

یک سامانه تشخیص نفوذ برای شهرهای هوشمند با استفاده از شبکه عصبی و الگوریتم اره ماهی

زهرا سرحدی^{۱*}، مهدی خزاعی پور^۲

دانشجوی دکترا، گروه مهندسی کامپیوتر، دانشکده فنی و مهندسی، واحد بیرجند، دانشگاه آزاد اسلامی، بیرجند، ایران^{۱*}

استادیار، گروه مهندسی کامپیوتر، دانشکده فنی و مهندسی، واحد بیرجند، دانشگاه آزاد اسلامی، بیرجند، ایران^۲

چکیده

اینترنت اشیا (IoT) شبکه‌ای گسترده از اشیای هوشمند متصل به اینترنت است که در شهرهای هوشمند برای یک پارچه‌سازی سامانه‌هایی مانند حمل و نقل، برق و بهداشت کاربرد دارد. یکی از چالش‌های مهم در شبکه‌های IoT حملات سایبری است که موجب اختلال در سرویس‌ها می‌شود. برای مقابله با این تهدیدات استفاده از سامانه‌های تشخیص نفوذ مبتنی بر یادگیری ماشین ضروری است. در این مقاله روشی ترکیبی برای تشخیص حملات به شهرهای هوشمند ارائه شده است که شامل سه مرحله است: (۱) متعادل‌سازی داده‌ها با تئوری بازی و شبکه GAN، (۲) انتخاب ویژگی با الگوریتم بهینه‌سازی اره ماهی، (۳) تنظیم پارامترهای ماشین بردار پشتیبان (SVM) با الگوریتم‌های محاسبات ریاضی. شبکه عصبی چندلایه برای تحلیل ویژگی‌ها و SVM برای طبقه‌بندی ترافیک استفاده شده‌اند. نتایج آزمایش‌ها روی مجموعه داده NSL-KDD در نرم‌افزار MATLAB، دقت ۹۹.۱۲ درصد، حساسیت ۹۸.۹۲ درصد و صحت ۹۸.۹۶ درصد را نشان می‌دهد. روش پیشنهادی نسبت به الگوریتم‌های گرگ خاکستری و ژنتیک عملکرد دقیق‌تری دارد.

واژگان کلیدی: اینترنت اشیا، شهرهای هوشمند، سامانه تشخیص نفوذ، یادگیری ماشین، الگوریتم اره ماهی، انتخاب ویژگی.

A detection system for smart cities Using a neural network and Sailfish Optimizer algorithm

Zahra Sarhadhi^{1*}, Mehdi khazaiepoor²

PhD student, Computer Engineering Department, Technical and Engineering Faculty, Birjand Branch, Islamic Azad University, Birjand, Iran^{1*}

Assistant Professor, Department of Computer Engineering, Technical and Engineering Faculty, Birjand Branch, Islamic Azad University, Birjand, Iran²

Abstract

"The Internet of Things" is an extensive network of intelligent objects that has a large number of objects connected to the Internet. One of the applications of the IOT network is in smart cities. In smart cities, all parts of the city, such as the transportation system, electricity network, health network, etc., are interconnected with IOT support. One of the critical challenges of the IOT network is the occurrence of attacks against this network, which causes the network services to be disrupted. Intrusion detection systems are used to detect attacks on the IOT. The role of an IoT network intrusion detection system is to analyze the network traffic, detect abnormal traffic, and send necessary warning to the firewall. One of the methods of detecting attacks on the IOT and smart cities is to use machine learning methods such as support vector machines (SVM). One method to reduce the error of the support vector machine in detecting attacks on the IOT network and the smart city is to use feature selection methods and optimize its parameters. By selecting the feature and optimizing the parameters of the support vector machine, the attack detection error will be reduced. In this article, an intrusion detection method with an artificial

* Corresponding author

* نویسنده عهده‌دار مکاتبات

neural network and a swordfish optimization algorithm is presented to detect attacks on the smart city. The proposed method includes three different phases: data set balancing with game theory and GAN network, feature selection with Sailfish Optimizer algorithm, and optimization of SVM parameters with Archimedes optimization algorithm (AOA) algorithm. The role of a multilayer neural network in the proposed method of evaluating feature vectors and the role of the support vector machine is to classify network traffic into two categories: attack and normal. The evaluation and tests performed in MATLAB software and on the NSL-KDD data set show that the accuracy, sensitivity, and precision of the proposed method are 99.12%, 98.92%, and 98.96%, respectively, and the support vector machine with Gaussian kernel seems to be more accurate. The results of the experiments showed that the proposed method is more accurate than meta-heuristic algorithms, such as gray wolf optimization and genetic algorithms in detecting attacks on the smart city.

Keywords: Internet of Things, Smart Cities, Intrusion Detection System, Machine Learning, Sailfish Optimizer Algorithm, Feature Selection.

سامانه‌های تشخیص نفوذ^۳ در حال حاضر بخش مهمی از حفاظت از امنیت میزبان‌ها و سامانه‌ها هستند. وظیفه مهم یک سامانه تشخیص نفوذ در شبکه تجزیه و تحلیل ترافیک شبکه و شناسایی حملات است و این حملات را می‌تواند به یک دیوار آتش گزارش دهد[۵].

