

پیش‌بینی کوتاه‌مدت بار الکتریکی با استفاده از مدل‌های خاکستری بهبودیافته مبتنی بر تکرار

کیان جوان‌اجدادی^۱، کارشناسی ارشد؛ سیدجلال سیدشناوا^۲، دانشیار؛ عبدالمجید دژم‌خوی^۳، استادیار

۱- دانشکده فنی و مهندسی - دانشگاه محقق اردبیلی - اردبیل - ایران - kian.javanajdadi@gmail.com

۲- دانشکده فنی و مهندسی - دانشگاه محقق اردبیلی - اردبیل - ایران - seyedshenava@uma.ac.ir

۳- دانشکده فنی و مهندسی - دانشگاه محقق اردبیلی - اردبیل - ایران - majiddejam@uma.ac.ir

چکیده: با افزایش تقاضای مصرف انرژی الکتریکی، شناسایی روند تغییرات بار از مسائل حائز اهمیت در شبکه‌های برق می‌باشد. در این میان پیش‌بینی کوتاه‌مدت بار برای اطمینان از تأمین تقاضا و امنیت شبکه یکی از حیاتی‌ترین مباحث در مدیریت فنی و اقتصادی صنعت برق به‌شمار می‌آید. تاکنون روش‌های متعددی با دقت‌های متفاوت به‌منظور مدل‌سازی و پیش‌بینی بار در کوتاه‌مدت ارائه شده است. اکثر این روش‌ها از تعداد داده‌های زیاد و پارامترهایی غیر از متغیر پیش‌بینی استفاده می‌کنند. در این مقاله، مدل خاکستری و مدل خاکستری غلتان که می‌تواند با استفاده از تعداد داده‌های کم و با دقت بالا برای مدل‌سازی و پیش‌بینی سری زمانی استفاده شود، بهبود داده شده است. برای افزایش دقت مدل‌های پیشنهادی، روش اصلاح باقی‌مانده به‌روش فوریه به‌کار گرفته شده است. علاوه بر این، عملکرد روش‌های پیشنهادی با چهار روش دیگر با اعمال آنها به شبکه‌های ایران و نیوآینگلند مقایسه شده است. چندین تعریف خطا به‌عنوان معیارهای توانایی و دقت انتخاب شده و حساسیت روش‌های پیشنهادی به تعداد داده‌های مورد نیاز و اندازه گام پیش‌بینی بررسی شده است. نتایج شبیه‌سازی عملکرد و دقت بالای مدل‌های پیشنهادی در مدل‌سازی و پیش‌بینی بار را نشان می‌دهد.

واژه‌های کلیدی: پیش‌بینی کوتاه‌مدت بار، مدل خاکستری، مدل خاکستری غلتان، مدل خاکستری اصلاح باقی‌مانده به‌روش فوریه.

Short-Term Electric Load Forecasting using Iteration Based Modified Grey Models

K. javanajdadi¹, MSc; S. J. SeyedShenava², Associate Professor; A. Dejamkhooy³, Assistant Professor

1- Faculty of Engineering, University of Mohaghegh Ardabili, Ardabil, Iran, Email: kian.javanajdadi@gmail.com

2- Faculty of Engineering, University of Mohaghegh Ardabili, Ardabil, Iran, Email: seyedshenava@uma.ac.ir

3- Faculty of Engineering, University of Mohaghegh Ardabili, Ardabil, Iran, Email: majiddejam@uma.ac.ir

Abstract: Regarding to increase electric power demand consumption, identification of its change circumstances is an important issue in electric networks. From this point of view, short-term load forecasting is vital problem in technical and economic management of the power industry to ensure supply demand and network security. So far numerous methods with different accuracy have been proposed to model and forecast electric load in short-term. Most of them utilize large amounts of data and other parameters of the predictor variable. In this paper, grey model (GM(1,1)) and rolling grey model (RGM) can model and forecast time series by using low number of data and high accuracy improved. Fourier residual correction grey model (FGM) has been employed to increase the accuracy of proposed methods. In addition, the proposed methods performances have been compared with four other methods by applying them on Iran and New England networks. Several error definitions have been adopted as ability and accuracy criteria. Also, the sensitivity of the proposed methods to the number of required data and prediction step size has been investigated. Simulation results show high performance and accuracy of the proposed methods in the modeling and load forecasting.

Keywords: Short-term load forecasting, grey model, rolling grey model, fourier residual correction grey model.

تاریخ ارسال مقاله: ۱۳۹۵/۱۱/۰۴

تاریخ اصلاح مقاله: ۱۳۹۶/۰۱/۱۶، ۱۳۹۶/۰۴/۱۱، ۱۳۹۶/۰۶/۱۵ و ۱۳۹۶/۰۸/۱۰

تاریخ پذیرش مقاله: ۱۳۹۶/۰۹/۰۴

نام نویسنده مسئول: سیدجلال سیدشناوا

نشانی نویسنده مسئول: ایران - اردبیل - خیابان دانشگاه - دانشگاه محقق اردبیلی - دانشکده فنی و مهندسی - گروه مهندسی برق و کامپیوتر.

۱- مقدمه

زمانی بر طبق داده‌های قبلی مورد استفاده قرار گیرند [۹]. مهم‌ترین روش‌های آماری شامل مدل‌های سری زمانی و مدل رگرسیون خطی چندگانه می‌باشد. از جمله پرکاربردترین مدل‌های سری زمانی مدل خودرگرسیون میانگین متحرک^۲ (ARMA) و مدل خودرگرسیون میانگین متحرک انباشته^۴ (ARIMA) می‌باشد [۱۰]. مدل ARIMA برای پیش‌بینی ساعتی با قابلیت تخمین بار بیک مورد استفاده قرار گرفته است [۱۱]. پیش‌بینی کوتاه‌مدت بار با استفاده از مدل ARMA با در نظر گرفتن فرآیند غیر گاوسی پیشنهاد شده است [۱۲]. مزیت مدل‌های سری زمانی این است که فقط از داده‌های خود برای پیش‌بینی استفاده می‌کنند، در کنار این مزیت از معایب این مدل‌ها خطای پیش‌بینی بالا نسبت به دیگر روش‌ها می‌باشد. ولی به دلیل این که این مدل‌ها به اطلاعات جانبی کمتری نیاز دارند، تمایل به استفاده از آن‌ها زیاد می‌باشد.

گروهی دیگر از مدل‌های پیش‌بینی روش‌های مبتنی بر هوش مصنوعی می‌باشد. این روش‌ها شامل شبکه‌های عصبی، سیستم‌های فازی و سیستم‌های خبره می‌باشد. شبکه‌های عصبی مصنوعی [۱۳، ۱۴] و سیستم‌های عصبی-فازی [۱۵، ۱۶]، به عنوان تقریب‌گرهای کلی^۵ پذیرفته شده و در کاربردهای مختلف به کار گرفته شده‌اند. شبکه‌های عصبی در دهه‌های اخیر به منظور مطالعات پیش‌بینی بار مورد توجه زیادی قرار گرفته است. این مدل‌های پیچیده توانایی یادگیری ارتباط بین بار، آب‌وهوا و همچنین ارتباط بین بارهای مختلف را دارند [۱۳]. این روش‌ها از تمام داده‌های آموزشی موجود برای مدل‌سازی و پیش‌بینی استفاده می‌کنند. بنابراین همانند مدل‌های سری زمانی جزء پیش‌بینی‌های کلی می‌باشند. دو روش شبکه عصبی پرسپترون چند لایه^۶ (MLP) و شبکه عصبی خودسازمانده^۷ (SOM) برای پیش‌بینی کوتاه‌مدت بار بررسی شده است [۱۷]. مدل SOM دقت قابل قبولی را نشان داده است، ولی برای رسیدن به این دقت تنظیم چند پارامتر دیگر برای رسیدن به بالاترین دقت مورد نیاز است. مدل $GM(1,1)$ ^۸ بهبود یافته با استفاده از شبکه عصبی مصنوعی برای پیش‌بینی تقاضای برق در تایوان پیشنهاد شده است. در این روش مقادیر خطای مدل $GM(1,1)$ با استفاده از شبکه عصبی تخمین‌گر بهبود یافته است [۱۸]. روش رگرسیون بردار پشتیبان (SVR) برای پیش‌بینی ساعت پیشرو با استفاده از داده‌های شرکت توزیع تهران بررسی شده است [۶]. پارامترهای SVR با استفاده از یک فرایند بهینه‌سازی شبکه و بررسی در توابع مختلف هسته انتخاب شده است. سه روش شبکه عصبی مصنوعی، مدل خودرگرسیون میانگین متحرک انباشته و رگرسیون خطی چندگانه برای پیش‌بینی کوتاه‌مدت بار مقایسه شده‌اند [۱۹]. هدف از مقایسه عملکرد این سه روش، مطالعه داده‌های بار با در نظر گرفتن تقاضای برق (جمعیت، شاخص سهام و مصرف برق) بوده است. آزمایش‌ها نشان داده است که اختلاف معنا داری بین خطاها وجود ندارد.

