

پیش‌بینی بازار برق به کمک شبکه‌ی عصبی و الگوریتم گرگ خاکستری

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

تاریخ دریافت: ۱۳۹۸/۰۷/۲۸

تاریخ پذیرش: ۱۳۹۸/۱۱/۳۰

چکیده

بازار برق در جهان امروز، به صورت علمی شناخته شده است و رقابت در آن هر روز بیشتر از قبل می‌شود. در این میان، ابزار پیش‌بینی قیمت به شرکت‌کنندگان بازار در به دست آوردن سود هرچه بیشتر، کمک شایانی می‌کند. هدف پژوهش حاضر، گسترش شبکه‌ی عصبی و بهینه‌سازی آن توسط الگوریتم گرگ خاکستری برای پیش‌بینی قیمت بازار برق است. از آنجا که در مدل‌های سنتی و همچنین مدل شبکه‌های عصبی همواره از روش‌های احتمالاتی جهت افزایش دقت پیش‌بینی استفاده می‌شود؛ در این مدل، سعی شده تا با ارائه‌ی روشی جدید، از این موارد صرف‌نظر شود. یکی از موضوعاتی که همواره دقت پیش‌بینی را تحت تأثیر قرار می‌دهد، وجود موارد بحرانی و ناگهانی در سیستم است؛ که در این تحقیق، با استفاده از شبکه عصبی بهینه شده توسط الگوریتم گرگ خاکستری، این مسائل کنترل خواهد شد. یکی از مزایای استفاده از الگوریتم گرگ خاکستری این است که این الگوریتم در بهینه‌های محلی به دام نمی‌افتد و توانایی شناسایی نقاط بهینه سراسری را دارد. در مدل پیشنهادشده، از اطلاعات بازار برق نوردیک استفاده شده است؛ اما بدیهی است که مدل مذکور برای هر بازار دیگری قابل استفاده می‌باشد. در پایان برای نشان دادن دقت این مدل، مقایسه‌ای بین آن و یکی از روش‌های سنتی انجام شده است. در این مقایسه مشاهده می‌گردد که استفاده از روش پیشنهادی این مقاله، باعث می‌شود تا MAPE نسبت به شبکه عصبی معمولی بهینه نشده به میزان حدود ۴ درصد بهبود یابد.

کلید واژه‌ها: الگوریتم گرگ خاکستری، پیش‌بینی قیمت، شبکه‌ی عصبی

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

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

^۳ استادیار، 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

پیش‌بینی بازار برق به کمک شبکه‌ی عصبی و.....

۱- مقدمه

پیش‌بینی بار یک فرایند مرکزی و جامع در برنامه ریزی و بهره‌برداری صنعت برق بوده است. روشهای زیادی در دو دهه اخیر برای حل بهینه این مسئله پیشنهاد شده‌اند. این روشها اغلب به لحاظ ماهیت با هم تفاوت داشته و به نظریات مختلف مهندسی و تحلیل‌های اقتصادی پاسخ می‌دهند. یکی از مراحل مهم در طراحی سیستم‌های توزیع انرژی الکتریکی پیش‌بینی بار و سیر تغییرات آن از زمان حال تا پایان سال مورد نیاز برای طراحی می‌باشد. پیش‌بینی صحیح بار علاوه بر صرفه جویی در هزینه‌های سرمایه‌گذاری، امکان برنامه‌ریزی زمانی مناسب جهت اجرای پروژه را نیز فراهم می‌نماید

رسیدن به بهره‌برداری و عملکرد موفق در صنعت برق، مستلزم دارا بودن چندین فاکتور است؛ از جمله‌ی این فاکتورها می‌توان به امنیت سیستم و بازده عملکرد اشاره کرد. در قسمت بازده عملکرد، صنعت به آماده‌سازی منابع و ظرفیت‌های کافی جهت تولید و انتقال برای تأمین مطمئنی از مصرف‌کننده نوسانی بوده و با افت‌وخیز تقاضا همراه است، نیاز دارد. این امر باید هم‌زمان با تحلیل‌های اقتصادی صورت گیرد تا قیمت بهره‌برداری کمینه شود [۱-۳]. دقت پیش‌بینی را می‌توان اولین نیاز چنین تحلیل‌هایی به حساب آورد؛ از این رو، اقتصاد بهره‌برداری و کنترل سیستم قدرت، به خطای پیش‌بینی حساس است. تأثیر خطای بزرگ

پیش‌بینی در قسمت بهره‌برداری، با ریسک بالا و یا بهره‌برداری محافظه‌کارانه منعکس می‌شود. از جمله‌ی 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 راه‌اندازی، اشاره کرد [۱].

موضوع پیش‌بینی قیمت، ابتدا در بازارهای بورس مدنظر بود؛ اما با روی کار آمدن بازارهای برق و تجدید ساختار سیستم برق، به‌عنوان یکی از مسائل اساسی بازار مورد بحث قرار گرفت. به‌طور کلی، پیش‌بینی را بر اساس طول دوره‌ی مورد نظر، به ۳ دسته تقسیم می‌کنند که به شرح زیر است [۴]:

پیش‌بینی بلندمدت قیمت؛ این نوع پیش‌بینی برای چند سال به‌کار می‌رود و عموماً نتایج جهت تعیین افزایش تورم و گستردگی سیستم و همچنین چگونگی بازار در سال‌های آینده مورد استفاده واقع می‌شود؛ اما باید دقت داشت که به دلیل زیاد بودن فاصله زمانی، دقت چنین پیش‌بینی‌هایی عموماً درست نیست.

پیش‌بینی میان‌مدت قیمت؛ در این نوع، برای چندین ماه و یا چندین هفته پیش‌بینی انجام می‌شود که برای تعیین نرخ سوخت و هزینه‌ی تعمیرات به‌کار می‌رود.

پیش‌بینی کوتاه‌مدت قیمت؛ در این پیش‌بینی، فاصله‌ی زمانی یک تا چند روز است و معمولاً به دلیل کوتاه بودن فاصله‌ی زمانی، از دقت بالایی برخوردار است؛ اما باید توجه داشت از آنجا که با مسائل انسانی و فاکتورهای متعددی جهت پیش‌بینی روبه‌رو هستیم، نمی‌توان پیش‌بینی را بدون خطا انجام داد؛ ولی باید تا حد امکان آن را کم کرد؛ چرا که به‌عنوان مثال در پیش‌بینی بار سیستم بریتانیا، خطای یک درصدی (۱٪) پیش‌بینی، منجر به افزایش ۱۰ میلیون پوندی هزینه‌ی بهره‌برداری در سال گشت [۵-۸].

۱-۱. پژوهش‌های مرتبط

پژوهش [۱]، یک روش پیش‌بینی جدید برای قیمت‌های نقدی کوتاه‌مدت در بازار قدرت Nordic پیشنهاد می‌کند. این الگوریتم جستجوی فاخته Le

enberg-Marquardt آموزش‌دیده، شبکه‌ی عصبی تغذیه‌ی روبه‌جلو CSLM را برای فرآیند حل پیشنهاد می‌کند که الگوریتم جستجوی بهبودیافته Levenberg-Marquardt و الگوریتم جستجوی Cuckoo را با هم ترکیب می‌کند. مدل پیشنهادی، توان تولیدی واقعی و بار سیستم را به‌عنوان مجموعه‌های ورودی برای تسهیل استفاده‌ی مؤثر از منابع انتقال و تولید توان از طریق شرکت‌کنندگان مستقیم بازار در نظر می‌گیرد. در طی آموزش، مدل پیشنهادی CSLM-FFNN، رابطه‌ی بین قیمت

منطقه‌ای و قیمت سیستم را برای دوره‌ی مشابه تعمیم داد. این مدل را می‌توان به‌منظور پیگیری روند تغییرات قیمت برق و حفظ دقت به دلیل سرعت آموزش سریع در الگوریتم یادگیری CSLM، به‌روزرسانی کرد. مدل توسعه‌یافته، با داده‌های در دسترس عموم به‌دست‌آمده از بخش Nord Pool و عملکرد مدل با شبکه‌های عصبی مصنوعی نوین و مدل‌های سری‌های زمانی مقایسه شده است. علاوه بر این، رویکرد پیشنهادی برای پیش‌بینی قیمت پاک‌سازی بازار در بازار برق اسپانیا به‌منظور ارزیابی بیشتر اعتبار این روش اعمال شده است. نتایج، نشان می‌دهد که مدل پیشنهادی CSLM-FFNN، عملکرد بهتری نسبت به روش‌های دیگر از لحاظ دقت پیش‌بینی و کارایی آموزشی نشان می‌دهد.

مقاله‌های [۲]، [۹-۱۰] با طراحی مجموعه‌ی جدیدی از ویژگی‌های صنایع‌دستی و اجرای یک ارزیابی تجربی گسترده درخصوص سهام نقدشونده و غیرنقدشونده، به این مشکل می‌پردازند؛ آن‌ها به‌طور خاص، مجموعه‌ی جدیدی از مشخصه‌های اقتصادی را اجرا می‌کنند که ویژگی‌های آماری اوراق بهادار اساسی را برای پیش‌بینی قیمت متوسط ثبت می‌کنند. علاوه بر این، یک پروتکل آزمایشی جدید برای یادگیری آنلاین ایجاد شده است که کار را به‌عنوان یک مسئله بهینه‌سازی چندهدفه (۱) مسیر حرکت قیمت (بعدی و ۲) تعداد رویدادهای ترتیب کتاب تا زمانی

پیش‌بینی بازار برق به کمک شبکه‌ی عصبی و.....

روشی مشابه کاهش دهد. این مطالعه، همچنین نشان می‌دهد که مدل‌سازی آینده، پتانسیل افزایش دقت بیشتری را دارد و یک رویکرد شبکه‌ی عصبی را به‌عنوان گام بعدی پیشنهاد می‌کند.

مقاله‌ی [۴]، اولین مجموعه‌ی داده در دسترس عموم از بازارهای سفارش با فرکانس بالا را برای پیش‌بینی قیمت متوسط توصیف می‌کند. نگارندگان، داده‌های سری زمانی برای پنج سهام از بازار بورس Nasdaq Nordic را برای مدت زمانی ۱۰ روز متوالی استخراج کردند که منجر به مجموعه داده‌ها از نمونه‌های سری زمانی حدود ۴ میلیون گردید. یک پروتکل آزمایشی اعتبارسنجی متقابل مبتنی بر روز نیز ارائه شده است که می‌تواند به‌عنوان یک معیار برای مقایسه‌ی عملکرد روش‌های نوین استفاده شود. عملکرد رویکردهای پایه نیز برای تسهیل مقایسه‌های تجربی فراهم شده است. به‌نظر می‌رسد که چنین مجموعه داده‌ها در مقیاس بزرگ می‌تواند به‌عنوان یک بستر آزمایشی برای ابداع راه‌حل‌های جدید سیستم‌های خبره برای آنالیز داده‌های دفتری فرکانس بالا عمل کند. در مقاله [۵]، پیش‌بینی قیمت برق با استفاده از J48، جنگل تصادفی و چانه‌زنی برای پیش‌بینی مؤثر قیمت برق مورد استفاده قرار می‌گیرند. این مدل‌ها به‌وسیله‌ی تقسیم‌بندی بازگشتی فضای داده و برازش یک مدل پیش‌بینی ساده در هر افراز به دست می‌آیند. اثربخشی روش‌های پیشنهادی از

که تغییر رخ می‌دهد را پیش‌بینی می‌کند. به‌منظور پیش‌بینی حرکت میانه‌ی قیمت، مشخصه‌ها به نه مدل یادگیری عمیق مختلف براساس شبکه‌های عصبی گیرنده‌های چندلایه، شبکه‌های عصبی محرمانه و حافظه‌ی باند کوتاه‌مدت تغذیه می‌شوند. سپس عملکرد روش پیشنهادی بر روی سهام نقدشونده و غیرنقدشونده مورد ارزیابی قرار می‌گیرد که به ترتیب برحسب سهام‌های TotalView-ITCH US و Nordic است. برای برخی از سهام‌ها، نتایج نشان می‌دهد که انتخاب صحیح یک مجموعه‌ی ویژگی و یک مدل می‌تواند به پیش‌بینی موفقیت‌آمیز این‌که چقدر طول می‌کشد تا یک حرکت قیمت سهام داشته باشد، یاری نماید. هدف مقاله [۳]، طراحی یک مدل پیش‌بینی تلفات خط جدید در Svk^۱ است که پیش‌بینی ساعتی تلفات خط انتقال را در روز بعد برای مناطق مناقصه سوئد ارائه می‌دهد (SE1-SE4). هدف نهایی کاهش هزینه‌های اضافی مربوط به پیش‌بینی‌های نادرست است. مدل توسعه‌یافته مبتنی بر تحلیل رگرسیون در تلفات تاریخی خط و جریان‌های مبادله تخمین زده‌شده بین مناطق مناقصه‌ی مجاور محاسبه‌شده توسط برنامه‌نویسی خطی است. نتایج شبیه‌سازی برای سال ۲۰۱۵، نشان می‌دهد که با برآوردهای نسبتاً ساده و فرضیات، ممکن است دقت پیش‌بینی را تا ۲۷ درصد در مقایسه با روش موجود افزایش دهد و هزینه‌های مربوطه را به

^۱ Svenska kraftnät

در مقاله حاضر، از شبکه عصبی به منظور پیشبینی قیمت در بازار برق استفاده شده است. همچنین از آنجایی که تعیین تعداد نوروها و لایه‌های پنهان در شبکه‌های عصبی از اهمیت خاصی برخوردار است در این مقاله از الگوریتم بهینه سازی گرگ خاکستری برای تعیین آنها استفاده شده است. این موضوع سبب شده تا شبکه عصبی بهبود یافته با الگوریتم گرگ خاکستری نسبت به یک شبکه عصبی معمولی دارای دقت بیشتری باشد و نیز در بهینه‌های محلی در دام نیافتد و به بهینه سراسری برسد.

