

پیش‌بینی نیاز مصرف فصلی شبکه برق ایران با استفاده از روش ترکیبی رگرسیون بردار پشتیبان و الگوریتم بهینه‌سازی مگس میوه

پریا سلیمانی^{۱*}، زهره یعقوبی^۲

۱. استادیار مهندسی صنایع، دانشگاه آزاد اسلامی، واحد تهران جنوب

۲. کارشناس ارشد مهندسی صنایع، دانشگاه آزاد اسلامی، واحد تهران جنوب

(تاریخ دریافت: ۹۶/۰۱/۱۷ تاریخ دریافت روایت اصلاح‌شده: ۹۷/۰۵/۲۹ تاریخ تصویب: ۹۷/۰۹/۱۲)

چکیده

پیش‌بینی دقیق نیاز مصرف شبکه برق ماهانه می‌تواند در برنامه‌ریزی انرژی مؤثر باشد و مدیریت صحیح‌تر مصرف برق را امکان‌پذیر کند. نیاز مصرف برق ماهانه نشان‌دهنده گرایش فصلی پیچیده و غیرخطی است یکی از مدل‌هایی که به‌طور گسترده برای پیش‌بینی سری‌های زمانی غیرخطی استفاده می‌شود، رگرسیون بردار پشتیبان (SVR) است که در آن باید انتخاب پارامترهای کلیدی و تأثیر تغییرات فصلی در نظر گرفته شود؛ بنابراین ضروری است پارامترهای مدل رگرسیون بردار پشتیبان به‌صورت مناسب انتخاب شوند و گرایش‌های غیرخطی و فصلی داده‌های نیاز مصرف برق تعدیل شوند. روشی که در پژوهش حاضر پیشنهاد می‌شود، پیوند زدن مدل رگرسیون بردار پشتیبان (SVR) با الگوریتم بهینه‌سازی مگس میوه (FOA) و تنظیم شاخص فصلی برای پیش‌بینی نیاز مصرف برق ماهانه است. علاوه بر این، به‌منظور ارزیابی جامع عملکرد پیش‌بینی مدل ترکیبی، نمونه‌ای کوچک از نیاز مصرف برق ماهانه ایران و نمونه بزرگی از تولید برق ماهانه ایران برای نشان دادن عملکرد پیش‌بینی بررسی شده است. همچنین در این پژوهش برتری «مدل ترکیبی رگرسیون بردار پشتیبان با الگوریتم بهینه‌سازی مگس میوه با تعدیل گرایش‌های فصلی (SFOASVR)» در مقایسه با سایر مدل‌های شناخته‌شده پیش‌بینی از نظر دقت پیش‌بینی و کم‌بودن خطای پیش‌بینی بررسی شده است. برای این منظور معیارهای ارزیابی ریشه میانگین مربعات خطا (RMSE) و میانگین درصد خطای مطلق (MAPE)، همچنین آزمون ناپارامتری ویلکاکسون صورت می‌گیرد. براساس نتایج، مدل SFOASVR از سایر مدل‌های پیش‌بینی خطای کمتری دارد و در نتیجه گزینه‌ای مناسب برای کاربردهای پیش‌بینی نیاز مصرف برق است.

واژه‌های کلیدی: الگوریتم بهینه‌سازی مگس میوه (FOA)، تغییرات فصلی، پیش‌بینی، رگرسیون بردار پشتیبان (SVR)، نیاز مصرف شبکه برق.

مقدمه

پیش‌بینی، چگونگی گزینش مقدار مناسب پارامترهای مدل SVR است. به‌تازگی پن الگوریتم بهینه‌سازی تکاملی جدیدی را براساس یافتن غذا به نام الگوریتم بهینه‌سازی مگس میوه (FOA) پیشنهاد داده است [۷]. فواید استفاده از این الگوریتم، کد برنامه کوتاه‌تر در مقایسه با دیگر الگوریتم‌های بهینه‌سازی و رسیدن سریع به راه‌حل بهینه سراسری است [۸]. از آنجا که فصلی بودن ویژگی مهمی در نیاز مصرف برق است، تأثیر آن بر دقت پیش‌بینی مصرف برق زیاد است و نباید در فرایند مدل‌سازی نادیده گرفته شود. تنظیم شاخص فصلی در این پژوهش به‌کمک سه پارامتر مدل SVR صورت می‌گیرد که مسئولیت رسیدگی به تغییرات فصلی را برعهده دارند. در این پژوهش، الگوریتم FOA به‌طور اتوماتیک به گزینش تخمینی پارامترهای مدل SVR برای پیش‌بینی نیاز مصرف برق

نیاز مصرف در صنعت مهم برق اهمیت ویژه‌ای دارد. نیاز مصرف مجموع بار مورد نیاز شبکه، از جمع بار تولیدشده در مجموع تولید ناویژه نیروگاه‌ها، دریافتی از کشورهای هم‌جوار، معادل افت فرکانس و معادل خاموشی اعمال‌شده به‌دست می‌آید [۱]. در نتیجه اگر پیش‌بینی دقیق نیاز مصرف برق ماهانه صورت بگیرد، می‌توان در برنامه‌ریزی‌های راهبردی در مقوله انرژی راهنمایی تأثیرگذار بود و مدیریت صحیح‌تر مصرف برق را براساس آن انجام داد. مدل رگرسیون بردار پشتیبان (SVR)^۱ شیوه‌ای توانا برای پیش‌بینی و حل روش‌های غیرخطی است و دقت زیادی در پیش‌بینی دارد [۶]. کارکرد پیش‌بینی مدل SVR به‌طور عمده، از سه مقدار پارامتر تقریبی آن تأثیر می‌پذیرد. قدم کلیدی برای بهبود عملکرد

بردار پشتیبان است. از آنجا که مشکل عمده این روش، تنظیم پارامترهای آن است، به منظور حل این مشکل از الگوریتم ترکیبی مورچگان و ازدحام ذرات استفاده شد. براساس نتایج پیش‌بینی، مدل مطرح‌شده نتایج پیش‌بینی دقیق‌تری از الگوهای سری‌های زمانی به دست می‌آید [۲].

آلاداک روش انتخاب معماری جدید را براساس الگوریتم جست‌وجوی ممنوع ارائه داد. همچنین پنج سری زمانی واقعی را با استفاده از شبکه عصبی مصنوعی تجزیه و تحلیل کرد و روش ارائه‌شده را برای انتخاب بهترین معماری به کار گرفت [۹].

وانگ و همکاران مدل پیش‌بینی قیمت برق را با استفاده از توالی پرهج و مرج برای پیش‌بینی کوتاه‌مدت مصرف برق در بازار برق استرالیا مطرح کردند. مدل اصلاح‌شده در تنظیم فصلی اعمال شده و مدل اصلاح‌شده دیگر با تنظیم فصلی و بهینه‌سازی ازدحام ذرات تطبیقی (APSO) پارامترها را برای سیستم پرهج و مرج تعیین کرده است. براساس نتایج تجربی، اجرای روش‌های مطرح‌شده به شکل فراوانی بهتر از الگوریتم پرهج و مرج سنتی است [۱۰].

کیران و همکاران روش ترکیبی جدید (HAP) را برای برآورد تقاضای انرژی ترکیه با استفاده از بهینه‌سازی ازدحام ذرات (PSO) و بهینه‌سازی کلونی مورچگان (ACO) پیشنهاد کردند. مدل ارائه‌شده تقاضای انرژی (HAPE) نخستین مدلی است که ادغام دو روش فراابتکاری ذکرشده را بیان می‌کند. روش ترکیبی براساس PSO و ACO برای برآورد تقاضای انرژی، با استفاده از تولید ناخالص داخلی (GDP)، جمعیت، واردات و صادرات اعمال شده است. با توجه به نتایج، خطاهای نسبی برآورد مدل HAPE کمترین است و فرم درجه دوم (HAPEQ) با توجه به نوسانات شاخص‌های اجتماعی و اقتصادی، راه‌حل بهتری است [۱۱].

لی و چوی ورشکستگی شرکت‌های چندصنعت کره‌ای را با استفاده از شبکه عصبی پس‌انتشار (BNN) بررسی کردند. این صنایع شامل ساخت‌وساز، خرده‌فروشی و صنایع تولیدی مثل ماشین‌آلات و تجهیزات بودند. در این پژوهش قرار بود مدل ویژه‌ای برای پیش‌بینی ورشکستگی با استفاده از انتخاب متغیرهای مستقل مناسب پیشنهاد

ماهان می‌پردازد. مدل SFOASVR پیشنهادی در این پژوهش به منظور بهبود عملکرد پیش‌بینی با در نظر گرفتن گرایش‌های نیاز مصرف برق فصلی و غیرخطی به کار گرفته شده است. همچنین اهمیت نیاز مصرف شبکه برق اینجا مطرح می‌شود. برای اینکه در کل مصارف برق خانگی و کشاورزی و صنعتی و تجاری خاموشی ایجاد نشود، نیاز مصرف به کمک نیروگاه‌ها و واردات و پس از کسر صادرات کشورهای مجاور به دست می‌آید. همچنین پیش‌بینی آن اهمیت و ضرورت بسیار مهمی برای برنامه‌های آینده مصرف برق در بخش‌های ذکرشده دارد. در این صورت اگر صرفه‌جویی صورت بگیرد مفید خواهد بود. به همین دلیل انتخاب مدل پیش‌بینی که بتواند دقت بسیاری داشته باشد به برنامه‌های راهبردی صنعت برق در این مورد کمک شایانی خواهد کرد؛ بنابراین در این پژوهش از مدل رگرسیون بردار پشتیبان (SVR) برای پیش‌بینی نیاز مصرف برق با روند فصلی که با استفاده از الگوریتم بهینه‌سازی مگس میوه (FOA) آموزش دیده است، استفاده شد تا بهترین عملکرد پیش‌بینی با دقت بالا برای نیاز مصرف برق و مدیریت و برنامه‌ریزی صحیح آینده براساس آن صورت بگیرد.

در این پژوهش در بخش ۲ ابتدا پیشینه پژوهش ذکر شده است. در بخش ۳ روش‌شناسی مدل SFOASVR مطرح شده که شامل عملکرد کلی مدل SVR، مدل ترکیبی FOASVR و تنظیم فصلی است. در بخش ۴ به نمونه عددی و مجموعه داده‌ها اشاره شده و در بخش ۵ مدل SFOASVR برای پیش‌بینی نیاز مصرف برق اعمال شده است. در این پژوهش، دو نمونه پیش‌بینی عددی، یک نمونه کوچک نیاز مصرف برق ایران و دیگری نمونه بزرگ تولید برق ایران، به منظور بررسی عملکرد مدل SFOASVR و مقایسه با سایر مدل‌های پیش‌بینی بررسی و تجزیه و تحلیل شده است. نتایج پیش‌بینی این دو نمونه و تجزیه و تحلیل آن‌ها به ترتیب در بخش‌های ۶ و ۷ و نتیجه‌گیری در بخش ۸ آمده است.

پیشینه پژوهش

سعادت‌پیشه از الگوهای سری‌های زمانی و روش‌های یادگیری ماشین برای پیش‌بینی میزان ترافیک شهری استفاده کرد. روش نوین او در این پایان‌نامه، روش ماشین

ترکیب‌شده با بهینه‌سازی کلونی مورچگان (ACO) را ارائه دادند. در این پژوهش، داده‌های تجاری واقعی شاخص سرمایه سهام تایوان به‌عنوان داده معیار استفاده شد. نتایج محاسباتی نشان می‌دهد مدل پیشنهادی بهتر از سایر مدل‌های موجود است [۱۸].

لی و همکاران به‌منظور بهبود دقت پیش‌بینی کوتاه‌مدت، مدل شبکه عصبی مصنوعی بهینه‌سازی‌شده را برای پیش‌بینی ساعتی مصرف برق ساختمان ارائه دادند. آن‌ها الگوریتم بهینه‌سازی ازدحام ذرات بهبودیافته (iPSO) را برای تعدیل وزن ساختار ANN استفاده کردند. برای مقایسه عملکرد نیز دو مدل پیش‌بینی دیگر به نام‌های ANN و مدل ترکیبی الگوریتم ژنتیک-ANN (GA-ANN) در این پژوهش استفاده شد. نتایج مقایسه نشان می‌دهد هر دو مدل iPSO-ANN و GA-ANN دقت بهتری از ANN دارند. از منظر مصرف‌کردن زمان، مدل iPSO-ANN زمان مدل‌سازی کوتاه‌تری از روش ANN دارد [۱۹].

