

## ارائه رویکرد مبتنی بر الگوریتم تکاملی تفاضلی چندهدفه برای مسئله تخصیص منبع در محیط رایانش ابری

سعید بختیاری\* ماهان خسروشاهی\*\*

\* استادیار گروه فتا، دانشگاه علوم انتظامی امین، تهران

\*\* دانشجوی کارشناسی ارشد مهندسی فناوری اطلاعات و ارتباطات، دانشگاه آزاد اسلامی واحد تهران مرکزی، تهران

تاریخ دریافت: ۱۴۰۰/۰۳/۲۴ تاریخ پذیرش: ۱۴۰۰/۱۲/۰۷

نوع مقاله: پژوهشی

### چکیده

در سال‌های اخیر، الگوی رایانش ابری به دلیل مقیاس‌پذیری بالا، قابلیت اطمینان، اشتراک اطلاعات و هزینه پایین نسبت به ماشین‌های مجزا، بسیار مورد توجه قرار گرفته است. در محیط ابر، زمانبندی و تخصیص بهینه وظایف بر استفاده مؤثر از منابع سیستم اثر می‌گذارد. در حال حاضر روش‌های متداول برای زمانبندی در محیط رایانش ابری با استفاده از روش‌های سنتی مانند حداقل-حداقل و روش‌های فرا ابتکاری مانند الگوریتم کلونی مورچه‌ها انجام می‌شود. روش‌های فوق بر بهینه‌سازی یک هدف متمرکز هستند و به طور همزمان چندین هدف را برآورد نمی‌کنند. هدف اصلی این تحقیق در نظر گرفتن چندین هدف (زمان اجرای کل، توافق‌نامه سطح سرویس، مهاجرت و انرژی مصرف شده) در مراکز داده ابری با زمانبندی و تخصیص بهینه وظایف می‌باشد. در این پژوهش الگوریتم تکاملی تفاضلی چندهدفه به دلیل ویژگی‌های ساختار ساده و پارامترهای قابل تنظیم کمتر، مورد استفاده قرار می‌گیرد. در روش پیشنهادی، رویکردی جدید مبتنی بر الگوریتم تکاملی تفاضلی برای حل مسأله تخصیص در فضای ابری ارائه می‌شود که در رویکرد ارائه شده سعی می‌شود که بر اساس تابع سودمندی چندهدفه تعریف شده و در نظر گرفتن بردارهای جهش و تقاطع بتوانیم در بهبود بهره‌وری از منابع و در نظر گرفتن اهدافی چون زمان، مهاجرت و انرژی تأثیرگذار باشیم. روش پیشنهادی از طریق شبیه‌ساز کلودسیم با آزمایش بر روی حجم کار بیش از هزار ماشین مجازی بر روی داده‌های Planet Lab ارزیابی شده است. نتایج حاصل از شبیه‌سازی نشان می‌دهد که روش پیشنهادی توانسته است معیار مصرف انرژی را نسبت به الگوریتم‌های FA و LrMmt، JqrMc مقایسه شده به طور میانگین به میزان ۲۳ درصد، تعداد مهاجرت‌ها را به طور میانگین به میزان ۲۹ درصد، زمان اجرای کل را به طور میانگین به میزان ۲۹ درصد و نقص توافق‌نامه سطح سرویس را به طور میانگین به میزان ۱ درصد بهبود دهد. در این صورت استفاده از رویکرد پیشنهادی در مراکز ابری منجر به سرویس‌های بهتر و مناسب به مشتریان این مراکز در حوزه‌های مختلفی از جمله آموزش، مهندسی، صنایع تولیدی، خدماتی و... خواهد شد.

واژگان کلیدی: رایانش ابری، زمانبندی، تخصیص، الگوریتم تکاملی تفاضلی چندهدفه، مهاجرت.

## ۱. مقدمه

رویکرد مبتنی بر تفاضلی دارای ویژگی‌های ساختار ساده و پارامترهای قابل تنظیم کمتر می‌باشد که برای حل انواع مسائل بهینه سازی پیچیده عددی و مهندسی منجر به نتایج رضایت بخشی شده است [۱]. از آنجایی که مسئله تخصیص منابع و زمانبندی در محیط رایانش ابری یک مسئله ان پی-سخت<sup>۵</sup> است، بدین جهت به کارگیری الگوریتم تکاملی تفاضلی چندهدفه در محیط رایانش ابری می‌تواند کارایی آن را به طور گسترده بهبود دهد. این الگوریتم برای غلبه بر عیب اصلی الگوریتم ژنتیک یعنی فقدان جستجوی محلی، ارائه شده است و تفاوت اصلی آن با الگوریتم ژنتیک در عملگر انتخاب می‌باشد. در رویکرد ارائه شده ابتدا سعی می‌شود که بر اساس تابع سودمندی چندهدفه تعریف شده و در نظر گرفتن بردارهای جهش و تقاطع بر اساس بهره‌وری از منابع و انرژی مصرفی قصد داریم با استفاده بهینه از منابع و بهبود بهره‌وری در کاهش زمان اجرای کل<sup>۶</sup> کارها، نقص توافق‌نامه سطح سرویس<sup>۷</sup>، تعداد مهاجرت‌ها و مصرف انرژی تأثیرگذار باشیم تا خدمات ابری مورد توجه مشتریان قرار گیرد.

## ۲. کارهای پیشین

رایانش ابری به عنوان یکی از انواع سیستم‌های توزیع شده که دسترسی به منابع گوناگون را از طریق سرویس‌ها بر روی بستر اینترنت فراهم می‌کند روز به روز در حال گسترش می‌باشد. از آنجایی که وظیفه ابر پاسخگویی به حجم بالای وظایف دریافتی است زمانبندی وظایف در رایانش ابری، مسأله بسیار مهمی می‌باشد که سعی دارد یک زمانبندی بهینه برای اجرای وظایف مشخص نماید. روش‌های بسیاری به ویژه روش‌های اکتشافی و تکاملی برای این مسأله ارائه گردیده است [۴]. که در ادامه به بررسی برخی از این پژوهش‌های اخیر می‌پردازیم.

در مقاله [۵] از مزایای روش مقیاس گذاری فرکانس و ولتاژ پویا<sup>۸</sup> همراه با رویکرد تجمیع<sup>۹</sup> برای ارائه دادن یک روش جدید چند معیاره فازی و راه حل مدیریت منبع واقعی استفاده شده است. ارزیابی گسترده الگوریتم‌های پیشنهادی با استفاده از شبیه‌ساز کلودسیم، کاهش‌های قابل توجهی در انرژی مصرفی، نقص توافق‌نامه سطح سرویس و تعداد مهاجرت‌ها در مقایسه با بهترین فناوری روز موجود نشان می‌دهد. این مقاله به بهبود زمان اجرای کل در محیط ابر توجه نکرده است.

مقاله [۶] روشی بر پایه الگوریتم زمانبندی انرژی آگاه<sup>۱۰</sup> برای تخصیص ماشین‌های مجازی ارائه نموده است. هدف اصلی این پژوهش کاهش مصرف انرژی و کاهش زمان پاسخ ماشین‌های مجازی می‌باشد. این مقاله همچنین وظایفی که بر روی ماشین‌های مجازی

رایانش ابری مدلی است برای فراهم کردن دسترسی آسان بر اساس تقاضای کاربر از طریق شبکه به مجموعه‌ای از منابع رایانشی قابل تغییر و پیکربندی (مثل: شبکه‌ها، سرورها، فضای ذخیره‌سازی، برنامه‌های کاربردی و سرویس‌ها) که این دسترسی بتواند بدون کمترین نیاز به مدیریت منابع و یا دخالت مستقیم فراهم‌کننده سرویس، به سرعت فراهم شده یا آزاد گردد [۱]. رایانش ابری را می‌توان از جمله بزرگترین راه‌حل‌های مشکلات صنعت فناوری اطلاعات برشمرد. در واقع با استفاده از آن می‌توان با صرف هزینه‌های کم و بدون نگرانی از ارتقای سخت افزار و یا به‌روزرسانی نرم‌افزار مورد استفاده، از امکاناتی نظیر قدرت پردازشی و یا فضای ذخیره‌سازی سرویس دهنده‌های ابری، تنها به واسطه اتصال به اینترنت، استفاده نمود. با توجه به گسترش روزافزون استفاده از رایانش ابری، سرویس دهندگان این تکنولوژی با چالش‌های جدیدی مواجه گردیده‌اند [۲]. مسأله تخصیص منابع و زمانبندی یکی از چالش‌های مهم در رایانش ابری می‌باشد. زمانبندی به معنای واگذاری کارآمد و مناسب منابع به کارهاست. هدف اصلی آن کوتاه کردن زمان تکمیل کار، بالا بردن توان عملیاتی سیستم و ایجاد تعادل بار بر روی منابع می‌باشد. این مسئله در ابر به دلیل مقیاس بزرگ منابع، پیچیده‌تر است؛ بنابراین شناخت بهتر الگوریتم‌ها می‌تواند در انتخاب الگوریتم مناسب جهت زمانبندی و تخصیص بهینه منابع کمک زیادی کند [۱] و [۲]. تخصیص منبع و زمانبندی برای پردازش توسط منابع مناسب موجود در شبکه ابر، به عنوان یک مسأله اساسی در رسیدن به کارایی بالا در سیستم رایانش ابری مطرح شده است. بر این اساس اگر به مسئله زمانبندی توجه نشود کارایی منابع ابری کاهش یافته و زمان اجرای کل افزایش می‌یابد. در حال حاضر روش‌های متداول برای زمانبندی و تخصیص منابع در محیط رایانش ابری با استفاده از روش‌های سنتی مانند روش حداقل-حداقل<sup>۱</sup>، روش حداکثر-حداقل<sup>۲</sup> و روش‌های فرا ابتکاری مانند الگوریتم کلونی مورچه‌ها<sup>۳</sup> و الگوریتم ژنتیک<sup>۴</sup> انجام می‌شود. روش‌های فوق غالباً بر بهینه سازی یک هدف متمرکز هستند و به طور همزمان چندین هدف را برآورد نمی‌کنند. در این میان برخی از الگوریتم‌های فرا ابتکاری نیاز به پارامترهای زیادی جهت تنظیم دارند و سرعت همگرایی آنها پایین است [۳]. روش‌های مختلفی مبتنی بر الگوریتم‌های فرا ابتکاری برای حل مسئله تخصیص و زمانبندی وجود دارند که هر کدام از آنها کارایی‌های مختلفی و پیچیدگی‌های متفاوتی دارند که در این مقاله الگوریتم تکاملی تفاضلی مورد مطالعه و بررسی قرار داده می‌شود.

