



## Intrusions Detection System in The Cloud Computing Using Heterogeneity Detection Technique

Roozbeh Hoseinnezhad<sup>1</sup>, Ali Ghaffari<sup>2\*</sup>

1. Phd. Student, Department of Computer Engineering, Tabriz Branch, Islamic Azad University, Tabriz, Iran.
2. Associate Professor, Department of Computer Engineering, Tabriz Branch, Islamic Azad University, Tabriz, Iran. (*Corresponding Author*, [A.ghaffari@iaut.ac.ir](mailto:A.ghaffari@iaut.ac.ir))

### Abstract

**Introduction:** The distributed structure of cloud computing makes it an attractive target for potential cyberattacks by intruders. In this paper, using the anomaly detection approach, a method for embedding an intrusion detection system for cloud computing is presented. Therefore, by studying how to check the parameters and the combined role of the parameters in the detection of penetration in the cloud, a method for detecting suspicious behavior in the cloud is provided. The most logical way to detect an intrusion is to use supervised methods to learn the parameters of normal customer behavior. Therefore, the detection of biased behavior in the form of suspicious behavior was implemented and discussed, investigated, and compared with an initial simulation in the form of identifying abnormal behavior in different behavioral areas by the neural network.

**Method:** In this article, the basis of abnormality detection in different aspects is to examine the behavior of users and use the capabilities of reproducing inputs in RNN neural networks. In these networks, during the training of the network, the weights are adjusted in such a way that they can minimize the average square of the error so that the network can produce common repeating patterns well. Therefore, after training, these networks cannot reproduce well the input patterns that are actually significantly different from the training samples. Hence, these networks are able to identify anomalies in the tested sets. Accordingly, RNN networks are used here to model normal behavior.

**Findings:** The simulation results show that the proposed method, which is based on the recurrent neural network, can improve the false positive, false negative, and detection accuracy compared to the classification method.

**Discussion:** In this article, the detection of biased behavior in the form of suspicious behavior was implemented and discussed, investigated, and compared with an initial simulation in the form of identifying abnormal behavior in different behavioral fields. The simulation results show that the proposed method, which is based on the iterative neural network, can improve the false positive, false negative, and detection accuracy compared to the classification method.

**Keywords:** Cloud computing, anomaly detection, normal behavior, behavioral parameters, biased behavior.

## تشخیص نفوذ در ابر رایانشی توسط تکنیک تشخیص ناهمگونی

سال سوم، بهار ۱۴۰۱  
شماره اول، صص: ۳۷ - ۴۶

تاریخ دریافت: ۱۴۰۰/۰۷/۰۳  
تاریخ پذیرش: ۱۴۰۰/۰۸/۱۹

روزبه حسین‌نژاد<sup>۱</sup>، علی غفاری<sup>۲\*</sup>

۱. دانشجوی دکتری، گروه مهندسی کامپیوتر، واحد تبریز، دانشگاه آزاد اسلامی، تبریز، ایران. [Roozbehmaah@gmail.com](mailto:Roozbehmaah@gmail.com)

۲. دانشیار، گروه مهندسی کامپیوتر، واحد تبریز، دانشگاه آزاد اسلامی، تبریز، ایران. (نویسنده مسئول)

[A.ghaffari@iaut.ac.ir](mailto:A.ghaffari@iaut.ac.ir)

**چکیده:** در سال‌های اخیر، ظهور و گسترش روزافزون استفاده از رایانش ابری، درک همه از معماری‌های زیرساخت، ارائه نرم‌افزار و مدل‌های توسعه را به شدت تغییر داده است. پس از انتقال از رایانه‌های مرکزی به مدل‌های سرویس گیرنده/سرویس دهنده، رایانش ابری عناصری از محاسبات گرید، محاسبات ابزار و محاسبات خودکار را در برمی‌گیرد و به یک معماری استقرار نوآورانه تبدیل می‌شود. این انتقال سریع به سمت رایانش ابری، نگرانی‌هایی برای موفقیت سیستم‌های اطلاعاتی، ارتباطات و امنیت اطلاعات ایجاد کرده است. ساختار توزیع شده رایانش ابری به‌عنوان هدفی جذاب برای حملات سایبری بالقوه توسط نفوذگران تبدیل می‌شود. در این مقاله با استفاده از رویکرد تشخیص ناهنجاری، روشی برای تعبیه یک سیستم تشخیص نفوذ برای رایانش ابری ارائه شده است. لذا با مطالعه بر روی چگونگی بررسی پارامترها و نقش ترکیبی پارامترها در تشخیص نفوذ در ابر، به بررسی و ارائه چهارچوب نظری به همراه شبیه‌سازی رفتار مشکوک در ابر پرداخته شده است. منطقی‌ترین روش برای شناسایی نفوذ، استفاده از روش‌های همراه با ناظر برای یادگیری پارامترهای رفتار عادی مشتریان است. لذا تشخیص رفتار مغرضانه در قالب رفتار مشکوک، با یک شبیه‌سازی اولیه در قالب شناسایی رفتار غیرعادی در حیطه‌های مختلف رفتاری توسط شبکه عصبی تکرارکننده پیاده‌سازی، بررسی و مقایسه شده است. نتایج حاصل از شبیه‌سازی روش پیشنهادی نشان می‌دهد که این تحقیق می‌تواند جنبه‌های جدیدی را برای بررسی مسأله تشخیص نفوذ در ابر ارائه کند و از روش دسته‌بندی نیز کارایی بهتری از خود نشان دهد.

**واژه‌های کلیدی:** ابر رایانشی، تشخیص ناهنجاری، پارامترهای رفتاری، رفتار نرمال، رفتار مغرضانه.

## ۱. مقدمه

مفهوم رایانش ابری از معماری نرم‌افزار توزیع‌شده پدیدآمده است. خدمات ابر محاسباتی از مراکز داده واقع‌شده، ارائه می‌شود در نقاط مختلف جهان مایکروسافت شیرپوینت و برنامه‌های گوگل نمونه‌هایی کلی از خدمات رایانش ابری هستند [4-1]. در حال حاضر، مدل‌های رایانش ابری منبع اصلی چالش‌ها و آسیب‌پذیری‌ها هستند. نفوذگران از ضعف مدل‌های ابری در دسترسی به داده‌های خصوصی کاربران با حمله به قدرت پردازش سیستم‌های کامپیوتری سوءاستفاده می‌کنند [8-5]. جدا از شباهت و نقاط مشترک رایانش ابر و شبکه‌های کامپیوتری، مسئله امنیت در رایانش ابری چالش اساسی محسوب می‌شود [11-9].

به‌طور کلی، دو نوع سیستم تشخیص نفوذ وجود دارد: سیستم‌های شناسایی سوءاستفاده و رفتارهای غیرعادی. در سیستم‌های شناسایی سوءاستفاده، سیستم از ساختار کلی حملات اطلاع دارد و الگوی خاصی را برای اشکال مختلف حملات در اختیار دارد که توسط آن می‌تواند از نفوذ به سیستم جلوگیری کرده و یا اقدامات لازم را برای مقابله با نفوذ انجام دهد. اما، در سیستم‌های شناسایی رفتارهای غیرعادی، تنها رفتار درست و معمولی کاربر است که اطلاعات و مشخصات آن در اختیار سیستم قرار دارد. از این رو، در این سیستم‌ها، هدف شناسایی رفتار غیرعادی است که احتمال دارد از نوع حمله و نفوذ باشد.

