

## **Short-term Electric Load Forecasting Using Grey Models By Considering Demand Response**

**S. J. SeyedShenava<sup>1</sup>, A. Dejamkhooy<sup>2</sup>, k. Javanajjadi<sup>3</sup>**

<sup>1</sup> Dept. of Electrical Engineering, University of Mohaghegh Ardabili, Ardabil, Iran

<sup>2</sup> Dept. of Electrical Engineering, University of Mohaghegh Ardabili, Ardabil, Iran

<sup>3</sup> Dept. of Electrical Engineering, University of Mohaghegh Ardabili, Ardabil, Iran

### **Abstract:**

In this paper the modified grey models are proposed for short-term load forecasting in presence of demand response. The demand response is a valuable element of the smart grids. On the other hand, short-term load forecasting is very important for energy purchase planning and optimal operating of restructured power systems. Since the consumer participation is undetermined and inherently uncertain, the load forecasting will be a difficult task in presence of demand response. Numerous methods have been proposed to the load forecasting, which they have little ability to track demand side reaction. Therefore, requirement of a high precision method to model and predict the electric load in presence of demand response is appreciable. In this paper, grey models, which utilize low number of data to high precision prediction, have been modified by an iterative strategy to short-term load forecasting in presence of demand response. Since grey models are local predictors, they show better ability in modeling and forecasting of the load profiles with the unexpected and sudden changes. After applying demand response scenarios on Iran consumption load data, they have been utilized to verify the proposed method. Simulation results show high performance and accuracy of the proposed methods.

**Keywords:** Demand response; Short-term load forecasting; Grey models.

## پیش‌بینی کوتاه‌مدت بار الکتریکی با استفاده از الگوهای خاکستری با در نظر گرفتن پاسخ‌گویی بار

سیدجلال سیدشنوا<sup>۱</sup>، عبدالمجید دژم‌خوی<sup>۲</sup>، کیان جوان‌اجدادی<sup>۳</sup>

۱- دانشیار، دانشکده فنی و مهندسی - دانشگاه محقق اردبیلی - اردبیل - ایران

seyedshenava@uma.ac.ir

۲- استادیار، دانشکده فنی و مهندسی - دانشگاه محقق اردبیلی - اردبیل - ایران

majiddejam@uma.ac.ir

۳- کارشناسی ارشد، دانشکده فنی و مهندسی - دانشگاه محقق اردبیلی - اردبیل - ایران

kian.javanajdadi@gmail.com

**چکیده:** در این مقاله الگوهای خاکستری بهبودیافته برای پیش‌بینی بار در حضور پاسخ‌گویی بار پیشنهاد شده است. پاسخ‌گویی بار، یکی از ویژگی‌های ارزشمند شبکه‌های هوشمند است. از طرف دیگر، در صنعت برق تجدید ساختار یافته، پیش‌بینی کوتاه‌مدت بار برای برنامه‌ریزی خرید انرژی و بهره‌برداری بهینه از سیستم قدرت اهمیت زیادی دارد. پیش‌بینی کوتاه‌مدت بار با در نظر گرفتن پاسخ‌گویی سمت تقاضا به دلیل نبود آگاهی دقیق از میزان مشارکت مصرف‌کنندگان، دشوار است. روش‌های متعدد ارائه‌شده برای پیش‌بینی بار تا کنون توانایی چندانی در رهگیری واکنش سمت تقاضا نداشته است؛ بنابراین به روشی برای الگوسازی و پیش‌بینی کوتاه‌مدت بار در حضور پاسخ‌گویی بار نیاز است. در این مقاله الگوهای خاکستری که از داده‌های کم و دقت زیاد بهره می‌گیرند، با روش‌های مبتنی بر تکرار برای پیش‌بینی کوتاه‌مدت بار بهبود یافته‌اند. این روش‌ها پیش‌بین‌کننده‌های محلی‌اند؛ به همین دلیل توانایی بهتری در الگوسازی پروفیل‌های بار با تغییرات ناگهانی از خود نشان می‌دهند؛ مانند آنچه در هنگام پاسخ‌گویی بار رخ می‌دهد. برای اعتبارسنجی روش‌های پیشنهادی، منحنی بار ایران پس از اعمال سناریوهای پاسخ‌گویی بار استفاده شده است و نتایج شبیه‌سازی عملکرد مطلوب و دقت زیاد روش‌های پیشنهادی را نشان می‌دهند.

**واژه‌های کلیدی:** پاسخ‌گویی بار؛ پیش‌بینی کوتاه‌مدت بار؛ الگوهای خاکستری.

### ۱- مقدمه

بار تغییر پیدا کرده است [۱]. هدف این برنامه‌ها تشویق مصرف‌کنندگان برای مدیریت زمان مصرف است تا طی آن ضمن ایجاد تعادل بین عرضه و تقاضای انرژی الکتریکی، هزینه‌ها کاهش و قابلیت اطمینان سیستم قدرت افزایش یابد [۲]. پاسخ‌گویی بار<sup>۲</sup> (DR) از مهم‌ترین برنامه‌های DSM است. برای الگوسازی پاسخ‌گویی بار روش‌های متعددی ارائه شده‌اند [۳]. از میان این روش‌ها قیمت‌گذاری زمان مصرف<sup>۳</sup> (TOU) و برنامه پاسخ‌گویی بار اضطراری<sup>۴</sup> (EDRP) کاربرد بیشتری دارند [۴]. از طرف دیگر، اطلاع از تقاضای آینده شبکه برای عملکرد موفق عملیات بازار برق در سیستم‌های تجدید ساختار یافته و برنامه‌های

اگرچه در اوایل مطرح‌شدن مدیریت سمت تقاضا<sup>۱</sup> (DSM)، کاهش تقاضای پیک راه‌حلی برای افزایش ظرفیت شبکه بود، در دهه‌های اخیر برنامه‌های DSM به مدیریت پروفیل

<sup>۱</sup> تاریخ ارسال مقاله: ۱۳۹۶/۰۳/۰۴

تاریخ پذیرش مقاله: ۱۳۹۶/۱۰/۰۴

نام نویسنده مسئول: سیدجلال سیدشنوا

نشانی نویسنده مسئول: ایران - اردبیل - خیابان دانشگاه - دانشگاه محقق اردبیلی - دانشکده فنی و مهندسی

گروه‌بندی مشتری‌ها و شبکه‌ی عصبی برای پیش‌بینی بار هر گروه ارائه شده است. متغیرهای آب‌وهوا و تقویم، ورودی دیگر برای الگوی پیشنهادی در نظر گرفته شده‌اند [۲۰].

همچنین در سال‌های اخیر، الگوهای ترکیبی مانند شبکه‌های عصبی - فازی [۲۱] و شبکه‌های عصبی موجک [۲۲] در پیش‌بینی بار استفاده شده‌اند. فرآیند حلقه بسته به‌منظور نحوه‌ی مدیریت DR و اتخاذ تصمیم برای قیمت‌گذاری برنامه‌ی TOU ارائه شده است. نحوه‌ی کار بدین گونه است که ابتدا تقاضای بار مشتریان با استفاده از روش ANFIS پیش‌بینی می‌شود، سپس این اطلاعات، جمع و در اختیار شرکت برق به منظور مدیریت DR و تصمیمات قیمت‌گذاری TOU قرار داده می‌شود. [۲۳]. الگوریتم سه قسمتی که شامل بسته تبدیل موجک، الگوی چند ورودی چند خروجی ماشین بردار پشتیبان براساس حداقل مربعات غیرخطی<sup>۹</sup> (NLSSVM) به‌منظور الگوسازی و الگوریتم کلونی زنبور عسل برای بهینه‌سازی پارامترهای NLSSVM برای پیش‌بینی همزمان قیمت و تقاضا با در نظر گرفتن اثرات متقابل برنامه‌های مدیریت سمت تقاضا بر ضریب بار پیشنهاد شده است. [۲۴، ۲۵]. روش‌های ذکرشده دقت مطلوبی را نشان داده‌اند؛ ولی بیشتر این روش‌ها برای رسیدن به دقت زیاد یا از تعداد داده‌های زیادی استفاده می‌کنند یا علاوه بر داده‌های بار از پارامتر دیگری مانند دما برای افزایش دقت پیش‌بینی استفاده می‌کنند که این یکی از معایب این روش‌ها است؛ زیرا اطلاعات، همیشه موجود و در دسترس نیست و در مواقعی که داده‌های زیادی در دسترس نباشد، این روش‌ها کارایی نخواهند داشت.

سیستم‌های فاقد اطلاعات (نامعین)، سیستم‌های خاکستری شناخته می‌شوند. الگوی خاکستری سری زمانی را براساس داده‌های اخیر پیش‌بینی می‌کند. این روش پیش‌بینی محلی، منحنی‌نمایی برای داده‌های اخیر استخراج می‌کند؛ سپس پیش‌بینی را براساس منحنی استخراج‌شده انجام می‌دهد [۲۶]. از الگوهای خاکستری برای پیش‌بینی بلندمدت بار (بار سالیانه) و نیز پیش‌بینی پیک بار استفاده شده‌اند [۲۷]. الگوی خاکستری چندمتغیره بهبودیافته برای پیش‌بینی مصرف انرژی در چین پیشنهاد شده است. برای پیدا کردن پارامترهای بهینه الگوی خاکستری، به‌منظور

پاسخ‌گویی بار بسیار بااهمیت است [۵]. پیش‌بینی کوتاه‌مدت بار این پتانسیل را دارد تا برای بهبود بهره‌وری بازار برق، کنترل بار، افزایش امنیت سیستم و ارائه‌ی منافع اقتصادی برای مصرف‌کنندگان، شرکت‌ها و اپراتورهای سیستم عمل کند [۶]. به احتمال زیاد اجرای برنامه‌های DR در صورت نبود پیش‌بینی دقیق بار با شکست مواجه خواهد شد [۷]. علاوه بر این، به سبب اینکه اپراتورهای سیستم از میزان مشارکت مصرف‌کنندگان در برنامه‌های پاسخ‌گویی بار اطلاع نخواهند داشت، کار پیش‌بینی بار به مراتب دشوارتر خواهد بود [۸]؛ بنابراین نیاز به روشی برای الگوسازی و پیش‌بینی کوتاه‌مدت بار در حضور پاسخ‌گویی بار کاملاً محسوس است.

