

Combining predictive models with heuristic methods for VM placement to reduce SLA violations in the cloud environment

Negin Najafizadegan¹, Eslam Nazemi^{2*} and Vahid Khajehvand³

1- Faculty of Computer and Information Technology Engineering, Qazvin Branch, Islamic Azad University, Qazvin, Iran.

2*- Faculty of Computer Engineering and Science, Shahid Beheshti University, Tehran, Iran.

3- Faculty of Computer and Information Technology Engineering, Qazvin Branch, Islamic Azad University, Qazvin, Iran.

¹negin_najafizadegan@yahoo.com, ^{2*}nazemi@sbu.ac.ir, and ³vahidkhajehvand@gmail.com

Corresponding author's address: Eslam Nazemi, Faculty of Computer Engineering and Science, Shahid Beheshti University, Tehran, Iran.

Abstract- Today, with the rise of cloud data centers, power consumption has increased and cloud infrastructure management has become more complex. On the other hand, meeting the needs of cloud users is an important goal in cloud infrastructure. The process of determining the load status of physical machines and placing virtual machines on suitable physical machines can reduce energy consumption and prevent service level agreement violations. To address these issues, a virtual machine placement solution with a prediction capability is required to effectively place virtual machines in the proper hosts at runtime. The aim of this study is to provide a cloud management strategy that uses regression, moving average and simple exponential smoothing predictive models to identify overloaded physical machines and heuristic methods based on energy consumption, CPU utilization, number of virtual machines and memory to determine the appropriate physical machine for virtual machine placement, so provides a proper trade-off between reducing service level agreement violations and energy consumption and also decreases the number of virtual machine migrations. The cloudsim simulator version 3.0.3 has been used to evaluate the proposed model. The simulation results show that the proposed model averagely reduced the service level agreement violations by 45.65%, energy consumption by 28.96% and the number of virtual machine migrations by 46.49% compared to similar methods.

Keywords- Cloud environment, virtual machine, prediction, placement, physical machine.

ترکیب مدل‌های پیش‌بینی و روش‌های اکتشافی برای جای‌گذاری ماشین‌های مجازی با هدف کاهش نقض توافق سطح سرویس در محیط ابر

نگین نجفی زادگان^۱، اسلام ناظمی*^۲، وحید خواجه‌وند^۳

۱- دانشکده مهندسی کامپیوتر و فناوری اطلاعات، واحد قزوین، دانشگاه آزاد اسلامی، قزوین، ایران

۲- دانشکده مهندسی برق و کامپیوتر، دانشگاه شهید بهشتی، تهران، ایران

۳- دانشکده مهندسی کامپیوتر و فناوری اطلاعات، واحد قزوین، دانشگاه آزاد اسلامی، قزوین، ایران

* نشانی نویسنده مسئول: اسلام ناظمی، تهران، دانشگاه شهید بهشتی، دانشکده مهندسی برق و کامپیوتر

چکیده- امروزه با افزایش مراکز داده ابر مصرف برق افزایش یافته و مدیریت زیرساخت ابر نیز پیچیده‌تر شده است. از طرف دیگر برآورده کردن نیازهای کاربران ابر از اهداف مهم در زیرساخت ابر می‌باشد. فرآیند تعیین وضعیت بار ماشین‌های فیزیکی و جای‌گذاری ماشین‌های مجازی روی ماشین‌های فیزیکی مناسب می‌تواند مصرف انرژی را کاهش دهد و از نقض توافق سطح سرویس کاربران جلوگیری کند. برای حل این‌گونه مسائل، یک راهکار جای‌گذاری ماشین‌های مجازی با توانایی پیش‌بینی مورد نیاز است تا ماشین‌های مجازی را به طور کارا در زمان اجرا در میزبان‌های مناسب قرار دهد. راهکارهای فعلی عمدتاً از یک مدل پیش‌بینی برای پیش‌بینی بار ماشین‌های فیزیکی استفاده کرده‌اند و یا اکثراً تنها به موضوع پیش‌بینی بار میزبان‌ها پرداخته‌اند و مسئله قرارگیری ماشین‌های مجازی را در نظر نگرفته‌اند. هدف این تحقیق ارائه یک راهکار مدیریت منابع ابر است که با استفاده از ترکیب مدل‌های پیش‌بینی رگرسیون، میانگین متحرک و هموارسازی نمایی ساده جهت شناسایی ماشین‌های فیزیکی فرابار و با استفاده از روش‌های اکتشافی مبتنی بر مصرف انرژی، بهره‌وری پردازنده، تعداد ماشین‌های مجازی و حافظه جهت تعیین ماشین فیزیکی مناسب برای جای‌گذاری ماشین‌های مجازی مهاجر بین کاهش تخطی در توافق سطح سرویس و کاهش مصرف انرژی مصالحه برقرار کند. برای ارزیابی مدل پیشنهادی از شبیه‌ساز **cloudsim** نسخه ۳.۰.۳ استفاده شده است. نتایج شبیه‌سازی نشان می‌دهد که مدل ارائه شده در مقایسه با روش‌های مشابه به طور میانگین تخطی از توافق سطح سرویس، مصرف انرژی و تعداد مهاجرت‌های ماشین‌های مجازی را به ترتیب ۴۵.۶۵٪، ۲۸.۹۶٪ و ۴۶.۴۹٪ کاهش داده است.

واژه‌های کلیدی: محیط ابر، ماشین مجازی، پیش‌بینی، جای‌گذاری، ماشین فیزیکی.

۱- مقدمه

داشته باشند. مشتریان می‌توانند از منابع مورد نیازشان در ابر برای مدت زمان معینی با پرداخت پول مشخصی استفاده نمایند [۱]. محاسبات ابر با استفاده از فناوری مجازی‌سازی منابع را به شکل سرویس ارائه می‌دهد و محیط نرم افزاری را در قالب ماشین مجازی ایجاد می‌کند. مجازی‌سازی یکی از مهم‌ترین فناوری‌هایی

محاسبات ابر یک الگوی محاسباتی محبوب و یک محیط مبتنی بر اینترنت است که در آن داده‌ها و برنامه‌های کاربردی می‌توانند به اشتراک گذاشته شوند. هزاران سیستم شبکه‌بندی شده می‌توانند در ابر منابعشان را به اشتراک بگذارند و به منابع دیگران دسترسی

[۳]. به طور کلی شمای قرارگیری ماشین مجازی به دو دسته ایستا و پویا گروه‌بندی می‌شود. در قرارگیری ایستای ماشین مجازی، نگاشت ماشین مجازی به ماشین فیزیکی در سرتاسر مدت زندگی یک ماشین مجازی ثابت است ولی در حالت پویا این امکان وجود دارد که قرارگیری اولیه ماشین مجازی روی ماشین فیزیکی بنا به دلایلی همچون تغییر در بار سیستم، تغییر پیدا کند. همچنین الگوریتم‌های قرارگیری پویای ماشین مجازی خود به دو دسته واکنشی و پیشگیرانه تقسیم می‌شود که در نوع واکنشی بعد از این که سیستم به یک وضعیت نامطلوب معین رسید، تغییرات اعمال می‌شود ولی در حالت پیشگیرانه قبل از این که سیستم به یک شرایط نامطلوبی برسد، ماشین فیزیکی مربوط به ماشین مجازی عوض می‌شود [۵].

در محیط‌های ابر مجازی شده نگرانی اصلی این است که کدام ماشین فیزیکی برای قرارگیری ماشین‌های مجازی اول انتخاب شود یا ماشین‌های مجازی را به کجا مهاجرت دهیم. این تصمیمات باید به صورت خودمختار توسط ابزار مدیریتی ابر بر اساس رفتار کاربران اتخاذ شود، کاربرانی که مکان قرارگیری ماشین مجازی خود را تعیین نمی‌کنند. اگرچه مهاجرت ماشین‌های مجازی برای مدیریت منابع در محیط ابر امری اساسی است ولی معمولاً سربار بالایی را به همراه دارد. این گونه مهاجرت‌ها اگر بیش از اندازه و در لحظات نامناسب انجام شود، به دلیل محیط اشتراکی ابر، نه تنها کارایی سرویس‌های قرار گرفته روی ماشین مجازی بلکه، کارایی سرویس‌های دیگر ماشین‌های مجازی ابر را نیز به خطر می‌اندازد [۳].

در این مقاله مسئله قرارگیری پویا و پیش‌گیرانه ماشین‌های مجازی روی ماشین‌های فیزیکی در ابر مورد توجه قرار گرفته است. برای حل این مسئله یک راهکار جدید مدیریت منابع ابر ارائه شده است که با استفاده از ترکیب مدل‌های پیش‌بینی جهت شناسایی ماشین‌های فیزیکی فرابار و با استفاده از روش‌های اکتشافی جهت تعیین ماشین فیزیکی مناسب برای جای‌گذاری ماشین‌های مجازی مهاجر بین کاهش تخطی در توافق سطح سرویس و کاهش مصرف انرژی مصالحه برقرار می‌کند. مدل پیشنهادی نوآوری‌های زیر را ارائه می‌دهد:

- استفاده از روش پیش‌بینی ترکیبی متشکل از رگرسیون^۴، میانگین متحرک^۵ و هموارسازی نمایی ساده^۶ جهت تعیین ماشین‌های فیزیکی فرابار
- ارائه یک الگوریتم چند معیاره مبتنی بر مصرف انرژی، بهره‌وری پردازنده، تعداد ماشین‌های مجازی و حافظه برای انتخاب ماشین‌های فیزیکی مقصد مناسب

است که در چند سال اخیر روی محاسبات تاثیر گذاشته است و این خصوصیت را دارد که چندین سیستم عامل را به صورت همزمان روی یک کامپیوتر اجرا کند [۲]. وقتی یک ماشین فیزیکی منابع کافی برای برآورده کردن تقاضایش ندارد، مرکز داغ^۱ نامیده می‌شود به این معنا که فرابار^۲ شده و نیاز دارد تا بعضی از ماشین‌های مجازی خود را به ماشین فیزیکی دیگری مهاجرت دهد. علاوه بر این که شرایط مرکز داغ برای یک ماشین فیزیکی منجر به نقض توافق سطح سرویس می‌شود، باعث می‌شود تا حرارت ماشین فیزیکی نیز به دلیل مصرف زیاد پردازنده بالا رود. این گرمای زیاد تولید شده منجر به افزایش مصرف برق سیستم‌های خنک کننده می‌شود. همچنین شلوغ بودن پردازنده باعث می‌شود زمان اجرای کارها طولانی‌تر شود که این امر خود منجر به فعال ماندن طولانی مدت ماشین‌های فیزیکی می‌شود [۳]. در مراکز داده ابر، ماشین‌های فیزیکی فرابار باعث عدم توازن بار می‌شوند و این عدم توازن به طور طبیعی کیفیت سرویس را کاهش می‌دهد. برای از بین بردن این وضعیت فراباری می‌بایست ماشین‌های مجازی را از ماشین‌های فیزیکی فرابار به ماشین فیزیکی مقصد فروربار^۲ انتقال داد. بنابراین مهاجرت ماشین‌های مجازی برای از بین بردن این مراکز داغ به منظور تضمین توافق‌های سطح سرویس برنامه‌های کاربردی در مراکز داده ابر، امری ضروری می‌باشد [۴].

فرآیند جا به جایی یک ماشین مجازی از یک ماشین فیزیکی به ماشین فیزیکی دیگر مهاجرت ماشین مجازی نامیده می‌شود. مهاجرت زنده ماشین مجازی، فرآیند جا به جایی ماشین‌های مجازی بدون مختل کردن خدمت آن‌ها یا قطع کاربران نهایی است که باعث کمینه مدت کار نکردن یک خدمت تا حد ممکن می‌شود و به طور یکپارچه کل ماشین مجازی را به ماشین فیزیکی منتقل می‌کند. سه سوال اساسی وجود دارد که می‌بایست به هنگام مهاجرت ماشین‌های مجازی پاسخ داده شود. این سه سوال عبارتند از:

۱. کدام ماشین‌های مجازی مهاجرت داده شوند؟
 ۲. ماشین‌های مجازی به کجا مهاجرت داده شوند؟
 ۳. چه زمان ماشین‌های مجازی مهاجرت داده شوند؟
- تصمیم‌گیری این که کدام ماشین فیزیکی یک ماشین مجازی را میزبانی کند باید بر اساس چندین معیار از جمله، منابع در دسترس ماشین‌های فیزیکی، مکان جغرافیایی، میزان برق مصرفی، گرمای فعلی و استفاده متوازن از منابع، اتخاذ شود. بعضی از نگرانی‌ها برای انتخاب یک ماشین فیزیکی این است که چگونه می‌توان یک شرایط افزایش یا کاهش بارکاری را شناسایی کرد