در سال‌های اخیر نیاز به کاهش هزینه‌ها و بالابردن سود شرکت‌های تولیدکننده برق منجر به توجه هر چه بیشتر به برنامه‌ریزی و مدیریت کارآمد شبکه برق شده است [۱]. در کشورهای در حال توسعه، صنعت برق اغلب قادر به پاسخ‌گویی به تقاضاهای پیک بار نمی‌باشد و در این کشورها مدیریت بار، معمولاً به شکل حذف بار که به صورت قطع برق یا کاهش ولتاژ در سطوح فرعی است، رخ می‌دهد. از این رو اتخاذ استراتژی‌های مناسب برای کنترل تولید و مدیریت بار ضروری است [۲]. یک مدیریت صحیح انرژی الکتریکی موقعی امکان‌پذیر خواهد بود که مدیران دیدی روشن از روند آتی تقاضای این انرژی داشته باشند. در این راستا پیش‌بینی تقاضای بار به عنوان مهم‌ترین ابزار برای استفاده بهینه از منابع انرژی، به رسمیت شناخته شده است. از طریق مطالعات انجام‌یافته در طی پیش‌بینی بار، شرکت‌ها می‌توانند برنامه‌ریزی‌های مناسب با توجه به ویژگی‌های رفتار مصرف‌نهایی مصرف‌کنندگان انجام دهند [۳].

پیش‌بینی بار از نظر افق زمانی را می‌توان به چهار گروه پیش‌بینی بسیار کوتاه‌مدت بار برای زمان‌های از چند دقیقه تا یک ساعت، پیش‌بینی کوتاه‌مدت بار برای زمان‌های از یک ساعت تا یک هفته، پیش‌بینی میان‌مدت بار برای زمان‌های از یک هفته تا یک سال و پیش‌بینی بلندمدت بار برای زمان‌های بیشتر از یک سال، تقسیم کرد [۴]. دلایل اصلی پیش‌بینی کوتاه‌مدت بار صرفه‌جویی اقتصادی در هزینه‌ها، زمان‌بندی مناسب برای بهره‌برداری اقتصادی از واحدهای قدرت و اطلاع از میزان بار شبکه برای اطمینان و امنیت شبکه است [۵]. در کوتاه‌مدت، مصرف انرژی الکتریکی بیشتر تحت تأثیر عوامل محیطی مانند دما، رطوبت هوا، پوشش ابر و سرعت باد قرار دارد و بر حسب زمان مانند ساعات روز هفته و مناسبت‌های خاص تغییر می‌نماید. روش‌های مختلفی در چند دهه گذشته برای رویارویی با پیچیدگی و اهمیت پیش‌بینی تقاضا ارائه شده است. برخی از مدل‌ها فقط از داده‌های بار استفاده می‌کنند، در حالی که برخی دیگر از مدل‌ها، علاوه بر این داده‌ها از پارامترهای دیگری مانند دما نیز برای پیش‌بینی بار استفاده می‌کنند [۶].

روش‌های استفاده‌شده برای مدل‌سازی و پیش‌بینی را می‌توان به دو بخش عمده روش‌های آماری و روش‌های مبتنی بر هوش مصنوعی تقسیم کرد [۷]. از جنبه دیگر روش‌های مدل‌سازی و پیش‌بینی به دو گروه کلی^۱ و محلی^۲ تقسیم می‌شوند. تفاوت بین روش‌های کلی و محلی در استفاده از تعداد داده‌ها برای پیش‌بینی می‌باشد. روش‌های کلی از تعداد داده‌های زیاد برای پیش‌بینی استفاده می‌کنند، در حالی که روش‌های محلی از تعداد داده‌های کم و محدود برای پیش‌بینی استفاده می‌کنند [۸].

مجموعه‌ای از مشاهدات درباره یک متغیر که در فواصل زمانی مساوی و منظمی جمع‌آوری شده باشد، سری زمانی نام دارد. از این منظر داده‌های بار را می‌توان به عنوان یک سری زمانی در نظر گرفت. مدل‌های سری زمانی می‌توانند برای پیش‌بینی مقدارهای بعدی سری

استفاده شده است [۱]. در آن تعدادی از پارامترها از طریق یک فرآیند چندهدفه که خطا و واریانس‌های خطا را مینیمم می‌کند، با هدف فراهم‌آوردن یک پیش‌بینی نهایی دقیق و قابل اعتماد بهینه می‌شود. روش‌های ذکرشده دقت قابل قبولی را نشان داده‌اند، ولی علاوه بر استفاده از داده‌های زیاد، از عوامل دیگری مانند درجه حرارت و ... برای پیش‌بینی استفاده می‌کنند که این یکی از بزرگ‌ترین معایب این روش‌ها می‌باشد، چرا که همیشه اطلاعات موجود و در دسترس نمی‌باشد و یا نیاز به یک مدل ریاضی صریح جهت تعیین رابطه بین بار و چند عامل ورودی دارند. در مواقعی که داده‌های زیادی در دسترس نباشد این روش‌ها قابل استفاده نخواهد بود. بنابراین نیاز به مدلی که با استفاده از تعداد داده‌های کم و بدون نیاز به هیچ متغیر خارجی مانند دما و دیگر پارامترها بالاترین دقت را نشان دهد، ضروری به نظر می‌رسد.

مدل خاکستری می‌تواند سری‌زمانی را بر اساس داده‌های اخیر پیش‌بینی کند [۲۷]. این روش پیش‌بینی محلی، یک منحنی برای داده‌های اخیر استخراج می‌کند، سپس پیش‌بینی را بر اساس منحنی استخراج شده انجام می‌دهد [۲۱]. مدل خاکستری $GM(1,1)$ از پرکاربردترین مدل‌های نظریه خاکستری و مدل خاکستری غلطان^{۱۱} (RGM) در هدف ما به کار گرفته شده‌اند، چرا که توانایی بالایی را در استفاده از داده‌های کم نشان دادند. علاوه بر این مدل‌ها، دقت $GM(1,1)$ با استفاده از سری فوریه بر مبنای روش اصلاح باقی‌مانده افزایش می‌یابد. بنابراین یک روش دیگر پیش‌بینی اصلاح شده که مدل خاکستری اصلاح باقی‌مانده فوریه^{۱۲} (FGM) نام دارد، مورد استفاده قرار می‌گیرد. برای جلوگیری از ساخت و ساز بی‌رویه تجهیزات در دراز مدت انواع مختلف مدل خاکستری برای پیش‌بینی بار سالانه به کار رفته است. همچنین یک روش دیگر به نام پیش‌بینی توپولوژیکی که از روش‌های تئوری خاکستری می‌باشد برای پیش‌بینی، تاریخی که در آن تقاضای پیک اتفاق می‌افتد استفاده شده است. نتایج نشان داد که مدل‌های خاکستری پیشنهادی در مقایسه با روش تجزیه و تحلیل رگرسیون دقت بالایی دارند [۲۸]. مدل خاکستری چندمتغیره بهبودیافته برای پیش‌بینی مصرف انرژی در چین پیشنهاد شده است. برای پیدا کردن پارامترهای بهینه مدل خاکستری، به منظور حداقل‌رساندن میانگین درصد خطا یک مدل بهینه‌سازی غیرخطی استفاده شده است [۲۹]. بهینه‌سازی ترکیبی مدل خاکستری^{۱۳} (HOGM) با ادغام بهینه‌سازی داخلی و خارجی برای پیش‌بینی بار پیشنهاد شده است. در این روش برای افزایش دقت پیش‌بینی پارامتر α مدل خاکستری بهینه می‌شود. همچنین یک مرحله پیش‌پردازش داده‌ها به منظور کاهش اثر داده‌های غیرطبیعی مانند داده‌های دما در مدل نیز وجود دارد [۳۰]. دیگر روش‌های بهینه‌سازی برای نمونه بهینه‌سازی شیر - مورچه هم با مدل خاکستری ادغام و برای پیش‌بینی بار سالانه مورد استفاده قرار گرفته است [۳۱]. به منظور افزایش عملکرد پیش‌بینی در کوتاه‌مدت، یک مدل خاکستری جدید تحت عنوان مدل خاکستری با زمان پاسخ‌دهی بهینه^{۱۴} (IRGM(1,1)) پیشنهاد شده است. برای این منظور یک روش

تحقیقات اخیر در موارد متعدد نشان داده است که روش‌های مبتنی بر مدل‌های خاکستری در مقایسه با پیش‌بینی شبکه‌های عصبی مصنوعی و روش ترکیبی عصبی-فازی از دقت بالاتری برخوردار هستند [۲۰-۲۲]. دلیل این برتری به محلی بودن پیش‌بینی توسط مدل‌های خاکستری برمی‌گردد. به عبارت دیگر روش‌های مبتنی بر یادگیری اولاً نیازمند به داده زیاد برای آموزش هستند و ثانیاً در صورت وقوع تغییر خارج از الگو از رهگیری آن ناتوان می‌باشند. در نهایت می‌توان گفت که از مهم‌ترین معایب روش‌های شبکه عصبی نحوه آموزش و تنظیم چند پارامتر برای رسیدن به دقت بالا می‌باشد. روش‌های پردازش سیگنال نظیر تبدیل موجک نیز برای پیش‌بینی مورد استفاده قرار گرفته است. یک روش پیش‌بینی بار بر اساس تبدیل موجک برای پیش‌بینی بار روز و هفته پیشرو پیشنهاد شده است [۲۳]. متغیرهای آب‌وهوا و داده‌های بار به چند بخش فرکانس پایین و فرکانس بالا از طریق تبدیل موجک تجزیه شده‌اند. استفاده از متغیر آب‌وهوا علاوه بر داده‌های بار و تجزیه داده‌های بار و آب‌وهوا به چندین بخش حاکی از پیچیدگی مدل پیشنهادی بوده است. روش ترکیبی که در آن تبدیل موجک برای کم‌کردن نوسانات در داده‌های ورودی، شبکه عصبی بهبودیافته برای یادگیری و نظریه آشوب همراه با جستجوی گرانشی که سعی در یافتن بهترین وزن‌ها و بایاس‌ها دارد، برای پیش‌بینی قیمت روزانه برق استفاده شده است [۲۴]. یک روش ترکیبی مبتنی بر تبدیل موجک دو بعدی برای پیش‌بینی بار پیشنهاد شده است [۲۵]. در این روش برای هر کدام از سری‌های بار تجزیه‌شده مدلی ارائه شده است. سپس پارامترهای مدل انتخابی توسط روش حداقل مربعات خطا تخمین زده می‌شود. روش ذکرشده دقت قابل قبولی را نشان داد. ولی از مهم‌ترین معایب آن استفاده از داده‌های زیاد بار و نیاز به یک روش دیگر برای تخمین پارامترهای مدل انتخابی بود.

