

دریافت مقاله: ۱۳۹۵/۱/۱۲

پذیرش مقاله: ۱۳۹۶/۱۱/۲۸

## پیش‌بینی تعداد مناسب ماشین‌های مجازی بر اساس سری زمانی و روش‌های هوشمند مبتنی بر خوشه‌بندی ماشین‌های مجازی

الناز اسداللهی<sup>۱</sup>، سید امیر اصغری<sup>۲\*</sup>

<sup>۱</sup> کارشناسی ارشد، دانشکده مهندسی برق و کامپیوتر، دانشگاه تبریز، تبریز، ایران

asadollahi@tabrizu.ac.ir

<sup>۲</sup> استادیار، دانشکده مهندسی برق و کامپیوتر، دانشگاه خوارزمی، تهران، ایران

asghari@khu.ac.ir

### چکیده

یکی از مهم‌ترین چالش‌های رایانش ابری، مدیریت منابع و بهینه‌سازی تخصیص منابع در مراکز داده‌ای ابری در لایه زیرساخت است. در این مقاله به بررسی موضوع تخمین تعداد مناسب ماشین‌های مجازی در مراکز داده‌ای ابری پرداخته شده است. از جمله ایرادات رویکردهای پیشین، در نظر گرفتن مستقل ماشین‌های مجازی و بی‌توجهی به رفتارهای مشابه ماشین‌های مجازی است. بهره‌جویی از الگوریتم‌های یادگیری ماشین و سری زمانی و راهکار خوشه‌بندی رفتاری و خودکار ماشین‌های مجازی به عنوان عناصر زمینه‌ساز تأمین بهینه منابع در نظر گرفته شده است. پیش‌بینی سری زمانی و استفاده از گذشته، برای تخمین آینده به هدف جلوگیری از نقض توافق سطح خدمات از یک سو و جلوگیری از صرف هزینه‌های تأمین، نگهداری و مجازی‌سازی ماشین‌های مجازی که در آینده مورد استفاده قرار نخواهند گرفت از سوی دیگر، موجب افزایش کیفیت خدمات ابری شده است. هر میزانی که پیش‌بینی انجام شده دقیق‌تر باشد، منابع ماشین‌های مجازی آماده‌شده با نیاز واقعی مشتریان در آینده سازگارتر خواهد بود و فراهم‌کنندگان خدمات ابری کمتر متضرر می‌شوند. نوآوری انجام‌شده اعمال خوشه‌بندی رفتاری و خودکار ماشین‌های مجازی است که موجب کاهش تعداد سری‌های زمانی مشابهی که در نهایت منجر به دریافت یک نوع ماشین مجازی می‌شود، دقت در پیش‌بینی سری زمانی ماشین‌های مجازی، کاهش بار پردازشی و سهولت در اعمال راهبردهای مدیریتی شده است. به کارگیری روش پیشنهادی، موجب افزایش دقت پیش‌بینی‌کننده‌ها و کاهش خطا به میزان ۱٫۹۳ برابر شده است.

واژه‌های کلیدی: رایانش ابری، تأمین منابع، ماشین مجازی، پیش‌بینی سری زمانی، خوشه‌بندی خودکار.

## ۱. مقدمه

در مدل رایانشی ابر، سرویس‌های بسیاری عرضه می‌شود. زیرساخت به‌عنوان سرویس (IaaS) [۱]، پلت فرم به‌عنوان سرویس (PaaS) [۲] و نرم‌افزار به‌عنوان سرویس (SaaS) [۳] از جمله مهم‌ترین سرویس‌های رایانش ابری به‌شمار می‌آیند و هر کدام خدمات متفاوتی را به کاربران ابر ارائه می‌دهند. یکی از مدل‌های خدماتی ارائه شده، زیرساخت به‌عنوان سرویس است که در آن زیرساخت‌هایی که مجازی‌سازی شده‌اند، به‌صورت سرویس عرضه می‌شوند و منابع سخت‌افزاری خام، مانند پردازنده، حافظه، ذخیره‌سازی و شبکه، به‌صورت سرویس‌های مجازی یا ماشین‌های مجازی به مشتریان ارائه می‌گردد [۴]. مشتریان به‌جای صرف هزینه زیاد برای ایجاد مرکز داده‌ای شخصی و یا خرید خدمات از شرکت‌های میزبان وب و سپس صرف هزینه برای به‌کارگیری کارمندان جدید برای مدیریت تجهیزات مورد نیاز، می‌توانند از ارائه‌دهندگان زیرساخت، این تجهیزات را اجاره کنند و فقط در ازای آنچه مصرف می‌کنند هزینه پرداخت نمایند. امکان دسترسی به منابع پردازشی مورد نیاز بر اساس تقاضا، زیرساخت به‌عنوان سرویس را به یک انتخاب اقتصادی و انعطاف‌پذیر برای مشتریان تبدیل می‌کند؛ زیرا به مشتری این اجازه داده می‌شود که مقدار مناسب منابع را به‌صورت پویا مبنی بر نیاز درخواست کند.

صرف نظر از نوع ابر، مدیریت منابع در ابر از اهمیت زیادی برخوردار است. بررسی‌های اخیر نشان می‌دهد که امنیت و کارایی دو اولویت اصلی برای مصرف‌کنندگان خدمات ابری هستند که کارایی به‌شدت تحت تأثیر شیوه مدیریت منابع قرار دارد [۵]. یکی از مهم‌ترین زیرشاخه‌های مدیریت منابع در حوزه رایانش ابری مسئله تأمین فوری منابع، در مراکز داده‌ای رایانش ابری است [۶ و ۷]. در حال حاضر، تحقیقات وسیعی برای طراحی و پیاده‌سازی سازوکارهای مناسب برای مدیریت منابع در ابر در حال انجام است. یک راهکار کارآمد برای مدیریت منابع باید باعث بهره‌وری بیشتر

از سخت‌افزارهای توزیع‌شده زیرساخت و همچنین دستیابی به کارایی بالاتر سیستم گردد [۸]. بهترین روش تأمین ماشین مجازی که وجود دارد، می‌تواند فرایند تأمین را در چند دقیقه انجام دهد. برای سرویس‌های نرمال این تأخیر منطقی است، اما برای وظایفی که در طی محاسبات نیاز به تعدیل مقیاس دارند، غیرقابل قبول است. بنابراین تأمین ماشین‌های مجازی باید در مدت زمان چند ثانیه انجام گیرد.

