

پیش‌بینی بار الکتریکی با بکارگیری مدل‌های ترکیبی پرسپترون‌های چندلایه و خودرگرسیون میانگین متحرک انباشته فصلی

فاطمه چاهکوتاهی^(۱) - مهدی خاشعی^(۲)

(۱) کارشناس ارشد - دانشکده مهندسی صنایع و سیستم‌ها، دانشگاه صنعتی اصفهان، اصفهان، ایران

(۲) استادیار - دانشکده مهندسی صنایع و سیستم‌ها، دانشگاه صنعتی اصفهان، اصفهان، ایران

تاریخ دریافت: ۹۸/۶/۱۶ تاریخ پذیرش: ۹۸/۱۱/۳

خلاصه: امروزه صرفه‌جویی اقتصادی در زمان و هزینه‌های عملکردی هر کشوری، نیازمند برنامه‌ریزی، تصمیم‌گیری و پیش‌بینی‌های درست و منطقی در حوزه‌های مختلف است. یکی از مهم‌ترین و شناخته‌شده‌ترین حوزه‌های مطرح در اقتصاد صرفه‌جویانه، پیش‌بینی انرژی‌های تجدیدپذیر و بار الکتریکی حاصله است. این کالا (الکتریسیته) با توجه به اینکه قابل ذخیره‌سازی نیست، پیش‌بینی آن با حساسیت بالاتری انجام می‌گیرد. همچنین علاوه بر غیرقابل ذخیره بودن، در مصرف این کالا الگوهای مختلفی نیز مشاهده می‌شود که مدل‌سازی آن را با روش‌های کلاسیک فصلی دشوار می‌سازد. بنابراین، به منظور حصول پیش‌بینی‌های دقیق در این حوزه، نیازمند روش‌هایی هستیم که بتوانند الگوهای موجود در داده‌های مرتبط با این حوزه را به صورت دقیق مدل‌سازی نمایند. در این مقاله از یک روش ترکیبی موازی که مدل‌های کلاسیک خطی را با مدل‌های هوش محاسباتی غیرخطی ترکیب می‌کند، پیشنهاد گردیده است. بدین منظور، یک مدل بهینه وزن‌دهی جهت ترکیب مدل‌ها که شامل پرسپترون‌های چندلایه و خودرگرسیون میانگین متحرک انباشته فصلی هستند، برای پیش‌بینی بار الکتریکی پیشنهاد شده است. ایده اصلی این مدل استفاده همزمان از مزایای مدل‌های تکی در مدل‌سازی سیستم‌های پیچیده در یک ساختار بهینه ترکیبی است. از لحاظ نظری، مدل پیشنهادی به دلیل استفاده از این ساختار بهینه غیرتکراری، دقت ناکمتری نسبت به مدل‌های ترکیبی فراباکتاری شبه‌بهینه و تکراری خواهد داشت. این درحالی است که هزینه‌های محاسباتی مدل پیشنهادی به دلیل غیرتکراری بودنش، به طور قابل توجهی پایین تر از این گونه از مدل‌ها خواهد بود. نتایج تجربی نشان می‌دهد که مدل پیشنهادی نتایج دقیق‌تری را نسبت به اجزای تشکیل‌دهنده خود و برخی مدل‌های ترکیبی فصلی دیگر داشته است.

کلمات کلیدی: مدل‌های ترکیبی، پیش‌بینی سری‌های زمانی فصلی، بار الکتریکی، پرسپترون‌های چندلایه، خودرگرسیون میانگین متحرک انباشته فصلی

Electricity Load Forecasting Using Hybrid Models Based on Multi-Layer Perceptrons Neural Network and Seasonal Auto-Regressive Integrated Moving Average models

Fatemeh Chahkoutahi⁽¹⁾ - Mehdi Khashei⁽²⁾

(1) Msc - Department of Industrial and Systems Engineering, Isfahan University of Technology

f.chahkoutahi@in.iut.ac.ir

(2) Assistant Professor - Department of Industrial and Systems Engineering, Isfahan University of Technology

khashei@cc.iut.ac.ir

Abstract: Nowadays, economic saving in time and operational costs of each country requires appropriate planning, decision making, and rational forecasts in different areas. One of the most important and well-known areas in saving economic that has received a lot of attention is renewable energies and produced electricity forecasting. Forecasting of electricity has often high sensitivity due to its distinguished feature of the impossibility of storing. In addition of impossibility of storing, various ambiguous patterns can be detected in the consumption of electricity that makes difficult its modeling process using classical approaches. Thus, in order to yield desired forecasts in this area, models is needed that can accurately model the existing pattern in electricity data sets. In this paper, a parallel hybrid model is proposed by combining seasonal classic linear and nonlinear intelligent methods. For this purpose, an optimal weighting algorithm is developed in order to parallel hybridization of multilayer perceptrons and seasonal autoregressive integrated moving average models for electricity load forecasting. The main idea of this model is to simultaneously use advantages of individual models in the modeling of complex systems in an optimal hybrid structure. Theoretically, the accuracy of the proposed model due to its non-iterative optimal process will not be worse than semi-optimal iterative meta-heuristic algorithms. Whereas, computational costs of the proposed model are significantly lower than these models, due to its non-iterative process. Experimental results indicate that the proposed model can achieve more accurate performance than its components and some other seasonal parallel hybrid methods.

Index Terms: Hybrid methods, Seasonal Time Series forecasting, electricity load, multi-layer perceptrons, Seasonal Auto-Regressive Integrated Moving Average models.

۱- مقدمه

نیروگاه‌های تولید و توزیع الکتریسیته از جمله سازمان‌هایی هستند که بسیار مورد توجه بوده و نیاز به تصمیمات مدیریتی اثربخش دارند. پیش‌بینی تقاضای الکتریسته یکی از مهم‌ترین فاکتورهای مؤثر در فرآیندهای تصمیم‌گیری مدیران مالی و عملیاتی نیروگاه‌های تولید و توزیع الکتریسته است. آگاهی از میزان تقاضای الکتریسته به‌منظور برنامه‌ریزی، صرفه‌جویی در زمان، حداقل‌سازی هزینه‌های عملیاتی و کاهش ریسک شبکه‌های تولید و توزیع الکتریسته بسیار مهم است. به همین دلیل دقت پیش‌بینی تقاضای الکتریسته برای بخش‌های مختلف اقتصادی حائز اهمیت بوده و مورد توجه مدیران مالی و عملیاتی نیروگاه‌های تولید و توزیع الکتریسته قرار گرفته است. در ادبیات موضوع مدل‌سازی‌های متعددی به‌منظور پیش‌بینی بار الکتریکی ارائه شده است. مدل‌سازی‌های جدید و بی‌وقفه برای بازارهای برق که داده‌های آن با الگوهای مختلف و تغییرات همراه هستند، بیانگر اهمیت بالای موضوع است. هدف از این مدل‌سازی‌ها، اساساً بهبود کیفیت تصمیمات اتخاذی مدیران در شرایط دشوار است. در دو دهه اخیر پژوهشگران بسیاری به مطالعه پیش‌بینی بار الکتریکی پرداخته‌اند و روش‌های گوناگونی همچون سری‌های زمانی [۳-۱]، مدل‌های رگرسیونی [۵-۴]، تکنیک‌های هوش مصنوعی [۷-۶] و منطق فازی [۸] را برای پیش‌بینی بار الکتریکی ارائه نموده‌اند. این‌گونه از مدل‌ها در مقالات بسیاری به‌منظور بهبود دقت روش‌های موجود و یا ارائه روش‌های ترکیبی جدید [۹] به‌منظور پیش‌بینی استفاده شده‌اند.

در ادبیات موضوع روش‌های آماری کلاسیک زیادی برای پیش‌بینی سری‌های زمانی فصلی، به‌خصوص پیش‌بینی بار الکتریکی ارائه شده است. یکی از مهم‌ترین و پرکاربردترین مدل‌های سری‌های زمانی، مدل‌های خودرگرسیون میانگین متحرک انباشته است. از زمان پیشنهاد مدل‌های خودرگرسیون میانگین متحرک انباشته توسط باکس-جنکینز [۱۰] تا به امروز، این‌گونه از مدل‌ها در مقالات بسیاری به‌منظور بهبود دقت روش‌های موجود و یا ارائه روش‌های ترکیبی جدید [۱۱] به‌منظور پیش‌بینی استفاده شده‌اند. کامارا و همکاران [۱۲] از مدل خودرگرسیون میانگین متحرک انباشته فصلی به‌منظور پیش‌بینی مصرف انرژی استفاده کرده‌اند. نوریزان و همکاران [۱۳] برای پیش‌بینی بار کوتاه‌مدت روش خودرگرسیون میانگین متحرک انباشته فصلی را ارائه نموده‌اند. همچنین سوارز و همکاران [۱۴] روش خودرگرسیون میانگین متحرک انباشته فصلی را برای پیش‌بینی کوتاه‌مدت بار الکتریکی پیشنهاد کرده‌اند. محدودیت اصلی این‌گونه از روش‌ها این است که مقدار آینده یک متغیر به‌صورت تابع خطی از چند مشاهده گذشته و خطاهای تصادفی فرض می‌شود. همچنین این‌گونه از روش‌ها نیازمند داده‌های زیادی به‌منظور حصول نتایج مطلوب هستند. بنابراین با توجه به اینکه امروزه با مجموعه‌ای از مسائل و سیستم‌هایی مواجه هستیم که دارای ویژگی‌هایی چون حجم بالای اطلاعات، روابط پیچیده و عدم قطعیت هستند، لذا نیاز به روش‌هایی کارآمد به‌منظور تجزیه و تحلیل مسائل در شرایط نامطمئن، با حجم اطلاعاتی بالا و روابط پیچیده احساس می‌گردد. مدل‌های متعددی در ادبیات موضوع برای غلبه بر این محدودیت‌ها ارائه شده‌اند.