در بخش بعدی روش‌های موجود برای پیش‌بینی قیمت در بازارهای برق شرح داده خواهد شد. در ادامه، نحوه مدلسازی و همچنین ساز و کار الگوریتم بهینه سازی گرگ خاکستری شرح داده خواهد شد. سپس در بخش بعد، روش پیشنهادی این مقاله و همچنین معیار MAPE شرح داده خواهد شد. در بخش شبیه‌سازی، روش پیشنهادی بر روی بازار برق نوردیک به منظور پیش‌بینی قیمت اعمال خواهد شد.

۲- پیش‌بینی قیمت در بازار برق

در گذشته، الگوریتم‌های متعددی که وابسته به تحلیل‌های آماری بود، جهت پیش‌بینی قیمت به کار گرفته می‌شد. مدل‌های پیش‌بینی قیمت را می‌توان به دو روش گسترده تقسیم کرد؛ در روش اول، پارامتری که در آن ارتباط میان قیمت و فاکتورهای

طریق آزمون‌های جامع با استفاده از داده‌های واقعی قیمت از بازار برق استرالیا تأیید شده است. مقایسه-ی این روش‌ها، نشان می‌دهد که چانه‌زنی به اندازه-ی دقت مورد توجه قرار می‌گیرد.

در مقاله [11]، از یک مدل هیبریدی مبتنی بر تبدیل ویولت مختلط و موتور پیش‌بینی چندسطحی به منظور پیش‌بینی قیمت در شبکه‌های هوشمند استفاده شده است. نحوه عملکرد این مدل به این صورت است که در ابتدا، از داده‌های ورودی تبدیل ویولت گرفته می‌شود و سپس داده‌های بدست آمده از مرحله قبل وارد یک موتور پیش‌بینی سه سطحی می‌شوند. در نهایت روش ارائه شده بر روی داده-های بازار برق انگلستان و استرالیا اعمال می‌شود تا کارایی آن مورد بررسی قرار گیرد.

مقاله [۱۲]، به منظور پیش‌بینی کوتاه مدت بار از یک روش انتخاب ویژگی جدید و همچنین از یک الگوریتم هوشمند جدید بعنوان موتور پیش‌بینی استفاده می‌کند. متد انتخاب ویژگی بکار رفته در این مقاله، به گونه‌ای است که بهترین مشخصه را برای ورود به موتور پیش‌بینی انتخاب می‌کند. موتور پیش‌بینی بکار رفته، شامل یک شبکه عصبی بهمراه یک الگوریتم هوشمند جدید است تا بتواند دقیق بالا و کارایی این مدل را تضمین نماید. در نهایت این روش بر روی چندین سیستم نمونه اعمال شده و توانایی این روش مورد بررسی قرار می‌گیرد.

پیش‌بینی بازار برق به کمک شبکه‌ی عصبی و.....

۱-۲. انواع قیمت در بازار برق

هنگامی که هیچ تراکمی در خط انتقال وجود ندارد، قیمت تمام‌شده‌ی بازار، تنها قیمت موجود برای کل سیستم است. باید دقت داشت که عمدتاً قیمت در بازار برق به ۳ نوع تقسیم می‌شود:

- قیمت محلی بازار LMP
- قیمت منطقه‌ای بازار ZMP
- قیمت تمام‌شده بازار MCP

پیش‌بینی قیمت‌های مذکور، به شرایطی بستگی دارد که ذکر کلیه‌ی این شرایط، در این مقوله نمی‌گنجد. در حالات اول و دوم، به دلیل اینکه اطلاعات مورد نیاز زیادی در رابطه با سیستم قدرت از جمله قابلیت اطمینان سیستم و واحدهای تولیدی، تراکم خطوط و... باید فراهم باشد، هدف نگارندگان در این مقاله فقط پیش‌بینی قیمت تمام‌شده‌ی بازار است. در حالت‌های اول و دوم، قیمت تمام‌شده همان قیمت محل و یا منطقه در نظر گرفته می‌شود. بسیاری از نشریات، کاربرد شبکه‌های عصبی و هوش مصنوعی را در مسئله‌ی پیش‌بینی قیمت و بار شرح داده‌اند. سیستم هوشمند در ابتدا در اوایل ۱۹۸۰ توضیح داده شد. برای مسئله‌ی پیش‌بینی قیمت باید یک پایگاه داده جهت جمع‌آوری اطلاعات انواع روزها، فاکتورهای اجتماعی و فاکتورهای آب‌وهوایی ایجاد کرد که در این پروژه، اطلاعات از بازار برق نوردیک جمع‌آوری شده است.


تأثیرگذار بر قیمت، صراحتاً فرمول‌بندی می‌شوند. در روش دیگر، داده‌های گذشته‌ی قیمت، جهت شکل‌گیری یک مدل قیمت به کار گرفته می‌شوند؛ بدین ترتیب، قیمت آینده را می‌توان به وسیله‌ی محاسبه‌ی قیمت‌های گذشته به دست آورد. اخیراً، علاقه‌مندی الگوریتم‌های به کار گرفته‌شده جهت کنترل مسائل پیش‌بینی، به سمت روش‌هایی تمایل پیدا کرده است که شبکه‌های عصبی مصنوعی نامیده می‌شود. به دلیل کارایی بالا در طبقه‌بندی، تخمین تابع و مسائل نگاشتی شبکه‌های عصبی به‌طور گسترده جهت مسائل پیش‌بینی به کار گرفته می‌شود. 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. با وجود گزارش‌های موفقیت‌آمیزی که در زمینه‌ی پیش‌بینی به ثبت رسیده است؛ اما هنوز موضوع پیش‌بینی قیمت مسئله‌ساز است؛ چراکه مثلاً یک پیش‌بینی‌کننده‌ی عمومی که بتواند به‌طور کلی جهت پیش‌بینی قیمت در هر منطقه‌ی جغرافیایی به کار رود، وجود ندارد؛ و دلیل این موضوع، وجود فاکتورهایی با اهمیت بالای تأثیرگذاری بر قیمت در هر ناحیه و منطقه‌ی برق خواهد بود؛ به‌عنوان مثال، اگر بار را به‌عنوان یکی از فاکتورهای مهمی که بر قیمت تأثیر می‌گذارد، در نظر بگیریم، متوجه می‌شویم که بار سیستم در هر منطقه‌ی جغرافیایی متفاوت است و نمی‌توان از مقدار مصرف یک منطقه به‌عنوان بار سیستم برای مناطق دیگر استفاده کرد.

۳- مدلسازی


۳-۱. جمع‌آوری اطلاعات

بازار نورد پول، بزرگ‌ترین بازار فیزیکی جهان است که هم خدمات بازار روزانه و هم بازار درون روزانه را به شرکت‌کنندگان (بازیگران) بازار ارائه می‌کند. ۳۱۷ شرکت از ۲۰ کشور جهان، معاملات تجاری خود را در این بازار انجام می‌دهند. گروه بازار نورد پول، دارای دفاتری در اسلو، هیلسینکی، استوکهولم، فردریکا و لندن است. این بازار، دارای مالکیت اپراتورهای سیستم انتقال نوردیک می‌باشد. بازار برق نورد پول (نوردیک)، از ۴ کشور نروژ، سوئد، دانمارک و فنلاند تشکیل شده است. این بازار، مکانی را فراهم کرده است که طی آن تولیدکنندگان، شرکت‌های بزرگ انرژی و مصرف‌کنندگان بزرگ بتوانند انرژی را در آنجا خریداری و یا به فروش برسانند. این قیمت، منبعی برای عمده‌فروشان نوردیک بوده و برای توزیع‌کنندگان انرژی به‌عنوان پایه‌ای برای قیمت فعلی است. هیئت‌مدیره انرژی و منابع آبی نروژ،


بازار نورد پول را تنظیم کرده و حق امتیاز مکان بازار را صادر می‌کنند. وزارت نفت و انرژی نروژ، سازمان‌دهی بازار نورد پول را برای معاملات فیزیکی و توان با کشورهای همسایه، در اختیار دارد. بعد از این مقدمه، نوبت به بررسی قیمت روزهای مختلف هفته در بازار نوردیک می‌رسد. شایان ذکر است که قیمت‌های به‌کار گرفته‌شده در این پروژه، به اوایل بهار تا اواخر پاییز سال ۲۰۰۹ میلادی مربوط می‌شود. پس از بررسی قیمت روزهای مختلف هفته، مشخص می‌شود که قیمت برق در این بازار برخلاف مصرف انرژی، آن‌چنان تحت تأثیر فصل‌های مختلف سال نیست؛ اما همان‌طور که می‌دانیم، مصرف انرژی در ماه‌ها و فصل‌های سال متفاوت بوده و از الگوهای مختلفی پیروی می‌کند. در شکل‌های ۱ الی ۵ تغییرات قیمت و میزان بار در فصل‌ها و روزهای مختلف نشان داده شده است.



