

پیش بینی بار و پیش بینی قیمت با استفاده از الگوریتم بهینه سازی مبتنی بر آموزش و یادگیری و شبکه عصبی فازی تطبیقی

فاطمه السادات موسوی علیزاده^۱، سید جعفر فاضلی آبلویی^{۲*}

۱- گروه برق، دانشکده فنی و مهندسی، واحد ساری، دانشگاه آزاد اسلامی، ساری، ایران

۲- گروه برق، دانشکده فنی و مهندسی، واحد نکا، دانشگاه آزاد اسلامی، نکا، ایران

*نویسنده مسئول: sj.fazeli@iau.ac.ir

چکیده

امروزه بازار برق در جهان به صورت علمی شناخته شده می باشد که رقابت در آن هر روز بیشتر از روز قبل است. از آنجا که قابلیت ذخیره سازی انرژی الکتریکی بسیار ناچیز می باشد، بنابراین پیش بینی بار مصرفی و قیمت برق به شرکت کنندگان بازار در بدست آوردن سود هرچه بیشتر کمک شایانی می کند. تأثیرپذیری الگوی بار از عوامل مختلف و غیرخطی بودن سیگنال قیمت برق، انجام پیش بینی دقیق بار و قیمت را دچار مشکل می کند؛ بنابراین استفاده از الگوریتم های هوشمند در مقایسه با روش های عددی و آماری کاربرد بیشتری در مسائل پیش بینی پیدا کرده است.

از اینرو در این پایان نامه مسائل مربوط به پیش بینی بار و قیمت برق بیان شده است. همچنین پیش بینی بار الکتریکی و قیمت برق با استفاده از شبکه عصبی فازی تطبیقی (ANFIS) ترکیبی با الگوریتم آموزش و یادگیری (TLBO) صورت گرفته است و تأثیر عوامل مختلف بر روی آن بررسی و شبیه سازی شده است. در واقع با ترکیب الگوریتم های تکاملی با سیستم عصبی فازی، تنظیم مقادیر بهینه پارامترهای شبکه عصبی فازی تطبیقی به الگوریتم بهینه سازی هوشمند آموزش و یادگیری محول گردد. هدف از بکارگیری این رویکرد بهبود عملکرد شبکه و کاهش پیچیدگی های محاسباتی در مقایسه با روش های گرادیان نزولی و حداقل مربعات می باشد. نتایج پیاده سازی الگوریتم پیشنهادی نشان دهنده کارایی بهتر این الگوریتم در مقایسه با الگوریتم های پیشین پیش بین بار و قیمت برق است.

واژه های کلیدی: پیش بینی بار، پیش بینی قیمت، الگوریتم بهینه سازی مبتنی بر آموزش و یادگیری، شبکه عصبی فازی تطبیقی

1. مقدمه (با 2 خط 9pt فاصله از کلمات کلیدی)

در فضای رقابتی صنعت برق مسائل مربوط به انرژی الکتریکی از جمله پیش‌بینی، بهینه‌سازی و ذخیره‌سازی اهمیت بیشتری پیدا کرده است. از آنجا که انرژی الکتریکی در حد جزئی قابلیت ذخیره‌سازی دارد، بنابراین تولید بیشتر یا کمتر از میزان مصرف خسارتی در پی دارد. پیش‌بینی بار به صورت کوتاه مدت برای زمان‌بندی تولید و به صورت بلند مدت برای مشخص کردن مقدار تولید نیرو در آینده و یا فروش بار و نیز پیش‌بینی دقیق قیمت ضروری می‌باشد [1].

پیش‌بینی بار به عنوان عاملی مهم در طرح توسعه و بهره‌برداری از سیستم‌های قدرت تلقی می‌شود و در واقع وسیله‌ای است که به کمک آن می‌توان در جهت بهبود و تصمیم‌گیری اقدام نمود. پیش‌بینی بار در برنامه‌ریزی توسعه آینده یک سیستم قدرت از اهمیت زیادی برخوردار است و اساس و مبنای مطالعات برنامه‌ریزی را تشکیل می‌دهد. مشکلات تصمیم‌گیری در این مورد موقعی بیشتر می‌شود که با بودجه محدود و هدف حداقل کردن هزینه از یک طرف و فشار متخصصین و مهندسین بخش قدرت برای خرید تجهیزات پیشرفته و گران‌قیمت از طرف دیگر و نیز گسترش بی‌رویه در استفاده از انرژی الکتریکی مواجه شود. اگر میزان بار پیش‌بینی شده کمتر از بار واقعی باشد ضریب اطمینان و در نتیجه کیفیت خدمات کاهش می‌یابد و این امر ممکن است حتی به خاموشی‌های اجباری منجر شود. این مسئله تا حدی کار مسئولین تجزیه و تحلیل قابلیت اطمینان سیستم را مشکل می‌سازد. از طرف دیگر اگر بار آینده بیش از مقدار مورد نیاز پیش‌بینی گردد سرمایه‌گذاری زیادی هدر می‌رود. بنا بر دلایل گفته شده پیش‌بینی بار امری ضروری به نظر می‌رسد چراکه باید بین عرضه و تقاضای برق یک تعادل نسبی برقرار شود تا منجر به داشتن یک شبکه توزیع اقتصادی و با قابلیت اطمینان بالا شود [2-3].

آنچه انجام پیش‌بینی دقیق بار و قیمت را دچار مشکل می‌کند، تأثیرپذیری الگوی بار از عوامل مختلف و غیرخطی بودن سیگنال قیمت برق می‌باشد؛ بنابراین استفاده از الگوریتم‌های هوشمند نسبت به روش‌های عددی و آماری کاربرد بیشتری در مسائل پیش‌بینی پیدا کرده است. روش‌های هوشمند به دلیل سادگی، عدم نیاز به مدل ریاضی دقیق و محاسبات کم جایگزین خوبی برای سایر روش‌ها به شمار می‌آیند [5].

نگرانی اصلی هر صنعت الکتریکی توانایی تولید قابل اطمینان و خدمت‌رسانی بدون وقفه به مصرف کنندگان خود است. برخلاف دیگر کالاها، انرژی الکتریکی به دلیل ماهیت طبیعی خود، به محض تولید باید مصرف شود که در غیر این صورت بابت تولید، تولیدکننده پولی دریافت نمی‌کند. بنابراین ایجاد طرح منابع مؤثر و مطمئن امری ضروری است. عملکردهایی مانند تعیین قیمت سوخت، برنامه‌ریزی ورود و خروج واحدهای تولیدی، همانند برنامه‌ریزی تعمیرات، باید تا حد امکان جهت کم کردن هزینه عملکرد سیستم، انجام شود [6].

تأثیر خطای بزرگ پیش‌بینی در قسمت بهره‌برداری در ریسک بالا و یا بهره‌برداری فوق محافظه کارانه منعکس می‌شود. از جمله اثرات خطای پیش‌بینی می‌توان به ورود بیش از نیاز واحدهای تولیدی و یا خرید انرژی از سیستم‌های همسایه و یا بالعکس فروش انرژی به قیمت بسیار ناچیز جهت خاموش نکردن واحد و جلوگیری از هزینه‌های سنگین راه اندازی، اشاره کرد [7].

با سمت‌گیری و تغییر ساختار بازار برق از بازار انحصاری دولتی به بازار رقابتی که در آن میزان تقاضا توسط نیروهای بازار تعیین می‌شود، نیاز به طراحی مدلی کارا و مناسب به گونه‌ای که ریسک شرکت در بازار رقابتی برای فعالان بازار برق را در جهت افزایش سوددهی آنها کاهش دهد، اهمیت ویژه‌ای یافته است. برای مدل‌سازی و پیش‌بینی بار در بازار رقابتی باید خصوصیات این کالا از جمله فصلی بودن تقاضا را در نظر گرفت. مدل ایجاد شده در صورتی که بتواند با ایجاد رابطه‌ای از داده‌های قبلی، کمترین خطای پیش‌بینی را داشته باشد، موثرتر و کارآمدتر خواهد بود. از جمله فاکتورهای تأثیرگذار بر قیمت برق عبارتند از [8]:

- قیمت‌های روزهای قبل: همانطور که می‌دانیم قیمت‌های روزهای قبل هر کالایی بر قیمت‌های روزهای بعد تأثیرگذار است.
- بار: با افزایش مصرف، تولیدکنندگان سعی در افزایش قیمت انرژی را دارند و بالعکس.
- آب و هوا: در فصل‌های مختلف سال که از آب و هوای مختلفی برخوردارند، قیمت انرژی متفاوت است.

- اقتصادی: مسائل مختلف مالی از جمله قیمت سوخت، هزینه تعمیرات و نگهداری ژنراتورها، خطوط توزیع و انتقال، بحران های مالی و تورم جهانی قیمت، از دیگر فاکتورهای تأثیرگذار بر قیمت آینده سیستم است که به دلیل پیچیدگی های آن و محدودیت های موجود، از این فاکتور در این پروژه صرف نظر می کنیم.
- فاکتورهای تصادفی: بعضی فاکتورهای تصادفی مانند مسابقات بزرگ جهانی و یا شرایط ناگهانی زمینی جوی وجود دارند که ممکن است بر قیمت تأثیرگذار باشند.
- فرار بودن قیمت: یکی از دلایلی که پیش بینی قیمت را مشکل می کند فرار بودن قیمت است. فرار بودن قیمت بدین معنی است که قیمت کالایی در یک ساعت مشخص از یک مقدار معین به دلیل بعضی عوامل محیطی ناگهان به چندین برابر مقدار خود در ساعت بعد می رسد.

از جمله دلایل فراریت و ایجاد قله ها و دره ها در منحنی قیمت به صورت زیر دسته بندی می شود [9]:

- فرار بودن قیمت سوخت
- عدم قطعیت دربار
- بی ثباتی در تولیدهای آبی
- خروج واحدهای تولیدی (عدم قطعیت در تولید)
- تراکم در خط
- رفتار شرکت کنندگان بازار
- دست کاری بازار (توان بازار، ریسک طرف مقابل)

در گذشته الگوریتم های متعددی که وابسته به تحلیل های آماری بود جهت پیش بینی قیمت به کار گرفته می شد. مدل های پیش بینی قیمت را می توان به دو روش گسترده تقسیم کرد. روش اول پارامتری است که در آن ارتباط میان قیمت و فاکتورهای تأثیرگذار بر قیمت، صراحتاً فرمول بندی می شوند. در روش دیگر داده های گذشته قیمت جهت شکل گیری یک مدل قیمت به کار گرفته می شوند، و بدین ترتیب قیمت آینده را می توان به وسیله محاسبه رگرسیون قیمت های گذشته بدست آورد [10]. در سالهای اخیر پژوهش های زیادی در این زمینه انجام شده است.

در پژوهش Gulesin و همکاران یک شبکه عصبی مبتنی بر بهینه سازی ازدحام ذرات جهشی (PSOM-NN) به منظور افزایش دقت پیش بینی تقاضا انرژی در ترکیه ارائه شده است. برخلاف برخی از مطالعات انجام شده که تمامی داده ها را به منظور آموزش شبکه بکار می گیرند، در شبکه پیشنهادی تنها بخشی از این داده ها برای آموزش استفاده شده است. بنابراین حدود 63٪ و 37٪ از داده های مذکور برای آموزش و آزمون به ترتیب استفاده شده است. تجزیه و تحلیل نتایج نشان داد که پیش بینی تقاضای انرژی توسط الگوریتم PSOM-NN در مقایسه با مطالعات قبلی از نظر جذر میانگین مربعات خطا، درصد خطای مطلق و انحراف مطلق میانگین بهتر بوده است. در نهایت، در این مطالعه پیش بینی آینده تحت سناریوهای مختلف نیز ارائه شده و مورد بحث قرار گرفته است [11].

در پژوهش Kankal و همکاران عملکرد یک شبکه عصبی مصنوعی با الگوریتم بهینه سازی براساس آموزش- یادگیری را برای مدل سازی تقاضای انرژی الکتریکی در ترکیه مورد مطالعه قرار گرفته شده است. همچنین شبکه عصبی مبتنی بر TLBO با شبکه عصبی ترکیبی براساس الگوریتم پس انتشار و شبکه عصبی براساس الگوریتم کلونی مورچگان مقایسه شده است. در این مطالعه تولید ناخالص داخلی، جمعیت، واردات، صادرات به عنوان متغیرهای مستقل مدل انتخاب شده است. نتایج ارائه شده، نشان می دهد که مدل شبکه عصبی مبتنی بر TLBO عملکردی بهتر از شبکه عصبی مبتنی بر الگوریتم پس انتشار و الگوریتم کلونی مورچگان در تخمین تقاضای انرژی الکتریکی دارد. جذر میانگین مربعات خطا از مقدار 42.3 درصد توسط شبکه عصبی مبتنی بر الگوریتم پس انتشار و الگوریتم کلونی مورچگان به مقدار 39.3 درصد توسط مدل شبکه عصبی مبتنی بر TLBO کاهش یافته است. سناریوهای مختلف طی یک دوره 6 ساله (2013-2018) پیش بینی مورد مطالعه قرار گرفته است [12].

