

The Electricity Consumption Prediction using Hybrid Red Kite Optimization Algorithm with Multi-Layer Perceptron Neural Network

Jalal Raeisi-Gahruei^{1,2}, M.Sc., Zahra Beheshti^{1,2}, Assistant Professor

¹Faculty of Computer Engineering- Najafabad Branch, Islamic Azad University, Najafabad, Iran

²Big Data Research Center- Najafabad Branch, Islamic Azad University, Najafabad, Iran
j.raeisi@sco.iaun.ac.ir, z-beheshti@iaun.ac.ir

Abstract

Since the electricity consumption's prediction is one of the most important aspects of energy management in each country, various methods based on artificial intelligence have been proposed to manage it. One of these methods is Artificial Neural Networks (ANN). To improve the performance of ANNs, an efficient algorithm is necessary to train it. Back Propagation (BP) algorithm is the most common algorithm employed in training ANNs, which is based on gradient descent. Since BP may fall in local optima, it cannot provide a good solution in some problems. To overcome this shortcoming, optimization algorithms like meta-heuristic algorithms can be applied to train ANNs. In this study, a new meta-heuristic algorithm called Red Kite Optimization Algorithm (ROA) is introduced, which is inspired by the social life of red kites in nature. The ROA has several advantages such as simplicity in structure and implementation, having few parameters and good convergence rate. The performance of ROA is compared with some recent metaheuristic algorithms on benchmark functions of CEC2018. Also, it is employed to train Multi-Layer Perceptron (MLP) for the electricity consumption prediction at peak load times in Iran. The results show the good performance of proposed algorithm compared with competitor algorithms in terms of solution accuracy and convergence speed.

Keywords: electricity consumption prediction, meta-heuristic algorithm, multi-layer perceptron neural network, red kite optimization algorithm

Received: 24 May 2022

Revised: 7 August 2022

Accepted: 22 September 2022

Corresponding Author: Dr. Zahra Beheshti

پیش‌بینی مصرف برق با استفاده از الگوریتم جدید بهینه‌سازی زغن و شبکه عصبی مصنوعی پرسپترون چند لایه

جلال رئیسی گهرویی^{۱،۲}، دانش‌آموخته کارشناسی ارشد، زهرا بهشتی^{۱،۲}، استادیار

۱- دانشکده مهندسی کامپیوتر- واحد نجف‌آباد، دانشگاه آزاد اسلامی، نجف‌آباد، ایران

۲- مرکز تحقیقات کلان داده- واحد نجف‌آباد، دانشگاه آزاد اسلامی، نجف‌آباد، ایران

j.raeisi@sco.iaun.ac.ir, z-beheshti@iaun.ac.ir

چکیده: از آنجا که پیش‌بینی مصرف برق از موارد مهم مدیریت انرژی هر کشور محسوب می‌شود، در سال‌های اخیر روش‌های مختلفی براساس هوش مصنوعی برای آن ارائه شده است. یکی از این روش‌ها، استفاده از شبکه‌های عصبی مصنوعی است. برای آن که این شبکه‌ها عملکرد خوبی داشته باشند، باید به خوبی آموزش ببینند. یکی از متداول‌ترین الگوریتم‌های آموزش مورد استفاده در این شبکه‌ها، الگوریتم پس انتشار خطاست که براساس گرادیان نزولی است. از آنجا که الگوریتم‌های مبتنی بر گرادیان نزولی ممکن است به نقاط بهینه محلی گرفتار شوند، در برخی از مسائل راه حل خوبی ارائه نمی‌دهند. از این رو برای آموزش این شبکه‌ها می‌توان از الگوریتم‌های بهینه‌سازی مانند الگوریتم‌های فراابتکاری که امکان فرار از بهینه‌های محلی را دارند، استفاده نمود. در این تحقیق، الگوریتم فراابتکاری جدیدی به نام الگوریتم بهینه‌سازی زغن معرفی می‌گردد که از زندگی اجتماعی زغن‌ها در طبیعت الهام گرفته شده است و دارای مزایایی مانند تعداد پارامترهای کم، قابلیت اکتشاف و سرعت همگرایی خوب، است. کارایی الگوریتم پیشنهادی، با چند الگوریتم جدید فراابتکاری روی توابع محک CEC2018 و برای آموزش شبکه عصبی در پیش‌بینی مصرف برق ایران در زمان‌های اوج مصرف بار، مقایسه گردیده است. نتایج حاصل، نشان می‌دهد الگوریتم پیشنهادی راه حل بهتری با خطای کمتری، در مقایسه با الگوریتم‌های رقیب به دست می‌آورد.

کلمات کلیدی: الگوریتم‌های فراابتکاری، الگوریتم بهینه‌سازی زغن، پیش‌بینی مصرف برق، شبکه‌های عصبی پرسپترون چندلایه

تاریخ ارسال مقاله: ۱۴۰۱/۳/۳

تاریخ بازنگری مقاله: ۱۴۰۱/۴/۵

تاریخ پذیرش مقاله: ۱۴۰۱/۶/۳۱

نام نویسنده‌ی مسئول: دکتر زهرا بهشتی

نشانی نویسنده‌ی مسئول: نجف‌آباد- بلوار دانشگاه- دانشگاه آزاد اسلامی واحد نجف‌آباد- دانشکده مهندسی کامپیوتر

۱- مقدمه

یکی از مسائل حائز اهمیت در بهره‌برداری و توسعه بهینه انرژی، اطلاع از میزان تقاضای آن در دوره‌های آینده است [۱-۳]. تاکنون روش‌های مختلفی برای پیش‌بینی و تخمین تقاضای انرژی ارائه شده است [۴-۷] که در اغلب آنها از مدل‌های ریاضی، شبکه‌های عصبی مصنوعی، سیستم‌های فازی^۱ و حداقل رگرسیون^۲ مربع جزئی برای پیش‌بینی‌های مختلف مانند پیش‌بینی میزان برق مصرفی مشترکان، تخمین مدل تقاضای نفت، سوخت‌های فسیلی، مصرف آب و غیره استفاده شده است. با توجه به آمارهای منتشر شده، تقاضای برق در ایران به عنوان یکی از حامل‌های انرژی، در طول سال‌های متوالی افزایش یافته و انتظار می‌رود این روند افزایشی همچنان ادامه داشته باشد، حتی در شرایط پاندمی کرونا در ایران، در کوتاه‌مدت با کاهش نسبی تقاضای برق مواجه گردیده ولی با ادامه یافتن شیوع کرونا و حذف برخی محدودیت‌ها، وضعیت مصرف برق کمابیش به وضعیت قبل از کرونا بازگشته است [۸].

با توجه به شرایط مختلف اقلیمی، تقاضای بار مصرفی نیز متفاوت خواهد بود، از این‌رو در یک گروه‌بندی کلی می‌توان پیش‌بینی بار مصرفی را در سه دسته کوتاه‌مدت، میان‌مدت و بلندمدت تقسیم کرد [۹-۱۱]. در این حوزه از پیش‌بینی کوتاه‌مدت بار مصرفی جهت تجزیه و تحلیل رخدادهای احتمالی و به طبع آن زمان وارد مدار کردن یا از مدار خارج کردن واحدهای تولید برق توسط دیسپاچینگ مرکز کنترل استفاده می‌شود. از پیش‌بینی میان‌مدت بار مصرفی جهت زمان‌بندی تعمیرات اساسی بهره می‌برند و همچنین از پیش‌بینی بلندمدت بار مصرفی جهت برنامه‌ریزی‌های توسعه زیر ساخت نیروگاهی و شبکه‌های توزیع استفاده می‌گردد [۱۲]. بنابراین، پیش‌بینی دقیق مصرف برق می‌تواند راه‌گشای مدیران جهت برنامه‌ریزی‌های دقیق‌تر باشد.

مدل‌های شبکه عصبی مصنوعی از سیستم‌های عصبی بیولوژیکی مغز الهام گرفته شده است و به طور گسترده در زمینه پیش‌بینی بار مصرفی استفاده شده‌اند [۱۳-۱۵]. این شبکه‌ها قادرند روابط غیرخطی دقیق را از میان متغیرهای ورودی، با استفاده از داده‌های آزمایشی استخراج کنند، لذا این شبکه‌ها توانایی انجام برازش منحنی را دارا هستند [۱۶]. همچنین شبکه‌های عصبی یک ابزار مناسب برای پیش‌بینی هستند به شرط آن که به خوبی آموزش دیده باشند. در یک شبکه عصبی بهترین خروجی، نسبت به داده ورودی جهت آموزش شبکه عصبی، زمانی به دست می‌آید که پارامترهای آن، به بهترین حالت تنظیم شده باشد تا خطای شبکه عصبی برای کل داده‌ها به حداقل برسد، از این رو پروسه آموزش شبکه عصبی تبدیل به یک مسأله بهینه‌سازی^۳ می‌شود.

یکی از معروف‌ترین الگوریتم‌هایی که برای آموزش شبکه‌های عصبی استفاده می‌شود الگوریتم پس انتشار خطاست^۴ که الگوریتمی برای یادگیری نظارتی شبکه عصبی با استفاده از گرادیان نزولی^۵ است [۱۷-۱۹]. در این الگوریتم، برای یک شبکه عصبی مصنوعی و تابع خطای مشخص، گرادیان تابع خطا نسبت به وزن‌های شبکه عصبی محاسبه می‌شود و براساس آن وزن‌های شبکه به روز می‌گردند [۲۰]. اگر چه این الگوریتم در برخی از موارد نتایج خوبی برای آموزش شبکه عصبی دارد اما به دلیل آن که براساس گرادیان نزولی است در بعضی مواقع به دام بهینه محلی گرفتار می‌آید و یا سرعت همگرایی در آن بسیار پایین است [۲۱-۲۳]. همچنین از معایب دیگر این الگوریتم، می‌توان وابستگی همگرایی آن به انتخاب مقادیر اولیه وزن‌های شبکه، بردارهای بایاس و پارامترها موجود در الگوریتم اشاره کرد [۲۴]. از این جهت، رویکرد استفاده از الگوریتم‌های بهینه‌سازی فراابتکاری که امکان فرار از بهینه‌های محلی را دارند، برای آموزش شبکه‌های عصبی می‌تواند گزینه مناسبی باشد [۲۵-۲۷]. الگوریتم‌های فراابتکاری در مسائل بهینه‌سازی پیوسته [۲۸-۳۱] و ناپیوسته [۳۲-۳۴] نتایج خوبی را ارائه کرده‌اند.

در این تحقیق الگوریتم فراابتکاری جدیدی به نام الگوریتم بهینه‌سازی زغن^۶ ارائه می‌گردد که از آن برای آموزش شبکه عصبی پرسپترون چند لایه^۷ در پیش‌بینی تقاضای برق به صورت کوتاه‌مدت و در زمان‌های اوج مصرف بار (پیک) استفاده می‌گردد. الگوریتم پیشنهادی که از رفتار دسته‌های زغن در طبیعت الهام گرفته شده است، دارای مزایایی است، از آن جمله می‌توان به تعداد پارامترهای کم، قابلیت اکتشاف و سرعت همگرایی خوب اشاره کرد که باعث می‌گردد نتایج خوبی را به دست آورد. الگوریتم پیشنهادی با الگوریتم بهینه‌سازی ملخ^۸ (GOA) [۳۵]، بهینه‌ساز کفتار خالدار^۹ (HSO) [۳۶]، بهینه‌ساز شاهین هریس^{۱۰} (HHO) [۳۷]، بهینه‌ساز رفتار سوسک بال‌آتشین^{۱۱} (FSBO) [۳۸] و الگوریتم بهینه‌سازی حسابی^{۱۲} [۳۹] که در حال

حاضر از الگوریتم‌های جدید هستند روی توابع CEC2018 [۴۰] برای ارزیابی قابلیت اکتشاف^{۱۳}، توازن بین اکتشاف و بهره‌برداری^{۱۴} و قابلیت بهره‌برداری مقایسه می‌گردد. همچنین کارایی الگوریتم پیشنهادی، جهت آموزش شبکه عصبی، برای پیش‌بینی مصرف برق ایران در زمان‌های پیک مصرف، بر روی داده‌های برق ایران از سال ۱۳۹۵ تا ۱۳۹۹ با الگوریتم‌های فوق مقایسه می‌گردد. نتایج شبیه‌سازی حاکی از عملکرد بسیار خوب الگوریتم پیشنهادی، در مقایسه با سایر الگوریتم‌ها است. ساختار مقاله در ادامه به این شرح است. در بخش دوم به پیشینه تحقیق در زمینه پیش‌بینی مصرف انرژی با شبکه‌های عصبی پرداخته می‌شود. در بخش سوم روش پیشنهادی شرح داده می‌شود که شامل الگوریتم بهینه‌سازی زغن و استفاده از آن برای آموزش شبکه عصبی است. در بخش چهارم، عملکرد الگوریتم پیشنهادی با الگوریتم‌های فراابتکاری ذکر شده بر روی توابع محک^{۱۵} CEC2018 و همچنین برای پیش‌بینی مصرف برق مقایسه می‌گردد و در بخش آخر به نتیجه‌گیری و پیشنهاداتی برای تحقیقات آینده براساس پژوهش فعلی اشاره می‌گردد.

۲- پیشینه تحقیق

امروزه از روش‌های مختلف مبتنی بر هوش مصنوعی، ابزارهای شبیه‌سازی و روش‌های مهندسی، برای پیش‌بینی تقاضای آینده مصرف انرژی بر اساس داده‌های موجود استفاده می‌شود. شهرها، بخش‌های صنعتی و ساختمانی به دلیل افزایش جمعیت جهان نیازمند روش‌های بهینه‌سازی و مدیریت کارآمد برای کاهش مصرف انرژی جهانی هستند [۴۲-۴۴]. بر همین اساس پژوهش‌های زیادی در این زمینه شده است که در ادامه به برخی از آنها پرداخته شده است.

روشی برای پیش‌بینی بار الکتریکی کوتاه-مدت با استفاده از الگوریتم بهینه‌سازی ازدحام ذرات^{۱۶} و شبکه عصبی مصنوعی با الگوریتم انتشار خطا به عقب در مرجع [۴۵] پیشنهاد شده که در این روش، یک شبکه عصبی سه لایه که در آن خطای پیش‌بینی شبکه عصبی به عنوان تابع هزینه الگوریتم ازدحام ذرات تعریف شده، طراحی گردیده است. نتایج شبیه‌سازی نشان دهنده قابلیت‌های برتر روش پیشنهادی در پیش‌بینی دقیق‌تر بار الکتریکی نسبت به الگوریتم انتشار خطا به عقب است. جهت پیش‌بینی میزان برق مصرفی، با استفاده از شبکه عصبی پرسپترون چندلایه، به همراه بهینه‌سازی پارامترهای آن توسط الگوریتمی به نام بهینه‌ساز چرخه آب^{۱۷}، در مرجع [۴۶] پیشنهاد شده است. این الگوریتم با دو الگوریتم دیگر یعنی الگوریتم بهینه‌ساز شیرمورچه^{۱۸} و الگوریتم بهینه‌ساز پرند ساتین^{۱۹} (نام پرند ای در استرالیا) مقایسه شده و نتایج ارزیابی نشان می‌دهد که ترکیب شبکه عصبی پرسپترون چند لایه با الگوریتم معرفی شده بهینه‌ساز چرخه آب، توانسته است خطای کمتری را در داده‌های آموزش و آزمون داشته باشد.

