

یک روش ترکیبی برای پیش‌بینی احتمالاتی میان-مدت قیمت برق با استفاده از یادگیری عمیق

محمدصادق سهرابی^۱ مجید معظمی^۲

۱- دانش آموخته کارشناسی ارشد- دانشکده مهندسی برق- واحد نجف‌آباد- دانشگاه آزاد اسلامی- نجف‌آباد- ایران

msadeghsohrabi63@gmail.com

۲- دانشیار- مرکز تحقیقات ریزشبکه‌های هوشمند- واحد نجف‌آباد- دانشگاه آزاد اسلامی- نجف‌آباد- ایران

m_moazzami@pel.iaun.ac.ir

چکیده: با تجدید ساختار در سیستم‌های قدرت، پیش‌بینی قیمت برق برای مدیریت بازار برق بسیار مهم شده است و نقش کلیدی در عملیات در بازار برق و شبکه‌های هوشمند ایفا می‌کند. در این مقاله یک روش ترکیبی برای پیش‌بینی احتمالاتی قیمت برق پیشنهاد می‌شود. در این روش ماتریس ویژگی‌ها با استفاده از روش تحلیل اجزای همسایگی استخراج می‌شود و از مجموعه‌های هدف که شامل مقادیر مشاهده شده قیمت برق است، بخش ثابت یا به عبارتی بخش فصلی آن جدا می‌شود. پس از آماده شدن داده‌های آموزش، این مجموعه به دو زیرمجموعه آموزش و اعتبارسنجی تقسیم می‌شود. پس از آن با استفاده از شبکه حافظه کوتاه-مدت بلند با سه لایه مخفی و با استفاده از روش آموزش ترتیبی مدل پیش‌بینی آموزش داده می‌شود و در دو مرحله آموزش و اعتبارسنجی مورد آزمایش قرار می‌گیرد. نتایج به دست آمده نشان می‌دهد روش ترکیبی پیشنهادی در این مقاله موجب کاهش خطای پیش‌بینی‌های نقطه‌ای می‌شود. بهترین نتیجه به دست آمده مربوط به مدل Winsorized با میانگین مطلق درصد خطا برابر با ۹/۲۰۰۹ است که کاهش خطا به میزان ۹/۶۳۳ نسبت به روش ارائه شده را نشان می‌دهد. نتایج به دست آمده نشان می‌دهد روش پیشنهادی برای پیش‌بینی قیمت برق روش کارآمدی است و می‌توان از آن برای پیش‌بینی میان-مدت قیمت برق بهره گرفت.

واژه‌های کلیدی: تحلیل اجزای همسایگی، جداسازی فصلی، پیش‌بینی احتمالاتی، شبکه حافظه کوتاه-مدت بلند، آموزش ترتیبی، ترکیب پیش‌بینی، تابع چگالی پیش‌بینی.

نوع مقاله: پژوهشی

DOI: 10.61186/jiaeee.20.4.412

تاریخ ارسال مقاله: ۱۳۹۸/۰۷/۱۷

تاریخ پذیرش مشروط مقاله: ۱۳۹۹/۰۶/۱۱

تاریخ پذیرش مقاله: ۱۴۰۱/۱۰/۰۵

نام نویسنده‌ی مسئول: دکتر مجید معظمی

نشانی نویسنده‌ی مسئول: ایران - اصفهان - نجف‌آباد - میدان دانشگاه - دانشگاه آزاد اسلامی واحد نجف‌آباد - دانشکده‌ی برق

۱- مقدمه

پس از تجدید ساختار در بازار برق و به وجود آمدن بازارهای رقابتی، قیمت برق در آینده برای فعالیت در بازار اهمیت بسیاری یافته است. از این نظر پیش‌بینی دقیق و قابل اعتماد قیمت برق به موضوعی جذاب برای محققان بسیاری در سراسر جهان تبدیل شده است. در بازار برق، قیمت برق مهم‌ترین سیگنال برای همه شرکت‌کنندگان در بازار و قیمت تسویه بازار، پایه‌ای‌ترین مفهوم قیمت‌گذاری است [۱].

پیش‌بینی قیمت توان الکتریکی در بازارهای تجدیدساختار شده مختلف در سراسر جهان، در [۷] تا [۲] ارائه شده است. دو دسته روش در پیش‌بینی قیمت برق مورد استفاده قرار گرفته است، روش آماری و روش داده محور. رگرسیون با مدل‌های جمع‌پذیر تعمیم یافته [۸] و روش کمترین کاهش و انتخاب عملگر $Lasso^1$ [۹]، در پیش‌بینی قیمت برق مورد استفاده قرار گرفته است. علاوه بر این، پیش‌بینی نقطه‌ای مقادیر و پیش‌بینی احتمالاتی در مرجع [۱۰] انجام شده است. اکثر مدل‌های سری‌های زمانی با قابلیت پیش‌بینی قیمت برق از طریق رابطه خطی بین ورودی‌ها کار می‌کنند. در مطالعات اخیر [۱۱] و [۱۲] از مدل‌های توسعه داده شده آماری که توانایی شناسایی ویژگی‌های غیرخطی در داده‌ها را دارند استفاده شده است. روش‌های ارائه شده در مراجع [۸-۱۲] روش‌هایی مبتنی بر رگرسیون خطی هستند که در آنها ضرایب رگرسیون تخمین زده شده و در پیش‌بینی مقادیر جدید مورد استفاده قرار می‌گیرند. مزیت این روش‌ها سرعت بالای پیش‌بینی است و ایراد آنها دقت نه چندان بالای این روش‌ها است.

روش‌های داده‌محور با استفاده از روابط غیرخطی بین ورودی‌ها به بهبود صحت پیش‌بینی کمک می‌کنند. استفاده از ماشین‌های بردار پشتیبان در پیش‌بینی قیمت برق، که از روش‌های داده‌محور محسوب می‌شود، در [۱۴] تا [۱۳] آمده است. مطالعه‌ای که در [۱۵] انجام شده است، روش‌های مختلف پیش‌بینی قیمت برق را مرور کرده و به این نتیجه رسیده که روش‌های داده‌محور بخصوص روش‌های مبتنی بر شبکه‌های عصبی نتایج بسیار خوبی ارائه می‌دهند. در مرجع [۱۶] یک روش ترکیبی به نام HEA^2 برای پیش‌بینی قیمت برق استفاده شده است. این روش ترکیبی از روش‌های اطلاعات دوطرفه، تبدیل موجک، بهینه‌سازی تکاملی ذرات و $ANFIS^3$ می‌باشد. داده‌های استفاده شده در [۱۶] شامل داده‌های بازار برق اسپانیا و بازار برق PJM^4 می‌باشد. روش دیگری که برای پیش‌بینی قیمت برق ارائه شده است $K-SVR$ نام دارد [۱۷]. این روش ترکیبی از روش‌های خوشه‌بندی، ماشین‌های بردار پشتیبان و رگرسیون بردار پشتیبان است و با حذف مرحله انتخاب ویژگی‌ها سعی بر کاهش دادن زمان محاسبات داشته است. داده‌های استفاده شده در این مطالعه نیز داده‌های بازار برق PJM است. در مرجع [۱۸] با استفاده از داده‌های سال ۲۰۰۵ در بازار استرالیا پیش‌بینی کوتاه‌مدت ماه-پیش قیمت برق انجام گرفته است. در این مطالعه میانگین مربعات خطا و میانگین مطلق درصد خطا

(MAPE^۵) های بدست آمده با استفاده از توپولوژی‌های مختلف با یکدیگر مقایسه شده است تا بهترین مدل برای پیش‌بینی قیمت برق معرفی شود [۱۸].