در پژوهش Kumarana و همکاران یک مدل ترکیبی شامل شبکه‌های عصبی مصنوعی و مبتنی بر الگوریتم بهینه‌سازی بیولوژیکی برای پیش‌بینی طولانی مدت تقاضای انرژی الکتریکی در هند ارائه شده است. این پیش‌بینی براساس شاخص‌های اجتماعی و اقتصادی، از جمله جمعیت و سرانه تولید ناخالص داخلی و با استفاده از دو شبکه عصبی مصنوعی بدست آمده است، این شبکه‌های عصبی مصنوعی از طریق یک الگوریتم بهینه‌سازی بیولوژیکی با هدف برازش کامل داده‌های ورودی و خروجی در فضا غیر خطی توسط به دست آوردن بهترین پارامترهای وزنی آموزش دیده‌اند. آموزش شبکه عصبی مصنوعی براساس بهینه‌سازی مبتنی بر الگوریتم بیولوژیکی دقت و صحت پیش‌بینی را بهبود می‌بخشد و از به دام افتادن در مینیمم‌های محلی جلوگیری می‌کند. علاوه بر این همگرایی به پایین‌ترین جذر میانگین خطا در حداقل تعداد تکرارها را افزایش می‌دهد. مدل نیاز به یک ورودی و سال از پیش‌بینی برای تقاضای انرژی دارد. پیش‌بینی انجام شده تا سال 2025 با مدل شبکه عصبی مصنوعی آموزش دیده توسط پس انتشار و مدل شبکه عصبی مصنوعی آموزش دیده توسط الگوریتم جستجوی هارمونی از لحاظ اثربخشی مقایسه شده است [13].

در پژوهش برزین‌پور و همکاران ضمن تحلیل عوامل موثر بر تقاضای برق خانگی، با استفاده از روش شبکه عصبی مصنوعی، مدلی با هدف شناخت الگوی مصرف برق خانگی ایجاد و با تعریف پنج سناریوی مختلف قیمتی، میزان مصرف تا سال آخر اجرای قانون هدفمندی یارانه‌ها پیش‌بینی شده است. سرانه مصرف برق خانگی، به عنوان متغیر وابسته مدل در نظر گرفته شده است و عواملی چون قیمت برق، درآمد سرانه ملی، شاخصی به نمایندگی از تعداد روزهای گرم سال و ساختار اقتصادی کشور به عنوان عوامل موثر بر آن انتخاب شده است. با توجه به نتایج به دست آمده از مدل که قابلیت توضیح بسیار خوبی داشته $R=0.996$ عوامل قیمتی نقش بسیار کمی در تعیین الگوی مصرف دارند. بنابراین اجرای طرح‌هایی از سوی سیاست‌گذاران این عرصه، به منظور تغییر قابل توجه قیمت برای اصلاح الگوی مصرف ضروری به نظر می‌رسد [14].

در مدل‌های کلاسیک ارائه شده در پیش‌بینی بار در بازار برق با تنوع تعداد متغیرهای ورودی و عدم پیروی متغیرها از یک مدل سری مشخص، خطای ناشی از پیش‌بینی افزایش خواهد یافت. بنابراین اخیراً، علاقه‌مندی الگوریتم‌های به کار گرفته شده جهت کنترل مسائل پیش‌بینی به سمت روش‌هایی تمایل پیدا کرده که شبکه‌های عصبی مصنوعی¹ (ANNs) نامیده می‌شوند. به دلیل کارایی بالا در طبقه بندی، تخمین تابع و مسائل نگاشتی، شبکه‌های عصبی به طور گسترده جهت مسائل پیش‌بینی به کار گرفته می‌شوند. خاصیت جالب شبکه‌های عصبی توانایی یادگیری خواص قیمت است که عموماً یا نمی‌توان آن را تعیین کرد و یا به محاسبات پیچیده‌ای جهت کشف آن نیاز است. گسترش تکنولوژی کامپیوترها توانایی گسترده‌ای را برای ترکیب روش‌ها در یک جا و یک زمان فراهم کرده است [15].

از اینرو در این تحقیق به منظور پیش‌بینی بار و قیمت برق در بلند مدت با کمترین خطای پیش‌بینی و برطرف کردن نواقص روش‌های قبلی، از روشی ترکیبی شبکه استنتاج فازی عصبی تطبیقی (ANFIS) مبتنی بر الگوریتم آموزش و یادگیری (TLBO) استفاده خواهد شد. در این روش در واقع با ترکیب الگوریتم‌های تکاملی با سیستم عصبی فازی سعی شده است تنظیم مقادیر بهینه پارامترهای شبکه عصبی فازی تطبیقی (که این پارامترها عبارتند از مرکز و میزان پراکندگی توابع عضویت فازی ورودی‌های شبکه و همچنین ضرایب وزنی خروجی)، به الگوریتم بهینه‌سازی هوشمند آموزش و یادگیری محول شود. هدف از بکارگیری این رویکرد بهبود عملکرد شبکه و کاهش پیچیدگی‌های محاسباتی در مقایسه با روش‌های گرادینان نزولی و حداقل مربعات می‌باشد [16-17]. همچنین از جمله فاکتورهای در نظر گرفته شده برای پیش‌بینی قیمت برق در این تحقیق عبارتند از: 1) قیمت‌های روزهای قبل، 2) بار مصرفی، 3) آب و هوا، 5) فاکتورهای تصادفی، 6) فرار بودن قیمت

¹ Artificial Neural Networks

2. مدل شبکه عصبی تطبیقی فازی مبتنی بر الگوریتم‌های بهینه‌سازی پیشنهادی جهت پیش‌بینی کوتاه مدت بار

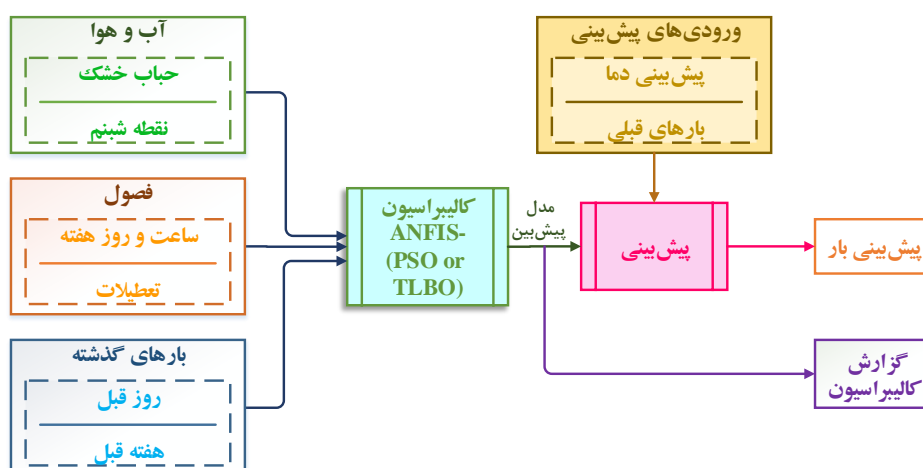
در حال حاضر، انواع مختلفی از معماری‌ها جهت پیش‌بینی بار مورد استفاده قرار می‌گیرد. دستورالعمل‌های تئوری بسیار کمی در انتخاب ورودی‌های مؤثر وجود دارد. برای انتخاب ورودی مؤثر، قانون خاصی وجود ندارد و انتخاب ورودی‌ها بیشتر به قضاوت مهندسی و تجربه وابسته می‌باشد و بایستی محقق خود در مورد رفتار سیستم مورد مطالعه و عوامل و شرایط مؤثر بر خروجی اطلاعات و دانش کسب کند اما در عین حال بعضی از مطالعات آماری در تعیین متغیرهایی با تأثیر بیشتر بر بار سیستم مؤثر باشد. توجه به پارامترهای مؤثر بر روی الگوی بار مصرفی مانند بار مصرفی گذشته، متغیرهای آب و هوایی (مانند میزان رطوبت، دما، گرد و غبار و سرعت باد)، روزهای هفته و فصول سال می‌تواند در تعیین ورودی‌ها نقش اساسی داشته باشد. میزان تقاضا در فصول مختلف متفاوت است. در فصل‌های سرد به علت نیاز به آب گرم و وسایل گرمایشی برقی و در فصل‌های گرم به علت نیاز به تهویه مناسب تقاضا بیشتر می‌شود.

یکی دیگر از عواملی که مستقیماً بر بار هر روز اثر دارد، کاری یا غیر کاری بودن روزهای هفته است. تأثیر این عامل به حدی است که در پروفیل بار و مقدار پیک بار در روزهای تعطیل و غیر تعطیل قابل مشاهده است.

برای پیش‌بینی بار، ماتریس ورودی شبکه پیشنهادی شامل عوامل زیر است:

- (1) درجه حرارت خشک²
- (2) دمای نقطه شبنم³
- (3) ساعات روز
- (4) ورودی برای مشخص شدن روز هفته (یک ورودی با مقدار 1 و یا صفر که بیانگر تعطیل بودن و یا نبودن روز مورد پیش‌بینی می‌باشد).
- (5) تعطیلات و شاخص آخر هفته (0 یا 1)
- (6) میزان بار متوسط مصرفی 24 ساعت قبل
- (7) میزان بار مصرفی 24 ساعت روز قبل
- (8) میزان بار مصرفی هفته قبل (168 ساعت قبل)

مدل شبکه پیشنهادی در شکل (1) نشان داده شده است.



شکل 1: مدل شبکه عصبی تطبیقی فازی مبتنی بر الگوریتم‌های بهینه‌سازی پیشنهادی جهت پیش‌بینی کوتاه مدت بار

² Dry-bulb temperature

³ Dew point temperature

2-1- پیش‌بینی قیمت برق با استفاده از مدل شبکه عصبی تطبیقی فازی مبتنی بر الگوریتم‌های

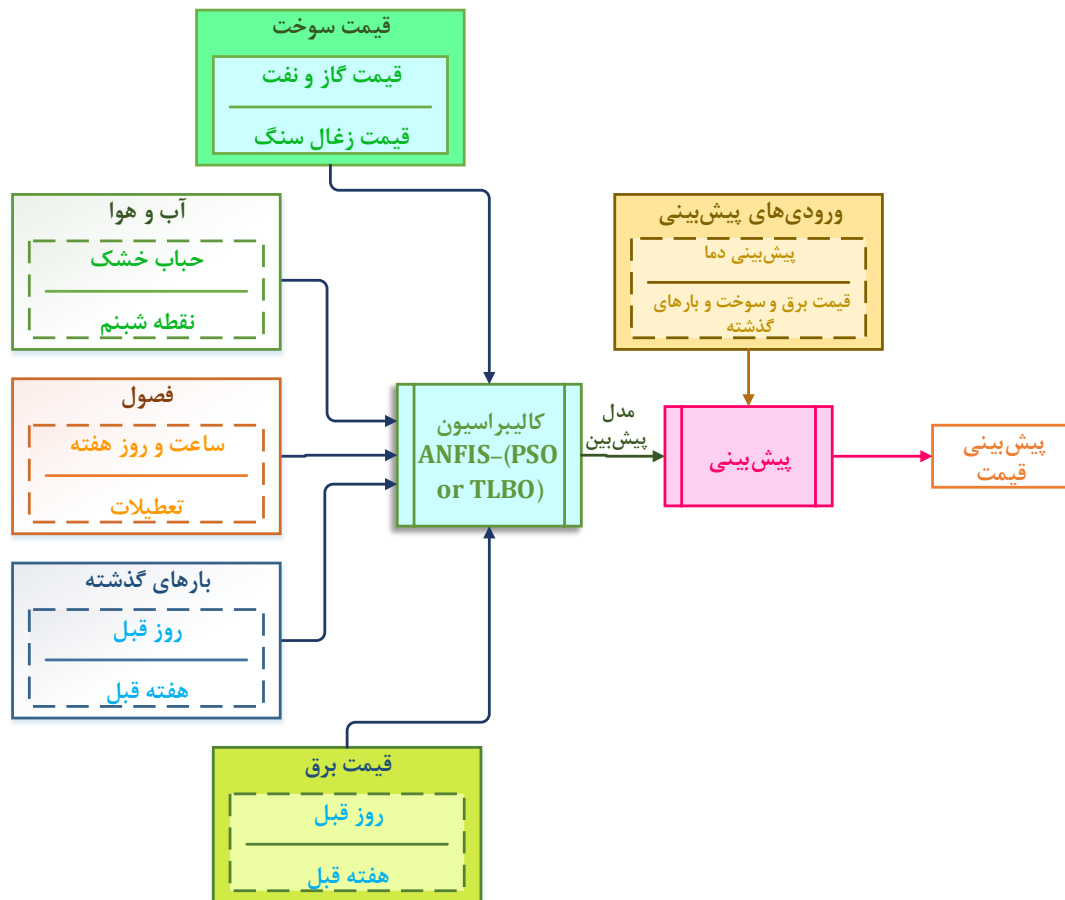
بهینه‌سازی پیشنهادی

به‌طور کلی مراحل طراحی یک سیستم هوشمند مبتنی بر شبکه عصبی مصنوعی تطبیقی فازی برای پیش‌بینی را به چهار مرحله زیر تقسیم نمود:

- (1) پیش‌پردازش داده‌ها
- (2) طراحی شبکه
- (3) پیاده‌سازی شبکه
- (4) تأیید شبکه

یکی از عوامل مؤثر بر قیمت انرژی الکتریکی، بار مصرفی می‌باشد. بنابراین در پیش‌بینی قیمت انرژی الکتریکی، بار مصرفی و قیمت انرژی الکتریکی را به عنوان ورودی شبکه تعریف خواهد شد. برای پیش‌بینی قیمت، ماتریس ورودی شامل عوامل زیر است:

- (1) درجه حرارت خشک
- (2) دمای نقطه شبنم
- (3) ساعات روز
- (4) ورودی برای مشخص شدن روز هفته (یک ورودی با مقدار 1 و یا صفر که بیانگر تعطیل بودن و یا نبودن روز مورد پیش‌بینی می‌باشد).
- (5) تعطیلات و شاخص آخر هفته (0 یا 1)
- (6) میزان بار متوسط مصرفی 24 ساعت قبل
- (7) میزان بار مصرفی 24 ساعت روز قبل
- (8) میزان بار مصرفی هفته قبل (168 ساعت قبل)
- (9) قیمت گاز طبیعی لحظه‌ای
- (10) قیمت گاز طبیعی گذشته
- (11) قیمت برق گذشته



شکل 2: مدل شبکه عصبی تطبیقی فازی مبتنی بر الگوریتم های بهینه سازی پیشنهادی جهت پیش بینی کوتاه مدت قیمت

3. نتایج مدل سازی

در این بخش به بررسی عملکرد روش پیشنهادی جهت پیش بینی قیمت و بار با استفاده از ANFIS-PSO و ANFIS-TLBO پرداخته می شود. سپس نتایج بدست آمده با روش های ANFIS، روش مبتنی بر شبکه های عصبی (ANN) و روش پیش بین ترکیبی ANFIS مبتنی بر الگوریتم بهینه سازی کلونی زنبور عسل مقایسه می گردد [18].

3-1- معیار ارزیابی

به منظور بررسی عملکرد روش های ارایه شده ANFIS-PSO و ANFIS-TLBO نیازمند حصول اطمینان از روش ارایه شده هستیم. هرچه ارزیابی عملکرد روش پیشنهادی دقیق تر باشد، تحلیل نتایج و اطمینان از درستی رویکرد نیز به مراتب بیشتر خواهد بود. در این تحقیق، برای ارزیابی رویکرد پیشنهادی ANFIS-PSO و ANFIS-TLBO از معیارهایی مانند میانگین قدر مطلق خطا (MAE)، میانگین قدر مطلق خطای درصدی (MAPE4) و قدر مطلق درصد خطای روزانه (DMAPE5) استفاده شده است، که به ترتیب در روابطه (1) تا (3) تعریف شده اند.

$$MAE = \frac{1}{N} \sum_{i=1}^N |Actual_i - Forecast_i| \quad (1)$$

⁴ Mean Absolute Percentage Error

⁵ Day Mean Absolute Percentage Error

$$MAPE = \frac{1}{N} \sum_{i=1}^N \frac{|Actual_i - Forecast_i|}{Actual_i} \times 100 \quad (2)$$

$$DMAPE = \frac{1}{24} \sum_{i=1}^{24} \frac{|Actual_i - Forecast_i|}{\sum_{t=1}^{24} Actual_t} \times 100 \quad (3)$$

که در این رابطه، N تعداد نمونه‌های پیش‌بینی شده و یا واقعی، $Actual$ مقدار واقعی و $Forecast$ مقدار پیش‌بینی شده می‌باشد. این روابطه برای پیش‌بینی بار کارآمد است.

3-2- مجموعه داده‌ی بازار نیوانگلند

در پیاده‌سازی روش پیشنهادی از مجموعه داده‌ی بازار نیوانگلند، که در طی سال‌های 2004 تا 2008 گردآوری شده است، بهره گرفته شده است [19]. این مجموعه شامل 9 ویژگی از 17544 نمونه از داده‌ها می‌باشد که 8 ویژگی زیر بعنوان ورودی شبکه پیش‌بین و ویژگی نهم (بار یا قیمت برق) بعنوان خروجی در نظر گرفته می‌شود.

- (1) درجه حرارت خشک⁶
- (2) دمای نقطه شبنم⁷
- (3) ساعات روز
- (4) ورودی برای مشخص شدن روز هفته (یک ورودی با مقدار 1 و یا صفر که بیانگر تعطیل بودن و یا نبودن روز مورد پیش‌بینی می‌باشد).
- (5) تعطیلات و شاخص آخر هفته (0 یا 1)
- (6) میزان بار متوسط مصرفی 24 ساعت قبل
- (7) میزان بار مصرفی 24 ساعت روز قبل
- (8) میزان بار مصرفی هفته قبل (168 ساعت قبل)
- (9) مقدار پارامترهای مورد نظر برای شبیه‌سازی

در جدول (1) مقدار پارامترها برای پیاده‌سازی الگوریتم ANFIS-PSO آورده شده است. مقدار پارامتر بیشترین سرعت ایجاد شده توسط سایر ذرات (V_{max}) برابر با 1.2 گرفته شده است. همچنین مقدار پارامتر وزن اینرسی حرکت ایجاد شده وزن اینرسی حرکت (w) را در ابتدا برابر 0.8 با لحاظ شده است، تا برقابلیت پویا تاکید داشته باشیم. این دو پارامتر میزان تاثیر حرکت قبلی ایجاد شده توسط سایر ذرات را کنترل می‌کنند. در طول تکرارهای برنامه این پارامتر نهایتاً به صورت خطی به مقدار 0.1 کاهش می‌یابند تا از خاصیت انتفاع بهره ببریم. زیرا در انتها به جواب برنامه نزدیک شده‌ایم و نیازمند تغییرات کوچک در مقدار جابجایی هستیم.

همچنین در اینجا ضریب یادگیری شخصی و گروهی بصورت خطی تغییر کنند، بطوری که c_1 کاهش و c_2 افزایش داده شود. این استراتژی بر روی جستجوی عمومی ذرات در فضای جستجو در ابتدای الگوریتم تاکید دارد و در انتهای الگوریتم به جستجوی محلی ذرات اهمیت داده و ذرات به سمت بهترین موقعیت ملاقات شده گروه جذب می‌شوند. مقادیر اولیه این ضرایب برابرند با $c_1(0) = 2, c_2(0) = 1$ و درنهایت به مقادیر $c_1 = 1, c_2 = 2$ تغییر می‌یابند.

تعداد ذرات (N) برابر با 50 لحاظ شده است، زیرا طبق آزمایشات تعداد بیشتر ذرات، تاثیری در بهبود دقت ندارد و فقط زمان اجرای برنامه افزایش می‌یابد. مقدار پارامتر تعداد دفعات اجرای الگوریتم ذرات برابر با 1500 در نظر گرفته شده است. این مقدار براساس چندین آزمایش و به صورت آزمایش و خطا به دست آمده است. مقدار بیشتر برای تکرارها منجر به آموزش بیش از حد و مقدار کمتر منجر به آموزش ناکامل می‌شود. مانند تمامی الگوریتم‌های تکاملی هوشمند دیگر به دلیل بکارگیری پارامترهای

⁶ Dry-bulb temperature

⁷ Dew point temperature

تصادفی با یکبار اجرای برنامه نمی‌توان به درستی نتایج استناد کرد، به همین دلیل برنامه 10 بار اجرا شده و با میانگین‌گیری از نتایج به دست آمده، اطلاعات دقیق‌تر و قابل اعتمادتری ارائه شده است.

به منظور پیاده‌سازی الگوریتم ANFIS-TLBO مقادیر مشخصات شبکه در جدول (2) آورده شده است. همانگونه که قبلاً نیز گفته شد، یکی از مهمترین ویژگی‌های الگوریتم TLBO، عدم وابستگی به پارامترهاست. زیرا این الگوریتم، کمترین تعداد پارامتر ممکن را دارد و از این نظر، می‌تواند یک امتیاز ویژه را داشته باشد. از اینرو همانطور که در جدول (5-2) مشاهده می‌گردد، تنها پارامتر مورد نیاز در الگوریتم TLBO ضریب یادگیری است که در این تحقیق بطور تصادفی با احتمال یکسان مقادیر 1 یا 2 را انتخاب می‌کند.

جدول 1: مقدار پارامترهای پیاده‌سازی روش ANFIS-PSO

پارامترها	مقدار
تعداد کل داده‌ها	52608
تعداد داده‌ها برای آموزش شبکه	34896
تعداد ورودی‌ها	8
تعداد خروجی‌ها	1
تعداد مجموعه‌های فازی به ازای هر ورودی	3
اندازه هر کدام از جمعیت‌های P_a, P_c, P_α	50
تعداد دفعات اجرای الگوریتم PSO	$Nt = 1500$
وزن اینرسی	$w(0) = 0.8$
ضریب یادگیری شخصی	$c_1(0) = 2$
ضریب یادگیری گروهی	$c_2(0) = 1$
حداکثر سرعت ذره	$V_{max} = 1.2$

جدول 2: مشخصات الگوریتم ANFIS-TLBO

پارامترها	مقدار
تعداد کل داده‌ها	52608
تعداد داده‌ها برای آموزش شبکه	34896
تعداد ورودی‌ها	8
تعداد خروجی‌ها	1
تعداد مجموعه‌های فازی به ازای هر ورودی	3
اندازه هر کدام از جمعیت‌های P_a, P_c, P_α	50
تعداد دفعات اجرای الگوریتم TLBO	۱۰۰۰
ضریب یادگیری	{1,2}

3-3- صحت عملکرد روش پیشنهادی

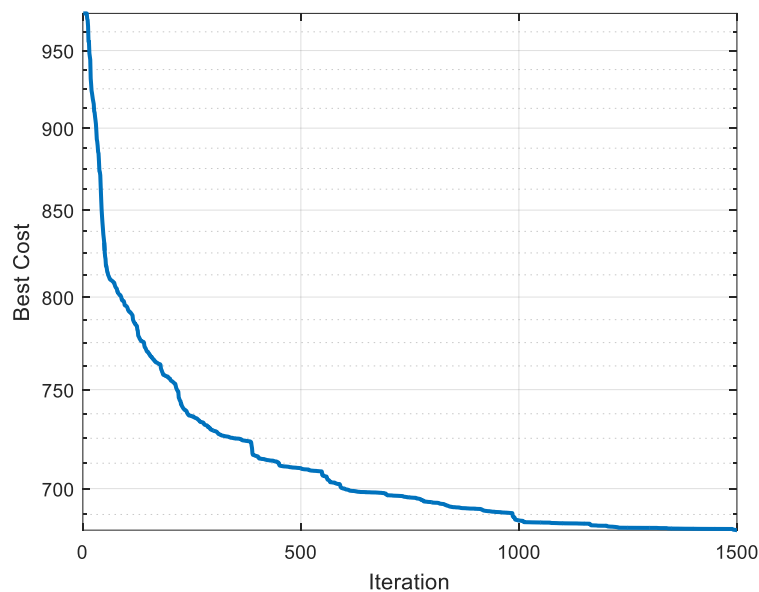
روش پیشنهادی ANFIS-TLBO و ANFIS-PSO در این تحقیق با نرم افزار متلب وژن 2015 پیاده‌سازی شده است. صحت روش‌های پیشنهادی با مقایسه نتایج ارائه شده در مقالات مختلف ارزیابی شده است.

3-3-1- پیش‌بینی بار برای بازار نیوانگلند توسط شبکه ANFIS-PSO

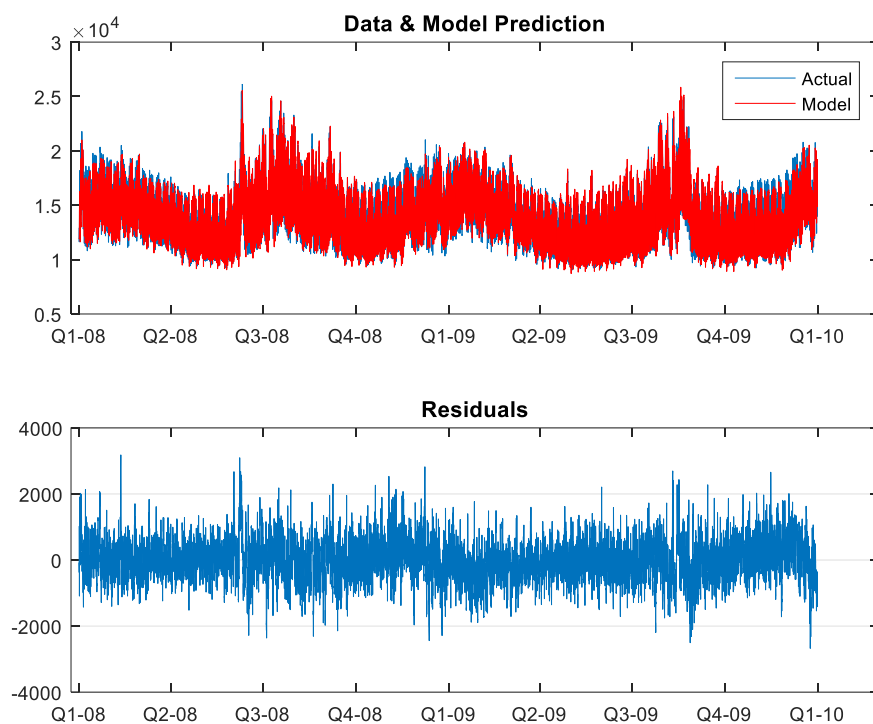
به منظور شبیه‌سازی و پیش‌بینی بار و قیمت با الگوریتم ANFIS-PSO از سیستم نیوانگلند به عنوان یک بازار واقعی استفاده شده است. علت این انتخاب به خاطر واقعی بودن اطلاعات و دسترسی آن می‌باشد. شکل (3) همگرایی تابع هزینه به هنگام آموزش شبکه ANFIS-PSO را نشان می‌دهد، در این شکل دیده می‌شود که بعد از 1000 تکرار الگوریتم آموزش دیده است و تغییرات تابع هزینه آن ناچیز است.

