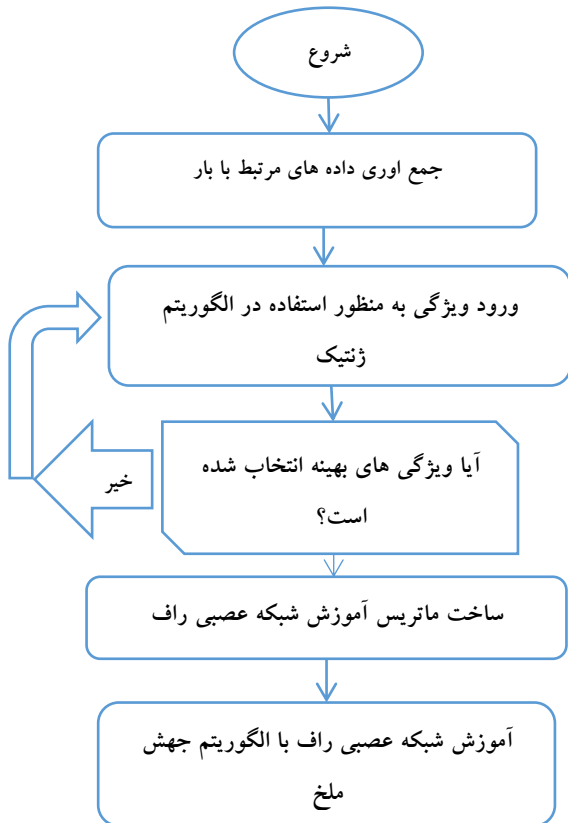
در این مقاله استفاده از الگوریتم ملخ برای اولین بار برای آموزش شبکه عصبی راف استفاده شده است. به کمک الگوریتم جهش، وزن‌های شبکه عصبی راف تعیین شده و در نهایت به کمک تابع هزینه ای که از خطای پیش بینی بدست می‌آید تکرار الگوریتم انجام می‌شود.

در ادامه ابتدا فرمولاسیون روش پیشنهادی ارائه می‌گردد که در آن مفاهیم مربوط به شبکه عصبی راف و الگوریتم بهینه‌سازی جهش ملخ توضیح داده خواهد شد. در ادامه روش پیشنهادی بر روی یک شبکه نمونه اعمال می‌گردد و دقت این روش در مقایسه با روشهای دیگر نشان داده خواهد شد.

۲. فرمولاسیون روش پیشنهادی

به منظور پیش بینی بار از شبکه عصبی راف استفاده شده است، بدین منظور اطلاعات بدست آمده به عنوان اطلاعات خام در نظر گرفته شده است که نیاز به پیش پردازش و غربال‌گری دارد. بر روی داده‌ها عملیات پیش پردازش صورت می‌گیرد به عبارتی ابتدا داده را برای استخراج ویژگی آماده می‌کنیم، در این مرحله از حذف نویز و فیلترهای حذف نویز استفاده می‌شود که داده‌های پرت و نامرتب کنار گذاشته شده و از فیلترهای میانگین به منظور کاهش حذف نویز استفاده می‌شود. بدین ترتیب داده‌هایی که به دلیل نویز زیاد ممکن است اتفاق افتاده باشند با روش حد آستانه و میانگین‌گیری حذف می‌شوند.

تکنیک‌هایی که در انتخاب متغیرها در پیش بینی سری زمانی یا شناخت الگو رایج هستند، وظایف این الگوریتم‌ها به طور مستقیم یا غیر مستقیم شامل حداکثر سازی اطلاعات متقابل بین داده‌های ورودی و خروجی می‌شود. با این وجود، این روش‌ها نیاز به تلاش محاسباتی بالا برای محاسبه آنتروپی مشترک، که نیاز به برآورد توزیع احتمالی مشترک است را دارد. برای جلوگیری از این تلاش محاسباتی، می‌توان یک انتخاب متغیر را بر اساس، اصل کمترین بیش از حد مجاز / حداکثر ارتباط استفاده کرد که اطلاعات متقابل را به صورت غیر مستقیم با هزینه محاسبات پایین به حداکثر می‌رساند. با این حال، مشکل بهینه



شکل ۱: فلوجارت پیشنهادی انتخاب ویژگی های بهینه با الگوریتم ژنتیک به منظور استخراج ویژگی های بهینه و ویژگی هایی که بیشترین تاثیر را در پیش بار دارند از مقاله [۲۳]


