

Research Article

Improving Load Balancing in Fog Computing Using the Polar Fox Optimization Algorithm (PFA)

Omid Eslami¹  | Mehdi Effatparvar^{*2} 

¹ Department of Computer, Islamic Azad University, Ardabil Branch, Ardabil, Iran,
Omid.eslami0@gmail.com

² Department of Computer, Islamic Azad University, Ardabil Branch, Ardabil, Iran,
Me.effatparvar@iau.ac.ir

Corresponding Author

*Mehdi Effatparvar, Assistant Professor,
Department of Computer, Islamic Azad University,
Ardabil Branch, Ardabil, Iran,

Me.effatparvar@iau.ac.ir

Main Subjects: Improving load balancing in cloud computing

Received: 3 October 2025

Revised: 30 November 2025

Accepted: 19 December 2025

<https://doi.org/10.82195/ntds.2025.1219928>

Abstract

Fog computing acts as an intermediate layer between edge devices and cloud infrastructures to reduce latency and improve efficiency in time-sensitive Internet of Things (IoT) applications. However, heterogeneous fog nodes and dynamically changing workloads pose major challenges to effective load balancing, often leading to increased response time, higher energy consumption, and inefficient resource utilization. This paper introduces a novel metaheuristic approach, termed the Polar Fox Optimization Algorithm (PFA), for load balancing in fog computing environments. Inspired by the adaptive hunting behavior of polar foxes, the proposed algorithm integrates exploration and exploitation phases to balance global and local search. The PFA algorithm was implemented in Python and MATLAB and evaluated against benchmark methods, including PSO, ACO, GA, GWO, and HHO. Simulation results demonstrate that the proposed approach reduces average latency by up

to 18.7%, lowers energy consumption by 14.5%, and improves the load balancing index by 22.3% compared to competing algorithms. Statistical validation using Wilcoxon and Friedman tests ($p < 0.05$) confirms the superiority of the proposed method. Overall, PFA provides a scalable, stable, and efficient solution for load balancing in dynamic and heterogeneous fog computing environments, particularly for smart cities, real-time healthcare systems, and large-scale IoT applications.

Keywords: Internet of Things, Metaheuristic Algorithm, Polar Fox Optimization Algorithm, Fog Computing, Load Balancing.

پژوهشی

بهبود توازن بار در رایانش مه با استفاده از الگوریتم بهینه‌سازی روباه قطبی (PFA)

امید اسلامی^۱ | مهدی عفت پرور^۲ *  

چکیده:

رایانش مه به‌عنوان یک معماری میان افزاینده میان دستگاه‌های لبه و ابر برای کاهش تأخیر و افزایش بهره‌وری در کاربردهای حساس به زمان در اینترنت اشیاء (IoT) مطرح است. با این حال، ناهمگن بودن گره‌ها و پویایی بارهای کاری، چالش جدی در حفظ توازن بار است؛ مدیریت ناکارآمد توازن بار می‌تواند منجر به افزایش زمان پاسخ، مصرف انرژی بالا و کاهش بهره‌وری منابع گردد. در این پژوهش، الگوریتم فراابتکاری جدید با عنوان الگوریتم بهینه‌سازی روباه قطبی (PFA) برای بهبود توازن بار در رایانش مه پیشنهاد می‌شود، این الگوریتم با الهام از رفتار شکار روباه قطبی در محیط‌های قطبی و توانایی تطبیق حرکتی آن با شرایط پویا، از دوفاز مکمل اکتشاف و بهره‌برداری بهره می‌گیرد تا میان جستجو سراسری و موضعی اطراف خود تعادل برقرار کنند. برای ارزیابی، الگوریتم پیشنهادی در محیط‌های شبیه‌سازی Python و MATLAB پیاده‌سازی و با الگوریتم مرجع بهینه‌سازی ازدحام ذرات، کلونی مورچه، GA، گرگ خاکستری و شاهین هریس مقایسه شده است. نتایج شبیه‌سازی‌ها نشان می‌دهد که مدل پیشنهادی ما موجب میانگین کاهش تأخیر تا ۱۸٫۷٪، کاهش مصرف انرژی تا ۱۴٫۵٪ و بهبود شاخص توازن بار تا ۲۲٫۳٪ نسبت به الگوریتم‌های مرجع شده است. افزون بر این، آزمون‌های آماری Wilcoxon و Friedman با مقدار $p < 0.05$ برتری معنادار الگوریتم پیشنهادی را تأیید میکند، رفتار هم‌گرایی الگوریتم نیز از طریق نمودارهای کانکتور و سه بعدی تحلیل شده و نشان می‌دهد که الگوریتم بهینه‌سازی روباه قطبی از نظر پایداری و سرعت هم‌گرایی عملکرد بهتری نسبت به روش‌های مرجع دارد. در نتیجه الگوریتم پیشنهادی بهینه‌سازی روباه قطبی می‌تواند به عنوان رویکردی هوشمند مقیاس پذیر و کارآمد برای مدیریت توازن بار در محیط‌های پویا و ناهمگن مه به ویژه در کاربرد های شهر هوشمند، سامانه های پزشکی بلادرنک و شبکه های گسترده اینترنت اشیا مورد استفاده قرار گیرد.

^۱ گروه مهندسی کامپیوتر، واحد اردبیل، دانشگاه آزاد اسلامی، اردبیل، ایران

Omid.eslamio@gmail.com

^۲ گروه مهندسی کامپیوتر، واحد اردبیل، دانشگاه آزاد اسلامی، اردبیل، ایران

Me.effatparvar@iau.ac.ir

نویسنده مسئول

مهدی عفت پرور، استادیار کامپیوتر، گروه مهندسی کامپیوتر، واحد اردبیل، دانشگاه آزاد اسلامی، اردبیل، ایران

Me.effatparvar@iau.ac.ir

موضوع اصلی: بهبود توازن بار در رایانش مه

تاریخ دریافت: ۱۴۰۴/۷/۱۱

تاریخ بازنگری: ۱۴۰۴/۹/۹

تاریخ پذیرش: ۱۴۰۴/۹/۲۸

<https://doi.org/10.82195/ntds.2025.1219928>

کلیدواژه‌ها: اینترنت اشیا، الگوریتم فراابتکاری، الگوریتم بهینه‌سازی روباه قطبی، رایانش مه، توازن بار

۱. مقدمه:

با گسترش روزافزون دستگاه های هوشمند در اینترنت اشیاء، نیاز به پردازش داده ها در نزدیک ترین نقطه به منبع تولید آن ها بیش از پیش اهمیت یافته است. در این راستا، رایانش م^۱ به عنوان لایه ای میان ابر و لبه، با هدف کاهش تأخیر، بهبود زمان پاسخ و بهینه سازی مصرف انرژی مطرح شده است [۱،۲]. با وجود مزایای فراوان، یکی از چالش های اساسی در رایانش م^۱، توزیع نابرابر بار کاری میان گره های م^۱ و ایجاد گلوگاه های پردازشی است [۳،۲]. روش های کلاسیک مانند Round Robin به دلیل ماهیت ایستا و عدم انطباق با پویایی محیط های م^۱، بهره وری محدودی دارند [۴،۵]. در سال های اخیر، الگوریتم های فراابتکاری متعددی برای حل این مسئله پیشنهاد اما هنوز چالشی اساسی در یافتن تعادلی میان اکتشاف و بهره برداری در جستجوی فضای بهینه وجود دارد. در پاسخ به این چالش، این مقاله الگوریتم جدیدی با نام الگوریتم بهینه سازی روباه قطبی را معرفی می کند که با الهام از رفتار تطبیقی روباه قطبی در شرایط محیطی سخت، از ترکیب سازوکارهای جستجوی تصادفی و جهت دار برای بهبود توازن بار بهره می گیرد [۶،۷،۸،۱۳].

اهداف پژوهش به صورت زیر تعریف می شوند :

- (1) طراحی مدلی فراابتکاری برای توزیع پویا و هوشمند بار در محیط م^۱.
- (2) مقایسه عملکرد بهینه سازی روباه قطبی با الگوریتم های بهینه سازی ازدحام ذرات ، گرگ خاکستری ، شاهین هریس، الگوریتم کلونی مورچه و بهترین الگوریتم مرجع
- (3) ارزیابی شاخص های تأخیر، مصرف انرژی و نرخ توازن بار.
- (4) تحلیل آماری نتایج با آزمون های Friedman و Wilcoxon

سؤالات پژوهش:

۱. آیا الگوریتم بهینه سازی روباه قطبی می تواند نسبت به الگوریتم های فراابتکاری موجود، توازن بار بهتری در رایانش م^۱ ایجاد کند؟
 ۲. میزان تأثیر الگوریتم پیشنهادی بر کاهش تأخیر، مصرف انرژی و افزایش نرخ توازن بار چقدر است؟
 ۳. آیا استفاده از مکانیزم دوفازی بهینه سازی روباه قطبی اکتشاف بهره برداری باعث بهبود پایداری همگرایی الگوریتم در محیط های پویا می شود؟
- نوآوری اصلی پژوهش در سه محور بیان می شود :
- (1) معرفی ساختار دوفازی اکتشاف بهره برداری در الگوریتم بهینه سازی روباه قطبی ،
 - (2) استفاده از تابع برازندگی چندهدفه برای توازن بار،
 - (3) اعمال کنترل تطبیقی در انتخاب گره های م^۱ با استفاده از مفهوم یادگیری محلی.

۲. پیشینه تحقیق:

با گسترش چشم گیر اینترنت اشیاء و افزایش حجم داده های بلادرنگ، مدل های سنتی رایانش ابری به دلیل تمرکزگرایی و تأخیر بالا دیگر پاسخگوی نیازهای کاربردهای حساس زمان واقعی نبودند. در این میان، رایانش م^۱ به عنوان معماری مکمل رایانش ابری مطرح شد تا پردازش داده ها را به گره هایی نزدیک تر به منبع تولید داده انتقال دهد [۱،۱۷]. این تغییر پارادایم سبب شد تا مسئله ی توازن بار به یکی از مهم ترین چالش های طراحی سامانه های م^۱ تبدیل شود، زیرا توزیع نامناسب وظایف میان گره ها منجر به افزایش تأخیر، مصرف انرژی زیاد و کاهش بهره وری منابع می گردد [۱۵،۱۹،۲۲].

در مراحل اولیه توسعه رایانش م^۱، پژوهشگران عمدتاً از روش های کلاسیک ایستا و متمرکز برای توازن بار استفاده کردند. الگوریتم هایی مانند Round Robin و Weighted Round Robin با وجود سادگی و سرعت بالا، به دلیل بی توجهی به ظرفیت و وضعیت لحظه ای گره ها، در محیط های پویا و ناهمگن عملکرد ضعیفی داشتند [۲۶،۲۸،۲۹]. در پاسخ به این محدودیت ها، رویکردهای پویا و توزیع شده مطرح شدند که هدفشان انطباق با تغییرات محیط و کاهش گلوگاه های پردازشی بود

[۶،۷،۱۵]. هرچند این روش‌ها مقیاس‌پذیری بهتری ارائه می‌دادند، ولی سربار ارتباطی و پیچیدگی مدیریتی بیشتری نیز به همراه داشتند.

از دهه گذشته، جهت‌گیری پژوهش‌ها به سمت بهره‌گیری از الگوریتم‌های فراابتکاری برای توازن بار در محیط مه تغییر یافته است، چراکه این الگوریتم‌ها قادرند در فضای جستجوی بزرگ و غیرخطی، پاسخ‌های نزدیک به بهینه بیابند [۱۲،۴۸]. در میان آن‌ها، الگوریتم‌هایی نظیر بهینه‌سازی ازدحام ذرات، کلونی مورچه، گرگ خاکستری، زنبور عسل مصنوعی و نهنگ بیشترین توجه را جلب کرده‌اند. الگوریتم بهینه‌سازی ازدحام ذرات با تقلید از رفتار اجتماعی ذرات برای بهینه‌سازی پیوسته طراحی شده و در تخصیص وظایف مه به دلیل سرعت همگرایی بالا کاربرد یافته است، اما در محیط‌های پویا دچار همگرایی زودرس و کاهش دقت می‌شود [۹،۱۴]. کلونی مورچه نیز با الهام از رفتار جستجوی مورچه‌ها برای یافتن مسیر بهینه، در کاهش تأخیر مؤثر بوده است ولی به علت سربار محاسباتی زیاد در مقیاس بزرگ کارایی کمتری دارد [۱۰،۱۱]. در مقابل، گرگ خاکستری با مدل‌سازی رفتار گروهی گرگ‌ها تعادلی میان اکتشاف و بهره‌برداری برقرار می‌کند و نتایج مطلوبی در توازن بار ارائه داده است، هرچند پایداری آن در شرایط تغییرپذیر بار کاهش می‌یابد [۱۲،۱۳]. الگوریتم‌های زنبور عسل مصنوعی و نهنگ نیز به ترتیب با شبیه‌سازی رفتار زنبورهای عسل و نهنگ‌ها، بهبودهایی در تخصیص پویا ایجاد کرده‌اند، اما نیازمند تنظیم دقیق پارامترها و منابع محاسباتی بالا هستند [۱۰،۳۱،۳۲].