یک روش پیش‌بینی دو مرحله‌ای جدید به نام پیش‌بینی ثانویه بر اساس تجزیه و تحلیل انحراف^۹ (SFDA) پیشنهاد شده است [۲۶]. در این روش روند کلی بار به وسیله روش سری زمانی سنتی پیش‌بینی شد، که مرحله اول پیش‌بینی نام‌گذاری شده است. در مرحله دوم انحراف ناشی از روش‌های سری زمانی با توجه به تأثیر عوامل مرتبط، پیش‌بینی و سپس به نتایج مرحله اول اضافه شده است. داده‌های بار و درجه حرارت به عنوان ورودی برای پیش‌بینی ساعت‌های بعدی در نظر گرفته شده است. روش پیش‌بینی‌کننده‌ی توابع شکل مشابه^{۱۰} (SSP) بر مبنای پیش‌بینی‌های سری زمانی برای پیش‌بینی کوتاه‌مدت معرفی شده است [۲]. از معایب این روش استفاده از نوع روز و داده‌های زیاد می‌باشد. پیش‌بینی کوتاه‌مدت بار با استفاده از روش پردازش داده‌های بزرگ بررسی شده است [۷]. از مزایای این روش پیش‌بینی دقیق بار به دلیل استفاده از پارامترهای مختلف مانند رطوبت بود. از مهم‌ترین معایب این روش پیچیده بودن روش پیشنهادی و استفاده از اطلاعات و پارامترهای زیادی برای رسیدن به پیش‌بینی دقیق بار مصرف‌کننده می‌باشد. از روش‌های بهینه‌سازی چند هدفه نیز برای پیش‌بینی کوتاه‌مدت بار

۲-۱- مدل GM(1,1)

مدل خاکستری مبتنی بر GM(1,1) به‌طور گسترده در کاربردهای مختلف استفاده شده است. الگوریتم GM(1,1) در ادامه تشریح می‌شود [۲۱، ۳۳].

فرض کنید سری داده‌های اصلی سطری به‌صورت رابطه (۱) باشد.

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

که در آن $x^{(0)}$ یک دنباله مثبت و n تعداد داده‌های نمونه‌برداری است. وظیفه مدل GM(1,1) پیش‌بینی مقدار $x^{(0)}(n+1)$ می‌باشد. با اعمال عملیات تولید انباشته^{۱۵} (AGO) به مجموعه ورودی $(x^{(0)})$ ، یک مجموعه جدید به‌صورت رابطه (۲) تولید می‌شود.

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

که $x^{(1)}$ را می‌توان به‌صورت رابطه (۳) بیان کرد.

$$x^{(1)}(k) = \sum_{i=1}^k x^{(0)}(i), \quad k = 1, 2, \dots, n \quad (3)$$

از آنجایی که تمام داده‌های $x^{(0)}$ مثبت هستند، $x^{(1)}$ یک مجموعه صعودی یا منحنی افزایشی است. با توجه به تعریف GM(1,1)، فرض کنیم $x^{(1)}$ می‌تواند با یک معادله دیفرانسیل مرتبه اول طبق رابطه (۴) مدل شود.

$$\frac{dx^{(1)}}{dt} + ax^{(1)}(t) = b \quad (4)$$

که در آن a و b پارامترهایی هستند که می‌توانند تعیین شوند. از آنجایی که $x^{(1)}(k) = x^{(1)}(k+1) - x^{(1)}(k)$ ، رابطه (۴) تقریباً می‌تواند به‌صورت رابطه (۵) بازنویسی شود.

$$x^{(0)}(k+1) + a \frac{x^{(1)}(k+1) + x^{(1)}(k)}{2} = b \quad (5)$$

با استفاده از روش حداقل مربعات خطا، پارامترهای a و b طبق رابطه (۶) به‌دست می‌آید.

$$\begin{bmatrix} a \\ b \end{bmatrix} = (B^T B)^{-1} B^T Y_N \quad (6)$$

که در آن B ماتریس تولید انباشته می‌باشد و طبق رابطه (۷) قابل محاسبه است.

$$B = \begin{bmatrix} -0.5(x^{(1)}(1) + x^{(1)}(2)) & 1 \\ -0.5(x^{(1)}(2) + x^{(1)}(3)) & 1 \\ \dots & \vdots \\ -0.5(x^{(1)}(n-1) + x^{(1)}(n)) & 1 \end{bmatrix} \quad (7)$$

و بردار ثابت Y_N به‌صورت رابطه (۸) خواهد بود.

$$Y_N = [x^{(0)}(2), x^{(0)}(3), \dots, x^{(0)}(n)]^T \quad (8)$$

حل رابطه (۴) یک تابع نمایی و شرایط اولیه $x^{(1)}(1) = x^{(0)}(1)$ است. سپس، مقدار پیش‌بینی $\hat{x}^{(1)}(k+1)$ طبق رابطه زیر به‌دست می‌آید:

$$\hat{x}^{(1)}(k+1) = \left(x^{(0)}(1) - \frac{a}{b} \right) e^{-ak} + \frac{b}{a}, \quad k = 2, \dots, n \quad (9)$$

در رابطه بالا $\hat{x}^{(1)}(1) = x^{(1)}(1)$ می‌باشد. برای به‌دست‌آوردن مقدار پیش‌بینی‌شده از داده‌های اولیه، عملیات تولید انباشته معکوس^{۱۶}

بهینه‌سازی غیرخطی بر اساس الگوریتم ازدحام مورد استفاده قرار گرفته است [۳۲]. در این تحقیقات از مدل‌های خاکستری برای پیش‌بینی بلند مدت استفاده شده است. این درحالی است که برای استفاده از قابلیت این مدل‌ها در پیش‌بینی کوتاه‌مدت نیاز به اعمال تغییرات اساسی است. از آنجایی که مدل‌های خاکستری پیش‌بینی‌های محلی هستند و تعداد داده‌های مورد استفاده در آن‌ها کم می‌باشد روش مبتنی بر تکرار برای آماده‌کردن آن‌ها برای پیش‌بینی کوتاه‌مدت بار پیشنهاد می‌شود. به عبارت دیگر، مدل‌های خاکستری برای تبدیل آن‌ها از پیش‌بینی محلی به پیش‌بینی کلی به‌وسیله تقسیم سری زمانی به چندین بخش و اعمال هر یک از توالی به مدل خاکستری در هر تکرار تعریف می‌شود. برای نشان‌دادن کارایی روش پیشنهادی در حل مسئله پیش‌بینی کوتاه‌مدت بار از داده‌های واقعی شبکه برق ایران و نیویانگلند استفاده شده است. سپس به‌منظور ارزیابی کارآمدی روش پیشنهادی نتایج به‌دست‌آمده از آن با شبکه عصبی مصنوعی، شبکه عصبی-فازی، شبکه عصبی خود سازمانده و رگرسیون بردار پشتیبان مقایسه می‌گردد. نتایج نشان داد که روش‌های بهبودیافته دقت بسیار بالایی نسبت به روش‌های کلی دارند. در میان مدل‌های خاکستری پیشنهادی روش FGM دقت بسیار بالایی را نشان داد. همچنین اثر تعداد داده‌های مورد استفاده و اندازه گام پیش‌بینی در هر تکرار در دقت مدل‌های پیشنهادی مورد بررسی قرار می‌گیرد. بدین ترتیب نوآوری‌های این مقاله به‌شرح زیر می‌باشد:

- توسعه یک روش مبتنی بر تکرار برای تقسیم سری زمانی برای اعمال بر مدل‌های خاکستری
- توسعه مدل غلتان برای پیش‌بینی بار کوتاه‌مدت
- ارزیابی کارایی روش و مدل‌های پیشنهادی در شبکه‌های واقعی

در ادامه ساختار مقاله در بخش‌های زیر تشریح می‌شود: بخش دوم به معرفی مدل‌های خاکستری، در بخش سوم مدل‌سازی و پیش‌بینی کوتاه‌مدت بار به روش پیشنهادی بیان می‌شود. در بخش چهارم داده‌های بار واقعی شبکه برق ایران و منطقه نیویانگلند ایالات متحده مورد مطالعه و نتایج مورد بحث و بررسی قرار می‌گیرد و نهایتاً بخش آخر به نتیجه‌گیری اختصاص یافته است.

۲- مدل‌های خاکستری

سیستم‌های فاقد اطلاعات به‌عنوان سیستم‌های خاکستری شناخته می‌شوند. نظریه سیستم خاکستری یک نظریه بین‌رشته‌ای است که در سال ۱۹۸۲ ارائه و از آن زمان تاکنون در زمینه‌های مختلف به‌کار برده شده است [۲۷]. به‌دلیل اطلاعات و دانش محدود، تنها بخشی از ساختار سیستم می‌تواند به‌طور کامل شناخته شود. نظریه سیستم خاکستری برای غلبه بر این مشکل مطرح و روش مبتنی بر این نظریه برای پیش‌بینی سری زمانی استفاده شده است. پیش‌بینی‌های خاکستری آینده را فقط بر اساس مجموعه‌ای از داده‌های اخیر در یک سری زمانی پیش‌بینی می‌کنند.


که در آن $\tilde{x}^{(0)}$ مقدار پیش‌بینی با استفاده از روش FGM می‌باشد.