۱-۲. شبکه عصبی راف

با توجه به اینکه در مسائل شناسایی، مقدار متغیر وابسته در دسترس است، برای آموزش شناساگر عصبی میتوان از یادگیری با نظارت استفاده نمود. از این رو، فرآیند یادگیری در شبکه عصبی راف مانند یک شبکه پرسپترون پیشرو چند لایه میتواند با استفاده از الگوریتم پس انتشار خطا مبتنی بر گرادینان نزولی مرتبه اول پیاده سازی شود، بطوریکه مقدار خطای ایجاد شده در خروجی شبکه با استفاده از این الگوریتم، کمینه میشود. هر چند که الگوریتم پس انتشار خطا مبتنی بر

سازی ترکیبی، به عنوان مثال برای بررسی همه ترکیبات ممکن از متغیرها، هنوز نشان دهنده تلاش محاسباتی بزرگ است. با توجه به این هزینه محاسباتی، برخی از آثار قبلی با روش ساده ای از جستجوی افزایشی، پیشنهاد شده است که به یک راه حل شبه مطلوب دست می یابد. با توجه به محدودیت های روش های موجود، این کد برای بهینه سازی ترکیبی با استفاده از الگوریتم های ژنتیک توسعه داده شد [۲۳].

در این مقاله سعی شده است از الگوریتم ژنتیک به عنوان انتخاب مولفه برای انتخاب ویژگی بهینه استفاده شود. استفاده از اطلاعات موثر در تولید، برای پیش بینی بار است. با توجه به اینکه داده های پایگاه داده، حجم بالایی از داده ها را دارا میباشند، در این مقاله از ویژگی هایی استفاده میشود که در پیش بینی بار، نقش موثری دارند. الگوریتم استفاده شده در این مقاله به صورت زیر میباشد که در شکل زیر نشان داده شده است.

یک عدد نیست و یک برد است، مانند دمای هوا، میزان بارش و غیره، اگر از شبکه عصبی معمولی استفاده شود نتایج خوبی حاصل نخواهد شد و میزان خطا بسیار زیاد خواهد بود. اما اگر از شبکه عصبی مبتنی بر نرونها راف استفاده شود این گونه مسائل قابل حل خواهد بود. یک نرون راف r یک زوج مرتب به صورت (r, \bar{r}) میباشد، به طوری که (\bar{r}) کرانه بالا و دیگری (r) کرانه پایین میباشد. یک نرون راف به نرون راف دیگر، از طریق دو یا چهار یال، متصل است. شکل ۲ سه نوع مختلف اتصال دو نرون راف را نشان میدهد. در شکل ۲ (الف) نرون r فعالیت نرون s را تعدیل میکند. حال اگر نرون r باعث تحریک نرون s گردد، شکل آن مانند شکل ۲ (ب) خواهد بود. آخرین نوع، مانند آنچه که در شکل ۲ (ج) آورده شده است، نوع اتصال کامل است، به طوری که شبکه، شامل اتصالات تحریک و تعدیلکننده است.



شکل ۲: سه نوع اتصال مختلف بین دو نرون راف، (الف) اتصال تعدیلکننده، (ب) اتصال تحریککننده، (ج) اتصال کامل


گرایان نزولی در آموزش انواع شبکههای عصبی پیشرو، روشی فراگیر و موفق بوده است با این حال دارای محدودیتهایی نظیر کمینه محلی است. در این مقاله به منظور بهبود شبکه عصبی راف از الگوریتم جهش ملخ استفاده شده است. از آنجا که اغلب سیستمهای واقعی از جمله سیستمهای بار مصرفی با عدم قطعیتهای زیادی مواجه هستند، شبکههای عصبی معمول، قادر به تقریب کامل آنها نبوده و اغلب عملکرد سیستم در مواجهه با اغتشاش، مطلوب نیست. برای رفع این مشکلات از شبکههای عصبی راف که یکی از شبکه عصبی مقاوم در برابر عدم قطعیت میباشد، استفاده میشود. تفاوت اصلی این شبکهها با شبکههای عصبی چندلایه در ساختار نرونها و وزنها ارتباطی بینها است. در این شبکهها به جای وزنها و نرونها قطعی از وزنها و نرونها بازهای استفاده میشود به این صورت که برای نرون ها و وزنها، حد بالا و پایین تعریف میشود و این روند برای تمامی لایه ها قابل اجرا است. بازهای بودن وزنها و نرونها با پوشش دادن عدم قطعیت موجود در مدل سیستم و دادههای ورودی میتواند مقاومت سیستم را در برابر نویز و اغتشاشات ورودی تا حد زیادی افزایش دهد [۱۴].