اینترنت اشیا شبکه‌ای بزرگ از اشیای متنوع و ناهمگن است و در این شبکه حملات می‌تواند بسیار پیچیده باشد؛ لذا برای طراحی یک سامانه تشخیص نفوذ چالش‌های مختلفی وجود دارد؛ برای نمونه در این شبکه گره‌های متصل به شبکه می‌توانند نقش حمله‌کننده داشته باشند، بدون آن‌که برای این هدف طراحی شده باشند. در اینترنت اشیا ارتش بات‌ها^۴ [۶] نقش مخربی علیه سرویس‌های ارائه‌دهنده خدمات دارد. در اینترنت اشیا و شهرهای هوشمند انواع ویروس و بدافزار^۵ [۷] می‌تواند اشیای هوشمند را آلوده کند و این اشیای هوشمند نقش حمله‌کننده را برعهده خواهند داشت. یکی از انواع حملاتی که می‌تواند در اینترنت اشیا، آسیب زیادی به زیرساخت‌ها وارد کند، حملات رد سرویس خدمات توزیع‌شده^۶ است. در این نوع از حملات تعدادی زیادی بات‌نت مشارکت دارند و هر بات‌نت یک ترافیک کاذب را برای یک سرویس‌دهنده ارسال می‌کند. در این نوع از حملات هدف آن است که سرویس‌دهنده دچار اختلال شود و نتواند به کاربران ارائه خدمات کند. دوربین‌های هوشمند در شهرهای هوشمند به دلیل پیکربندی ضعیف امنیتی می‌توانند گزینه‌ای مناسبی برای هکرها باشند تا از این طریق حملات خود را عملی کنند[۸].

در شبکه اینترنت اشیا و شهرهای هوشمند اشیای ناهمگن زیادی وجود دارد و این دستگاه‌ها توسط سازندگان مختلفی تولید می‌شوند که برای کاهش هزینه‌ها تلاش دارند تا نکات امنیتی را رعایت نکنند. با وجود این چالش‌ها برای ارتقای امنیت شبکه اینترنت اشیا و

۱- مقدمه

امنیت فناوری‌های جدید از جمله شبکه اینترنت اشیا^۱ [۱] و شهرهای هوشمند^۲ [۲] یک موضوع مداوم در حال توسعه و در حال ظهور است. پیشرفت بیشتر فناوری‌ها منجر به آسیب‌پذیری بیشتر و افزایش تهدید حملات به شبکه می‌شود و باعث می‌شود نوع حملات نیز پیشرفته شود. روش‌های امنیتی سنتی برای برقراری امنیت شبکه دیگر معتبر نیستند؛ زیرا حملات هوشمندانه‌تری در حال انجام است. این امر باعث شده‌است تا پژوهش‌گران جنبه دیگری برای محافظت از سامانه‌ها در برابر حملات استفاده کنند؛ زیرا در این حالت داده‌ها کمابیش از هر دستگاه تولید می‌شود و هر دستگاه متصل به شبکه اینترنت اشیا می‌تواند نقش یک حمله‌کننده به شبکه را داشته باشد. مطالعات نشان می‌دهد که فناوری‌های اخیر داده‌های عظیمی از طیف گسترده‌ای از منابع را تولید می‌کنند؛ برای مثال تلفن‌های هوشمند که منبع داده‌های چندجریانی را از مجموعه‌های حس‌گر خود مانند شتاب‌سنج، ژيروسکوپ و سامانه موقعیت‌یابی جهانی ارائه می‌کنند[۳].

در سال‌های اخیر، با توسعه مداوم فناوری ارتباطات شبکه، اینترنت اشیا، محاسبات ابری و سایر فناوری‌های این فناوری‌های مبتنی بر شبکه به شدت در جامعه مدرن ریشه پیدا کرده‌اند. هم‌زمان با رشد و توسعه شبکه اینترنت اشیا، وضعیت امنیتی در فضای سایبری به طور فزاینده‌ای پیچیده می‌شود. امنیت سایبری شرکت‌ها، دولت‌ها و افراد دائم در معرض تهدیدات مختلف امنیت سایبری قرار دارند. بر اساس «گزارش ربات بد ۲۰۲۱» منتشرشده به وسیله Imperva در سال ۲۰۲۱، تنها ۵۹.۲ درصد از کل ترافیک شبکه را ترافیک انسانی تشکیل می‌دهد. در میان ترافیک تولیدشده به وسیله ماشین‌ها، ترافیک مخرب ۲۵.۶ درصد از کل ترافیک شبکه را تشکیل می‌دهد[۴]. در بسیاری از حوادث امنیتی شبکه، نفوذهای مخرب سهم زیادی را به خود اختصاص می‌دهند که تهدیدات بزرگی هم به کاربران شبکه و هم به شرکت‌ها تحمیل می‌کند؛

³ Intrusion detection systems (IDS)

⁴ Botnet

⁵ Malware

⁶ Distributed denial-of-service attack (DDoS attack)

¹ Internet of Things

² Smart cities

هدف اصلی ما از این پژوهش ارائه یک سامانه تشخیص نفوذ هوشمند برای تشخیص حملات در اینترنت اشیا است. این مقاله دارای چند بخش مختلف است در بخش دوم پیشینه پژوهش ارائه می‌شود و در بخش سوم نیز روش پیشنهادی برای تشخیص حملات به اینترنت اشیا با الگوریتم اره ماهی و شبکه عصبی مصنوعی ارائه می‌شود. در بخش چهارم روش پیشنهادی تجزیه و تحلیل و نتایج آن بیان می‌شود. در بخش پنجم نیز نتیجه گیری مقاله و پیشنهادهای آینده ارائه می‌شود.

۲- پیشینه پژوهش

در این بخش ادبیات موضوعی و مروری بر پیشینه پژوهش و کارهای مرتبط در حوزه اینترنت اشیا، شهرهای هوشمند و سامانه‌های تشخیص بررسی خواهد شد.