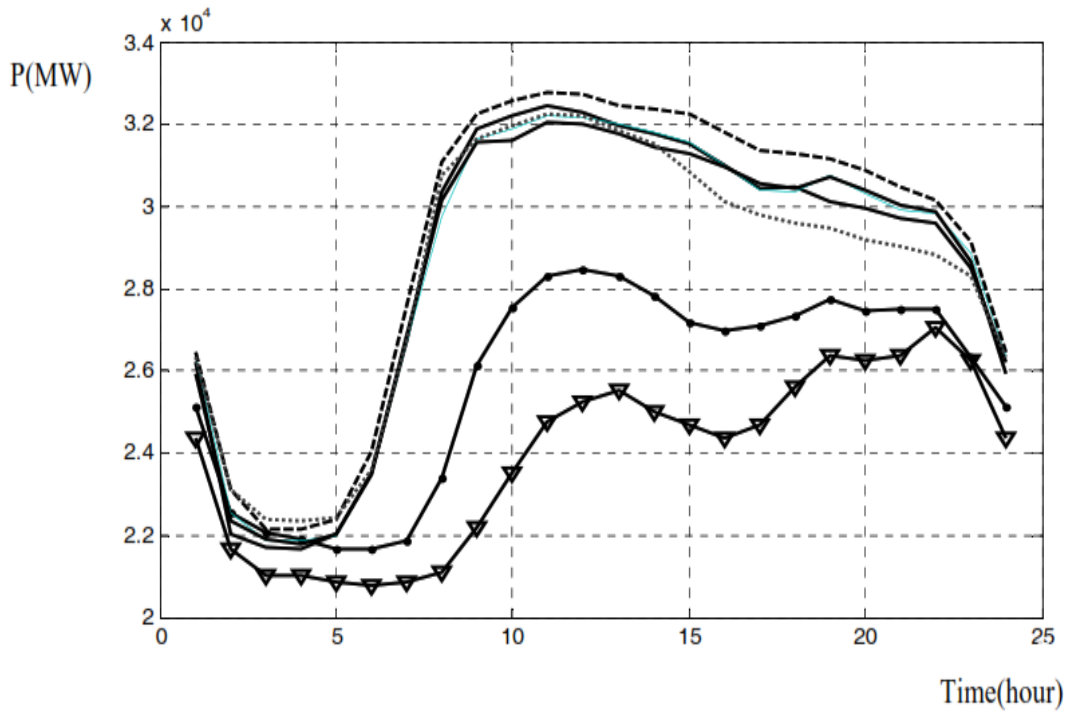
شکل ۱: قیمت در سه فصل سال



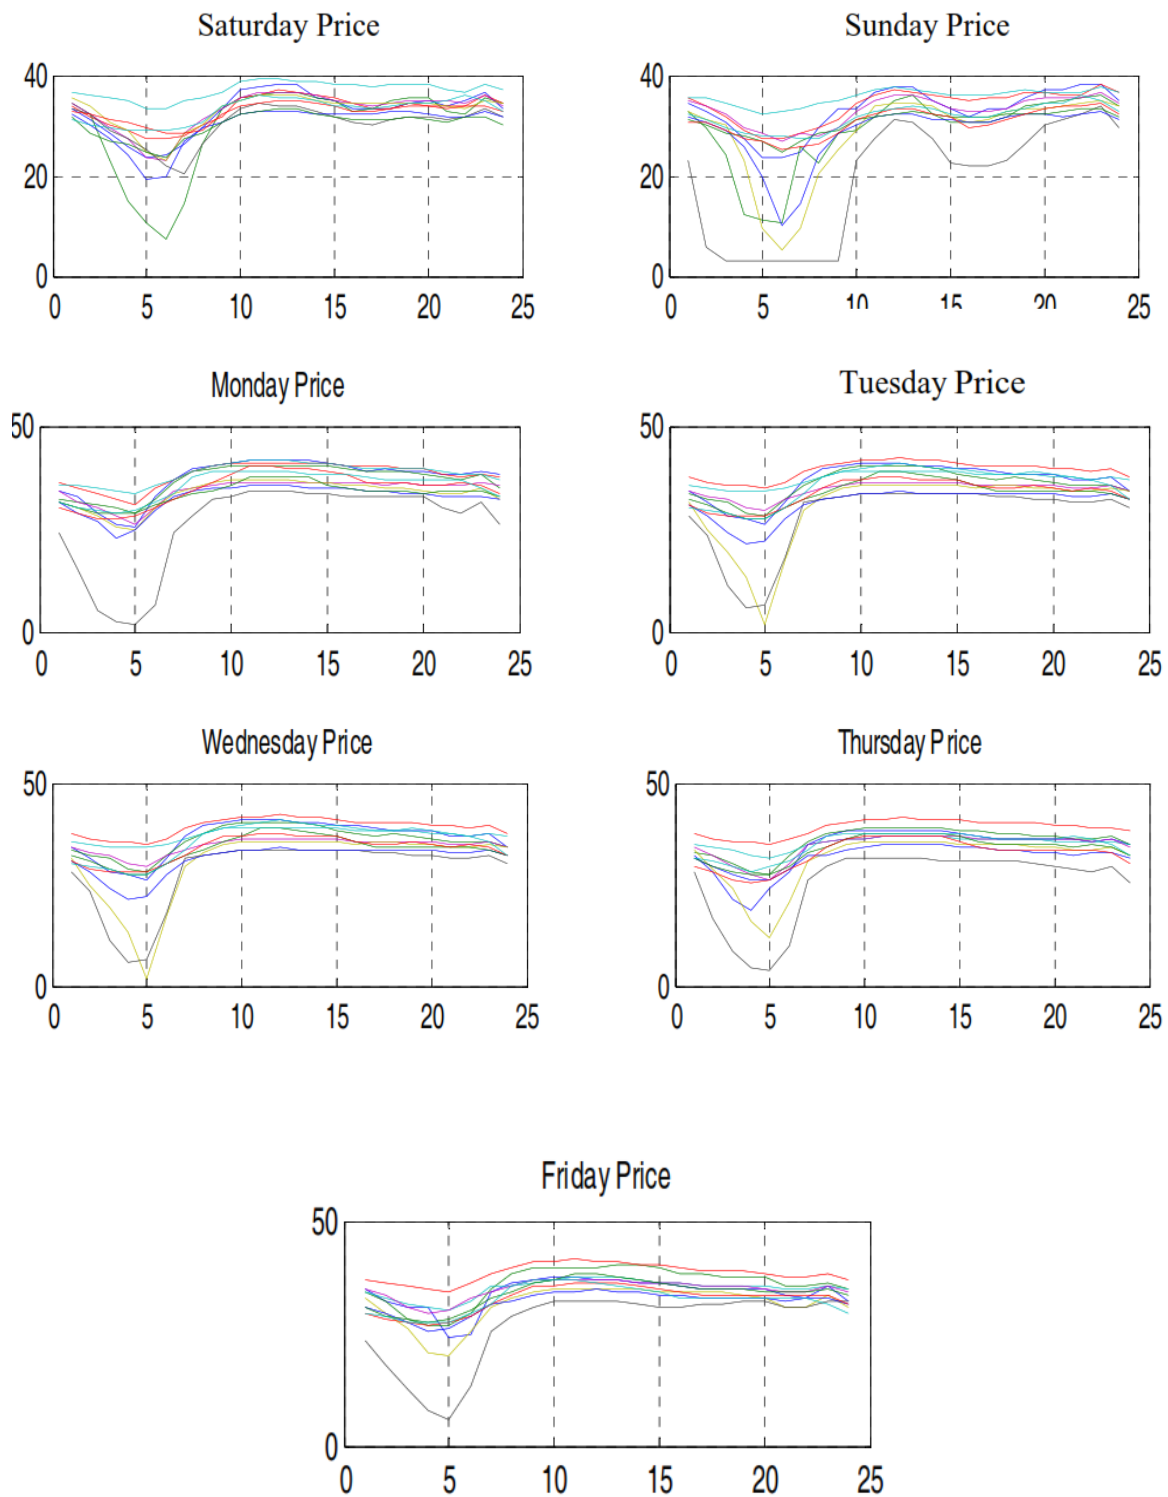
شکل ۲: بار در سه فصل سال



شکل ۳: قیمت برق در روزهای مختلف هفته



شکل ۴: بار روزهای مختلف هفته




شکل ۵: الگوی قیمتی در روزهای مختلف هفته

۳-۲ الگوریتم بهینه‌سازی گرگ خاکستری

در اطراف ما، همواره نشانه‌هایی برای الگوبرداری جهت حل و بهینه‌سازی مسائل پیچیده وجود دارد. در این نوشتار، درخصوص الگوریتمی صحبت خواهد شد که با الگوبرداری از یک سازمان طبیعی برای حل مسائل بهینه‌سازی مورد استفاده قرار می‌گیرد. در این نوشتار، به صورت خلاصه به الگوریتم بهینه‌سازی گرگ خاکستری پرداخته خواهد شد. همان‌گونه که پیداست، الگوریتم بهینه‌سازی گرگ خاکستری یا Grey Wolf Optimization (GWO)، از سازمان‌دهی موجود در گرگ خاکستری برای شکارکردن در طبیعت الگوبرداری می‌کند [۱۳]. این الگوریتم، در سال ۲۰۱۴ میلادی توسط میرجلیلی و همکاران در دانشگاه شهید بهشتی ارائه شد. الگوریتم مذکور، همانند الگوریتم‌های PSO و ACO جزو الگوریتم‌های هوش جمعی است و برای تعیین موقعیت گرگ‌ها در فضای حل مسئله، تنها از یک عملگر (ترکیبی) استفاده می‌کند.

گرگ‌های خاکستری، موجوداتی هستند که به صورت نیمه‌دمکراسی زندگی می‌کنند و جایگاه هر گرگ در اجتماع آن‌ها پیداست. در این اجتماع، گرگ رهبر، جانشینان او و سایر گرگ‌ها نیز شناخته شده هستند. گرگ‌های خاکستری، به صورت دسته‌جمعی زندگی و شکار می‌کنند. در هر گروه از گرگ‌های خاکستری، به طور متوسط بین ۷ الی ۱۲ گرگ وجود دارد. این ۴ دسته‌ها، یکی از خطرناک‌ترین شکارچیان هستند. گرگ‌های خاکستری، برای شکار کردن ابتدا دور طعمه حلقه زده و طعمه را محاصره می‌کنند و با تنگ‌تر کردن حلقه‌ی محاصره، شروع به خسته کردن طعمه می‌کنند. سپس به صورت نوبتی و با دستور گرگ رهبر، به طعمه حمله کرده و در نهایت طعمه را از پای درمی‌آورند. در شکل زیر، نمونه‌ای از حمله‌ی گرگ‌ها به شکار در دنیای واقعی آورده شده است.



شکل ۶: نمونه‌ای از حمله‌ی گرگ‌ها به شکار در دنیای واقعی

پیش‌بینی بازار برق به کمک شبکه‌ی عصبی و.....

گاهی مشاهده شده است که در صورت از دست دادن امگاها، کل دسته دچار مشکلات و جنگ‌های داخلی می‌شود.

به گرگ‌هایی که در سلسله‌مراتب بالا ذکر نشده است، گرگ‌های دلتا [Delta] گفته می‌شود. گرگ‌های دلتا، تحت فرمان آلفا و بتا بوده؛ ولی نسبت به امگا برتری دارند.

بر اساس این موارد، الگوریتم GWO تبیین شد و معادلات ریاضی زیر در GWO به کار می‌رود.

همان‌طور که در بخش‌های پیشین اشاره شد، گرگ‌های خاکستری در طی فرآیند شکار، طعمه را محاصره می‌کنند. برای مدل کردن سازوکار شکار، از روابط زیر استفاده می‌شود [۱۳]:

$$\vec{D} = |\vec{C} \cdot \vec{X}_p(t) - \vec{X}(t)| \quad (1)$$


$$\vec{X}(t+1) = \vec{X}_p(t) - \vec{A} \cdot \vec{D} \quad (2)$$

$$\vec{A} = 2\vec{a} \cdot \vec{r}_1 - \vec{a} \quad (3)$$

$$\vec{C} = 2 \cdot \vec{r}_2 \quad (4)$$

- در روابط بالا، t ، برابر تکرار الگوریتم است.
- بردارهای A و C ، ضرایب بردار مکان طعمه و X ، بردار مکان گرگ خاکستری است.

همان‌گونه که بیان شد، گرگ‌های خاکستری به صورت یک سلسله‌مراتب (با سخت‌گیری زیاد) زندگی می‌کنند. شکل زیر، ساختار سلسله‌مراتب گرگ‌های خاکستری را نشان می‌دهد.



شکل ۷: ساختار سلسله‌مراتب گرگ‌های خاکستری


جفت آلفا [Alpha] که به عنوان رهبر گروه شناخته می‌شوند، تصمیم‌گیری درباره‌ی شکار، مکان خواب، زمان بیدار شدن و... را بر عهده دارند. تصمیمات آلفا، به کل گروه اعمال می‌شود. با این حال، نوعی رفتار دموکراتیک نیز مشاهده می‌شود.

رده‌ی دوم در سلسله‌مراتب یک دسته، متعلق به گرگ‌های بتا [Beta] است. گرگ‌های بتا به آلفا در تصمیم‌گیری‌ها و سایر فعالیت‌های دسته کمک می‌کنند. این گرگ‌ها در مواقعی که آلفا بسیار پیر شده و یا می‌میرد، بهترین کاندید برای آلفا شدن هستند.

گرگ‌های با پایین‌ترین مقام، گرگ‌های امگا [Omega] هستند. این گروه از گرگ‌ها، نقش پیش‌مرگ را در دسته بازی می‌کنند. آن‌ها باید مطیع تمام گرگ‌های دیگر باشند و همچنین آخرین گرگ‌هایی هستند که غذا می‌خورند. این‌طور به نظر می‌آید که امگاها اهمیت پایینی در دسته دارند؛ اما

- a به صورت خطی و در طی تکرارها از مقدار ۲ به ۰ کاهش می یابد. Γ_1 و Γ_2 بردارهای تصادفی در بازه $[0/1]$ هستند.

برای یک مسئله‌ی دوبعدی، بردارها به صورت زیر خواهد بود (موقعیت بردارها در دو بعد و موقعیت بعدی آنها):



شکل ۸: موقعیت بردارها در دو بعد و موقعیت بعدی آنها

معادلات ریاضی الگوریتم GWO با در نظر گرفتن سلسله مراتب موجود در شکل ۲:

$$\vec{D}_\alpha = |\vec{C}_1 \cdot \vec{X}_\alpha - \vec{X}|, \vec{D}_\beta = \quad (5)$$


$$|\vec{C}_2 \cdot \vec{X}_\beta - \vec{X}|, \vec{D}_\delta = |\vec{C}_3 \cdot \vec{X}_\delta - \vec{X}|$$

$$\vec{X}_1 = \vec{X}_\alpha - \vec{A}_1 \cdot (\vec{D}_\alpha), \vec{X}_2 = \vec{X}_\beta - \quad (6)$$

$$\vec{A}_2 \cdot (\vec{D}_\beta), \vec{X}_3 = \vec{X}_\delta - \vec{A}_3 \cdot (\vec{D}_\delta)$$

$$\vec{X}(t+1) = \frac{\vec{X}_1 + \vec{X}_2 + \vec{X}_3}{3} \quad (7)$$

فلوچارت الگوریتم GWO به صورت زیر است:



شکل ۹: فلوچارت الگوریتم GWO

پیش‌بینی بازار برق به کمک شبکه‌ی عصبی و.....

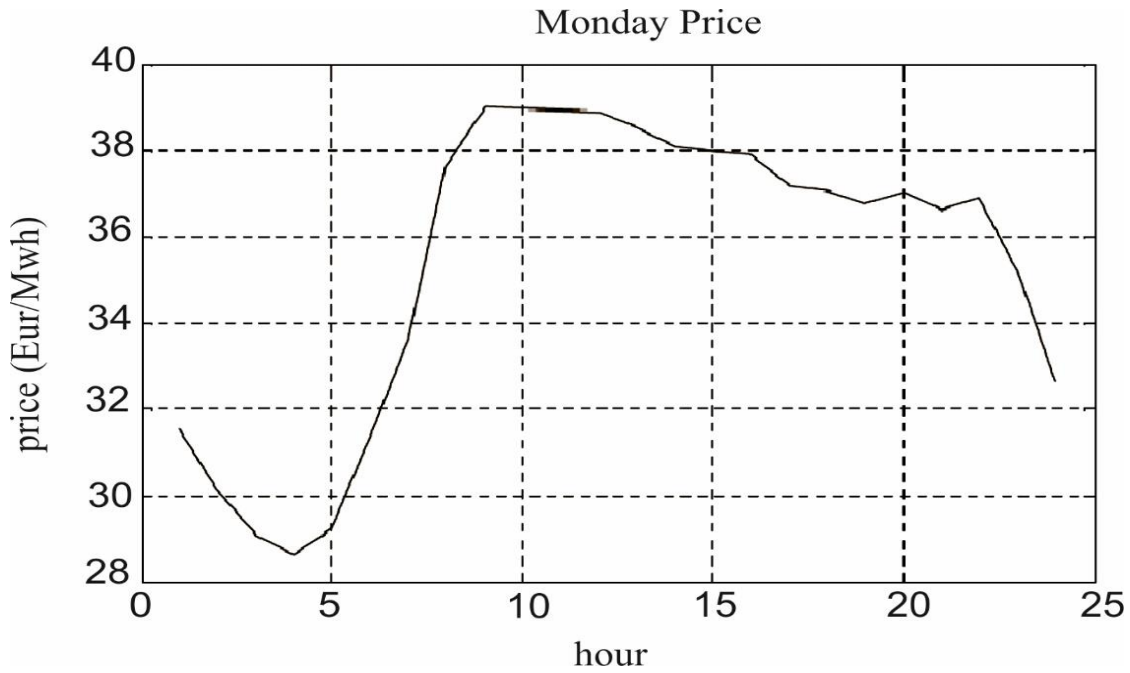
۳-۳. طراحی شبکه‌ی عصبی

می‌شویم که در روزهای تعطیل مقدار قیمت از روزهای عادی پایین‌تر است. دلیل این موضوع، این است که در روزهای تعطیل، کارخانجات و مراکز صنعتی بزرگ، مصرف خود را کم می‌کنند و اکثر مصرف سیستم برای مراکز خانگی است؛ بنابراین، Gencoها برای جلوگیری از خاموش شدن واحد و راه‌اندازی مجدد ژنراتورها، (هزینه‌ی راه‌اندازی واحدهای بخار بسیار بالا است) مصرف‌کنندگان خود را به مصرف در روزهای تعطیل و ساعت اولیه‌ی روز و یا پایانی شب، تشویق می‌کنند و برای این امر، قیمت خرید انرژی برای مصرف‌کننده را بسیار پایین می‌آورند؛ به‌عنوان مثال، قیمت برق در ساعت ۱۰ یک روز تعطیل، ممکن است حدود (Eur/MWh) ۲۰ باشد که در همین ساعت یک روز عادی، قیمت حدود (Eur/MWh) ۴۰ است. در بعضی مواقع، تولیدکنندگان برای رهایی از هزینه‌ی راه‌اندازی، حتی ممکن است قیمت را به صفر هم برسانند.