یک شبکه عصبی راف از نرونها معمولی و نرونها راف که به هم متصل شدهاند تشکیل یافته است. زمانی که ورودی یک شبکه عصبی

گروه ها از تمام موجودات قرار دارند. اندازه گروه ها ممکن است در مقیاس خیلی بزرگ و یک کابوس برای کشاورزان باشد. ملخهای بالدار مهاجر آسیایی آفریقایی از خانواده ملخ های جهنده صدادار هستند. آنها در گروههای بزرگ زندگی می کنند. بزرگترین گروه ملخ ها که تا کنون ثبت شده، در سال ۱۸۷۵ در نبراسکا دیده شده، که در حدود بیش از ۱۱ هزارمیلیارد ملخ بالدار در کنار هم وجود داشته است. جنبه منحصر به فرد ازدحام ملخ ها این است که رفتار گروهی، هم در بین ملخ های پوره (نوزاد حشرات بدون دگردیسی را که از نظر شکل شبیه والدین بوده و تنها از نظر جثه کوچک ترند) و هم در بین ملخ های بزرگسال و بالغ دیده می شود. میلیون ها ملخ پوره می پرند و همانند میله سیلندر حرکت می کنند. در مسیر خود، تقریباً همه پوشش گیاهی را می خورند و بعد از این رفتار، زمانی که این ملخ ها بالغ می شوند، گروهی را در هوا تشکیل می دهند. این چگونگی مهاجرت ملخ ها در مسافت های بزرگ است.

مشخصه و ویژگی اصلی گروه در مرحله لارو (به نوزاد کرمی شکل حیواناتی که دگردیسی کامل دارند مانند حشرات و دوزیستان، لارو گفته می شود) حرکت آرام و گام های کوچک ملخ ها می باشد. در مقابل حرکت های

شبکه عصبی راف در پیش بینی بارهای کوتاه مدت کاربرد زیادی دارد، از جمله مقاله [۱۴] که نشان می دهد شبکه عصبی راف ابزار مناسبی برای پیش بینی بارهای کوتاه مدت به شمار می رود.



شکل ۳: ساختار نرون راف

۲-۲. الگوریتم بهینه سازی ملخ GOA⁵ [۲۴]

ملخ از خانواده حشرات می باشد. آنها به عنوان آفت شناخته می شوند چرا که موجب آسیب زدن به محصولات کشاورزی می باشند. چرخه زندگی ملخ در شکل ۴ نشان داده شده است.



شکل ۴: سیر تکاملی ملخ

اگرچه ملخ معمولاً در طبیعت بصورت تکی و جداگانه دیده می شود، آنها در یکی از بزرگترین

ایجاد رفتار تصادفی می توان رابطه فوق را بصورت ۲ بازنویسی کرد.

$$X_i = r_1 S_i + r_2 G_i + r_3 A_i \quad (2)$$

که در آن r_1 و r_2 و r_3 اعدادی تصادفی در بازه $[0,1]$ می باشند. مقدار S_i یعنی تعامل اجتماعی برای ملخ i ام با توجه به رابطه زیر محاسبه می شود:

$$S_i = \sum_{j=1}^N s(d_{ij}) \widehat{d}_{ij} \quad (3)$$

که در آن d_{ij} فاصله بین ملخ i ام با ملخ j ام را نشان می دهد و به صورت $d_{ij} = |x_j - x_i|$ محاسبه می شود. S یک تابع برای تعریف فشار نیروی اجتماعی می باشد. همانطور که در رابطه ۳ نشان داده شده است و $\widehat{d}_{ij} = \frac{x_j - x_i}{d_{ij}}$ یک بردار واحد از i امین ملخ به j امین ملخ می باشد. تابع S ، که نیروی اجتماعی را تعریف می کند، همانند زیر محاسبه می شود:


$$S(r) = f e^{\frac{-r}{l}} - e^{-r} \quad (4)$$

که در آن f نشان دهنده شدت جاذبه و l نشان دهنده طول مقیاس جاذبه می باشد. تابع S در شکل ۵ نشان داده شده است تا چگونگی تاثیر بر روی تعامل اجتماعی (جاذبه و دافعه) ملخ ها را نشان دهد.

ناگهانی و بلند از ویژگی های اسای گروه در بزرگسالی می باشد. جستجوی منبع غذا یکی دیگر از ویژگی های مهم توده ملخ ها می باشد. همانطور که در مقدمه بحث شد، الگوریتم های الهام گرفته شده از طبیعت بصورت منطقی، فرایند جستجو را به دو بخش تقسیم می کنند: اکتشاف و بهره برداری. در اکتشاف، عامل های جستجو تشویق به حرکت های تصادفی می شوند، در حالی که در مرحله بهره برداری، آنها تمایل به حرکت های محلی در اطراف مکان خود دارند. این دو عمل و همچنین جستجوی هدف، به طور طبیعی توسط ملخ انجام می گیرد. بنابراین، اگر ما روشی برای مدل کردن ریاضی این رفتار پیدا کنیم، می توانیم یک الگوریتم الهام گرفته از طبیعت جدید را طراحی کنیم. مدل ریاضی به کار گرفته شده برای شبیه سازی رفتار ملخ ها به شکل زیر می باشد:

$$X_i = S_i + G_i + A_i \quad (1)$$


که در آن X_i موقعیت i امین ملخ را مشخص میکند، S_i تعامل اجتماعی و G_i نیروی گرانش اعمال شده به ملخ i ام می باشد و A_i جهت باد را نمایش می دهد. توجه داشته باشید که به منظور