موفقیت خدمات ابری به‌شدت به مدیریت مؤثر منابع مجازی وابسته است. مدیریت مؤثر منابع مجازی به‌عنوان یک چالش عمده و پیچیده شناخته شده است. عامل ایجادکننده این پیچیدگی ماهیت پویای منابعی است که ناهمگون هستند [۹]. در این مقاله، سعی بر آن شده است که برخلاف اکثر روش‌های موجود مدیریت منابع، که هر ماشین مجازی را به‌عنوان یک جعبه سیاه در نظر می‌گیرد [۱۰]، از ویژگی‌های رفتاری ماشین‌های مجازی به‌عنوان کلیدی برای کشف شباهت میان آن‌ها استفاده کرده و خوشه‌بندی ماشین‌های مجازی را انجام دهد. اعمال خوشه‌بندی ماشین‌های مجازی به‌عنوان ایده اصلی در نظر گرفته می‌شود.

در ادامه به شرح ساختار کلی مقاله پرداخته می‌شود. در فصل دوم ابتدا به مرور کارهای انجام‌شده در تأمین منابع پرداخته می‌شود. سپس مسئله اصلی مورد بررسی، که تخمین تعداد مناسب ماشین‌های مجازی در محیط ابری است، طرح می‌گردد و در نهایت راهکار ارائه‌شده برای حل مسئله به همراه جزئیات بیان می‌شود. فصل چهارم نتایج تجربی به‌دست‌آمده ارائه می‌گردد و در نهایت، نتیجه‌گیری کلی تحت عنوان فصل پنجم مطرح می‌شود.

## ۲. مروری بر کارهای پیشین

در کارهایی که توسط پژوهشگران برای انجام تأمین منابع، زمانبندی و توازن بار در محیط ابری صورت گرفته است، دامنه برنامه‌های کاربردی که در نظر گرفته شده، ممکن است وابسته به کاربر یا فراهم‌کننده خدمات، متفاوت باشد. برای به‌دست آوردن نتایج بهتر شمار زیادی از رویکردهای متفاوت

نظری صف می توان به نگرانی در رابطه با زمان ورود، در تخمین پارامترها اشاره کرد [۱۳].

#### ۴.۲. رویکرد مدیریت منابع مبتنی بر بازار

مادامی که رایانش ابری بر نحوه پرداخت به میزان مصرف تأکید می کند، یک توان بالقوه برای به کارگیری روش های مدیریتی منابع مبتنی بر بازار وجود دارد. روش های مدیریتی منابع مبتنی بر بازار به طبقه بندی بازگشت ارز و هزینه تخصیص منبع، بسته به محدودیت های کیفیت خدمات مشتری و هزینه های انرژی می پردازد. شمار زیادی از سیستم ها از روش مبتنی بر بازار برای مدیریت منابع در انواع محیط های محاسباتی استفاده می کنند [۱۴]؛ اما هیچ یک از این سیستم ها بر مسئله بهره وری از انرژی به منظور افزایش سود مالی تمرکز نکرده اند. بنابراین هیچ یک از این سیستم ها قادر به حمایت از رایانش ابری سبز و پیشنهاد منبع با در نظر گرفتن تمام محدودیت های کیفیت خدمات مشتریان و صرفه جویی در انرژی نیستند.

#### ۵.۲. رویکرد سری زمانی و الگوریتم های یادگیری ماشین

سری زمانی و رویکردهای مبتنی بر الگوریتم های یادگیری ماشین جزو رویکردهای فعال در طبیعت هستند. روش کلی شامل تحلیل، یادگیری و تخمین یا پیش بینی پارامترها با برداشت از مقادیر داده در گذشته است.

رویکرد یادگیری ماشین قادر به معرفی تأمین پویا با روش های پیش بینی هوشمند و خودکار برای مدیریت مراکز داده های ابری است. این روش ها قادر به یادگیری رفتار سیستم از داده ها در گذشته و تخمین رفتار آنها در آینده هستند [۱۲]. برای پیش بینی سری های زمانی، استفاده از الگوریتم های یادگیرنده هوش مصنوعی به عنوان یک رویکرد فعال مد نظر گرفته شده است. روش حل مسئله تخمین تعداد مناسب ماشین های مجازی در محیط ابری با استفاده از الگوریتم های یادگیرنده هوش مصنوعی به پیش بینی سری زمانی تقاضا با استفاده از پیش بینی کننده های نایو، رگرسیون خطی، رگرسیون غیر خطی، رگرسیون خطی با غیر کرنل و الگوریتم های

ارائه شده است که در ادامه به توضیح اجمالی این رویکردها پرداخته می شود.

#### ۱.۲. رویکرد مبتنی بر سیاست

بسیاری از بازیگران بازار تجاری مانند *مازون* یک رویکرد مبتنی بر سیاست را به کار می گیرند که در آن به تعریف مجموعه ای از سیاست ها برای مدیریت تخصیص منابع به یک برنامه کاربردی می پردازند. سیاست ها به عنوان حد بالا و حد پایین معیارهای کیفیت خدمات، در نظر گرفته می شوند و در صورتی که محدودیت ها نقض شوند، یک واکنش متناظر به وقوع می پیوندد. واکنش متناظر می تواند شامل وارد کردن یا خارج کردن یک یا چند ماشین مجازی به محیط ابر باشد که بسته به سیاست تعیین شده، این واکنش مشخص می گردد [۱۱].

#### ۲.۲. رویکرد نظری کنترل

در رویکرد نظری کنترل، از کنترل کننده ها به منظور انجام تأمین منابع استفاده می شود. از جمله ایرادات رویکرد نظری محدودیت در استفاده از ویژگی های کارایی است. نظریه های کنترل احتیاج به آموزش سیستم دارند تا از این طریق بتوانند پارامترهای کنترلی مربوط به یک حجم کاری رسیده را تشخیص دهند. از لحاظ پیاده سازی آسان هستند؛ اما برای رسیدن به دقت بالا روش های خوبی نیستند به این معنا که احتمال بروز خطا در این دسته از روش ها بالاست [۱۲].