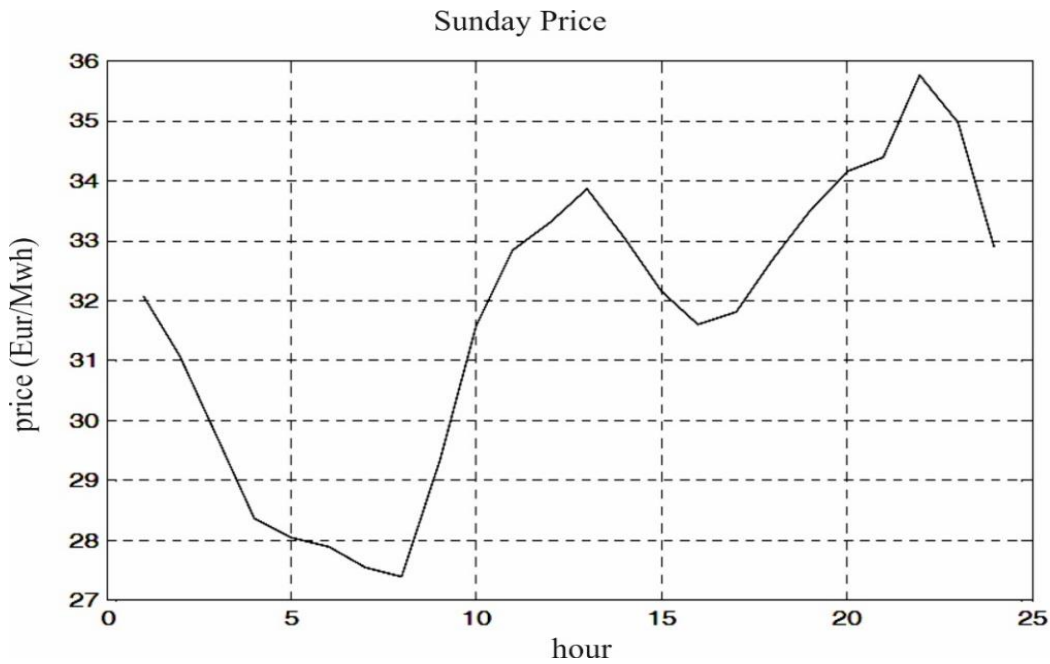
هنگامی که مدل‌های مختلف قیمتی را در بازار نوردیک مورد بررسی قرار می‌دهیم، به نکاتی برمی‌خوریم که در اینجا به ذکر بعضی از آنها که برای طراحی شبکه عصبی نیاز است، پرداخته می‌شود.

الف) قیمت در ساعات اولیه‌ی نیمه‌شب در روزهای عادی از مقدار کمی برخوردار است و به‌مرور که به سمت روشنایی پیش می‌رویم، به مقدار این قیمت افزوده شده و در ساعات میانی روز به ماکزیمم مقدار خود می‌رسد. با توجه به این نکته، تقسیم شبکه‌ی اصلی به چند زیر شبکه که کارایی مدل را بالا ببرد، بسیار مفید خواهد بود.

ب) در روزهای مختلف هفته، قیمت متفاوت است؛ به‌عنوان مثال، اگر دو نمودار قیمت در روزهای هفته را که در آن قیمت روز دوشنبه و روز یکشنبه نمایش داده شده است، مقایسه کنیم، متوجه



شکل (۱۰): قیمت روز دوشنبه



شکل (۱۱): قیمت روز یکشنبه (تعطیل)

برای طراحی شبکه‌ی عصبی جهت پیش‌بینی قیمت، داده‌ها را جهت آموزش شبکه به صورت زیر تقسیم می‌کنیم:

این تفاوت قیمت بین روزهای تعطیل و غیرتعطیل آشکار است؛ به عنوان مثال، در ساعت ۱۰ که در اکثر روزهای کاری بالاترین قیمت را برای انرژی داریم، در روز یکشنبه، قیمتی معادل ۳۲ دلار داریم.

پیش‌بینی بازار برق به کمک شبکه‌ی عصبی و.....

- قیمت از ساعت ۱ - ۶
- قیمت از ساعت ۷ - ۱۲
- قیمت از ساعت ۱۳ - ۱۸
- قیمت از ساعت ۱۹ - ۲۴

قیمت همان روز در دو ساعت قبل P (d, h-2)

قیمت همان روز در سه ساعت قبل P (d, h-3)

قیمت همان روز در چهار ساعت قبل P (d, h-4)

قیمت همان روز در پنج ساعت قبل P (d, h-5)

قیمت همان روز در شش ساعت قبل P (d, h-6)

قیمت روز قبل در همان ساعت قبل P (d-1, h)

قیمت آن روز در هفته قبل و همان ساعت (d-7, h)

اما در این مقاله، هدف پیش‌بینی قیمت برای روز آینده است و در این حالت برای هر کدام از شبکه‌های چهارگانه در هر روز، اطلاعات ورودی به صورت زیر خواهند بود.

$$P = \begin{bmatrix} p_1 \\ p_2 \\ p_3 \\ \vdots \\ p_n \end{bmatrix}$$

عناصر بردار P، قیمت‌های روز گذشته در همان ساعت است؛ به عنوان مثال، اگر هدف پیش‌بینی قیمت از ساعت ۱-۶ صبح روز چهارشنبه باشد، باید قیمت همین ساعات روز سه‌شنبه به شبکه ارائه شود.

$$T = \begin{bmatrix} t_1 \\ t_2 \\ t_3 \\ \vdots \\ t_n \end{bmatrix}$$

ذکر این نکته ضروری است که به دلیل آنکه روز قبل از دوشنبه یعنی یکشنبه یک روز تعطیل است

خروجی شبکه نیز به همین صورت خواهد بود؛ یعنی همانند تقسیم‌بندی فوق برای هر ورودی، خروجی معادل را خواهیم داشت و سپس آن‌ها را کنار هم قرار داده و قیمت یک روز را به دست می‌آوریم؛ به عبارت دیگر، جهت آموزش شبکه، داده‌های روزهای قبل را به ۴ قسمت تقسیم کرده و به شبکه ارائه می‌کنیم. به طور کلی برای مدل ارائه شده، هفت گروه روز را در نظر می‌گیریم.

- دوشنبه نوع ۱

- سه‌شنبه نوع ۲

- چهارشنبه نوع ۳

- پنجشنبه نوع ۴

- جمعه نوع ۵

- شنبه نوع ۶


- یکشنبه نوع ۷

به عنوان مثال، اگر هدف پیش‌بینی قیمت در ۱ ساعت آینده باشد، آنگاه باید اطلاعات زیر به عنوان ورودی باشند.

قیمت همان روز در یک ساعت قبل P (d, h-1)

و استفاده از آن به عنوان ورودی جهت پیش‌بینی قیمت روز دوشنبه به عنوان یک روز کاری ممکن است کارایی شبکه را پائین بیاورد، از روز جمعه که آخرین روز کاری هفته می‌باشد، برای پیش‌بینی قیمت روز دوشنبه استفاده شده است.

روز شنبه و یکشنبه، با دیگر روزهای هفته متفاوت‌اند و علت آن تعطیل بودن آن‌هاست. روز شنبه و یکشنبه از الگوی همین روزها در هفته‌های قبل پیروی می‌کنند و نگارندگان متن حاضر نیز این الگوها یعنی هفته‌های قبل را برای آموزش به شبکه در نظر می‌گیرند.



شکل (۱۲): نمای کلی از ANN برای STPF

نرون افزایش می‌یابد که در قسمت بعد توضیح داده خواهد شد.

تعداد نرون‌ها در لایه‌ی پنهان، از قاعده‌ی خاصی پیروی نمی‌کند و فقط با سعی و خطا می‌توان تعداد آن‌ها را در این مرحله پیدا کرد. تعداد زیاد نرون‌ها، دقت شبکه را بالا می‌برد؛ اما زمان آموزش را نیز به همان نسبت و شاید هم بیشتر بالا می‌برد و بالعکس، کاهش نرون‌ها از دقت شبکه کاسته و

به‌طور کلی، می‌توان شبکه‌ی عصبی مورد استفاده در این پروژه را در شکل فوق مشاهده کرد. البته این شبکه برای یک روز بوده و برای پیش‌بینی هفتگی، به هفت شبکه مشابه آن نیاز است. با توجه به این شکل، هرکدام از این زیر شبکه‌ها دارای ۶ نرون ورودی و ۶ نرون خروجی است. البته این تعداد برای ورودی، هنگامی که از بار همراه با قیمت برای پیش‌بینی قیمت استفاده می‌شود، به ۱۲

پیش‌بینی بازار برق به کمک شبکه‌ی عصبی و.....

را دارند که این موضوع، MAPE را بسیار زیاد می‌کند؛ به‌عنوان مثال، فرض کنید که قیمت واقعی حدود صفر است؛ بنابراین، MAPE معادل با بی‌نهایت می‌شود. پس برای محاسبه‌ی این معیار باید رابطه‌ای جدید تعریف کرد. رابطه‌ی MAPE برای پیش‌بینی قیمت به‌صورت زیر تعریف می‌شود:

$$Actual_{avr} = \frac{1}{N} \sum_{i=1}^N Actual_i \quad (9)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \frac{|Actual_i - Forecast_i|}{Actual_{avr}} \times 100 \quad (10)$$

در رابطه $Actual_{avr}$ مقدار متوسط قیمت واقعی است که در مخرج رابطه‌ی دوم به‌کار رفته است. مزیت این رابطه، در این است که دیگر هیچ‌گاه مخرج رابطه‌ی (۱۰) صفر و یا نزدیک به آن نخواهد شد و نگرانی‌ها در رابطه با اشتباه محاسبه کردن MAPE برطرف خواهد شد.

اکنون که معیار مقایسه را یافتیم، به مقایسه‌ی شبکه‌ها با یکدیگر می‌پردازیم. اولین مقایسه‌ای که انجام می‌گیرد، به طرح تقسیم شبکه به چهار زیر شبکه مربوط است که در آن هر زیر شبکه، دارای ورودی ۶ ساعتی است. برای این کار، یک روز از کل داده‌ها و روزهای مختلف را بدون توجه به تعطیلی و یا عادی بودن آن انتخاب می‌کنیم و درصد خطای آن را محاسبه می‌کنیم. در همین زمان، این روز را با شبکه‌ای که ورودی آن ۲۴ ساعتی است، پیش‌بینی می‌کنیم؛ اما از آنجایی که

زمان آموزش را می‌کاهد. قبل از اینکه به مقایسه‌ی شبکه در حالت‌های مختلف پرداخته شود، باید معیار مقایسه‌ی شبکه نیز تعریف گردد. این معیار، به‌اتفاق نظر تمامی مقالات در زمینه‌ی پیش‌بینی MAPE^۱ یعنی درصد متوسط خطای مطلق است که در زیر به شرح آن پرداخته خواهد شد.

❖ درصد خطای مطلق (MAPE)

هنگامی که دست به عمل پیش‌بینی می‌زنیم، باید طرح مورد مطالعه را که می‌تواند شبکه‌ی عصبی، رگرسیون و یا سری زمانی باشد، طوری تنظیم کنیم که خطای حاصل از آن به حداقل ممکن برسد و در نهایت طرح‌های مختلف را با یکدیگر مقایسه کنیم تا ببینیم که کدام طرح بهتر است. یک معیار مقایسه برای پیش‌بینی قیمت و یا بار، مقدار درصد خطای مطلق و یا MAPE است که به‌صورت زیر تعریف می‌شود:

$$MAPE = \frac{1}{N} \sum_{i=1}^N \frac{|Actual_i - Forecast_i|}{Actual_i} \times 100 \quad (8)$$

که در این رابطه، N تعداد نمونه‌های پیش‌بینی شده و یا واقعی است. رابطه‌ی فوق، برای اندازه‌گیری خطا در موارد پیش‌بینی بار، رابطه‌ای کارآمد است؛ اما در رابطه با قیمت این‌گونه نیست؛ زیرا همان‌گونه که در بخش‌های قبل شرح داده شد، در بعضی از روزها یا ساعات، تولیدکنندگان انرژی سعی در فروش قیمت با نرخ‌های نزدیک به صفر

^۱ Mean Absolute Percentage Error

پس از هر بار اجرای برنامه مقدار MAPE فرق می‌کند، برنامه را برای هر کدام از حالت‌ها ۳ بار اجرا می‌کنیم و در نهایت، مقدار متوسط می‌گیریم. نتایج

جدول (۱): مقایسه شبکه‌های تقسیم‌شده و یکپارچه

دفعات اجرای برنامه	MAPE (%)	
	حالت تک شبکه‌ای با ۲۴ ورودی	حالت ۴ شبکه‌ای با ۶ ورودی
۱	۵/۱۹	۲/۵
۲	۲/۳۵	۲/۴۱
۳	۴/۴۹	۳/۰۲
متوسط	۳/۹۴	۲/۰۶

آموزشی شبکه را زیاد انتخاب کنیم، شبکه داده‌هایی را که جلوتر برای آموزش به شبکه ارائه شده‌اند، کم‌کم فراموش کرده و پارامترهای (وزن‌ها و بایاس‌ها) خود را برای داده‌های جدید تنظیم می‌کند و باز هم ممکن است با ارائه‌ی یک ورودی جدید، خطای شبکه زیاد باشد؛ بنابراین، انتخاب تعداد داده‌های آموزشی را از ۲۰ تا ۳۵ بردار انتخاب می‌کنیم. برای مقایسه‌ی پاسخ شبکه به تعداد بردارهای مختلف جدول (۲) تنظیم شده است.

