

زمانبندی وظایف در سیستم‌های توزیع شده لایه مه و ابر محاسباتی با استفاده از الگوریتم بهینه‌سازی سوک سرگین

* رضا عزیزی^۱، محسن اقبالی^۲

^۱ استادیار گروه مهندسی کامپیوتر، واحد میبد، دانشگاه آزاد اسلامی، میبد، ایران، azizi.reza@maybodiau.ac.ir

^۲ دانشجوی دکتری مهندسی کامپیوتر، گروه مهندسی کامپیوتر، واحد میبد، دانشگاه آزاد اسلامی، میبد، ایران، m.eghbali@maybodiau.ac.ir

چکیده

در چند سال گذشته اینترنت اشیاء رشد قابل توجهی داشته است و تعداد زیادی شیء هوشمند به آن متصل شده است. رایانش ابری به عنوان یک سیستم پردازش داده‌ها در اینترنت اشیاء است با این حال، سرورها در الگوی محاسبات ابری معمولاً در یک فاصله فیزیکی طولانی از دستگاه‌های اینترنت اشیاء قرار دارند و تأخیر زیاد ناشی از فواصل طولانی نمی‌تواند به طور مؤثر برنامه‌های اینترنت اشیاء بلادرنگ را برآورده کند. به دلیل این مسائل، محاسبات لبه و مه به عنوان فناوری محاسباتی محبوب در زمینه اینترنت اشیاء ظاهر شده است. یکی از چالش‌های مهم اینترنت اشیاء، مستله زمان‌بندی وظایف در لایه مه و ابر است. در روش پیشنهادی برای تخصیص منابع آزاد از شبکه عصبی LSTM استفاده می‌شود و برای زمانبندی بهینه وظایف در لایه ابر و مه از الگوریتم بهینه‌سازی سوک سرگین استفاده می‌شود. آزمایشات نشان می‌دهد که در مجموعه داده HPC2N دقت، حساسیت و صحت روش پیشنهادی برای پیش‌بینی وضعیت منابع به ترتیب برابر ۹۴/۷۲ و ۹۴/۶۴ درصد است. در مجموعه داده NASA دقت، حساسیت و صحت پیش‌بینی روش پیشنهادی در تخصیص منابع درصد، ۹۳/۲۱ و ۹۱/۶۴ درصد است. در مجموعه داده MLP، DCNN، RNN، LSTM دقت به ترتیب برابر ۹۵/۶۸ و ۹۴/۶۱ درصد است. روش پیشنهادی نسبت به روش‌های Makespan، PSO، AVOA، AO_AVOA، FA و HHO مقدار کمتری و بهتری را در زمان‌بندی وظایف نشان می‌دهد.

کلید واژه- اینترنت اشیاء، الگوریتم بهینه‌سازی سوک سرگین، زمانبندی وظایف، لایه ابر، لایه مه

۱- مقدمه

با تکامل فناوری‌های دیجیتال، حجم عظیمی از داده‌ها از منابع متعدد تولید می‌شود. چنین داده‌هایی را می‌توان با استفاده از راه حل‌های رایانش ابری ذخیره و پردازش کرد. با این حال، رایانش ابری نمی‌تواند تحرک و امنیت اینترنت اشیاء را پشتیبانی کند [۱]. اینترنت اشیاء از گره‌های توزیع شده عظیمی تشکیل شده است که در آنها هر گره متشکل از حسگرهای مختلفی است. هر حسگر در داخل یک گره متوجه تفاوت‌هایی می‌شود که در ناحیه محصور در پهنه‌ای باند مجاز خود رخ داده است. متعاقباً پس از خوشه‌بندی و ارزیابی داده‌های جمع‌آوری شده، تصمیمات سنتی و اقدامات ترتیب داده شده اتخاذ می‌شود. اینترنت اشیاء سیستمی است که در کاربردهای مختلف مانند تولید، مراقبت‌های بهداشتی، کشاورزی، مناطق شهری و غیره کشف شده است [۲].

رایانش ابری یک مرحله دسترسی به داده‌ها^۱ برای پشتیبان‌گیری و پردازش داده‌ها است زیرا دارای ذخیره‌سازی و پردازش بالایی است. داده‌های گستردۀ تولید شده توسط دستگاه‌های اینترنت اشیاء برای پردازش (تخلیه کار) به محاسبات ابری ارائه می‌شود. با این حال، انتقال مستقیم داده‌ها به ابر ممکن است باعث هزینه‌های شبکه یا به عبارتی سربار پهنه‌ای باند شود. ابر معمولاً تاخیر پردازش داده‌های آپلود شده را به

دلیل زمان پاسخ طولانی به تاخیر می اندازد^[۳]. در نتیجه، یک جایگزین جدید، یعنی محاسبات مه، برای رسیدگی به توانایی های دستگاه های اینترنت اشیا معرفی شد. بنابراین، محاسبات مه توسط سیسکو در سال ۲۰۱۲ برای حل این چالش ها ارائه شد. محاسبات مه، خدمات ابری را تا لب شبکه گسترش می دهد. با انجام عملیات مربوطه با استفاده از منابع محلی که در نزدیکی دستگاه های لبه اینترنت اشیاء وجود دارد، زمان و حجم انتقال داده را کاهش داد. بنابراین استفاده از منابع محلی باعث کاهش هزینه ها، کاهش تاخیر، افزایش سطح محرومگی و امنیت و کاهش بار ترافیک شبکه می شود. وقتی منابع موثری در محاسبات مه وجود نداشته باشد، از منابع ابری با هزینه های بالاتر استفاده می شود. محاسبات مه و محاسبات لبه اغلب به جای یکدیگر در مطالعات برای اشاره به همان مفهوم توزیع منابع محاسباتی نزدیکتر به کاربران نهایی استفاده می شوند^[۴].

با اینترنت اشیا، اتصال به اینترنت فراتر از دستگاه های هوشمند سنتی مانند گوشی های هوشمند و تبلت ها به طیف متنوعی از دستگاه ها و موارد دیگر (حسگرها، ماشین ها، وسایل نقلیه و غیره) گسترش می یابد. اینترنت اشیاء حجم عظیمی از داده ها را تولید می کند که نیاز به ذخیره، پردازش و تجزیه و تحلیل برای به دست آوردن اطلاعات ارزشمند به منظور برآوردن اهداف و نیازهای کاربر دارند. علاوه بر این، تعداد و مقیاس برنامه ها و خدمات نیز به سرعت در حال افزایش است بنابراین، نیازمند قابلیت پردازشی است تا آنجا که حتی قدرمندترین دستگاه های هوشمند در حال حاضر نمی توانند آن را برآورده کنند^[۵]. محیط ابری که به عنوان یک مرکز منبع بزرگ شناخته می شود و امکان دسترسی همه جانبه به اشتراک گذاری و ارائه منابع به کاربران را به صورت انعطاف پذیر از طریق مکانیزم مجازی سازی فراهم می کند، می تواند یک پلتفرم بالقوه برای پشتیبانی از پیشرفت های اینترنت اشیا باشد. محدودیت های دستگاه های هوشمند موجود (عمر باتری، قدرت پردازش، ظرفیت ذخیره سازی و منابع شبکه) را می توان با انجام کارهای وقت گیر و پرمحصول به یک پلتفرم محاسباتی قدرتمند مانند محاسبات ابری به حداقل رساند و در همان حال وظایف ساده را برای دستگاه های هوشمند واگذار کرد^[۶]. مدل محاسباتی مه- ابر دارای مزایای متعددی از جمله کاهش تأخیر، کاهش ترافیک شبکه و افزایش کارایی انرژی است، با این حال، این مدل جدید با مجموعه ای از چالش ها نیز همراه است^[۷].

یکی از چالش های مطرح در اینترنت اشیا، تخصیص منابع^[۸] و زمان بندی وظایف^[۹] است. یک سیستم بسیار توزیع شده مانند محاسبات مه- ابر یک پلت فرم ایده آل برای استقرار برنامه های کاربردی است؛ آن دسته از برنامه های موازی که وظایف آنها مستقل از یکدیگر است. برنامه های کاربردی در بسیاری از سناریوها ظاهر می شوند، از جمله داده کاوی، جستجو های گسترده (مانند شکستن کلید)، محاسبات فراكتال، زیست شناسی محاسباتی، تصویربرداری کامپیوتوری، رمزگذاری از مزگشایی ویدیو و برنامه های کاربردی مختلف اینترنت اشیاء^[۱۰]. چالش اصلی، زمان بندی وظایف در مجموعه گره های پردازشی از جمله گره های ابری (مانند سوروها یا ماشین های مجازی) و گره های مه است. هدف از زمان بندی وظایف در سیستم مه- ابر به نفع کاربران یا ارائه دهنده های خدمات است. از طرف کاربران، آنها نگران برخی از معیارهای ساخت، بودجه، مهلت، امنیت و هزینه هستند. از سوی دیگر، هدف ارائه دهنده های خدمات، متعادل کردن بار، استفاده از منابع و بهره وری انرژی است. برای تضمین QoS، زمان پاسخگویی نقش مهمی در زمانی که مستقیماً بر تجربه کاربر تأثیر می گذارد، ایفا می کند^[۱۱]. علاوه بر این، هزینه پیاده سازی نیز جنبه ای است که بسیار مورد علاقه و اقبال کاربران بوده است. یک برنامه زمانبندی کار که زمان تکمیل را به حداقل می رساند و در هزینه های پولی صرفه جویی می کند، توافق نامه سطح خدمات امضا شده با کاربران را برآورده می کند^[۱۲]. مدیریت وظایف در عماری های ابر- مه یک موضوع مهم است. استفاده بهینه از منابع ابری برای افزایش پارامترهای کیفی مختلف مانند زمان اجرای کار، هزینه عملیات و مصرف انرژی موضوع مهمی است. زمان بندی کار مناسب در محیط مه، هزینه ها و تاخیرهای پردازش/ ارتباطات را کاهش می دهد. یکی از مشکلات محققان، انتخاب یک روش زمانبندی کارآمد است^[۱۳].

مسئله زمانبندی کار، دشواری چند جمله ای غیر قطعی و بهینه سازی چالش برانگیز است^[۱۴]. امروز، الگوریتم فرالبتکاری کاربردی می تواند برای حل مسئله زمانبندی وظایف، مورد استفاده قرار گیرد. از جمله روش های فرالبتکاری که برای زمانبندی وظایف مورد استفاده قرار گرفته است، می توان به الگوریتم ژنتیک^[۱۵]، الگوریتم بهینه سازی ذرات^[۱۶]، الگوریتم بهینه سازی وال^[۱۷] و الگوریتم بهینه سازی شاهین^[۱۸]

^۱Fog Computing (FC)

^۲Resource allocation

^۳Tasks scheduling

^۴Service Level Agreement (SLA)

^۵Task management

^۶NP-hard

^۷Genetic algorithms(GA)

^۸Particle swarm optimization (PSO) algorithm

اشاره کرد. هدف از این مقاله، ارایه یک رویکرد جدید برای در نظر گرفتن منابع ابر و مه برای زمانبندی کارها و وظایف در اینترنت اشیا است. ارایه یک تابع هدف جدید در زمانبندی برای کاهش تاخیر اجرای وظایف از دیگر اهداف تحقیق بهشمار می‌رود. در روش پیشنهادی برای زمانبندی وظایف از الگوریتم بهینه‌سازی سوک سرگین استفاده می‌شود تا تاخیر اجرای وظایف کاهش داده شود. ارایه یک نسخه گستته از الگوریتم سوک سرگین [۱۷] برای زمانبندی وظایف در لایه مه و ابر، نخستین نوآوری مقاله است. نوآوری دیگر مقاله ارایه یک تابع هدف کارآمد برای زمانبندی وظایف است. به کارگیری منابع در لایه مه و ابر برای زمانبندی بهینه، دیگر نوآوری این مقاله بهشمار می‌رود. پیش‌بینی بار محاسباتی منابع با استفاده از شبکه عصبی LSTM برای اجرای وظایف روی منابع آزاد از نوآوری‌های دیگر مقاله است. سهم نویسنده‌گان در ارایه یک الگوریتم زمانبندی کارآمد در اینترنت اشیا در موارد ذیل خلاصه می‌شود:

- پیش‌بینی منابع آزاد با شبکه عصبی LSTM و زمانبندی وظایف طبق منابع آزاد
- ارایه یک نسخه گستته از الگوریتم بهینه‌سازی سوک سرگین برای زمانبندی
- زمانبندی دو سطحی در لایه مه و ابر
- تلفیق هوش گروهی و یادگیری عمیق در زمانبندی بهینه
- ارایه یک تابع هدف جدید برای زمانبندی وظایف در لایه مه و ابر

این مقاله یک روش زمانبندی دو سطحی در لایه مه و ابر و دارای ۵ بخش است. در بخش II کارهای مرتبط در زمینه زمانبندی کارها ارایه می‌شود. در بخش III، سیستم زمانبندی دو سطحی بر اساس یادگیری عمیق و الگوریتم بهینه‌سازی سوک سرگین توسعه داده شده است. در بخش IV، روش پیشنهادی پیاده‌سازی و با روش‌های مشابه مورد مقایسه قرار می‌گیرد. در بخش V نتایج تحقیق و یافته‌های تحقیق به همراه پیشنهادهای آتی ارایه می‌شود.

۲- کارهای مرتبط

رایانش ابری با استفاده از تکنیک‌های محاسبات موازی و توزیع شده، منابع رایانه مشترک را از طریق اینترنت در دسترس مشتریان قرار می‌دهد. مدل کسب‌وکار «پرداخت به حساب» رایانش ابری را تقریباً دموکراتیک کرده است. ارائه دهنده‌گان خدمات و کاربران نهایی در این مرحله از استقرار نرم افزار شرکت می‌کنند. ارائه دهنده‌گان خدمات ابری قابلیت‌های محاسباتی را از طریق رایانه‌های مجازی به مشتریان خود ارائه می‌دهند. ارائه دهنده‌گان خدمات از این ماشین‌های مجازی برای خدمات مشتری در سطح برنامه استفاده می‌کنند. ارائه دهنده‌گان خدمات، الگوریتم‌های زمان‌بندی کار را برای پخش مشاغل مشتری در سراسر ماشین‌های مجازی، کاهش زمان پاسخگویی، اطمینان از کیفیت بالای خدمات و به حداکثر رساندن منابع پیاده‌سازی می‌کنند. به همین دلیل، الگوریتم زمان‌بندی کار، بخش مهمی از هر عماری ابری است. رایانش ابری نیاز به تنظیماتی برای چندین تکنیک رمانبندی مورد استفاده در محیط‌های مختلف رایانه دارد. ممکن است یک روش زمانبندی بهینه شده برای یک خوشه در فضای ابری ضعیف عمل کند. قبل از اینکه الگوریتم بتواند با ساختار محیط ابری مقابله کند، بخش‌های روش باید به فضای مشکل منتقل شوند. هرچه تنوع ماشین‌های مجازی و اندازه بارهای کاری که مدیریت می‌شوند بیشتر باشد، تعداد پیکربندی‌های کار موجود بیشتر است. یافتن کوتاه‌ترین مسیر در میان همه جایگشت‌های بالقوه یکی از چالش برانگیزترین مشکلات در علم کامپیوتر برای زمانبندی است. عماری اینترنت اشیاء به طور معمول مانند شکل ۱، از سه لایه شامل لایه زیرساخت، لایه محاسبات مه و لایه محاسبات ابری تشکیل شده است [۱۸]:

- لایه زیرساخت: این لایه از دستگاه‌های پایانه با عملکردهای مختلف مانند سنسور(حسگر)‌های مختلف، دستگاه‌های پردازشی و پایانه‌های مختلف هوشمند تشکیل شده است. پایانه‌های هوشمند، وظایف ساده را به صورت محلی انجام می‌دهند اما قادر به انجام کارهای پیچیده در زمان واقعی نیستند.