#### ۳.۲. رویکرد نظری صف

این رویکرد در شماری از کارها به منظور تخمین پارامترهای کارایی در برنامه های کاربردی اینترنت به کار گرفته می شود. رویکرد مبتنی بر صف از جمله روش های آسان برای پیاده سازی به شمار می آید. دلیل آسان بودن پیاده سازی را می توان عدم نگهداری داده های آموزشی دانست. برخلاف روش های هوش مصنوعی که مجبور به نگهداری این اطلاعات اند، در رویکرد نظری صف داده های آموزشی نگهداری نمی شوند. واضح است که نگهداری داده های حجیم احتیاج به امکانات ویژه ای دارد که در رویکرد نظری صف نیازی به تأمین این امکانات ویژه نیست. از جمله معایب روش

ماشین مجازی را در محیط ابر فراهم کند، با نظر به اینکه هزینه‌ای بابت منابع بیش از حد تخمین زده شده نپردازد و میزان تقاضا بیشتر از میزان در نظر گرفته شده باشد، نقص توافق سطح خدمات رخ می‌دهد و فراهم‌کننده مجبور به پرداخت هزینه جریمه نقض توافق سطح خدمات می‌شود.

در اینجا اهمیت پیش‌بینی تعداد مناسب ماشین‌های مجازی آشکار می‌شود. پیش‌بینی تعداد مناسب ماشین‌های مجازی، به فراهم‌کنندگان خدمات ابری کمک می‌کند تا در تأمین ماشین‌های مجازی دچار تخمین کمتر از حد و تخمین بیشتر از حد نشوند. به‌طور معمول مسئله تأمین فوری منابع درخواست شده را می‌توان به‌عنوان یک مسئله پیش‌بینی سری زمانی در نظر گرفت.

در واقع مسئله تأمین منابع در ابر به‌عنوان یک مسئله پیش‌بینی در نظر گرفته می‌شود و سری زمانی تقاضاها مربوط به ماشین‌های مجازی هدف پیش‌بینی است.

#### ۴. راهکار پیشنهادی

در راهکار پیشنهادی، تخمین تعداد مناسب ماشین‌های مجازی در دو فاز انجام می‌شود: در فاز اول، ماشین‌های مجازی خوشه‌بندی خودکار و رفتاری می‌شوند و در فاز دوم با استفاده از الگوریتم‌های یادگیرنده هوش مصنوعی و اعمال یک روش گروهی سعی بر پیش‌بینی تعداد مناسب ماشین‌های مجازی می‌شود.

۱.۴. فلوچارت روش تخمین تعداد مناسب ماشین‌های مجازی در شکل (۱) فلوچارت روش تخمین تعداد مناسب ماشین‌های مجازی ارائه شده است و در ادامه به توضیح هر بخش از آن پرداخته می‌شود و بخش نوآوری اعمال شده مورد بررسی قرار می‌گیرد.

در ابتدا در خواست‌های رسیده از جانب مشتریان مبنی بر دریافت منابع در یک بازه زمانی  $t$ ، در یک فایل مخصوص ذخیره‌سازی می‌شود. تمام سری‌های زمانی مطرح شده در بازه زمانی یک‌روزه در نظر گرفته شده است. سری زمانی جمع‌آوری شده توسط برش‌های متفاوت، سطح پیچیدگی متفاوتی

مکاشفه‌ای استفاده می‌شود [۵]. نتایج حاصل از این طرح نشان می‌دهد، برای تخمین و پیش‌بینی سری‌های زمانی به دلیل تنوعی که انواع مختلف ماشین مجازی دارند و به‌تبع آن سری‌های زمانی متفاوتی که ایجاد می‌شود، نمی‌توان یک پیش‌بینی‌کننده‌ای ارائه داد که برای همه انواع ماشین‌های مجازی بهترین جواب را نتیجه دهد. نتایج به‌دست‌آمده از این راهکار و عدم یافت یک پیش‌بینی‌کننده بهینه که برای انواع ماشین مجازی همواره بهترین جواب را ارائه دهد، ایده خوشه‌بندی رفتاری ماشین‌های مجازی را به ذهن می‌رساند.

مطالعات انجام شده نشان می‌دهد به‌کارگیری روش‌های سنتی پیش‌بینی سری زمانی برای حل مسئله تأمین فوری منابع مورد نیاز، مناسب نخواهد بود؛ زیرا کارایی قابل قبولی را ارائه نمی‌دهند [۱۵]. علاوه بر این، روش‌های پیش‌بینی سنتی قادر به انطباق با تغییرات پویای و وابسته محیط ابر نیستند [۱۶].