مرجع [۱۹] مدلی برای پیش‌بینی قیمت برق ارائه داده است که حاصل ترکیب سری‌های زمانی فازی با الگوریتم بهینه‌سازی جستجوی هماهنگی سراسری و ماشین بردار پشتیبان براساس روش کمترین مربعات خطا است. در این روش در ابتدا مرکز خوشه‌بندی هر یک از خوشه‌ها محاسبه شده است؛ سپس مقادیر بهینه پارامترهای ماشین بردار پشتیبان با استفاده از الگوریتم جستجوی هماهنگی سراسری به دست آمده‌اند که مدل پیش‌بینی نهایی را تشکیل می‌دهند. مرجع [۲۰] روشی براساس جداسازی سری‌های زمانی قیمت برق و پیش‌بینی در مرحله بعد ارائه داده است. در این روش ابتدا داده‌های قیمت برق با استفاده از روش جداسازی Beveridge-Nelson به سه قسمت شامل داده‌های قطعی، داده‌های دوره‌ای و داده‌های تصادفی تقسیم می‌شوند؛ سپس با استفاده از الگوریتم بهینه‌سازی مگس میوه مقادیر بهینه پارامترهای ماشین بردار پشتیبان مبتنی بر روش کمترین مربعات خطا، محاسبه و برای هر یک از داده‌ها مدل پیش‌بینی، آموزش داده می‌شود. در مرجع [۲۱] از ترکیب دو شبکه عصبی عمیق، یعنی شبکه عصبی پیچیده و حافظه کوتاه-مدت بلند برای پیش‌بینی قیمت برق استفاده شده است.

در [۲۲] عدم قطعیت مدل پیش‌بینی‌کننده در نظر گرفته شده است و از تکنیک بوت استرپینگ برای پیاده‌سازی عدم قطعیت استفاده شده است. روش مذکور از یادگیری تعمیم داده شده استفاده کرده است. این روش، مبتنی بر روش یادگیری ماشین شدید تعمیم یافته است که برای بهبود شبکه‌های عصبی استفاده می‌شود. مرجع [۲۳] از ترکیب روش‌هایی همچون تبدیل موجک، یادگیری ماشین شدید و بوت استرپ، روشی برای پیش‌بینی بلادرنگ فواصل زمان و قیمت روز - پیش برق ارائه داده است. در مرجع [۲۴] شانزده نوع تبدیل برای تثبیت واریانس پیش‌بینی و کاهش شدت جهش قیمت بررسی شده است. نمونه‌ای از پیش‌بینی احتمالاتی میان‌مدت در مرجع [۲۵] ارائه شده است. در [۲۵] از رگرسیون چندکی برای تخمین دقیق ریسک در بازار تجدید ساختار شده استفاده شده است. از دیگر مطالعاتی که اخیراً در زمینه پیش‌بینی قیمت برق انجام گرفته است و در آن از شبکه‌های حافظه کوتاه-مدت بلند بهره گرفته شده است می‌توان به مرجع [۲۶] اشاره کرد. در پژوهش مذکور نیز از داده‌های بازار استرالیا استفاده شده است. در مرجع [۲۷] ترکیبی از الگوریتم دیفرانسیل تکاملی و شبکه حافظه کوتاه-مدت بلند به منظور پیش‌بینی قیمت برق ارائه شده است. در پژوهش ارائه شده در مرجع [۲۸] یک شبکه حافظه کوتاه-مدت بلند سه لایه به منظور پیش‌بینی بار و قیمت برق ارائه شده است.

با وجود پژوهش‌های فراوانی که در زمینه پیش‌بینی قیمت برق انجام شده است، همواره محققان به دنبال ارائه روش‌های جدیدی هستند که روش‌های موجود را از نظر دقت و سرعت انجام پیش‌بینی

$$P(\text{Ref}(x) = x_j | S) \quad (2)$$

$$d_w(x_i, x_j) = \sum_{r=1}^p w_r^2 |x_{ir} - x_{jr}| \quad (3)$$

w_r شامل وزن‌های ویژگی‌ها هستند. فرض کنید رابطه زیر برقرار باشد [۲۹]:

$$P(\text{Ref}(x) = x_j | S) \propto k(d_w(x, x_j)) \quad (4)$$

k نشان‌دهنده تابع کرنل یا تابع مشابهت است و زمانی که $d_w(x, x_j)$ کوچک باشد مقدار این تابع بزرگ در نظر گرفته می‌شود. در مرجع [۲۹] تابع k به صورت زیر پیشنهاد شده است:

$$k(z) = e^{-\frac{z^2}{\sigma^2}} \quad (5)$$

نقطه مرجع برای نقطه x از مجموعه S انتخاب می‌شود در نتیجه مجموع احتمالات انتخاب تمامی نقاط موجود در مجموعه S باید برابر با ۱ باشد. در نتیجه می‌توان نوشت [۲۹]:

$$P(\text{Ref}(x) = x_j | S) = \frac{k(d_w(x, x_j))}{\sum_{j=1}^n k(d_w(x, x_j))} \quad (6)$$

اکنون فرض کنید این دسته‌بندی کننده تصادفی قرار است در عملکرد کاربرد *Leave-One-Out* مورد استفاده قرار گیرد و قرار است برچسب x_i با استفاده از داده‌های S^{-i} پیش‌بینی شود. احتمال آنکه نقطه x_j به عنوان نقطه مرجع x_i انتخاب شود برابر است با [۲۹]:

$$p_{ij} = P(\text{Ref}(x_i) = x_j | S^{-i}) = \frac{k(d_w(x_i, x_j))}{\sum_{j=1, j \neq i}^n k(d_w(x_i, x_j))} \quad (7)$$

میانگین احتمال *Leave-One-Out* دسته‌بندی صحیح برابر با احتمال p_i است که در آن دسته‌بندی کننده تصادفی مشاهده \hat{a}_m را با استفاده از S^{-i} در دسته درست قرار دهد [۲۹]:

$$p_i = \sum_{j=1, j \neq i}^n P(\text{Ref}(x_i) = x_j | S^{-i}) I(y_i = y_j) = \sum_{j=1, j \neq i}^n p_{ij} y_{ij} \quad (8)$$

$$y_{ij} = I(y_i = y_j) = \begin{cases} 1 & \text{if } y_i = y_j \\ 0 & \text{otherwise} \end{cases} \quad (9)$$