در گذشته انواع مختلفی از روش‌ها برای پیش‌بینی بار در کوتاه‌مدت مورد استفاده قرار گرفته است. برخی از روش‌ها تنها از داده‌های بار [۹]، درحالی‌که برخی دیگر علاوه بر استفاده از داده‌های بار از پارامترهای دیگری مانند دما برای پیش‌بینی استفاده می‌کنند [۱۰]. از دیگر دیدگاه، روش‌های استفاده‌شده برای پیش‌بینی به دو بخش عمده روش‌های آماری و روش‌های مبتنی بر هوش مصنوعی تقسیم می‌شوند. از مهم‌ترین روش‌های آماری، الگوهای سری‌زمانی مانند الگوی خود رگرسیون میانگین متحرک<sup>۱۰</sup> (ARMA) [۱۱]، رگرسیون خطی چندگانه [۱۲] و هموارسازی نمایی [۱۳] هستند. یک روش کلی بر مبنای سری زمانی که از دو الگوی خود رگرسیون<sup>۱۱</sup> (AR) و میانگین متحرک<sup>۱۲</sup> (MA) بهره می‌گیرد برای پیش‌بینی تقاضای برق با چرخه مختلف فصلی در شبکه قدرت پیشنهاد شده است [۱۴]. از روش‌های مبتنی بر هوش مصنوعی شبکه‌های عصبی [۱۵]، سیستم‌های خبره [۱۶]، ماشین بردار پشتیبان<sup>۱۳</sup> (SVM) [۱۷] و سیستم‌های فازی [۱۸] هستند.

پیش‌بینی کوتاه‌مدت بار در حضور DR نیز مطالعه و بررسی شده است. از الگوریتم بهینه‌ساز اجتماع ذرات برای بهینه‌سازی وزن‌های شبکه عصبی در طول فرآیند آموزش برای پیش‌بینی در کوتاه‌مدت استفاده شده است [۱۹]. فرآیندی سه مرحله‌ای به‌منظور بهبود دقت پیش‌بینی بار روزانه با استفاده از الگوریتم خوشه‌بندی k-means برای

بنابراین در صورت هرگونه تغییر و خروج از الگو توانایی بیشتری از خود نشان می‌دهند. در کارهای گذشته که از الگوهای خاکستری معمولی استفاده کرده‌اند، خطای الگوها برای پیش‌بینی تعداد داده‌های زیاد (تعداد داده‌های پیش‌بینی مورد نظر)، بالا بوده است. به عبارت دیگر، الگوهای خاکستری معمولی به الگوسازی و پیش‌بینی تعداد داده‌های زیاد قادر نیستند؛ بنابراین در این مقاله برای الگوسازی و پیش‌بینی پروفیل بار با در نظر گرفتن DR، الگوهای خاکستری با استراتژی تکرار بهبود یافته‌اند. برای نشان دادن کارایی الگوهای پیشنهادی، این الگوها با سه روش دیگر پیش‌بینی بار مقایسه شده‌اند؛ همچنین اثر تعداد داده‌های استفاده‌شده و اندازه گام پیش‌بینی در هر تکرار در دقت الگوهای پیشنهادی بررسی شده‌اند.

در ادامه، در بخش دوم، الگوی پاسخ‌گویی بار و الگوهای خاکستری معرفی شده‌اند. در بخش سوم الگوسازی و پیش‌بینی کوتاه‌مدت بار به روش پیشنهادی بیان شده است. در بخش چهارم، دو بخش متفاوت مطالعه شده و نتایج بحث و بررسی شده‌اند و در بخش آخر، نتیجه‌گیری شده است.

## ۲- پاسخ‌گویی بار و الگوهای خاکستری

### ۲-۱- الگوسازی پاسخ‌گویی بار

برنامه‌های DR به منظور بالا بردن حساسیت مشترکان نسبت به تغییرات و تحولات بازار طراحی شده‌اند [۳۲]. بسیاری از شرکت‌های برق تا حدود زیادی از برنامه‌ی قیمت‌گذاری زمان مصرف استفاده می‌کنند. در این برنامه دو یا سه بازه زمانی در طول روز تعریف می‌شود که یکی معرف زمان‌هایی با قیمت بیشتر (زمان اوج) و دیگری، معرف زمان‌هایی با قیمت کمتر (زمان عادی) است. تعریف ساعات اوج و ساعات غیراوج برای شرکت‌های مختلف، شکل‌های مختلفی دارد که بستگی زیادی به منطقه، نوع مصرف برق در منطقه پوشش‌یافته و آب‌وهوای منطقه دارد [۱]. در برنامه EDRP، مصرف‌کنندگانی که با اعلام شرایط اضطراری در شبکه اقدام به کاهش مصرف کنند، مبلغی به‌عنوان پاداش از طرف شرکت برق دریافت خواهند کرد؛ اما

حداقل رساندن میانگین درصد خطای الگوی بهینه‌سازی غیرخطی به کار برده شده است [۲۸]. بهینه‌سازی ترکیبی الگوی خاکستری<sup>۱۱</sup> (HOGM) با ادغام بهینه‌سازی مُد داخلی و خارجی برای پیش‌بینی بار پیشنهاد شده است. در این روش برای افزایش دقت پیش‌بینی پارامتر  $\alpha$  الگوی خاکستری بهینه می‌شود. [۲۹]. دیگر روش‌های بهینه‌سازی برای نمونه بهینه‌ساز شیر - مورچه هم با الگوی خاکستری، ادغام و برای پیش‌بینی بار سالانه استفاده می‌شوند [۳۰]. برای افزایش عملکرد پیش‌بینی در کوتاه‌مدت، الگوی خاکستری جدید با عنوان الگوی خاکستری با زمان پاسخ‌دهی بهینه<sup>۱۱</sup> (IRGM(1,1)) پیشنهاد شده است. برای این منظور، روش بهینه‌سازی غیرخطی براساس الگوریتم بهینه‌سازی تجمع ذرات استفاده شده است [۳۱]. در بیشتر این پژوهش‌ها پیش‌بینی بلندمدت بار (بیشتر سال‌های محدود پیش‌رو) انجام گرفته است و برای افزایش دقت الگوهای خاکستری از الگوریتم‌های بهینه‌سازی استفاده شده است. همچنین با توجه به اینکه الگوی خاکستری می‌تواند سری‌زمانی را براساس داده‌های اخیر پیش‌بینی کند، در بیشتر پژوهش‌های انجام‌شده با استفاده از الگوهای خاکستری، معیاری برای انتخاب بهینه تعداد داده‌ها مشاهده نشده است. این درحالی است که برای استفاده از قابلیت این الگوها در پیش‌بینی کوتاه‌مدت به اعمال تغییرات اساسی نیاز دارد.

با توجه به اینکه در حضور DR، اطلاع دقیقی از رفتار مصرف‌کننده در دسترس نیست، پیش‌بین‌کننده‌های کلی و روش‌های مبتنی بر یادگیری که با شناسایی الگو اقدام به پیش‌بینی می‌کنند، توانایی چندانی در الگوسازی پروفیل بار نخواهند داشت. برای غلبه بر این مشکلات، الگوهای خاکستری پیش‌بین‌کننده‌های محلی در چنین شرایطی عملکرد بهتری دارند. به همین منظور در این مقاله الگوی خاکستری<sup>۱۲</sup> (GM(1,1)) که از پرکاربردترین الگوهای نظریه خاکستری است و الگوی خاکستری غلتان<sup>۱۳</sup> (RGM) به‌کار گرفته شده‌اند؛ زیرا توانایی بیشتری در استفاده از داده‌های کم دارند. علاوه بر این الگوها، الگوی خاکستری اصلاح‌شده باقی‌مانده به روش فوریه<sup>۱۴</sup> (FGM) برای افزایش دقت مدل GM(1,1) به کار گرفته شده است. این الگوها با استفاده از داده‌های اخیر، پیش‌بینی را انجام می‌دهند و

پیش‌بینی کوتاه‌مدت بار الکتریکی با استفاده از الگوهای خاکستری با در نظر گرفتن پاسخ‌گویی بار

در ادامه از رابطه (۱) به‌عنوان الگوی ریاضی پاسخ‌گویی بار با در نظر گرفتن الاستیسیته خودی استفاده شده است [۳۴].

$$d(i) = d_0(i) \left\{ 1 + \frac{E(i)[\rho(i) - \rho_0(i) + A(i)]}{\rho_0(i)} \right\} \quad (KWh) \quad (1)$$

در رابطه بالا  $d(i)$  بار لحظه‌ای (مصرف بعد از اجرای برنامه) (KWh)،  $d_0(i)$  بار اولیه (مصرف قبل از اجرای برنامه) (KWh)،  $E(i)$  الاستیسیته خودی بار،  $\rho_0(i)$  قیمت برق قبل از کاهش بار (Rials/KWh)،  $\rho(i)$  قیمت برق بعد از کاهش بار (Rials/KWh) و  $A(i)$  (بر حسب Rials) جایزه تشویقی برنامه EDRP است.

## ۲-۲- الگوهای خاکستری

سیستم‌های فاقد اطلاعات، سیستم‌های خاکستری شناخته می‌شوند. معمولاً به دلیل اطلاعات و دانش محدود، تنها بخشی از ساختار سیستم به‌طور کامل شناخته می‌شود. نظریه سیستم خاکستری برای غلبه بر این مشکل مطرح شده است. روش مبتنی بر نظریه خاکستری برای پیش‌بینی سری زمانی استفاده شده است [۳۲]. پیش‌بین‌های خاکستری آینده را تنها براساس مجموعه‌ای از داده‌های اخیر در سری زمانی پیش‌بینی می‌کنند.

