

پیش‌بینی بار الکتریکی با به‌کارگیری مدل‌های ترکیبی سیستم‌های فازی-عصبی و خودرگرسیون میانگین متحرک انباشته فصلی

مهدی خاشعی* و فاطمه چاهکوتاهی

دانشکده مهندسی صنایع و سیستم‌ها، دانشگاه صنعتی اصفهان، اصفهان

(دریافت مقاله: ۱۳۹۶/۵/۸ - دریافت نسخه نهایی: ۱۳۹۷/۸/۲۸)

چکیده - امروزه پیش‌بینی تقاضای الکتریسیته به‌عنوان یکی از مهم‌ترین حوزه‌های پیش‌بینی، نقشی اساسی در فرایند تصمیم‌گیری‌های اقتصادی دارد. آنچه که الکتریسیته را از سایر کالاها متمایز می‌سازد عدم امکان ذخیره‌سازی آن در مقیاس وسیع، هزینه‌بر و زمان‌بر بودن ساخت نیروگاه‌های جدید تولید و توزیع برق است. همچنین وجود روند نوسانی و غیرخطی و همچنین ابهام و پیچیدگی در داده‌های الکتریسیته موجب شده که استفاده از مدل‌های معمول پیش‌بینی تقاضای الکتریسیته کارآمد نباشند. لذا ارائه مدل‌های جدید با استفاده از ابزارهای هوش محاسباتی و محاسبات نرم و ترکیب مدل‌ها از جمله دقیق‌ترین و پرکاربردترین روش‌های حال حاضر به‌منظور مدل‌سازی پیچیدگی و عدم قطعیت موجود در داده‌ها هستند. لذا در این مقاله یک مدل ترکیبی بهینه موازی با استفاده از ابزارهای هوش محاسباتی و محاسبات نرم، به‌منظور پیش‌بینی بار الکتریکی ارائه می‌شود. روش ترکیبی ارائه شده در این مقاله بر اساس روش‌های خودرگرسیون میانگین متحرک انباشته فصلی و سیستم‌های استنتاج فازی-عصبی است. ایده اصلی ارائه روش‌های ترکیبی، استفاده همزمان از مزایای مدل‌های تکی در مدل‌سازی سیستم‌های پیچیده در یک ساختار و همچنین غلبه بر محدودیت‌های مدل‌های تکی است. نتایج حاصل نشان می‌دهد که روش ترکیبی پیشنهادی عملکرد ضعیف‌تری نسبت به سایر روش‌های ترکیبی تکراری شبه بهینه نداشته و همچنین هزینه محاسباتی آن کمتر از این گونه از روش‌ها دارد. علاوه بر این، روش پیشنهادی توانسته است نتایج دقیق‌تری در مقایسه با مدل‌های تشکیل‌دهنده خود و همچنین برخی از روش‌های ترکیبی فصلی به‌دست آورد.

واژه‌های کلیدی: ابزارهای هوش محاسباتی و محاسبات نرم، پیش‌بینی سری‌های زمانی فصلی، بار الکتریکی، سیستم‌های استنتاج فازی-عصبی (ANFIS)، خودرگرسیون میانگین متحرک انباشته فصلی (SARIMA).

Electricity Load Forecasting by Combining Adaptive Neuro-fuzzy Inference System and Seasonal Auto-Regressive Integrated Moving Average

M. Khashei* and F. Chahkoutahi

Department of Industrial and Systems Engineering, Isfahan University of Technology, Isfahan, Iran

Abstract: Nowadays, electricity load forecasting, as one of the most important areas, plays a crucial role in the economic

*: مسئول مکاتبات، پست الکترونیکی: khashei@cc.iut.ac.ir

process. What separates electricity from other commodities is the impossibility of storing it on a large scale and cost-effective construction of new power generation and distribution plants. Also, the existence of seasonality, nonlinear complexity, and ambiguity pattern in electricity data set makes it more difficult to forecast by using the traditional methods. Therefore, new models, computational intelligence and soft computing tools and combining models are the most accurate and widely used methods for modeling the complexity and uncertainty in the data set. In this paper, a parallel optimal hybrid model using computational intelligence tools and soft computations is proposed to forecast the electricity load forecasting. The main idea of this model is the use of the advantages of the individual models in the modeling of complex systems in a structure and elimination of the limitations of them, simultaneously. The experimental results indicate that the proposed hybrid model has a higher performance accuracy in comparison to iterative suboptimal hybrid models and its computational cost is lower than the other hybrid models; also, the proposed model can achieve more accurate results, as compared with its component and some other seasonal hybrid models.

Keywords: Computational Intelligence and Soft Computing Tools, Seasonal Time Series Forecasting, electricity load, Adaptive neuro-Fuzzy Inference System (ANFIS), Seasonal Auto-Regressive Integrated Moving Average models (SARIMA).

فهرست علائم

قوه اشتعال نرمال شده (معادله ۳)	\bar{w}_i	خطای تصادفی (رابطه ۲)	a_t
برآورد وزن مدل خودرگرسیون میانگین متحرک انباشته فصلی (رابطه ۵)	\hat{W}_{SARIMA}	تعداد داده‌ها (رابطه ۱)	m
برآورد وزن مدل سیستم استنتاج فازی-عصبی (رابطه ۵)	\hat{W}_{ANFIS}	تعداد اجزای مورد استفاده در ساختار مدل ترکیبی (رابطه ۱)	n
مقادیر مشاهده شده (رابطه ۲)	y_t	مرتب خودرگرسیون غیرفصلی (رابطه ۲)	p
مقدار پیش‌بینی شده مدل ترکیبی (رابطه ۱)	$\hat{Y}_{Com,t}$ ($t = 1, 2, \dots, m$)	مرتب خودرگرسیون فصلی (رابطه ۲)	P
مقدار پیش‌بینی شده آمین جزء (رابطه ۱)	$\hat{Y}_{i,t}$ ($i = 1, 2, \dots, n$) ($t = 1, 2, \dots, m$)	مرتب میانگین متحرک غیرفصلی (رابطه ۲)	q
پارامتر مدل میانگین متحرک غیرفصلی (رابطه ۲)	θ	مرتب میانگین متحرک فصلی (رابطه ۲)	Q
پارامتر مدل میانگین متحرک فصلی (رابطه ۲)	Θ	تعداد دوره‌ها (رابطه ۲)	s
پارامتر مدل خودرگرسیون غیرفصلی (رابطه ۲)	ϕ	مجموع مربع باقی‌مانده‌ها (رابطه ۵)	$\sum_{t=1}^m \hat{u}_t^2$
پارامتر مدل خودرگرسیون (رابطه ۲)	Φ	وزن مربوط به آمین جزء (رابطه ۱)	W_i ($i = 1, 2, \dots, n$)