<sup>۱</sup> Total Execution time

<sup>۲</sup> Service-level agreement (SLA)

<sup>۳</sup> Dynamic voltage and frequency scaling (DVFS)

<sup>۴</sup> Consolidation

<sup>۵</sup> Energy-Aware

<sup>۱</sup> Min-Min

<sup>۲</sup> Max-Min

<sup>۳</sup> Ant Colony Optimization (ACO)

<sup>۴</sup> Genetic

<sup>۵</sup> NP-Hard

اجرا می‌شوند را به گونه‌ای برای اجرا، اولویت بندی می‌کند تا این وظایف در کمترین زمان ممکن اجرا گردند. این مقاله به بهبود زمان اجرای وظیفه و زمان واقعی در محیط ابر توجه نکرده است.

تجمیع پویای ماشین مجازی معیار مهمی در بهبود بهره‌وری منابع می‌باشد. در مقاله [۷] یک سیاست تخصیص ماشین مجازی جدید به نام SABFD<sup>۱۱</sup> و یک سیاست مهاجرت جدید برای انتخاب ماشین مجازی به نام انتخاب ماشین مجازی برای مهاجرت مبتنی بر بهره پردازنده پیشنهاد شده است. نتایج تجربی آزمایشات، بهبود انرژی مصرفی و کارایی را در استفاده از این دو سیاست نسبت به برنامه‌های تجمیع پویای ماشین مجازی موجود نشان می‌دهد. از معایب این مقاله می‌توان به عدم توجه به زمانبندی و تخصیص منابع نام برد.

در مقاله [۱۰] به معرفی مکانیسم داوری در استراتژی انتخاب که می‌تواند زمان اجرای الگوریتم تکاملی تفاضلی را کاهش دهد، پرداخته شده است. در این مقاله به طور مؤثر کاستی‌های الگوریتم تکامل دیفرانسیل استاندارد را با سرعت همگرایی آهسته بهبود بخشیده است. در این مقاله بر بهبود الگوریتم تکاملی چندهدفه با هدف کاهش زمان متمرکز شده است. در این مقاله به معیارهای بهبود انرژی و کیفیت سرویس توجهی نشده است.

در مقاله [۸] یک الگوریتم بهینه سازی ترکیبی مبتنی بر الگوریتم ژنتیک و تکاملی تفاضلی ارائه شده است. با توجه به اینکه فرایند زمانبندی وظایف در محیط ابر یک ویژگی طبیعت پویا دارد بر این اساس محدودیت تابع هدف تنها از این جهت نمی‌تواند خواسته‌های کاربران را برآورده نماید. با توجه به همین مشکل یک الگوریتم چندهدفه مبتنی بر الگوریتم ژنتیک و الگوریتم تکاملی تفاضلی در این مقاله ارائه می‌شود که در الگوریتم پیشنهادی زمان کل، هزینه و تعادل بار به طور همزمان بررسی می‌گردد. در فاز جمعیت اولیه و ترکیب مجدد تنوع جمعیت اولیه با معرفی فاکتورهای مختلف فرد افزایش می‌یابد که می‌تواند مانع عبور افراد مشابه و رعایت قوانین درونی نسل‌های طبیعی شود. معرفی الگوریتم تکاملی تفاضلی در مرحله جهش الگوریتم ژنتیک می‌تواند نه تنها به مزایای قابلیت جستجوی سراسری الگوریتم ژنتیک منجر شود بلکه باعث سرعت بخشیدن به الگوریتم برای بهینه سازی راه حل با استفاده از قابلیت‌های جستجوی محلی و سرعت همگرایی سریع الگوریتم تکاملی تفاضلی می‌شود. نتایج شبیه‌سازی در کلودسیم نشان می‌دهد که این الگوریتم می‌تواند دو الگوریتم ژنتیک و تفاضلی را با توجه به کیفیت خدمات و تعادل بار ماشین مجازی در شرایط مشابه بهینه سازد و یک الگوریتم کارآمد برای زمانبندی وظایف در محیط ابر باشد. روش پیشنهادی را می‌توان تنها در محیط محاسبات پایدار استفاده کرد. درحالی‌که در دنیای واقعی، استفاده از منابع محاسباتی به صورت تمام وقت مفید نیستند. بنابراین بهتر است اهداف دیگری مانند استحکام، قابلیت اطمینان و امنیت علاوه بر اهداف مطالعه شده برای کارهای بعدی مورد توجه قرار گیرد.

در مقاله [۱۱] یک رویکرد تکاملی جدید و مؤثر، برای تخصیص ماشین‌های مجازی که می‌تواند بهره‌وری انرژی در مرکز داده ابری را با در نظر گرفتن ماشین‌های مجازی رزرو شده بیشتر به حداکثر رساند معرفی شده است. این رویکرد می‌تواند دسترسی سریع به یک راه حل تخصیص بهینه برای یک دسته از ماشین‌های مجازی رزرو شده را فراهم کند و در عین حال ماشین‌های مجازی بیشتری را با ماشین‌های فیزیکی کمتری تجمیع نماید تا بهینه‌سازی انرژی بهتری را در مقایسه با روش‌های موجود ایجاد نماید. در این مقاله به کاهش زمان اجرا و تعداد مهاجرت‌ها توجهی نشده است.

در مقاله [۱۲] یک رویکرد چندهدفه برای زمانبندی جریان کاری در محیط‌های ابری پیشنهاد شده است. در این تحقیق نویسنده یک الگوریتم ژنتیکی چند منظوره جدید برای زمانبندی جریان کار در محیط ابر ارائه داده است. نتایج شبیه سازی نشان می‌دهد که الگوریتم پیشنهادی نه تنها از نظر بودجه، مهلت و انرژی بهبود یافته بلکه در استفاده از منابع ابر نیز در مقایسه با الگوریتم‌های رقابتی بهبود یافته است. این مقاله به اهداف دیگری مانند سطح امنیتی، اعتماد و رضایت کاربر هنگام زمانبندی توجه نکرده است. همچنین باید تحمل خطا در هنگام ترسیم وظایف گردش کار به منابع ابری مورد توجه قرار گیرد.

در مقاله [۱۳] یک الگوریتم اکتشافی چندوجهی هیبریدی جدید مبتنی بر الگوریتم ژنتیکی<sup>۱۳</sup> (NSGA-II) و الگوریتم جستجوی گرانش<sup>۱۴</sup> (GSA) برای تسهیل انتخاب ماشین‌های مجازی برای زمانبندی وظایف ارائه کرده است. نتایج شبیه سازی نشان می‌دهد که الگوریتم پیشنهادی در مقایسه با سایر الگوریتم‌های زمانبندی چندهدفه عملکرد بهتری داشته و اهداف تعیین شده را برآورده می‌کند. در مسئله زمانبندی پویا عوامل دیگری مانند دما تأثیر دارند و سربار انرژی باید با جزئیات مورد بررسی قرار گیرد.

مقاله [۹] یک رویکرد ترکیبی از الگوریتم زمانبندی وظایف را که ترکیبی از ویژگی‌های مطلوب دو الگوریتم ابتکاری الهام گرفته از زیست شناسی می‌باشد، ارائه کرده است. این رویکرد ترکیبی از الگوریتم‌های ژنتیک و الگوریتم‌های جستجوی باکتری<sup>۱۲</sup> در رایانش

<sup>۱۲</sup> Non-dominated Sorting Genetic Algorithm-II

<sup>۱۳</sup> Gravitational Search Algorithm

<sup>۱۱</sup> Space Aware Best Fit Decreasing (SABFD)

<sup>۱۲</sup> Bacterial Foraging (BF) Algorithms

محاسبات مبتنی بر ابر، علی‌رغم مزایای بسیار زیاد آن، تأثیرات نامناسبی بر محیط زیست نیز دارد. انتشار گازهای گلخانه‌ای و انرژی مصرفی توسط مراکز داده ابر، مهمترین مسأله‌ای است که نیاز به توجه جدی دارد. تجمیع ماشین مجازی یک روش اساسی برای صرفه‌جویی در مصرف انرژی و استفاده بهینه از منابع می‌باشد. با این حال، رویکردهای تجمیع ماشین مجازی موجود بدون در نظر گرفتن عوامل کیفیت سرویس<sup>۱۹</sup> به طور تهاجمی باعث کاهش مصرف انرژی می‌شوند. برخلاف راه‌حل‌های موجود، راه حل ارائه شده در مقاله [۱۷]، یک چارچوب عمومی است زیرا، هم برای پردازنده و هم برای کارهای فشرده ورودی / خروجی کار می‌کند. اثربخشی چارچوب پیشنهادی با استفاده از مجموعه داده واقعی پلت‌فرم Planet Lab و CloudSim نشان داده شده است. راه‌حل پیشنهادی را می‌توان در مراکز داده ابری استفاده کرد تا محاسبات کارآمد انرژی را فعال نماید. این مقاله به معیارهای کیفیت سرویس و کاهش مهاجرت توجهی نکرده است.

آگاهی از انرژی، چالش بزرگی برای زیرساخت‌های رایانش ابری و توسعه مراکز داده نسل بعدی است. تجمیع ماشین‌های مجازی یکی از تکنیک‌هایی است که می‌تواند برای کاهش هزینه‌های مربوط به انرژی و مسائل پایداری زیست محیطی مراکز داده استفاده گردد. در زمان‌های اخیر ثابت شده است که رویکردهای یادگیری هوشمند برای مدیریت منابع در مراکز داده ابری مؤثر می‌باشند. در مقاله [۱۸] به بررسی کاربرد الگوریتم‌های یادگیری تقویتی<sup>۲۰</sup> (RL) برای مسأله تجمیع ماشین مجازی، که ظرفیت آن‌ها را برای بهینه‌سازی توزیع ماشین‌های مجازی در مرکز داده برای بهبود منابع نشان می‌دهد، پرداخته شده است. تعیین سیاست‌های کارآمد در محیط‌های پویا می‌تواند کار دشواری باشد، با این حال، روش پیشنهادی RL به دلیل توانایی ذاتی استدلال در عدم اطمینان در صورت عدم دانش کامل، رفتار بهینه را می‌آموزد. با استفاده از داده‌های بار کاری واقعی، یک تحلیل مقایسه‌ای از الگوریتم‌های محبوب RL از جمله SARSA و Q-learning ارائه داده شده است. نتایج تجربی نشان می‌دهند چگونه این رویکرد ۲۵٪ بهره‌وری انرژی را بهبود می‌بخشد در حالی که ۶۳٪ نقض خدمات را نسبت به الگوریتم اکتشافی محبوب انرژی آگاه کاهش می‌دهد. در این مقاله به معیارهای زمان و مهاجرت توجهی نشده است.