شکل (4) تغییرات پیش‌بینی بار و مقدار پیش‌بینی شده توسط روش پیشنهادی در طول دو سال نشان می‌دهد. در این شکل به وضوح دیده می‌شود خطای پیش‌بینی در حدود 2 MWh بوده است که مقدار ناچیزی است.

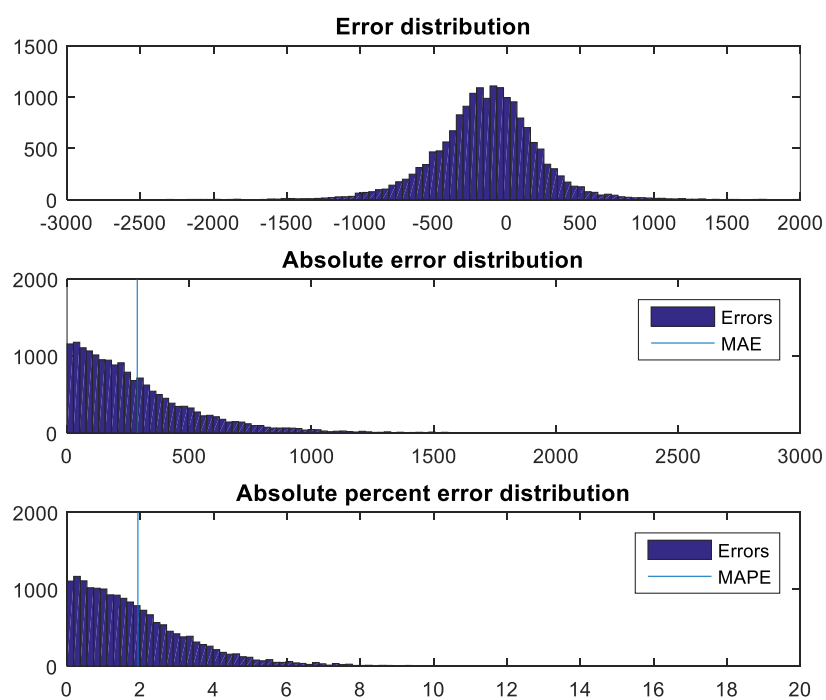
الگوریتم پیشنهادی دارای کارایی بالای سرعت مناسب و دقت بالا می‌باشد. برای نشان دادن کارایی روش پیشنهادی از معیارهایی مانند میانگین قدر مطلق خطای درصدی (MAPE) و یا میانگین قدر مطلق خطا (MAE) استفاده شده است که روابط آن در فصل قبل تعریف گردید. مقدار بدست آمده برای معیارهای MAPE، MAE و DMAPE به ترتیب 1.93، 287.215 MWh و 1.87 می‌باشد. نتایج بدست آمده نشان از کارایی و دقت مناسب برای مساله پیش‌بینی را به همراه دارد. شکل (5) نحوه تغییرات خطا و معیارهای مورد نظر را نشان می‌دهد. شکل (6) تغییرات خطای ایجاد شده در پیش‌بینی بار ساعتی را نشان می‌دهد. پیوستگی مناسب در محدوده کم نشان از دقت بالای این روش پیشنهادی می‌باشد. همچنین به منظور مقایسه کارایی روش پیشنهادی انجام پیش‌بینی میان مدت به وسیله الگوریتم پیشنهادی، شبکه عصبی در طول یک هفته انجام گرفته است. نتایج شبیه‌سازی در شکل (7) نشان داده شده است. منظور نشان دادن کارایی بالای روش پیشنهادی، دوره زمانی را در یک سال افزایش داده یا به عبارتی پیش‌بینی بلند مدت انجام می‌دهیم. پیش‌بینی بار برای یک هفته از سال 2008 در بازار نیوانگلند نیز در شکل (8) ارایه شده است.



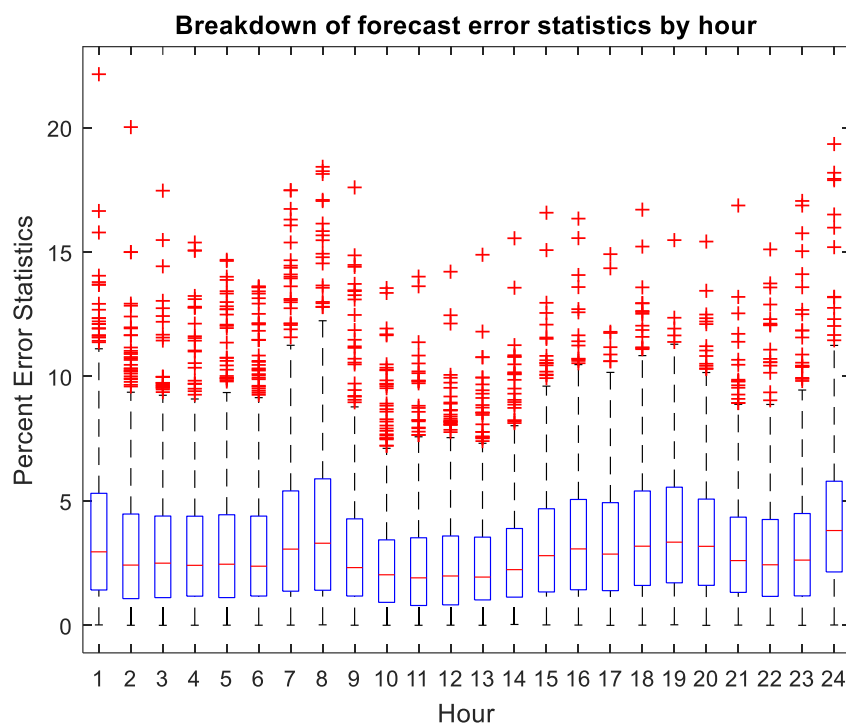
شکل 3: همگرایی تابع هزینه به هنگام آموزش شبکه ANFIS-PSO



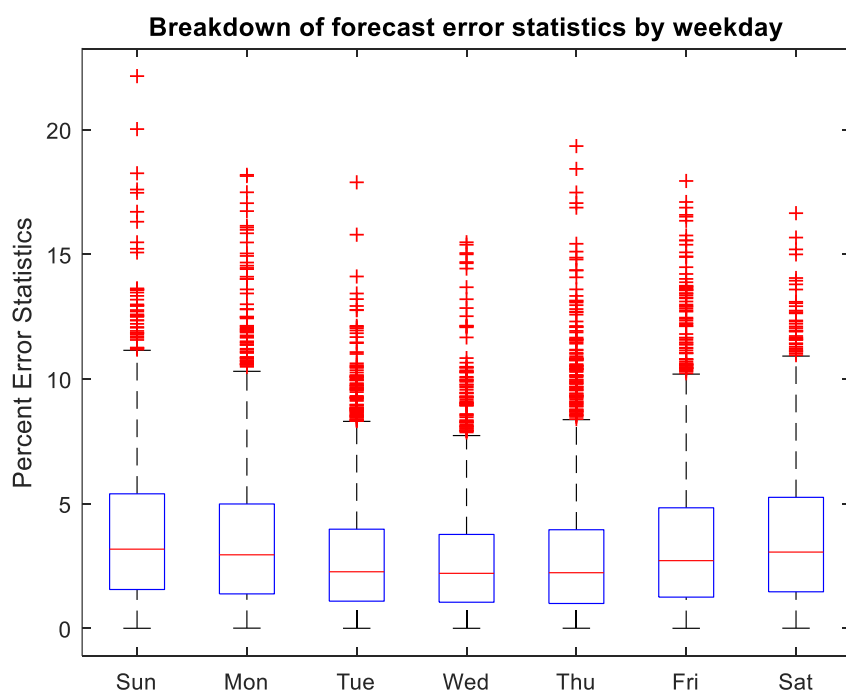
شکل 4: تغییرات بار ساعتی و پیش‌بینی آن توسط الگوریتم ANFIS-PSO در طول دو سال



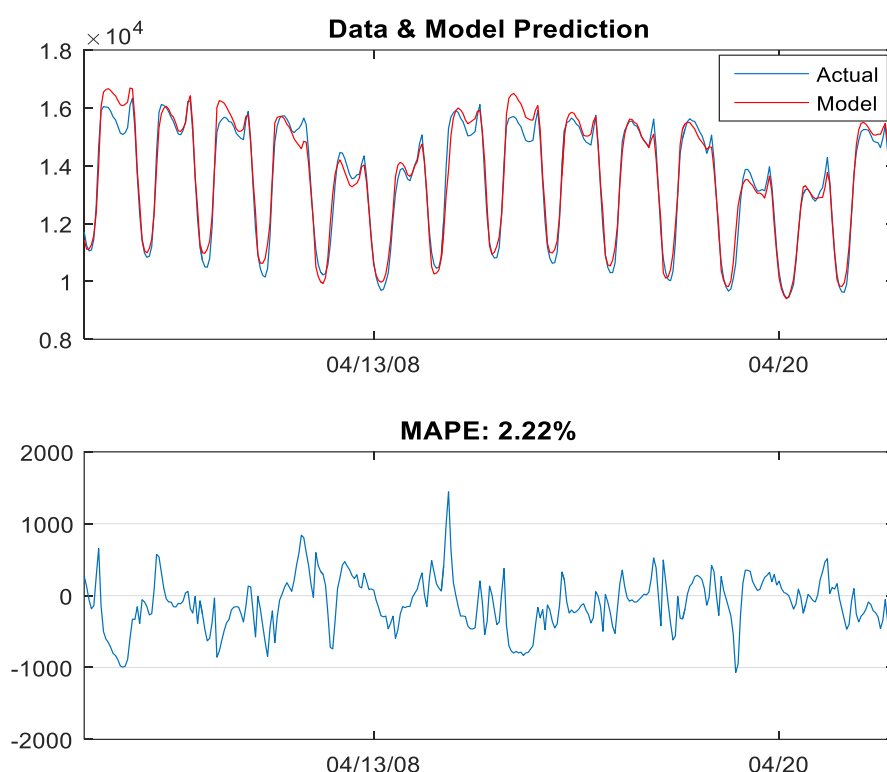
شکل 5: نحوه توزیع خطا حاصل از پیش‌بینی بار برای معیارهای معرفی شده براساس الگوریتم ANFIS-PSO



شکل 6: نحوه توزیع خطای حاصل از پیش‌بینی برای بار ساعتی براساس الگوریتم ANFIS-PSO



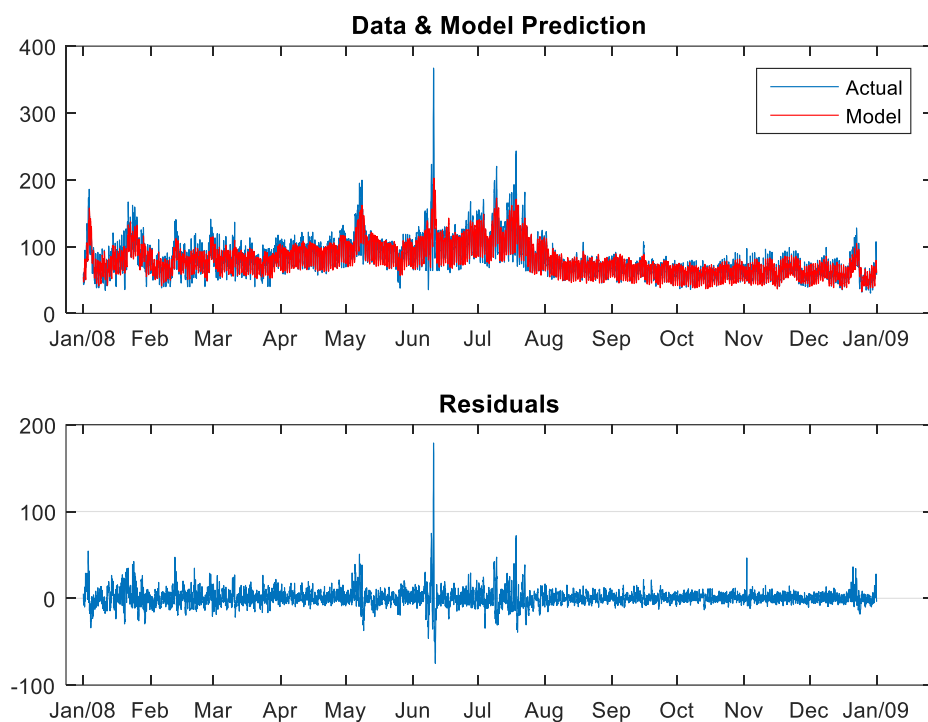
شکل 7: نحوه توزیع خطای پیش‌بینی برای بار روزانه براساس الگوریتم ANFIS-PSO