میانگین احتمال *Leave-One-Out* دسته‌بندی صحیح با استفاده از دسته‌بندی کننده تصادفی برابر است با [۲۹]:

$$F(w) = \frac{1}{n} \sum_{i=1}^n p_i \quad (10)$$

سمت راست رابطه فوق وابسته به بردار وزنه‌های w است. هدف روش آنالیز اجزای همسایگی حداکثر کردن $F(w)$ نسبت به w است. تابع هدف تنظیم شده برای این کار برابر است با [۲۹]:

$$F(w) = \frac{1}{n} \sum_{i=1}^n p_i - \lambda \sum_{r=1}^p w_r^2 = \frac{1}{n} \sum_{i=1}^n \left[\sum_{j=1, j \neq i}^n p_{ij} y_{ij} - \lambda \sum_{r=1}^p w_r^2 \right] = \frac{1}{n} \sum_{i=1}^n F_i(w) \quad (11)$$

ارتقاء بخشند. هدف ارائه این مقاله نیز ارائه روشی به منظور افزایش دقت پیش‌بینی قیمت برق با استفاده از شبکه عصبی حافظه کوتاه-مدت بلند است. در این مقاله یک روش ترکیبی برای پیش‌بینی احتمالاتی قیمت برق ارائه می‌شود که مبتنی بر روش تحلیل اجزای همسایگی است. داده‌های استفاده شده در این مقاله، مجموعه داده‌های بازار استرالیا است. در این روش ماتریس ویژگی‌ها با استفاده از روش تحلیل اجزای همسایگی از مجموعه‌ی آموزش استخراج می‌شود و از مجموعه‌های هدف که شامل مقادیر مشاهده شده قیمت برق است، بخش ثابت یا به عبارتی بخش فصلی آن جدا می‌شود. پس از آماده شدن داده‌های آموزش، این داده‌ها به دو بخش آموزش و اعتبارسنجی تقسیم می‌شود. با استفاده از بخش آموزش و با کمک شبکه حافظه کوتاه-مدت بلند با سه لایه مخفی و روش آموزش رگرسیون ترتیبی^۷ یک مدل پیش‌بینی آموزش داده می‌شود و مقایسه‌ای میان نتایج به دست آمده با روش ارائه شده در مرجع [۲۸] انجام می‌گیرد.

در ادامه در ابتدای بخش دوم روش‌شناسی شامل تحلیل اجزای همسایگی و ساختار شبکه حافظه کوتاه-مدت بلند ارائه می‌شود. در بخش سوم روش پیشنهادی به منظور پیش‌بینی احتمالاتی میان-مدت قیمت برق ارائه شده است. در بخش چهارم نتایج شبیه‌سازی و در بخش پایانی نتایج پژوهش ارائه می‌شود.

۲- روش‌شناسی

۲-۱- روش تحلیل اجزای همسایگی

یک مسأله دسته‌بندی چند دسته‌ای با یک مجموعه از نمونه‌های آموزشی به شکل زیر را در نظر بگیرید [۲۹]:

$$S = \{(x_i, y_i), i = 1, 2, \dots, n\} \quad (1)$$

به طوری که $x_i \in \mathbb{R}^p$ بردارهای ویژگی، $y_i \in \{1, 2, \dots, c\}$ بردار هدف (شامل برچسب هر دسته) مربوط به ماتریس ویژگی‌ها و n تعداد نمونه‌ها باشد. بدین ترتیب می‌توان دسته‌بندی کننده‌ای $f: \mathbb{R}^p \rightarrow \{1, 2, \dots, c\}$ ساخت که یک بردار ویژگی را به عنوان ورودی می‌گیرد و دسته‌ای را برای آن پیش‌بینی می‌کند [۲۹].

یک دسته‌بندی کننده تصادفی را در نظر بگیرید به طوری که این دسته‌بندی کننده به طور تصادفی یک نقطه از S نقطه موجود را به عنوان نقطه مرجع x ، $\text{Ref}(x)$ انتخاب می‌کند و برچسب‌های x برچسب‌های نقطه‌ی مرجع هستند. این طرح مشابه یک دسته‌بندی کننده است که در آن نقطه مرجع $\text{Ref}(x)$ طوری انتخاب می‌شود که نزدیکترین همسایگی برای نقطه جدید x باشد. در روش تحلیل اجزای همسایگی نقطه مرجع به طور تصادفی انتخاب می‌شود و تمامی نقاط موجود در S احتمال انتخاب شدن به عنوان نقطه مرجع را دارند.

احتمال آنکه نقطه x_j از مجموعه S به عنوان نقطه مرجع نقطه x انتخاب شود با کاهش فاصله آن از نقطه x افزایش می‌یابد. فاصله مذکور با استفاده از تابع فاصله d_w قابل اندازه‌گیری است [۲۹].

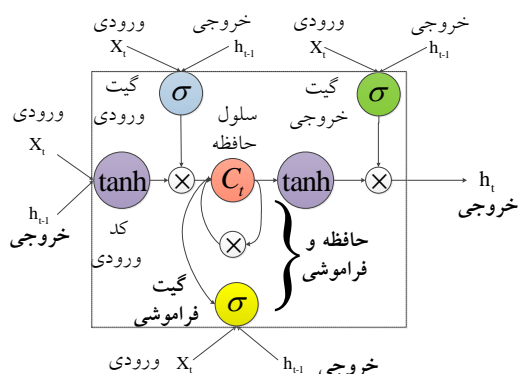
پس از اضافه کردن پارامتر تنظیم، تابع هدف به منظور بهینه‌سازی برابر است با [۲۹]:

$$f(w) = \frac{1}{n} \sum_{i=1}^n l_i + \lambda \sum_{r=1}^p w_r^2 \quad (17)$$

۲-۲- شبکه عصبی عمیق حافظه کوتاه-مدت بلند

شبکه حافظه کوتاه-مدت بلند روشی برای آموزش عمیق است و برای اولین بار در سال ۱۹۷۷ توسط هاکریتز و همکارانش ارائه شد [۳۰]. هدف اصلی ارائه این روش جلوگیری از بین رفتن شیب در روش شیب نزولی است که در زمان آموزش یک مدل شبکه عصبی با استفاده از الگوریتم پس‌انتشار رخ می‌دهد. با از بین رفتن شیب، در مرحله آموزش overfit رخ می‌دهد و چنین مدلی توانایی تعمیم در زمان آزمایش را ندارد.

در شبکه حافظه کوتاه-مدت بلند هر نورون در لایه مخفی یک سلول حافظه است و یک لبه بازگشتی دارد که به خود نورون متصل می‌شود. این لبه دارای وزنی برابر با ۱ است که باعث حفظ شیب در مرحله آموزش می‌شود. این شبکه پنج واحد اصلی دارد، بلوک حافظه، سلول‌های حافظه، واحد دریافت ورودی‌ها، واحد خروجی‌ها و بلوک فراموشی. سلول‌های حافظه واحدهای بازگشتی خطی دارند که با عنوان Constant Error Carousel (CEC) شناخته می‌شوند. سیگنال‌های فعال‌سازی و خطا توسط CEC در شبکه به گردش در می‌آیند که موجب می‌شود این بخش مانند یک واحد ذخیره‌سازی کوتاه-مدت عمل کند. واحدهای ورودی، خروجی و فراموشی آموزش داده می‌شوند تا تصمیم بگیرند که کدام اطلاعات باید در واحد حافظه ذخیره شوند و در چه بازه زمانی و در چه زمانی اطلاعات ذخیره شده خوانده شوند.