^۱Whale optimization algorithm(WOA)

^۲Harris hawks optimization(HHO) algorithm

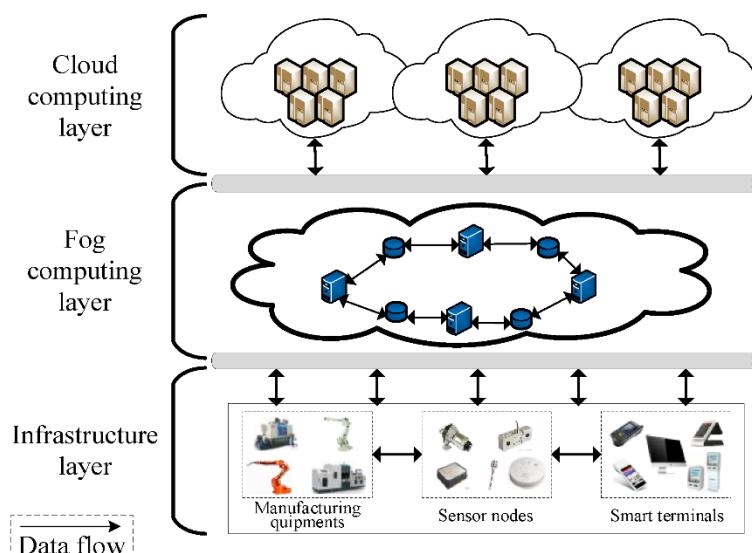
^۳Dung beetle optimizer

لایه محاسبات مه: این لایه عمدتاً از گره‌های مه تشکیل شده است. اینها سرورهایی با قابلیت‌های محاسباتی، ارتباطی و ذخیره‌سازی معین در خطوط تولید هوشمند مانند حسگرهای هوشمند، دستگاه‌های پردازش هوشمند و دستگاه‌های چندرسانه‌ای هوشمند هستند. این لایه می‌تواند درخواست‌های پایانه‌های خط تولید هوشمند را حس کرده و خدمات مختلفی را بلادرنگ ارائه دهد که

می‌تواند تاخیر پردازش وظایف را تا حد زیادی کاهش دهد و کیفیت سرویس اپلیکیشن‌های بلادرنگ را تضمین کند.

لایه محاسبات ابری: لایه رایانش ابری شامل خوشه‌هایی با ظرفیت محاسبات و ذخیره‌سازی عظیم است که خدمات از راه دور را

برای خطوط تولید هوشمند به منظور انجام وظایف محاسباتی پیچیده ارائه می‌دهد.

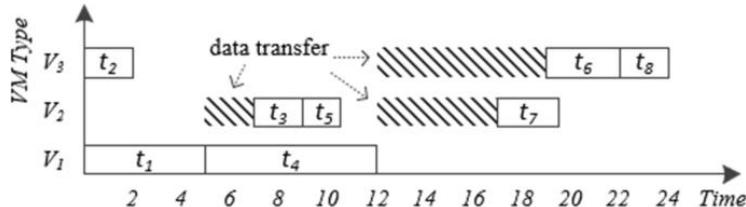


شکل ۱: معماری سه لایه اینترنت اشیاء [۱۸]

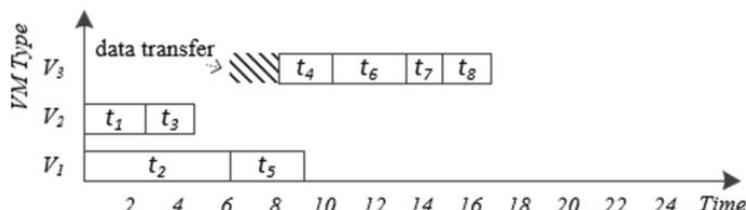
Figure 1. The three-layer architecture of the Internet of Things[18]

تعادل بار یکی از مهم‌ترین مشکلات برای اجرای وظایف زمان‌بندی چند منبعی در یک محیط محاسباتی ناهمگن است. اگر رویکرد متعادل کننده بار در برنامه کمک شود، می‌تواند بر مصرف انرژی تأثیر بگذارد. استفاده از CPU نیز برای هر دو قرارداد سطح سرویس و مصرف انرژی اجباری است که مستقیماً بر زمان‌بندی وظایف متعادل‌سازی بار تأثیر می‌گذارد. استفاده از CPU بر پردازش کار تأثیر می‌گذارد و هر گره CPU خود را برای پردازش وظایف دارد. بنابراین، روش پیشنهادی با هدف افزایش زمان‌بندی کار برای بهبود پردازش کار انجام می‌شود. ایجاد تعادل نگرانی بین منابع و وظایف، پاسخ پردازش وظایف و مدیریت منابع را به طور قابل توجهی بهبود می‌بخشد. متعادل‌سازی بار یک تکنیک ضروری در مدیریت منابع است که با تعبیه عوامل مدیریت وظیفه می‌تواند به یک سیستم قوی تبدیل شود. زمان‌بندی شامل یافتن یک نقشه‌برداری بهینه برای تخصیص n وظیفه به پردازنده‌های متعدد است و علاوه بر این، چندین متغیر حیاتی برای افزایش زمان‌بندی در رایانش ابری وجود دارد[۱۹]. زمان‌بندی را می‌توان یک نگاشت از اجرای وظایف روی منابع آزاد در لایه مه با ابر در نظر گرفت. در شکل ۲، یک فرآیند زمان‌بندی در لایه ابر و روی ماشین‌های مجازی نمایش داده شده است. با توجه به شکل ۲، وظایف t1 تا t8 را می‌توان روی منابع مختلف V1، V2 و V3 اجرا کرد. در حالت اول وظیفه اول و دوم در ماشین مجازی اول و سوم اجرا شده اما در سناریوی دوم وظیفه یک و دوم روی ماشین مجازی اول و دوم اجرا شده است. اجرای ترتیبی کارها و وظایف روی ماشین‌های مجازی باعث می‌شود که زمان‌بندی‌های مختلفی برای اجرای وظایف در لایه مه و ابر در نظر گرفته شود و از این رو یافتن اجرای وظایف بهینه از اهمیت بالایی برخوردار است[۲۰]. برای انجام زمان‌بندی، تاکنون روش‌های مختلفی ارایه شده که یک دسته‌بندی از آن در شکل ۳، قابل مشاهده است. با توجه به شکل مورد نظر برای زمان‌بندی وظایف روش‌های مبتنی بر لیست، اکتشافی، فراابتکاری، یادگیری ماشین و ترکیبی ارایه شده است[۲۱].

Schedule Plan 1

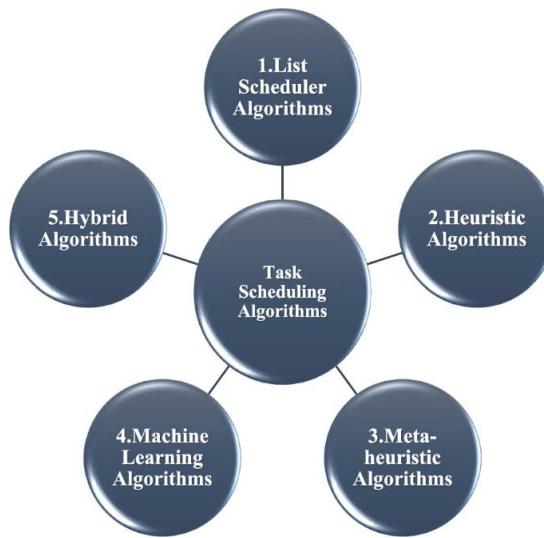


Schedule Plan 2



شکل ۲: اجرای چند وظیفه در منابع اینترنت اشیاء [۲۰]

Figure 2. Multitasking in Internet of Things[20]

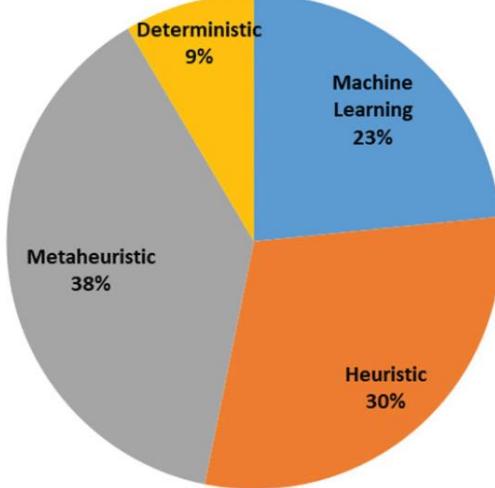


شکل ۳: روش‌های مختلف زمانبندی در اینترنت اشیاء [۲۱]

Figure 3. Different scheduling methods in the Internet of Things[21]

مکانیسم‌های یادگیری ماشین را می‌توان در زمانبندی وظایف مه برای بهبود کارایی و دقت فرآیند زمانبندی استفاده کرد. با تجزیه و تحلیل داده‌های تاریخی و شناسایی‌الگوها، الگوریتم‌های یادگیری ماشین می‌تواند بارهای ترافیکی آینده را پیش‌بینی و بر این اساس تخصیص وظایف را بهینه کنند. این می‌تواند منجر به کاهش تاخیر و بهبود عملکرد سیستم و همچنین استفاده بهتر از منابع شود. علاوه بر این، یادگیری ماشین می‌تواند برای شناسایی ناهنجاری‌ها یا خرابی‌های احتمالی در سیستم و اتخاذ اقدامات پیشگیرانه برای جلوگیری از آنها استفاده شود. به طور کلی، ترکیب مکانیسم‌های یادگیری ماشین در زمانبندی وظایف مه می‌تواند اثربخشی فرآیند را افزایش داده و عملکرد کلی سیستم‌های محاسباتی مه را بهبود بخشد [۲۲]. مکانیسم‌های مبتنی بر اکتشاف برای زمانبندی وظایف مه روش‌هایی هستند که از قوانین سرانگشتی یا بهترین شیوه‌ها برای تخصیص وظایف به دستگاه‌ها در یک محیط محاسباتی مه استفاده می‌کنند. این مکانیسم‌ها بر تکنیک‌های یادگیری ماشین تکیه نمی‌کنند، بلکه بر قوانین تصمیم‌گیری ساده مبتنی بر تجربه یا شهود هستند. مکانیسم‌های مبتنی بر

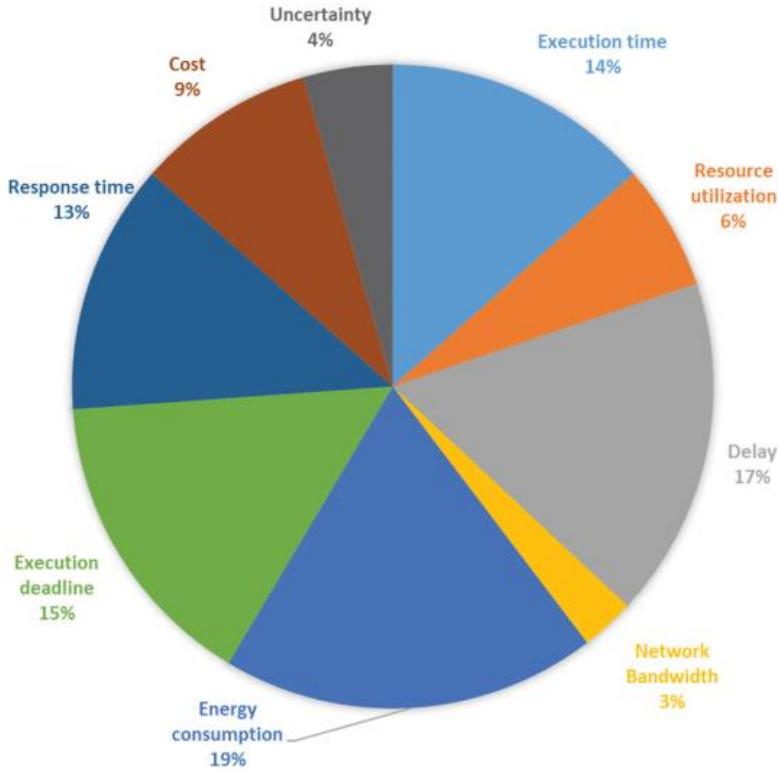
اکتشاف می‌توانند ساده و آسان برای پیاده‌سازی باشند، اما ممکن است همیشه به تخصیص بهینه کار منجر نشوند. آنها همچنین مانند رویکردهای مبتنی بر یادگیری ماشینی، با شرایط در حال تغییر سازگار نیستند یا از تجربیات گذشته درس نمی‌آموزند. بخش زیر چندین روش زمان‌بندی می‌بیندی می‌بینی بر اکتشافی را بررسی می‌کند که از عوامل مختلف برای دستیابی به نتایج زمان‌بندی بهبود یافته استفاده می‌کنند [۲۲]. در الگوریتم‌های فراابتکاری، یک فضای حل تصادفی برای زمان‌بندی کار استفاده می‌شود. با تغییرات اندکی در الگوریتم‌های فراابتکاری، می‌توان از آنها برای حل مسائل مختلف بهینه‌سازی استفاده کرد. الگوریتم‌های فراابتکاری، مستقل از مسئله هستند. به کارگیری محاسبات مه با استفاده از الگوریتم‌های فراابتکاری در بهبود استفاده از منابع و کاهش تأخیر در محیط‌های محاسباتی مه توزیع شده امیدوار کننده است [۲۲]. مکانیسم‌های قطعی همیشه خروجی یکسانی را برای یک ورودی معین تولید می‌کنند. مکانیسم‌های قطعی برای زمان‌بندی و ظایف مه شامل استفاده از مجموعه‌ای از قوانین و الگوریتم‌های از پیش تعریف شده برای تخصیص وظایف به گرههای مه است. جست‌وجوی جامع نمونه‌ای از رویکرد قطعی به مسئله زمان‌بندی کار است. الگوریتم‌های جامع کل فضای جست‌وجو را برای یافتن طرح بهینه بر اساس مدل هزینه داده شده بر می‌شمارند. این مکانیسم‌ها شامل هیچ روش تصادفی یا احتمالی نیستند. مکانیسم‌های قطعی برای زمان‌بندی و ظایف مه ساده و آسان برای پیاده‌سازی هستند. با این حال، ممکن است همیشه منجر به استفاده بهینه از منابع یا کاهش تأخیر نشوند [۲۲].