نتایج جدول فوق، دلیلی بر انتخاب شبکه‌ای با ۴ زیرمجموعه است. علت اینکه MAPE مقدار کمتری پیدا کرده، می‌تواند این باشد که در حالت ۴ شبکه‌ای مدل ANN، توانایی تفکیک بیشتری را پیدا می‌کند و وزن‌ها و بایاس‌ها، خودشان را برای ورودی و خروجی‌های کمتری تنظیم می‌کنند و بنابراین، نتایج بهتری حاصل خواهد شد.

دومین مقایسه‌ای که برای این بخش در نظر گرفته شده، انتخاب تعداد بردارهای آموزشی است. اگر تعداد بردارها برای آموزش را کم انتخاب کنیم، شبکه توانایی طبقه‌بندی تعداد گروه‌های کمتری را پیدا خواهد کرد که ممکن است با اعمال ورودی‌های جدید، نتایج مطلوب حاصل نشده و مقدار خطا زیاد باشد؛ اما اگر تعداد بردارهای

جدول (۲): تعداد بردارهای آموزشی

شماره اجرا	تعداد بردارها جهت آموزش					
	۲۰	۲۳	۲۵	۲۸	۳۰	۳۵
	MAPE (%)					
۱	۱۰/۶۴	۲/۰۱	۲/۵	۲/۴	۸/۴	۴/۰۹
۲	۱۲/۳۸	۱/۹	۲/۶	۲/۶۳	۸/۶۴	۳/۹۳
۳	۹/۲۵	۲/۲	۲/۴۳	۲/۲۷	۸/۱	۴/۲۱
متوسط	۱۰/۷۵	۲/۰۶	۲/۰۶	۲/۴۳	۸/۳۸	۴/۰۷

قیمت هر کالایی در بازار، از عوامل مختلفی تأثیر می‌پذیرد که این عوامل، گاه پیدا و گاه نهان هستند؛ اما بعضی مواقع بحران‌های اقتصادی، قیمت را آن‌چنان تغییر می‌دهند که امکان پیش‌بینی آن بسیار مشکل است. در چنین مواقعی باید به روش‌هایی که ذکر شد، رو آورد که از میان این روش‌ها، به توزیع احتمالاتی قیمت می‌توان اشاره کرد.

الف) حذف چنین موارد غیرعادی

ب) استفاده از حد بالای قیمت

روش (الف)، روش چندان خوبی به نظر نمی‌رسد؛ چراکه حالات غیرعادی همیشه جزء بازار است و نمی‌توان به‌طور کامل آن‌ها را حذف کرد؛ اما روش (ب)، روشی است که در آن قیمت را حذف نمی‌کنیم، بلکه آن را نرم کرده و شیب صعودی‌اش را کم می‌کنیم. جهت استفاده از روش (ب)، باید از رابطه‌ی زیر استفاده کنیم:

$$P' = \begin{cases} P & \text{if } P < UL \\ UL + UL * \text{Log} \left(\frac{P}{UL} \right) & \text{if } P > UL \end{cases} \quad (11)$$

در این رابطه، P قیمت واقعی سیستم است و P' قیمت تبدیل شده‌ی آن است. اگر قیمت سیستم از قیمتی به‌عنوان قیمت حدی، UL ، تعیین کردیم کمتر

در توزیع احتمالاتی قیمت، برای نقاط ماکزیمم و مینیمم قیمتی که ممکن است در هر روز یک مقدار خاصی را برگزیند، یک احتمال در نظر گرفته می‌شود و با توجه به آن احتمال مقدار قیمتی که توسط شبکه‌ی عصبی پیش‌بینی شده است، تخمین زده می‌شود. این روش، با محاسبات زیادی همراه بوده و معمولاً استفاده از آن بسیار وقت‌گیر است.

در تحقیق حاضر، سعی شده تا با استفاده از روش‌های دیگر از این روش صرف‌نظر شود؛ اما هدف از این بخش، ارائه‌ی راهکاری جهت کنترل پاسخ شبکه به چنین داده‌هایی (داده‌های بحرانی) جهت آموزش و یا ورود به شبکه است. هنگامی

دست آورده شود. با انتخاب کم نرون‌ها، شبکه قادر به نگاشت مناسب ورودی به خروجی نخواهد بود، از طرف دیگر، انتخاب زیاد نرون‌ها توانایی یادگیری را پایین آورده و زمان آموزش را افزایش می‌دهد. شبکه ممکن است نقاط آموزش را بیش‌ازحد در نظر گرفته و توانایی‌اش در استخراج مشخصه‌های مربوط به دیگر ورودی‌های پایین بیاید. به این مسئله، بیش‌برازش^۱ گفته می‌شود.

بعضی قوانین جهت تعیین حد بالای نرون‌های مورد نیاز در شبکه و حد بالای وزن‌ها آورده شده است. یکی از این قوانین، به شرح زیر است که در آن تعداد نرون‌های لایه پنهان را مشخص می‌کند:

$$(۱۳) \text{تعداد نرون‌ها در لایه خروجی} \times \text{تعداد نرون‌ها در لایه ورودی} = \sqrt{\text{تعداد نرون‌ها در لایه پنهان}}$$

در کلیه حالاتی که از الگوریتم گرگ خاکستری برای تعیین این تعداد استفاده نمی‌کنیم، از رابطه‌ی فوق جهت تعیین نرون‌ها استفاده کرده و به ذکر این نکته اکتفا می‌کنیم که صحت رابطه‌ی گفته‌شده در اکثر شبکه‌ها برقرار است و درستی این رابطه با سعی و خطا به دست خواهد آمد.

یکی دیگر از نکاتی که باید به آن اشاره کرد، این است که توابع به کار گرفته‌شده در مدل ارائه شده توابع هستند. استفاده از توابع خطی، مقدار MAPE را زیاد می‌کند و باعث واگرایی شبکه و جواب‌های

باشد، آنگاه $P' = P$ می‌باشد؛ اما اگر این قیمت از UL بیشتر باشد، به صورت لگاریتمی خم کرده و از افزایش بیش‌ازحد آن جلوگیری می‌کنیم. در این مقاله، قیمت حدی را (Eur/MWh) ۵۰ در نظر گرفته‌ایم. باید توجه داشت که بعد از شبیه‌سازی شبکه با ورودی‌های جدید باید آن‌ها را به حالت ابتدایی خود بازگرداند که برای این موضوع باید از رابطه‌ی (۵) که عکس عمل لوگاریتم است، استفاده کرد.

$$K = \begin{cases} K' & \text{if } K' < UL \\ UL * 10^{(K' - UL)/UL} & \text{if } K' > UL \end{cases} \quad (۱۲)$$

که در این رابطه، K' پاسخ شبکه و K مقدار واقعی قیمت است.

۴- روش پیشنهادی

تعداد نرون‌ها در ورودی و خروجی به‌وسیله‌ی تعداد متغیرهای ورودی و خروجی مشخص می‌شود. همان‌طور که در قسمت‌های قبل هم گفته شد، تعداد نرون‌ها در مدل ارائه شده در ورودی و خروجی و در حالتی که بار را نیز جزء شاخص‌های ورودی به حساب آوریم، در لایه‌ی پنهان توانایی یادگیری شبکه را تعیین کرده و با پیچیدگی مسئله، تعیین می‌شود. برای یک شبکه تعامل میان دقت و توانایی کلی، می‌تواند به‌وسیله‌ی انتخاب مناسب واحدهای پنهان به

^۱ Over fitting

پیش بینی بازار برق به کمک شبکه‌ی عصبی و.....

ابتدا رابطه‌ی بار و قیمت را به دست آوریم و درصد همبستگی آن‌ها را حساب کنیم. برای این موضوع، می‌توانیم از کواریانس بار و قیمت استفاده کنیم.

کواریانس و بعد از آن ضریب همبستگی به صورت زیر تعریف می‌شوند:

$$COV(p, d) = E[(p - \mu_p) \cdot (d - \mu_d)] \quad (14)$$

$COV(p, d)$: کواریانس قیمت و تقاضا

E : امید ریاضی

μ_p : امید ریاضی قیمت

μ_d : امید ریاضی تقاضا

p, d به ترتیب تقاضا و قیمت می‌باشند.

بعد از محاسبه‌ی کواریانس، نوبت به محاسبه‌ی ضریب همبستگی می‌رسد که رابطه‌ی بار و قیمت را توضیح می‌دهد و به شرح زیر است.

$$P_{p,d} = COV(p, d) / \sigma_p \sigma_d \quad (15)$$

$$\sigma_p = \sqrt{\sum_{i=1}^n (p_i - p_{avr})^2 / n} \quad (16)$$

$$\sigma_d = \sqrt{\sum_{i=1}^n (d_i - d_{avr})^2 / n} \quad (17)$$

که در این رابطه σ_p ، انحراف استاندارد قیمت و σ_d ، انحراف استاندارد بار و $P_{p,d}$ ضریب همبستگی (Correlation Coefficient) قیمت و بار است.

نامعقول می‌شود؛ اما استفاده از تابع سیگموئیدی در لایه‌ی پنهان و خروجی، ما را در به دست آوردن جوابی منطقی تر هدایت می‌کند. تا اینجا آماده‌ایم که شبکه را برای اجرا و شبیه‌سازی آموزش دهیم. تنها موضوع باقیمانده در آموزش شبکه، پیش‌پردازش داده است که در بخش‌های بعدی به آن اشاره کرده و کل شبیه‌سازی‌ها را بعد از ذکر پیش‌پردازش و پس‌پردازش داده انجام خواهیم داد. اغلب علت افزایش قیمت به دلیل افزایش مصرف، تعمیرات اضطراری ژنراتور، وقوع تراکم و یا اتفاقی در خط است. هرچند که این موضوع ممکن است خود به دلیل‌های غیرمعمول ایجاد شود؛ برای مثال، در ژانویه‌ی سال ۲۰۰۴، سرمای شدید هوا که در ۱۰۰ سال گذشته بعد از سال ۱۸۹۳ بی‌سابقه بود، منجر به افزایش قیمت در سراسر زمستان، نوسان قیمت سوخت‌ها و مصرف بیش‌ازحد شد. در این زمان، در میان روزهای ۱۴ تا ۱۶ ژانویه، قیمت گاز طبیعی بیش از ۱۰ برابر گشت و ۴۰ درصد نیروگاه‌های بازار نیو انگلند^۱ که گاز طبیعی می‌سوزانند، افزایش قیمت داشتند؛ و بدین ترتیب، قیمت انرژی الکتریکی در عمده‌فروشی بالغ بر ۵۰۰ دلار بر مگاوات ساعت در ۱۵ ژانویه شد. با توجه به مثال ذکرشده در بالا، چنین به نظر می‌رسد که استفاده از بار به‌عنوان مشخصه‌ای دیگر از داده‌های آموزشی ورودی برای بهتر آنالیز کردن و تفکیک کردن خروجی، مفید به نظر می‌رسد؛ اما قبل از آن باید

^۱. New England

$P_{p,d} = 1$ ، نشان‌دهنده‌ی این است که بین بار و قیمت، یک رابطه‌ی کاملاً خطی وجود دارد و هرچه این مقدار کمتر شود، از این رابطه‌ی خطی کاسته می‌شود؛ تا جایی که $P_{p,d} = 0$ نشان‌دهنده‌ی این است که بین بار و قیمت هیچ رابطه‌ی نمی‌توان یافت؛ اما نتایج چنین نشان می‌دهند که همیشه و

جدول (۳): ضریب همبستگی بار و قیمت روز دوشنبه در چند ماه مختلف

روزهای دوشنبه	۹ مارس	۱۴ آوریل	۱۹ می	۲۴ ژوئن	۳۹ ژولای	۴ سپتامبر
$P_{p,d}$	۰/۷۹۹۷	۰/۹۳۹	۰/۹۷۵۹	۰/۹۱۵	۰/۹۱۷۸	۰/۹۹۰۲

با مقایسه‌ی این شکل‌ها (شکل ۹)، درمی‌یابیم که رابطه‌ی قیمت امروز و روز گذشته (b) از دیگر موارد بیشتر است. به همین دلیل، اولین و مهم‌ترین ورودی قیمت در روز گذشته است که ۶ ورودی اول شبکه را تشکیل می‌دهد. دومین مورد که بعد از رابطه‌ی قیمت دیروز و امروز از همه بالاتر است، رابطه‌ی قیمت و بار در همین روز است که گفته شد فرض بر این است که بار روز آینده را می‌دانیم؛ بنابراین، دومین ورودی را بار پیش‌بینی‌شده‌ی روز آینده در نظر می‌گیریم و بدین ترتیب، تعداد ورودی‌های شبکه به ۱۲ عدد افزایش می‌یابد.