## ۲-۲-۱- الگوی GM(1,1)


الگوی خاکستری مبتنی بر GM(1,1) به‌طور گسترده در کاربردهای مختلف استفاده شده است. منظور از (1,1) معادله دیفرانسیل مرتبه اول تک‌متغیره است. الگوریتم GM(1,1) در ادامه به اختصار تشریح می‌شود [۳۵، ۳۶]. فرض کنید سری داده‌های اصلی سطری به‌صورت رابطه (۲) باشد.

$$x^{(0)} = (x^{(0)}(1), x^{(0)}(2), \dots, x^{(0)}(n)), \quad n \geq 4 \quad (2)$$

که در آن  $x^{(0)}$  یک دنباله مثبت و  $n$  تعداد داده‌های نمونه برداری است. وظیفه الگوی GM(1,1) پیش‌بینی مقدار  $x^{(0)}(n+1)$  است. با اعمال عملیات تولید انباشته<sup>۲۰</sup> (AGO) به مجموعه ورودی  $(x^{(0)})$ ، مجموعه جدید به‌صورت رابطه (۳) تولید می‌شود.

قطع یا کاهش مصرف به‌صورت داوطلبانه و اختیاری است و مشتریان بین کاهش مصرف و دریافت وجه و یا کاهش‌ندادن مصرف حق انتخاب دارند. در این شرایط با کم‌نکردن مصرف، مشترکان ملزم به پرداخت جریمه نمی‌شوند [۴].

شکل (۱) نشان می‌دهد به دلیل حساسیت بار نسبت به قیمت، چگونه کاهش اندکی در سمت تقاضا، به مقدار زیادی بر قیمت انرژی الکتریکی اثر می‌گذارد. حساسیت میزان مصرف به قیمت را الاستیسیته<sup>۱۵</sup> یا  $E$  می‌نامند که برای هر ناحیه یا کشوری متفاوت است.



شکل (۱): تاثیر الاستیسیته بار بر قیمت برق [۳]

بارها درباره قیمت متفاوت انرژی الکتریکی در دوره‌های زمانی مختلف به دو دسته تک‌دوره‌ای و چنددوره‌ای تقسیم می‌شوند. بارهایی که امکان جابه‌جایی در دوره‌های مختلف را ندارند و تنها روشن یا خاموش می‌شوند (مانند بارهای روشنایی) بارهای تک‌دوره‌ای هستند و واکنش این نوع بارها در مقابل قیمت، حساسیت تک‌دوره‌ای<sup>۱۶</sup>، نامیده و با الاستیسیته خودی<sup>۱۷</sup> ارزیابی می‌شوند. علامت الاستیسیته خودی همواره منفی است؛ زیرا هنگامی که در یک دوره قیمت افزایش می‌یابد، مقدار تقاضا در همان دوره کم می‌شود و برعکس. بارهایی که در دوره‌های مختلف جابه‌جا می‌شوند، یعنی مصرف از زمان پیک به زمان میان‌باری یا کم باری منتقل می‌شود، بارهای چنددوره‌ای هستند و واکنش این نوع بارها در مقابل قیمت، حساسیت چنددوره‌ای، نامیده<sup>۱۸</sup> و با الاستیسیته متقابل<sup>۱۹</sup> ارزیابی می‌شوند. علامت این ضریب همواره مثبت است؛ زیرا هنگامی که در یک دوره خاص قیمت افزایش می‌یابد، مقدار تقاضا در دوره‌های دیگر افزایش می‌یابد [۳۳].

انباشته معکوس<sup>۳۱</sup> (IAGO) اعمال می‌شود؛ بنابراین، الگوی خاکستری به معادله زیر منجر می‌شود:

$$\hat{x}^{(0)}(k+1) = \hat{x}^{(1)}(k+1) - \hat{x}^{(1)}(k), \quad k = 2, \dots, n \quad (11)$$

معادله (۱۱) مقدار بعدی داده‌های ورودی یعنی مقدار  $x^{(0)}(n+1)$  را پیش‌بینی می‌کند.

### ۲-۲-۲- تصحیح خطای GM(1,1) با سری فوریه

روش‌های بسیاری برای افزایش دقت الگوهای خاکستری به وسیله الگوسازی مقادیر باقی‌مانده پیش‌بینی خاکستری اصلی پیشنهاد شده‌اند [۳۷]. یکی از این روش‌های اصلاح باقی‌مانده، استفاده از سری فوریه است. با اعمال این روش، مقدار پیش‌بینی شده به مقدار اصلی نزدیک‌تر می‌شود. این روش، الگوی خاکستری اصلاح باقی‌مانده به روش تبدیل فوریه (FGM) نامیده می‌شود [۳۸].

فرض کنید بردار باقی‌مانده  $E_r$  به صورت زیر تعریف شود:

$$E_r = [E_r(2), E_r(3), \dots, E_r(n)]^T \quad (12)$$

به عبارت دیگر، طبق رابطه (۱۳) خواهیم داشت:

$$E_r(k) = x^{(0)}(k) - \hat{x}^{(0)}(k), \quad k = 2, \dots, n \quad (13)$$

که در آن  $x^{(0)}$  و  $\hat{x}^{(0)}$  به ترتیب بیان‌کننده مقدار واقعی و مقدار پیش‌بینی شده با روش GM(1,1) است. سری فوریه سری باقی‌مانده را به صورت رابطه (۱۴) تقریب می‌زند.

$$E(k) = \frac{1}{2}a_0 + \sum_{i=1}^{k_a} \left( a_i \cos\left(\frac{2\pi i}{T}k\right) + b_i \sin\left(\frac{2\pi i}{T}k\right) \right) \quad (14)$$

در معادله فوق  $k > 0$  و  $T = n - 1$  دوره تناوب سری باقی‌مانده و  $k_a = [(n-1)/2] - 1$  حداقل فرکانس گسترش سری‌های فوریه را نشان می‌دهند.

همچنین پارامترهای ثابت  $a_0$ ،  $a_i$  و  $b_i$  در رابطه (۱۴) با اعمال روش حداقل مربعات به صورت زیر برآورد می‌شوند:

$$C = (P^T \cdot P)^{-1} P^T E_r \quad (15)$$

که در آن ماتریس P طبق رابطه (۱۶) به دست می‌آید.

$$x^{(1)} = (x^{(1)}(1), x^{(1)}(2), \dots, x^{(1)}(n)), \quad n \geq 4 \quad (3)$$

که  $x^{(1)}$  به صورت رابطه (۴) بیان خواهد شد.

$$x^{(1)}(k) = \sum_{i=1}^k x^{(0)}(i), \quad k = 1, 2, \dots, n \quad (4)$$

از آنجایی که تمام داده‌های  $x^{(0)}$  مثبت‌اند،  $x^{(1)}$  مجموعه صعودی خواهد بود، به عبارت دیگر، منحنی افزایشی است. با توجه به تعریف GM(1,1)، فرض کنیم  $x^{(1)}$  می‌تواند با یک معادله دیفرانسیل مرتبه اول طبق رابطه (۵) مدل شود.

$$\frac{dx^{(1)}}{dt} + ax^{(1)}(t) = b \quad (5)$$

که در آن a و b پارامترهایی هستند که تعیین می‌شوند. از آنجایی که  $x^{(1)}(k+1) = x^{(1)}(k) + x^{(0)}(k+1)$ ، رابطه (۵) تقریباً به صورت رابطه (۶) بازنویسی می‌شود.

$$x^{(0)}(k+1) + a \frac{x^{(1)}(k+1) + x^{(1)}(k)}{2} = b \quad (6)$$

با استفاده از روش حداقل مربعات خطا، پارامترهای a و b طبق رابطه (۷) به دست می‌آیند.

$$\begin{bmatrix} a \\ b \end{bmatrix} = (B^T B)^{-1} B^T Y_N \quad (7)$$

که در آن B ماتریس تولید انباشته است و طبق رابطه (۸) محاسبه می‌شود.

$$B = \begin{bmatrix} -0.5(x^{(1)}(1) + x^{(1)}(2)) & 1 \\ -0.5(x^{(1)}(2) + x^{(1)}(3)) & 1 \\ \dots & \vdots \\ -0.5(x^{(1)}(n-1) + x^{(1)}(n)) & 1 \end{bmatrix} \quad (8)$$

بردار ثابت  $Y_N$  به صورت رابطه (۹) خواهد بود.

$$Y_N = [x^{(0)}(2), x^{(0)}(3), \dots, x^{(0)}(n)]^T \quad (9)$$

حل رابطه (۵) تابع نمایی است که شرایط اولیه برای  $x^{(1)}(1) = x^{(0)}(1)$ ، سپس مقدار پیش‌بینی  $\hat{x}^{(1)}(k+1)$  طبق رابطه زیر به دست می‌آید:

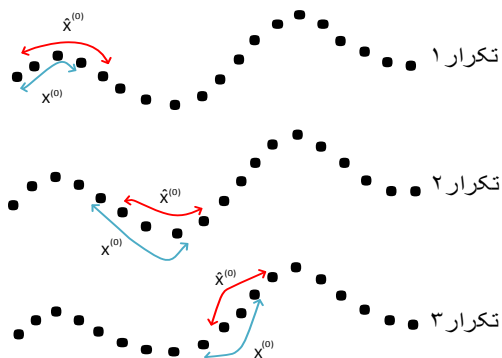
$$\hat{x}^{(1)}(k+1) = \left( x^{(0)}(1) - \frac{a}{b} \right) e^{-ak} + \frac{b}{a}, \quad k = 2, \dots, n \quad (10)$$

در رابطه بالا  $\hat{x}^{(1)}(1) = x^{(1)}(1)$  است. برای به دست آوردن مقدار پیش‌بینی شده از داده‌های اولیه، عملیات تولید

پیش‌بینی کوتاه‌مدت بار الکتریکی با استفاده از الگوهای خاکستری با در نظر گرفتن پاسخ‌گویی بار

$$P = \begin{bmatrix} \frac{1}{2} \cos\left(\frac{2\pi \cdot 2}{T}\right) & \sin\left(\frac{2\pi \cdot 2}{T}\right) & \cos\left(\frac{2 \cdot 2\pi \cdot 2}{T}\right) & \sin\left(\frac{2 \cdot 2\pi \cdot 2}{T}\right) & \dots & \cos\left(\frac{k_a \cdot 2\pi \cdot 2}{T}\right) & \sin\left(\frac{k_a \cdot 2\pi \cdot 2}{T}\right) \\ \frac{1}{2} \cos\left(\frac{2\pi \cdot 3}{T}\right) & \sin\left(\frac{2\pi \cdot 3}{T}\right) & \cos\left(\frac{2 \cdot 2\pi \cdot 3}{T}\right) & \sin\left(\frac{2 \cdot 2\pi \cdot 3}{T}\right) & \dots & \cos\left(\frac{k_a \cdot 2\pi \cdot 3}{T}\right) & \sin\left(\frac{k_a \cdot 2\pi \cdot 3}{T}\right) \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ \frac{1}{2} \cos\left(\frac{2\pi \cdot n}{T}\right) & \sin\left(\frac{2\pi \cdot n}{T}\right) & \cos\left(\frac{2 \cdot 2\pi \cdot n}{T}\right) & \sin\left(\frac{2 \cdot 2\pi \cdot n}{T}\right) & \dots & \cos\left(\frac{k_a \cdot 2\pi \cdot n}{T}\right) & \sin\left(\frac{k_a \cdot 2\pi \cdot n}{T}\right) \end{bmatrix} \quad (16)$$

تکرارهای بعدی نیز انجام می‌شود. سه تکرار از این روش پیشنهادی برای الگوسازی و پیش‌بینی بار در شکل (۲) نشان داده شده‌اند.