در مرجع [۴۷] رویکردی مبتنی بر یادگیری عمیق^{۲۰} برای پیش‌بینی تقاضا و مصرف انرژی جهت استفاده در بخش‌های صنعتی و ساختمانی پیشنهاد شد، که در آن برای تضمین عملکرد مدل، ابتدا پیش‌پردازش و نرمال‌سازی روی داده‌ها انجام گرفت. سپس با به‌کارگیری شبکه عصبی کانولوشن، و شبکه حافظه کوتاه‌مدت بر روی داده‌های سری زمانی، تقاضا و مصرف انرژی با بازه زمانی متفاوت پیش‌بینی گردید. در روش پیشنهادی، از مفهوم یادگیری فعال مبتنی بر میانگین متحرک^{۲۱}، برای اطمینان و بهبود عملکرد پیش‌بینی سیستم استفاده شد و با استفاده از مجموعه دادگان UCI و مجموعه دادگان ساختمان تجاری کشور کره جنوبی، ارزیابی صورت گرفت، که نشان‌دهنده میزان خطای پایین‌تر سیستم پیشنهادی در مقایسه با شبکه عصبی کانولوشن^{۲۲}، مدل رگرسیون، شبکه حافظه کوتاه‌مدت و روش ترکیبی شبکه عصبی کانولوشن با شبکه حافظه کوتاه‌مدت است. با این حال، روش پیشنهادی در این تحقیق نیاز زمان بسیار زیادی برای پیش‌بینی دارد.

یک روش ترکیبی با استفاده از شبکه عصبی المان^{۲۳} و الگوریتم بهینه‌سازی ازدحام ذرات، برای پیش‌بینی بار کوتاه‌مدت برق مصرفی در مرجع [۴۸] پیشنهاد شده که از الگوریتم بهینه‌سازی ازدحام ذرات برای تنظیم پارامترهای شبکه المان استفاده می‌شود. در این روش، علیرغم بهبود دقت روش پیشنهادی نسبت به سایر روش‌های مورد مقایسه، زمان زیادی طول می‌کشد تا پیش‌بینی انجام شود.

در پژوهشی که بر روی پیش‌بینی برق مصرفی یک ساختمان دانشگاهی، در روزهای کاری و غیرکاری که در مرجع [۴۹] انجام شد، این نتیجه برداشت گردید که میزان اشغال و شرایط محیطی محلی، مانند دما، نسبت رطوبت، تابش خورشیدی، نوع ابر و

سرعت باد، می‌تواند بر مصرف انرژی الکتریکی واقعی ساختمان دانشگاه برای روزهای کاری و غیر کاری تأثیر بگذارند. در این پژوهش دو مدل رگرسیون خطی و شبکه عصبی مورد مقایسه قرار گرفتند. نتایج نشان می‌دهد که شبکه عصبی دقیق‌تر و پایدارتر از روش رگرسیون خطی در پیش‌بینی مصرف برق برای روزهای کاری است، همچنین در روزهای کاری، نرخ اشغال ساختمان در کنار دما و رطوبت محیطی نیز، به شدت بر مصرف برق در ساختمان تأثیر گذار است.

پیش‌بینی یک روز بعد مصرف برق کشور سریلانکا در مرجع [۵۰] ارائه شده که با داشتن داده‌های ۱۱ سال از مصرف برق روزانه این کشور، داده‌ها با استفاده از شبکه عصبی چند لایه پیشخور و با الگوریتم پس انتشار خطا، آموزش دیدند و نتایج را در کنار یک مدل رگرسیون چندگانه ارائه نمودند، نتایج حاکی از آن است که شبکه عصبی چند لایه پیشخور نسبت به مدل رگرسیون ارائه شده، از دقت بالاتری در نتایج پیش‌بینی برخوردار است.

در پژوهشی که در مرجع [۵۱] انجام شده است، روشی برای پیش‌بینی بار میان-مدت تا کوتاه-مدت معرفی گردید که می‌تواند برای پیش‌بینی بارها در ساعات مختلف و در روزهای مختلف هر ماه استفاده شود. روش پیشنهادی، برای کمک به تولید برق و برنامه‌ریزی خرید برق مورد بررسی قرار گرفت. این روش از ترکیب شبکه عصبی پرسپترون چند لایه و الگوریتم بهینه‌سازی ملخ، برای به دست آوردن نتایج با دقت بالا برای پیش‌بینی بار استفاده شد. روش پیشنهادی با چندین الگوریتم فراابتکاری از جمله الگوریتم‌های بهینه‌سازی ذرات، زنبور عسل مصنوعی، فاخته، مورچه، گرگ و شیر مورچه و چند شبکه عصبی دیگر مقایسه شد، که نتایج حاکی از پیش‌بینی بهتر الگوریتم پیشنهادی بود. همچنین برای پیش‌بینی نرخ مصرف انرژی الکتریکی شهر بوسا در ترکیه، از ترکیب چندین الگوریتم فراابتکاری با شبکه عصبی پرسپترون چند لایه برای تعیین بهینه وزن و ضرایب بایاس در ساختار شبکه استفاده شد. از جمله این الگوریتم‌ها، الگوریتم بهینه‌ساز حسابی، سفره ماهی^{۲۴}، شاهین هریس، کفتارهای خالدار، گرگ خاکستری بهبود یافته، سالپ، بهینه‌ساز مبتنی بر گرادیان، جستجوی ارگانسیم‌های همزیست و ازدحام ذرات بود [۵۲].

با به کارگیری رگرسیون بردار پشتیبان و شبکه عصبی، پیش‌بینی مصرف برق سال‌های ۲۰۱۰ و ۲۰۱۱ ترکیه در پژوهش مرجع [۵۳] انجام گردید. در نتایج به دست آمده نشان می‌دهد که مدل رگرسیون بردار پشتیبان در پیش‌بینی سری‌های زمانی داده‌های مصرف برق با توجه به فصول مختلف سال از مدل شبکه عصبی بهتر عمل می‌نماید.

با توجه به پژوهش‌های ذکر شده، روش‌های زیادی برای پیش‌بینی مصرف برق و سایر انرژی‌ها ارائه شده است، که برخی از این روش‌ها مانند روش‌هایی که از یادگیری عمیق یا از روش‌های رای‌گیری اکثریت برای پیش‌بینی استفاده می‌کنند، زمان‌بر هستند و الگوریتم پیش‌فرض آموزش شبکه عصبی نیز همان الگوریتم پس انتشارخطاست که احتمال افتادن در بهینه‌های محلی را دارد [۵۴، ۵۵]. همچنین، برخی از روش‌ها از الگوریتم‌هایی مانند بهینه‌سازی ازدحام ذرات و یا کرم شبتاب جهت آموزش شبکه عصبی استفاده کرده‌اند، این الگوریتم‌ها نیز دارای قابلیت اکتشاف ضعیفی هستند و به دام بهینه‌های محلی گرفتار می‌آیند [۵۶، ۵۷]. از این‌رو نیاز است با استفاده از روش‌ها و الگوریتم‌های جدیدتر، به پیش‌بینی دقیق‌تر پرداخت. در ادامه الگوریتم جدیدی به نام الگوریتم بهینه‌سازی زغن معرفی می‌گردد که با قابلیت اکتشاف خوب و توازن بین اکتشاف و بهره‌برداری در اجرا، می‌تواند عملکرد خوبی داشته باشد. از الگوریتم پیشنهادی در جهت آموزش شبکه عصبی پرسپترون چندلایه برای پیش‌بینی مصرف برق در زمان‌های اوج بار استفاده می‌شود.

۳- روش پیشنهادی

پژوهش‌های انجام شده نشان می‌دهد که شبکه عصبی یک ابزار مناسب برای پیش‌بینی است که با استفاده از الگوریتم مناسب برای آموزش و انتخاب ساختار مناسب برای آن می‌توان دقت پیش‌بینی را افزایش داد. در پژوهش حاضر، شبکه عصبی پرسپترون چند لایه مورد استفاده قرار گرفته است که توسط الگوریتم جدید پیشنهادی بهینه‌سازی زغن که در ادامه به آن پرداخته می‌شود، آموزش داده می‌شود. در ضمن کد آن الگوریتم بهینه‌سازی زغن در برنامه متلب پیاده سازی شده است^{۲۵}.

۱-۳- الگوریتم بهینه‌سازی زغن

در زبان فارسی زغن، با نام کورکور، نیز نامیده می‌شود. این پرنده در مناطقی از کشورهای خاورمیانه به صورت پراکنده دیده می‌شود و معمولاً نزدیک دریاچه‌ها و مناطق پردرخت که از نظر شکار مناسب باشند آشیانه می‌سازند. زغن‌ها که به صورت دسته جمعی زندگی می‌کنند در کنار حرکات تصادفی و متاثر از موقعیت همدیگر حین پرواز، از سرعت بالایی در شکار برخوردار هستند. این پرندگان دارای صداهایی به نام صدای اتحاد^{۲۶} هستند که در مواقعی مثل پیدا کردن طعمه خوب، منبع آب، مهاجرت، زاد و ولد آن را تولید می‌کنند. صداهایی که در مواقع خطر مثل حمله دشمن، مرگ زغن دیگر، زلزله، طوفان و غیره صدای خطر^{۲۷} نام دارد و جهت خبردار کردن سایر زغن‌ها استفاده می‌شود. برای شبیه‌سازی رفتار پرنده در یافتن غذا، ویژگی‌های هر پرنده را می‌توان مانند جدول (۱) به صورت یک ساختار در نظر گرفت که شامل موقعیت پرنده، مقدار تابع ارزیابی، میزان جابجایی نقطه‌ای، صدای خطر (جهت مولفه انفرادی)، صدای اتحاد (جهت مولفه اجتماعی)، موقعیت جدید پرنده و مقدار تابع ارزیابی جدید پرنده است.

الگوریتم‌های فراابتکاری برای به دست آوردن نتایج خوب، ابتدا باید فضای جستجوی مسأله را به خوبی پیمایش کنند و به اکتشاف بپردازند تا در دام بهینه‌های محلی گرفتار نگردند. سپس به تدریج از مرحله اکتشاف، به مرحله بهره‌برداری حرکت کنند و در تکرارهای آخر به بهره‌برداری بپردازند، یعنی در اطراف راه‌حل‌های خوب را جستجو کنند تا بهترین راه‌حل را بیابند. الگوریتم دارای سه مرحله اصلی است که در ادامه به توضیح رابطه‌های هر کدام از مرحله‌ها پرداخته می‌شود. مرحله اول- موقعیت اولیه پرندگان: در مرحله اول مطابق رابطه (۱)، موقعیت پرندگان با توزیع یکنواخت در فضای مسأله به صورت تصادفی مقداردهی اولیه می‌گردد.

$$Pos_{i,j}(t) = Var_{min} + rand(Var_{max} - Var_{min}), i=1,2,\dots,N, j=1,2,\dots,d, t=1,2,\dots,MaxIteration \quad (1)$$

که در آن Var_{min} و Var_{max} به ترتیب حد بالا و حد پایینی بازه قابل قبول را نشان می‌دهد، $Pos_{i,j}(t)$ موقعیت پرنده i ام در بعد j ام و در تکرار t ام است، $rand$ عددی تصادفی در بازه $[0,1]$ ، N تعداد کل پرندگان، d تعداد ابعاد مسأله و $MaxIteration$ تعداد کل تکرارهای الگوریتم هستند.

مرحله دوم- انتخاب رهبر: فرآیند انتخاب رهبر مطابق رابطه (۲) به دست می‌آید:

$$\overline{Best}(t) = \overline{Pos}_i(t) \quad \text{if } F_i(t) \text{ is better than } F_{Best}(t) \quad (2)$$

که در آن $Best(t)$ موقعیت بهترین پرنده در تکرار t ام، $Pos_i(t)$ موقعیت پرنده i ام در تکرار t ام، $F_i(t)$ مقدار تابع ارزیابی پرنده i ام در تکرار t ام و $F_{Best}(t)$ مقدار تابع ارزیابی بهترین پرنده در تکرار t ام است.

مرحله سوم- حرکت زغن‌ها: با توجه به این که زغن‌ها باید به تدریج از اکتشاف به سمت بهره‌برداری حرکت کنند، ضریبی کاهش^{۲۸} مطابق رابطه (۳) در نظر گرفته شده است که از آن در روابط مربوط به حرکت این پرنده استفاده می‌گردد.

$$D = \left(\exp\left(\frac{t}{MaxIteration}\right) - \frac{t}{MaxIteration} \right)^{-10} \quad (3)$$

که در آن t تکرار فعلی است. اگر $MaxIteration$ برابر ۳۰۰۰ در نظر گرفته شود، نمودار کاهش^{۲۸} رابطه فوق مشابه شکل (۱) است.

تغییر موقعیت زغن‌ها از طریق رابطه (۴) و رابطه (۵) به دست می‌آید:

$$\overline{NewPos}_i(t+1) = \overline{Pos}_i(t) + \overline{Pm}_i(t+1) \quad (4)$$


$$\overline{Pm}_i(t+1) = D(t) \times \overline{Pm}_i(t) + SC(t) \odot \left(\overline{Pos}_{(ByRWS)}(t) - \overline{Pos}_i(t) \right) + UC(t) \odot \left(\overline{Best}(t) - \overline{Pos}_i(t) \right) \quad (5)$$

که در آن $Pos_{(ByRWS)}(t)$ زغنی است که بر اساس چرخ رولت از زغن‌ها انتخاب می‌شود و با زغن i ام متفاوت است. بردار $\overline{NewPos}_i(t+1)$ نیز موقعیت موقت جدید زغن i ام است. SC و UC به ترتیب بردارهای تصادفی از مولفه‌های اجتماعی و انفرادی هستند. مقادیر بردار $\overline{NewPos}_i(t+1)$ در صورتی که از محدوده مسأله خارج شده باشد، مجدداً به محدوده مسأله برمی‌گردد:

$$\overline{NewPos}_i(t+1) = \max\left(\min\left(\overline{NewPos}_i(t+1), Var_{max}\right), Var_{min}\right) \quad (6)$$

Table (1): The variables of the proposed algorithm
جدول (1): متغیرهای مورد استفاده در الگوریتم پیشنهادی

علامت اختصاری	توضیحات
\vec{Pos}	موقعیت پرنده
F	مقدار تابع ارزیابی
\vec{Pm}	میزان جابجایی نقطه‌ای
\vec{SC}	صدای خطر (مولفه انفرادی)
\vec{UC}	صدای اتحاد (مولفه اجتماعی)
\vec{NewPos}	موقعیت جدید پرنده
\vec{Best}	بهترین موقعیت به دست آمده تاکنون



شکل (1): نمودار ضریب کاهشی

Figure (1): The diagram of decreasing coefficient

Algorithm 1-The pseudo code of ROA

1. Input: VarMin, VarMax, MaxIteration, Dimension, Cost Function
2. Initializing the population of red kites by Eq. (1)
3. **While** termination criteria are not met
4. Evaluating the population
5. Selecting the best red kite as a leader
6. Calculating decrease coefficient by Eq. (3)
7. Calculating SC and UC by Eq. (7)
8. Updating Red kites positions by Eq. (4) and (5)
9. Replacing New Red kites positions in the population if they are better than previous positions
10. **End while**
11. Return Leader

