

پیشبینی کوتاه مدت بار بر مبنای شبکه های عصبی بهبود یافته و الگوریتم زنبور عسل

کامران حسن پوری باعصمت^{۱*}، دانیال بختیاری^۲

۱- شرکت مهندسی قدس نیرو، تهران، ایران

۲- شرکت سنگ آهن گهر زمین، سیرجان، ایران

خلاصه

خطاها یا اختلافات در تقاضای پیش‌بینی بار نسبت به تغذیه‌ها می‌تواند به جریمه‌های سنگین قیمت و یا از دست رفتن فرصت‌های مالی منجر شود. پیش‌بینی بار به عنوان ابزاری کارآمد در کاهش خطاهای پیش‌بینی و کاهش جریمه‌های قیمت توسط بهره‌برداران مورد استفاده قرار می‌گیرد. در این مقاله روشی ترکیبی مبتنی بر روش‌های شبکه عصبی و کلونی زنبور عسل برای پیش‌بینی بار کوتاه مدت ارائه شده است. از الگوریتم کلونی زنبور عسل به منظور بهینه‌سازی رویه یادگیری شبکه عصبی استفاده خواهد شد. وزن‌های بهینه شده به روشی بازگشتی با به کارگیری روش بهینه‌سازی کلونی زنبور عسل به دست آمده که از الگوریتم کلونی زنبور عسل برای جستجوی بهترین پارامترهای آموزش استفاده می‌شود. هدف از این مقاله ارتقای دقت پیش‌بینی بار با به کارگیری بهینه‌سازی داخلی و قابلیت بالای همگرایی کلونی زنبور عسل بوده است شبکه عصبی با استفاده از الگوریتم بهینه‌سازی کلونی زنبور عسل آموزش داده شده است تا وزن‌های اتصالات نوروها به دست آید.

روشی مبتنی بر استفاده از شبکه عصبی و کلونی زنبور عسل برای پیش‌بینی بار کوتاه مدت در شبکه استان کرمانشاه با لحاظ کردن میزان مصرف روزها در گذشته و عوامل آب و هوایی مانند وزش باد، دما ارائه گردید. نتایج پیاده‌سازی روش پیشنهادی در متلب نشان داد که استفاده از روش الگوریتم کلونی زنبور عسل و شبکه عصبی از دقت مطلوبی برخوردار بوده است به طوری که انحراف پیش‌بینی بار در بدترین شرایط به عدد یک رسید و در بیشتر موارد در زیر یک بود که حد قابل قبولی می‌باشد. به طور کلی نتایج شبیه‌سازی حاکی از کارایی روش پیشنهادی داشته است.

کلمات کلیدی: الگوریتم کلونی زنبور عسل، شبکه عصبی، پیش‌بینی بار

* Corresponding author: Ghods Niroy Engineering Company (GNEC)

Email: kamran.baesmat@gmail.com

۱. مقدمه

سیستم قدرت الکتریکی شامل تعداد زیادی عناصر به هم پیوسته است که در یک منطقه جغرافیایی وسیع جهت تولید و تغذیه قدرت الکتریکی به نقاط مختلف در حال کار می‌باشند. عموماً تجهیزات تولید فقط در چند نیروگاه بزرگ متمرکز شده‌اند. سیستم توزیع قدرت از تجهیزات گوناگون زیادی تشکیل شده است که در تمام مناطق خدماتی بار توزیع قدرت را بر عهده دارند. هر واحد سیستم توزیع باید به طور مناسبی جا یابی شود تا تقاضای حومه را نیز پاسخگو باشد. طراحی آتی سیستم عبارتست از تعیین ظرفیت و مکان تجهیزات از قبیل پست‌ها، خطوط انتقال تغذیه کننده آنها، فیدرهایی که قدرت را از پست‌ها به تمامی مناطق خدماتی راهبری می‌کنند و هزاران وسیله دیگر که توانایی توزیع را تکمیل می‌نمایند [۱،۲]. اولین گام در طراحی، پیش بینی تقاضای بار الکتریکی آتی و نیز جزئیات جغرافیایی است به گونه ای که بتوان اندازه و مکان تجهیزات را طراحی نمود. نکته مهم در طراحی سیستم قدرت، حصول گسترش منظم و اقتصادی است که نیاز آتی عامه را با در نظر گرفتن قابلیت اطمینان مناسب برآورده سازد. عناصر سیستم تغذیه یعنی خطوط انتقال فرعی، پست‌ها و فیدرهای توزیع عموماً دارای ظرفیت‌هایی هستند که چندین مرتبه کوچک تر از بار کل سیستم می‌باشند. طراحی چنین سیستمی عبارتست از تعیین اندازه‌های صحیح، مکان‌های مناسب، اتصالات پیوسته و زمان‌بندی جهت اضافه کردن تجهیزات در آینده. طراحی صحیح تجهیزات توزیع برای آینده به پیش بینی توزیع جغرافیایی تقاضای الکتریکی در آینده نیازمند است به طوری که تمایز بین ظرفیت‌های ممکنه، مکان‌ها و اتصالات قابل تغییر باشند. کیفیت و دقت این پیش بینی تأثیر زیادی بر کیفیت طراحی سیستم تغذیه بعدی دارد. بنابراین روش‌های انجام چنین پیش‌بینی‌هایی موضوعی است که طی چندین ساله اخیر مورد توجه زیادی قرار گرفته است. طی دهه اخیر چندین روش کامپیوتری عملی و به حد کافی اتوماتیک برای استفاده در طراحی سیستم تغذیه ارائه شده است. در بسیاری از این روش‌ها، برای بهبود طراحی سیستم و تعیین یک طرح توسعه با هزینه کمینه از بهینه سازی استفاده گردیده است. با توجه به اهمیت روزافزون پیش‌بینی بار در بهره‌برداری سیستم‌های قدرت و بازار برق، روش‌هایی به منظور پیش‌بینی دقیق‌تر بار ارائه شده است و در این میان روش‌هایی که بر اساس دید کارشناسانه و از منظر افراد خبره ارائه می‌شوند، توانایی بالاتری از خود نشان می‌دهند [۳].

در این مقاله روشی مبتنی بر استفاده از الگوریتم کلونی زنبور عسل برای پیش‌بینی بار کوتاه مدت در سیستم قدرت با لحاظ کردن میزان مصرف روزها در گذشته و عوامل آب و هوایی ارائه خواهد شد. هدف آن است با استفاده از روش پیشنهادی دقت پیش‌بینی بار را ارتقا دهیم. روش پیشنهادی در محیط نرم افزار Matlab پیاده سازی خواهد شد.

۲. مروری بر مقالات و کارهای گذشته

در [۵] روشی جدید برای پیش‌بینی بار ارائه گردیده است، در این روش مدل‌های سری‌های زمانی و پیش‌بینی تطبیق منحنی برای پیش‌بینی ساعتی بار برای روزهای هفته استفاده شده است. تکنیک پیش‌بینی منحنی تطبیق (CFP) به صورت ترکیبی با الگوریتم‌های ژنتیک برای به دست آوردن پارامترهای بهینه مدل گوسی در راستای رسیدن به خطای مینیمم بین بار پیش‌بینی شده و واقعی استفاده شده است. مدل پیشنهادی ساده، سریع و دقیق است. در این مقاله نشان داده شده است که روش پیشنهادی با ارائه نتایجی دقیق با خطای کمتر از ۱ درصد روشی مناسب است.

در [۶] روش پیشرفته‌ی شبکه‌های عصبی برای مواجهه‌ی موفقیت‌آمیز با مشکل پیش‌بینی بار کوتاه مدت ارائه گردیده است. روش‌های متعددی شامل رمزگذاری گوسی انتشار پستی (BP)، فعال کردن تصادفی پنجره، شبکه‌های تابع اساسی

شعاعی، شبکه‌های عصبی بازگشت‌پذیر زمان حقیقی و تغییرات آن‌ها در این مقاله ارائه و مقایسه گردیده است. عملکرد هر ساختار پیشنهادی با استفاده از مطالعات شبیه‌سازی، و استفاده از اطلاعات بار ساعتی از سیستم قدرت در یونان، ارزیابی شده است. نتایج آماری خطای پیش‌بینی متناظر با سری‌های زمانی بار مینیمم و ماکزیمم در این مقاله نشان داده‌اند که مدل‌های پیش‌بینی بار پیشنهادی، روش‌هایی دقیق نسبت به مدل‌های سنتی هستند. در نهایت، یک روش پردازش موازی برای ۲۴ ساعت پیش‌رو ارائه گردیده است. مزیت روش‌های پیشنهادی این مقاله دقت بیش‌تر بدون نیاز به پیچیدگی بیش از حد است.