انتخاب گردیده است زیرا دارای سربار کم و دقت پیش‌بینی بالا می‌باشد. لیانگ [۷] یک مدل پیش‌بینی چند منبعی را برای پیش‌بینی بار ماشین فیزیکی ارائه داده است. این مدل، بار ماشین فیزیکی را از طریق محاسبه رابطه آن ماشین فیزیکی با دیگر منابع پیش‌بینی می‌کند. بنابراین رفتار منبع تقریباً همانند منبعی است که با آن به شدت هم‌بسته است. آن‌ها نتیجه‌گیری کرده‌اند که این روش به خصوص در زمانی که منابع خیلی پویا هستند می‌تواند موثر باشد. بلاگلازو [۸] یک تحلیل رقابتی روی مسئله مهاجرت ماشین مجازی به تنهایی و در هنگام یکپارچگی^۱ پویای ماشین‌های مجازی انجام داده است. این مقاله ضرایب رقابتی را برای الگوریتم‌های برخط بهینه قطعی به دست آورده است. به علاوه آن‌ها روش‌های اکتشافی تطبیقی جدیدی را برای یکپارچگی پویای ماشین‌های مجازی پیشنهاد داده‌اند که بر اساس تحلیل داده‌های گذشته استفاده منابع، توسط ماشین‌های مجازی می‌باشد. الگوریتم ارائه شده مصرف انرژی را کاهش می‌دهد و سطح بالایی از توافق سطح سرویس را تضمین می‌کند ولی تنها از یک مدل پیش‌بینی استفاده می‌کند. آریانیان [۹] سیاست میانگین متحرک پنجره‌ای را برای شناسایی ماشین‌های فیزیکی فرابار پیشنهاد داده است که تمام معیارهای ورودی از جمله پردازنده، حافظه و پهنای باند شبکه را در فرآیند تصمیم‌گیری در نظر می‌گیرد و رخداد مهاجرت ماشین‌های مجازی را که به علت افزایش بار ناگهانی رخ می‌دهد کاهش می‌دهد. این مقاله نیز تنها از یک مدل پیش‌بینی استفاده می‌کند. سابیرات [۱۰] یک الگوریتم ترکیبی را برای پیش‌بینی وضعیت آینده مصرف انرژی ماشین‌های مجازی، منبع، زیرساخت و سطوح سرویس محیط ابر ارائه داده است. پیش‌بینی‌گر آن‌ها شامل چهار مدل پیش‌بینی پایه میانگین متحرک، هموارسازی نمایی، رگرسیون خطی و هموارسازی نمایی دو برابر است. مدل‌های پیش‌بینی هر کدام به تنهایی مصرف انرژی تک تک ماشین‌های مجازی را در بازه زمانی بعدی پیش‌بینی می‌کنند. بعد از آن مقدار پیش‌بینی که اخیراً کمترین مقدار خطای میانگین مطلق را داشته است، به عنوان مقدار نهایی پیش‌بینی انتخاب می‌شود. ولی در این روش دقت بستگی به انواع بارکاری دارد. به دلیل این‌که میزان استفاده از منابع ابر، از زمانی به زمان دیگر و از ماشین فیزیکی به ماشین فیزیکی دیگر به شدت تغییر می‌کند، بنابراین تعیین مدلی برای پیش‌بینی میزان استفاده از منابع ابر نه تنها به زمان بلکه به روند تغییر میزان استفاده از منابع ابر نیز بستگی دارد. در نتیجه استفاده از الگوریتم‌های پیش‌بینی ترکیبی که چندین مدل پیش‌بینی را با یکدیگر ترکیب می‌کند، می‌تواند برای رسیدن به

مقاله به این صورت بخش‌بندی شده است: در بخش دوم کارهای گذشته مرتبط به طور خلاصه توضیح داده شده است، بخش سوم مدل پیشنهادی را به همراه هر یک از الگوریتم‌های استفاده شده در هر یک از مراحل توصیف می‌کند، در بخش چهارم روش ارزیابی شده با استفاده از شبیه‌ساز CloudSim ارزیابی و با دیگر روش‌ها مقایسه شده است و در نهایت نتیجه‌گیری و کارهای آینده در بخش پنجم آورده شده است.

۲- کارهای مرتبط

فرآیند شناسایی به موقع ماشین‌های فیزیکی فرابار و جای‌گذاری ماشین‌های مجازی آن در ماشین‌های فیزیکی مناسب می‌تواند باعث کاهش مصرف انرژی و کاهش تعداد نقض‌های توافق سطح سرویس شود. در این بخش کارهای گذشته در زمینه کشف به موقع ماشین‌های فیزیکی فرابار و جای‌گذاری ماشین‌های مجازی روی ماشین‌های فیزیکی مناسب بررسی خواهد شد. کارهای مرتبط به دو دسته زیر تقسیم می‌شوند:

۱. کارهای انجام شده در زمینه پیش‌بینی بار ماشین‌های فیزیکی در ابر
۲. کارهای انجام شده در زمینه قرارگیری ماشین‌های مجازی در ابر

۲-۱- کارهای انجام شده در زمینه پیش‌بینی بار ماشین‌های

فیزیکی در ابر

برای قراگیری پیش‌گیرانه ماشین‌های مجازی بر روی ماشین‌های فیزیکی نیاز به یک الگوریتم پیش‌بینی جهت شناسایی ماشین‌های فیزیکی فرابار می‌باشد. با استفاده از یک الگوریتم پیش‌بینی مناسب می‌توان ماشین‌های فیزیکی را قبل از این‌که فرابار شوند شناسایی کرد و به این ترتیب نقض توافق سطح سرویس را کاهش داد. در این بخش تعدادی از کارهای انجام شده در زمینه پیش‌بینی بار ماشین فیزیکی مورد بررسی قرار گرفته است.

دیندا [۶] یک نرم افزار پیش‌بینی را طراحی کرده است که بار آینده پردازنده ماشین‌های فیزیکی را بر اساس تاریخچه استفاده آن‌ها از پردازنده پیش‌بینی می‌کند. نویسندگان در این مقاله کارایی به کار بردن بعضی از مدل‌های پیش‌بینی خطی از جمله میانگین متحرک^۷، خودهمبسته^۸، میانگین متحرک خودهمبسته^۹ و میانگین متحرک خودهمبسته یکپارچه کوچک را برای پیش‌بینی بار پردازنده، ارزیابی کرده‌اند. بر اساس نتایج ارزیابی، مدل خودهمبسته به عنوان بهترین مدل پیش‌بینی از میان همه مدل‌های پیش‌بینی

۲-۲- کارهای انجام شده در زمینه قرارگیری ماشین‌های مجازی در ابر

در قرارگیری پویای ماشین‌های مجازی، می‌توان ماشین فیزیکی ماشین‌های مجازی را در حین اجرای ماشین مجازی تغییر داد. در این بخش تعدادی از کارهای مرتبط با قرارگیری ماشین‌های مجازی آورده شده است.

باسو [۱] از یک الگوریتم ژنتیک بهبودیافته برای کاهش مصرف کل انرژی استفاده می‌کند. همچنین زمان‌بندی ماشین‌های مجازی را نیز انجام می‌دهد. بنابراین ماشین‌های فیزیکی بیشتر یا کمتر از حد ظرفیت آنها پر نمی‌شوند. هر کروموزوم در جمعیت، یک ماشین فیزیکی در نظر گرفته می‌شود و هر ماشین مجازی به یک ماشین فیزیکی تخصیص داده می‌شود. ماشین‌های مجازی روی هر ماشین فیزیکی همانند ژن‌های یک کروموزوم هستند. عملیات متقاطع و جهش بعد از این که هر عملیات بهینه‌سازی برای بدست آوردن نتایج تخصیص کارها استفاده شد، انجام می‌شود. در این روش توازن بار و بهره‌برداری از منابع بهبود می‌یابد. در واقع در این مقاله یک الگوریتم ژنتیک تغییر یافته با بهینه‌سازی جست و جوی محلی ارائه شده است که پارامترهای مصرف حافظه و انرژی را کاهش می‌دهد ولی در ارزیابی الگوریتم، پارامتر تعداد مهاجرت‌های ماشین مجازی که خود باعث افزایش مصرف انرژی می‌شود، بررسی نشده است. الهربی [۱۲] قرارگیری ماشین‌های مجازی روی ماشین‌های فیزیکی در یک مرکز داده را به صورت یک مسئله بهینه‌سازی ترکیبی محدود در نظر گرفته است و از اطلاعات نمایه^{۱۱} ماشین‌های مجازی و فیزیکی برای کمینه کردن مصرف انرژی تمام ماشین‌های فیزیکی فعال استفاده می‌کند و همچنین یک سیستم کلونی مورچه‌ها با روش‌های اکتشافی جدید را ترکیب کرده و به عنوان یک راه حل برای بهینه‌سازی انرژی مسئله ارائه داده است. این مقاله راه‌حلی برای یافتن ماشین فیزیکی فرابار ارائه نداده است. شاوا [۱۳] روی بهبود مسئله قرارگیری ماشین مجازی با در نظر گرفتن رابطه بین ماشین‌های مجازی مهاجر مقدم بر قرارگیری تمرکز کرده است. این روش ماشین‌های مجازی را که طبق نتایج پیش‌بینی برای تکمیل اجرا به یکدیگر نیاز دارند، با یکدیگر ترکیب می‌کند که اینکار باعث می‌شود مصرف انرژی و کارایی بهبود یابد. در واقع این روش منابع پردازنده و پهنای باند شبکه مورد نیاز فعلی و آینده ماشین‌های مجازی مهاجر را به دست می‌آورد و این اطلاعات را در اختیار استراتژی قرارگیری ماشین مجازی روی ماشین فیزیکی قرار می‌دهد. ولی این روش تعداد ماشین‌های مجازی و میزان انرژی ماشین فیزیکی را در انتخاب ماشین فیزیکی مقصد در نظر

هدف مورد نظر سودمند باشد [۱۱]. مقاله [۱۱] یک الگوریتم پیش‌بینی ترکیبی بر اساس اتوماتای یادگیر را برای پیش‌بینی میزان استفاده از منابع پیشنهاد داده است. این الگوریتم جدیدترین مدل‌های پیش‌بینی را با یکدیگر ترکیب می‌کند و برای هر مدل وزنی را تعیین می‌کند. الگوریتم پیشنهاد شده بر اساس کارایی که هر مدل پیش‌بینی دارد، مقدار پیش‌بینی مدل‌ها را با یکدیگر ترکیب می‌کند. نتایج نشان می‌دهد الگوریتم پیشنهادی نسبت به بقیه الگوریتم‌های ترکیبی مدل‌های پیش‌بینی خطای پیش‌بینی کمتری دارد. از آنجایی که بارکاری ماشین‌های فیزیکی دارای نوسان است، می‌بایست از روش پیش‌بینی استفاده کرد که بتواند تغییرات بار کاری را در نظر بگیرد و نوسانات بار کاری را پیش‌بینی کند. همچنین دقت روش پیش‌بینی می‌بایست مستقل از نوع بار کاری باشد. در صورت استفاده از تنها یک مدل پیش‌بینی احتمال خطای پیش‌بینی بالاتر است. در صورتی که با استفاده از ترکیب مدل‌های پیش‌بینی خطی و غیر خطی می‌توان دقت پیش‌بینی را بالا برد. روش پیش‌بینی پیشنهاد شده با استفاده از ترکیب مدل‌های پیش‌بینی خطی و غیر خطی بار کاری ماشین‌های فیزیکی را پیش‌بینی می‌کند و همچنین نوسانات بار کاری را در پیش‌بینی در نظر می‌گیرد. جدول ۱ روش‌های ارائه شده در زمینه پیش‌بینی بار ماشین‌های فیزیکی را با یکدیگر مقایسه می‌کند

جدول ۱ - مقایسه روش‌های ارائه شده در زمینه پیش‌بینی بار

ماشین‌های فیزیکی

روش	مزایا	معایب
دیندا [۶]	سربار محاسباتی و ارتباطی کمی دارد	تغییرات بارکاری را در نظر نمی‌گیرد
[۷] لیانگ	دقت پیش‌بینی بالا هم در ایستگاه‌های کاری و هم در محیط توری دارد	ناتوانی در پیش‌بینی نوسانات بارکاری دارد
[۸] بویا	مصرف انرژی را کاهش می‌دهد و سطح بالایی از توافق سطح سرویس را تضمین می‌کند	تنها از یک مدل پیش‌بینی استفاده می‌کند.
[۹] آریاتیان	مهاجرت ماشین مجازی را کاهش می‌دهد	تنها از یک مدل پیش‌بینی استفاده می‌کند.
[۱۰] اسبیرات	وضعیت آینده مصرف انرژی را در سطوح مختلف ماشین‌های مجازی، منبع، زیرساخت و سطوح سرویس پیش‌بینی می‌کند.	دقت بستگی به انواع بارکاری دارد
[۱۱] آقبایی	از چندین مدل پیش‌بینی استفاده می‌کند.	پیچیدگی محاسبات نسبتاً بالایی دارد