نتایج به‌دست آمده از شواهد علمی و عملی نشانگر آن است که ادغام و ترکیب مدل‌های مختلف می‌تواند یک روش مؤثر برای غلبه بر محدودیت‌های مدل‌های تک‌تکی و همچنین بهبود دقت پیش‌بینی‌ها باشند. اخیراً مدل‌های ترکیبی بسیاری در ادبیات موضوع پیش‌بینی ارائه شده است. هدف اصلی از ترکیب مدل‌های مختلف، استفاده همزمان از مزایای مدل‌های تک است.

بدین منظور پژوهشگران مدل‌های ترکیبی زیادی از ترکیب مدل‌های مختلف با هم برای پیش‌بینی بار الکتریکی ارائه کرده‌اند. نیو و همکاران در مقاله [۱۵] یک روش ترکیبی مبتنی بر شبکه‌های عصبی، به‌منظور پیش‌بینی کوتاه‌مدت بار الکتریکی ارائه نمودند. آن‌ها مدل پیشنهادی خود را با سایر مدل‌ها مقایسه کردند و به این نتیجه دست یافتند که مدل ترکیبی پیشنهادی، عملکرد بهتری را داشته است. کوهی و کی‌نیا در مقاله [۱۶] یک روش ترکیبی شبکه عصبی برای پیش‌بینی بار الکتریکی ارائه کردند. نتایج به‌دست آمده از مقایسه بین مدل پیشنهادی آن‌ها و سایر مدل‌ها نشان‌دهنده خطای کمتر مدل پیشنهادی نسبت به سایر مدل‌ها بوده است. نی و همکاران در مقاله [۱۷] از ترکیب روش‌های خودرگرسیون میانگین متحرک انباشته و ماشین‌های بردار پشتیبان برای پیش‌بینی کوتاه‌مدت بار الکتریکی استفاده کرده‌اند.

هو و همکاران با بکارگیری روش‌های بهینه‌سازی ازدحام ذرات، شبکه عصبی پسانتشار و الگوریتم ژنتیک، یک روش ترکیبی به‌منظور پیش‌بینی کوتاه‌مدت بار الکتریکی ارائه نموده‌اند [۱۸]. ژانگ و همکاران در مقاله [۱۹] برای بهبود دقت پیش‌بینی بار الکتریکی در کوتاه‌مدت، یک مدل ترکیبی جدید مبتنی بر روش‌های تجزیه حالت تجربی بهبودیافته، خودرگرسیون میانگین متحرک انباشته و شبکه عصبی موجک ارائه نموده‌اند و با برخی دیگر از روش‌های ترکیبی مقایسه نموده‌اند. نتایج شبیه‌سازی نشان می‌دهد که مدل پیشنهادی عملکرد خوبی در پیش‌بینی بار الکتریکی نسبت به سایر مدل‌های مقایسه‌شده داشته است. هونگ و فن روش‌های تجزیه حالت تجربی و ماشین بردار رگرسیون را به‌منظور پیش‌بینی بار الکتریکی با یکدیگر ترکیب نموده‌اند [۲۰]. وو و همکاران در مقاله [۲۱] یک مدل ترکیبی جدید مبتنی بر شبکه عصبی رگرسیون عمومی اصلاح‌شده برای پیش‌بینی بار الکتریکی کوتاه‌مدت پیشنهاد کرده‌اند. ژپائو و همکاران در مقاله [۲۲] به‌منظور پیش‌بینی سیستم انرژی الکتریکی، مدل‌های شبکه عصبی موجک و الگوریتم جستجوی فاخته بهبودیافته را با یکدیگر ترکیب نمودند. جاودانی و همکاران یک روش ترکیبی مبتنی بر شبکه‌های عصبی پیچشی و سری‌های زمانی فازی به‌منظور پیش‌بینی بار الکتریکی کوتاه‌مدت ارائه نموده‌اند [۲۳]. یانگ و همکاران در مقاله [۲۴] یک روش ترکیبی براساس مدل‌های شبکه‌های عصبی انتشار پسخور، سیستم استنتاج فازی-عصبی تطبیقی و خودرگرسیون میانگین متحرک انباشته فصلی برای پیش‌بینی بار الکتریکی ارائه کرده‌اند.

روش‌هایی که تاکنون در ادبیات موضوع ارائه شده است اغلب روش‌هایی هستند که در ساختار ترکیبشان از روش‌هایی با هزینه محاسباتی بالا و غیربهینه استفاده می‌شود. در این مقاله، یک مدل ترکیبی بهینه موازی، براساس مدل‌های پرسپترون‌های چندلایه و خودرگرسیون میانگین

متحرک انباشته فصلی به منظور مدل سازی رابطه بین مشاهدات نظیر به نظیر فصل های متوالی استفاده می گردد. اصطلاحاً یک سری زمانی $\{y_t | t=1,2,\dots,k\}$ از مدل سری زمانی باکس-جنکینز توسط فرآیند $SARIMA(p,d,q)(P,D,Q)_s$ با میانگین μ تولید می شود اگر:

$$\phi_p(B)\Phi_p(B^s)\nabla^d\nabla_s^D(y_t-\mu)=\Theta_q(B^s)\theta_q(B)a_t \quad (1)$$

به قسمی که y_t و a_t مقادیر مشاهده شده و خطای تصادفی در دوره زمانی $(t=1,2,\dots,k)$ هستند. $\phi_p(B)=1-\sum_{i=1}^p\phi_iB^i$ و $\theta_q(B)=1-\sum_{i=1}^q\theta_iB^i$ به ترتیب عملگرهای خودرگرسیون غیرفصلی (AR) و میانگین متحرک غیرفصلی (MA) هستند و $\Phi_p(B^s)=1-\sum_{i=1}^p\Phi_{is}B^{is}$ و $\Theta_q(B^s)=1-\sum_{i=1}^q\Theta_{is}B^{is}$ عملگرهای خودرگرسیون و میانگین متحرک فصلی هستند. عملگر B عملگر انتقال پسرو است. $\nabla^d=(1-B)^d$ عملگر تفاضل گیری غیرفصلی و $\nabla_s^D=(1-B^s)^D$ عملگر تفاضل گیری فصلی است. S

تعداد دوره ها، p مرتبه خودرگرسیون غیرفصلی، P مرتبه خودرگرسیون فصلی، q مرتبه میانگین متحرک غیرفصلی و Q مرتبه میانگین متحرک فصلی است. a_t متغیری تصادفی با توزیع نرمال با میانگین صفر و واریانس σ^2 و مستقل از مشاهدات است. در حالت کلی فرآیند فرمول بندی مدل خودرگرسیون میانگین متحرک انباشته فصلی شامل چهار مرحله تکراری مطابق زیر است:

- ۱- تعیین ساختار $SARIMA(p,d,q)(P,D,Q)_s$
- ۲- تخمین پارامترهای مجهول.
- ۳- تست نیکویی برازش بر روی باقیمانده ها.
- ۴- پیش بینی نتایج براساس داده های معلوم.

مرحله اول، تعیین صحیح مرتبه مدل خودرگرسیون میانگین متحرک انباشته است. یک راه حل اساسی به منظور شناسایی مدل، استفاده از توابع خودهمبستگی (ACF) و خودهمبستگی جزئی (PACF) است. در این مرحله با رسم نمودارهای خودهمبستگی و خودهمبستگی جزئی، ایستایی در میانگین مورد ارزیابی قرار گرفته و مراتب P, p, q و Q را می توان تعیین نمود. البته روش های دیگری نیز در ادبیات موضوع برای شناسایی مرتبه مدل پیشنهاد شده است. معیارهای اطلاعاتی همچون معیار آکائیک یکی از شناخته شده ترین این روش ها می باشند. به علاوه، در سال های اخیر روش های مختلفی براساس روش های هوشمند مثل شبکه های عصبی، الگوریتم ژنتیک [۲۵] و یا سیستم فازی [۲۶] به منظور شناسایی دقیق تر مرتبه مدل های خودرگرسیون میانگین متحرک انباشته پیشنهاد شده است. هنگامی که یک مدل آزمایشی تشخیص داده شد تخمین پارامترهای مدل کار ساده ای بوده و از طریق حداقل سازی ترم خطا به دست می آیند. در این فرایند، مدلی که دارای مجموع مربعات خطا و یا میانگین مربعات خطای کوچکتری باشد، انتخاب می گردد. آخرین گام مدل سازی، کنترل تشخیص مناسب بودن مدل است و اساساً به منظور چک کردن اینکه فرضیات مدل در مورد خطاها صدق می کند یا نه استفاده می شود. اگر مدل انتخابی مناسب نباشد یک مدل آزمایشی جدید باید تشخیص داده شود و موارد فوق دوباره تکرار گردند.