شکل ۴: سهم روش‌های مختلف زمانبندی در اینترنت اشیا [۲۲]

با توجه به نمودار فوق، الگوریتم‌های زمانبندی فرایابتکاری و ابتکاری در زمانبندی کارها و وظایف دارای سهمی به ترتیب و در حدود ۳۸ درصد و ۳۰,۵ درصد است.

در زمانبندی وظایف شاخص‌های مختلفی به کار گرفته می‌شود که تعدادی از آنها در شکل ۵، نمایش داده شده است. با توجه به شکل مورد نظر می‌توان گفت که مصرف انرژی، مهلت زمانی در اجرای وظایف، تاخیر اجرا و زمان اجرا از مهمترین شاخص‌های ارزیابی در زمانبندی است [۲۲].



شکل ۵: شاخص های اصلی در زمانبندی [۲۲]
Figure 5. Main indicators in timing[22]

برای زمانبندی وظایف در لایه مه یا ابر تاکنون مطالعه انجام شده است که بیشتر آنها بر محور روش های بهینه سازی و فرالبتکاری است که در ادامه تعدادی از کارهای مرتبط در این زمینه مرور می شود. در [۲۳] سال ۲۰۲۳، یک روش زمان بندی وظایف و متعادل سازی منابع محاسبات مه در کارخانه هوشمند ارایه شده است. در این پژوهش یک الگوریتم زمان بندی ژنتیکی تقسیم بازه ای بهبود یافته یا الگوریتم زمان بندی تقسیم فاصله زمانی بر اساس الگوریتم ژنتیک برای برنامه ریزی و تخصیص وظایف در کارخانه هوشمند پیشنهاد شده است. نتایج شبیه سازی نشان می دهد که در مقایسه با الگوریتم زمان بندی پیش فرض IDGSA، Kubernetes می تواند زمان پردازش داده ها را تا ۵۰ درصد کاهش دهد و استفاده از منابع محاسباتی مه را تا ۶۰ درصد بهبود بخشید. در مقایسه با الگوریتم ژنتیک سنتی، با تکرارهای کمتر، روش آنها می تواند زمان پردازش داده ها را تا ۷ درصد کاهش دهد و استفاده از منابع محاسباتی مه را تا ۹ درصد بهبود بخشد و در مقایسه با روش معمولی Joines&Houck، الگوریتم پیشنهادی می تواند بسیار سریع تر همگرا شود و نتایج بهینه سازی بهتری را ارایه کند. علاوه بر این، شبیه سازی نشان می دهد که روش آنها در محاسبات مشترک ابری و مه می تواند کل تاخیر کار را به ترتیب ۱۸ و ۷ درصد در مقایسه با محاسبات فقط ابری و فقط مه کاهش دهد.

در [۲۴] سال ۲۰۲۳، مروری بر تکنیک های زمان بندی وظایف در محاسبات ابری و مه انجام شده است. زمان بندی کارآمد بر روی ابر برای استفاده بهینه از منابع در مراکز داده حیاتی است. با ظهور برنامه های نسل پنجم و اینترنت اشیاء که تعداد زیادی کار با الزامات تأخیر دقیق ایجاد می کنند، چالش برانگیزتر شده است. این امر محاسبات مه / لبه را به وجود می آورد که یک لایه مکمل برای ابر محاسباتی است. تأخیر وظایف در محاسبات مه را می توان کاهش داد زیرا پردازش در شبکه به دستگاه های نهایی و کاربران نزدیک تر انجام می شود، اما به دلیل در دسترس بودن منابع محدود، نمی توان هر کار را در مه برنامه ریزی کرد. الگوریتم های زمان بندی مرسوم اغلب در بهره برداری از منابع ناهمگن شکست می خورند. بنابراین، الگوریتم های زمان بندی به خوبی طراحی شده و به خوبی تنظیم شده برای دستیابی به کیفیت بهتر خدمات مورد نیاز هستند. در این مطالعه، الگوریتم های زمان بندی کار پیشرفتی در محیط های ابر و مه در مجموعه های از ابعاد مختلف مورد بررسی قرار

می‌گیرند. مطالعات نشان داد ۹۷ درصد از مطالعات بر اهداف چندگانه تمرکز می‌کنند و ۶۸ درصد از تکنیک‌ها غیر قطعی هستند. علاوه بر این، در مجموع بیست هدف زمان‌بندی مختلف با زمان ساخت، استفاده از منابع، تاخیر، معادل‌سازی بار و مصرف انرژی به عنوان مهم‌ترین معیارها شناسایی شده‌اند. روش‌های ارزیابی شامل شبیه‌سازی (۵۱ درصد)، آزمایش‌های واقعی (۴۴ درصد)، معادلات تحلیلی (۲ درصد) و مجموعه داده‌ها (۴۳ درصد) وغیره بررسی می‌شوند. در پایان، مسائل باز، چالش‌ها و جهت‌گیری‌های آتی مورد بحث قرار می‌گیرد.

در [۲۵]، سال ۲۰۲۳، یک روش زمان‌بندی کار بهینه در شبکه مه و ابر با استفاده از الگوریتم پروانه-شعله چنددهده ارایه دادند. آزمایشات آنها نشان داد روش پیشنهادی از الگوریتم بهینه‌سازی ازدحام ذرات، الگوریتم کرم شب تاب، الگوریتم‌های ازدحام سالپ، بهینه ساز شاهین هریس و کلونی زنبورهای مصنوعی در زمانبندی تأخیر کمتری ارایه می‌کند. بر اساس آزمایش‌ها، راه حل پیشنهادی زمان تکمیل وظایف اینترنت اشیا و زمان خروجی را کاهش داده است، بنابراین تأخیر ناشی از پردازش وظایف، مصرف انرژی و انتشار CO₂ و افزایش نرخ عملکرد سیستم را کاهش داده است.

در [۲۶]، سال ۲۰۲۳، برای زمان‌بندی کار در معماری لبه-مه-ابر یک رویکرد معادل کننده بار چند هدفه با استفاده از الگوریتم یادگیری تقویتی ارایه دادند. در این پژوهش، یک الگوریتم زمان‌بندی مه یادگیری تقویتی برای رسیدگی زمان‌بندی وظایف پیشنهاد شده است. نتایج تجربی نشان می‌دهد که الگوریتم پیشنهادی تعادل بار را افزایش داده و زمان پاسخ را در مقایسه با الگوریتم‌های زمان‌بندی موجود کاهش می‌دهد. علاوه بر این، الگوریتم پیشنهادی از نظر تعداد دستگاه‌های مورد استفاده از سایر رویکردها بهتر عمل می‌کند.

در [۲۷]، سال ۲۰۲۳، یک الگوریتم جدید الهام گرفته از طبیعت برای زمان‌بندی وظایف بهینه در سیستم مه-ابر ارایه دادند. در سال‌های اخیر، به دلیل رشد تصاعدی داده‌های تولید شده توسط دستگاه‌های هوشمند متصل به هم، استفاده از برنامه‌های کاربردی اینترنت اشیاء مبتنی بر ابر مه به طور پیوسته در حال افزایش بوده است. با این حال، ارائه‌دهندگان ابری که مسئول این برنامه‌های کاربردی اینترنت اشیاء هستند با دو مشکل اساسی نحوه محافظت از سیستم در برابر کاربران غیرقابل اعتماد و نحوه تخصیص واحدهای پردازش برای برآورده کردن خواسته‌ها با هزینه‌های قابل قبول روبرو هستند. در این پژوهش، یک نسخه بهبود یافته از الگوریتم بهینه‌سازی مبتنی بر انتخاب زندگی برای حل زمان‌بندی کار ارایه شده است. زمان‌بندی وظایف یکی از برگسته‌ترین مشکلات در تخصیص منابع است. الگوریتم پیشنهادی آنها نه تنها سرعت همگرایی را افزایش می‌دهد، بلکه تنوع را بهتر حفظ می‌کند و قدرت، تأخیر و هزینه را بهینه می‌کند. آزمایشات نشان می‌دهد الگوریتم بهینه‌سازی مبتنی بر انتخاب زندگی با دستیابی به نتایج بهتر برای تأخیر و مصرف انرژی از روش‌های پیشرفتہ مشابه بهتر عمل می‌کند.

در [۲۸]، سال ۲۰۲۳، یک الگوریتم جستجوی گرانشی چند هدفه برای زمان‌بندی وظایف در سیستم محاسباتی ابری مبتنی بر اینترنت اشیاء ارایه شده است. در این پژوهش، یکتابع چند هدفه جدید برای به حداقل رساندن هزینه ساخت، انرژی و هزینه پولی برای زمان‌بندی کار در سیستم مه-ابر پیشنهاد شده است. در این پژوهش، عملکرد الگوریتم پیشنهادی در دو سناریو مورد ارزیابی قرار گرفته است. ابتدا، عملکرد روش پیشنهادی با برخی از روش‌های بهینه‌سازی چنددهده بهتری دارد. سپس از این الگوریتم برای یافتن راه حل مناسب برای مسئله زمان‌بندی کار الگوریتم پیشنهادی نسبت به سایر روش‌ها عملکرد بهتری دارد. سپس از این الگوریتم برای توابع تست استاندارد مقایسه می‌شود. نتایج نشان می‌دهد که استفاده می‌شود. رویکرد پیشنهادی مصرف انرژی را تا ۲۲ درصد و هزینه پردازش را تا ۴۰ درصد بهبود بخشیده است. تجزیه و تحلیل آماری نشان می‌دهد که در [۲۹]، سال ۲۰۲۳، یک استراتژی زمان‌بندی کار مبتنی بر الگوریتم بهینه‌سازی کرکس‌های آفریقا ای برای محاسبات مه-ابر ارایه دادند. این پژوهش یک استراتژی برنامه‌ریزی وظایف مبتنی بر الگوریتم بهینه‌سازی کرکس‌های آفریقا پیشرفتہ برای محاسبات مه-ابر پیشنهاد می‌کند. کمینه‌سازی زمان ساخت، هزینه و مصرف انرژی در الگوریتم پیشنهادی به عنوان تابع هدف در نظر گرفته می‌شود. برای اولویت بندی وظایف، بهترین و بدترین روش بهمنظور رسیدگی به حساسیت تاخیرهای کار استفاده می‌شود. وظایف حساس به تأخیر، به محیط مه فرستاده می‌شوند، در حالی که وظایف تحمل تأخیر به ابر ارسال می‌شوند. نتایج شبیه‌سازی نشان می‌دهد روش آنها شاخص makepan را تا ۵۳ درصد و مصرف انرژی را تا ۴۴ درصد بهبود می‌دهد.

در [۳۰]، سال ۲۰۲۳، یک روش زمان‌بندی بهینه در شبکه اینترنت اشیاء-مه-ابر با استفاده از ترکیب الگوریتم بهینه‌ساز عقاب طلایی و الگوریتم بهینه‌سازی کرکس‌های آفریقا ارایه دادند. در این پژوهش مشکل زمان‌بندی وظایف در محیط مه-ابر برای اجرای درخواست‌های وظایف اینترنت اشیاء به عنوان یک مشکل بهینه‌سازی با توجه به نیازهای بیشتر QoS در نظر گرفته شده است. ترکیبی از الگوریتم بهینه‌ساز عقاب طلایی و الگوریتم بهینه‌سازی کرکس‌های آفریقا برای حل مشکل زمان‌بندی کار در محیط مه-ابر استفاده شده است. روش پیشنهادی آنها

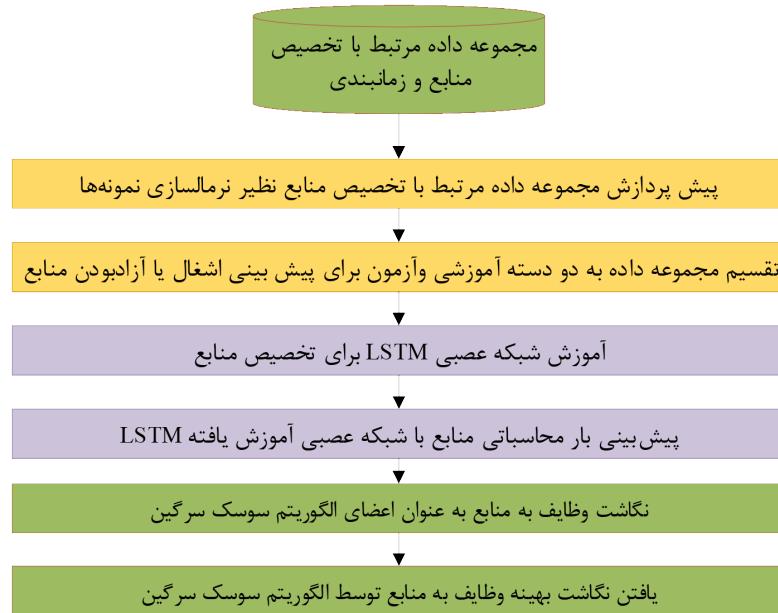
در زمانبندی برای بهبود فرآیند اکتشاف الگوریتم کرکس استفاده شد و مرحله اکتشاف الگوریتم عقاب طلایی با فاز بهره برداری کرکس ترکیب شد. کمینه‌سازی تابع زمان انجام برای ارزیابی الگوریتم بهینه‌سازی برای بهینه‌سازی مسئله زمان‌بندی و یافتن بهترین ماشین‌های مجازی در محیط ابر-مه به کار گرفته شده است. روش پیشنهادی آنها در زمانبندی برای دو مجموعه داده با استفاده از معیارهای زمان ساخت، مقدار تابع تناسب، PIR و زمان توان اعمال شد. آزمایشات نشان داد روش پیشنهادی آنها در زمانبندی در مقایسه با الگوریتم‌های PSO، FA، HHO و AVOA از نظر معیارهای ارزیابی مانند تأخیر بهتر عمل می‌کند.