در مقاله [۱۴] یک الگوریتم زمانبندی را که از رفتار انگلی پرند فاخته تقلید می‌نماید، پیشنهاد شده است. فاخته‌ها با بهره‌گیری از لانه‌های دیگر پرندگان، تخم‌های مشابه با خود را تکثیر می‌کنند. الگوریتم زمانبندی فاخته پیشنهاد شده را تحت تعداد مختلفی از گره‌ها و درصد کارها با اولویت بالا ارزیابی می‌کند. نتایج تجربی نشان می‌دهد که الگوریتم پیشنهادی از نظر معیارهایی چون میانگین استفاده از پردازنده و متوسط زمان چرخش برای هر نوع کار برتری داشته است.

تخصیص، زمانبندی و کارایی انرژی موضوعات مهمی در سیستم‌های ابری می‌باشند. مقاله [۱۵] به تخصیص و زمانبندی جهت حداقل کردن تعداد سرورهای فعال پرداخته است. در این مقاله از الگوریتم کرم شب تاب جهت فرآیند تخصیص استفاده شده است. این الگوریتم متعلق به الگوریتم‌های تصادفی می‌باشد بدین معنا که یک نوع جستجوی تصادفی برای رسیدن به مجموعه‌ای از راه‌حل‌ها به کار برده می‌شود. مشخصه اصلی کرم‌های شب تاب نور چشمک زن آن‌ها است. کرم‌های شب تاب به سمت گرمی می‌روند که پرنورتر است. نتایج شبیه‌سازی نشان دهنده این است که روش ارائه شده در زمان اجرا بهبود داشته است. از معایب این مقاله می‌توان به عدم توجه به معیارهای انرژی و بهبود بهره‌وری از منابع نام برد.

رایانش ابری در دهه اخیر رشد سریعی داشته است، از این روی نگرانی فزاینده‌ای در مورد انرژی مورد نیاز مراکز ابر وجود دارد. یک روش برای حل این مسأله، تجمیع پویای ماشین مجازی<sup>۱۵</sup> (DVMC) است که در آن ماشین‌های مجازی (میزهای مجازی) در تعداد کمتری میزبان قرار می‌گیرند، در حالی که میزبانانی که ماشین مجازی ندارند در حالت خواب قرار داده می‌شوند. DVMC به طور سنتی با استراتژی‌هایی که بر اساس توپولوژی متمرکز ساخته می‌شوند، حل می‌شود. یکی از معایب این راه‌حل‌ها این است که آن‌ها در مراکز داده بسیار بزرگ مقیاس خوبی ندارند زیرا گره مدیر به یک تنگنا و یک نقطه خرابی تبدیل می‌شود. بر این اساس در مقاله [۱۶] قراردادهای شایعه پراکنی<sup>۱۶</sup> (GC) را که یک چارچوب جدید چند عاملی برای تهیه استراتژی‌های همکاری غیر متمرکز است پیشنهاد شده است. GC از پروتکل شایعه<sup>۱۷</sup> و پروتکل قرارداد خالص<sup>۱۸</sup> الهام گرفته است. با استفاده از GC، یک استراتژی GC مبتنی بر DVMC توسعه داده شده است و آن با دو استراتژی محبوب Sercon که متمرکز است و ecoCloud که استراتژی توزیع شده می‌باشد، مقایسه شده است. در این روش کاهش مصرف انرژی در نظر گرفته شده اما به مسأله سربار محاسباتی توجهی نشده است.

<sup>۱۸</sup> Contract Net Protocol (CNP)

<sup>۱۹</sup> Quality of Service (QoS)

<sup>۲۰</sup> Reinforcement Learning

<sup>۱۵</sup> Dynamic Virtual Machine Consolidation (DVMC)


<sup>۱۶</sup> Gossip Contracts (GC)

<sup>۱۷</sup> Gossip

### ۳. روش پیشنهادی

#### ۳.۱ کلیت روش پیشنهادی

الگوریتم تکاملی تفاضلی یک الگوریتم جدید اکتشافی است که دارای ویژگی‌های ساده و پارامترهای قابل تنظیم کمتر می‌باشد که برای حل انواع مسائل بهینه سازی پیچیده عددی و مهندسی منجر به نتایج رضایت بخشی شده است. از آنجائی که مسئله زمانبندی و تخصیص در محیط ابری یک مسئله پیچیده سخت است، بدین جهت کاربرد الگوریتم تکاملی تفاضلی در تخصیص منابع در محیط ابری می‌تواند کارایی را به طور قابل توجهی بهبود دهد. همچنین مسئله مصرف انرژی در سیستم‌های ابری مسئله مهمی است و باید منابع به شیوه‌ای مناسب مدیریت شوند و به گونه‌ای ماشین‌های مجازی به منابع محاسباتی تخصیص داده شوند که منابع دچار پرباری نشوند. با توجه به ماهیت الگوریتم تکاملی تفاضلی که به دنبال جواب بهینه هستند برای انتخاب میزبان مناسب برای تخصیص و جای‌دهی مناسب با هدف بهبود فرایند زمانبندی و کاهش مصرف انرژی از الگوریتم تکاملی تفاضلی استفاده می‌گردد. با توجه به این تعاریف روند کلی الگوریتم تکاملی تفاضلی در شکل ۱ نمایش داده شده است. این الگوریتم از چهار مرحله تشکیل شده است که در شکل زیر نمایش داده شده است.



شکل ۱. روند کلی الگوریتم تکاملی تفاضلی

در ادامه جزئیات روش پیشنهادی بیان شده است.

#### ۳.۱.۱ گام اول: ورودی‌های الگوریتم پیشنهادی

با توجه به شکل بالا، این الگوریتم دارای چهار مرحله اصلی شامل ورودی، جهش، تقاطع و انتخاب می‌باشد. برای حل مسئله پیشنهادی ابتدا به گام اول، ورودی‌ها در روش پیشنهادی می‌پردازیم. در گام اول ماشین‌های مجازی و میزبان‌های فیزیکی به عنوان مؤلفه‌های ورودی مسئله در نظر گرفته می‌شوند. بعد از اینکه ورودی‌های مسئله مشخص شد، بردارهایی از آنها تشکیل می‌گردد. بردارهای مسئله به تعداد ماشین‌های مجازی و میزبان‌های فیزیکی به عنوان جمعیت اولیه در نظر گرفته می‌شوند.

#### ۳.۱.۲ گام دوم: جهش در الگوریتم پیشنهادی

با توجه به بردارهای ایجاد شده در مرحله قبل، مشخصات ماشین‌های مجازی و مشخصات میزبان‌های فیزیکی به عنوان جمعیت اولیه برای ورودی الگوریتم تکاملی تفاضلی تعیین می‌گردد. با توجه به ورودی‌های ایجاد شده در مرحله قبل، به دنبال میزبان فیزیکی می‌گردیم که بتواند بهترین تخصیص برای ماشین‌های مجازی و درخواست‌ها به لحاظ منابع آزاد داشته باشد. هر چه پردازنده و حافظه

آزاد بیشتر باشد، احتمال پربار شدن سرور و مهاجرت اضافی که در افزایش زمان و مصرف انرژی تأثیرگذار است، کاهش پیدا می‌کند. در نتیجه برای در نظر گرفتن عملگر جهش از آنجا که این بردار در ابتدا بدترین حالت در نظر گرفته می‌شود، در نتیجه بردار جهش با مقدار موقت تابع هدف بیشتر مقادری می‌شود.

#### ۳.۱.۳ گام سوم: تقاطع در الگوریتم پیشنهادی

در هر مرحله از الگوریتم تکاملی تفاضلی بردار تقاطع محاسبه می‌شود. بردار تقاطع بر اساس تابع هدف سنجیده می‌شود و اگر مقدار تابع هدف کمتر از مقدار قبلی باشد، آنگاه در مرحله انتخاب، این مقدار جایگزین مقدار قبلی می‌گردد. این عملیات بر اساس تعداد منابع محاسباتی که در نظر گرفته شده است تکرار می‌شود تا به بهترین جواب برای به دست آوردن بهترین منبع محاسباتی دست یابد.

#### ۳.۱.۴ گام چهارم: انتخاب در الگوریتم پیشنهادی

در گام سوم، چنانچه مقدار تابع هدف محاسبه شده توسط بردار تقاطع کمتر از مقدار آن در بردار جهش باشد، آنگاه بردار تقاطع جایگزین بردار جهش از نسل قبل می‌گردد. این مرحله انتخاب نام دارد و توسط تابع هدف مشخص می‌گردد. تمامی مراحل جهش، تقاطع و انتخاب تکرار می‌گردد و در پایان بهترین جواب جایگزین بردار قبلی می‌شود. برای این منظور فرمول‌های زیر جهت تقاطع، توسط تابع هدف برای انتخاب بهترین منبع محاسباتی جهت تخصیص در نظر گرفته شده است.

$$\text{fitness} = \text{MIN} \left( \frac{\text{RequestedCPU}_{VM_i}}{\text{AllocatedCPU}_{PM_j}} + \frac{\text{RequestedRAM}_{VM_i}}{\text{AllocatedRAM}_{PM_j}} + w_{PM_j} \right) \quad (1)$$

$$i = 1, 2, \dots, N, j = 1, 2, \dots, M$$

در نتیجه رابطه (۱) برای تابع هدف در نظر گرفته شده است.

در رابطه (۱)،  $\text{RequestedCPU}_{VM_i}$  میزان پردازنده درخواست شده توسط ماشین مجازی  $i$  ام،  $\text{AllocatedCPU}_{PM_j}$  میزان پردازنده اختصاص داده شده به میزبان فیزیکی  $j$  ام،  $w_{PM_j}$  میزان بار استفاده شده توسط میزبان فیزیکی  $j$  ام،  $\text{RequestedRAM}_{VM_i}$  میزان حافظه درخواست شده توسط ماشین مجازی  $i$  ام،  $\text{AllocatedRAM}_{PM_j}$  میزان حافظه اختصاص داده شده توسط میزبان فیزیکی  $j$  ام می‌باشد.