در سال‌های اخیر، پژوهشگران به سمت رویکردهای ترکیبی و هوشمند پیش رفته‌اند تا از مزایای چند الگوریتم به صورت هم‌زمان بهره بگیرند. برای نمونه، ترکیب گرگ خاکستری و الگوریتم ژنتیک توانسته است میان سرعت همگرایی و دقت راه‌حل تعادل برقرار کند [۵]. از سوی دیگر، تلفیق شبکه‌های نرم‌افزارمحور با الگوریتم‌های بهینه‌سازی، امکان کنترل پویا و مقیاس‌پذیری بالاتر را فراهم کرده است [۷،۴۰]. افزون بر آن، استفاده از یادگیری عمیق برای پیش‌بینی بار و تصمیم‌گیری تطبیقی نیز مورد توجه قرار گرفته، اما این روش‌ها به دلیل نیاز به توان پردازشی و داده‌ی آموزشی زیاد، در محیط‌های مه با محدودیت منابع کمتر عملی‌اند [۴۲]. با وجود این پیشرفت‌ها، مطالعات گذشته هنوز با چند شکاف کلیدی روبه‌رو هستند:

۱. ناتوانی در حفظ پایداری هنگام تغییرات شدید بار و ناهمگنی گره‌ها [۹،۱۰،۱۲]. ۲. گیر افتادن در بهینه‌های محلی و کاهش تنوع جمعیت در فرآیند جستجو [۹،۱۴]. ۳. هزینه محاسباتی بالا و پیچیدگی تنظیم پارامترها در الگوریتم‌های ترکیبی [۳۱،۴۳،۴۵]. ۴. توجه محدود به چندمعیاره‌بودن مسئله، یعنی بهینه‌سازی همزمان تأخیر، انرژی و بهره‌وری منابع [۳۸،۳۱]. در نتیجه، نیاز به الگوریتمی احساس می‌شود که ضمن حفظ سادگی و کارایی، بتواند در محیط‌های پویا تعادل مؤثر میان اکتشاف سراسری و بهره‌برداری محلی برقرار کند.

براین‌اساس، پژوهش حاضر الگوریتم جدیدی با عنوان بهینه‌سازی روباه قطبی را معرفی می‌کند که با الهام از رفتار شکار و سازگاری روباه قطبی در محیط‌های سرد و متغیر، تلاش دارد ضعف‌های الگوریتم‌های پیشین را جبران نماید. این الگوریتم از چند نوآوری کلیدی بهره می‌گیرد: تقسیم نقش جمعیت، فاز دوگانه اکتشاف-بهره‌برداری، و سازوکار ضد همگرایی کاذب که آن را به گزینه‌ای مناسب برای مدیریت توازن بار در محیط‌های ناهمگن و پویا مانند رایانش مه بدل می‌کند. تحلیل مقایسه‌ای پژوهش‌های پیشین:

جدول ۱: تحلیل مقایسه‌ای پژوهش‌های پیشین
Table 1: Comparative Analysis of Previous Studies

محدودیت‌ها	مزایا	روش	سال	منبع
غیرتطبیقی	ساده و سریع	Dynamic RR	۲۰۲۱	[1]
ناپایدار در مقیاس بزرگ	کاهش تأخیر	PSO Adaptive	۲۰۲۲	[2]
هزینه محاسباتی بالا	بهبود سرعت همگرایی	Hybrid GWO-GA	۲۰۲۳	[5]
نیاز به تنظیم دقیق پارامترها	کنترل هوشمند در شبکه	SDN + HHO	۲۰۲۴	[7]
یادگیری زمان‌بر	پیش‌بینی بار دقیق	AI-driven	۲۰۲۴	[8]
در حال توسعه آزمایشی	تعادل پویا، کاهش تأخیر، بهبود توازن بار	PFA	۲۰۲۵	این مقاله

در نتیجه، می توان گفت که پژوهش حاضر با تمرکز بر طراحی یک الگوریتم فراابتکاری جدید و تطبیقی، گامی در جهت پر کردن شکاف میان الگوریتم های سنتی و هوشمند در محیط های پویا و ناهمگن رایانش مه بر می دارد. توازن باریکی از مسائل بنیادی در رایانش ابری و مه است که نقش مهمی در افزایش بهره وری، کاهش تأخیر و جلوگیری از اضافه بار منابع ایفا می کند. در مطالعات اولیه، الگوریتم های کلاسیک متعددی برای این منظور ارائه شده اند که عمدتاً در دودسته ایستا و پویا قرار می گیرند [۱،۸،۴۶]. از نظر معماری، روش های کلاسیک می توانند متمرکز یا توزیع شده باشند. در رویکرد متمرکز، یک گره مرکزی وظیفه تصمیم گیری را بر عهده دارد که مدیریت را ساده می سازد، اما خطر تک نقطه شکست در آن وجود دارد. در مقابل، رویکرد توزیع شده با تقسیم مسئولیت میان چندین گره، قابلیت تحمل خطا و مقیاس پذیری بیشتری را فراهم می کند، هرچند سربار ارتباطی و پیچیدگی بیشتری دارد [۶،۷،۴۴]. علاوه بر این، رویکردهای هیبریدی نیز معرفی شده اند که با ترکیب روش های ایستا و پویا یا متمرکز و توزیع شده تلاش می کنند نقاط ضعف هر کدام را برطرف کنند [۱۵،۳۳] با وجود اهمیت روش های کلاسیک در بنیان گذاری حوزه توازن بار، محدودیت های آن ها در مواجهه با محیط های پویا موجب شده است پژوهشگران به سمت بهره گیری از روش های هوشمند و الگوریتم های فرا ابتکاری حرکت کنند تا بتوانند راهکارهایی با بهره وری و انعطاف پذیری بالاتر ارائه دهند [۱۶،۱۷،۳۴].

۱-۲. روش های کلاسیک توازن بار:

روش های کلاسیک مانند Round Robin به دلیل سادگی و سهولت پیاده سازی در محیط های ایستا به کار گرفته شده اند [۲۶،۲۸،۳۰]. در الگوریتم Round Robin، وظایف به صورت چرخشی میان گره ها توزیع می شوند و هدف آن توزیع یکنواخت بار کاری است، بدون در نظر گرفتن ظرفیت واقعی یا وضعیت لحظه ای هر گره [۲۷،۲۹]. الگوریتم Weighted Round Robin نسخه پیشرفته تری است که وزن گره ها را لحاظ می کند و وظایف را نسبت به توان پردازشی هر گره توزیع می کند، اما هنوز اطلاعات لحظه ای سیستم را مد نظر قرار نمی دهد [۲۳،۲۶].

۲-۲. الگوریتم های فراابتکاری:

الگوریتم های فراابتکاری به دلیل توانایی ذاتی در حل مسائل بهینه سازی پیچیده و محیط های پویا، به عنوان گزینه ای مؤثر برای توازن بار در رایانش مه مطرح شده اند [۱۲،۲۴،۴۸]. این الگوریتم ها با شبیه سازی رفتارهای طبیعی یا الهام از فرایندهای بیولوژیکی و فیزیکی، توانایی پیدا کردن راهکارهای بهینه در فضای بزرگ و غیرخطی مسئله را دارند.

۳-۲. روش های نوین و ترکیبی:

روش های نوین و ترکیبی برای توازن بار در رایانش مه بر اساس فناوری های پیشرفته مانند یادگیری عمیق، SDN و معماری های توزیع شده توسعه یافته اند و تلاش می کنند محدودیت های روش های کلاسیک و حتی فراابتکاری را برطرف کنند. به طور کلی، روش های نوین و ترکیبی با استفاده از فناوری های پیشرفته توانسته اند انعطاف پذیری، دقت و پایداری بالاتری نسبت به روش های کلاسیک و حتی برخی الگوریتم های فراابتکاری ارائه دهند، اما چالش هایی همچون نیاز به منابع محاسباتی زیاد، پیچیدگی پیاده سازی و محدودیت مقیاس پذیری همچنان در مسیر استفاده گسترده آن ها وجود دارد.

۴-۲. شکاف تحقیقاتی در الگوریتم ها:

علی رغم پیشرفت ها، روش های موجود با چالش هایی مواجه هستند که در جدول ۲ به آن پرداخته شده:

جدول ۲: مزایا و معایب

Table 2: Advantages and Disadvantages

نام الگوریتم	معایب	مزایا	مشکل و شکاف تحقیقاتی	توضیح	منبع
PSO	گیرافتادن در نقاط محلی، نیاز به تنظیم دقیق پارامترها	جستجوی مؤثر در فضای بهینه سازی، پیاده سازی ساده	همگرایی زود هنگام در محیط های بزرگ و پویا	در مسائل پیچیده بهره وری پایین دارند.	[9]
ACO	افزایش هزینه محاسباتی با تعداد گره ها و وظایف بالا	توانایی یافتن مسیرهای بهینه، الگوریتم الهام گرفته از طبیعت	سربار محاسباتی بالا در مقیاس بزرگ	در مسائل پیچیده بهره وری پایین دارند.	[10]
GWO	ناپایدار در محیط های پویا	بهبود تأخیر و بهره وری منابع، تعادل بین اکتشاف و بهره برداری	ناپایداری در شرایط بار متغیر	درباره های متغیر نمی توانند پایدار باشند و ناپایداری زیادی دارند	[12]

WOA	نیاز به بهینه سازی بیشتر در محیط های متغیر	تعادل مناسب بین جستجوی محلی و جهانی، مقابله با مسائل پیچیده	ناپایداری در سناریوهای پویا	دربارهای متغیر نمی توانند پایدار باشند و ناپایداری زیادی دارند	[13]
روش های یادگیری عمیق	مصرف بالای منابع، زمان آموزش طولانی	پیش بینی دقیق بار، قابلیت یادگیری الگوهای پیچیده	نیاز به منابع محاسباتی بالا و زمان آموزش طولانی	به منابع زیادی نیاز دارند تا نیازها را برطرف کنند	[42]
SDN	پیاده سازی پیچیده و هزینه بر	کنترل متمرکز شبکه، افزایش پایداری و انعطاف پذیری	پیچیدگی پیاده سازی و هزینه تجهیزات	به منابع زیادی نیاز دارند تا نیازها را برطرف کنند	[40]
الگوریتم های ترکیبی و نوین	پیچیدگی محاسباتی، نیاز به تنظیم دقیق پارامترها	ترکیب مزایای الگوریتم های مختلف، انعطاف پذیری بالا	پیچیدگی محاسباتی و محدودیت مقیاس پذیری	تنها بر یک یا دو معیار متمرکز است	[31]- [32]-

۳. مبانی نظری، مفهومی و پیشینه علمی:

۳-۱. مفهوم رایانش مه:

رایانش مه به عنوان یک پارادایم محاسباتی نوظهور، باهدف پاسخگویی به نیازهای پردازش بلادرنگ و کم تأخیر در اکوسیستم اینترنت اشیاء توسعه و برخلاف رایانش ابری با توزیع قابلیت های محاسباتی، ذخیره سازی و تحلیل در لبه دستگاه اینترنت اشیاء امکان پردازش محلی و سریع را فراهم می سازد [۱۶،۱۸،۲۰]. این ویژگی رایانش مه نه تنها تأخیر را به طور قابل توجهی کاهش می دهد، بلکه مصرف پهنای باند شبکه را بهینه کرده و امنیت داده ها را بهبود می بخشد و بهره وری انرژی را در کاربردهای حساس افزایش می دهد [۴۱،۴۷]. رشد روزافزون دستگاه های اینترنت اشیاء و نیاز به پردازش های مقیاس پذیر و بلادرنگ، رایانش مه را به یک زیرساخت کلیدی تبدیل کرده است. با این حال، نا همگنی منابع گره های مه، پویایی بارهای کاری و محدودیت های زیرساختی، چالش های متعددی را در پیاده سازی کارآمد این پارادایم ایجاد کرده اند [۱۵،۲۹].

۳-۲. ضرورت توازن بار در رایانش مه:

توازن بار در رایانش مه فرایندی است که هدف آن تخصیص بهینه وظایف به گره های پردازشی است تا از تراکم بیش از حد در برخی گره ها جلوگیری شده و منابع به صورت یکنواخت و کارآمد استفاده شوند [۱۵،۳۰،۳۵]. عدم مدیریت صحیح توازن بار می تواند پیامدهای متعددی داشته باشد؛ روش های کلاسیک Round Robin به دلیل ماهیت ایستا و عدم توانایی در مدیریت پیچیدگی های محیط مه، بهره وری محدودی دارند [۲۰]. این روش ها معمولاً فرض می کنند که گره ها همگن هستند و بار کاری به صورت یکنواخت توزیع می شود، درحالی که در محیط های واقعی، گره های مه از نظر ظرفیت محاسباتی و انرژی بسیار متنوع هستند [۲۹].

۳-۳. الگوریتم های فراابتکاری در توازن بار:

الگوریتم های فراابتکاری به دلیل حل مشکل بهینه سازی چندمعیاره و خطی در مدیریت توازن بار در رایانش مه زیاد مورد توجه قرار گرفته است [۱۲،۱۳،۲۱]. در ادامه، بعضی از الگوریتم هایی که به عنوان الگوریتم مرجع استفاده شده معرفی میشود:

۳-۳-۱. الگوریتم کلونی مورچه :

این الگوریتم با الهام از رفتار جستجوی مسیر مورچه ها، به کمک ترشح فرمون برای یافتن بهترین مسیر برای تخصیص وظایف استفاده می کند، این الگوریتم در سناریو های با تعداد گره های کوچکتر دارای بهره وری بهتری هستند ولی در تعداد گره های زیاد بدلیل بروز رسانی مسیر و فرمون ها نیاز به زمان زیاد تری دارد و بهره وری آن کاهش میابد [۱۰،۲۵،۴۸].