در [۳۱]، سال ۲۰۲۴، یک روش زمانبندی مبتنی بر یادگیری تقویتی عمیق برای بهینه‌سازی بار سیستم و زمان پاسخگویی در محیط‌های محاسباتی لبه و مه ارایه شده است. از آنجایی که تعداد زیادی از برنامه‌های اینترنت اشیاء نیاز به اجرا در منابع لبه/مه دارد، ممکن است سرورها بیش از حد بارگذاری شوند. از این رو، ممکن است سرورهای لبه/مه را مختل کند و همچنین بر زمان پاسخگویی برنامه‌های اینترنت اشیا تأثیر منفی بگذارد. علاوه بر این، بسیاری از برنامه‌های کاربردی اینترنت اشیاء از اجزای وابسته تشکیل شده‌اند که محدودیت‌های اضافی را برای اجرای خود متتحمل می‌شوند. علاوه بر این، محیط‌های محاسباتی لبه/مه و برنامه‌های اینترنت اشیاء ذاتاً پویا و تصادفی هستند. بنابراین، زمان‌بندی کارآمد و سازگار برنامه‌های اینترنت اشیاء در محیط‌های محاسباتی لبه/مه ناهمگن، از اهمیت بالایی برخوردار است. با این حال، منابع محاسباتی محدود در سرورهای لبه/مه بار اضافی را برای اعمال تکنیک‌های بهینه اما محاسباتی نیازمند تحمیل می‌کند. برای غلبه بر این چالش‌ها، آنها یک الگوریتم برنامه‌ریزی و زمانبندی مبتنی بر یادگیری تقویتی را پیشنهاد دادند تا زمان پاسخ‌دهی برنامه‌های ناهمگن اینترنت اشیا را به طور سازگار و کارآمد بهینه کند و بار سرورهای لبه/مه را متعادل کند. نتایج به دست آمده نشان می‌دهد که روش آنها در مقایسه با الگوریتم‌های فرالبتکاری و سایر تقویت‌کننده‌ها، به ترتیب تا ۵۵، ۳۷ و ۵۰ درصد هزینه اجرای برنامه‌های اینترنت اشیاء را از نظر تعادل بار، زمان پاسخ و هزینه وزنی کاهش می‌دهد.

در [۳۲]، سال ۲۰۲۴، رویکرد مبتنی بر الگوریتم بهینه‌سازی هریس هاکس و سیستم فازی برای بهبود زمان‌بندی وظایف مبتنی بر ابر را ارایه دادند. زمان‌بندی وظایف مستلزم تخصیص وظایف مختلف به ماشین‌های مجازی است. در نتیجه، الگوریتم‌های زمان‌بندی برای دستیابی به مجموعه‌ای از اهداف، از جمله کاهش زمان ساخت، به حداقل رساندن مصرف انرژی، افزایش بهره‌وری منابع، دستیابی به متعادل‌سازی بار و بهینه‌سازی هزینه‌ها، با دقت ساخته می‌شوند. با توجه به اهمیت عمیق این اهداف، الگوریتم‌هایی که برای چنین سناریوهایی طراحی شده‌اند، همواره اهداف متعددی را در بر می‌گیرند. این پژوهش یک الگوریتم زمان‌بندی کار چنددهفه ابتکاری را برای محاسبات ابری معرفی می‌کند که به طور یکپارچه الگوریتم بهینه‌سازی هریس هاکس را ادغام می‌کند و قدرت منطق فازی را در خود جای می‌دهد. این روش، از الگوریتم شاهین برای کشف فضای راه حل گسترده استفاده می‌کند در حالی که راه حل‌های تولید شده را از طریق منطق فازی در معرض ارزیابی دقیق قرار می‌دهد. آزمایشات نشان داد روش آنها در حدود ۷۳ درصد باعث کاهش در مصرف انرژی و ۱۹ درصد کاهش چشمگیر هزینه می‌شود.

۳- روش پیشنهادی

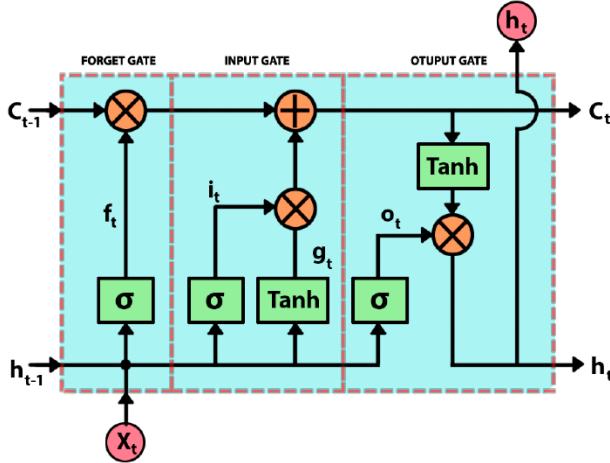
روش پیشنهادی در این بخش برای زمانبندی وظایف، ارایه و معرفی می‌شود. در روش پیشنهادی در فاز اول با استفاده از شبکه عصبی LSTM میزان بار هر منبع پیش‌بینی می‌شود و در ادامه هر منبع که دارای بار محاسباتی کمتری باشد برای به کارگیری زمانبندی تخصیص داده می‌شود. برای تخصیص وظایف به منابع که می‌تواند ماشین‌های فیزیکی و مجازی باشد از الگوریتم بهینه‌سازی سوسک سرگین استفاده می‌شود. روش پیشنهادی برای تخصیص منابع از الگوریتم LSTM و برای زمانبندی از الگوریتم سوسک سرگین استفاده می‌شود. مراحل روش پیشنهادی برای تخصیص منابع و زمانبندی در شکل ۶، نمایش داده شده است.



شکل ۶: چارچوب سیستم پیشنهادی برای تخصیص منابع و زمانبندی وظایف
Figure 6. A proposed system framework for resource allocation and task scheduling

۳-۱- پیش بینی منابع در دسترس با LSTM

یکی از چالش‌های مهم انواع روش‌های زمانبندی بی‌توجهی به تخصیص منابع است. در بیشتر مطالعات مرتبط با زمانبندی، فرض بر آن است که همه منابع در دسترس است اما در عمل، برخی از منابع که می‌توانند ماشین‌های فیزیکی یا مجازی باشند دارای بار محاسباتی زیادی می‌شوند. استفاده از منابعی که مرتبط اشغال می‌شوند باعث می‌شود تا وظایف به کندی روی آنها اجرا شود. یک رویکرد مناسب آن است که وظایف روی منابعی اجرا شود که بار محاسباتی آنها زیاد نشود. به عبارت بهتر یک مکانیزم پیش‌بینی برای اشغال یا آزاد بودن منابع می‌تواند به زمانبندی بهینه کمک نماید. برای پیش‌بینی وضعیت منابع در روش پیشنهادی از شبکه عصبی مصنوعی LSTM استفاده می‌شود زیرا این شبکه، توانایی بالایی برای پیش‌بینی رویدادها دارد. واحدهای LSTM توسعه شبکه‌های تکراری هستند که به آن‌ها اجازه می‌دهند تا اطلاعات را خود را برای مدت طولانی تری مانند حافظه رایانه به خاطر بسپارند. می‌تواند اطلاعات را از سلول خود بخواند، بنویسد و حذف کند، اطلاعات را ذخیره کند و از ناپدید شدن آنها در طول زمان جلوگیری کند. سلول بر اساس درجه اهمیتی که به آن اختصاص داده شده است اطلاعات را ذخیره کند از دریافت می‌کند ذخیره یا حذف کند. این اهمیت از طریق وزن اتصالات تعیین می‌شود، بنابراین LSTM در طول زمان یاد می‌گیرد که تشخیص دهد چه بخشی از اطلاعات مهم است و چه چیزی مهم نیست. اجرای یک حالت داخلی سلول که حافظه بلندمدت ایجاد می‌کند. همانطور که در شکل ۷، نشان داده شده است، یک نورون LSTM از سه گیت: ورودی، فراموشی و خروجی تشکیل شده است که تعیین می‌کند آیا ورودی جدید مجاز است، کدام اطلاعات حذف می‌شود یا اینکه اجازه دارد در زمان فعلی بر خروجی تأثیر بگذارد.[۳۳]



شکل ۷: ساختار یک نورون عصبی در شبکه LSTM

Figure 6. The structure of a neuron in a network

ساختار نورون LSTM (دروازه فراموشی، دروازه ورودی، دروازه خروجی) در شکل فوق نشان داده است. σ مخفف تابع سیگموئید، X_t داده ورودی و h_t خروجی شبکه جاری است. اولین دروازهای که از چپ به راست در شکل فوق ظاهر می شود، دروازه فراموشی است که تصمیم می گیرد چه اطلاعاتی از حالت سلول (C_t) از طریق یک تابع سیگموئید (σ) کنار گذاشته شود و مطابق معادله ۱، فرموله می شود:

$$f_t = \sigma(W_f * [h_{t-1}, x_t] + b_f) \quad (1)$$

که در آن (h_{t-1}) خروجی قبلی واحد، (x_t) ورودی، (W_f) ماتریس وزن دروازه فراموشی و (b_f) بایاس گیت است. خروجی بین مقداری از ۰ تا ۱ خواهد بود که ۰ نشان دهنده حذف کل و ۱ کل اطلاعات را حفظ می کند. پس از این مرحله، دروازه ورودی ادامه می یابد که نشان می دهد چه بخشی از اطلاعات جدید در حالت سلول ذخیره می شود. این دروازه از دو تابع یکی سیگموئیدی و دیگری مماس هذلولی تشکیل شده است که میزان به روز رسانی حالت را تعیین می کند که در معادلات ۲ و ۳ فرموله شده اند.

$$i_t = \sigma(W_i * [h_{t-1}, x_t] + b_i) \quad (2)$$

$$g_t = \tanh(W_g * [h_{t-1}, x_t] + b_g) \quad (3)$$

ماتریس وزن مطابق معادله ۴، با حذف اطلاعات غیر ضروری و به روز رسانی آن با اطلاعات جدید به دست آمده، وضعیت جدید واحد به دست می آید.

$$C_t = \sigma(W_o * [h_{t-1}, x_t] + b_o) \quad (4)$$

در نهایت خروجی واحد را تعیین کنید (h_t)، که نسخه ای از حالت سلولی است که توسط ورودی فعلی و خروجی قبلی فیلتر شده است. جایی که W_o و b_o ماتریس وزن و بایاس برای دروازه خروجی هستند که در معادلات ۵ و ۶ فرموله شده است:

$$\sigma_t = \sigma(W_o * [h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = o_t * \tanh(C_t) \quad (6)$$

در روش پیشنهادی شبکه عصبی LSTM با اجراهای قبلی از سیستم آموزش داده می شود. ورودی شبکه LSTM منابع و خروجی آن پیش‌بینی اشغال یا آزاد بودن منبع است و هدف از به کارگیری LSTM در روش پیشنهادی، اجرای وظایف در منابع آزاد است.

۳-۲- تابع هدف زمانبندی

هنگامی که در خواستهای لایه حسگر به لایه مه در قالب وظایف ارسال می شوند، به وظایف کوچک و مستقل تجزیه می شوند تا در زیرساخت محاسباتی مه و ابر پردازش شوند. هر کار دارای ویژگی هایی نظیر تعداد دستورالعمل ها، حافظه مورد نیاز، اندازه فایل های ورودی و خروجی

است [۳۴]. با فرض اینکه T_k نشان دهنده k امین وظیفه باشد، در هر بار مجموعه‌ای از n وظیفه مستقل به صورت معادله ۷، به سیستم ارسال می‌شود:

$$T = \{T_1, T_2, T_3, \dots, T_n\} \quad (7)$$

زیرساخت محاسباتی مه و ابر، از پردازنده‌ها، یعنی گره‌های ابری و گره‌های مه که ویژگی‌های یکسانی مانند نرخ CPU، هزینه استفاده از CPU، هزینه استفاده از حافظه و هزینه استفاده از پهنای باند را دارند، تشکیل شده است. با این حال، گره‌های ابری معمولاً قادرمندتر از گره‌های مه هستند اما هزینه استفاده از آنها بیشتر است. در روش پیشنهادی فرض می‌شود که m پردازنده در گره‌های لایه مه و ابر قرار دارد و تعداد گره‌های لایه مه و ابر با f و c نمایش داده می‌شود ($N = N_{\text{cloud}}UN_{\text{Fog}}$) و به صورت معادله ۸ بیان می‌شود:

$$N = \{N_1, N_2, N_3, \dots, N_m\} \quad (8)$$

که در آن N_i گره پردازش شماره i را نشان می‌دهد. هر کار T_k به پردازنده N_i اختصاص داده می‌شود که به صورت Tik نمایش داده می‌شود. یک پردازنده را می‌توان برای پردازش مجموعه‌ای از یک یا چند کار اختصاص داد که در معادله ۹، ارایه شده است:

$$N_iTasks = \{T_x^i, T_y^i, \dots, T_z^i\} \quad (9)$$

مسئله زمانبندی کار در محیط محاسباتی مه و ابر را می‌توان به صورت جستجوی مجموعه‌ای معادله ۱۰، فرموله کرد:

$$NodeTasks = \{T_1^a, T_2^b, T_3^c, \dots, T_n^p\} \quad (10)$$

برای مجموعه‌ای از وظایف $NiTasks$ ، زمان اجرا (EXT) آن گره نیاز به تکمیل تمام وظایف محول شده به شرح رابطه ۱۱ محاسبه می‌شود:

$$EXT(N_i) = \sum_{T_k^i \in N_iTasks} Exetime(T_k^i) = \frac{\sum_{T_k^i \in N_iTasks} length(T_k^i)}{CPURate(N_i)} \quad (11)$$

که در آن $EXT(N_i)$ زمان اجرای T_k^i پردازش شده در گره N_i است که به صورت معادله ۱۲، محاسبه می‌شود:

$$Exetime(T_k^i) = \frac{length(T_k^i)}{CPURate(N_i)} \quad (12)$$

با $length(T_k^i)$ طول زمانی اجرای وظیفه T_k^i و $CPURate(N_i)$ نرخ پردازش در پردازنده گره i است. برای تکمیل تمام وظایف، از زمانی Makespan که در خواست دریافت می‌شود تا زمانی که آخرین کار تکمیل یا زمانی که آخرین ماشین تمام می‌شود، تعريف شده است که با نمایش داده شده و با فرمول معادله ۱۳، تعیین می‌شود:

$$Makespan = \max_{1 \leq i \leq m} [EXT(N_i)] \quad (13)$$

فرض کنید $MinMakespan$ حد پایینی Makespan باشد، یعنی سیستم به کوتاه‌ترین زمان نیاز دارد تا تمام آن کار را کامل کند. در حالت ایده‌آل، زمانی که همه گره‌ها همه وظایف محول شده را همزمان به پایان برسانند با $MinMakespan$ نشان داده و با معادله ۱۴، فرموله می‌شود و می‌توان آن را مانند معادله ۱۵، فرموله کرد:

$$MinMakespan = EXT(N_1) = \dots = EXT(N_m) \quad (14)$$

$$MinMakespan = \frac{\sum_{1 \leq k \leq n} length(T_k)}{\sum_{1 \leq i \leq n} CPURate(N_i)} \quad (15)$$

کمترین هزینه‌ای است که برای انجام مجموعه‌ای از وظایف T در سیستم مه و ابر لازم است و زمانی به دست می‌آید که هر وظیفه به ارزان ترین گره اختصاص داده شود. با ارائه اطلاعات هر گره، به راحتی می‌توان تعیین کرد که کدام گره وظیفه T را با کمترین هزینه پردازش می‌کند که با نمایش داده می‌شود، بنابراین، $MinTotalCost$ یک مجموعه از وظایف T خاص است و می‌تواند به صورت معادله ۱۶ تعريف شود:

$$MinTotalCost = \sum_{T_k \in T} MinCost(T_k) = \sum_{T_k \in T} \min_{1 \leq i \leq m} (Cost(T_k^i)) \quad (16)$$

با توجه به مطالب ارایه شده یکتابع هدف مناسب می‌تواند به صورت معادله ۱۷، در نظر گرفته شود:

$$\min(F) = \alpha * \frac{MinMakespan}{Makespan} + (1 - \alpha) * \frac{MinTotalCost}{TotalCost} \quad (17)$$

اگر $\alpha = 0.5$ باشد؛ یعنی زمان و هزینه در بهینه‌سازی T اولویت یکسانی دارند. زمانی که $\alpha = 0.5$ بیشتر باشد نشان دهنده آن است که حداقل رساندن زمان ساخت با اولویت بالاتر از هزینه کل تمرکز می‌کند، این مورد، زمانی است که کاربر مایل است پول بیشتری برای

دستیابی به عملکرد بهتر بپردازد. بر عکس، زمانی که Alpha از $5/0$ کمتر است، هزینه بیشتر از زمان، اولویت بندی می‌شود یعنی کاربر بودجه محدودی دارد. هدف، بهینه سازی زمان اجرا و هزینه پردازش است، یعنی یافتن راه حل به گونه‌ای که TotalCost حداقل و نزدیک به MinTotalCost باشد.