در [۷] روش‌های شبکه عصبی و مدل‌سازی رگرسیون برای پیش‌بینی بار استفاده شده است. روشی برای پیش‌بینی روزی خاص برای شرکت‌های برق با استفاده از اطلاعات گذشته ارائه گردیده است. بنابراین، روشی اصلاحی مبتنی بر شبکه عصبی به صورت ترکیبی با روش رگرسیون بر شبکه الکتریکی KSA به صورت وابسته با اطلاعات گذشته برای پیش‌بینی تقاضای بار تا سال ۲۰۲۰ ارائه گردیده است. این تکنیک با برون‌یابی منحنی‌های روند به عنوان روشی سنتی (مدل‌های رگرسیون خطی) مقایسه شده است. نتایج برنامه نشان داده است که روش پیشنهادی کارآمد و ساده است.

در [۸] پیش‌بینی بار با استفاده از اطلاعات ورودی وابسته به پارامترهایی نظیر بار ساعت جاری و دو ساعت قبل، دمای ساعت جاری و دو ساعت قبل، وزش باد ساعت جاری و دو ساعت قبل ارائه گردیده است. پیش‌بینی تقاضای بار برای ساعت آینده مبتنی بر پارامترهای ورودی در آن ساعت است. در این مقاله، از روش رگرسیون چندپارامتری برای پیش‌بینی استفاده شده است که خطا در محدوده قابل قبولی است. الگوریتم‌های پیاده‌سازی کننده این تکنیک‌های پیش‌بینی با استفاده از Matlab پیاده‌سازی شده است و بر مورد مطالعاتی اعمال گردیده است.

در [۹] پیش‌بینی بار را برای ارتقای قابلیت اطمینان شبکه اطلاعات خطوط توان متناوب ضروری دانسته و زمان‌بندی بار بهینه در سیستم خانگی هوشمند را ارائه کرده است. در این مقاله، پیش‌بینی بار کوتاه مدت با استفاده از شبکه فازی عصبی و الگوریتم ژنتیک اصلاح شده، پیشنهاد شده است. این روش به صورت دقیق و با توجه به انواع مختلف روزها و اطلاعات آب‌وهوایی، بار ساعتی را پیش‌بینی می‌کند. با معرفی عملگرهای جدید ژنتیکی، پلت فرم GA اصلاح شده، بهتر از الگوریتم‌های GA سنتی پاسخ می‌دهد. ساختار شبکه بهینه را می‌توان با GA اصلاحی می‌توان محقق کرد. توابع عضویت و قواعد شماره‌گذاری شبکه فازی عصبی به صورت اتوماتیک به دست می‌آیند. نتایج نشان داده شده در این مقاله حاکی از کارآمدی روش ذکر شده دارند.

در [۱۰] ذکر شده است که در بازارهای برق رقابتی، پیش‌بینی بار کوتاه‌مدت برای بهره‌برداری مطمئن سیستم قدرت حائز اهمیت است. در هر حال پیش‌بینی بار موثر از نقطه‌نظر اثرات پیچیده بر روی بار توسط فاکتورهای متعدد، پیچیده است. این مقاله از روش شبکه عصبی موج ضربه‌ای مبتنی بر روز مشابه برای پیش‌بینی فردا استفاده کرده است. این ایده برای انتخاب روز مشابه به عنوان ورودی مبتنی بر آنالیز همبستگی می‌باشد و از تجزیه موج ضربه و جدا کردن شبکه‌های عصبی برای گرفتن ویژگی‌های بار در فرکانس‌های پایین و بالا استفاده شده است. برخلاف فضای نویز، بار فرکانس بالا با مولفه‌های فرکانس بالا و تسریع به عنوان ورودی روز مشابه به خوبی پیش‌بینی شده است. نتایج شبیه‌سازی عددی نشانگر دقت بالای روش ذکر شده است.

در [۱۱]، اطلاعات آب‌وهوایی به عنوان فاکتوری مهم در پیش‌بینی بار استفاده شده است. معمولاً مدل‌های پیش‌بینی بار با استفاده از این اطلاعات ساخته و تست می‌شوند. در هر حال، عملکرد آن‌لاین مدل‌های پیش‌بینی بار نیاز به استفاده از پیش‌بینی‌های آب‌وهوایی با خطاهای پیش‌بینی مرتبط دارد. این خطاها به طور ناگزیر به ضعیف شدن عملکرد مدل منجر می‌شود. این یک فاکتور مهم در پیش‌بینی بار است اما به طور گسترده در مقالات مورد بررسی قرار نگرفته است. هدف اصلی این مقاله، ارائه تکنیکی جدید برای مینیمم کردن اثرات خطای پیش‌بینی آب‌وهوا می‌باشد. علاوه بر این، تکنیکی

تکمیلی برای مدل کردن خطاهای پیش‌بینی بار برای منعکس کردن دقت فعلی ارائه گردیده است. تکنیک پیشنهادی ترکیبی از مدل‌های پیش‌بینی بار مختلف می‌باشد. تخمین پارامتر ممکن است به دو دسته تقسیم شود: زیر مدل و تخمین پارامتر ترکیبی. نشان داده شده است که کمترین PMSE با آموزش زیرمدل‌ها با آب‌وهوای واقعی متناظر است اما آموزش ترکیبی با آب‌وهوای پیش‌بینی متناظر است.

در [۱۲] بر جمع‌آوری پیچیده فضای نویری اطلاعات و ویژگی‌های پیچیده بار اشاره شده است. در این مقاله، روش شبکه‌های عصبی موج ضربه‌ای با فیلترینگ اطلاعات پیشنهاد شده است. ایده کلیدی، استفاده از تکنیک فیلترینگ جهش برای پیدا کردن جهش‌های اطلاعات بار و تصحیح آن‌ها می‌باشد. تجزیه موج ضربه‌ای برای تجزیه کردن بارهای فیلتر شده به مولفه‌های فرکانس بالا استفاده شده است، سپس شبکه‌های عصبی مجزا شده برای گرفتن مولفه‌های مجزا استفاده می‌شوند. نتایج شبکه‌های عصبی در نهایت برای تشکیل پیش‌بینی نهایی ترکیب می‌شوند. برای اجرای پیش‌بینی‌ها، ۱۲ شبکه عصبی موج ضربه‌ای استفاده شده است. نتایج عددی نشانگر اثرات فیلترینگ بر روی دقت پیش‌بینی‌هایی است که بر روی بازار برق نیوانگلند اجرا شده است.

در [۱۳] هدف توسعه مدلی برای پیش‌بینی ۲۴ ساعت بار برق شیراز است. برای دستیابی به این هدف، از شبکه عصبی انتشار پستی تطبیقی مورد استفاده قرار گرفته است. تنها شرایط آب‌وهوایی و فاکتورهای زمانی وارد محاسبات پیش‌بینی بار شده است. مدل برای پیش‌بینی بار تاریخ ۲۱ مارچ ۲۰۰۹ در ناحیه شیراز تست شده است، که نتایج حاکی از عملکرد مطلوب می‌باشد.

در مرجع [۱۴] یک روش ترکیبی برای پیش‌بینی بار کوتاه مدت با ترکیب روش کلاسیک آرام سازی نمائی برای پیش‌بینی سری‌های زمانی با روش بوسستینگ گرادیان روشی قوی برای یادگیری ماشینی ارائه شده است. روش پیشنهادی این مرجع بر روی شبکه واقعی تست شده است و نتایج حاکی از ارتقای دقت پیش‌بینی داشته است.