شکل (۲): شبه کد الگوریتم بهینه‌سازی زغن

Figure (2): The Pseudo-code of red kite optimization algorithm

موقعیت موقت جدید در صورتی جایگزین می‌گردد که تابع ارزیابی موقعیت موقت جدید زغن، بهتر از تابع ارزیابی موقعیت قبلی هر زغن باشد. در این صورت مقدار آن در بردار $Pos_i(t+1)$ برابر بردار $NewPos_i(t+1)$ و در غیر این صورت، همان $Pos_i(t+1)$ همان موقعیت قبلی باقی می‌ماند. همان‌طور که گفته شد UC , SC که بردارهای تصادفی از مولفه‌های اجتماعی و انفرادی هستند، نمایانگر صدای اتحاد و صدای خطر در هر زغن هستند و مطابق رابطه زیر به دست می‌آیند:

$$\begin{cases} \vec{SC}(t+1) = r_1 \\ \vec{UC}(t+1) = r_2 \end{cases} \quad \text{if } rand \leq 0.5$$

$$\begin{cases} \vec{SC}(t+1) = r_3 \\ \vec{UC}(t+1) = r_1 \end{cases} \quad \text{Other wise}$$
(۷)

که در آن مقدار r_1 بردار عددی حقیقی و تصادفی در بازه $[1,2]$ ، r_2 بردار عددی حقیقی و تصادفی در بازه $[1,3]$ و r_3 بردار عددی حقیقی و تصادفی در بازه $[0,1]$ هستند. مقدار $rand$ نیز عددی تصادفی در بازه $[0,1]$ لحاظ شده است. در الگوریتم زغن،

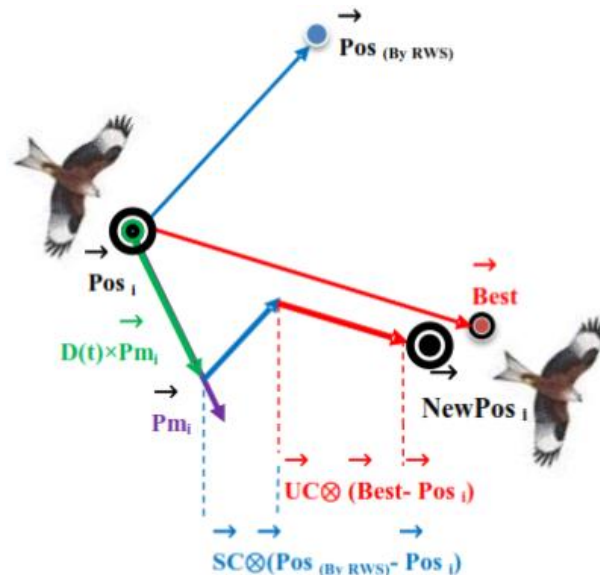
ضریب انفرادی باعث اکتشاف و ضریب اجتماعی آن باعث بهره‌برداری در هر زغن می‌شود. در شکل (۲) شبه کد الگوریتم بهینه‌ساز زغن نشان داده شده است. شکل (۳) نشان می‌دهد که چگونه هر زغن برای به‌دست آوردن بهترین راه‌حل در فضای جستجو حرکت می‌کند. همان‌طور که در شکل دیده می‌شود، هر زغن براساس موقعیت فعلی خود، موقعیت یک همسایه تصادفی انتخاب شده توسط چرخ رولت و بهترین راه‌حل یافت شده تاکنون، حرکت می‌کند و با انجام جستجوی محلی بر اساس همسایه انتخاب شده و جستجوی سراسری فضا بر اساس بهترین راه‌حل، فضا را به خوبی پیمایش می‌کند. در تکرارهای اولیه که $D(t)$ نزدیک به یک است، به اکتشاف و جستجوی فضاهای جدید پرداخته می‌شود. در حرکت بر اساس مولفه انفرادی، زغن براساس موقعیت خود و یک همسایه تصادفی به اکتشاف می‌پردازد. مولفه اجتماعی نیز، زغن‌ها را به سمت بهینه سراسری سوق می‌دهد. به تدریج که الگوریتم از تکرارهای اولیه به سمت تکرارهای میانی می‌رود، ضریب $D(t)$ هم کاهش می‌یابد تا توازن بین اکتشاف و بهره‌برداری برقرار گردد و در تکرارهای پایانی این ضریب به سمت صفر میل می‌کند و الگوریتم به بهره‌برداری و جستجوی بهترین راه‌حل از بین راه‌حل‌های خوب به‌دست آمده، می‌پردازد.

۲-۳- استفاده از الگوریتم بهینه‌سازی زغن برای آموزش شبکه عصبی پرسپترون چند لایه

در میان مدل‌های مختلف شبکه عصبی که تاکنون پیشنهاد شده است، شبکه عصبی پرسپترون چند لایه یکی از معروف‌ترین آنها است. این شبکه عصبی مصنوعی، شامل چندین لایه است که هر لایه از چندین گره پردازشی تشکیل شده است و به دلیل توانایی در نگاشت ورودی-خروجی برای مسائل مختلف، به ویژه در پیش‌بینی‌ها مورد استفاده قرار گرفته است. ساختار این شبکه عصبی به این صورت است که در آن هر گره با وزن‌های مختلف به گره‌های لایه بعدی متصل می‌شود و پس از انجام محاسبات در لایه‌های متوالی، مقادیر خروجی حاصل از آنها، به گره‌های لایه خروجی داده می‌شود [۳۰]:

$$U_j = \sum_{i=1}^n w_{ij}x_i + \theta_j \quad (8)$$

$$O_j = f_j(U_j) \quad (9)$$



شکل (۳): حرکت هر زغن برای یافتن بهترین راه‌حل در الگوریتم بهینه‌سازی زغن
Figure (3): The movement of each red kite in red kite optimization algorithm (ROA)

Algorithm 2-The pseudo code of ROA-MLP

1. **Input:** Data collection, VarMin, VarMax, MaxIteration
2. **Output:** Data Prediction
3. Reading data set and dividing into the training set and testing set
4. Defining the network structure (Setting the number of inputs, output and hidden neurons)
5. Determining Dimension of each Red kite by Eq. (10)
6. **Training MLP network by ROA algorithm**
7. Initializing the population of red kites
8. **While** termination criteria are not met
9. Evaluating the population based on fitness function Eq. (11)
10. Selecting the best red kites as a leader
11. Calculating decrease coefficient by Eq. (3)
12. Calculating SC and UC by Eq. (7)
13. Updating Red kites positions by Eq. (4) and Eq. (5)
14. Replacing New Red kites positions in the population if they are better than previous positions
15. **End while**
16. Set the weights and biases of MLP based on the leader's position
17. Computing the results of testing set data based on the trained MLP

شکل (۴): شبه کد الگوریتم بهینه‌ساز زغن - شبکه عصبی پرسپترون چند لایه

Figure (4): The ROA-MLP algorithm pseudo-code

که در آن گره n دارای ورودی است و w_{ij} وزن ارتباط بین گره i و j است. U_j مجموع ورودی‌ها در وزن‌های هر ورودی است که پس از افزودن بایاس θ_j به دست می‌آید. O_j مقدار خروجی است با استفاده از مقدار تابع فعال‌سازی به ازای U_j ، $f_j(U_j)$ به دست می‌آید. عملکرد شبکه عصبی پرسپترون چند لایه بستگی به ساختار و الگوریتم یادگیری آن دارد. بنابراین، انتخاب تعداد گره‌ها (نرون‌ها) در هر لایه، توزیع لایه‌ها، وزن‌های اختصاص داده شده، عملکرد تابع فعال‌سازی و تابع خطا، چالش اصلی در استفاده از شبکه عصبی پرسپترون چند لایه هستند. جهت بهبود عملکرد شبکه عصبی از نظر خطای کمتر، پیش‌بینی و دقت طبقه‌بندی، رویکرد یادگیری تلفیقی شبکه عصبی پرسپترون چند لایه با الگوریتم‌های فراابتکاری در نظر گرفته می‌شود [۵۸، ۵۹]. پس از آن جهت تعیین ابعاد هر عضو جمعیت در این الگوریتم‌ها، مطابق رابطه (۱۰)، تعداد نرون‌ها در هر لایه باید تعیین شود، از این رو برای هر عضو یک بردار با ابعادی شامل وزن‌ها و بایاس شبکه تعریف می‌شود.

$$\text{Dimension} = (\text{Input} \times \text{Hidden}) + (\text{Hidden} \times \text{Output}) + \text{Hidden}_{\text{bias}} + \text{Output}_{\text{bias}} \quad (10)$$

که در آن Input, Hidden, Output به ترتیب به تعداد نرون‌های ورودی، مخفی و خروجی شبکه عصبی پرسپترون چند لایه هستند. همچنین Hidden bias, Output bias تعداد بایاس‌های نرون‌های لایه‌های مخفی و خروجی را نمایش می‌دهند. در شکل (۴)، شبه کد الگوریتم بهینه‌ساز زغن برای آموزش شبکه عصبی پرسپترون چند لایه نشان داده شده است. در روش پیشنهادی پس از خواندن محتویات مجموعه دادگان و تقسیم آن به مجموعه داده‌های آموزش^{۲۹} و آزمون^{۳۰} و معین شدن ابعاد هر زغن، جمعیت در الگوریتم ترکیبی که با الگوریتم بهینه‌ساز زغن - شبکه عصبی پرسپترون چند لایه (ROA-MLP) مشخص شده است، به صورت تصادفی مقدار دهی می‌شود، که شامل مقداردهی به وزن‌ها و بایاس‌های آن است. سپس خطای شبکه که میانگین مربعات خطا^{۳۱} (MSE) است، از رابطه (۱۱) به دست می‌آید و بهترین عضو جمعیت مشخص می‌گردد.

$$\text{MSE} = \frac{1}{N} \sum_{j=1}^N (y_j - O_j)^2 \quad (11)$$

که در آن N تعداد الگوها Y_j, O_j به ترتیب خروجی شبکه عصبی و خروجی مطلوب هستند. براساس الگوریتم بهینه‌ساز زغن، اعضا جمعیت موقعیت خود را به روز می‌کنند و براساس آن، وزن‌ها و بایاس‌های جدیدی به دست می‌آید و الگوریتم تکرار می‌شود تا بهترین نتیجه که کمترین خطا را دارد به دست آید.

۴- نتایج و ارزیابی روش پیشنهادی

کارایی الگوریتم پیشنهادی، با الگوریتم‌های فراابتکاری بهینه‌سازی ملخ [۳۵]، گفتارهای خالدار [۳۶]، شاهین هریس [۳۷]، سوسک بال‌آتشین [۳۸] و الگوریتم بهینه‌سازی حسابی [۳۹] مقایسه می‌گردد. پارامترهای این الگوریتم‌ها، براساس مرجع‌های آنها، در جدول (۲) مشخص شده‌اند، عملکرد الگوریتم بهینه‌ساز زغن (ROA) بر روی توابع محک CEC2018 [۴۰] در مقایسه

با الگوریتم‌های ذکر شده، مورد بررسی قرار می‌گیرد، سپس این الگوریتم‌ها برای آموزش شبکه عصبی MLP در قیاس با الگوریتم‌های ذکر شده، جهت پیش‌بینی مصرف برق ایران در زمان اوج مصرف، مورد بررسی قرار می‌گیرد.

۱-۴- نتایج ارزیابی الگوریتم‌ها بر روی توابع محک CEC2018

توابع بهینه‌سازی، از دسته مسائلی هستند که باید نقاط کمینه بهینه آنها توسط الگوریتم‌هایی فراابتکاری، به دست آید و شامل توابع تک-حالته^{۳۲}، چند-حالته^{۳۳}، ترکیبی^{۳۴} و ترکیب‌بندی شده^{۳۵} هستند.

Table (2): The Parameters setting of compared algorithms

جدول (۲): مقادیر پارامترهای الگوریتم‌های مورد مقایسه

الگوریتم	پارامتر	مقدار
GOA	cMax	۱
	cMin	۰/۰۰۰۱
SHO	HEY, CV	۰
HHO	beta	۱/۵
FSO	C1, C2, C3, C4	rand
AOA	alpha, delta	۰/۱
	beta	۱/۵
	u	۰/۲۶۵
	r0	۱۰

Table (3): The results of meta-heuristic algorithms on CEC2018 functions with dimension 50

جدول (۳): نتایج ارزیابی الگوریتم‌های فراابتکاری مورد مقایسه بر روی توابع CEC2018 با بعد ۵۰