۳-۳- زمانبندی با الگوریتم سوسک سرگین

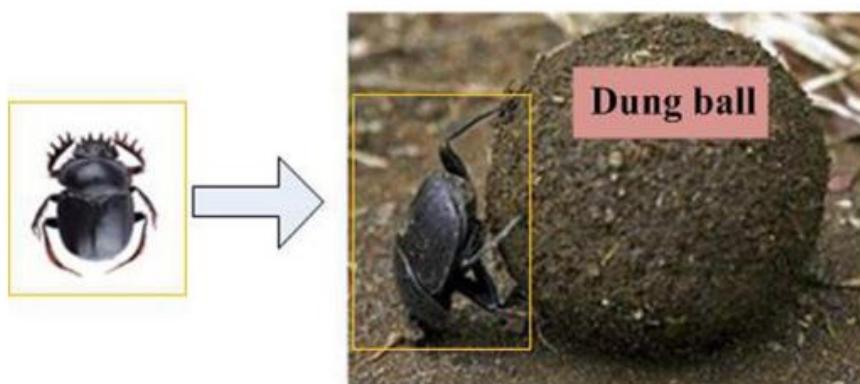
در روش پیشنهادی برای بهینه‌سازی نگاشت وظایف به منابع آزاد در لایه مه و ابر از الگوریتم بهینه‌سازی سوسک سرگین استفاده می‌شود. در روش پیشنهادی هر نگاشت از مجموعه‌ای از وظایف روی تعدادی منبع به عنوان یک راه حل در الگوریتم بهینه‌سازی سوسک سرگین در نظر گرفته می‌شود. در شکل ۷، نگاشت مجموعه‌ای از وظایف به منابع در لایه مه و ابر نمایش داده است که این ماتریس را می‌توان یک سوسک سرگین در نظر گرفت. در اینجا فرض می‌شود که ۱۰ وظیفه وجود دارد که روی سه منبع آزاد زمانبندی می‌شوند. صفر نشان دهنده آن است که وظیفه در منبع اجراء نمی‌شود و یک نشان دهنده اجرای وظیفه در منبع است [۳۴].

	T_1	T_2	T_3	T_4	T_5	T_6	T_7	T_8	T_9	T_{10}
N_1	0	1	0	0	1	0	0	0	1	0
N_2	0	0	0	1	0	1	1	0	0	0
N_3	1	0	1	0	0	0	0	1	0	1

شکل ۷: ساختار یک راه حل در روش پیشنهادی برای زمانبندی وظایف

Figure 7. Structure of a solution in the proposed method for task scheduling

الگوریتم بهینه‌سازی سوسک سرگین از رفتار سوسک‌های سرگین مدلسازی و فرموله شده است. گونه‌های مختلفی برای سوسک‌های سرگین وجود دارد، مانند Harold Caccobius jessoensis، Onthophagus gibbulus، Copris ochus Motschulsky وغیره. معروف است که سوسک سرگین به عنوان یک حشره معمولی در طبیعت از سرگین حیوانات تغذیه می‌کند. سوسک‌های سرگین در اکثر نقاط جهان یافت می‌شوند و به عنوان تجزیه کننده در طبیعت عمل می‌کنند، به این معنا که آنها در اکوسیستم، اهمیت حیاتی دارند. تحقیقات نشان داده است که سوسک‌های سرگین عادت جالبی دارند؛ سرگین را به شکل توب در می‌آورند سپس آن را حرکت در می‌آورند، همانطور که در شکل ۸، نشان داده شده است. شایان ذکر است هدف سوسک‌های سرگین این است که گوی سرگین خود را به سرعت و کارآمدتر حرکت دهند که این کار می‌تواند از تکمیل شدن آنها توسط سایر سوسک‌های سرگین جلوگیری کند [۱۷].

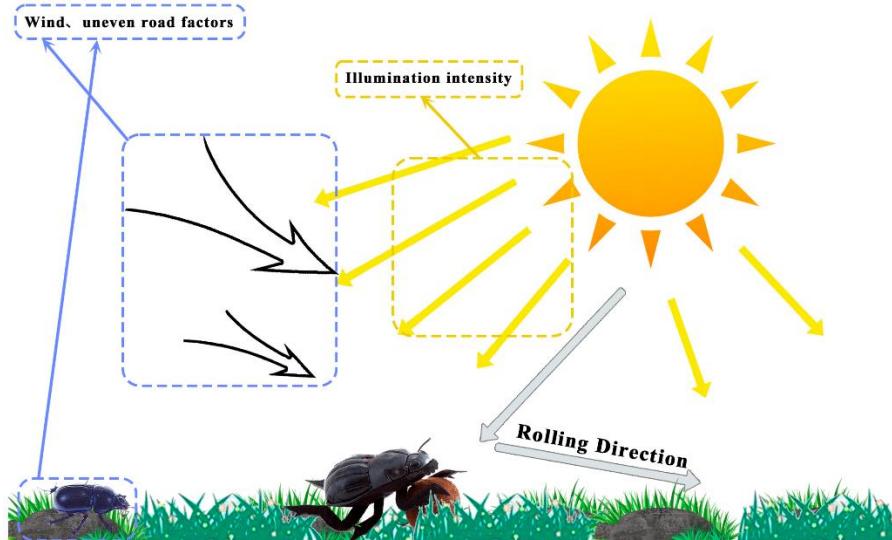


شکل ۸: حرکت دادن سرگین توسط سوسک سرگین

Figure 8. Dung moving by dung beetles

الگوریتم بهینه‌سازی سوسک سرگین یک الگوریتم جدید بهینه‌سازی هوش ازدحامی است که از رفتار اجتماعی جمعیت سوسک‌های سرگین الهام گرفته شده است. این سوسک‌ها سرگین را قبل از اینکه به مکانی امن بغلتانند، به صورت توب، فشرده می‌کنند. آن‌ها می‌توانند توب‌های سرگین بسیار بزرگ‌تری را بغلتانند و از نشانه‌های آسمانی برای چرخاندن آن‌ها در یک خط مستقیم در صورت وجود منبع نور استفاده کنند. با این حال، در غیاب منبع نور، مسیرهای آنها منحنی و مستعد اختلالات طبیعی می‌شود. بقای سوسک‌های سرگین به طور پیچیده‌ای با به دست

آوردن گلوله های سرگین مرتبط است، جایی که برخی برای تولید مثل و پرورش فرزندان شان استفاده می شوند در حالی که بقیه به عنوان غذا مورد استفاده قرار می گیرند. الگوریتم بهینه سازی سوسک سرگین پنج رفتار کلیدی را که توسط سوسک های سرگین به کار گرفته می شود، شبیه سازی می کند و این رفتارها توب غلتاندن، رقصیدن، جستجوی غذا، دزدی و تولید مثل است. جمعیت سوسک های سرگین به چهار زیر گروه تقسیم می شوند که عبارتند از: غلتکها، باز تولید کنندگان، خردسالان و دزدها و هر نوع سوسک استراتژی های جستجوی متفاوتی برای خود در نظر می گیرند [۱۷]. در طول فرآیند غلتیدن، سوسک های سرگین باید با استفاده از نشانه های آسمانی، بهویژه خورشید و ماه حرکت کنند تا مسیر حرکت مستقیم توب سرگین را حفظ کنند. در شکل ۹، مدل مسیر سوسک سرگین نمایش داده شده است. می توان مشاهده کرد که سوسک های سرگین از خورشید برای جهت یابی استفاده می کنند، با فلش نشان دهنده، جهت چرخش آنها مشخص شده است. [۳۵].



شکل ۹: حرکت دادن سرگین توسط سوسک سرگین

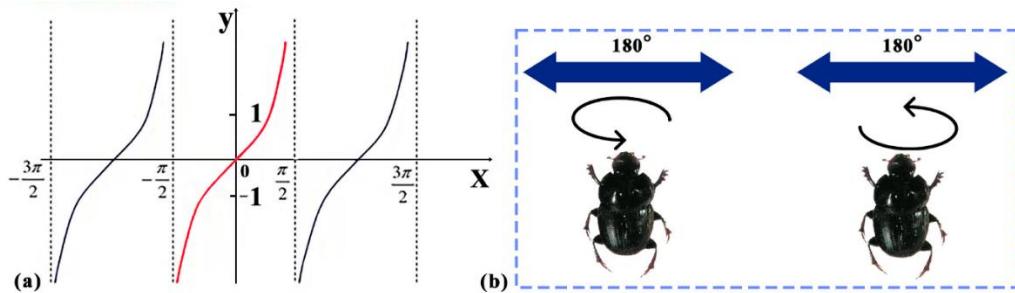
Figure 9. Dung moving by dung beetles

با فرض اینکه شدت منبع نور نیز بر مسیر غلتشی سوسک های سرگین تأثیر می گذارد، موقعیت سوسک به روز می شود و می توان آن را به صورت معادله ۱۸، نشان داد:

$$X_i(t+1) = X_i(t) + \alpha \times k \times X_i(t+1) + b \times \Delta x \quad (18)$$

$$\Delta x = |X_i(t) - X^w| \quad (19)$$

در این معادلات t نشان دهنده تعداد تکرار فعلی است. $X_i(t)$ نشان دهنده اطلاعات موقعیت سوسک i ام در تکرار t است. پارامتر k یک عدد ثابت بین 0 و 0.5 است که ضریب انحراف را نشان می دهد. b یک مقدار ثابت متعلق به بازه صفر و یک است. α یک ضریب طبیعی است که به صورت ۱ یا -1 - اختصاص داده می شود. X^w نشان دهنده بدترین موقعیت است و Δx تغییر شدت نور را شبیه سازی می کند. پارامتر a عوامل طبیعی (مانند باد و زمین ناهموار) را شبیه سازی می کند که می تواند باعث انحراف سوسک سرگین از جهت اصلی خود شود. به طور خاص، $a = 1$ نشان دهنده عدم انحراف است، در حالی که $-1 = a$ نشان دهنده انحراف از جهت اصلی است. Δx بزرگتر به معنی منبع نور ضعیفتر است که دو مزیت را به همراه دارد که عبارتند از: کاوش کامل کل فضای مشکل در طول فرآیند بهینه سازی و افزایش قابلیت های جستجو و کاهش احتمال به دام افتادن در بهینه محلی. عوامل طبیعی مختلف، مانند باد و زمین ناهموار، می توانند تأثیری قابل توجه بر مسیر حرکت سوسک های سرگین داشته باشند. در چنین شرایطی، سوسک های سرگین معمولاً به روی گوی سرگین می روند و رفتار رقصانی را انجام می دهند که شامل یک سری چرخش و مکث است. آنها از طریق این رفتار رقصی، جهت حرکت خود را با تغییر جهت تعیین می کنند و در نتیجه مسیر جدیدی را به دست می آورند. برای تقلید از این رفتار رقصیدن، یکتابع مماس برای به دست آوردن جهت چرخش جدید استفاده می شود. شکل ۱۰، مدل تابع مماس و مدل رقص سوسک های سرگین را نشان می دهد. توجه به این نکته مهم است که فقط مقادیر تعریف شده در بازه 0 و 1 تابع مماس باید در نظر گرفته شوند [۳۵]:



شکل ۱۰: تابع مماس و مدل رقص سوسک های سرگین. (الف) تابع مماس در جهت نور. (ب) مدل رقص سوسک های سرگین.

Figure 10. Tangent function and dance model of dung beetles

هنگامی که جهت صحیح با موفقیت مشخص شد، سوسک غلتکی باید به چرخاندن توب به جلو ادامه دهد. در این مرحله، به روزرسانی موقعیت سوسک غلتکی به شرح معادله ۲۰، است:

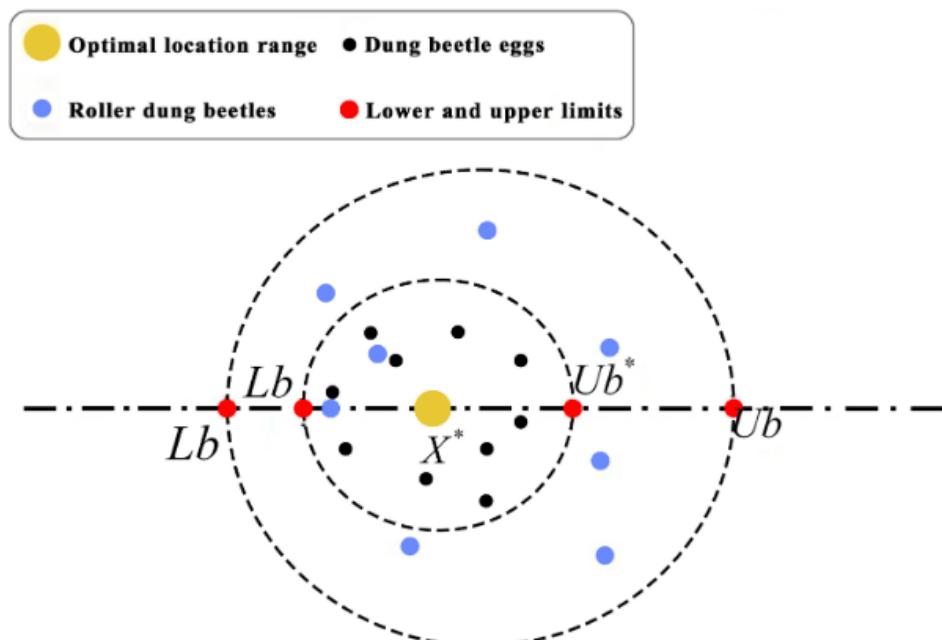
$$X_i(t+1) = X_i(t) + \tan \beta |X_i(t) - X_i(t-1)| \quad (20)$$

که در آن زاویه انحراف $\beta \in [0, \pi]$ است و در معادله، t تعداد تکرارهای جاری را نشان می‌دهد. $X_i(t)$ اطلاعات موقعیت سوسک غلتکی i در تکرار t را نشان می‌دهد. $|X_i(t) - X_i(t-1)|$ تفاوت مطلق بین موقعیت i ام سوسک در تکرار t و موقعیت آن در تکرار قبلی $(t-1)$ است. می‌توان مشاهده کرد که به روز رسانی موقعیت سوسک غلتکی ارتباط نزدیکی با اطلاعات موقعیت فعلی و سابق آن دارد. توجه به این نکته ضروری است که اگر زاویه انحراف برابر با $0, \pi/2$ یا π باشد، موقعیت سوسک به روز نمی‌شود. برای ایجاد یک محیط امن برای فرزندان خود، انتخاب محل تخمگذاری مناسب برای سوسک‌های سرگین بسیار مهم است. با الهام از بحث فوق الذکر، یک استراتژی انتخاب مرز برای شبیه‌سازی منطقه‌ای که سوسک‌های ماده سرگین تخم می‌گذارند پیشنهاد شده است و به صورت زیر معادله ۲۱ و ۲۲ فرموله می‌شود:

$$\min(X^* * (1-R), Uh) \quad (21)$$

$$\min(X^* * (1-R), Lh) \quad (22)$$

که در آن X^* نشان دهنده بهترین موقعیت محلی فعلی است. Lh^* و Uh^* به ترتیب مرزهای بالایی و پایینی ناحیه تخمگذاری را نشان می‌دهند. $R = 1 - t/T_{max}$ ، که در آن T_{max} حداکثر تعداد تکرار را نشان می‌دهد. Lh و Uh به ترتیب کران‌های بالایی و پایینی فضای جستجو هستند، همانطور که در شکل ۱۱، نشان داده شده است [۳۵].