شکل (۱): معماری یک واحد شبکه حافظه کوتاه-مدت بلند [۲۸]

جریان ورودی‌های جدید به سلول‌ها با استفاده از سلول ورودی انجام می‌گیرد. سلول خروجی در مورد سه مسئله تصمیم‌گیری می‌کند، بسط زمان برای مقدار عددی درون سلول که قرار است در فعال‌سازی واحد خروجی و گیت فراموشی استفاده شود، بازه زمانی حفظ مقادیر سلول‌ها و تعیین زمان فراموشی مقادیر برای سلول‌های حافظه. شبکه تمامی واحدها را بازه‌های زمانی $t=0, 1, 2, \dots$ به روزرسانی می‌کند و سیگنال‌های خطا را برای تمامی وزن‌ها محاسبه می‌نماید. عملکرد

در رابطه فوق λ پارامتر تنظیم است. این پارامتر موجب صفر شدن بسیاری از وزن‌ها در بردار w می‌شود. با تنظیم مقدار پارامتر تابع کرنل σ در p_{ij} برابر با ۱، یافتن بردار وزن w را می‌توان به شکل مسئله بهینه‌سازی زیر برای یک λ معین بیان کرد [۲۹]:

$$\hat{w} = \arg \min_w f(w) = \arg \min_w \frac{1}{n} \sum_{i=1}^n f_i(w) \quad (12)$$

$$f(w) = -F(w), \quad f_i(w) = -F_i(w)$$

$$\frac{1}{n} \sum_{i=1}^n \sum_{j=1, j \neq i}^n p_{ij} = 1 \quad (13)$$

و در صورتی که یک مقدار ثابت به یک تابع هدف اضافه شود آرگومان مینیمم تغییر نخواهد کرد، در نتیجه می‌توان تابع هدف را با اضافه کردن ثابت ۱ بازنویسی کرد [۲۹]:

$$\begin{aligned} \hat{w} &= \arg \min_w \{1 + f(w)\} = \arg \min_w \left\{ \frac{1}{n} \sum_{i=1}^n \sum_{j=1, j \neq i}^n p_{ij} y_{ij} + \lambda \sum_{r=1}^p w_r^2 \right\} \\ &= \arg \min_w \left\{ \frac{1}{n} \sum_{i=1}^n \sum_{j=1, j \neq i}^n p_{ij} (1 - y_{ij}) + \lambda \sum_{r=1}^p w_r^2 \right\} \\ &= \arg \min_w \left\{ \frac{1}{n} \sum_{i=1}^n \sum_{j=1, j \neq i}^n p_{ij} l(y_i, y_j) + \lambda \sum_{r=1}^p w_r^2 \right\} \end{aligned} \quad (14)$$

تابع تلفات نیز برابر است با:

$$l(y_i, y_j) = \begin{cases} 1 & \text{if } y_i \neq y_j \\ 0 & \text{otherwise} \end{cases} \quad (15)$$

حال یک مسئله رگرسیون را با یک مجموعه از نمونه مشاهدات مشابه با مجموعه S در رابطه (۱) را در نظر بگیرید. تنها تفاوتی که با مسئله دسته‌بندی وجود دارد مقادیر پاسخ‌های $y_i \in \mathbb{R}$ است. در اینجا هدف پیش‌بینی پاسخ y است که در مجموعه S ارائه شده است. یک مدل رگرسیون تصادفی را در نظر بگیرید به طوری که مدل رگرسیون به طور تصادفی یک نقطه از S را به عنوان نقطه مرجع برای نقطه x ($Ref(x)$) انتخاب می‌کند و مقادیر پاسخ در نقطه x برابر با مقادیر پاسخ در نقطه‌ی مرجع هستند.

احتمال انتخاب نقطه x_j از مجموعه S به عنوان نقطه مرجع برای نقطه x برابر با رابطه (۶) است و با فرض اینکه این مدل رگرسیون تصادفی قرار است در عملکرد کاربرد $Leave-One-Out$ مورد استفاده قرار گیرد و قرار است پاسخ x_i با استفاده از داده‌های S^{-i} پیش‌بینی شود، احتمال آنکه نقطه x_j به عنوان نقطه مرجع x_i انتخاب شود را می‌توان از رابطه (۷) به دست آورد.

اکنون فرض کنید \hat{y}_i مقدار عددی پاسخی باشد که مدل رگرسیون تصادفی را پیش‌بینی می‌کند و y_i پاسخ واقعی برای x_i باشد. در این صورت می‌توان تابع تلفات $\mathbb{R} \rightarrow \mathbb{R}^2 \rightarrow \mathbb{R}$ را به شکلی تعریف کرد که بیانگر عدم تطابق y_i و \hat{y}_i باشد. مقدار میانگین $l(y_i, \hat{y}_i)$ برابر است با [۲۹]:

$$l_i = E(l(y_i, \hat{y}_i) | S^{-i}) = \sum_{j=1, j \neq i}^n p_{ij} l(y_i, \hat{y}_i) \quad (16)$$

از قدیمی شدن اطلاعات، دروازه فراموشی آن را پاک می‌کند و حالت سلول حافظه را به صفر تنظیم می‌کند، بنابراین مانع از نزدیک شدن حالت سلول به بی‌نهایت شده و امکان ذخیره اطلاعات تازه بدون دخالت عملیات قبلی را فراهم می‌نماید. خروجی سلول y_C حاصل ضرب وضعیت سلول S_C در فعالیت گیت خروجی y_{out} سلول حافظه است:

$$y_{C_j}(t) = y_{out_j}(t) S_{C_j}(t) \quad (24)$$

عملیات گذر به جلو شبکه با استفاده از معادلات فوق بیان شد. اکنون باید عملیات گذر به عقب بیان شود. تابع هدف E با استفاده از تابع شیب نزولی و وزن‌های w_{lm} به‌روزرسانی می‌شود. وزن‌ها با استفاده از Δw_{lm} که با استفاده از نرخ آموزش α و شیب منفی تابع هدف E به دست می‌آید، به روز می‌شوند. وزن‌های واحد خروجی با استفاده از روش استاندارد پس‌انتشار به صورت زیر به‌روزرسانی می‌شود [۲۸]:

$$\Delta w_{km}(t) = \alpha \delta_k(t) y_m(t-1) \quad (25)$$

$$\delta_k(t) = -\frac{\partial E(t)}{\partial z_k(t)} \quad (26)$$

بر اساس مقادیر هدف t_k ، تابع هدف، مربعات خطا است [۲۸]:

$$\delta_k(t) = f'_k(z_k(t)) e_k(t) \quad (27)$$

$$e_k(t) = t_k(t) - y_k(t) \quad (28)$$

وزن‌های واحد منبع برای اتصال به گیت خروجی تغییر می‌کند که این وزن‌ها نیز با استفاده از روش پس‌انتشار به دست می‌آیند [۲۸]:

$$\Delta w_{out,m}(t) = \alpha \delta_{out_j}(t) y_m(t) \quad (29)$$

خطای وضعیت داخلی با استفاده از $e_{S_{C_j}}$ نمایش داده می‌شود و برای هر یک از سلول‌های حافظه محاسبه می‌گردد [۲۸]:

$$e_{S_{C_j}}(t) = y_{out_j}(t) \left(\sum_k w_{kc_j} \delta_k(t) \right) \quad (30)$$