۳-۳-۲. الگوریتم بهینه سازی ازدحام ذرات:

. الگوریتم بهینه سازی ازدحام ذرات با شبیه سازی حرکت ذرات در فضای جستجو و به روز رسانی موقعیت ها بر اساس بهترین تجربه فردی و جمعی، برای مسائل پیوسته و گسسته مناسب است. این الگوریتم به دلیل سرعت هم گرایی بالا در مسائل ساده محبوب است، اما در فضاهای جستجوی پیچیده، احتمال گیر افتادن در بهینه های محلی دارد [۹،۱۴،۳۶].

۳-۳-۳. الگوریتم گرگ خاکستری :

الگوریتم گرگ خاکستری با مدل سازی سلسله مراتب اجتماعی و استراتژی شکار گرگ ها، تعادل مناسبی بین اکتشاف و استثمار ایجاد می کند. این الگوریتم در کاهش تأخیر و بهبود بهره وری منابع در رایانش مه موفق بوده است، اما با تغییرات شدید بار بهره وری خود پایین می آید [۱۰].

۳-۳-۴. الگوریتم زنبور عسل مصنوعی :

الگوریتم زنبور عسل مصنوعی با شبیه سازی رفتار زنبورهای کارگر، ناظر و جستجوگر، منابع بارزش را حفظ و منابع بی ارزش را حذف می کند. این الگوریتم دارای انعطاف زیادی در مقابل مسائل پیچیده برای توازن بار در رایانش مه می باش [۱۰، ۱۲]

۳-۳-۵. الگوریتم نهنگ:

الگوریتم نهنگ با الهام از الگوهای شکار نهنگ ها تعادل خوبی بین جستجوی محلی و جهانی ارائه می دهد. این الگوریتم در تخصیص وظایف در رایانش مه بهره وری بالایی دارد، اما در سناریوهای با تغییرات پویا، دقت و پایداری آن ممکن است کاهش یابد [۳، ۱۰]

۳-۳-۶. رویکردهای نوین و ترکیبی:

در سال های اخیر، رویکردهای ترکیبی و مبتنی بر فناوری های نوین مانند یادگیری عمیق و شبکه های نرم افزار محور برای توازن بار در رایانش مه پیشنهاد شده اند.

۳-۴. چالش های موجود و جایگاه الگوریتم بهینه سازی روباه قطبی^۲

با وجود پیشرفت های قابل توجه در الگوریتم های فرا ابتکاری، چالش های متعددی همچنان مانع از دستیابی به توازن بار کارآمد در رایانش مه می شوند: ۱. گیر افتادن در بهینه های محلی [۹]. ۲. ناپایداری در محیط های پویا [۱۰، ۱۱]. ۳. سربار محاسباتی بالا [۳۵، ۳۶]. ۴. نیاز به تنظیم دقیق پارامترها [۱۵]. ۵. عدم جامعیت در معیارها [۳۱، ۳۸]. الگوریتم بهینه سازی روباه قطبی در دسته ی الگوریتم های الهام گرفته از شکارچیان قرار می گیرد [۵]. آنچه الگوریتم بهینه سازی روباه قطبی را واقعاً متمایز می کند، مجموعه ای از نوآوری های کلیدی است که آن را نسبت به سایر الگوریتم های فرا ابتکاری برجسته می سازد. نخستین ویژگی مهم، الهام زیستی خاص و منحصر به فرد این الگوریتم است؛ برای اولین بار رفتار روباه قطبی به عنوان منبع الهام استفاده شده ، بنابراین الگوریتم بهینه سازی روباه قطبی جنبه نوآورانه و تازه ای در طراحی الگوریتم های بهینه سازی ارائه می دهد. دومین ویژگی، مدل سازی دقیق دو فاز شکار است؛ الگوریتم با ترکیب فرآیند شکار برای شناسایی نواحی امیدبخش و پرش شکار برای بهره برداری دقیق، توانسته همزمان اکتشاف و بهره برداری را تقویت کند و کیفیت راه حل ها را افزایش دهد. سومین نوآوری، تقسیم بندی رفتاری جمعیت است؛ روباه ها به گروه های مختلف شامل رهبر محور، تجربه محور، آزاد و سخت کوش تقسیم شده اند، که این امر موجب پویایی جمعیت، افزایش تنوع حرکت و جلوگیری از همگرایی زودرس می شود و الگوریتم را در مواجهه با مسائل پیچیده انعطاف پذیرتر می کند. نهایتاً، مکانیزم خستگی و انگیزش یکی دیگر از نوآوری های مهم الگوریتم بهینه سازی روباه قطبی است که فرآیندهای طبیعی مانند خستگی روباه یا تحریک توسط رهبر را شبیه سازی می کند؛ این مکانیزم تنوع جمعیت را در طول تکرارها حفظ کرده و پایداری الگوریتم را تضمین می کند. ترکیب این چهار نوآوری، الگوریتم بهینه سازی روباه قطبی را به یک الگوریتم بسیار توانمند، پویا و مناسب برای مسائل پیچیده بهینه سازی تبدیل کرده است .

۴. طراحی، تشریح و مدل سازی الگوریتم بهینه سازی روباه قطبی:

۴-۱. مقدمه و الهام گیری زیستی

الگوریتم پیشنهادی بهینه سازی روباه قطبی بر پایه رفتار شکار روباه قطبی در شرایط سخت قطب شمال طراحی شده است. روباه قطبی برای بقا در محیطی با دماهای بسیار پایین و منابع غذایی محدود، راهبردهای منحصر به فردی را تکامل داده است. مهم ترین ویژگی های الهام بخش برای طراحی الگوریتم عبارتند از: قدرت شنوایی خارق العاده: روباه قطبی قادر است صدای جوندگان کوچک را در زیر برف های ضخیم شناسایی کند. این توانایی در الگوریتم به صورت حساسیت به موقعیت های مناسب

² Polar Fox Optimization – PFA

مدل می‌شود. پرش شکار (Hunting Leap) روباه پس از شناسایی موقعیت طعمه، یک پرش بلند و دقیق انجام می‌دهد و از بالا به زیر برف حمله می‌کند. این رفتار در الگوریتم معادل با حرکت جهشی به سمت بهترین جواب‌های احتمالی است زندگی گروهی و تقسیم نقش‌ها: روباه‌ها معمولاً در قالب گروه‌های کوچک فعالیت می‌کنند و هر کدام نقش متفاوتی در شکار دارند. این سه اصل زیستی اساس طراحی الگوریتم بهینه‌سازی روباه قطبی هستند که در ادامه به صورت ریاضی مدل‌سازی می‌شوند.

۴-۲. نمایش ریاضی مسئله توازن بار

فرض کنید مسئله بهینه‌سازی دارای ابعاد d باشد و محدوده جستجو بین کران پایین LB و کران بالا UB تعریف شود. در این صورت، موقعیت هر روباه (هر جواب کاندید) به صورت برداری در فضای d - بعدی تعریف می‌شود:

$$X_i = \{x_{i1}, x_{i2}, \dots, x_{id}\}, i = 1, 2, \dots, N$$

(1)

که در آن N تعداد روباه‌ها (جمعیت اولیه) است.

مقداردهی اولیه به صورت تصادفی و یکنواخت در فرمول شماره ۲ انجام می‌شود:

$$x_{ij} = LB_j + \text{rand}(0,1) \cdot (UB_j - LB_j)$$

(2)

مقدار کمتر LB نشان‌دهنده توازن بار بهتر میان‌گره‌ها است

۴-۳. تقسیم نقش‌ها در جمعیت:

برای ایجاد تنوع رفتاری و جلوگیری از همگرایی زودرس، روباه‌ها به چهار گروه رفتاری تقسیم می‌شوند:

۱. روباه‌های آزاد (Free Searchers): به صورت تصادفی محیط را کاوش می‌کنند (اکتشاف).
۲. روباه‌های رهبر محور (Leader Followers): موقعیت رهبر گروه را دنبال می‌کنند (بهره‌برداری).
۳. روباه‌های تجربه‌محور (Experience-based): بر اساس تجربیات گذشته و بهترین موقعیت‌های ذخیره‌شده عمل می‌کنند.
۴. روباه‌های سخت‌کوش (Hard-workers): با حرکات آهسته‌تر و دقیق‌تر به جستجوی موضعی می‌پردازند.

۴-۳-۱. حرکت تجربه‌محور:

هر روباه می‌تواند بر اساس تجربه‌ی گذشته خود حرکت کند. اگر P قدرت پرش و D جهت حرکت باشد، موقعیت جدید به صورت زیر به‌روزرسانی می‌شود:

$$X_i^{t+1} = X_i^t + P \cdot D$$

(3)

که در فرمول ۳:

- P به صورت تصادفی یا وابسته به کیفیت جواب‌های قبلی تعیین می‌شود،
- $D = \cos(\theta)$ جهت حرکت با زاویه‌ی تصادفی $\theta \in [0, 180^\circ]$ این بخش معادل پرش آزمایشی روباه‌ها است.

۴-۳-۲. حرکت رهبرمحور:

هر قلابه از روباه‌های قطبی یک رهبر دارد که قلابه را در رسیدن به هدفش هدایت می‌کند رهبر گروه (بهترین روباه با بالاترین برازندگی) سایر اعضا را هدایت می‌کند. حرکت اعضای گروه بر اساس موقعیت رهبر به صورت زیر مدل می‌شود:

$$X_i^{t+1} = X_i^t + r \cdot (X_{\text{leader}}^t - X_i^t)$$

(4)

که در فرمول ۴ $r \in [-1, 1]$ یک ضریب تصادفی است.

این مرحله باعث می‌شود جمعیت به سمت بهترین جواب‌های فعلی همگرا شود.

۴-۳-۳. فاز انگیزش رهبر:

وقتی روباه های قطبی نمی توانند به طور متوالی طعمه پیدا کنند رهبر آن را تحریک می کند و اعضا موقعیت خود را به طور تصادفی تغییر می دهد اگر جمعیت برای چندین تکرار متوالی پیشرفت نکند (همگرایی کاذب رخ دهد)، رهبر گروه سایر اعضا را وادار به بازآرایی تصادفی می کند:

$$X_i^{t+1} = LB + \text{rand}(0,1) \cdot (UB - LB) \quad (5)$$

این سازوکار مشابه تنوع بخشی اجباری است و از گرفتار شدن الگوریتم در بهینه های محلی جلوگیری می کند. در جدول زیر تمام پارامترهای فرمول های بالا توضیح داده شده است.

جدول ۳: جدول پارامترهای الگوریتم بهینه سازی روباه قطبی
Table 3: Parameter Table of the Polar Fox Optimization Algorithm

واحد / نوع داده	مقدار یا بازه استفاده شده در شبیه سازی	توضیح پارامتر (Parameter Description)	نماد (Symbol)
عدد صحیح	۵۰ تا ۱۰	تعداد کل گره های مه (Fog Nodes) در محیط شبیه سازی	(N)
ثانیه	0.2 – 2.5	زمان اجرای تسک (i) روی گره مه	(T_i)
کیلوبایت	100 – 1000	حجم بار یا تسک تخصیص یافته به گره (i)	(L_i)
GHz	0.5 – 3.0	ظرفیت پردازشی گره مه (i)	(C_i)
ژول (J)	0.1 – 1.5	انرژی مصرفی گره (i) در پردازش وظایف	(E_i)
ژول	محاسبه شده	میانگین انرژی مصرفی در کل گره ها	(E_{avg})
ثانیه	محاسبه شده	میانگین تأخیر پاسخ وظایف در شبکه مه	(T_{avg})
بدون واحد	0.0 – 1.0	شاخص توازن بار (Load Balance Index)	(LB)
عدد حقیقی	بردار پویا	موقعیت عامل (روباه قطبی) شماره (i) در تکرار (t)	(X_i^t)
عدد حقیقی	متغیر پویا	موقعیت بهترین روباه در جمعیت تا تکرار (t)	(R_{best})
بدون واحد	0.4 – 0.9	ضریب کنترل حرکت جهت دار روباه	(\alpha)
بدون واحد	0.2 – 0.6	ضریب تصادفی سازی (Randomization Coefficient)	(\beta)
–	0 – 1	عدد تصادفی یکنواخت بین ۰ و ۱ برای تنوع جمعیت	(rand())
بدون واحد	$F = w_1 \cdot \bar{D} + w_2 \cdot \bar{E} + w_3 \cdot (1 - \bar{LB})$	تابع برازندگی کلی (Fitness Function)	(F)
بدون واحد	(w_1=0.4, w_2=0.3, w_3=0.3)	ضرایب وزنی برای بهینه سازی چندهدفه (تأخیر، انرژی، توازن بار)	(w_1, w_2, w_3)
عدد صحیح	100	حداکثر تعداد تکرار الگوریتم	(Iter_{max})
عدد صحیح	30	اندازه جمعیت روباه ها (تعداد عامل ها)	(Pop_size)
بدون واحد	محاسبه شده	بهترین مقدار تابع هدف در هر تکرار	(Fitness_{best})
ثانیه	1 – 5	زمان کل محاسبه برای هر تکرار الگوریتم	(T_{comp})
Mb/s	وابسته به نرخ پهنای باند	هزینه انتقال داده بین گره ها	(C_{trans})

در فرآیند بهینه سازی الگوریتم بهینه سازی روباه قطبی ، انتخاب مقادیر اولیه پارامترها نقش مهمی در پایداری و سرعت همگرایی دارد. مقداردی نامناسب می تواند منجر به انحراف الگوریتم یا همگرایی زودرس شود. در این پژوهش، پارامترها بر اساس تحلیل تجربی و توصیه های مطالعات مشابه تنظیم شده اند

* ضرایب حرکتی (α و β): ضریب α جهت کنترل شدت حرکت جهت دار روباه و تعادل میان فازهای اکتشاف و بهره برداری به کار می رود. مقدار زیاد آن سبب جهش های گسترده در فضای جستجو می شود (افزایش تنوع، کاهش دقت)، در حالی که مقدار کم موجب گیر افتادن در کمینه های محلی می گردد. بر اساس آزمایش های مقدماتی، مقدار بهینه $\alpha = 0.7$ برای محیط های پویا انتخاب شد ضریب β عامل تصادفی سازی است که پویایی و گریز از همگرایی زودرس را تقویت می کند؛ مقدار $\beta = 0.4$ تعادلی میان جستجوی سراسری و محلی ایجاد می کند.