شکل ۱۱: مدل مفهومی استراتژی انتخاب مرز
Figure 11. Conceptual model of boundary selection strategy

شایان ذکر است که هر گلوله سرگین حاوی یک تخم یک سوسک سرگین است. علاوه بر این، نقاط قرمز مرزهای بالایی و پایینی را نشان می‌دهد. در الگوریتم سوسک سرگین فرض بر این است که هر سوسک سرگین ماده در هر تکرار فقط یک تخم می‌گذارد. با توجه به تغییرات دینامیکی در محدوده مرزی در طول تکرار، این به جلوگیری از به دام افتادن الگوریتم در بهینه محلی کمک می‌کند که عمدتاً توسط مقدار وزن اینرسی R تعیین می‌شود. بنابراین، موقعیت توبهای تخم مرغ نیز در طول فرآیند تکرار پویا است و با معادله ۲۳ می‌شود:

$$Y_i(t+1) = X^* + b_1(Y_i(t) - Lh^*) + b_2(Y_i(t) - Uh^*) \quad (23)$$

که در آن $Y_i(t)$ اطلاعات موقعیت i -امین توب تخم مرغ را در تکرار t -امین نشان می‌دهد، X^* نشان دهنده بهترین موقعیت محلی است و از طرفی Lh^* و Uh^* نشان دهنده مرزهای بالایی و پایینی ناحیه تخم‌گذاری است. از طرفی $((Y_i(t) - Lh^*) - (Y_i(t) - Uh^*))$ یک بردار تصادفی در محدوده 0 و 1 است و D بعد مسئله بهینه سازی را نشان می‌دهد. برخی از سوسک‌های سرگین بالغ در جستجوی غذا در زمین فرو می‌روند و این نوع سوسک‌ها به عنوان سوسک‌های سرگین کوچک شناخته می‌شوند. برای شبیه‌سازی فرآیند جستجوی علوفه سوسک‌های سرگین کوچک، تعیین منطقه بهینه علوفه ضروری است. معادله شبیه‌سازی برای این ناحیه به صورت زیر معادله ۲۴ و ۲۵ مشخص می‌شود:

$$Lm = \max(X^* * (1 - R), Lh) \quad (24)$$

$$Um = \min(X^* * (1 - R), Uh) \quad (25)$$

به گونه‌ای که Xh نشان دهنده بهترین موقعیت سراسری است. Lm و Um به ترتیب مرزهای پایین و بالایی منطقه جستجوی بهینه هستند. Uh و Lh مرزهای پایین و بالایی فضای جستجو هستند. بنابراین، به روز رسانی موقعیت برای سوسک‌های سرگین کوچک به شرح ۲۶، است:

$$X_i(t+1) = X_i(t) + C_1 * (X_i(t) - Lm) + C_2 * (X_i(t) - Um) \quad (26)$$

که در آن (t) X_i نشان دهنده موقعیت i -امین سوسک سرگین در تکرار t -ام است. $C1$ و $C2$ عددی است که به طور تصادفی به دنبال توزیع نرمال ایجاد می‌شود و $C2$ یک بردار تصادفی در محدوده 0 و 1 است. با توجه به اینکه برخی از سوسک‌های سرگین که به آنها دزد می‌گویند، توبهای سرگین را از سایر سوسک‌ها می‌دزندن، اطلاعات موقعیت سارق در طول فرآیند تکرار به صورت زیر به روزرسانی می‌شود. بر اساس رابطه ۲۶، می‌توان مشاهده کرد که Xh منبع غذایی بهینه را نشان می‌دهد. با فرض اینکه منطقه اطراف Xh نشان دهنده مکان اصلی برای غذای رقابتی است، به روز رسانی موقعیت برای دزد مطابق معادله (۲۷)، ارائه می‌شود:

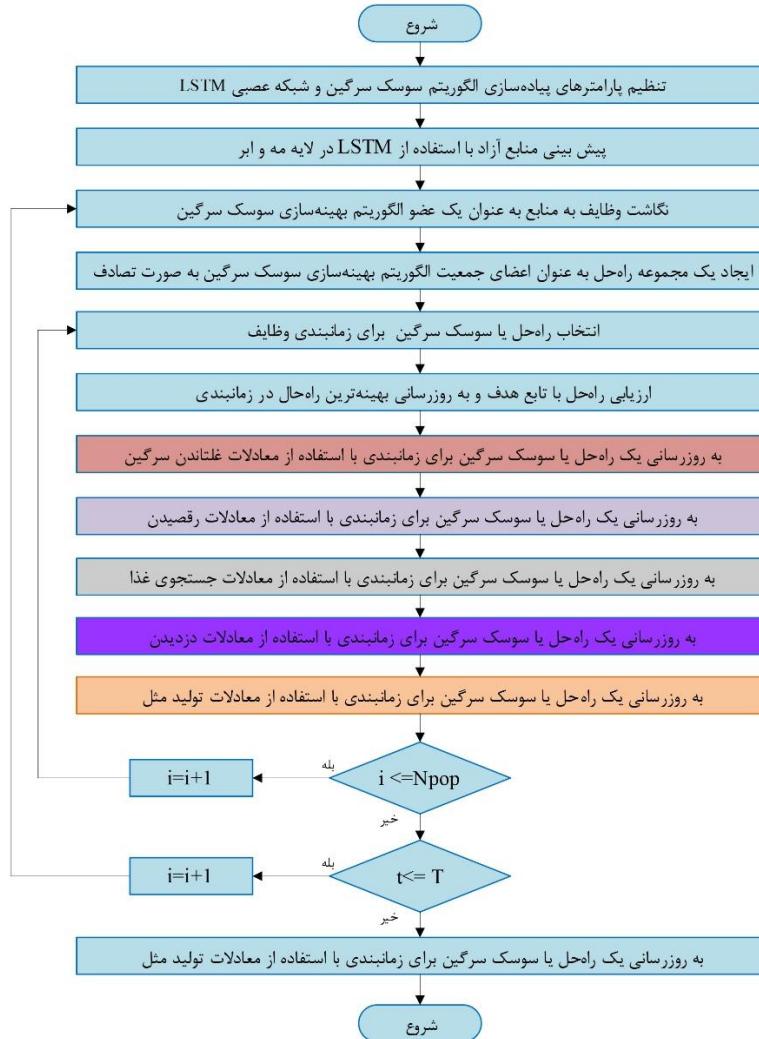
$$X_i(t+1) = X^* + W * g * |X_i(t) - X^*| + |X_i(t) - X^*| \quad (27)$$

که در آن (t) $Xi(t)$ اطلاعات موقعیت i -امین سارق را در تکرار t -امین نشان می‌دهد، Xh نشان دهنده بهترین موقعیت سراسری، X^* نشان دهنده بهترین موقعیت محلی فعلی، $|X - Xh|$ و $|Xi(t) - Xh|$ به ترتیب نشان دهنده تفاوت‌های مطلق بین موقعیت فعلی و بهترین موقعیت‌های محلی و جهانی است. g یک بردار تصادفی با اندازه 1 در D و یک دنباله توزیع نرمال است و W یک ثابت است. اگرچه الگوریتم سوسک سرگین دارای قابلیت‌های بهینه‌سازی قوی و سرعت هم‌گرایی سریع است، اما از عدم تعادل بین اکتشاف جهانی و توئانایی‌های بهره‌برداری محلی رنج می‌برد و آن را مستعد گیر کردن در بهینه محلی و نشان دادن قابلیت‌های ضعیف اکتشاف جهانی می‌کند. در شکل ۱۱، فلوچارت روش پیشنهادی برای تخصیص منابع و زمانبندی وظایف و کارها ارایه شده است. در روش پیشنهادی دو فاز اصلی ذیل وجود دارد:

- پیش‌بینی منابع آزاد با استفاده از شبکه عصبی LSTM

- زمانبندی بهینه وظایف با استفاده از الگوریتم بهینه‌سازی سوسک سرگین

در روش پیشنهادی هر نگاشت وظایف به منابع به عنوان یک راه حل یا یک سوسک سرگین در نظر گرفته می‌شود و توسط این الگوریتم تلاش می‌شود تا بهینه‌ترین سوسک یا زمانبندی وظایف محاسبه شود.



شکل ۱۲: فلوچارت پیشنهادی برای زمانبندی وظایف

Figure 12. Suggested flowchart for task scheduling

۴-نتایج تجربی

در این بخش روش پیشنهادی برای زمانبندی کارها و وظایف مورد ارزیابی قرار گرفته می‌شود. در بخش اول شاخص‌های ارزیابی برای پیش‌بینی وضعیت اشغال یا آزاد بودن منابع معرفی شده و سپس شاخص‌های ارزیابی برای زمانبندی نیز ارایه می‌شود سپس پارامترهای به کار رفته برای پیاده‌سازی‌ها نیز معرفی می‌شود. در ادامه نیز با آزمایشات روش پیشنهادی در MatLab پیاده‌سازی و با روش‌های مشابه مقایسه می‌شود.

۱-۴-شاخص‌های ارزیابی

برای ارزیابی روش پیشنهادی در فاز پیش‌بینی وضعیت منابع از شاخص‌های دقت، حساسیت و صحت استفاده می‌شود که ضابطه آنها به ترتیب در رابطه ۲۸، ۲۹ و ۳۰ فرموله شده است.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (28)$$

$$Sensitivity = \frac{TP}{TP + FN} \times 100\% \quad (29)$$

$$Precision = \frac{TP}{TP + FP} \times 100\% \quad (30)$$

- مفهوم هر کدام از شاخص های ارزیابی از جمله TP، TN، FP و FN برای زمانبندی به شرح ذیل است:
- نمونه های صحیح مثبت(TP): منبع به کار رفته دارای بار عملیاتی زیادی است و روش پیشنهادی نیز به درستی پیش بینی کرده این منبع دارای بار عملیاتی زیاد است.
- نمونه های غلط مثبت(FP): منبع به کار رفته دارای بار عملیاتی کم است و روش پیشنهادی نیز به اشتباه پیش بینی کرده این منبع دارای بار زیاد است.
- نمونه های صحیح منفی(TN): منبع به کار رفته دارای بار عملیاتی اندک است و روش پیشنهادی نیز به درستی پیش بینی کرده این منبع دارای بار عملیاتی اندک است.
- نمونه های غلط منفی(FN): منبع به کار رفته دارای بار عملیاتی زیادی است و روش پیشنهادی نیز به اشتباه پیش بینی کرده این منبع دارای بار عملیاتی اندک است.
- علاوه بر این شاخص ها، برای زمانبندی وظایف می توان به شاخص های مانند تأخیر زمانبندی و makespan اشاره کرد. کمینه نودن تین مقادیر نشان دهنده آن است که الگوریتم زمانبندی به کار رفته دارای کارایی بالایی برای زمانبندی وظایف در لایه مه و ابر محاسباتی است.

۴-۲-پارامترها

در جدول(۱)، مجموعه ای از پارامترهای به کار رفته برای شبیه سازی و پیاده سازی در نرم افزار Matlab نشان داده شده است. در این جدول، اطلاعات مرتبط با ماشین های فیزیکی و مجازی به عنوان منابع به کار رفته نمایش داده است.

جدول ۱: پارامترهای مرتبط با پیاده سازی مرتبط با منابع

Table 1. Implementation-related parameters related to resources

	Specification	Amount
Physical Machine	Clients Count	[60, 120]
	Hosts Count	6
	CPU capacity	[100, 5000]
	Storage	1 TB
	Network Bandwidth	10 Gb/s
Virtual Machine	RAM size	6 GB
	VMs count	25
	CPU capacity	[100, 5000]
	Storage	20 GB
	RAM size	1 GB
	Network Bandwidth	1 Gb/s
	Processor	Xen
	Processors' count	1

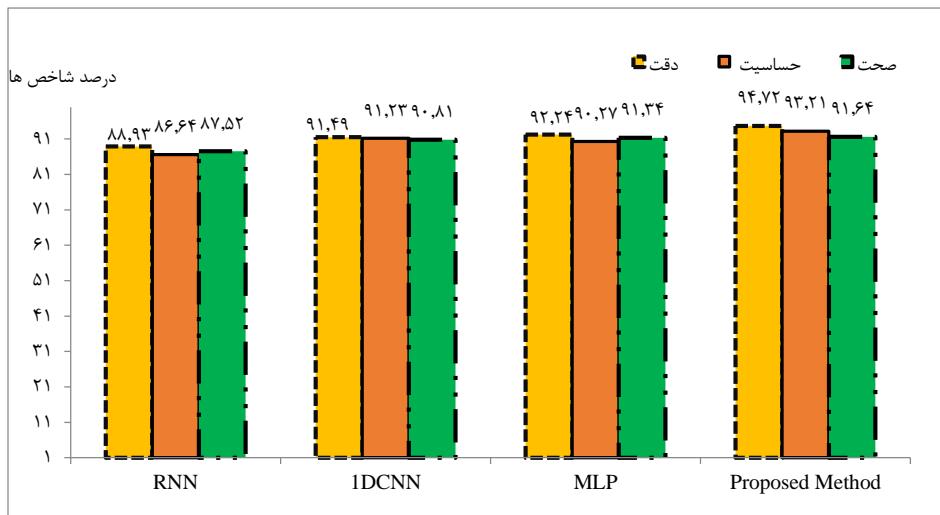
علاوه بر این پارامترها، برخی از پارامترها نیز مرتبط با الگوریتم بهینه سازی سوک سرگین است و به عنوان مثال اندازه جمعیت اولیه برابر ۱۵ و تعداد تکرار الگوریتم برابر ۵۰ و هر آزمایش ۲۵ مرتبه تکرار می شود تا متوسط شاخص ها محاسبه شود.