در این مقاله با استفاده از رویکرد تشخیص ناهنجاری، روشی برای تعبیه یک سیستم تشخیص نفوذ برای رایانش ابری ارائه می‌شود. در روش پیشنهادی از شبکه عصبی استفاده شده است.

ساختار مقاله به‌صورت زیر سازمان‌دهی شده است: بخش ۲ به روش‌های پیشین و روش‌های مرتبط با موضوع این مقاله می‌پردازد. بخش ۳، راه-حل پیشنهادی را ارائه می‌دهد. بخش ۴، ارزیابی کارایی روش پیشنهادی را نشان می‌دهد. در نهایت، بخش ۵ به جمع‌بندی و اشاره به کارهای آینده می‌پردازد.

## ۲. پیشینه پژوهش

در [3]، نویسندگان یک سیستم تشخیص نفوذ کارآمد را برای محیط ابری با استفاده از تکنیک‌های انتخاب ویژگی و طبقه‌بندی مجموعه توسعه داده‌اند. این روش بر تکنیک انتخاب ویژگی مجموعه تک متغیره تکیه داشت که برای انتخاب مجموعه‌های ویژگی کاهش یافته ارزشمند از مجموعه داده‌های نفوذی داده‌شده استفاده می‌شود. در حالی که طبقه‌بندی‌کننده‌های گروهی که می‌توانند به‌خوبی طبقه‌بندی‌کننده‌های منفرد را با هم ترکیب کنند تا با استفاده از تکنیک رأی‌گیری، یک طبقه‌بندی قوی تولید کنند. یک روش پیشنهادی مبتنی بر مجموعه به-طور مؤثر طبقه‌بندی می‌کند که آیا رفتار ترافیک شبکه عادی است یا حمله. نتایج روش پیشنهادی به میزان قابل توجهی افزایش عملکرد در مقایسه با سایر روش‌های موجود دست‌یافت. علاوه بر این، آن‌ها یک آزمون زوجی را انجام داده و ثابت کردند که عملکرد روش پیشنهادی به‌طور

معنی‌داری با سایر روش‌های موجود متفاوت است. در نهایت، نتیجه این بررسی با بهترین دقت و کمترین نرخ هشدار کاذب به‌دست آمد.

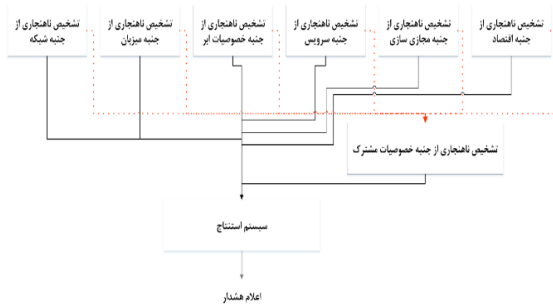
در [۱۲]، یک تکنیک برای تشخیص حملات DDoS با استفاده از یک مدل شبکه عصبی مصنوعی (ANN) پیشنهاد شده است. این مدل با استفاده از الگوریتم رقابتی امپریالیستی آموزش داده شده است. مجموعه داده NSL KDD برای ارزیابی عملکرد تکنیک پیشنهادی استفاده می‌شود. روش پیشنهادی ما دقت تشخیص ۸۳٫۵٪ و ۶۵٪ را با مجموعه داده‌های KDDTest+ و KDDTest-21 به ترتیب می‌دهد. مقایسه عملکرد با برخی دیگر از تکنیک‌های مبتنی بر یادگیری ماشین و تکنیک‌های پیشرفته نیز ارائه شده است. در [۱۳]، روشی مبتنی بر تشخیص ناهنجاری ارائه شده است که در آن از شبکه‌های عصبی پیش‌خوردی به‌منظور مدل‌سازی رفتار کاربران استفاده شده است. در [۱۴] مدلی برای شناسایی حملاتی از نوع حملات سیل‌آسا به‌نام معماری جلوگیری از حملات سیل‌آسا در محیط ابرایانش ابری ارائه شده است. نکته خاصی که در این کار دیده می‌شود، ارائه ترافیک به سیستم تشخیص نفوذ پس از گذر از یک فیلتر انتخاب ویژگی است. بدین ترتیب، انتظار می‌رود بتوان از طریق این امر سرعت و دقت تشخیص نفوذ را بالا برد.

در [۱۵]، مفهومی به‌نام سیستم تشخیص نفوذ مینی برای تشخیص حملات در ابر رایانشی ارائه شده است. ایده اصلی در معماری ارائه شده در این کار بر این مبنا بنا شده است که بتوان از طریق تخصیص سیستم‌های تشخیص نفوذ مینی به هر کاربر از سر بار سنگین تشخیص نفوذ، در نتیجه تخصیص سیستم تشخیص نفوذ کلی به ابر جلوگیری کرد. بدین ترتیب، عملیات تشخیص نفوذ در ابر می‌تواند با سرعت بالاتر و دقت بیشتر انجام شود، ترافیک سنگین درخواست‌ها و انتقال اطلاعات حتی در بهترین حالت نیاز به تعبیه سیستم‌های سنگین در ابر دارد و سیستم تشخیص نفوذ مرکزی کار دشواری در ارائه کیفیت مناسب در برابر این ترافیک و حجم حملات ورودی خواهد داشت.

در [۱۶] یک مدل تشخیص نفوذ یکپارچه برای شناسایی رفتار مشکوک در محیط رایانش ابری ارائه شده است. در این کار برای تشخیص رفتار مشکوک از مفاهیم شناسایی ناهنجاری و شناسایی امضا استفاده می‌شود. اساس کارکردی این کار بر پایه شناسایی نفوذها و ناهنجاری‌هایی است که موجب به‌وجود آمدن تهدید برای محیط ابر می‌شوند. بدین ترتیب، در این کار از شناسایی ناهنجاری به‌منظور شناسایی رفتار غیرمنتظره و از شناسایی امضا برای شناسایی رفتار مشکوک به نفوذ در نتیجه مشاهدات پیشین و از پیش تعریف‌شده، استفاده می‌شود.

در [۱۷] رویکردی برای شناسایی حملات از نوع انکار سرویس توزیع‌شده در وب سرویس‌های درون ابر رایانشی ارائه شده است. در این کار نوع جدیدی از آسیب‌پذیری در وب سرویس‌های مبتنی بر ابر بررسی شده است که در آن برای ایجاد مشکل حملات انکار سرویس در لایه برنامه کاربردی تلاش می‌شود. هدف این نوع حملات منابع پردازشی هستند که توسط


جلوگیری از گرفتاری در رفتار محلی پارامترها در حوزه‌های خود در این معماری اضافه شده است.