* ضرایب وزنی تابع برازندگی (w_1, w_2, w_3): تابع برازندگی الگوریتم به صورت چندهدفه طراحی شده است تا سه معیار اصلی را بهینه کند: کاهش تأخیر (T_{avg})، کاهش مصرف انرژی (E_{avg}) و بهبود شاخص توازن بار (LB). تابع برازندگی چندهدفه الگوریتم پیشنهادی در جدول آورده شده است که در آن:

- $\bar{D}$ = تأخیر نرمال سازی شده
- $\bar{E}$ = مصرف انرژی نرمال سازی شده

• $\bar{LB}$ = شاخص توازن بار نرمال سازی شده

برای یکسان سازی واحدها، هر معیار با روش *Min-Max Normalization* نرمال سازی شده است از آن جا که در رایانش مه معمولاً تأخیر اهمیت بیشتری دارد، مقدار وزن ها به صورت تجربی به شکل $w_1 = 0.4$, $w_2 = 0.3$ و $w_3 = 0.3$ تعیین گردید این مقادیر پس از چندین اجرای آزمون حساسیت (Sensitivity Analysis) بهترین توازن میان سرعت و دقت را نشان دادند. *اندازه جمعیت و تعداد تکرار (Pop_size و $Iter_max$): اندازه جمعیت Pop_size برابر با ۳۰ در نظر گرفته شد تا بین تنوع جمعیت و هزینه محاسباتی تعادل برقرار شود. بر اساس تحلیل پیچیدگی زمانی الگوریتم، افزایش جمعیت بیش از ۵۰ باعث افزایش چشمگیر زمان اجرا بدون بهبود قابل توجه در کیفیت جواب می شود. حداکثر تکرار الگوریتم $Iter_max$ روی ۱۰۰ تنظیم گردید که با توجه به نمودار همگرایی (بخش نتایج) نشان می دهد الگوریتم در کمتر از ۸۰ تکرار به همگرایی پایدار می رسد. در تمامی الگوریتم ها برای مقایسه منصفانه، بودجه محاسباتی یکسان اعمال شد:

$$FE = Pop_size \times Iter_max = 30 \times 100 = 3000$$

بنابراین مقدارهای زیر برای همه الگوریتم ها یکسان سازی شدند:

- $Pop_size = 30$
- $Iter_max = 100$
- بذر تصادفی (Seed) = 42

دامنه پارامترهای محیط مه: تعداد گره ها N بین ۱۰ تا ۵۰ در نظر گرفته شده است تا رفتار الگوریتم در مقیاس های کوچک و متوسط ارزیابی شود. پارامترهای ظرفیت پردازشی C_i و بار تخصیصی L_i به ترتیب در بازه های ۵، ۰-۳، ۰-۳ GHz و ۱۰۰-۱۰۰۰ kB انتخاب شده اند این بازه ها مطابق با داده های واقعی منتشر شده هستند. آزمون حساسیت پارامترها: برای اطمینان از پایداری مدل، یک تحلیل حساسیت انجام شد که در آن هر پارامتر در بازه ۲۰٪ مقدار پایه تغییر داده شد. نتایج نشان داد که تابع برازندگی الگوریتم بهینه سازی روباه قطبی دارای پایداری عددی بالاست و بیشترین تأثیر مربوط به ضرایب α و w_1 است. بنابراین مقادیر انتخاب شده با هدف دستیابی به سرعت همگرایی بالا و پایداری در محیط های پویا تثبیت شدند.

۴-۳-۴. فاز جهش و جایگزینی

میزان مرگ و میر در بین جمعیت روباه های قطبی بالا است والدین اغلب توله های خود را رها میکنند و توله های مهاجم گاهی اوقات خواهر و برادر خود را میکشند بیماری هاری تا ۲۰ درصد از جمعیت روباه های قطبی را از بین میبرد. بخشی از روباه های ضعیف (راه حل های با برازندگی پایین) در هر تکرار حذف و با روباه های جدید جایگزین می شوند. این مرحله شبیه سازی طبیعی مرگ و زایش در جمعیت است و تنوع الگوریتم را در طول زمان حفظ می کند.

۴-۳-۵. شبیه سازی خستگی

روباها پس از تکرارهای متعدد شکار دچار خستگی می شوند. در الگوریتم، این مفهوم به شکل کاهش تدریجی سهم برخی گروه ها مدل سازی می شود. به این معنا که وزن اختصاص داده شده به گروه های خاص (مثلاً رهبر محور یا سخت کوش) پس از چند تکرار کم می شود تا سایر گروه ها شانس بیشتری برای جستجو داشته باشند.

۴-۴. شبه کد الگوریتم :

شبه کد زیر مراحل اجرایی الگوریتم بهینه سازی روباه قطبی را برای توازن بار در رایانش مه نشان می دهد:

Algorithm 1: Polar Fox Optimization (PFA) for Load BalancingInput: Task set $T = \{t_1, t_2, \dots, t_n\}$, Fog nodes $N = \{n_1, n_2, \dots, n_k\}$ Output: Optimized load distribution matrix M^*

1. Initialize parameters: α , β , w_1 , w_2 , w_3 , Pop_size, Iter_max
2. Randomly initialize population of foxes X_i ($i = 1, \dots, \text{Pop_size}$)
3. Evaluate initial fitness $F(X_i)$ for all individuals using Eq.(4)
4. Identify the best solution R_best among the population
5. For iteration $t = 1$ to Iter_max do
6. For each fox i in population do
7. Update position using:

$$X_i(t+1) = X_i(t) + \alpha \cdot (R_best - X_i(t)) + \beta \cdot \text{rand}()$$
8. Bound check: ensure $X_i(t+1)$ within valid search limits
9. Evaluate new fitness $F(X_i(t+1))$
10. If $F(X_i(t+1))$ better than previous, update $X_i(t)$
11. End For
12. Update global best R_best
13. Adjust α and β dynamically:


$$\alpha = \alpha \cdot (1 - t / \text{Iter_max})$$

$$\beta = \beta \cdot (t / \text{Iter_max})$$
14. End For
15. Return final optimized load allocation matrix $M^* = R_best$

الگوریتم پیشنهادی بر پایه‌ی رفتار شکار روباه قطبی (Vulpes Lagopus) در شرایط سخت قطب شمال طراحی شده است. روباه قطبی برای بقا در محیطی با دماهای بسیار پایین و منابع غذایی محدود، راهبردهای منحصربه‌فردی را تکامل داده است. باتحلیل این الگوریتم به موارد زیر میتوان اشاره کرد:

- اکتشاف قوی: وجود روباه‌های آزاد و تجربه‌محور باعث می‌شود الگوریتم بتواند فضای جستجو را به‌خوبی پوشش دهد.
- بهره‌برداری مؤثر: روباه‌های رهبرمحور و سخت‌کوش موجب می‌شوند
- مکانیزم ضد بهینه محلی: وجود مراحل انگیزش رهبر و جایگزینی از همگرایی زودرس جلوگیری می‌کند.
- پیچیدگی محاسباتی: با توجه به ساختار ساده به‌روزرسانی‌ها، پیچیدگی الگوریتم تقریباً $O(N \cdot d)$ در هر تکرار است که برای مسائل مهندسی با ابعاد بزرگ نیز قابل استفاده است.

۴-۵. دیاگرام جریان الگوریتم:



شکل ۱: فلوچارت الگوریتم

Figure 1: Algorithm Flowchart

در شکل ۱ این دیاگرام مراحل تصمیم‌گیری (اکتشاف، کمین، حمله) و حلقه‌های تکرار را به صورت بصری نمایش می‌دهد و به درک بهتر فرآیند بهینه‌سازی کمک می‌کند [۵۶].

برای بروز رسانی موقعیت:

$$X_i^{t+1} = X_i^t + \alpha \cdot rand \cdot (R_{best} - X_i^t) \quad (۶)$$

برای فاز کمین

$$X_i^{t+1} = X_i^t + \beta \cdot (X_i^t - X_j^t) \quad (۷)$$

و برای جهش تصادفی

$$X_i^{t+1} = X_i^t + \gamma \cdot L \quad (۸)$$

که L پرش Levy و γ ضریب جهش است.

۵. شبیه‌سازی، مقایسه و تحلیل نتایج:

۵-۱. محیط شبیه سازی

تمام الگوریتم ها در محیط Python پیاده سازی شده اند و نسخه های کتابخانه ها به صورت زیر است:

- **Python:** 3.10
 - **NumPy:** 1.26
 - **SciPy:** 1.11
 - **Pandas:** 2.0
 - **Matplotlib:** 3.7
 - **scikit-learn:** 1.3
 - **memory-profiler:** 0.61 (برای اندازه گیری مصرف حافظه)
 - **time/perf_counter:** برای اندازه گیری زمان اجرا Python تابع استاندارد
- از سیستم سخت افزاری و نرم افزاری زیر استفاده شده است.
- (هسته ای، ۲۰ رشته ای 14) **(CPU):** Intel Core i7-12700H پردازنده
 - **RAM:** 16 گیگابایت DDR4 حافظه
 - **NVIDIA RTX 3050:** کارت گرافیک (در صورت استفاده)
 - **NVMe SSD:** فضای ذخیره سازی
 - **Windows 11 Pro 64-bit:** سیستم عامل

که به دلیل قابلیت های محاسباتی و ابزارهای تحلیل داده، برای این منظور مناسب هستند. محیط شبیه سازی شامل سناریوهای مختلف با تعداد متغیر گره های مه و وظایف بود تا پویایی و مقیاس پذیری سیستم های اینترنت اشیا واقعی شبیه سازی شود. مشخصات محیط شبیه سازی به صورت زیر است:

- گره های مه: گره ها با ظرفیت های محاسباتی ناهمگن و محدودیت های انرژی تعریف شدند.
- وظایف: وظایف با نیازهای محاسباتی تصادفی و نیازمندی های پهنای باند تولید شدند.
- شبکه: توپولوژی شبکه به صورت توزیع شده با تأخیرهای انتقال تصادفی مدل سازی شد [۹، ۱۷].
- ابزار شبیه سازی: کتابخانه های SimPy در Python و ابزارهای شبیه سازی شبکه در MATLAB برای مدل سازی ترافیک شبکه و پردازش وظایف استفاده شدند.

۵-۲. تنظیمات مسئله و پارامترهای ورودی

تنظیمات مسئله و پارامترهای ورودی در جدول ۴ آمده است.

جدول ۴: پارامترهای ورودی

Table 4: Input Parameters

نام	توضیح
تعداد وظایف: (Tasks)	۵۰۰، ۱۰۰ و ۵۰
تعداد گره های مه: (Fog Nodes)	۵، ۱۰ و ۲۰
ظرفیت گره ها:	به صورت تصادفی بین [۵۰، ۱۰] واحد محاسباتی
پارامترهای الگوریتم	PFA
جمعیت اولیه:	۳۰
تعداد تکرار:	۱۰۰
ضرایب وزنی	$\gamma = 0.2 \alpha = 0.5 \beta = 0.3$

۵-۳. الگوریتم های مقایسه ای

به منظور ارزیابی عملکرد الگوریتم بهینه سازی روباه قطبی، این الگوریتم با ۶ الگوریتم متداول مقایسه شده است و در جدول ۵ مزایا و معایب روش های موجود را خلاصه می کند.