و قرارگیری برخط را برای ماشین‌های مجازی تقاضا شده در نظر گرفته است. این روش انرژی را ذخیره و همزمان توافقی‌های سطح سرویس کارا را نیز ضمانت می‌کند. این مقاله مناسب‌ترین فرکانس ولتاژ را که تنها بستگی به نوع پردازنده دارد، تعیین می‌کند تا مصرف انرژی را کمینه کند و از طریق تکنیک‌های تغییر پویای فرکانس ولتاژ^{۱۴} حد بالای ذخیره انرژی را فراهم آورد. همچنین برای حالت‌های برخط، یک روش توازن زمانی برخط اکتشافی برای قرارگیری ماشین‌های مجازی طراحی شده است که مبتنی بر تقاضاست و می‌تواند انتقال بین حالت‌ها را به وسیله توازن مدت زمان و بهره‌برداری سرویس‌دهنده‌ها، کاهش دهد. این مقاله تعداد مهاجرت‌های ماشین‌های مجازی را در روش پیشنهادی بررسی نکرده است. در [۸]، بلاگلزو و بویا یک تحلیل رقابتی را انجام می‌دهند و ضرایب رقابتی را برای الگوریتم‌های قطعی برخط بهینه و برای مسئله مهاجرت ماشین‌های مجازی به تنهایی و همچنین برای یکپارچه‌سازی پویای ماشین‌های مجازی اثبات می‌کنند. به علاوه آن‌ها یک روش ابتکاری تطبیق‌پذیر جدید را برای یکپارچه‌سازی پویای ماشین‌های مجازی بر اساس یک تحلیل از داده‌های گذشته مصرف منبع توسط ماشین‌های مجازی پیشنهاد داده‌اند. روش ارائه شده مصرف انرژی را کاهش داده و توافق سطح سرویس را رعایت می‌کند. این مقاله تعداد ماشین‌های مجازی ماشین‌فیزیکی را در انتخاب ماشین‌فیزیکی مقصد در نظر نمی‌گیرد. بلاگلزو، [۱۸] یک چارچوب مبتنی بر معماری و یک سری قواعد را برای محاسبات ابر با صرفه در مصرف انرژی تعریف کرده است. همچنین الگوریتم‌هایی را برای تخصیص و تدارک منابع برای مدیریت محیط محاسبات ابر، ارائه داده است به گونه‌ای که در مصرف انرژی صرفه‌جویی می‌کند. روش‌های اکتشافی تخصیص آگاه از انرژی ارائه شده، منابع مرکز داده را برای برنامه‌های کاربر به گونه‌ای تدارک می‌بیند که مصرف انرژی را کاهش داده و در عین حال کیفیت سرویس توافق شده را رعایت می‌کند. این مقاله تعداد ماشین‌های مجازی ماشین‌فیزیکی را در انتخاب ماشین‌فیزیکی مقصد در نظر نمی‌گیرد. هوری [۱۹]، یک روش یکپارچه‌سازی ماشین‌های مجازی آگاه از کیفیت سرویس را ارائه داده است که بر اساس تاریخچه بهره‌برداری از منابع ماشین‌های مجازی عمل می‌کند. این مقاله معیارهای کیفیت سرویس و مصرف انرژی را بهبود می‌دهد ولی تعداد ماشین‌های مجازی ماشین‌فیزیکی را در انتخاب ماشین‌فیزیکی در نظر نمی‌گیرد. آریانیان [۲۰] یک روال مدیریت منابع ابر و همچنین روشی برای تصمیم‌گیری اکتشافی چند معیاره برای تعیین ماشین‌های فیزیکی فروبار و قرارگیری ماشین‌های مجازی در حال مهاجرت ارائه داده است. روش

نمی‌گیرد. قبایی [۱۱]، الگوریتمی برای تخصیص ماشین‌های مجازی ارائه می‌دهد که مصرف انرژی و تخطی از توافق سطح سرویس را کاهش می‌دهد. روش پیشنهادی بر اساس الگوریتم بهترین قرارگیری نزولی^{۱۲} است که از تئوری اتوماتای یادگیر، ضریب همبستگی و الگوریتم پیش‌بینی گروهی در تخصیص ماشین‌های مجازی استفاده می‌کند. این مقاله تعداد ماشین‌های مجازی ماشین‌فیزیکی را در انتخاب ماشین‌فیزیکی در نظر نمی‌گیرد. فرحناکیان [۱۴] یک معماری سیستم توزیع شده را ارائه داده است که یکپارچگی ماشین‌های مجازی را به صورت پویا برای کاهش مصرف انرژی مرکز داده‌ها انجام داده است، در حالی که کیفیت سرویس مطلوب را نیز حفظ کرده است. چون مسئله یکپارچگی ماشین‌های مجازی یک مسئله بسیار دشوار^{۱۳} است، از یک الگوریتم فرا اکتشافی بهینه‌سازی برخط کلونی مورچه‌ها استفاده شده است. یکپارچگی ماشین‌های مجازی مبتنی بر سیستم کلونی مورچه‌ها یک راه حل نزدیک به بهینه بر اساس یک تابع هدف مشخص شده را بدست می‌آورد. این مقاله به بررسی خصوصیات ماشین‌های فیزیکی برای انتخاب ماشین‌فیزیکی مناسب به عنوان مقصد ماشین‌های مجازی مهاجر نمی‌پردازد. هالاوی [۱۵] یک روش جدید با استفاده از الگوریتم‌های ژنتیک برای پیدا کردن راه‌های بهینه برای مسائل بسته‌بندی برداری چند بعدی با هدف بهبود تخصیص منابع ابر و یکپارچگی ماشین‌های مجازی ارائه می‌کند. دو الگوریتم ژنتیک ترکیبی مرتب‌سازی اولین مناسب و الگوریتم ژنتیک ترکیبی مرتب‌سازی دومین مناسب، توسعه و با هم ترکیب شده‌اند. الگوریتم ترکیبی ارائه شده تعداد کل سرویس‌دهنده‌های در حال اجرا و هدر رفت منابع در هر سرویس‌دهنده را کمینه می‌کند. این مقاله میزان تخطی از توافق سطح سرویس را در نظر نگرفته است. فردوس [۱۶] یک شمای یکپارچگی ماشین‌های مجازی را ارائه داده است که روی بهره‌برداری متوازن منابع سرویس‌دهنده‌ها در میان منابع محاسباتی مختلف (پردازنده، حافظه، شبکه و I/O) با هدف کمینه کردن مصرف برق و هدررفت منابع تمرکز کرده است. چون مسئله یکپارچگی ماشین‌های مجازی یک مسئله بسیار دشوار است و برای مرکز داده‌های وسیع از نظر محاسباتی اجرا نشدنی است، این مقاله روش فرااکتشافی بهینه‌سازی کلونی مورچه‌ها را با روش استفاده متوازن از منابع محاسباتی بر اساس جبر برداری ترکیب کرده است. این مقاله میزان تخطی از توافق سطح سرویس را در روش پیشنهادی در نظر نگرفته است. تنگ [۱۷] با در نظر گرفتن این که فراهم‌آورنده زیر ساخت به عنوان سرویس‌چندین امکان قیمت‌گذاری را حمایت می‌کند، یکپارچگی دسته‌ای را برای ماشین‌های مجازی رزرو شده

[۲۰]	سطح سرویس و تعداد مهاجرت‌های ماشین‌های مجازی را کاهش داده است.	فیزیکی فرابار ارائه نداده است.
آریانیان [۹]	انرژی، تخطی از توافق سطح سرویس و تعداد مهاجرت‌ها را در مراکز داده ابر کمینه می‌کند.	کاری در زمینه انتخاب ماشین‌های فیزیکی مقصد مناسب برای قرارگیری ماشین‌های مجازی مهاجر انجام نداده است.

دو معیار تخطی از توافق سطح سرویس و تعداد مهاجرت‌های ماشین‌های مجازی در مسئله جای‌گذاری ماشین‌های مجازی حائز اهمیت بالایی می‌باشند. برای کاهش نقض توافق سطح سرویس می‌بایست با استفاده از روش‌های پیش‌بینی ماشین‌های فیزیکی را پیش از آن‌که فرابار شوند، شناسایی کرد. کارهای گذشته انجام شده در زمینه جای‌گذاری ماشین‌های مجازی بعضاً هر دو معیار تخطی از توافق سطح سرویس و تعداد مهاجرت‌های ماشین‌های مجازی را در نظر نگرفته‌اند و یا روشی برای تعیین ماشین‌های فرابار ارائه نداده‌اند. همچنین به بررسی خصوصیات ماشین‌های فیزیکی جهت انتخاب برای قرارگیری ماشین‌های مجازی پرداخته‌اند. ما در این مقاله راهکاری را پیشنهاد می‌دهیم که در ابتدا با استفاده از یک روش پیش‌بینی ترکیبی که از سه مدل رگرسیون، میانگین متحرک و هموارسازی نمایی ساده تشکیل شده است، بار ماشین‌های فیزیکی را پیش‌بینی می‌کند و ماشین‌های فیزیکی را پیش از آن‌که فرابار شوند شناسایی می‌کند. به این ترتیب تعداد تخطی‌های توافق سطح سرویس را کاهش می‌دهد. همچنین در قسمت جای‌گذاری ماشین‌های مجازی، ماشین‌های فیزیکی مقصد را از نظر خصوصیات میزان انرژی، بهره‌وری پردازنده، تعداد ماشین‌های مجازی و مصرف حافظه آن‌ها بررسی نموده و ماشین فیزیکی مناسب را انتخاب می‌کند که خود به کاهش نقض توافق سطح سرویس کمک می‌کند.

۳- راهکار پیشنهادی

در این بخش مدل پیشنهادی به همراه الگوریتم‌های ارائه شده توضیح داده خواهد شد.

هدف راهکار ارائه شده شناسایی ماشین‌های فیزیکی فرابار و جای‌گذاری ماشین‌های مجازی ماشین فیزیکی فرابار در ماشین فیزیکی مناسب با هدف کاهش نقض توافق سطح سرویس و کاهش مصرف انرژی است. مسئله مورد بررسی در این تحقیق، شناسایی پیشگیرانه ماشین‌های فیزیکی فرابار به منظور جلوگیری از نقض توافق سطح سرویس و جای‌گذاری ماشین‌های مجازی ماشین فیزیکی فرابار در ماشین فیزیکی مناسب با حداقل انرژی مصرفی می‌باشد. در این مسئله n ماشین فیزیکی $h_1, h_2, h_3, \dots, h_n$ و k ماشین مجازی $vm_1, vm_2, vm_3, \dots, vm_k$ وجود دارد که در هر

پیشنهادی مصرف انرژی، تخطی از توافق سطح سرویس و تعداد مهاجرت‌های ماشین‌های مجازی را کاهش داده است. این مقاله روشی برای تعیین ماشین‌های فیزیکی فرابار ارائه نداده است. آریانیان در [۹]، سیاست‌هایی را برای مدیریت برخط و فعال منابع ارائه داده است که انرژی، تخطی از توافق سطح سرویس و تعداد مهاجرت‌ها را در مراکز داده ابر کمینه می‌کند. در واقع این مقاله یک روش پیش‌بینی را پیشنهاد داده است که ماشین‌های فیزیکی فرابار را تعیین می‌کند، همچنین تکنیک‌های تصمیم‌گیری چند معیاره‌ای را برای انتخاب ماشین‌های مجازی ارائه داده است. این مقاله کاری در زمینه انتخاب ماشین‌های فیزیکی مقصد مناسب برای قرارگیری ماشین‌های مجازی مهاجر انجام نداده است. در جدول ۲ مزایا و معایب روش‌های گذشته در زمینه یکپارچگی و قرارگیری ماشین‌های مجازی آورده شده است.

جدول ۲- مقایسه کارهای انجام شده در زمینه قرارگیری ماشین‌های مجازی در ابر

روش	مزایا	معایب
باسو [۱۱]	پارامترهای مصرف حافظه و انرژی را کاهش می‌دهد	تعداد مهاجرت‌های ماشین‌های مجازی را در نظر نگرفته است
الهربی [۱۲]	مصرف انرژی را کاهش می‌دهد	راه‌حلی برای یافتن ماشین فیزیکی فرابار ارائه نداده است.
شاوا [۱۳]	مصرف انرژی و کارایی را بهبود می‌دهد	تعداد ماشین‌های مجازی ماشین فیزیکی را در انتخاب ماشین فیزیکی در نظر نمی‌گیرد.
قبایی [۱۱]	مصرف انرژی و تخطی از توافق سطح سرویس را کاهش می‌دهد	تعداد ماشین‌های مجازی ماشین فیزیکی را در انتخاب ماشین فیزیکی در نظر نمی‌گیرد.
فرحناکیان [۱۴]	مصرف انرژی را کاهش می‌دهد	به بررسی خصوصیات ماشین‌های فیزیکی برای انتخاب ماشین فیزیکی مقصد مناسب نمی‌پردازد.
هالاوی [۱۵]	مصرف انرژی را کاهش می‌دهد	معیار نقض توافق سطح سرویس را در نظر نگرفته است
فردوس [۱۶]	مصرف برق و هدررفت منابع را کاهش داده است	معیار نقض توافق سطح سرویس را در نظر نگرفته است
تنگ [۱۷]	مصرف انرژی را کاهش می‌دهد و توافق سطح سرویس کارا را تضمین می‌کند	تعداد مهاجرت‌های ماشین‌های مجازی را در نظر نگرفته است
بلاگلزو [۸]	مصرف انرژی و نقض توافق سطح سرویس را کاهش می‌دهد	تعداد ماشین‌های مجازی ماشین فیزیکی را در انتخاب ماشین فیزیکی در نظر نمی‌گیرد.
بلاگلزو [۱۸]	مصرف انرژی را کاهش داده و در عین حال کیفیت سرویس توافق شده را رعایت می‌کند.	تعداد ماشین‌های مجازی ماشین فیزیکی را در انتخاب ماشین فیزیکی در نظر نمی‌گیرد.
هوری [۱۹]	معیارهای کیفیت سرویس و مصرف انرژی را بهبود می‌دهد.	تعداد ماشین‌های مجازی ماشین فیزیکی را در انتخاب ماشین فیزیکی در نظر نمی‌گیرد.
آریانیان	مصرف انرژی، تخطی از توافق	روش برای تعیین ماشین‌های

γ باشد، سپس مدل رگرسیون خطی به شکل رابطه (۱) خواهد بود.

$$y = \beta_0 + \sum_{i=1}^m \beta_i + x_i \quad (1)$$

در رابطه بالا β پارامتری است که کمک می‌کند تا مدل بهتر با نقاط داده منطبق باشد [۲۳].

- میانگین متحرک:

در مدل پیش‌بینی میانگین متحرک، به جای استفاده از مقادیر گذشته متغیر پیش‌بینی در یک رگرسیون، از خطاهای پیش‌بینی گذشته استفاده می‌شود. رابطه (۲) یک مدل میانگین متحرک را نشان می‌دهد.

$$y_t = c + e_t + \theta_1 e_{t-1} + \theta_2 e_{t-2} + \dots + \theta_q e_{t-q} \quad (2)$$

به مدل رابطه (۲) MA(q) گفته می‌شود که در آن e_t نویز سفید و θ پارامتر مدل می‌باشد. قدرت این مدل سادگی و ضعف آن حساسیت به روندهاست.