۲-۳- ارزیابی نتایج

برای ارزیابی نتایج به دست آمده شاخص‌های میانگین مجذور خطا (MSE) و جذر آن (RMSE)، شاخص ضریب تعیین (R^2)، میانگین مطلق خطا (MAE) و میانگین مطلق درصد خطا مورد استفاده قرار گرفته‌اند که تعاریف آنها در ذیل آمده است [۳۱]. y در روابط زیر مقدار واقعی، \hat{y} مقادیر پیش‌بینی شده و \bar{y} میانگین مقادیر موجود در بردار هدف است.

$$MSE = \frac{1}{N_i} \sum_{i=1}^N \frac{1}{N_i} \sum_{i=1}^N [y_i - \hat{y}_i]^2 \quad (31)$$

$$RMSE = \sqrt{MSE_i} \quad (32)$$

$$R^2 = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})}{\sum_{i=1}^n (y_i - \bar{y})} \quad (33)$$

واحدها به عنوان گذر رو به جلو و محاسبه سیگنال خطا به عنوان گذر به عقب شناخته می‌شود. شکل (۱) یک واحد شبکه عصبی حافظه کوتاه‌مدت بلند را نمایش می‌دهد.

روابط زیر عملیات گذر رو به جلو در شبکه حافظه کوتاه‌مدت بلند را نمایش می‌دهند. بلوک حافظه با z و سلول‌های حافظه استفاده شده در هر بلوک z (شامل S_z سلول) با v نمایش داده شده است. C_j^v سلول v ام از بلوک حافظه z ام است. وزن بین واحد l ام و m ام است و محدوده مقدار m برای واحدهای مبدا متغیر است. زمانی که فعال‌سازی واحد مبدا $y_m(t-1)$ مربوط به واحد ورودی است، آخرین ورودی خارجی $y_m(t)$ مورد استفاده قرار می‌گیرد. محاسبه خروجی y_C از سلول حافظه مبتنی بر وضعیت سلول‌های استفاده شده اخیر S_C و چهار منبع ورودی است. ورودی خود سلول‌ها Z_C ، ورودی گیت‌های ورودی Z_{in} ، ورودی گیت‌های فراموشی Z_ϕ و ورودی گیت‌های خروجی Z_{out} است [۲۸]. ورودی خالص سلول برای هر گذر رو به جلو به شکل زیر قابل محاسبه است:

$$Z_{C_j}(t) = \sum_m w_{C_j m} y_m(t-1) \quad (18)$$

پس از محاسبه ورودی خالص، کد ورودی یا تابع تبدیل g روی رابطه فوق اعمال می‌شود. تابع زیگموئید f_{in} برای محاسبه مقادیر فعال‌سازی گیت‌های ورودی بلوک حافظه مورد استفاده قرار می‌گیرد [۲۸].

$$y_{in_j}(t) = f_{in_j}(Z_{in_j}(t)) \quad (19)$$

$$Z_{in_j}(t) = \sum_m w_{in_j m} y_m(t-1) \quad (20)$$

حاصل Z_{in} و $Z_{C_j}(t)$ محاسبه می‌شود. مقدار فعال‌سازی گیت‌های ورودی y_{in} در تمامی سلول‌های بلوک حافظه ضرب می‌شود تا الگوهای فعالیت در حافظه ذخیره شوند. در فرآیند آموزش گیت ورودی ذخیره کردن اطلاعات مهم در بلوک حافظه را با در نظر گرفتن ($y_{in} \approx 1$) و حذف ورودی‌های بی‌ربط را با در نظر گرفتن ($y_{in} \approx 0$) فرا می‌گیرد.

در ابتدا، وضعیت S_C از یک سلول حافظه C برابر با صفر در نظر گرفته می‌شود. در طول آموزش CEC بخشی از مقادیر را که در گیت فراموشی باقی مانده است جمع می‌کند. فعالیت گیت فراموشی بلوک حافظه به شکل زیر محاسبه می‌شود [۲۸]:

$$y_{\phi_j}(t) = f_{\phi_j}(z_{\phi_j}(t)) \quad (21)$$

$$Z_{\phi_j}(t) = \sum_m w_{\phi_j m} y_m(t-1) \quad (22)$$


f_ϕ نشان‌دهنده تابع زیگموئید در محدوده $[0, 1]$ است. وضعیت جدید سلول با استفاده از رابطه زیر محاسبه می‌شود [۲۸]:

$$S_{C_j}(t) = y_{\phi_j}(t) S_{C_j}(t-1) + y_{in_j}(t) g(z_{C_j}(t)), \quad S_{C_j}(0) = 0 \quad (23)$$

زمانی که دروازه فراموشی باز است ($y_{in} \approx 1$)، مقدار عددی در واحد CEC در گردش است. هنگامی که گیت ورودی در حال یادگیری ذخیره کردن اطلاعات در سلول حافظه است، دروازه فراموشی نیز در حال یادگیری مدت زمان محدود کردن هر یک از اطلاعات است. پس

پیش‌بینی به دست آید. شکل (۲) مراحل آموزش مدل‌های پیش‌بینی را نمایش می‌دهد.

داده‌های ورودی، داده‌های پس از استخراج ویژگی با استفاده از روش تحلیل اجزای همسایگی است و داده‌های هدف بردارهای حاوی X_t های استخراج شده از قیمت برق است. پیش از شروع مرحله آموزش، ۲۵٪ از داده‌های هر یک از زیرمجموعه داده‌ها به طور تصادفی از آن جدا می‌شود و برای اعتبارسنجی از مدل‌های آموزش مورد استفاده قرار می‌گیرد. بخش بزرگتر مجموعه داده شامل ماتریس‌های ورودی و هدف به ۱۰۰ زیرمجموعه کوچکتر با طول‌های متفاوت تقسیم می‌شود و بر اساس اندازه طول‌های زیرمجموعه‌ها از بزرگ به کوچک مرتب شده و با استفاده از روش آموزش ترتیبی شبکه حافظه کوتاه-مدت بلند آموزش مدل‌ها انجام می‌گیرد. قابل ذکر است که شبکه پیشنهادی برای پیش‌بینی قیمت برق یک شبکه حافظه کوتاه-مدت بلند با سه لایه مخفی است.