ژو و همکاران روش جدیدی را که FNF-SVRLP (همسایگان کاذب فیلترشده-پیش‌بینی‌کننده محلی رگرسیون بردار پشتیبان) نامیده می‌شود، برای پیش‌بینی کوتاه‌مدت تقاضای گاز طبیعی ارائه دادند. این مدل بهتر از روش‌های SVRLP (پیش‌بینی محلی رگرسیون بردار پشتیبان)، ARMA (اتورگرسیو میانگین متحرک) و ANN (شبکه عصبی مصنوعی) است و با موفقیت برای عملیات گازی روزانه کاربرد دارد [۲۰].

ولف و همکاران رگرسیون بردار پشتیبان (SVR) را روی مجموعه داده بزرگ، برای پیش‌بینی‌های تغییرات فصلی شمارشی و پیش‌بینی‌های مسیر حرکت ابر براساس ماهواره به‌کار بردند. SVR نتایج امیدوارکننده‌ای را به‌ویژه در مقایسه با روش‌های فیزیکی، بدون هرگونه بهبودسازی‌های آماری نشان می‌دهد [۲۱].

سان و ژو، GA (الگوریتم ژنتیک) را برای بهینه‌سازی وزن اتصال و آستانه BPNN^۳ سنتی (شبکه عصبی پس انتشار) به‌کار بردند. مدل جدید BPNN که براساس GA ایجاد شده است، با عنوان GA-BPNN (شبکه عصبی پس انتشار براساس الگوریتم ژنتیک) نامیده می‌شود. سپس نمونه‌ای عملی را در صنعت برق در چین در طول

شود. دقت پیش‌بینی BNN با تجزیه و تحلیل تفکیک چندمتغیره مقایسه شده است. دقت پیش‌بینی ورشکستگی با استفاده از BNN بیشتر از MDA است [۱۲].

هونگ و همکاران مدل پیش‌بینی بار الکتریکی مبتنی بر SVR و الگوریتم ترکیبی جدید یعنی الگوریتم ژنتیک پرهرج و مرج (CGA) را به‌منظور بهبود عملکرد پیش‌بینی ارائه دادند. مثالی عددی برای نشان‌دادن عملکرد پیش‌بینی مدل SSVRCGA بررسی شده است. نتایج پیش‌بینی آن‌ها نشان می‌دهد بازده مدل پیش‌بینی پیشنهادی نتایج دقیق‌تری از سایر مدل‌ها مانند ARIMA و TF-ε-SVR-SA دارد؛ بنابراین مدل SSVRCGA جایگزین امیدوارکننده‌ای برای پیش‌بینی بار الکتریکی است [۱۳].

ژی آونگ و همکاران چارچوبی جدید از مدل SVR را برای پیش‌بینی مقدار تقاضای برق ساعتی پیشنهاد دادند. مطالعه تجربی آن‌ها نشان می‌دهد چارچوب مدل‌سازی ارائه‌شده می‌تواند عملکرد پیش‌بینی بهتری از برخی هم‌تایان از نظر اندازه‌گیری دقت پیش‌بینی داشته باشد [۱۴].

منگ و همکاران براساس الگوریتم‌های SVR و PSO یک مدل پیش‌بینی محتوای گاز در زغال‌سنگ را ارائه دادند که در آن، مدل SVR با تابع پایه شعاعی (RBF)^۲ به‌منظور تسهیل در پیش‌بینی، و PSO برای بهینه‌سازی پارامترهای مدل SVR استفاده شد. براساس نتایج تجربی، مدل PSO-SVR می‌تواند دقت پیش‌بینی بیشتری از مدل شبکه عصبی مصنوعی و مدل معمولی SVR، به‌ویژه تحت شرایط نمونه‌های محدود به‌دست بیاورد [۱۵].

جمیان و همکاران دو روش را برای (ایستگاه تعویض باتری خودرو) که روش‌های تحلیلی و فراابتکاری (کلونی مصنوعی زنبورعسل (ABC)) است، استفاده کردند و نتیجه گرفتند که روش‌ها نتایجی مشابه در یافتن بهینه محلی دارند [۱۶].

یان و چاوده‌وری از ماشین بردار پشتیبان (SVM) برای پیش‌بینی برق میان‌مدت استفاده کردند. مدل ارائه‌شده آن‌ها دقت پیش‌بینی بیشتری در مقایسه با سایر مدل‌ها دارد [۱۷].

کای و همکاران مدل سری‌های زمانی فازی جدید

به دست می آید. درحقیقت هدف اصلی مینیمم کردن تابع زیر است:

$$R(f) = 1/2w^T w + C.E(x_i, y_i, f) \quad (3)$$

E تابع تلفات و C پارامتری است که براساس حداقل کردن خطای تخمین و مساوی در نظر گرفتن وزن ها تنظیم می شود. معمولاً از تابع تلفات حساس استفاده می شود [۲۵]. رابطه ۳ را می توان به صورت زیر نوشت:

$$\min 1/2w^T w + C \sum_{i=1}^n (\xi_i + \xi_i^*) \quad (4)$$

$$i = 1, 2, \dots, n$$

$$y_i - w^T \cdot \phi(x_i) - b \leq \varepsilon + \xi_i$$

$$i = 1, 2, \dots, n$$

قیدود:

$$w^T \cdot \phi(x_i) - y_i + b \leq \varepsilon + \xi_i^*$$

$$\xi_i, \xi_i^* \geq 0, \quad i = 1, 2, \dots, n$$

که در آن x_i متغیر ورودی است که با استفاده از تابع نگاشت، به فضایی با بعد بالاتر برده می شود. y_i متغیر خروجی، C هزینه خطا ξ_i خطای یادگیری پایین تر و ξ_i^* خطای یادگیری بالاتر است. در اینجا ξ_i و ξ_i^* متغیرهای کمکی برای مقابله با قیدهای اجرانشدنی در مسئله بهینه سازی رابطه ۴ است [۲۶]. برای حل مسئله بهینه سازی می توان از روش لاگرانژ استفاده کرد که تابع لاگرانژ در مورد این مسئله به صورت رابطه ۵ تعریف می شود که در این تابع $\eta_i, \alpha_i, \eta_i^*$ و ضرایب لاگرانژ هستند:

$$L = R(f) - \sum_{i=1}^n (\eta_i \xi_i + \eta_i^* \xi_i^*) - \sum_{i=1}^n \alpha_i (\varepsilon + \xi_i - y_i + w^T \cdot \phi(x_i) + b) - \sum_{i=1}^n \alpha_i^* (\varepsilon + \xi_i^* + y_i - w^T \cdot \phi(x_i) - b) - \sum_{i=1}^n \alpha_i^* (\varepsilon + \xi_i^* + y_i - w^T \cdot \phi(x_i) - b) \quad (5)$$

و از تابع لاگرانژ بالا نسبت به w و y_i و ξ_i و ξ_i^* مشتق جزئی گرفت [۲۴] و بهینه سازی سازی را به صورت زیر در آورد:

$$\max -\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n (\alpha_i - \alpha_i^*) (\alpha_j - \alpha_j^*) \phi_i(x) \phi_j(x) - \varepsilon \sum_{i=1}^n (\alpha_i - \alpha_i^*) + \sum_{i=1}^n y_i (\alpha_i - \alpha_i^*) \quad (6)$$

دوره ۲۰۰۳-۲۰۱۰ به منظور بررسی الگوریتم پیشنهادی انتخاب کردند. نتایج در مقایسه با سه الگوریتم دیگر نشان می دهد که این مدل می تواند برای ارزیابی امنیت مالی صنعت برق چین به طور مؤثر اعمال شود. همچنین مدل GA-BPNN نه تنها می تواند تا حد زیادی کاهش احتمال به دام افتادن در مینیمم محلی را ایجاد کند، بلکه می تواند بهبود سرعت همگرایی و دقت پیش بینی را فراهم آورد [۲۲].

روش شناسی مدل SFOASVR

مدل رگرسیون بردار پشتیبان (SVR)

ایده اصلی مدل SVR به این صورت است که داده های واقعی x نگاشتی غیرخطی به یک فضای ویژگی با بعد بالاتر است. داده های آموزشی به شکل $\{(x_1, y_1), \dots, (x_n, y_n)\}$ نمایش داده می شوند که $x_i \in R^n$ است و x_i متغیر ورودی است (شامل داده های آموزشی که در داده های نیاز مصرف برق از سال ۸۹ تا ۹۳ یعنی داده های پنج سال است) و y_i متغیر خروجی واقعی است (شامل داده های آموزشی که نیاز مصرف های نیاز مصرف برق داده های سال ۹۴ است). اندیس i اندیس داده های آموزشی است. تابع زیر را در نظر بگیرید:

$$f(x_i) = w^T x_i + b \quad (1)$$

که در آن x_i متغیر ورودی، w ماتریس وزن و b دوره بایاس است [۲۳]. مدل رگرسیون در رابطه ۱ با استفاده از تابع نگاشت (x_i) می تواند به صورت زیر در نظر گرفته شود:

$$f(x_i) = w^T \cdot \phi(x_i) + b \quad (2)$$

درحقیقت در رابطه ۲، $f(x_i)$ نشان دهنده متغیر خروج پیش بینی شده است [۲۴]. در داده ها نیاز مصرف برق مقادیر پیش بینی شده است که از طریق مدل برای سال ۹۴ به دست می آید. با استفاده از رابطه ۲، داده های ورودی اصلی به فضایی با بعد بالا برده می شوند که در آن مسئله تفکیک پذیر غیرخطی در همین فضای جدید به تفکیک پذیر خطی تبدیل می شود. همان طور که در رابطه ۲ مشاهده می شود، تابع نگاشت تحت تأثیر ماتریس وزن w و بایاس b است. مقادیر مناسب برای این دو پارامتر از مینیمم کردن خطای تخمین و مساوی در نظر گرفتن وزن ها

$$g_{k0} = rand(LR) \quad (7)$$

$$h_{k0} = rand(LR) \quad (8)$$

گام ۲. تعیین جهت و مسافت جست‌وجوی مگس‌ها به‌طور تصادفی

در این مرحله، برای اینکه بتوان رفتار بویایی مگس‌ها را شبیه‌سازی کرد، براساس روابط ۹ و ۱۰ مقادیری به‌صورت تصادفی برای حرکت مگس در طول و عرض محور مختصات به مختصات فعلی اضافه می‌شود (تنظیم " = ۰ تکرار ") با این کار هم مسافت و هم جهت حرکت به‌صورت تصادفی تعیین می‌شود:

$$g_{kp} = g_{k0} + rand(FR) \quad (9)$$

$$h_{kp} = h_{k0} + rand(FR) \quad (10)$$

در روابط بالا اندیس p نشان‌دهنده اندیس موقعیت مکانی ثانویه به بعد جمعیت مگس میوه است که $p=1,2,\dots, \text{sizepop}$ و rand یک تابع تولید اعداد تصادفی است که از توزیع یکنواخت است.

گام ۳. محاسبه میزان تشخیص شدت بویایی مگس‌ها تا زمانی که محل غذا معلوم نشده باشد، فاصله هر مگس تا مبدأ مختصات (Dist) محاسبه می‌شود (رابطه ۱۱) و براساس آن میزان تشخیص شدت بویایی (S_{kp}) هر مگس میوه که قاعدتاً رابطه معکوسی با میزان فاصله محاسبه شده دارد، براساس رابطه ۱۲ به‌دست می‌آید:

$$Dist_{kp} = \sqrt{g_{kp}^2 + h_{kp}^2} \quad (11)$$

$$k = C, \gamma, \varepsilon \quad (12)$$

$$S_{kp} = 1 / Dist_{kp}$$

سه پارامتر ε ، γ و C مدل SVR به $S_{\gamma p}$ و $S_{\varepsilon p}$ و S_{CP} وابسته هستند. علاوه‌براین نیاز است شکل‌های خاص مربوطی تنظیم شوند. در این پژوهش پس از تنظیم مداوم، به شکل متناظر خاص با بهترین عملکرد می‌رسیم:

$$C = 20 * S_{cp}, \quad \gamma = S_{\gamma p}, \quad \varepsilon = S_{\varepsilon p}$$

شایان ذکر است که تنظیم شکل‌های خاص مربوط باید با توجه به داده‌های اصلی ساخته شده باشد.