بر اساس تابع هدف ارائه شده میزبانی که منابع بیشتری در اختیار ماشین مجازی قرار دهد میزبان مناسب‌تری برای جای‌دهی ماشین مجازی می‌باشد. در نتیجه بر اساس تابع هدف تعریف شده میزبانی که پردازنده آزاد و حافظه بیشتری در اختیار ماشین مجازی قرار دهد میزبان مناسب‌تری برای تخصیص می‌باشد. با توجه به تابع هدف ارائه شده در واقع میزبانی که منابع آزاد بیشتری دارد مناسب‌تر است و همچنین میزان حافظه بر روی زمان مهاجرت تأثیر دارد بر همین

$$MAD = \text{median}_i(|X_i - \text{median}_j(X_j)|) \quad (2)$$

MAD با انحراف میانگین داده‌ها شروع می‌شود و متوسط مقدار مطلق آنها است. بر این اساس حد بالای آستانه به صورت رابطه (۳) تعریف می‌شود که  $s \in R^+$  و امنیت روش را تنظیم می‌کند.

$$T_u = 1 - s \cdot MAD \quad (3)$$

### ۲.۲.۳ گام دوم: انتخاب ماشین مجازی

برای سیاست مهاجرت و انتخاب ماشین مجازی از میزبان پربار از سیاست حداقل زمان مهاجرت<sup>۲۴</sup> (MMT) استفاده می‌کنیم. این سیاست ماشین مجازی که، به کمترین زمان برای تکمیل یک مهاجرت نسبت به دیگر ماشین‌های مجازی تخصیص یافته به میزبان فیزیکی دارد، برای مهاجرت انتخاب می‌کند. زمان مهاجرت با مقدار حافظه استفاده شده توسط ماشین مجازی تقسیم بر پهنای باند شبکه در دسترس برای میزبان فیزیکی  $V_j$  محاسبه می‌شود. مجموعه‌ای از ماشین‌های مجازی می‌باشد که اخیراً به میزبان فیزیکی  $V_j$  تخصیص یافته است. سیاست MMT ماشین مجازی که در آن  $V$  شرایط فرمول ارائه شده در رابطه (۴) را برآورده کند، پیدا می‌کند [۱۹].

$$u \in V_j | \forall \alpha \in V_j. \frac{RAM_u(u)}{NET_j} \leq \frac{RAM_u(\alpha)}{NET_j} \quad (4)$$

$RAM_u(\alpha)$  مقدار RAM استفاده شده اخیر توسط ماشین مجازی  $\alpha$  می‌باشد.  $NET_j$  پهنای باند شبکه در دسترس برای میزبان فیزیکی  $V_j$  می‌باشد.

### ۲.۳ گام سوم: انتخاب میزبان فیزیکی

در نهایت برای انتخاب مقصد برای میزبانی ماشین‌های مجازی مهاجر از سیاست پیشنهادی جهت فرایند تخصیص و استفاده از الگوریتم تکاملی تفاضلی پیشنهاد شده استفاده می‌شود.

اساس در تابع هدف، استفاده از حافظه در نظر گرفته شده است. تابع هدف الگوریتم تکاملی تفاضلی با توجه به شرایط مسئله تکرار می‌شود تا بهترین جواب بهینه به دست آید و در نهایت میزبان فیزیکی که پردازنده آزاد و حافظه بیشتر دارد، برای تخصیص در نظر گرفته می‌شود. از آنجا که پردازنده بیشترین تأثیر را در مصرف انرژی دارد با در نظر گرفتن پردازنده در تابع هدف پیشنهادی باعث می‌شود میزبانی که پردازنده آزاد بیشتری دارد جهت تخصیص انتخاب شود در واقع این میزبان احتمال پربار شدن آن کمتر است و از مهاجرت اضافی که در افزایش زمان و انرژی مصرفی تأثیرگذار است جلوگیری می‌کند و همچنین از تعداد سرورهای فعال کمتری استفاده خواهد شد در نتیجه کاهش سرورها باعث کاهش مصرف انرژی نیز می‌شود.

### ۲.۳ تجمیع پویای ماشین مجازی

تجمیع پویای ماشین مجازی، ماشین‌های مجازی را در تعداد سرورهای کمتری قرار می‌دهد تا از منابع بهینه استفاده کند و مصرف انرژی را کاهش دهد. فرایند تجمیع پویای ماشین‌های مجازی بعد از تخصیص و جهت بهینه‌سازی آن صورت می‌گیرد که در حالت کلی به سه مرحله تقسیم می‌شود، که شامل:

**مرحله اول: شناسایی میزبان فیزیکی پربار، شناسایی میزبان‌های فیزیکی که دچار پرباری بیش از حد شده‌اند که نیاز به مهاجرت یک یا چند ماشین مجازی از این میزبان‌های فیزیکی برای جلوگیری از نقض کیفیت سرویس وجود دارد.**

**مرحله دوم: انتخاب ماشین مجازی، انتخاب ماشین مجازی مناسب جهت مهاجرت از منبعی که دچار پرباری شده است.**

**مرحله سوم: انتخاب میزبان فیزیکی، انتخاب مقصد مناسب برای جای‌دهی ماشین‌های مجازی مهاجر.**

### ۱.۲.۳ گام اول: شناسایی میزبان فیزیکی پربار

در مقاله [۱۹]، مصطفی و همکاران چهار مکانیزم آستانه پویا جهت تشخیص سرور پربار پیشنهاد کرده‌اند که شامل متوسط انحراف مطلق<sup>۲۱</sup> (MAD)، رگرسیون محلی<sup>۲۲</sup> (LR) و محدوده بین چارک<sup>۲۳</sup> (IQR) می‌باشد. در روش پیشنهادی جهت شناسایی سرورهای پربار برای جلوگیری از پرباری و نقض کیفیت سرویس از روش MAD استفاده شده است. ما MAD را به دلیل اینکه در مقایسه با مدل‌های خارجی مقاوم است، انتخاب کردیم. علاوه بر این، MAD از دانش قبلی برای ایجاد آستانه جدید استفاده می‌کند.

سیاست MAD یک تخمین‌گر قوی از واریانس نمونه یا انحراف استاندارد برای یک مجموعه داده تک متغیری  $X_1, X_2, \dots, X_n$  است. MAD به‌عنوان متوسط انحراف مطلق از میانگین داده‌ها تعریف می‌شود [۱۹]. در رابطه (۲) این سیاست بیان شده است.

<sup>۲۲</sup> Interquartile Range (IQR)

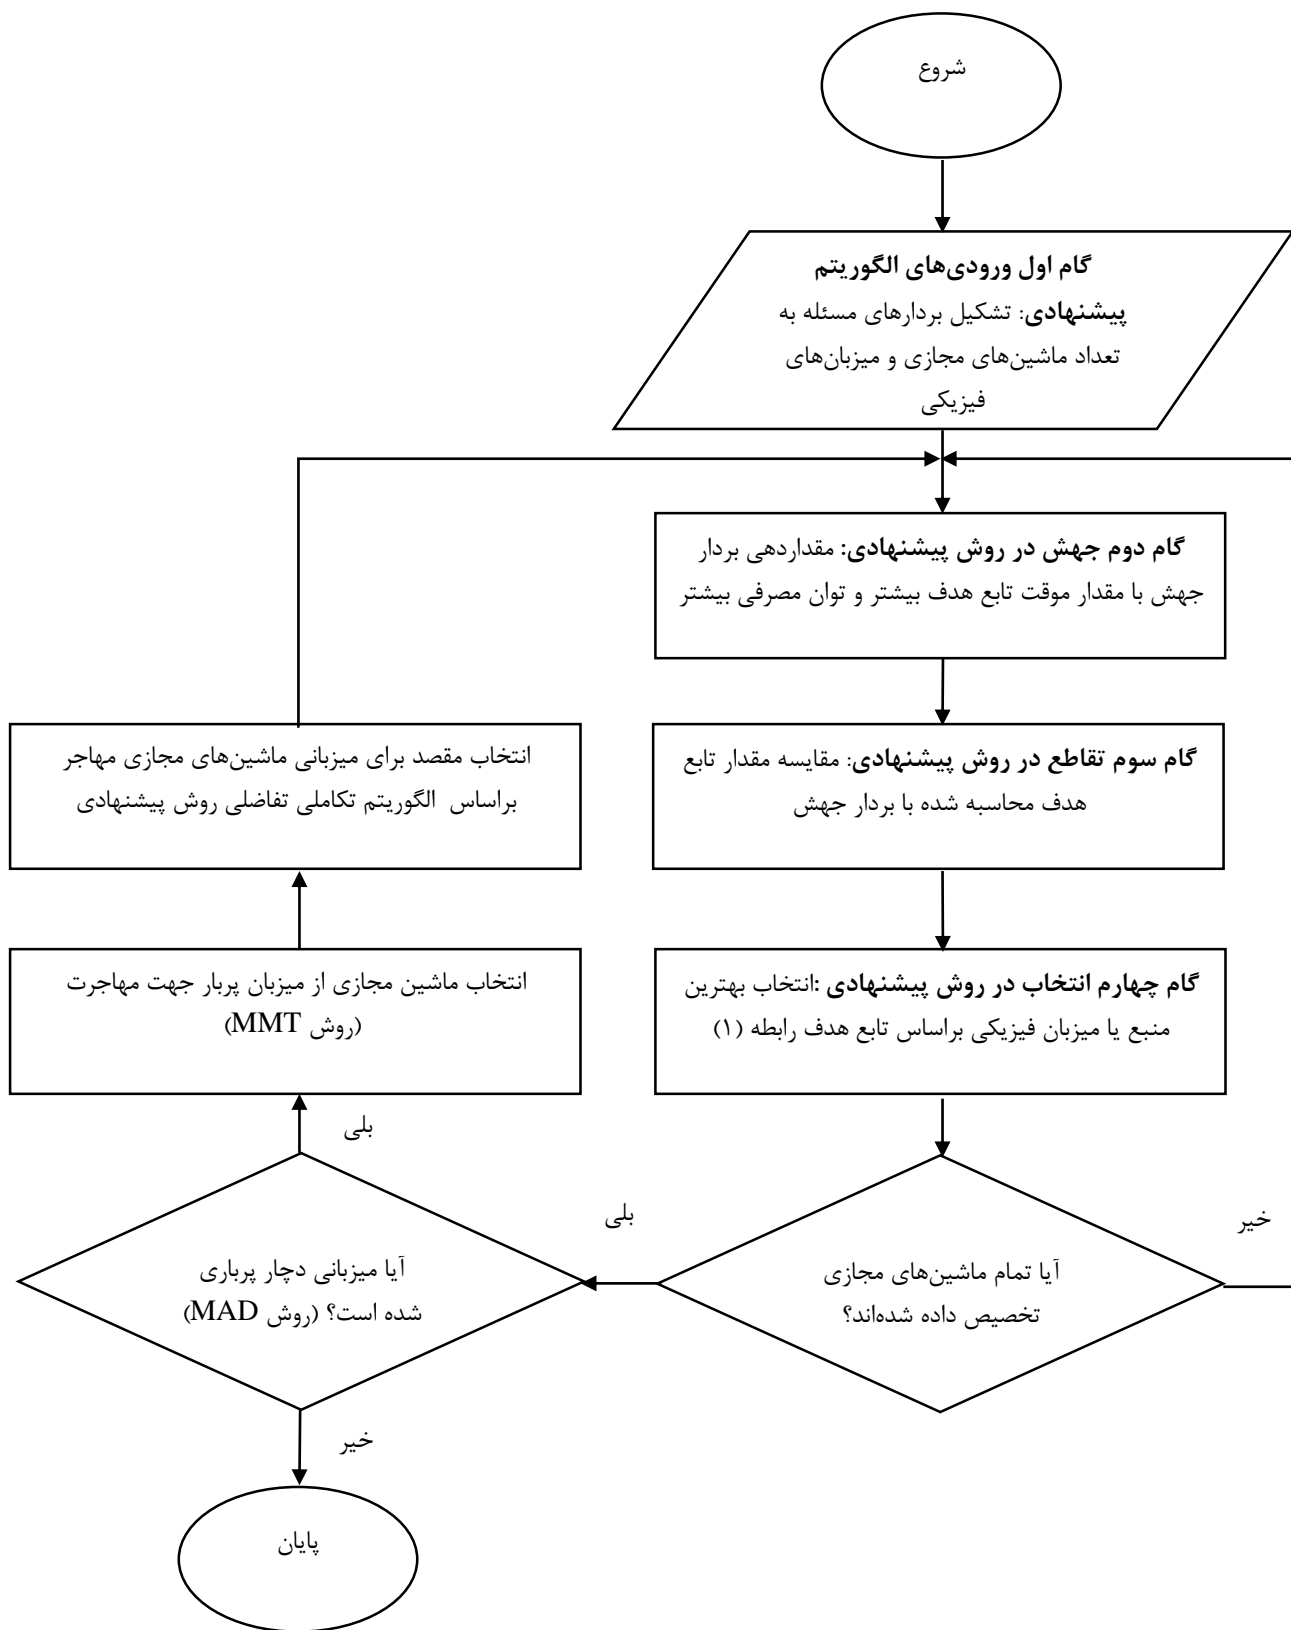
<sup>۲۴</sup> Minimum Migration Time (MMT)