شکل (۲): دیاگرام شماتیک مرحله آموزش مدل‌ها

۴- نتایج شبیه‌سازی

با توجه به آنچه گفته شد داده‌های استفاده شده در این پژوهش داده‌های مربوط به پیش‌بینی قیمت برق در بازار استرالیا است [۳۴]. هدف از استفاده از یادگیری عمیق برای ساخت مدل پیش‌بینی یافتن الگوهای موجود در نمونه‌های آموزشی بدون استفاده از یک مجموعه داده عظیم است. از این نظر مجموعه داده‌های آموزش شامل داده‌های سالهای (۲۰۰۵-۲۰۰۴) و مجموعه داده‌های آزمایش شامل یک سال یعنی داده‌های سال ۲۰۰۸ است. داده‌های مذکور شامل ۹ ویژگی هستند که عبارتند از دمای هوای خشک، نقطه شبنم، ساعت در روز،

$$MAE = \frac{1}{N} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (34)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100 \quad (35)$$

۳- روش پیشنهادی

اولین مرحله در روش پیشنهادی، پیش‌پردازش روی داده‌ها است که می‌تواند به دو بخش تقسیم شود. بخش پیش‌پردازش روی داده‌های ورودی مدل‌های آموزش و بخش پیش‌پردازش روی داده‌های هدف که شامل مقادیر مشاهده شده قیمت برق می‌باشند. با توجه به آنچه درباره چگونگی استخراج ویژگی از داده‌ها با استفاده از روش تحلیل اجزای همسایگی برای مسأله رگرسیون بیان شد، روی داده‌های ورودی مدل‌ها با استفاده از این روش استخراج ویژگی انجام می‌گیرد و مقدار پارامترها و وزن‌های ویژگی‌ها معین می‌شوند. قابل ذکر است که هر ستون در ماتریس ورودی شامل یکی از ویژگی‌ها و هر یک از سطرها بیانگر یک برچسب زمان است. از آنجا که روش تحلیل اجزای همسایگی یک روش برای استخراج ویژگی نظارت شده است، پیش از استفاده از این روش باید پیش‌پردازش روی داده‌های هدف، یعنی قیمت‌ها انجام گیرد. به منظور کاهش خطا در روش پیشنهادی در ابتدا از قیمت‌های مشاهده شده موجود در بردار هدف لگاریتم طبیعی گرفته می‌شود:

$$LP_t = \ln(P_t) \quad (36)$$

علاوه بر این، قیمت‌های برق یک مؤلفه فصلی برجسته، همراه با برگشت به میانگین سطح دارند. بنابراین، این خصوصیات باید در الگویی از قیمت برق درج شود. با توجه به آنچه در مرجع [۳۲] ارائه شده است، می‌توان قیمت برق را به شکل زیر مدل کرد:

$$LP_t = f(t) + X_t \quad (37)$$

P_t قیمت لحظه‌ای برق است. لگاریتم قیمت برق توسط دو بخش مدل شده است: $f(t)$ و X_t . $f(t)$ بخش فصلی و ثابت مدل در نظر گرفته می‌شود و X_t بخش تصادفی است که مقادیر آن به عنوان بردار هدف در آموزش مدل‌های پیش‌بینی مورد استفاده قرار می‌گیرد. می‌توان با استفاده از توابع مثلثاتی $f(t)$ را به شکل زیر مدل کرد [۳۳]:

$$f(t) = s_1 \sin(2\pi t) + s_2 \cos(2\pi t) + s_3 \sin(4\pi t) + s_4 \cos(4\pi t) + s_5 \quad (38)$$

با $s_i, i = 1, 2, \dots, 5$ پارامترهای ثابت هستند و t نیز برچسب زمان است. با توجه به روابط ارائه شده بردار نهایی هدف برابر است با:

$$X_t = LP_t - f(t) s_4 \cos(4\pi t) + s_5 \quad (39)$$

به این طریق بخش ثابت و فصلی قیمت پیش از ساختن مدل پیش‌بینی حذف می‌شود و در زمان پیش‌بینی میان‌مدت مقدار آن به مقدار پیش‌بینی شده توسط مدل اضافه می‌گردد تا نتیجه نهایی


پس از انجام مرحله پیش‌پردازش و تولید ماتریس‌های ورودی و هدف، نوبت به آموزش مدل پیش‌بینی می‌رسد. در این مرحله داده‌ها به دو بخش شامل یک بخش یک چهارمی و یک بخش سه چهارمی تقسیم می‌شوند. با استفاده از بخش بزرگتر مدل پیش‌بینی آموزش داده می‌شود و با استفاده از بخش کوچکتر اعتبارسنجی انجام می‌گیرد. از آنجا که شبکه‌های LSTM با روش ترتیبی آموزش داده می‌شوند ابتدا بخش مورد استفاده در مرحله آموزش به ۱۰۰ زیرمجموعه با طول‌های مختلف تقسیم شده و مرتب می‌شود. مجموعه‌ی مذکور شامل ورودی‌ها و اهداف است که در شکل‌های (۶) نمایش داده شده است.

پس از آن، مدل با استفاده از شبکه LSTM سه لایه آموزش داده می‌شود که تنظیمات آن در جدول (۱) نمایش داده شده است.

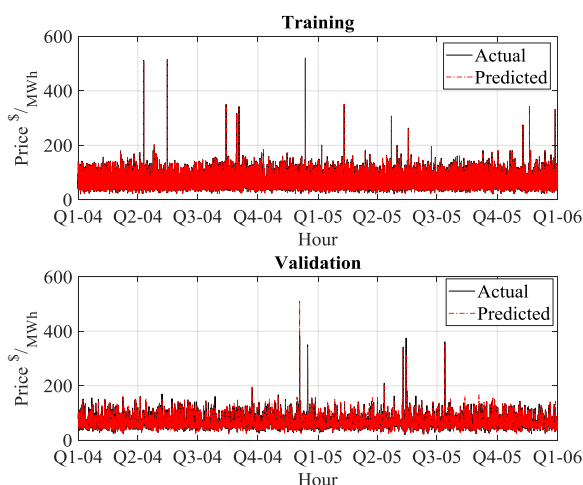
جدول (۱): مشخصات شبکه LSTM در مرحله آموزش

تعداد لایه مخفی	تعداد تکرار	اندازه مینی-بچ‌ها	نرخ آموزش اولیه
۳	۱۰	۱۰	۰/۰۱

نتایج آموزش و اعتبارسنجی مدل در شکل‌های (۷) و (۸) و جدول (۲) نمایش داده شده است. همانطور که مشاهده می‌شود میزان خطا در مراحل آموزش و اعتبارسنجی قابل قبول است.



شکل (۶): زیرمجموعه داده‌های مرتب شده برای آموزش ترتیبی




شکل (۷): نمودارهای آموزش و اعتبارسنجی مدل پیش‌بینی


روز هفته، نشانه‌ای که روزهای تعطیل را تعیین می‌کند، بار سیستم قدرت، بار در روز و ساعت مورد نظر در همان روز در هفته قبل، قیمت برق در روز و ساعت مورد نظر در همان روز در هفته قبل و میانگین قیمت گاز طبیعی در هفته قبل.

اولین گام در مرحله پیش‌پردازش نتایج، جداسازی فصلی است که نتیجه آن در شکل (۳) نمایش داده شده است. گام دوم به کارگیری روش تحلیل اجزای همسایگی به منظور استخراج ویژگی‌ها از داده‌های خام و تعیین وزن‌های لازم به منظور انجام رگرسیون است. نتایج استخراج ویژگی‌ها در شکل‌های (۴) و (۵) نمایش داده شده است.