۳-۲- مدل‌سازی و پیش‌بینی کوتاه‌مدت بار به روش پیشنهادی

همان‌طور که در بخش قبل بیان گردید، مدل‌های خاکستری پیش‌بینی‌های محلی هستند. با توجه به این حقیقت، دقت آن‌ها در اتصال به داده‌های بزرگ خیلی بالا نیست. بنابراین مدل‌های خاکستری باید برای پیش‌بینی کوتاه‌مدت بار اصلاح شوند. در این مقاله مدل‌های خاکستری با استفاده از یک روش جدید مبتنی بر تکرار به‌عنوان مدل پیش‌بینی بار بهبود داده می‌شوند.

۳-۱- GM(1,1) و FGM بهبود یافته

فرض کنید $m[t]$ به‌عنوان داده‌های بار در نظر گرفته شود. این سری زمانی شامل m داده می‌باشد. همچنین n تعداد داده‌های نمونه‌برداری از سری زمانی می‌باشد، که در هر GM(1,1) استفاده می‌شود. ابتدا تعدادی داده محدود برای پیش‌بینی انتخاب می‌شود. در تکرار اول وظیفه مدل GM(1,1) پیش‌بینی مقدار $n+1$ می‌باشد. در تکرار دوم از داده $n+1$ تا داده $2n$ به‌عنوان ورودی برای GM(1,1) در نظر گرفته می‌شود، همانند تکرار اول وظیفه مدل GM(1,1) پیش‌بینی مقدار داده بعدی یعنی $2n+1$ می‌باشد. به همین منوال این کار برای تکرارهای بعدی نیز انجام می‌شود. سه تکرار از این روش پیشنهادی برای مدل‌سازی و پیش‌بینی بار در شکل ۱ و در شکل ۲ فلوجارت الگوریتم پیشنهادی برای حل مسئله پیش‌بینی بار نشان داده شده است.



شکل ۱: روش پیشنهادی مبتنی بر تکرار: x_0 و \hat{x}_0 به ترتیب بیان‌گر مقادیر واقعی و مقادیر پیش‌بینی شده

$$P = \begin{bmatrix} \frac{1}{2} & \cos(\frac{2\pi.2}{T}) & \sin(\frac{2\pi.2}{T}) & \cos(\frac{2.2\pi.2}{T}) & \sin(\frac{2.2\pi.2}{T}) & \dots & \cos(\frac{k_a.2\pi.2}{T}) & \sin(\frac{k_a.2\pi.2}{T}) \\ \frac{1}{2} & \cos(\frac{2\pi.3}{T}) & \sin(\frac{2\pi.3}{T}) & \cos(\frac{2.2\pi.3}{T}) & \sin(\frac{2.2\pi.3}{T}) & \dots & \cos(\frac{k_a.2\pi.3}{T}) & \sin(\frac{k_a.2\pi.3}{T}) \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ \frac{1}{2} & \cos(\frac{2\pi.n}{T}) & \sin(\frac{2\pi.n}{T}) & \cos(\frac{2.2\pi.n}{T}) & \sin(\frac{2.2\pi.n}{T}) & \dots & \cos(\frac{k_a.2\pi.n}{T}) & \sin(\frac{k_a.2\pi.n}{T}) \end{bmatrix} \quad (15)$$

(IAGO) اعمال می‌شود. بنابراین، مدل خاکستری به‌معادله زیر منجر می‌شود:

$$\hat{x}^{(0)}(k+1) = \hat{x}^{(1)}(k+1) - \hat{x}^{(1)}(k), \quad k = 2, \dots, n \quad (10)$$

معادله (۱۰) مقدار بعدی داده‌های ورودی یعنی مقدار $x^{(0)}(n+1)$ را پیش‌بینی می‌کند.

۲-۲- تصحیح خطای GM(1,1) توسط سری فوریه

روش‌های بسیاری برای افزایش دقت مدل‌های خاکستری به‌وسیله مدل‌سازی مقادیر باقی‌مانده پیش‌بینی خاکستری پیشنهاد شده است. یکی از این روش‌های اصلاح باقی‌مانده از سری فوریه استفاده می‌کند. با اعمال این روش مقدار پیش‌بینی شده به‌مقدار اصلی نزدیک‌تر می‌شود. این روش، مدل خاکستری اصلاح باقی‌مانده به‌روش تبدیل فوریه (FGM) نام دارد [۲۲].

اجازه دهید بردار باقی‌مانده E_r به‌صورت زیر تعریف شود:

$$E_r = [E_r(2), E_r(3), \dots, E_r(n)]^T \quad (11)$$

به‌عبارت دیگر رابطه (۱۱) طبق رابطه زیر به‌دست می‌آید:

$$E_r(k) = x^{(0)}(k) - \hat{x}^{(0)}(k), \quad k = 2, \dots, n \quad (12)$$

که در آن $x^{(0)}$ و $\hat{x}^{(0)}$ به ترتیب بیانگر مقدار واقعی و مقدار پیش‌بینی شده با روش GM(1,1) می‌باشد. سری فوریه می‌تواند سری باقی‌مانده را به‌صورت رابطه (۱۳) تقریب بزند.

$$E(k) = \frac{1}{2}a_0 + \sum_{i=1}^{k_a} \left(a_i \cos\left(\frac{2\pi i}{T}k\right) + b_i \sin\left(\frac{2\pi i}{T}k\right) \right) \quad (13)$$

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

همچنین پارامترهای ثابت a_0 ، a_i و b_i در رابطه (۱۳) با اعمال

روش حداقل مربعات به‌صورت زیر برآورد می‌شود:

$$C = (P^T.P)^{-1}P^T E_r \quad (14)$$

که در آن ماتریس P طبق رابطه (۱۵) به‌دست می‌آید.

با جاگذاری رابطه (۱۱) و (۱۵) در (۱۴) خواهیم داشت:


$$C = [a_0, a_1, b_1, a_2, b_2, \dots, a_{k_a}, b_{k_a}]^T \quad (16)$$

در نهایت سری پیش‌بینی اصلی به‌شکل زیر اصلاح می‌شود:

$$\tilde{x}^{(0)}(k) = \hat{x}^{(0)}(k) + E(k), \quad k = 2, 3, \dots, n \quad (17)$$

۳-۲- مدل خاکستری غلتان

مدل غلتان GM(1,1) بر مبنای انتقال داده‌ها برای ساخت GM(1,1) می‌باشد. این مدل ابتدا با استفاده از داده‌های $x^{(0)}(1)$ تا $x^{(0)}(n)$ ، مدل مقدار داده بعدی یعنی $x^{(0)}(n+1)$ را پیش‌بینی می‌کند. در گام بعدی، اولین داده همواره انتقال داده می‌شود؛ بدین معنی که از داده $x^{(0)}(2)$ تا مقدار پیش‌بینی‌شده 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، مدل خاکستری غلتان نام دارد. شکل ۳ نحوه ی محاسبه سه داده بعدی با استفاده از پنج داده را با مدل RGM نشان می‌دهد.



شکل ۳: مثالی از فرآیند پیش‌بینی با مدل RGM با $n=5$ ، $m=1$ و $k=3$

در شکل ۳، n تعداد داده انتخابی، m تعداد داده پیش‌بینی‌شده در هر حلقه و k عدد غلتان می‌باشد. دلیل انتخاب عدد ۳ برای عدد غلتان پیش‌بینی سه داده بعدی با استفاده از مدل RGM می‌باشد.

۳-۳- ارزیابی دقت مدل‌ها

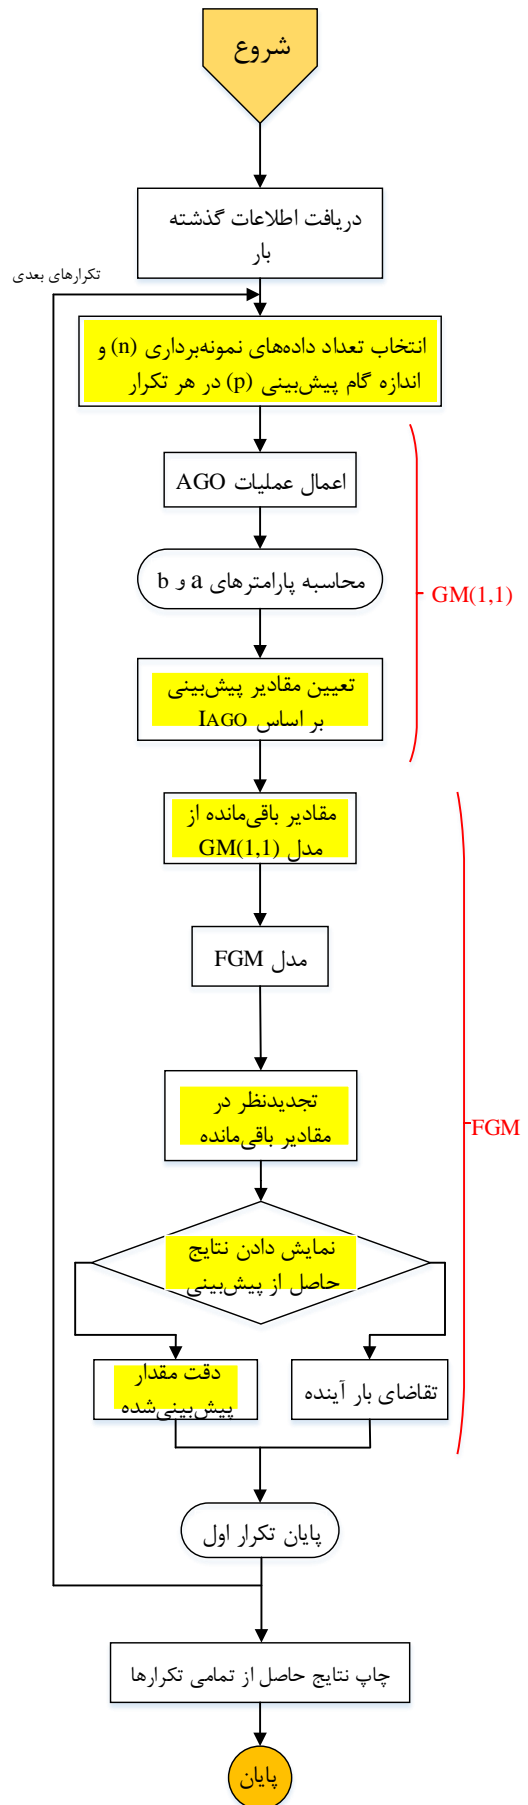
برای ارزیابی دقت مدل‌های پیشنهادی معیارهای مختلفی وجود دارد. این معیارها مقایسه بین مقادیر واقعی و مقادیر پیش‌بینی‌شده انجام می‌دهند. برای مقایسه‌ی کارایی روش‌های پیش‌بینی از معیارهایی مانند میانگین مربعات خطا^{۱۷} (MSE)، میانگین قدر مطلق خطا^{۱۸} (AME) و میانگین قدر مطلق درصد خطا^{۱۹} (MAPE) استفاده می‌شود که با روابط زیر تعریف می‌شوند:

$$MSE = \frac{1}{n} \sum_{k=1}^n (x^{(0)}(k) - \hat{x}^{(0)}(k))^2 \quad (18)$$

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

$$MAPE(\%) = \frac{1}{n} \sum_{k=1}^n \frac{|x^{(0)}(k) - \hat{x}^{(0)}(k)|}{x^{(0)}(k)} \times 100 \quad (20)$$


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



شکل ۲: فلوچارت سیستم پیش‌بینی بار ارائه‌شده

۴- نتایج شبیه‌سازی


در این بخش توانایی مدل‌های خاکستری پیشنهادی مبتنی بر روش تکرار مورد ارزیابی قرار می‌گیرند. از داده‌های شبکه برق ایران و شبکه برق نیویارک برای پیش‌بینی استفاده شده است. در مطالعه اول به منظور شبیه‌سازی و پیش‌بینی بار ۲۴ ساعته با مدل‌های پیشنهادی از داده‌های بار مصرف ساعتی کل ایران استفاده شده است. علت انتخاب این داده‌ها، دردسترس بودن آن‌ها می‌باشد. هدف پیش‌بینی بار ۲۴ ساعته روز جمعه مورخه ۹۳/۱/۸ می‌باشد. برای دستیابی به بهترین عملکرد GM(1,1) در هر تکرار حداقل داده به عنوان 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 که در هر تکرار GM(1,1) متفاوت تولید خواهد شد، چرا که 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 مدل‌های خاکستری تولیدشده، بار ۲۴ ساعته مدل می‌شود. شکل ۴ تغییرات پیش‌بینی به کمک سه مدل پیشنهادی را برای ۲۴ ساعت نشان می‌دهد. نمودار درصد خطای مدل‌های پیشنهادی بین مقدار واقعی و مقدار پیش‌بینی شده برای ۲۴ ساعت در شکل ۵ نشان داده شده است.



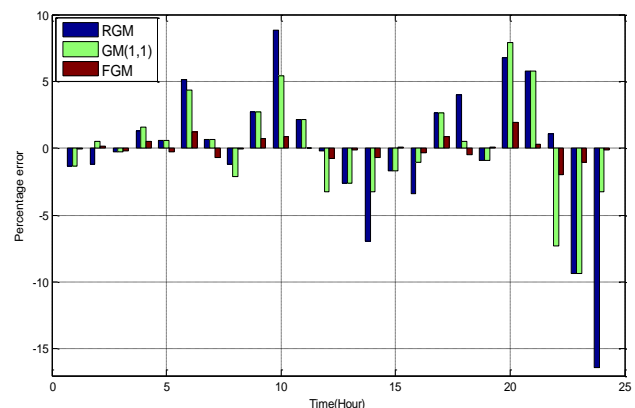
شکل ۴: تغییرات پیش‌بینی بار ۲۴ ساعت به کمک مدل‌های پیشنهادی

همچنین در جدول ۱ نتایج پیش‌بینی بار با مدل‌های پیشنهادی داده شده است. لازم به ذکر است که مقادیر داده‌شده برای بار واقعی و پیش‌بینی شده برحسب پریونیت (pu) می‌باشد. طبق جدول ۱ در مدل GM(1,1) مقادیر خطای MSE، AME و MAPE به ترتیب ۰/۰۰۸۹، ۰/۰۷۰۳ و ۲/۹۷۱۸٪ است. برای افزایش دقت مدل پیشنهادی، روش FGM به کار برده شده است و در هر تکرار نتایج GM(1,1) اصلاح می‌شود. MSE، AME و MAPE برای مدل FGM به ترتیب 10^{-4} × ۳/۵۳۹۸، ۰/۰۱۳۱ و ۰/۵۶۷۶٪ می‌باشد. این نتایج نشان می‌دهد که استراتژی اصلاح باقی‌مانده در افزایش دقت پیش‌بینی به طور موفقیت آمیزی عمل می‌کند. به عنوان مثال خطای MAPE تقریباً ۸۱٪ بهبود یافته است. همچنین مقادیر مربوط به خطای MSE، AME و MAPE در مدل خاکستری غلتان به ترتیب ۰/۰۱۵۷، ۰/۰۸۵۱ و ۳/۶۲۸۸٪ می‌باشد. دقت این روش پایین‌تر از مدل پیشنهادی GM(1,1) و به طور واضح پایین‌تر از FGM است. به عنوان مثال MAPE مدل غلتان تقریباً ۱۹٪ بیشتر از MAPE مدل GM(1,1) پیشنهادی و ۸۵٪ بیشتر از MAPE مدل FGM می‌باشد.

تا این بخش مدل‌های متفاوت خاکستری شبیه‌سازی شد و بالاترین خطا ۳/۶۲۸۸٪ در بدترین مدل است که مربوط به مدل غلتان می‌باشد و در میان روش‌های شبیه‌سازی شده، روش FGM اصلاح‌شده بهترین عملکرد و بالاترین دقت را نشان داد. به منظور نشان دادن عملکرد بالای مدل‌های خاکستری بهبودیافته نسبت به مدل‌های خاکستری معمول (غیر بهبودیافته) در شکل ۶ نتایج حاصل از پیش‌بینی بار با مدل‌های خاکستری معمول نشان داده شده است. طبق شکل، سه مدل معمول GM(1,1)، FGM و مدل خاکستری غلتان قادر به رهگیری و تقریب پروفیل بار نمی‌باشند، این در حالی است که مدل‌های خاکستری بهبودیافته که در شکل ۴ نشان داده شد، می‌توانند پروفیل بار را مدل و پیش‌بینی نمایند.