<sup>۲۱</sup> Medium Absolute Deviation (MAD)

<sup>۲۲</sup> Local Regression (LR)

### ۳.۳ فلوجارت روش پیشنهادی

برای این منظور در شکل ۲ مراحل الگوریتم بیان شده است.



شکل ۲. فلوجارت روش پیشنهادی

در نتیجه کل مصرف انرژی مراکز داده ابری را می‌توان به عنوان مجموع عملکرد توان مصرفی همه میزبان‌ها تعریف کرد، همانطور که در رابطه (۷) نشان داده شده است.

بر اساس رابطه (۷) تعداد میزبان‌های فیزیکی و  $E_i$  توان مصرفی میزبان فیزیکی  $i$  ام می‌باشد.

در محیط ابری برای در نظر گرفتن کیفیت سرویس، معیاری به نام توافق‌نامه سطح سرویس (SLA) در نظر گرفته شده است. نقض توافق‌نامه سطح سرویس در محیط محاسبات ابری بسیار نامطلوب است و هزینه‌های سنگینی دارد. برای این منظور دو معیار برای اندازه‌گیری سطح نقض توافق‌نامه سطح سرویس در نظر گرفته می‌شود [۱۹].

- $SLATAH^{25}$  (نقض توافق‌نامه سطح سرویس میزبان فعال): زمانی که ماشین‌های فیزیکی فعال هستند و بهره ۱۰۰٪ پردازنده را تجربه می‌کنند و دچار پرباری می‌شوند.
- $PDM^{26}$  (نقض کارایی با توجه به مهاجرت): کاهش کارایی کل با مهاجرت ماشین‌های مجازی.

این دو معیار به صورت زیر تعریف می‌شوند:

$$SLATAH = \frac{1}{N} \sum_{i=1}^N \frac{T_{si}}{T_{ai}} \quad (8)$$

$$PDM = \frac{1}{M} \sum_{j=1}^M \frac{C_{dj}}{C_{rj}} \quad (9)$$

$N$  تعداد منابع محاسباتی،  $T_{si}$  زمان کل در زمانی که ماشین فیزیکی  $i$  ام بهره‌ی ۱۰۰٪ را متحمل می‌شود که نقض کیفیت سرویس را ایجاد می‌کند.  $T_{ai}$  زمان کل ماشین فیزیکی  $i$  ام که در حالت فعال است،  $M$  تعداد ماشین‌های مجازی،  $C_{dj}$  نقض کارایی ماشین مجازی  $j$  ام که با مهاجرت ایجاد می‌شود را برآورد می‌کند.  $C_{rj}$  کل ظرفیت پردازنده درخواست شده توسط ماشین مجازی  $j$  ام در زمان اجرای آن است. در آزمایشات  $C_{dj}$  با ۱۰٪ از بهره پردازنده در MIPS در طول همه مهاجرت‌های ماشین مجازی  $j$  ام برآورد شده است. از آنجا که هر دو معیار  $SLATAH$  و  $PDM$  به طور مستقل و با اهمیت برابر سطح توافق‌نامه سطح سرویس نقض شده را تعیین می‌کنند، بنابراین یک معیار ترکیبی که شامل هر دو نقض کارایی با توجه به ماشین فیزیکی پربار و با توجه به مهاجرت ماشین مجازی است در نظر گرفته می‌شود [۱۹].

$$SLAV = SLATAH * PDM \quad (10)$$

### ۴.۳ معیارهای ارزیابی روش پیشنهادی

برای این منظور معیارهایی که قصد داریم روش پیشنهادی خود را با آن مقایسه کنیم شامل انرژی مصرفی میزبان‌های فیزیکی، تعداد مهاجرت‌ها، نقض توافق‌نامه سطح سرویس و زمان اجرای کل می‌باشد. زمان اجرای کل موضوع مهمی است که با تخصیص، زمانبندی مناسب و استفاده بهینه از منابع می‌توانیم در بهبود این معیار تأثیرگذار باشیم. همچنین انرژی مصرفی میزبان‌های فیزیکی با تخصیص، جای‌دهی مناسب و استفاده بهینه از منابع قابل بهبود است. انرژی مصرفی شده مراکز داده ابری بر اساس بهره‌وری از پردازنده در نظر گرفته می‌شود. با توجه به اینکه استفاده از پردازنده نقش مهمی در انرژی مصرفی در مقایسه با منابع دیگر دارد. یک منبع فیزیکی بیکار تقریباً هفتاد درصد نسبت به میزبانی که از تمام بهره پردازنده خود استفاده می‌کند، انرژی مصرفی می‌کند [۱۸]. در نتیجه معیاری که برای انرژی مصرفی در نظر گرفته شده است، هم مربوط به زمانی که یک سرور بیکار است و هم مربوط به زمانی است که از پردازنده خود حداکثر استفاده را می‌کند. در نتیجه برای این منظور مصطفی و همکاران [۱۹] در سال ۲۰۱۸ فرمولی بر اساس بهره پردازنده برای اندازه‌گیری میزان انرژی مصرفی منابع فیزیکی ارائه کرده‌اند که در رابطه (۵) بیان شده است.

$$P(u) = 0.7 \times P_{max} + 0.3 \times P_{max} \times U \quad (5)$$

بر اساس رابطه (۵)،  $P_{max}$  حداکثر انرژی مصرفی شده هنگامی که یک منبع فیزیکی به طور کامل مورد استفاده قرار می‌گیرد می‌باشد. این معیار در آزمایشات مقدار ۲۵۰ وات در نظر گرفته می‌شود که یک مقدار مناسب برای منابع فیزیکی می‌باشد.  $U$  بهره‌وری از پردازنده است. با توجه به اینکه بهره‌وری از پردازنده با گذشت زمان تغییر می‌کند این معیار به صورت انتگرال بیان می‌شود. برای این منظور، بهره‌وری از پردازنده را به صورت تابعی از زمان بیان کرده‌اند که این فرمول در رابطه (۶) ارائه شده است [۱۹].

$$E_i = \int_{t_0}^{t_1} P(u(t_i)) dt \quad (6)$$

با توجه به رابطه ارائه شده مصرف کل انرژی توسط میزبان فیزیکی  $i$  ام به صورت انتگرال تابع مصرف انرژی روی یک دوره زمانی  $t$  تا  $t_1$  محاسبه می‌شود.  $u(t_i)$  میزان استفاده از پردازنده میزبان فیزیکی  $i$  ام را به صورت تابعی از زمان نشان می‌دهد.

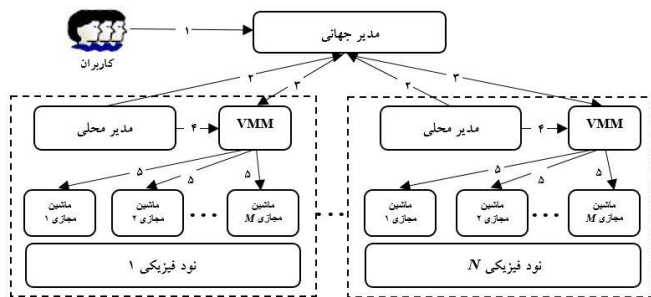
<sup>25</sup> Performance Degradation due to Migrations

<sup>26</sup> SLA violation Time per Active Host  

$$E_{DataCenter} = \sum_{i=0}^N E_i \quad (7)$$



ایجاد می کنند. این جریان کاری شامل انواع مختلفی از برنامه ها مانند رایانش سریع<sup>۲۸</sup> و وب اپلیکیشن ها که از منابع به طور همزمان استفاده می کنند می باشد [۲۰].