شکل ۵: تعامل اجتماعی (جاذبه و دافعه) ملخ ها

۲.۰۷۹ تا نزدیک ۴ افزایش می یابد و سپس به تدریج کاهش می یابد. تغییر پارامترهای l و f در رابطه ۴ منجر به رفتارهای اجتماعی مختلف در ملخ های مصنوعی خواهد شد. به منظور مشاهده تاثیر این دو پارامتر، تابع S در شکل ۶ با مقادیر مختلف l و f ترسیم شده است.

در این شکل ممکن است متوجه شده باشید که در فاصله ۰ تا ۱۵ که در نظر گرفته شده است، دافعه در بازه $[0, 2.079]$ رخ داده است [۲۴]. هنگامی که یک ملخ در فاصله ۲.۰۷۹ از ملخ دیگر است نه جاذبه و نه دافعه ای وجود ندارد. که به آن منطقه یا فاصله راحتی یا آسایش گفته میشود. همچنین شکل ۵ نشان می دهد که جاذبه از فاصله



شکل ۶: تابع S با مقادیر مختلف l و f

آنها زیاد است را اعمال کند. برای حل این مشکل، ما فاصله بین دو ملخ را به بازه [1,4] نگاشت میکنیم. شکل تابع S در این بازه در شکل ۵ نشان داده شده است. مولفه G در رابطه ۲ به صورت زیر محاسبه می شود:

$$G_i = -g\hat{e}_g \quad (5)$$

که g ثابت گرانشی و \hat{e}_g بردار واحد به سمت مرکز زمین می باشد. مولفه A در معادله ۲ به صورت زیر محاسبه می شود.

$$A_i = u\hat{e}_w \quad (6)$$

که u ثابت رانش و \hat{e}_w بردار واحد در جهت باد می باشد. ملخ های پوره بال ندارند، بنابراین حرکت آنها به شدت به جهت وزش باد بستگی دارد. جایگزینی S و G و A در رابطه ۲ را می توان بصورت زیر گسترش داد:


$$X_i = \sum_{j=1, j \neq i}^N s(|X_j - X_i|) \frac{X_j - X_i}{d_{ij}} - g\hat{e}_g + u\hat{e}_w \quad (7)$$

که در آن $s(r) = fe^{-r} - e^{-r}$ و N تعداد ملخ ها می باشد.

تعداد متغیرها برای بهینه سازی دو برابر تعداد نرون ها و مقادیر بایاس لایه ها می باشد که در مجموع ۳۰ متغیر بهینه شده برای وزن های شبکه عصبی راف محاسبه شده است.

این شکل نشان میدهد که پارامترهای l و f منطقه راحتی و جاذبه و دافعه را بطور قابل توجهی تغییر می دهد. باید توجه کرد که مناطق جاذبه یا دافعه برای برخی مقادیر خیلی کوچک هستند (بعنوان مثال l=1 و f=1). از بین همه این مقادیر که در شکل دیده می شود ما مقادیر l=1.5 و f=0.5 را انتخاب کرده ایم.

یک مدل مفهومی از تراکنش های بین ملخ ها و منطقه راحتی با استفاده از تابع S در شکل ۷ نشان داده شده است.



شکل ۷: یک مدل مفهومی از تراکنش های بین ملخ ها و منطقه راحتی

لازم به ذکر است که در فرم ساده شده، این تعامل اجتماعی در برخی مدل های ازدحام ملخ ها بعنوان نیروی محرکه در نظر گرفته می شود. اگرچه تابع s قادر است تا فضای بین دو ملخ را به نواحی دافعه و جاذبه و آسایش تقسیم کند، این تابع، مقادیر نزدیک به صفر با فاصله بیشتر از ۱۰ همانند آنچه در شکل ۵ و ۶ نشان داده شده است را برمیگرداند. بنابراین، این تابع قادر نیست تا نیروی شدیدی را بین دو ملخ که فاصله بین

در جدول شماره ۱، پارامترهای مورد استفاده برای الگوریتم جهش ملخ آورده شده است که پارامترهای مذکور بر اساس صحیح و خطا و آزمایش بدست آمده اند.