- هموارسازی نمایی:

روش هموارسازی نمایی ساده، تکنیکی است که به تدریج با گذشت زمان وزن نمونه‌ها را کاهش می‌دهد به طوری که نمونه‌های قدیمی‌تر وزن کمتر و نمونه‌های جدیدتر وزن بیشتری دارند. در حالی که در مدل میانگین متحرک، نمونه‌ها دارای وزن‌های برابر هستند. مدل هموارسازی نمایی در رابطه (۳) نشان داده شده است.

$$y'_{T+1|T} = \alpha y_T + \alpha(1-\alpha)y_{T-1} + \alpha(1-\alpha)^2 y_{T-2} + \dots \quad (3)$$

در رابطه بالا $0 \leq \alpha \leq 1$ است که ضریب هموارسازی و y' متغیر وابسته خروجی می‌باشد. این روش نسبت به روش میانگین متحرک نسبت به روندها منعطف‌تر است ولی هیچ‌جز فصلی یا درون‌یابی ندارد [۲۴].

اگر با استفاده از مدل پیش‌بینی ترکیبی ماشین‌فیزیکی در بازه زمانی بعدی فرابار شناسایی شود، در مرحله جای‌گذاری با استفاده از روش‌های اکتشافی، ماشین‌های فیزیکی مناسب مقصد برای قرارگیری ماشین‌های مجازی مهاجر منتقل شده از سرور فرابار انتخاب می‌شود. به این ترتیب مصرف انرژی و تخطی از توافق سطح سرویس کاهش می‌یابد. منظور از فراباری کاهش منبع محاسباتی CPU برای پردازش درخواست‌های کاربران می‌باشد [۲۵] و [۸]. بدین منظور مقاله مروری رفرنس [۳] با بررسی‌های گسترده‌ای که در کارهای قبلی انجام داده، بیان می‌کند که تعداد زیادی از کارهای قبلی به هنگام تصمیم‌گیری در جای‌گذاری و مهاجرت ماشین مجازی، تنها نیازمندی‌های CPU را در نظر می‌گیرند زیرا CPU حیاتی‌ترین منبع است که باعث نقض توافق

کدام از ماشین‌های فیزیکی تعدادی ماشین مجازی قرار گرفته‌اند. هر کدام از این ماشین‌های مجازی دارای یک سیستم عامل مجزا هستند و تمام این ماشین‌های مجازی توسط ناظر ماشین مجازی^{۱۵} ایجاد و اجرا می‌شوند.

در این مطالعه سیستم محاسبات ابر یک محیط زیرساخت به عنوان سرویس^{۱۶} می‌باشد. این بدین معناست که فراهم آورنده منبع از نوع برنامه‌های کاربردی که در سیستم وجود دارد بی‌خبر است. بنابراین سیستم باید مستقل از برنامه باشد یعنی بتواند به صورت کارا بارهای کاری ناشناخته و پیچیده را مدیریت کند. انرژی مصرف شده توسط مهاجرت ماشین‌های مجازی بستگی به خصوصیات بارهای کاری دارد [۲۱]. اما از آنجایی که این سیستم مستقل از برنامه‌های کاربردی است (یعنی می‌تواند به صورت کارا بارهای کاری ناشناخته و پیچیده را مدیریت کند)، بنابراین محاسبه مصرف انرژی به دلیل مهاجرت نادیده گرفته می‌شود.

در معماری سیستم مورد بررسی، در یک مرکز داده یک مخزن ذخیره‌سازی مبتنی بر شبکه^{۱۷} وجود دارد که در آن کلیه داده‌ها به اشتراک گذاشته شده است و به هنگام مهاجرت ماشین‌های مجازی داده‌های مخزن ذخیره‌سازی مهاجرت داده نمی‌شود و تنها حافظه دسترسی تصادفی^{۱۸} منتقل می‌شود که در این حافظه فقط سیستم عامل وجود دارد [۲۲]. از طرف دیگر به دلیل این که در سیستم محاسبات ابر مورد نظر تنها یک مرکز داده وجود دارد و مهاجرت‌ها تنها در یک مرکز داده رخ می‌دهد، تجهیزات شبکه محدود بوده و مصرف انرژی قابل ملاحظه‌ای ندارند. برای شناسایی پیش‌گیرانه ماشین‌های فیزیکی فرابار از یک روش پیش‌بینی ترکیبی استفاده شده است که در ادامه توضیح داده خواهد شد.

۳-۱- روش پیش‌بینی ترکیبی

در راهکار ارائه شده میزان بارکاری هر ماشین فیزیکی در آینده با استفاده از الگوریتم پیش‌بینی ترکیبی، پیش‌بینی می‌شود. این روش پیش‌بینی از نتایج مدل‌های پیش‌بینی رگرسیون، میانگین متحرک و هموارسازی نمایی ساده میانگین می‌گیرد و نتیجه را به عنوان نتیجه نهایی پیش‌بینی برمی‌گرداند. هر یک از مدل‌های پیش‌بینی مورد استفاده در ادامه آورده شده است.

- مدل رگرسیون:

این مدل پیش‌بینی رابطه بین یک یا چند متغیر ورودی X و متغیر وابسته خروجی Y را مدل می‌کند و از یک رابطه خطی برای داده‌های مشاهده شده استفاده می‌کند. اگر مجموعه متغیرهای ورودی مستقل $X = [x_1, x_2, x_3, \dots, x_m]$ و متغیر خروجی وابسته

دلیل بررسی این معیار این است که هر ماشین مجازی دارای الگوی بار کاری مربوط به خود است. با افزایش تعداد ماشین‌های مجازی روی یک سرور، تنوع بار کاری روی آن سرور نیز افزایش می‌یابد. در نتیجه هر چقدر تعداد ماشین‌های مجازی روی یک سرور افزایش یابد، احتمال این که هر کدام از این ماشین‌های مجازی به سمت فراباری پیش روند، بیشتر می‌شود که این امر مدیریت سرور را پیچیده‌تر کرده و باعث افزایش احتمال فراباری سرور می‌شود. رابطه (۵) روش اکتشافی اول را نشان می‌دهد.

ماکزیمم تعداد ماشین‌های مجازی $V_h(\Delta t)$ نسبت به ماشین فیزیکی h_i را به ماکزیمم تعداد ماشین‌های مجازی روی کلیه ماشین‌های فیزیکی در بازه زمانی Δt نشان می‌دهد.

$$V_h(\Delta t) = \frac{VM\ NUM(h_i, \Delta t)}{\max_{h_i \in host\ List} VM\ NUM(h, \Delta t)} \quad (5)$$

روش اکتشافی دوم در مقالات زیادی از جمله [۱۸]، استفاده شده است. این روش اکتشافی قصد دارد ماشین فیزیکی را بر اساس میزان مصرف برق آن بعد از جایگذاری ماشین مجازی انتخاب کند. هر چقدر این تغییرات کمتر باشد، آن ماشین فیزیکی انتخاب مناسب‌تری است. رابطه (۶) روش اکتشافی دوم را نشان می‌دهد که در آن $Power\ after\ allocation(h_i, v, \Delta t)$ میزان انرژی مصرفی ماشین فیزیکی h_i بعد از قرارگیری ماشین مجازی در بازه زمانی Δt را نشان می‌دهد. در این رابطه نسبت میزان انرژی هر ماشین فیزیکی به ماکزیمم مقدار انرژی مصرفی ماشین‌های فیزیکی محاسبه می‌شود.

$$P_h(\Delta t) = \frac{Power\ after\ allocation(h_i, v, \Delta t)}{\max_{h_i \in host\ List} Power\ after\ allocation(h, v, \Delta t)} \quad (6)$$

روش اکتشافی سوم میزان بهره‌وری پردازنده ماشین‌های فیزیکی را مورد بررسی قرار می‌دهد. روش اکتشافی سوم در رابطه (۷) نشان داده شده است. در این رابطه $CPU(h_i, \Delta t)$ میزان بهره‌وری پردازنده ماشین فیزیکی h_i می‌باشد. به این صورت که هر چقدر میزان بهره‌وری پردازنده ماشین فیزیکی کمتر باشد یعنی این ماشین فیزیکی مناسب‌تر است. در این رابطه نیز نسبت میزان بهره‌وری پردازنده هر ماشین فیزیکی به ماکزیمم مقدار بهره‌وری پردازنده ماشین‌های فیزیکی محاسبه می‌شود.

$$CPU_h(\Delta t) = \left[\frac{CPU(h_i, \Delta t)}{\max_{h_i \in host\ List} CPU(h, \Delta t)} \right] \quad (7)$$

روش اکتشافی چهارم میزان تاخیر مهاجرت ماشین‌های مجازی ماشین‌های فیزیکی را مورد بررسی قرار می‌دهد. روش اکتشافی چهارم در رابطه (۸) نشان داده شده است. در این رابطه $R(h_i, \Delta t)$ میزان حافظه اشغالی ماشین فیزیکی h_i می‌باشد. به این صورت که

سطح سرویس و در نهایت منجر به مهاجرت ماشین مجازی می‌شود در نتیجه میزان بهره‌وری منبع پردازش‌کننده یعنی CPU ملاک تعیین فراباری سرورها در نظر گرفته شده است.

همچنین برای تعیین وضعیت فراباری، یک سری زمانی در نظر گرفته شده است که اندازه آن ۱۰ می‌باشد. هر نمونه در این سری زمانی میزان بهره‌وری پردازنده سرور در آن بازه زمانی به خصوص را نشان می‌دهد. طول هر بازه زمانی نیز ۵ دقیقه در نظر گرفته شده است. در رابطه (۴) مجموعه سری زمانی مورد بررسی آورده شده است.

$$th_i = \{U_{\Delta t}^{CPU}(h_i), U_{\Delta t-1}^{CPU}(h_i), U_{\Delta t-2}^{CPU}(h_i), \dots, U_{\Delta t-w+1}^{CPU}(h_i)\} \quad (4)$$

در رابطه بالا $U_{\Delta t}^{CPU}(h_i)$ بهره‌وری پردازنده، سرور i را در بازه زمانی Δt (فعلی) نشان می‌دهد. همچنین منظور از زمان پیش‌بینی بعدی $U_{\Delta t+1}^{CPU}(h_i)$ می‌باشد و بهره‌وری پردازنده سرور i در بازه زمانی بعدی با استفاده از تعداد نمونه‌های قبلی پیش‌بینی می‌شود. از آن جایی که برای شناسایی سرورهای فرابار از روش پیش‌بینی استفاده شده است، مبنای مقدار حد آستانه مقاله پایه‌ای [۸] در نظر گرفته شده که در این مقاله حد آستانه برابر با یک می‌باشد. به این معنا که یک سرور فرابار به دلیل اتمام ظرفیت پردازشی توانایی پردازش درخواست‌های رسیده‌اش را نداشته باشد. برای پردازش درخواست‌ها در سرور ملاک میزان بهره‌وری پردازنده سرور می‌باشد [۸]، [۲۰] و [۲۵]. اگر این میزان بزرگتر یا مساوی ۱ باشد، یعنی کل توان پردازشی سرور توسط ماشین‌های مجازی اشغال شده و سرور در وضعیت فرابار قرار دارد.

برای جای‌گذاری ماشین‌های مجازی مهاجر از سرورهای فرابار از یک روش جای‌گذاری چند معیاره استفاده شده است که با استفاده از روش‌های اکتشافی گوناگون، ماشین‌های فیزیکی مناسب را برای جای‌گذاری انتخاب می‌کند. هر یک از روش‌های اکتشافی مورد استفاده در ادامه توضیح داده شده است.

۳-۲- روش‌های اکتشافی

در این تحقیق چهار روش اکتشافی جهت تعیین ماشین فیزیکی مناسب استفاده شده است که در ادامه هر یک، توضیح داده خواهد شد. روش‌های اکتشافی الگوریتم‌هایی هستند که با یک ایده خیلی ساده و خاص خود مسئله سعی می‌کنند مسئله را به صورت شبه بهینه حل کنند و مزیت اصلی آن‌ها سرعت بالایشان می‌باشد زیرا فضای حالت خیلی بزرگی را بررسی نمی‌کنند.

روش اکتشافی اول به این صورت عمل می‌کند که هر چه تعداد ماشین‌های مجازی روی یک ماشین فیزیکی بیشتر باشد، آن سرور انتخاب مناسبی برای جای‌گذاری ماشین‌های مجازی نمی‌باشد.

روش‌های اکتشافی که مبتنی بر انرژی، بهره‌وری پردازنده، تعداد ماشین‌های مجازی و حافظه مصرفی می‌باشند هر ماشین فیزیکی را رتبه‌بندی می‌کند. در نهایت ماشین فیزیکی مناسب با کمترین رتبه را انتخاب کرده و ماشین‌های مجازی را از ماشین فیزیکی فرابار به ماشین فیزیکی انتخاب شده مهاجرت می‌دهد. در ادامه الگوریتم‌های مورد استفاده در راهکار پیشنهادی آورده شده است. اختصارات مورد استفاده در الگوریتم‌ها و روابط به همراه تعاریف آن‌ها در جدول ۳ آورده شده است.