متحرک انباشته فصلی به منظور پیش بینی بار الکتریکی ارائه شده است. در این مدل علاوه بر غلبه بر محدودیت های مدل های تشکیل دهنده آن، به طور همزمان از مزایای مدل ها در مدل سازی ساختارهای خطی و غیر خطی برای پیش بینی سری های زمانی فصلی استفاده می گردد. تفاوت اصلی این مقاله با سایر روش ها نحوه ترکیب مدل ها و وزن دهی به مدل های استفاده شده در ساختار مدل ترکیبی است که در مرحله سوم روش پیشنهادی شرح داده شده است. مدل ارائه شده شامل چهار مرحله: (۱) مرحله مدل سازی قطعی و خطی، (۲) مرحله مدل سازی غیرخطی، (۳) مرحله وزن دهی و (۴) مرحله ترکیب است. در دو مرحله اول دو مدل پرسپترون های چندلایه و خودرگرسیون میانگین متحرک انباشته فصلی به صورت جداگانه مدل سازی می شود. سپس اهمیت نسبی (وزن) هر مدل توسط روش پیشنهادی محاسبه می شود. در نهایت، مقادیر پیش بینی به دست آمده از اجزای مدل پیشنهادی به منظور محاسبه پیش بینی نهایی با هم ترکیب می شوند.

نظر به اینکه مدل پیشنهادی از یک روش وزن دهی مستقیم استفاده می کند، هزینه محاسباتی مدل سازی آن به صورت قابل توجهی از سایر روش های ترکیبی موازی که از مدل های فراابتکاری برای وزن دهی استفاده می کنند پایین تر است. همچنین استفاده از این رویکرد وزن دهی مدل سازی را با دقت غیرکمتر از سایر مدل های ترکیبی موازی انجام می دهد. سایر قسمت های این مقاله بدین صورت است: در قسمت بعد مدل خودرگرسیون میانگین متحرک انباشته فصلی و پرسپترون های چندلایه به طور خلاصه ارائه گردیده است. در قسمت سوم، فرموله سازی مدل ترکیبی پیشنهادی ارائه گردیده است. در قسمت چهارم، معیارهای آماری برای مقایسه مدل ها بکار گرفته شده است و در نهایت نیز نتایج حاصله مورد بررسی و تجزیه و تحلیل قرار گرفته اند.

۲- روش ها

در این بخش اجزای خطی و غیرخطی مدل پیشنهادی از جمله مدل خودرگرسیون میانگین متحرک انباشته فصلی و پرسپترون های چندلایه به طور خلاصه بررسی می شود.

۲-۱- مدل خودرگرسیون میانگین متحرک انباشته فصلی

مدل های خودرگرسیون میانگین متحرک انباشته یکی از محبوب ترین و کاربردی ترین مدل های پیش بینی سری های زمانی است که توسط باکس-جنکینز [۱۰] ارائه شده اند. این گونه از مدل ها در پیش بینی های مالی، مهندسی، حمل و نقل و بسیاری زمینه های دیگر مورد استفاده قرار گرفته اند. مشکل عمده مدل های خودرگرسیون میانگین متحرک انباشته، عدم توانایی آنها در مدل سازی ساختارهای همراه با الگوهای فصلی بود. بنابراین باکس-جنکینز یک نسخه فصلی از مدل های خودرگرسیون میانگین متحرک انباشته اراده نمودند، که اصطلاحاً مدل خودرگرسیون میانگین متحرک انباشته فصلی نامیده می شود.

پدیده فصلی بودن بدین صورت است که علاوه بر وجود تناوب بین مشاهدات متوالی، بین مشاهدات نظیر به نظیری که متعلق به فصل های متوالی نیز هستند دیده می شود. در حالت کلی، مدل خودرگرسیون میانگین متحرک انباشته برای توصیف رابطه بین مقادیر مشاهدات متوالی استفاده می گردد، در حالی که مدل خودرگرسیون میانگین

۲-۲- شبکه‌های عصبی در مدل‌سازی سری‌های زمانی

شبکه‌های عصبی مصنوعی از جمله روش‌هایی هستند که قادر به تخمین موارد غیرخطی متعدد در داده‌ها بوده و یک چارچوب محاسبه‌ای انعطاف‌پذیر برای دامنه وسیعی از مسائل غیرخطی هستند. یکی از مزیت‌های بارز این گونه از مدل‌ها نسبت به مدل‌های غیرخطی دیگر، این است که شبکه‌های عصبی مصنوعی یک تقریب‌زننده جهانی هستند که می‌توانند هر نوع تابعی را با دقت دلخواه تقریب بزنند [۲۷]. این گونه از شبکه‌ها به هیچ‌گونه پیش‌فرضی در مورد شکل مدل در فرآیند مدل‌سازی نیاز ندارند و به‌طور کلی یک مدل مبتنی بر داده هستند. شبکه‌های عصبی پیشرو با یک لایه مخفی یکی از پرکاربردترین مدل‌های شبکه‌های عصبی برای پیش‌بینی سری‌های زمانی هستند [۲۸].

این گونه مدل‌ها اساساً از سه لایه پردازش ساده اطلاعات متصل به‌هم تشکیل شده‌اند. رابطه بین خروجی (y_t) و ورودی‌های مدل $(y_{t-1}, \dots, y_{t-p})$ در این گونه از شبکه‌ها به این ترتیب است:

$$y_t = b_0 + \sum_{j=1}^q w_j \cdot g(b_{0j} + \sum_{i=1}^p w_{i,j} \cdot y_{t-i}) + \varepsilon_t \quad (2)$$

به‌طوری که ε_t ترم خطا و w_j و $w_{i,j}$ عوامل مدل بوده که اغلب وزن‌های اتصالی نامیده می‌شوند، p تعداد گره‌های ورودی و q تعداد گره‌های مخفی هستند. توابع سیگموئیدی (رابطه ۳) و خطی از جمله توابعی هستند که اغلب به عنوان توابع فعال‌سازی برای لایه‌های مخفی و خروجی مورد استفاده قرار می‌گیرند.

$$\text{Sig}(x) = \frac{1}{1 + \exp(-x)} \quad (3)$$

از این‌رو مدل شبکه‌های عصبی مصنوعی رابطه (۲) در حقیقت به‌عنوان یک نگاشت غیرخطی از مشاهده‌های گذشته به مقدار آینده خواهند بود، به عبارت دیگر:

$$y_t = f(y_{t-1}, \dots, y_{t-p}, w) + \varepsilon_t \quad (4)$$

به‌طوری که w بردار همه عوامل و f تابعی است که توسط ساختار شبکه عصبی و وزن‌های انتقال تعیین می‌شود. بنابراین شبکه‌ی عصبی معادل یک مدل خودرگرسیون میانگین غیرخطی است. رابطه (۴) همچنین بیانگر این موضوع است که یک نرون (خروجی) در لایه خروجی برای پیش‌بینی یک مرحله‌ای مورد استفاده قرار می‌گیرد. مدل ساده بیان‌شده توسط رابطه (۴) قدرت تقریب بسیار زیادی دارد؛ چرا که به شرط آنکه تعداد گره‌های مخفی (q) به اندازه کافی بزرگ باشند، قادر است هر تابع دلخواه را تقریب بزند. در عمل اغلب ساختار شبکه عصبی ساده که تعداد نرون کمتری در لایه مخفی دارد، در پیش‌بینی‌های خارج از نمونه (داده‌های تست) بهتر عمل می‌کند و این به دلیل دوری جستن از مسئله برازش بیش از حد است که اغلب در فرآیند مدل‌سازی شبکه‌های عصبی رخ می‌دهد [۲۹].

یک مدل بیش از حد برازش‌شده، برای داده‌هایی که برای ساخت مدل استفاده شده باشند، برازش خوبی نشان می‌دهد، اما توانایی تعمیم آن، برای داده‌های خارج از نمونه، بسیار ضعیف خواهد بود. انتخاب تعداد نرون‌های لایه مخفی، وابسته به داده‌ها بوده و هیچ قانون سیستماتیکی

برای تعیین این عامل در طراحی شبکه‌های عصبی وجود ندارد. علاوه بر این، مرحله مهم دیگر مدل‌سازی شبکه‌های عصبی، انتخاب تعداد وقفه‌های موجود در مشاهده‌ها به عنوان بردار ورودی شبکه است که شاید مهم‌ترین عامل در طراحی مدل‌های شبکه‌های عصبی باشد؛ چرا که این عامل در تعیین ساختار خودهمبسته غیرخطی سری‌های زمانی نقش اساسی دارد [۳۰].