۲-۱- اینترنت اشیا

اینترنت اشیا به طور گسترده به عنوان یکی از رایج ترین انقلاب های فناوری در دو دهه گذشته در نظر گرفته می شود. دستگاه های اینترنت اشیا بیشتر به عنوان دستگاه های محاسباتی با قابلیت های سنجش، قدرت محاسباتی داخلی و شبکه ای مجهز به اینترنت برای برقراری ارتباط با یکدیگر تلقی می شوند. این حوزه فناوری، یکی از حوزه هایی است که به سرعت در حال رشد است و به ارتباطات ماشین به ماشین متکی است و از پشته پروتکل اینترنت^۸ برای برقراری ارتباط سرتاسری^۹ استفاده می کند. در ساده ترین عبارت، اینترنت اشیا به عنوان شبکه ای متشکل از میلیاردها دستگاه تلقی می شود که می تواند اطلاعات را حس کرده و فعال کند و به یک سامانه متمرکز منتقل کند. امروزه دستگاه ها و برنامه های IoT در حوزه های مختلفی مانند ترابری، خرده فروشی، مراقبت های بهداشتی، شبکه شهر هوشمند، حمل و نقل هوشمند و مدیریت بلایا مستقر و استفاده شده اند.

با وجود پیشرفت های فناوری در این حوزه های فردی، ناهمگونی دستگاه های اینترنت اشیا و وجود چالش های استاندارد سازی اشیا هنوز مورد توجه قرار نگرفته است. با وجود فقدان استانداردها، سامانه های اینترنت اشیا در حال حاضر با سرعت خیره کننده ای در حال گسترش اند. سامانه های اینترنت اشیا اکنون از جمعیت جهان فراتر رفته و پیش بینی می شود تا سال ۲۰۲۵ به هشتاد میلیارد دستگاه برسد. به منظور اطمینان از قابلیت همکاری، مقیاس پذیری و قابلیت اطمینان سامانه های اینترنت اشیا، بررسی دقیق تری از پشته فناوری مورد نیاز است. برآوردها نشان می دهد که در سال ۲۰۲۵ تعداد کل نصب

شهرهای هوشمند نیاز به سامانه های امنیتی هوشمند و دقیقی است که بتواند جلوی حملات را بگیرد و دارای هوشمندی بالایی باشد. یک روش کارآمد برای تشخیص حملات به شبکه اینترنت اشیا و شهرهای هوشمند، استفاده از روش های یادگیری ماشین و یادگیری عمیق است. از جمله روش های یادگیری که برای تشخیص حملات به کار گرفته شده است می توان به شبکه عصبی مصنوعی^۱ [۹]، ماشین بردار پشتیبان^۲ [۱۰] و جنگل تصادفی^۳ [۱۱] اشاره کرد؛ هر کدام از این روش ها تلاش دارند تا الگوی حملات به شبکه را تشخیص دهند و حملات مخرب را به دیوار آتش گزارش دهند. یکی از چالش های مهم روش های یادگیری ماشین آن است که روی همه ویژگی ها آموزش داده می شوند و این موضوع باعث می شود که یادگیری روی ویژگی های مهم متمرکز نشود. یک روش برای آن که خطای خروجی روش های یادگیری ماشین در تشخیص حملات کاهش داده شود، استفاده از انتخاب ویژگی^۴ است [۱۲]. انتخاب ویژگی باعث می شود که ورودی های یادگیری ماشین نیز کاهش داده شود و این موضوع باعث می شود که زمان یادگیری نیز کاهش یابد. برای تشخیص نفوذ به شبکه در اینترنت اشیا تاکنون از چند روش انتخاب ویژگی استفاده شده است که نمونه آن الگوریتم ژنتیک^۵ [۱۳] و الگوریتم بهینه سازی ذرات^۶ [۱۴] است. در این پژوهش برای تشخیص حملات به شبکه اینترنت اشیا از یک روش دو مرحله ای استفاده می شود. در روش پیشنهادی در ابتدا مرحله انتخاب ویژگی با الگوریتم اره ماهی^۷ [۱۵] انجام می شود؛ سپس از طبقه بندی کننده شبکه عصبی برای تحلیل ترافیک شبکه استفاده می شود. سامانه پیشنهادی مورد نظر از این جهت مزیت دارد که مفاهیم هوش گرویی را با شبکه عصبی ترکیب می کند تا تحلیل ترافیک با دقت بیشتری انجام شود. سهم ما نویسندگان در این مقاله در موارد زیر خلاصه شده است:

- ارائه یک نسخه دودویی از الگوریتم اره ماهی برای انتخاب ویژگی
- متعادل سازی مجموعه داده با تئوری بازی و یادگیری عمیق مبتنی بر روش GAN
- بهینه سازی فرای پارامترهای SVM با الگوریتم بهینه سازی محاسبات ریاضی
- تلفیق شبکه عصبی مصنوعی و الگوریتم اره ماهی در انتخاب ویژگی

¹ Artificial neural network

² Support vector machines (SVMs)

³ Random forest

⁴ Feature selection

⁵ Genetic algorithm

⁶ Particle swarm optimization algorithm

⁷ Sailfish optimization algorithm

⁸ Internet Protocol Stack

⁹ end-to-end communication

دستگاه‌های اینترنت اشیا در سراسر جهان از ۷۵ میلیارد نفر فراتر رود که این موضوع در شکل (۱)، نمایش داده شده‌است [۱۶]. پژوهش‌گران در حال حاضر در حال بررسی روش آدرس‌دهی IPv6 برای شبکه‌های بزرگ‌ترند که پیش‌بینی می‌شود به استاندارد نشان‌دهی برای دستگاه‌های IoT تبدیل شود.

مدل‌های مرجع اینترنت اشیا گامی روبه‌جلو در درک دسترسی به منابع، فناوری‌ها و هم‌گرایی لایه‌های تجاری به‌منظور اطمینان از مقیاس‌پذیری بازار است. به‌طور مشابه، نقش عناصر مختلف فعال در این لایه‌های اینترنت اشیا باید بررسی شود.