جدول ۳- اختصارات و تعاریف

تعاریف	اختصارات
تعداد کل ماشین‌های فیزیکی	hl
بازه زمانی فعلی	Δt
لیست ماشین‌های مجازی مهاجر	mvl
لیست ماشین‌های فیزیکی فرابار	os
ماشین فیزیکی i ام	h_i
ماشین مجازی j ام	v_j
مدل پیش‌بینی j ام	pm_j
حد آستانه بار ماشین فیزیکی	Upper_threshold
میزان بار ماشین فیزیکی در بازه زمانی بعدی	Service Usage $_{\Delta t+1}$
تعداد ماشین‌های مجازی فیزیکی در بازه زمانی فعلی	$V_h(\Delta t)$
میزان انرژی ماشین فیزیکی بعد از جای‌گذاری ماشین مجازی	$P_h(\Delta t)$
میزان پردازنده ماشین فیزیکی	CPU $_h(\Delta t)$
میزان حافظه اشغالی ماشین فیزیکی	$R_h(\Delta t)$
نگاشت ماشین مجازی j ام به ماشین فیزیکی i ام	Map(h_i, v_j)
لیست کلیه نگاشت‌های ماشین‌های مجازی به ماشین‌های فیزیکی	map_list
تعداد روش‌های اکتشافی	nh
میزان تخطی از توافق سطح سرویس	SLAV
مدت زمانی که ماشین فیزیکی در حالت فرابار بوده است	SLAVT
مجموع زمان‌هایی که ماشین فیزیکی i ام فرابار بوده	T_{si}
مجموع زمان‌هایی را نشان می‌دهد که ماشین فیزیکی i ام روشن بوده	T_{ai}
مدت زمانی که ماشین مجازی j ام در مجموع زمان‌های اجرایش در حال مهاجرت است	C_{dj}
مجموع کل زمان اجرای ماشین مجازی j ام را نشان می‌دهد.	C_{rj}

الگوریتم ۱ مرحله شناسایی ماشین‌های فیزیکی فرابار را نشان می‌دهد که بخشی از این الگوریتم مرتبط با الگوریتم پیش‌بینی است. الگوریتم پیش‌بینی یک مدل پیش‌بینی ترکیبی است که در الگوریتم ۲ آورده شده است. در الگوریتم ۱ در ابتدای کار، تک تک ماشین‌های فیزیکی h_i موجود در لیست hl بررسی می‌شوند. اگر مدل پیش‌بینی طبق الگوریتم ۲، h_i را بر اساس بهره‌وری

هر چقدر میزان حافظه اشغالی سرور توسط ماشین‌های مجازی کمتر باشد یعنی این ماشین فیزیکی مناسب‌تر است. زیرا به هنگام فرابار شدن، ماشین‌های مجازی این سرور در زمان کمتری به سرورهای دیگر مهاجرت داده می‌شوند. این امر باعث بهبود نقض توافق سطح سرویس می‌شود. در این رابطه نیز نسبت میزان تاخیر مهاجرت هر ماشین فیزیکی به ماکزیمم مقدار تاخیر مهاجرت ماشین‌های فیزیکی محاسبه می‌شود.

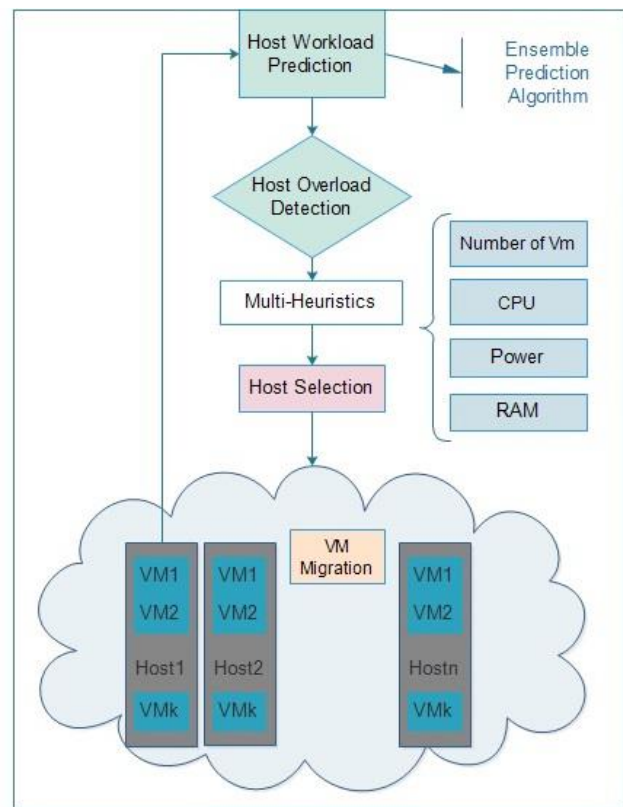
$$R_h(\Delta t) = \left[\frac{R(h_i, \Delta t)}{\max_{h_i \in \text{host List}} R(h, \Delta t)} \right] \quad (8)$$

در رابطه بالا $R(h_i, \Delta t)$ از رابطه (۹) محاسبه می‌شود.

$$R(h_i, \Delta t) = \sum_{i=1}^k vm_i^{RAM}(h_i, \Delta t) \quad (9)$$

۳-۳- مدل و الگوریتم‌های راهکار پیشنهادی

راهکار پیشنهادی از یک روش پیش‌بینی ترکیبی و یک روش جای‌گذاری ماشین مجازی چند معیاره استفاده کرده که در شکل ۱ نشان داده شده است.



شکل ۱- توالی راهکار پیشنهادی

همان‌طور که در شکل ۱ نشان داده شده است راهکار پیشنهادی ابتدا با استفاده از روش پیش‌بینی ترکیبی ماشین‌های فیزیکی را قبل از این که فرابار شوند شناسایی می‌کند. سپس با استفاده از

هر بازه زمانی ۵ دقیقه‌ای می‌باشد). خط چهارم الگوریتم بهره‌وری پردازنده ماشین فیزیکی λ_m را نشان می‌دهد که به تعداد اندازه پنجره بازه‌های زمانی، در سری زمانی اضافه شده است. pm_j هر مدل پیش‌بینی ساده و منفرد است. در خط هفتم میانگین نتایج مدل‌های پیش‌بینی برای بازه زمانی بعدی محاسبه می‌شود. اگر نتیجه به دست آمده نشان دهد که بهره‌وری پردازنده ماشین فیزیکی λ_m از یک حد آستانه بیشتر است، آن ماشین فیزیکی فرابار شناسایی می‌شود.

پس از شناسایی ماشین‌های فیزیکی که قرار است در بازه زمانی بعدی فرابار شوند، می‌بایست ماشین‌های مجازی این ماشین‌های فیزیکی را به ماشین‌های فیزیکی مناسبی مهاجرت داد. الگوریتم ۳ فرآیند انتخاب ماشین‌های فیزیکی مناسب را نشان می‌دهد. این مرحله از چندین معیار جهت انتخاب ماشین فیزیکی مناسب استفاده می‌کند. معیارهای مورد بررسی همان‌طور که در بخش ۳-۲ توضیح داده شد، تعداد ماشین‌های مجازی، میزان بهره‌وری پردازنده، میزان انرژی و حافظه مصرفی ماشین فیزیکی می‌باشند.

الگوریتم ۳ به طور خاص یک الگوریتم تخصیص ماشین مجازی چند اکتشافی^{۲۰} است. یعنی یک الگوریتم جایگذاری ماشین مجازی است که از چندین روش اکتشافی برای پیدا کردن ماشین فیزیکی مناسب به عنوان مقصد ماشین‌های مجازی مهاجر استفاده می‌کند. در خط دوم الگوریتم تک تک ماشین‌های مجازی که در mvl قرار دارند، بررسی می‌شوند تا روی ماشین‌های فیزیکی مناسب جایگذاری شوند. mvl لیست ماشین‌های مجازی مهاجری است که با استفاده از روش کمینه زمان مهاجرت، در مرحله قبل انتخاب شده‌اند. در خط سوم تک تک ماشین‌های فیزیکی توسط روش‌های اکتشافی برای جایگذاری ماشین‌های مجازی مهاجر بر روی آن‌ها بررسی می‌شوند. چهار روش اکتشافی تعداد ماشین‌های مجازی، میزان بهره‌وری پردازنده، میزان انرژی ماشین فیزیکی و حافظه، می‌باشد که در خط‌های ۴ تا ۷ آورده شده‌اند. در واقع در این‌جا چند ایده روش اکتشافی که کاربردی هستند برای تخصیص ماشین‌های مجازی بر روی ماشین‌های فیزیکی با هدف کمینه کردن مصرف انرژی استفاده شده است.

در خط هشتم الگوریتم $CostScore_{hi}$ محاسبه می‌شود. این پارامتر مجموع نتایج روش‌های اکتشافی در یکدیگر را برای تک تک ماشین‌های فیزیکی نشان می‌دهد. امتیاز هر ماشین فیزیکی برای انتخاب جهت قرارگیری ماشین‌های مجازی با $CostScore_{hi}$ مشخص می‌شود. با استفاده از این پارامتر مشخص می‌شود که ماشین فیزیکی λ_m تا چه اندازه برای قرارگیری ماشین مجازی λ_m مناسب است. در نهایت یک امتیاز نهایی برای تک تک ماشین‌های

پردازنده‌ی آن فرابار شناسایی کرده باشد، h_i به لیست ماشین‌های فیزیکی فرابار اضافه می‌شود. در واقع OS لیست کلیه ماشین‌های فیزیکی فرابار را نشان می‌دهد. در خط هفتم الگوریتم به ازای تک تک ماشین‌های فیزیکی موجود در لیست OS، ماشین‌های مجازی مهاجر از بین کلیه ماشین‌های مجازی این ماشین‌های فیزیکی، انتخاب می‌شوند تا از فرابار شدن این ماشین‌های فیزیکی جلوگیری شود. زیرا بر اساس مدل پیش‌بینی حدس زده شده که

الگوریتم ۱: تحلیل ماشین فیزیکی فرابار

```

1: Input:  $hl$  /*Host List*/ Output:  $mvl$  /*Migration VM List*/
2: foreach  $h_i$  in  $hl$  do
3:   if  $h_i$  is overloaded then
   /*According to Algorithm 2*/
4:     Add  $h_i$  to  $os$ 
5:   end if
6: end for
7: for each  $h_i$  in  $os$  do
8:    $mvl \leftarrow$  Select migrant VMs from overloaded  $h_i$  /*
by MMT algorithm [ $\lambda$ ] */
9: end for each
10: return  $mvl$ 
    
```

این ماشین‌های فیزیکی قرار است در آینده فرابار شوند. سپس ماشین‌های مجازی انتخاب شده به لیست ماشین‌های مجازی مهاجر اضافه می‌شوند. انتخاب ماشین‌های مجازی مهاجر از ماشین‌های فیزیکی که فرابار شده‌اند، بر اساس روش کمترین زمان مهاجرت^{۱۹} [λ] انجام می‌شود که در خط هشتم الگوریتم نشان داده شده است. در نهایت این الگوریتم لیست ماشین‌های مجازی مهاجر را به عنوان خروجی برمی‌گرداند.

الگوریتم ۲: شناسایی ماشین فیزیکی فرابار با استفاده از الگوریتم پیش‌بینی ترکیبی

```

1: Input:  $h_i$  Output:  $Is\_Overloaded$ 
2: Define timeseries  $ts$ 
3: for  $w = 0$  to Window_Size do
4:   Add Resource_Usage_History( $h_i, \Delta t - w$ ) to  $ts$ 
5: end for
6: for each constituent prediction model  $pm_j$  do
7:    $Service\_Usage_{\Delta t+1}(h_i) \leftarrow$  Average(Predict( $m_j, \Delta t + 1$ ))
8: end for each
9: Return  $Service\_Usage_{\Delta t+1}(h_i) > Upper\_threshold$ 
    
```

در الگوریتم ۲ برای تک تک ماشین‌های فیزیکی h_i وضعیت فرابار بودن یا نبودن این ماشین فیزیکی تعیین می‌شود. در این قسمت از یک سری زمانی برای تخمین آینده استفاده شده است. همچنین یک اندازه پنجره تعریف شده که چند بازه زمانی اخیر را در نظر می‌گیرد (که فرض در این مسئله اندازه پنجره ۱۰ است و

```

7:  $R_h(\Delta t) = \left\lceil \frac{R(h_i, \Delta t)}{\max_{h_i \in \text{host List}} R(h, \Delta t)} \right\rceil$ 
8:  $\text{Cost Score}_{hi} = V_{hi}(\Delta t) \times P_{hi}(\Delta t) \times \text{CPU}_{hi}(\Delta t) \times R_{hi}(\Delta t)$ 
9: end for each
10:  $h_i = \text{host with minimum Cost Score}_i$ 
11:  $\text{map\_list} \leftarrow \text{map\_list} + \text{Map}(h_i, v_j)$ 
12: end for each
13: for each  $h_i$  in  $hl$  order by CPU utilization do
14: if  $h_i$  was not overloaded and  $h_i$  is not in  $\text{map\_list}$ 
then
15: update  $\text{map\_list}$  by migrating VMs in  $h_i$ 
16: sign  $h_i$  as underloaded host
17: end if
18: end if
19: end for each
20: return  $\text{map\_list}$ 
21: for each  $v_j$  in  $\text{map\_list}$  do
22: migrate  $v_j$  to  $h_i$  in  $\text{map\_list}$ 
23: end for each
24: for each host  $h_i$  in  $hl$  do
25: if  $\text{sign}(h_i) == \text{underloaded}$  then
26: Turn  $h_i$  to sleep mode
27: end if
28: end for each

```

در راهکار پیشنهادی با استفاده از یک روش پیش‌بینی ترکیبی میزان بار کاری ماشین‌های فیزیکی در بازه زمانی بعدی پیش‌بینی شده است. روش پیش‌بینی ترکیبی ارائه شده از سه روش پیش‌بینی رگرسیون، میانگین متحرک و روش پیش‌بینی هموارسازی نمایی شده تشکیل شده است که نوسانات بارکاری را با دقت بیشتری نسبت به روش‌های پیش‌بینی مورد مقایسه، پیش‌بینی می‌کند. در قسمت پیش‌بینی راهکار پیشنهادی، ماشین‌های فیزیکی قبل از این‌که فرابار شوند شناسایی شده و ماشین‌های مجازی آن‌ها به ماشین‌های فیزیکی دیگر انتقال داده می‌شوند. در قسمت دوم راهکار پیشنهادی از روش امتیازبندی ماشین‌های فیزیکی استفاده شده است. در این روش امتیازبندی چهار روش اکتشافی جهت انتخاب ماشین‌فیزیکی مناسب مورد بررسی قرار گرفته است. روش‌های قبلی در انتخاب ماشین‌فیزیکی مقصد مناسب، معیار میزان حافظه مصرفی سرور توسط ماشین‌های مجازی را در نظر نگرفته‌اند. پیش‌بینی می‌شود از آنجایی که راهکار پیشنهادی ماشین‌های فیزیکی را قبل از این فرابار شوند شناسایی می‌کند و ماشین‌های مجازی آن‌ها را به ماشین‌های فیزیکی با میزان بهره‌وری، انرژی، تعداد ماشین‌های مجازی و حافظه مصرفی کمتر انتقال می‌دهد بتواند تعداد تخطی‌های توافق سطح سرویس، مصرف انرژی و تعداد مهاجرت‌ها را نسبت به روش‌های مورد مقایسه کاهش دهد.