شکل ۱: مدل روش پیشنهادی

### ۲.۳. تشخیص ناهنجاری

در این مقاله، مبنای تشخیص ناهنجاری در جنبه‌های مختلف، بررسی وضعیت رفتار کاربران و استفاده از قابلیت‌های تولید مجدد ورودی‌ها در شبکه‌های عصبی RNN است [18, 19]. در این شبکه‌ها طی آموزش شبکه، وزن‌ها به گونه‌ای تنظیم می‌شوند که بتوانند میزان متوسط مربع خطا را کمینه سازند به طوری که شبکه بتواند الگوهای تکراری مشترک را به خوبی تولید کنند [20]. از این رو، این شبکه‌ها پس از آموزش نمی‌توانند الگوهای ورودی را که در واقع به صورت ناهنجاری تفاوت عمده‌ای به نمونه‌های آموزشی دارند، به خوبی باز تولید کنند. از این رو، این شبکه‌ها قادرند به شناسایی ناهنجاری در مجموعه‌های مورد آزمون بپردازند [21-24]. به این ترتیب، در اینجا از شبکه‌های RNN به منظور مدل‌سازی رفتار نرمال استفاده می‌شود. شکل ۲، معماری عمومی یک RNN را نشان می‌دهد.



شکل ۲: معماری عمومی یک شبکه RNN

در شکل ۲ شبکه RNN دارای سه لایه پنهان (لایه ۲ و ۳ و ۴) است. تعداد نرون‌های داخل لایه ورودی و خروجی با یکدیگر و با تعداد ویژگی‌های ورودی با شبکه برابر است که باید توسط شبکه RNN مورد نظر مدل‌سازی و باز تولید شوند. تعداد لایه‌های پنهان و همچنین تعداد نرون‌های درون هر لایه معمولاً به صورت تجربی انتخاب می‌شوند. در اینجا معیار جدیدی برای استنتاج میزان ناهنجاری معرفی می‌شود. این معیار که پس از نرمال‌سازی داده‌ها، محاسبه می‌شود، با نام فاکتور ناهنجاری معرفی می‌شود که توسط محاسبه میزان متوسط ناهنجاری در میان ویژگی‌های مورد استفاده در داده‌ها مقادری می‌شود:

ارسال درخواست‌های پروتکل دسترسی شی ساده انجام می‌گیرد، به طوری که این درخواست‌ها حاوی محتوای XML مغرضانه هستند. این حملات قابل شناسایی در لایه شبکه یا انتقال نیستند زیرا به صورت بسته‌های مشروع ظاهر می‌شوند.

### ۳. روش پیشنهادی

با توجه به این که معماری سرویس‌گرا از دیگر فناوری‌های برقراری ابر محسوب می‌شود، آسیب‌پذیری‌های مربوط به این معماری نیز، ابر را تحت تأثیر قرار می‌دهند. هنگامی که حملاتی از نوع جلوگیری از سرویس توزیع شده، صورت بگیرد، منابع سیستم برای دسترسی توسط کاربر یا مشتری دچار اختلال می‌شوند. پارامترهای مورد استفاده برای حوزه سرویس عبارت‌اند از: میزان توقف موقت ارائه خدمت (TSU) و میزان ارزش توقف موقت ارائه خدمت (TSUV). میزان توقف موقت ارائه خدمت عبارت است از میزان زمانی که به هر دلیل سرویس در ابر در دسترس نیست.

### ۱.۳. معماری سیستم تشخیص نفوذ پیشنهادی

در سیستم‌های تشخیص ناهنجاری یک نوع ارتباط متقابل میان پارامترهای ورودی وجود دارد که علاوه بر این ارتباط متقابل میان ورودی‌ها، بر اساس نوع سیستم تشخیص نفوذ، ارتباط متقابلی میان برخی از خروجی‌ها و ارتباط متقابلی میان برخی از ورودی‌ها به وجود می‌آید. این امر، مبنای برخی روش‌های مدل‌سازی محسوب می‌شود، اما چنانچه سیستم تشخیص نفوذ بر مبنای رویکرد یادگیری همراه با ناظر برای ساخت مدل نرمال از رفتار مورد نظر ساخته شود، این امر بیشتر مورد توجه قرار می‌گیرد. بارزترین نمونه از این نوع ارتباطات پارامتریک می‌تواند در گره‌های پنهان شبکه‌های عصبی مشاهده شود که خروجی را بر اساس اتصالات درونی میان لایه پنهان و لایه ورودی و همچنین معماری اتصالات گره‌ها و تابع انتقال گره‌ها تعیین می‌کند. همچنین، روش‌های یادگیری در شبکه‌های عصبی نیز به گونه‌های متفاوت رویکرد مدل‌سازی رفتار را به روش مذکور تحت تأثیر قرار می‌دهند. این امر در شبکه‌های عصبی مبتنی بر نظریه تشدید تطبیقی ART بیشتر قابل رؤیت است که به صورت خام یک روش یادگیری غیرهمراه با ناظر است. اما با ترکیب نظریه‌های تکاملی مانند Fuzzy ART، به رویکردی همراه با ناظر تبدیل می‌شود. البته در اینجا، تمرکز کار روی همان یادگیری همراه با ناظر توسط شبکه‌های عصبی است که بدون جداسازی دسته‌های مختلف ورودی‌ها می‌تواند پیچیدگی محاسباتی قابل توجهی را به سیستم تشخیص نفوذ تحمیل کند. بنابراین، مدل رویکرد پیشنهادی به صورت شکل ۱ درمی‌آید. در رویکرد پیشنهادی، یک مؤلفه دیگر نیز با نام تشخیص ناهنجاری از جنبه خصوصیات مشترک نیز مشاهده می‌شود. این مؤلفه در واقع برخی پارامترها را مد نظر قرار می‌دهد که کلیت رفتار سیستم را نشان می‌دهند و در واقع ورودی‌های آن نوعی ارتباط متقابل را با یکدیگر برای تعیین رفتار خروجی سیستم از برخی جنبه‌ها دارا می‌باشند. این امر، برای

$$OF = \frac{1}{N} \sum_{i=1}^N (x^i - t^i)^2 \quad (1)$$

به طوری که مقدار خروجی ویژگی  $i$  ام بوده و مقدار واقعی این ویژگی است. اما، ممکن است در مواردی مقدار  $OF$  کوچک باشد اما از نظر یک یا چند ویژگی خاص این مقدار زیاد باشد، بنابراین نیاز است بیشترین اختلاف نیز بررسی شود تا به عنوان یک متریک تکمیلی در کنار  $OF$  ارزیابی شود:

$$O_{max} = \max\{(x^i - t^i)^2; i = 1, \dots, N\} \quad (2)$$

در این تحقیق به منظور آزمایش رویکرد پیشنهادی برای تشخیص نفوذ در ابر رایانشی، به دلیل عدم وجود پایگاه داده معتبر در ابر، به شبیه سازی و تولید پایگاه داده پرداخته می شود. به منظور برطرف شدن این مشکل، قید شده است که نیاز شبکه ها بیش از آن که یادگیری همراه با ناظر باشد، یادگیری نظارت نشده است. به طور خلاصه این مشکل در نهایت با رویکردی به نام  $RBM$  بررسی شد. در شبکه های  $RBM$ ، یادگیری غیرنظارتی توسط نوعی شبکه عصبی پیاده سازی می شود که امکان استخراج ویژگی های سطح بالاتر را از داده های خام ورودی فراهم می کند. اگرچه رویکردهایی مبتنی بر تابع گوسی برای مدل سازی توابع غیرخطی ارائه شده است، اما آموزش زنجیره ای برای مدل سازی کرنل های گوسی امری بسیار زمانبر است. از این رو، ادامه کار برای ساخت مدل رفتار نرمال در تشخیص نفوذ مبتنی بر ناهنجاری در این تحقیق نمی تواند مسیر  $RBM$ ، و شبکه های عمیق را طی کند.