همانطور که پیش از این اشاره شد، برای پیش‌بینی بار روزانه روشهای مختلفی توسط محققین بکار گرفته شده است. برخی محققین از روشهای سری زمانی و رگرسیون خطی یا روشهای تلفیقی آنها با سیستم خبره استفاده نموده اند. مرجع [۱۵] از سری زمانی جهت پیش‌بینی بار استفاده نموده است که تجربیات اپراتور خبره را نیز بعنوان یکی از پارامترهای مدل در نظر می‌گیرد. در این مرجع از هشت دسته بندی برای بارها (شنبه‌ها، یکشنبه‌ها تا چهارشنبه‌ها، پنجشنبه‌ها، جمعه‌ها، تعطیلات عمومی فصل گرم و تعطیلات عمومی فصل سرد) استفاده شده است.

در مرجع [۱۶] یک مدل شبکه عصبی متشکل از دو شبکه خودسازمانده، که یکی بالای دیگری قرار دارد استفاده نموده است. یکی از شبکه‌های اطلاعات را به صورت مناسبی دسته بندی کرده و به عنوان داده‌های ورودی به شبکه دیگر ارسال می‌نماید از این مدل جهت پیش‌بینی بار ساعتی در طول ۲۴ ساعت بعد از دوره آموزش مورد ارزیابی قرار گرفته است.

در مرجع [۱۷] جهت پیش‌بینی دقیقتر بار چندین تکنیک شامل، آنالیز Gary، آنالیز یادگیری پس‌خور تصادفی با نرخ یادگیری پویا و مونتوم را با یکدیگر تلفیق نموده و برای پنج شبکه تا مدت زمانی پنج روز بعد، بار شبکه‌ها را پیش‌بینی نموده است.

برخی دیگر نیز با شناسایی روزهای وابسته به روز مورد بررسی و یا بررسی دیگر عوامل تاثیر گذار بر مصرف بار مثلا درجه حرارت هوا، رطوبت هوا، سرعت باد، پوشش ابر، ساعات آفتابی، میزان بارش و غیره سعی در پیش‌بینی دقیقتر بار نموده‌اند [۱۸].

ساختار شبکه عصبی برگرفته از مدل‌هایی است که بشر برای مغز انسان و سلول‌های عصبی آن متصور است. در دهه‌های گذشته، تحقیق زیادی بر روی کاربرد تکنیک‌های هوش مصنوعی {AI} برای مساله پیش‌بینی بار انجام شده اند. در میان این تکنیک‌ها، مدل‌هایی که بیشترین توجه را به سوی خود جلب نموده اند، شبکه‌های عصبی مصنوعی {ANNs}

هستند. اولین گزارش ها در مورد کاربرد این روش در مسائل پیش بینی بار در اواخر دهه ۱۹۸۰ و اوایل دهه ۱۹۹۰ منتشر شد و این روش بدلیل قابلیت مطلوب آن در مدلسازی غیر خطی به شکل گسترده در پیش بینی بار سیستم های الکتریکی مورد استفاده قرار گرفته است [۱۹].

در مرجع [۲۰] از دو روش پیش بینی استفاده شده است. ابتدا بارهای محلی بصورت جداگانه پیش بینی شده سپس بصورت یکجا، از شبکه عصبی برای پیش بینی استفاده شده و نمونه ی آماری این مقاله شبکه ی توزیع نیوزلند است. در مرجع [۲۱] ابتدا به اهمیت پیش بینی کوتاه مدت بار پرداخته سپس روشهای سنتی پیش بینی بار را توضیح داده و در بخش دوم این مقاله ضمن معرفی معرفي شبکه عصبی با استفاده از آن برای یک منطقه کوچک پیش بینی بار انجام گرفته است.

در مرجع [۲۲] یک روش جدید ترکیبی برای پیش بینی کوتاه مدت بار در سیستم های قدرت ارائه شده است. روش برآورد پیش بینی با کمک (FASE) و پرسپترون چند لایه (MLP) شبکه های عصبی تشکیل شده است. FASE پیش بینی بار ساعت به ساعت با استفاده از داده های قبلی آن است. سپس ورودی و خروجی از FASE به شبکه عصبی MLP تغذیه می کند. به عبارت دیگر، MLP آموزش دیده برای استخراج تابع نگاشت بین ورودی ها و خروجی از FASE (به عنوان ویژگی های ورودی) و بار واقعی به عنوان ویژگی های خروجی. روش ارائه شده ترکیبی بر روی یک سیستم قدرت واقعی، بخشی از شبکه برق ایران مورد بررسی قرار گرفت. نتایج به دست آمده، جامع مورد بحث، نشان می دهد که روش ترکیبی از دقت پیش بینی بهتر از روش های دیگر، مانند MLP، FASE، و دوره ای خودکار رگرسیون مدل (PAR) می باشد.

در مرجع [۲۳] پنج روش به طور کامل برای پیش بینی بار کوتاه مدت (تا ۲۴ ساعت) ارائه شده است. آنها عبارتند از: رگرسیون چندگانه خطی؛ سری های زمانی تصادفی، صاف نمایی عمومی، فضای حالت و فیلتر کالمن و یک رویکرد مبتنی بر دانش، شرح مختصری از هر یک از این تکنیک، همراه با معادلات لازم باشد، ارائه شده است. الگوریتم های پیاده سازی این تکنیک های متفاوت برای پیش بینی بار برنامه ریزی شده و به یک پایگاه داده برای مقایسه مستقیم اعمال شده است. خلاصه مقایسه ای از نتایج که به درک درستی از سطح تکنیک ها و عملکرد آنها می رسیم ارائه شده است.

در مرجع [۲۴] هر دو مدل BP و ARIMA شبکه عصبی در حوزه های خطی و غیر خطی پیش بینی بار استفاده شده است. همچنین یک مدل ترکیبی از دو مدل برای پیش بار روز پیش رو ارائه شده است که این روش از کارایی مطلوبی برخوردار می باشد.

در مرجع [۲۵] نیز به طراحی کارآمد و دقیق پیش بینی بار با توجه به درک مناسب از مشخصات سیستم پرداخته شده است و عوامل مختلف از قبیل اثر رفتار مشتری و اثر تلفات کلی در خطوط انتقال مورد بحث قرار گرفته است. این مشخصات به صورت ضرایب زمانی، آب و هوایی، اقتصادی و اغتشاشات تصادفی دسته بندی شده است.

۳. روش پیشنهادی

30 mm

در این بخش به نحوه مداسازی پیش بینی بار با استفاده از روش های شبکه عصبی و کلونی زنبور عسل خواهیم پرداخت. روش شبکه عصبی، روشی پیشرفته است که از یک مدل تشخیص الگوی ابتدائی برای پیش بینی بار استفاده می کند. این روش مبتنی بر مفهوم شبکه عصبی از "یادگیری از گذشته" به منظور پیش بینی آینده می باشد. شما باید به صورت متناوب مدل شبکه عصبی را برای به دست آوردن نتایج دقیق تر، آموزش دهید.

در این الگوریتم، یک شبکه از نورون ها با استفاده از اطلاعات گذشته آموزش داده می شوند. وزن های اتصالات داخلی نورون ها طوری تنظیم می شوند که آن ها با اطلاعات گذشته تطبیق داده شوند. پس از مرحله آموزش، این شبکه عصبی

برای پیش‌بینی بار آینده استفاده می‌شود. در این مقاله در رویه یادگیری بهینه‌سازی وزن‌ها با استفاده از الگوریتم کلونی زنبور عسل صورت می‌گیرد.

شبکه عصبی می‌تواند به طور کارآمدی رابطه‌ای خطی بین پارامترهای ورودی و خروجی مدل کند. برای پیش‌بینی بار، مدل شبکه عصبی می‌تواند از پارامترهای مشابهی که در MLR به کار رفت، استفاده کند. تنها این بار، رابطه به صورت رابطه‌ای غیرخطی مدل می‌شود که دقیق‌تر است.

بیان غیرخطی از مدل MLR به صورت رابطه ۳-۸ خواهد بود:

$$P(t)=f(t, T(t)-T_s), (T(t)-T_c)^2, (T(t)-T_c)^3, (T(t)-T(t-1)), (T(t-1)-T(t-2)), (T(t-2)-T(t-3)), WP_1(t), WP_2(t), WP_3(t) \quad (1)$$

هدف، آموزش یک مدل شبکه عصبی برای تطبیق مدل غیرخطی بالا می‌باشد. هر شبکه عصبی می‌تواند دارای یک لایه اولیه، یک زوج لایه‌های پنهان و یک لایه خروجی باشد.