۱- مقدمه

دقت پیش‌بینی‌ها برای بازارهای انرژی حائز اهمیت بوده است. بنابراین مدل‌های دقیق برای پیش‌بینی بار الکتریکی به‌ویژه برای عملیات و برنامه‌ریزی شرکت‌های برق ضروری بوده و مورد توجه مدیران بخش‌های مالی و عملیاتی نیروگاه‌های تولید و توزیع الکتریسیته قرار گرفته است. همین امر پژوهشگران را ترغیب به ارائه روش‌های دقیق به‌منظور پیش‌بینی بار الکتریکی کرده است. مطالعاتی

پیش‌بینی بار الکتریکی به‌منظور برنامه‌ریزی، جلوگیری از اتلاف زمان و هزینه‌ها امری ضروری است. افزایش خطای پیش‌بینی بار الکتریکی می‌تواند منجر به افزایش چشمگیر هزینه‌های عملیاتی شده و باعث اتلاف زمان و انرژی شود. با توجه به تأثیر پیش‌بینی‌های بار الکتریکی در برنامه‌ریزی، تصمیم‌گیری، اعمال سیاست‌ها و هزینه‌ها

که تاکنون انجام شده با استفاده از روش‌هایی چون سری‌های زمانی [۳-۱]، مدل‌های رگرسیونی [۴ و ۵]، تکنیک‌های هوش مصنوعی [۶ و ۷] و منطق فازی [۸] بوده است. این روش‌ها به منظور افزایش دقت مدل‌های پیش‌بینی موجود و یا ارائه مدل‌های ترکیبی [۹] مورد استفاده قرار گرفته است.

در ادبیات موضوع روش‌های آماری کلاسیک زیادی برای پیش‌بینی سری‌های زمانی فصلی، به خصوص 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 بوکس-جنکینز [۱۰] تا به امروز، این گونه از مدل‌ها در مقالات بسیاری به منظور بهبود دقت روش‌های موجود و یا ارائه روش‌های ترکیبی جدید [۱۱] به منظور پیش‌بینی استفاده شده‌اند. کامارا و همکاران [۱۲] از مدل خودرگرسیون میانگین متحرک انباشته فصلی به منظور پیش‌بینی مصرف انرژی استفاده کرده‌اند. نتایج حاصل عملکرد قابل قبولی داشته است. نوریزان و همکاران [۱۳] برای پیش‌بینی بار کوتاه‌مدت روش خودرگرسیون میانگین متحرک انباشته فصلی را ارائه کرده‌اند. همچنین سوارز و مدریوس [۱۴] روش خودرگرسیون میانگین متحرک انباشته فصلی را برای پیش‌بینی کوتاه‌مدت بار الکتریکی پیشنهاد کرده‌اند. محدودیت اصلی این گونه از روش‌ها این است که مقدار آینده یک متغیر به صورت تابع خطی از چند مشاهده گذشته و خطاهای تصادفی فرض می‌شود. همچنین این گونه از روش‌ها نیازمند داده‌های زیادی به منظور حصول نتایج مطلوب هستند. 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 به منظور تجزیه و تحلیل مسائل در شرایط نامطمئن، با حجم اطلاعاتی بالا و روابط پیچیده احساس می‌شود. مدل‌های متعددی در ادبیات موضوع برای غلبه بر این محدودیت‌ها ارائه شده است. نتایج به دست آمده از شواهد علمی و عملی نشانگر آن است که ادغام و ترکیب مدل‌های

روش‌های عددی در مهندسی، سال ۳۸، شماره ۱، تابستان ۱۳۹۸

مختلف می‌تواند یک روش مؤثر برای غلبه بر محدودیت‌های مدل‌های تکی و همچنین بهبود دقت پیش‌بینی‌ها باشند. به تازگی مدل‌های ترکیبی بسیاری در ادبیات موضوع روش‌های پیش‌بینی ارائه شده است. هدف اصلی از ترکیب مدل‌های مختلف، استفاده همزمان از مزایای مدل‌های تک است.

بدین منظور پژوهشگران بسیاری مدل‌های ترکیبی زیادی از ترکیب مدل‌های مختلف با هم برای پیش‌بینی بار الکتریکی ارائه کرده‌اند. یاسلان و بیجان [۱۵] یک روش که بر اساس رگرسیون بردار پشتیبان است، به منظور پیش‌بینی پیشنهاد کرده‌اند. نتایج تجربی نشان می‌دهد که عملکرد مدل پیشنهادی بهتر از روش‌های شبکه‌های عصبی مصنوعی و مدل‌های رگرسیونی بوده است. هو و همکاران [۱۶] از یک روش ترکیبی بر اساس روش‌های شبکه عصبی رگرسیونی و الگوریتم بهینه‌سازی مگس میوه، به منظور پیش‌بینی بار الکتریکی ارائه کرده‌اند. اولادگوک و همکاران [۱۷] با استفاده از روش شبکه عصبی و الگوریتم ژنتیک پیش‌بینی را برای بار الکتریکی انجام داده‌اند. نی و همکاران [۱۸] از ترکیب روش‌های خودرگرسیون میانگین متحرک انباشته و ماشین‌های بردار پشتیبان برای پیش‌بینی کوتاه‌مدت بار الکتریکی استفاده کرده‌اند.