F#	Measure	GOA (2017)	SHO (2019)	HHO (2019)	AOA (2021)	FSO (2021)	ROA
۱	AVG	۲۳۸۴۵۰۰۰۰۰	۱۲۲۵۷۰۰۰۰۰	۶۱۸۰۷۰۰۰	۱۰۴۰۴۰۰۰۰۰	۱۴۷۴۲۰۰۰۰۰	۱۰۱۸۷۰۰۰۰۰
	STD	۹۵۶۰۵۰۰۰۰۰	۴۵۵۱۰۰۰۰۰	۱۵۳۴۱۰۰۰	۸۹۷۴۷۰۰۰۰۰	۴۲۵۳۱۰۰۰۰۰	۱۴۷۷۷۰۰۰۰۰
	Min	۸۸۳۴۲۰۰۰۰۰	۱۱۴۰۱۰۰۰۰۰۰	۴۰۹۸۹۰۰۰	۸۳۵۰۳۰۰۰۰۰	۸۴۶۷۵۰۰۰۰۰	۱۹۱/۷۷
۳	AVG	۱۳۴۴۴۰	۹۵۸۶۴۰۰۰۰۰	۴۱۳۷۸	۱۶۸۰۶۰	۲۸۸۶۸۰۰	۲۱۷۴۰
	STD	۵۳۲۹۳	۵۱۷۶۶۰۰۰۰۰	۱۰۴۳۱	۱۹۸۸۳	۲۳۹۲۶۰۰	۶۴۲۹/۸
	Min	۶۹۹۳۲	۲۳۲۸۹۰	۲۰۳۷۱	۱۳۷۶۷۰	۸۰۲۹۰۰	۱۰۹۹۷
۴	AVG	۱۷۰۰/۶	۴۶۵۱۶	۶۴۰/۵۱	۲۹۶۷۴	۷۵۴۵/۹	۵۹۸/۲۴
	STD	۱۰۴۰	۳۶۴۴/۳	۶۰/۶۳۲	۶۹۸۷/۶	۲۸۹۲/۶	۱۱۴/۲
	Min	۸۱۸/۵	۳۸۱۷۱	۵۳۰/۴۲	۱۷۱۹۷	۳۱۳۹/۹	۴۳۲/۰۲
۵	AVG	۹۴۶/۸۲	۱۲۸۰/۹	۸۸۲/۱۳	۱۱۲۱/۵	۱۰۸۶/۶	۶۷۰/۱
	STD	۶۹/۵۷۶	۲۰/۱۰۷	۳۵/۵۲۶	۳۶۰/۷۹	۲۵/۱۲	۳۱/۲۱۲
	Min	۸۳۲/۰۴	۱۲۴۳/۲	۷۷۴/۳	۱۰۵۵/۹	۱۰۳۱/۸	۶۱۵/۴۱
۶	AVG	۶۸۱/۴۱	۷۲۴/۱۶	۶۷۱/۹۳	۶۹۱/۵۴	۶۵۵/۴	۶۱۶/۲۷
	STD	۱۳/۱۹	۲۱۱۹۶۸۵	۵/۰۹۰۲	۲۰۴۱۰۹۸	۱۹۷۱۷۳۳	۹/۱۵۴۸
	Min	۶۵۲/۹۹	۷۰۸/۲۹	۶۵۵/۷۶	۶۷۶/۴۲	۶۴۳/۷۵	۶۰۲/۹۱
۷	AVG	۱۳۵۵/۹	۲۱۳۴/۳	۱۷۸۹/۹	۱۹۰۶/۷	۱۴۴۱/۳	۸۳۹/۴۵
	STD	۱۵۲/۰۳	۴۳/۵۴	۸۸/۹۸۴	۶۵/۳۱۲	۴۸/۴۵۸	۲۲/۱۲
	Min	۱۱۰/۱/۹	۲۰۲۸/۲	۱۶۴۵/۶	۱۷۳۸/۳	۱۳۶۰/۸	۸۰۶/۶
۸	AVG	۱۲۷۶/۱	۱۶۱۵/۲	۱۱۸۰/۹	۱۴۷۸/۴	۱۳۹۵/۷	۹۷۳/۹۸
	STD	۱۱۴/۷۵	۳۷/۴۳۸	۲۵/۲۴	۳۳/۹۴۶	۳۶/۹۹۴	۳۴/۸۴۹
	Min	۱۰۹۴/۷	۱۵۲۵/۸	۱۱۳۱/۷	۱۴۰۷/۳	۱۳۰۸/۵	۹۰۲/۴۸
۹	AVG	۲۴۲۴۴	۵۳۸۰۵	۲۲۶۰۱	۲۶۶۲۱	۴۹۹۷۳	۹۰۲۴/۶
	STD	۶۷۴۴/۱	۳۷۶۵/۳	۲۵۹۹/۹	۲۵۷۵/۷	۸۸۳۲/۲	۶۸۹۶/۱
	Min	۱۳۵۵۹	۴۷۵۱۵	۱۷۷۰۹	۲۰۷۲۲	۳۵۹۶۳	۱۳۰۹
۱۰	AVG	۸۷۱۸/۵	۱۷۲۶۸	۹۰۶۲/۷	۱۳۱۷۳	۱۶۷۱۳	۶۷۲۴/۷
	STD	۹۸۱/۷۸	۵۶۶/۹۹	۸۲۷/۰۱	۶۶۲/۰۵	۴۳۸/۳۸	۶۸۸/۱۵
	Min	۶۷۹۷/۸	۱۶۱۷۰	۶۹۲۶/۳	۱۱۲۵۶	۱۵۶۸۷	۵۲۸۳/۴

در توابع تک-حالتی فقط یک نقطه بهینه سراسری وجود دارد و برای ارزیابی قابلیت بهره‌برداری الگوریتم‌های فراابتکاری استفاده می‌شود، بنابراین در این توابع سرعت رسیدن به جواب مطلوب (بهره‌برداری) حائز اهمیت است. توابع چند-حالتی، دارای تعدادی بهینه‌های محلی هستند و باید الگوریتم قابلیت اکتشاف خوبی داشته باشد تا عامل‌ها در دام بهینه محلی گرفتار نشوند. توابع ترکیبی و ترکیب‌بندی‌شده با توجه به اینکه تلفیقی از توابع تک حالتی و چند حالتی هستند، به ترتیب دارای ساختاری پیچیده‌تر از آنها هستند و توازن بین اکتشاف و بهره‌برداری الگوریتم در آن بررسی می‌شود [۴۰].

الگوریتم ROA بر روی توابع CEC2018 با تعداد ابعاد ۵۰، در ۳۰ مرتبه و با تعداد جمعیت ۴۰ اجرا گردید، که در هر اجرا حداکثر تکرار، ۳۰۰۰ در نظر گرفته شده است. میانگین بهترین حالت، انحراف معیار و بهترین نتایج به‌دست آمده الگوریتم‌های مورد مقایسه، در جدول‌های (۳)، (۴) و (۵) آمده است. در بررسی نتایج مشاهده می‌گردد که الگوریتم پیشنهادی در توابع ۱ و ۳ که از دسته تک-حالتی و جهت بررسی قابلیت بهره‌برداری است، توانسته است در بین الگوریتم‌ها در ۳۰ مرتبه اجرا، حداقل مقدار را برای این توابع به‌دست آورد. همچنین در تابع ۳ میانگین بهتری نسبت به دیگر الگوریتم‌ها کسب کرده است. در توابع گروه چند حالتی که شامل توابع ۴ تا ۱۰ هستند و جهت بررسی قابلیت اکتشاف است، الگوریتم پیشنهادی با استفاده از حرکت عامل‌ها با ضریبی از SC به سمت عاملی که بر اساس مکانیزم چرخ رولت انتخاب می‌شود، توانسته است، نسبت به دیگر الگوریتم‌های مورد مقایسه رتبه بهتری کسب نماید.

Table (4): The results of meta-heuristic algorithms on CEC2018 functions with dimension 50

جدول (۴): نتایج ارزیابی الگوریتم‌های فراابتکاری مورد مقایسه بر روی توابع CEC2018 با بعد ۵۰

F#	Measure	GOA (2017)	SHO (2019)	HHO (2019)	AOA (2021)	FSO (2021)	ROA
۱۱	AVG	۴۱۸۲	۹۱۰۱۴	۱۴۹۰/۶	۲۱۱۱۶	۱۳۲۴۲۰	۱۲۵۵
	STD	۵۳۲۴/۷	۵۷۷۵۴	۷۲/۷۴۷	۲۹۵۹/۸	۵۲۱۷۸	۳۹/۶۷۲
	Min	۱۵۹۶/۱	۲۸۴۸۶	۱۳۷۴/۴	۱۳۵۲۹	۵۷۷۳۶	۱۱۹۶/۳
۱۲	AVG	۲۱۳۱۳۰۰۰۰	۱۰۸۴۸۰۰۰۰۰۰	۷۴۳۱۶۰۰۰	۷۱۹۵۳۰۰۰۰۰	۲۲۳۸۹۰۰۰۰۰	۷۴۸۲۳۰۰۰۰
	STD	۱۹۶۸۳۰۰۰۰	۱۶۶۸۵۰۰۰۰۰	۳۷۳۷۱۰۰۰	۱۲۱۳۸۰۰۰۰۰	۵۵۳۲۹۰۰۰۰۰	۱۲۱۴۶۰۰۰۰۰
	Min	۱۴۶۷۱۰۰۰	۶۳۹۵۳۰۰۰۰۰	۱۷۶۵۴۰۰۰	۵۳۷۹۸۰۰۰۰۰	۶۳۴۴۰۰۰۰۰	۲۳۸۷۱۰
۱۳	AVG	۳۰۱۶۳۰۰	۶۵۴۷۵۰۰۰۰۰	۳۳۹۴۵۰۰	۳۱۱۱۰۰۰۰۰۰	۳۵۷۴۰۰۰۰۰	۲۳۲۵۱۰۰۰
	STD	۷۹۲۷۵۰۰	۱۹۱۶۹۰۰۰۰۰	۳۱۹۳۳۰۰	۱۱۶۲۸۰۰۰۰۰	۱۲۰۵۸۰۰۰۰۰	۱۰۷۳۵۰۰۰۰
	Min	۳۰۹۱۸	۳۰۱۱۹۰۰۰۰۰	۱۲۸۰۶۰۰	۱۰۳۳۲۰۰۰۰۰	۱۶۳۳۷۰۰۰۰	۱۵۰۸/۸
۱۴	AVG	۷۶۸۲۳۰	۲۵۰۲۹۰۰۰۰	۶۴۷۸۹۰	۲۶۳۵۸۰۰۰	۵۹۳۹۶۰۰	۴۴۶۷۰
	STD	۱۱۰۸۵۰۰	۱۶۹۰۱۰۰۰۰	۴۵۷۳۳۰	۲۸۹۸۹۰۰۰	۱۹۲۰۱۰۰	۳۲۲۹۰
	Min	۲۶۹۶۹	۴۴۴۱۰۰۰۰	۶۱۶۶۳	۵۷۸۴۷۰	۲۱۴۵۸۰۰	۶۵۵۷/۲
۱۵	AVG	۵۰۱۱۲	۱۴۷۲۳۰۰۰۰۰	۳۸۹۰۳۰	۹۵۳۹۱۰۰۰۰	۴۰۹۴۴۰۰۰	۶۹۵۲/۷
	STD	۲۶۹۶۶	۲۸۷۰۹۰۰۰۰۰	۱۶۱۶۵۰	۱۱۷۱۸۰۰۰۰۰	۱۵۲۶۵۰۰۰	۶۳۵۶/۲
	Min	۱۳۴۳۷	۷۵۷۲۱۰۰۰۰۰	۱۶۴۸۲۰	۲۴۲۲۵	۱۹۳۷۳۰۰۰	۱۵۶۰/۹
۱۶	AVG	۴۰۱۳/۶	۱۳۳۲۵	۴۳۱۷/۲	۷۳۲۶/۲	۶۹۲۵/۹	۲۷۶۶/۱
	STD	۴۷۰/۶۹	۲۹۷۱/۲	۴۲۷/۰۸	۱۷۰۸/۳	۳۶۶/۰۵	۵۰/۱/۶۵
	Min	۳۲۵۱/۳	۸۴۰۹/۹	۳۲۳۴/۸	۴۱۸۳	۵۸۱۰/۶	۲۱۴۷/۷
۱۷	AVG	۳۲۹۴/۸	۳۵۲۵۹	۳۶۷۴/۳	۵۷۵۹	۵۰۱۲/۱	۲۶۶۴/۶
	STD	۳۲۲/۸۷	۱۹۴۹۳	۴۵۶/۷۲	۱۱۵۸/۳	۲۴۷/۳۳	۲۵۰/۴۲
	Min	۲۶۸۳/۱	۷۹۱۷/۴	۲۸۶۹/۸	۳۵۴۲/۳	۴۶۴۰/۷	۲۱۷۵/۲
۱۸	AVG	۲۳۵۳۹۰۰	۷۱۱۳۲۰۰۰۰	۴۰۳۵۵۰۰	۷۶۰۸۹۰۰۰	۱۵۳۰۶۰۰۰۰	۴۹۴۷۳۰
	STD	۲۰۰۲۵۰۰	۳۸۴۶۹۰۰۰۰	۳۵۴۷۱۰۰	۴۴۷۷۹۰۰۰	۶۸۷۲۸۰۰۰	۳۱۵۰۳۰
	Min	۱۱۰۹۳۰	۱۰۷۰۵۰۰۰۰	۴۵۰۰۶۰	۸۴۱۷۸۰۰	۶۳۶۷۶۰۰۰	۷۷۱۲۷
۱۹	AVG	۲۴۷۵۹۰۰	۸۳۱۰۰۰۰۰۰۰	۸۸۸۱۲۰	۱۰۱۰۵۰۰۰۰۰	۲۲۰۴۳	۱۶۳۲۶
	STD	۲۰۲۶۲۰۰	۲۴۰۱۰۰۰۰۰۰	۵۳۳۶۸۰	۸۰۶۴۴۰۰۰۰	۱۲۳۳۲	۸۷۹۹/۶
	Min	۸۱۷۱/۶	۲۷۲۴۳۰۰۰۰۰	۱۴۴۹۵۰	۱۳۹۰۳۰۰	۲۲۶۹/۴	۲۲۲۴/۲
۲۰	AVG	۲۵۷۴/۷	۴۹۹۶/۷	۳۴۵۶/۳	۳۴۹۲/۹	۴۷۲۹/۵	۲۶۹۱/۶
	STD	۴۴۵/۷۲	۱۹۰/۰۴	۲۷۵/۹۵	۲۴۲/۴۲	۲۰۳/۷۵	۲۷۶/۷
	Min	۲۵۲/۱۸	۴۵۴۹/۹	۲۸۲۳/۵	۲۸۸۹/۳	۴۲۵۹/۱	۲۲۳۸/۵

Table (5): The results of meta-heuristic algorithms on CEC2018 functions with dimension 50
 جدول (۵): نتایج ارزیابی الگوریتم‌های فراابتکاری مورد مقایسه بر روی توابع CEC2018 با بعد ۵۰