اینترنت مدرن ترکیبی پیچیده از گره‌های اینترنت، دستگاه‌های اینترنت اشیا و اشیای هوشمند است. شبکه‌های مجهز به اینترنت نیاز به پیاده‌سازی یک پشته IP برای ارتباط بین شبکه‌های اشیا دارند. با گسترش شبکه‌های اینترنتی، شرکت‌ها و همچنین جوامع پژوهشی در حال سرمایه‌گذاری در شبکه‌های IP انعطاف‌پذیر و مقیاس‌پذیر برای آینده‌اند.

در حال حاضر، شبکه‌های مجهز به اینترنت هم از نظر پیاده‌سازی فنی و هم در نیازهای برنامه‌های پایانی بسیار متفاوت‌اند. یک گره محاسباتی معمولی (مانند رایانه‌های

شخصی، لپ‌تاپ‌ها، تلفن‌های همراه و تبلت‌ها) کل پشته TCP/IP را بر اساس مدل اتصال سامانه‌های باز پیاده‌سازی می‌کند؛ با این حال، به‌دلیل منابع محدود موجود در دستگاه‌های اینترنت اشیا، بر حسب معمول یک پشته IP سبک‌وزن پیاده‌سازی می‌شود. در دسترس‌بودن منابع داخلی و مصرف انرژی دستگاه در درجه نخست اجرای پروتکل‌ها و استانداردهای مناسب در دستگاه‌های اینترنت اشیا را تنظیم می‌کند؛ بنابراین، در اصل بررسی معماری‌ها و پلتفرم‌های IoT برای درک نقش و رفتار در هر لایه از پشته فناوری مهم است. برای اینترنت اشیای چندمعماری در نظر گرفته شد که سه مدل مطرح آن در شکل (۲) به نمایش گذاشته شده‌است [۱۶].

در این معماری‌ها که به معماری سه‌لایه و پنج‌لایه معروف‌اند، لایه‌های حس‌گر، لایه شبکه، لایه کاربردی، لایه میان‌افزار و لایه تجاری وجود دارد. در اینترنت اشیا، لایه حس‌گر اطلاعات را به‌وسیله حس‌گرها گردآوری کرده و به‌کمک لایه شبکه می‌توان این اطلاعات را برای لایه کاربردی ارسال کرد و آن‌ها را پردازش کرد. اطلاعات در لایه کاربردی می‌تواند در سامانه‌های ابری پردازش و تحلیل شود و الگوی مفید آن‌ها استخراج شود.



(شکل-۱): افزایش تعداد اشیای هوشمند بین سال‌های ۲۰۱۹ تا ۲۰۳۰ [۱۶]
(Figure-1): Increasing the number of smart objects between 2019 and 2030 [16]


۲-۲- حملات به شبکه اینترنت اشیا

طی چند سال گذشته استفاده از دستگاه‌های هوشمند اینترنت اشیا مانند دوربین‌های هوشمند، تلویزیون‌های هوشمند، پوشیدنی‌های هوشمند، اسباب‌بازی‌های هوشمند، لامپ‌های هوشمند و غیره به‌طور تصاعدی در زندگی روزمره ما در حال افزایش بوده‌است؛ در نتیجه، این پیشرفت در فناوری محاسباتی، به دستگاه‌های هوشمند این قابلیت را داده‌است که بدون دخالت انسان، به‌صورت خودکار با یکدیگر در تعامل باشند؛ با وجود این‌که دستگاه‌های اینترنت اشیا در بسیاری از زمینه‌ها به ما



(شکل-۲): سه معماری مطرح در اینترنت اشیا [۱۶]
(Figure-2): three proposed architectures in the Internet of Things [16]

منسجم در شبکه علیه یک سرویس، اجرایی می‌کنند. در این نوع حملات سرویس‌دهنده دیگر نمی‌تواند به ارائه خدمات به کاربران قانونی بپردازد. ارزیابی‌ها مطابق گزارش سیکسو نشان می‌دهد حملات DDoS تا سال ۲۰۲۲ رشد قابل توجهی خواهد داشت که یکی از دلایل اصلی این حملات وجود گره‌های آلوده به بدافزار است. طبق برآوردهای سیکسو تا سال ۲۰۲۲، میزان حملات DDoS در مقایسه با سال ۲۰۱۷ حدود دو برابر می‌شود که در نمودار شکل (۴) این موضوع نشان داده شده است. افزایش حجم و ترافیک حملات DDoS به سرعت در حال افزایش است و برآوردها نشان می‌دهد که حجم ترافیک این حملات تا ۱.۷ ترابایت بر ثانیه نیز خواهد بود. در مقایسه بین سال‌های ۲۰۱۷ و ۲۰۱۸، تعداد حملات علیه سامانه‌های امنیتی مانند سامانه تشخیص حملات و دیوار آتش به ترتیب از ۱۶ به ۳۱ درصد افزایش داشته است [۲۰].