شکل (۵) چگونگی حداقل شدن تابع هدف در فرآیند استخراج ویژگی را نمایش می‌دهد. با بررسی این نمودار می‌توان کمترین و بیشترین مقادیر MSE به دست آمده در طول تکرارهای بهینه‌سازی را به دست آورد. کمترین مقدار MSE برابر با ۰/۰۱۷۲ و مربوط به تکرار ۵۲۹ است.




شکل (۳): نمودار تعیین بخش فصلی و حذف آن از مجموعه آموزش



شکل (۴): نمودار وزن‌های ۱ حاصل از استخراج ویژگی‌ها




شکل (۵): نمودار تابع هدف در استخراج ویژگی در ۱۰۰۰ تکرار



شکل (۱۱): نمودار باقی‌مانده پیش‌بینی قیمت برق در سال ۲۰۰۸
با مشاهده نتایج ارائه شده در جدول فوق می‌توان دریافت استفاده از روش ترکیبی پیشنهادی موجب کمتر شدن میانگین مطلق درصد خطا (MAPE) در پیش‌بینی نقطه‌ای به میزان ۵/۵۴۵ درصد نسبت به روش ارائه شده در مرجع [۲۸] شده است.

نتیجه پیش‌بینی میان-مدت قیمت توان الکتریکی برای سال ۲۰۰۸ در شکل (۱۰) و باقی‌مانده پیش‌بینی در شکل (۱۱) نمایش داده شده است. میانگین مطلق درصد خطا (MAPE) در پیش‌بینی یک سال-پیش برابر با ۱۰/۲۸۵ محاسبه شده است که خطای مناسبی برای این دوره پیش‌بینی است.


تابع چگالی احتمالات پیش‌بینی در شکل (۱۲) نمایش داده شده است. این نمودار نشان می‌دهد که چقدر احتمال دارد تا مقدار پیش‌بینی شده در هر یک از بازه‌های نمایش داده شده باشند.



شکل (۱۲): نمودار چگالی احتمالات پیش‌بینی قیمت برق در سال ۲۰۰۸

۵- نتیجه‌گیری

در این مقاله یک روش ترکیبی به منظور پیش‌بینی احتمالاتی قیمت برق و جزئیات مدل ریاضی آن پیشنهاد شده است. در روش پیشنهادی در این مقاله مجموعه داده‌های بازار استرالیا به چند زیرمجموعه تقسیم شده و ماتریس ویژگی‌ها با استفاده از روش تحلیل اجزای همسایگی استخراج می‌شود. مرحله بعدی در روش پیشنهادی به جداسازی بخش فصلی داده‌های هدف که شامل قیمت‌های برق ثبت شده هستند، اختصاص دارد. پس از آن، داده‌های آموزش به دو بخش آموزش و اعتبارسنجی تقسیم می‌شود. بخش آموزش به ۱۰۰ زیرمجموعه با طول‌های مختلف تقسیم می‌شود و بر اساس طول بخش‌ها از بیشترین طول به کمترین طول مرتب می‌گردد. پس از آن با استفاده از شبکه حافظه کوتاه-مدت بلند با سه لایه مخفی یک مدل




شکل (۸): نمودارهای رگرسیون آموزش و اعتبارسنجی مدل

پیش‌بینی

جدول (۲): خطای مراحل آموزش و اعتبارسنجی

	MAPE(%)	MAE (\$/MWh)	R ²	RMSE	MSE
آموزش	۰/۰۰۶۱۲	۰/۰۰۴۰۵	۱	۰/۰۲۳۳۶	۰/۰۰۰۵۴
اعتبارسنجی	۴/۷۵۸۷	۳/۱۴۸۲	۰/۹۵۴۵۵	۵/۵۷۲۵	۳۱/۰۵۳


اما بدون یک مقایسه نمی‌توان نتایج را قابل قبول دانست. بدین منظور مقایسه‌ای بین نتایج به دست آمده با استفاده از روش ترکیبی پیشنهادی در این مقاله و روش ارائه شده در مرجع [۲۸] ارائه شده است. برای آنکه بتوان نتایج به دست آمده را با یکدیگر مقایسه کرد، داده‌های استفاده شده در این مقاله، برای ساختن مدل پیش‌بینی به روش پیشنهادی در مرجع [۲۸] مورد استفاده قرار گرفته است. روش مذکور نیز مانند روش پیشنهادی در این مقاله از شبکه‌ی LSTM بهره گرفته است. پیش‌بینی انجام گرفته برای هفته اول ماه ژانویه سال ۲۰۰۸ است و نتایج آن در شکل (۹) و جدول (۳) نمایش داده شده است.



شکل (۹): نمودار مقایسه نتایج برای هفته اول ژانویه ۲۰۰۸

جدول (۳): خطای آزمایش مدل‌های پیش‌بینی و مقایسه

مدل	MAPE(%)	MAE (\$/MWh)	R ²	RMSE	MSE
پیش‌بینی	۱۳/۲۸۹	۱۱/۱۵۳	۰/۷۸۴۲۳	۱۵/۰۷۷	۲۲۷/۳۳
مقایسه	۱۸/۸۳۴	۱۵/۸۰۸	۰/۵۳۱۶	۲۲/۲۱۵	۴۹۳/۴۹



- Australia," in *Abstr. Appl. Anal.*, vol. 2014, Article ID 504064, 2014.
- [14] X. Yan and N. A. Chowdhury, "Mid-term electricity market clearing price forecasting: A multiple SVM approach," *Int. J. Elec. Power*, vol. 58, pp. 206-214, 2014.
- [15] R. Weron, "Electricity price forecasting: A review of the state-of-the-art with a look into the future," *Int.J.Forecast.*, vol. 30, no. 4, pp. 1030-1081 2014.
- [16] Osorio, G. J., Matis, J.C.O., Catalao, J.P.S., "Electricity prices forecasting by a hybrid evolutionary-adaptive methodology," *Energy Conversion and Management*, Vol.80, pp. 363-373, April. 2014.
- [17] Feijoo, F., Silva, W., K..Das, T., "A computationally efficient electricity price forecasting model for realtime energy market," *Energy Conversion and Management*, Vol.113, pp. 27-35, April. 2016.
- [18] Hossam, M., El-Hawary, M., " Hourly Electricity Price Forecasting for the Next Month Using Multilayer Neural Network," *IEEE Canadian journal of electrical and computer engineering*, vol.39, pp. 283-291, December. 2016.
- [19] Y.H. Chen, W.C. Hong, W. Shen, N.N. Huang, "Electric Load Forecasting Based on a Least Squares Support Vector Machine with Fuzzy Time Series and Global Harmony Search Algorithm," *MDPI energies*, Vol. 9, No. 2, January 2016.
- [20] W. Guo, Z. Zhao, "A Novel Hybrid BND-FOA-LSSVM Model for Electricity Price Forecasting," *MDPI Information*, Vol. 8, No. 4, September 2017.
- [21] P.H. Kuo, C.J. Huang, "An Electricity Price Forecasting Model by Hybrid Structured Deep Neural Networks," *MDPI Sustainability*, Vol. 10, No. 4, April 2018.
- [22] M. Rafiei, T. Niknam, M. Khooban, "Probabilistic Forecasting of Hourly Electricity Price by Generalization of ELM for Usage in Improved Wavelet Neural Network," *IEEE Trans. Industrial Informatics.*, Vol. 13, No. 1, pp. 71-79, Feb. 2017.
- [23] R. Tahmasebifar, M. Sheikh-El-Eslami, R. Kheirollahi, "Point and interval forecasting of real-time and day-ahead electricity prices by a novel hybrid approach," *IET Generation, Transmission & Distribution*, Vol. 11, No. 9, pp. 2173-2183, June. 2017.
- [24] B. Uniejewski, R. Weron and F. Ziel, "Variance Stabilizing Transformations for Electricity Spot Price Forecasting," *IEEE Trans. Power Syst.*, Vol. 33, No. 2, pp. 2219-2229, March. 2018.
- [25] A. Bello, D. W. Bunn, J. Reneses, A. Muñoz, "Medium-Term Probabilistic Forecasting of Electricity Prices: a Hybrid Approach," *IEEE Trans. Power Syst.*, Vol. 32, No. 1, pp. 334-343, Jan. 2017.
- [26] L. L. Jiang, G. Hu, "Day-Ahead Price Forecasting for Electricity Market using Long-Short Term Memory Recurrent Neural Network", 2018 15th International Conference on Control, Automation, Robotics and Vision (ICARCV), IEEE, 18-21 Nov. 2018.
- [27] L. Penga, S. Liub, R. Liu, L. Wang, "Effective long short-term memory with differential evolution algorithm for electricity price prediction", *Elsevier Energy*, Vol. 162, pp. 1301-1314, 1 November 2018.
- [28] S. Mujeeb, N. Javaid, M. Ilahi, Z. Wadud, F. Ishmanov, M. K. Afzal, "Deep Long Short-Term Memory: A New Price and Load Forecasting Scheme for Big Data in Smart Cities", *MDPI Sustainability*, Vol. 11, No. 4, February 2019.
- [29] Yang, W., K. Wang, W. Zuo. "Neighborhood Component Feature Selection for High-Dimensional