شکل ۶: نتایج حاصل از پیش‌بینی با استفاده از مدل‌های خاکستری معمولی



شکل ۵: درصد خطای مدل‌های پیشنهادی برای ۲۴ ساعت

جدول ۱: نتایج پیش‌بینی بار با استفاده از مدل‌های پیشنهادی

ساعت	بار واقعی	GM(1,1)		FGM		RGM	
		پیش‌بینی	خطا(%)	پیش‌بینی	خطا(%)	پیش‌بینی	خطا(%)
۱	۲/۳۳۷۲	۲/۳۶۷۶	-۱/۳۰۲۸	۲/۳۳۸۷	-۰/۰۶۴۷	۲/۳۶۷۶	-۱/۳۰۲۸
۲	۲/۲۴۹۴	۲/۲۳۷۶	۰/۵۲۴۲	۲/۲۴۵۳	۰/۱۸۱۰	۲/۲۷۵۹	-۱/۱۷۶۶
۳	۲/۱۴۸۲	۲/۱۵۳۸	-۰/۲۶۳۰	۲/۱۵۲۵	-۰/۲۰۰۲	۲/۱۵۳۸	-۰/۲۶۳۰
۴	۲/۰۹۶۱	۲/۰۶۲۳	۱/۶۱۳۰	۲/۰۸۴۹	۰/۵۳۷۹	۲/۰۶۹۴	۱/۲۷۵۱
۵	۲/۰۲۷۳	۲/۰۱۵۰	۰/۶۰۳۴	۲/۰۳۲۰	-۰/۲۳۳۹	۲/۰۱۵۰	۰/۶۰۳۴
۶	۲/۰۶۲۷	۱/۹۷۲۵	۴/۳۷۲۷	۲/۰۳۷۱	۱/۲۴۱۷	۱/۹۵۷۰	۵/۱۲۸۰
۷	۲/۰۴۲۰	۲/۰۲۸۶	۰/۶۵۶۵	۲/۰۵۶۰	-۰/۶۸۶۵	۲/۰۲۸۶	۰/۶۵۶۵
۸	۲/۰۱۶۵	۲/۰۵۸۷	-۲/۰۹۳۲	۲/۰۱۷۷	-۰/۰۵۸۴	۲/۰۴۰۸	-۱/۲۰۷۷
۹	۲/۰۵۰۳	۱/۹۹۴۶	۲/۷۱۹۵	۲/۰۳۵۶	۰/۷۲۰۴	۱/۹۹۴۶	۲/۷۱۹۵
۱۰	۲/۱۶۱۸	۲/۰۴۴۷	۵/۴۱۶۶	۲/۱۴۲۴	۰/۸۹۶۶	۱/۹۷۰۷	۸/۸۳۸۵
۱۱	۲/۲۷۶۰	۲/۲۲۶۵	۲/۱۷۵۳	۲/۲۷۶۲	-۰/۰۰۸۰	۲/۲۲۶۵	۲/۱۷۵۳
۱۲	۲/۳۲۲۴	۲/۳۹۷۸	-۳/۲۴۶۳	۲/۳۴۰۸	-۰/۷۹۵۰	۲/۳۲۷۴	-۰/۲۱۶۸
۱۳	۲/۳۵۵۸	۲/۴۱۷۷	-۲/۶۲۷۰	۲/۳۵۹۶	-۰/۱۵۹۴	۲/۴۱۷۷	-۲/۶۲۷۰
۱۴	۲/۳۲۲۸	۲/۳۹۸۹	-۳/۲۷۶۶	۲/۳۳۹۶	-۰/۷۲۱۸	۲/۴۸۴۳	-۶/۹۵۴۳
۱۵	۲/۲۹۵۳	۲/۳۳۴۱	-۱/۶۹۰۷	۲/۲۹۳۹	۰/۰۵۹۹	۲/۳۳۴۱	-۱/۶۹۰۷
۱۶	۲/۲۴۰۵	۲/۲۶۴۷	-۱/۰۷۹۸	۲/۲۴۷۴	-۰/۳۰۸۲	۲/۳۱۵۸	-۳/۳۶۲۹
۱۷	۲/۲۶۵۰	۲/۲۰۵۲	۲/۶۴۲۰	۲/۲۴۵۴	۰/۸۶۵۸	۲/۲۰۵۲	۲/۶۴۲۰
۱۸	۲/۲۴۸۲	۲/۲۳۶۷	۰/۵۱۲۲	۲/۲۵۸۵	-۰/۴۵۹۵	۲/۱۵۸۲	۴/۰۰۲۷
۱۹	۲/۲۳۸۹	۲/۲۵۹۰	-۰/۸۹۴۷	۲/۲۳۷۰	۰/۰۸۴۵	۲/۲۵۹۰	-۰/۸۹۴۷
۲۰	۲/۴۱۵۴	۲/۲۲۴۷	۷/۸۹۶۳	۲/۳۶۹۰	۱/۹۲۲۴	۲/۲۵۱۳	۶/۷۹۵۱
۲۱	۲/۶۲۷۸	۲/۴۷۵۳	۵/۸۰۴۳	۲/۶۲۰۲	۰/۲۸۹۶	۲/۴۷۵۳	۵/۸۰۴۳
۲۲	۲/۶۴۸۲	۲/۸۴۲۲	-۷/۳۲۶۶	۲/۷۰۰۴	-۱/۹۷۳۲	۲/۶۲۰۲	۱/۰۵۵۲
۲۳	۲/۵۶۲۹	۲/۸۰۱۹	-۹/۳۲۸۲	۲/۵۸۹۹	-۱/۰۵۳۹	۲/۸۰۱۹	-۹/۳۲۸۲
۲۴	۲/۴۶۸۶	۲/۵۴۹۱	-۳/۲۵۸۸	۲/۴۷۱۱	-۰/۰۹۸۸	۲/۸۷۲۷	-۱۶/۳۷۰۲
MSE		۰/۰۰۸۹		۰/۰۰۰۳		۰/۰۱۵۷	
AME		۰/۰۷۰۳		۰/۰۱۳۲		۰/۰۸۵۱	
MAPE(%)		۲/۹۷۱۸		۰/۵۶۷۶		۳/۶۲۸۸	




شکل ۷: مقایسه‌ی تغییرات پیش‌بینی بار با مدل‌های پیشنهادی و دو روش ANN و ANFIS

برای مقایسه کارایی مدل‌های پیشنهادی، این مدل‌ها با دیگر روش‌های پیش‌بینی بار مانند شبکه عصبی مصنوعی (ANN) و یک شبکه عصبی- فازی (ANFIS) مقایسه گردید. شکل ۷ مقایسه‌ی تغییرات مقادیر واقعی و پیش‌بینی شده با مدل‌های خاکستری پیشنهادی و دو روش ANN و ANFIS را نشان می‌دهد. همچنین در شکل ۸ مقایسه بین دقت مدل‌های پیشنهادی و دو روش سنتی ذکر شده، داده شده است. همان‌طور که انتظار می‌رفت طبق نتایج سایر تحقیقات [۲۲-۲۰] انجام شده دقت مدل‌های پیشنهادی بالاتر از روش‌های مبتنی بر یادگیری می‌باشد. دلیل این امر نیز عدم رهگیری این روش‌ها در تغییرات خارج از الگو می‌باشد.

معکوسی بر دقت گذاشته و خطا افزایش پیدا می‌کند. همچنین نتایج نشان می‌دهد که پیش‌بینی‌های دورتر خطای بالاتری نسبت به پیش‌بینی‌های نزدیک‌تر دارند. به عبارت دیگر هرچه محدوده پیش‌بینی شده از لحاظ زمانی به داده‌ها نزدیک‌تر باشد خطا کمتر است. این نتیجه خصلت ذاتی هر نوع پیش‌بینی می‌باشد. برای تعدادی مشخص از داده‌های ورودی دقت مدل FGM بالاترین و دقت مدل غلتان پایین‌ترین می‌باشد.

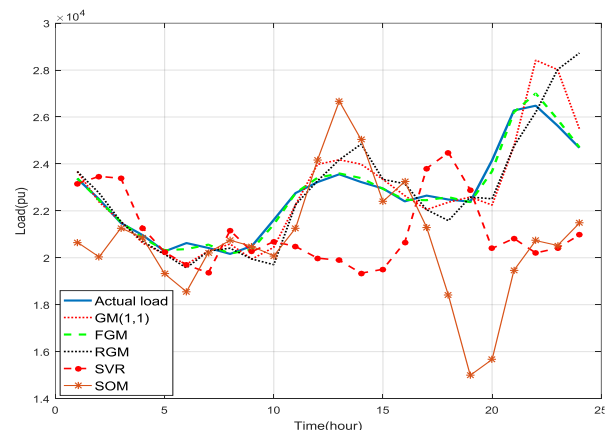
جدول ۲: مقایسه خطای مدل‌های پیشنهادی به ازای n و p های متفاوت

model	n	p	MSE	AME	MAPE(%)
GM(1,1)	۴	۱	۰/۰۰۸۹	۰/۰۷۰۳	۲/۹۷۱۸
		۲	۰/۰۱۸۳	۰/۰۹۱۱	۳/۸۷۳۱
		۳	۰/۰۶۳۴	۰/۱۵۸۹	۶/۶۵۸۱
	۵	۱	۰/۰۱۲۵	۰/۰۸۲۹	۳/۵۰۳۹
		۲	۰/۰۲۸۸	۰/۱۲۲۰	۵/۱۵۴۵
		۳	۰/۰۴۷۱	۰/۱۶۰۳	۶/۸۳۶۱
	۶	۱	۰/۰۱۶۱	۰/۰۹۶۱	۴/۱۰۸۴
		۲	۰/۰۳۲۱	۰/۱۴۲۰	۶/۰۶۲۹
		۳	۰/۰۴۳۱	۰/۱۷۰۳	۷/۴۰۳۷
FGM	۴	۱	۰/۰۰۰۳	۰/۰۱۳۱	۰/۵۶۷۶
		۲	۰/۰۰۵۲	۰/۰۵۱۱	۲/۱۶۸۶
		۳	۰/۰۱۵۹	۰/۰۷۹۵	۳/۳۲۹۵
	۵	۱	۰/۰۰۳۹	۰/۰۴۵۰	۱/۹۰۵۶
		۲	۰/۰۰۹۲	۰/۰۶۹۶	۲/۹۳۹۷
		۳	۰/۰۱۹۸	۰/۱۰۵۲	۴/۴۶۱۵
	۶	۱	۰/۰۰۶۳	۰/۰۶۲۷	۲/۶۷۹۸
		۲	۰/۰۱۴۷	۰/۰۹۹۰	۴/۲۲۳۳
		۳	۰/۰۱۸۱	۰/۱۱۰۲	۴/۷۶۷۶
RGM	۴	m=۱, k=۲	۰/۰۱۵۷	۰/۰۸۵۱	۳/۶۲۸۸
		m=۱, k=۳	۰/۰۶۲۴	۰/۱۵۶۱	۶/۵۳۰۴
		m=۱, k=۴	۰/۰۴۱۳	۰/۱۵۸۲	۶/۹۱۱۳
	۵	m=۱, k=۲	۰/۰۲۵۷	۰/۱۱۴۵	۴/۸۴۳۲
		m=۱, k=۳	۰/۰۴۹۹	۰/۱۵۵۹	۶/۶۱۰۲
		m=۱, k=۴	۰/۰۴۰۲	۰/۱۶۲۴	۷/۱۳۱۴
	۶	m=۱, k=۲	۰/۰۳۰۵	۰/۱۳۶۶	۵/۸۱۷۶
		m=۱, k=۳	۰/۰۴۳۶	۰/۱۶۵۱	۷/۱۲۲۴
		m=۱, k=۴	۰/۰۴۶۴	۰/۱۸۲۵	۸/۰۴۴۴



شکل ۸: مقایسه دقت مدل‌های خاکستری پیشنهادی و دو روش ANFIS و ANN


به منظور ارزیابی عملکرد مدل‌های پیشنهادی با تحقیقات انجام شده در قسمت مقدمه، این مدل‌ها با دو روش SOM و SVR طبق شکل ۹ مقایسه شده است. همان‌طور که مشهود است مدل‌های پیشنهادی عملکرد بهتری نسبت به دو روش ذکر شده دارند. SOM و SVR در بهترین عملکرد خود به ترتیب مقادیر خطای ۸/۹۳٪ و ۱۰/۸۲٪ را نشان دادند.