(شکل-۳): حملات رد سرویس خدمات توزیع شده در

اینترنت اشیاء [۱۹]

(Figure-3): denial of service attacks of distributed [19] services in the Internet of Thing



(شکل-۴): رشد حملات رد سرویس خدمات توزیع شده در

سال‌های اخیر [۲۰]

(Figure -4): The growth of distributed service denial of service attacks in recent year [20]

۲-۳- سامانه تشخیص نفوذ


سامانه تشخیص نفوذ به شبکه یک وظیفه مهم دارد و آن تجزیه و تحلیل اطلاعات و ترافیک شبکه برای تشخیص حملات است. بیشتر سامانه‌های تشخیص نفوذ ساختار مشترکی دارند که شامل یک مازول جمع‌آوری داده‌ها و ترافیک است که به احتمال زیاد حاوی شواهدی از یک

کمک می‌کنند، ویژگی‌های امنیتی ناچیز یا بسیار محدودی دارند؛ علاوه بر این، بسیاری از دستگاه‌های اینترنت اشیا دارای یک کلید ثابت یا نام کاربری و رمز عبور پیش فرض با کد سخت هستند که کاربر نمی‌تواند آن‌ها را تغییر دهد. این تله‌های امنیتی، بهره‌برداری از این دستگاه‌های ناامن اینترنت اشیا و کنترل آن‌ها را برای هکرها آسان می‌کند. روندهای اخیر نشان می‌دهد که با افزایش سریع تعداد دستگاه‌های ناامن اینترنت اشیا، حملات سایبری روز به روز در حال افزایش است [۱۷].

در میان حملات سایبری اخیر، حملات بات‌نت و انکار سرویس توزیع شده (DDoS) شایع‌ترین حملاتی هستند که هم از نظر فراوانی و هم از نظر بزرگی در دهه گذشته افزایش یافته‌اند. حمله بات‌نت یک حمله سایبری است که در آن مهاجم ابتدا یک شبکه را پویش می‌کند تا دستگاه‌های دارای امنیت ضعیف یا آسیب‌پذیر را جست‌وجو کند، پس از تجزیه و تحلیل اطلاعات پویش، مهاجم دستگاه‌های آسیب‌پذیر را هدف قرار می‌دهد تا یک برنامه ربات را از طریق بدافزار در آن‌ها نصب کند. برنامه ربات نصب شده دستگاه‌های آلوده را به یک سرور مرکزی یا یک شبکه هم‌تا متصل می‌کند که از آنجا دستورهای بیشتر به آن‌ها ارسال می‌شود تا فعالیت‌های مخرب مختلفی مانند ارسال هرزنامه‌ها، DDoS و غیره را از تعداد زیادی دستگاه انجام دهند. هنگامی که یک دستگاه اینترنت اشیا آلوده و بخشی از یک بات‌نت می‌شود، مهاجم از دستگاه آلوده برای انجام حملات DDoS استفاده می‌کند. حمله بات‌نت نه تنها تهدیدی جدی برای دستگاه‌های ناامن اینترنت اشیا، بلکه تهدیدی حیاتی برای کل اینترنت است. با ظهور حمله بات‌نت Mirai در سال ۲۰۱۶، حملات بات‌نت IoT به طور مداوم در حال افزایش است. پس از افشای عمومی کد منبع بات‌نت Mirai، بسیاری از انواع بات‌نت Mirai و تقلیدکنندگان آن تکامل یافته‌اند. گونه‌های جدیدی از بات‌نت Mirai و نسخه‌های تقلید شده از آن با استفاده از کدهای مخرب، میلیون‌ها دستگاه اینترنت اشیا را آلوده کرده‌اند و حملات DDoS بزرگ و فاجعه‌باری علیه GitHub، AWS و غیره را در چند سال گذشته انجام داده‌اند [۱۸]. در شکل (۲)، یک سناریو از حملات علیه شبکه اینترنت اشیا و شهرهای هوشمند نشان داده شده است که در آن هکر می‌تواند در بخش‌های مختلف شبکه اینترنت اشیا نفوذ کند و سرویس‌های شبکه را مورد حمله قرار دهد [۱۹].

در این نوع از حملات تلاش می‌شود تا یک هکر تعداد زیادی سامانه را به بدافزار آلوده کرده و هر کدام از آن‌ها نقش یک بات‌نت را بازی کنند. در این حالت مشاهده می‌شود که بات‌نت‌ها با هم هماهنگ بوده و حملاتی

اندازه‌گیری می‌کند. سامانه‌های تشخیص نفوذ مبتنی بر شبکه را می‌توان بیشتر به سامانه‌های مبتنی بر بسته و جریان تقسیم کرد. اطلاعات بسته شبکه مانند بار یا هدر، برای سامانه‌های تشخیص نفوذ مبتنی بر بسته استفاده می‌شود؛ در نتیجه، بیشتر به آن سامانه‌های تشخیص نفوذ سنتی می‌گویند. در مقابل، سامانه‌های تشخیص نفوذ مبتنی بر جریان، ناهنجاری‌های درون یک شبکه را بر اساس ویژگی‌های جریان شبکه، مانند نرخ داده و بایت‌ها تحلیل و نظارت می‌کند؛ بنابراین، آن را به عنوان تحلیل رفتار شبکه نیز می‌شناسند. طبقه‌بندی فعالیت‌های مخرب یا غیرعادی شبکه با استفاده از مدل‌های یادگیری ماشین نظارت شده یا بدون نظارت امکان‌پذیر است [۲۷].




(شکل-۶): دسته‌بندی انواع سامانه‌های تشخیص نفوذ [۲۷]
(Figure-6): Classification of types of intrusion detection systems [27]

در ادامه این بخش تعدادی از مطالعات در زمینه سامانه‌های تشخیص نفوذ به شبکه مرور و بررسی می‌شود. در [۲۸] با هدف مقابله با حملات سایبری روشی برای تشخیص و پیش‌بینی نفوذ در شبکه ارائه می‌شود که بر پایه الگوریتم متاهیوریستیک گرگ خاکستری بهبود یافته است. ارزیابی با مجموعه داده NSL-KDD نشان داد که مدل پیشنهادی دقتی برابر با ۹۷.۱۴ درصد و ۹۸.۹۷ درصد در شناسایی حملات دارد که نسبت به روش‌های سنتی برتری محسوسی دارد؛ از جمله دستاوردها می‌توان به افزایش دقت، بهبود توازن تشخیص و کاهش چالش‌های طبقه‌بندی اشاره کرد.