هیچ تئوری خاصی برای انتخاب p وجود ندارد. از این رو تجربه و آزمایش‌ها، مشخص‌کننده مقدار مناسب p و همچنین q خواهد بود. وقتی یک ساختار شبکه‌ای p و q مشخص شد، شبکه آماده آموزش و تخمین عوامل است. همانند مدل‌سازی خودرگرسیون میانگین متحرک انباشته عوامل طوری تخمین زده می‌شوند که معیار دقت مانند میانگین مربع خطاها حداقل شود. فرآیند این آموزش توسط الگوریتم‌های بهینه‌سازی غیرخطی همچون پس‌انتشار خطا انجام می‌گیرد.

مدل برآوردشده اغلب توسط یک نمونه جداگانه که در فرآیند آموزش مورد استفاده قرار نگرفته است (داده‌های تست) ارزیابی می‌شود و این با فرآیند مدل‌سازی مدل خودرگرسیون میانگین متحرک انباشته که از یک نمونه برای شناسایی، تخمین و ارزیابی مدل استفاده می‌کند متفاوت است. دلیل این موضوع این است که شکل کلی مدل (خطی) برای مدل‌سازی خودرگرسیون میانگین متحرک انباشته از قبل مشخص است [۳۱]، در صورتی که در مدل‌سازی شبکه‌های عصبی این طور نبوده و در مدل‌سازی با شبکه‌های عصبی مصنوعی مدل غیرخطی همانند مرتبه مدل باید تخمین زده شود و ممکن است شبکه دچار برازش بیش از حد شود.

۳- مدل ترکیبی پیشنهادی

مدل‌های ترکیبی سال‌های متمادی مورد مطالعه پژوهشگران بسیاری قرار گرفته است. دستیابی به نتایج دقیق‌تر با استفاده از روش‌های ترکیبی توجه پژوهشگران را به ارائه این گونه روش‌ها دوجندان نموده است. هدف اصلی در استفاده از این روش‌ها، غلبه بر محدودیت‌های مدل‌های تکی و استفاده همزمان از مزایای مدل‌های تکی می‌باشد. یک راه‌حل مناسب و همچنین پرکاربرد برای ترکیب مدل‌های تکی و رسیدن به دقت قابل‌قبول، ترکیب مدل‌های مختلف به‌صورت موازی می‌باشد. در این مقاله ترکیب اجزای تشکیل‌دهنده مدل براساس وزنشان با یکدیگر صورت می‌گیرد. فرمول‌سازی این ترکیب به‌صورت زیر است:

$$\begin{aligned} \hat{f}_{Com,t} &= W_1 \hat{f}_{1,t} + W_2 \hat{f}_{2,t} + \dots + W_n \hat{f}_{n,t} \\ &= \sum_{i=1}^n W_i \hat{f}_{i,t} \quad (i=1,2,\dots,n) (t=1,2,\dots,m) \end{aligned} \quad (5)$$

به‌طوری که $\hat{f}_{Com,t}$ ($t=1,2,\dots,m$) مقدار پیش‌بینی‌شده مدل ترکیبی در زمان t ، W_i ($i=1,2,\dots,n$) وزن مربوط به i امین جزء، $\hat{f}_{i,t}$ ($i=1,2,\dots,n$) ($t=1,2,\dots,m$) مقدار پیش‌بینی-شده i امین جزء در زمان t ، تعداد اجزای مورد استفاده در ساختار مدل ترکیبی و تعداد داده‌ها نیز به‌ترتیب با n و m نمایش داده شده است. وزن مربوط به هر یک از اجزای تشکیل‌دهنده مدل پیشنهادی به

مرحله سوم: مرحله وزن دهی. در مرحله سوم از مدل پیشنهادی، با استفاده از یک فرآیند حداقل مربعات، وزن هر یک از اجزای تشکیل دهنده مدل به طور مجزا محاسبه گردیده و در ترکیب خطی استفاده می شود. به این ترتیب، معادله دستیابی به وزن مورد نظر در مدل به صورت زیر فرموله می شود:

$$y_t = W_{SARIMA} \cdot \hat{f}_{SARIMA,t} + W_{MLP} \hat{f}_{MLP} + u_t \quad (8)$$

$$t = 1, 2, 3, \dots, m$$

فرض اولیه مدل حداقل مربعات این است که خطای صفر یا ناچیز در متغیر مستقل وجود دارد، از این رو این مدل تلاش بر حداقل سازی میانگین مربع خطا در متغیر وابسته را دارد.

$$\sum_{t=1}^m \hat{u}_t^2 = \sum_{t=1}^m (f_t - \hat{W}_{SARIMA} \hat{f}_{SARIMA,t} - \hat{W}_{MLP} \hat{y}_{MLP})^2 \quad (9)$$

که در آن، $\sum_{t=1}^m \hat{u}_t^2$ مجموع مربع باقی مانده ها (RSS) است. به عبارت دیگر، فرآیند وزن دهی پیشنهادی متشکل از برآورد \hat{W}_{SARIMA} و \hat{W}_{MLP} بوده که $\sum_{t=1}^m \hat{u}_t^2$ را به حداقل می رساند. این عمل از طریق مشتق گیری از معادله (۹) نسبت به \hat{W}_{SARIMA} و \hat{W}_{MLP} و قرار دادن نتایج مشتق گیری برابر با صفر حاصل می شود. حاصل این فرآیند یک دستگاه دو معادله و دو مجهول به شکل زیر است:

$$\sum_{t=1}^m f_t \hat{f}_{SARIMA,t} = \hat{W}_{SARIMA} \sum_{t=1}^m \hat{f}_{SARIMA,t}^2 + \hat{W}_{MLP} \sum_{t=1}^m \hat{f}_{SARIMA,t} \hat{f}_{MLP,t} \quad (10)$$

$$\sum_{t=1}^m f_t \hat{f}_{MLP,t} = \hat{W}_{SARIMA} \sum_{t=1}^m \hat{f}_{MLP,t} \hat{f}_{SARIMA,t} + \hat{W}_{MLP} \sum_{t=1}^m \hat{f}_{MLP,t}^2$$

شکل ماتریسی معادله (۱۰) را می توان به صورت معادله (۱۱) بیان کرد. سپس، با جایگزین کردن $\hat{f}_{SARIMA,t} = \hat{f}_{1,t}$ ، $\hat{f}_{MLP,t} = \hat{f}_{2,t}$ ، $\hat{W}_{SARIMA} = \hat{W}_1$ و $\hat{W}_{MLP} = \hat{W}_2$ معادله (۱۱) را می توان به مطابق رابطه (۱۲) بازنویسی کرد:

$$\begin{bmatrix} \sum_{t=1}^m \hat{f}_{SARIMA,t}^2 & \sum_{t=1}^m \hat{f}_{SARIMA,t} \hat{f}_{MLP,t} \\ \sum_{t=1}^m \hat{f}_{MLP,t} \hat{f}_{SARIMA,t} & \sum_{t=1}^m \hat{f}_{MLP,t}^2 \end{bmatrix} \begin{bmatrix} \hat{W}_{SARIMA} \\ \hat{W}_{MLP} \end{bmatrix} = \begin{bmatrix} \hat{f}_{SARIMA,1} \\ \hat{f}_{MLP,1} \end{bmatrix}$$

$$\begin{bmatrix} \sum_{t=1}^m \hat{f}_{1,t}^2 & \sum_{t=1}^m \hat{f}_{1,t} \hat{f}_{2,t} \\ \sum_{t=1}^m \hat{f}_{2,t} \hat{f}_{1,t} & \sum_{t=1}^m \hat{f}_{2,t}^2 \end{bmatrix} \begin{bmatrix} \hat{W}_1 \\ \hat{W}_2 \end{bmatrix} = \begin{bmatrix} \hat{f}_{1,1} & \hat{f}_{1,2} & \dots & \hat{f}_{1,m} \\ \hat{f}_{2,1} & \hat{f}_{2,2} & \dots & \hat{f}_{2,m} \end{bmatrix} \begin{bmatrix} f_1 \\ f_2 \\ \dots \\ f_m \end{bmatrix} \quad (12)$$

بر این اساس، وزن های مربوط به هر مدل را می توان با حل این معادله به صورت زیر به دست آورد:

$$\hat{W} = (\hat{Y}' \hat{Y})^{-1} \hat{Y}' Y \quad (14)$$

بنابراین \hat{W}_{SARIMA} و \hat{W}_{ANFIS} مطابق روابط (۱۵) و (۱۶) به دست می آیند:

روشی که در آن دقت مدل به حداکثر رسیده و یا میانگین مربع خطا حداقل است، محاسبه گردیده است. چندین روش مختلف بهینه سازی ابتکاری و فرا ابتکاری مانند الگوریتم ژنتیک و تکامل دیفرانسیل، در سال های اخیر به منظور بهبود عملکرد پیش بینی ارائه شده است. ولی این روش ها دو مشکل عمده دارند. اولین مشکل این روش ها هزینه بالا و زمان بر بودن مدل سازی و مشکل دوم قرار گرفتن آنها در بهینه های محلی است. به عبارت دیگر، این روش ها یک جواب بهینه محلی مناسبی را نتیجه می دهند ولی جواب بهینه اصلی را تضمین نمی کنند. بنابراین، در این مقاله یک الگوریتم مستقیم دقیق به منظور محاسبه وزن مربوط به اجزای مدل ارائه شده است. به این ترتیب، فرآیند این روش را می توان در چهار مرحله به صورت زیر خلاصه نمود:

مرحله اول: مرحله مدل سازی خطی. در این مرحله از مدل پیشنهادی، ابتدا مدل خودرگرسیون میانگین متحرک انباشته فصلی به منظور مدل سازی ساختارهای خطی موجود در مجموعه داده ها بکار گرفته می شود. نتایجی که از این مرحله به دست می آید همان مقادیر پیش بینی شده ای است که فقط ساختارهای خطی را در نظر گرفته است و به شرح زیر است:

$$\hat{f}_{SARIMA,t} = \sum_{i=1}^p \phi_i y_{t-i} + \sum_{j=1}^p \Phi_{js} y_{t-js} + \sum_{i=1}^p \sum_{j=1}^p \phi_i \Phi_{js} y_{t-i-js} + a_t + \sum_{k=1}^q \theta_k a_{t-k} + \dots \quad (6)$$

$$\dots + \sum_{i=1}^q \Theta_{js} \cdot a_{t-js} + \sum_{k=1}^q \sum_{l=1}^q \theta_l \Theta_{js} a_{t-i-js}$$

$$(t = 1, 2, \dots, m)$$

مرحله دوم: مرحله مدل سازی غیرخطی. در مرحله دوم، از یک شبکه پرسپترون های چندلایه به منظور مدل سازی ساختارهای همبستگی غیرخطی در مجموعه داده ها استفاده می گردد. در این مرحله نیز مقادیر پیش بینی برای زمانی که فقط ساختارهای غیرخطی در مدل سازی مد نظر قرار گرفته، به دست می آید که در رابطه (۷) نشان داده شده است:

$$\hat{f}_{MLP,t} = b_0 + \sum_{j=1}^q w_j \cdot g(b_0 + \sum_{i=1}^p w_{i,j} \cdot y_{t-i} + \sum_{i=1}^p w_{i,j} \cdot y_{t-is}) + \varepsilon_t \quad (7)$$

$$(t = 1, 2, \dots, m)$$

$$\begin{bmatrix} \hat{f}_{SARIMA,2} & \dots & \hat{f}_{SARIMA,m} \\ \hat{f}_{MLP,2} & \dots & \hat{f}_{MLP,m} \end{bmatrix} \begin{bmatrix} f_1 \\ f_2 \\ \dots \\ f_m \end{bmatrix} \quad (11)$$

یا به عبارت دیگر و به فرم ماتریسی معادله فوق الذکر را می توان به صورت زیر بازنویسی نمود:

$$(\hat{Y}' \hat{Y}) \hat{W} = \hat{Y}' Y \quad (13)$$

$$\hat{W}_{SARIMA} = \frac{\left(\sum_{t=1}^m y_t \hat{y}_{SARIMA,t} \right) \left(\sum_{t=1}^m \hat{y}_{MLP,t}^2 \right) - \left(\sum_{t=1}^m y_t \hat{y}_{MLP,t} \right) \left(\sum_{t=1}^m \hat{y}_{SARIMA,t} \hat{y}_{MLP,t} \right)}{\left(\sum_{t=1}^m \hat{y}_{SARIMA,t}^2 \right) \left(\sum_{t=1}^m \hat{y}_{MLP,t}^2 \right) - \left(\sum_{t=1}^m \hat{y}_{SARIMA,t} \hat{y}_{MLP,t} \right)^2} \quad (15)$$

$$\hat{W}_{MLP} = \frac{\left(\sum_{t=1}^m y_t \hat{y}_{MLP,t} \right) \left(\sum_{t=1}^m \hat{y}_{SARIMA,t}^2 \right) - \left(\sum_{t=1}^m y_t \hat{y}_{SARIMA,t} \right) \left(\sum_{t=1}^m \hat{y}_{SARIMA,t} \hat{y}_{MLP,t} \right)}{\left(\sum_{t=1}^m \hat{y}_{SARIMA,t}^2 \right) \left(\sum_{t=1}^m \hat{y}_{MLP,t}^2 \right) - \left(\sum_{t=1}^m \hat{y}_{SARIMA,t} \hat{y}_{MLP,t} \right)^2} \quad (16)$$

یکدیگر جمع می‌گردد. حاصل جمع به دست آمده نتیجه نهایی پیش‌بینی را از مدل ترکیبی بهینه موازی به دست می‌دهد که به شرح معادله (۱۷) است:

مرحله چهارم: مرحله ترکیب. در آخرین مرحله از مدل پیشنهادی، وزنی که در مراحل قبل برای هر یک اجزا (خودرگرسیون میانگین متحرک انباشته فصلی و پرسپترون‌های چندلایه) محاسبه گردید در مقادیر پیش‌بینی شده مربوط به همان جز ضرب شده و نتایج حاصله با

$$\hat{y}_{Com,t} = W_{SARIMA} \hat{y}_{SARIMA,t} + W_{MLP} \hat{y}_{MLP,t} \quad (t = 1, 2, \dots, m)$$

$$\begin{aligned} &= \frac{\left(\sum_{t=1}^m y_t \hat{y}_{SARIMA,t}^2 \right) \left(\sum_{t=1}^m \hat{y}_{MLP,t}^2 \right) - \left(\sum_{t=1}^m y_t \hat{y}_{MLP,t} \right) \left(\sum_{t=1}^m \hat{y}_{SARIMA,t} \hat{y}_{MLP,t} \right)}{\left(\sum_{t=1}^m \hat{y}_{SARIMA,t}^2 \right) \left(\sum_{t=1}^m \hat{y}_{MLP,t}^2 \right) - \left(\sum_{t=1}^m \hat{y}_{SARIMA,t} \hat{y}_{MLP,t} \right)^2} \\ &+ \frac{\left(\sum_{t=1}^m y_t \hat{y}_{MLP,t}^2 \right) \left(\sum_{t=1}^m \hat{y}_{SARIMA,t}^2 \right) - \left(\sum_{t=1}^m y_t \hat{y}_{SARIMA,t} \right) \left(\sum_{t=1}^m \hat{y}_{SARIMA,t} \hat{y}_{MLP,t} \right)}{\left(\sum_{t=1}^m \hat{y}_{SARIMA,t}^2 \right) \left(\sum_{t=1}^m \hat{y}_{MLP,t}^2 \right) - \left(\sum_{t=1}^m \hat{y}_{SARIMA,t} \hat{y}_{MLP,t} \right)^2} \end{aligned} \quad (17)$$

۴- مجموعه داده‌ها

در این مقاله، از داده‌های بار الکتریکی نیو ساوت ولز (NSW) به منظور ارزیابی عملکرد مدل پیشنهادی جمع‌آوری شده است (شکل (۱)). این مجموعه داده‌ها از ۲ مه ۲۰۱۱ تا ۳ ژوئیه ۲۰۱۱ در نیو ساوت ولز جمع‌آوری شده و متشکل از ۳۰۲۴ داده نیم‌ساعتی است. مجموعه داده‌ها به دو زیر مجموعه تقسیم می‌شود: آموزش و آزمون. هشت هفته اول (۲ ماه مه ۲۰۱۱ تا ۲۶ ژوئن ۲۰۱۱)، شامل ۲۶۸۸ مشاهده، به عنوان مجموعه آموزش استفاده می‌شود. هفته آخر (۲۷ ژوئن ۲۰۱۱-۳ ژوئیه ۲۰۱۱)، شامل ۳۳۶ مشاهده، به عنوان مجموعه آزمون استفاده می‌شود. داده‌های بار به صورت نیم ساعتی بوده و از ۰۰:۰۰:۲۳ جمع‌آوری شده است، به این معنی که هر روز دارای ۴۸ مشاهده می‌باشد. در این مقاله سه معیار سنجش: میانگین قدرمطلق خطا (MAE)، جذر میانگین مربعات خطا (RMSE) و همچنین میانگین درصدی قدرمطلق خطا (MAPE) مورد استفاده قرار گرفته‌اند. این معیارها مطابق روابط زیر محاسبه می‌گردد:

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{P_i - A_i}{A_i} \right| \times 100\% \quad (20)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |P_i - A_i| \quad (18)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (P_i - A_i)^2} \quad (19)$$


۵- بررسی عملکرد مدل پیشنهادی در مقایسه با سایر مدل‌ها

در این بخش، عملکرد مدل پیشنهادی با اجزای تشکیل‌دهنده آن (خودرگرسیون میانگین متحرک انباشته فصلی و پرسپترون‌های چندلایه) و مدل ترکیبی موازی براساس الگوریتم ژنتیک و مدل یانگ [۲۴] با استفاده از مجموعه داده‌های نیو ساوت ولز مقایسه شده است. معیارهای آماری میانگین قدرمطلق خطا، جذر میانگین مربعات خطا و میانگین درصدی قدرمطلق خطا مدل‌های فوق‌الذکر برای مجموعه داده‌های آموزش و آزمون در جدول (۱) خلاصه گردیده است. علاوه بر این، درصد بهبود مدل پیشنهادی در مقایسه با سایر مدل‌ها در جدول (۲) گزارش شده است.