شکل (۲): روش پیشنهادی مبتنی بر تکرار:  $\hat{x}^{(0)}$  و  $x^{(0)}$  به ترتیب بیان‌کننده مقادیر واقعی و مقادیر پیش‌بینی شده

تاکنون پیش‌بینی مقدار داده بعدی با مدل  $GM(1,1)$  بحث شد. این بدان معنی است که اندازه گام پیش‌بینی یک فرض شد. هر  $GM(1,1)$  ساخته شده بیشتر از یک داده را پیش‌بینی می‌کند. به عبارت دیگر، اندازه گام پیش‌بینی ( $p$ ) می‌تواند بیشتر از یک باشد.

الگوی  $FGM$  برای پیش‌بینی و الگوسازی به روش پیشنهادی به همان صورتی که در قسمت قبل توضیح داده شد، مشابه روش  $GM(1,1)$  به کار برده می‌شود. به عبارت دیگر،  $GM(1,1)$  ساخته شده در هر تکرار با استفاده از روش فوریه اصلاح می‌شود.

### ۳-۲- الگوی خاکستری غلتان

الگوی غلتان  $GM(1,1)$  بر مبنای انتقال داده‌ها برای ساخت  $GM(1,1)$  است. این الگو ابتدا با استفاده از داده‌های  $x^{(0)}(1)$  تا  $x^{(0)}(n)$  الگوی مقدار داده بعدی یعنی  $x^{(0)}(n+1)$  را پیش‌بینی می‌کند. در گام بعدی،

با جای‌گذاری رابطه (۱۲) و (۱۶) در رابطه (۱۵) خواهیم داشت:

$$C = [a_0, a_1, b_1, a_2, b_2, \dots, a_{ka}, b_{ka}]^T \quad (17)$$

در نهایت سری پیش‌بینی اصلی به شکل رابطه (۱۸) اصلاح می‌شود:

$$\tilde{x}^{(0)}(k) = \hat{x}^{(0)}(k) + E(k), \quad k = 2, 3, \dots, n \quad (18)$$

که در آن مقدار پیش‌بینی با استفاده از روش  $FGM$  است.

### ۳- روش پیشنهادی برای الگوسازی و پیش‌بینی

#### کوتاه‌مدت بار در حضور DR

همان‌طور که در بخش قبل بیان شد الگوهای خاکستری پیش‌بین‌های محلی‌اند. با توجه به این حقیقت، دقت آنها در ارتباط با داده‌های بزرگ، خیلی زیاد نیست؛ بنابراین الگوهای خاکستری باید برای پیش‌بینی کوتاه‌مدت بار اصلاح شوند. در این مقاله الگوهای خاکستری با استفاده از یک روش مبتنی بر تکرار به‌عنوان الگوی پیش‌بینی بار بهبود داده شده‌اند.

#### ۳-۱- $GM(1,1)$ و $FGM$ بهبودیافته

فرض کنید  $m[t]$  داده‌های بار در نظر گرفته شود. این سری زمانی شامل  $m$  داده است.  $n$  تعداد داده‌های نمونه‌برداری از سری زمانی است که در هر  $GM(1,1)$  استفاده می‌شود. ابتدا تعدادی داده محدود برای پیش‌بینی انتخاب می‌شود. در تکرار اول، وظیفه الگوی  $GM(1,1)$  پیش‌بینی مقدار  $n+1$  است. در تکرار دوم از داده  $n+1$  تا داده  $2n$  ورودی برای  $GM(1,1)$  در نظر گرفته شده است؛ همانند تکرار اول وظیفه الگوی  $GM(1,1)$  پیش‌بینی مقدار داده بعدی یعنی  $2n+1$  است. به همین منوال این کار برای

$$MSE = \frac{1}{n} \sum_{k=1}^n (x^{(0)}(k) - \hat{x}^{(0)}(k))^2 \quad (19)$$

$$MAE = \frac{1}{n} \sum_{k=1}^n |x^{(0)}(k) - \hat{x}^{(0)}(k)| \quad (20)$$

$$MAPE(\%) = \frac{1}{n} \sum_{k=1}^n \frac{|x^{(0)}(k) - \hat{x}^{(0)}(k)|}{x^{(0)}(k)} \times 100 \quad (21)$$

در معادلات فوق  $x^{(0)}$  و  $\hat{x}^{(0)}$  به ترتیب بیان کننده مقادیر واقعی و پیش‌بینی شده و  $n$  تعداد داده‌های انتخابی است.


#### ۴- نتایج شبیه‌سازی

##### ۴-۱- اجرای برنامه‌های DR

از برنامه‌های TOU و EDRP برای به دست آوردن منحنی بار مصرفی روزانه با در نظر گرفتن واکنش سمت تقاضا استفاده شده است. هرچند عملیات DR در سمت مشترکان و شبکه توزیع انجام می‌گیرد، انباشته شدن اثرات DR در پروفیل بار کل نیز تأثیر دارد [۳۹]. هدف از این مطالعه، الگوسازی و پیش‌بینی پروفیل بار (پروفیلی که با تأثیر از DR تغییر شکل داده است) است؛ بنابراین میزان مشارکت بارها در فرآیند DR در روش پیشنهادی اهمیت چندانی ندارد. به منظور بررسی و آزمون همزمان برنامه‌های ذکر شده، منحنی بار کل مصرفی کشور ایران در تاریخ ۹۳/۰۵/۲۹، انتخاب و منحنی بار آن روز، مطالعه و بررسی شده است. در دسترس بودن داده‌های بار ایران و نیز امکان استفاده عملی از نتایج مقاله در آینده، از دلایل استفاده از داده‌های ایران است. این منحنی به سه دوره زمانی جداگانه کم باری (۱ الی ۱۱ صبح)، بار میانه (۱۹ الی ۲۴) و بار پیک (۱۲ الی ۱۸) تقسیم شده است. با توجه به اینکه بازار خرده‌فروشی و به تبع آن، اطلاعات الاستیسیته قیمتی بار در داخل کشور وجود ندارد، مقدار الاستیسیته خودی بار،  $-0.1$  معادل نصف مقدار الاستیسیته خودی بازار انگلستان و ولز فرض شده است.

برای به دست آوردن منحنی بار مصرفی روزانه با در نظر گرفتن DR، چهار سناریو متفاوت در نظر گرفته شده است. دلیل اصلی اعمال چهار سناریو، نحوه تغییر و

نخستین داده همواره انتقال داده می‌شود؛ بدین معنی که از داده  $x^{(0)}(2)$  تا مقدار پیش‌بینی شده داده  $x^{(0)}(n+1)$  برای پیش‌بینی مقدار داده بعدی یعنی  $x^{(0)}(n+2)$  استفاده می‌شود. این فرآیند تا پایان دنباله تکرار می‌شود. این روش، الگوی خاکستری غلتان نام دارد. شکل (۳) نحوه محاسبه سه داده بعدی با استفاده از پنج داده را با الگوی RGM نشان می‌دهد.



شکل (۳): مثالی از فرآیند پیش‌بینی با الگوی RGM با  $k=3$  و  $n=5$

در شکل (۳)،  $n$  تعداد داده انتخابی و  $k$  عدد غلتان است. دلیل انتخاب عدد ۳ برای عدد غلتان پیش‌بینی سه داده بعدی با استفاده از الگوی RGM است.

##### ۳-۳- ارزیابی دقت الگوها

برای ارزیابی دقت الگوهای پیشنهادی از معیارهایی مانند میانگین مربعات خطا<sup>۲۲</sup> (MSE)، میانگین قدر مطلق خطا<sup>۲۳</sup> (MAE) و میانگین قدر مطلق درصد خطا<sup>۲۴</sup> (MAPE) استفاده شده است. این معیارها به ترتیب با روابط زیر تعریف می‌شوند:



**۴-۱-۲- سناریوی دوم، اجرای برنامه TOU با****الاستیسیته ۵۰٪**

در این سناریو مقدار الاستیسیته نصف شده است؛ برای مثال با اجرای برنامه TOU با الاستیسیته ۵۰٪، مشترک در ساعت پیک،  $1743 \text{ MW}$  یعنی  $3/7\%$  از بار خود را کم کرده است. این در حالی است که در اجرای برنامه TOU با الاستیسیته ۱۰۰٪، مشترک  $7/4\%$  از بار خود را کم می‌کرد. دیده می‌شود با کم‌شدن الاستیسیته، تغییرات منحنی بار و در نتیجه، امکان اجرای برنامه کاهش می‌یابد. منحنی بار تغییر یافته با این سناریو در شکل (۴) نشان داده شده است.

**۴-۱-۳- سناریوی سوم، اجرای همزمان برنامه‌های****TOU و EDRP با پاداش  $250 \text{ Rials/KWh}$** 

منحنی تغییرات بار با اجرای همزمان برنامه‌های TOU و EDRP با پاداش  $250 \text{ Rials/KWh}$  در زمان‌های پیک، در شکل (۴) نشان داده شده است. همان‌طور که انتظار می‌رود به دلیل پاداش لحاظ‌شده در زمان‌های پیک بار، پیک کاهش و بار در دوره کم‌باری افزایش می‌یابد. با اجرای این سناریو مشترک در ساعت پیک،  $5843 \text{ MW}$  یعنی  $12/4\%$  از بار خود را کم کرده است. در این سناریو، مشترک نسبت سناریوی دوم،  $8/7\%$  و نسبت به سناریوی اول،  $5\%$  بیشتر از بار خود را در ساعت پیک کاهش داده است.