F#	Measure	GOA (2017)	SHO (2019)	HHO (2019)	AOA (2021)	FSO (2021)	ROA
۲۱	AVG	۲۸۱۱/۶	۳۴۷۶/۱	۲۸۲۷/۶	۳۰۴۸/۵	۲۸۹۳/۸	۲۴۵۶/۹
	STD	۸۵/۸۷۲	۹۰/۱۹۲	۹۸/۲۳۵	۷۷/۸۱۹	۳۲/۷۲۵	۳۶/۱۰۸
	Min	۲۶۹۲/۲	۳۲۲۷	۲۶۴۴/۸	۲۸۸۸/۶	۲۸۲۸/۲	۲۳۹۹/۶
۲۲	AVG	۱۰۳۱۵	۱۸۹۱۳	۱۰۹۹۰	۱۵۲۲۶	۱۸۱۷۸	۸۰۵۷/۶
	STD	۹۵۱/۴۶	۷۱۳/۱۴	۸۰۷/۴۸	۶۵۶/۳۷	۳۵۵/۷۸	۲۴۶۹/۳
	Min	۸۶۷۲/۸	۱۷۳۲۶	۹۷۷۳/۲	۱۳۷۸۰	۱۷۶۷۲	۲۳۰۰
۲۳	AVG	۳۷۵۷/۷	۴۸۷۲/۸	۳۷۹۳/۷	۴۳۸۰	۳۳۴۴/۸	۲۹۴۵/۳
	STD	۱۷۲/۴۴	۲۹۲/۱۴	۱۶۹/۴	۲۵۳/۲۸	۵۰/۳۶۳	۵۸/۱۹۲
	Min	۳۵۳۴/۲	۴۲۷۵/۲	۳۴۱۵/۸	۳۹۰۳	۳۲۵۶/۵	۲۸۲۹/۶
۲۴	AVG	۳۶۷۳/۷	۵۴۰۰/۶	۴۲۸۵/۲	۴۹۱۸/۹	۳۵۴۸/۸	۳۱۴۳
	STD	۱۸۱/۴۱	۴۹۴/۵۹	۲۱۴/۹۹	۲۵۶/۴۶	۲۴/۷۳۷	۷۸/۱۴۸
	Min	۳۲۰۹/۴	۴۶۴۵/۷	۳۷۴۸/۲	۴۴۰۹	۳۵۰۳/۹	۳۰۶۰/۴
۲۵	AVG	۳۹۹۷/۵	۱۷۰۷۵	۳۱۶۳/۶	۱۴۹۵۸	۶۴۲۵/۶	۳۰۴۰/۳
	STD	۷۸۳/۱	۶۶۰/۶۶	۳۴/۶۱۷	۱۵۳۴/۸	۱۱۶۶/۷	۳۸/۵۳۲
	Min	۳۱۱۵/۷	۱۵۴۲۵	۳۰۹۲/۲	۱۱۴۸۱	۴۳۱۸/۱	۲۹۸۰/۴
۲۶	AVG	۹۲۵۴/۲	۱۸۵۷۴	۱۰۵۳۹	۱۶۳۰۹	۹۵۴۵/۶	۴۳۴۳/۱
	STD	۲۶۱۵/۱	۵۴۱/۹۲	۲۱۱۱/۷	۱۰۲۰/۴	۴۵۵/۷۱	۱۴۷۰
	Min	۴۲۵۵/۵	۱۷۲۵۰	۳۳۳۵/۴	۱۴۲۰۹	۸۲۹۳	۲۹۰۰
۲۷	AVG	۳۶۹۸/۱	۸۰۸۸/۲	۴۲۵۷/۶	۶۵۶۵/۵	۵۶۵۲/۴	۳۴۰۴/۹
	STD	۲۴۷/۸۵	۸۷۱/۳۲	۳۲۵/۳۶	۵۶۰/۷۳	۵۰/۱۳۲	۸۱/۵۵۹
	Min	۳۳۸۳/۱	۶۲۷۸/۷	۳۷۹۳	۵۴۴۲	۴۷۲۴/۲	۳۲۶۴/۳
۲۸	AVG	۳۹۰۸	۱۵۹۴۴	۳۴۰۳/۲	۱۱۹۰۰	۸۷۸۸/۸	۳۳۸۸/۸
	STD	۶۰۲/۴۲	۱۲۱۰/۸	۴۳/۴۹۸	۹۲۳/۱	۶۹۴/۹۶	۱۲۹/۸۴
	Min	۳۳۶۵/۸	۱۴۰۵۲	۳۳۰۱/۸	۱۰۴۰۵	۷۷۸۱/۲	۳۲۷۸/۲
۲۹	AVG	۵۶۸۶/۸	۵۹۴۶۱۰	۵۴۷۷/۴	۳۰۹۴۱	۱۶۰۰۷	۴۰۵۱/۳
	STD	۴۹۳/۷	۶۹۱۲۷۰	۳۸۲/۶۱	۲۲۰۰۶	۵۵۷۱/۸	۲۵۴/۱۴
	Min	۴۶۴۶/۴	۱۹۵۲۳	۴۷۳۲	۱۳۴۷۰	۹۲۰۹/۹	۳۶۰۹/۴
۳۰	AVG	۵۷۹۱۸۰۰۰	۱۴۰۱۵۰۰۰۰۰	۲۴۹۵۹۰۰۰	۴۲۴۵۲۰۰۰۰	۱۰۵۲۳۰۰۰۰	۹۴۱۴۰۰
	STD	۱۳۹۷۴۰۰۰	۳۷۶۶۳۰۰۰۰۰	۵۷۷۳۹۰۰	۳۰۴۸۱۰۰۰۰۰	۴۲۶۹۲۰۰۰۰	۲۲۲۴۴۰۰
	Min	۲۸۳۶۳۰۰۰	۷۴۸۰۳۰۰۰۰۰	۱۲۴۱۰۰۰۰	۴۹۷۰۶۰۰۰۰	۵۳۴۷۸۰۰۰۰	۶۱۹۱۷۰۰

نقطه عطف نتایج را می‌توان در نتایج مربوط به توابع ترکیبی و ترکیب‌بندی شده دانست، چرا که همان‌طور که پیشتر بیان گردید، توابع ترکیبی (۱۱ تا ۲۰)، توازن بین قابلیت اکتشاف و بهره‌برداری را در الگوریتم مورد بررسی قرار می‌دهد، که الگوریتم پیشنهادی در روند اجرا، با دارا بودن پارامترهای UC و SC و ضریب کاهش D، با توجه به جدول‌های (۳)، (۴) و (۵)، به خوبی توانسته است نسبت به دیگر الگوریتم‌های مورد مقایسه، به جواب بهتری در این مسائل دست یابد. کارایی الگوریتم و قابلیت برقراری توازن بین اکتشاف و بهره‌برداری، برای توابع دسته چهارم (توابع ۲۱ تا ۳۰) که از توابع ترکیب‌بندی شده و بسیار پیچیده هستند، نیز صدق می‌کند.

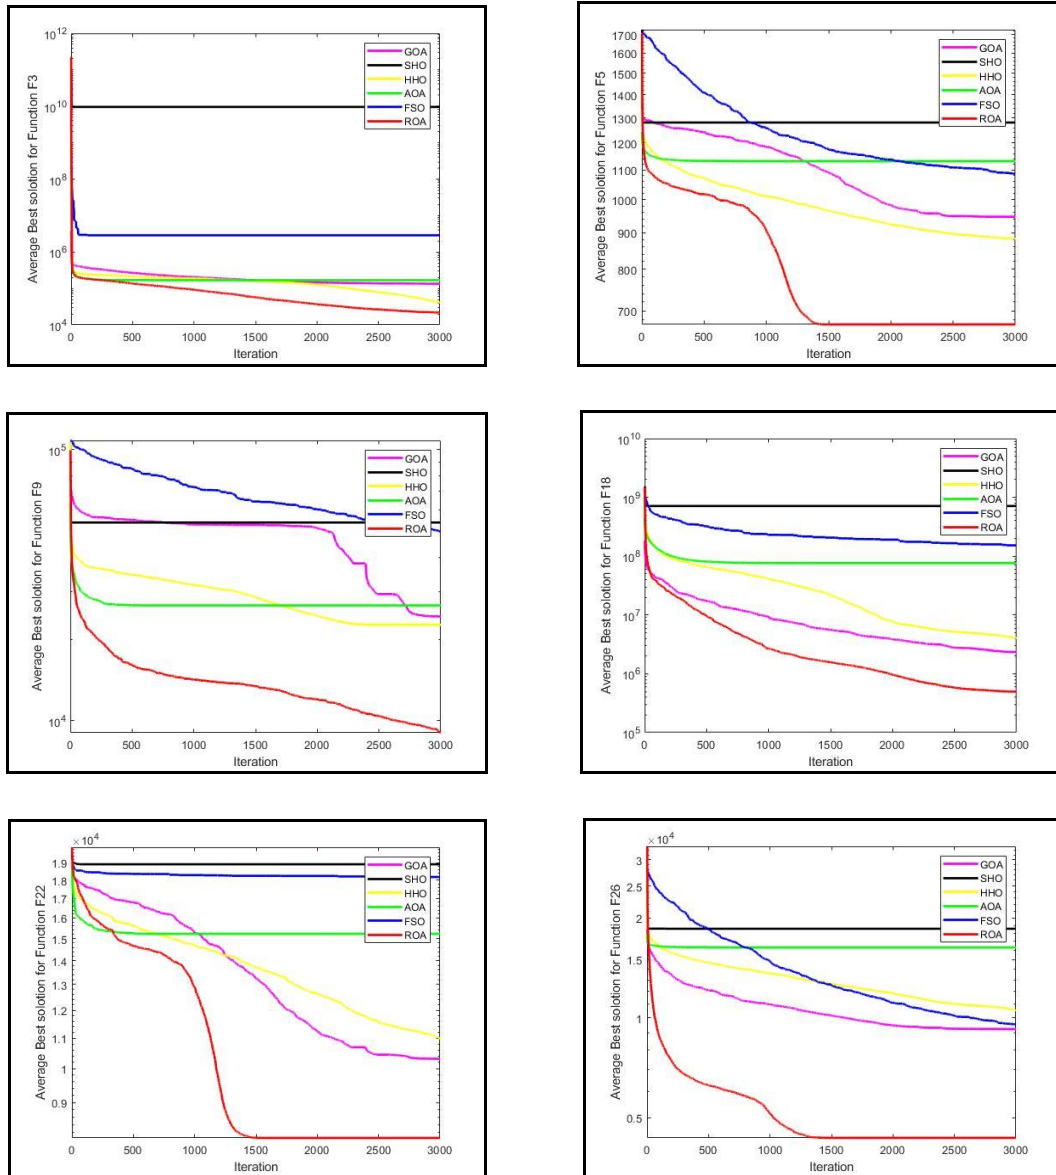
در این توابع الگوریتم پیشنهادی بهترین نتایج و الگوریتم بهینه‌سازی گفتار خالدار نتایج ضعیفی را ارائه کرده‌اند. اگر اکتشاف ضعیف باشد و یا توازن بین اکتشاف و بهره‌برداری به خوبی انجام نشود، یا در مرحله بهره‌برداری فضاهای امیدبخش به خوبی پیمایش نگردند، راه‌حل‌های خوبی به دست نمی‌آید. نتایج آزمون فریدمن [۶۰] الگوریتم‌های مورد مقایسه در جدول (۶) نشان داده شده است. آزمون فریدمن یک آزمون ناپارامتری، معادل آنالیز واریانس با اندازه‌های تکراری است که از آن برای مقایسه میانگین رتبه‌ها در بین k متغیر (گروه) استفاده می‌شود [۶۰]. نتایج الگوریتم‌ها در ۳۰ بار تکرار، با یکدیگر مقایسه شده‌اند و توسط آزمون فریدمن رتبه‌بندی شده‌اند. همان‌طور که در جدول (۶) مشاهده می‌شود، الگوریتم پیشنهادی بهترین رتبه و الگوریتم‌های بهینه‌سازی شاهین هریس و ملخ در رتبه‌های بعدی قرار دارند.

Table (6): The Friedman test results of meta-heuristic algorithms on CEC2018 functions

جدول (۶): نتایج ارزیابی الگوریتم‌های فراابتکاری مورد مقایسه بر روی توابع CEC2018 براساس آزمون فریدمن

F#	GOA (2017)	SHO (2019)	HHO (2019)	AOA (2021)	FSO (2021)	ROA
۱	۳/۸	۵/۹۳	۱/۷	۵/۰۷	۳/۲	۱/۵
۳	۳/۱۷	۵/۶۳	۱/۱	۳/۸۳	۵/۳۷	۱/۹
۴	۳	۶	۱/۶	۵	۴	۱/۴
۵	۲/۹۳	۶	۲/۱۷	۴/۸	۴/۱	۱
۶	۳/۹۳	۶	۳/۱۷	۴/۷۳	۲/۱۷	۱
۷	۲/۲۷	۶	۴/۲۳	۴/۷۷	۲/۷۳	۱
۸	۳	۵/۹۷	۲/۲	۴/۹	۳/۹۳	۱
۹	۲/۸۳	۵/۶	۲/۵۷	۳/۵۷	۵/۳۷	۱/۰۷
۱۰	۲/۳۷	۵/۷	۲/۶	۴	۵/۳	۱/۰۳
۱۱	۳/۰۳	۵/۲۳	۲	۳/۹۷	۵/۷۷	۱
۱۲	۲/۴	۵/۹۷	۱/۸۷	۵/۰۳	۴	۱/۷۳
۱۳	۱/۹۳	۵/۹۷	۲/۶۷	۵/۰۳	۳/۹۷	۱/۴۳
۱۴	۲/۲۷	۶	۲/۷	۴/۸۳	۴/۱	۱/۱
۱۵	۲/۰۳	۶	۳/۰۳	۴/۸۳	۴/۱	۱
۱۶	۲/۴	۵/۹۳	۲/۶۳	۴/۵۷	۴/۴۳	۱/۰۳
۱۷	۲/۲۳	۶	۲/۷۷	۴/۶	۴/۳۷	۱/۰۳
۱۸	۲/۲۳	۶	۲/۷	۴/۱۳	۴/۸۳	۱/۱
۱۹	۳/۹	۶	۳/۱۳	۴/۹۷	۱/۷۳	۱/۲۷
۲۰	۳/۱۳	۵/۸۷	۲/۸	۲/۹۳	۵/۱۳	۱/۱۳
۲۱	۲/۷۳	۶	۲/۸۳	۴/۸۳	۳/۶	۱
۲۲	۲/۱۳	۵/۸	۲/۸	۴	۵/۲	۱/۰۷
۲۳	۳/۴۷	۵/۹	۳/۵۷	۵/۰۷	۲	۱
۲۴	۲/۷۳	۵/۸۳	۴	۵/۱۷	۲/۲۷	۱
۲۵	۳/۰۳	۵/۸	۲/۰۳	۵/۲	۳/۹۳	۱
۲۶	۲/۷۷	۵/۹۷	۳/۵۳	۵/۰۳	۲/۶۳	۱/۰۷
۲۷	۳/۰۳	۵/۹	۳/۹	۵/۱	۲/۰۷	۱
۲۸	۳/۸۳	۶	۲/۷۷	۵	۲/۲۷	۱/۱۳
۲۹	۲/۶۷	۵/۹	۲/۳۳	۴/۹۷	۴/۱۳	۱
۳۰	۳	۶	۲	۴/۹	۴/۱	۱
Sum	۸۲/۲۷	۱۷۰/۹	۷۷/۴	۱۳۴/۸۳	۱۱۰/۸۱	۳۲/۹۹
Rank	۳	۶	۲	۵	۴	۱

در شکل (۵) نمودار همگرایی الگوریتم‌های مورد مقایسه بر روی برخی از توابع CEC2018 در هر چهار گروه، نشان داده شده است. همان‌طور که در این شکل مشخص است الگوریتم پیشنهادی در کنار اکتشاف خوب، از توازن بین قابلیت‌های اکتشاف و بهره‌برداری مناسبی برخوردار است. تفاوت سرعت همگرایی و همگرا شدن به جواب بهتر، در این نمودارها نشان می‌دهد که اختلاف قابل توجهی بین الگوریتم پیشنهادی با سایر الگوریتم‌های مورد مقایسه است. در این نمودارها، الگوریتم‌های خالدار نتایج ضعیفی را از خود نشان می‌دهد و در همان تکرارهای اولیه به دلیل اکتشاف ضعیف به دام بهینه‌های محلی گرفتار می‌آید.