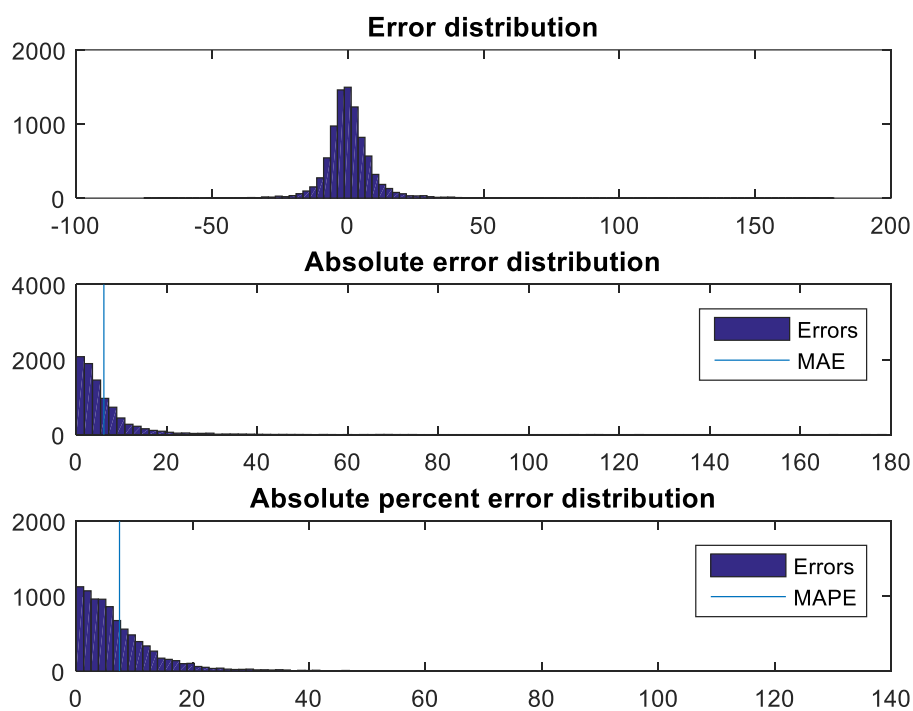
شکل 8: پیش‌بینی بار برای یک هفته از سال براساس الگوریتم ANFIS-PSO

3-3-2- پیش‌بینی قیمت برق برای بازار نیوانگلند توسط شبکه ANFIS-PSO

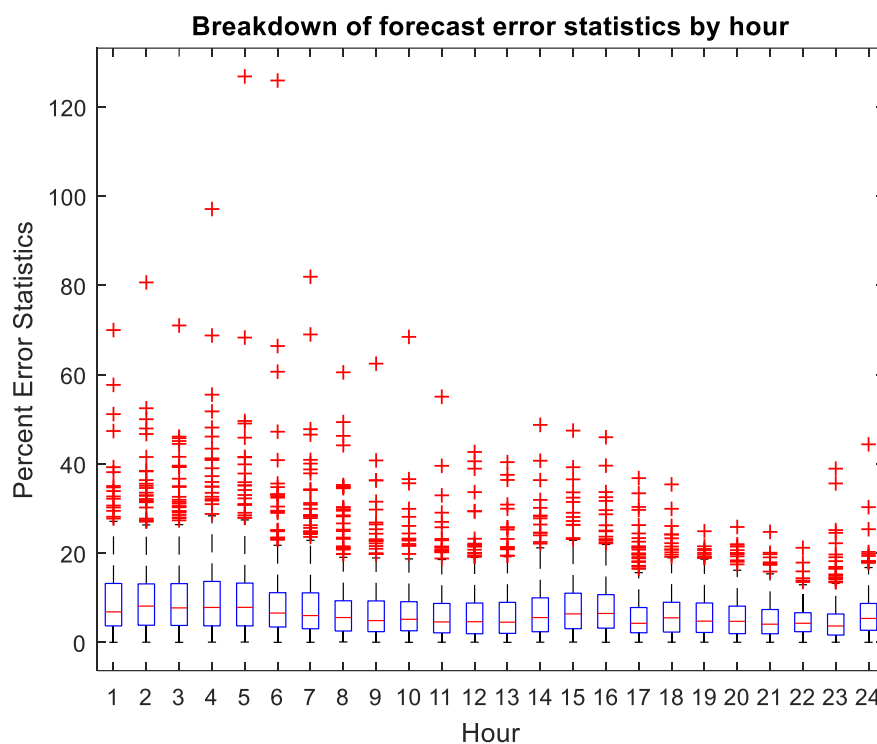
شکل (9) تغییرات قیمت برای سیستم نیوانگلند برای کلیه ساعت‌های سال 2008 را نشان می‌دهد. برای پیش‌اطلاعات 50 روز قبل آن گرفته شده و بعد از آرایش دهی بر روی داده‌های ورودی 13 کاندید برای آموزش وارد شبکه ANFIS-PSO شده‌اند. در این شکل دیده می‌شود حداکثر خطای پیش‌بینی در حدود 200 است که نسبتاً زیاد است. برای ارزیابی کارایی روش پیشنهادی در این مورد نیز از معیارهایی مانند میانگین قدر مطلق خطای درصدی (MAPE) و یا میانگین قدر مطلق خطا (MAE) استفاده شده است که روابط آن در فصل قبل تعریف گردید. مقدار بدست آمده برای معیارهای MAPE، MAE و DMAPE به ترتیب 6.93، 10 و 5.02 می‌باشد. نتایج بدست آمده نشان از کارایی و دقت قابل قبول برای مساله پیش‌بینی را به همراه دارد. شکل (10) نحوه تغییرات خطای پیش‌بینی قیمت را با معیارهای مورد نظر را نشان می‌دهد. شکل (11) تغییرات خطای ایجاد شده در پیش‌بینی قیمت ساعتی را نشان می‌دهد. پیوستگی مناسب در محدوده کم نشان از دقت بالای این روش پیشنهادی می‌باشد. همچنین به منظور مقایسه کارایی روش پیشنهادی انجام پیش‌بینی میان مدت به وسیله الگوریتم پیشنهادی، شبکه عصبی در طول یک هفته انجام گرفته است. نتایج شبیه‌سازی در شکل (12) نشان داده شده است. به منظور نشان دادن کارایی روش پیشنهادی، دوره زمانی را در یک سال افزایش داده یا به عبارتی پیش‌بینی بلند مدت انجام می‌دهیم. پیش‌بینی قیمت برای یک هفته از سال 2008 در بازار نیوانگلند نیز در شکل (13) ارایه شده است.



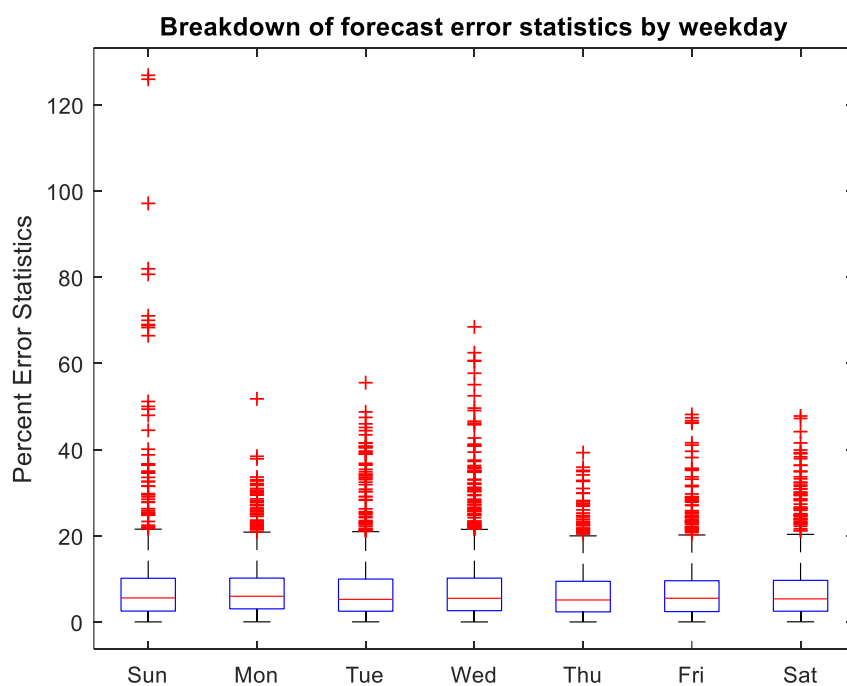
شکل 9: تغییرات قیمت ساعتی و پیش‌بینی آن توسط الگوریتم ANFIS-PSO در طول یکسال



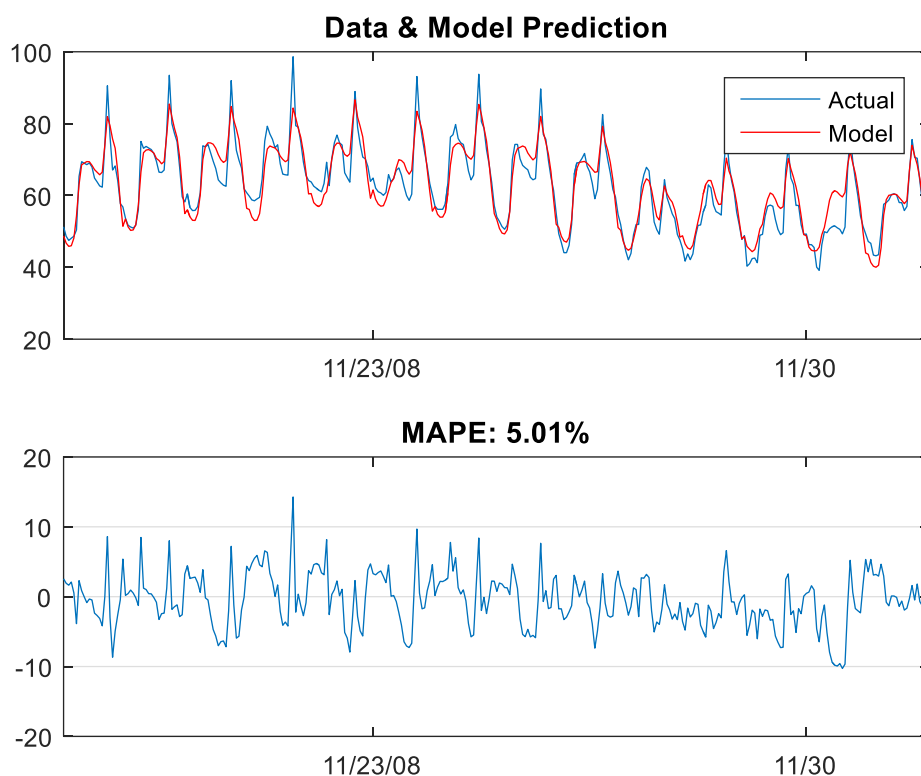
شکل 10: نحوه توزیع خطا حاصل از پیش‌بینی قیمت برای معیارهای معرفی شده براساس الگوریتم ANFIS-PSO



شکل 11: نحوه‌ی توزیع خطای حاصل از پیش‌بینی برای قیمت ساعتی براساس الگوریتم ANFIS-PSO



شکل 12: نحوه‌ی توزیع خطای پیش‌بینی برای قیمت روزانه براساس الگوریتم ANFIS-PSO



شکل 13: پیش‌بینی قیمت برای یک هفته از سال براساس الگوریتم ANFIS-PSO

3-3-3- پیش‌بینی بار برای بازار نیوانگلند توسط شبکه ANFIS-TLBO

به منظور شبیه‌سازی و پیش‌بینی بار و قیمت با الگوریتم ANFIS-TLBO از سیستم نیوانگلند به عنوان یک بازار واقعی استفاده شده است. مانند تمامی الگوریتم‌های تکاملی هوشمند دیگر به دلیل بکارگیری پارامترهای تصادفی با یکبار اجرای برنامه نمی‌توان به درستی نتایج استناد کرد، به همین دلیل برنامه 10 بار اجرا شده و با میانگین‌گیری از نتایج به دست آمده، اطلاعات دقیق‌تر و قابل اعتمادتری ارائه شده است. همچنین رویکرد پیشنهادی با روش‌های مشابه دیگر همچون روش ANFIS، روش شبکه عصبی و روش پیش‌بین ترکیبی ANFIS مبتنی بر الگوریتم بهینه‌سازی کلونی زنبور عسل که در مرجع [19] ارائه شده‌اند، مقایسه شده است. نتایج این مقایسه در جدول (3) آمده است.