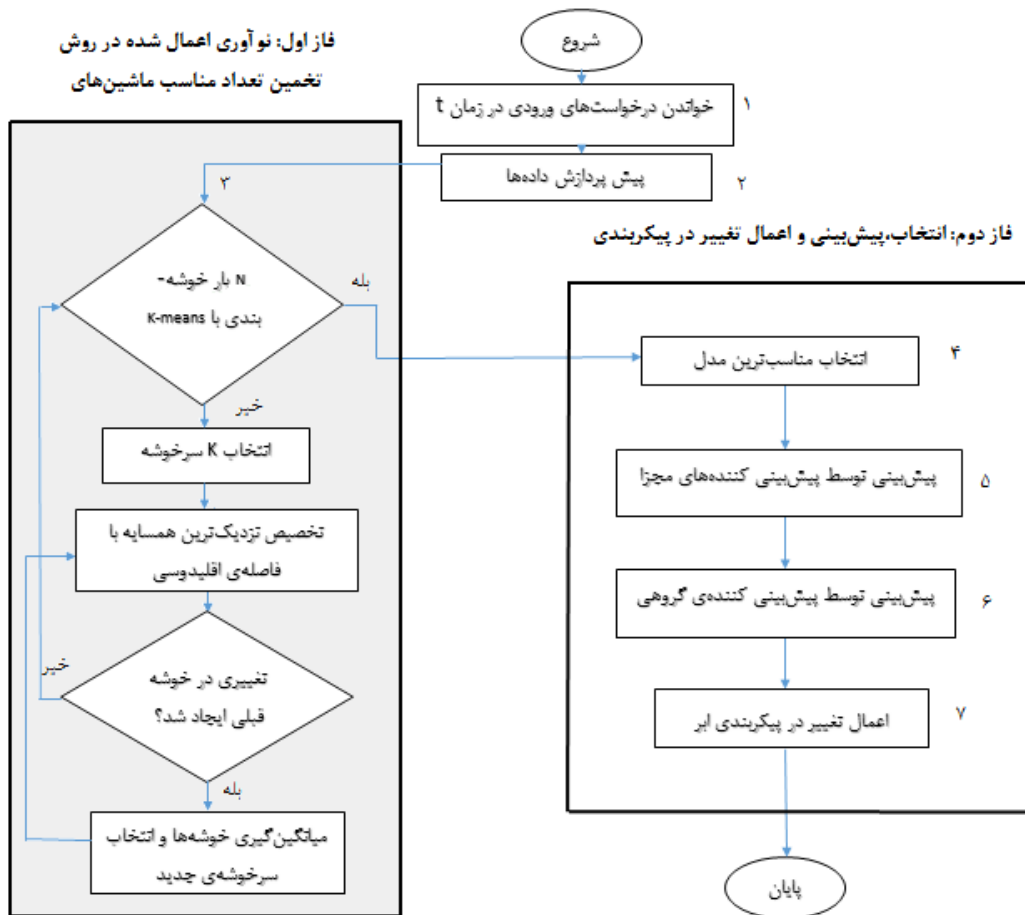
#### ۳. طرح مسئله

در محیط پویای ابر، مشتریان همواره در حال تغییرند. مشتریان بسته به درخواستی که از محیط رایانش ابری دارند، منابع مورد نیاز خود را تقاضا می‌کنند. فراهم‌کنندگان منابع ابری در برابر خدماتی که به مشتریان خدمات ابر ارائه می‌دهند، ملزم به رعایت قرارداد وضع شده در توافق سطح خدمات هستند [۱۷]. فراهم‌کنندگان خدمات ابری مالک تجهیزات سخت‌افزاری و ماشین‌های فیزیکی نیستند، بلکه سخت‌افزار و منابع فیزیکی را اجاره می‌کنند [۱۸]. آن‌ها با اعمال فناوری مجازی‌سازی، به ساخت نمونه‌های مجازی از منابع فیزیکی می‌پردازند و با اجرای برنامه‌های کاربردی منابع مجازی را در اختیار مشتری ابر قرار می‌دهند. در صورتی که فراهم‌کنندگان ابر شمار زیادی از ماشین‌های مجازی را به امید آنکه در آینده نزدیک مورد استفاده قرار خواهند گرفت، در محیط رایانش ابری فراهم‌کنند اما میزان تقاضا برای دستیابی به منابع کمتر از میزان در نظر گرفته شده توسط ابر باشد، از آنجا که نگهداری، مجازی‌سازی و تأمین منابع برای فراهم‌کننده ابر هزینه‌بر است [۱۹]، فراهم‌کننده ابر متضرر می‌گردد. اگر فراهم‌کننده تعداد اندکی

باشد. جمع‌آوری سری زمانی ساعتی نیز نمی‌تواند مناسب باشد؛ زیرا طول عمر ماشین‌های مجازی بسیار کوتاه نیست. یک بازه زمانی مناسب، مقادیر در هر برجسب زمانی را با داده‌های آماری مهمی روبه‌رو خواهد کرد. بنابراین داده‌های در نظر گرفته شده برای بازه زمانی یک روز مناسب‌ترین حالت در نظر گرفته می‌شود.

هر در خواست شامل مجموعه‌ای از اطلاعات است که ممکن است برای حل مسئله اهمیتی نداشته باشد. در مرحله پیش‌پردازش داده‌ها ورودی به یک سری زمانی تبدیل شده و سری زمانی مربوط به هر ماشین مجازی بروزرسانی می‌شود.

را برای پیش‌بینی خواهند داشت. برای مثال همان طور که از شکل (۲) مشخص است، سری‌های جمع‌آوری شده در هفته، روز و ساعت بسیار متفاوت‌اند. شکل (۲) نشان می‌دهد که هر چقدر بازه‌ها بزرگ‌تر باشند، مقدار تأمین در هر بازه زمانی بزرگ‌تر خواهد شد. بنابراین اگر بازه زمانی هفته در نظر گرفته شود، تعداد ماشین‌های مجازی بیشتری را در هر بازه زمانی باید تأمین کرد. در مقایسه با یک برش ظریف‌تر، انحراف پیش‌بینی در بخش کوچک‌تر برای سری زمانی جمع‌آوری شده هفتگی، اتلاف منبع زیادی را به همراه خواهد داشت. بنابراین جمع‌آوری سری زمانی هفتگی نمی‌تواند منعکس‌کننده شرایط واقعی ابر



شکل (۱): فلوچارت روش تخمین تعداد مناسب ماشین‌های مجازی

ماشین مجازی و همچنین برای جلوگیری از تکرار پیش‌بینی سری‌های زمانی ایده مطرح شده در این بخش، خوشه‌بندی رفتاری سری‌های زمانی متعلق به ماشین‌های مجازی شبیه به هم است.

فاز اول: خوشه‌بندی ماشین‌های مجازی به دلیل وجود شباهت زیاد بین درخواست‌هایی که در نهایت منجر به تخصیص یک نوع خاصی از ماشین‌های مجازی می‌شود و وجود وابستگی، بین سری‌های زمانی مربوط به یک نوع