شکل ۹: مقایسه تغییرات پیش‌بینی بار با مدل‌های پیشنهادی و دو روش SOM و SVR

با توجه به این که مدل‌های خاکستری با استفاده از داده‌های اخیر و محدود ساخته شده و تغییرات داده‌ها را به خوبی مدل می‌کنند ولی در عین حال معیاری جهت انتخاب بهینه تعداد داده‌ها در کارهای تحقیقاتی گذشته مشاهده نشده است. به همین دلیل انتخاب تعداد داده به عنوان یکی از عوامل دخیل در دقت پیش‌بینی در این مقاله مورد بحث قرار گرفته است. در جدول ۲ چگونگی تأثیر دو عامل تعداد داده مورد استفاده در هر مدل خاکستری (n) و گام پیش‌روی پیش‌بینی (p) در دقت پیش‌بینی مورد بررسی قرار گرفته است.

نتایج نشان می‌دهد با افزایش تعداد داده‌های استفاده شده در هر مدل خاکستری خطا افزایش پیدا می‌کند. دلیل این امر این است که ماهیت مدل خاکستری یک برآزش نمایی بوده و افزایش تعداد داده‌ها اثر




شکل ۱۲: تغییرات بار پیش‌بینی‌شده با روش GM(1,1) پیشنهادی و تعداد داده‌های متفاوت



شکل ۱۳: درصد خطای روش GM(1,1) پیشنهادی برای ۲۴ ساعت با تعداد داده‌های متفاوت

شکل ۱۴ و ۱۵ به ترتیب تغییرات پیش‌بینی بار و درصد خطا را با اندازه گام پیش‌بینی متفاوت با استفاده از مدل FGM نشان می‌دهد. به ازای افزایش اندازه گام پیش‌بینی از یک به دو، مقدار MAPE از 0.183% ، 0.911% و 3.8731% تغییر پیدا کرده و مقدار MAPE 30% به افزایش یافته است. همچنین افزایش تعداد داده‌های انتخابی به پنج منجر به افزایش MAPE از 2.9718% به 3.5039% می‌شود و در این حالت مقدار MAPE به 18% افزایش می‌یابد.


شکل ۱۶ و ۱۷ به ترتیب تغییرات پیش‌بینی بار و درصد خطا را با تعداد داده‌های متفاوت با استفاده از مدل FGM نشان می‌دهد. همان‌طور که از شکل مشخص است، افزایش تعداد داده‌ها باعث کاهش دقت پیش‌بینی می‌شود.




شکل ۱۴: تغییرات بار پیش‌بینی‌شده با روش FGM پیشنهادی و اندازه گام پیش‌بینی متفاوت

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 پیش‌بینی‌شده و دقت مدل‌های پیشنهادی مورد بررسی قرار می‌گیرد. تغییرات بار پیش‌بینی‌شده با استفاده از مدل GM(1,1) برای ۲۴ ساعت با اندازه گام پیش‌بینی متفاوت در شکل ۱۰ نشان داده شده است. همچنین شکل ۱۱ درصد خطای پیش‌بینی ۲۴ ساعت با استفاده از این روش به‌ازای اندازه گام پیش‌بینی متفاوت را نشان می‌دهد. با افزایش اندازه گام پیش‌بینی از یک به دو، مقادیر مربوط به سه معیار MSE، AME و MAPE به ترتیب به 0.183% ، 0.911% و 3.8731% تغییر پیدا کرده و مقدار MAPE 30% افزایش یافته است. همچنین افزایش تعداد داده‌های انتخابی به پنج منجر به افزایش MAPE از 2.9718% به 3.5039% می‌شود و در این حالت مقدار MAPE به 18% افزایش می‌یابد.

شکل ۱۲ تغییرات بار پیش‌بینی‌شده به‌ازای تعداد داده‌های انتخابی متفاوت و شکل ۱۳ درصد خطای ساعتی این پیش‌بینی را با مدل GM(1,1) پیشنهادی نشان می‌دهد. همان‌طور که از شکل مشخص است با افزایش تعداد داده‌های نمونه‌برداری خطای منحنی‌های بار پیش‌بینی شده افزایش می‌یابد.




شکل ۱۵: تغییرات بار پیش‌بینی‌شده با مدل GM(1,1) پیشنهادی و اندازه گام پیش‌بینی متفاوت



شکل ۱۶: درصد خطای مدل GM(1,1) پیشنهادی برای ۲۴ ساعت با اندازه گام پیش‌بینی متفاوت

همان‌طور که از جدول قابل مشاهده است میانگین خطای پیش‌بینی روز پیشرو ۰/۷۹٪ می‌باشد.




شکل ۱۸: مقایسه خطای پیش‌بینی (MAPE) به‌ازای تعداد داده‌ها و اندازه گام پیش‌بینی متفاوت

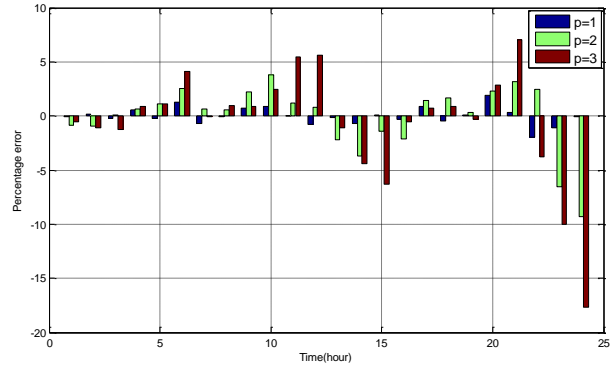
جدول ۳: خطای پیش‌بینی در چهار فصل نیویارک

Day	Winter Jan ۱۱-۱۷	Spring April ۱۲-۱۸	Summer July ۱۹-۲۵	Autum Nov ۸-۱۴	میانگین خطای روز پیشرو
	FGM	FGM	FGM	FGM	
Mon	۰/۹۱	۱	۰/۷۵	۰/۹۱	۰/۸۹
Tues	۰/۸۱	۰/۷۵	۰/۶۵	۰/۸۳	۰/۷۶
wed	۰/۹	۰/۸۹	۰/۶	۰/۹۴	۰/۸۳
Thurs	۰/۸	۰/۹۷	۰/۷۱	۰/۸۷	۰/۸۳
Fri	۰/۸۲	۰/۸۹	۰/۵۸	۱	۰/۸۲
Sat	۰/۷۴	۰/۶۶	۰/۶۶	۰/۹۸	۰/۷۶
Sun	۰/۷۱	۰/۷۱	۰/۵۸	۰/۷۹	۰/۶۹
میانگین	۰/۸۱	۰/۸۳	۰/۶۴	۰/۹	۰/۷۹


با توجه به جدول ۳ دقت پیش‌بینی بار مدل پیشنهادی FGM برای فصل پاییز به‌صورت جزئی بالاتر از سایر فصل‌ها می‌باشد. در شکل ۱۹ تغییرات پیش‌بینی بار در فصل پاییز نشان داده شده است. همچنین با توجه به جدول ۳ دقت پیش‌بینی مدل پیشنهادی برای روزهای متفاوت بین دو مقدار ۰/۶٪ تا ۱٪ تغییر کرد.




شکل ۱۹: تغییرات پیش‌بینی بار در فصل پاییز (۸-۱۴ Nov) توسط مدل پیشنهادی FGM



شکل ۱۵: درصد خطای روش FGM پیشنهادی برای ۲۴ ساعت با اندازه گام پیش‌بینی متفاوت



شکل ۱۶: تغییرات بار پیش‌بینی شده با روش FGM پیشنهادی و تعداد داده‌های متفاوت



شکل ۱۷: درصد خطای روش FGM پیشنهادی برای ۲۴ ساعت با تعداد داده‌های متفاوت

شکل ۱۸ مقایسه مقادیر MAPE برای ۲۴ ساعت را به‌ازای تعداد داده‌ها و اندازه گام پیش‌بینی متفاوت توسط سه روش پیشنهادی نشان می‌دهد. با افزایش اندازه گام پیش‌بینی و تعداد داده‌های نمونه‌برداری مقادیر خطا افزایش یافته است. به‌عبارت دیگر افزایش اندازه گام پیش‌بینی و تعداد داده‌های نمونه‌برداری باعث کاهش دقت پیش‌بینی می‌شود. از طرفی دیگر در پیش‌بینی بار ۲۴ ساعتی مقدار MAPE کمتر از ۵٪ است. این مقدار خطا برای پیش‌بینی بار مورد قبول می‌باشد. در مطالعه‌ی دوم از داده‌های بار مصرف منطقه نیویارک برای پیش‌بینی بار روزهای متفاوت از فصول مختلف استفاده شده است. جدول ۳ خطای (MAPE) پیش‌بینی بار روزهای متفاوت پیش‌رو مربوط به چهار فصل منطقه نیویارک و میانگین خطای (MAPE) ایام هفته و روز پیشرو را با استفاده از مدل پیشنهادی FGM نشان می‌دهد.