۴-۳-مجموعه داده

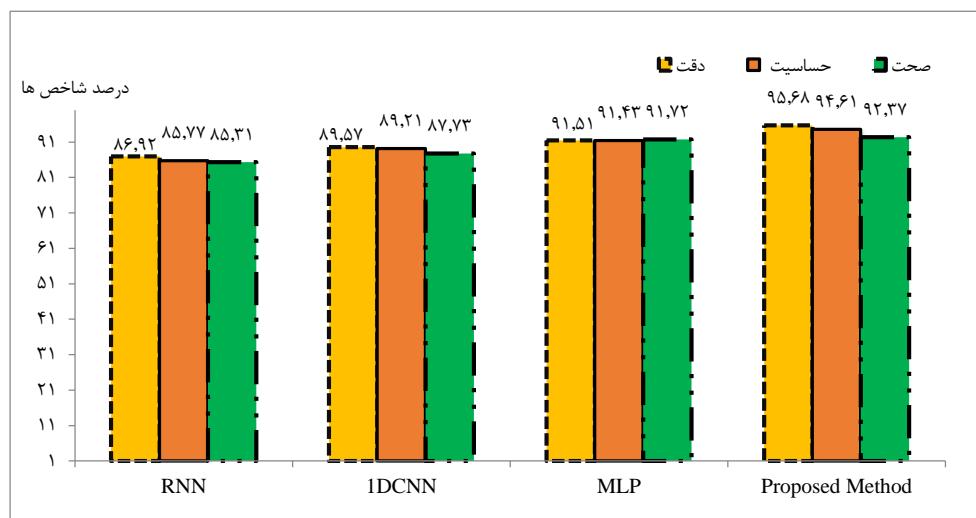
برای پیاده سازی ها دو مجموعه داده مختلف، HPC2N و NASA استفاده شده است که هر کدام دارای ۵۰۰، ۱۰۰۰، ۱۵۰۰ و ۲۰۰۰ وظیفه هستند. مجموعه داده iPSC ناسا مربوط به ۲۵۷ کاربر است، به ۲۴۰ پردازنده یا CPU نیاز است. میانگین تعداد وظایف در این مجموعه داده ۲۰۲/۸۷۱ است. در مجموع ۱۲۸ پردازنده یا CPU برای مجموعه داده HPC2N مورد نیاز است که مربوط به ۶۹ کاربر است. میانگین تعداد وظایف در این مجموعه داده ۱۸/۲۳۹ است [۳۰].

۴-۴-پیش بینی در تخصیص منابع

در این بخش شبکه عصبی LSTM روی مجموعه‌ای از ویژگی‌ها مرتبط با مجموعه داده HPC2N و NASA آموزش داده می‌شود. در نمودار شکل ۱۳ و ۱۴ به ترتیب شاخص دقت، حساسیت و صحت روش پیشنهادی در این دو مجموعه داده با شبکه عصبی RNN، ۱DCNN، MLP، Proposed Method مورد مقایسه قرار گرفته است.



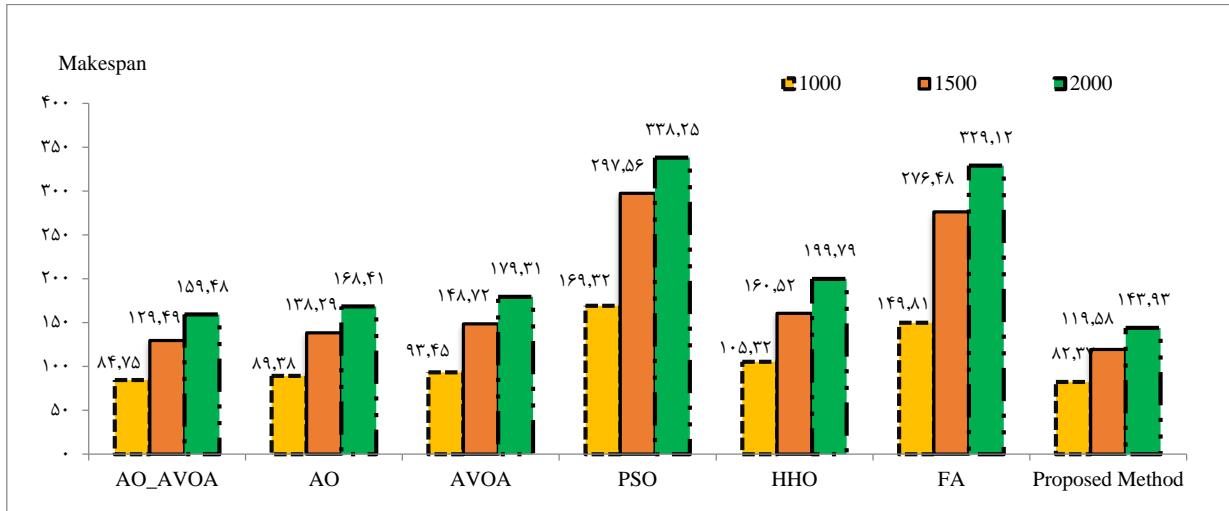
شکل ۱۳: مقایسه دقت، حساسیت و صحت در پیش بینی وضعیت منابع در مجموعه داده HPC2N
Figure 13. Comparison of accuracy, sensitivity and accuracy in predicting resource status in HPC2N dataset



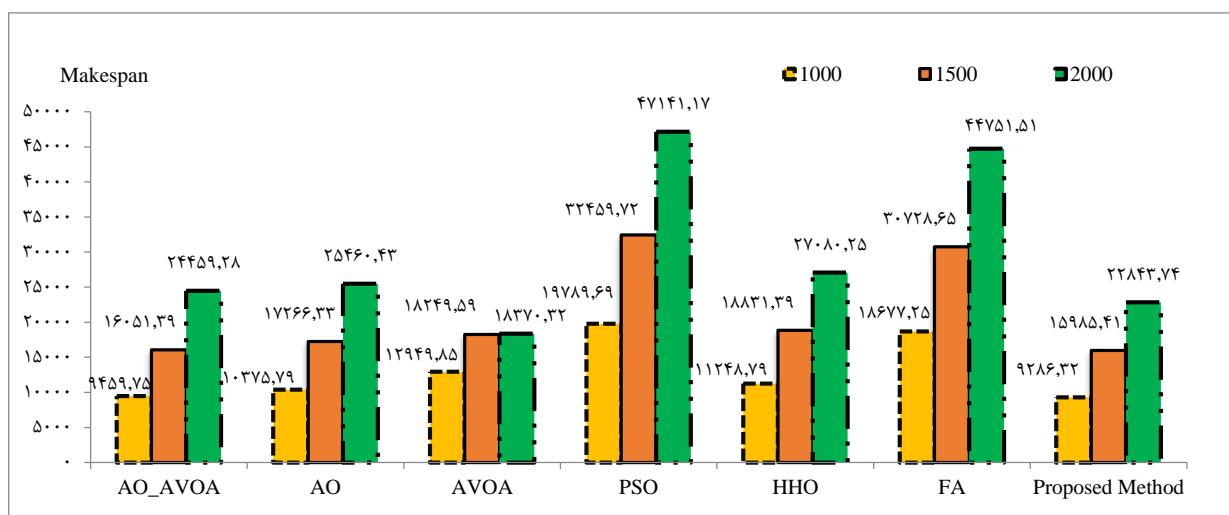
شکل ۱۴: مقایسه دقت، حساسیت و صحت در پیش بینی وضعیت منابع در مجموعه داده NASA
Figure 14. Comparison of accuracy, sensitivity and accuracy in predicting resource status in NASA dataset

آزمایشات در مجموعه داده HPC2N نشان می‌دهد که دقت، حساسیت و صحت روش پیشنهادی برای پیش بینی وضعیت منابع (آزاد یا مشغول) به ترتیب برابر ۹۴/۷۲ درصد، ۹۳/۲۱ درصد و ۹۱/۶۴ درصد است. روش پیشنهادی در مجموعه داده HPC2N نسبت به روش‌های ۱DCNN، RNN، MLP دقت بیشتری در پیش بینی وضعیت منابع برای زمانبندی دارد. در مجموعه داده NASA دقت، حساسیت و صحت پیش بینی روش پیشنهادی به ترتیب برابر ۹۵/۶۸ درصد، ۹۴/۶۱ درصد و ۹۲/۳۷ درصد است. با توجه به آزمایشات در مجموعه داده NASA

دقت روش پیشنهادی و سایر روش‌ها نسبت به مجموعه داده HPC2N بیشتر است که دلیل آن می‌تواند دقت گردآوری در مجموعه داده NASA باشد. در هر دو مجموعه داده روش پیشنهادی نسبت به سه روش پیش‌بینی کننده دیگر موفق‌تر بوده است و بدترین عملکرد در پیش‌بینی منابع و تخصیص آنها مرتبط با RNN است. برای فاز زمانبندی روش پیشنهادی در دو مجموعه داده HPC2N و NASA در Makespan نظیر Makespan با روش‌های فرآیندکاری مقایسه شده است و برای مقایسه از نتایج بهدست آمده در پژوهش [۳۰]، در سال ۲۰۲۳ استفاده می‌شود که در نمودار شکل ۱۵ و ۱۶ مقایسه شده است.

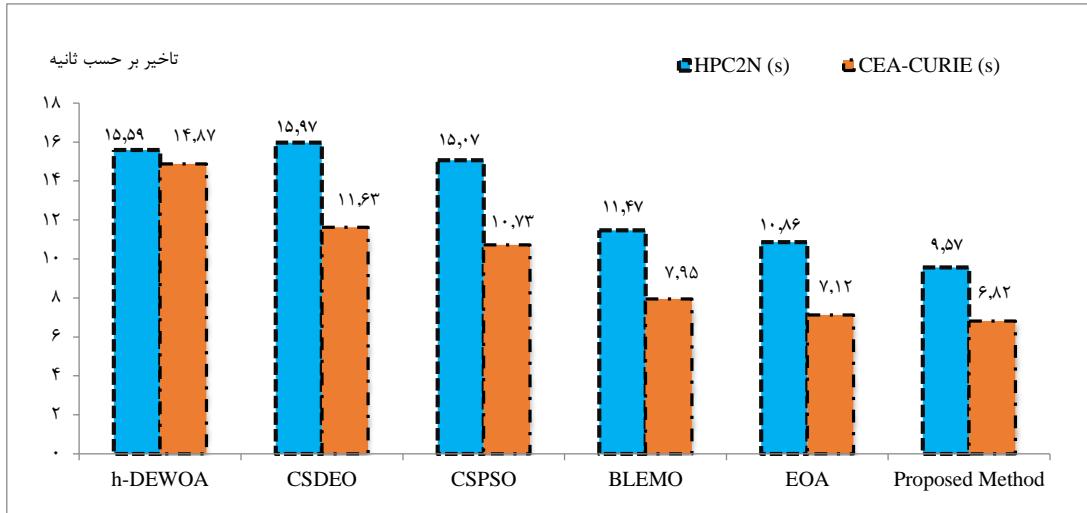


شکل ۱۵: مقایسه شاخص Makespan در مجموعه داده NASA به ازای ۱۰۰۰، ۱۵۰۰ و ۲۰۰۰ وظیفه
Figure 15. Comparison of Makespan index in NASA dataset for 1000, 1500 and 2000 tasks



شکل ۱۶: مقایسه شاخص Makespan در مجموعه داده HPC2N به ازای ۱۰۰۰، ۱۵۰۰ و ۲۰۰۰ وظیفه
Figure 16. Comparison of Makespan index in HPC2N dataset for 1000, 1500 and 2000 tasks

آزمایشات نشان می‌دهد در دو مجموعه NASA و HPC2N شاخص Makespan روش پیشنهادی نسبت به روش‌های AO_AVOA، AVOA، PSO، HHO و FA دارای مقادیر کمتری است و تین موضوع نشان می‌دهد روش پیشنهادی نسبت به این روش‌ها سریع‌تر و ظایف‌تر است. در نمودار شکل ۱۷، تاخیر و زمان اجرای الگوریتم پیشنهادی در دو مجموعه داده HPC2N و CEA-CURIE با روش‌های h-DEWOA، EOA، BLEMOS و CSPSO مطابق پژوهش [۳۶]، که در سال ۲۰۲۳ انجام شده است، نمایش داده می‌شود.



شکل ۱۷: مقایسه تاخیر در اجرای زمانبندی وظایف

Figure 17. Comparison of delays in the implementation of task scheduling

آزمایشات نشان داد تاخیر روش پیشنهادی در دو مجموعه داده HPC2N و CEA-CURIE به ترتیب برابر ۶/۸۲ و ۹/۵۷ ثانیه است و نسبت به روش‌های EOА, CSPSO, CSDEO, BLEMO و h-DEWOA کمتری در زمانبندی وظایف در لایه مه و ابر است.

۵-نتیجه گیری

پتانسیل برجسته پلتفرم‌های ابری، پردازش و ذخیره‌سازی کلان داده‌های جمع‌آوری شده از تجهیزات اینترنت اشیا را تسريع می‌کند. طرح‌های پردازش مبتنی بر مه می‌توانند کیفیت خدمات را برای برنامه‌های اینترنت اشیا بهبود بخشد و تاخیرهای بیش از حد و چالش‌های امنیتی را کاهش دهند. همچنین، از آنجایی که مصرف انرژی می‌تواند مستقیماً باعث انتشار CO₂ از مه و گره‌های ابری شود، یک روش زمانبندی کار کارآمد، مصرف انرژی را کاهش می‌دهد. در این راستا، نیاز روزافزون به یک مکانیسم زمانبندی وظایف کارآمد با در نظر گرفتن مدیریت بهینه منابع اینترنت اشیا به طور فزاینده‌ای احساس می‌شود. زمانبندی وظایف اینترنت اشیا بر اساس محاسبات مه‌ابر نقش مهمی در پاسخ به درخواست‌های کاربران دارد. برنامه‌ریزی بهینه وظایف می‌تواند عملکرد سیستم را بهبود بخشد. بنابراین، این مطالعه از یک روش زمانبندی درخواست وظایف اینترنت اشیا بر روی منابع توسط الگوریتم بهینه‌سازی سوک سرگین استفاده می‌کند. کیفیت خدمات اینترنت اشیا مبتنی بر محاسبات مه‌ابر را افزایش می‌دهد تا زمان تکمیل درخواست‌های کار و زمان عملیات سیستم و مصرف انرژی را کاهش دهد. اگر مصرف انرژی کاهش یابد، درصد انتشار CO₂ نیز کاسته می‌شود. سپس روش زمانبندی پیشنهادی برای حل مسئله زمانبندی کار با استفاده از مجموعه داده‌ها ارزیابی می‌شود. در این مقاله یک نسخه زمانبندی برای وظایف در لایه مه و ابر ارایه شده است. در روش پیشنهادی با استفاده از شبکه عصبی LSTM از اداد پیش‌بینی و تخصیص داده می‌شود و سپس با استفاده از الگوریتم بهینه‌سازی سوک سرگین تلاش می‌شود تا زمانبندی بهینه برای وظایف و کارها محاسبه شود. آزمایشات نشان داد دقت تخصیص منابع در لایه مه و ابر در روش پیشنهادی بیشتر از شبکه عصبی MLP، RNN، DCNN،^۱ AVOA، AO_AVOA، PSO، HHO و FA کمتر است. در کارهای آتی تلاش می‌شود برای پیش‌بینی منابع زمانبندی در لایه مه و لایه ابر از ترکیب شبکه Makespan است. آزمایشات نشان داد شخصیت AVOA، AO_AVOA، PSO، HHO و FA روش پیشنهادی در زمانبندی کارها در لایه مه و ابر نسبت به روش‌های سوک سرگین با توابع آشوبناک در زمانبندی وظایف در لایه مه و ابر است.