شکل ۴: معماری سیستم [۲۰]

لایه نرم افزاری سیستم شامل مدیران محلی و جهانی می باشد همان طور که در شکل ۴ نشان داده شده است. مدیران محلی درون هر نود به عنوان یک ماژول VMM قرار داده شده اند. هدف آنها مانیتور کردن مداوم استفاده از پردازنده توسط هر نود، تغییر اندازه ماشین های مجازی بر اساس نیاز منابع از آنها و تصمیم گیری در مورد اینکه چه زمانی و کدام ماشین مجازی باید از نود مهاجرت داده شود (۴). مدیر جهانی داخل نود اصلی قرار دارد و اطلاعات را از مدیران محلی برای برقرار نگه داشتن استفاده از منابع جمع آوری می کند (۲). مدیر محلی دستوراتی را برای بهینه سازی فرآیند تخصیص صادر می کند (۳). ماژول های VMM تغییر اندازه نهایی و مهاجرت ماشین های مجازی و همچنین تغییرات در میزان مصرف انرژی در هر نود را انجام می دهند (۵) [۲۰].

#### ۲.۴ معماری پردازنده

در این مقاله، معماری پردازنده های سرورهای فیزیکی چند هسته ای می باشند. در این معماری یک پردازنده چند هسته ای با تعداد  $n$  هسته که هر کدام  $m$  میلیون دستورالعمل را در ثانیه می توانند اجرا کنند به عنوان یک پردازنده تک هسته ای با ظرفیت کل اجرای  $nm$  میلیون دستورالعمل در ثانیه می باشد. این کار به صورت نرم افزاری انجام می شود و همچنین ماشین های مجازی به هسته های پردازشی وابسته نیستند و می توانند با استفاده از الگوریتم زمان بندی اشتراک زمانی با استفاده از یک هسته دلخواه اجرا شوند. تنها محدودیت این روش این است که ظرفیت پردازنده مورد نیاز برای یک ماشین مجازی باید کمتر و یا برابر با ظرفیت یک هسته باشد. زمانی که ظرفیت پردازنده مورد نیاز برای یک ماشین مجازی بیشتر از ظرفیت یک هسته باشد نیاز به موازی اجرا شدن آن می باشد. به دلیل اینکه اطلاعاتی از قبل در مورد برنامه های در حال اجرا روی ماشین های مجازی نداریم و همچنین موازی سازی خودکار یک مشکل پیچیده تحقیقاتی می باشد ما موازی اجرا شدن ماشین های مجازی را در نظر نمی گیریم [۲۰].

برای رویکرد پیشنهادی شبه کد زیر در نظر گرفته شده است.

#### Pseudo-code Algorithm

**Input:** hostList, vmList **Output:** allocation of VMs

- ۱) For each VM in VmList do
- ۲) allocatedHost ← NULL;
- ۳) MinFitness ← MAX;
- ۴) For each host in HostList do
- ۵) if host has enough resource for vm then
- ۶) fitness ←  $(\text{RequestedCPU}(\text{VM})/\text{AllocatedMipsForVm}(\text{PM})) + (\text{RequestedRAM}(\text{VM})/\text{AllocatedRAMForVm}(\text{PM})) + \text{host.getMaxUtilization}();$
- ۷) if fitness < MinFitness then
- ۸) MinFitness ← fitness;
- ۹) AllocatedHost ← host;
- ۱۰) end if
- ۱۱) end if
- ۱۲) if allocatedHost ≠ NULL then
- ۱۳) allocate vm to allocatedHost
- ۱۴) end if
- ۱۵) end for
- ۱۶) return allocation;
- ۱۷) end for

شکل ۳. شبه کد الگوریتم پیشنهادی

#### ۴. تجزیه و تحلیل

##### ۱.۴ معماری سیستم

در این مقاله، معماری سیستم هدف یک محیط زیرساخت به عنوان سرویس می باشد که توسط یک دیتاسنتر در مقیاس بزرگ که شامل  $N$  نود فیزیکی ناهمگن می باشد ارائه شده است. مشخصات هر نود شامل پردازنده، حافظه و پهنای باند می باشد. سرورها دیسک های داخلی ندارند. حافظه ذخیره سازی به صورت ذخیره ساز تحت شبکه<sup>۲۷</sup> ارائه شده است که برای مهاجرت ماشین های مجازی به صورت آنلاین استفاده می شود. کاربران مستقل از هم درخواست هایی را ارسال می کنند که برای اجرای این درخواست ها نیاز به  $M$  ماشین مجازی ناهمگن با مشخصات مورد نیاز از پردازنده، حافظه و پهنای باند می باشد. کاربران به صورت مستقل از هم جریان های کاری متنوعی

<sup>۲۸</sup> High Performance Computing (HPC)

<sup>۲۷</sup> Network Attached Storage (NAS)

#### ۳.۴ شبیه‌سازی

می‌شود. مشخصات انواع ماشین‌های مجازی استفاده شده در جدول ۲ آورده شده است. ماشین‌های مجازی از نظر سرعت پردازش و میزان حافظه متفاوت می‌باشند. همانطور که در جدول ۲ نشان داده شده است.

جدول ۲. مشخصات ماشین‌های مجازی در شبیه‌سازی

میزبان فیزیکی	سرعت پردازش (MIPS)	حافظه (MB)	تعداد هسته	پهنای باند (Gbit / s)	سایز (GB)
HP ProLiant ML110 G4	۱۸۶۰	۴۰۹۶	۲	۱	۱
HP ProLiant ML110 G5	۲۶۶۰	۴۰۹۶	۲	۱	۱

حجم کاری استفاده شده، حجم کاری واقعی می‌باشد که توسط داده‌های Planet Lab در ده روز مختلف دریافت شده است [۲۴]. این داده‌ها از داده‌های استفاده از پردازنده توسط بیش از ۱۰۰۰ ماشین مجازی در یک زمان از سرورهای واقع در بیش از ۵۰۰ مکان آورده شده است. برای این منظور، به طور تصادفی ۱۰ روز از بین جریان کار جمع‌آوری شده در ماه‌های مارس و آوریل ۲۰۱۱ انتخاب شده است. مشخصات داده‌ها در جدول ۳ نمایش داده شده است.

جدول ۳. مشخصات داده‌های جریان کار

تاریخ	تعداد ماشین‌های مجازی	Median	St. Dev
۲۰۱۱/۰۳/۰۳	۱۰۵۲	۶٪	۱۷٪/۰۹
۲۰۱۱/۰۳/۰۶	۸۹۸	۵٪	٪۱۶/۸۳
۲۰۱۱/۰۳/۰۹	۱۰۶۱	۴٪	٪۱۵/۵۷
۲۰۱۱/۰۳/۲۲	۱۵۱۶	۵٪	٪۱۲/۷۸
۲۰۱۱/۰۳/۲۵	۱۰۷۸	۶٪	٪۱۴/۱۴
۲۰۱۱/۰۴/۰۳	۱۴۶۳	۶٪	٪۱۶/۵۵
۲۰۱۱/۰۴/۰۹	۱۳۵۸	۶٪	٪۱۵/۰۹
۲۰۱۱/۰۴/۱۱	۱۲۳۳	۶٪	٪۱۵/۰۷
۲۰۱۱/۰۴/۱۲	۱۰۵۴	۶٪	٪۱۵/۱۵
۲۰۱۱/۰۴/۲۰	۱۰۳۳	۴٪	٪۱۵/۲۱

ارزیابی الگوریتم پیشنهادی در زیرساخت مراکز داده ابری در مقیاس بزرگ و بر روی یک زیرساخت واقعی بسیار دشوار می‌باشد. در نتیجه برای اطمینان از تکرار آزمایش‌ها، شبیه‌سازها به عنوان راهی برای ارزیابی عملکرد پیشنهادی انتخاب شده‌اند. ابزار کلودسیم<sup>۲۹</sup> به عنوان یک بستر شبیه‌سازی انتخاب شده است [۲۱]. زیرا یک چارچوب شبیه‌سازی مدرن می‌باشد که برای محاسبات ابری طراحی شده است. این ابزار برخلاف سایر ابزارهای شبیه‌سازی، امکان مدل‌سازی محیط‌های مجازی، پشتیبانی از تأمین منابع درخواستی و مدیریت آنها را فراهم می‌کند. این شبیه‌ساز برای برنامه‌های آگاه از انرژی<sup>۳۰</sup> نیز توسعه یافته است. جدا از مدل‌سازی مصرف انرژی، قابلیت شبیه‌سازی برنامه‌های کاربردی با حجم کاری پویا نیز گنجانده شده است. برای ارزیابی روش پیشنهادی از حجم کاری دنیای واقعی برای ارزیابی بهتر، استفاده کرده‌ایم. حجم کاری استفاده شده، حجم کاری واقعی می‌باشد که توسط داده‌های Planet Lab ایجاد شده است. در نتیجه در ابزار کلودسیم، ما یک مرکز داده شبیه به ۸۰۰ گره فیزیکی ناهمگن را شبیه‌سازی کرده‌ایم که نیمی از آنها سرورهای HP ProLiant ML110 G4 می‌باشند و نیمی دیگر سرورهای HP ProLiant ML110 G5 می‌باشند. مشخصات این سرورها بر اساس [۲۲] در جدول ۱ آورده شده است. هر دسته از سرورها دارای سرعت پردازش، میزان حافظه، تعداد هسته و پهنای باند متفاوتی می‌باشند.