فیزیکی محاسبه می‌شود و ماشین فیزیکی که کمترین رتبه را در میان کل ماشین‌های فیزیکی فعال داشته باشد به عنوان مقصد ماشین مجازی زام انتخاب می‌شود. CostScore_{hi} در رابطه (۱۰) نشان داده شده است. در این رابطه $V_{hi}(\Delta t)$ تعداد ماشین‌مجازی ماشین فیزیکی h_i ، $P_{hi}(\Delta t)$ میزان انرژی ماشین فیزیکی h_i و $\text{CPU}_{hi}(\Delta t)$ میزان بهره‌وری پردازنده ماشین فیزیکی h_i و $R_{hi}(\Delta t)$ میزان حافظه ماشین‌های مجازی سرور h_i را در بازه زمانی Δt نشان می‌دهد.

$\text{Cost Score}_{hi} = V_{hi}(\Delta t) \times P_{hi}(\Delta t) \times \text{CPU}_{hi}(\Delta t) \times R_{hi}(\Delta t)$ (۱۰)
در خط دهم الگوریتم نگاشت برای تک تک ماشین‌های مجازی روی h_i انجام می‌شود و در انتهای الگوریتم، تک تک ماشین‌های مجازی مهاجر صاحب یک ماشین فیزیکی شده و در یک لیست maplist قرار می‌گیرند. بعد از تعیین ماشین فیزیکی مقصد مناسب، نوبت به تعیین ماشین‌های فیزیکی فروبار است. برای انجام این کار کلیه ماشین‌های فیزیکی بر اساس بهره‌وری پردازنده‌شان مرتب می‌شوند. سپس ماشین‌های فیزیکی که فرابار نیستند و یا به عنوان ماشین فیزیکی مقصد انتخاب نشده‌اند، بر اساس بهره‌وری پردازنده‌شان به عنوان ماشین فیزیکی فروبار تعیین می‌شوند و maplist به روز رسانی می‌شود. در نهایت کلیه ماشین‌های مجازی در maplist به ماشین فیزیکی مناسب انتقال داده می‌شوند و کلیه ماشین‌های فیزیکی فروبار به حالت خواب می‌روند.

در الگوریتم جای‌گذاری ماشین‌مجازی پیشنهادی، می‌بایست روی N سرور مختلف معیارهای گوناگون را بررسی کرده که یکی از این معیارها مجموع حافظه تک تک ماشین‌ها مجازی (K عدد ماشین‌مجازی) می‌باشد. در نهایت باید با انتخاب سرور مناسب، K ماشین مجازی را روی سرورهای انتخاب شده جای‌گذاری کرد. در نتیجه سربار محاسباتی الگوریتم $N \times K \times K = N \times K^2$ می‌باشد که N تعداد سرورها و K تعداد ماشین‌های مجازی می‌باشد.

الگوریتم ۳: الگوریتم چند اکتشافی برای تخصیص ماشین‌های مجازی به ماشین‌های فیزیکی

```

1: Input:  $hl$  /*Host List*/,  $mvl$  /*Migrating VM list*/
Output:  $\text{maplist}$ 
/** Allocate migrating VMs from overutilized hosts**/
2: for each VM  $v_j$  in  $mvl$  do
3: for each Host  $h_i$  in  $hl$  do
4:  $V_h(\Delta t) = \frac{\text{VM NUM}(h_i, \Delta t)}{\max_{h_i \in \text{host List}} \text{VM NUM}(h, \Delta t)}$  /* VM level*/
5:  $P_h(\Delta t) = \frac{\text{Power after allocation}(h_i, v, \Delta t)}{\max_{h_i \in \text{host List}} \text{Power after allocation}(h, v, \Delta t)}$  /*Power level*/
6:  $\text{CPU}_h(\Delta t) = \left\lceil \frac{\text{CPU}(h_i, \Delta t)}{\max_{h_i \in \text{host List}} \text{CPU}(h, \Delta t)} \right\rceil$  /*Load level*/

```

۴- ارزیابی

سه معیار تخطی از توافق سطح سرویس، تعداد مهاجرت‌های ماشین‌های مجازی و انرژی برای ارزیابی مدل پیشنهادی استفاده شده‌اند. تخطی از توافق سطح سرویس زمانی رخ می‌دهد که فراهم‌آورنده نرم‌افزار به عنوان سرویس در برآوردن معیارهای از پیش تعیین شده که در توافق سطح سرویس کاربر آمده است، شکست می‌خورد. معیارهای ارزیابی در روابط ۱۱ تا ۱۴ آورده شده است که بر مبنای مقاله [۲۶] می‌باشد.

SLAV، کاهش کارایی را توصیف می‌کند که به دلیل فراباری ماشین‌های فیزیکی و یا مهاجرت ماشین‌های مجازی رخ داده است.

$$SLAV = SLAVO \times SLAVM \quad (11)$$

SLAVO، درصد زمان‌هایی را نشان می‌دهد که طی آن ماشین‌های فیزیکی فعال بهره‌وری پردازنده بالای صد درصد داشته‌اند، یا به عبارتی تعداد درخواست‌هایی که دریافت کرده‌اند بیش از ظرفیت آن‌ها بوده است و از فرمول زیر بدست می‌آید:

$$SLAVO = \frac{1}{M} \sum_{i=1}^M \frac{T_{si}}{T_{ai}} \quad (12)$$

M تعداد ماشین‌های فیزیکی است؛ T_{si} ، کل زمان‌هایی را نشان می‌دهد که ماشین فیزیکی i بهره‌برداری پردازنده ۱۰۰ درصد داشته یا فرابار بوده است. و T_{ai} ، کل زمان‌هایی را نشان می‌دهد که ماشین فیزیکی i فعال بوده است. SLAVM، کل کاهش کارایی را نشان می‌دهد که به دلیل مهاجرت ماشین‌های مجازی رخ داده است و از رابطه زیر محاسبه می‌شود:

$$SLAVM = \frac{1}{N} \sum_{j=1}^N \frac{C_{dj}}{C_{rj}} \quad (13)$$

N تعداد ماشین‌های مجازی است؛ C_{dj} تخمین کاهش کارایی ماشین مجازی j است که به دلیل مهاجرت‌ها رخ داده است. C_{rj} کل میزان پردازنده درخواست شده توسط ماشین مجازی j در طول عمرش می‌باشد.

انرژی که توسط یک مرکز داده مصرف می‌شود به دو بخش تقسیم می‌شود [۲۱]: انرژی مورد استفاده توسط تجهیزات فناوری اطلاعات (مثل سرورها، شبکه‌ها، مخزن ذخیره‌سازی و ...) و انرژی مورد استفاده توسط امکانات زیرساخت (مثل سیستم‌های خنک کننده و سیستم‌های تهویه). در این مقاله انرژی مصرفی توسط تجهیزات فناوری اطلاعات به عنوان انرژی مصرفی مرکز داده در نظر گرفته شده است که شامل انرژی مصرفی توسط CPU و RAM می‌باشد. مصرف انرژی دو جز دیگر یعنی دیسک و واسط شبکه نادیده گرفته شده است. دلیل این امر این است که دیسک

در این زیرساخت تقریباً بلااستفاده است، زیرا تنها در آن سیستم عامل به صورت محلی ذخیره می‌شود و یک واسط شبکه 10Gbps تنها نزدیک به ۱۰٪ از انرژی یک سرور را مصرف می‌کند، در حالی که یک کارت شبکه 1 Gbps کمتر از ۷٪ انرژی مصرف می‌کند [۲۷]، [۲۸]. در این مقاله کارت شبکه‌های مورد استفاده 1 Gbps می‌باشد. همچنین از آنجایی که معماری مورد بررسی واقع در یک مرکز داده ابر می‌باشد، در نتیجه ارتباطات میان سرورها در یک شبکه محلی می‌باشد و از تجهیزات شبکه به ندرت استفاده می‌شود. در نتیجه میزان انرژی مصرف شده ماشین‌های فیزیکی به میزان پردازنده و حافظه مصرفی آن‌ها بستگی دارد که بر اساس معیار SPECpower [۲۹] واقع در جدول ۵ و رفرنس [۲۸] محاسبه شده است.

همچنین معیار ترکیبی ESV برای نشان دادن میزان مصالحه بین مصرف انرژی و نقض توافق سطح سرویس است که به صورت زیر بدست می‌آید:

$$ESV = \text{Energy Consumption} \times SLAV \quad (14)$$

برای ارزیابی همزمان کمینه انرژی مصرفی، نقض توافق سطح سرویس و تعداد مهاجرت‌های ماشین‌های مجازی معیار ESM در رابطه (۱۵) تعریف شده در [۲۰] استفاده شده است.


$$ESM = ESV \times \text{Migration counts} \quad (15)$$

برای آزمایش روش پیشنهادی از ابزار CloudSim [۳۰] استفاده شده است که ابزاری برای مدلسازی و محاسبه زیرساخت‌ها و خدمات است. داده بارکاری واقعی به عنوان بخشی از پروژه کومان^{۲۱} [۳۱] است. در این پروژه، داده استفاده از پردازنده هر پنج دقیقه از بیشتر از هزاران ماشین مجازی جمع آوری شده و در فایل‌های مختلف ذخیره شده است. ماشین‌های مجازی روی ماشین‌های فیزیکی قرار گرفته‌اند که در بیشتر از ۵۰۰ مکان در سراسر جهان واقع شده‌اند. در واقع بارکاری نمایشی از محیط ابر، تحت زیرساخت به عنوان سرویس مثل آمازون است که چندین کاربر مستقل، ماشین‌های مجازی را ایجاد و مدیریت می‌کنند. جدول ۴ پیکربندی ماشین‌های فیزیکی که در این شبیه‌سازی استفاده شده‌اند را نشان می‌دهد. این جدول بر اساس استاندارد مقالات و استاندارد AmazonEC2 می‌باشد.

همچنین نمودار شکل ۲ وضعیت بار کاری مورد استفاده را نشان می‌دهد. در این نمودار در محور افقی روزهای بار کاری را نشان داده شده است. همچنین در محور عمودی سمت راست این نمودار تعداد ماشین‌های مجازی در هر روز این بار کاری مشخص شده و

محور عمودی سمت چپ میانگین بار کاری کلیه ماشین‌های مجازی در آن روز بار کاری را نشان می‌دهد.

محور عمودی سمت چپ میانگین بار کاری کلیه ماشین‌های مجازی در آن روز بار کاری را نشان می‌دهد.



شکل ۲- وضعیت بار کاری مورد استفاده

جدول ۶- انواع ماشین‌های مجازی مورد استفاده در ارزیابی

VM Type	High-CPU Medium Instance	Extra Large Instance	Small Instance	Micro Instance
CPU (MIPS)	2500	2000	1000	500
RAM (MB)	870	1740	1740	613

جدول ۷- اطلاعات بار کاری استفاده شده

Date	Number of VMs	Means (%)	SD (%)
03/03/2011	1052	12.31	17.09
06/03/2011	898	11.44	12.83
09/03/2011	1061	10.70	15.57
22/03/2011	1516	9.26	12.78
25/03/2011	1078	10.56	14.14
03/04/2011	1463	12.39	16.55
09/04/2011	1358	11.12	15.09
11/04/2011	1233	11.56	15.07
12/04/2011	1054	11.54	15.15
20/04/2011	1033	10.43	15.21

جدول ۴- پیکربندی ماشین‌های فیزیکی استفاده شده در شبیه‌سازی

Server	CPU Model	Cores	Frequency (MHz)	RAM (GB)
HP ProLiant G4	Intel Xeon 3040	2	1860	4
HP ProLiant G5	Intel Xeon 3075	2	2660	4

۴-۱- ارزیابی روش پیش‌بینی پیشنهادی

جدول ۵ میزان مصرف انرژی توسط هر یک از ماشین‌های فیزیکی تعریف شده در جدول ۶ را نشان می‌دهد. همان‌طور که مشاهده می‌شود مصرف انرژی ماشین‌های فیزیکی با افزایش بهره‌وری پردازنده، افزایش می‌یابد. همچنین ماشین‌های فیزیکی مختلف با فرکانس پردازنده مختلف در میزان بهره‌وری پردازنده یکسان، مصرف انرژی متفاوتی از خود نشان داده‌اند.