جدول ۱: توضیحات استخراج شده برای الگوریتم جهش ملخ

متغیرها	مشخصات الگوریتم جهش ملخ
متلب	نرم افزار مورد استفاده
۱۰۰۰	تعداد ملخ
1.5	(مقیاس طول جاذبه) l
0.5	(شدت جاذبه) f
$1e^{-4}$	C_{min}
1	C_{max}
0.2	r
۳۰ دقیقه	مدت زمان
دو هسته ای	CPU
۵۰	تعداد تکرار
۲	تعداد لایه های شبکه عصبی راف
۱۴	تعداد نرون لایه میانی
۳۰	تعداد متغیرهای بهینه الگوریتم ملخ

به منظور بهینه سازی ضرایب وزن های شبکه عصبی راف از الگوریتم جهش ملخ استفاده شده است (شکل ۸). بهینه سازی به کمک تعیین تابع هزینه ای که مجموع خطاهای آموزش را شامل می شود تعیین شده است. تابع هزینه اختلاف مقدار خروجی داده های آموزش از مقادیر تخمین زده شده به کمک شبکه عصبی راف بدست آمده است. بهینه سازی صورت گرفته شده در نرم افزار متلب می باشد.

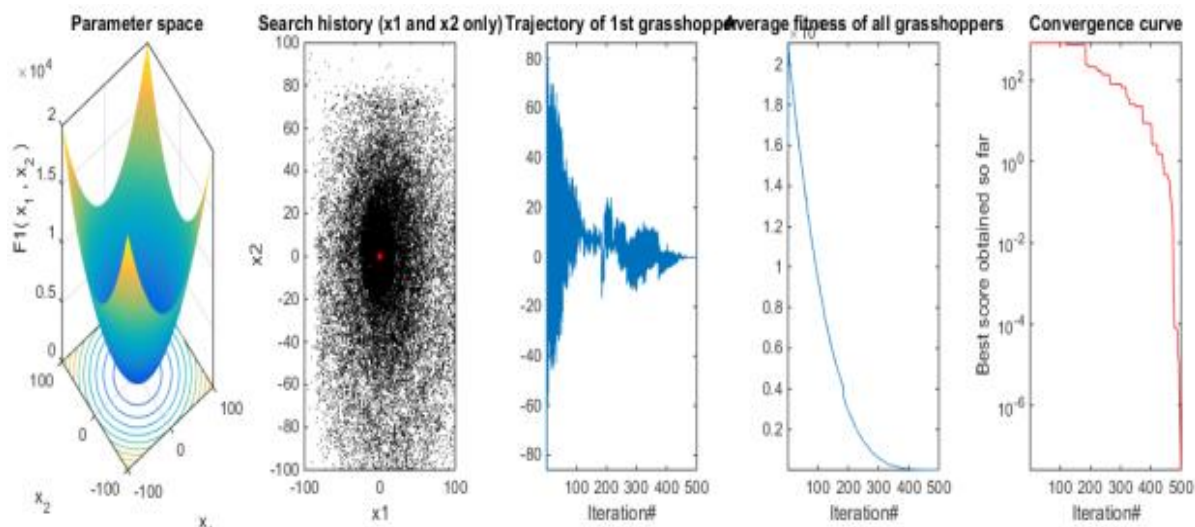
در شکل ۸-الف، شبه کد مربوط به الگوریتم بهینه سازی جهش ملخ آورده شده است. نمودار همگرایی یک تابع معیار نیز در شکل ۸-ب قابل مشاهده است. همان طور که مشاهده می شود این الگوریتم در بهینه های محلی گیر نمی کند و کارایی مناسبی را در یافتن اکستریم سراسری، ارائه می دهد.

```

Initialize the swarm  $X_i$  ( $i = 1, 2, \dots, n$ )
Initialize  $c_{max}$ ,  $c_{min}$ , and maximum number of iterations
Calculate the fitness of each search agent
 $T$  = the best search agent
while ( $l < \text{Max number of iterations}$ )
    Update  $c$ 
    for each search agent
        Normalize the distances between grasshoppers
        Update the position of the current search agent
        Bring the current search agent back if it goes outside the boundaries
    end for
    Update  $T$  if there is a better solution
     $l = l + 1$ 
end while
Return  $T$ 


```

شکل ۸-الف: شبه کد الگوریتم بهینه سازی جهش ملخ



شکل ۸-ب: هزینه ی میانگین و مینیمم همه ی جواب ها بر حسب تکرار الگوریتم

دسامبر از واحد SCADA به صورت ساعتی استخراج شده است که در شکل های ۹ تا ۱۳ پارامترهای مورد نیاز این مقاله استخراج شده است.