رویکردهای مبتنی بر تشخیص امضا در واقع می توانند با تولید نتایج مثبت اشتباه کمتر خودنمایی کنند. اما، مشکل عمده این روش این است که اساساً با این ابعاد وسیع در ابر و تعدد مؤلفه های دخیل درون محیط ابر، اطلاعات مبنی بر امضای نفوذها و حملات در عمل بسیار ناچیز است. از این رو، رویکرد تشخیص ناهنجاری برای تشخیص رفتار مغرضانه، در حال حاضر، راهکار مناسب برای تشخیص نفوذ محسوب خواهد شد. در این مقاله بیشتر به تشخیص رفتار مشکوک از طریق تشخیص ناهنجاری در رفتار کاربران می پردازیم. بنابراین، معیار ارزیابی در این تحقیق مبتنی بر سنجش های تشخیص ناهنجاری خواهد بود.

### ۳.۳. ایجاد پایگاه داده

در اینجا پایگاه داده ۵ دسته مختلف از داده ها را در برمی گیرد: شبکه یا  $NIDS$ ، ماشین مجازی یا  $VMIDS$ ، حوزه تقاضا، حوزه ابر و حوزه سرویس. از این رو، این ۵ حوزه بررسی می شوند:

#### حوزه شبکه

پارامترهای منتخب برای حوزه شبکه شامل موارد زیر می شوند: پروتکل مورد استفاده ( $PID$ )، طول سرآیند بسته اطلاعاتی ( $PLEN$ )،  $Check$  ( $CS$ )، پورت مبدأ و پورت مقصد.

در ابر ماشین مجازی بر اساس قوانین میزبان، بسته به ترافیک و مجموعه ای خاص از بسته ها می شود. نکته مهم اینجاست که این ترافیک با توجه به آزادی عمل کاربران برای استفاده از سیستم ها و مکان های مختلف برای برقراری ارتباط با ابر، و همچنین مشخص نبودن میزبان فیزیکی ماشین مجازی مشتری مشخص که با توجه به توزیع بار و

متعادل سازی بار در ابر در هر لحظه می تواند تغییر کند، به طور قطع نمی تواند وابسته به نشانی  $IP$  مبدأ و نشانی مقصد باشد. البته در ادبیات موضوع نشانی مبدأ و نشانی مقصد تقریباً جزء لاینفک سیستم های تشخیص نفوذ مبتنی بر شناخت ناهنجاری در شبکه است. پارامترهای مشترک دیگر نیز، با توجه به نشانی مبدأ و مقصد می تواند شامل پورت ارتباطی مبدأ و مقصد باشد که دیگر نشانی مبدأ و مقصد را برخلاف نشانی  $IP$ ، موقعیت جغرافیایی محدود نمی کند.

#### حوزه ماشین مجازی

حوزه ماشین مجازی شامل موارد زیر می شود: نام مالک ماشین مجازی ( $VMO$ )، نام فرآیند ( $PO$ )، تعداد نخ های فرآیند ( $TN$ )، درصد استفاده از ظرفیت پردازنده ( $CU$ ) و درصد استفاده از ظرفیت ( $RAM$  ( $RU$ )).

#### حوزه تقاضا

حوزه تقاضا شامل موارد زیر می باشد: میزان تقاضا، میزان رد شدن درخواست، میزان دانه دانه ای بودن تقاضا. با توجه به این که تقاضا به ابر بیشتر تقاضا برای یک محصول تجاری محسوب شده و ماهیت ابر که مستقیماً ارائه خدمات پردازشی برخط را برای مشتریان در بازار فراهم می کند، قوانین بازارهای محصولات تجاری نیز بر ارائه تقاضا به ابر حاکم خواهد بود. این امر مانند تقاضا برای سهام محسوب می شود و تقاضا برای محصولات تجاری و سهام و به طور کلی پارامترهای وابسته اقتصادی به محصولات تجاری دارای دوره های تکرار الگو هستند. در واقع دوره های تکرار الگو شامل دوره های بلندمدت، میان مدت و کوتاه مدت می شوند که تکرار این ها طی زمان منجر به تولید رفتار خاص مربوط به یک پارامتر مدل سازی می شود. البته طول مدت زمان ممکن است یک الگو میزان پیوسته ای را از کوتاه مدت تا بلندمدت شامل شود و پارامترهای مدل سازی نیز در زمان پیوسته مدل سازی می شوند. این دوره های زمانی تکرار الگو، در حقیقت مبنای اصل پیش بینی برای سری های زمانی را تشکیل می دهد و این دوره های مشخص هستند که قابلیت پیش بینی را فراهم می سازند. بر این اساس، روند میزان تقاضا با توجه به دوره های تکراری رفتار مشتریان؛ میزان رد شدن درخواست با توجه به ظرفیت منابع در ابر و تعداد و میزان درخواست ها و میزان دانه دانه ای بودن تقاضا با توجه به نیازهای مشخص کاربران، در زمان های مشخص در روز می تواند بیان کننده تأثیر عامل اقتصادی تقاضا بر تشکیل رفتار نرمال میان کاربران در ابر محسوب شود. در واقع، در طراحی سیستم های تشخیص نفوذ مبتنی بر شبکه تحلیل خاصی را نمی توان برای توجیه رفتار نرمال مشتریان ارائه کرد، اما با اضافه شدن عامل اقتصادی تقاضا در ابر وجود رفتار نرمال کاملاً قابل توجیه بوده و مبنای قوی دارد. بنابراین، وجود رفتار نرمال بر اساس وجود عامل اقتصادی تقاضا در ابر و در نتیجه طراحی سیستم های تشخیص نفوذ مبتنی بر شناخت ناهنجاری در ابر مبنای جامعیت بسیار قوی تری در ابر نسبت به سیستم مشابه در شبکه های کامپیوتری و دیگر حوزه های تشخیص نفوذ دارد.