گام ۴. مدل SVR و محاسبه میزان تابع برازندگی میزان تشخیص شدت بویایی (S_{kp}) به‌عنوان تابع تشخیص شدت بویایی (که تابع برازندگی این الگوریتم است) در نظر گرفته می‌شود و برای یافتن شدت بویایی

با توجه به رابطه ۶ [۲۰] لازم است $\phi_i(x)\phi_j(x)$ که کرنل نامیده می‌شود، مشخص باشد که به‌طور معمول از تابع کرنل گاوسی (RBF) [۲۶] به شکل $k(x_i, x_j) = \exp(-\frac{\|x_i - x_j\|^2}{2\gamma^2})$ استفاده می‌شود. در اینجا γ پارامتر کرنل (RBF) است. در مدل رگرسیون بردار پشتیبان باید سه پارامتر C، ε و پارامتر کرنل γ تعیین شوند که نقشی اساسی در پیش‌بینی توسط رگرسیون بردار پشتیبان دارند. پارامتر C درجه ریسک تجربی SVR، ε عرض بازه خطا و γ عرض تابع گاوسی از تابع کرنل است [۲۱]. در این پژوهش از الگوریتم FOA برای انتخاب مقادیر مناسب سه پارامتر مدل SVR استفاده شده است.

الگوریتم بهینه‌سازی مگس میوه (FOA) و به‌کارگیری FOA برای انتخاب سه پارامتر مدل SVR مدل ترکیبی FOASVR

پن در سال ۲۰۱۲ الگوریتم بهینه‌سازی مگس میوه (FOA) را که به الگوریتم بهینه‌سازی مگس نیز مشهور است ارائه داد [۷]. الگوریتم FOA روشی نوین برای جست‌وجوی جواب بهینه سراسری است که بر پایه رفتار غذایابی مگس میوه مدل‌سازی و عرضه شده است. مگس میوه در مقایسه با انواع صنف‌های هم‌سان، رتبه برگزیده‌ای در حس تشخیص و ادراک اطراف خود به‌ویژه در حس‌های بویایی و بینایی دارد. مراحل الگوریتم FOA براساس ویژگی‌های غذایابی مگس‌ها برای انتخاب سه پارامتر مدل SVR به‌صورت زیر تعریف می‌شود:

گام ۱. تعیین پارامترها و موقعیت اولیه مگس‌ها به‌صورت تصادفی
پارامترها شامل اندازه جمعیت (sizepop)، حداکثر تعداد تکرار (Maxgen)، محدوده محل اولیه تصادفی ازدحام مگس میوه (LR) و دامنه پرواز تصادفی (FR) هستند. پس از آن موقعیت مکانی اولیه هریک از اعضای جمعیت مگس‌های میوه (g_{k0}, h_{k0})، به‌صورت تصادفی تعیین می‌شود که می‌تواند به کمک رابطه‌های زیر به‌دست بیاید. در این رابطه‌ها، اندیس k که ε و γ و $k=C$ است. اندیس پارامترهای مدل SVR است که مقدار بهینه آن با استفاده از الگوریتم FOA تعیین می‌شود و اندیس 0 اندیس موقعیت مکانی اولیه جمعیت مگس است:

توجه به اهمیت تعداد گره ورودی در تعیین ساختار مدل اتورگرسیو سری زمانی، تعداد گره‌های ورودی به‌طور جدی بر عملکرد پیش‌بینی تأثیر می‌گذارد [۲۵].

گام ۵. یافتن بهترین میزان شدت بویایی

یافتن مگس میوه با بهترین شدت بویایی (به‌عنوان مثال حداقل انحراف) در میان ازدحام مگس میوه:

$$[best\ smell_k \quad best\ index_k] \text{in}(smell_{kp}) \quad (۱۵)$$

گام ۶. حرکت به‌سوی بهترین موقعیت

بهترین میزان شدت بویایی را نگه دارید و مختصاتش را مکاتبه کنید. سپس جمعیت مگس میوه برای پرواز به سمت مختصات g و h مکاتبه‌شده از بینایی استفاده می‌کنند.

$$smell_{best\ k} = bestsmell_k \quad (۱۶)$$

$$g_{k0} = g(bestindex_k) \quad (۱۷)$$

$$h_{k0} = h(bestindex_k) \quad (۱۸)$$

در این تکرار، مکان مکاتبه‌شده ازدحام مگس میوه برای جست‌وجو کردن پارامترهای بهینه (ϵ و γ و C) به‌ترتیب $(g_{C0}, h_{\gamma0}, g_{\epsilon0})$ و $(g_{\gamma0}, h_{\epsilon0})$ هستند؛ بنابراین علامت‌گذاری $g_{\text{تکرار}} = (g_{C0}, g_{\gamma0}, g_{\epsilon0})$ تکرار محور $(h_{C0}, h_{\gamma0}, h_{\epsilon0})$ تکرار محور مکان ازدحام ذرات هستند که به‌طور هم‌زمان ۳ پارامتر را در این تکرار جست‌وجو کردند.

گام ۷. بهینه‌سازی تدریجی

تعداد تکرار = تکرار + ۱ و ثبت کردن بهینه‌سازی تکراری به تکرار اجرای گام‌های ۲-۶.

گام ۸. معیارهای توقف

هنگامی که شدت بو بهتر از نتایج تکراری قبلی نمی‌شود، یا از تعدادی تکرار، تکرار به حداکثر می‌رسد، گردش متوقف می‌شود. در اینجا سه مقدار بهینه پارامتر مدل SVR به‌دست آمده است. در غیر این صورت بازگشت به گام ۷ صورت می‌گیرد. هنگامی که تکرار متوقف

$$\text{می‌شود (حداکثر تعداد تکرار)} \quad G = (g_{\text{محور}}^{(1)}, \dots, g_{\text{محور}}^{(n)}) \quad \text{و}$$

$$\text{(حداکثر تعداد تکرار)} \quad H = (h_{\text{محور}}^{(1)}, \dots, h_{\text{محور}}^{(n)}) \quad \text{به‌ترتیب}$$

وضعیت محور g و h در مسیر پرواز مگس میوه است [۲۵، ۲۷ و ۲۸].

($Smell_{kp}$) برای موقعیت مکانی هر مگس کاربرد دارد. سه مقدار پارامتر فوق به مدل SVR برای پیش‌بینی مسئله جایگزین می‌شود و سپس محاسبه شدت بوی $smell_{kp}$ صورت می‌گیرد. در این پژوهش، تابع برازندگی، میانگین مربعات خطا (MSE) است که انحراف بین مقادیر پیش‌بینی و مقادیر واقعی است که در رابطه ۱۴ آمده است.

$$Smell_{kp} = function(S_{kp}) \quad (۱۳)$$

$$MSE = \frac{1}{n} \sum_{t=1}^n (f_t - \hat{f}_t)^2 \quad (۱۴)$$

که n تعداد دوره‌های پیش‌بینی است و f_t و \hat{f}_t به‌ترتیب مقدار واقعی و مقدار پیش‌بینی‌شده در زمان t هستند. در واقع همان مقدار واقعی مثلاً نیاز مصرف برق در فروردین‌ماه سال ۹۴ است و \hat{f}_t مقدار پیش‌بینی نمونه نیاز مصرف برق در همین زمان است که با استفاده از پیش‌بینی مبتنی بر نورد محاسبه می‌شود. روش پیش‌بینی مبتنی بر نورد برای کمک به FOA برای تعیین مقادیر مناسب ۳ پارامتر مدل SVR استفاده می‌شود. به‌طور جزئی، در مرحله آموزش، داده‌های آموزشی به دو زیرمجموعه تقسیم می‌شوند که زیرمجموعه در جریان (برای مثال n داده نیاز مصرف برق) و زیرمجموعه خارج جریان ($n - 60$ نقطه داده نیاز مصرف برق) نامیده می‌شوند. در مرحله اول n داده نیاز مصرف برق قبلی در زیرمجموعه در جریان برای به‌حداقل رساندن خطای آموزشی از طریق اصل خطر سازی استفاده می‌شود. پس از آن پیش‌بینی نیاز مصرف برق یعنی $(n+1)$ امین پیش‌بینی نیاز مصرف برق صورت می‌گیرد. در مرحله دوم n نقطه نیاز مصرف برق (به‌عنوان مثال از $n+1$ امین داده به بعد) به‌عنوان زیرمجموعه در جریان جدید استفاده می‌شود. به همین ترتیب در مرحله بعد یک گام جلوتر پیش‌بینی نیاز مصرف برق را به‌دست می‌آوریم (به‌عنوان مثال $(n+2)$ پیش‌بینی نیاز مصرف نیاز مصرف برق). روش پیش‌بینی مبتنی بر نورد تا شصتمین پیش‌بینی مصرف برق ادامه می‌یابد. در این میان می‌توان خطای آموزش را در مرحله آموزش دریافت کرد. درحالی‌که حداقل خطای آموزشی (MSE در رابطه ۱۴) رخ می‌دهد، پارامترهای تنظیم‌شده به‌عنوان بهترین مقادیر پارامتر انتخاب می‌شوند. مجموعه داده‌های آزمایشی تنها برای بررسی سطح دقیق پیش‌بینی به کار می‌روند. با این حال با

۱۳۸۹ تا اسفند سال ۱۳۹۴ به‌عنوان مجموعه داده‌ها استفاده شده است. از شکل ۲ به‌روشنی می‌توان دریافت که داده‌های کل نیاز مصرف ماهانه شبکه برق ایران خصوصیات فصلی و غیرخطی را نشان می‌دهند. پیشنهاد این پژوهش مقایسه عملکرد پیش‌بینی مدل SFOASVR با سایر مدل‌هاست؛ مانند SVR (مدل رگرسیون بردار پشتیبان)، BPNN (مدل شبکه عصبی پس‌انتشار)، SARIMA^۶ (مدل میانگین متحرک خودهم‌بسته یکپارچه با تعدیل گرایش‌های فصلی)، SACOSVR^۷ (مدل ترکیبی رگرسیون بردار پشتیبان با الگوریتم بهینه‌سازی کلونی مورچگان با تعدیل گرایش‌های فصلی) و SPSOSVR^۸ (مدل ترکیبی رگرسیون بردار پشتیبان با الگوریتم بهینه‌سازی ازدحام ذرات با تعدیل گرایش‌های فصلی). علاوه‌براین به‌منظور بررسی عملکرد مکانیسم تنظیم فصلی، مدل ACOSVR (مدل ترکیبی رگرسیون بردار پشتیبان با الگوریتم بهینه‌سازی کلونی مورچگان)، PSOSVR (مدل ترکیبی رگرسیون بردار پشتیبان با الگوریتم بهینه‌سازی ازدحام ذرات) [۴] و FOASVR (مدل ترکیبی رگرسیون بردار پشتیبان با الگوریتم بهینه‌سازی مگس میوه)، بدون تنظیم فصلی نیز در مقایسه در نظر گرفته شده‌اند. در این پژوهش، شش سال (۷۲ ماه) در مجموعه داده‌ها وجود دارد که به دو مجموعه داده‌های آموزشی (۵ سال) و مجموعه داده‌های آزمایشی (۱۲ ماه در سال ۱۳۹۴) تقسیم شده‌اند.