در [۲۹] با توجه به افزایش پیچیدگی و تنوع حملات سایبری، مدلی هوشمند برای تشخیص نفوذ در شبکه ارائه شده است. با استفاده از روش PCA حجم داده‌ها کاهش یافته و سپس شبکه عصبی CNN برای شناسایی و طبقه‌بندی حملات به کار رفته است؛ این ترکیب باعث بهبود دقت، افزایش سرعت و کاهش نرخ خطا نسبت به روش‌های پیشین شده است.

در [۳۰] یک مدل انتخاب ویژگی مؤثر با استفاده از الگوریتم‌های فراابتکاری ترکیبی برای تشخیص نفوذ اینترنت اشیا ارائه شده است. این پژوهش یک روش انتخاب ویژگی جدید با استفاده از الگوریتم بهینه‌سازی پرندگان و گوریل ارائه داده است. روش آن‌ها روی چهار مجموعه داده NSL-KDD،

حمله است. ماژول تجزیه و تحلیل حملات وظیفه دارد ترافیک شناسایی شده را بررسی کرده و در صورت تشخیص الگوی یک حمله، نتایج را از طریق سازوکار گزارش‌دهی ارسال کند. در ماژول جمع‌آوری داده‌ها، ترافیک ورودی هر بخش از اینترنت اشیا را می‌توان جمع‌آوری و بررسی کرد تا ترافیک عادی از ناهنجاری یا حمله شناخته شود. ماژول تجزیه و تحلیل را می‌توان با استفاده از روش‌های مختلف پیاده‌سازی کرد؛ با این حال، روش‌های مبتنی بر یادگیری ماشین و یادگیری عمیق از بهترین روش‌ها برای تحلیل ترافیک شبکه است. در شکل (۵) یک سامانه تشخیص نفوذ به شبکه با روش‌های یادگیری ماشین و یادگیری عمیق نشان داده شده است.



(شکل-۵): نقش روش‌های یادگیری ماشین و یادگیری

عمیق برای تحلیل ترافیک اینترنت اشیا [۲۱]

(Figure-5): The role of machine learning and deep learning methods for Internet of Things traffic analysis [21]

در این شکل، مشاهده می‌شود که ورودی‌های مرتبط با روش‌های یادگیری ماشین و یادگیری عمیق در واقع ترافیک شبکه بوده و این اطلاعات برای آموزش و ارزیابی شبکه عصبی مصنوعی استفاده می‌شود. در اینجا ترافیک شبکه می‌تواند در دسته حمله یا نرمال و یا مشکوک قرار داده شود.

۲-۴- مرور مطالعات

سامانه تشخیص نفوذ نرم‌افزار یا سرویسی است که فعالیت‌های غیرعادی را در یک شبکه یا سامانه کنترل یا شناسایی می‌کند. برای پیش‌بینی ناهنجاری‌ها در شبکه‌های اینترنت اشیا، به طور معمول از روش‌های متنوع مانند یادگیری ماشین، روش‌های اکتشافی یا روش‌های فهرست سیاه استفاده می‌شود. شکل (۶)، نشان می‌دهد که سامانه‌های تشخیص نفوذ بیشتر به دو نوع سامانه‌های تشخیص نفوذ مبتنی بر میزبان و مبتنی بر شبکه تقسیم می‌شوند. یک سامانه تشخیص نفوذ مبتنی بر میزبان، یک دستگاه یا میزبان واحد را بر اساس اطلاعات دستگاه، مانند گزارش‌های سامانه، نظارت و ایمن می‌کند [۲۷]. در مقابل، یک سامانه تشخیص نفوذ مبتنی بر شبکه، جریان داده‌ها را در یک شبکه با دسترسی و تجزیه و تحلیل داده‌ها

CICIDS-2017، UNSW-NB15 و BoT-IoT پیاده‌سازی شده‌است. نتایج آزمایش‌ها نشان داد سامانه تشخیص نفوذ آن‌ها از روش‌های بهینه‌سازی ذرات و کلونی زنبور عسل در مرحله انتخاب ویژگی دقیق‌تر است.

در [۳۱] یک مدل تشخیص نفوذ انتخاب ویژگی مبتنی بر یادگیری تقویتی عمیق ارائه شده‌است. این پژوهش یک مدل تشخیص نفوذ شبکه را بر اساس استخراج ویژگی RFE و یادگیری تقویت عمیق ارائه می‌کند. سامانه تشخیص نفوذ پیشنهادی زیرمجموعه بهینه ویژگی‌ها را با استفاده از روش انتخاب ویژگی RFE پالایه می‌کند. در این مدل، ویژگی‌های منتخب با روش RFE به شبکه عصبی داده شده و با استفاده از مجموعه داده CSE-CIC-IDS2018 برای آموزش سامانه تشخیص نفوذ استفاده شده‌اند. نتایج تجربی نشان می‌دهد که مدل پیشنهادی می‌تواند زیرمجموعه بهینه ویژگی‌ها را انتخاب کند، حدود هشتاد درصد از ویژگی‌های اضافی را حذف کند و ویژگی‌های انتخاب شده را از طریق مدل یادگیری یاد بگیرد تا عملکرد سامانه تشخیص نفوذ را برای شناسایی حمله شبکه افزایش دهد.

در [۳۲] یک مدل یادگیری عمیق برای طراحی سامانه‌های تشخیص نفوذ شبکه ارائه شده‌است. برای تشخیص نفوذ در این مطالعه یک NIDS مبتنی بر ناهنجاری با استفاده از یک مدل یادگیری عمیق انباشته-LSTM با یک تکنیک پیش‌پردازش جدید پیشنهاد شده‌است که ویژگی‌های بدون زمینه به آن داده می‌شود و مجموعه داده CICIDS2017 به دست می‌آید؛ این سامانه همچنین می‌تواند در محیط‌های مختلف بدون ازدست‌دادن دقت خود به دلیل مبتنی بر ویژگی‌های بدون متن اعمال شود.