**۴-۱-۴- سناریوی چهارم، اجرای همزمان برنامه‌های****TOU و EDRP با پاداش  $500 \text{ Rials/KWh}$** 

منحنی تغییرات بار با اجرای همزمان برنامه‌های TOU و EDRP با پاداشی معادل دو برابر پاداش اعمال‌شده در سناریوی سوم، یعنی  $500 \text{ Rials/KWh}$  در زمان‌های پیک، در شکل (۴) نشان داده شده است. دیده می‌شود با افزایش مبلغ پاداش در زمان‌های پیک با کاهش بار بیشتری در زمان‌های پیک نسبت به سناریوی سوم مواجه شده‌ایم. با اجرای این سناریو مشترک در ساعت پیک،  $8199 \text{ MW}$  یعنی  $17/4\%$  از بار خود را کم کرده است. به عبارت دیگر، در این سناریو کاهش بار در ساعت پیک،  $5\%$  بیشتر از کاهش بار در سناریوی سوم است.


یکنواخت‌تر شدن پروفیل بار با اعمال برنامه‌های DR است. پتانسیل اجرای برنامه‌های EDRP و TOU معادل  $100\%$  در نظر گرفته شده است. هر چند این فرض واقعی نیست، باید توجه کرد روش پیشنهادی برای پیش‌بینی مستقل از سطح بار است. به سبب اینکه درصد مشارکت بارها در DR، در سطح بار تأثیر می‌گذارد، اعتبارسنجی روش پیشنهادی حساس به درصد مشارکت DR نیست. در مقاله حاضر، محاسبات با مقادیر متفاوتی از قابلیت اجرا، ارائه و مقایسه شده‌اند.

پیاده‌سازی روش پیشنهادی برای پیش‌بینی بار، با استفاده از سناریوهای مورد بحث در عمل، مستلزم وجود زیر ساخت مخابراتی گسترده و ایجاد سیستم هوشمند است. به عبارت دیگر، در شرایط وجود سیگنال قیمت حداقل یا قیمت سه‌سطحی، وجود امکانات ارتباطی دوطرفه بین کلیه مشترکان و مراکز اصلی کنترل سیستم (ISO) ضروری است. در این مقاله هدف، نشان‌دادن کارآمدی روش پیشنهادی در حضور DR با فرض وجود چنین سیستمی است.


**۴-۱-۱- سناریوی اول، اجرای برنامه TOU**

در این سناریو از برنامه قیمت‌گذاری زمان مصرف یا TOU استفاده شده است. میانگین قیمت فروش هر  $\text{KWh}$  در سال  $1393$ ،  $500$  ریال بوده است. بر این اساس، قیمت در زمان پیک معادل  $870$  ریال، قیمت در زمان میان‌باری معادل  $550$  ریال و قیمت در زمان کم‌باری معادل  $270$  ریال فرض شده است (تعرفه سه قسمتی). در این حالت، پاداش مبتنی بر اجرای برنامه EDRP صفر در نظر گرفته شده است که معمولاً برای زمان‌های پیک اعمال می‌شود. شکل (۴) نشان‌دهنده منحنی بار اولیه و بار تغییر یافته با الگوی پاسخ‌گویی بار طبق رابطه (۱) است؛ در حالتی که تنها برنامه TOU اجرا شود. همان‌طور که مشاهده می‌شود با توجه به افزایش قیمت در زمان‌های پیک، مشترک بار خود را کاهش و با توجه به کاهش قیمت در زمان‌های کم‌باری، مصرف خود را افزایش داده است؛ برای مثال با اجرای برنامه TOU، مشترک در ساعت پیک (ساعت ۱۵)  $3487 \text{ MW}$  یعنی  $7/4\%$  از بار خود را کم کرده است.

است. به همین منظور از چهار سناریوی ذکر شده در قسمت‌های قبل، برای نمونه از تغییرات بار سناریوی دوم برای پیش‌بینی بار استفاده شده است. هدف پیش‌بینی بار ۲۴ ساعته روز چهارشنبه مورخه ۹۳/۰۵/۲۹ با در نظر گرفتن DR است. با توجه به اینکه در تاریخ مطالعه شده تعرفه سه قسمتی اعمال شده است، به‌ازای هر تغییر تعرفه روش پیشنهادی اجرا شده است. برای دستیابی به بهترین عملکرد  $GM(1,1)$  در هر تکرار حداقل داده، به‌عنوان داده ورودی و اندازه گام پیش‌بینی برابر یک در نظر گرفته شده است. در این شرایط ۲۴ تکرار برای محاسبه بار ۲۴ ساعته موجود خواهد بود. یادآوری می‌شود در هر تکرار،  $GM(1,1)$  متفاوتی تولید خواهد شد؛ زیرا هر  $GM(1,1)$  با پارامترهای  $a$  و  $b$  شناسایی می‌شود؛ بنابراین در هر تکرار  $a$  و  $b$ های متفاوت موجود خواهد بود. با جمع‌آوری کل الگوهای خاکستری تولید شده، بار ۲۴ ساعته مدل می‌شود. شکل (۶) تغییرات پیش‌بینی بار به کمک سه الگوی خاکستری پیشنهادی و شکل (۷) درصد خطای این الگوها را برای ۲۴ ساعت نشان می‌دهد.

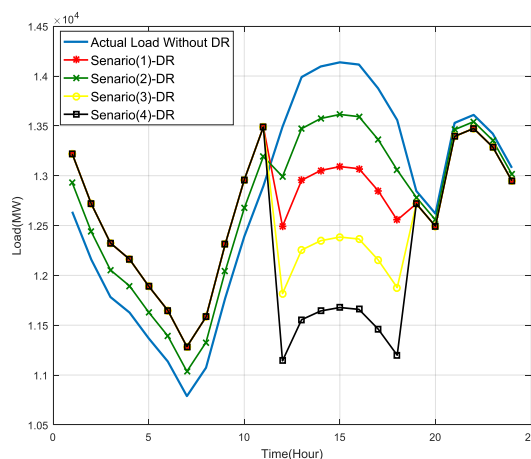


شکل (۶): تغییرات پیش‌بینی بار به کمک الگوهای خاکستری پیشنهادی با در نظر گرفتن DR



شکل (۴): تغییرات منحنی بار قبل و بعد از اجرای برنامه‌های DR

در شکل (۵) قابلیت اجرای برنامه‌های EDRP و TOU معادل ۳۰٪ در نظر گرفته شده است؛ یعنی ۳۰٪ از کل بار در برنامه‌های پاسخ‌گویی بار مشارکت می‌کند؛ به همین منظور، مقادیر بار اولیه در ۳۰٪ ضرب شده است؛ برای مثال با قابلیت اجرای ۳۰٪ در سناریو اول مشترک در ساعت پیک  $1046\text{MW}$  و در سناریو دوم  $523\text{MW}$  از بار خود را کم می‌کند.




شکل (۵): تغییرات منحنی بار قبل و بعد از اجرای برنامه‌های DR، با قابلیت اجرای ۳۰٪

#### ۴-۲- پیش‌بینی بار با در نظر گرفتن DR

در این بخش به منظور پیش‌بینی بار با در نظر گرفتن DR، بار کل مصرفی روزانه ایران مطالعه و بررسی شده


پیش‌بینی کوتاه‌مدت بار الکتریکی با استفاده از الگوهای خاکستری با در نظر گرفتن پاسخ‌گویی بار

(غیر بهبودیافته) در شکل (۸) نتایج حاصل از پیش‌بینی بار با الگوهای خاکستری معمولی نشان داده شده است. طبق شکل، سه الگوی GM(1,1)، FGM و الگوی خاکستری غلتان اصلاً به رهگیری و تقریب پروفیل بار قادر نبوده‌اند. این در حالی است که الگوهای خاکستری بهبودیافته در شکل (۶) می‌توانند پروفیل بار را مدل و پیش‌بینی کنند.



شکل (۸): نتایج حاصل از پیش‌بینی بار با استفاده از الگوهای خاکستری معمولی با در نظر گرفتن DR

در ادامه برای مقایسه کارایی الگوهای پیشنهادی، این الگوها با سه روش دیگر پیش‌بینی بار یعنی شبکه عصبی مصنوعی (ANN)، شبکه عصبی - فازی (ANFIS) و ماشین بردار پشتیبان (SVM) مقایسه شده‌اند. مقدار خطای MAPE به‌دست آمده برای سه روش ANN، ANFIS و SVM به ترتیب برابر  $۳/۹\%$ ،  $۲/۸\%$  و  $۵/۱۸\%$  است. همان‌طور که مشهود است دقت این سه الگو در پیش‌بینی با تعداد داده‌های کم به مراتب پایین‌تر از الگوهای خاکستری پیشنهادی است. در بین سه الگوی ذکر شده، شبکه عصبی - فازی عملکرد بهتری نسبت به دو روش دیگر نشان داده است. شکل (۹) تغییرات پیش‌بینی بار با الگوهای خاکستری پیشنهادی و سه روش ذکر شده را نشان می‌دهد. در شکل (۱۰) مقایسه بین دقت الگوهای خاکستری پیشنهادی و سه روش ذکر شده نشان داده شده است.