مدل پیش‌بینی نیاز مصرف برق SFOASVR

انتخاب پارامترها توسط الگوریتم FOA

ضروری است داده‌های خام به‌منظور بهبود دقت پیش‌بینی نرمال شوند. در نمونه نیاز مصرف برق که از سال ۸۹ تا ۹۴ هستند؛ متغیر x_i داده‌ها از سال ۸۹ تا ۹۳ و متغیر y_i داده‌های سال ۹۴ هستند که به‌طور کلی در رابطه ۲۲ هر دوی این داده‌ها را با متغیر Z_i نشان می‌دهیم. داده‌های خام نرمال شده، همان‌طور که در رابطه ۲۲ آمده است، در محدوده $[0,1]$ هستند.

$$\tilde{Z}_i = \frac{Z_i - Z_{\min}}{Z_{\max} - Z_{\min}} \quad (22)$$

تنظیم فصلی و نمودار جریان مدل SFOASVR

در این پژوهش با توجه به نوع داده نیاز مصرف برق، رویکرد Deo و Hurvich برای محاسبه شاخص فصلی و تنظیم اثرات فصلی انتخاب شده [۲۹] که در رابطه ۱۹ آمده است:

$$Season_t = \frac{y_t}{f_t} = \frac{y_t}{\sum_{i=1}^n (\beta_i - \beta_i^*) L(x, x_i) + b} \quad (19)$$

در رابطه ۱۹، $Season_t$ نشان‌دهنده شاخص فصلی هر دوره یا سال، y_t مقدار خروجی واقعی و f_t مقدار خروجی پیش‌بینی شده در روش رگرسیون بردار پشتیبان و β_i و β_i^* ضرایب لاگرانژ هستند.

در رابطه ۱۹، $t = j, n+j, 2n+j, \dots, (m-1)n+j$ برای نقطه هم‌زمان (یا ماه) در هر دوره، j اندیس ماه و m اندیس تعداد سال‌های قبل از سال پیش‌بینی است؛ برای نمونه نیاز مصرف برق کل داده‌ها از سال ۸۹ تا ۹۴ است که ما می‌خواهیم سال ۹۴ را پیش‌بینی کنیم؛ پس m در این نمونه تعداد سال ۸۹ تا ۹۳ است که ۵ است. سپس محاسبه شاخص فصلی (SI) هر ماه j در رابطه ۲۰ آمده است:

$$SI_j = \frac{1}{m} (Season_j + Season_{n+j} + Season_{(m-1)n+j}) \quad (20)$$

که $j=1,2,\dots,n$ در نهایت مقدار پیش‌بینی مدل SFOASVR را می‌توان با رابطه ۲۱ به‌دست آورد:

$$f_{n+1} = (\sum_{i=1}^n (\beta_i - \beta_i^*) L(x_{n+1}, x_i) + b) \times SI_l \quad (21)$$

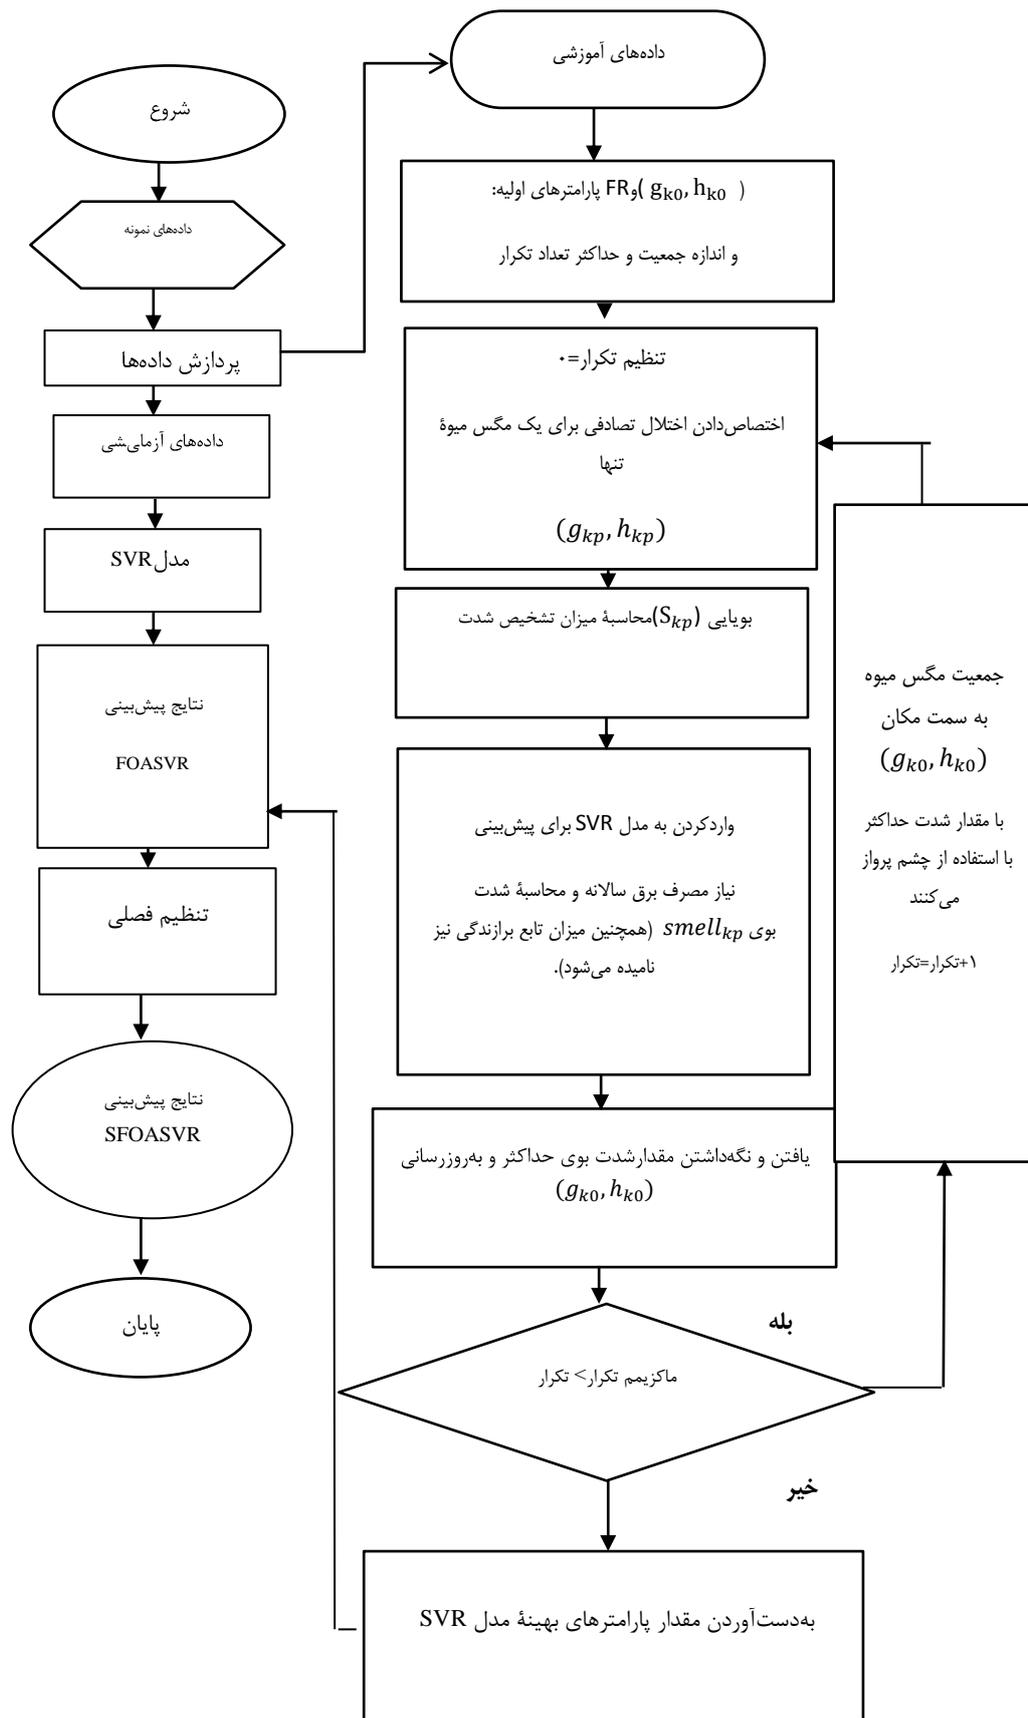
که $l=1,2,\dots,n$ حاکی از نقطه هم‌زمان (یا ماه) در دوره‌های پیش‌بینی شده است [۲۹ و ۲۵].

نمودار جریان الگوریتم FOA برای انتخاب ۳ پارامتر مدل SVR فصلی (به نام SFOASVR) در شکل ۱ آمده است.

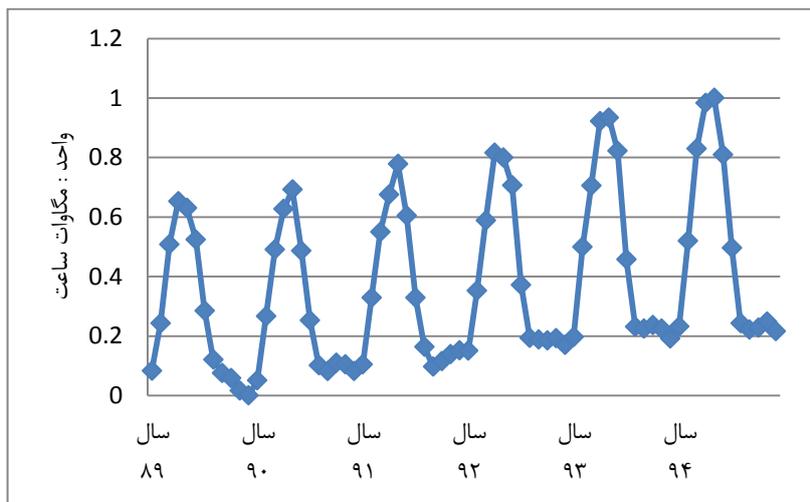
نمونه عددی و مجموعه داده‌ها

برای بررسی اثربخشی مدل SFOASVR در این پژوهش ۲ نمونه کوتاه‌مدت و بلندمدت انتخاب شده که شامل نیاز مصرف ماهانه شبکه برق ایران از فروردین سال ۱۳۸۹ تا اسفند سال ۱۳۹۴ و تولید ماهانه شبکه برق ایران از فروردین سال ۱۳۷۴ تا اسفند سال ۱۳۹۳ است [۳].

کل نیاز مصرف ماهانه شبکه برق ایران از فروردین سال



شکل ۱. نمودار جریان مدل SFOASVR



شکل ۲. کل نیاز مصرف ماهانه نرمال شده شبکه برق ایران در طول فروردین‌ماه سال ۱۳۸۹ تا اسفندماه سال ۱۳۹۴

پارامترهای ϵ ، γ و C مدل SVR اعداد (۰/۰۳۳۹، ۰/۰۲۷۷) و (۲۶/۴۸۱) برای پیش‌بینی برق ماهانه ایران انتخاب شده‌اند.

تنظیم فصلی

برای کل نیاز مصرف برق ماهانه ایران، همراه وضعیت نیاز مصرف برق خود را دارد؛ بنابراین طول فصل می‌تواند عدد ۱۲ انتخاب شود. با توجه به رابطه‌های ۱۹ و ۲۰، دوازده شاخص فصلی می‌تواند با استفاده از مقادیر پیش‌بینی FOASVR و مقادیر واقعی مجموعه آموزش محاسبه شود که این شاخص‌ها در جدول ۲ آمده است. با توجه به رابطه ۲۱، مقادیر پیش‌بینی شده در مجموعه آزمایشی که به کمک شاخص فصلی تنظیم شده‌اند، به داده‌های واقعی بسیار نزدیک‌ترند؛ بنابراین گفته می‌شود مقدار پیش‌بینی نهایی SFOASVR می‌تواند با اعمال کردن شاخص‌های فصلی برای تنظیم مقادیر پیش‌بینی FOASVR به دست بیاید.