در این مقاله قصد داریم برای بهینه‌سازی عملکرد شبکه عصبی از روش الگوریتم کلونی زنبور عسل استفاده نماییم. بدین منظور روشی ترکیبی برای پیش‌بینی بار کوتاه مدت استفاده خواهیم نمود. از الگوریتم کلونی زنبور عسل به منظور بهینه‌سازی رویه یادگیری شبکه عصبی استفاده خواهد شد. وزن‌های بهینه شده به روشی بازگشتی با به کارگیری روش بهینه‌سازی کلونی زنبور عسل به دست خواهد آمد که از الگوریتم کلونی زنبور عسل برای جستجوی بهترین پارامترهای آموزش استفاده خواهد شد. هدف از این مقاله ارتقای دقت پیش‌بینی بار با به کارگیری بهینه‌سازی داخلی و قابلیت بالای همگرایی کلونی زنبور عسل می‌باشد. همچنان که اشاره گردید روش پیشنهادی مبتنی بر ترکیب روش شبکه عصبی و کلونی زنبور عسل می‌باشد. شبکه عصبی با استفاده از الگوریتم بهینه‌سازی کلونی زنبور عسل آموزش داده شده است تا وزن‌های اتصالات نورون‌ها به دست آید. در ادامه به نحوه مدلسازی روش شبکه عصبی و کلونی زنبور عسل خواهیم پرداخت. همچنان که اشاره گردید روش شبکه عصبی یک شبکه پردازش اطلاعات الهام گرفته از سیستم عصبی انسان می‌باشد یعنی قواعد را از طریق تجربه یادگرفته و ایجاد می‌کند. این روش سیستمی پارامتری و قابل تنظیمی می‌باشد و رفتار شبکه را می‌توان با ساختار شبکه، روش‌های اتصال، قواعد یادگیری و توابع انتقال خروجی تنظیم کرد. در طی آموزش، وزن‌های نورونی به منظور دستیابی به سطح مطلوب دقت بهینه‌سازی می‌شوند. زمانی که آموزش انجام شد، شبکه قادر به پذیرش ورودی‌های جدید برای پیش‌بینی خروجی خواهد بود. مبتنی بر عملکرد پیش‌بینی و قابلیت کنترل سیستم‌های دینامیک و غیرخطی، شبکه عصبی به عنوان ابزاری قوی در پیش‌بینی و مدلسازی مواردی همچون سری زمانی در نظر گرفته می‌شود. الگوریتم کلونی زنبور عسل الهام گرفته از رفتار هوشمند جمعیت زنبور عسل در جستجوی غذا می‌باشد. در الگوریتم کلونی زنبور عسل، موقعیت هر منبع غذا متناظر با یک راه حل ممکن برای مساله بهینه‌سازی می‌باشد و مقدار نکتار (شهد) یک منبع غذایی نشانگر مقدار شایستگی (کیفیت) راه حل متناظر می‌باشد. همچنان که اشاره گردید مجموع زنبورها در یک کلونی را می‌توان به سه دسته تقسیم کرد: کارگر، تماشاگر، و پیشرو می‌باشد. زنبورهای کارگر و تماشاگر در کندو برابر بوده و متناظر با یک تعداد راه حل در جمعیت می‌باشند. فرمول بندی مدل مدنظر برای پیش‌بینی بار در اینجا بحث می‌شود که شامل پارامترهای شبکه عصبی و کلونی زنبور عسل می‌باشد. ورودی‌ها از شبکه عصبی که وزن‌های اتصال آن با استفاده از رویه یادگیری به دست می‌آیند عبور می‌کنند و نتایج در هر تکرار ارزیابی می‌شود.

رابطه غیرخطی و پیچیده ای میان بار و فاکتورهای تاثیرگذار بر آن وجود دارد. تقاضا در افق کوتاه مدت تحت تاثیر ورودی‌های تقویم، شرایط آب و هوایی می‌باشند. ورودی‌های تقویم شامل زمان روز، روز از هفته و تعطیلات می‌باشد. پارامترهای آب و هوایی معمولاً شامل دما، رطوبت و یا وزش باد و شدت تابش خورشید می‌باشد. به دلیل آن که فاکتورهای ورودی تاثیر بسزایی در مدلسازی پیش‌بینی بار دارند، ورودی‌های شبکه عصبی باید به دقت در مدلسازی وارد شوند. ورودی‌های انتخاب شده مبتنی بر همبستگی آن‌ها با بار خروجی می‌باشند. یک شبکه عصبی سه لایه پیش‌خور برای پیش‌بینی بار استفاده می‌شود. ورودی‌ها متغیرهای تاثیرگذار در تغییرات بار و خروجی بار ساعات بعدی می‌باشد. تعداد نورون‌ها در لایه پنهان بر روی قابلیت یادگیری و عمومیت دهی تاثیرگذار هستند. نورون‌های لایه پنهان براساس تعداد ورودی‌ها و خروجی‌ها انتخاب می‌شوند و با افزایش آهسته‌ی نورون‌ها از شایستگی خارج نرم جلوگیری می‌گردد تا نتایج بهینه حاصل شود. شبکه عصبی استفاده شده در این مطالعه شامل هشت ورودی (I)، پنج نورون پنهان (H) و یک نورون خروجی می‌باشد. علاوه بر این دو نورون بایاس اضافی (b1, b2) در نظر گرفته شده است که یکی در لایه پنهان و دیگری در لایه خروجی می‌باشد که در مجموع به ۵۳ اتصال نورونی منجر می‌گردد. اتصالات نورون‌ها با ضرب نورون‌ها در هر لایه حساب می‌شود. در این مقاله ۹ (۸ ورودی + ۱ بایاس) به پنج نورون پنهان وصل هستند که ۵۳ اتصال نورونی را نتیجه می‌دهند. این موضوع را می‌توان به صورت
$$N = (I + b1) * H + (H + b2) * O + b1 + b2$$
 فرموله کرد.

تابع تبدیل سیگموئید برای دستیابی به خروجی نورون استفاده می‌شود. خطای میانگین مربعات (MSE^*) به منظور ارزیابی عملکرد شبکه عصبی استفاده می‌شود. وزن‌ها از یک توزیع یکنواخت مقداردهی اولیه می‌گردند. در اینجا به نحوه تنظیمات الگوریتم کلونی زنبور عسل به منظور بهینه سازی اتصالات نورون‌های شبکه عصبی می‌پردازیم. تعداد منابع غذایی در این جا ۲۸ در نظر گرفته شده است که جمعیت زنبورهای عسل نیز می‌باشد. تعداد زنبورهای کارگر و تماشاگر نیز ۱۴ می‌باشد. دیمانسیون فضای جستجو برابر با ۵۳ یعنی تعداد اتصالات وزن‌ها می‌باشد. مرزهای بالا و پایین برابر با ۱ و -۱ می‌باشد.

رویه یادگیری الگوریتم کلونی زنبور عسل بر پایه مراحل مختلف می‌باشد. مرحله اول مقداردهی اولیه می‌باشد که یک جمعیت اولیه از منابع غذایی N به صورت تصادفی در رنج مرزهای بالا و پایین تولید می‌شوند. رابطه ۳-۹ برای مقداردهی اولیه جمعیت استفاده می‌شود. در این جا سایز جمعیت ۲۸ است.

$$x_{ij} = x_j^{min} + rand(0,1)(x_j^{max} - x_j^{min}) \quad (2)$$

که در این رابطه I بیانگر آمین منبع غذایی و J متغیر بهینه سازی مربوط به آمین منبع غذایی می‌باشد. در این مرحله مقدار نکتار هر منبع غذایی محاسبه خواهد شد و شایستگی منبع غذایی مطابق با رابطه زیر ارزیابی می‌گردد:

$$fitness_i = \frac{1}{1 + f_i} \quad ; f_i \geq 0$$

$$1 + abs(f_i) \quad ; f_i < 0 \quad (3)$$

که در رابطه فوق f_i هزینه مربوط به راه حل Xi می‌باشد و این تابع مستقیماً بای تابع هزینه مساله حداکثرسازی رابطه دارد. در اینجا پس از تعیین شایستگی، هر زنبور کارگر یک منبع غذای کاندید جدید V_i سپرا در همسایگی منابع غذایی موجود جستجو می‌کند. منبع غذایی جدید براساس اطلاعات زنبورها مقایسه می‌شوند و براساس رابطه ۳-۱۱ ارزیابی می‌گردند. در این جا انتخاب حریصانه[†] برای انتخاب منبع غذایی بهتر به عنوان منبع غذایی جدید انتخاب می‌شود.