شکل ۹: توان مصرفی شبکه دبی [۲۲]

شکل های ۹ تا ۱۳ به عنوان ورودی های شبکه هوشمند در نظر گرفته می شود که توانایی تشخیص را برای پیش بینی بار ایجاد می نماید.


روش پیشنهادی، آموزش شبکه عصبی راف به کمک الگوریتم جهش ملخ می باشد. با کمک الگوریتم جهش ملخ، تابع هزینه پیشنهادی که برابر است با مجموع خطای داده های آموزش به ازای ضرایب مختلف وزن های شبکه عصبی راف که الگوریتم ملخ پیشنهاد می دهد، کمینه شده و الگوریتم جهش ملخ می تواند شبکه عصبی راف را که با الگوریتم بازگشت به عقب آموزش می بیند، بهبود دهد. الگوریتم جهش ملخ کمک می نماید که آموزش شبکه عصبی راف در نقاط بهینه محلی، کمتر قرار گیرد.

۳. شبیه سازی


داده های مورد نیاز شبیه سازی از مرجع [۲۲] اخذ شده اند. داده ها مربوط به شهر دبی از کشور امارات می باشد که در بازه اول ژانویه تا ۳۱



شکل ۱۳: شاخص GHI برحسب زمان



شکل ۱۰: دما برحسب زمان [۲۲]




شکل ۱۱: سرعت باد برحسب زمان [۲۲]

به منظور آماده سازی داده ها برای شبکه های هوشمند داده ها، در ابتدا پیش پردازش با حذف داده های NULL و حذف داده های پرت انجام می شود. برای پیاده سازی در متلب جدول ورودی را به عنوان یک ماتریس در نظر می گیریم که ستونها به جز ستون آخر ویژگی ها می باشند و ستون آخر مربوط به مقدار بار می باشند.

در شبیه سازی برای داده های مقاله [۲۲] نکته مهمی که مشاهده می شود این است که زمان بار پیک و بار سبک هر روز کاملاً درست پیش بینی شده اند. اما خطای نسبتاً محسوس در بعضی از روزها برای میزان بار مشاهده می شود. به عنوان پارامترهای ورودی در شبکه عصبی که به پیش بینی بار می پردازیم، پارامترهای اولیه برای شبکه عصبی راف به صورت جدول ۲ می باشد. قابل ذکر است این پارامترها بر اساس صحیح و خطا و آزمایش و با توجه به دیتاست بدست آمده اند.


جدول ۲: پارامترهای شبکه عصبی تحت آموزش

پارامترهای شبکه عصبی راف	مقادیر
تعداد نرون	۵
تعداد متغیر وزن در لایه اول	۶
تعداد متغیر وزن در لایه خروجی	۶
Eta	۰/۰۱
B ₂	۱
B ₁	۱




شکل ۱۲: رطوبت برحسب زمان


در این مرحله نمونه ها به دو دسته، تست و آموزش تقسیم می شوند (جدول شماره ۳) و برای



شکل ۱۴-الف: FCM clustering ANFIS with backpropagation



شکل ۱۴-ب: FCM clustering ANFIS with Gradient Descent



شکل ۱۴-پ: Subtractive clustering ANFIS with Gradient Descent

کارایی شبکه عصبی راف و جهش ملخ استفاده می شود. قابل ذکر است از ۸۰ درصد کل داده‌ها به منظور آموزش شبکه عصبی استفاده شده است که این موضوع در جدول ۳ قابل ملاحظه است.



جدول ۳: داده های هرکلاس برای آموزش و تست

تعداد	کلاس های مختلف
۱۷۰۰۰	کل داده
۴۰۰۰	داده تست
۱۳۰۰۰	داده آموزش

۴. ارزیابی روش پیشنهادی و نتیجه گیری


به منظور ارزیابی کارایی الگوریتم پیشنهادی با شبکه عصبی با آموزش بازگشت به عقب و شبکه فازی عصبی GRID PARTITION و SUBTRACTIVE CLUSTERING , FCM شبکه عصبی راف با آموزش بازگشت به عقب مقایسه شده است. در ابتدا روش های فازی عصبی با یکدیگر مقایسه شده است و بهترین شبکه فازی عصبی، روش GRID PARTITION به کمک آموزش بازگشت به عقب می باشد (شکل ۱۴).

کارایی مطلوب تری در پیش بینی بازار از خود نشان داده است (شکل ۱۵).




شکل ۱۵: پیش بینی بار به کمک شبکه عصبی چند لایه و شبکه عصبی راف


الگوریتم پیشنهادی آموزش شبکه عصبی راف با کمک الگوریتم جهش ملخ می باشد که در شکل ۱۶ نشان داده شده است.