در رابطه ۲۲، Z_{min} و Z_{max} مقدار حداکثر و حداقل داده‌ها هستند [۵ و ۲۷]. همچنین روش پیش‌بینی بر پایه نورد یا غلت برای کمک به الگوریتم FOA باید برای تعیین مقادیر مناسب سه پارامتر SVR به کار گرفته شود [۲۵ و ۳۰]. براساس تاریخ ادبیات پیشین و بسیاری از آزمایش‌ها در داده‌های آزمایشی، در این پژوهش مقادیر پارامترهای الگوریتم FOA: $LR=[1,2]$, $Maxgen=200$, $sizepop=20$, $FR=[-10,10]$ و مناسب برای مدل FOASVR با اعداد مختلف مجموعه در جریان در جدول ۱ آمده است. براین اساس، زمانی که مدل FOASVR تعداد زیرمجموعه در جریان ۲۴ است، بهترین عملکرد را دارد. در مدل FOASVR، هم‌گرایی روند MSE تکراری برای بهینه‌سازی پارامتر در مرحله آموزش، در تکرار ۴۷ با مقدار $MSE=0.0121$ اتفاق افتاده است. با توجه به نتایج حاصل از FOA برای تنظیم سه پارامتر مدل SVR،

جدول ۱. پارامترهای مدل FOASVR

اعداد مجموعه در جریان	پارامترها			MAPE (درصد)
	C	γ	ϵ	
۴	۳۲/۷۸۸	۰/۰۳۱	۰/۰۳۷۷	۷۰/۲۹۴۶۷۹۵
۸	۲۵/۱۸۶۵	۰/۰۳۴۳	۰/۰۲۵۹	۷۶/۷۰۸۹۷۴۶
۱۲	۶۶/۱۸۹۹	۰/۰۶۴۶	۰/۱۲۲۷	۳۱/۶۲۹۹۶۴۳
۱۶	۹۳/۲۳۵	۰/۰۶۵۶	۰/۰۴۴۴	۱۹/۹۱۸۷۰۰۴
۲۰	۳۸/۰۰۶	۰/۰۳۳۱	۰/۰۳۳۵	۱۲/۶۷۲۹۸۹۴
۲۴	۲۶/۴۸۱	۰/۰۳۳۹	۰/۰۲۷۷	۱۲/۶۰۸۲۷۶۵
۲۸	۶۱/۱۴۸	۰/۰۵۵۶	۰/۰۲۷۲	۱۶/۷۳۳۷۹۲۱

جدول ۲. شاخص فصلی برای همراه برای مدل SFOASVR

شاخص فصلی	ماه	شاخص فصلی	ماه
۰/۸۴۴۲۹۷۶	مهر	۰/۸۰۷۸۲۶۸	فروردین
۰/۸۱۵۶۱۱۸	آبان	۰/۷۰۲۵۳۷۷	اردیبهشت
۰/۷۹۹۰۴۱۴	آذر	۰/۸۲۸۶۳۹۲	خرداد
۰/۸۰۱۳۵۵۶	دی	۰/۹۲۴۵۰۴۸	تیر
۰/۷۸۷۹۱۲۵	بهمن	۰/۹۲۴۸۵۲۹	مرداد
۰/۷۹۰۲۲۲۳	اسفند	۰/۸۹۱۱۶۲۶	شهریور

نتایج پیش‌بینی مثال اول

پس از فرایند ضد نرمال‌سازی (داده‌ها را دوباره به حالت واقعی برمی‌گردانیم)، در جدول ۳ فهرست نتایج پیش‌بینی نیاز مصرف برق ماهانه با استفاده از مدل‌های مختلف آمده است. همچنین ریشه میانگین مربعات خطا (RMSE) و میانگین درصد خطای مطلق (MAPE) نیز برای محاسبه و مقایسه عملکرد پیش‌بینی مدل ارائه شده با مدل‌های دیگر استفاده شده است [۵]. مقایسه مقادیر RMSE و MAPE برای مدل‌های مختلف در جدول ۳ آمده است. این مقادیر می‌تواند به کمک رابطه‌های زیر به دست بیاید.

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (f_t - \hat{f}_t)^2} \quad (23)$$

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{\hat{f}_t - f_t}{f_t} \right| \times 100 \quad (24)$$

که f_t مقدار واقعی در زمان t و \hat{f}_t مقدار پیش‌بینی شده در زمان t است [۲۵]. برای دستیابی به نتایج در این پژوهش از نرم‌افزارهای MATLAB، Eviews و SPSS استفاده شده و بهینه‌سازی مدل SVR نیز با استفاده از نرم‌افزار MAT صورت گرفته است.

بنابراین می‌توان نتیجه گرفت که:

۱. مقادیر RMSE و MAPE محاسبه شده به کمک مدل SFOASVR (که به ترتیب ۲۶۳۳۲۰/۴۶ و ۱۰/۲۴۷۹۹۴۴ درصد هستند) از سایر مدل‌ها کمترند که این امر تفاوت بسیار کمی را میان مقادیر پیش‌بینی شده و واقعی نشان می‌دهد؛ بنابراین نتایج پیش‌بینی شده به کمک مدل SFOASVR از مدل‌های دیگر در پیش‌بینی نیاز مصرف برق ماهانه ایران برتر است.

۲. تنظیم شاخص فصلی سبب می‌شود مقدار پیش‌بینی به داده‌های واقعی بسیار نزدیک‌تر شود. به‌موجب این مورد، SACOSVR بهتر از ACOSVR، SPSOSVR بهتر از PSOSVR و SFOASVR بهتر از FOASVR است. مقادیر RMSE و MAPE آن‌ها در جدول ۳ آمده است.

۳. مقدار RMSE و MAPE مدل FOASVR کوچک‌تر از مدل PSOSVR و مدل PSOSVR کوچک‌تر از مدل ACOSVR است؛ بنابراین با استفاده از این مقادیر می‌توان دریافت که مدل FOASVR برتر از هر دو مدل PSOSVR و ACOSVR است. براساس این نتایج، الگوریتم FOA، پتانسیل جست‌وجوی سه مقدار پارامتر SVR را برای بهبود دقت پیش‌بینی به‌خوبی دارد. جالب است که نتایج حاصل از SARIMA دقت بیشتری از BPNN و مدل SVR تنها دارد. علت این است که SARIMA تنظیم فصلی را در نظر می‌گیرد و SVR تنها با پیش‌فرض پارامترهای نامناسب و بدون نیاز به تنظیم شاخص‌های فصلی است. به‌دست آوردن مدل شبکه عصبی قابل‌اعتماد شامل انتخاب تعداد زیادی از پارامترها از طریق آزمون و خطاست؛ از این رو برای نمونه کوچک نیاز مصرف برق ایران، BPNN نمی‌تواند تغییرات فصلی و روند را با موفقیت در نظر بگیرد. مدل‌های پیوندی با SVR روش‌های پیش‌بینی هستند که برای نمونه کوچک هم مؤثرند؛ درحالی‌که BPNN تنها برای نمونه‌های بزرگ مؤثر است، اما از آنجا که مدل BPNN قادر به ساخت مدل فصلی به‌طور مستقیم است و فصلی‌سازی از قبل لازم نیست [۳۱]، مقادیر پیش‌بینی BPNN در مقایسه با SVR تنها، دقت بیشتری دارد.

جدول ۳. نتایج پیش‌بینی نیاز مصرف برق ماهانه ایران برای هر مدل (واحد: مگاوات ساعت)

ماه	واقعی	SARIMA	BPNN	SVR	ACOSVR	PSOSVR	FOASVR	SACOSVR	SPSOSVR	SFOASVR
فروردین ۱۳۹۴	۱۸۵۵۸۲۴۸	۲۲۷۶۳۰۲۶	۲۳۳۳۳۳۹۶	۱۸۷۳۹۹۲۲	۲۵۵۹۹۶۳۱	۲۳۰۹۸۱۸۶/۹	۲۰۷۱۸۱۱۳	۲۰۶۸۰۰۶۸/۹	۱۸۶۵۹۳۵/۲	۱۶۷۳۶۶۴۷/۲
اردیبهشت ۱۳۹۴	۲۳۱۳۵۲۱۴	۲۳۳۵۶۳۲۸	۲۳۴۰۱۷۲۱	۲۲۹۲۸۸۱۱	۲۵۹۵۲۲۹۹/۴	۲۶۰۳۷۱۱۲/۶	۲۸۸۱۷۷۱۸	۱۸۳۲۲۴۶۷/۸	۱۸۲۹۲۰۵۲/۳	۲۰۲۴۵۵۳۲/۲
خرداد ۱۳۹۴	۲۸۰۶۳۶۶۵	۲۳۸۳۰۱۹۸	۲۴۲۲۹۹۶۳	۲۴۵۹۵۱۸۹	۲۶۰۴۴۸۱۰/۶	۲۶۰۳۷۱۱۲/۶	۲۸۸۵۶۶۰۴	۲۱۵۸۱۷۵۲/۳	۲۱۵۷۵۲۷۳/۴	۲۳۹۱۱۷۱۴/۸
تیر ۱۳۹۴	۳۰۴۹۸۵۶۰	۲۳۸۹۶۸۲۶	۲۵۱۷۱۱۳۸	۲۲۸۹۶۶۶۰	۲۵۹۵۰۳۵۴/۳	۲۶۰۳۷۱۱۲/۶	۲۸۷۸۳۸۱۱	۲۳۹۹۱۲۲۶/۵	۲۴۰۷۱۴۳۵	۲۶۶۱۰۷۷۱
مرداد ۱۳۹۴	۳۰۷۶۷۸۴۷	۲۳۶۸۲۴۵۱	۲۵۹۲۰۹۹۶	۲۳۸۱۶۹۰۴	۲۶۰۰۳۴۹۰/۶	۲۶۰۳۷۱۱۲/۶	۲۹۲۶۲۹۰۴	۲۴۰۴۹۴۰۲/۶	۲۴۰۸۰۴۹۸	۲۷۰۶۳۸۸۰/۳
شهریور ۱۳۹۴	۲۷۷۳۲۷۷۵	۲۳۳۵۳۵۹۲	۲۶۰۱۱۹۶۱	۱۷۲۱۳۵۵۷	۲۵۷۸۵۵۲۳/۶	۲۶۰۳۷۱۱۲/۶	۲۷۹۰۷۳۱۴	۲۲۹۷۹۰۹۵/۲	۲۳۲۰۳۳۰۱/۹	۲۴۸۶۹۵۵/۵
مهر ۱۳۹۴	۲۲۷۵۳۵۶۸	۲۳۰۶۳۲۱۵	۲۵۹۲۲۲۸۹	۳۲۵۴۳۰۷۴	۲۱۸۸۳۷۹۳/۹	۲۶۰۳۷۱۰۸/۴	۲۴۰۰۵۵۸۴	۱۸۴۷۶۴۳۳/۹	۲۱۹۸۳۰۶۷/۲	۲۷۰۶۳۸۸۰/۳
آبان ۱۳۹۴	۱۸۷۳۱۵۰۱	۲۲۸۸۸۹۰۸	۲۵۴۴۵۳۵۱	۲۹۲۰۳۲۴۶	۲۱۳۴۶۰۹۸/۱	۲۳۰۹۸۱۸۷	۲۱۳۹۲۰۵۶	۱۷۴۱۰۱۲۹/۸	۱۸۸۳۹۱۵۴/۲	۱۷۴۴۷۶۱۴
آذر ۱۳۹۴	۱۸۳۸۷۴۴۴	۲۲۸۰۴۷۵۳	۲۴۹۱۲۸۱۸	۲۹۶۰۲۵۶۲	۲۱۳۶۸۴۸۳/۸	۲۳۰۹۸۱۸۶/۹	۲۱۲۷۴۲۵۸	۱۷۰۷۴۳۰۲/۶	۱۸۴۵۶۴۰۶/۹	۱۶۹۹۹۰۱۲/۳
دی ۱۳۹۴	۱۸۵۰۲۲۱۱	۲۲۷۶۲۹۲۳	۲۳۷۵۱۲۱۱	۲۴۹۷۹۱۳۴	۲۳۰۳۵۷۱۶/۶	۲۳۰۹۸۱۸۶/۹	۲۱۳۶۴۲۰۵	۱۸۴۵۹۸۰۰/۲	۱۸۵۰۹۸۶۱/۱	۱۷۱۲۰۳۲۴/۷
بهمن ۱۳۹۴	۱۸۸۲۰۰۷۴	۲۲۸۰۸۶۲۹	۲۳۳۷۰۱۴۱	۱۱۰۳۹۴۴۴	۲۵۴۱۳۰۳۷/۶	۲۳۰۹۸۱۹۰/۹	۲۱۶۱۳۲۸۳	۲۰۰۲۳۲۴۹/۳	۱۸۱۹۹۹۵۲/۷	۱۷۰۲۹۳۷۵/۴
اسفند ۱۳۹۴	۱۸۳۱۴۲۲۰	۲۲۹۰۹۳۴۹	۲۳۳۲۴۲۶۵	۱۹۲۸۴۸۵۴	۲۵۶۶۴۳۰۴/۷	۲۳۰۹۸۱۸۶/۹	۲۱۲۱۶۸۹۴	۲۰۲۸۰۵۰۵/۲	۱۸۲۵۲۷۰۱/۷	۱۶۷۶۶۰۶۲/۵
RMSE		۴۴۷۸۵۰۷/۴	۴۶۸۵۵۹۷/۷	۷۴۳۶۲۱۰/۵	۴۵۰۲۷۱۰/۱۸	۴۰۰۶۷۷۶/۳۸	۲۶۴۹۱۹۴	۴۱۶۰۴۷۳/۴۱	۳۷۹۸۱۱۵/۸۱	۲۶۳۳۲۰۱/۴۶
MAPE(%)		۱/۸۰۰۴۴۹۵	۲۰/۴۲۷۳۷۳	۲۸/۴۲۷۳۷۴	۱۹/۰۳۲۶۹۴۲	۱۸/۱۱۶۸۰۶۶	۱۰/۹۷۷۸۷۵	۱۳/۸۶۵۳۳۴۸	۱۰/۳۱۲۶۰۹۸	۱۰/۲۴۷۹۹۴۴