شکل (۵): نمودار همگرایی الگوریتم‌های فراابتکاری مورد مقایسه بر روی توابع CEC2018 با بعد ۵۰

Figure (5): The Convergence curve of metaheuristic algorithms on CEC2018 functions with dimension 50

۲-۴- نتایج ارزیابی الگوریتم‌ها در آموزش شبکه عصبی پرسپترون چند لایه برای پیش‌بینی مصرف برق

الگوریتم‌های بیان شده در بخش ۴، برای آموزش شبکه عصبی چند لایه مورد استفاده قرار می‌گیرند تا نتایج حاصل از آنها برای پیش‌بینی مصرف برق مورد ارزیابی قرار گیرد. در این تحقیق، از معیارهای ارزیابی مانند میانگین مربعات خطا (MSE) که در رابطه (۱۱) به آن اشاره شد، جذر ریشه میانگین مربع خطا^{۳۶} (RMSE)، میانگین قدر مطلق خطا^{۳۷} (MAE)، ضریب همبستگی^{۳۸} (R)، ضریب کارایی نش‌ساتکلیف^{۳۹} (NSE) و شاخص توافق^{۴۰} (d) جهت بررسی نتایج پیش‌بینی استفاده می‌شود. همچنین به منظور ارزیابی عملکرد شبکه عصبی در آموزش صحیح داده‌ها، تابع خطای داده‌ها بر اساس روش محاسبه میانگین مربعات خطا (MSE) مورد استفاده قرار گرفته است. لذا میانگین قدر مطلق خطا که برای برآورد میزان خطای واقعی است و در واقع قدر مطلق تفاوت بین مقادیر پیش‌بینی و مقادیر واقعی است نیز مورد بررسی قرار می‌گیرد. مقدار R همبستگی بین داده‌های واقعی و داده‌های پیش‌بینی شده را نشان می‌دهد و از -۱ تا ۱ متغیر است، اگر R نزدیک به صفر باشد، به این معنی است که هیچ رابطه‌ای بین متغیرها وجود ندارد و اگر مقدار آن مثبت باشد، به این معنی است که یک متغیر در مقایسه با دیگری بزرگ‌تر است و برای R- برعکس این موضوع صادق است. بنابراین -۱ یا ۱ مقدار ایده‌آل این ضریب است [۶۱،۶۲]. ضریب

NSE برای بررسی توانایی مدل‌هایی مانند پیش‌بینی استفاده می‌شود [۶۳]. مقدار این ضریب می‌تواند از $-\infty$ تا ۱ متغیر باشد و زمانی که میزان آن ۱ باشد، نمایانگر انطباق کامل بین داده‌های واقعی و داده‌های پیش‌بینی است و بازه صفر نشان می‌دهد که پیش‌بینی‌های مدل به اندازه میانگین داده‌های مشاهده شده دقیق هستند، در حالی که NSE کمتر از صفر نشان می‌دهد که میانگین مشاهده شده، پیش‌بینی بهتری نسبت به مدل است. از این رو این ضریب به عنوان یک معیار استاندارد شده برای میزان خطای پیش‌بینی مدل است که اختلاف نسبی بین مقادیر مشاهده شده و شبیه‌سازی شده را نشان می‌دهد [۶۴]. همچنین d میزان برآورد دقیق از متغیر مطلوب، توسط متغیر پیش‌بینی شده را نشان می‌دهد و در اصل معیاری برای بررسی میزان بدون خطا بودن پیش‌بینی است [۶۴]. روابط (۱۲) تا (۱۶)، نحوه محاسبه این شاخص‌ها را نشان می‌دهد.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N [(y_i - O_j)]^2} \quad (12)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - O_j| \quad (13)$$

$$R = \frac{\sum_{i=1}^N (y_i - \bar{O}_j)(y_i - \bar{y}_i)}{\sqrt{\sum_{i=1}^N (y_i - \bar{O}_j)^2} \sqrt{\sum_{i=1}^N (y_i - \bar{y}_i)^2}} \quad (14)$$

$$NSE = 1 - \frac{\sum_{i=1}^N (y_i - O_j)^2}{\sum_{i=1}^N (y_i - \bar{y}_i)^2} \quad (15)$$

$$d = 1 - \frac{\sum_{i=1}^N (O_j - y_i)^2}{\sum_{i=1}^N [|O_i - \bar{y}_i| + |(y_i - \bar{y}_i)|]^2} \quad (16)$$

اگر مقدار پیش‌بینی به مقدار واقعی نزدیک باشد، MSE اثر خطاهای بین صفر و یک را کمتر در نظر می‌گیرد و برعکس اثر خطاهای بزرگتر، بیشتر در نظر گرفته می‌شود. به طور مثال خطای ۰/۵ و ۰/۲۵ و خطای ۱۲، ۱۴۴ در نظر گرفته می‌شود. به همین علت، برای بررسی و تشخیص تغییرات خطا، MAE و RMSE نیز بررسی می‌گردد.

۱-۲-۴- نرمال‌سازی داده‌ها

عملیات نرمال‌سازی باعث می‌شود تمام داده‌های موجود در بازه [۰ و ۱] قرار گیرند تا در شبکه عصبی مورد استفاده قرار گیرند. روش‌های مختلفی برای نرمال‌سازی داده‌ها وجود دارد که رابطه‌های (۱۷) و (۱۸) بیان‌کننده این روش هستند [۲۰]. رابطه (۱۷) برای داده‌های ورودی و رابطه (۱۸) برای خروجی استفاده می‌شود.

$$XN = \left(\frac{X - \min(X)}{\max(X) - \min(X)} \times 2 \right) - 1 \quad (17)$$

$$YN = \frac{Y}{\max(Y)} \quad (18)$$

که در آن X داده‌های ورودی، $\min(X)$ کوچکترین داده ورودی، $\max(X)$ بزرگترین داده ورودی است. همچنین Y داده‌های خروجی و $\max(Y)$ نیز بزرگترین داده خروجی است.

۲-۲-۴- توابع فعالیت

هر نرون شبکه عصبی، یک توابع فعالیت را بر ترکیبی خطی از ورودی‌ها و پارامترهای شبکه (یعنی W و b) اعمال می‌کند تا پاسخ خاص خود را ارائه دهد. تعدادی از توابع وجود دارد که می‌تواند برای این منظور استفاده شود. با این حال بسیاری از

مطالعات برتری توابع هایپربولیک را برای نرون‌های لایه پنهان و تابع سیگموئید جهت خروجی در پیش‌بینی نرمال شده را بیان کرده‌اند.

$$\text{Response} = \text{Tansig}(W \times I + b) \quad (19)$$

$$\text{Tansig}(x) = \frac{2}{1 + e^{-2x}} - 1 \quad (20)$$

$$\text{Logsig}(x) = \frac{1}{1 + e^{-x}} \quad (21)$$

۳-۲-۴- نتایج پیش‌بینی مصرف برق

در این بخش، به ارزیابی روش پیشنهادی، برای پیش‌بینی مصرف برق ایران در زمان اوج مصرف بار پرداخته می‌شود. داده‌های مربوطه از پایگاه آماری شرکت مدیریت شبکه برق ایران^{۴۱} و از سال ۱۳۹۵ تا ۱۳۹۹ گرفته شده است [۴۱]. در روش پیشنهادی از یک شبکه عصبی شامل لایه ورودی، لایه پنهان و لایه خروجی استفاده می‌شود. تعداد ورودی‌ها در لایه اول ۶ و شامل ذخیره نیروگاه‌ها، مصرف برق صنایع، تولید نیروگاه‌های تجدیدپذیر در مجموع ۲۴ ساعت، میانگین فرکانس تولیدی، نیاز مصرف برق در پیک یکسال گذشته در زمان متناظر و مصرف برق فعلی در پیک هستند. در ارزیابی‌های صورت گرفته، جهت آموزش شبکه عصبی از ۸۰ درصد داده‌ها و جهت آزمون از ۲۰ درصد داده‌ها استفاده شده است، همچنین تعداد نرون‌ها در لایه مخفی ۵ و ۱۰ است تعداد ۱ نرون نیز برای خروجی در نظر گرفته شده است.

نتایج با ۵ و ۱۰ نرون در لایه مخفی به ترتیب در جدول‌های (۷) و (۸) نمایش داده شده است. بعد هر عضو جمعیت در الگوریتم‌های فراابتکاری مورد مقایسه، براساس رابطه (۱۰) به دست می‌آید. الگوریتم بهینه‌سازی زغن و سایر الگوریتم‌های مورد مقایسه، مقادیر وزن‌ها و بایاس‌ها را می‌یابند. به این ترتیب، مناسب بودن هر پاسخ (در هر تکرار) توسط یک تابع هدف گزارش می‌شود، در این پژوهش از میانگین مربعات خطا، رابطه (۱۱) برای این منظور استفاده می‌شود. بنابراین هر چه مقدار تابع هدف کمتر باشد، مقدار پیش‌بینی شبکه به مقدار مطلوب نزدیک‌تر است [۴۱]. عملکرد روش پیشنهادی الگوریتم بهینه‌سازی زغن جهت آموزش شبکه عصبی پرسپترون چند لایه (ROA-MLP) با دیگر الگوریتم‌هایی که در بهینه‌سازی توابع بخش قبل، مورد ارزیابی قرار گرفتند، جهت پیش‌بینی مصرف برق ایران در زمان اوج مصرف، مقایسه می‌گردند. این مقایسه براساس معیارهای ذکر شده برای پیش‌بینی است. پس از نرمال‌سازی داده‌ها، آنها به دو بخش داده‌های آموزش و آزمون تقسیم‌بندی می‌گردند و آموزش توسط الگوریتم‌ها شروع می‌شود. در هر تکرار وزن‌ها و بایاس‌های شبکه توسط الگوریتم‌ها محاسبه می‌شوند. بهترین وزن‌ها و بایاس‌ها آنهایی هستند که حداقل مقدار خطای خروجی را تولید کنند. مقادیر این وزن‌ها و بایاس‌ها، پس از پایان آموزش روی شبکه عصبی قرار می‌گیرند و داده‌های آزمون به شبکه داده می‌شود تا خطای پیش‌بینی از روی آنها محاسبه - گردد. اگر شبکه عصبی خوب آموزش دیده باشد، خطای داده‌های آزمون هم کم خواهد بود. با توجه به نتایج به دست آمده در جدول‌های (۷) و (۸)، در صورتی که تعداد ۱۰ نرون در لایه مخفی در نظر گرفته شود، الگوریتم‌ها عملکردی مطلوب‌تری نسبت به زمانی که ۵ نرون در لایه مخفی در نظر گرفته می‌شود، دارند. البته همانطور که مشاهده می‌گردد، الگوریتم زغن پیشنهادی حتی با ۵ نرون در لایه مخفی نیز، نسبت به بقیه الگوریتم‌ها نتایج بهتری را نشان می‌دهد،

Table (7): The results of algorithms with 5 neurons in the hidden layer of MLP

جدول (۷): نتایج معیارهای ارزیابی با ۵ نرون در لایه مخفی شبکه عصبی

Evaluation parameters		GOA-MLP (2017)	SHO-MLP (2017)	HHO-MLP (2019)	AOA-MLP (2021)	FSO-MLP (2021)	ROA-MLP
MSE	Train	۰/۰۰۲۵	۰/۰۱۳۸	۰/۰۰۳۹	۰/۰۰۹۹	۰/۰۰۳۳	۰/۰۰۱۷
	Test	۰/۰۰۲۳	۰/۰۱۴۸	۰/۰۰۴۵	۰/۰۱۰۵	۰/۰۰۳۴	۰/۰۰۱۶
RMSE	Train	۰/۰۴۷۹	۰/۱۲۱۴	۰/۰۶۶۵	۰/۱۰۱۷	۰/۰۵۶۹	۰/۰۴۰۷
	Test	۰/۰۵۰۱	۰/۱۱۷۴	۰/۰۶۱۶	۰/۰۹۸۶	۰/۰۵۸۱	۰/۰۳۹۷
MAE	Train	۰/۰۳۹۵	۰/۰۹۶۴	۰/۰۴۸۹	۰/۰۷۹۴	۰/۰۴۳۵	۰/۰۳۲۴
	Test	۰/۰۳۷۴	۰/۰۹۹	۰/۰۵۲۵	۰/۰۸۲۵	۰/۰۴۳۸	۰/۰۳۱۳
R	Train	۰/۹۴۳۲	۰/۷۶۴۷	۰/۹۰۷۳	۰/۸۴۷۲	۰/۹۱۸۶	۰/۹۵۷۵
	Test	۰/۹۳۸۲	۰/۷۵۱۷	۰/۹۰۶۷	۰/۸۳۵	۰/۹۱۲۸	۰/۹۵۳۴
d	Train	۰/۹۵۷۵	۰/۵۰۱۳	۰/۹۲۶۵	۰/۷۰۹۱	۰/۹۵۳۴	۰/۹۷۵۴
	Test	۰/۹۵۷۷	۰/۴۸۹۶	۰/۹۱۹	۰/۶۹۶۵	۰/۹۴۹۷	۰/۹۷۴۷
NSE	Train	۰/۸۶۶۴	۰/۲۵۴۳	۰/۷۸۹۴	۰/۴۷۱۵	۰/۸۲۵۵	۰/۹۱۲۹
	Test	۰/۸۶۴۳	۰/۲۳۷۲	۰/۷۷۷۴	۰/۴۴۶۴	۰/۸۱۶۹	۰/۹۰۸

Table (8): The results of algorithms with 10 neurons in the hidden layer of MLP

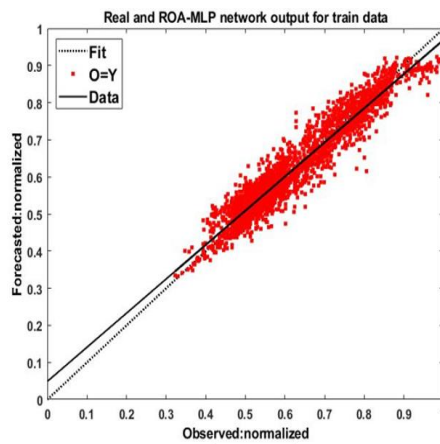
جدول (۸): نتایج معیارهای ارزیابی با ۱۰ نرون در لایه مخفی شبکه عصبی

Evaluation parameters		GOA-MLP (2017)	SHO-MLP (2017)	HHO-MLP (2019)	AOA-MLP (2021)	FSO-MLP (2021)	ROA-MLP
MSE	Train	۰/۰۰۱۹	۰/۰۱۱۹	۰/۰۰۳۴	۰/۰۰۷	۰/۰۰۴	۰/۰۰۱۴
	Test	۰/۰۰۲۱	۰/۰۱۱۳	۰/۰۰۳۳	۰/۰۰۷۵	۰/۰۰۳۷	۰/۰۰۱۷
RMSE	Train	۰/۰۴۵۷	۰/۱۰۵۱	۰/۰۵۶۹	۰/۰۸۴۷	۰/۰۶۲۸	۰/۰۳۷۴
	Test	۰/۰۴۳۶	۰/۱۰۷۹	۰/۰۵۸	۰/۰۸۱۹	۰/۰۶۰۵	۰/۰۴۰۷
MAE	Train	۰/۰۳۳۹	۰/۰۸۳۷	۰/۰۴۴۸	۰/۰۶۴۶	۰/۰۴۹۵	۰/۰۲۹۴
	Test	۰/۰۳۵۷	۰/۰۸۱۸	۰/۰۴۳۷	۰/۰۶۶۲	۰/۰۴۷۹	۰/۰۳۲۳
R	Train	۰/۹۵۲	۰/۸۲۷۴	۰/۹۱۷۶	۰/۸۹۸۷	۰/۹۱۲۸	۰/۹۶۱۵
	Test	۰/۹۴۶۴	۰/۸۲۷۵	۰/۹۲۴۱	۰/۸۹۸۳	۰/۹۰۹۹	۰/۹۵۷۲
d	Train	۰/۹۷	۰/۶۶۴	۰/۹۳۸۱	۰/۸۳۹۸	۰/۹۳۷۳	۰/۹۷۹۹
	Test	۰/۹۶۶۳	۰/۶۷۱۱	۰/۹۴۲۹	۰/۸۳۳۴	۰/۹۳۷۲	۰/۹۷۷۶
NSE	Train	۰/۸۹۷	۰/۳۷۲۷	۰/۸۱۴۸	۰/۶۲۲۳	۰/۷۹۱۱	۰/۹۲۴۴
	Test	۰/۸۸۵۸	۰/۳۶۹۵	۰/۸۲۶۹	۰/۶۰۵۶	۰/۷۸۵	۰/۹۱۵۹