شکل ۱۴-ت: Subtractive clustering ANFIS with backpropagation



شکل ۱۴-ث: GridPartition ANFIS with Gradient Descent



شکل ۱۴-ج: GridPartition ANFIS with backpropagation

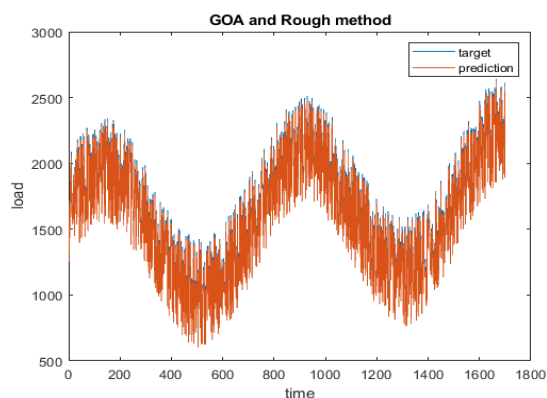
شبکه عصبی راف و شبکه عصبی MLP با یکدیگر در شکل ۱۵ مقایسه شده است. شبکه عصبی راف نسبت به شبکه عصبی چند لایه،

۰/۴۶	۳۰۹	۱/۶۱۳۷	Anfis FCM-BP
۰/۴۷	۳۰۹	۱/۶۱۳۷	Anfis SC-DG
۰/۴۷	۳۰۸	۱/۶۱۳۷	Anfis SC-BP
۰/۴۶	۳۰۶	۱/۶۱۳۷	Anfis GP-BP
۰/۴۶	۳۰۶	۱/۶۱۳۷	Anfis GP-DG
۲/۲۷	۷۷۰	۵/۹۴	Nn BP
۲/۳۲	۲۰۵	۰/۳۲۲	Rough BP
۲/۳	۲۰۴	۰/۲۵۸	Goa-rough GOA

با استفاده از الگوریتم جهش ملخ در این مقاله توانسته ایم نتایج را به میزان ۵ درصد نسبت به مقاله شبکه عصبی راف (مرجع ۱۴) بهبود ببخشیم که بر اساس شاخص های ارزیابی Mse و rmsa و R2 قابل مشاهده است.

۵. نتیجه گیری

پیش بینی بار یک فرایند مرکزی و جامع در برنامه ریزی و بهره برداری صنعت برق بوده است. روش های زیادی در دو دهه اخیر برای به حل بهینه این مسئله پیشنهاد شده اند. در این مقاله با استفاده از مرجع [۲۲]، کیس استادی استخراج می شود. در ابتدا داده های پرت و نویزی به کمک الگوریتم های پیش پردازش بهبود داده می شود. سپس به کمک الگوریتم ژنتیک، ویژگی های بهینه استخراج می شود. به منظور پیش بینی سری زمانی بار کوتاه مدت از الگوریتم های شبکه عصبی، شبکه عصبی راف، شبکه عصبی راف



شکل ۱۶: پیش بینی بار به کمک شبکه عصبی راف و الگوریتم جهش ملخ

معیارهای ارزیابی دقت و پیش بینی خروجی است که تفاوت آن ها نسبت به خطای پیش بینی مشخص شده است. معیارهای ارزیابی RMSE و MSE و r^2 می باشد که برای روش های بیان شده محاسبه گردیده و با روش پیشنهادی مقایسه شده است (جدول ۴)

جدول ۴: مقایسه روش های پیش بینی

R ₂	rmsa	Mse	روش آموزش
۰/۴۷	۳۰۸	۱/۶۱۳۷	Anfis FCM-DG

عصبی راف به کمک الگوریتم ملخ توانسته است خطای پیش بینی را تا میزان زیادی نسبت به شبکه فازی عصبی بهبود دهد و الگوریتم جهش ملخ شبکه عصبی راف را نسبت به آموزش بازگشت به عقب تا حد قابل ملاحظه ای بهبود داده است.

بهینه شده با GOA انجام شده است. با استفاده از انواع شبکه عصبی می توان با دقت خوبی منحنی بار روزانه را پیش بینی کرد. ابتدا الگوی بار روزهای سال جاری یا آینده با استفاده از شبکه عصبی پرسپترون و فازی عصبی و راف بر اساس اطلاعات سالهای گذشته مشخص می کنیم. شبکه

مراجع (Reference):