است، SFOASVR، SPSOSVR و SACOSVR اجرای بهتری از SARIMA و BPNN در سطح معنی‌داری آماری ۵ درصد دارند. علاوه‌براین مدل SFOASVR اجرای بهتری از FOASVR در سطح معناداری آماری ۵ درصد دارد. در نتیجه مدل SFOASVR پیشنهادی انحراف کمی بین مقادیر پیش‌بینی و مقادیر واقعی دارد و در میان ۷ مدل دیگر، در مقایسه با مدل‌های SACOSVR و SPSOSVR به دلیل عملکرد پیش‌بینی نزدیک به یکدیگر (از نظر نوع مدل ترکیبی و استفاده از تنظیم شاخص فصلی یکسان) تفاوت چشمگیری ندارد، اما از پنج مدل SARIMA، BPNN، ACOSVR، PSOSVR، FOASVR به‌طور چشمگیری بهتر است.

در این پژوهش آزمون رتبه علامت‌دار ویلکاکسون برای بررسی اینکه آیا مدل SFOASVR مطرح شده به‌طور قابل‌توجهی برتر از مدل‌های دیگر است، انجام شده است. این تست آزمون آماری ناپارامتری برای گروه‌های وابسته به‌شمار می‌آید [۳۲]. جدول ۴، نتایج حاصل از آزمون علامت‌دار ویلکاکسون را برای نتایج پیش‌بینی هر مدل نشان می‌دهد که در این جدول آماره ویلکاکسون و مقدار p-value متناظر با آن درون پرانتز برای مقایسه هر دو زوج از مدل‌ها آمده است. این مقدار معیار تصمیم خواهد بود که اگر از ۰/۰۵ کمتر باشد؛ یعنی مدلی که در سطر نوشته شده اجرای بهتری از مدلی است که در ستون نوشته شده است. مدل SVR تنها بدون تنظیم فصلی در نظر گرفته نشده است. همان‌طور که در جدول ۴ آمده

جدول ۴. آزمون رتبه علامت‌دار ویلکاکسون برای نتایج پیش‌بینی نیاز مصرف برق ایران برای هر مدل

	SARIMA	BPNN	ACOSVR	PSOSVR	FOASVR	SACOSVR	SPSOSVR
BPNN	-۳/۰۵۹(۰/۰۰۲*)	-	-	-	-	-	-
ACOSVR	-۲/۳۵۳(۰/۰۱۹*)	-۰/۷۸(۰/۹۳۷)	-	-	-	-	-
PSOSVR	-۳/۰۵۹(۰/۰۰۲*)	-۰/۳۱۴(۰/۷۵۴)	-۰/۶۲۸(۰/۵۳۰)	-	-	-	-
FOASVR	-۰/۹۴۱(۰/۳۴۷)	-۰/۰۷۸(۰/۹۳۷)	-۰/۰۷۸(۰/۹۳۷)	-۰/۶۲۸(۰/۵۳۰)	-	-	-
SACOSVR	-۲/۸۲۴(۰/۰۰۵*)	-۳/۰۵۹(۰/۰۰۲*)	-۳/۰۵۹(۰/۰۰۲*)	-۳/۰۵۹(۰/۰۰۲*)	-۳/۰۵۹(۰/۰۰۲*)	-	-
SPSOSVR	-۲/۶۶۷(۰/۰۰۸*)	-۳/۰۵۹(۰/۰۰۲*)	-۲/۹۸۱(۰/۰۰۳*)	-۳/۰۵۹(۰/۰۰۲*)	-۳/۰۵۹(۰/۰۰۲*)	-۰/۶۲۸(۰/۵۳۰)	-
SFOASVR	-۲/۱۱۸(۰/۰۰۳۴*)	-۲/۵۱(۰/۰۰۱۲*)	-۲/۷۴۶(۰/۰۰۶*)	-۲/۸۲۴(۰/۰۰۵*)	-۳/۰۵۹(۰/۰۰۲*)	-۰/۱۵۷(۰/۸۷۵)	-۰/۷۰۶(۰/۴۸۰)

پرانتز: مقدار استاندارد (p-value). * تفاوت قابل توجه در $\alpha = 0/05$

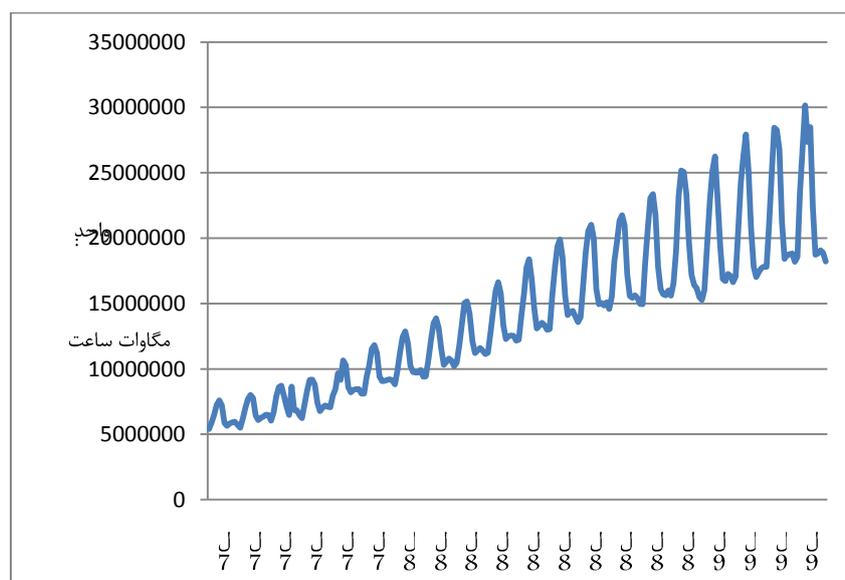
که هر روشی که خطای مطلق آن کمتر شد، در واقع بهتر پیش‌بینی کرده است. خطای مطلق با توجه به رابطه ۲۵ محاسبه می‌شود:

$$E_{abs} = |f_t - \hat{f}_t| \quad (25)$$

که در این رابطه E_{abs} نشان‌دهنده مخفف خطای مطلق (Absolute Error)، f_t نشان‌دهنده مقدار واقعی و \hat{f}_t نشان‌دهنده مقدار پیش‌بینی است [۳۳]. در جدول ۶ خطاهای مطلق هر روش برای هر ماه به‌منظور تولید برق ماهانه ایران آمده است. مواردی که مشخص شده است نشان می‌دهد در هر ماه آن روش پیش‌بینی بهتری از بقیه روش‌ها داشته است؛ برای نمونه تولید برق هم آزمون رتبه علامت‌دار ویلکاکسون برای اینکه آیا مدل SFOASVR پیشنهادی به‌طور قابل‌توجه بهتر از مدل‌های دیگر است، انجام شده است. مدل SVR بدون تنظیم فصلی در نظر گرفته نشده است. جدول ۷ نتایج حاصل از آزمون رتبه ویلکاکسون را برای پیش‌بینی با استفاده از مدل‌های SARIMA، BPNN، ACOSVR، PSOSVR، SFOASVR، SACOSVR، FOASVR و SPSOSVR نشان می‌دهد. مدل SFOASVR پیشنهادی در نمونه تولید برق ایران نیز تا حد زیادی انحراف کمی میان مقادیر پیش‌بینی و مقادیر واقعی دارد و از بیشتر مدل‌های دیگر مقایسه‌شده به‌طور چشمگیری بهتر است.

شبیه‌سازی مثال دوم

در مثال دوم، کل تولید برق ماهانه ایران به کمک ۹ مدل مدنظر پیش‌بینی شده است. نمودار داده‌های نرمال‌شده کل تولید برق ماهانه ایران از فروردین‌ماه سال ۱۳۷۴ تا اسفندماه سال ۱۳۹۳ در شکل ۳ آورده شده است. جدول ۵ فهرست نتایج پیش‌بینی تولید ماهانه برق را در سال ۱۳۹۳ و مقادیر RMSE و MAPE را نشان می‌دهد. نتایج پیش‌بینی تولید برق هم مشابه نیاز مصرف برق است؛ تنها تفاوت در مقایسه میان مدل BPNN با سایر مدل‌هاست. با توجه به مقادیر RMSE و MAPE در جدول ۵ مدل BPNN برتر از مدل SARIMA، SVR، ACOSVR، PSOSVR، FOASVR و SPSOSVR است، اما برتر از SFOASVR، SACOSVR و SPSOSVR نیست. علاوه‌براین SFOASVR پیشنهادی هنوز هم برتر از مدل‌های SARIMA، BPNN، SVR، ACOSVR، PSOSVR، FOASVR، SACOSVR و SPSOSVR است که در جدول ۵ آمده است؛ بنابراین مدل SFOASVR پیشنهادی، جایگزینی بسیار امیدوارکننده برای سایر روش‌های موجود پیش‌بینی نیاز مصرف برق است. در این بخش، بحث دیگری را هم می‌توان مطرح کرد که در هر ماه کدام روش بهتر پیش‌بینی کرده است. این موضوع را می‌توان با استفاده از خطای مطلق انجام داد



شکل ۳. کل تولید ماهانه نرمال‌شده شبکه برق ایران در طول فروردین سال ۱۳۷۴ تا اسفند سال ۱۳۹۳

جدول ۵. نتایج پیش‌بینی تولید برق ماهانه ایران برای هر مدل (واحد: مگاوات ساعت)