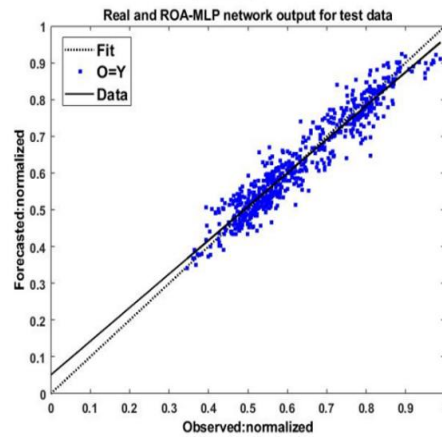
Table (9): The results of Friedman test based on MSE

جدول (۹): نتایج آزمون فریدمن براساس معیار MSE

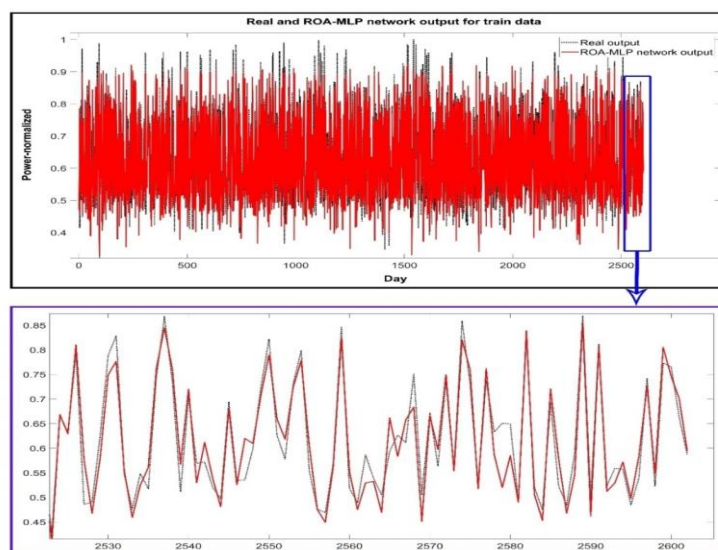
داده‌ها	لایه پنهان	GOA-MLP (2017)	SHO-MLP (2017)	HHO-MLP (2019)	AOA-MLP (2021)	FSO-MLP (2021)	ROA-MLP
داده‌های تعلیم داده شده	۵	۲/۴	۶/۴	۳/۵	۵	۳/۱	۱
	۱۰	۲/۱	۶/۵	۳/۴	۴/۹	۳/۸	۱
داده‌های آزمایش	۵	۲/۲	۶/۵	۳/۹	۵	۲/۹	۱
	۱۰	۲/۲	۶/۴	۳/۴	۵/۲	۳/۶	۱



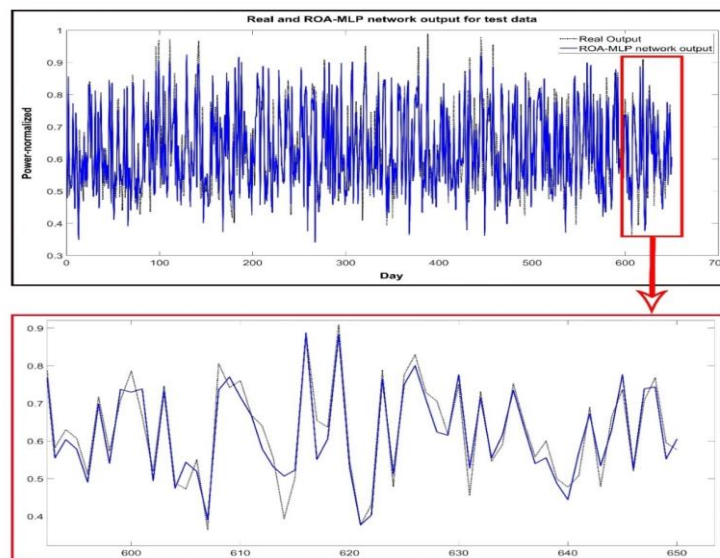
شکل (۶): نمودار پراکندگی مقادیر پیش‌بینی شده برق مصرفی توسط ROA-MLP با ۱۰ نرون در لایه مخفی بر روی داده‌های آموزش
 Figure (6): The scatter diagram of the electricity consumption prediction of ROA-MLP with 10 neurons in the hidden layer on training data



شکل (۷): نمودار پراکندگی مقادیر پیش‌بینی شده برق مصرفی توسط ROA-MLP با ۱۰ نرون در لایه مخفی بر روی داده‌های آزمون
 Figure (۷): The scatter diagram of the electricity consumption prediction of ROA-MLP with 10 neurons in the hidden layer on testing data



شکل (۸): میزان پیش‌بینی برق مصرفی در داده‌های آموزش با استفاده از ROA-MLP با ۱۰ نرون در لایه مخفی
 Figure (8): The electricity consumption prediction of ROA-MLP using training data with 10 neurons in the hidden layer



شکل (۹): میزان پیش‌بینی برق مصرفی در داده‌های تست با استفاده از ROA-MLP با ۱۰ نرون در لایه مخفی
Figure (9): The electricity consumption prediction of ROA-MLP using testing data with 10 neurons in the hidden layer

در این دو جدول، الگوریتم بهینه‌سازی کفتارهای خالدار و الگوریتم بهینه‌ساز حسابی نتایج ضعیف‌تری را نسبت به سایر الگوریتم‌های مورد مقایسه نشان می‌دهند. از آنجا که الگوریتم پیشنهادی، اکتشاف خوبی داشته است، فضاهای مناسبی را مورد جستجو قرار داده و در مراحل بعد، زغن‌ها از این فضاهای امید بخش برای یافتن بهترین جواب استفاده می‌کنند. سایر الگوریتم‌های مورد مقایسه، اکتشاف خوبی ندارند و در بهینه‌های محلی متوقف می‌شوند. الگوریتم کفتار، به دلیل آن که جمعیت از ابتدا، براساس موقعیت اعضا بهتر حرکت می‌کند، اگر این اعضا، در بهینه‌های محلی گرفتار شوند، امکان فرار از آنها را ندارد. به همین دلیل نتایج ضعیفی را در مقایسه با سایر الگوریتم‌ها ارائه می‌دهد.

در جدول (۹)، آزمون فریدمن جهت رتبه‌بندی الگوریتم‌ها استفاده شده که رتبه‌بندی براساس معیار خطا (میانگین مربعات خطا) است. مقادیر کوچک‌ترین در این جدول بهتر هستند. در این جدول الگوریتم پیشنهادی رتبه اول (کمترین خطا) و الگوریتم کفتارهای خالدار، بدترین رتبه در میان الگوریتم‌های مورد مقایسه دارد. در شکل (۶) نمودار پراکندگی مقادیر پیش‌بینی شده برق مصرفی در مقابل مقادیر مشاهده شده توسط ROA-MLP با ۱۰ نرون در لایه مخفی برای داده‌های آموزش و شکل (۷) برای داده‌های آزمون نشان داده شده است. هر چه پراکندگی داده‌ها در اطراف خط رگرسیون کمتر باشد، نشان دهنده دقت بالای مدل است. در شکل‌های (۸) و (۹) به ترتیب خروجی داده‌های آموزش و آزمون و مقایسه آن‌ها با داده‌های مشاهده شده، نمایش داده شده است. همان‌گونه که در این شکل‌ها مشاهده می‌شود، در اکثر موارد نمودار پیش‌بینی هم راستا با مقادیر مشاهده شده است. همچنین، نتایج داده‌های آزمون نشان می‌دهد که شبکه عصبی به خوبی آموزش دیده و نتایج داده‌های آزمون، دارای خطای بسیار پایینی است.

۵- نتیجه‌گیری

حامل‌های انرژی نقش به‌سزایی در تحقق توسعه کشورها دارند. از آنجا که پیش‌بینی میزان مصرف برق، به دلیل ارتباط با بخش‌ها و نهادهای دیگر، نقش قابل توجهی در تصمیم‌گیری‌ها و پیش برد اهداف توسعه‌ی کشورها ایفا می‌کند، بهبود دقت پیش‌بینی نیز مورد توجه بسیاری از محققان در این حوزه قرار گرفته است. از این‌رو با استفاده از روش‌های مختلف سعی بر پیش‌بینی تولید و مصرف برق گردیده تا راه‌گشای مدیران جهت برنامه‌ریزی‌های دقیق‌تر باشد. در این پژوهش پس از معرفی الگوریتم بهینه‌سازی زغن، عملکرد آن بر روی توابع استاندارد CEC2018 با الگوریتم‌های فراابتکاری ملخ، بهینه‌ساز کفتارهای خالدار، شاهین هریس، بهینه‌ساز سوسک بال‌آتشین و بهینه‌ساز حسابی مورد بررسی قرار گرفته است. در این توابع الگوریتم‌ها از نظر قابلیت بهره‌برداری، اکتشاف و توازن بین اکتشاف و بهره‌برداری مورد مقایسه قرار می‌گیرند و نتایج نشان از برتری

الگوریتم پیشنهادی نسبت به سایر الگوریتم‌های مورد مقایسه بر روی این توابع دارد. با توجه به عملکرد خوب الگوریتم پیشنهادی، از آن برای آموزش شبکه عصبی مصنوعی پرسپترون چند لایه بر روی داده‌های مصرف برق ایران از سال ۱۳۹۵ تا سال ۱۳۹۹ استفاده شد. نتایج به دست آمده نشان می‌دهد که آموزش شبکه عصبی پرسپترون چند لایه با استفاده از الگوریتم بهینه‌سازی زغن، نتایج بهتری را نسبت به سایر الگوریتم‌های فراابتکاری مورد مقایسه در این پژوهش دارد. با توجه به نتایج خوبی که الگوریتم پیشنهادی ارائه کرده است، می‌توان در جهت گسترش این تحقیق در خصوص راه‌کارهای پژوهش‌های آینده، به مواردی اشاره کرد از جمله: ارزیابی عملکرد الگوریتم پیشنهادی در سایر مسائل بهینه‌سازی، پیاده‌سازی الگوریتم دودویی و چند هدفه از الگوریتم بهینه‌سازی زغن برای حل مسائل ناپیوسته و چند هدفه و همچنین ارائه راه‌کارهایی برای بهبود الگوریتم پیشنهادی.

References

مراجع

- [1] A. Román-Portabales, M. López-Nores, J.J. Pazos-Arias, "Systematic Review of electricity demand forecast using ANN-based machine learning algorithms", *Sensors*, vol. 21, no. 13, Article Number: 4544, July 2021 (doi: 10.3390/s21134544).
- [2] M.R. Kazemzadeh, A. Amjadian, T. Amraee, "A hybrid data mining driven algorithm for long term electric peak load and energy demand forecasting", *Energy*, vol. 204, Article Number: 117948, Aug. 2020 (doi: 10.1016/j.energy.2020.117948).
- [3] S. Moalem, R. M. Ahari, G. Shahgholian, M. Moazzami, S.M. Kazemi, "Long-term demand forecasting in electrical energy supply chain of espidan ironstone industry using deep learning and extreme learning machine", *Journal of Intelligent Procedures in Electrical Technology*, vol. 13, no. 49, pp. 1-20, June 2022 (doi: 10.1001.1.23223871.1401.13.49.1.0).
- [4] H. Fu, J.C. Baltazar, D.E. Claridge, "Review of developments in whole-building statistical energy consumption models for commercial buildings", *Renewable and Sustainable Energy Reviews*, vol. 147, Article Number: 111248, Aug. 2021 (doi: 10.1016/j.rser.2021.111248).
- [5] S. Lange, J. Pohl, T. Santarius, "Digitalization and energy consumption. Does ICT reduce energy demand?", *Ecological Economics*, vol. 176, Article Number: 106760, Oct. 2020 (doi: 10.1016/j.ecolecon.2020.106760).
- [6] S. Williams, M. Short, "Electricity demand forecasting for decentralised energy management", *Energy Built Environ.* vol. 1, no. 2, pp. 178-186, April 2020 (doi: 10.1016/j.enbenv.2020.01.001).
- [7] A. Daniel, B. Bharathi Kannan, N. Yuvaraj, N. V Kousik, "Predicting energy demands constructed on ensemble of classifiers", *International Journal of Mechanical Engineering*, vol. 6, no. 3, pp. 575-583, Dec. 2021.
- [8] K. Otoufat shamsi, S. Ghane, R. Ghaemmaghami, H. Hedayati, A. Abdalisousan, "Effect of corona virus on electricity consumption in iran and the world", *Journal of Intelligent Procedures in Electrical Technology*, vol. 12, no. 45, pp. 49-62, June 2021 (doi: 10.1001.1.23223871.1400.12.1.4.0).
- [9] N. Shirzadi, A. Nizami, M. Khazen, M. Nik-Bakht, "Medium-term regional electricity load forecasting through machine learning and deep learning", *Designs*, vol. 5, no. 2, Article Number: 5020027, April 2021 (doi: 10.3390/designs5020027).
- [10] F.M. Andersen, H. V Larsen, T.K. Boomsma, "Long-term forecasting of hourly electricity load: Identification of consumption profiles and segmentation of customers", *Energy Conversion and Management*, vol. 68, pp. 244-252, April 2013 (doi: 10.1016/j.enconman.2013.01.018).
- [11] H. Eskandari, M. Imani, M.P. Moghaddam, "Convolutional and recurrent neural network based model for short-term load forecasting", *Electric Power Systems Research*, vol. 195, Article Number: 107173, June 2021 (doi: 10.1016/j.epsr.2021.107173).
- [12] H.M. Al-Hamadi, S.A. Soliman, "Long-term/mid-term electric load forecasting based on short-term correlation and annual growth", *Electric Power Systems Research*, vol. 74, no. 3, pp. 353-361, June 2005 (doi: 10.1016/j.epsr.2004.10.015).
- [13] E. Elbeltagi, H. Wefki, "Predicting energy consumption for residential buildings using ANN through parametric modeling", *Energy Reports*, vol. 7, pp. 2534-2545, Nov. 2021 (doi: 10.1016/j.egy.2021.04.053).
- [14] K. Balachander, D. Paulraj, "ANN and fuzzy based household energy consumption prediction with high accuracy", *Journal of Ambient Intelligence and Humanized Computing*, vol. 12, pp. 7543-7557, July 2021 (doi: 10.1007/s12652-022-04223-y).
- [15] D. Ramos, P. Faria, Z. Vale, R. Correia, "Short time electricity consumption forecast in an industry facility", *IEEE Trans. on Industry Applications*, vol. 58, no. 1, pp. 123-130, Feb. 2022 (doi: 10.1109/TIA.2021.31-