مراجع

- [1] A. S. Abohamama, A. El-Ghamry & E. Hamouda, "Real-time task scheduling algorithm for IoT-based applications in the cloud–fog environment," *Journal of Network and Systems Management*, vol. 30, no.4, 35,54, 27 May 2022, doi: 10.1007/s10922-022-09664-6.
- [2] D. R. Prapti, A. R. Mohamed Shariff, H. Che Man, N. M. Ramli, T. Perumal, & M. Shariff, "Internet of Things (IoT)-based aquaculture: An overview of IoT application on water quality monitoring," *Reviews in*

Aquaculture, vol. 14, no. 2, pp. 979-992, 19 November 2021, doi: 10.1111/raq.12637.

- [3] I. Attiya, M. Abd Elaziz, L. Abualigah, T. N. Nguyen, & A. A. Abd El-Latif, "An improved hybrid swarm intelligence for scheduling iot application tasks in the cloud," *IEEE Transactions on Industrial Informatics*, vol. 18, no. 9, pp. 6264-6272, 04 February 2022, doi: 10.1109/TII.2022.3148288
- [4] A. Rahimikhanghah, M. Tajkey, B. Rezazadeh, & A. M. Rahmani, "Resource scheduling methods in cloud and fog computing environments: a systematic literature review," *Cluster Computing*, vol. 25, pp. 911-945, 1-35. April 2022, doi: 10.1007/s10586-021-03467-1.
- [5] M. T. Zhou, T. F. Ren, Z. M. Dai, & X. Y. Feng, "Task scheduling and resource balancing of fog computing in smart factory," *Mobile Networks and Applications*, vol. 28, no. 1, pp. 19-30. February 2023, doi: 10.1007/s11036-022-01992-w.
- [6] S. Subbaraj, R. Thiyagarajan, & M. Rengaraj, "A smart fog computing based real-time secure resource allocation and scheduling strategy using multi-objective crow search algorithm," *Journal of Ambient Intelligence and Humanized Computing*, vol. 14, no. 2, pp. 1003-1015. February 2023, doi: 10.1007/s12652-021-03354-y.
- [7] M. R. Raju, & S. K. Mothku, "Delay and energy aware task scheduling mechanism for fog-enabled IoT applications: A reinforcement learning approach," *Computer Networks*, vol. 224, 109603, 8 February 2023, doi: 10.1016/j.comnet.
- [8] H. Wadhwa, & R. Aron, "Optimized task scheduling and preemption for distributed resource management in fog-assisted IoT environment," *The Journal of Supercomputing*, vol. 79, no. 2, pp. 2212-2250, February 2023, doi : 10.1007/s11227-022-04747-2.
- [9] T. K. Vashishth, , V. Sharma, K. K. Sharma, B. Kumar, S. Chaudhary, & R. Panwar, (2024). "Intelligent Resource Allocation and Optimization for Industrial Robotics Using AI and Blockchain," In *AI and Blockchain Applications in Industrial Robotics IGI Global*, pp. 82-110, December 2023, doi : 10.4018/979-8-3693-0659-8.ch004.
- [10] Saifeng, Z. (2024). "AQINM: an adaptive QoS management framework based on intelligent negotiation and monitoring in cloud," *International Journal of Information Technology and Management*, vol. 23, no. 1, pp. 33-47, 22 January 2024, doi: 10.1504/IJITM.2024.136183.
- [11] E. Khezri, R. O. Yahya, H. Hassanzadeh, M. Mohaidat, S. Ahmadi, & M. Trik, "DLJSF: Data-Locality Aware Job Scheduling IoT tasks in fog-cloud computing environments," *Results in Engineering*, vol. 21, 101780. 24 January 2024, doi: 10.1016/j.rineng.2024.101780.
- [12] Y. Lin, Y. Xu, J. Zhu, X. Wang, L. Wang, & G. Hu, "MLATSO: A method for task scheduling optimization in multi-load AGVs-based systems," *Robotics and Computer-Integrated Manufacturing*, vol. 79, 102397, February 2023, doi: 10.1016/j.rcim.2022.102397.
- [13] Y. Shen, & H. Li, "A multi-strategy genetic algorithm for solving multi-point dynamic aggregation problems with priority relationships of tasks," *Electronic Research Archive*, vol.32, no. 1, pp. 445-472, 2024, doi: 10.3934/era.2024022.
- [14] X. Fu, Y. Sun, H. Wang, & H. Li, "Task scheduling of cloud computing based on hybrid particle swarm algorithm and genetic algorithm," *Cluster Computing*, vol. 26, no. 5, pp. 2479-2488, October 2023, doi: 10.1007/s10586-020-03221-z.
- [15] S. Mangalampalli, S. K. Swain, G. R. Karri, & S. Mishra, "SLA Aware Task-Scheduling Algorithm in Cloud

Computing Using Whale Optimization Algorithm," *Scientific Programming*, vol. 2023, 20 Apr 2023, doi: 10.1155/2023/8830895.

- [16] S. Mangalampalli, G. R. Karri, S. N. Mohanty, S. Ali, M. I. Khan, D. Abduvalieva, F. A. Awwad & E. A. Ismail, "Fault tolerant trust based task scheduler using Harris Hawks optimization and deep reinforcement learning in multi cloud environment," *Scientific Reports*, vol. 13, no. 1, 19179. 06 November 2023, doi.org/10.1038/s41598-023-46284-9.
- [17] J. Xue, & B. Shen, "Dung beetle optimizer: A new meta-heuristic algorithm for global optimization," *The Journal of Supercomputing*, vol. 79, no. 7, pp. 7305-7336, May 2023, doi.org/10.1007/s11227-022-04959-6.
- [18] Z. Yin, F. Xu, Y. Li, C. Fan, F. Zhang, G. Han, & Y. Bi, "A multi-objective task scheduling strategy for intelligent production line based on cloud-fog computing," *Sensors*, vo. 22, no. 4, 1555, 15 February 2022, doi: 10.3390/s22041555.
- [19] A. A. Mutlag, M. Khanapi Abd Ghani, M. A. Mohammed, M. S. Maashi, O. Mohd, S. A. Mostafa, , k. h. Abdulkareem, G. Marques, & I. de la Torre Díez, (2020). "MAFC: Multi-agent fog computing model for healthcare critical tasks management," *Sensors*, vol. 20, no. 7, 1853, 25 March 2020, doi.org: 10.3390/s20071853.
- [20] X. Ma, H. Gao, H. Xu, & M. Bian, "An IoT-based task scheduling optimization scheme considering the deadline and cost-aware scientific workflow for cloud computing," *EURASIP Journal on Wireless Communications and Networking*, vol. 2019, no. 249, pp. 1-19, 08 November 2019, doi: 10.1186/s13638-019-1557-3.
- [21] M. Hosseini Shirvani, "A survey study on task scheduling schemes for workflow executions in cloud computing environment: classification and challenges," *The Journal of Supercomputing*, pp. 1-54, 07 December 2023 , doi: 10.1007/s11227-023-05806-y.
- [22] M. Hosseinzadeh, E. Azhir, J. Lansky, S. Mildeova, O. H. Ahmed, M. H. Malik, & F. Khan, "Task Scheduling Mechanisms for Fog Computing: A Systematic Survey," *IEEE Access*, vol. 11, pp. 50994–51017, 18 May 2023, doi: 10.1109/ACCESS.2023.3277826.
- [23] Zhou, M. T., Ren, T. F., Dai, Z. M., & Feng, X. Y. (2023). "Task scheduling and resource balancing of fog computing in smart factory," *Mobile Networks and Applications*, vol. 28, no. 1, pp. 19-30, February 2023, doi: 10.1007/s11036-022-01992-w.
- [24] Z. A. Khan, I. A. Aziz, & N. A. B. Osman, "A Review on Task Scheduling Techniques in Cloud and Fog Computing: Taxonomy, Tools, Open Issues, Challenges, and Future Directions," *IEEE Access*, vol. 11, pp. 143417 – 143445, 18 December 2023, doi: 10.1109/ACCESS.2023.3343877.
- [25] T. Salehnia, A. Seyfollahi, , S. Raziani, A. Noori, A. Ghaffari, A. R. Alsoud, & L. Abualigah, "An optimal task scheduling method in IoT-Fog-Cloud network using multi-objective moth-flame algorithm," *Multimedia Tools and Applications*, pp. 1-22, 11 September 2023, doi: 10.1007/s11042-023-16971-w
- [26] F. Ramezani Shahidani, A. Ghasemi, A. Toroghi Haghigat, & A. Keshavarzi, "Task scheduling in edge-fog-cloud architecture: a multi-objective load balancing approach using reinforcement learning algorithm," *Computing*, vol. 105, no. 6, pp. 1337-1359, June 2023, doi: 10.1007/s00607-022-01147-5.
- [27] B. M. Nguyen, T. Nguyen, Q. H. Vu, H. H. Tran, H. Vo, H. T. T. Binh, S. Yu , Z. Wu, "A novel nature-inspired algorithm for optimal task scheduling in fog-cloud blockchain system," *IEEE Internet of Things Journal*, vol. 11, 06 July 2023, doi: 10.1109/JIOT.2023.3292872.

- [28] J. Z. Ahmadabadi, S. E. Mood, & A. Souri, “Star-quake: A new operator in multi-objective gravitational search algorithm for task scheduling in IoT based cloud-fog computing system,” *IEEE Transactions on Consumer Electronics*, January 2023, doi: 10.1109/TCE.2023.3321708.
 - [29] R. Ghafari, & N. Mansouri, “E-AVOA-TS: Enhanced African vultures optimization algorithm-based task scheduling strategy for fog–cloud computing,” *Sustainable Computing: Informatics and Systems*, vol. 40, 100918, December 2023, doi: 10.1016/j.suscom.2023.100918.
 - [30] Q. Liu, H. Kosarirad, S. Meisami, K. A. Alnowibet, & A. N. Hoshyar, “An Optimal Scheduling Method in IoT-Fog-Cloud Network Using Combination of Aquila Optimizer and African Vultures Optimization,” *Processes*, vol. 11, no. 4, 1162, 10 April 2023, doi: 10.3390/pr11041162.
 - [31] Z. Wang, M. Goudarzi, M. Gong, & R. Buyya, “Deep Reinforcement Learning-based scheduling for optimizing system load and response time in edge and fog computing environments,” *Future Generation Computer Systems*, vol. 152, pp. 55-69, Mtch 2024, doi: /10.1016/j.future.2023.10.012
 - [32] M. Osmanpoor, A. Shameli-Sendi, & F. Faraji Daneshgar, “Convergence of the Harris hawks optimization algorithm and fuzzy system for cloud-based task scheduling enhancement,” *Cluster Computing*, pp. 1-15, 09 January 2024, doi.org/10.1007/s10586-023-04225-1.
 - [33] D. Sanchez Narvaez, C. Villaseñor, C. Lopez-Franco, & N. Arana-Daniel, “Order-Based Schedule of Dynamic Topology for Recurrent Neural Network,” *Algorithms*, vol. 16, no. 5, 231. 28 April 2023, doi: 10.3390/a16050231.
 - [34] B. M. Nguyen, , H. Thi Thanh Binh, T. The Anh, & D. Bao Son, “Evolutionary algorithms to optimize task scheduling problem for the IoT based bag-of-tasks application in cloud–fog computing environment,” *Applied Sciences*, vol. 9, no. 9, 1730, 26 April 2019, doi: 10.3390/app9091730.
 - [35] L. Li, L. Liu, Y. Shao, X. Zhang, Y. Chen, C. Guo, & H. Nian, “Enhancing Swarm Intelligence for Obstacle Avoidance with Multi-Strategy and Improved Dung Beetle Optimization Algorithm in Mobile Robot Navigation,” *Electronics*, vol. 12, no. 21, 4462, 30 October 2023 , doi: 10.3390/electronics12214462.
 - [36] M. S. Kumar, & G. R. Karri, “Eeoaa: cost and energy efficient task scheduling in a cloud-fog framework,” *Sensors*, vol. 23, no. 5, 2445, 22 February 2023, doi: 10.3390/s23052445.



Tasks scheduling in distributed fog layer and cloud computing systems using dung beetle optimization algorithm

Reza Aziz, Assistant Professor¹, Mohsen Eghbali, PhD Student²

Abstract

The Internet of Things has grown significantly in the past few years, and many intelligent objects have been connected to it. Cloud computing is a data processing system in the Internet of Things. However, the servers in the cloud computing paradigm are usually located at a long physical distance from the Internet of Things devices. The high latency caused by long distances cannot effectively implement real-time Internet of Things applications. Edge and fog computing has emerged as a popular computing technology in the field of the Internet of Things. One of the critical challenges of the Internet of Things is the problem of scheduling tasks in the fog and cloud layer. In the proposed method, the LSTM neural network allocates free resources, and the dung beetle optimization algorithm is used to schedule tasks optimally in the cloud and fog layer. Experiments show that in the HPC2N data set, the accuracy, sensitivity, and precision of the proposed method for predicting the state of resources are equal to 94.72%, 93.21%, and 91.64%, respectively. In the NASA data set, the proposed method's accuracy, sensitivity, and precision in resource allocation are 95.68%, 94.61%, and 92.37%, respectively. The proposed method is more accurate in allocating resources for scheduling than the RNN, 1DCNN, and MLP methods. The Makespan index of the proposed method shows a lower and better value in task scheduling than the AO_AVOA, AVOA, PSO, HHO, and FA methods.

Keywords: Cloud layer, Dung beetle optimization algorithm, Fog layer, Task scheduling, Internet of Things.