هرچند که رابطه‌ی قیمت و دیگر موارد یعنی بار روز گذشته از مقدار قابل توجهی برخوردار است؛ ولی از این عناصر در محاسبه‌ی قیمت روز آینده استفاده نمی‌کنیم؛ چراکه سردرگمی شبکه افزایش یافته و امکان واگرا شدن و رسیدن به جواب‌های غیرمنطقی ایجاد می‌شود.

همان‌طور که انتظار می‌رفت، اعداد نشان‌دهنده‌ی رابطه‌ی تقریباً خطی بار و قیمت است؛ بنابراین، برای بالا بردن دقت شبکه می‌توان بار را به‌عنوان یکی دیگر از مشخصه‌های ورودی به‌عنوان داده‌ی آموزشی همراه با قیمت به شبکه وارد کرد. در این حالت و از آنجا که شبکه را به ۴ زیرشبکه تقسیم کرده‌ایم، تعداد ورودی‌های شبکه به ۱۲ عدد افزایش می‌یابد؛ اما به‌مراتب دقت تا حدودی بالا می‌رود. ضریب همبستگی میان قیمت و موارد مختلف نشان داده شده است. در این شکل، a، ضریب همبستگی میان قیمت روز فعلی و همین روز در هفته گذشته می‌باشد؛ b، همین ضریب را برای قیمت روز فعلی و روز گذشته نشان می‌دهد؛ c، رابطه‌ی قیمت امروز و بار در همین روز را مشخص می‌کند؛ و در نهایت d، ضریب همبستگی را میان قیمت روز فعلی و بار روز قبلی به نمایش می‌گذارد.


پیش‌بینی بازار برق به کمک شبکه‌ی عصبی و.....

واقعیت هم نیست؛ زیرا معمولاً پیش‌بینی بار با خطایی معادل ۱ الی ۲ درصد انجام شده و عموماً پیش‌بینی بار بسیار ساده‌تر از پیش‌بینی قیمت است؛ بنابراین، در مدل ارائه‌شده در این مقاله از مقدار بار واقعی سیستم به جای بار پیش‌بینی‌شده استفاده می‌شود. بدیهی است برای اینکه به واقعیت نزدیک‌تر شویم، باید حتماً عمل پیش‌بینی بار قبل از قیمت انجام شود؛ ولی همان‌طور که گفته شد، اگر داده‌های کافی در دسترس باشد، عمل پیش‌بینی بار به مقدار واقعی بسیار نزدیک خواهد بود.


نکته‌ی قابل توجه برای اضافه کردن بار -به‌عنوان یکی دیگر از مشخصه‌های قیمتی- این است که از آنجا که هدف ما پیش‌بینی قیمت روز آینده است، باید ابتدا بار روز آینده را پیش‌بینی کرده و سپس قیمت را به دست آوریم؛ اما از آنجا که پیش‌بینی بار نیاز به داده‌هایی همچون داده‌های آب‌وهوایی (مانند دما، سرعت باد، رطوبت و غیره) را دارد و ما از این داده‌ها اطلاعی نداریم، فرض می‌کنیم که بار روز آینده را داریم و با این فرض، قیمت را پیش‌بینی می‌کنیم. این فرض آن‌چنان دور از




ضریب همبستگی قیمت روز فعلی و همین روز در هفته-ی گذشته



ضریب همبستگی قیمت روز فعلی و روز گذشته



ضریب همبستگی قیمت روز فعلی و بار همین روز



ضریب همبستگی قیمت روز فعلی و بار روز گذشته

شکل (۱۳): ضریب همبستگی میان قیمت و موارد مختلف

قطعاً در محدوده‌ی برد مورد نظر قرار خواهد گرفت.

برای داده‌های خروجی نیز با توجه به تابع سیگموئیدی در خروجی ساینبدی ضروری خواهد بود و خروجی شبکه باید همانند ورودی که اصلاح شده، تغییر کند؛ زیرا خروجی در محدوده‌ی [۱ و -۱] است.

یکی از موارد ساینبدی داده‌ها، این است که همه‌ی داده‌ها را به یک طول واحد تبدیل کنیم؛ اما این نوع ساینبدی منجر به تخریب پراکندگی میان ورودی و خروجی خواهد شد. راه دوم، استفاده از نرمالیزه کردن داده‌ها است. این رهیافت، همه‌ی متغیرهای ورودی را به یک مقدار ماکزیمم و مینیمم نرمالیزه می‌کند. مراحل زیر، جهت نرمالیزه کردن اطلاعات در برنامه به کار گرفته شده است.

(۱) جمع‌آوری داده‌های آموزشی براساس انتخاب تعداد بردارها جهت آموزش؛

(۲) محاسبه‌ی اندازه‌های آماری همانند مینیمم و ماکزیمم هر بردار آموزشی؛

(۳) نرمالیزه کردن هر بردار با استفاده از رابطه زیر:

$$Y_n = \frac{Y - Y_{\min}}{Y_{\max} - Y_{\min}} * 2 - 1 \quad (18)$$

که در این رابطه، Y_n مقدار نرمالیزه‌شده‌ی بردار آموزشی ورودی Y ،

Y_{\max} مقدار ماکزیمم بردار ورودی،

Y_{\min} مقدار مینیمم بردار ورودی است.

جهت آموزش شبکه برای پیش‌بینی قیمت یک روز خاص، دنبال آموزشی از چند هفته پیش از آن روز جمع‌آوری شده و به شبکه آموزش داده می‌شود و شبکه، توانایی تفکیک آن را خواهد داشت؛ در نتیجه، پراکندگی قیمت در فصل‌های مختلف، ذاتاً به حساب آورده شده و دیگر نیاز به شاخص فصلی در مدل که نشان‌دهنده‌ی فصل‌های مختلف است، نمی‌باشد؛ اما قبل از آموزش شبکه به وسیله‌ی این داده‌ها، چند اصلاح باید بر روی داده‌ها انجام شود.

از آنجایی که متغیرهای ورودی مختلف عموماً محدوده‌ی برد مختلفی را همراه دارند، به کار بردن مستقیم داده‌ها برای آموزش ممکن است منجر به واگرا شدن مسئله شود؛ برای مثال، در مسئله‌ی پیش‌بینی قیمت، قیمت دارای مقادیری در محدوده‌ی ۱۰ تا ۸۰ دلار بوده و این در حالی است که تابع تانژانت هیپربولیک، دارای خروجی بین [۱ و -۱] است و قطعاً خروجی مطلوب حاصل نخواهد شد. هنگامی که بار را نیز به عنوان قسمت دوم داده‌ی آموزشی به شبکه ارائه می‌کنیم، مسئله بدتر می‌شود؛ چراکه در این حالت، بار محدوده‌ای بین ۱۰ تا $4.5 * 10^4$ مگاوات را داراست و هنگامی که بار و قیمت همراه با هم به شبکه ارائه شوند، نتایج کاملاً غیرعادی خواهند بود؛ بنابراین، کاملاً منطقی است که متغیرها را در یک برد یکسان ساینبدی کنیم. ساینبدی متغیرهای ورودی، این اطمینان را می‌دهد که هر ورودی با هر مقداری

پیش‌بینی بازار برق به کمک شبکه‌ی عصبی و.....

۴) ایجاد فایل داده‌ی آموزشی برای هر شبکه (اکنون شبکه برای آموزش آماده است)؛

۵) ذخیره کردن مقادیر مینم و ماکزیمم آخرین ورودی از قیمت برای بازگرداندن خروجی به مقدار واقعی.

واضح است از آنجا که خروجی شبکه مقدار بسیار کمی در محدوده‌ی [۱- و ۱] خواهد داشت، باید آن را به مقدار قابل فهم ترجمه کرد که برای این حالت باید عکس رابطه‌ی (۱۱) را حساب کنیم.

$$Y = \frac{(Y_{n+1})(Y_{\max} - Y_{\min})}{2} + Y_{\min} \quad (19)$$

موارد گفته‌شده بین همه‌ی شبکه‌های به کار رفته در این مقاله صادق است و از آن‌ها در همه‌ی حالت‌ها یعنی در حالت پیش‌بینی قیمت بدون در نظر گرفتن بار و پیش‌بینی قیمت با در نظر گرفتن بار استفاده می‌شود.

بعد از اصلاح داده‌ها جهت آموزش و ارائه‌ی آن‌ها به شبکه، نوبت به شبیه‌سازی شبکه با داده‌های جدید می‌رسد. همان‌طور که قبلاً ذکر شد، این ورودی جدید همان قیمت روز گذشته است که به شبکه برای شبیه‌سازی و پیش‌بینی قیمت روز بعد ارائه می‌شود.

تمامی موارد گفته‌شده در قسمت‌های قبلی، برای پیش‌بینی قیمت با استفاده از شبکه‌ی عصبی لازم بوده و کارایی شبکه با استفاده از آن‌ها بالا می‌رود؛ اما در اینجا به روشی که اصل مقاله هم بر آن تأکید دارد، اشاره می‌کنیم که به‌وسیله‌ی آن دیگر نگرانی

ما از تعیین تعداد نرون‌های لایه‌ی پنهان و بیش‌برازش برطرف می‌شود و این روش، استفاده از الگوریتم گرگ خاکستری است. الگوریتم گرگ خاکستری، به علت سادگی و توانایی قابل توجه در بهینه‌سازی توابع غیرخطی، از سال ۲۰۱۴ مورد توجه بوده است و یکی از موارد بهینه‌سازی آن یافتن تعداد نرون‌های لایه‌ی پنهان است.

برای اجرای الگوریتم گرگ خاکستری در شبکه‌ی عصبی، ابتدا باید جمعیت اولیه را تعیین کنیم. همان‌طور که قبلاً ذکر شد، انتخاب جمعیت اولیه، زمان رسیدن به پاسخ و امکان جستجو میان افراد (جواب‌های مسئله) را تغییر می‌دهد. انتخاب تعداد زیاد افراد، امکان یافتن جواب‌های متنوع را در مسئله ایجاد می‌کند و بالطبع زمان رسیدن به هدف افزایش می‌یابد. از طرفی با انتخاب تعداد افراد کم ممکن است جواب‌هایی از مسئله را که به هدف نزدیک‌تر باشند، از دست بدهیم؛ ولی درنهایت، مسئله سریع‌تر همگرا می‌شود. در این پروژه، تعداد افراد جمعیت بر اساس تعداد نرون‌های ورودی و خروجی تعیین می‌شود؛ چراکه در اکثر مراجع انتخاب تعداد نرون‌های لایه‌ی پنهان به ۳ صورت امکان‌پذیر است:

- ۱) تعداد نرون‌های لایه‌ی ورودی به‌علاوه‌ی تعداد نرون‌های لایه‌ی خروجی
- ۲) نصف حاصل جمع تعداد نرون‌های لایه‌ی ورودی و تعداد نرون‌های لایه‌ی خروجی

(۳) میانگین هندسی تعداد نرون‌های لایه‌ی ورودی و تعداد نرون‌های لایه‌ی خروجی

در کلیه‌ی حالت‌های گفته‌شده، بیشترین تعداد نرون در لایه‌ی پنهان در حالت ۱ اتفاق می‌افتد و بنابراین، ما نیز تعداد افراد جمعیت را بر اساس بیشترین جواب‌ها انتخاب می‌کنیم؛ بدین ترتیب که اگر تعداد نرون‌های ورودی را ۱۲ (۶ نرون به‌عنوان قیمت در ۶ ساعت از روز و ۶ نرون به‌عنوان بار همان ۶ ساعت از روز دیگر) و تعداد نرون‌های خروجی را ۶ (قیمت پیش‌بینی‌شده در همان ۶ ساعت از روز آینده) در نظر بگیریم، تعداد نرون‌های لایه‌ی پنهان ۱۸ می‌شود و از آنجایی که با اعداد باینری سروکار داریم، مجبوریم که تعداد افراد را ۵ قرار دهیم؛ چون تعداد افراد با عبارت 2^n مشخص می‌شود و اگر n را برابر ۴ در نظر بگیریم، 2^4 برابر با ۱۶ است؛ از این‌رو برای اینکه عدد ۱۷ و ۱۸ را که ممکن است جزء بهترین جواب‌ها باشند از دست ندهیم، باید $n = 5$ در نظر بگیریم.

روش کار، بدین شرح است که تابع هدفی که برای الگوریتم گرگ خاکستری مد نظر قرار می‌گیرد، تابع MSE و یا متوسط مجموع مربعات خطا است. البته این تابع مستقیماً به‌کار نرفته و با اعمال تغییر به‌عنوان تابع هدف و یا Fitness function است. تابع به‌صورت زیر می‌باشد:

$$fitness = \frac{1}{1+err} \quad (20)$$

$$err = \sum_{i=1}^p \frac{|z_i - z_i^p|^2}{p} \quad (21)$$

که در آن p ، تعداد نمونه‌های به‌کار رفته در طول فرآیند آموزش، Z_i و Z_i^p به ترتیب خروجی‌های پیش‌بینی‌شده و خروجی واقعی هنگام آموزش BP بوده و err متوسط مجموع مربعات خطا است. الگوریتم بهینه‌سازی گرگ خاکستری، مراحل زیر را جهت یافتن تعداد نرون‌های لایه‌ی پنهان طی می‌کند.

(۱) ایجاد جمعیت اولیه با فرض اینکه تعداد نرون‌های لایه‌ی پنهان حداکثر می‌تواند ۶۴ نرون باشد.

(۲) اجرای شبکه و ارزیابی تابع هدف برای هرکدام از افراد جمعیت؛

(۳) ارزیابی برآزش هرکدام از افراد (Fitness Value) با استفاده از رابطه‌ی زیر:

$$FitVal(i) = \frac{FitFcn(i)}{\sum_{i=1}^n FitVal(i)} \quad (22)$$

که در این رابطه، $FitVal(i)$ برآزش هرکدام از افراد، $FitFcn(i)$ مقدار تابع هدف برای هرکدام از افراد و n تعداد افراد در جمعیت است؛

(۴) انتخاب ۲ نفر از افرادی که دارای بالاترین برآزش هستند، مستقیماً برای نسل بعد؛

(۵) انجام عملگرهای گرگ خاکستری

(۶) تکرار مرحله‌ی دوم تا هنگامی که معیار توقف فرار رسد.