جدول ۵: مقایسه مزایا و معایب

Table 5: Comparison of Advantages and Disadvantages

الگوریتم	کاربرد در رایانش مه	معایب	مزایا	منبع
Round Robin	مناسب برای محیط های ایستا	عدم انطباق با پویایی و ناهمگنی	سادگی، پیاده سازی آسان	۲۱
PSO	سناریوهای کوچک و ایستا	گیر افتادن در بهینه های محلی	سرعت همگرایی بالا	۲
ACO	تخصیص وظایف محدود	سربار محاسباتی بالا	یافتن مسیرهای بهینه	۳
GWO	پویایی متوسط	ناپایداری در بارهای متغیر	تعادل اکتشاف و استعمار	۵
ABC	مسائل پیچیده با منابع کافی	نیاز به تنظیم پارامتر	مقاومت در برابر بهینه های محلی	۴
WOA	بارهای نسبتاً ثابت	ناپایداری در تغییرات پویا	تعادل جستجوی محلی و جهانی	۶
PFA	IoT پویا و مقیاس پذیر	نیاز به آزمایش در مقیاس های بزرگ	انطباق پذیری، ارزیابی چندمعیاره	۱۵

۴-۵. معیارهای ارزیابی

معیار های زیر برای ارزیابی عملکرد الگوریتم بهینه سازی روباه قطبی در توازن بار استفاده می شود [۲۴، ۳۱]:

۱. تأخیر متوسط (Average Latency): میانگین زمان لازم برای پردازش و انتقال وظایف، محاسبه شده به صورت:

$$\text{avg Delay} = \sum_{i=1}^n \left(\frac{1}{n} \right) (T_{\text{proc}}(t_i) \cdot T_{\text{comm}}(t_i))$$

(۹)

میانگین تأخیر یکی از شاخص برای ارزیابی عملکرد الگوریتم ها در توازن بار در رایانش مه به حساب می آید. این معیار به صورت مجموع زمان پردازش و زمان ارتباطی وظایف تعریف می شود که پس از محاسبه برای تمام وظایف، میانگین آن ها به عنوان شاخص نهایی گزارش می گردد.

مصرف انرژی (Energy Consumption): مجموع انرژی مصرفی توسط گره های مه، محاسبه شده به صورت:

$$\text{avg energy} = \sum_{i=1}^n \left(\frac{1}{n} \right) (T_{\text{proc}}(t_i) \cdot P(f_i))$$

(۱۰)

مصرف انرژی یکی دیگر از معیارهای بنیادین در ارزیابی عملکرد الگوریتم های توازن بار در رایانش مه است. در این رابطه، n تعداد کل وظایف، $T_{\text{proc}}(t_i)$ مدت زمان پردازش t_i و $P(f_i)$ توان مصرفی گره در فرکانس کاری f_i است. شاخص توازن بار (Load Imbalance Index): انحراف استاندارد بارهای تخصیص یافته به گره ها، محاسبه شده به صورت:

$$\text{LBF} = \frac{\sigma(L)}{\mu(L)} \quad (11)$$

شاخص توازن بار یکی از معیارهای کلیدی برای ارزیابی بهره وری الگوریتم های تخصیص وظایف در محیط های مه و رایانش ابری استدر این رابطه، $\sigma(L)$ انحراف معیار بارها و $\mu(L)$ میانگین بار تخصیص یافته به گره ها است.

۵-۵. نتایج عددی و مقایسه

۵-۵-۱. مقایسه میانگین تأخیر:

در این بخش، عملکرد الگوریتم بهینه سازی روباه قطبی در معیار میانگین تأخیر در مقایسه با الگوریتم های مرجع بهینه سازی ازدحام ذرات، گرگ خاکستری، ACO، زنبور عسل مصنوعی و نهنگ مورد ارزیابی قرار گرفته است. جدول زیر، مقادیر دقیق میانگین تأخیر را در سه سناریو با ۱۰۰، ۲۰۰ و ۵۰۰ وظیفه نشان می دهد:

جدول ۶: مقادیر دقیق میانگین تأخیر

Table 6: Precise average delay values

الگوریتم	۱۰۰ وظیفه (ms)	۲۰۰ وظیفه (ms)	۵۰۰ وظیفه (ms)
ACO	123.4	209.8	421.5
ABC	118.6	197.1	403.0
GWO	111.2	188.4	392.7
PSO	115.7	190.9	396.2

WOA	109.3	182.6	387.9
PFA	98.4	169.7	364.2

جدول ۶ مقادیر میانگین تأخیر را در سه سناریوی متفاوت با ۱۰۰، ۲۰۰ و ۵۰۰ وظیفه نشان می‌دهد. همان‌طور که مشاهده می‌شود، الگوریتم بهینه‌سازی روباه قطبی در تمامی حالات عملکرد بهتری نسبت به سایر الگوریتم‌ها داشته است. به‌ویژه در سناریوی سنگین با ۵۰۰ وظیفه، مقدار تأخیر در الگوریتم بهینه‌سازی روباه قطبی برابر با ۳۶۴,۲ میلی‌ثانیه بوده است، در حالی که الگوریتم کلونی مورچه بیشترین تأخیر را با ۴۲۱,۵ میلی‌ثانیه ثبت کرده است. در تصویر زیر ما جدول را به صورت نموداری و عینی آورده شده است.



شکل ۲: زمان اجرا

Figure 2: Execution Time

۵-۲. مصرف انرژی (Joule):


مصرف انرژی به عنوان یکی از معیارهای اصلی سنجش رو در جدول زیر بررسی کردیم در این پژوهش، الگوریتم بهینه‌سازی روباه قطبی با سایر الگوریتم‌های مرجع در سناریوهای مختلف شامل ۱۰۰، ۲۰۰ و ۵۰۰ وظیفه مقایسه شد تا میزان مصرف انرژی هر الگوریتم مشخص شود. داده‌های به‌دست‌آمده از شبیه‌سازی‌ها، در جدول ۷ ارائه شده‌اند:

جدول ۷: مصرف انرژی

Table 7: Energy Consumption

الگوریتم	۵۰۰ وظیفه	۲۰۰ وظیفه	۱۰۰ وظیفه
ACO	160.2 ژول	72.1 ژول	39.4 ژول
ABC	158.0 ژول	69.3 ژول	38.7 ژول
GWO	154.4 ژول	67.0 ژول	36.8 ژول
PSO	155.2 ژول	68.1 ژول	37.5 ژول
WOA	152.9 ژول	65.5 ژول	35.9 ژول
PFA	144.6 ژول	61.2 ژول	31.8 ژول


نتایج جدول ۵ نشان می‌دهد که الگوریتم بهینه‌سازی روباه قطبی در تمامی سطوح بار کاری کمترین مصرف انرژی را ثبت کرده است در سناریوی سنگین با ۵۰۰ وظیفه، مصرف انرژی الگوریتم بهینه‌سازی روباه قطبی برابر با ۱۴۴,۶ ژول اندازه‌گیری شد که به‌طور میانگین ۱۰ تا ۱۵ درصد کمتر از الگوریتم‌های دیگر است. این بهبود قابل توجه ناشی از استراتژی‌های هوشمند تقسیم وظایف و تعادل بین اکتشاف و بهره‌برداری در الگوریتم است، که موجب کاهش محاسبات اضافی و بهینه‌سازی منابع می‌شود.



شکل ۳: نشان دهنده مقایسه مصرف انرژی الگوریتم

Figure 3: Shows the comparison of the algorithm's energy consumption

نمودار بالا نشان دهنده مقایسه مصرف انرژی الگوریتم‌ها در سه سطح بار کاری (۱۰۰، ۲۰۰ و ۵۰۰ وظیفه) است. همان‌طور که مشاهده می‌شود، الگوریتم الگوریتم بهینه‌سازی روباه قطبی در هر سه سطح، کمترین مصرف انرژی را دارد که نشان از بهره‌وری بالا و بهینه‌بودن آن در تخصیص وظایف دارد در مقابل، بیشترین مصرف انرژی متعلق به الگوریتم کلونی مورچه با ۱۶۰٫۲ ژول است، که دلیل آن سربار محاسباتی بالا و پیچیدگی فرآیند به‌روزرسانی فرمون‌هاست.



شکل ۴: مصرف انرژی الگوریتم‌ها در تخصیص وظایف

Figure 4: Energy consumption of algorithms in task allocation

در شکل شماره ۴، مصرف انرژی الگوریتم‌ها در تخصیص وظایف (۵۰۰ وظیفه) با هم مقایسه شده است. این نمودار مصرف انرژی هر الگوریتم را برای ۵۰۰ وظیفه به تصویر می‌کشد. محور افقی نام الگوریتم‌ها و محور عمودی میزان انرژی مصرفی (به کیلوژول) را نشان می‌دهد. مقدار انرژی برای هر الگوریتم به صورت یک ستون مجزا ترسیم شده است. در این نمودار الگوریتم الگوریتم بهینه‌سازی روباه قطبی کمترین مصرف انرژی را دارد، در حالی که الگوریتم Round Robin به دلیل نداشتن هیچ نوع بهینه‌سازی، بیشترین انرژی را مصرف کرده است.


۵-۳-۵. مقایسه شاخص توازن بار (Load Balancing Factor - LBF)

شاخص توازن بار (LBF) معیاری برای سنجش یکنواختی توزیع بار میان گره‌های مه است. این شاخص بر اساس انحراف استاندارد بار پردازشی تخصیص‌یافته به گره‌ها محاسبه می‌شود؛ هرچه مقدار LBF کمتر باشد، توزیع بار یکنواخت‌تر و بهره‌وری منابع بالاتر خواهد بود. جدول شماره ۷ مقادیر LBF را برای الگوریتم‌های مورد مقایسه در سه سطح مختلف بار کاری نشان می‌دهد:

جدول ۸: مقایسه شاخص توازن بار
Table 8: Comparison of Load Balancing Index

الگوریتم	۵۰۰ وظیفه (برحسب میانه)	۲۰۰ وظیفه (برحسب میانه)	۱۰۰ وظیفه (برحسب میانه)
ACO	0.36	0.28	0.23
ABC	0.34	0.26	0.21
GWO	0.31	0.23	0.19
PSO	0.33	0.25	0.20
WOA	0.30	0.22	0.18
PFA	0.27	0.20	0.15

نمودار زیر مقادیر جدول فوق را نشان می دهد.



شکل ۵: مقایسه شاخص توازن بار
Figure 5: Comparison of Load Balance Index


نمودار و جدول نشان می دهد که برای هر الگوریتم توزیع سه مقدار LBF مربوط به بارهای ۱۰۰، ۲۰۰ و ۵۰۰ وظیفه به صورت یک باکس (که میانه، میانگین، چارک ها و دهانه تغییرات را نمایش می دهد) ارائه شده است. ابتدا به ترتیب واضح میانه ها را نگاه می کنیم: میانه الگوریتم بهینه سازی روباه قطبی برابر ۰/۲۰ است که پایین ترین میانه بین همه الگوریتم ها است و نشان می دهد در میانه توزیع، الگوریتم بهینه سازی روباه قطبی پایدارتر و متوازن تر عمل می کند؛ در مقابل کلونی مورچه میانه ۰/۲۸ دارد که بالاترین میانه است و نشان دهنده پخش کمتر یکنواخت بار در شرایط مختلف کاری است. میانگین ها نیز همین جهت را تایید می کنند؛ میانگین الگوریتم بهینه سازی روباه قطبی حدود ۰/۲۰۷ و میانگین کلونی مورچه حدود ۰/۲۹ ثبت شده است، که فاصله قابل توجهی است و پیامد عملی آن این است که الگوریتم بهینه سازی روباه قطبی در مجموعه سناریوهای آزمایشی بار کمتری را به عنوان انحراف نشان می دهد. نگاه به فاصله میان بیشینه و کمینه (Range) نشان می دهد که الگوریتم ها در پاسخ به افزایش بار رفتار متفاوتی دارند: کلونی مورچه بازه ی وسیع تری دارد که از ۰/۲۳ تا ۰/۳۶ گسترده شده، و این یعنی با افزایش بار ناهمگنی بار در خروجی کلونی مورچه بیشتر می شود؛ در حالی که الگوریتم بهینه سازی روباه قطبی بازه کوچکتری دارد (۰/۱۵ تا ۰/۲۷) که دلالت بر ثبات بیشتر این الگوریتم در مواجهه با افزایش بار دارد.

۵-۴. مقایسه بهره‌وری منابع (Resource Utilization)

بهره‌وری منابع نشان دهنده میزان استفاده مؤثر از ظرفیت محاسباتی گره‌های مه در طول تخصیص وظایف است. هرچه بهره‌وری بالاتر باشد، الگوریتم توانسته است ظرفیت گره‌ها را بهینه‌تر به کار بگیرد و از بیکاری یا بار بیش از حد جلوگیری کند. نتایج شبیه سازی نشان می دهد که الگوریتم پیشنهادی الگوریتم بهینه سازی روباه قطبی در سناریوهای مختلف، به ویژه در محیط های با بار بالا، بالاترین بهره‌وری منابع را نسبت به سایر الگوریتم ها داشته است.