در این مقاله، یک مدل جدید ترکیبی بهینه موازی، بر اساس مدل‌های سیستم استنتاج فازی-عصبی، و خودرگرسیون میانگین متحرک انباشته فصلی به منظور پیش‌بینی بار الکتریکی ارائه شده است. ایده اصلی این مدل غلبه بر محدودیت‌های مدل‌های تشکیل‌دهنده آن و استفاده همزمان از مزایای این مدل‌ها در مدل‌سازی سیستم‌های پیچیده و مبهم برای پیش‌بینی سری‌های زمانی فصلی است. مدل ارائه شده شامل چهار مرحله: (۱) مرحله مدل‌سازی قطعی و خطی، (۲) مرحله مدل‌سازی فازی، (۳) مرحله وزن‌دهی و (۴) مرحله ترکیب است. در دو مرحله اول دو مدل سیستم استنتاج فازی-عصبی و خودرگرسیون میانگین متحرک انباشته فصلی به صورت جداگانه مدل‌سازی می‌شوند. سپس اهمیت نسبی (وزن) هر مدل توسط روش پیشنهادی محاسبه می‌شود. در نهایت، مقادیر پیش‌بینی

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 غیر کمتر از سایر مدل های ترکیبی موازی انجام می دهد. سایر قسمت های این مقاله بدین صورت است: در قسمت دوم، فرمول سازی مدل ترکیبی پیشنهادی ارائه شده است. در قسمت سوم، معیارهای آماری برای مقایسه مدل ها به کار گرفته شده است و در نهایت نیز نتایج حاصل مورد بررسی و تجزیه و تحلیل قرار گرفته اند.

۲- مدل ترکیبی پیشنهادی

در سال های اخیر، مدل های سری زمانی ترکیبی متعددی در ادبیات موضوع به منظور دستیابی به مدل های دقیق تر، قابل اعتمادتر و همچنین برای غلبه بر محدودیت های مدل های تکی توسعه یافته اند. هدف اصلی این گونه از مدل ها، استفاده همزمان از مزایای مدل های تکی است. مدل های ترکیبی موازی یکی از شناخته شده ترین و پرکاربردترین مدل های ترکیبی هستند که در آنها اجزای مدل بر اساس وزنشان با یکدیگر ترکیب می شوند. این ترکیب به صورت زیر است:

$$\hat{Y}_{Com,t} = W_1 \hat{f}_{1,t} + W_2 \hat{y}_{2,t} + \dots + W_{n-1} \hat{y}_{n-1,t} + W_n \hat{y}_{n,t} \\ = \sum_{i=1}^n W_i \hat{y}_{i,t} \quad (i=1,2,\dots,n) \quad (t=1,2,\dots,m) \quad (1)$$

به طوری که $\hat{Y}_{Com,t}$ ($t=1,2,\dots,m$) مقدار پیش بینی شده مدل ترکیبی در زمان t ، W_i ($i=1,2,\dots,n$) وزن مربوط به i امین جزء، $\hat{y}_{i,t}$ ($i=1,2,\dots,n$) ($t=1,2,\dots,m$) مقدار پیش بینی شده i امین جزء در زمان t است و تعداد اجزای مورد استفاده در ساختار مدل ترکیبی و تعداد داده ها نیز به ترتیب با n و m نمایش داده شده است. وزن مربوط به هر یک از اجزای تشکیل دهنده مدل پیشنهادی به روشی که در آن دقت مدل به حداکثر رسیده و یا

میانگین مربع خطا حداقل است، محاسبه شده است. در سال های اخیر چندین تکنیک مختلف بهینه سازی ابتکاری و فراابتکاری مانند الگوریتم ژنتیک و تکامل دیفرانسیل 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 مناسب 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، فرایند این روش را می توان در چهار مرحله به صورت زیر خلاصه کرد:

مرحله اول: مرحله مدل سازی قطعی خطی: در این مرحله از مدل پیشنهادی، یک مدل خودرگرسیون میانگین متحرک انباشته فصلی به منظور مدل سازی ساختارهای همبستگی قطعی خطی در مجموعه داده های اساسی استفاده می شود. به این ترتیب، نتیجه نهایی این مرحله که مقدار پیش بینی شده برای ساختارهای همبستگی قطعی خطی است، به شرح زیر است:

$$\hat{Y}_{SARIMA,t} = \sum_{i=1}^p \phi_i Y_{t-i} + \sum_{j=1}^P \Phi_{js} Y_{t-js} + \\ \sum_{i=1}^p \sum_{j=1}^P \phi_i \Phi_{js} Y_{t-i-js} + a_t + \\ \sum_{k=1}^q \theta_k a_{t-k} + \dots + \sum_{l=1}^Q \Theta_{ls} \cdot a_{t-js} + \\ \sum_{k=1}^q \sum_{l=1}^Q \theta_k \Theta_{ls} a_{t-i-js} \quad (t=1,2,\dots,m) \quad (2)$$

مرحله دوم: مرحله مدل سازی فازی: در این مرحله، یک سیستم استنتاج فازی-عصبی تطبیقی به منظور مدل سازی ساختارهای همبستگی غیرقطعی غیرخطی در مجموعه داده های اساسی استفاده می شود. به این ترتیب، نتیجه نهایی این مرحله که مقدار پیش بینی شده برای ساختارهای همبستگی غیرقطعی غیرخطی است، به شرح زیر است:

$$\hat{Y}_{ANFIS,t} = \sum_i \bar{w}_i Y_{i,t} = \sum_i w_i Y_{i,t} / \sum_i w_i \quad (3) \\ (t=1,2,\dots,m)$$

$$\sum_{t=1}^m \hat{u}_t^2 = \sum_{t=1}^m \left(y_t - \hat{W}_{SARIMA} \hat{Y}_{SARIMA,t} - \hat{W}_{ANFIS} \hat{Y}_{ANFIS,t} \right)^2 \quad (5)$$

که در آن، $\sum_{t=1}^m \hat{u}_t^2$ مجموع مربع باقی مانده‌ها (RSS) است. به عبارت دیگر، فرایند وزن‌دهی پیشنهادی متشکل است از برآورد \hat{W}_{SARIMA} و \hat{W}_{ANFIS} طوری که $\sum_{t=1}^m \hat{u}_t^2$ حداقل شود. این عمل از طریق مشتق‌گیری از معادله (5) نسبت به \hat{W}_{SARIMA} و \hat{W}_{ANFIS} و برابر قرار دادن نتایج مشتق‌گیری با صفر حاصل می‌شود. حاصل نهایی این فرایند که همان \hat{W}_{SARIMA} و \hat{W}_{ANFIS} است، به صورت زیر به دست می‌آید:

$$\hat{W}_{SARIMA} = \frac{\left(\sum_{t=1}^m y_t \hat{Y}_{SARIMA,t} \right) \left(\sum_{t=1}^m \hat{Y}_{ANFIS,t} \right) - \left(\sum_{t=1}^m y_t \hat{Y}_{ANFIS,t} \right) \left(\sum_{t=1}^m \hat{Y}_{SARIMA,t} \hat{Y}_{ANFIS,t} \right)}{\left(\sum_{t=1}^m \hat{Y}_{SARIMA,t} \right) \left(\sum_{t=1}^m \hat{Y}_{ANFIS,t} \right) - \left(\sum_{t=1}^m \hat{Y}_{SARIMA,t} \sum_{t=1}^m \hat{Y}_{ANFIS,t} \right)^2} \quad (6)$$

$$\hat{W}_{ANFIS} = \frac{\left(\sum_{t=1}^m y_t \hat{Y}_{ANFIS,t} \right) \left(\sum_{t=1}^m \hat{Y}_{SARIMA,t} \right) - \left(\sum_{t=1}^m y_t \hat{Y}_{SARIMA,t} \right) \left(\sum_{t=1}^m \hat{Y}_{SARIMA,t} \hat{Y}_{ANFIS,t} \right)}{\left(\sum_{t=1}^m \hat{Y}_{SARIMA,t} \right) \left(\sum_{t=1}^m \hat{Y}_{ANFIS,t} \right) - \left(\sum_{t=1}^m \hat{Y}_{SARIMA,t} \sum_{t=1}^m \hat{Y}_{ANFIS,t} \right)^2} \quad (7)$$

فازی-عصبی تطبیقی با استفاده از وزن‌های به دست آمده در مراحل قبل محاسبه شده و به عنوان پیش‌بینی نهایی مدل، به شرح زیر پیشنهاد می‌شود:

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

$$\begin{aligned} &= \frac{\left(\sum_{t=1}^m y_t \hat{Y}_{SARIMA,t} \right) \left(\sum_{t=1}^m \hat{Y}_{ANFIS,t} \right) - \left(\sum_{t=1}^m y_t \hat{Y}_{ANFIS,t} \right) \left(\sum_{t=1}^m \hat{Y}_{SARIMA,t} \hat{Y}_{ANFIS,t} \right)}{\left(\sum_{t=1}^m \hat{Y}_{SARIMA,t} \right) \left(\sum_{t=1}^m \hat{Y}_{ANFIS,t} \right) - \left(\sum_{t=1}^m \hat{Y}_{SARIMA,t} \sum_{t=1}^m \hat{Y}_{ANFIS,t} \right)^2} + \\ &\frac{\left(\sum_{t=1}^m y_t \hat{Y}_{ANFIS,t} \right) \left(\sum_{t=1}^m \hat{Y}_{SARIMA,t} \right) - \left(\sum_{t=1}^m y_t \hat{Y}_{SARIMA,t} \right) \left(\sum_{t=1}^m \hat{Y}_{SARIMA,t} \hat{Y}_{ANFIS,t} \right)}{\left(\sum_{t=1}^m \hat{Y}_{SARIMA,t} \right) \left(\sum_{t=1}^m \hat{Y}_{ANFIS,t} \right) - \left(\sum_{t=1}^m \hat{Y}_{SARIMA,t} \sum_{t=1}^m \hat{Y}_{ANFIS,t} \right)^2} \end{aligned} \quad (8)$$

مرحله سوم: مرحله وزن‌دهی: در مرحله سوم از مدل پیشنهادی، یک فرایند حداقل مربعات به منظور محاسبه وزن هر یک از اجزای تشکیل دهنده مدل پیشنهادی (مدل خودرگرسیون میانگین متحرک انباشته فصلی و سیستم استنتاج فازی-عصبی تطبیقی) در ترکیب خطی استفاده می‌شود. به این ترتیب، معادله دستیابی به وزن مورد نظر در مدل ارائه شده می‌تواند به صورت زیر فرموله شود:

$$y_t = W_{SARIMA} \cdot \hat{Y}_{SARIMA,t} + W_{ANFIS} \hat{Y}_{ANFIS,t} + u_t \quad t = 1, 2, 3, \dots, m \quad (4)$$

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 دارد.

مرحله چهارم: مرحله ترکیب. در آخرین مرحله از مدل پیشنهادی، حاصل جمع وزن‌های نتایج پیش‌بینی مدل خودرگرسیون میانگین متحرک انباشته فصلی و سیستم استنتاج

۳- مجموعه داده‌ها

در این مقاله، از داده‌های بار الکتریکی شهر نیو ساوت ولز (NSW) کشور استرالیا به منظور ارزیابی عملکرد مدل پیشنهادی در مقایسه با اجزای آن و همچنین برخی از مدل‌های ترکیبی فصلی دیگر استفاده شده است (شکل ۱). این مجموعه داده‌ها از ۲ مه ۲۰۱۱ تا ۳ ژوئیه ۲۰۱۱ در این شهر ولز جمع‌آوری شده و متشکل از ۳۰۲۴ داده نیم‌ساعتی است. مجموعه داده‌ها به دو زیرمجموعه تقسیم می‌شوند: 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 تا ۳ ژوئیه ۲۰۱۱)، شامل ۳۳۶ مشاهده، به عنوان مجموعه آزمون استفاده می‌شود. داده‌های بار به صورت نیم‌ساعتی بوده و از ۰:۰۰-۲۳:۳۰ جمع‌آوری شده است، به این معنی که هر روز دارای ۴۸ مشاهده است. در این مقاله سه معیار سنجش میانگین قدر مطلق خطا، جذر میانگین مربعات خطا و همچنین میانگین درصدی قدر مطلق خطا مورد استفاده قرار گرفته‌اند. این معیارها به ترتیب مطابق روابط زیر محاسبه می‌شود:

$$MAE = \frac{1}{N} \sum_{i=1}^N |P_i - A_i| \quad (9)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (P_i - A_i)^2} \quad (10)$$

$$MAPE(\%) = \frac{1}{N} \sum_{i=1}^N \left| \frac{P_i - A_i}{A_i} \right| \times 100 \quad (11)$$