جدول 3: میانگین نتایج تشخیص تقلب در کارت‌های اعتباری پس از 10 بار اجرای الگوریتم

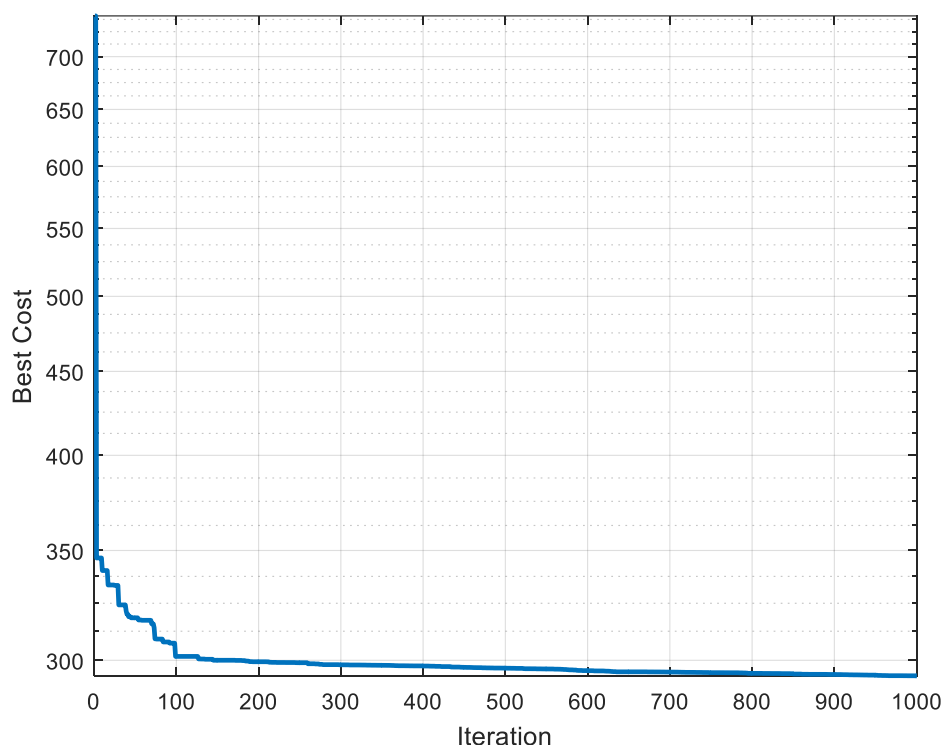
روش ارزیابی	معیار MAE (MWh)	معیار MAPE (%)
روش براساس شبکه عصبی	۲۸۸,۹	1.95
روش براساس ANFIS	504.4	3.45
روش ANFIS مبتنی بر کلونی زنبور عسل	236.43	1.57
روش براساس ANFIS-PSO	287.2	1.93
روش براساس ANFIS-TLBO	220.21	1.38

همانگونه در جدول (3) مشاهده می‌گردد الگوریتم‌های پیشنهادی دارای دقت تشخیص بالاتر نسبت به دیگر الگوریتم‌ها مذکور می‌باشد. همچنین از نتایج ارایه شده می‌توان دریافت که عملکرد الگوریتم ANFIS-TLBO بهتر از الگوریتم ANFIS-PSO بوده است.

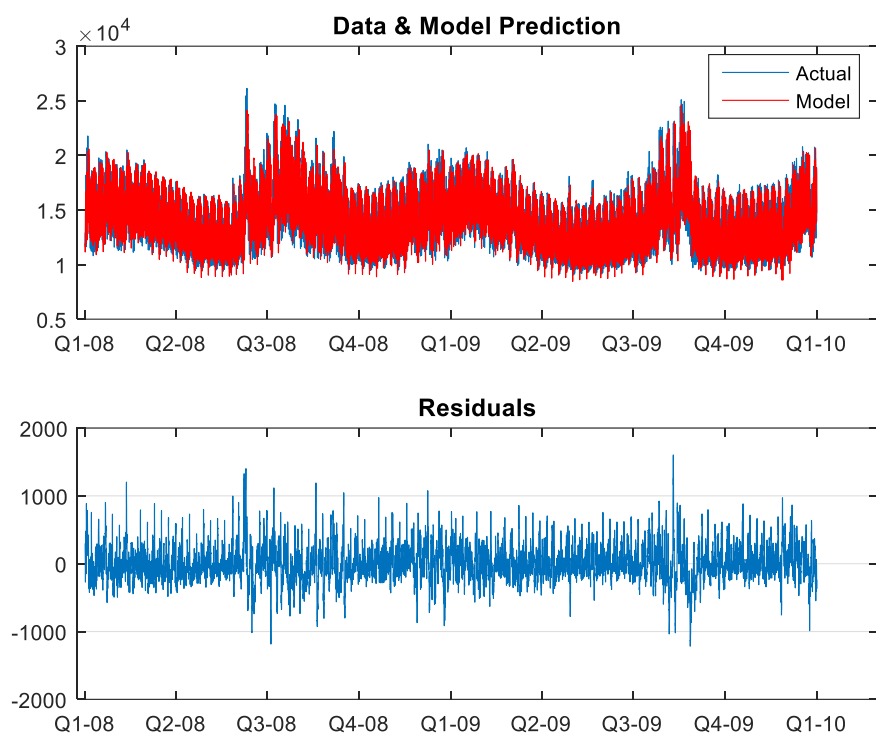
شکل (14) همگرایی تابع هزینه به هنگام آموزش شبکه ANFIS-TLBO را نشان می‌دهد، در این شکل دیده می‌شود که بعد از 100 تکرار الگوریتم آموزش دیده است و تغییرات تابع هزینه آن ناچیز است.

شکل (15) تغییرات پیش‌بینی بار و مقدار پیش‌بینی شده توسط روش پیشنهادی در طول دو سال نشان می‌دهد. در این شکل به وضوح دیده می‌شود خطای پیش‌بینی در حدود 1.5 MWh بوده است که مقدار ناچیزی است.

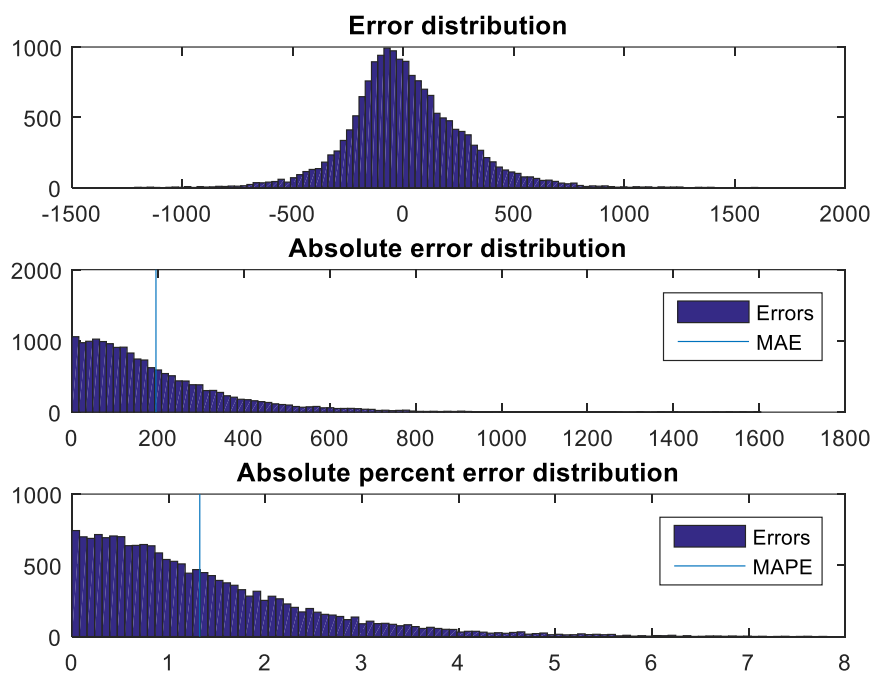
الگوریتم پیشنهادی دارای کارایی بالای سرعت مناسب و دقت بالا می‌باشد. برای نشان دادن کارایی روش پیشنهادی از معیارهایی مانند میانگین قدر مطلق خطای درصدی (MAPE) و یا میانگین قدر مطلق خطا (MAE) استفاده شده است. مقدار بدست آمده برای معیارهای MAPE، MAE و DMAPE برای الگوریتم ANFIS-TLBO به ترتیب 1.38، 1.38 و 220.216 MWh و 1.45 می‌باشد. نتایج بدست آمده نشان می‌دهد که دقت الگوریتم ANFIS-TLBO بیشتر از الگوریتم ANFIS-PSO بوده است. شکل (16) نحوه تغییرات خطا و معیارهای مورد نظر را نشان می‌دهد. شکل (17) تغییرات خطای ایجاد شده در پیش‌بینی بار ساعتی را نشان می‌دهد. پیوستگی مناسب در محدوده کم نشان از دقت بالای این روش پیشنهادی می‌باشد. همچنین به منظور مقایسه کارایی روش پیشنهادی انجام پیش‌بینی میان مدت به وسیله الگوریتم پیشنهادی، شبکه عصبی در طول یک هفته انجام گرفته است. نتایج شبیه‌سازی در شکل (18) نشان داده شده است. منظور نشان دادن کارایی بالای روش پیشنهادی، دوره زمانی را در یک سال افزایش داده یا به عبارتی پیش‌بینی بلند مدت انجام می‌دهیم. پیش‌بینی بار برای یک هفته از سال 2008 در بازار نیوانگلند نیز در شکل (19) ارایه شده است.



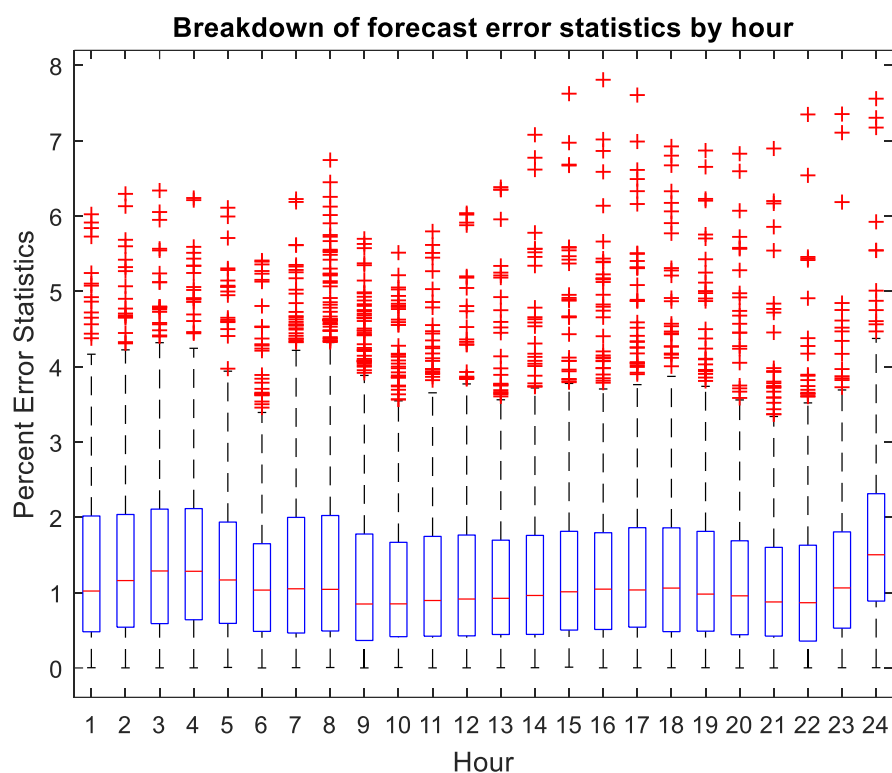
شکل 14: همگرایی تابع هزینه به هنگام آموزش شبکه ANFIS-TLBO