دانه دانه ای بودن عبارت است از:

$$Granularity = \frac{\sum_{i=1}^N e^{CPU_i}}{e^{\sum_{i=1}^N CPU_i}} \quad (2)$$

البته برای مقادیری که در اینجا به عنوان دانه‌دانه‌ای بودن به دست می‌آید، سیستم شبکه عصبی به دلیل محدوده وسیع این متغیر کارایی کمی از خود نشان می‌دهد. از این رو، رابطه (۲) با رابطه (۳) جایگزین می‌شود.

$$Granularity_t = \frac{e^{Nt}}{N_t} \quad (3)$$

به طوری که N تعداد درخواست‌ها در زمان t می‌باشد.

### حوزه ابر

حوزه خصوصیات ابر شامل پارامترهای زیر می‌شود: روند بارکاری پردازنده (CW)، روند بارکاری (RAM (RW). اگرچه عامل اقتصاد روند ورودی تقاضا به ابر را پوشش داد، اما بحث درونی ابر دارای برخی پارامترهای منحصر به فرد است که باید از دیدگاه پارامترهای درونی ابر به آن توجه شود. این پارامترها شامل میزان کلی بارکاری پردازنده‌ها و RAM های موجود در مجموعه منابع ابر است. مبنای این دو پارامتر این است که علاوه بر ماشین‌های مجازی، مکانیسم‌های مدیریتی میزبان‌های فیزیکی نیز مقادیری از منابع ابر را مصرف می‌کنند که مصارف کنترلی و مدیریت دارند. بنابراین، با توجه به عوامل بیرونی، بارکاری و روند تغییر آن در لحظات مختلف روز می‌تواند وابسته به این موارد نیز باشد. حال آن‌چه اهمیت این پارامترها را بیشتر می‌کند، حملاتی هستند که منابع ابر را مصرف کرده و خود ابر را تحت تأثیر قرار می‌دهند. بدین ترتیب، با مشاهده و مانیتورینگ این رفتار از بارکاری پردازنده و RAM می‌توان ناهنجاری‌های قابل توجه را تشخیص داده و به سیستم تشخیص و یا سیستم جلوگیری از نفوذ ارجاع داد.

### حوزه سرویس

پارامترهای مورد استفاده برای حوزه سرویس عبارت‌اند از: میزان توقف موقت ارائه خدمت (TSU) و میزان ارزش توقف موقت ارائه خدمت (TSUV). میزان توقف موقت ارائه خدمت عبارت است از میزان زمانی که به هر دلیل سرویس در ابر در دسترس نیست. این مورد نیز یکی دیگر از مواردی است که منحصراً در ابر مورد توجه است چون خدمات به عنوان شیء سرویس ارائه شده و مدت زمانی که دسترسی به این شیء امکان پذیر نیست یعنی توقف موقت در ارائه خدمت از سوی ابر به مشتری رخ داده است.

هنگامی که حملاتی از نوع DoS یا هر شکل مربوط به آن مانند DDos و یا به صورت Flood صورت گیرد، منابع سیستم و شبکه برای دسترسی توسط کاربر یا مشتری دچار اختلال می‌شوند. هنگامی که ماشین‌های مجازی از یک ماشین فیزیکی میزبان به ماشین فیزیکی میزبان دیگر انتقال می‌یابند، این امر معمولاً به صورت فرآیند Pre-Copy انجام می‌شود. در نتیجه، یک ماشین مجازی دیگر به صورت موازی با ماشین مجازی مورد نظر بر روی ماشین فیزیکی مقصد کار می‌کند و تا زمانی که انتقال اطلاعات نیازمند کمترین زمان توقف موقت ارائه خدمت برای انتقال اطلاعات ضروری مجموعه کاری پردازنده شود، این امر ادامه خواهد یافت. بنابراین، در زمان‌های مختلف روز هنگامی که میزان تقاضا و بارکاری در مدت زمان‌های یکسان در روزهای مختلف میزان متفاوتی را نسبت به دیگر لحظات در روز شامل می‌شود، میزان توقف

موقت ارائه خدمت نیز به نسبت متفاوت خواهد بود. اگرچه، این میزان می‌تواند تابعی از وضعیت ابر، وضعیت و تقاضای مشتریان و عوامل بیرونی باشد؛ اما، به هر حال تابعی از برخی متغیرها از قبیل روند رفتاری مشتریان، میزان بارکاری، تعمیر و نگهداری و موارد درون و برون سیستمی است.


درواقع، هرچقدر سرویس هزینه بالاتری داشته باشد، میزان توقف موقت ارائه خدمت نیز مهم‌تر خواهد بود. برای تأکید می‌توان به این امر اشاره کرد که انتظار می‌رود حملات بیشتر به ماشین‌های مجازی مهم‌تر صورت گیرند تا ماشین‌های مجازی ارزان‌تر و کوچک‌تر. هرچند، اهداف مختلف نفوذگران می‌تواند نتایج و نیت‌های متفاوتی داشته و به طور کلی خود ابر را هدف قرار دهند، اما این امر می‌تواند برای تحت تأثیر قرار دادن یک ماشین مجازی با تأثیر بر ماشین‌های مجازی دیگر رخ دهد.

### ۴.۳. مدل‌سازی سری‌های زمانی با استفاده از ابزار یادگیری


#### ماشین

مدل‌سازی مذکور به معنی این است که سیستم یادگیرنده قابلیت بازتولید خروجی دریافتی را پس از دریافت ورودی مربوطه داراست. در این تحقیق البته ما با دو نوع یادگیری نظارتی روبرو هستیم. پارامترهای مربوط به حوزه شبکه و ماشین مجازی توسط تعبیه یک autoencoder (یا شبکه عصبی تکرارکننده) از طریق همان شکل (ورودی-خروجی) مربوط به یادگیری نظارتی اما با دریافت زوج مقادیر (ورودی-ورودی)، مدل‌سازی می‌شوند که همان شکل یادگیری نظارتی کلاسیک می‌باشد. اما، پارامترهای حوزه‌های تقاضا، ابر و سرویس به صورت سری زمانی مطرح می‌شوند و شکل ورودی-خروجی را برای سیستم یادگیرنده فراهم نمی‌کنند. چنانچه بخواهیم یک سری زمانی را توسط روش‌های یادگیری ماشین نظارتی مدل‌سازی کنیم، مسئله به طور کلی با نام مسئله یادگیری نظارتی ترتیبی شناخته خواهد شد. مدل‌سازی سری‌های زمانی می‌تواند دو جنبه متفاوت داشته باشد. جنبه اول رابطه محور پایه یا زمان را با مقدار پارامتر متغیر مورد مدل‌سازی قرار داده و به پیش‌بینی پارامتر اصلی سری زمانی توسط عامل زمان می‌پردازد. اما، این نوع مدل‌سازی نمی‌تواند انعطاف پذیری کافی را برای مسائل چندمتغیره فراهم آورد، زیرا پارامتر مورد نظر ممکن است کاملاً به زمان وابسته نبوده و روند پیشین تغییر مقدار متغیر را دنبال کند. بنابراین، رویکرد جامعی که برای مدل‌سازی سری‌های زمانی استفاده می‌شود، معمولاً بیش از آن که عامل زمان را در محاسبه مقدار آتی متغیر دخیل کند، به پیش‌بینی مقدار آتی متغیر توسط بازبینی و مدل‌سازی چند مقدار اخیر آن می‌پردازد. البته، چگونگی این امر خود مباحث بازی را در استخراج الگو و داده‌کاو می‌بازد، اما به طور کلی روش‌های شناخته شده‌ای مانند پنجره لغزان، بیش‌ترین کاربرد را در شناسایی الگوها و مدل‌سازی سری‌های زمانی توسط روش‌های یادگیری نظارتی داراست. بنابراین اینجا نیز از تکنیک پنجره لغزان استفاده می‌شود.