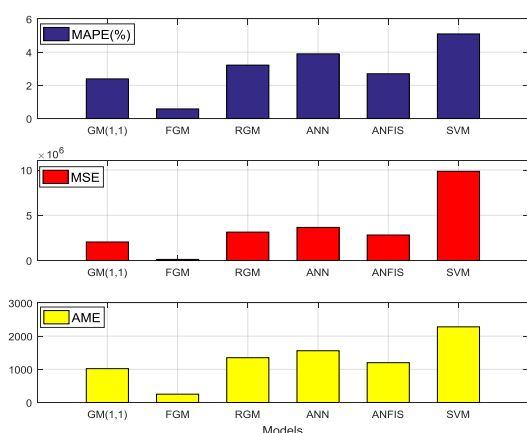
شکل (۷): درصد خطای الگوهای پیشنهادی برای ۲۴ ساعت

در جدول (۱) نتایج پیش‌بینی بار با الگوهای خاکستری پیشنهادی با در نظر گرفتن DR داده شده است. مقادیر داده شده برای بار واقعی و پیش‌بینی شده برحسب مگاوات (MW) است. طبق جدول در الگوی GM(1,1) مقادیر خطای MSE، MAE و MAPE به ترتیب  $۲/۰۵ \times ۱۰^۶$ ،  $۱۰۲۰$  و  $۲/۳۹\%$  است. برای افزایش دقت الگوی پیشنهادی، روش FGM به کار برده شده است و در هر تکرار نتایج GM(1,1) اصلاح می‌شوند. MSE، MAE و MAPE برای الگوی FGM به ترتیب  $۱/۲۲ \times ۱۰^۵$ ،  $۲۵۱/۰۱$  و  $۰/۵۸\%$  است. این نتایج نشان می‌دهند استراتژی اصلاح باقی‌مانده در افزایش دقت پیش‌بینی موفقیت‌آمیز بوده است؛ برای مثال، خطای MAPE تقریباً  $۷۵\%$  بهبود یافته است. همچنین مقادیر مربوط به خطای MSE، MAE و MAPE در الگوی خاکستری غلتان به ترتیب  $۳/۱۴ \times ۱۰^۶$ ،  $۱۳۵۰$  و  $۳/۲۲\%$  است. دقت این روش پایین‌تر از الگوی پیشنهادی GM(1,1) و به‌طور واضح پایین‌تر از FGM است؛ برای مثال، MAPE الگوی غلتان تقریباً  $۳۵\%$  بیشتر از MAPE الگوی GM(1,1) پیشنهادی و  $۴۵۰\%$  بیشتر از MAPE الگوی FGM است. تا این بخش الگوهای متفاوت خاکستری، شبیه‌سازی شد. بیشترین خطا  $۳/۲۲\%$  در بدترین الگو است که مربوط به الگوی غلتان است. در میان روش‌های شبیه‌سازی شده، روش FGM اصلاح شده بهترین عملکرد و بیشترین دقت را نشان داد.

به‌منظور نشان دادن عملکرد بالای الگوهای خاکستری بهبودیافته نسبت به الگوهای خاکستری معمولی

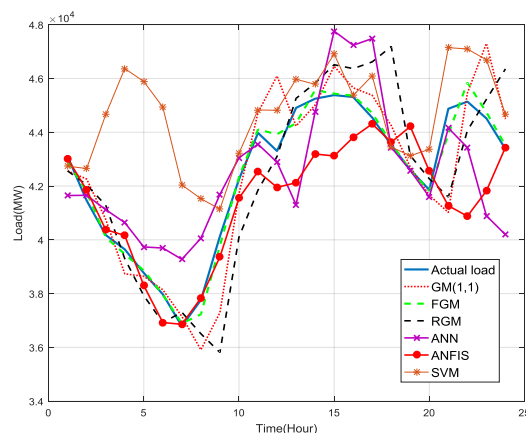
جدول (۱): نتایج پیش‌بینی بار با استفاده از الگوهای خاکستری پیشنهادی با در نظر گرفتن DR

ساعت	بار با در نظر گرفتن DR	GM(1,1)		FGM		RGM	
		پیش‌بینی	خطا(%)	پیش‌بینی	خطا(%)	پیش‌بینی	خطا(%)
۱	۴۳۰۹۸	۴۲۵۶۳	۱/۲۴	۴۲۸۹۳	۰/۴۷	۴۲۵۶۳	۱/۲۴
۲	۴۱۴۵۸	۴۲۲۶۰	-۱/۹۳	۴۱۷۹۷	-۰/۸۱	۴۲۰۴۴	-۱/۴۱
۳	۴۰۱۷۹	۴۰۷۶۲	-۱/۴۵	۴۰۰۹۷	۰/۲	۴۱۲۸۵	-۲/۷۵
۴	۳۹۶۴۷	۳۸۷۳۶	۲/۲۹	۳۹۴۷۲	۰/۴۴	۳۹۲۹۹	۰/۸۷
۵	۳۸۷۶۸	۳۸۶۴۴	۰/۳۲	۳۸۸۵۸	-۰/۲۳	۳۷۹۲۳	۲/۱۸
۶	۳۷۹۷۵	۳۸۱۴۲	-۰/۴۴	۳۷۹۵۷	۰/۰۴	۳۶۹۲۵	۲/۷۶
۷	۳۶۷۸۹	۳۷۱۵۳	-۰/۹۸	۳۶۸۹۲	-۰/۲۷	۳۷۳۰۷	-۱/۴
۸	۳۷۷۶۱	۳۵۹۰۹	۴/۹	۳۷۲۲۹	۱/۴	۳۶۵۰۷	۳/۳۲
۹	۴۰۱۳۴	۳۷۲۹۳	۷/۰۷	۳۹۷۸۳	۰/۸۷	۳۵۸۱۲	۱۰/۷۶
۱۰	۴۲۲۴۶	۴۱۷۱۱	۱/۳۶	۴۲۳۳۵	-۰/۲۱	۴۰۰۹۸	۵/۰۸
۱۱	۴۳۹۷۶	۴۴۷۲۷	-۱/۷	۴۴۱۰۲	-۰/۲۸	۴۱۸۴۹	۴/۸۳
۱۲	۴۳۳۰۴	۴۶۰۹۴	-۶/۴۴	۴۳۹۲۵	-۱/۴۳	۴۳۰۹۸	۰/۴۷
۱۳	۴۴۹۰۷	۴۴۲۳۴	۱/۴۹	۴۴۳۳۷	۱/۲۶	۴۵۲۵۹	-۰/۷۸
۱۴	۴۵۲۴۸	۴۵۰۰۹	۰/۵۲	۴۵۵۶۷	-۰/۷	۴۵۸۲۹	-۱/۲۸
۱۵	۴۵۳۸۱	۴۶۴۵۵	-۲/۳۶	۴۵۴۳۶	-۰/۱۲	۴۶۵۱۲	-۲/۴۹
۱۶	۴۵۳۰۹	۴۵۶۵۴	-۰/۷۶	۴۵۳۶۰	-۰/۱۱	۴۶۳۶۵	-۲/۳۳
۱۷	۴۴۵۴۵	۴۵۳۷۴	-۱/۸۶	۴۴۷۱۸	-۰/۳۸	۴۶۶۱۶	-۴/۶۵
۱۸	۴۳۵۲۳	۴۴۲۵۱	-۱/۶۷	۴۳۵۸۹	-۰/۱۵	۴۷۱۸۹	-۸/۴۲
۱۹	۴۲۶۰۹	۴۲۷۰۳	-۰/۲۲	۴۲۵۸۷	۰/۰۵	۴۳۱۳۳	-۱/۲۳
۲۰	۴۱۸۵۵	۴۱۶۵۶	۰/۴۷	۴۱۸۲۰	۰/۰۸	۴۲۲۶۸	-۰/۹۸
۲۱	۴۴۸۷۴	۴۱۰۱۹	۸/۵۹	۴۳۹۳۵	۲/۰۹	۴۱۵۹۰	۷/۳۱
۲۲	۴۵۱۴۰	۴۵۴۵۹	-۰/۷	۴۵۸۴۴	-۱/۵۶	۴۴۰۶۱	۲/۳۸
۲۳	۴۴۵۱۵	۴۷۳۰۳	-۶/۲۶	۴۴۷۴۴	-۰/۵۱	۴۵۲۲۴	-۱/۵۹
۲۴	۴۳۳۷۸	۴۴۴۸۶	-۲/۵۵	۴۳۵۰۶	-۰/۲۹	۴۶۳۵۴	-۶/۸۶
MSE		$۲/۰۵ \times ۱۰^۶$		$۱/۲۲ \times ۱۰^۵$		$۳/۱۴ \times ۱۰^۶$	
MAE		$۱/۰۲ \times ۱۰^۳$		۲۵۱/۰۱		$۱/۳۵ \times ۱۰^۳$	
MAPE(%)		۲/۳۹		۰/۵۸		۳/۲۲	



شکل (۱۰): مقایسه دقت الگوهای خاکستری پیشنهادی و سه روش

روش ANN، ANFIS و SVM با در نظر گرفتن DR




شکل (۹): تغییرات پیش‌بینی بار با الگوهای خاکستری پیشنهادی و سه روش


روش ANN، ANFIS و SVM با در نظر گرفتن DR

پیش‌بینی کوتاه‌مدت بار الکتریکی با استفاده از الگوهای خاکستری با در نظر گرفتن پاسخ‌گویی بار

الگوهای پیشنهادی بررسی شده‌اند. نتایج پیش‌بینی بار با استفاده از الگوی  $GM(1,1)$  برای ۲۴ ساعت به‌ازای اندازه گام پیش‌بینی متفاوت با در نظر گرفتن DR در شکل (۱۱) نشان داده شده‌اند.



(الف)



(ب)

شکل (۱۱): نتایج پیش‌بینی بار با الگوی  $GM(1,1)$  به‌ازای گام‌های پیش‌بینی متفاوت با در نظر گرفتن DR. الف) تغییرات پیش‌بینی بار، ب) خطای ساعتی بار

با افزایش اندازه گام پیش‌بینی از یک به دو، مقادیر مربوط به سه معیار  $MSE$ ،  $MAE$  و  $MAPE$  به ترتیب به  $۳/۵۵ \times ۱۰^۶$ ،  $۱۳۱۰$  و  $۳/۱$ ٪ تغییر پیدا کرده و مقدار  $MAPE$  ۳۰٪ افزایش یافته است. همچنین افزایش تعداد داده‌های انتخابی به پنج با اندازه گام پیش‌بینی یک، به افزایش مقدار  $MAPE$  از  $۲/۳۹$ ٪ به  $۲/۷۲$ ٪ منجر شده است که در این حالت مقدار  $MAPE$ ،  $۱۴$ ٪ افزایش می‌یابد. طبق شکل (۱۱) مشهود است با افزایش اندازه گام پیش‌بینی

همچنین برای بررسی تأثیر تعداد داده‌ها ( $n$ ) و اندازه گام پیش‌بینی ( $p$ ) در خطای الگوها، در جدول (۲) مقایسه‌ای بین خطای الگوهای خاکستری پیشنهادی به‌ازای تعداد داده‌ها و اندازه گام پیش‌بینی متفاوت انجام شده است.