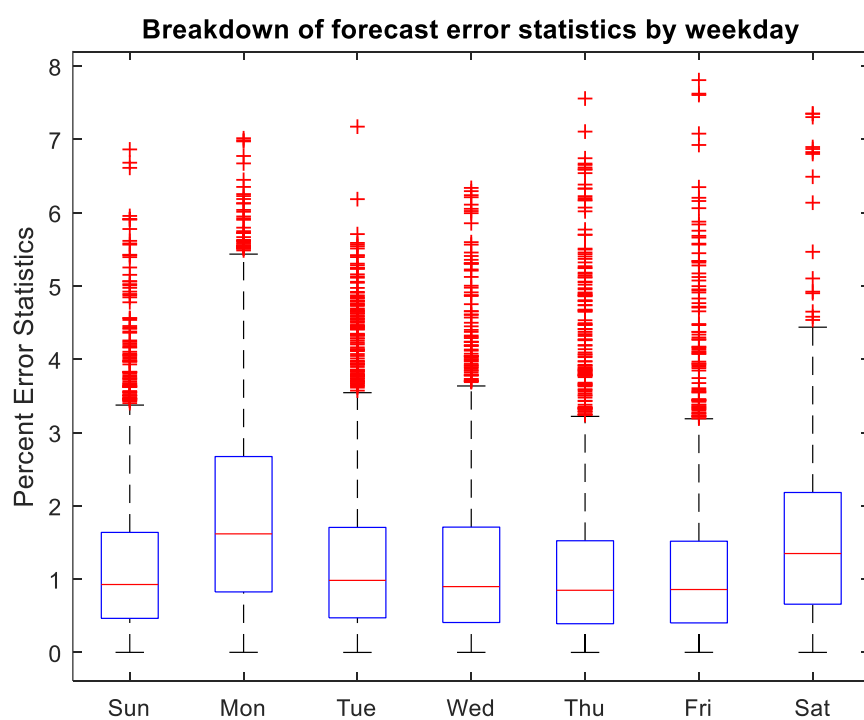
شکل 15: تغییرات بار ساعتی و پیش‌بینی آن توسط الگوریتم ANFIS-TLBO در طول دو سال



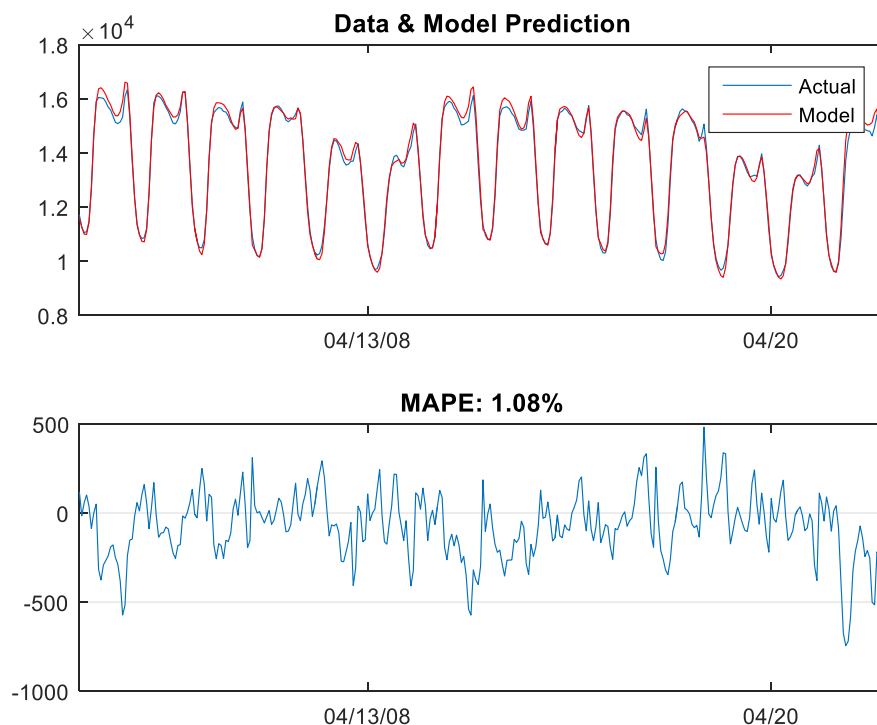
شکل 16: نحوه توزیع خطا حاصل از پیش‌بینی بار برای معیارهای معرفی شده براساس الگوریتم ANFIS-TLBO



شکل 17: نحوه توزیع خطای حاصل از پیش‌بینی برای بار ساعتی براساس الگوریتم ANFIS-TLBO



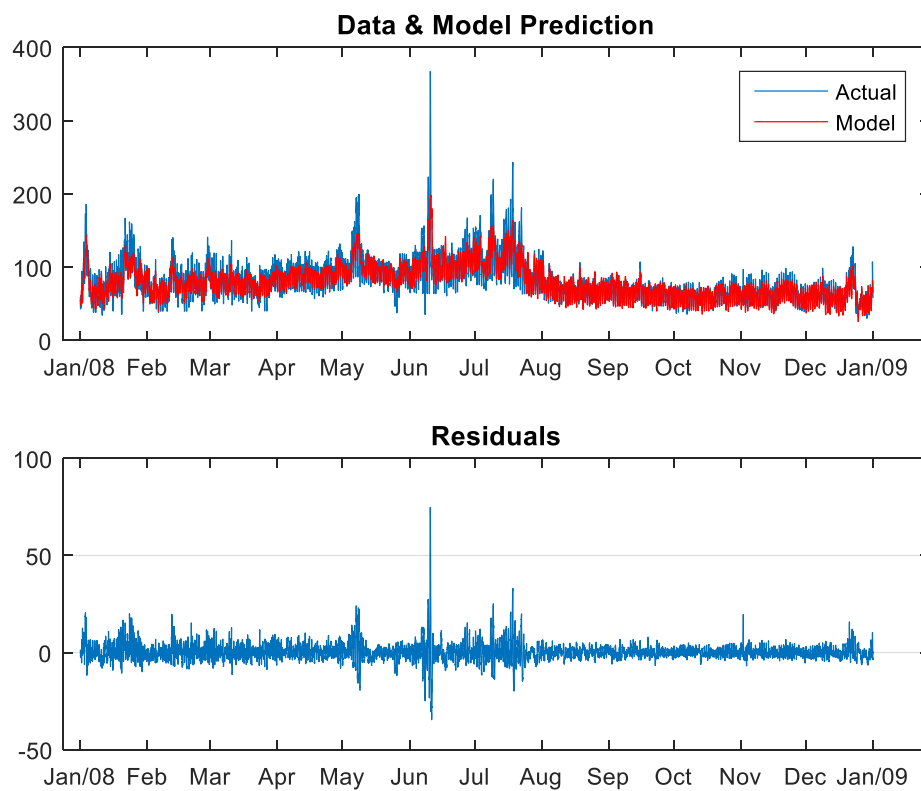
شکل 18: نحوه توزیع خطای پیش‌بینی برای بار روزانه براساس الگوریتم ANFIS-TLBO



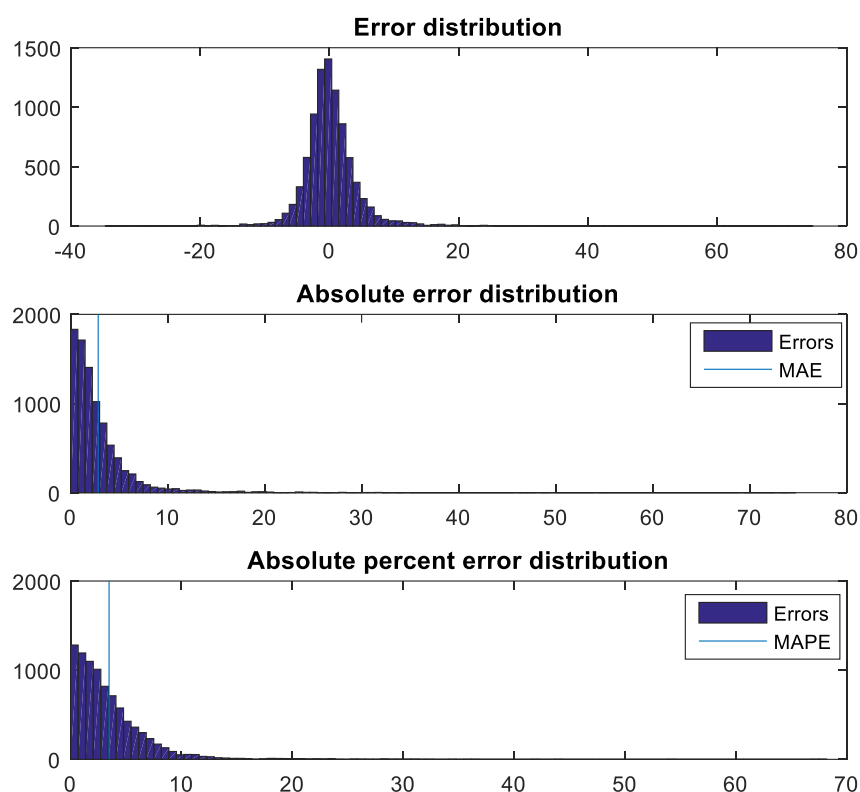
شکل 19: پیش‌بینی بار برای یک هفته از سال براساس الگوریتم ANFIS-TLBO

3-3-4- پیش‌بینی قیمت برق برای بازار نیوانگلند توسط شبکه ANFIS-TLBO

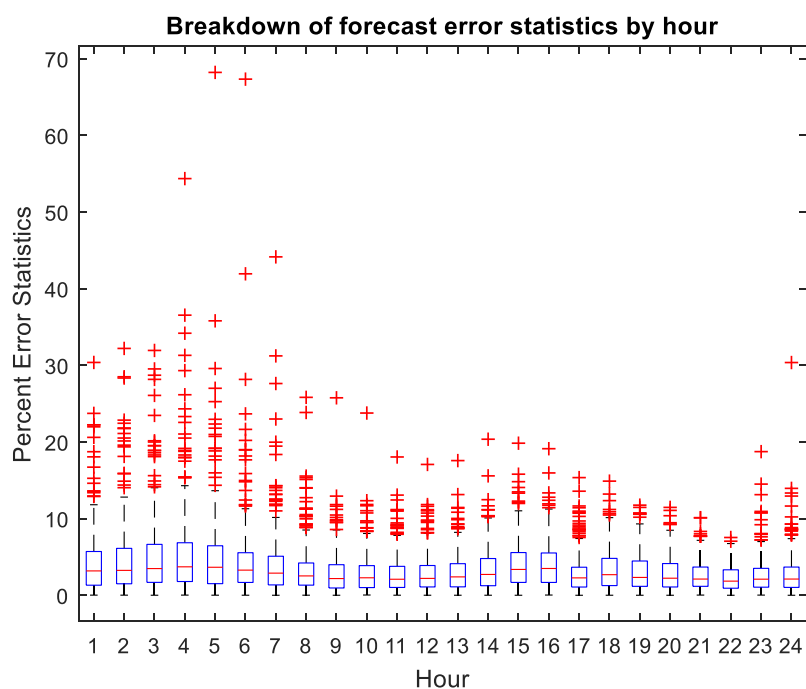
شکل (20) تغییرات قیمت برای سیستم نیوانگلند برای کلیه ساعت‌های سال 2008 را نشان می‌دهد. برای پیش‌اطلاعات 50 روز قبل آن گرفته شده و بعد از آرایش دهی بر روی داده‌های ورودی 13 کاندید برای آموزش وارد شبکه ANFIS-TLBO شده‌اند. در این شکل دیده می‌شود حداکثر خطای پیش‌بینی در حدود 80 است که نسبت به الگوریتم ANFIS_PSO بسیار کمتر است. برای ارزیابی کارایی روش پیشنهادی در این مورد نیز از معیارهایی مانند میانگین قدر مطلق خطای درصدی (MAPE) و یا میانگین قدرمطلق خطا (MAE) استفاده شده است. مقدار بدست آمده برای معیارهای MAPE، MAE و DMAPE براساس رویکرد ANFIS-TLBO به ترتیب 3.47، 2.85 و ۳.۸۲ می‌باشد. نتایج بدست آمده نشان از کارایی و دقت قابل قبول برای مساله پیش‌بینی را به همراه دارد. شکل (21) نحوه تغییرات خطای پیش‌بینی قیمت را با معیارهای مورد نظر را نشان می‌دهد. شکل (22) تغییرات خطای ایجاد شده در پیش‌بینی قیمت ساعتی را نشان می‌دهد. پیوستگی مناسب در محدوده کم نشان از دقت بالای این روش پیشنهادی می‌باشد. همچنین به منظور مقایسه کارایی روش پیشنهادی انجام پیش‌بینی میان مدت به وسیله الگوریتم پیشنهادی، شبکه عصبی در طول یک هفته انجام گرفته است. نتایج شبیه‌سازی در شکل (23) نشان داده شده است. به منظور نشان دادن کارایی روش پیشنهادی، دوره زمانی را در یک سال افزایش داده یا به عبارتی پیش‌بینی بلند مدت انجام می‌دهیم. پیش‌بینی قیمت برای یک هفته از سال 2008 در بازار نیوانگلند نیز در شکل (24) ارایه شده است. از نتایج بدست آمده از الگوریتم ANFIS-TLBO به منظور پیش‌بین قیمت برق و همچنین مقایسه آن با نتایج حاصل از الگوریتم ANFIS-PSO به وضوح مشاهده می‌گردد که دقت روش ANFIS-TLBO بالاتر بوده است.