تکنیک پنجره لغزان، درحقیقت پنجره به طول N داده متوالی از سری زمانی را جدامی‌کند. از داده‌های درون این پنجره N-1 داده اول



(ب)



(ج)

شکل ۳: نمودار مشخصه پارامترهای حوزه تقاضا

برای تعیین معماری شبکه عصبی، ابتدا لازم است شکل ورودی و خروجی به صورت رابطه (۴) تعیین شود.

$$\begin{cases} \text{input: } \{x_{t-2}, x_{t-1}, x_t\} \\ \text{output: } x_{t+1} \end{cases} \quad (4)$$

اما، برای تعیین معماری شبکه عصبی موردنظر، نکته مبهم تعداد گره‌های لایه پنهان است؛ البته تابع انتقال گره‌های لایه میانی و گره‌های خروجی نیز بسیار مهم هستند. اما با توجه به این که شبکه عصبی به‌عنوان تقریب‌زننده عمومی برای توابع غیرخطی پیوسته معمولاً دارای تابع انتقال Sigmoid در گره‌های لایه پنهان و تابع انتقال خطی در گره‌های لایه خروجی است، لذا، این توابع را برای شبکه عصبی یادشده در نظر می‌گیریم. اما، تعداد گره‌های لایه پنهان موضوع بسیار مهمی است که نقش قابل‌توجهی در کارایی شبکه عصبی در مدل‌سازی داده‌های موردنظر دارد. در واقع با تغییر تعداد گره‌ها، کارایی شبکه عصبی را در مدل‌سازی سری‌های زمانی رفتار نرمال کاربران بررسی کرده و بهترین گزینه را انتخاب می‌کنیم. برای هر سه پارامتر Dem، Gran و Rej معماری شبکه‌های عصبی استفاده‌شده به صورت (۳)، (۸)، (۱)، به معنی سه ورودی، ۸ گره در لایه پنهان و یک خروجی می‌باشد. جدول (۱) تحلیل حساسیت را برای پارامترهای Dem، Gran و Rej نشان می‌دهد:


به‌عنوان ورودی در نظر گرفته شده و داده  $N$  به‌عنوان خروجی مطرح می‌شود. بدین ترتیب، چنانچه از ابتدای سری زمانی با حرکت به اندازه یک واحد، تمام داده‌های متوالی را به این شکل درآوریم، مسئله به‌صورت دلخواه برای پذیرش توسط روش‌های یادگیری نظارتی از قبیل شبکه عصبی درمی‌آید. بدین ترتیب، می‌توان توسط شبکه‌های عصبی به مدل‌سازی پارامترهای رفتار نرمال کاربران در حوزه‌های تقاضا، ابر و سرویس پرداخت.

#### ۴. ارزیابی شبکه عصبی در مدل‌سازی داده‌های ورودی

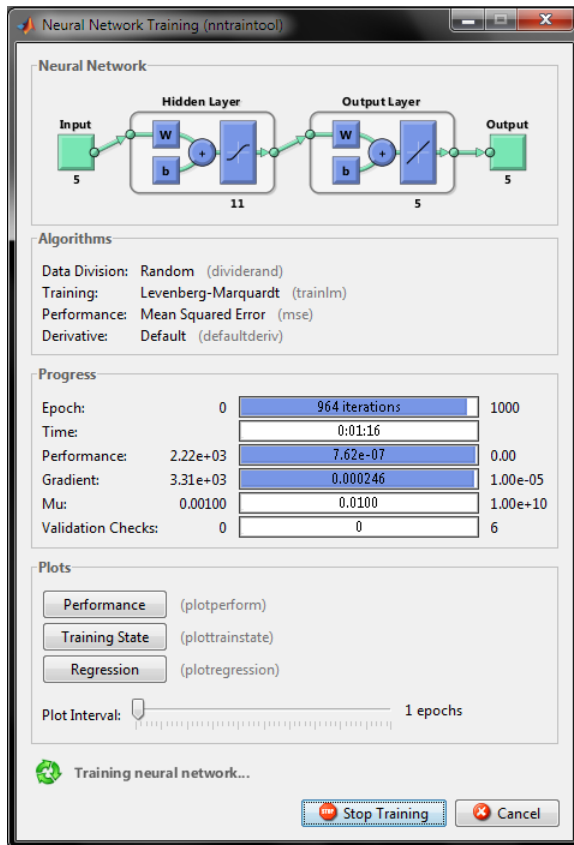
در این تحقیق، به‌طور کلی یادگیری نظارتی برای دو حوزه شبکه و ماشین مجازی به‌صورت یادگیری نظارتی کلاسیک و برای سه حوزه تقاضا، ابر و سرویس به‌صورت ترتیبی استفاده می‌شود. در ادامه به شرح نحوه ارزیابی هریک از این حوزه‌ها می‌پردازیم.

##### ۱.۴. مدل‌سازی سری زمانی حوزه تقاضا

پارامترهای حوزه تقاضا نقطه اتکای این مقاله برای توجیه قابل‌پیش‌بینی بودن و دارای الگوهای معین بودن مشتریان در ابر است. بنابراین، باید بتوان پیش از هرچیز این جنبه را بررسی کرد. در واقع این پارامترها چنانچه لازم باشد به‌صورت زوج مقادیر «ورودی-خروجی» یا همان یادگیری نظارتی مدل‌سازی شوند، مسئله را به شکل یادگیری نظارتی ترتیبی مطرح می‌کنند که به‌شکل خام توسط شبکه‌های عصبی قابل مدل‌سازی نیست. از این‌رو، با استفاده از تکنیک پنجره لغزان این پارامترها به شکل مسئله یادگیری نظارتی کلاسیک در خواهند آمد. بدین ترتیب، توسط انتخاب پنجره‌ای با اندازه ۴ واحد، مدل‌سازی را برای این پارامترها انجام می‌دهیم. شکل ۳ نمودار توزیع تعداد تقاضا، میزان دانه‌دانه‌ای بودن تقاضا و نرخ رد شدن درخواست را نشان می‌دهد.