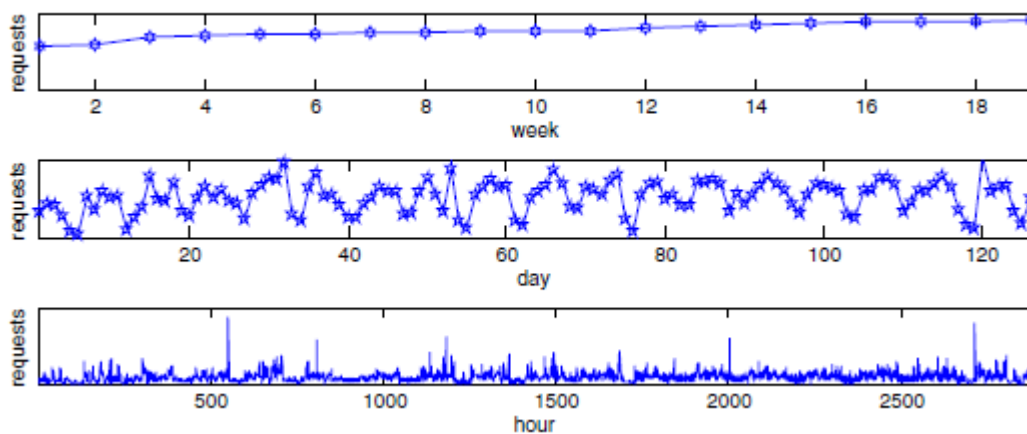
در الگوریتم  $k$ -means به کار گرفته شده، بردار ویژگی‌ها شامل هفت ویژگی است. در ادامه به توضیح این ویژگی‌ها پرداخته می‌شود. آهنگ تغییرات سری زمانی، با یک تابع درجه سوم طبق رابطه (۲) مشخص شده است. در شکل (۳) آهنگ تغییرات سیگنال شش سری زمانی که به صورت تصادفی از مجموعه داده‌ها انتخاب شده، نمایش داده شده است. چهار ضریب  $a$ ،  $b$ ،  $c$  و  $d$  چهار ویژگی بردار را تأمین می‌کند و سه فرکانس غالب که از فرمول بسط سریه فوریه طبق رابطه (۳) به دست می‌آیند، سه ویژگی دیگر بردار ویژگی‌ها را شامل می‌شود. سری فوریه، آنالیزی بر روی یک سیگنال سری زمانی انجام داده و طیف فرکانسی سیگنال مورد نظر را رسم می‌کند مانند شکل (۴). بسط سری فوریه به‌عنوان یک روش بسیار سودمند برای تفکیک یک تابع تناوبی دلخواه به مجموعه‌ای از جملات ساده بوده که به راحتی می‌توان آن‌ها را فهمید و منحصراً حل کرد و دوباره با ترکیب آن‌ها راه حل مسئله اولیه را به دست آورد، یا اینکه یک تقریب مطلوب و مناسبی را برای آن تخمین زد.

$$y = ax^3 + bx^2 + cx^1 + d \quad (2)$$


$$f(t) = a_0 + \sum_{n=1}^{\infty} (a_n \cos(w_n t) + b_n \sin(w_n t)) \quad (3)$$

در خوشه‌بندی رفتاری ماشین‌های مجازی، آنچه به‌عنوان ویژگی در نظر گرفته می‌شود، ویژگی مربوط به تقاضای ماشین‌های مجازی است. برای خوشه‌بندی رفتاری ماشین‌های مجازی معیار مورد تقاضا قرار گرفتن یک ماشین مجازی از سایر ویژگی‌هایش مهم‌تر در نظر گرفته می‌شود. در واقع برای هر ماشین مجازی یک سری زمانی وجود دارد که مشخص می‌کند در هر بازه زمانی، این ماشین مجازی چند دفعه مورد تقاضا قرار گرفته است. ایده خوشه‌بندی رفتاری ماشین‌های مجازی، فقط با در دست داشتن سری زمانی مربوط به آن ماشین مجازی انجام می‌گیرد و خوشه‌های مشابه را تعیین می‌کند. همان‌طور که در فلوچارت قابل مشاهده است، نوآوری اعمال‌شده در روش پیشین تخمین تعداد مناسب ماشین‌های مجازی، استفاده از الگوریتم  $k$ -means با  $N$  بار اجرا، به منظور خوشه‌بندی رفتاری ماشین‌های مجازی است. در این الگوریتم، ویژگی‌های مسئله ما برای خوشه‌بندی  $N$  بار به صورت جداگانه به الگوریتم  $k$ -means داده می‌شوند. معیار شباهت در نظر گرفته شده برای الگوریتم خوشه‌بندی  $k$ -mean ارائه شده فاصله اقلیدسی است. در مختصات دکارتی اگر  $q = (q_1, q_2, \dots, q_n)$  و  $p = (p_1, p_2, \dots, p_n)$  دو نقطه در فضای اقلیدسی  $n$  بعدی باشند، آنگاه فاصله اقلیدسی بین آن‌ها به صورت رابطه (۱) محاسبه می‌شود.


$$Distance(p, q) = \sqrt{(q_1 - p_1)^2 + (q_2 - p_2)^2 + \dots + (q_n - p_n)^2} \quad (1)$$



شکل (۲): نمودار یک سری زمانی در برش‌های زمانی ساعت، روز و هفته



شکل (۳): نمودار آهنگ تغییرات سیگنال سری‌های زمانی



شکل (۴): نمایش بسط فوریه یک سری زمانی

که تازه وارد شده‌اند، مدل مناسب انتخاب شده و پارامترهای جدید مدل آموزش‌یافته ذخیره می‌شود و مورد استفاده مولفه پیش‌بینی قرار می‌گیرد. برای پیش‌بینی سری زمانی درخواست‌ها از چهار پیش‌بینی‌کننده مجزا استفاده می‌شود. رگرسیون خطی، رگرسیون بردار پشتیبان، شبکه عصبی و میانگین متحرک. روش گروهی با در نظر گرفتن نقطه ضعف عدم توانایی پیش‌بینی بهینه در هر نوع ماشین مجازی در پیش‌بینی‌کننده‌های مجزا، یک سازوکار رأی‌گیری مهیا می‌کند. در راهکار پیشنهادی نیز از سازوکار رأی‌گیری ارائه‌شده استفاده شده است. پیش‌بینی‌کننده گروهی با ترکیب هوشمندانه خطی نتایج به‌دست‌آمده از پیش‌بینی‌کننده‌های مجزا به نتیجه نهایی پیش‌بینی را محاسبه می‌کند.