نتایج حاصله از اجرای مدل‌ها نشان می‌دهد که نه تنها مدل پیشنهادی به طور قابل توجهی نتایج دقیق‌تر از اجزای آن را به همراه داشته، بلکه نسبت به مدل ترکیبی موازی براساس ژنتیک الگوریتم در تمامی مقادیر خطاها عملکرد بهتری داشته است (جدول (۲)). به عنوان مثال، میزان درصد بهبود مدل پیشنهادی در مقایسه با مدل ترکیبی موازی براساس ژنتیک الگوریتم که دارای نزدیک‌ترین دقت عملکرد به مدل

مدل ترکیبی پیشنهادی در مقایسه با برخی مدل‌ها شکست خورده ولی در عین حال نتایج منفی در جدول بهبود، نشان‌دهنده قدرت تعمیم بالای مدل است که در داده‌های آزمون مشاهده می‌شود.

پیشنهادی است، با استفاده از معیارهای عملکردی میانگین قدرمطلق خطا، میانگین درصدی قدرمطلق خطا و جذر میانگین مربعات خطا به ترتیب ۱۰/۸۸٪، ۱۰/۴۵٪ و ۲۲/۷۳٪، برای داده‌های آزمون است. همچنین در جدول (۲) ستون مربوط به آموزش نشان می‌دهد که



شکل (۱): داده‌های بار الکتریکی نیو ساوت ولز.
Fig. (1): the New South Wales (NSW) data sets

Table (1): Forecasting performance of the proposed model against other those models in train and test data sets.

جدول (۱): معیارهای عملکردی مدل پیشنهادی در مقایسه با سایر روش‌ها در مجموعه‌های آموزش و آزمون

جذر میانگین مربعات خطا		میانگین درصدی قدرمطلق خطا		میانگین قدرمطلق خطا		مدل
آزمون	آموزش	آزمون	آموزش	آزمون	آموزش	
۱۹۹/۳۱	۲۱۰/۲۹	٪۱/۶۵	٪۱/۹۰	۱۵۹/۵۳	۱۶۹/۸۱	یانگ
۱۶۲/۸۱	۱۴۹/۲۴	٪۰/۹۷۱	٪۱/۱۶۷	۸۶/۷۶	۱۰۹/۷۶	خودرگرسیون میانگین متحرک انباشته فصلی
۱۱۹/۲۹	۱۱۸/۹۵	٪۰/۹۱۹	٪۰/۹۲۴	۸۶/۶۵	۸۷/۴۴	شبکه‌های عصبی مصنوعی
۱۱۵/۶۹	۱۱۷/۹۴	٪۰/۸۸۵	٪۰/۹۰۳	۸۳/۶۸	۸۵/۲۶	سیستم‌های تطبیقی فازی-عصبی
۱۰۳/۴۹	۱۱۶/۶۵	٪۰/۷۶۱	٪۰/۹۰۱	۷۱/۲۲	۸۴/۹۴	مدل ترکیبی ژنتیک-الگوریتم
۸۴/۳۲	۱۱۸/۹۵	٪۰/۶۸۹	٪۰/۹۲۴	۶۴/۲۳	۸۷/۴۴	مدل ترکیبی پیشنهادی

به ترتیب ۵۳/۱۰، ۰/۶۰٪ و ۷۲/۸۲ به دست آمده است. عملکرد مدل ترکیبی برای روز چهارشنبه نسبت به سایر روزهای هفته ضعیف‌تر بوده و معیارهای عملکردی میانگین قدرمطلق خطا، میانگین درصدی قدرمطلق خطا و جذر میانگین مربعات خطا برای روز چهارشنبه به ترتیب ۶۹/۶۴، ۰/۷۲٪ و ۹۰/۲۳ است.

همچنین معیارهای عملکردی مدل ترکیبی پیشنهادی به تفکیک روزهای هفته برای داده‌های آزمون در جدول (۳) آورده شده است. نتایج نشان می‌دهد که بهترین عملکرد مدل پیشنهادی مربوط به روز شنبه بوده و معیارهای عملکردی میانگین قدرمطلق خطا، میانگین درصدی قدرمطلق خطا و جذر میانگین مربعات خطا برای این روز

Table (2): Improvement percentages of the proposed model against other those models in train and test data sets.

جدول (۲): میزان درصد بهبود مدل پیشنهادی در مقایسه با سایر روش‌ها در مجموعه‌های آموزش و آزمون.

میزان بهبود (٪)						مدل
جذر میانگین مربعات خطا		میانگین درصدی قدرمطلق خطا		میانگین قدرمطلق خطا		
آزمون	آموزش	آزمون	آموزش	آزمون	آموزش	
٪۱۳۶/۴	٪۷۶/۷۸	۱۳۹/۵	٪۱۰۵/۶	٪۱۴۸/۴	٪۹۴/۲۰	یانگ
٪۹۳/۰۹	٪۲۵/۴۶	٪۴۰/۹۳	٪۲۶/۳۰	٪۳۵/۰۸	٪۲۵/۵۳	خودرگرسیون میانگین متحرک انباشته فصلی
٪۴۱/۴۷	٪۰/۰۰	٪۳۳/۳۸	٪۰/۰۰	٪۳۴/۹۱	٪۰/۰۰	شبکه‌های عصبی مصنوعی
٪۳۷/۲۰	٪-۰/۸۵	٪۲۸/۴۸	٪-۲/۲۷	٪۳۰/۲۸	٪-۲/۴۹	سیستم‌های تطبیقی فازی-عصبی
٪۲۲/۷۳	٪-۱/۹۳	٪۱۰/۴۵	٪-۲/۴۹	٪۱۰/۸۸	٪-۲/۸۵	مدل ترکیبی الگوریتم ژنتیک

Table (3): Results of the proposed model in whole test week.
جدول (۳): معیارهای عملکردی مدل پیشنهادی به تفکیک روزهای هفته (داده‌های آزمون)

معیار سنجش	شنبه	یکشنبه	دوشنبه	سه‌شنبه	چهارشنبه	پنج‌شنبه	جمعه	کل هفته
میانگین قدرمطلق خطا	۵۳/۱۰	۷۰/۸۱	۶۲/۶۶	۷۲/۰۸	۶۹/۶۴	۵۹/۹۵	۶۱/۳۶	۶۴/۲۳
میانگین درصدی قدرمطلق خطا	٪۰/۶۰	٪۰/۸۳	٪۰/۶۶	٪۰/۷۴	٪۰/۷۲	٪۰/۶۳	٪۰/۶۵	٪۰/۶۹
جذر میانگین مربعات خطا	۷۲/۸۲	۹۶/۵۶	۸۶/۰۲	۸۸/۸۰	۹۰/۲۳	۷۶/۸۰	۷۸/۹۹	۸۴/۳۲

Table (4): Mean Absolute Error (MAE) of the proposed model against its components in whole test week.
جدول (۴): میانگین قدرمطلق خطای روش پیشنهادی و مدل‌های تشکیل‌دهنده آن برای داده‌های آزمون.

مدل	شنبه	یکشنبه	دوشنبه	سه‌شنبه	چهارشنبه	پنج‌شنبه	جمعه	کل هفته
خودرگرسیون میانگین متحرک انباشته فصلی	۶۶/۸۷	۸۴/۲۵	۸۴/۶۷	۹۲/۹۵	۹۴/۲۵	۹۶/۸۳	۸۷/۴۷	۸۶/۷۶
پرسپترون‌های چندلایه	۱۰۳/۸۳	۱۰۵/۱۱	۹۲/۳۳	۹۲/۰۷	۷۰/۶۹	۷۱/۷۵	۷۰/۷۳	۸۶/۶۵
مدل ترکیبی پیشنهادی	۵۳/۱۰	۷۰/۸۱	۶۲/۶۶	۷۲/۰۸	۶۹/۶۴	۵۹/۹۵	۶۱/۳۶	۶۴/۲۳

روش‌های پیش‌بینی و مدل‌سازی‌های نوین در این حوزه‌ها امکان‌پذیر می‌باشد. پیش‌بینی بار الکتریکی یکی از حوزه‌های مورد مطالعه و توجه در سال‌های اخیر می‌باشد. توجه به این کالا بدین خاطر است که تولید و توزیع آن باید همزمان صورت گیرد؛ چرا که الکتریسیته قابلیت ذخیره‌سازی ندارد. همین امر سبب ایجاد سطح بالایی از پیچیدگی‌ها گردیده و اهمیت و حساسیت دقت پیش‌بینی را بالا می‌برد.

در این مقاله، به منظور بالا بردن دقت پیش‌بینی‌ها یک روش ترکیبی کارا ارائه شده است که در آن به منظور وزن‌دهی به مدل‌های ترکیبی یک روش بهینه با هزینه محاسباتی بسیار کم ارائه شده است. همچنین مدل ترکیبی پیشنهادی توانایی مدل‌سازی همزمان ساختارهای خطی و غیرخطی و همچنین الگوهای فصلی موجود در داده‌ها را نیز دارد. ایده روش پیشنهادی ترکیب مدل‌های خطی خودرگرسیون میانگین متحرک انباشته فصلی با مدل‌های غیرخطی پرسپترون‌های چندلایه غیرفصلی به‌طور موازی به منظور بهره‌گیری از مزایای منحصر به فرد هر یک از این مدل‌ها می‌باشد. مدل ارائه شده با توجه به از یک الگوریتم وزن‌دهی بهینه استفاده می‌نماید و همچنین اینکه تمامی الگوها و ساختارهای (خطی/غیرخطی) موجود در مجموعه داده‌ها را مدل‌سازی می‌کند، نتایجی را که به دست می‌دهد دقیق‌تر از سایر روش‌ها بوده است. همچنین روش معرفی شده وزن‌دهی در ترکیب موازی ریسک کمتری را به دنبال داشته است. هزینه محاسباتی با بکارگیری روش ترکیبی بهینه موازی به‌وضوح از روش‌هایی که از الگوریتم‌های فراابتکاری برای وزن‌دهی استفاده می‌نمایند، پایین‌تر می‌باشد.