معیار توقف در اینجا تعداد تکرار است که ما در این پروژه برای حصول اطمینان از اینکه تمامی افراد

پیش‌بینی بازار برق به کمک شبکه‌ی عصبی و.....

شکل شماره ۱۴: فلوچارت روش پیشنهادی

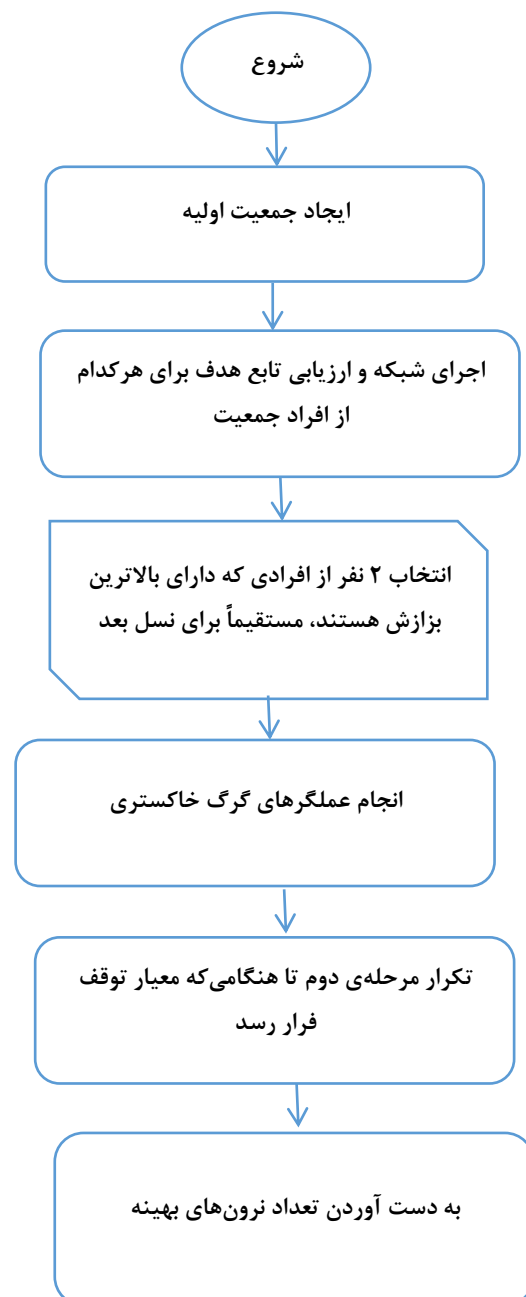
قبل از اینکه الگوریتم گرگ خاکستری شروع به کار کند، باید نکاتی را در نظر گرفت. اولین نکته‌ی قابل توجه، این است که از آنجا که اعداد موجود در جمعیت به صورت تصادفی انتخاب می‌شوند، امکان اینکه عدد انتخاب‌شده صفر باشد نیز وجود دارد؛ اما عدد صفر نمی‌تواند به‌عنوان تعداد نرون‌های لایه‌ی پنهان در نظر گرفته شود. برای جلوگیری از این وضعیت، هرگاه عدد انتخابی صفر شد، به‌دلخواه آن را به عدد دیگر تبدیل می‌کنیم. نکته‌ی دوم این است که عدد انتخابی هیچ‌گاه نباید منفی شود. بدین منظور، همواره باید اعداد را به صورت مثبت درآورده و در الگوریتم گرگ خاکستری به کار بریم.

عد از اینکه الگوریتم گرگ خاکستری در شبکه‌ی عصبی به کار برده شد، مدت زمانی که صرف یافتن تعداد نرون‌های لایه پنهان می‌شود، تا اندازه‌ای بالا می‌رود و زمان همگرایی و آموزش ANN زیاد می‌شود؛ اما به هر ترتیب مقدار MAPE باز هم کاهش یافته و دقت ANN در یافتن الگوها و تفکیک آن‌ها از یکدیگر بیشتر می‌شود. در این قسمت، به اجرای الگوریتم برای روز سه‌شنبه پرداخته و نتایج آن را در ۳ مرحله به دست می‌آوریم. شایان ذکر است که انتخاب روز سه‌شنبه اختیاری بوده و هدف به دست آوردن نرون‌های لایه‌ی پنهان است.

شایسته مورد توجه قرار بگیرند، ۱۵۰ تکرار در نظر گرفته‌ایم.

(۷) به دست آوردن تعداد نرون‌های بهینه (و یا نزدیک به بهینه).

فلوچارت شکل ۱۴، روش پیشنهادی در این مقاله را ارائه می‌دهد:




۵- شبیه‌سازی و ابزار آن

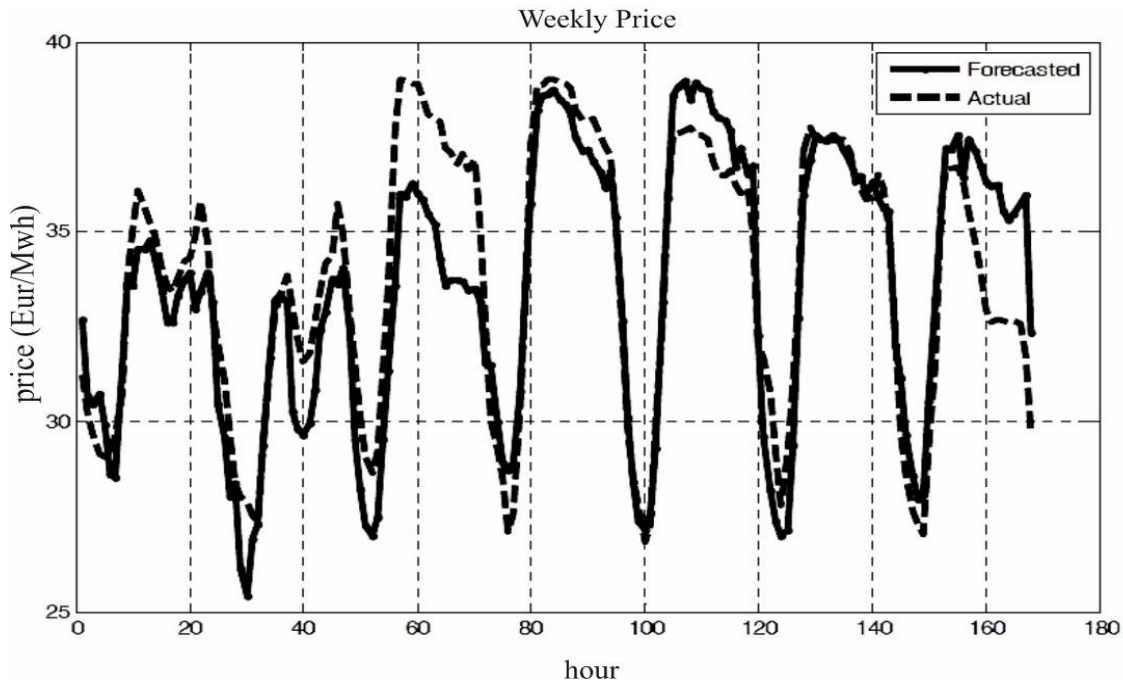
پیشرفت کامپیوترها و نرم‌افزارهای شبیه‌سازی، انتخاب آن‌ها را برای مقاصد هم‌چون شبکه‌های عصبی سخت می‌کند؛ اما در این میان، نرم‌افزار MATLAB که از برجسته‌ترین نرم‌افزارهای محاسباتی است، در زمینه‌ی شبکه‌های عصبی پیشگام بوده و ما نیز بر همین اساس این نرم‌افزار را جهت مطالعات خود و شبیه‌سازی‌های مربوطه انتخاب می‌کنیم.

در این قسمت، لازم می‌دانیم که مقایسه‌ای بین دو حالت گفته‌شده انجام دهیم تا استفاده از مشخصه‌ی بار به همراه قیمت را جهت بررسی دقت شبکه دریابیم. بدین منظور، قیمت یک هفته‌ی متوالی را

در دو حالت ذکرشده شبیه‌سازی کرده و مقدار MAPE هر یک را در جدول (۴) قرار می‌دهیم. با مراجعه به این نمودارها و جداول، مشاهده می‌شود که استفاده از مشخصه‌ی بار به همراه قیمت بر دقت شبکه تأثیرگذار است و دقت آن را بالا می‌برد؛ و با بررسی سیستم‌های مختلف در دنیا و بازارهای دیگر، این دقت بیشتر نمایان می‌شود؛ ولی چون بازار نوردیک از موارد بسیار زیادتری مانند گوناگونی شرایط آب‌وهوایی برخوردار است، دقت پیش‌بینی با اضافه کردن مشخصه‌ی بار چندان به چشم نمی‌خورد. در قسمت‌های بعدی، نحوه‌ی محاسبه‌ی تعداد نرون‌های لایه‌ی پنهان را با استفاده از قواعد سرانگشتی و الگوریتم گرگ خاکستری شرح خواهیم داد.



شکل (۱۵): پیش‌بینی قیمت بدون در نظر گرفتن بار



شکل (۱۶): پیش‌بینی قیمت با در نظر گرفتن بار

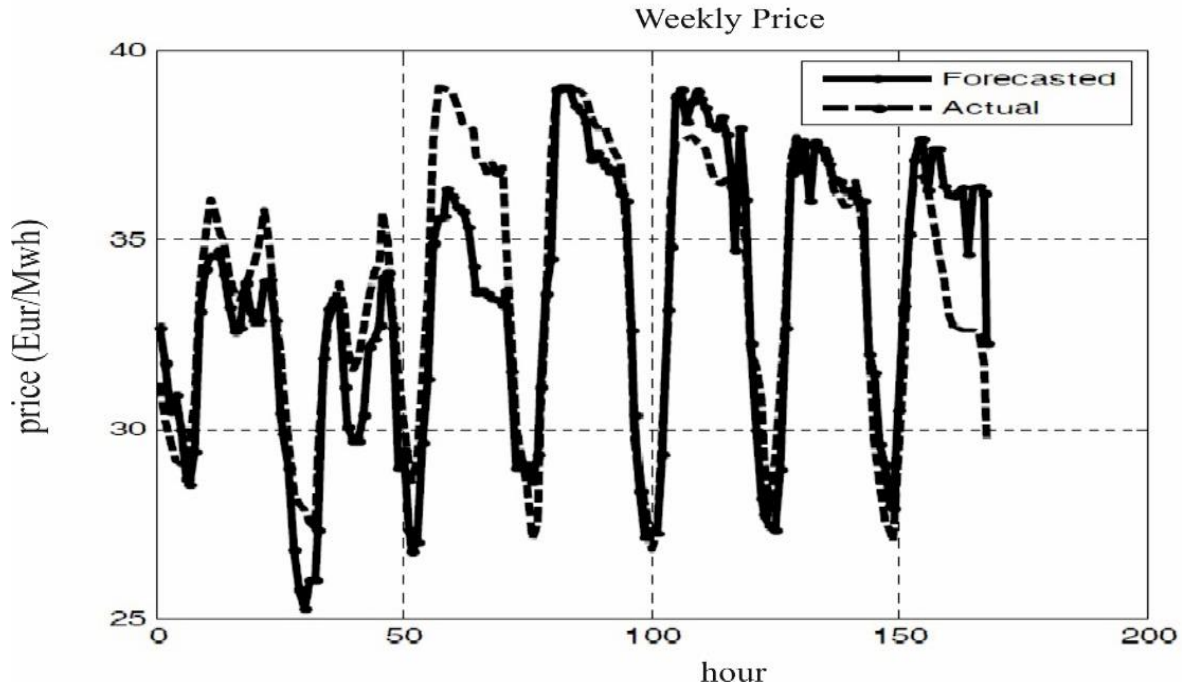
همان‌طور که در جدول (۴) مشاهده می‌شود، علاوه بر کاسته شدن متوسط خطای مطلق، زمان پاسخ شبکه نیز کم شده است. علت این امر را می‌توان چنین بیان کرد که با اضافه شدن مشخصه‌ی بار به الگوهای ورودی شبکه، پارامترهای خود را سریع‌تر تنظیم کرده و از سردرگمی بیشتر برای تنظیم آن‌ها دور می‌شود و این موضوع همگرایی سریع‌تر شبکه و پاسخ آن را در پی خواهد داشت.

جدول (۴): نتایج دو نوع ورودی مختلف به شبکه

قیمت به‌عنوان ورودی			قیمت و بار به‌عنوان ورودی		
تعداد اجرا	MAPE (%)	زمان (ثانیه)	تعداد اجرا	MAPE (%)	زمان (ثانیه)
۱	۸/۳	۵۰	۱	۴	۳۳
۲	۷/۹۱	۴۴	۲	۳/۹۳	۳۴
۳	۸/۰۱	۴۶	۳	۴/۰۲	۳۳
متوسط	۷/۹۹	۴۶/۶۷	متوسط	۳/۹۸	۳۳/۳۴

کلی‌همه‌ی عناصری که نیاز به مقداردهی اولیه دارند، در ابتدا به‌صورت کاملاً تصادفی انتخاب می‌شوند.