جدول (۲): مقایسه خطای الگوهای خاکستری پیشنهادی به‌ازای

$n$  و  $p$  های متفاوت با در نظر گرفتن DR


model	n	p	MSE	MAE	MAPE(%)		
GM(1,1)	۴	۱	$۲/۰۵ \times ۱۰^۶$	۱۰۲۰	۲/۳۹		
		۲	$۳/۵۵ \times ۱۰^۶$	۱۳۱۰	۳/۱		
		۳	$۵/۹۶ \times ۱۰^۶$	۱۶۹۰	۳/۹۲		
		۱	$۲/۵۹ \times ۱۰^۶$	۱۱۶۰	۲/۷۲		
		۲	$۳/۵۰ \times ۱۰^۶$	۱۴۵۰	۳/۴۲		
		۳	$۵/۳۸ \times ۱۰^۶$	۱۶۴۰	۳/۸۴		
	۶	۱	$۳/۰۴ \times ۱۰^۶$	۱۳۸۰	۳/۲۳		
		۲	$۵/۷۱ \times ۱۰^۶$	۱۸۲۰	۴/۲۵		
		۳	$۵/۹ \times ۱۰^۶$	۱۹۸۰	۴/۶۴		
		FGM	۴	۱	$۱/۲۲ \times ۱۰^۵$	۲۵۱/۰۱	۰/۵۸
				۲	$۹/۴۴ \times ۱۰^۵$	۶۸۵/۱	۱/۶۲
				۳	$۱/۶۷ \times ۱۰^۶$	۹۰۹/۲۴	۲/۱
۶	۱		$۷/۹۶ \times ۱۰^۵$	۶۶۲/۶۶	۱/۵۵		
	۲		$۱/۵۸ \times ۱۰^۶$	۹۱۰/۲	۲/۱۲		
	۳		$۱/۶۶ \times ۱۰^۶$	۱۰۴۰	۲/۴۷		
RGM	۵	۱	$۱/۱۹ \times ۱۰^۶$	۸۹۳/۲۴	۲/۰۸		
		۲	$۲/۶۶ \times ۱۰^۶$	۱۲۴۰	۲/۹		
		۳	$۲/۵۰ \times ۱۰^۶$	۱۳۱۰	۳/۰۸		
		۴	k=۲	$۳/۱۴ \times ۱۰^۶$	۱۳۵۰	۳/۲۲	
			k=۳	$۵/۲۸ \times ۱۰^۶$	۱۶۳۰	۳/۷۶	
			k=۴	$۸/۸۳ \times ۱۰^۶$	۲۱۹۰	۵/۰۶	
	۶	k=۲	$۴/۳۴ \times ۱۰^۶$	۱۴۴۰	۳/۴		
		k=۳	$۵/۴۶ \times ۱۰^۶$	۱۶۲۰	۳/۸		
		k=۴	$۱/۱۸ \times ۱۰^۷$	۲۶۴۰	۶/۱۶		
		۷	k=۲	$۴/۴۹ \times ۱۰^۶$	۱۷۷۰	۴/۱۴	
			k=۳	$۵/۴۹ \times ۱۰^۶$	۱۷۹۰	۴/۲۷	
			k=۴	$۱/۵۴ \times ۱۰^۷$	۱۶۱۴	۷/۶۳	

همان‌گونه که ذکر شد در شبیه‌سازی‌های قبلی با استفاده از حداقل داده، ساعت‌های بعدی پیش‌بینی شد. در مواقعی لازم است بیشتر از یک ساعت پیش‌بینی شود؛ یعنی اندازه گام پیش‌بینی افزایش یابد و یا در مواقعی تعداد داده‌های بیشتری برای پیش‌بینی نمونه‌برداری شود. به همین دلیل در ادامه، تأثیر تعداد داده‌های نمونه‌برداری و اندازه گام پیش‌بینی متفاوت در تغییرات منحنی بار، پیش‌بینی و دقت

خطا با اندازه گام پیش‌بینی متفاوت با در نظر گرفتن DR با استفاده از الگوی FGM در شکل (۱۳) نشان داده شده است. به ازای افزایش اندازه گام پیش‌بینی از یک به دو، مقدار MAPE از ۰/۵۸٪ به ۱/۶۲٪ و به ازای اندازه گام پیش‌بینی سه، به مقدار ۲/۱٪ افزایش یافته است.



(الف)




(ب)

شکل (۱۳): نتایج پیش‌بینی بار با الگوی FGM به ازای گام پیش‌بینی متفاوت با در نظر گرفتن DR. الف) تغییرات پیش‌بینی بار، ب) خطای ساعتی بار


در شکل (۱۴) نتایج پیش‌بینی بار با تعداد داده‌های متفاوت با استفاده از الگوی FGM نشان داده شده است. همان‌طور که از شکل مشخص است افزایش تعداد داده‌ها باعث کاهش دقت پیش‌بینی می‌شود.

تغییرات منحنی بار پیش‌بینی شده نسبت به حالت‌های قبلی و منحنی بار واقعی بدتر می‌شود.

نتایج پیش‌بینی بار با استفاده از الگوی GM(1,1) برای ۲۴ ساعت به ازای تعداد داده‌های متفاوت با در نظر گرفتن DR در شکل (۱۲) نشان داده شده‌اند. همان‌طور که از شکل مشخص است با افزایش تعداد داده‌های نمونه‌برداری نیز خطای پیش‌بینی بار افزایش می‌یابد.



(الف)



(ب)

شکل (۱۲): نتایج پیش‌بینی بار با الگوی GM(1,1) به ازای تعداد داده‌های انتخابی متفاوت با در نظر گرفتن DR. الف) تغییرات پیش‌بینی بار؛ ب) خطای ساعتی بار

طبق شکل (۱۲)، با افزایش تعداد داده‌های انتخابی نیز تغییرات بار پیش‌بینی شده نسبت به بار واقعی بدتر می‌شود و دقت پیش‌بینی کاهش می‌یابد. نتایج پیش‌بینی بار و درصد

پیش بینی کوتاه مدت بار الکتریکی با استفاده از الگوهای خاکستری با در نظر گرفتن پاسخ گویی بار


که مشاهده می شود روش پیشنهادی، عملکرد بهتری نسبت به بیشتر مراجع اشاره شده دارد.

## ۵- نتیجه گیری


در این مقاله الگوهای خاکستری بهبود یافته برای پیش بینی بار کوتاه مدت در حضور پاسخ سمت تقاضا ارائه شده اند. با استفاده از یک روش مبتنی بر تکرار الگوی خاکستری، الگوی خاکستری اصلاح باقی مانده به روش فوریه و الگوی خاکستری غلتان بهبود داده شدند. طبق نتایج حاصل از معیار خطا، روش پیشنهادی در پیش بینی بار ۲۴ ساعته ایران به مقدار خطای زیر یک درصد دست یافت. مشاهده شد کمترین خطا مربوط به الگوی خاکستری فوریه است که بیشترین دقت را نشان داد و دقت الگوی خاکستری بهتر از الگوی خاکستری غلتان بود. همچنین کارایی الگوهای پیشنهادی با سه روش کلی ANN، ANFIS و SVM مقایسه شد. با مقایسه خطای الگوهای خاکستری پیشنهادی و سه روش کلی مزبور، خطای روش های کلی در مقایسه با روش های محلی در استفاده از تعداد داده های کم برای پیش بینی بار بسیار زیاد بود. پس روش های کلی در مواقعی که تعداد داده های زیادی در دسترس نباشد، کارایی نخواهند داشت؛ بنابراین طرح پیش بینی محلی جدید، عملکرد خیلی بهتری نسبت به طرح های کلی نشان داد. سپس تأثیر تعداد داده ها و اندازه گام پیش بینی در دقت الگوهای پیشنهادی بررسی شد. نتایج نشان دادند با افزایش تعداد داده ها و اندازه گام پیش بینی، خطای الگوها افزایش یافت؛ ولی افزایش خطای الگوها به ازای افزایش اندازه گام پیش بینی، بیشتر از افزایش خطا به ازای افزایش تعداد داده ها بود.

جدول (۳): مقایسه دقت الگوی پیشنهادی با نتایج سایر مراجع

مرجع	افق پیش بینی	MAPE (%) مراجع	MAPE (%) روش پیشنهادی
[۸]	روز پیش رو (با گام پیش بینی نیم ساعت)	۱/۸۸	۰/۷۳
[۱۴]	تعدادی ساعت های پیش رو	۰/۸۶	۱/۳۵
[۱۷]	هفته پیش رو	۱/۸۵	۲/۲۶
[۲۵]	روز پیش رو	۴/۳	۲/۹
[۲۹]	روز پیش رو	۳/۲۳	۱/۷۸
[۳۰]	چند سال پیش رو	۳/۲۳-۴/۰۴	۱/۲۳
[۳۱]	چند سال پیش رو	۱/۵۷	۰/۸۶
[۳۶]	پیش بینی قیمت محصول سال های پیش رو	۰/۹۸	۰/۷



(الف)



(ب)

شکل (۱۴): نتایج پیش بینی بار با الگوی FGM به ازای تعداد داده های متفاوت با در نظر گرفتن DR. الف) تغییرات پیش بینی بار؛ ب) خطای ساعتی بار

در جدول (۳) دقت الگوهای پیشنهادی با نتایج سایر مراجع مقایسه شده است. برای این منظور، روش پیشنهادی بر داده های ارائه شده در آن مراجع، اعمال شده است و نتایج حاصل در ستون سوم جدول (۳) آورده شده اند. همان طور