- 23103).
- [16] H.T. Yang, C.M. Huang, "A new short-term load forecasting approach using self-organizing fuzzy ARMAX models", *IEEE Trans. on Power Systems*, vol. 13, no. 1, pp. 217-225, Feb. 1998 (doi: 10.1109/59.651639).
- [17] K. Subramanian, A.P. Sathiyagnanam, D. Damodharan, N. Sivashanmugam, "Artificial neural network based prediction of a direct injected diesel engine performance and emission characteristics powered with biodiesel", *Materials Today: Proceedings*, vol. 43, pp. 1049-1056, Jan. 2021 (doi: 10.1016/j.matpr.2020.08.015).
- [18] P.V Paul, N. Deepika, "Stock market prediction based on technical-deviation-ROC indicators using stock and feeds data", *Recent Advances in Computer Science and Communications*, vol. 15, no. 3, pp. 367-375, Mar. 2022 (doi: 10.2174/2666255813999200831120847).
- [19] A. Jafarian, R. Rezaei, A. Khalili-Golmankhaneh, "On solving fractional higher-order equations via artificial neural networks", *Iranian Journal of Science and Technology*, vol. 46, no. 2, pp. 535-545, Feb. 2022 (doi: 10.1007/s40995-021-01254-6).
- [20] A. Baba, "Advanced AI-based techniques to predict daily energy consumption: A case study", *Expert Systems with Applications*, vol. 184, Article Number: 115508, Dec. 2021 (doi: 10.1016/j.eswa.2021.115508).
- [21] Y. Wu, X. Li, Q. Liu, G. Tong, "The analysis of credit risks in agricultural supply chain finance assessment model based on genetic algorithm and backpropagation neural network", *Computational Economics*, June 2021 (doi: 10.1007/s10614-021-10137-2).
- [22] S.R. Naganna, P.C. Deka, M.A. Ghorbani, S.M. Biazar, N. Al-Ansari, Z.M. Yaseen, "Dew point temperature estimation: Application of artificial intelligence model integrated with nature-inspired optimization algorithms", *Water Resources Management Strategy Under Global Change*, vol. 11, no. 4, pp. 742-759, April 2019 (doi: 10.3390/w11040742).
- [23] Y. Xue, Y. Wang, J. Liang, "A self-adaptive gradient descent search algorithm for fully-connected neural networks", *Neurocomputing*, vol. 478, pp. 70-80, March 2022 (doi: 10.1016/j.neucom.2022.01.001).
- [24] M. Puig-Arnavat, J.C. Bruno, "Artificial neural networks for thermochemical conversion of biomass, in: Recent Adv", *Recent Advances in Thermo-Chemical Conversion of Biomass*, pp. 133-156, Jan. 2019 (doi: 10.1016/B978-0-444-63289-0.00005-3).
- [25] D.H. Tran, D.L. Luong, J.S. Chou, "Nature-inspired metaheuristic ensemble model for forecasting energy consumption in residential buildings", *Energy*, vol. 191, Article Number: 116552, Jan. 2015 (doi: 10.1016/j.energy.2019.116552).
- [26] M.A. Sahraei, M.K. Çodur, "Prediction of transportation energy demand by novel hybrid meta-heuristic ANN", *Energy*, vol. 249, Article Number: 123735, June 2022 (doi: 10.1016/j.energy.2022.123735).
- [27] T. Singh Rajput, A. Thomas, "Optimizing passive design strategies for energy efficient buildings using hybrid artificial neural network (ANN) and multi-objective evolutionary algorithm through a case study approach", *International Journal of Construction Management*, pp. 1-13, March 2022 (doi: 10.1080/15623599.2022.2056409).
- [28] Z. Beheshti, S.M. Shamsuddin, S. Hasan, "Improved centripetal accelerated particle swarm optimization", vol. 258, pp. 54-79, Feb. 2014 (doi: 10.1016/j.ins.2013.08.015).
- [29] S. Kiani, R. Tarkesh Esfahani, Z. Zojaji, "Optimizing the Cutting of Inconel 718 Sheets with CO2 Laser by Particle Swarm Algorithm", *Intelligent Procedures in Electrical Technology*, vol. 13, pp. 111-124, May 2022 (doi: 20.1001.1.23223871.1401.13.51.7.0).
- [30] Z. Beheshti, M. Firouzi, S.M. Shamsuddin, "A new rainfall forecasting model using the CAPSO algorithm and an artificial neural network", *Neural Computing and Applications*, vol. 27, no. 8, pp. 2551-2565, Nov. 2016 (doi: 10.1007/s00521-015-2024-7).
- [31] L. Ajami Bakhtiarvand, Z. Beheshti, "A New Data Clustering Method Using 4-Gray Wolf Algorithm", *Nashriyyah Muhandisi Barq va Muhandisi Kampyutar Iran*, vol. 4, no. 1, pp. 261-274, Winter 2022 (doi: 20.1001.1.16823745.1400.19.4.12.5).
- [32] Z. Beheshti, "BMNABC: Binary Multi-Neighborhood Artificial Bee Colony for High-Dimensional Discrete Optimization Problems", *Cybernetics and Systems*, vol. 49, no. 7, Article Number: 1541597, pp. 452-474, Nov. 2018 (doi: 10.1080/01969722.2018.1541597).
- [33] Z. Beheshti, "UTF: Upgrade transfer function for binary meta-heuristic algorithms", *Applied Soft Computing*, vol. 106, Article Number: 107346, July 2021 (doi: doi.org/10.1016/j.asoc.2021.107346).
- [34] Z. Beheshti, "A novel x-shaped binary particle swarm optimization", *Soft Computing*, vol. 25, no. 4, Feb. 2021 (doi: 10.1007/s00500-020-05360-2).
- [35] S. Saremi, S. Mirjalili, A. Lewis, "Grasshopper Optimisation Algorithm: Theory and application", *Advances in Engineering Software*, vol. 105, pp. 30-47, March 2017 (doi: 10.1016/j.advengsoft.2017.01.004).
- [36] G. Dhiman, V. Kumar, "Spotted hyena optimizer: A novel bio-inspired based metaheuristic technique for engineering applications", *Advances in Engineering Software*, vol. 114, pp. 48-70, Dec. 2017 (doi:

- 10.1016/j.advengsoft.2017.05.014).
- [37] A.A. Heidari, S. Mirjalili, H. Faris, I. Aljarah, M. Mafarja, H. Chen, "Harris hawks optimization: Algorithm and applications", *Future Generation Computer Systems*, vol. 97, pp. 849-872, Aug. 2019 (doi: 10.1016/j.future.2019.02.028).
- [38] M.M. Noel, V. Muthiah-Nakarajan, G.B. Amali, A.S. Trivedi, "A new biologically inspired global optimization algorithm based on firebug reproductive swarming behavior", *Expert Systems with Applications*, vol. 183, Article Number: 115408, Nov. 2021 (doi: 10.1016/j.eswa.2021.115408).
- [39] L. Abualigah, A. Diabat, S. Mirjalili, M. Abd Elaziz, A.H. Gandomi, "The arithmetic optimization algorithm", *Computer Methods in Applied Mechanics and Engineering*, vol. 376, Article Number: 113609, April 2021 (doi: 10.1016/j.cma.2020.113609).
- [40] K. V Price, N.H. Awad, M.Z. Ali, P.N. Suganthan, "Problem definitions and evaluation criteria for the 100-digit challenge special session and competition on single objective numerical optimization", *Technical Report Nanyang Technological University of Singapore*, Nov. 2018.
- [41] S.M. Barakchian, S.F. Ardestani, H. Shokoochian, "Short-term Forecast of Hourly Electricity Demand in Iran Using a Forecast Combination Method", *Planning and Budgeting*, vol. 24, no. 4, pp. 57-73, Feb. 2020 (doi: 10.29252/jpbud.24.4.57).
- [42] S.S.S. Ali, M.R. Razman, A. Awang, M.R.M. Asyraf, M.R. Ishak, R.A. Ilyas, R.J. Lawrence, "Critical determinants of household electricity consumption in a rapidly growing city", *Energy Consumption and Sustainable Urban Environment*, vol. 13, no. 8, April 2021 (doi: 10.3390/su13084441).
- [43] Z. Wang, T. Hong, H. Li, M.A. Piette, "Predicting city-scale daily electricity consumption using data-driven models", *Advances in Applied Energy*, vol. 2, Article Number: 100025, May 2021 (doi: 10.1016/j.adapen.2021.100025).
- [44] M. Oh, K.M. Jang, Y. Kim, "Empirical analysis of building energy consumption and urban form in a large city: A case of Seoul", *Energy and Buildings*, vol. 245, Article Number: 111046, August 2021 (doi: 10.1016/j.enbuild.2021.111046).
- [45] Z. Shafiei Chafi, H. Afrakhte, "Short-term load forecasting using neural network and particle swarm optimization (PSO) algorithm", *Mathematical Problems in Engineering*, vol. 2021, Article Number: 5598267, April 2021 (doi: 10.1155/2021/5598267).
- [46] H. Moayedi, A. Mosavi, "Electrical power prediction through a combination of multilayer perceptron with water cycle ant lion and satin bowerbird searching optimizers", *Applications of Artificial Intelligence in New Energy Technology Systems*, vol. 13, no. 4, Feb. 2021 (doi: 10.3390/su13042336).
- [47] M. Ishaq, S. Kwon, "Short-term energy forecasting framework using an ensemble deep learning approach", *IEEE Access*, vol. 9, Article Number: 3093053, June 2021 (doi: 10.1109/ACCESS.2021.3093053).
- [48] K. Xie, H. Yi, G. Hu, L. Li, Z. Fan, "Short-term power load forecasting based on Elman neural network with particle swarm optimization", *Neurocomputing*, vol. 416, pp. 136-142, Nov. 2020 (doi: 10.1016/j.neucom.2019.02.063).
- [49] M.K. Kim, Y.-S. Kim, J. Srebric, "Predictions of electricity consumption in a campus building using occupant rates and weather elements with sensitivity analysis: Artificial neural network vs. linear regression", *Sustainable Cities and Society*, vol. 62, Article Number: 102385, Nov. 2020 (doi: 10.1016/j.scs.2020.102385).
- [50] S.L. Karunathilake, H.R.K. Nagahamulla, "Artificial neural networks for daily electricity demand prediction of Sri Lanka", 017 Seventeenth International Conference on Advances in ICT for Emerging Regions (ICTer), pp. 1-6, Sep. 2017 (doi: 10.1109/ICTER.2017.8257823).
- [51] M. Talaat, M.A. Farahat, N. Mansour, A.Y. Hatata, "Load forecasting based on grasshopper optimization and a multilayer feed-forward neural network using regressive approach", *Energy*, vol. 196, Article Number: 117087, April 2020 (doi: 10.1016/j.energy.2020.117087).
- [52] S. Duman, A. Dalcali, H. Özbay, "Manta ray foraging optimization algorithm-based feedforward neural network for electric energy consumption forecasting", *International Transactions on Electrical Energy Systems*, vol. 31, no. 9, Sep. 2021 (doi: 10.1002/2050-7038.12999).
- [53] G. Oğcu, O.F. Demirel, S. Zaim, "Forecasting electricity consumption with neural networks and support vector regression", *Procedia- Social and Behavioral Sciences*, vol. 58, August 2012 (doi: 10.1016/j.sbspro.2012.09.1144).
- [54] K. Lan, D. Wang, S. Fong, L. Liu, K.K.L. Wong, N. Dey, "A survey of data mining and deep learning in bioinformatics", *medical systems*, vol. 42, no. 8, June 2018 (doi: 10.1007/s10916-018-1003-9).
- [55] A. Shrestha, A. Mahmood, "Review of deep learning algorithms and architectures", *IEEE Access*, vol. 7, April 2019 (doi: 10.1109/ACCESS.2019.2912200).
- [56] R.P. Parouha, P. Verma, "State-of-the-art reviews of meta-heuristic algorithms with their novel proposal for unconstrained optimization and applications", *Archives of Computational Methods in Engineering*, vol. 28, no. 5, pp. 4049-4115, August 2021 (doi: 10.1007/s11831-021-09532-7).

- [57] S. Desale, A. Rasool, S. Andhale, P. Rane, "Heuristic and meta-heuristic algorithms and their relevance to the real world: a survey", *Computer Engineering in Research Trends*, vol. 2, no. 5, pp. 296-304, May 2015.
- [58] A. Kaveh, M.I. Ghazaan, "Comparison of four meta-heuristic algorithms for optimal design of double-layer barrel vaults", *International Journal of Space Structures*, vol. 33, no. 3-4, pp. 115-123, Oct. 2018 (doi: 10.1177/0266351118803019).
- [59] J. Nayak, B. Naik, H.S. Behera, "A novel nature inspired firefly algorithm with higher order neural network: performance analysis", *Engineering Science and Technology*, vol. 16, no. 1, pp. 197-211, March 2016 (doi: 10.1016/j.jestch.2015.07.005).
- [60] M.R. Gabor, "Is the old communist brand preferred by the young consumers? A country of origin study case with multimethod analysis", *Risk in Contemporary Economy*, vol. 19, pp. 355-366, Oct. 2018 (doi: 10.26397/rce2067053243).
- [61] A. Agresti, "Analysis of Ordinal Categorical Data", New York City John Wiley & Sons, March 2010 (doi: 10.1002/9780470594001).
- [62] Kendall, M. G, "The treatment of ties in ranking problems", *Biometrika*, vol. 33, no. 3, pp. 239-251, Nov. 1945 (doi: 10.2307/2332303).
- [63] A.N. Mandeville, P.E. O'connell, J. V Sutcliffe, J.E. Nash, "River flow forecasting through conceptual models part III-The Ray catchment at Grendon Underwood", *Hydrology*, vol. 11, no. 2, pp. 109-128, August 1970 (doi: 10.1016/0022-1694(70)90098-3).
- [64] C.J. Willmott, "On the validation of models", *Physical Geography*, vol. 2, no. 2, pp. 184-194, July 1981 (doi: 10.1080/02723646.1981.10642213).

زیر نویس‌ها

- | | |
|---|---|
| 1. Fuzzy systems | 22. Convolutional neural network |
| 2. Regression | 23. Elman neural network |
| 3. Optimization | 24. Manta ray foraging optimizer algorithm |
| 4. Error backpropagation algorithm | 25. https://www.mathworks.com/matlabcentral/file-exchange/116125-redkite-optimization-algorithm-roa-for-global-optimization |
| 5. Decreasing gradient | 26. Union call (UC) |
| 6. Red kite | 27. Stress call (SC) |
| 7. Multi-layer perceptron (MLP) | 28. Decrease coefficient |
| 8. Grasshopper optimization algorithm (GOA) | 29. Training data |
| 9. Spotted hyena optimizer (SHO) | 30. Testing data |
| 10. Harris hawk's optimization (HHO) | 31. Mean squared error |
| 11. Firebug reproductive Swarming behavior optimization (FSO) | 32. Unimodal functions |
| 12. Arithmetic optimization algorithm (AOA) | 33. Multimodal functions |
| 13. Exploration | 34. Hybrid functions |
| 14. Exploitation | 35. Composition functions |
| 15. Benchmark functions | 36. Root mean square error |
| 16. Particle swarm optimizer algorithm (PSO) | 37. Mean absolute error |
| 17. Water cycle optimizer algorithm | 38. Pearson sample correlation coefficient |
| 18. Antlion optimizer algorithm | 39. Nash-sutcliffe model efficiency coefficient |
| 19. Satin bowerbird optimizer algorithm (SBO) | 40. Index of agreement |
| 20. Deep learning | 41. https://www.igmc.ir/contact-us/managers |
| 21. Moving average | |