ماه	واقعی	SARIMA	BPNN	SVR	ACOSVR	PSOSVR	FOASVR	SACOSVR	SPSOSVR	SFOASVR
فروردین ۱۳۹۳	۱۸۵۵۵۵۴۷/۷	۲۴۵۹۷۴۱۷	۲۴۵۷۹۴۹۲	۲۶۱۱۲۳۰۰	۲۵۸۲۶۶۵۹	۲۵۲۰۶۰۲۹/۶	۲۶۴۸۴۵۳۰/۱	۱۵۹۸۰۸۷۲	۱۵۶۱۳۴۹۱	۱۶۴۸۶۲۸۸
اردیبهشت ۱۳۹۳	۲۳۵۳۰۱۳۸/۷	۲۵۹۵۳۶۰۲	۲۶۹۵۸۷۰۴	۲۸۱۶۷۰۴۳	۲۸۴۵۲۱۶۶	۲۷۶۰۵۸۶۷/۴	۲۷۷۵۰۸۱۹/۹	۲۰۸۹۲۴۳۲	۲۰۳۱۰۴۷۵	۲۰۵۶۰۹۶۰
خرداد ۱۳۹۳	۲۶۸۴۵۸۶۳/۲	۲۷۶۷۳۹۴۹	۲۸۹۵۷۹۸۶	۲۸۰۶۶۷۷۸	۲۸۲۳۳۳۲۵	۲۷۹۱۳۱۳۵/۶	۲۸۱۲۶۹۶۰/۱	۲۴۲۰۵۴۳۴	۲۳۸۲۳۷۳۳	۲۴۶۲۰۱۱۰
تیر ۱۳۹۳	۳۰۱۵۶۴۶۴/۸	۲۹۴۵۶۹۸۰	۲۸۹۵۷۹۹۱	۲۷۸۹۳۱۸۷	۲۸۱۰۰۰۵۱	۲۷۹۱۳۱۳۵/۶	۲۸۵۸۳۱۹۵/۹	۲۶۴۳۳۷۱۳	۲۶۲۱۴۴۵۱	۲۷۶۵۱۲۸۰
مرداد ۱۳۹۳	۲۷۳۵۲۱۷۸/۶	۲۹۹۴۲۷۲۱	۲۸۹۵۷۹۹۱	۲۷۰۰۱۳۴۵	۲۶۹۵۵۱۹۶	۲۷۹۱۳۱۳۵/۶	۲۸۳۷۱۲۱۶/۳	۲۵۸۱۹۱۸۸۷	۲۶۷۹۴۳۱۶	۲۸۰۴۰۸۰۶
شهریور ۱۳۹۳	۲۸۴۹۸۴۳۳/۹	۲۸۶۱۵۴۴۶	۲۸۹۵۷۹۱۰	۲۸۸۶۴۰۱۰	۲۸۶۲۶۳۳۴	۲۷۹۱۳۱۳۵/۶	۲۸۹۲۴۱۹۱/۸	۲۵۵۲۳۰۵۹	۲۴۸۶۵۱۴۵	۲۶۲۴۲۳۷۱
مهر ۱۳۹۳	۲۳۳۵۵۱۶۵/۷	۲۶۴۰۹۷۷۷	۲۶۳۹۶۰۹۹	۲۴۶۴۳۳۲۵	۲۵۶۷۸۱۸۰	۲۷۰۳۹۰۳۸	۲۵۹۶۰۵۶۱/۷	۱۸۷۷۱۸۸۷	۱۹۸۱۰۷۲۵	۱۹۳۷۷۱۳۹
آبان ۱۳۹۳	۱۸۷۲۷۳۴۳/۲	۲۴۶۷۱۴۳۳	۲۴۶۶۵۰۲۱	۲۴۶۳۳۰۸۰	۲۴۴۱۱۶۷۸	۲۵۲۹۳۸۲۳/۴	۲۴۸۷۷۳۲۸/۳	۱۵۷۹۰۴۹۹	۱۶۴۳۸۱۱۰	۱۶۲۳۲۱۹۹
آذر ۱۳۹۳	۱۸۸۲۷۵۷۵	۲۴۸۲۰۱۰۳	۲۴۶۹۲۶۲۸	۲۴۵۶۳۳۱۶	۲۴۰۶۰۶۰۱	۲۵۳۳۷۲۶۰/۸	۲۴۸۵۰۷۷۰/۶	۱۵۳۱۹۱۵۲	۱۶۲۶۶۰۸۴	۱۵۸۷۹۰۹۵
دی ۱۳۹۳	۱۹۰۶۱۱۸۵/۲	۲۵۲۲۷۵۶۰	۲۴۶۴۹۲۳۴	۲۴۷۸۹۲۱۵	۲۴۵۶۷۸۲۳	۲۵۴۴۹۹۵۸/۸	۲۵۰۳۳۴۶۳/۸	۱۵۷۳۰۷۸۸	۱۶۴۳۰۵۴۷	۱۶۱۱۸۸۵۱
بهمن ۱۳۹۳	۱۸۸۷۸۸۸۲/۴	۲۵۱۴۰۰۸۶	۲۴۶۴۸۳۹۱	۲۹۰۳۹۷۱۸	۲۸۹۵۰۷۷۱	۲۵۳۶۲۰۱۲/۴	۲۴۹۴۵۵۱۷/۴	۱۸۵۱۹۳۱۰	۱۶۳۰۵۰۷۶	۱۶۰۴۲۷۴۷
اسفند ۱۳۹۳	۱۸۲۰۸۵۹۵/۶	۲۴۷۵۶۵۸۵	۲۴۳۸۷۹۲۲	۲۴۳۷۷۹۱۰	۲۳۶۷۸۶۲۸	۲۵۰۹۳۶۱۱/۸	۲۳۹۶۰۱۷۶/۹	۱۴۸۱۲۰۸۸	۱۵۷۶۴۴۴۷	۱۵۱۱۵۳۶۳
RMSE		۴۶۴۲۸۲/۴	۴۵۲۱۱۶۰/۲	۵۲۶۳۷۱۵/۲	۵۱۳۱۶۰۹/۵	۵۰۴۳۳۱۰/۴۶	۴۸۱۷۹۰۶/۷	۲۹۱۶۴۴۹	۲۸۱۲۴۷۵/۱	۲۵۸۱۹۸۵/۳
MAPE (درصد)		۲۰/۱۰۴۷۴۱	۲۰/۰۸۶۲۷۶	۲۲/۰۸۰۵۷	۲۱/۶۳۴۰۶۶	۲۲/۰۷۲۳۸۸۲	۲۰/۹۸۴۷۸۲۱	۱۲/۶۲۴۹۶۹	۱۲/۲۲۷۹۲۷	۱۱/۱۱۶۸۲۵

جدول ۶. خطای مطلق نتایج پیش‌بینی تولید برق ماهانه ایران برای هر مدل (واحد: مگاوات ساعت)

ماه	SARIMA	BPNN	SVR	ACOSVR	PSOSVR	FOASVR	SACOSVR	SPSOSVR	SFOASVR
فروردین ۱۳۹۳	۶۰۴۱۸۶۹/۱	۶۰۲۳۹۴۴/۵	۷۵۵۶۷۵۲/۱	۷۲۷۱۱۱۱	۶۶۵۰۴۸۱/۹	۷۹۲۸۹۸۲/۴	۲۵۷۴۶۷۵/۶۵۷	۲۹۴۲۰۵۶/۵	۲۰۶۹۲۵۹/۶۴
اردیبهشت ۱۳۹۳	۲۴۲۳۴۶۳/۱	۳۴۲۸۵۶۵/۳	۴۶۳۶۰۳/۹	۴۹۲۲۰۲۷/۸	۴۰۷۵۲۸۸/۷	۴۲۲۰۶۸۱/۲	۲۶۳۷۷۰۶/۶۴۸	۳۲۱۹۶۶۴/۱	۲۹۶۹۱۷۸/۵۵
خرداد ۱۳۹۳	۸۲۸۰۸۶/۱۳	۲۱۱۲۱۲۲/۴	۱۲۲۰۹۱۵	۱۴۷۷۴۶۱/۴	۱۰۶۷۲۷۲/۴	۱۲۸۱۰۹۶/۹	۲۶۴۰۴۲۹/۱۱۷	۳۰۱۲۱۳۰/۲	۲۲۲۵۷۵۲/۸۷۷
تیر ۱۳۹۳	۶۹۹۴۸۵/۲۵	۱۱۹۸۴۷۳/۷	۲۲۶۳۲۷۸	۲۰۵۶۴۱۳/۹	۲۲۴۳۳۲۹/۲	۱۵۷۳۳۶۸/۹	۳۷۳۲۷۵۱/۵۶۷	۳۹۴۲۰۱۴/۲	۲۵۰۵۱۸۴/۳۱
مرداد ۱۳۹۳	۲۵۹۰۵۴۲/۵	۱۶۰۵۸۱۲/۵	۳۵۰۸۳۳/۴۶	۳۹۶۹۸۲/۰۹	۵۶۰۹۵۶/۹۶	۱۰۱۹۰۳۷/۷	۱۴۶۰۲۹۱/۳۷۴	۵۵۷۸۶۲/۲۹	۶۸۸۶۲۷/۶۹۰۹
شهریور ۱۳۹۳	۱۱۷۰۱۲/۲۴	۴۵۹۴۷۶/۳۵	۳۶۵۵۷۶/۰۶	۱۴۴۲۰۰/۴۹	۵۸۵۲۹۸/۳۴	۴۲۵۷۵۷/۹۲	۲۹۷۵۳۷۴/۷۶۳	۳۶۳۳۲۸۸/۹	۲۲۵۶۰۶۲/۹۷۱
مهر ۱۳۹۳	۴۰۵۴۶۱۱/۴	۴۰۴۰۹۳۲/۸	۲۲۸۸۱۵۹/۱	۳۳۳۳۸۱۴/۳	۴۶۸۳۸۷۲/۳	۳۶۰۵۳۹۶	۳۵۸۳۲۷۸/۹۹۴	۲۵۴۴۴۴/۵	۲۹۷۸۰۲۶/۸۸۶
آبان ۱۳۹۳	۵۹۳۳۸۹۸/۵	۵۹۲۷۸۶/۹	۵۸۹۵۵۴۵/۷	۵۶۷۴۱۳۳/۴	۶۵۵۶۲۸۹/۲	۶۱۳۹۷۹۴/۱	۲۹۴۷۰۳۵/۱۰۹	۲۲۹۹۴۴۴/۳	۲۵۰۵۳۳۴/۹۸۱
آذر ۱۳۹۳	۵۹۹۲۵۲۷/۷	۵۸۶۵۰۵۲/۹	۵۷۳۵۷۴۰/۹	۵۲۳۳۰۲۵/۸	۶۵۰۹۶۸۵/۸	۶۰۲۳۱۹۵/۶	۳۵۰۸۴۲۲/۵۷۸	۲۵۶۱۴۹۱/۵	۲۹۶۸۴۸۰/۲۶۴
دی ۱۳۹۳	۶۱۶۶۳۷۴/۴	۵۵۸۸۰۳۸/۷	۵۷۲۸۰۳۰/۲	۵۵۰۶۶۳۷/۷	۶۳۸۱۷۷۳/۶	۵۹۷۲۲۷۸/۶	۳۳۳۰۳۹۷/۵۸۹	۲۶۳۰۶۳۸/۱	۲۹۶۲۳۳۴/۵۶۲
بهمن ۱۳۹۳	۶۲۶۱۲۰۳/۳	۵۷۶۹۵۰۸/۱	۱۰۱۶۰۸۳۶	۱۰۰۷۱۸۸۹	۶۴۸۳۱۳۰	۶۰۶۶۶۳۵	۳۵۹۵۷۲/۳۲۱۷	۲۵۷۳۸۰۶/۵	۲۸۴۶۱۳۵/۴۷۳
اسفند ۱۳۹۳	۶۵۴۷۹۸۹/۱	۶۱۷۹۳۲۶	۶۱۶۹۳۱۴/۲	۵۴۷۰۰۳۲/۶	۶۸۸۵۰۱۶/۲	۵۷۵۱۵۸۱/۳	۳۳۹۶۵۰۷/۵۸۸	۲۴۴۴۱۴۸/۷	۳۰۹۳۳۲۲/۶۳۳

جدول ۷. آزمون رتبه علامت‌دار ویلکاکسون برای نتایج پیش‌بینی تولید برق ایران برای هر مدل

	SARIMA	BPNN	ACOSVR	PSOSVR	FOASVR	SACOSVR	SPSOSVR
BPNN	-۰/۸۶۳(۰/۳۸۸)	-	-	-	-	-	-
ACOSVR	-۰/۳۹۲(۰/۶۹۵)	-۰/۶۲۸(۰/۵۳۰)	-	-	-	-	-
PSOSVR	-۰/۶۲۸(۰/۵۳۰)	-۰/۳۳۵(۰/۸۱۴)	-۰/۹۴۱(۰/۳۴۷)	-	-	-	-
FOASVR	-۰/۰۷۸(۰/۹۳۷)	-۰/۱۵۷(۰/۸۷۵)	-۱/۳۳۴(۰/۱۸۲)	-۰/۰۷۸(۰/۹۳۷)	-	-	-
SACOSVR	-۳/۰۵۹(۰/۰۰۲*)	-۳/۰۵۹(۰/۰۰۲*)	-۳/۰۵۹(۰/۰۰۲*)	-۳/۰۵۹(۰/۰۰۲*)	-۳/۰۵۹(۰/۰۰۲*)	-	-
SPSOSVR	-۳/۰۵۹(۰/۰۰۲*)	-۳/۰۵۹(۰/۰۰۲*)	-۳/۰۵۹(۰/۰۰۲*)	-۳/۰۵۹(۰/۰۰۲*)	-۳/۰۵۹(۰/۰۰۲*)	۰(۱)	-
SFOASVR	-۳/۰۵۹(۰/۰۰۲*)	-۳/۰۵۹(۰/۰۰۲*)	-۳/۰۵۹(۰/۰۰۲*)	-۳/۰۵۹(۰/۰۰۲*)	-۳/۰۵۹(۰/۰۰۲*)	-۱/۳۵۵(۰/۲۰۹)	-۱/۳۳۴(۰/۱۸۲)

پراتنز: مقدار استاندارد (p-value). * تفاوت چشمگیر در $\alpha = 0.05$

نتیجه‌گیری

برق، مدل‌های پیوندی با SVR عملکرد بهتری در پیش‌بینی دارند، اما در نمونه بزرگ تولید برق، عملکرد BPNN برتر از مدل‌های پیوندی است، اما تنظیم شاخص فصلی سبب می‌شود در هر دو نمونه مدل‌هایی که تنظیم شاخص فصلی را در نظر گرفتند، برتر از مدل‌های دیگر باشند.