همچنین برای بهتر نشان دادن عملکرد مدل پیشنهادی و دقت پیش‌بینی مدل، مقادیر پیش‌بینی شده در مقابل مقادیر واقعی به تفکیک روزهای هفته برای مجموعه داده‌های آزمون در شکل (۲) نمایش داده شده است. این نمودار نشان می‌دهد که مدل ترکیبی ارائه شده دارای دقت بالایی می‌باشد. پیش‌بینی‌های صورت گرفته با استفاده از مدل ترکیبی ارائه شده نشان می‌دهد که مقادیر به دست آمده به مقادیر واقعی بسیار نزدیک است.

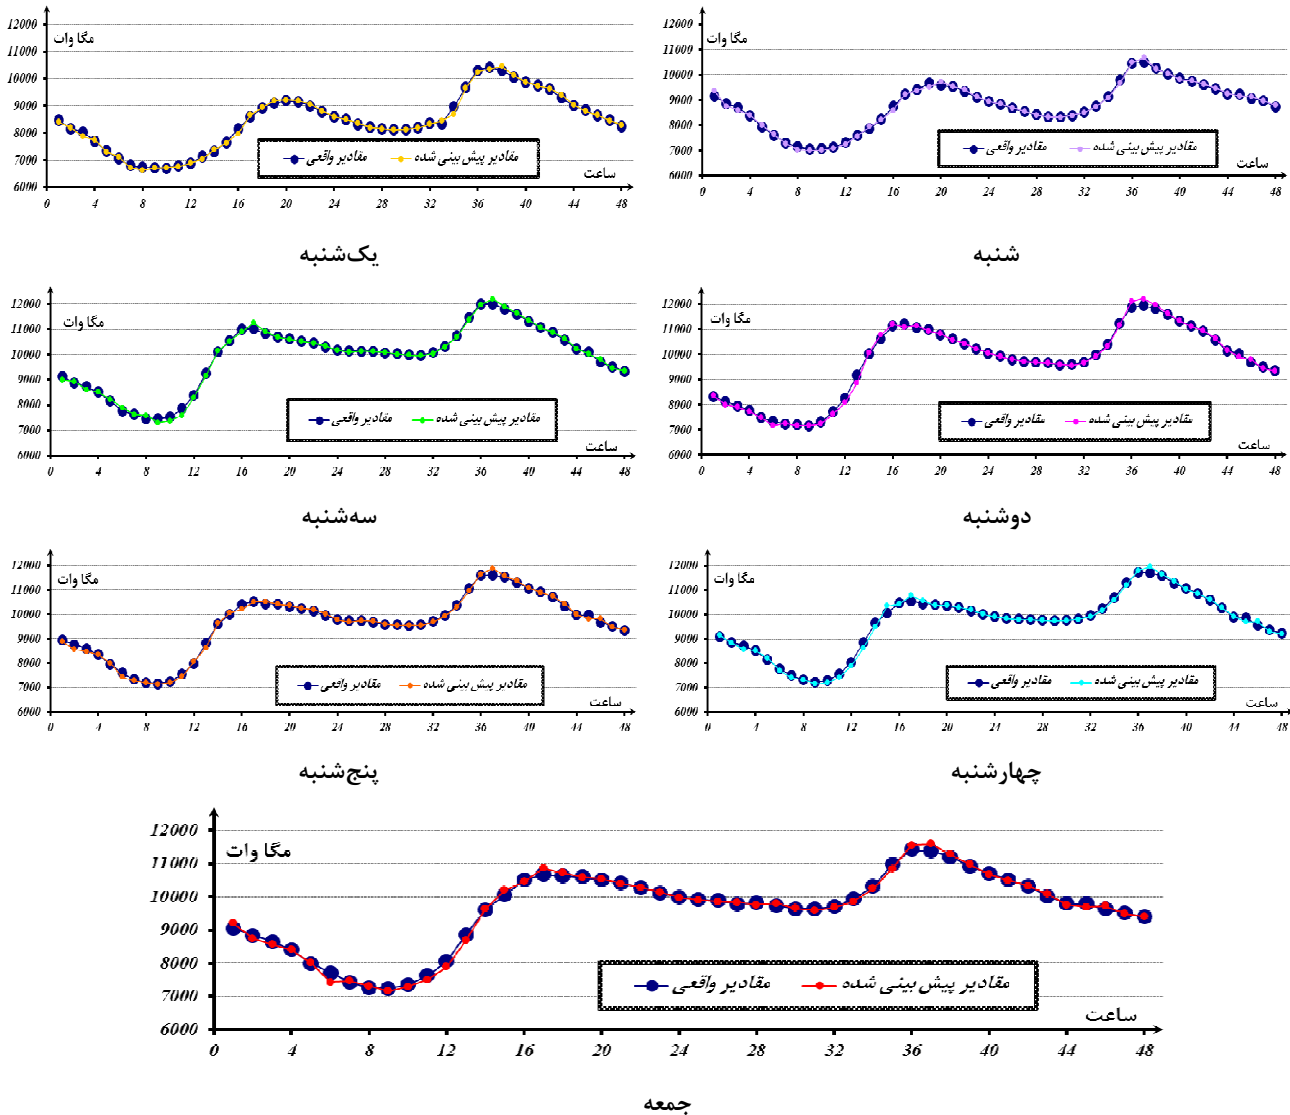
در جدول‌های (۴) الی (۶) عملکرد مدل پیشنهادی و مدل‌های خودرگرسیون میانگین متحرک انباشته فصلی (SARIMA) و پرسپترون‌های چندلایه (MLP) با یکدیگر مقایسه گردیده است. همان‌گونه که در بخش‌های پیشین گفته شد، معیارهای برتری مدل‌ها بر یکدیگر هرچه کمتر بودن میانگین قدرمطلق خطا (MAE)، جذر میانگین مربعات خطا (RMSE) و میانگین درصدی قدرمطلق خطا (MAPE) برای هر یک از مدل‌ها می‌باشد. نتایج گزارش شده در جدول‌های (۴) الی (۶) نتایج را به تفکیک روزهای هفته محاسبه کرده است. نتایج حاصله برتری مدل پیشنهادی را نسبت به سایر مدل‌ها نشان می‌دهد. همچنین بهترین دقت به دست آمده مربوط به روز شنبه بوده است.

۵- نتیجه‌گیری

برنامه‌ریزی و تصمیم‌گیری مناسب و در نهایت پیش‌بینی‌های دقیق در حوزه‌های مختلف یک راه‌حل مفید برای صرفه‌جویی در اقتصاد، زمان و منابع انرژی یک کشور می‌باشد. رسیدن به این اهداف با بهبود

Table (5): Mean Absolute Percentage Error (MAPE) of the proposed model against its components in whole test week.
جدول (۵): میانگین درصدی قدرمطلق خطای روش پیشنهادی و مدل‌های تشکیل‌دهنده آن برای داده‌های آزمون.

معیار سنجش	شنبه	یکشنبه	دوشنبه	سه‌شنبه	چهارشنبه	پنج‌شنبه	جمعه	کل هفته
خودرگرسیون میانگین متحرک انباشته فصلی	٪۰/۷۶	٪۰/۵۹	٪۰/۸۹	٪۰/۰۲	٪۰/۱۰۶	٪۰/۱۰۷	٪۰/۱۰۳	٪۰/۹۷
پرسپترون‌های چندلایه	٪۰/۱۱۴	٪۰/۱۲۳	٪۰/۹۵	٪۰/۹۲/۰	٪۰/۷۲/۰	٪۰/۷۴/۰	٪۰/۷۴/۰	٪۰/۹۲/۰
مدل ترکیبی پیشنهادی	٪۰/۶۰	٪۰/۸۳	٪۰/۶۶	٪۰/۷۴	٪۰/۷۲	٪۰/۶۳	٪۰/۶۵	٪۰/۶۹



شکل (۲): مقادیر واقعی و پیش‌بینی‌شده توسط مدل ترکیبی پیشنهادی به تفکیک روزهای هفته (داده‌های آزمون)
 Fig. (2): Actual and forecasted values of the proposed model for each day of the test week.

Table (6): Root Mean Square Error (RMSE) of the proposed model against its components in whole test week.

جدول (۶): جذر میانگین مربعات خطای روش پیشنهادی و مدل‌های تشکیل‌دهنده آن برای داده‌های آزمون.