جدول ۵- میزان مصرف انرژی ماشین‌های فیزیکی به وات

HP ProLiant G5	HP ProLiant G4	Server
93.7	86	Idle
97	89.4	10%
101	92.6	20%
105	96	30%
110	99.5	40%
116	102	50%
121	106	60%
125	108	70%
129	112	80%
133	114	90%
135	117	Full

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - Y'_i)^2 \quad (16)$$

$$MAD = \frac{1}{n} \sum_{i=1}^n |Y_i - Y'_i| \quad (17)$$

جدول ۶ و ۷ به ترتیب انواع ماشین‌های مجازی مورد استفاده و بارکاری مورد استفاده را به تفکیک روزهای مختلف بارکاری نشان می‌دهد. بارکاری در ۱۰ روز مختلف از تاریخ ۲۰۱۱/۰۳/۰۳ تا

همچنین نتایج مقایسه خطای روش پیش‌بینی ترکیبی پیشنهادی با دو روش دیگر با استفاده از معیارهای MSE و MAD در جدول ۸ نشان داده شده است. نتایج مقایسه نشان می‌دهد که خطای روش پیش‌بینی ترکیبی پیشنهادی در معیار MSE نسبت به روش میانگین متحرک ۱۵.۷۳٪ و نسبت به روش هموارسازی نمایی ساده، ۱۶.۱۶٪ کاهش داشته است. همچنین خطای روش پیشنهادی با استفاده از معیار MAD، نسبت به روش میانگین متحرک ۸.۸۲٪ و نسبت به روش هموارسازی نمایی ساده ۹.۷۶٪ کمتر شده است.

جدول ۸- مقایسه‌ی میزان خطای روش‌های پیش‌بینی مختلف بر اساس

معیارهای خطای مختلف

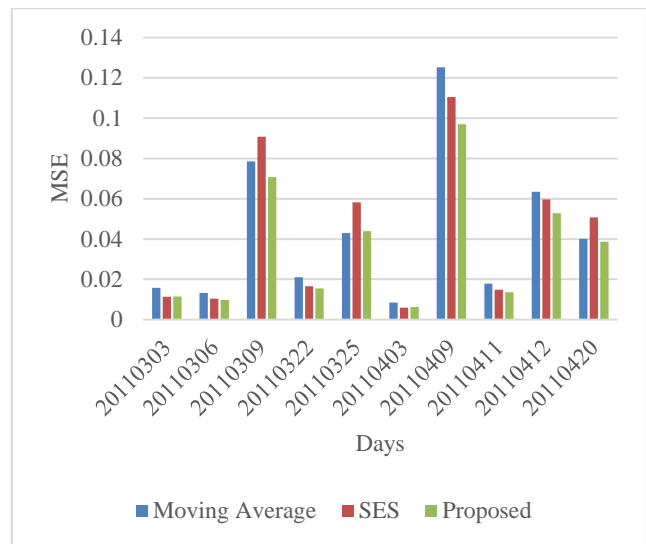
MAD	MSE	روش/معیار خطا
0.14862	0.042676	میانگین متحرک
0.150163	0.042896	هموارسازی نمایی ساده
0.135513	0.035962	پیشنهادی

۴-۲- ارزیابی نهایی روش پیشنهادی به همراه روش پیش‌بینی و جای‌گذاری پیشنهادی

در این بخش راهکار پیشنهادی با دو راهکار دیگر در جدول ۹ مقایسه شده است. راهکار اول از روش LR در پیش‌بینی بارکاری، MMT در انتخاب ماشین‌های مجازی، PABFD در جای‌گذاری ماشین‌های مجازی و SM در شناسایی ماشین‌های فیزیکی فروبار استفاده کرده است. راهکار دوم ماشین‌های فیزیکی فرابار را با روش حد آستانه ثابت شناسایی می‌کند و در انتخاب ماشین‌های مجازی از روش MMT، در جای‌گذاری ماشین‌های مجازی از روش PABFD و در شناسایی ماشین‌های فیزیکی فروبار از روش SM استفاده می‌کند. جدول ۹ سناریوهای مورد مقایسه را در ارزیابی نتایج را نشان می‌دهد.


جدول ۹- سناریوهای مورد بررسی در ارزیابی نتایج

توضیحات	سناریو
از LR برای شناسایی سرورهای فرابار/ MMT انتخاب ماشین‌های مجازی/ PABFD جای‌گذاری ماشین‌های مجازی/ SM شناسایی سرورهای فروبار	LR/MMT/PABFD/SM [۸]
از THR برای شناسایی سرورهای فرابار/ MMT انتخاب ماشین‌های مجازی/ PABFD جای‌گذاری ماشین‌های مجازی/ SM شناسایی سرورهای فروبار	THR/MMT/PABFD/SM [۸]
از ترکیب روش‌های پیش‌بینی رگرسیون، میانگین متحرک و هموارسازی نمایی ساده برای پیش‌بینی سرورهای فرابار/ MMT انتخاب ماشین‌های مجازی/ روش چند اکتشافی و امتیازدهی برای جای‌گذاری ماشین‌های مجازی/ SM شناسایی سرورهای فروبار	راهکار پیشنهادی




شکل ۳- مقایسه میانگین مربع خطای پیش‌بینی راهکار پیشنهادی با راهکارهای دیگر در ۱۰ روز بار کاری

همچنین در شکل ۴ میانگین انحراف مطلق روش پیش‌بینی پیشنهادی با دو روش پیش‌بینی میانگین متحرک و هموارسازی نمایی ساده مقایسه شده است.



شکل ۴- مقایسه میانگین انحراف مطلق پیش‌بینی راهکار پیشنهادی با راهکارهای دیگر در ۱۰ روز بار کاری

نتایج مقایسه میزان خطای پیش‌بینی راهکار پیشنهادی با دو راهکار دیگر در هر دو معیار ارزیابی خطا، نشان می‌دهد که در اکثر روزهای بار کاری خطای راهکار پیش‌بینی پیشنهادی از دو راهکار دیگر کمتر می‌باشد. دلیل این امر، استفاده از میانگین نتایج روش‌های پیش‌بینی مختلف با میزان خطاهای پیش‌بینی متفاوت می‌باشد. از آنجایی که دقت روش‌های پیش‌بینی مختلف از ابتدا برای ما روشن نیست، با استفاده از ترکیب روش‌های پیش‌بینی مختلف، مقدار پیش‌بینی نهایی به مقدار واقعی نزدیک‌تر شده و مقدار خطای پیش‌بینی کمتر می‌شود.



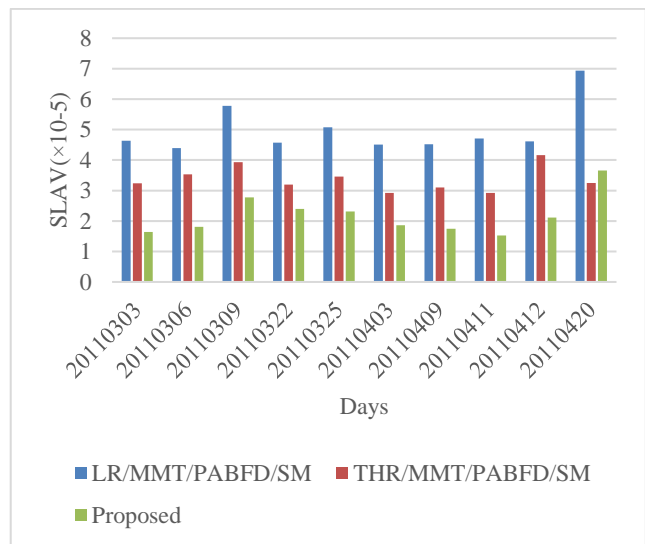
شکل ۷-مقایسه تعداد مهاجرت‌های ماشین‌های مجازی راهکار پیشنهادی با راهکارهای دیگر در ۱۰ روز بار کاری

ماشین‌های مجازی آن سریع‌تر مهاجرت داده می‌شوند که این امر نیز خود منجر به کاهش نقض توافق سطح سرویس می‌شود. همچنین با انتخاب ماشین فیزیکی با مصرف انرژی پایین‌تر، روش پیشنهادی توانسته در کلیه روزهای بار کاری نسبت به دو روش دیگر، انرژی کمتری را مصرف کند. از طرف دیگر به دلیل شناسایی به موقع ماشین‌های فیزیکی فرابار و مهاجرت ماشین‌های مجازی این سرورها، از افزایش بار بیش از اندازه این سرورها و در نتیجه مصرف بالای انرژی آن‌ها جلوگیری می‌شود.


نمودار شکل ۷ تعداد مهاجرت‌های ماشین‌های مجازی راهکار پیشنهادی را در ۱۰ روز بار کاری با دو راهکار دیگر مقایسه می‌کند. نتایج نشان می‌دهد که با شناسایی درست ماشین‌های فیزیکی فرابار و همچنین انتخاب سرورهای مناسب با احتمال ظرفیت پردازنده آزاد بیشتر برای جایگذاری ماشین‌های مجازی مهاجر، در راهکار پیشنهادی، در کلیه روزهای بار کاری تعداد مهاجرت‌های راهکار پیشنهادی از دو راهکار دیگر کمتر بوده است. دلیل بررسی این معیار این است که کاهش مهاجرت بیهوده ماشین‌های مجازی باعث کاهش PDM می‌شود که بخشی از رابطه SLAV است. پس با کاهش PDM، SLAV کاهش می‌یابد. در ادامه در نمودارهای شکل‌های ۸ و ۹ نتایج حاصل از دو معیار ESV و ESM در راهکار پیشنهادی با راهکارهای دیگر مقایسه شده است.

در نمودار شکل ۸ معیار ESV هر سه راهکار مورد بررسی قرار گرفته است. نتایج نشان می‌دهد که راهکار پیشنهادی نسبت به دو راهکار دیگر در کلیه روزهای بار کاری ESV کمتری دارد. همان‌طور که قبلاً گفته شد معیار ESV مصالحه‌ای را بین دو معیار انرژی و نقض توافق سطح سرویس برقرار می‌کند که نتایج نشان

نمودارهای شکل‌های ۵، ۶ و ۷ به ترتیب تعداد نقض‌های توافق سطح سرویس، میزان مصرف انرژی و تعداد مهاجرت‌های ماشین‌های مجازی و راهکار پیشنهادی را با دو سناریو دیگر مقایسه می‌کند. نتایج شبیه‌سازی نشان می‌دهد که تعداد نقض توافق سطح سرویس راهکار پیشنهادی در ۹ روز از ۱۰ روز بار کاری نسبت به روش THR/MMT/PABFD/SM کمتر بوده و در کلیه روزهای بار کاری از روش LR/MMT/PABFD/SM کمتر بوده است. دلیل این امر شناسایی به موقع ماشین‌های فیزیکی فرابار و انتقال ماشین‌های مجازی آن‌ها به ماشین‌های فیزیکی با میزان بهره‌وری، انرژی، تعداد ماشین مجازی و حافظه کمتر است. از طرف دیگر با انتخاب ماشین‌فیزیکی که ماشین‌های مجازی آن حافظه کمتری دارند، در صورت فراباری این ماشین‌فیزیکی،



شکل ۵-مقایسه تعداد نقض توافق سطح سرویس راهکار پیشنهادی با راهکارهای دیگر در ۱۰ روز بار کاری



شکل ۶-مقایسه میزان انرژی مصرفی راهکار پیشنهادی با راهکارهای دیگر در ۱۰ روز بار کاری

جدول ۱۰-مقایسه میانگین نتایج معیارهای هدف در راهکار پیشنهادی

ESM	ESV ($\times 10^{-3}$)	و راهکارهای دیگر			Approach
		Migrations	Energy	SLAV ($\times 10^{-5}$)	
280.4878 839	9.783416 433	28174.7	199.10 01	4.97 4	LR/MMT/PABF D/SM
207.0693 192	7.697076 165	26601.9	231.85 131	3.37 1	THR/MMT/PAB FD/SM
48.25240 716	3.235108 485	14642.3	152.17 683	2.18 4	Proposed

جدول ۱۱-درصد بهبود نتایج معیارهای هدف راهکار پیشنهادی نسبت

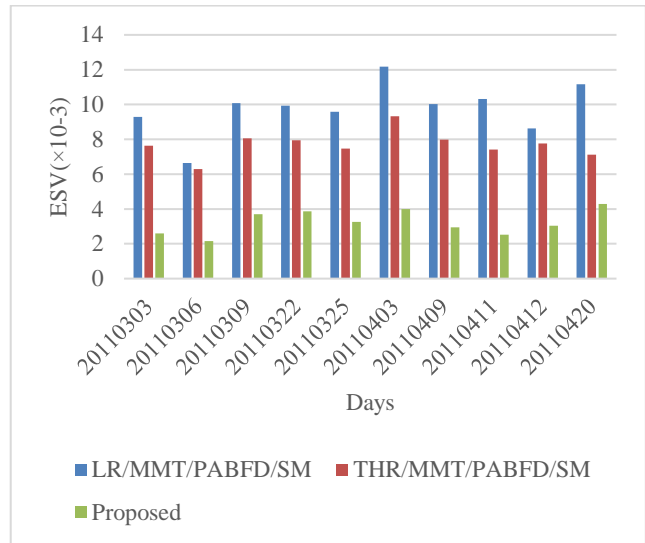
ESM	ESV ($\times 10^{-3}$)	به راهکارهای دیگر			Approach
		Migrations	Energy	SLAV ($\times 10^{-5}$)	
82.8 %	66.93 %	48.03%	23.57 %	56.09 %	LR/MMT/PABFD/S M
76.7 %	57.97 %	44.96%	34.36 %	35.21 %	THR/MMT/PABFD/ SM

همان‌طور که در جدول ۱۱ نشان داده شده است راهکار پیشنهادی به دلیل شناسایی درست و به موقع ماشین‌های فیزیکی فرابار و در نظر گرفتن معیارهای گوناگون در انتخاب ماشین فیزیکی مناسب توانسته تعداد تخطی‌های توافق سطح سرویس، مصرف انرژی و تعداد مهاجرت‌های بیهوده ماشین‌های مجازی را نسبت به دو راهکار دیگر به طور میانگین به ترتیب ۴۵.۶۵٪ و ۲۸.۹۶٪ و ۴۶.۴۹٪ کاهش دهد. همچنین مصالحه قابل توجهی بین میزان مصرف انرژی، تعداد تخطی‌های توافق سطح سرویس و مهاجرت ماشین‌های مجازی نسبت به دو راهکار دیگر برقرار کند.