۴- بررسی عملکرد مدل پیشنهادی در مقایسه با

سایر مدل‌ها

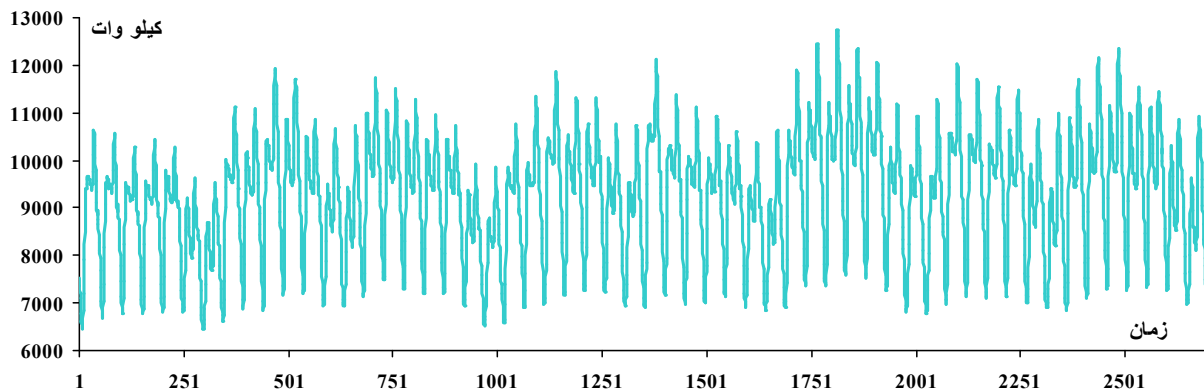
در این بخش، عملکرد مدل پیشنهادی با اجزای تشکیل‌دهنده آن (خودرگرسیون میانگین متحرک انباشته فصلی و سیستم استنتاج فازی-عصبی) و مدل ترکیبی موازی براساس ژنتیک الگوریتم با استفاده از مجموعه داده‌های شهر نیو ساوت ولز (NSW) مقایسه شده است. معیارهای آماری میانگین قدر مطلق خطا، جذر

میانگین مربعات خطا و میانگین درصدی قدر مطلق خطا مدل‌های که قبل از این گفته شد برای مجموعه داده‌های آموزش و آزمون در جدول (۱) خلاصه شده است. علاوه بر این، درصد بهبود مدل پیشنهادی در مقایسه با سایر مدل‌ها در جدول (۲) گزارش شده است.

نتایج حاصل از اجرای مدل‌ها نشان می‌دهد که نه تنها مدل پیشنهادی به طور قابل توجهی نتایجی دقیق‌تر از اجزای آن را به همراه داشته، بلکه نسبت به مدل ترکیبی موازی بر اساس ژنتیک الگوریتم در تمامی مقادیر خطاها عملکرد بهتری داشته است (جدول ۳). به عنوان مثال، میزان بهبود (درصد) مدل پیشنهادی در مقایسه با مدل ترکیبی موازی بر اساس ژنتیک الگوریتم که دارای نزدیک‌ترین دقت عملکرد به مدل پیشنهادی است. با استفاده از معیارهای عملکردی میانگین قدر مطلق خطا، جذر میانگین مربعات خطا و میانگین درصدی قدر مطلق خطا به ترتیب ۸/۲۳، ۷/۵۹ و ۱۱/۹۴ درصد، برای داده‌های آزمون 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 قدر مطلق خطا، جذر میانگین مربعات خطا و میانگین درصدی قدر مطلق خطا برای این روز به ترتیب ۵۲/۴۵، ۰/۵۹ و ۷۳/۳۹ درصد به دست آمده است. عملکرد مدل ترکیبی برای روز چهارشنبه نسبت به سایر روزهای هفته ضعیف‌تر بوده و معیارهای عملکردی میانگین قدر مطلق خطا، جذر میانگین مربعات خطا و میانگین درصدی قدر مطلق خطا برای روز چهارشنبه به ترتیب ۷۵/۰۶، ۰/۷۹ و ۱۰۳/۱۶ درصد است.

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



شکل ۱- داده‌های بار الکتریکی شهر نیو ساوت ولز

جدول ۱- معیارهای عملکردی مدل پیشنهادی در مقایسه با سایر روش‌ها در مجموعه‌های آموزش و آزمون