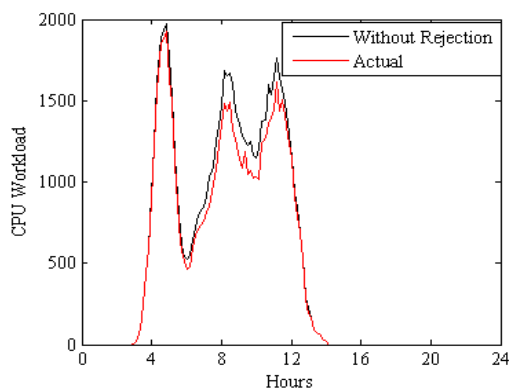
(د)



شکل ۴: مدل RNN مربوط به سیستم تشخیص نفوذ حوزه شبکه

#### ۴.۴. مدل سازی سیستم حوزه ابر

حوزه ابر نیز برای مدل سازی رفتار عمومی ابر شامل پارامترهایی در قالب سری های زمانی برای بارکاری کلی پردازنده و RAM می باشد. این پارامترها نیز با استفاده از تکنیک پنجره لغزان، با پنجره های به اندازه ۴ واحد، از مسئله یادگیری نظارتی ترتیبی به شکل مسئله نظارتی کلاسیک درمی آیند. شبکه های عصبی مورد استفاده برای مدل سازی بارکاری پردازنده و RAM به صورت  $1(7(3)$  می باشد. در شکل ۵ در الف و ب به ترتیب نمودار رفتار عمومی ابر برای بارکاری پردازنده و RAM را در زمان های یک روز نشان داده می شوند.



(الف)

جدول ۱: تحلیل حساسیت را برای پارامترهای Gran.Dem و Rej

Rej		Gran		Dem		میزان نویز %
R	NMSE	R	NMSE	R	NMSE	
0.97	۰.۰۰۳۳	۰.۹۸	۰.۰۰۴۴	۰.۹۷	۰.۰۰۵۲	0
۰.۹۷	۰.۰۰۴۸	۰.۹۷	۰.۰۰۴۹	۰.۹۶	۰.۰۰۶۸	۵
۰.۹۶	۰.۰۰۶۱	۰.۹۵	۰.۰۰۵۸	۰.۹۵	۰.۰۰۹۳	10
۰.۹۴	۰.۰۰۷۹	۰.۹۴	۰.۰۰۸۸	۰.۹۳	۰.۰۱۳	15


#### ۲.۴. مدل سازی NIDS

برای مدل سازی رفتار نرمال کاربران در حوزه شبکه باید پارامترهای زیر را مدل سازی کند: شناسه کاربری، پروتکل مورداستفاده، طول سرآیند بسته اطلاعاتی، Check Sum، پورت مبدأ و پورت مقصد. شبکه عصبی مورد استفاده برای مدل سازی رفتار نرمال کاربران در حوزه شبکه همان طور که پیش تر عنوان شد یک شبکه عصبی تکرارکننده یا به صورت فنی تر یک autoencoder است. معماری این شبکه نیز به صورت سعی و خطا انتخاب شده و در نهایت به شکل  $6(6(9(6)$  درآمده است.

#### ۳.۴. مدل سازی VMIDS

مانند مدل سازی در حوزه شبکه، حوزه رفتار ماشین مجازی نیز باید به صورت مدل سازی رفتار نرمال ماشین های مجازی توسط شبکه عصبی تکرارکننده یا autoencoder برای پارامترهای زیر صورت گیرد: نام مالک ماشین مجازی، نام فرآیند، تعداد نخ های فرآیند، درصد استفاده از ظرفیت پردازنده و درصد استفاده از ظرفیت RAM. مانند حوزه شبکه، سعی و خطا معیار تعیین مدل RNN برای مدل سازی رفتار نرمال ماشین مجازی خواهد بود. مدل این شبکه به صورت  $5(5(11(5)$  در نظر گرفته شده است. این مدل در شکل ۴ آمده است.





(ب)

شکل ۶: نمودار توقف موقت ارائه خدمت. الف) TSU، ب) TSUV


معماری‌های شبکه‌های عصبی تعبیه‌شده برای پارامترهای این حوزه شامل روند میزان توقف موقت ارائه خدمت و ارزش توقف موقت ارائه خدمت به ترتیب به صورت (۱۷/۳، ۱۷/۳) و (۱۸/۳) می‌باشد. جدول ۳ تحلیل حساسیت را برای شبکه‌های عصبی این حوزه نشان می‌دهد.

جدول ۳: کارایی شبکه عصبی برای مدل‌سازی TSU و TSUV

میزان نویز	TSUV		TSU	
	R	NMSE	R	NMSE
0%	۰.۹۷	۰.۰۱۲	۰.۹۵	۰.۰۱۱
5%	۰.۹۶	۰.۰۱۵	۰.۹۳	۰.۰۱۴
۱۰%	۰.۹۴	۰.۰۱۷	۰.۹۲	۰.۰۱۸
15%	۰.۹۳	۰.۰۲	۰.۹۲	۰.۰۲۳

## ۵. نتیجه‌گیری

درواقع رویکردهای پیشین با تعداد ارجاعات بسیار زیاد معمولاً شبکه عصبی مدل‌ساز را به صورت یک دسته‌بندی‌کننده با یک گره در لایه خروجی به کار می‌بردند تا بتوانند با یک مقدار صفر و یا یک نفوذ یا عادی بودن رفتار را دسته‌بندی کنند. برای این امر، لازم است رفتار حمله همراه رفتار عادی با تعداد داده‌های برابر یعنی ۵۰٪ رفتار عادی و ۵۰٪ رفتار مربوط به نفوذ به شبکه به عنوان ورودی وارد شود و یک برچسب تفاوت این دو رفتار متفاوت را به شبکه اطلاع دهد. مشکلی که درباره این رویکرد در ادبیات موضوع نیز به آن اشاره شده، همان مشکل معروف پیش‌برازش است که البته با مکانیسم‌های Cross-validation در قالب Early Stopping توسط شبکه‌های عصبی به آن پرداخته شده و مشکل برطرف خواهد شد. در این مقاله مدل‌سازی رفتار نرمال انجام شده و در روش مورد مقایسه مدل‌سازی نفوذ صورت می‌گیرد. اما از طرفی، برای روش پیشنهادی داده‌های نفوذ در دسترس نیست و برای رویکرد مورد مقایسه داده‌های عادی به این صورت، معیارهای ارزیابی منطقی‌تقابل برعکس نتایج مثبت اشتباه و نتایج منفی اشتباه را در پی خواهند داشت. بنابراین، اگرچه حوزه معیارهای ارزیابی را در تقابل یکدیگر قرار می‌دهد، اما رویکرد و دیدگاه مدل‌سازی یکسان بوده و کاملاً تطبیق می‌کند. روش پیشنهادی و روش مورد مقایسه هر دو در تلاشند تا آنچه در اختیار دارند



(ب)

شکل ۵: نمودار رفتار عمومی ابر برای بارکاری پردازنده و RAM


جدول ۲ تحلیل حساسیت برای کارایی این شبکه‌ها را در حضور نویز نشان می‌دهد.