## مراجع

- term horizon", *Electric Power Systems Research*, Vol. 142, pp. 58-73, 2017.
- [15] M. R. Cogollo and J. D. Velasquez, "Methodological advances in artificial neural networks for time series forecasting", *Latin America Transactions, IEEE (Revista IEEE America Latina)*, Vol. 12, No. 4, pp. 764-771, Jun 2014.
- [16] K.J. Hwan, and G.W. Kim, "A Short-term load forecasting expert system", *In Science and Technology, 2001. KORUS'01. Proceedings. The Fifth Russian-Korean International Symposium on*, Vol. 1, pp. 112-116, August 2002.
- [17] A. Selakov, D. Cvijetinovic, and L. Milovic, "Hybrid PSO-SVM method for short-term load forecasting during periods with significant temperature variations in city of Burbank", *Applied Soft Computing*, Vol. 16, No. 3, pp. 80-88, Mar 2013.
- [18] P. A. Mastorocostas, J. B. Theocharis, and A. G. Bakirtzis, "Fuzzy modeling for short term load forecasting using the orthogonal least squares method", *IEEE Transactions on Power Systems*, Vol. 14, No. 1, pp. 29-36, Feb 1999.
- [19] M. Q. Raza, M. Nadarajah, D. Q. Hung, and Z. Baharudin, "An Intelligent Hybrid Short Term Load Forecast Model For Seasonal Prediction of Smart Power Grid", *Sustainable Cities and Society*. DOI: <http://dx.doi.org/doi:10.1016/j.scs.2016.12.006>, 2016.
- [20] F. L. Quilumba, W. J. Lee, H. Huang, D. Y. Wang, and R. L. Szabados, "Using smart meter data to improve the accuracy of intraday load forecasting considering customer behavior similarities", *IEEE Transactions on Smart Grid*, Vol. 6, No. 2, pp. 911-918, 2015.
- [21] H. Chegini, A. Shirvani, MM. Pedram, et al, "Short term load forecasting of Iran's power systems with neuro-fuzzy application and SSA analysis", *7th Int. Cof. Comp. Sci. Inf. Tech.*, pp. 2000-2004, 2009.
- [22] C. Ying, L. Peter B, G. Che, et al, "Short-term load forecasting: similar day-based wavelet neural networks", *IEEE transaction on power systems*, Vol. 25, No. 1, pp. 322-330, 2010.
- [23] Y. Ozturk, D. Senthilkumar, S. Kumar, and G. Lee, "An intelligent home energy management system to improve demand response", *IEEE Transactions on Smart Grid*, Vol. 4, No. 2, pp. 694-701, 2013.
- [24] A. Ghasemi, H. Shayeghi, M. Moradzadeh, and M. Nooshyar, "A novel hybrid algorithm for electricity price and load forecasting in smart grids with demand-side management", *Applied Energy*, Vol. 177, pp. 40-59, 2016.
- [25] H. Shayeghi, A. Ghasemi, "Modeling of Multi input Multi Output based LSSVM for Electricity Price and Load Forecasting in Smart Grid with Considering Demand Side Management", *Computational Intelligence in Electrical Engineering*, Vol. 8, Issue 4, Article 8, pp. 87-106, Winter 2016
- [1] V. V. Terzija, "Adaptive Under Frequency Load Shedding Based on the Magnitude of the Disturbance Estimation", *IEEE Trans. on Power Systems*, Vol. 21, No. 3, pp.1260-1266, August 2006.
- [2] M. Rastegar, and M. Fotuhi-Firuzabad, "Outage management in residential demand response programs", *IEEE Transactions on Smart Grid*, Vol. 6, No. 3, pp. 1453-1462, 2015.
- [3] U.S. Department of Energy, "Benefits of Demand Response in Electricity Markets and Recommendations to Achieving Them", A Report to the United States Congress Pursuant to Section 1252 of the Energy Policy, 2006.
- [4] D.M. Kim, and J.O. Kim, "Design of emergency demand response program using analytic hierarchy process", *IEEE Transactions on Smart Grid*, Vol. 3, No. 2, pp. 635-644, 2012.
- [5] Q. Zhou, W. Guan, and W. Sun, "Impact of demand response contracts on load forecasting in a smart grid environment", *In Power and Energy Society General Meeting IEEE*, pp. 1-4, July 2012.
- [6] J. Schachter, and P. Mancarella, "A short-term load forecasting model for demand response applications", *In European Energy Market (EEM), 2014 11th International Conference on the IEEE*, pp. 1-5, May 2014.
- [7] D. Masri, H. Zeineldin, and W.L. Woon, "Electricity price and demand forecasting under smart grid environment", *In Environment and Electrical Engineering (EEEIC), 2015 IEEE 15th International Conference on IEEE*, pp. 1956-1960, June 2015.
- [8] S. Fan, and R.J. Hyndman, "Short-term load forecasting based on a semi-parametric additive model", *IEEE Transactions on Power Systems*, Vol. 27, No. 1, pp. 134-141, 2012.
- [9] N. Amjady, "Short-term bus load forecasting of power systems by a new hybrid method", *IEEE Transaction on Power System*, Vol. 22, No. 1, pp. 333-341, 2007.
- [10] N. Amjady, "Short-term hourly load forecasting using time series modeling with peak load estimation capability", *IEEE Transaction on Power System*, Vol. 16, No. 4, pp. 798-805, 2001.
- [11] K. Moshkbar-Bakhshayesh, and M. B. Ghofrani, "Development of a robust identifier for NPPs transients combining ARIMA model and EBP algorithm", *IEEE Transactions on Nuclear Science*, Vol. 61, No. 4, pp. 2383-2391, July 2014.
- [12] N. Amral, CS. Ozveren, and D. King, "Short Term load forecasting using multiple linear regression", *UPEC 2007 .42nd International*, pp. 1192-1198, 2007.
- [13] R. Gob, K. Lurz, and A. Pievatolo, "Electrical load forecasting by exponential smoothing with covariates", *Applied Stochastic Models in Business and Industry*, Vol. 29, No. 6, pp. 629-645, Dec 2013.
- [14] K. G. Boroojeni, M. H. Amini, S. Bahrami, S. S. Iyengar, A. I. Sarwat, and O. Karabasoglu, "A novel multi-time-scale modeling for electric power demand forecasting: from short-term to medium-



- [34] P. Teimourzadeh Baboli, M. Eghbal, M. Parsa Moghaddam and H. A. Aalami, "Customer behavior based demand response model", *In IEEE Power and Energy Society General Meeting*, pp. 1-7, 2012.
- [35] S. F. Su, C. B. Lin and Y. T. Hsu, "A high precision global prediction approach based on local prediction approaches", *IEEE Trans. Syst., Man, Cybern. Part C: Applications and Reviews*, Vol. 32, No. 4, pp. 416-425, 2002.
- [36] E. Kayacan, B. Ulutas and O. Kaynak, "Grey system theory-based models in time series prediction", *Expert Systems with Applications*, Vol. 37, No. 2, pp. 1784-1789, Mar 2010.
- [37] A. Dejamkhooy, and A. Dastfan, "Modeling and forecasting non-stationary voltage fluctuation based on grey system theory", in press, 2015.
- [38] S. F. Su, C. B. Lin, and Y. T. Hsu, "A high precision global prediction approach based on local prediction approaches," *IEEE Trans. Syst., Man, Cybern. Part C: Applications and Reviews*, Vol. 32, No. 4, pp. 416-425, Nov 2002.
- [39] H. Aalami, G. R. Yousefi, and M. Parsa Moghadam, "The Effect of Demand Response Programs on Iranian Power Consumption", *Iranian Journal of Electrical and Computer Engineering*, Vol. 6, No. 4, pp. 317-325, Winter 2009.
- [26] S. Liu and Y. Liu, "Grey Systems: Theory and Applications", Berlin, Germany: Springer-Verlag, 2010.
- [27] H. Morita, D. P. Zhang and Y. Tamura, "Long-Term Load Forecasting Using Grey System Theory", *Electrical engineering in Japan*, Vol. 115, No. 2, pp. 11-20, 1995.
- [28] Z. X. Wang and P. Hao, "An improved grey multivariable model for predicting industrial energy consumption in China", *Applied Mathematical Modelling*, Vol. 40, No. 11, pp. 5745-5758, 2016.
- [29] M. Jin, X. Zhou, Z. M. Zhang and M. M. Tentzeris, "Short-term power load forecasting using grey correlation contest modeling", *Expert Systems with Applications*, Vol. 39, No. 1, pp. 773-779, 2012.
- [30] H. Zhao and S. Guo, "An optimized grey model for annual power load forecasting", *Energy*, Vol. 107, pp. 272-286, 2016.
- [31] N. Xu, Y. Dang and Y. Gong, "Novel grey prediction model with nonlinear optimized time response method for forecasting of electricity consumption in China", *Energy*, Vol. 118, pp. 473-480, 2017.
- [32] D.S. Kirschen, "Demand-side view of electricity markets", *IEEE Transactions on Power Systems*, Vol. 18, No. 2, pp. 520-527, 2003.
- [33] D.S. Kirschen, and G. Strbac, "Fundamentals of power system economics", John Wiley & Sons, 2004.

- 
- <sup>1</sup> Demand Side Management  
<sup>2</sup> Demand Response  
<sup>3</sup> Time of Use  
<sup>4</sup> Emergency Demand Response Programs  
<sup>5</sup> Autoregressive Moving Average  
<sup>6</sup> Auto-Regressive  
<sup>7</sup> Moving-Average  
<sup>8</sup> Support Vector Machine  
<sup>9</sup> Nonlinear Least Square Support Vector Machine  
<sup>10</sup> Hybrid Optimization Grey Model  
<sup>11</sup> Improved-response Grey Prediction Model  
<sup>12</sup> Grey Model  
<sup>13</sup> Rolling Grey Model  
<sup>14</sup> Fourier Residual Correction Grey Model  
<sup>15</sup> Elasticity  
<sup>16</sup> Single Period  
<sup>17</sup> Self Elasticity  
<sup>18</sup> Multi Period  
<sup>19</sup> Cross Elasticity  
<sup>20</sup> Accumulating Generation Operator  
<sup>21</sup> Inverse Accumulating Generation Operator  
<sup>22</sup> Mean Square Error  
<sup>23</sup> Mean Absolute Error  
<sup>24</sup> Mean Absolute Percentage Error