FOA می‌تواند سه مقدار مناسب پارامتر مدل SVR را که عملاً می‌تواند دقت پیش‌بینی نیاز مصرف برق ماهانه را تشکیل دهد، انتخاب کند. علاوه بر این با توجه به مزیت FOA در رسیدن به راه‌حل بهینه سراسری سریع، سرعت بهینه‌سازی FOA سریع‌تر از ACO و PSO است. در همین حال، براساس مقادیر RMSE و MAPE، مدل SFOASVR عملکردی بهتر از مدل SACOSVR و SPSOSVR در پیش‌بینی نیاز مصرف برق ماهانه دارند. در نتیجه مدل SFOASVR پیشنهادی، ابزار پیش‌بینی قابل‌اعتمادی است و به طور مؤثر، دقت پیش‌بینی نیاز مصرف برق ماهانه را بهبود می‌بخشد.

در پژوهش‌های آینده می‌توان به بررسی دیگر الگوریتم‌های بهینه‌سازی پیشرفته، برای تعیین پارامترهای مدل رگرسیون بردار پشتیبان (SVR) مثل الگوریتم خفاش (Bat Algorithm) و دیگر مکانیسم‌ها مانند روند یا تمایل بلندمدت (trend) برای پیوند زدن با مدل پیش‌بینی SVR پرداخت.

پیش‌بینی دقیق نیاز مصرف برق می‌تواند به اجرای سیاست‌های انرژی کمک چشمگیری کند. در این پژوهش، داده‌های نیاز مصرف برق ماهانه ایران روند رشد قوی و فصلی آشکار را نشان می‌دهند. به‌منظور بهبود دقت پیش‌بینی با ویژگی‌های غیرخطی و فصلی، در این پژوهش پیشنهاد پیوند مدل SVR فصلی با الگوریتم بهینه‌سازی مگس میوه (SFOASVR) صورت گرفت که در آن الگوریتم تکاملی جدیدی به نام FOA استفاده شده است که نتیجه آن مقادیر مناسب جست‌وجوی سه پارامتر پیشنهادی در مدل SVR است. در این میان مکانیسم فصلی برای مقابله با تمایل فصلی هم اعمال شده است. برای مقایسه، مدل‌های دیگر (SARIMA, BPNN, SVR, SACOSVR, SPSOSVR) انتخاب شده‌اند. علاوه بر این به‌منظور بررسی عملکرد مکانیسم تنظیم فصلی، ACOSVR, PSOSVR و مدل FOASVR (بدون نیاز به تنظیم شاخص فصلی) نیز در مقایسه در نظر گرفته شده‌اند. با توجه به نیاز مصرف برق ماهانه ایران در طول فروردین‌ماه سال ۱۳۸۹ تا اسفندماه سال ۱۳۹۴ و تولید برق ماهانه ایران در طول فروردین‌ماه سال ۱۳۷۴ تا اسفندماه سال ۱۳۹۳ به‌عنوان نمونه، نتایج پیش‌بینی مدل‌های مختلف به‌دست آمده است. نتایج تجربی در دو نمونه مشاهده می‌شود: در نمونه کوچک نیاز مصرف

منابع

1. (2016). Detailed Statistics of Iran's Power Industry Specially Produced In 1394, Tehran, Tavanir Specialized Parent Company.
2. Ssaadatpisheh, S. (2012). Estimation of Urban Traffic Using the SVR Model by Ant Colony Optimization Algorithm, Master's Thesis, Operational Research, Faculty of Science, Shiraz University of Technology.
3. Site of Tavanir Specialist Company, Joint Stock Company for Production, Transfer and Distribution of Iran's Power: [Http://Tavanir.Org.Ir](http://Tavanir.Org.Ir).

4. Kiani, M. et al. (2015). "An Efficient Genetic Algorithm for the Routing of Vehicles, Considering the Skills of Team Workers", *Journal of Industrial Engineering.*, Vol. 49, No. 2, PP. 257-277.
5. Mirtalayi, M. et al. (2012). "A Trust-Based Intelligent Algorithm for Determining Customer Values in a Financial System", *Journal of Industrial Engineering*, Vol. 46, No. 1, PP. 91-104.
6. Tan, P. et al. (2015). "Estimation of Higher Heating Value of Coal Based on Proximate Analysis Using Support Vector Regression", *Fuel Processing Technology*, Vol. 138, PP. 298-304.
7. Pan, W.T. (2012). "A New Fruit Fly Optimization Algorithm: Taking the financial Distress Model As An Example", *Knowledge-Based Systems.*, Vol. 26, PP.69-74.
8. Li, T. et al. (2016). "An Ensemble Fruit Fly Optimization Algorithm for Solving Range Image Registration to Improve Quality Inspection of Free-Form Surface Parts", *Information Sciences*, Vol. 367-368, PP. 953-974.
9. Aladag, C. H. (2011). "A New Architecture Selection Method Based on Tabu Search for Artificial Neural Networks", *Expert Systems with Applications*, Vol. 38, No. 4, PP. 3287-3293.
10. Wang, J. et al. (2012). "The Model of Chaotic Sequences Based on Adaptive Particle Swarm Optimization Arithmetic Combined with Seasonal Term", *Applied Mathematical Modelling*, Vol. 36, No. 3, PP. 1184-1196.
11. Kiran, M. S. et al. (2012). "Novel Hybrid Approach Based on Particle Swarm Optimization and Ant Colony Algorithm to Forecast Energy Demand of Turkey", *Energy Conversion and Management*, Vol. 53, No. 1, PP. 75-83.
12. Lee, S., and Choi, W. S. (2013). "A Multi-Industry Bankruptcy Prediction Model Using Back-Propagation Neural Network and Multivariate Discriminant Analysis", *Expert Systems with Applications*, Vol. 40, No. 8, PP. 2941-2946.
13. Hong, W. C. et al. (2013). "Cyclic Electric Load Forecasting by Seasonal SVR with Chaotic Genetic Algorithm", *Electrical Power and Energy Systems*, Vol. 44, No. 1, PP. 604-614.
14. Xiong, T, Bao, Y., and Hu. Z. (2014). "Interval Forecasting of Electricity Demand: A Novel Bivariate EMD-Based Support Vector Regression Modeling Framework", *Electrical Power and Energy Systems*, Vol. 63, PP. 353-362.
15. Meng, Q., Ma, X., and Zhou, Y. (2014). "Forecasting of Coal Seam Gas Content by Using Support Vector Regression Based on Particle Swarm Optimization", *Journal of Natural Gas Science and Engineering*, Vol. 21, PP. 71-78.
16. Jamian, J. J. et al. (2014). "Simulation Study on Optimal Placement and Sizing of Battery Switching Station Units Using Artificial Bee Colony Algorithm", *Electrical Power and Energy Systems*, Vol. 55, PP. 592-601.
17. Yan, X. and Chowdhury, N. A. (2014). "Mid-Term Electricity Market Clearing Price Forecasting: A Multiple Svmapproach", *Electrical Power and Energy Systems*, Vol. 58, PP. 206-214.
18. Cai, Q. et al. (2015). "A New Fuzzy Time Series Forecasting Model Combined with Ant Colony Optimization and Auto-Regression", *Knowledge-Based Systems*, Vol. 74, PP. 61-68.
19. Li, K. et al. (2015). "Building's Electricity Consumption Prediction Using Optimized Artificial Neural Networks and Principal Component Analysis", *Energy and Buildings*, Vol. 108, PP. 106-113.
20. Zhu, L. et al. (2015). "Short-Term Natural Gas Demand Prediction Based on Support Vector Regression with False Neighbours filtered", *Energy*, Vol. 80, PP. 428-436.
21. Wolff, B. et al. (2016). "Comparing Support Vector Regression for PV Power Forecasting to a Physical Modeling Approach Using Measurement, Numerical Weather Prediction, and Cloud Motion Data", *Solar Energy*, Vol. 135, PP. 197-208.
22. Sun, W., and Xu, Y. (2016). "Financial Security Evaluation of the Electric Power Industry in China Based on a Back Propagation Neural Network Optimized by Genetic Algorithm", *Energy*, Vol. 101, PP. 366-379.
23. Dong, Z. et al. (2015). "A Novel Hybrid Approach Based on Self-Organizing Maps, Support Vector Regression and Particle Swarm Optimization to Forecast Solar Irradiance", *Energy*, Vol. 82, PP. 570-577

24. Jiang, B. T. and Zhao, F. Y. (2013). "Particle Swarm Optimization-Based Least Squares Support Vector Regression for Critical Heat Flux Prediction", *Annals of Nuclear Energy*, Vol. 53, PP. 69–81.
25. Cao, G. and Wu, L. (2016). "Support Vector Regression with Fruit fly Optimization Algorithm for Seasonal Electricity Consumption Forecasting", *Energy*, Vol. 115, PP. 734-745.
26. Wua, C., Tzeng, G., and Lin, R. (2009). "A Novel Hybrid Genetic Algorithm for Kernel Function and Parameter Optimization in Support Vector Regression", *Expert Systems with Applications*, Vol. 36, PP. 4725-4735.
27. Li, H. et al. (2013). "A Hybrid Annual Power Load Forecasting Model Based on Generalized Regression Neural Network with Fruit Fly Optimization Algorithm", *Knowledge-Based Systems*, Vol. 37, PP. 378–387.
28. Niu, J. et al. (2015). "Fruit Fly Optimization Algorithm Based on Differential Evolution and Its Application on Gasification Process Operation Optimization", *Knowledge-Based Systems*, Vol. 88, PP. 253-263.
29. Deo, R., Hurvich, C., and Lu, Y. (2006). "Forecasting Realized Volatility Using a Long-Memory Stochastic Volatility Model: Estimation, Prediction and Seasonal Adjustment", *Journal of Econometrics*, Vol. 131, No. 1 and 2, PP. 29–58.
30. Wei, Y., and Cao, Y. (2017). "Forecasting House Prices Using Dynamic Model Averaging Approach: Evidence from China", *Economic Modelling*, Vol. 61, PP. 147–155.
31. Ghose, D. K., Panda, S. S., and Swain, P. C. (2010). "Prediction of Water Table Depth in Western Region, Orissa Using BPNN and RBFN Neural Networks", *Journal of Hydrology*, Vol. 394, No. 3 and 4, PP. 296–304.
32. Perolat, J. et al. (2015). "Generalizing the Wilcoxon Rank-Sum Test for Interval Data", *International Journal of Approximate Reasoning*, Vol. 56, PP. 108–121.
33. Myttenaere, A. et al. (2016). "Mean Absolute Percentage Error For Regression Models", *Neurocomputing*, Vol. 192, PP. 38–48.

واژگان انگلیسی به ترتیب استفاده در متن

1. Seasonal Fruit fly Optimization Algorithm Support Vector Regression
2. Radial Basis Function
3. Back Propagation Neural Network
4. Location Range
5. Flight Range
6. Seasonal Auto Regressive Integrated Moving Average
7. Seasonal Ant Colony Optimization Support Vector Regression
8. Seasonal Particle Swarm Optimization Support Vector Regression
9. Root Mean Square Error
10. Mean Absolute Percentage Error