نکته قابل توجه در این بخش، استخراج نتایج در حالت‌های مختلف با تعداد مراکز خوشه متفاوت است که هدف، به‌دست‌آوردن بهترین حالت برای انتخاب تعداد مراکز خوشه است (N عددی در بازه یک تا هشت در نظر گرفته شده است). انتخاب تعداد مناسب خوشه‌ها در الگوریتم k-means از جمله مسائل مهم به شمار می‌آید. با اعمال ارزیابی‌های متفاوت، بهترین k برای خوشه‌بندی انتخاب می‌شود. بدین ترتیب فاز اول و نوآوری اعمال‌شده در روش تخمین تعداد مناسب ماشین‌های مجازی به پایان می‌رسد.

**فاز دوم:** همان طور که در شکل (۱) نمایان است، فاز دوم شامل انتخاب مناسب‌ترین مدل، پیش‌بینی و تغییر پیکربندی ابر است. در مرحله انتخاب مناسب مدل بر مبنای درخواست‌هایی

روی یک سیستم با ویندوز ۸، با پردازنده ۸ هسته‌ای ۲،۴ گیگا هرتز اینتل همراه با ۶ گیگا بایت حافظه انجام گرفته است. در این بخش ابتدا به تعیین تعداد مناسب مراکز خوشه برای الگوریتم خوشه‌بندی و سپس میزان اثر بخشی روش گروهی بر نتایج پیش‌بینی پرداخته می‌شود. مقایسه نتایج روش پیشنهادی با الگوریتم‌های دیگر از طریق دو معیار خطا و زمان صورت می‌گیرد. خطای محاسبه‌شده شامل خطای پیش‌بینی است.

از پنج الگوریتم برای پیش‌بینی و تخمین تعداد مناسب ماشین‌های مجازی استفاده شده است. از آنجا که مجموعه داده‌ها به صورت تصادفی ایجاد می‌شوند و ممکن است پارامتر تصادفی منجر به بروز رفتار تصادفی شود، هر آزمایش ده بار تکرار شده و مقدار متوسط نتایج به دست آمده از تکرارها به عنوان نتیجه اعلام می‌گردد.

خطا با افزایش تعداد خوشه کاهش پیدا می‌کند، اما زمان اجرا افزایش می‌یابد. حداکثر مقدار قابل در نظر گرفتن برای  $k$  می‌تواند به اندازه تعداد کل داده‌های ورودی باشد. در این صورت، هر داده دارای یک مرکز خوشه متناظر است که دقیقاً بر آن منطبق است؛ یعنی خطا صفر است. اما ذکر این نکته ضروری است که هدف از استفاده الگوریتم‌های خوشه‌بندی، رسیدن به یک الگو برای ساختار داده است. با در نظر گرفتن  $k$  به تعداد داده‌ها اگرچه خطا کمینه می‌شود، الگویی برای خوشه‌بندی یافت نشده است. موضوع مهم یافتن تعداد مناسب خوشه در الگوریتم خوشه‌بندی است. در اینجا با بررسی نمودارهای مربوط به تغییرات زمان و خطا بر حسب تعداد خوشه برای هر پنج روش مشاهده می‌شود که تا مقدار  $k=6$  تغییرات خطا قابل ملاحظه است. بنابراین در مبادله صرف زمان برای به دست آوردن دقت بیشتر، صرف آن میزان زمان برای به دست آوردن دقت قابل ملاحظه مقرون به صرفه است؛ در حالی که از  $k=6$  تا  $k=7$  کاهش خطا آنقدر زیاد نیست که روش حل را درگیر زمان و بار پردازشی بیشتر کرد. همان طور که در شکل (۵) مشاهده می‌شود، با افزایش تعداد خوشه‌ها زمان اجرا افزایش پیدا می‌کند و در شکل (۶) نشان داده شده است که خطای پیش‌بینی کاهش پیدا می‌کند. افزایش زمان به دلیل افزایش تعداد

$f(0,0)$  یک تابع هزینه را نشان می‌دهد که خطای پیش‌بینی را اندازه‌گیری می‌کند. یک پیش‌بینی‌کننده خوب باید قادر به کاهش خطای پیش‌بینی به حداکثر میزان ممکن باشد. در واقع در طرح مسئله تخمین تعداد مناسب ماشین‌های مجازی  $v$  باید قبل از اینکه مشتری درخواستش را بدهد، آماده شده باشد تا خطای محاسبه‌شده طبق رابطه (۴) به حداقل میزانش برسد.

$$E = \sum_t f(v(t), v^{\wedge}(t)) \quad (4)$$

برای ترکیب نتایج پیش‌بینی یک راهبرد ترکیب خطی به کار گرفته می‌شود. فرض کنید مقدار پیش‌بینی‌شده توسط پیش‌بینی‌کننده  $p \in P$  در زمان  $v_p(t), t$  باشد و ضریب وزنی متناظر آن  $w_p(t)$  که مجموع ضرایب وزنی پیش‌بینی‌کننده در مجموع یک می‌شود طبق رابطه (۵).

$$\sum_p w_p(t) = 1 \quad (5)$$

در این صورت پیش‌بینی‌کننده گروهی از ترکیب خطی وزن‌دار نتایج پیش‌بینی‌کننده‌های مجزا مطابق رابطه (۶) استفاده می‌کند.

$$v^{\wedge}(t) = \sum_p v_p^{\wedge}(t) w_p(t) \quad (6)$$

در ابتدا که  $t = 0$  است همه پیش‌بینی‌کننده‌ها یک سهم برابر در تعیین نتیجه پیش‌بینی دارند طبق رابطه (۷).

$$w_p(0) = \frac{1}{|p|} \quad (7)$$

ذکر این نکته ضروری است که از خطای نسبی نمی‌توان به عنوان ضرایب وزنی جدید برای پیش‌بینی‌کننده‌ها استفاده کرد؛ زیرا نرمال نشده‌اند. با بروزرسانی که انجام می‌شود، وزن بهترین پیش‌بینی‌کننده افزایش پیدا می‌کند تا بیشترین اثر را در نتیجه نهایی داشته باشد.

در آخرین مرحله فاز دوم به اعمال تغییر پیکربندی ابر پس از ارسال نتیجه نهایی پرداخته شده است تا تعداد مناسب ماشین‌های مجازی بروزرسانی شود.