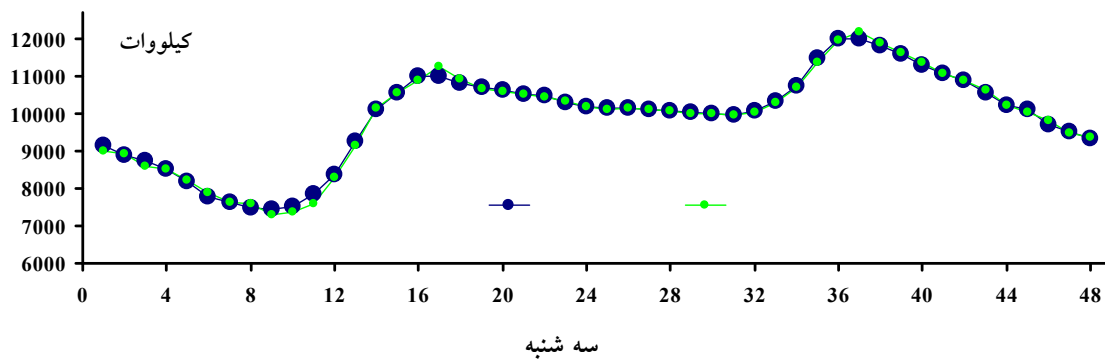
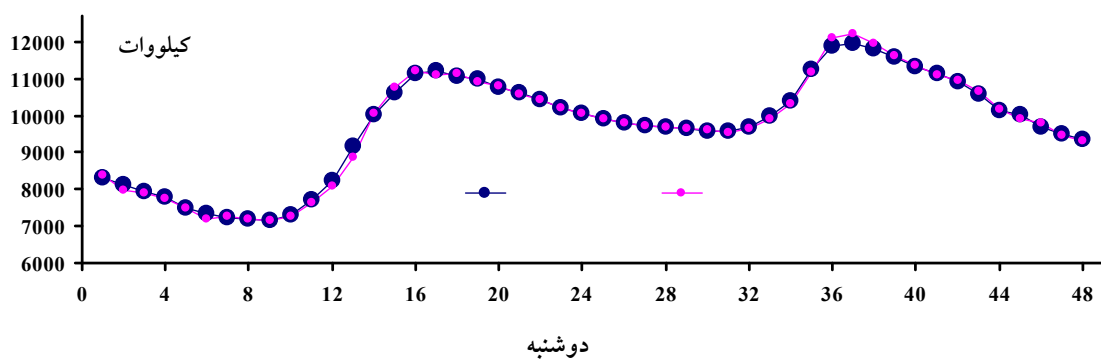
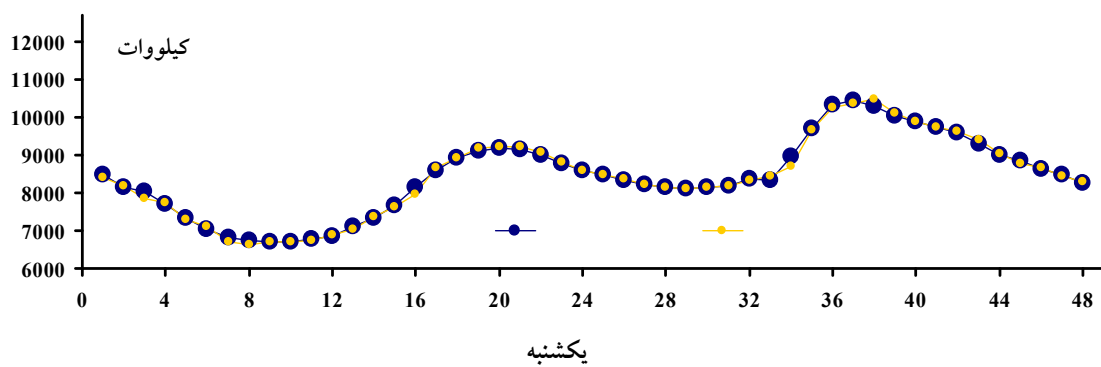
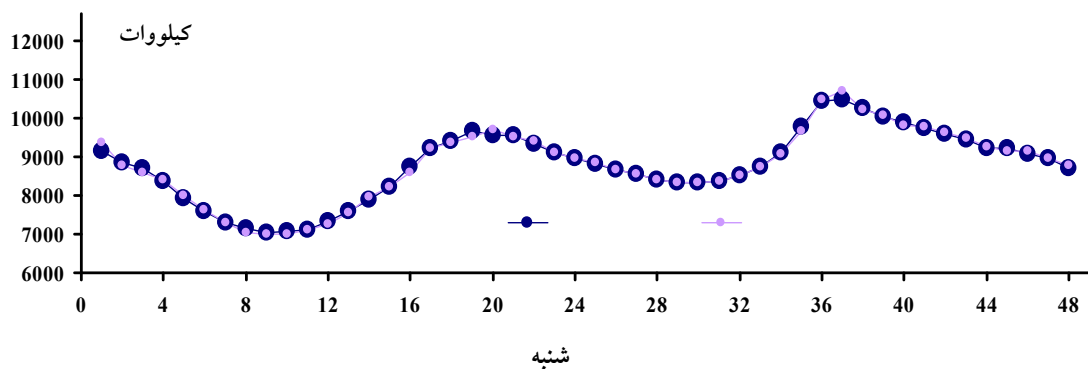
جذر میانگین مربعات خطا		میانگین درصدی قدر مطلق خطا (درصد)		میانگین قدر مطلق خطا		مدل
آزمون	آموزش	آزمون	آموزش	آزمون	آموزش	
۱۶۲/۸۱	۱۴۹/۲۴	۰/۹۷۱	۱/۱۶۷	۸۶/۷۶	۱۰۹/۷۶	خودرگرسیون میانگین متحرک انباشته فصلی
۱۱۹/۲۹	۱۱۸/۹۵	۰/۹۱۹	۰/۹۲۴	۸۶/۶۵	۸۷/۴۴	شبکه‌های عصبی مصنوعی
۱۱۵/۶۹	۱۱۷/۹۴	۰/۸۸۵	۰/۹۰۳	۸۳/۶۸	۸۵/۲۶	سیستم‌های تطبیقی فازی-عصبی
۱۰۱/۴۹	۱۱۶/۸۷	۰/۷۵۱	۰/۹۰۱	۷۰/۲۰	۸۴/۹۴	مدل ترکیبی ژنتیک الگوریتم
۸۹/۳۷	۱۱۵/۱۲	۰/۶۹۴	۰/۸۹۹	۶۴/۴۲	۸۴/۵۸	مدل ترکیبی پیشنهادی

جدول ۲- میزان درصد بهبود مدل پیشنهادی در مقایسه با سایر روش‌ها در مجموعه‌های آموزش و آزمون