در [۳۳] برای حل مشکل عدم تعادل طبقه در سامانه‌های تشخیص نفوذ شبکه از نمونه‌گیری مجدد داده‌ها و یادگیری عمیق استفاده شده‌است. در این پژوهش یک روش نمونه‌گیری مجدد داده‌ها در ترکیب با مدل‌های مختلف یادگیری عمیق برای کاهش مشکل عدم تعادل طبقه پیشنهاد شده‌است. مدل پیشنهادی بر روی مجموعه داده NSL-KDD معیار با استفاده از معیارهای دقت ارزیابی می‌شود. نتایج تجربی نشان می‌دهند که در طبقه‌بندی دودویی، روش پیشنهادی عملکرد سامانه تشخیص نفوذ را بهبود می‌بخشد.

در [۳۴] یک رویکرد یادگیری عمیق فراابتکاری ترکیبی با مجموعه‌ای از شبکه‌های عصبی مکرر ارائه شده‌است. انواع مختلف حملات در سامانه‌های اینترنت اشیا با استفاده از مدل‌های یادگیری عمیق مانند LSTM، GRU و RNN شناسایی شده‌اند. انتخاب ویژگی‌ها با استفاده از بهینه‌سازی هریس هاک و جهش مشتق کسری، همان طور که در این

پژوهش به کاررفته‌است، انجام می‌شود. برای ارزیابی رویکرد پیشنهادی، از مجموعه داده‌های در دسترس عموم استفاده شد و تحلیل تجربی نشان داد که رویکرد پیشنهادی از نظر دقت و کارایی به خوبی نسبت به سایر روش‌های مرتبط کار می‌کند. در [۳۵] یک رویکرد سامانه تشخیص نفوذ قابل اعتماد با استفاده از شبکه عصبی پیچیده عمیق ارائه شده‌است. تازگی این مطالعه در توسعه یک سامانه تشخیص نفوذ قابل اعتماد است که از پتانسیل DCNN برای تجزیه و تحلیل ترافیک شبکه استفاده می‌کند. چهارچوب پیشنهادی با چهار مجموعه داده سامانه تشخیص نفوذ در دسترس عموم، یعنی 2012 ISCX-IDS، DDos، CICIDS2017 و CICIDS2018 ارزیابی می‌شود. نتایج آن‌ها اثربخشی مدل بهینه‌سازی شده DCNN را در بهبود عملکرد و دقت تشخیص نفوذ نشان می‌دهد.

در [۳۶] ایمن‌سازی سامانه‌های اینترنت اشیا و SDN با استفاده از تشخیص نفوذ خودکار مبتنی بر یادگیری عمیق ارائه شده‌است. این پژوهش یک سامانه تشخیص نفوذ خودکار دوسطحی امن را بر اساس یک شبکه بهبودیافته LSTM پیشنهاد می‌کند. سامانه پیشنهادی بین ترافیک حمله و ترافیک خوش‌خیم تفاوت قائل می‌شود، دسته حمله را شناسایی و نوع حمله فرعی را با عملکرد بالا تعریف می‌کند. سامانه پیشنهادی با دو مجموعه داده واقعی جدید (ToN-IoT) و (InSDN) آموزش داده شده و عملکرد آن مورد ارزیابی قرار گرفته است. نتایج تجربی نشان می‌دهد که سامانه پیشنهادی در تشخیص بسیاری از انواع حملات از سایرین بهتر عمل می‌کند. دقت ۹۶.۳۵ درصد، نرخ تشخیص ۹۶ درصد و دقت ۹۸.۴ درصد را برای مجموعه داده ToN-IoT به دست می‌آورد.

در [۳۷] سامانه تشخیص نفوذ بر پایه LSTM و GRU عمیق با شبکه ایمن برای تشخیص نفوذ پیشرفته در محیط‌های IoT ارائه شده‌است. ارزیابی‌ها نشان می‌دهد سامانه تشخیص نفوذ پیشنهادی نسبت به LSTM و GRU دقت بیشتری ارائه می‌کند و از طرفی توانایی تشخیص حملات ترکیبی و پیچیده را دارد.

در [۳۸] یک سامانه تشخیص نفوذ بر اساس شبکه عصبی عمیق برای تشخیص حملات ارائه شده‌است. هدف از این پژوهش طراحی یک مدل شبکه عصبی عمیق برای تشخیص نفوذ است و روش‌هایی مانند SMOTE و نمونه‌گیری تصادفی برای رسیدگی به عدم تعادل داده‌ها در مجموعه داده CICIDS 2017 استفاده شده‌است. نتایج نشان می‌دهد که مدل یادگیری عمیق در پیش‌بینی حملات با مجموعه داده‌های CICIDS 2017 عالی بود و نرخ ازدست‌دادن ۰.۰۱۰۲ است.

در [۳۹] یک سامانه تشخیص نفوذ بر پایه یادگیری عمیق با رویکرد هوش مصنوعی برای تشخیص حمله نفوذ

در شبکه اینترنت اشیا ارائه شده است. در این مطالعه تکنیک بهینه سازی سلسله مراتب شرکتی^۱ برای انتخاب ویژگی های مهم از پایگاه های داده استفاده می شود. راه حل پیشنهادی مبتنی بر بهینه سازی عقاب طلایی سیستم فازی چندلایه پرسپترون رابط فازی حریم خصوصی و امنیت را در زیرساخت شبکه حرفه ای بهبود می بخشد. آن ها روش خود را روی دو مجموعه داده NSL-KDD و UNSW-NB15 اجرا و بررسی کرده اند و نتایج نشان داده است که دقت آن از الگوریتم ژنتیک و الگوریتم ذرات در تشخیص نفوذ بیشتر است.