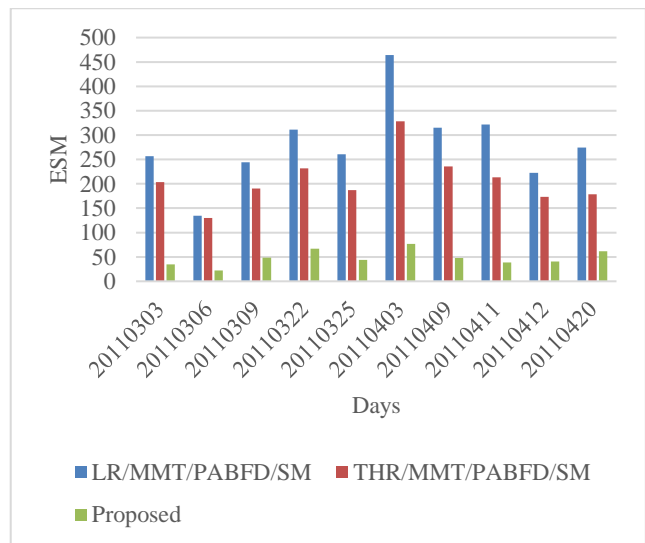
۵- نتیجه‌گیری و کارهای آینده

امروزه با افزایش مراکز داده ابر مصرف برق افزایش یافته و مدیریت زیرساخت ابر نیز پیچیده‌تر شده است. از طرف دیگر برآورده کردن نیازهای کاربران ابر از اهداف مهم در زیرساخت ابر می‌باشد. فرآیند تعیین وضعیت بار ماشین‌های فیزیکی و جای‌گذاری ماشین‌های مجازی روی ماشین‌های فیزیکی مناسب می‌تواند مصرف انرژی را کاهش دهد و از نقض توافق سطح سرویس کاربران جلوگیری کند. برای حل این‌گونه مسائل، یک راهکار جای‌گذاری ماشین‌های مجازی با توانایی پیش‌بینی مورد نیاز است تا ماشین‌های مجازی را به طور کارا در زمان اجرا در میزبان‌های مناسب قرار دهد. در این تحقیق یک راهکار جدید ارائه شد که شامل یک روش پیش‌بینی ترکیبی برای شناسایی ماشین‌های فیزیکی فرابار و یک روش چند اکتشافی برای تعیین ماشین‌های فیزیکی مناسب مقصد جهت جای‌گذاری ماشین‌های مجازی می‌باشد. راهکار پیشنهادی با راهکارهای دیگر ارائه شده در

می‌دهد راهکار پیشنهادی نسبت به دو راهکار دیگر مصالحه‌ی بهتری بین این دو معیار برقرار کرده است.



شکل ۸-مقایسه ESV راهکار پیشنهادی با راهکارهای دیگر در ۱۰ روز بار کاری



شکل ۹-مقایسه ESM راهکار پیشنهادی با راهکارهای دیگر در ۱۰ روز بار کاری

نمودار شکل ۹ معیار ESM را در راهکار پیشنهادی با راهکارهای دیگر در ۱۰ روز بار کاری مقایسه می‌کند. نتایج حاصل از این مقایسه نشان می‌دهد که راهکار پیشنهادی نسبت به دو راهکار دیگر مصالحه‌ی بهتری را در میزان انرژی مصرفی، نقض توافق سطح سرویس و تعداد مهاجرت‌های ماشین‌های مجازی برقرار کرده است. در نهایت جدول ۱۰ میانگین نتایج معیارهای مختلف در راهکار پیشنهادی و جدول ۱۱ درصد بهبود نتایج معیارها را با راهکارهای دیگر مقایسه می‌کند.

93, pp. 322-342, 2019.

- [14] F. Farahnakian , A. Ashraf , T. Pahikkala , P. Lijeberg , J. Plosila , I. Porres , H. Tenhunen, "Using Ant Colony System to Consolidate VMs for Green Cloud Computing," *IEEE TRANSACTIONS ON SERVICES COMPUTING*, vol. 8, no. 2, pp. 178-198, 2015.
- [15] H. Hallawi ,J. Mehnén ,H. He, "Multi-Capacity Combinatorial Ordering GA in Application to Cloud Resources Allocation and Efficient Virtual Machines Consolidation," *Future Generation Computer Systems*, vol. 69, pp. 1-10, 2017.
- [16] H. Ferdaus, M. Murshed ,R. Calheiros ,B. Rajkumar, "Virtual Machine Consolidation in Cloud Data Centers Using ACO Metaheuristic," in *European Conference on Parallel Processing vol 8632 Springer, Cham*, 2014.
- [17] F. Teng , L. Yu , T. Li , D. Deng , F. Magoules, "Energy efficiency of VM consolidation in IaaS clouds," *The Journal of Supercomputing*, vol. 73, no. 2, pp. 782-809, 2017.
- [18] A. Beloglazov , J. Abawajyb, R. Buyyaa, "Energy-aware resource allocation heuristics for efficient management of data centers," *Future Generation Computer Systems*, vol. 28, no. 5, pp. 755-768, 2012.
- [19] A. Horri·M. S. Mozafari·Gh. Dastghaibiyfard, "Novel resource allocation algorithms to performance and energy efficiency in cloud computing," *The Journal of Supercomputing*, vol. 69, pp. 1445-1461, 2014.
- [20] E. Arianyan , H. Taheri, S. Sharifian, "Novel energy and SLA efficient resource management heuristics for consolidation of virtual machines in cloud data centers," *Computers & Electrical Engineering*, vol. 47, pp. 222-240, 2015.
- [21] M Dayarathna, Y Wen, R. Fan, "Data center energy consumption modeling: a survey.," *IEEE Communications Surveys & Tutorials*, vol. 18, pp. 732-794, 2018.
- [22] S. Rahmani, V. Khajehvand, "Burst-aware virtual machine migration for improving performance in the cloud," *International journal of communication systems*, pp. 1-21, 2020.
- [23] S. Islam; J. Keung; K. Lee; A. Liu, "Empirical prediction models for adaptive resource provisioning in the cloud," *Future Generation Computer Systems*, vol. 28, no. 1, pp. 155-162, 2012.
- [24] V. Rogerio Messia; J. Cezar Estrella; R. Ehlers; M. Jose Santana; R. Carlucci Santana; S. Rei, "Combining Time Series Prediction Models Using Genetic Algorithm to Auto-scaling Web Applications Hosted in the Cloud Infrastructure," *Neural Computing and Applications*, vol. 27, p. 2383-2406, 2018.
- [25] S. Rahmani; V. Khajehvand; M. Torabian, "Kullback-Leibler distance criterion consolidation in cloud," *Journal of Network and Computer Applications*, vol. 170, 2020.
- [26] F. Farahnakian , A. Ashraf , T. Pahikkala , P. Lijeberg , J. Plosila , I. Porres , H. Tenhunen, "Using Ant Colony System to Consolidate VMs for Green Cloud Computing," *IEEE TRANSACTIONS ON SERVICES COMPUTING*, vol. 8, no. 2, pp. 178-198, 2015.
- [27] H Liu, C-Z Xu, H Jin, J Gong, X Liao., "Performance and energy modeling for live migration of virtual machines," in *Proceedings of the 20th International Symposium on High Performance Distributed Computing*, 171-182, 2011.
- [28] P. H.P.Castro; V. L.Barreto; S. Corrêa;L. ZambenedettiGranvilleb; K. VieiraCardoso;, "A joint CPU-RAM energy efficient and SLA-compliant approach for cloud data centers," *Computer Networks*, vol. 91, pp. 1-13, 2016.
- [29] SPEC, "SPEC power benchmarks, Standard Performance Evaluation Corporation, in, Retrieved from <http://www.spec.org/benchmarks.html#power>," 2011. [Online].
- [30] R.N. Calheiros, R. Ranjan, A. Beloglazov, C.A. De Rose, R. Buyya, "CloudSim: a toolkit for modeling and simulation of cloud computing environments and evaluation of resource provisioning algorithms," *Software:Practice and Experience*, vol. 41, no. 1, pp. 23-50, 2011.
- [31] K. Park and V. Pai, "CoMon: a mostly-scalable monitoring system for PlanetLab," *ACM SIGOPS Operating Systems Review*, vol. 40, no. No 1, pp. 65-74, 2006.

این زمینه مقایسه شد و نتایج حاصل از شبیه‌سازی نشان می‌دهد که راهکار پیشنهادی به طور میانگین تعداد نقض‌های توافق سطح سرویس، میزان مصرف انرژی و تعداد مهاجرت‌های ماشین‌های مجازی را به ترتیب ۴۵.۶۵٪، ۲۸.۹۶٪ و ۴۶.۴۹٪ کاهش داده و بین مصرف انرژی، تعداد نقض‌های توافق سطح سرویس و تعداد مهاجرت‌های ماشین‌های مجازی مصالحه برقرار کرده است. ما در آینده قصد داریم تا برای شناسایی ماشین‌های فیزیکی فرابار روش‌های پیش‌بینی دیگری را نیز مورد بررسی قرار دهیم و همچنین در مرحله تعیین ماشین فیزیکی مناسب معیارهای بیشتری را در نظر بگیریم. به علاوه برای شناسایی فراباری سرورها معیارهای دیگری نیز بررسی خواهد شد.

مراجع

- [1] S. Basu, G. Kannayaram, S. Ramasubbarreddy, "Improved Genetic Algorithm for Monitoring of Virtual Machines in Cloud Environment," *Smart Intelligent Computing and Applications*, vol. 105, pp. 319-326, 2019.
- [2] Anitha Ponraj, "Optimistic virtual machine placement in cloud data centers using queuing approach," *Future Generation Computer Systems*, vol. 93, pp. 338-344, 2019.
- [3] Manoel C. Silva Filho, Claudio C. Monteiro , Pedro R.M. Inácio , Mário M. Freire, "Approaches for optimizing virtual machine placement and migration in cloud environments: A survey," *Journal of Parallel and Distributed Computing*, vol. 111, pp. 222-250, 2018.
- [4] Z. Li, "An adaptive overload threshold selection process using Markov decision processes of virtual machine in cloud data center," *Cluster Computing*, vol. 22, p. 3821-3833, 2019.
- [5] M. Masdari, S.S Nabavi,V. Ahmad, "An overview of virtual machine placement schemes in cloud computing," *Journal of Network and Computer Applications*, vol. 66, pp. 106-127, 2016.
- [6] P. A. Dinda, "Design, implementation, and performance of an extensible toolkit for resource," *Parallel Distrib. Syst. IEEE Trans*, vol. 17, no. 2, pp. 160-173, 2006.
- [7] J. Liang, K. Nahrstedt, and Y. Zhou, "Adaptive multi-resource prediction in distributed resource," in *IEEE International Symposium on Cluster Computing and the Grid*, Chicago, IL, USA, USA, 2004.
- [8] A. Beloglazov , 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. 24, no. 13, pp. 1397-140, 2012.
- [9] E. Arianyan;H. Taheri;S. Sharifian, "Novel heuristics for consolidation of virtual machines in cloud data centers using multi-criteria resource management solutions," *The Journal of Supercomputing*, vol. 72, no. 2, pp. 688-717, 2016.
- [10] J. Subirats and J. Guitart, "Assessing and forecasting energy efficiency on Cloud computing platforms," *Futur. Gener. Comput. Syst*, vol. 45, pp. 70-94, 2015.
- [11] M. Ghobaei-Arani; A. Rahmanian; M. Shamsi ; A. Rasouli-Kenari, "A learning-based approach for virtual machine placement in cloud data centers," *Int J Commun Syst*, vol. 31, no. 8, pp. 1-18, 2018.
- [12] F. Alharbi, Yu. Tian, M. Tang, We. Zhang, "An Ant Colony System for energy-efficient dynamic Virtual Machine Placement in data centers," *Expert Systems with Applications*, vol. 120, pp. 228-238, 2019.
- [13] R. Shawa, E. Howleya, E. Barretta, "An energy efficient anti-correlated virtual machine placement algorithm using resource usage predictions," *Simulation Modelling Practice and Theory*, vol.

پاورقی‌ها:

- ¹ Hot Spot
- ² Overloaded
- ³ Underloaded
- ⁴ Regression model
- ⁵ Moving average
- ⁶ Simple Exponential Smoothing (SES)
- ⁷ Autoregressive (AR)
- ⁸ Autoregressive Moving Average (ARMA)
- ⁹ Autoregressive Integrated Moving Average (ARIMA)
- ¹⁰ Consolidation
- ¹¹ Profile
- ¹² Best Fit Decreasing
- ¹³ NP-hard
- ¹⁴ Dynamic Voltage Frequency Scaling (DVFS)
- ¹⁵ Virtual Machine Monitor (VMM)
- ¹⁶ Infrastructure as a service (IaaS)
- ¹⁷ Network-attached Storage (NAS)
- ¹⁸ RAM
- ¹⁹ Minimum Migration Time (MMT)
- ²⁰ Multi Heuristic
- ²¹ CoMon
- ²² Mean Squared Error (MSE)
- ²³ Mean Absolute Deviation (MAD)