۵- نتیجه‌گیری

در این مقاله پیش‌بینی بار مصرفی ۲۴ ساعته ایران انجام شد. پیش‌بین‌های محلی خوب با دقت بالا نظیر مدل‌های مبتنی بر نظریه خاکستری برای مدل‌سازی و پیش‌بینی کوتاه‌مدت بار به‌کار گرفته شد. مدل‌های $GM(1,1)$ ، FGM و مدل خاکستری غلتان با استفاده از یک روش مبتنی بر تکرار بهبود داده شد. طبق نتایج حاصل از معیار خطا، سه مدل ذکرشده به‌ترتیب به مقادیر خطای ۰.۰۵۶۷۶% ، ۰.۲۰۹۷۱۸% و ۰.۳۰۶۲۸۸% در بهترین حالت یعنی زمانی که از حداقل داده و اندازه گام پیش‌بینی استفاده می‌کردند، دست یافتند. مشاهده شد که کمترین خطا مربوط به مدل FGM است که بالاترین دقت را نشان داد و دقت مدل $GM(1,1)$ بهتر از مدل خاکستری غلتان بود. مشاهده شد که مدل‌های خاکستری پیشنهادی برای رسیدن به این دقت بالا به غیر از داده‌های بار به هیچ پارامتر دیگری مانند دما و ... نیاز نداشتند. همچنین کارایی این مدل‌های پیشنهادی با چهار روش کلی ANN ، $ANFIS$ ، SVR و SOM مقایسه شد. چهار روش کلی ذکرشده به‌ترتیب به مقادیر خطای ۰.۱۲۰۳۱% ، ۰.۷۰۳۵% ، ۰.۸۰۹۳% و ۰.۱۰۸۲% در بهترین عملکرد خود دست یافتند. با مقایسه خطای مدل‌های خاکستری پیشنهادی و سایر روش‌های کلی بررسی‌شده، خطای روش‌های کلی در مقایسه با روش‌های محلی در استفاده از تعداد داده‌های کم برای پیش‌بینی بار بسیار بالا بود. پس روش‌های کلی در مواقعی که تعداد داده‌های زیادی در دسترس نباشد، کارایی مناسبی نخواهند داشت. بنابراین طرح پیش‌بینی محلی جدید عملکرد خیلی بهتری نسبت به طرح‌های کلی نشان داد. سپس تأثیر تعداد داده‌ها و اندازه گام پیش‌بینی در دقت مدل‌های پیشنهادی بررسی شد. نتایج حاکی از این بود که با افزایش تعداد داده‌ها و اندازه گام پیش‌بینی خطای مدل‌ها افزایش یافت. در مرحله آخر، پیش‌بینی بار ۲۴ ساعت (روزانه) برای فصل‌های مختلف منطقه نیویورک انجام پذیرفت. در این مورد نیز روش پیشنهادی کارایی مطلوب خود را نمایان ساخت.

مراجع

- [6] S. Fattaheian, A. Fereidunian, H. Gholami-Dehkordi and H. Lesani, "Hour-ahead demand forecasting in smart grid using support vector regression (SVR)," *International Transactions Electric Energy Systems*, vol. 24, no. 12, pp. 1650-1663, 2013.
- [7] Z. Pei, X. Wu, X. Wang and S. Bi, "Short-term load forecasting based on big data technologies," *CSEE Journal of Power and Energy Systems*, vol. 1, no. 3, pp. 59-67, 2015.
- [8] Y. Goude, R. Nedellec and N. Kong "Local Short and Middle Term Electricity Load Forecasting With Semi-Parametric Additive Models," *IEEE Transactions on Smart Grid*, vol. 5, no. 1, pp. 440-446, 2014.
- [9] G. P. Box and G. M. Jenkins, *Time Series Analysis: Forecasting and Control*, New York: Wiley, 2008.
- [10] Y. Chakhchoukh, P. Panciatici and L. Mili, "Electric Load Forecasting Based on Statistical Robust Methods," *IEEE Transactions on Power Systems*, vol. 26, no. 3, pp. 982-991, 2011.
- [11] N. Amjady, "Short-term hourly load forecasting using time-series modeling with peak load estimation capability," *IEEE Transactions on Power Systems*, vol. 16, no. 3, pp. 498-505, 2001.
- [12] S. Huang and K. Shih, "Short-term load forecasting via ARMA model identification including non-Gaussian process considerations," *IEEE Transactions on Power Systems*, vol. 18, no. 2, pp. 673-679, 2003.
- [13] T. H. K. Yu and K. H. Huang, "A neural network-based fuzzy time series model to improve forecasting," *Expert Systems with Applications*, vol. 37, no. 4, pp. 3366-3372, 2010.
- [14] C. N. Ko and C. M. Lee, "Short-term load forecasting using SVR (support vector regression)-based radial basis function neural network with dual extended Kalman filter," *Energy*, vol. 49, no. 1, pp. 413-422, 2013.
- [15] L. X. Wang and J. M. Mendel, "Generating fuzzy rules by learning from examples," *IEEE Trans. Syst., Man, Cybern*, vol. 22, no. 6, pp. 1414-1427, 1992.
- [16] J. A. Dickerson and B. Kosko, "Fuzzy function approximation with ellipsoidal Rules," *IEEE Trans. Syst., Man, Cybern. Part B: Cybernetics*, vol. 26, no. 4, pp. 542-560, 1996.
- [17] S. Valero and J. Aparicio, "Comparative analysis of Self Organizing Maps vs. multilayer perceptron neural networks for short-term load forecasting," *Modern Electric Power Systems (MEPS), Proceedings of the International IEEE Symposium*, pp. 1-5, 2010.
- [18] C.C. Hsu and C.Y. Chen, "Applications of improved grey prediction model for power demand forecasting," *Energy Conversion and management*, vol. 44, no. 14, pp. 2241-2249, 2003.
- [19] K. Kandanand, "Forecasting Electricity Demand in Thailand with an Artificial Neural Network Approach," *Energies*, vol. 4, no. 8, pp. 1246-1257, 2011.
- [20] C. B. Lin, S. F. Su and Y. T. Hsu, "High precision forecast using grey models," *International Journal of Systems Science*, vol. 32, no. 5, pp. 609-619, 2001.
- [21] 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.
- [22] A. Dejamkhooy and A. Dastfan, "Modeling and forecasting non-stationary voltage fluctuation based on grey system theory," *IEEE Transactions on Power Delivery*, DOI: 10.1109/TPWRD.2014.2386696, in press, 2015.
- [23] A. Shekhar Pandey, D. Singh and S. Kumar Sinha, "Intelligent Hybrid Wavelet Models for Short-Term Load Forecasting," *IEEE Transactions on Power Systems*, vol. 25, no. 3, pp. 1266-1273, 2010.
- [۲۴] حسین شایقی و علی قاسمی، «پیش‌بینی قیمت روزانه برق با شبکه عصبی بهبودیافته مبتنی بر تبدیل موجک و روش آشوبناک جستجوی گرانشی»، *مجله مهندسی برق دانشگاه تبریز*، جلد ۴۵، شماره ۴، زمستان ۱۳۹۴.
- [۲۵] فرشته صادقی، ابوالفضل جلیلود، سیدهادی حسینی و منیژه صفاری، «ارائه یک روش ترکیبی مبتنی بر تبدیل موجک گسسته برای پیش‌بینی
- [1] M. Tucci, E. Crisostomi, G. Giunta and M. Raugi, "A Multi-Objective Method for Short-Term Load Forecasting in European Countries," *IEEE Transactions on Power Systems*, vol. 31, no. 5, pp. 3537-3547, 2016.
- [2] E. Paparoditis and T. Sapatinas, "Short-Term Load Forecasting: The Similar Shape Functional Time-Series Predictor," *IEEE Transactions on Power Systems*, vol. 28, no. 4, pp. 3818-3825, 2013.
- [3] C. Cecati, J. Kolbusz, P. Rózycki, P. Siano and B. M. Wilamowski, "A novel RBF training algorithm for short-term electric load forecasting and comparative studies," *IEEE Transactions on Industrial Electronics*, vol. 62, no. 10, pp. 6519-6529, 2015.
- [4] H. Yu-Hsiang, "Household electricity demand forecast based on context information and user daily schedule analysis from meter data," *IEEE Transactions on Industrial Informatics*, vol. 11, no. 1, pp. 33-43, 2015.
- [5] L. Song, P. Wang and L. Goel, "A novel wavelet-based ensemble method for short-term load forecasting with hybrid neural networks and feature selection," *IEEE Transactions on Power Systems*, vol. 31, no. 3, pp. 1788-1798, 2016.

- [30] 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.
- [31] H. Zhao and S. Guo, "An optimized grey model for annual power load forecasting," *Energy*, vol. 107, pp. 272-286, 2016.
- [32] 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.
- [33] 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, 2010.
- بار الکتریکی با استفاده از یک مدل دو بعدی»، *مجله مهندسی برق دانشگاه تبریز*، جلد ۴۵، شماره ۳، پاییز ۱۳۹۴.
- [26] Y. Wang, Q. Xia and C. Kang, "Secondary Forecasting Based on Deviation Analysis for Short-Term Load Forecasting," *IEEE Transactions on Power Systems*, vol. 26, no. 2, pp. 500-507, 2011.
- [27] S. Liu and Y. Liu, *Grey Systems: Theory and Applications*, Berlin, Germany: Springer-Verlag, 2010.
- [28] 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.
- [29] 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.

زیر نویس‌ها

- | | |
|--|--|
| ¹¹ Rolling Grey Model | ¹ Global |
| ¹² fourier residual correction grey model | ² Local |
| ¹³ Hybrid Optimization Grey Model | ³ Autoregressive Moving Average |
| ¹⁴ Improved-response Grey Prediction Model | ⁴ Autoregressive Integrated Moving Average |
| ¹⁵ Accumulating Generation Operator | ⁵ Global Approximators |
| ¹⁶ Inverse Accumulating Generation Operator | ⁶ Multilayer Perceptron Neural Network |
| ¹⁷ Mean Square Error | ⁷ Self-Organizing Map Neural Network |
| ¹⁸ Error Absolute Mean | ⁸ Grey Model |
| ¹⁹ Mean Absolute Percentage Error | ⁹ Secondary Forecasting based on Deviation Analysis |
| | ¹⁰ Similar Shape Functional Pridector |