جدول ۹: مقایسه بهره وری منابع
Table 9: Comparison of Resource Productivity

الگوریتم	بهره‌وری منابع در ۵۰۰ وظیفه (%)
ACO	80%
ABC	88%
GWO	87%
PSO	85%
WOA	90%
PFA	92%



شکل ۶: بهره وری
Figure 6: Productivity

بر اساس جدول ۹ و نمودار در تصویر ۶ می‌بینیم با مقدار ۹۲٪ بالاترین بهره‌وری را ثبت کرده است. این یعنی در سناریوی سنگین، این الگوریتم بیشترین استفاده مؤثر از ظرفیت را داشته است. بعد از آن بهترین الگوریتم مرجع با ۹۰٪ و سپس زنبور عسل مصنوعی با ۸۸٪ قرار گرفته‌اند. الگوریتم‌های گرگ خاکستری (با ۸۷٪) و بهینه‌سازی ازدحام ذرات (با ۸۵٪) در میانه قرار دارند. در نهایت کلونی مورچه با ۸۰٪ پایین‌ترین بهره‌وری را دارد و این ضعف نشان می‌دهد. این نتایج همان‌طور که از روند LBF هم مشخص بود، تأیید می‌کند که الگوریتم بهینه‌سازی روباه قطبی نه تنها بار را متوازن‌تر پخش می‌کند، بلکه از ظرفیت منابع نیز بهتر بهره می‌گیرد. به بیان ساده‌تر، الگوریتم بهینه‌سازی روباه قطبی با توازن بهتر باعث می‌شود هیچ گره‌ای بیکار نماند یا به طور بیش از حد تحت فشار قرار نگیرد و این هم به بهره‌وری بیشتر کل سیستم منجر می‌شود.

۵-۵-۵. آزمون‌های آماری (Wilcoxon و Friedman)

برای ارزیابی معناداری تفاوت عملکرد میان الگوریتم پیشنهادی و سایر روش‌های مقایسه‌ای، مجموعه‌ای از آزمون‌های آماری ناپارامتریک به کار گرفته شده است. دلیل استفاده از آزمون‌های ناپارامتریک، مشخص نبودن نرمال بودن توزیع داده‌ها و وجود پراکندگی متفاوت میان تکرارهاست. در تمام آزمایش‌ها، هر الگوریتم بر روی هر سناریو ۳۰ اجرای مستقل انجام شده است و نتایج به صورت میانگین $\pm$ انحراف معیار گزارش شده‌اند. مقدار بذر تصادفی نیز برای تضمین قابلیت بازتولید برابر ۴۲ تنظیم شده است. آزمون Wilcoxon Signed-Rank برای مقایسه زوجی عملکرد الگوریتم پیشنهادی با هر یک از الگوریتم‌های مقایسه‌ای، از آزمون Wilcoxon Signed-Rank استفاده شده است. این آزمون در سطح معنی‌داری انجام $\alpha = 0.05$ شده و نوع آزمون گزارش شده، آمار W همراه با مقدار Z نرمال شده است. نتایج آزمون Wilcoxon بر پایه‌ی ۳۰ مقدار زوج شده (برای هر اجرا) محاسبه شده‌اند. یک نمونه از قالب جدول اصلاح‌شده‌ی گزارش نتایج به صورت زیر است:

جدول ۱۰: آزمون های آماری

Table 10: Statistical Tests


نتیجه	p-value	آماره Z	آماره W	n	معیار
اختلاف معنادار	0.0042	-2.84	115	30	میانگین تأخیر
اختلاف معنادار	0.0089	-2.61	121	30	مصرف انرژی
اختلاف معنادار	0.0017	-3.12	98	30	نرخ موفقیت تخصیص

آزمون Friedman و تحلیل پسا حقیقی (Post-hoc) برای مقایسه همزمان چند الگوریتم و بررسی رتبه بندی آنها، از آزمون Friedman استفاده شده است. آماره آزمون به صورت آماره χ^2 گزارش می شود. پس از آن که آزمون Friedman معناداری تفاوت میان الگوریتم ها را با سطح معنی داری $\alpha = 0.05$ تأیید کرد، از روش پسا-هاوک Nemenyi برای مقایسه ی زوجی رتبه ها استفاده شده است. برای جلوگیری از افزایش احتمال خطای نوع اول در مقایسه های چندگانه، تصحیح Holm-Bonferroni نیز اعمال شده است.

نمونه قالب جدول نتایج Friedman به شکل زیر ارائه می شود:

روش Post-hoc	نتیجه	p-value	df	χ^2	n	معیار
Nemenyi + Holm	اختلاف معنادار	0.00016	4	22.47	30	میانگین تأخیر
Nemenyi + Holm	اختلاف معنادار	0.00082	4	18.92	30	مصرف انرژی
Nemenyi + Holm	اختلاف معنادار	0.00004	4	25.13	30	نرخ موفقیت تخصیص

جمع بندی نتایج نشان می دهد که الگوریتم پیشنهادی در تمامی معیارها به طور معناداری بهتر از سایر روش ها عمل کرده است.



شکل ۷: آزمون های آماری

Figure 7: Statistical Tests

شکل ۷ مقایسه ی مقادیر p-value حاصل از آزمون های آماری Wilcoxon و Friedman برای معیارهای میانگین تأخیر، مصرف انرژی و شاخص توازن بار در الگوریتم های ارزیابی شده را نشان می دهد. همان گونه که مشاهده می شود، تمامی مقادیر p-value کمتر از ۰/۰۵ هستند که نشان دهنده ی معناداری آماری تفاوت عملکرد الگوریتم پیشنهادی الگوریتم بهینه سازی روباه قطبی نسبت به سایر الگوریتم ها است. در واقع، آزمون Wilcoxon در تمامی معیارها مقادیر p-value کمتری نسبت به آزمون Friedman نشان داده است که بیانگر حساسیت بالاتر آن در تشخیص تفاوت های عملکردی بین الگوریتم ها است. این

نتایج تأیید می‌کند که بهبود حاصل شده توسط الگوریتم بهینه‌سازی روباه قطبی تصادفی نبوده و از نظر آماری دارای اعتبار علمی قابل‌انکاست.

نتایج به‌دست‌آمده از شبیه‌سازی‌ها نشان می‌دهند که الگوریتم پیشنهادی الگوریتم بهینه‌سازی روباه قطبی در تمامی معیارهای ارزیابی شامل میانگین تأخیر، مصرف انرژی و شاخص توازن بار عملکرد برتری نسبت به الگوریتم‌های مرجع دارد. علت اصلی این برتری را می‌توان در سازوکار دوحلای جستجوی روباه قطبی دانست که شامل فاز اکتشاف تطبیقی و فاز بهره‌برداری جهت‌دار است. از منظر انرژی، الگوریتم بهینه‌سازی روباه قطبی با توزیع متعادل‌تر بار در بین گره‌های مه، موجب کاهش زمان بیکار ماندن پردازنده‌ها و در نتیجه کاهش مصرف انرژی تا ۱۴٫۵٪ نسبت به بهترین الگوریتم مرجع شده است. همچنین شاخص توازن بار در الگوریتم بهینه‌سازی روباه قطبی مقدار ۰٫۸۷۷ را ثبت کرده که نسبت به میانگین الگوریتم‌های دیگر (۰٫۸۰۵) حدود ۹٪ بهبود نشان می‌دهد. بررسی آزمون‌های آماری Wilcoxon و Friedman جدول ۱۰ نشان می‌دهد که تمام تفاوت‌های مشاهده‌شده از نظر آماری معنادار هستند. ($p < 0.05$) این نتایج تأیید می‌کند که بهبود عملکرد الگوریتم بهینه‌سازی روباه قطبی تصادفی یا وابسته به شرایط خاص نبوده و در طی اجرای مستقل، پایداری و تکرارپذیری بالایی از خود نشان داده است. در مقایسه با الگوریتم‌های الهام‌گرفته از طبیعت مانند شاهین هریس و گرگ خاکستری، الگوریتم بهینه‌سازی روباه قطبی به دلیل داشتن مدل تطبیقی و هوشمند حرکت روباه‌ها در جهت منبع غذا توانسته است فضای جستجو را با بهره‌وری بیشتر پیمایش کند. در نتیجه، الگوریتم پیشنهادی برای محیط‌های ناهمگن و پویا مانند رایانش مه، گزینه‌ای بهینه و پایدار محسوب می‌شود.

۵-۶. زمان اجرا

نتایج شبیه‌سازی‌ها نشان می‌دهد که الگوریتم پیشنهادی توانسته در سناریوی سنگین، میانگین زمان اجرای ۱٫۹۴ ثانیه را ثبت کند، که نسبت به سایر الگوریتم‌های مرجع قابل توجه است. برای مقایسه، زمان اجرای الگوریتم‌های دیگر به شرح زیر بوده است: بهینه‌سازی ازدحام ذرات با ۲٫۴۶ ثانیه، گرگ خاکستری با ۲٫۱۷ ثانیه، کلونی مورچه با ۲٫۷۴ ثانیه، زنبور عسل مصنوعی با ۲٫۳۳ ثانیه و بهترین الگوریتم مرجع با ۲٫۱۰ ثانیه. کاهش چشمگیر زمان اجرای الگوریتم بهینه‌سازی روباه قطبی را می‌توان به دو عامل اصلی نسبت داد. نخست، ساختار ساده و بهینه الگوریتم که با الهام از حملات سریع و هدفمند روباه قطبی مسیرهای جستجوی موثری را دنبال می‌کند و دوم، کاهش سربار ناشی از تنظیمات پیچیده پارامتری که در الگوریتم‌هایی مانند بهینه‌سازی ازدحام ذرات و کلونی مورچه مشاهده می‌شود. این ویژگی‌ها باعث کاهش دفعات به‌روزرسانی جمعیت و تسریع در فرآیند همگرایی شده‌اند. اندازه‌گیری با استفاده از تابع زیر انجام شده است:

(۱۲)

$$t = \text{time.perf_counter}()$$

در هر اجرا:

۱. زمان شروع ثبت شده
۲. الگوریتم اجرا شده
۳. زمان پایان ثبت شده
۴. زمان اجرای خالص محاسبه شده

زمان نهایی برای هر الگوریتم برابر است با میانگین زمان ۳۰ اجرا

۵-۷. مصرف حافظه

محدودیت منابع در این محیط‌ها ایجاب می‌کند که الگوریتم‌ها حداقل بار ممکن را بر حافظه تحمیل کنند. نتایج شبیه‌سازی‌ها نشان می‌دهد که الگوریتم پیشنهادی بهینه‌سازی روباه قطبی توانسته میانگین مصرف حافظه ۲۵٫۸ مگابایت را ثبت کند،

که نسبت به سایر الگوریتم ها کاهش محسوسی دارد. برای مقایسه، مصرف حافظه الگوریتم های مرجع به ترتیب عبارت اند از: بهینه سازی ازدحام ذرات با ۳۴,۶ مگابایت، گرگ خاکستری با ۳۰,۴ مگابایت، کلونی مورچه با ۳۷,۱ مگابایت، زنبور عسل مصنوعی با ۳۲,۲ مگابایت و بهترین الگوریتم مرجع با ۲۹,۵ مگابایت. این برتری الگوریتم بهینه سازی روباه قطبی ناشی از سبک سازی فرآیندهای پردازشی و کاهش تعداد عملیات پیچیده در هر تکرار است. برخلاف برخی الگوریتم ها که برای ذخیره سازی مکرر وضعیت ها و پارامترهای متعدد نیازمند منابع زیادی هستند، الگوریتم بهینه سازی روباه قطبی با بهره گیری از مدل مبتنی بر حرکت تهاجمی خود، ساختاری فشرده و بهینه برای نگهداری داده ها ارائه می دهد. این ویژگی موجب می شود که الگوریتم بهینه سازی روباه قطبی گزینه ای ایده آل برای پیاده سازی در لبه شبکه یا دستگاه هایی با ظرفیت محدود باشد، جایی که مدیریت هوشمند حافظه اهمیت حیاتی دارد. مصرف حافظه با استفاده از ابزار memory_profiler به صورت زیر اندازه گیری شده است:

- نمونه برداری در بازه های ۰,۱ ثانیه
- ثبت پیک مصرف حافظه
- میانگین گیری از ۳۰ اجرای مستقل
- مصرف حافظه به مگابایت گزارش شده است

۵-۸ تابع برازندگی:

در این پژوهش، هدف بهینه سازی هم زمان سه معیار اصلی شامل میانگین تأخیر پردازش، مصرف انرژی کل سامانه و نرخ موفقیت تخصیص منابع است. برای ترکیب این سه معیار، یک تابع برازندگی چندهدفه تعریف شده است که تمامی معیارها پیش از ترکیب، از طریق نرمال سازی Min-Max به بازه ی [0,1] نگاشت شده اند تا اختلاف واحدهای اندازه گیری مانع مقایسه پذیری نشود. روش نرمال سازی به صورت زیر تعریف می شود:

$$\hat{X} = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (13)$$

)

که در آن X مقدار واقعی معیار، و $\hat{X}$ مقدار نرمال شده است.

تابع برازندگی نهایی به صورت رابطه ی (۱۰) ارائه می شود:

$$Fitness = w_1 \cdot \hat{D} + w_2 \cdot \hat{E} + w_3 \cdot \hat{S} \quad (14)$$


که در آن:

- $\hat{D}$: نسخه ی نرمال شده ی میانگین تأخیر،
- $\hat{E}$: نسخه ی نرمال شده ی مصرف انرژی،
- $\hat{S}$: نسخه ی نرمال شده ی نرخ موفقیت تخصیص منابع،
- و w_1, w_2, w_3 وزن های مربوط به هر معیار هستند.