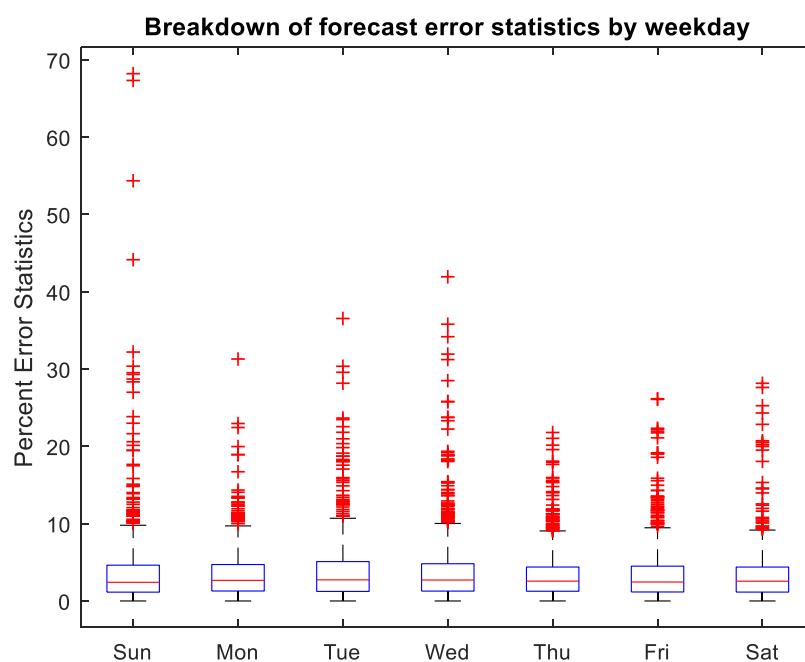
شکل 20: تغییرات قیمت ساعتی و پیش‌بینی آن توسط الگوریتم ANFIS-TLBO در طول یکسال



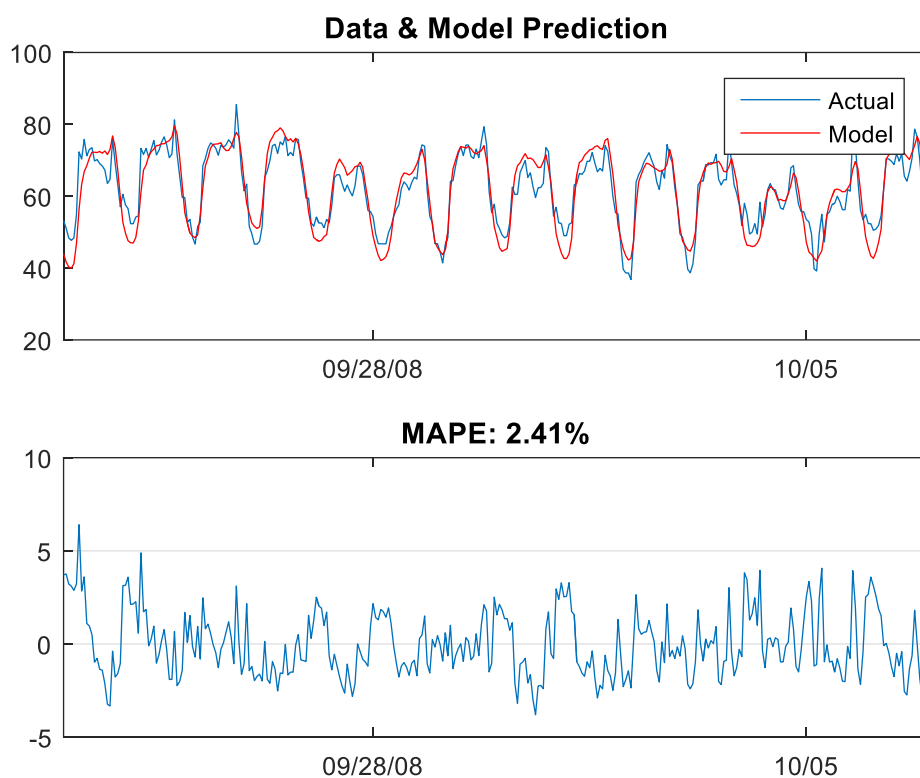
شکل 21: نحوه توزیع خطا حاصل از پیش‌بینی قیمت برای معیارهای معرفی شده براساس ANFIS-TLBO



شکل 22: نحوه‌ی توزیع خطای حاصل از پیش‌بینی قیمت ساعته براساس ANFIS-TLBO



شکل 23: نحوه توزیع خطای پیش‌بینی برای قیمت روزانه براساس ANFIS-TLBO



شکل 24: پیش‌بینی قیمت برای یک هفته از سال براساس ANFIS-TLBO

4. نتیجه گیری

در پی تغییر ساختار بازار برق از بازار انحصاری دولتی به بازار رقابتی که در آن قیمت توسط نیروهای بازار تعیین می‌شود، مدل‌سازی و پیش‌بینی بار مورد تقاضا کاملاً ریسکی و همراه با عدم قطعیت الکتریسته تعیین شده در بازار رقابتی برای فعالان بازار برق اهمیت ویژه‌ای یافته است. برای مدل‌سازی و پیش‌بینی در بازار رقابتی باید ویژگی‌های این کلا از جمله عدم قطعیت ذخیره‌سازی، کم‌کشش بودن، فصلی بودن تقاضا و لزوم تعادل پیوسته‌ی عرضه و تقاضا که منجر به فراریت میزان تقاضا می‌گردد، در نظر گرفت. هدف از این پایان‌نامه طراحی و اجرای یک مدل از پیاده‌سازی الگوریتم‌های ANFIS-TLBO و ANFIS-PSO برای پیش‌بینی رفتار کوتاه مدت، میان مدت و بلند مدت میزان بار در بازار برق جهانی می‌باشد.

در این تحقیق، عملکرد روش‌های پیشنهادی ANFIS-PSO و ANFIS-TLBO به منظور نشان دادن کارایی در حل مساله پیش‌بینی بار و قیمت در بازار برق با نتایج بدست آمده با روش‌های ANFIS، روش مبتنی بر شبکه عصبی و روش شبکه عصبی فازی تطبیقی مبتنی بر کلونی مصنوعی زنبور عسل مقایسه گردید. نتایج حاصل از مقایسه حاکی از کارایی بهتر الگوریتم‌های پیشنهادی از نظر دقت نسبت به روش‌های مقایسه‌ای بود، که این به دلیل استراتژی‌های قدرتمند است که در الگوریتم PSO و TLBO وجود دارد که باعث می‌شود فرآیند بهینه‌سازی وزن‌های شبکه را به خوبی انجام داده و دسته بندی مناسبی تولید نماید. البته لازم به ذکر است که الگوریتم شبکه ANFIS خود نیز الگوریتم قدرتمند جهت پیش‌بینی و تشخیص نسبت به سایر الگوریتم‌های شبکه عصبی می‌باشد، زیرا همانطور که قبلاً نیز اشاره شد، این الگوریتم دارای مزایایی هر دو سیستم فازی و شبکه عصبی بصورت یکجا می‌باشد.

همچنین مقایسه نتایج حاصل از دو الگوریتم ANFIS-PSO و ANFIS-TLBO نشان داد، که الگوریتم مبتنی بر آموزش براساس TLBO دارای دقت بالاتر و خطای کمتر است. این بدلیل آن است، که الگوریتم TLBO دارای پارامترهای کمتری به منظور تنظیم نمود، است. لذا نتایج بدست آمده از این روش مستقل از پارامترهای قابل تنظیم است و همچنین پیاده‌سازی آن نیز نسبت به الگوریتم PSO ساده‌تر است.

5. منابع و مراجع

1. Ya'an. L., Xiaohong. G., "Purchase Allocation and Demand Bidding in Electric Power Markets," IEEE Trans. Power Systems, vol. 18, pp.106 -112, 2003.
2. Mohammad. Sh., Hatim. Y., Zuyi. L., "Market Operation in Electricity Power System: Forecasting, Scheduling and Risk Managment," John Wiley & Sons, 2002.
3. Hernández. L., Baladrón. C., Aguiar. J. M., Calavia. L., Carro. B., Sánchez. E. A., Pérez. F., Fernández. Á., Lloret. J., "Artificial Neural Network for Short-Term Load Forecasting in Distribution Systems", Energies, pp. 1876-1598, 2014.
4. Hippert. H. S., Pedreira. C. E., and Souza. R. c., "Neural Networks for Short-Term Load Forecasting: A Review and Evaluation", IEEE Transactions On Power Systems, vol. 16, pp.44-55, 2002.
5. Marija. I., Francisco. G., Lester. F., "Power systems restructuring engineering and economics", Springer Science & Business Media. 2013.
6. Ghosh. S., and Reilly. D. L., "Credit Card Fraud Detection with a Neural-Network", Proceedings of the Twenty-Seventh Hawaii International Conference on System Sciences, IEEE, vol. 3, pp. 621-630, 2011.
7. Dorronsoro. J. R., Ginel. F., Sanchez. C., and Cruz. C. S., "Neural fraud detection in credit card operations", IEEE Transactions on Neural Networks, vol. 8, pp. 827-843, 1997.

8. Guo. T., and Yang. L., "Neural Data Mining For Credit Card Fraud Detection", International Conference on Machine Learning and Cybernetics, vol. 7, pp. 3630 – 3634, 2008.
9. Gudise. V. G., Venayagamoorthy. G. K., "Comparison of particle swarm optimization and backpropagation as training algorithms for neural networks", Proceedings of the 2003 IEEE Swarm Intelligence Symposium, pp. 110-117, 2003.
10. Zhang. J. R., Zhang. J., Lok. T. M., Lyu. M. R., "A hybrid particle swarm optimization–back-propagation algorithm for feedforward neural network training", Applied Mathematics and Computation, vol. 185, pp. 1026-1037, 2007.
11. Gulesin. S. D., "Forecasting the energy demand of Turkey with a NN based on an improved Particle Swarm Optimization", The Natural Computing Applications Forum, pp.1-11, 2016.
12. Kankal. M., Uzlu. E., "Neural network approach with teaching–learning-based optimization for modeling and forecasting long-term electric energy demand in Turkey", The Natural Computing Applications Forum, pp. 1-11, 2016.
13. Kumarana. J., Ravi. G., "Long-term Sector-wise Electrical Energy Forecasting Using Artificial Neural Network and Biogeography-based Optimization", Electric Power Components and Systems, vol.43, pp.1225-1234, 2015.
14. فرناز برزین پور، سعید کریمی، "پیش‌بینی آثار سناریوهای مختلف هدفمندی یارانه‌ها بر تقاضای برق خانگی با استفاده از شبکه‌های عصبی"، نشریه تخصصی مهندسی صنایع، دوره 48، صفحه 83 تا 90، سال 1393.
15. Hernandez. L., Baladrón. C., Aguiar. J. M., Carro. B., Antonio. J., Sanchez. E., Jaime. L., "Short-term load forecasting for microgrids based on artificial neural networks", Energies, vol. 6, pp. 1358-1408, 2013.
16. Carvalho. M., Ludermir. T. B., "Particle swarm optimization of neural network architectures and weights", 7th International Conference on Hybrid Intelligent Systems, pp. 336-339, 2007.
17. Freitag. S., Muhanna. R. L., Graf. W., "A particle swarm optimization approach for training artificial neural networks with uncertain data", 5th International Conference on Reliable Engineering Computing, Litera, Brno, vol 151, pp. 347-367, 2012.
18. Liang. Q., Wang. Z., Fan. Y., Liu. C., Yan. X., Hu. C., Yao. H., "Multi-label Classification based on Particle Swarm Algorithm", IEEE 9th International Conference on Mobile Ad-hoc and Sensor Networks, pp. 421-424, 2013.
19. Hubel. D. H., Wiesel. T. N., "Brain and visual perception: the story of a 25-year collaboration", Color Research & Application, vol. 31, pp. 156-156, 2005.

Load forecasting and price forecasting using Teaching Learning based Optimization and learning and adaptive fuzzy neural network

Fatemehsadat Mosavi Alizadeh¹, Seyyed Jafar Fazeli Abelouei^{2*}

Department of electrical, Sari branch, Islamic Azad University, Sari, Iran, mousavi_alizade@yahoo.com

Department of electrical, Neka branch, Islamic Azad University, Neka, Iran, sj.fazeli@iau.ac.ir

Abstract— Today, the electricity market in the world is known scientifically that the competition in it is more every day than the previous day. Since the ability to store electrical energy is very small, therefore, forecasting the consumption load and the price of electricity helps the market participants to get more profit. The impact of the load pattern on various factors and the non-linearity of the electricity price signal make it difficult to accurately forecast the load and price; Therefore, the use of intelligent algorithms has found more use in forecasting problems compared to numerical and statistical methods. Therefore, in this thesis, the issues related to forecasting the load and electricity price are stated. Also, the electric load and electricity price have been predicted using the Adaptive neuro fuzzy inference system (ANFIS) combined with the Teaching Learning based Optimization (TLBO) and the effect of various factors on it has been investigated and simulated. In fact, by combining the evolutionary algorithms with the fuzzy neural system, the adjustment of the optimal values of the parameters of the adaptive fuzzy neural network should be assigned to the intelligent optimization algorithm of teaching and learning. The purpose of using this approach is to improve network performance and reduce computational complexity compared to gradient descent and least squares methods. The results of the implementation of the proposed algorithm show the better efficiency of this algorithm compared to previous algorithms for predicting load and electricity price.

Keywords: Load forecasting, price forecasting, Teaching Learning based Optimization, Adaptive neuro fuzzy inference system