بعد از انتخاب ابزار لازم جهت شبیه‌سازی باید پارامترهای شبکه را تنظیم نمود تا بهترین نتایج حاصل شوند. وزن‌ها و بایاس‌های شبکه و به‌طور



شکل (۱۷): قیمت پیش‌بینی‌شده‌ی بازار برق نوردیک با استفاده از ANN بهینه‌شده با گرگ خاکستری از ۱۲ آوریل ۲۰۰۹ تا ۱۸ آوریل ۲۰۰۹

جدول (۵): نتایج اجرای الگوریتم گرگ خاکستری در ANN برای یک روز (سه‌شنبه)

اجرا	اجرای اول	اجرای دوم	اجرای سوم
MAPE (%)	۲/۳۵	۲/۳۲	۲/۱۶
زمان (ثانیه)	۱۴۵	۱۴۶	۱۴۸
تعداد نرون‌های لایه‌ی پنهان	۴	۹	۳۵

جدول (۶): نتایج دو مدل برای یک هفته از ماه دسامبر

ANN بهینه‌شده با گرگ خاکستری		ANN	
MAPE (%)	۳/۹۵	MAPE (%)	۴/۱۳
زمان (ثانیه)	۹۹۰	زمان (ثانیه)	۳۳
تعداد نرون‌های لایه‌ی پنهان	۳۰	تعداد نرون‌های لایه‌ی پنهان	۱۰

می‌شود شبکه عصبی پیشنهادی جوابهای مختلفی را به ازای آرایش‌های مختلف شبکه (تعداد نرون‌های لایه‌های پنهان) به دست آورده است.

در جدول شماره (۵)، نتایج اجرای الگوریتم گرگ خاکستری در ANN برای یک روز (سه‌شنبه) آورده شده است. همان‌گونه که مشاهده

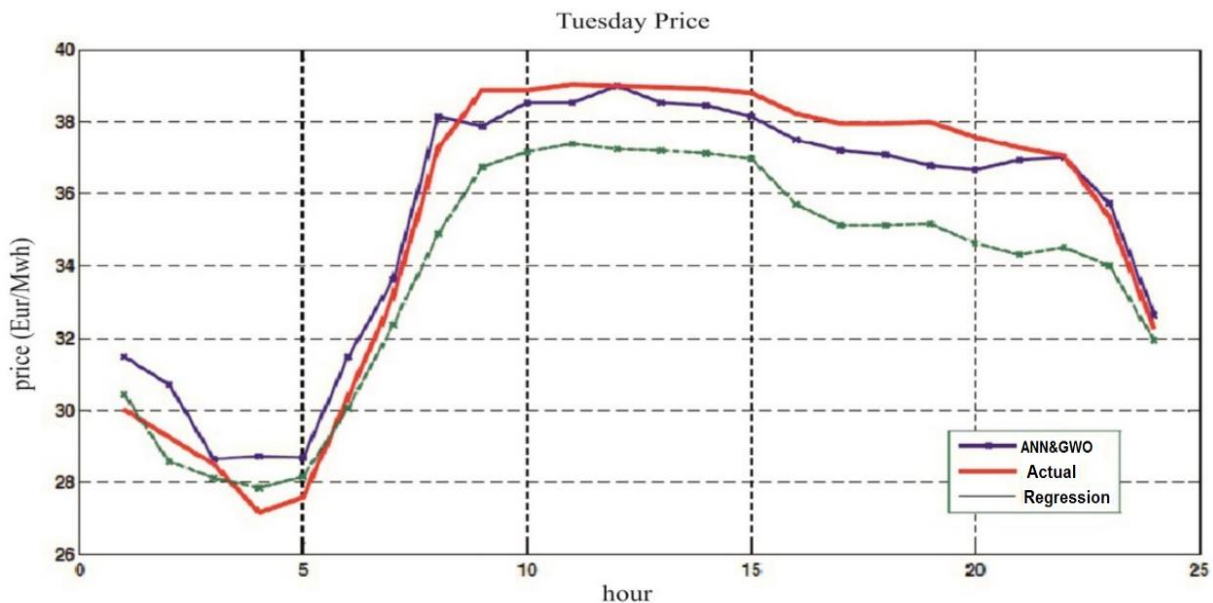
پیش‌بینی بازار برق به کمک شبکه‌ی عصبی و.....

همان‌گونه که مشاهده می‌شود، روش ارائه‌شده (مدل ANN بهینه‌شده با گرگ خاکستری)، در هر حالت بهترین نتایج را دارد و این نشان‌دهنده‌ی این است که ANN، مدلی است که می‌تواند برای شرایط غیرعادی به‌کار رود و نگرانی از بابت عملکرد آن کمتر به چشم می‌خورد؛ درحالی که روش رگرسیونی، روشی است که بر پایه‌ی مشاهدات فعلی است و حافظه‌ای هم در آن برای ثبت وقایع گذشته وجود ندارد. درنهایت، پیش‌بینی قیمت روز سه‌شنبه به‌وسیله‌ی هر سه روش انجام شده و در شکل (۱۸) نشان داده شده است.

همچنین در این جدول، ارتباط میان تعداد نرون-ها، زمان و دقت (شاخص MAPE) قابل ملاحظه است.

در جدول شماره (۶)، نتایج دو مدل برای یک هفته از ماه دسامبر آورده شده است. همان‌گونه که مشاهده می‌شود شاخص MAPE در شبکه عصبی بهینه شده با گرگ خاکستری، مقدار کمتری دارد که این موضوع نشان‌دهنده عملکرد مطلوب روش پیشنهادی این مقاله است. همچنین مشاهده می‌شود با افزایش تعداد نرون‌های لایه پنهان، زمان آموزش شبکه عصبی نیز افزایش می‌یابد.

نتیجه‌گیری



شکل (۱۸): پیش‌بینی قیمت با ۲ روش مختلف

گوناهگونی برای این موضوع به‌کار برده می‌شود؛ اما هیچ‌یک از آن‌ها از دقت کافی برای تعیین قیمت برخوردار نبودند و این حالت در مواقع

پیش‌بینی قیمت، امری مهم و ضروری برای کلیه-ی شرکت‌کنندگان در بازار برق تجدیدساختاریافته است. درگذشته، روش‌های

بحرانی که سیستم وارد حالات غیرعادی می‌شد، بیشتر به چشم می‌خورد. این موضوع، گردانندگان بازار را بر آن داشت که روش‌های جدیدتری را برای پیش‌بینی انتخاب کنند و استفاده از شبکه‌ی عصبی، مهم‌ترین این روش‌ها به‌شمار می‌رفت. با روی کار آمدن روش شبکه‌های عصبی، پیش‌بینی‌های بار و قیمت بهبود یافت؛ اما استفاده از آن‌ها خود با مشکلاتی مواجه بود که می‌توان از عمده‌ترین آن‌ها به بهینه‌سازی شبکه و به دست آوردن کارایی بهتر به‌وسیله‌ی تعیین تعداد نرون‌های لایه‌ی پنهان، اشاره کرد. استفاده از روشی که همراه با اجرای برنامه‌ی شبکه‌ی عصبی آن را به سمت شبکه‌ی بهینه پیش ببرد، عمده‌ی کاری است که باید انجام شود. ایجاد چنین شبکه‌ای، در عین سادگی فقط با روش‌های هوشمند مانند الگوریتم گرگ خاکستری امکان‌پذیر است؛ که در این مقاله از این روش یعنی الگوریتم گرگ خاکستری، برای بهینه‌سازی شبکه استفاده شده است. کلیه‌ی کارهای انجام‌شده در زمینه‌ی پیش‌بینی قیمت، هر یک دارای مزایا و معایبی هستند که در اینجا سه مدل ANN، ANN بهینه‌شده با گرگ خاکستری و رگرسیون، مورد بررسی قرار گرفت. در مدل ANN بهینه‌شده با گرگ خاکستری، برخلاف مدل ساده‌ی ANN، دیگر نگرانی تعیین تعداد نرون‌های لایه‌ی پنهان را نخواهیم داشت؛ چراکه یافتن این تعداد به‌صرف وقت زیادی می‌انجامد

و مدل ارائه‌شده، ما را در صرف وقت و سعی و خطا، خودکفا می‌کند. مدل‌های ANN و رگرسیون نسبت به مدل بهینه‌شده توسط گرگ خاکستری، از کارایی کمتری برخوردارند. این نتایج، به‌ویژه هنگامی که شرایط غیرعادی در سیستم ایجاد شود، محسوس‌تر است. با توجه به معیار مقایسه‌ی روش‌های مختلف پیش‌بینی (MAPE) می‌توان کارایی بالاتر مدل ارائه‌شده در مقاله را به‌وضوح مشاهده کرد. در مدل ANN بهینه‌شده با گرگ خاکستری، فقط کافی است که قیمت و بار گذشته‌ی سیستم را بدانیم؛ شبکه، خود ما را در رساندن به نداشت غیرخطی ورودی و خروجی یاری می‌کند؛ اما در روش رگرسیون باید عواملی تأثیرگذار بر قیمت را بیابیم که پیدا کردن همه‌ی عوامل، عملاً غیرممکن است و در نتیجه همواره مدل با خطای نسبتاً بزرگ‌تری در برابر ANN و مدل بهینه‌شده-ی آن برخوردار است. هنگامی که از موارد مختلف تأثیرگذار بر قیمت به‌عنوان ورودی شبکه استفاده می‌شود، متوجه می‌شویم که استفاده از عوامل زیاد، سردرگمی شبکه را بالا برده و در نتیجه پاسخ شبکه با خطای زیادی همراه خواهد بود؛ بنابراین، استفاده از بار و قیمت به‌عنوان ورودی، بهترین نتایج را به دنبال دارد. تعداد بردارهای آموزشی، نقش بسزایی در به دست آوردن نتایج، بازی می‌کنند. تعداد زیاد بردارها، منجر به فراموشی بردارهای اولیه‌ی

محاسباتی گران منجر می‌شود؛ اما در مدلی که در این مقاله ارائه شده، از آنجا که شبکه با الگوریتم گرگ خاکستری کار می‌کند و هدف تابع بهینه‌سازی در این الگوریتم، کاهش خطا است، می‌توان تا اندازه‌ی زیادی از محاسبات گفته‌شده چشم‌پوشی کرد و مدل خود به‌تنهایی، ما را در یافتن پاسخ بهینه یاری می‌کند.

ارائه‌شده به شبکه می‌شود و تعداد کم کاهش توانایی شبکه در بازشناسی مناسب‌ترین الگو را نتیجه می‌دهد؛ بنابراین، باید تعدادی مناسب برای این منظور انتخاب کرد که در این پروژه این امر انجام شده است. در مدل ANN ساده، همواره به توزیع احتمالاتی قیمت برای پیش‌بینی قیمت نیاز است که این موضوع خود به‌صرف وقت و

مراجع:

BASED METHODS," *Compusoft*, vol. 8, pp. 2985-2989, 2019.

[6] O. Abedinia, N. Amjady, and H. Zareipour, "A new feature selection technique for load and price forecast of electrical power systems," *IEEE Transactions on Power Systems*, vol. 32, pp. 62-74, 2016.

[7] W. Gao, A. Darvishan, M. Toghani, M. Mohammadi, O. Abedinia, and N. Ghadimi, "Different states of multi-block based forecast engine for price and load prediction," *International Journal of Electrical Power & Energy Systems*, vol. 104, pp. 423-435, 2019.

[8] P. Luckow, E. A. Stanton, S. Fields, B. Biewald, S. Jackson, J. Fisher, *et al.*, "2015 carbon dioxide price forecast," *Cambridge, Massachusetts*, 2015.

[9] A. R. Gollou and N. Ghadimi, "A new feature selection and hybrid forecast engine for day-ahead price forecasting of electricity markets," *Journal of Intelligent & Fuzzy Systems*, vol. 32, pp. 4031-4045, 2017.

[10] N. Ghadimi, A. Akbarimajd, H. Shayeghi, and O. Abedinia, "Application of a new hybrid forecast engine with feature

[1] M. K. Kim, "Short-term price forecasting of Nordic power market by combination Levenberg–Marquardt and Cuckoo search algorithms," *IET Generation, Transmission & Distribution*, vol. 9, pp. 1553-1563, 2015.

[2] A. Ntakaris, G. Mirone, J. Kannianen, M. Gabbouj, and A. Iosifidis, "Feature Engineering for Mid-Price Prediction Forecasting with Deep Learning," *arXiv preprint arXiv:1904.05384*, 2019.

[3] J. Sahlin, "Line Loss Prediction Model Design at Svenska kraftnät: Line Loss Prediction Based on Regression Analysis on Line Loss Rates and Optimisation Modelling on Nordic Exchange Flows," ed, 2016.

[4] A. Ntakaris, M. Magris, J. Kannianen, M. Gabbouj, and A. Iosifidis, "Benchmark dataset for mid-price forecasting of limit order book data with machine learning methods," *Journal of Forecasting*, vol. 37, pp. 852-866, 2018.

[5] A. Srivastava, D. Singh, A. Pandey, and S. Kumar, "SHORT TERM PRICE FORECASTING USING TREE

forecast engine with feature selection technique and improved meta-heuristic algorithm for electricity load forecasting," *Energy Elsevier*, vol 161, pp. 130-142, 2018.

[13] S. Mirjalilia, S. M. Mirjalilib, and A. Lewis, "Grey Wolf Optimizer," *Advances in Engineering Software Elsevier*, vol 69, pp. 46-61, 2014.

selection algorithm in a power system," *International Journal of Ambient Energy*, vol. 40, pp. 494-503, 2019.

[11] N. Ghadimi, A. Akbarimajd, H. Shayeghi, and O. Abedinia, "A new prediction model based on multi-block forecast engine in smart grid," *Journal of Ambient Intelligence and Humanized Computing*, vol. 9, pp. pages 1873–1888, 2018.

[12] N. Ghadimi, A. Akbarimajd, H. Shayeghi, and O. Abedinia, "Two stage