* Mean Squared Error

† Greedy Selection

$$v_{ij} = x_{ij} + \varphi_{ij}(x_{ij} - x_{kj}) \quad (4)$$

که در این رابطه یک متغیر بهینه سازی تصادفی در رنج [1,D] می باشد و k یک منبع غذایی انتخاب شده به صورت تصادفی و متفاوت از i می باشد که یک عدد تصادفی حقیقی با توزیع یکنواخت در بازه -1 و 1 است. D یک عدد غیرمنفی است.

در اینجا به نحوه وزن دهی راه حل می پردازیم. احتمال انتخاب یک راه حل در جمعیت متناسب با مقدار نکتار در منبع غذایی و یا مقدار شایستگی منبع غذایی در جمعیت می باشد. با استفاده از روش انتخاب چرخ رولت [30]، هر زنبور تماشاگر یک منبع غذایی با احتمال بالاتر را با استفاده از رابطه 5 انتخاب می کند. سپس یک راه حل کاندید مبتنی بر رابطه 4 تولید می شود [32].

$$p_i = \frac{fitness_i}{\sum_{i=1}^N fitness_i} \quad (5)$$

که p_i احتمال منبع غذایی i ام می باشد. در اینجا راه حل ها ارزیابی شده و منابع غذایی بهتر جایگزین دیگر منابع غذایی می شوند که این امر با رویه انتخاب حریصانه صورت می پذیرد. راه حل بهتر که ترکیب وزن های نورونی است به شبکه عصبی داده می شود تا در رویه پردازش قرار بگیرد. در شبکه عصبی نورون های مختلف در سه لایه ترکیب شده و وزن های اتصال و سیگنال های ورودی در هر نورون پردازش شده و به دیگر نورون ها در لایه دیگر می روند.

یک نورون تکی ورودی های وزن دهی شده را با استفاده از فرمول زیر محاسبه می کند:

$$y_i = \sum_{i=1}^n x_i w_{ij} \quad (6)$$

که در این رابطه x_i بردار ورودی و w_{ij} وزن های متناظر با بردار ورودی می باشد. Y_i نیز پاسخ نورون مبتنی بر تابع هدف است.

مطابق با رابطه 7 برای خروجی، نورون از یک تابع تبدیل سیگموئید استفاده می کند:

$$y_i = \frac{1}{1 + e^{-x_j}} \quad (7)$$

شبکه تابع هدف و خطا را با استفاده از رابطه 8 محاسبه می کند:

$$E = \frac{1}{n} \sum_{i=1}^n (y_i - a_i)^2 \quad (8)$$

که y_i خروجی به دست آمده از در نورون i و a_i خروجی مطلوب است. در این گام، شبکه تابع هدف را به مرحله آموزش برمی گرداند تا راه حل ها بیشتر ارزیابی شوند.

پس از آن که هر راه حل کاندید با استفاده از زنبورهای مصنوعی تولید شده و در شبکه عصبی پیش خور ارزیابی شد، شایستگی راه حل با بهترین راه حل قبلی محاسبه می شود. اگر راه حل جدید بهتر یا برابر مقدار شایستگی پیشین بود، بهترین راه حل قبلی با راه حل جدید در حافظه جایگزین می شود.

الگوریتم کلونی زنبور عسل مراحل ذکر شده را تا برآورده شدن معیار خاتمه یا تعدادی معین تکرار انجام می دهد. پس از خاتمه الگوریتم مقدار شایستگی و موقعیت بهینه منبع غذایی به عنوان پارامترهای تصمیم گیری ذخیره می شوند. در این مقاله الگوریتم در صورتی دیگر تکرار نمی شود که به تکرار 500 برسد و یا خطای میانگین مربعات به کمتر از 0.0001 برسد.

رویه مرحله مقدار دهی اولیه تا مرحله خاتمه برای زنبورهای کارگر تکرار می شود تا راه حلی بهتر پیدا کنند و پس از آن زنبورهای تماشاگر فراخوانده می شوند تا راه حل ها را براساس احتمالاتشان مجدداً تولید کنند. اگر زنبورهای تماشاگر قادر به یافتن مینیمم مطلق نشوند، پس از آن زنبورهای پیشرو شروع به تولید یک راه حل تصادفی می شوند. این رویه از یافتن مینیمم محلی جلوگیری می کند. هر نوع زنبور راه حل های کاندید را به شبکه عصبی می دهد تا مقدار هدف محاسبه شود و مجدداً برای انتخاب یا رد راه حل بازگردانده شود.

رویه آموزش شبکه عصبی از طریق الگوریتم کلونی زنبور عسل تشریح شد. هر یک از زنبورهای کارگر و زنبورهای تماشاگر در گام نخست قرار دارند و سه خط خروجی دارند. یک خط به بلوک شبکه عصبی وصل می گردد تا روندهای محاسباتی شایستگی و خطا را انجام دهد و مجدداً راه حل ها را به بلوک های زنبورها می دهد. این رویه تا زمانی که همه زنبورهای بلوک ها خسته شوند ادامه می یابد. اگر تمامی زنبورهای یک بلوک خسته شوند و شرط خاتمه برآورده نشود، سپس به سراغ زنبورهای پیشرو برای تولید تصادفی می رویم تا فضای جستجو را تغییر دهند.

۴. تحلیل نتایج

همچنان که در فصول پیشین اشاره گردید در این مقاله از روش الگوریتم کلونی زنبور عسل و شبکه عصبی برای پیش استفاده Matlab بینی بار شبکه استان کرمانشاه استفاده می شود. در این تحقیق برای پیش بینی بار کوتاه مدت از برنامه از روش الگوریتم بهینه سازی کلونی زنبور عسل و شبکه عصبی مطابق روابط بخش Matlab شده است؛ که در برنامه سوم، استفاده گردیده است. برای شبیه سازی از اطلاعات ۳ ساله بار ساعتی و اطلاعات آب و هوایی شامل دما و رطوبت مربوط به شبکه کرمانشاه به عنوان اطلاعات گذشته استفاده گردیده است. این اطلاعات ۲ ساله از سال ۱۳۹۳ تا سال ۱۳۹۵ جمع آوری گردیده است.


لازم به ذکر است استان کرمانشاه به علت گستردگی زیاد جغرافیای آب و هوایی به صورت چندین منطقه در نظر گرفته می شود که بار کل استان در این مقاله در نظر گرفته شده است. اطلاعات شامل بار، دما و وزش باد در استان کرمانشاه می باشد. همچنین برای مقایسه اطلاعات پیش بینی شده با واقعیت پیش بینی بار سال ۱۳۹۵ انجام گرفته است؛ اما می توان برنامه نوشته شده را بصورت ساعتی برای زمان های آینده نیز استفاده کرد. در واقع فقط برای تست و مقایسه با اطلاعات در دسترس از پیش بینی سال ۱۳۹۵ استفاده گردیده است. جهت پیش بینی بار سال ۱۳۹۵، این شبیه سازی ها برای پیک بار انجام شده است.