پیش‌بینی آموزش داده می‌شود و در دو مرحله آموزش و اعتبارسنجی مورد آزمایش قرار می‌گیرد. نتایج به دست آمده با نتایج حاصل از روش ارائه شده در مرجع [۲۸] مقایسه شده و در بخش پیش‌بینی‌های احتمالاتی، نتایج مربوط به باقی‌مانده پیش‌بینی‌ها و توابع چگالی پیش‌بینی ارائه شده‌اند. نتایج به دست آمده و مقایسه با روش‌های مشابه نشان می‌دهد استفاده از روش پیشنهادی در این مقاله موجب افزایش دقت پیش‌بینی شده است.

مراجع

- [1] M. Shahidehpour, H. Yamin, Z. Li, "Market Operations in Electric Power Systems, Tarbiat modares university, 1384.
- [۲] رحمت الله هوشمند، مجید معظمی، "پیش‌بینی کوتاه مدت قیمت تراکم گرهی در یک سیستم قدرت بزرگ تجدید ساختاریافته با استفاده از شبکه‌های عصبی مصنوعی با بهینه‌سازی آموزش ژنتیکی"، *مجله انجمن برق و الکترونیک ایران*، سال یازدهم، شماره اول، صفحات ۳۷-۴۸، بهار و تابستان ۱۳۹۳.
- [۳] حمید کریمی، شهرام جدید، "تعیین قیمت بهینه برای برنامه پاسخگویی بار با هدف بهبود همزمان سود مصرف‌کنندگان و ضریب بار شبکه"، *مجله انجمن برق و الکترونیک ایران*، سال هفدهم، شماره دوم، صفحات ۱۴۹-۱۵۹، تابستان ۱۳۹۹.
- [4] P. Kou, D. Liang, L. Gao and J. Lou, "Probabilistic electricity price forecasting with variational heteroscedastic gaussian process and active learning," *Energy Conversion and Management*, vol. 89, no. 0, pp. 298-308, 2015.
- [5] N. A. Shrivastava and B. K. Panigrahi, "A hybrid wavelet-ELM based short term price forecasting for electricity markets," *Int. J. Elec. Power & Energy. Syst.*, vol. 55, pp. 41-50, 2014.
- [6] K. He, Y. Xu, Y. Zou and L. Tang, "Electricity price forecasts using a curvelet denoising based approach," *Physica A: Statistical Mechanics and its Applications*, vol. 425, pp. 1-9, 2015.
- [7] C. Wan, M. Niu, Y. Song and Z. Xu, "Pareto optimal prediction intervals of electricity price," *IEEE Trans. Power Syst.* in press, 2016.
- [8] P. Gaillard, Y. Goude and R. Nedellec, "Additive models and robust aggregation for GEFCom2014 probabilistic electric load and electricity price forecasting," *Int. J. Forecast.*, 2016, in press.
- [9] F. Ziel, "Forecasting electricity spot prices using lasso: On capturing the autoregressive intraday structure," *IEEE Trans. Power Syst.*, 2016, in press.
- [10] T. Hong, P. Pinson, S. Fan, H. Zareipour, A. Troccoli and R.J. Hyndman, "Probabilistic energy forecasting: Global energy forecasting competition 2014 and beyond," *Int.J.Forecast.* 2016.
- [11] P. Gaillard, Y. Goude and R. Nedellec, "Additive models and robust aggregation for GEFCom2014 probabilistic electric load and electricity price forecasting," *Int. J. Forecast.*, 2016, in press.
- [12] F. Ziel, "Forecasting electricity spot prices using lasso: On capturing the autoregressive intraday structure," *IEEE Trans. Power Syst.*, 2016, in press.
- [13] Y. Yang, Y. Dong, Y. Chen and C. Li, "Intelligent optimized combined model based on GARCH and SVM for forecasting electricity price of New South Wales,

- Data." Journal of Computers. Vol. 7, Number 1, January, 2012.
- [30] Hochreiter, S.; Schmidhuber, J. Long short-term memory. Neural Comput. 1997, 9, 1735–1780.
- [31] K. B. Sahay and M. M. Tripathi, "Day ahead hourly load and price forecast in ISO New England market using ANN," in Proc. Annu. IEEE India Conf. (INDICON), Dec. 2013, pp. 1–6.
- [32] Escribano, Alvaro, Pena, Juan Ignacio, Villaplana, Pablo. "Modeling Electricity Prices: International Evidence." Universidad Carlos III de Madrid, Working Paper 02-27, 2002.
- [33] Lucia, Julio J., Schwartz, Eduardo. "Electricity Prices and Power Derivatives: Evidence from the Nordic Power Exchange." Review of Derivatives Research. Vol. 5, Issue 1, pp 5-50, 2002.
- [34] The Australian Energy Market Operator (AEMO). [Online]. Available: <http://www.aemo.com.au/Electricity/Planning/Forecasting> (2015).

زیر نویس‌ها

¹ Least Absolute Shrinkage and Selection Operator

² Hybrid Evolutionary-Adaptive

³ Adaptive neuro-fuzzy inference system

⁴ Pennsylvania–New Jersey–Maryland

⁵ Mean Absolute Percentage Error

⁶ Long Short-Term Memory

⁷ sequence to sequence regression