جدول ۲: کارایی شبکه عصبی برای مدل‌سازی TSU و TSUV

میزان نویز	بارکاری RAM		بارکاری CPU	
	R	NMSE	R	NMSE
۰٪	۰.۹۵	۰.۰۱۲	۰.۹۴	۰.۰۱۶
۵٪	۰.۹۵	۰.۰۱۶	۰.۹۳	۰.۰۱۹
۱۰٪	۰.۹۴	۰.۰۲۲	۰.۹۳	۰.۰۲۷
۱۵٪	۰.۹۲	۰.۰۳۵	۰.۹۰	۰.۰۳۲

## ۵.۴. مدل‌سازی سیستم حوزه سرویس

حوزه سرویس مانند حوزه تقاضا و حوزه ابر دارای پارامترهایی از نوع سری زمانی است که همانند این دو حوزه توسط تکنیک پنجره لغزان با پنجره‌هایی با اندازه ۴ به مسئله یادگیری نظارتی کلاسیک تبدیل می‌شود. شکل ۴ نمودار TSU و TSUV را نشان می‌دهد.



(الف)

را مدل‌سازی‌کنند و آنچه در اختیار نیست را به صورت تصادفی تولید می‌کنند. بنابراین چنانچه هر دو برای داده یکسان پیاده‌سازی شوند ولی اهمیت حوزه روش مورد مقایسه به مدل‌سازی داده‌های رفتار نرمال تغییر کند، مسأله مقایسه به تقابل کارایی دو روش یادگیری ماشین در مدل‌سازی داده‌های موجود تبدیل می‌شود. نوع متغیرهای مورد ارزیابی در جدول ۴ دیده می‌شود:

## مراجع

- [13] R. Sondhiya, M. Shreevastav, and M. Mishra, "To Improve Security in Cloud Computing with Intrusion detection system using Neural Network," *International Journal of Soft Computing and Engineering (IJSCE)* vol. 3, 2013.
- [14] K. Zunnurhain, "FAPA: a model to prevent flooding attacks in clouds," in *Proceedings of the 50th Annual Southeast Regional Conference*, 2012, pp. 395-396.
- [15] S. N. Dhage and B. Meshram, "Intrusion detection system in cloud computing environment," *International Journal of Cloud Computing*, 2012, vol. 1, pp. 282-61.
- [16] H. M. Alsafi, W. M. Abdullallah, and A.-S. K. Pathan, "IDPS: an integrated intrusion handling model for cloud computing environment," *International Journal of Computing & Information Technology (IJCIT)*, vol. 4, pp. 1-16, 2012.
- [17] T. Vissers, T. S. Somasundaram, L. Pieters, K. Govindarajan, and P. Hellinckx, "DDoS defense system for web services in a cloud environment," *Future Generation Computer Systems*, vol. 37, pp. 37-45, 2014.
- [18] Kim, M., Ou, E., Loh, P. L., Allen, T., Agasie, R., & Liu, K. (2020). RNN-Based online anomaly detection in nuclear reactors for highly imbalanced datasets with uncertainty. *Nuclear Engineering and Design*, 364, 110699.
- [19] Wei, G., & Wang, Z. (2021). Adoption and realization of deep learning in network traffic anomaly detection device design. *Soft Computing*, 25(2), 1147-1158.
- [20] Chaibi, N., Atmani, B., & Mokaddem, M. (2020, October). Deep Learning Approaches to Intrusion Detection: A new Performance of ANN and RNN on NSL-KDD. In *Proceedings of the 1st International Conference on Intelligent Systems and Pattern Recognition* (pp. 45-49).
- [21] Murugesan, M., & Thilagamani, S. (2020). Efficient anomaly detection in surveillance videos based on multi layer perception recurrent neural network. *Microprocessors and Microsystems*, 79, 103303.
- [22] Wu, D., Zhu, H., Zhu, Y., Chang, V., He, C., Hsu, C. H., ... & Huang, Z. (2020). Anomaly Detection Based on RBM-LSTM Neural Network for CPS in Advanced Driver Assistance System. *ACM Transactions on Cyber-Physical Systems*, 4(3), 1-17.
- [23] Yin, C., Zhang, S., Wang, J., & Xiong, N. N. (2020). Anomaly detection based on convolutional recurrent autoencoder for IoT time series. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*.
- [24] Luo, D., Lu, J., & Guo, G. (2020). Road Anomaly Detection Through Deep Learning Approaches. *IEEE Access*, 8, 117390-117404.
- [1] Jaber, A. N., & Rehman, S. U. (2020). FCM-SVM based intrusion detection system for cloud computing environment. *Cluster Computing*, 1-11.
- [2] Shamshirband, S., Fathi, M., Chronopoulos, A. T., Montieri, A., Palumbo, F., & Pescapè, A. (2020). Computational intelligence intrusion detection techniques in mobile cloud computing environments: Review, taxonomy, and open research issues. *Journal of Information Security and Applications*, 55, 102582.
- [3] Krishnaveni, S., Sivamohan, S., Sridhar, S. S., & Prabakaran, S. (2021). Efficient feature selection and classification through ensemble method for network intrusion detection on cloud computing. *Cluster Computing*, 1-19.
- [4] Zhang, Z., Wen, J., Zhang, J., Cai, X., & Xie, L. (2020). A many objective-based feature selection model for anomaly detection in cloud environment. *IEEE Access*, 8, 60218-60231.
- [5] Wei, J., Long, C., Li, J., & Zhao, J. (2020). An intrusion detection algorithm based on bag representation with ensemble support vector machine in cloud computing. *Concurrency and Computation: Practice and Experience*, 32(24), e5922.
- [6] Krishnaveni, S., Vigneshwar, P., Kishore, S., Jothi, B., & Sivamohan, S. (2020). Anomaly-based intrusion detection system using support vector machine. In *Artificial Intelligence and Evolutionary Computations in Engineering Systems* (pp. 723-731). Springer, Singapore.
- [7] Aldribi, A., Traore, I., Moa, B., & Nwamuo, O. (2020). Hypervisor-based cloud intrusion detection through online multivariate statistical change tracking. *Computers & Security*, 88, 101646.
- [8] Abdulkadder, I. H., Zhou, S., Zou, D., Aziz, I. T., & Akber, S. M. A. (2020). Multi-layered intrusion detection and prevention in the SDN/NFV enabled cloud of 5G networks using AI-based defense mechanisms. *Computer Networks*, 179, 107364.
- [9] Alkadi, O., Moustafa, N., Turnbull, B., & Choo, K. K. R. (2020). A deep blockchain framework-enabled collaborative intrusion detection for protecting iot and cloud networks. *IEEE Internet of Things Journal*.
- [10] Mugabo, E., & Zhang, Q. Y. (2020). Intrusion Detection Method Based on Support Vector Machine and Information Gain for Mobile Cloud Computing. *IJ Network Security*, 22(2), 231-241.
- [11] Kushwah, G. S., & Ranga, V. (2020). Voting extreme learning machine based distributed denial of service attack detection in cloud computing. *Journal of Information Security and Applications*, 53, 102532.
- [12] Kushwah, G.S. and Ranga, V., 2022. DDoS Attacks Detection in Cloud Computing Using ANN and Imperialistic Competitive Algorithm. In *Artificial Intelligence and Sustainable Computing* (pp. 253-263). Springer, Singapore.