## ۵. نتایج تجربی

آزمایش‌های انجام‌شده برای ارزیابی روش پیشنهادی و میزان اثربخشی خوشه‌بندی رفتاری و خودکار ماشین‌های مجازی، بر



پیش‌بینی از آن جهت مهم است که می‌تواند بستر مناسبی را برای پیدا کردن تعداد خوشه مناسب فراهم کند.


تکرار در الگوریتم خوشه‌بندی است و در یک مسئله خوشه‌بندی افزایش تعداد خوشه‌ها افزایش دقت و به تبع آن، کاهش خطا را در پیش دارد. تغییرات تعداد خوشه و خطای



شکل (۵): نمودار تغییرات زمان (ثانیه) بر حسب تعداد خوشه برای پنج پیش‌بینی‌کننده

خوشه‌ها بهینه در نظر گرفته شود، زمان و خطا بهینه خواهد بود. ذکر این نکته حائز اهمیت است که دقت روش گروهی به انتخاب تعداد خوشه بستگی ندارد و اگر تعداد خوشه بهینه در نظر گرفته نشود نیز پیش‌بینی‌کننده گروهی نسبت به سایر روش‌ها از دقت بالاتری برخوردار است.


برای تمامی پیش‌بینی‌کننده‌ها آهنگ تغییرات خطا با افزایش تعداد خوشه نمایش داده می‌شود. با افزایش تعداد خوشه‌ها خطا در تمامی پیش‌بینی‌کننده‌ها کاهش می‌یابد. همان‌طور که در نمودار مشخص است، با افزایش تعداد خوشه‌ها دقت پیش‌بینی‌کننده ترکیبی گروهی کاهش پیدا نمی‌کند. انتخاب تعداد خوشه مناسب باعث بهینه‌گی می‌شود. زمانی که تعداد




شکل (۶): نمودار تغییرات خطا بر حسب تعداد خوشه برای پنج پیش‌بینی‌کننده

اعمال خوشه‌بندی موجب کاهش خطا و افزایش دقت پیش‌بینی می‌شود. در شکل (۷) مقایسه خطا مشهود است و به‌طور متوسط کاهش خطا به میزان ۱,۹۳ برابر است. در شکل (۸) که برای مقایسه زمان مصرف‌شده در هر دو روش پیشنهادی و بدون خوشه‌بندی قابل مشاهده است. همان‌طور که در نمودار مشخص شده، افزایش زمان به میزان ۴,۳۱ برابر بوده است.

در این بخش به ارزیابی نتایج با اعمال خوشه‌بندی و بدون در نظر گرفتن خوشه‌بندی انجام می‌شود. طبق نتایج به‌دست‌آمده در مرحله پیشین، تعداد مناسب برای خوشه‌بندی شش در نظر گرفته می‌شود. همان‌طور که از نمودارهای بخش قبل استنتاج می‌شود، اعمال روش ترکیب خطی و زن‌دار که از آن با عنوان روش گروهی یاد شد، اثر مطلوبی بر جواب‌های به‌دست‌آمده دارد. از این‌رو مقایسه روش خوشه‌بندی و بدون اعمال خوشه‌بندی بهینه‌ترین حالت به‌دست‌آمده از نتایج انجام می‌گیرد.

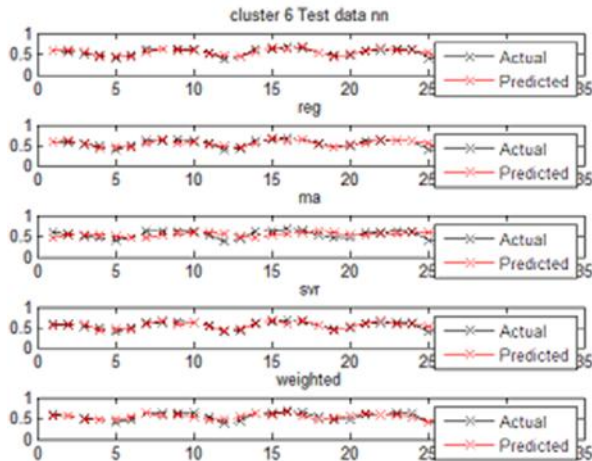


شکل (۷): نمودار مقایسه خطا دو روش با خوشه‌بندی و بدون خوشه‌بندی

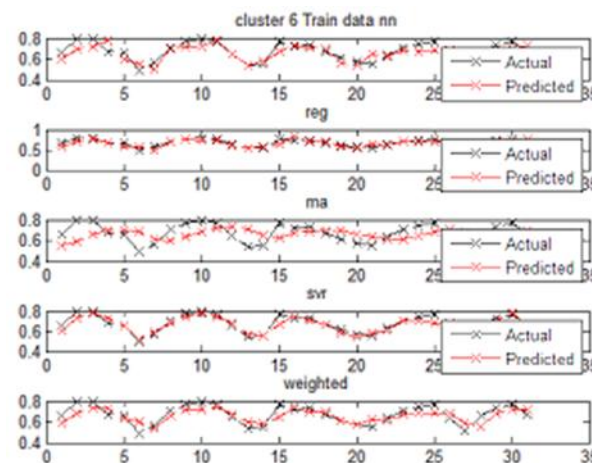


شکل (۸): نمودار مقایسه زمان در دو روش با خوشه‌بندی و بدون خوشه‌بندی

بهینه، خوشه‌بندی ماشین‌های مجازی می‌تواند رخداد آشفستگی در سری‌های زمانی متفاوتی را که از مشتریان دریافت می‌شود، تا حدی سامان دهد و موجب پیش‌بینی دقیق‌تر سری زمانی شود.



شکل (۹): نمودار پیش‌بینی تخمین داده‌های آزمایشی برای  $k=6$



شکل (۱۰): نمودار پیش‌بینی تخمین داده‌های آموزشی برای  $k=6$

شایان ذکر است که افزایش زمان در سیستم‌های امروزی که قدرت به‌کارگیری پردازش‌های موازی را به ما می‌دهند، مسئله بسیار بغرنجی نیست. همچنین در مسائل پیش‌بینی دقت پیش‌بینی‌کننده‌ها اثر مطلوب خود را در کارایی سیستم اعمال خواهد کرد.