همچنان که اشاره گردید در این مقاله از روش بهینه سازی الگوریتم کلونی زنبور عسل به منظور آموزش بهینه وزن های تر است که از یک مدل تشخیص الگوی ابتدائی روش شبکه عصبی استفاده می شود. روش شبکه عصبی، روشی پیشرفته کند. این روش مبتنی بر مفهوم شبکه عصبی از "یادگیری از گذشته" به منظور پیش بینی آینده برای پیش بینی بار استفاده می می باشد. شما باید به صورت متناوب مدل شبکه عصبی را برای به دست آوردن نتایج دقیق تر، آموزش دهید. در این الگوریتم، یک شبکه از نورون ها با استفاده از اطلاعات گذشته آموزش داده می شوند. وزن های اتصالات داخلی نورون ها طوری تنظیم می شوند که آن ها با اطلاعات گذشته تطبیق داده شوند. پس از مرحله آموزش، این شبکه عصبی برای

پیش‌بینی بار آینده استفاده می‌شود. شبکه عصبی می‌تواند به طور کارآمدی رابطه‌ای خطی بین پارامترهای ورودی و خروجی به کار رفت، استفاده کند. MLR مدل کند. برای پیش‌بینی بار، مدل شبکه عصبی می‌تواند از پارامترهای مشابهی که در تنها این بار، رابطه به صورت رابطه‌ای غیرخطی مدل می‌شود که دقیق‌تر است. در این جا از هشت پارامتر زیر برای پیش‌بینی بار و مدل‌سازی شبکه عصبی استفاده گردیده است:

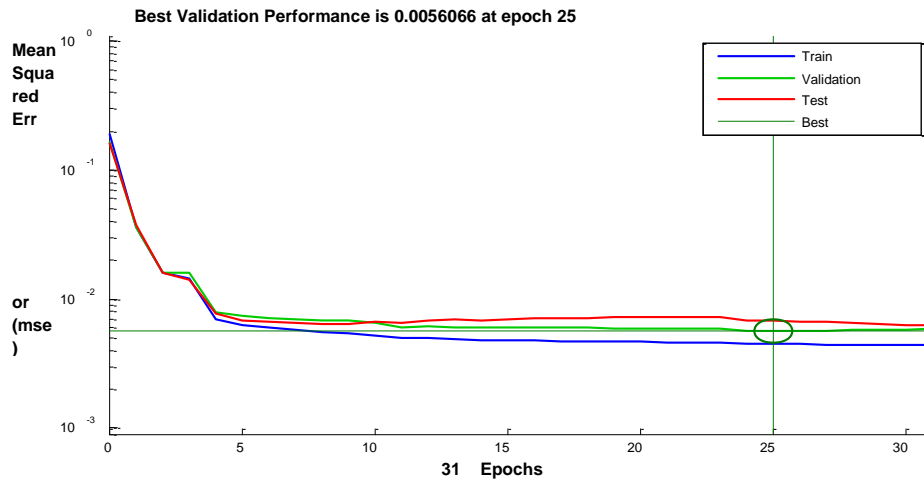
$$P(t) = f(t, T(t) - T_s), (T(t) - T_c)^2, (T(t) - T_c)^3, (T(t) - T(t-1)), (T(t-1) - T(t-2)), (T(t-2) - T(t-3)), WP_1(t) \quad (9)$$

هدف، آموزش یک مدل شبکه عصبی برای تطبیق مدل غیرخطی بالا می‌باشد. هر شبکه عصبی می‌تواند دارای یک لایه وزش باد لحاظ گردیده است. همچنین WP_1 اولیه، یک زوج لایه‌های پنهان و یک لایه خروجی باشد. در رابطه ۴-۱ و $T(t-2)$ و $T(t-1)$ دمای بحرانی می‌باشد که در بخش دوم آن را معرفی نمودیم. همچنین T_c و T_s دمای زمان $T(t)$ می‌باشد. [۳۳] دمای زمان‌های قبلی می‌باشد. شایان ذکر است که این رابطه برگرفته از مرجع $T(t-3)$ به منظور آموزش شبکه عصبی در محیط نرم افزار متلب از روش بهینه سازی کلونی زنبور عسل استفاده شده است. که این در محیط متلب انجام شده است. در واقع ماژول شبکه عصبی با تغییرات در تابع Trainlm.m کار با تغییر تابع Trainlm از الگوریتم بهینه سازی کلونی زنبور عسل آموزش داده می‌شود. در شکل ۱ پارامترهای استفاده شده Trainlm و نحوه تنظیمات شبکه عصبی و تعداد لایه‌ها نشان داده شده است.



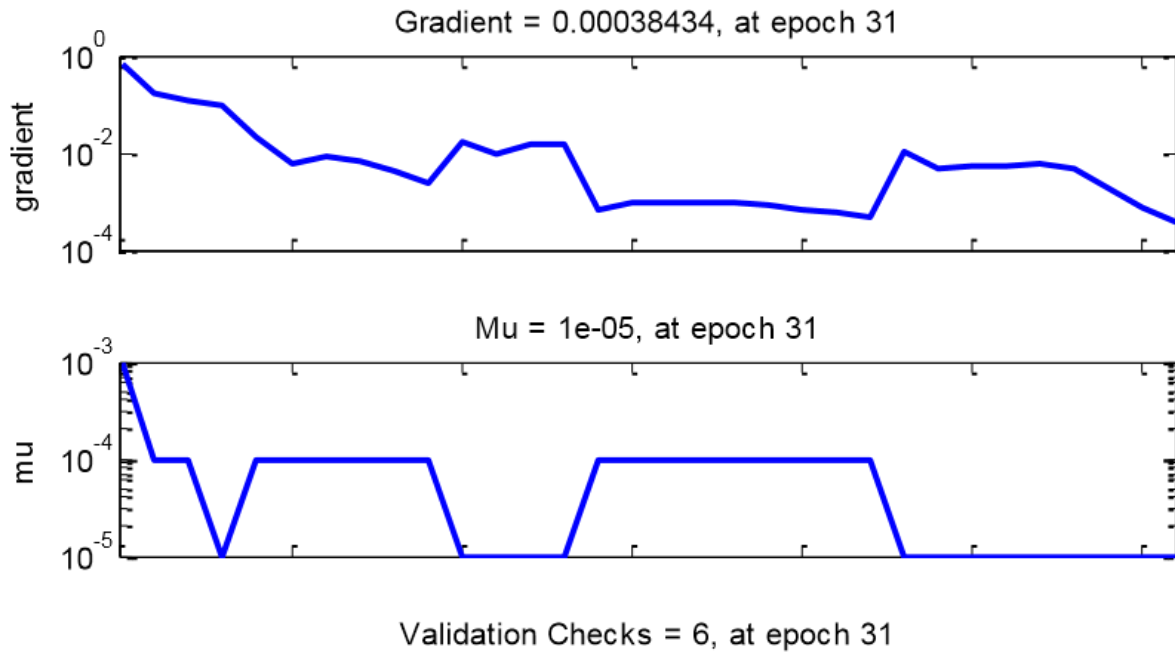
شکل ۱ شبکه عصبی استفاده شده

در این برنامه از رابطه اصلی بخش ۳ که دما و وزش باد از ورودی‌های اصلی شبکه بوده‌اند، استفاده شده است. معیارهای می‌باشد. همچنان که مشاهده می‌شود آموزش شبکه پس از ۳۱ تکرار انجام شده است. $1e^{-7}$ توقف ۱۰۰۰ تکرار و گرادیان لازم به ذکر است در این جا جهت پیاده‌سازی شبکه عصبی از ۵ نورون استفاده شده است. که همچنان که مشاهده می‌شود خطا در حد قابل قبولی می‌باشد. همچنین بهترین عملکرد در تکرار ۲۵ بوده است. در این شکل خط آبی رنگ اطلاعات آموزش، خط سبز مربوط به معتبرسازی و خط قرمز مربوط به تست می‌باشد.



شکل ۲ عملکرد شبکه عصبی

در شکل ۳ وضعیت آموزش از لحاظ پارامترهای میو، گرادیان، و Vafail آورده شده است.