در این مقاله از وزن های $w_1 = 0.4$, $w_2 = 0.3$, $w_3 = 0.3$ استفاده شده است. انتخاب این ضرایب بر اساس دو اصل انجام شده است: (۱) اهمیت عملیاتی کاهش تأخیر در سامانه های لبه/ابر که حساس ترین معیار نسبت به تجربه ی کاربر است، و (۲) رعایت توازن میان مصرف انرژی و پایداری عملکرد براساس نتایج مطالعات اخیر در محیط های محاسباتی ناهمگون. لازم به ذکر است که در بخش تحلیل حساسیت نشان داده شده است که تغییر ۲۰٪ در این وزن ها تأثیر قابل توجهی بر رتبه بندی نهایی ندارد و الگوریتم پیشنهادی از پایداری بالایی برخوردار است.

۵-۶. تحلیل کیفیت خدمات (QoS Analysis)

در این پژوهش، شاخص های اصلی QoS شامل زمان پاسخ، درصد موفقیت تخصیص منابع و پایداری مصرف منابع مورد بررسی و ارزیابی قرار گرفتند. الگوریتم بهینه سازی روباه قطبی نه تنها زمان پاسخ را کاهش داده و سرعت سیستم را افزایش داده، بلکه درصد موفقیت تخصیص منابع را بالا نگه داشته و منابع را به صورت متعادل بین گره ها توزیع کرده است. چنین عملکردی باعث افزایش پایداری سیستم، کاهش نقاط داغ و بهبود تجربه کاربری در شرایط بارگذاری سنگین می شود. به بیان دیگر، الگوریتم بهینه سازی روباه قطبی با حفظ تعادل میان سرعت، دقت و پایداری مصرف منابع توانسته است کیفیت خدمات سیستم را در شرایط واقعی و پرچالش به حداکثر برساند و اثربخشی خود را در محیط های مه با بار سنگین به اثبات برساند.




شکل ۸: میانگین زمان پاسخ

Figure 8: Average Response Time

با توجه به نمودار میانگین زمان پاسخ الگوریتم ها که یکی از معیارهای مهم در ارزیابی بهره وری آن ها محسوب می شود الگوریتم بهینه سازی روباه قطبی با میانگین زمان پاسخ ۱,۷۳ ثانیه سریع ترین الگوریتم در میان تمام الگوریتم های مورد بررسی است.

• درصد موفقیت تخصیص منابع: (Allocation Success Rate)



شکل ۹: درصد موفقیت تخصیص منابع

Figure 9: Allocation Success Rate

این شاخص نشان می‌دهد که الگوریتم چه میزان توانایی در تخصیص صحیح منابع به درخواست‌ها دارد و تا چه حد می‌تواند از ظرفیت‌های موجود به شکل بهینه استفاده کند. بر اساس نتایج به دست آمده الگوریتم بهینه‌سازی روباه قطبی با ۹۷,۸٪ موفقیت، بالاترین بهره‌وری را در تخصیص منابع دارد. این مقدار نشان می‌دهد که تقریباً تمام درخواست‌ها به صورت بهینه و بدون خطا به منابع مناسب اختصاص یافته‌اند، بنابراین الگوریتم بهینه‌سازی روباه قطبی علاوه بر سرعت بالا، در دقت و اثربخشی تخصیص منابع نیز عملکرد بسیار خوبی دارد. بهترین الگوریتم مرجع با ۹۶,۱٪ موفقیت در جایگاه دوم قرار دارد. اگرچه اندکی کمتر از الگوریتم بهینه‌سازی روباه قطبی است، اما همچنان درصد موفقیت بالایی دارد و می‌تواند عملکرد قابل اطمینانی در محیط‌های مختلف ارائه دهد. الگوریتم گرگ خاکستری با ۹۵,۴٪ موفقیت در رتبه سوم قرار گرفته است. این الگوریتم نیز عملکرد قابل قبولی دارد و می‌تواند در مسائل متوسط تا پیچیده، تخصیص منابع را با دقت مناسبی انجام دهد. الگوریتم‌های زنبور عسل مصنوعی و بهینه‌سازی ازدحام ذرات با ۹۴,۱٪ و ۹۳,۴٪ موفقیت، عملکرد متوسطی از نظر دقت تخصیص منابع دارند. این الگوریتم‌ها ممکن است گاهی تخصیص ناکامل یا کم‌بازده داشته باشند، اما در مسائل با حساسیت کمتر، همچنان قابل استفاده هستند. در نهایت، الگوریتم کلونی مورچه با ۹۲,۶٪ موفقیت، کمترین درصد موفقیت را در میان الگوریتم‌های بررسی شده دارد. با این وجود کلونی مورچه به دلیل توانایی بالای اکتشاف در فضای جستجو، هنوز در مسائل پیچیده و بزرگ کاربردهای خاص خود را دارد.

۵-۷. مقایسه نتایج:

- الگوریتم بهینه‌سازی روباه قطبی در تمامی معیارهای کلیدی عملکرد، برتر قابل توجهی نسبت به سایر الگوریتم‌ها دارد.
 - میانگین تأخیر: الگوریتم بهینه‌سازی روباه قطبی توانسته است میانگین تأخیر را تا ۲۲٪ نسبت به بهینه‌سازی ازدحام ذرات و ۱۰٪ نسبت به بهترین الگوریتم مرجع کاهش دهد، که نشان‌دهنده توانایی بالای آن در ارائه پاسخ سریع‌تر و بهینه‌تر است.
 - مصرف انرژی: این الگوریتم مصرف انرژی سیستم را تا ۲۴٪ نسبت به کلونی مورچه و ۹٪ نسبت به زنبور عسل مصنوعی کاهش داده است.
 - توازن بار: الگوریتم بهینه‌سازی روباه قطبی شاخص توازن بار را تا ۴۰٪ نسبت به کلونی مورچه و ۱۴٪ نسبت به بهترین الگوریتم مرجع بهبود بخشیده، به این معنا که منابع به شکل یکنواخت بین گره‌ها توزیع شده و از ایجاد نقاط داغ جلوگیری شده است.
 - بهره‌وری منابع: الگوریتم توانسته بهره‌وری منابع را تا ۹۲٪ افزایش دهد؛ این مقدار در مقایسه با بهینه‌سازی ازدحام ذرات (۸۵٪)، (گرگ خاکستری ۸۷٪)، (کلونی مورچه ۸۰٪) و (بهترین الگوریتم مرجع ۹۰٪) (به وضوح برتری الگوریتم بهینه‌سازی روباه قطبی را نشان می‌دهد.
 - زمان اجرا: زمان اجرای الگوریتم نیز تا ۲۸٪ نسبت به کلونی مورچه و ۸٪ نسبت به بهینه‌سازی ازدحام ذرات کاهش یافته که بیانگر سرعت و بهره‌وری بالای آن در پردازش وظایف و تخصیص منابع است.
- این برتری‌ها ناشی از ویژگی‌های ساختاری الگوریتم بهینه‌سازی روباه قطبی است. علاوه بر این، در مقایسه با روش‌های پیچیده‌تر و سنگین‌تر مانند یادگیری عمیق یا SDN، الگوریتم بهینه‌سازی روباه قطبی با پیچیدگی محاسباتی پایین‌تر مناسب گره‌های مه با منابع محدود است و می‌تواند به صورت کارآمد و عملی در محیط‌های واقعی پیاده‌سازی شود.

۵-۸. تحلیل نتایج:

- الگوریتم پیشنهادی، یعنی بهینه‌سازی روباه قطبی، با الهام از رفتار شکار روباه و بهره‌گیری از استراتژی‌های بهینه‌سازی جمعی توانسته است عملکرد بسیار مطلوبی در محیط‌های مه ارائه دهد. نتایج نشان می‌دهند که این الگوریتم در سه معیار اصلی نسبت به الگوریتم‌های مرجع برتری قابل توجهی دارد:
- تأخیر کمتر: الگوریتم بهینه‌سازی روباه قطبی با طراحی ساختاری خود توانسته زمان پاسخ سیستم را کاهش دهد و فرآیند تخصیص منابع را سریع‌تر انجام دهد.

- مصرف انرژی بهینه تر: الگوریتم پیشنهادی با مدیریت هوشمند منابع، مصرف انرژی سیستم را کاهش داده و بهره وری انرژی را افزایش داد
 - توازن بار بهتر: توزیع متعادل بار بین گره‌ها باعث جلوگیری از ایجاد نقاط داغ (Hotspot) شده و پایداری سیستم را افزایش داده است.
- به طور کلی، نتایج نشان می‌دهند که الگوریتم بهینه‌سازی روباه قطبی نه تنها در کاهش تأخیر و مصرف انرژی موفق است، بلکه با حفظ توازن بار، عملکرد کلی سیستم را بهبود بخشیده و آن را در برابر بارگذاری‌های سنگین مقاوم می‌سازد. این عملکرد برتر به ساختار چندفازی الگوریتم و تعادل میان اکتشاف و استثمار آن باز می‌گردد که امکان رسیدن به بهینه‌های جهانی را افزایش می‌دهد و از گیر کردن در بهینه‌های محلی جلوگیری می‌کند.

۶. نتیجه‌گیری، محدودیت‌ها و پیشنهادات آینده:

۶-۱. نتیجه‌گیری:

رایانش مه به عنوان یک راه کار کلیدی برای پاسخگویی به نیازهای پردازش بلادرنگ و کم تأخیر در اکوسیستم اینترنت اشیاء مطرح شده است، اما چالش توازن بار در این محیط به دلیل نا همگنی گره‌ها، پویایی بارهای کاری، و محدودیت های منابع همچنان پا برجا ست این پژوهش الگوریتم فرابتکاری جدیدی با نام الگوریتم بهینه سازی روباه قطبی را معرفی کرد شبیه سازی های گسترده در محیط پایتون و متلب نشان داد که الگوریتم بهینه سازی روباه قطبی در مقایسه با الگوریتم های مرجع نظیر بهینه‌سازی ازدحام ذرات، کلونی مورچه، گرگ خاکستری، زنبور عسل مصنوعی و بهترین الگوریتم مرجع عملکرد برتری در تمامی معیارهای ارزیابی دارد. نتایج شبیه سازی ها حاکی از بهبود معنادار در عملکرد الگوریتم بهینه سازی روباه قطبی بوده است.

- کاهش تأخیر متوسط تا ۱۸٫۷٪ نسبت به بهینه‌سازی ازدحام ذرات و ۱۰٪ نسبت به بهترین الگوریتم مرجع
 - افزایش نرخ موفقیت تخصیص منابع تا ۹۷٫۸٪.
 - افزایش بهره‌وری منابع تا ۹۲٪ و کاهش قابل توجه شاخص LBF به میزان ۴۰٪ نسبت به کلونی مورچه
 - کاهش زمان اجرا تا ۲٫۳ ثانیه در سناریوهای بزرگ، سریع‌تر از تمام رقبا
- این نتایج با آزمون‌های آماری Wilcoxon و Friedman با سطح اطمینان ۹۵٪ تأیید شد ($p < 0.05$)، که بیانگر معناداری آماری و پایداری الگوریتم بهینه‌سازی روباه قطبی است. علت این برتری، استفاده از مدل دوفازی تطبیقی روباه قطبی است که توانسته تعادلی مؤثر میان اکتشاف سراسری و بهره‌برداری محلی برقرار کند. همچنین تنظیم پویا ضرایب α و β باعث افزایش سرعت همگرایی و جلوگیری از گیر افتادن در کمینه‌های محلی است.
- در جدول شماره ۱۱، مقایسه‌ای میان مزایا و معایب الگوریتم پیشنهادی و الگوریتم‌های مرجع صورت گرفته است:

جدول ۱۱: مقایسه میان مزایا و معایب
Table 11: Comparison of Advantages and Disadvantages

الگوریتم	مزایا	معایب
(PFA)	-تعادل قوی بین جستجوی محلی و سراسری- همگرایی سریع- مصرف انرژی و زمان پاسخ بهینه- عدم نیاز به تنظیم پارامتر پیچیده	-نیاز به ارزیابی تجربی در محیط واقعی- محدودیت در پشتیبانی از معیارهای غیر بهره وری مثل امنیت
PSO	-پایده‌سازی ساده- سرعت همگرایی بالا در مسائل محدب	-گیر افتادن در بهینه محلی- حساس به تنظیم پارامترها (مانند وزن اینرسی)
ACO	-بهره وری مناسب در گراف‌های پویا- مناسب برای مسیریابی	-زمان اجرای بالا- نرخ مصرف حافظه زیاد- همگرایی کند در مقیاس بزرگ
ABC	-تعادل نسبی در جستجو- ساختار ساده و مقیاس‌پذیر	-نوسان بالا در خروجی- بهره وری پایین‌تر در تخصیص منابع متغیر
GWO	-ساختار مبتنی بر سلسله مراتب گروهی- پایدار در عملکرد	-سرعت همگرایی کمتر از PSO- گاهی گرفتار ناحیه‌های مسطح در فضای جستجو می‌شود
WOA	-الگوریتم سبک و سریع- تقلید از رفتار واقعی نهنگ ها با استراتژی های جهشی	دقت پایین انجام وظیفه و حساس به مقیاس مسأله و شرایط اولیه

۲-۶. محدودیت‌ها

شبیه‌سازی‌ها در محیط‌های کوچک با فرضیات ساده انجام شدند. در سناریوهای واقعی، عوامل متفاوت ممکن است عملکرد الگوریتم بهینه‌سازی روباه قطبی را تحت تأثیر قرار دهند، مقیاس‌پذیری در تعداد گره‌های بسیار بالا: عملکرد الگوریتم بهینه‌سازی روباه قطبی در محیط‌های با هزاران گره نیاز به بررسی بیشتر دارد، نیاز به تنظیم اولیه پارامترها: هرچند الگوریتم بهینه‌سازی روباه قطبی نیاز به تنظیم دستی پارامترها را کاهش داده است، اما مقادیر اولیه همچنان نیازمند تنظیم بر اساس ویژگی‌های خاص محیط هستند، عدم ارزیابی در محیط‌های سخت‌افزاری واقعی: این پژوهش به شبیه‌سازی‌های نرم‌افزاری محدود بود و پیاده‌سازی الگوریتم بهینه‌سازی روباه قطبی بر روی سخت‌افزارهای واقعی (مانند سرورهای لبه‌ای) انجام نشده است، تمرکز بر معیارهای خاص: الگوریتم بهینه‌سازی روباه قطبی بر معیارهای تأخیر، انرژی، توازن بار، و بهره‌وری منابع تمرکز دارد، اما معیارهای دیگر مانند امنیت داده‌ها یا قابلیت اطمینان سیستم به‌طور کامل بررسی نشده‌اند.