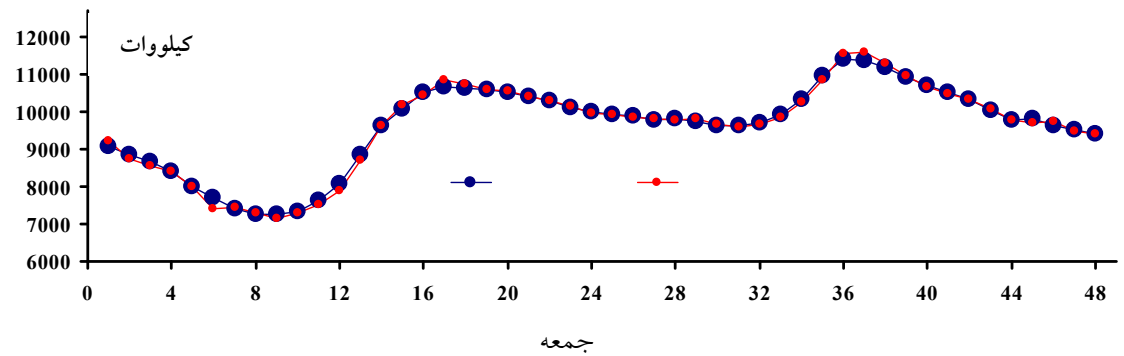
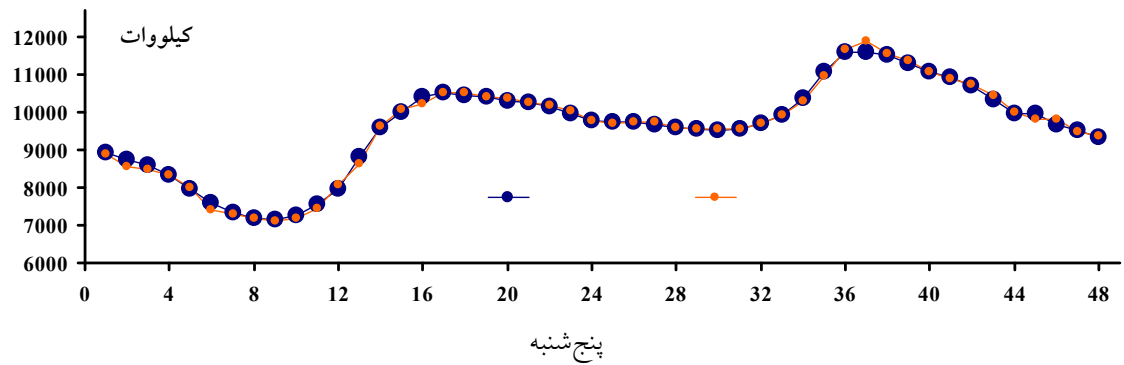
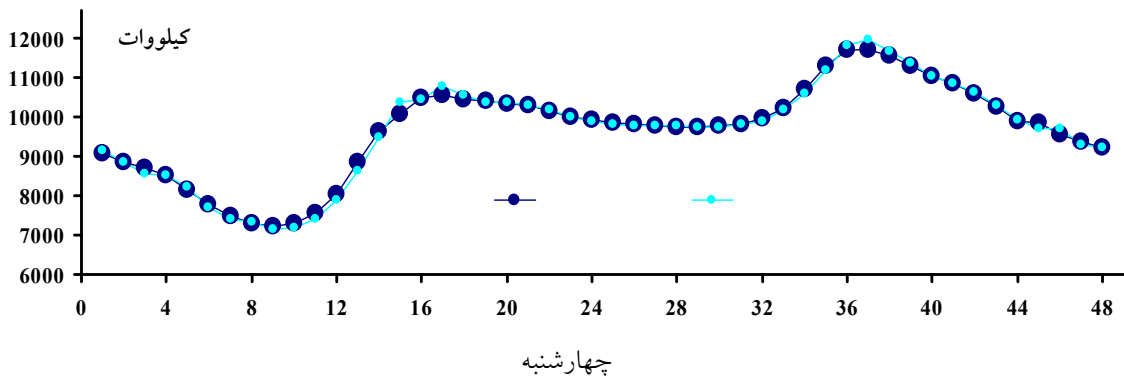
جذر میانگین مربعات خطا		میانگین درصدی قدر مطلق خطا (درصد)		میانگین قدر مطلق خطا		مدل
آزمون	آموزش	آزمون	آموزش	آزمون	آموزش	
۴۵/۱۱	۲۲/۸۶	۲۸/۵۳	۲۲/۹۶	۲۵/۷۵	۲۲/۹۴	خودرگرسیون میانگین متحرک انباشته فصلی
۲۵/۰۸	۳/۲۲	۲۴/۴۸	۲/۷۱	۲۵/۶۵	۳/۲۷	شبکه‌های عصبی مصنوعی
۲۲/۷۵	۲/۳۹	۲۱/۵۸	۰/۴۴	۲۳/۰۲	۰/۸۰	سیستم‌های تطبیقی فازی-عصبی
۱۱/۹۴	۱/۵۰	۷/۵۹	۰/۲۲	۸/۲۳	۰/۴۲	مدل ترکیبی ژنتیک الگوریتم

جدول ۳- معیارهای عملکردی مدل پیشنهادی به تفکیک روزهای هفته (داده‌های آزمون)

معیار سنجش	شنبه	یکشنبه	دوشنبه	سه‌شنبه	چهارشنبه	پنج‌شنبه	جمعه	کل هفته
میانگین قدر مطلق خطا	۵۲/۴۵	۵۴/۵۶	۶۷/۹۴	۶۳/۶۶	۷۵/۰۶	۶۵/۷۴	۷۰/۲۸	۶۴/۲۴
میانگین درصدی قدر مطلق خطا	%/۵۹	%/۶۵	%/۷۰	%/۶۸	%/۷۹	%/۶۹	%/۷۵	%/۶۹
جذر میانگین مربعات خطا	۷۳/۳۹	۷۵/۸۴	۹۷/۱۲	۸۸/۹۲	۱۰۳/۱۶	۸۹/۹۹	۹۳/۲۶	۸۸/۸۱



شکل ۲- مقادیر واقعی و پیش‌بینی شده توسط مدل ترکیبی پیشنهادی به تفکیک روزهای هفته (داده‌های آزمون)



ادامه شکل ۲-

مدل‌ها بر یکدیگر هرچه کمتر بودن میانگین قدر مطلق خطا، جذر میانگین مربعات خطا و میانگین درصدی قدر مطلق خطا برای هر یک از مدل‌ها است. نتایج در جدول‌های (۴) تا (۶) به تفکیک روزهای هفته آمده است. نتایج حاصل برتری مدل پیشنهادی را نسبت به سایر مدل‌ها نشان می‌دهد. همچنین بهترین دقت به دست آمده مربوط به روز شنبه بوده است.

ترکیبی ارائه شده دارای دقت بالایی است. 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) تا (۶) عملکرد مدل پیشنهادی و مدل‌های خودرگرسیون میانگین متحرک انباشته فصلی و سیستم استنتاج فازی-عصبی با یکدیگر مقایسه شده است. همان‌گونه که در بخش‌های پیشین گفته شد، معیارهای برتری

جدول ۴- میانگین قدر مطلق 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
سیستم‌های تطبیقی فازی-عصبی	۷۵/۱۲	۷۵/۷۸	۹۳/۸۳	۸۸/۸۴	۷۹/۳۷	۹۰/۴۹	۸۲/۳۲	۸۳/۶۸
مدل ترکیبی پیشنهادی	۵۲/۴۵	۵۴/۵۶	۶۷/۹۴	۶۳/۶۶	۷۵/۰۶	۶۵/۷۴	۷۰/۲۸	۶۴/۲۴

جدول ۵- میانگین درصدی قدر مطلق 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	٪۰/۱۰۲	٪۰/۱۰۶	٪۰/۱۰۷	٪۰/۱۰۳	٪۰/۹۷
سیستم‌های تطبیقی فازی-عصبی	٪۰/۸۴	٪۰/۸۸	٪۰/۹۵	٪۰/۸۹	٪۰/۸۳	٪۰/۹۴	٪۰/۸۶	٪۰/۸۹
مدل ترکیبی پیشنهادی	٪۰/۵۹	٪۰/۶۵	٪۰/۷۰	٪۰/۶۸	٪۰/۷۹	٪۰/۶۹	٪۰/۷۵	٪۰/۶۹