شکل ۳ وضعیت آموزش شبکه عصبی

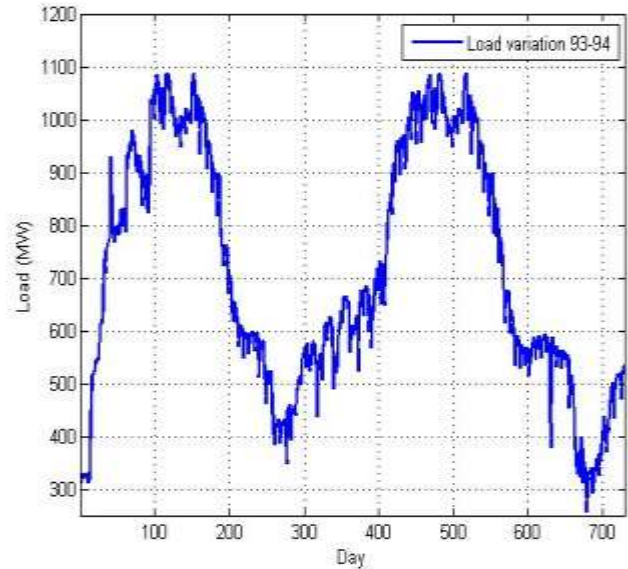
۵. داده‌های ورودی

25 mm

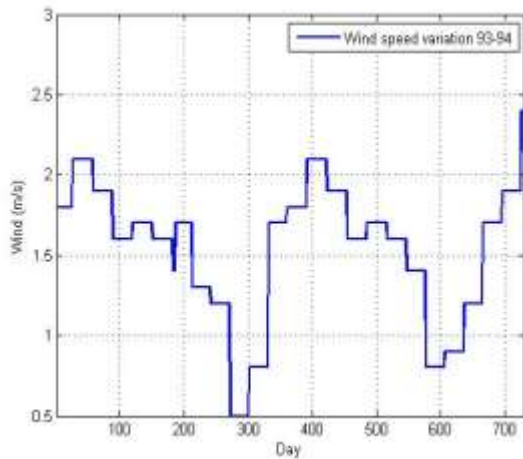
به منظور پیش بینی بار در این مقاله از داده‌های گذشته ی بار، دما و وزش باد استفاده شده است که در شکل‌های ۴، ۵ و ۶ نمودار روند تغییرات آن‌ها برای دو سال آموزش یعنی ۹۳ و ۹۴ آورده شده است.



شکل ۴ تغییرات دمایی طی دو سال ۹۳ و ۹۴

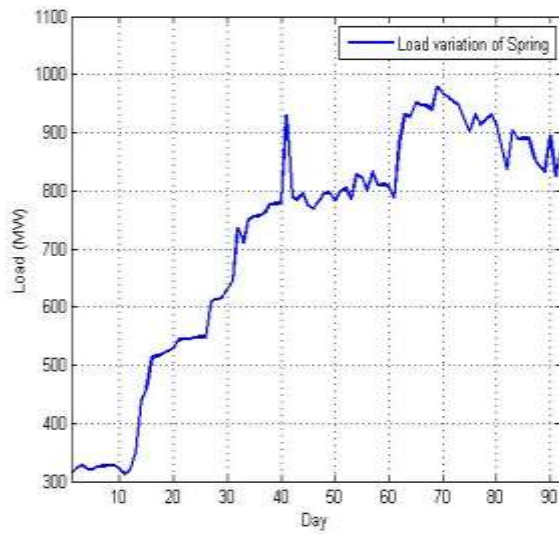


شکل ۶ تغییرات تقاضا طی دو سال ۹۳ و ۹۴

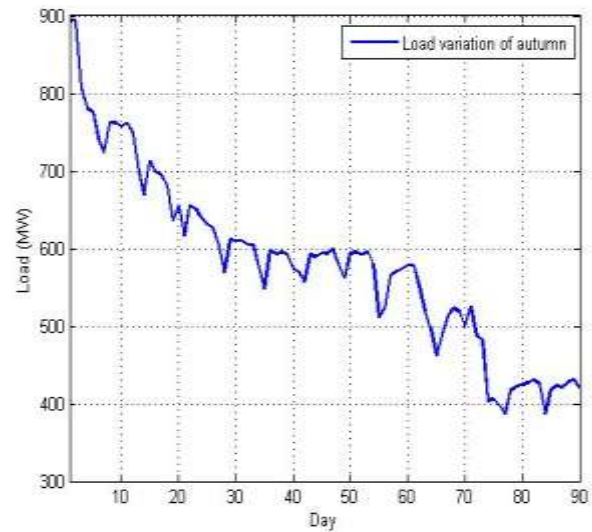


شکل ۵ تغییرات وزش باد طی سال‌های ۹۳-۹۴


در این جا جهت نمودار کردن تغییرات دمایی فصول، پارامترها را به صورت بخشی نیز آورده ایم تا به صورت دقیق تر متوجه تغییرات گردیم.



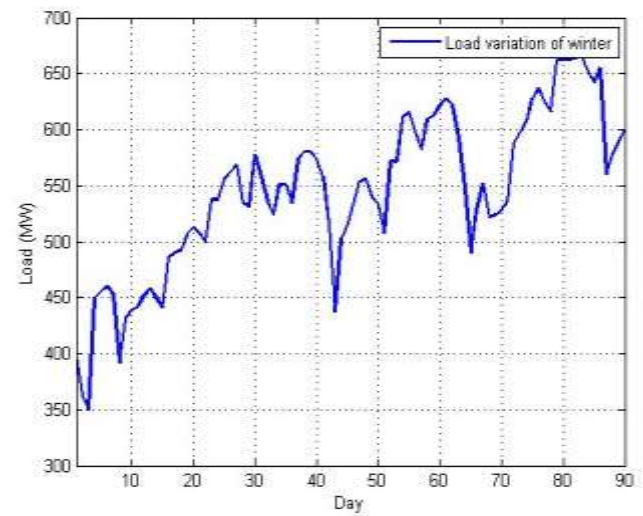
شکل ۷ تغییرات بار بهار ۹۳



شکل ۹ تغییرات بار پاییز ۹۳



شکل ۸ تغییرات بار تابستان ۹۳



شکل ۱۰ تغییرات بار زمستان ۹۳

۶. مقایسه

جهت درک بهتر مقایسه ای بین روش پیشنهادی با روش شبکه عصبی بدون بهینه سازی و داده های واقعی صورت گرفته است.

جدول 1 مقایسه روش پیشنهادی با روش شبکه عصبی بدون بهینه سازی براساس خطای پیش بینی

ABC با بهینه سازی				بدون بهینه سازی				ماه
مقدار واقعی	مقدار خطای بدون بهینه سازی	روز	بیشترین خطا	مقدار واقعی	مقدار خطای ABC روش	روز	بیشترین خطا	
594	0.86	6	0.71	686	0.16	29	3.79	فروردین
1011	1.11	2	0.37	1091	0.21	19	3.25	مرداد
523	2.52	16	0.82	477	0.66	13	2.90	آذر
491	3.94	28	1.05	526	0.61	1	2.84	بهمن

شایان ذکر است این چهار ماه به طور نمونه برای چهار بخش انتخاب شده است و برای کل سال بیشترین میزان خطا برای روش بدون بهینه سازی به مقدار 3.99 درصد می رسد و برای روش پیشنهادی به مقدار 1.052 درصد می رسد که مقداری بسیار مطلوب می باشد.

بر مبنای مطالعات صورت گرفته در مقاله های پیشین در ارتباط با مقایسه میان روش های مختلف پیش بینی بار از میان سه روش روز مشابه، رگرسیون و شبکه عصبی، روش شبکه عصبی دارای نتایج مطلوبتری می باشد.

همچنین در این مقاله از روش بهینه سازی کلونی زنبور عسل به منظور بهینه سازی استفاده نمودیم که نسبت به دیگر روش های بهینه سازی نظیر ژنتیک و PSO دارای مزایای زیر می باشد: از لحاظ پیاده سازی ساده بوده و در آن نیاز به تنظیم پارامترها کمتر می باشد. همچنین براساس آن چه در اکثر مراجع نظیر مرجع [۳۱] ذکر شده است این الگوریتم توانایی مناسبی در تنظیم بهینه وزن های شبکه عصبی دارد که مهم ترین دلیل انتخاب این مقاله برای بهینه سازی بوده است.

شایان ذکر است تعداد داده های آموزش در این تحقیق برابر با دو سال یعنی ۷۳۰ و داده های تست نیز برابر با ۳۶۵ بوده است. همچنین برای مدلسازی روش پیشنهادی الگوریتم کلونی زنبور عسل از مرجع [۳۲] استفاده شده است.