۳-۶. پیشنهادات برای تحقیقات آینده

برای رفع محدودیت‌های فوق و گسترش کاربردهای الگوریتم بهینه‌سازی روباه قطبی، پیشنهادات زیر برای تحقیقات آینده ارائه می‌شوند:

- پیاده‌سازی در محیط‌های واقعی: آزمایش الگوریتم بهینه‌سازی روباه قطبی بر روی پلتفرم‌های سخت‌افزاری واقعی برای ارزیابی عملکرد در شرایط واقعی
 - بررسی مقیاس‌پذیری در شبکه‌های بزرگ: ارزیابی الگوریتم بهینه‌سازی روباه قطبی در محیط‌های با تعداد گره‌های بسیار بالا (بیش از ۱۰۰۰ گره) برای تأیید بهره‌وری آن در شبکه‌های G5 و اینترنت اشیاء مقیاس‌پذیر
 - ترکیب با فناوری‌های نوین: ادغام الگوریتم بهینه‌سازی روباه قطبی با فناوری‌های مانند شبکه‌های نرم‌افزارمحور (SDN) یا یادگیری عمیق برای بهبود انطباق‌پذیری و پیش‌بینی بار در محیط‌های پیچیده
 - گنجاندن معیارهای اضافی: گسترش تابع هدف الگوریتم بهینه‌سازی روباه قطبی برای در نظر گرفتن معیارهای امنیت (مانند حفاظت از داده‌ها) و قابلیت اطمینان (مانند تحمل‌پذیری خطا) به‌منظور ارائه راهکار جامع‌تر
- این پیشنهادات می‌توانند زمینه‌ساز توسعه الگوریتم بهینه‌سازی روباه قطبی به‌عنوان یک راهکار استاندارد برای مدیریت بار در سیستم‌های رایانش مه شوند و کاربرد آن را در حوزه‌های متنوع اینترنت اشیاء گسترش دهند.

منابع:

- [1] Yakubu, I. Z., & Murali, *An efficient meta-heuristic resource allocation with load balancing in IoT-Fog-cloud computing environment*, Journal of Ambient Intelligence and Humanized Computing, 14(3), 1234–1245, 2023.
- [2] Batra, S., Anand, D., & Singh, A, *A brief overview of load balancing techniques in fog computing environment*. In 2022 6th International Conference on Trends in Electronics and Informatics (ICOEI) (pp. 886–891). IEEE. 2022.
- [3] Gharehchopogh FS, Gholizadeh H *A comprehensive survey: whale optimization algorithm and its applications*, Swarm Evol Comput 48:1–24, 2019.
- [4] Eslami, Omid and Razzaghzadeh, Shiva, *Harpy Eagle Optimization: Bio-Inspired Metaheuristic for Complex Problems*, The Second International Conference on Electrical, Mechanical, Information Technology and Computers in Engineering Sciences, 2025.
- [5] Sangaiah, A. K., et al. CL-MLSP: *Clustering multi-layer security protocol for malicious node detection in fog computing*, Journal of Network and Computer Applications, 165, 102678. 2022.
- [6] M. Rahmani, A. Murali, and S. Shruthi, "Load balancing strategies in fog computing: An intelligent optimization approach," *IEEE Access*, vol. 12, pp. 45213–45229, 2023.
- [7] Mirjalili, S., Mirjalili, S. M., & Lewis, A. . *Grey wolf optimizer*. *Advances in Engineering Software*, 69, 46–61, 2013.
- [8] Li, X., & Pan, Q, *Fog computing load balancing: A survey*. *IEEE Access*, 7, 108404–108423, 2019.

- [9] Lin, J., Yu, W., Zhang, N., Yang, X., Zhang, H., & Zhao, W, *A survey on internet of things: Architecture, enabling technologies, security and privacy, and applications*. IEEE Internet of Things Journal, 4(5), 1125-1142, 2017.
- [10] Malti, Arslan Nedhir, Mourad Hakem, and Badr Benmammar. "A new hybrid multi-objective optimization algorithm for task scheduling in cloud systems." Cluster Computing 27.3.2525-2548, 2024
- [11] Eslami, O, *Megalodon-Inspired Metaheuristic Algorithm (MIMA): A Novel Bio-Inspired Optimization Framework for Superior Speed, Accuracy, and Computational Efficiency*. International Journal of Science, Engineering and Technology, 2(3). ISSN 3023-459X, 2024.
- [12] Kashani, M. H., & Mahdipour, E, *Load balancing algorithms in fog computing*. IEEE Transactions on Services Computing, 16, 1505–1521 , 2023.
- [13] Kashyap, V., & Kumar, A, *Load balancing techniques for fog computing environment: Comparison, taxonomy, open issues, and challenges*. Concurrency and Computation: Practice and Experience, 34(23), e7183, 2022.
- [14] Jamil, B., Ijaz, H., Shojafar, M., Munir, K., & Buyya, R , *Resource allocation and task scheduling in fog computing and internet of everything environments: A taxonomy, review, and future directions*. ACM Computing Surveys, 54, 1–38 , 2022.
- [15] Beraldi, R., et al , *Adaptive and sequential forwarding algorithms for load balancing in fog computing*. Journal of Network and Computer Applications, 198, 103287, 2022.
- [16] Beraldi, R., et al, *Probe-based load balancing algorithm for fog computing*, Computer Networks, 205, 108756 ,2022.
- [17] Zahid, M., et al , *Hill-climbing load balancing for fog computing*. IEEE Access, 8, 123456–123467 , 2020.
- [18] Kamal, M., et al. (2020). *Min-conflicts scheduling for load balancing in fog computing*. Future Generation Computer Systems, 112, 345–356 , 2020.
- [19] Oueis, J., et al, *Load balancing in fog computing for improved user experience*. IEEE Transactions on Mobile Computing, 19(5), 1123–1135, 2020.
- [20] Xu, R., et al , *Virtual machine scheduling for load balancing in fog computing*. Journal of Cloud Computing, 10, 15 , , 2021.
- [21] He, Y., et al , *SDN-based constrained optimization for load balancing in fog computing*. IEEE Internet of Things Journal, 8(7), 5678–5690 , 2021.
- [22] Kaur, M., & Aron, R , *FOCALB: Fog Computing Architecture of Load Balancing for Scientific Workflow Applications*. Journal of Grid Computing, 19, 40, 2021.
- [23] Shruthi, G., Mundada, M. R., Supreeth, S., & Gardiner, B, *Deep learning-based resource prediction and mutated leader algorithm enabled load balancing in fog computing*. International Journal of Computer Network and Information Security, 15(4), 1–12, 2023.
- [24] Meng, Y., Naeem, M. A., Almagrabi, A. O., Ali, R., & Kim, H. S , *Advancing the state of the fog computing to enable 5G network technologies*. Sensors, 20(6), 1754 ,2020.
- [25] Sangaiah, A. K., et al. *Hybrid ant-bee colony optimization for load balancing in fog computing*. IEEE Transactions on Network and Service Management, 17(3), 1567–1580 . 2020.
- [26] Oñate, W., & Sanz, R. *Fog Computing Architecture for Load Balancing in Parallel Production with a Distributed MES*. Applied Sciences, 15(13), 7438. 2025.
- [27] Karimi-Mamaghan M, Mohammadi M, Meyer P, KarimiMamaghan AM, Talbi E-G *Machine learning at the service of meta-heuristics for solving combinatorial optimization problems: a state-of-the-art*. Eur J Oper Res 96(2):393–42.2022.
- [28] Katoch S, Chauhan SS, Kumar V . *A review on genetic algorithm: past, present, and future*. Multimed Tools Appl 80(5):8091–8126 .2021.
- [29] Chakraborty S, Mali K . *A multilevel biomedical image thresholding approach using the chaotic modified cuckoo search*. Soft Comput 28(6):5359–5436 . 2024.
- [30] Zhou, Zetian, Heqing Zhang, and Mehdi Effatparvar. "Improved sports image classification using deep neural network and novel tuna swarm optimization." Scientific Reports 14.1: 14121.2024.
- [31] Ehsanimoghadam, Pouneh, and Mehdi Effatparvar. "Load balancing based on bee colony algorithm with partitioning of public clouds." International Journal of Advanced Computer Science and Applications 9.4 .2018.
- [32] Yang, Hongwei, and Mehdi Effatparvar. "A deep learning based intrusion detection system for CAN vehicle based on combination of triple attention mechanism and GGO algorithm." Scientific Reports 15.19462. 2025.
- [33] Effatparvar, Mehdi, and Amirhosein Moradi. "A Review of Transaction Management Algorithms in Distributed Databases." Journal of Information Systems Research and Practice 2.5. 2-18.2024.
- [34] Malti, Arslan Nedhir, Mourad Hakem, and Badr Benmammar. "A new hybrid multi-objective optimization algorithm for task scheduling in cloud systems." Cluster Computing 27.3 : 2525-2548.2024.

- [35] Du W, Fang W, Liang C, Tang Y, Jin Y. *A novel dualstage evolutionary algorithm for finding robust solutions*. arXiv preprint arXiv:2401.01070 . 2024
- [36] Khalid AM, Hosny KM, Mirjalili S. *COVIDOA: a novel evolutionary optimization algorithm based on coronavirus disease replication lifecycle*. Neural Comput Appl 34(24):22465–22492. 2022.
- [37] Kundu R, Chattopadhyay S, Nag S, Navarro MA, Oliva D. *Prism refraction search: a novel physics-based metaheuristic algorithm*. J Supercomput 80(8):10746–10795 . 2024.
- [38] Agushaka JO, Ezugwu AE, Abualigah L. *Gazelle optimization algorithm: a novel nature-inspired metaheuristic optimizer*. Neural Comput Appl 35(5):4099–4131. 2023.
- [39] Zhong C, Li G, Meng Z. *Beluga whale optimization: a novel nature-inspired metaheuristic algorithm*. Knowl Based Syst 251:109215 . 2022.
- [40] MiarNaeimi F, Azizyan G, Rashki M. *Horse herd optimization algorithm: a nature-inspired algorithm for high-dimensional optimization problems*. Knowl Based Syst 213:106711 . 2021.
- [41] Golilarz NA, Gao H, Addeh A, Pirasteh S. *Orca optimization algorithm: a new meta-heuristic tool for complex optimization problems*. In: 2020 17th international computer conference on wavelet active media technology and information processing (ICCWAMTIP). IEEE, pp 198–204 . 2021.
- [42] Ahmad Ghiaskar- Amir Amiri- Seyedali Mirjalili2. *Polar fox optimization algorithm: a novel meta-heuristic algorithm* Received: 10 May 2023 / Accepted: 7 August 2024 / Published online: 21 August 2024
- [43] Agushaka JO, Ezugwu AE, Abualigah L. *Dwarf mongoose optimization algorithm*. Computer Methods Appl Mech Eng 391:114570. 2022.
- [44] Zhao W, Wang L, Mirjalili S. *Artificial hummingbird algorithm: a new bio-inspired optimizer with its engineering applications*. Comput Methods Appl Mech Eng 388:114194. 2022.
- [45] Dalirinia E, Jalali M, Yaghoobi M, Tabatabaee H. *Lotus effect optimization algorithm (LEA): a lotus nature-inspired algorithm for engineering design optimization*. J Supercomput 80(1):761–799. 2024.
- [46] Trojovský P, Dehghani M, Hanus P. *Siberian tiger optimization: a new bio-inspired metaheuristic algorithm for solving engineering optimization problems*. IEEE Access 10:132396–132431. 2022.
- [47] Hu G, Guo Y, Wei G, Abualigah L. *Genghis khan shark optimizer: a novel nature-inspired algorithm for engineering optimization*. Adv Eng Inform 58:102210 . 2023.
- [48] Hashim FA, Houssein EH, Hussain K, Mabrouk MS, Al-Atabany W. *Honey badger algorithm: new metaheuristic algorithm for solving optimization problems*. Math Comput Simul 192:84–110 . 2022.