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
سیستم‌های تطبیقی فازی-عصبی	۱۰۸/۵۶	۱۰۹/۹۳	۱۲۸/۴۵	۱۲۲/۵۶	۱۱۰/۲۳	۱۲۰/۷۰	۱۰۷/۶۴	۱۱۵/۴۴
مدل ترکیبی پیشنهادی	۷۳/۳۹	۷۵/۸۴	۹۷/۱۲	۸۸/۹۲	۱۰۳/۱۶	۸۹/۹۹	۹۳/۲۶	۸۸/۸۱

۵- نتیجه‌گیری

بهینه ترکیبی موازی بر اساس سیستم استنتاج فازی-عصبی (ANFIS) و خودرگرسیون میانگین متحرک انباشته فصلی (SARIMA) به منظور پیش‌بینی بار الکتریکی مطرح شده است. مدل پیشنهادی با اجزای تشکیل‌دهنده خود و سایر مدل‌ها مقایسه شده است. نتایج حاصل برتری مدل پیشنهادی و بهبود دقت را نشان می‌دهد. کمتر بودن معیارهای آماری مدل پیشنهادی، مدل‌سازی الگوهای فصلی/غیرفصلی و همچنین فازی/غیرفازی این برتری را تأیید می‌کند.

دقت پیش‌بینی‌ها یکی از مهم‌ترین فاکتورهای موثر بر کیفیت تصمیم‌گیری است که رابطه مستقیمی با کیفیت این تصمیم‌ها دارد. پیش‌بینی تقاضای الکتریسیته یکی از چالش‌برانگیزترین حوزه‌های پیش‌بینی است. مشخصه منحصر به فرد الکتریسیته که پیش‌بینی را در مقایسه با سایر کالاهای تولیدی دشوارتر می‌سازد، عدم امکان ذخیره‌سازی آن به منظور مصرف در آینده است. این موضوع سبب ایجاد سطح بالایی از ابهام در داده‌های مرتبط این گونه از بازارها می‌شود. در این مقاله، یک مدل جدید

واژه‌نامه

1. residual sum of squares (RSS)

1. Box, G. E. P., and Jenkins, G. M., *Time Series Analysis, Forecasting and Control*, Holden-Day, San Francisco, 1970.
2. Saab, S., Badr, E., and Nasr, G., "Univariate Modeling and Forecasting of Energy Consumption: the Case of Electricity in Lebanon", *Energy*, Vol. 26, No. 1, pp. 1-14, 2001.
3. Park, J. H., Park, Y. M., and Lee, K. Y., "Composite Modeling for Adaptive Short-Term Load Forecasting", *IEEE Transactions on Power Systems*, Vol. 6, No. 2, pp. 450-457, 1991.
4. Bunn, D. W., and Farmer, E. D., *Comparative Models for Electrical Load Forecasting*, John Wiley & Sons, New York, 1985.
5. Taylor, J. W., and Buizza, R., "Using Weather Ensemble Predictions in Electricity Demand Forecasting", *International Journal of Forecasting*, Vol. 19, pp. 57-70, 2003.
6. Hsu, C. C., and Chen, C. Y., "Regional Load Forecasting in Taiwan: Applications of Artificial Neural Networks", *Energy Conversion and Management*, Vol. 44, pp. 1941-1949, 2003.
7. Novak, B., "Superfast Autoconfiguring Artificial Neural Networks and Their Application to Power Systems", *Electric Power Systems Research*, Vol. 35, pp. 11-16, 1995.
8. Panapakidis, I. P., and Athanasios S. D., "Day-Ahead Electricity Price Forecasting via the Application of Artificial Neural Network Based Models", *Applied Energy*, Vol. 172, pp. 132-151, 2016.
9. Zendejboudi, S., Rezaei, N., and Lohi, A., "Applications of Hybrid Models in Chemical, Petroleum, and Energy Systems: A Systematic Review", *Applied Energy*, Vol. 228, pp. 2539-2566, 2018.
10. Box, P., and Jenkins, G. M., *Time Series Analysis: Forecasting and Control*, Holden-day Inc, San Francisco, CA, 1976.
11. Khashei, M., Bijari, M., and Raissi Ardali, Gh. A., "Hybridization of Autoregressive Integrated Moving Average (ARIMA) with Probabilistic Neural Networks (PNNs)", *Computers & Industrial Engineering*, Vol. 63, No. 1, pp. 37-45, 2012.
12. Camara A., Feixing, W., and Xiuqin, L., "Energy Consumption Forecasting using Seasonal ARIMA with Artificial Neural Networks Models", *International Journal of Business and Management*, Vol. 11, No. 5, p. 231, 2016.
13. Norizan, M., Maizah, A., and Zuhaimy I., "Short Term Load Forecasting using Double Seasonal ARIMA Model, In *Proceedings of the Regional Conference on Statistical Sciences*, Vol. 10, pp. 57-73, 2010.
14. Soares, L. J., and Medeiros M. C., "Modeling and Forecasting Short-Term Electricity Load: A Comparison of Methods with an Application to Brazilian Data", *International Journal of Forecasting*, No. 24, No. 4, pp. 630-44, 2008.
15. Yaslan, Y., and Bahadır B., "Empirical Mode Decomposition Based Denoising Method with Support Vector Regression for Time Series Prediction: A Case Study for Electricity Load Forecasting", *Measurement*, Vol. 103, pp. 52-61, 2017
16. Hu, R., Shiping, W., Zhigang, Z., and Tingwen, H., "A Short-Term Power Load Forecasting Model Based on The Generalized Regression Neural Network with Decreasing Step Fruit Fly Optimization Algorithm", *Neurocomputing*, Vol. 221, pp. 24-31, 2017.
17. Olagoke, M. D., Ayeni, A., and Hambali, M. A., "Short Term Electric Load Forecasting using Neural Network and Genetic Algorithm", *International Journal of Applied Information Systems*, No. 10, pp. 22-28, 2016.
18. Nie, H., Liu, G., Liu, X., and Wang, Y., "Hybrid of ARIMA and SVMs for Short-Term Load Forecasting", *Energy Procedia*, Vol. 16, pp. 1455-1460, 2012.