جدول ۱. مشخصات میزبان‌های فیزیکی در شبیه‌سازی

ماشین مجازی	Extra-large instance	Small instance	Micro instance
سرعت پردازش (MIPS)	۲۰۰۰	۱۰۰۰	۵۰۰
حافظه (MB)	۳۷۵۰	۱۷۰۰	۶۱۳
پهنای باند (Gbit / s)	۱	۱	۱
سایز (GB)	۲,۵	۲,۵	۲,۵

مشخصات انواع ماشین‌های مجازی استفاده شده بر اساس نمونه‌های واقعی آمازون EC2 می‌باشد [۲۳]. با این تفاوت که همه ماشین‌های مجازی تک هسته‌ای هستند زیرا داده‌های حجم کاری مورد استفاده برای شبیه‌سازی از ماشین‌های مجازی تک هسته‌ای استفاده می‌کنند. در ابتدا، ماشین‌های مجازی با توجه به منابع مورد نیاز تخصیص داده می‌شوند. با این حال، در طول عمر شبیه‌سازی ماشین‌های مجازی با توجه به حجم کار از منابع کمتری استفاده می‌کنند و فرصت‌هایی برای تجمع ماشین‌های مجازی ایجاد

<sup>۳۰</sup> Energy-Aware


<sup>۲۹</sup> CloudSim

فضای ابری می‌باشد که در رویکرد ارائه شده سعی می‌شود بر اساس تابع سودمندی چندهدفه تعریف شده و در نظر گرفتن بردارهای جهش و تقاطع بر اساس بهره‌وری از منابع و انرژی مصرفی، قصد داریم با استفاده بهینه از منابع و بهبود بهره‌وری در کاهش زمان اجرای کل کارها، انرژی مصرفی، تعداد مهاجرت‌ها و نقض کیفیت سرویس تأثیرگذار باشیم. برای بررسی روش پیشنهادی و روش‌های مورد مقایسه از شبیه‌ساز کلودسیم استفاده شده است.

در ادامه نمودارهای حاصل از شبیه‌سازی بر روی داده‌های Planet Lab برای پارامترهای کیفیت سرویس مورد نظر آورده شده است.

#### ۴.۵.۱ بررسی انرژی مصرفی

معیار انرژی مصرفی میزان اتلاف انرژی کل مراکز داده که شامل مجموع انرژی میزبان‌های فیزیکی می‌باشد را نمایش می‌دهد. این اتلاف انرژی، ناشی از اجرای وظایف مورد نظر بر روی هسته‌های پردازشی مختلف است. شکل ۵، انرژی مصرفی روش پیشنهادی DEO و روش‌های مورد مقایسه را بر روی داده‌های Planet Lab نمایش می‌دهد



شکل ۵. انرژی مصرفی

انتخاب شود در واقع این میزان احتمال پربار شدن آن کمتر است و از مهاجرت اضافی که در افزایش انرژی مصرفی تأثیرگذار است جلوگیری می‌کند و همچنین از تعداد سرورهای فعال کمتری استفاده خواهد شد. در نتیجه ما توانسته‌ایم مصرف انرژی را در مقایسه با مقالات مورد مطالعه کاهش دهیم. انرژی مصرفی در روش پیشنهادی DEO به میزان ۱۷٪ نسبت به روش IqrMc، ۴۶٪ نسبت به روش LrMmt و ۸٪ نسبت به روش FA بهبود داشته است.

#### ۴.۵.۲ بررسی تعداد مهاجرت‌ها


یکی از مهمترین عواملی که بر مصرف انرژی و نقض توافق‌نامه سطح سرویس تأثیر می‌گذارد تعداد مهاجرت‌ها می‌باشد. شکل ۶ مقایسه بین روش DEO با IqrMc، LrMmt و FA از نظر تعداد مهاجرت‌ها را نمایش می‌دهد.

الگوریتم پیشنهادی و روش مورد مقایسه با استفاده از محیط توسعه نت‌بینز در نرم‌افزار کلودسیم ورژن ۳ کد نویسی شده‌اند و در سیستم عامل ویندوز ۶۴ بیتی و با حافظه ۸G اجرا گردیده است.

#### ۴.۴ نتایج شبیه‌سازی

معیارها و پارامترهای کیفیت سرویسی که در روش پیشنهادی در نظر گرفته شده است، انرژی مصرفی، تعداد مهاجرت‌ها، نقض توافق‌نامه سطح سرویس و زمان اجرای کل کارها می‌باشند. کارهایی که جهت مقایسه در نظر گرفته شده است روش IqrMc و روش LrMmt در مقاله [۲۰] و روش FA در مقاله [۱۴] می‌باشد. علت انتخاب این روش‌ها سازگاری بیشتر روش‌های مورد مقایسه با محیط شبیه‌سازی و استفاده از الگوریتم‌های فرا اکتشافی و غیر فرا اکتشافی می‌باشد. ایده و روش پیشنهاد شده در این مقاله، رویکردی جدید مبتنی بر الگوریتم تکاملی تفاضلی برای حل مساله تخصیص در

با توجه به شکل ۵، روش پیشنهادی کمترین میزان مصرف انرژی در بین سایر الگوریتم‌ها در تمام ده روز را دارا می‌باشد. داده‌ها در زمان‌های متفاوتی بر روی محور افقی و انرژی مصرفی برحسب کیلو وات بر روی محور عمودی نشان داده شده است. با توجه به نمودار فوق مشخص است که، عملکرد روش پیشنهادی DEO در کاهش انرژی مصرفی در مقایسه با روش‌های مورد مقایسه IqrMc، LrMmt، FA بهتر می‌باشد. همانطور که در نمودار بالا نمایش داده می‌شود در روش پیشنهادی سعی شده است با استفاده از الگوریتم تکاملی تفاضلی تخصیص مؤثر و مناسبی از منابع محاسباتی انجام شود. از آنجایی که پردازنده بیشترین تأثیر را در مصرف انرژی دارد در رویکرد ارائه شده که بر اساس تابع سودمندی چندهدفه تعریف شده است با در نظر گرفتن پردازنده در تابع هدف پیشنهادی باعث می‌شود میزبانی که پردازنده آزاد بیشتری دارد جهت تخصیص




شکل ۶. تعداد مهاجرت‌ها

تعداد مهاجرت‌ها در مقایسه با مقالات مورد مطالعه نسبت به روش IqrMc به میزان ۲۳٪، نسبت به روش LrMmt به میزان ۵۱٪ و نسبت به روش FA به میزان ۱۳٪ بهبود داشته باشد.

#### ۴.۵.۳ بررسی زمان اجرای کل

یکی دیگر از اهداف الگوریتم پیشنهادی، به حداقل رساندن زمان اجرای کل می‌باشد. شکل ۷، زمان اجرای کل روش پیشنهادی و روش مقالات مورد مقایسه را بر روی داده‌های Planet Lab نمایش می‌دهد.

در نمودار بالا مشاهده می‌شود که روش DEO حداقل تعداد مهاجرت را در تمام ده روز دارد. از آنجایی که میزان حافظه بر روی مهاجرت تأثیر دارد در رویکرد ارائه شده که بر اساس تابع سودمندی چندهدفه تعریف شده است با در نظر گرفتن حافظه در تابع هدف پیشنهادی باعث می‌شود میزبانی که حافظه آزاد بیشتری دارد جهت تخصیص انتخاب شود در واقع این میزبان احتمال پر بار شدن آن کمتر است و از مهاجرت‌های اضافی جلوگیری می‌کند و در انتخاب مقصد مناسب برای تجمیع با استفاده از تابع هدف چند معیاره در الگوریتم پیشنهادی از مهاجرت‌های اضافی جلوگیری می‌کند. در نتیجه در روش پیشنهادی ما توانسته‌ایم تعداد مهاجرت‌ها را در مقایسه با مقالات مورد مقایسه کاهش دهیم. شکل ۶ تعداد مهاجرت‌ها را در این ده روز نمایش می‌دهد. رویکرد ارائه شده بر اساس تابع سودمندی چندهدفه تعریف شده توانسته است در کاهش




شکل ۷. زمان اجرای کل

روش LrMmt به میزان ۴۶٪ و نسبت به روش FA به میزان ۱۸٪ بهبود داشته است.

#### ۴.۵.۴ بررسی نقض توافق نامه سطح سرویس

یکی دیگر از معیارهای مهم که در بهبود بهره‌وری سیستم‌های ابری نقش حیاتی دارد، معیار کیفیت سرویس می‌باشد که در شرکت‌های ارائه دهنده ابر نقش بسیار مهمی دارد. هر چه بتوانیم در شناسایی سرور پر بار در تجمیع روش مناسب‌تری را ارائه دهیم بهتر می‌توانیم در کاهش نقض توافق نامه سطح سرویس که به معیارهای تعداد مهاجرت‌ها و پربار بودن سرورها بستگی دارد، تأثیرگذار باشیم. شکل ۸ نتایج ارزیابی میانگین نقض توافق نامه سطح سرویس روش پیشنهادی و سایر روش‌ها را در روزهای مختلف بر روی داده‌های Planet Lab نمایش می‌دهد.

با توجه به شکل ۷، روش پیشنهادی کمترین میزان زمان اجرای کل در بین سایر الگوریتم‌ها در بین روزهای مختلف را دارا می‌باشد. داده‌ها در روزهای متفاوت بر روی محور افقی و زمان اجرا بر حسب ثانیه بر روی محور عمودی نشان داده شده است. با توجه به نمودار فوق مشخص می‌باشد که، عملکرد روش پیشنهادی DEO در کاهش زمان اجرای کل در مقایسه با روش‌های مورد مقایسه IqrMc، LrMmt و FA بهتر می‌باشد. در رویکرد ارائه شده که بر اساس تابع سودمندی چندهدفه تعریف شده است با در نظر گرفتن پردازنده و حافظه در تابع هدف پیشنهادی باعث می‌شود میزبانی که پردازنده آزاد و حافظه بیشتری دارد جهت تخصیص انتخاب شود در واقع این میزبان احتمال پربار شدن آن کمتر است و از مهاجرت اضافی که در افزایش زمان اجرای کل تأثیرگذار است جلوگیری می‌کند و از تعداد سرورهای فعال کمتری استفاده خواهد شد که باعث بهینه‌سازی فرآیند تخصیص می‌شود. در نتیجه زمان اجرای کل در روش پیشنهادی DEO نسبت به روش IqrMc به میزان ۲۳٪، نسبت به



شکل ۸. میانگین نقض توافق نامه سطح سرویس

برای به حداکثر رساندن مزایای ارائه دهندگان خدمات ابری، لازم است مصرف انرژی بدون هیچ گونه عارضه جانبی یا تضعیف توافق نامه سطح سرویس در مراکز ابری کاهش پیدا کند. الگوریتم‌های متنوعی برای تخصیص وظایف به منابع در محیط ابر پیشنهاد شده است که اغلب آن‌ها معیارهایی همچون توزیع بار متعادل، تخصیص بهینه‌ی منابع، کاهش زمان اجرا و کاهش انرژی مصرفی را در نظر نمی‌گیرند. برای بهبود انرژی مصرفی علاوه بر فرآیند تخصیص، مدیریت منابع با استفاده از تجمیع ماشین‌های مجازی نقش مؤثری را در محاسبات ابری ایفا می‌کند. به همین دلیل به منظور زمانبندی و تخصیص بهینه وظایف به منابع در محیط ابر یک رویکرد مبتنی بر الگوریتم تکاملی تفاضلی چندهدفه برای مساله زمانبندی کارها، حل مساله تخصیص و بهبود بهره‌وری از منابع در محیط رایانش ابری ارائه می‌شود. در روش پیشنهادی سعی می‌شود که بر اساس تابع