۷. نتیجه‌گیری

بهبود دقت STLFF همیشه یکی از مشکلات ناکارآمد برنامه ریزی سیستم های قدرت است. در این مقاله یک روش ترکیبی جدید STLFF بر اساس الگوریتم ANN و ABC پیشنهاد شده است. در مدل پیشنهادی مدل بار اصلاح شده بر اساس داده های آب و هوا و تاریخچه در نظر گرفته شده است. الگوریتم ABC برای بهینه سازی روش یادگیری ANN استفاده می شود. وزنهای بهینه شده با استفاده از روش تکراری بر اساس ABC که بیشترین سازگاری را با ANN دارند. نتایج شبیه سازی روش ANNABC ثابت کرد که دقت STLFF به طور قابل توجهی در مقایسه با ANN بدون بهینه سازی بهبود یافته است.

۸. مراجع

- [1] Li and W. Chen. (2012), "Application of BP neural network algorithm in sustainable development of highway construction projects," Physics Procedia, vol. 25, pp. 1212–1217.
- [2] Y. H. Bao and J. Ren.(2011),"Wetland landscape classification based on the BP neural network in DaLinor lake area," Procedia Environmental Sciences, vol. 10, pp. 2360–2366.
- [3] F. M. Tseng, H. C. Yu, and G. H. Tzeng.(2002),"Combining neural network model with seasonal time series ARIMA model," Technological Forecasting and Social Change, vol. 69, no. 1, pp. 71–87.
- [4] Wei-Chiang Hong.(2011), "Electric load forecasting by seasonal recurrent SVR (support vector regression) with chaotic artificial bee colony algorithm", energy journal.
- [5] M. A. Farahat and M. Talaat. (2010), "A New Approach for Short-Term Load Forecasting Using Curve Fitting Prediction Optimized by Genetic Algorithms", Proceedings of the 14th International Middle East Power Systems Conference.

- [6] K. Kalaitzakis, G.S. Stavrakakis, E.M. Anagnostakis.(2002), "Short-term load forecasting based on artificial neural networks parallel implementation", Electric Power Systems Research.
- [7] Saeed M. Badran, Ossama B. Abouelatta, "Forecasting Electrical Load using ANN Combined with Multiple Regression Method", The research of Jordan, Volume II.
- [8] Mrs. J. P. Rothe Dr. A. K. Wadhvani Dr. Mrs. S. Wadhvani.(2011), "Short Term Load Forecasting Using Multi Parameter Regression", (IJCSIS) International Journal of Computer Science and Information Security.
- [9] S. H. Ling, Frank H. F. Leung, H. K. Lam, Peter K. S. Tam.(2003), "Short-Term Electric Load Forecasting Based on a Neural Fuzzy Network", IEEE TRANSACTIONS ON INDUSTRIAL ELECTRONICS, VOL. 50, NO. 6.
- [10] Ying Chen, Peter B. Luh, Che Guan, Yige Zhao, Laurent D. Michel, Matthew.(2010), "Short-Term Load Forecasting: Similar Day-Based Wavelet Neural Networks", IEEE TRANSACTIONS ON POWER SYSTEMS, VOL. 25, NO. 1
- [11] Damien Fay and John V. Ringwood.(2010), "On the Influence of Weather Forecast Errors in Short-Term Load Forecasting Models", IEEE TRANSACTIONS ON POWER SYSTEMS, VOL. 25, NO. 3.
- [12] Che Guan, Laurent D. Michel, Yuting Wang, and Peter B. Friedland.(2013), "Very Short-Term Load Forecasting: Wavelet Neural Networks With Data Pre-Filtering", IEEE TRANSACTIONS ON POWER SYSTEMS, VOL. 28, NO. I.
- [13] Alireza Keshavarz Choobeh.(2012), "Short Term Load Forecasting for Shiraz Region Using Adaptive Back Propagation Neural Network", 2012 4th International Conference on Computer Modeling and Simulation.
- [14] ictor Mayrink.(2016),"A hybrid method using Exponential Smoothing and Gradient Boosting for electrical short-term load forecasting", Latin American IEEE Conference.
- [15] Amjady, N.(2001), "Short-Term Hourly Load Forecasting Using Time-Series Modeling With Peak Load Estimation Capability", IEEE Trans. Power Systems, Vol. ۱۶, No.۴, PP.۸۰۵-۷۹۸, November.
- [16] Carpinteriro, O.A.S. Alves Da Silva, A.P. (۲۰۰۰),"A Hierarchical Neural Model in Short-Term LoadForecasting ", Conference Publications, Vol. ۶, No.۳, PP. .۲۴۶-۲۴۱

- [17] Huang, H.G., Hwang, R.C., Hsieh, J.G., March .(۲۰۰۲), "A New Artificial Intelligent Peak Power Load Forecaster Based On Non-Fixed Neural Networks", Electrical Power Energy Systems, ۲۴, PP.۲۵۰-۲۴۵,
- [18] Saini, L.M., Soni, M.K.(۲۰۰۲) , "Artificial Neural Networks Based Peak Load Forecasting Using Conjugate Gradient Methods", IEEE Trans. Power Systems, Vol. ۱۷, No.۳, PP.۹۱۲-۹۰۷
- [19] Hippert, H.S., Pedreira, C.E., Castro, S.R.(۲۰۰۱) ,"Neural Networks For Short-Term Load Forecasting: A Review And Evaluation", IEEE Trans. Power Systems, Vol. ۱۶, No.۱, PP.۴۴- ۵۵
- [20] Kenji Nose-Filho, Anna Diva Plasencia Lotufo, and Carlos Roberto Minussi , (2011).“Short-Term Multi nodal Load Forecasting Using a Modified General Regression Neural Network” IEEE TRANSACTIONS ON POWER DELIVERY, VOL. 26, NO. 4, OCTOBER.
- [21] Mohan B. Tasre, Vilas N. Ghate, Prashant P. Bedekar ,(2012). “Hourly Load Forecasting Using Artificial Neural” IEEE- International Conference On Advances In Engineering, Science And Management (ICAESM -2012) March 30, 31.
- [22] Amjady.N, (2007).“Short-Term Bus Load Forecasting of Power System by a New Hybrid Method” , IEEE Transactions on Power Systems, Vol.22 , No. I, pp: 333-341, February.
- [23] I. Moghram and S. Rahman,(1989). "Analysis and evaluation of five short-term load forecasting techniques," IEEE Transactions on Power Systems, vol:4, pp: 1484-1491.
- [24] Yi Yang,1 JieWu,2 Yanhua Chen,1 and Caihong Li1, (2013). "A New Strategy for Short-Term Load Forecasting", Hindawi Publishing Corporation.
- [25] Muhammad Usman Fahad and Naeem Arbab,(2014). "Factor Affecting Short Term Load Forecasting", Journal of Clean Energy Technologies, Vol. 2, No. 4, October.
- [26] E. Bonabeau, M. Dorigo, G. Theraulaz, (1999). “Swarm Intelligence: From Natural to Artificial Systems”, New York, NY: Oxford University Press.
- [27] Tereshko V., Loengarov A,(2005). "Collective Decision-Making in Honey Bee Foraging Dynamics", Journal of Computing and Information Systems, 9(3), 1-7.

- [28] Dervis KARABOGA.(1995), "AN IDEA BASED ON HONEY BEE SWARM FOR NUMERICAL OPTIMIZATION"; TECHNICAL REPORT-TR06, OCTOBER, 2005.
- [29] 8. T. D. Seeley, The Wisdom of the Hive (Harvard University Press, Cambridge, MA.
- [30] Goldberg David E .(1989)," Genetic algorithms in search, optimization and machine learning", 1st edn. Addison-Wesley Longman Publishing Co., Inc, Boston.
- [31] Beatriz A. Garro.(2011), "Artificial Neural Network Synthesis by means of Artificial Bee Colony (ABC) Algorithm", IEEE Congress Evolutionary Computation.
- [32] Shahid M. Awan , Muhammad Aslam , Zubair A. Khan , Hassan Saeed. (2014), "An efficient model based on artificial bee colony optimization algorithm with Neural Networks for electric load forecasting", Neural Computing journal.
- [33] OSI OpenSTLF User's Guide. 2007, Revision 4.2.