معیار سنجش	شنبه	یکشنبه	دوشنبه	سه‌شنبه	چهارشنبه	پنجشنبه	جمعه	کل هفته
خودرگرسیون میانگین متحرک انباشته فصلی	۱۰۷/۹۷	۱۸۱/۴۶	۱۶۹/۷۹	۱۴۴/۵۴	۱۶۷/۲۶	۱۸۴/۱۹	۱۷۱/۳۰	۱۶۰/۹۳
پرسپترون‌های چندلایه	۱۴۵/۳۴	۱۴۲/۵۵	۱۳۶/۴۲	۱۱۶/۹۴	۹۵/۶۳	۹۳/۴۳	۸۹/۵۰	۱۱۷/۱۲
مدل ترکیبی پیشنهادی	۷۲/۸۲	۹۶/۵۶	۸۶/۰۲	۸۸/۸۰	۹۰/۲۳	۷۶/۸۰	۷۸/۹۹	۸۴/۳۲

References

- [1] R. Weron, A. Misiorek, "Forecasting spot electricity prices: a comparison of parametric and semiparametric time series models", International Journal of Forecasting, Vol. 24, No. 4, pp. 744–763, Oct./Dec. 2008 (doi: 10.1016/j.ijforecast.2008.08.004).
- [2] S. Saab, E. Badr, G. Nasr, "Univariate modeling and forecasting of energy consumption: the case of electricity in Lebanon", Energy, No. 26, No. 1, pp. 1–14, Jan. 2001 (doi: 10.1016/S0360-5442(00)00049-9).
- [3] J. H. Park, Y. M. Park, K. Y. Lee, "Composite modeling for adaptive short-term load forecasting", IEEE Trans. on Power Systems, Vol. 6, No. 2, pp. 450–457, May 1991 (doi: 10.1109/59.76686).
- [4] D. W. Bunn, E. D. Farmer, "Comparative models for electrical load forecasting", John Wiley & Sons, New York, 1985.
- [5] J. W. Taylor, R. Buizza, "Using weather ensemble predictions in electricity demand forecasting", International Journal of Forecasting, No. 19, No. 1, pp. 57–70, Jan./March 2003 (doi: 10.1016/S0169-2070(01)00123-6).
- [6] D. Singhal, K. S. Swarup, "Electricity price forecasting using artificial neural networks", International Journal of Electrical Power and Energy Systems, Vol. 33, No. 3, pp. 550–555, March 2011 (doi: 10.1016/j.ijepes.2010.12.009).

- [7] B. Novak, "Superfast autoconfiguring artificial neural networks and their application to power systems", *Electric Power Systems Research*, Vol. 35, No. 1, pp. 11–16, Oct. 1995 (doi: 10.1016/0378-7796(95)00980-9).
- [8] A. M. Al-Kandari, S. A. Soliman, M. E. El-Hawary, "Fuzzy short-term electric load forecasting", *International Journal of Electrical Power & Energy Systems*, Vol. 26, No. 2, pp. 111–122, 2004 (doi: 10.1016/S0142-0615(03)00069-3).
- [9] J. P. Choudhury, B. Sarker, S. K. Mukherjee, "Forecasting of engineering manpower through fuzzy associative memory neural network with ARIMA: A comparative study", *Neuro Computing*, Vol. 47, pp. 241-257, Aug. 2002 (doi: 10.1016/S0925-2312(01)00590-2).
- [10] P. Box, G. M. Jenkins, "Time series analysis: forecasting and control", Holden-day Inc, San Francisco, CA, 1976.
- [11] M. Khashei, M. Bijari, "A novel hybridization of artificial neural networks and ARIMA models for time series forecasting", *Applied Soft Computing*, Vol. 11, No. 2, pp. 2664–2675, March 2011 (doi: 10.1016/j.asoc.2010.10.015).
- [12] A. Camara W. Feixing L. Xiuqin, "Energy consumption forecasting using seasonal ARIMA with artificial neural networks models", *International Journal of Business and Management*, Vol. 11, No. 5, April 2016 (doi: 10.5539/ijbm.v11n5p231).
- [13] N. Mohamed, M. H. Ahmad, Z. Ismail, "Short term load forecasting using double seasonal ARIMA model", *Proceeding of the Regional Conference on Statistical Sciences*, Vol. 10, pp. 57-73, 2010.
- [14] L. J. Soares, M. C. Medeiros, "Modeling and forecasting short-term electricity load: A comparison of methods with an application to Brazilian data", *International Journal of Forecasting*, Vol. 24, No. 4, pp. 630-44, Oct./Dec. 2008 (doi: 10.1016/j.ijforecast.2008.08.003).
- [15] M. Niu, S. Sun, J. Wu, L. Yu, J. Wang, "An innovative integrated model using the singular spectrum analysis and nonlinear multi-layer perceptron network optimized by hybrid intelligent algorithm for short-term load forecasting", *Applied Mathematical Modelling*, Vol. 40, No. 5-6, pp. 4079-4093, March 2016 (doi: 10.1016/j.apm.2015.11.030).
- [16] S. Kouhi, F. Keynia, "A new cascade NN based method to short-term load forecast in deregulated electricity market", *Energy Conversion and Management*, Vol. 71, pp. 76-83, July 2013 (doi: 10.1016/j.enconman.2013.03.014).
- [17] H. Nie, G. Liu, X. Liu, Y. Wang, "Hybrid of ARIMA and SVMs for short-term load forecasting", *Energy Procedia*, Vol. 16, pp. 1455-1460, 2012 (doi: 10.1016/j.egypro.2012.01.229).
- [18] Y. Hu, J. Li, M. Hong, J. Ren, R. Lin, Y. Liu, M. Liu, Y. Man, "Short term electric load forecasting model and its verification for process industrial enterprises based on hybrid GA-PSO-BPNN algorithm—A case study of papermaking process", *Energy*, Vol. 170, pp. 1215-1227, March 2019 (doi: 10.1016/j.energy.2018.12.208).
- [19] J. Zhang, Y. M. Wei, D. Li, Z. Tan, J. Zhou, "Short term electricity load forecasting using a hybrid model", *Energy*, Vol. 158, pp 774-781, Sept. 2018 (doi: 10.1016/j.energy.2018.06.012).
- [20] W. Hong, G. Fan, "Hybrid empirical mode decomposition with support vector regression model for short term load forecasting", *Energies*, Vol. 12, No. 6, pp. 1-16, 2019.
- [21] Z. Wu, X. Zhao, Y. Ma, X. Zhao, "A hybrid model based on modified multi-objective cuckoo search algorithm for short-term load forecasting", *Applied Energy*, Vol. 237, pp. 896-909 (doi: 10.1016/j.apenergy.2019.01.046).
- [22] L. Xiao, W. Shao, M. Yu, J. Ma, C. Jin, "Research and application of a hybrid wavelet neural network model with the improved cuckoo search algorithm for electrical power system forecasting", *Applied Energy*, Vol. 198, pp. 203-222, July 2017 (doi: 10.1016/j.apenergy.2017.04.039).
- [23] H.J. Sadaei, P.C. L. Silva, F.G. Guimarães, M.H. Lee, "Short-term load forecasting by using a combined method of convolutional neural networks and fuzzy time series", *Energy*, Vol. 175, pp. 365-377, May 2019 (doi: 10.1016/j.energy.2019.03.081).
- [24] Y. Yang, Y. Chen, Y. Wang, C. Li, L. Li, "Modelling a combined method based on ANFIS and neural network improved by DE algorithm: A case study for short-term electricity demand forecasting", *Applied Soft Computing*, Vol. 49, pp. 663-675 Dec. 2016 (doi: 10.1016/j.asoc.2016.07.053).
- [25] T. Minerva, I. Poli, "Building ARMA models with genetic algorithms", *Lecture Notes in Computer Science.*, 2037, pp. 335–342, 2001 (doi: 10.1007/3-540-45365-2-35).
- [26] M. Haseyama, H. Kitajima, "An ARMA order selection method with fuzzy reasoning", *Signal Processing*, Vol. 81, No. 6, pp. 1331–1335, June 2001 (doi: 10.1016/S0165-1684(01)00051-2).
- [27] K. Smith, N. Gupta, D. Jatinder, "Neural networks in business: techniques and applications for the operations researcher", *Computers and Operations Research*, No. 27, No. 11-12, pp.1045-1076, Sept. 2000 (doi: 10.1016/S0305-0548(99)00141-0).
- [28] H.B. Hwarng, H. T. Ang, "A simple neural network for ARMA (p; q) time series", *Omega*. No. 29, PP. 319–333, 2001.
- [29] H. Demuth, B. Beale, *Neural Network Toolbox User Guide*, The Mathworks Inc, Natick. 2004.
- [30] S. Thawornwong, D. Enke, "The adaptive selection of financial and economic variables for use with artificial neural networks", *Neurocomputing*, Vol. 56, pp.205-232, Jan. 2004 (doi: 10.1016/j.neucom.2003.05.001).
- [31] G. Nasr, E.A. Badr, C. Joun, "Back propagation neural networks for modeling gasoline consumption", *Energy Conversion and Management*, No. 44, No. 6, pp. 893–905, April 2003 (doi: 10.1016/S0196-8904(02)00087-0).