- [1] G. Gross and F. D. Galiana, "Short-term load forecasting," *Proceedings of the IEEE*, vol. 75, pp. 1558-1573, 1987.
- [2] H. S. Hippert, C. E. Pedreira, and R. C. Souza, "Neural networks for short-term load forecasting: A review and evaluation," *IEEE Transactions on power systems*, vol. 16, pp. 44-55, 2001.
- [3] C.-N. Lu, H.-T. Wu, and S. Vemuri, "Neural network based short term load forecasting," *IEEE Transactions on Power Systems*, vol. 8, pp. 336-342, 1993.
- [4] T. Peng, N. Hubele, and G. Karady, "Advancement in the application of neural networks for short-term load forecasting," *IEEE Transactions on Power Systems*, vol. 7, pp. 250-257, 1992.
- [5] I. Moghram and S. Rahman, "Analysis and evaluation of five short-term load forecasting techniques," *IEEE Transactions on power systems*, vol. 4, pp. 1484-1491, 1989.
- [6] K. Lee, Y. Cha, and J. Park, "Short-term load forecasting using an artificial neural network," *IEEE Transactions on Power Systems*, vol. 7, pp. 124-132, 1992.
- [7] A. Bakirtzis, V. Petridis, S. Kiartzis, M. Alexiadis, and A. Maissis, "A

neural network short term load forecasting model for the Greek power system," *IEEE Transactions on power systems*, vol. 11, pp. 858-863, 1996.

[8] W. Christiaanse, "Short-term load forecasting using general exponential smoothing," *IEEE Transactions on Power Apparatus and Systems*, pp. 900-911, 1971.

[9] H. Mori and H. Kobayashi, "Optimal fuzzy inference for short-term load forecasting," in *Power Industry Computer Application Conference, 1995. Conference Proceedings.*, 1995 IEEE, 1995, pp. 312-318.

[10] G. Zhu, T.-T. Chow, and N. Tse, "Short-term load forecasting coupled with weather profile generation methodology," *Building Services Engineering Research and Technology*, vol. 39, pp. 310-327, 2018.

[11] H. Jiang, Y. Zhang, E. Muljadi, J. J. Zhang, and D. W. Gao, "A short-term and high-resolution distribution system load forecasting approach using support vector regression with hybrid parameters optimization," *IEEE Transactions on Smart Grid*, vol. 9, pp. 3341-3350, 2018.

[12] W. Kong, Z. Y. Dong, D. J. Hill, F. Luo, and Y. Xu, "Short-term

residential load forecasting based on resident behaviour learning,” IEEE Transactions on Power Systems, vol. 33, pp. 1087-1088, 2018.

[13] S. S. Pal and S. Kar, “Time series forecasting for stock market prediction through data discretization by fuzzistics and rule generation by rough set theory,” Mathematics and Computers in Simulation, 2019.

[14] T. Zhang, D. Liu, and D. Yue, “Rough neuron based rbf neural networks for short-term load forecasting,” in Energy Internet (ICEI), IEEE International Conference on, 2017, pp. 291-295.

[15] P. Jiang, F. Liu, and Y. Song, “A hybrid forecasting model based on date-framework strategy and improved feature selection technology for short-term load forecasting,” Energy, vol. 119, pp. 694-709, 2017.

[16] G. Zhu, T.-T. Chow, and N. Tse, “Short-term load forecasting coupled with weather profile generation methodology,” Building Services Engineering Research and Technology, vol. 39, pp. 310-327, 2018.

[17] S. Arora and J. Taylor, “Short-term Load Forecasting for Special Days Using Rule-based Models: A Case Study for France,” European Journal of Operational Research, 2018.

[18] N. Zeng, H. Zhang, W. Liu, J. Liang, and F. E. Alsaadi, “A switching delayed PSO optimized extreme learning machine for short-term load forecasting,”

Neurocomputing, vol. 240, pp. 175-182, 2017.

[19] X. Sun, Z. Ouyang, and D. Yue, “Short-term load forecasting model based on multi-label and BPNN,” in Advanced Computational Methods in Life System Modeling and Simulation, ed: Springer, 2017, pp. 263-272.

[20] Y. Liang, D. Niu, and W.-C. Hong, “Short term load forecasting based on feature extraction and improved general regression neural network model,” Energy, vol. 166, pp. 653-663, 2019.

[21] T.-H. Dang-Ha, F. M. Bianchi, and R. Olsson, “Local short term electricity load forecasting: Automatic approaches,” arXiv preprint arXiv:1702.08025, 2017.

[22] L. Friedrich and A. Afshari, “Short-term forecasting of the Abu Dhabi electricity load using multiple weather variables,” Energy Procedia, vol. 75, pp. 3014-3026, 2015.

[23] O. Ludwig and U. Nunes; “Novel Maximum-Margin Training Algorithms for Supervised Neural Networks,” IEEE Transactions on Neural Networks, vol.21, issue 6, pp. 972-984, Jun. 2010

[24] S. Saremi, S. Mirjalili, and A. Lewis, “Grasshopper optimisation algorithm: theory and application,” Advances in Engineering Software, vol. 105, pp. 30-47, 2017.