با توجه به شکل ۸، روش پیشنهادی DEO در تاریخ‌های ۳/۹/۲۰۱۱ و ۴/۲۰/۲۰۱۱ نتوانسته عملکرد بهتری را نسبت به سایر الگوریتم‌ها نشان دهد. میزان درصد میانگین نقض توافق نامه سطح سرویس بر روی محور عمودی نمایش داده شده است. با توجه به نمودار فوق مشخص می‌باشد که عملکرد روش DEO در کاهش نقض توافق نامه سطح سرویس در اکثر روزها در مقایسه با روش‌های مورد مقایسه بهتر می‌باشد. دلیل این کاهش تخصیص مناسب و جلوگیری از پرباری و کاهش مهاجرت‌های اضافی با تعریف تابع هدف چند معیاره پیشنهادی می‌باشد. در نتیجه در روش پیشنهادی ما نتوانسته‌ایم نسبت به روش IqrMc به میزان ۱٪، نسبت به روش LrMmt به میزان ۲٪ و نسبت به روش FA به میزان ۱٪ در کاهش نقض توافق نامه سطح سرویس تأثیرگذار باشیم.

#### ۵. نتیجه‌گیری و پیشنهادات

37th Chinese Control Conference (CCC), 2018: IEEE, pp. 4489-4494.

[4] E. H. Houssein, A. G. Gad, Y. M. Wazery, and P. N. Suganthan, "Task scheduling in cloud computing based on meta-heuristics: Review, taxonomy, open challenges, and future trends," *Swarm and Evolutionary Computation*, vol. 62, p. 100841, 2021.

[5] E. Arianyan, H. Taheri, and V. Khoshdel, "Novel fuzzy multi objective DVFS-aware consolidation heuristics for energy and SLA efficient resource management in cloud data centers," *Journal of Network and Computer Applications*, vol. 78, pp. 43-61, 2017.

[6] D. Maharana, B. Sahoo, and S. Sethi, "Energy-efficient real-time tasks scheduling in cloud data centers," *International Journal of Science Engineering and Advance Technology, IJSEAT*, vol. 4, no. 12, pp. 78-773, 2017.

[7] H. Wang and H. Tianfield, "Energy-aware dynamic virtual machine consolidation for cloud datacenters," *IEEE Access*, vol. 6, pp. 10209-10273, 2018.

[8] Y. Li, S. Wang, X. Hong, and Y. Li, "Multi-objective task scheduling optimization in cloud computing based on genetic algorithm and differential evolution algorithm." pp. 4489-4494.

[9] S. Srichandan, T. A. Kumar, and S. Bibhudatta, "Task scheduling for cloud computing using multi-objective hybrid bacteria foraging algorithm," *Future Computing and Informatics Journal*, vol. 3, no. 2, pp. 210-230, 2018.

[10] J. Li, J. Liu, and J. Wang, "An improved differential evolution task scheduling algorithm based on cloud computing," in 2018 11th International Symposium on Distributed Computing and Applications for Business Engineering and Science (DCABES), 2018: IEEE, pp. 30-35.

[11] X. Zhang et al., "Energy-aware virtual machine allocation for cloud with resource reservation," *Journal of Systems and Software*, vol. 147, pp. 147-161, 2019.

[12] A. Rehman, S. S. Hussain, Z. ur Rehman, S. Zia, and S. Shamshirband, "Multi-objective approach of energy efficient workflow scheduling in cloud environments,"

سودمندی چندهدفه تعریف شده و در نظر گرفتن بردارهای جهش و تقاطع بر اساس بهره‌وری از منابع و انرژی مصرفی قصد داریم در کاهش اهدافی چون زمان اجرای کل و مصرف انرژی تأثیرگذار باشیم. ما الگوریتم پیشنهادی را از طریق شبیه‌سازی‌های گسترده در شبیه‌ساز کلودسیم با آزمایش بر روی حجم کار بیش از هزار ماشین مجازی بر روی داده‌های Planet Lab ارزیابی کرده‌ایم. نتایج شبیه‌سازی نشان دهنده این می‌باشد که الگوریتم پیشنهادی توانسته است معیارهای مصرف انرژی را نسبت به سه الگوریتم مورد مقایسه به طور میانگین به میزان 23 درصد، تعداد مهاجرت‌ها را به طور میانگین به میزان 29 درصد، زمان اجرای کل را به طور میانگین به میزان 29 درصد، نقص توافق‌نامه سطح سرویس را به طور میانگین به میزان 1 درصد نسبت به روش‌های مورد مقایسه بهبود دهد. در این صورت استفاده از رویکرد پیشنهادی در مراکز ابری منجر به سرویس‌های بهتر و مناسب به مشتریان این مراکز خواهد شد. لذا برای کارهای آینده در راستای این پژوهش در نظر داریم موارد زیر را مورد مطالعه قرار دهیم:

- استفاده از چند الگوریتم فرا ابتکاری به صورت ترکیبی با استفاده از تابع هدف ارائه شده در روش پیشنهادی.
- ترکیب پردازش ابری با پردازش مه به منظور جلوگیری از تأخیر و استفاده از تابع هدف ارائه شده در روش پیشنهادی به منظور تخصیص کارآمدتر.
- در نظر گرفتن معیارهای نقض کیفیت سرویس و چارچوب‌های امنیتی در روش پیشنهادی.
- بررسی روش پیشنهادی در شبکه‌های خودرویی به منظور بهبود انرژی و کاهش هزینه.
- ترکیب روش پیشنهادی با شبکه‌های مه و اینترنت اشیا به منظور بهبود بهره‌وری و کاهش هزینه‌ها در این شبکه‌ها.

## مراجع

[1] H. Yuan, J. Bi, and M. Zhou, "Spatial task scheduling for cost minimization in distributed green cloud data centers," *IEEE Transactions on Automation Science and Engineering*, vol. 16, no. 2, pp. 729-740, 2018.

[2] A. Arunarani, D. Manjula, and V. Sugumaran, "Task scheduling techniques in cloud computing: A literature survey," *Future Generation Computer Systems*, vol. 91, pp. 407-415, 2019.

[3] Y. Li, S. Wang, X. Hong, and Y. Li, "Multi-objective task scheduling optimization in cloud computing based on genetic algorithm and differential evolution algorithm," in 2018

- Practice and experience*, vol. ۴۱, no. ۱, pp. ۲۳-۵۰, ۲۰۱۱.
- [۲۲] Standard Performance Evaluation Corporation.  
[https://www.spec.org/power\\_ssj/2008/results/](https://www.spec.org/power_ssj/2008/results/)
- [۲۳] Amazon EC2 Instance Types.  
<https://aws.amazon.com/ec2/instance-types/>
- [۲۴] K. Park and V. S. Pai, "CoMon: a mostly-scalable monitoring system for PlanetLab," *ACM SIGOPS Operating Systems Review*, vol. ۴۰, no. ۱, pp. ۶۵-۷۴, ۲۰۰۶.
- Concurrency and Computation: Practice and Experience*, vol. ۳۱, no. ۸, p. e۴۹۴۹, ۲۰۱۹.
- [۱۳] K. Naik, G. Meera Gandhi, and S. Patil, "Multiobjective virtual machine selection for task scheduling in cloud computing," in *Computational Intelligence: theories, applications and future directions-volume I*: Springer, ۲۰۱۹, pp. ۳۱۹-۳۳۱.
- [۱۴] E. Aloboud and H. Kurdi, "Cuckoo-inspired job scheduling algorithm for cloud computing," *Procedia Computer Science*, vol. ۱۵۱, pp. ۱۰۷۸-۱۰۸۳, ۲۰۱۹.
- [۱۵] M. Aruna, D. Bhanu, and S. Karthik, "An improved load balanced metaheuristic scheduling in cloud," *Cluster Computing*, vol. ۲۲, no. ۵, pp. ۱۰۸۷۳-۱۰۸۸۱, ۲۰۱۹.
- [۱۶] N. Mc Donnell, E. Howley, and J. Duggan, "Dynamic virtual machine consolidation using a multi-agent system to optimise energy efficiency in cloud computing," *Future Generation Computer Systems*, vol. ۱۰۸, pp. ۲۸۸-۳۰۱, ۲۰۲۰.
- [۱۷] N. Khattar, J. Singh, and J. Sidhu, "An energy efficient and adaptive threshold VM consolidation framework for cloud environment," *Wireless Personal Communications*, vol. ۱۱۳, no. ۱, pp. ۳۴۹-۳۶۷, ۲۰۲۰.
- [۱۸] R. Shaw, E. Howley, and E. Barrett, "Applying reinforcement learning towards automating energy efficient virtual machine consolidation in cloud data centers," *Information Systems*, vol. ۱۰۷, p. ۱۰۱۷۲۲, ۲۰۲۲.
- [۱۹] S. Mustafa, K. Bilal, S. U. R. Malik, and S. A. Madani, "SLA-aware energy efficient resource management for cloud environments," *IEEE Access*, vol. ۶, pp. ۱۵۰۰۴-۱۵۰۲۰, ۲۰۱۸.
- [۲۰] A. Beloglazov and R. Buyya, "Optimal online deterministic algorithms and adaptive heuristics for energy and performance efficient dynamic consolidation of virtual machines in cloud data centers," *Concurrency and Computation: Practice and Experience*, vol. ۲۴, no. ۱۳, pp. ۱۳۹۷-۱۴۲۰, ۲۰۱۲.
- [۲۱] R. N. Calheiros, R. Ranjan, A. Beloglazov, C. A. De Rose, and R. Buyya, "CloudSim: a toolkit for modeling and simulation of cloud computing environments and evaluation of resource provisioning algorithms," *Software:*

ارائه رویکرد مبتنی بر الگوریتم تکاملی تفاضلی چندهدفه برای مسئله تخصیص منبع در محیط رایانش ابری