در نمودارهای شکل (۹) و (۱۰) برای خوشه‌بندی با شش خوشه روند تخمین در داده‌های واقعی و پیش‌بینی شده برای هر پنج روش پیش‌بینی انجام گرفته، نمایش داده می‌شود.

## ۶. نتیجه‌گیری

برای مدیریت وظیفه و ایجاد انگیزه پیش‌بینی، پیش‌بینی گروهی به‌واسطه کلاس‌بندی همتا با در نظر گرفتن تفاوت‌ها ایجاد می‌شود. در سناریوی پیش‌بینی، ارتباط زمانی بین رکوردها وجود دارد. از این رو خوشه‌بندی سری‌های زمانی مشابه، خطای آموزش سیستم و به تبع آن، خطای تخمین را کاهش خواهد داد. از آنجا که برچسب پیش‌بینی‌کننده‌ها پیوسته‌اند، باید نتایج پیش‌بینی‌کننده گروهی به‌خوبی کنترل شود. خوشه‌بندی رفتاری و خودکار ماشین‌های مجازی، افزون بر کاهش خطای پیش‌بینی، راهبردهای مدیریتی مربوط به ماشین‌های مجازی را نیز آسان‌تر می‌کند. به‌کارگیری هر راهبرد مدیریتی که نیازمند بررسی ماشین‌های مجازی به‌صورت مجزا است؛ برای مثال راهبردهای مدیریتی تعدیل مقیاس با اعمال خوشه‌بندی می‌تواند از مرکز خوشه به‌عنوان عناصر هر خوشه استفاده کند. خوشه‌بندی ماشین‌های مجازی در حذف داده‌های تکراری اثر بسزایی دارد و به کاهش سرپار کمک می‌کند. همچنین اعمال روش گروهی ارائه شده و تشخیص جواب

## مراجع

- [1] D. Ardagna, B. Panicucci, M. Trubian, L. Zhang, "Energy-aware autonomic resource allocation in multitier virtualized environments", *Services Computing*, Vol. 5, pp. 2–19, 2012.
- [2] M. Panda and M. Ranjan Patra, "Network Intrusion Detection of Using Naïve Bayes", *International Journal of Computer Science and Network Security*, Vol. 7, pp. 258-263, 2007.
- [3] R. Wasim Ahmad, A. Gani, S. Hafizah, M. Shiraz, A. Yousafzai, "A survey on virtual machine migration and server consolidation frameworks for cloud data centers", *Journal of Network and Computer Applications*, Vol. 52, pp. 11-25, 2015.
- [4] E. Amigó, J. Gonzalo, J. Artiles, F. Verdejo, "A comparison of extrinsic clustering evaluation metrics based on formal constraints", *Information Retrieval*,

- Vol. 12, pp. 461–486, 2009.
- [5] Majumdar Sh, "*Resource Management on Clouds: Handling Uncertainties in Parameters and Policies*", International journal of CSI Communication, Vol. 35, pp. 16-19, 2011.
- [6] Y. Jiang, C.-S. Perng, T. Li, and R. Chang, "*ASAP: a self-adaptive prediction system for instant cloud resource demand provisioning*", Technological Research In Engineering, Vol. 2, pp. 2347-4718, 2014.
- [7] Y. Jiang, C.-S. Perng, T. Li, and R. Chang, "*Intelligent cloud capacity management*", Network Operations and Management Symposium (NOMS), vol. 12, pp. 11-23, 2012.
- [8] Y. Jiang, C.-S. Perng, T. Li, and R. Chang, "*Self-adaptive cloud capacity planing*", Service Computing, Vol. 7, pp. 131-140, 2010.
- [9] Y. Jiang, C.-S. Perng, T. Li, and R. N. Chang, "*Cloud analytics for capacity planning and instant vm provisioning*", Network and Service Management, IEEE Transactions, Vol. 10, pp. 312-325, 2013.
- [10] C. Canali and R. Lancellotti, "*Detecting similarities in virtual machine behavior for cloud monitoring using smoothed histograms*", Journal of Parallel and Distributed Computing, Vol. 74, pp. 2757-2769, 2014.
- [11] M. Z. Hasan, E. Magana, A. Clemm, L. Tucker, and S. L. D. Gudreddi, "*Integrated and autonomic cloud resource scaling*", Network Operations and Management Symposium (NOMS), Vol. 12, pp. 1327-1334, 2012.
- [12] P. D. Kaur and I. Chana, "*A resource elasticity framework for QoS-aware execution of cloud applications*", Future Generation Computer Systems, Vol. 37, pp. 14-25, 2014.
- [13] D. Kusic, J.O. Kephart, J.E. Hanson, N. Kandasamy, G. Jiang, "*Power and performance management of virtualized computing environment via lookahead*", Cluster Compute, Vol. 12, pp. 1-15, 2009.
- [14] M. Hedwig, S. Malkowski, and D. Neumann, "*Towards Autonomic Cost-Aware Allocation of Cloud Resources*", ICIS, Vol. 12, pp. 180, 2010.
- [15] A. Kamra, V. Misra, and E. M. Nahum, "*Yaksha: A self-tuning controller for managing the performance of 3-tiered web sites in Quality of Service*", Services Computing, Vol. 5, pp. 47-56, 2004.
- [16] W. Iqbal, M. N. Dailey, D. Carrera, and P. Janecek, "*Adaptive resource provisioning for read intensive multi-tier applications in the cloud*", Future Generation Computer Systems, Vol. 37, pp. 871-879, 2011.
- [17] W. Iqbal, M. N. Dailey, D. Carrera, and P. Janecek, "*Sla-driven automatic bottleneck detection and resolution for read intensive multi-tier applications hosted on a cloud*", Advances in Grid and Pervasive Computing, Vol. 23, pp. 37-46, 2010.
- [18] E. Caron, F. Desprez, and A. Muresan, "*Forecasting for grid and cloud computing on-demand resources based on pattern matching*", Cloud Computing Technology and Science (CloudCom), Vol. 11, pp. 456-463, 2010.
- [19] A. Shahin, E. Magana, A. Mohammad, "*Automatic Cloud Resource Scaling Algorithm based on Long Short-Term Memory Recurrent Neural Network*", International Journal of Advanced Computer Science and Applications, Vol. 7, pp. 279-285, 2016.