(جدول ۱-): مرور کارهای مرتبط با تشخیص حملات

(Table-1): A Review of Related Works on Attack Detection

معایب	مزایا	روش	پژوهش
عدم آزمون روی داده های دنیای واقعی و جدی	بهبود سرعت طبقه بندی دقت بالا کاهش نرخ خطای منفی کاذب (FN) و مثبت کاذب (FP)	الگوریتم بهبود یافته گرگ خاکستری همراه با انتخاب ویژگی و Random Fores	[28]
مدل پیچیده	کاهش ابعاد داده ورودی اندک دقت بالا	ترکیبی از الگوریتم PCA + شبکه عصبی پیچشی (CNN) + یادگیری عمیق	[29]
افزایش زمان سربار انتخاب ویژگی	از روش های بهینه سازی ذرات و کلونی زنبور عسل دقیق تر است	ترکیب الگوریتم بهینه ساز پرندگان و گوریل	[30]
عدم انتخاب ویژگی هوشمندانه	هشتاد درصد از ویژگی های اضافی را حذف می کند	تقویتی و انتخاب ویژگی بر انتخاب ویژگی عمیق یادگیری تقویتی	[31]
عدم متعادل سازی مجموعه داده	دقت بالا	مدل گیری عمیق انباشته: LSTM	[32]
عدم انتخاب ویژگی هوشمندانه	متعادل سازی مجموعه داده و افزایش دقت یادگیری	نمونه گیری مجدد داده ها با یادگیری عمیق	[33]
پیچیدگی مدل قابل توجه است	دقت بالا	مدل هایی مانند LSTM, GRU, RNN	[34]
عدم تعادل مجموعه داده و عدم کاهش ابعاد ورودی بدون انتخاب ویژگی هوشمندانه	دقت بیشتر از CNN	شبکه عصبی پیچیده عمیق	[35]
عدم بهینه سازی پارامترها	دقت تشخیص ۹۶ درصد و دقت ۹۸.۴ درصد	تشخیص نفوذ خودکار مبتنی بر SDN با یادگیری عمیق	[36]
عدم تشخیص حملات در زمان واقعی	دقت GRU و LSTM در تشخیص حملات ترکیبی	تشخیص حملات مبتنی بر یادگیری عمیق با پایه GRU, LSTM	[37]
متعادل سازی به روش SMOTE ضعیف است	نرخ از دست دادن اندک در حدود ۰.۰۱۰۲ است	متعادل سازی ترافیک شبکه با روش SMOTE	[38]
قطعیت کم در روش های فازی	دقت بیشتر از الگوریتم GA, PSO	تکنیک بهینه سازی سلسله مراتب شرکتی و یادگیری عمیق فازی	[39]
عدم تعادل ویژگی در مجموعه داده	دقت مدل پیش بینی ۹۸.۷۶ درصد	یادگیری عمیق با استفاده از استراتژی بهینه سازی آشفته	[40]

^۱ Corporate Hierarchy optimization (CHO)

در [۴۰] یک سامانه تشخیص نفوذ شبکه مبتنی بر یادگیری عمیق با استفاده از استراتژی بهینه سازی آشفته^۲ ارائه شده است. پس از پیش پردازش، مجموعه داده های نامتعادل با استفاده از رویکرد نمونه گیری مصنوعی توسعه یافته متعادل می شوند و پس از متعادل سازی، ویژگی های مجموعه داده با استفاده از تجزیه و تحلیل مؤلفه اصلی به کمک هسته برداشته می شوند. ویژگی های بهینه به وسیله الگوریتم بهینه سازی انتخاب می شوند؛ پس از استخراج همه ویژگی های مورد نیاز، حملات به وسیله مدل Dugat-LSTM طبقه بندی می شوند. در این پژوهش از مجموعه داده TON-IOT برای ارزیابی استفاده می شود. نتایج آزمایش ها نشان می دهد که مدل پیشنهادی در مجموعه داده TON-IOT به دقت ۹۸.۷۶ درصد دست یافته است. در جدول (۱)، کارهای مرتبط با تشخیص حملات با مزایا و معایب آن ها بررسی شده است.

بررسی کارهای مرتبط در زمینه تشخیص نفوذ به شبکه

نشان می دهد که این روش ها از چالش های زیر رنج می برند:

- در برخی از سامانه های تشخیص نفوذ از سازوکار امضا و فهرست سیاه استفاده شده است، اما این روش ها به حافظه زیادی نیاز دارند و از طرفی زمان جست و جو در آن ها قابل توجه است و توانایی تشخیص حملات جدید را ندارند.

- روش های اکتشافی یکی دیگر از روش های توسعه سامانه های تشخیص نفوذ است، اما این روش فاقد سازوکار یادگیری و تشخیص حملات پیچیده است و از طرفی کیفیت تشخیص حملات به کیفیت تابع اکتشافی بستگی دارد.

- روش های یادگیری ماشین و یادگیری عمیق توانایی تشخیص حملات پیچیده را دارند، اما این روش ها تعادل در مجموعه داده، انتخاب ویژگی و بهینه سازی پارامترهای مدل های یادگیری را ندارند.

برای تشخیص نفوذ دقیق در این مقاله و رفع این چالش ها یک سامانه تلفیقی هوش گروهی و یادگیری ماشین ارائه می شود. برای رفع چالش عدم تعادل در مجموعه داده های تشخیص نفوذ از تئوری بازی و شبکه عصبی GAN استفاده می شود و در مرحله بعدی برای کاهش ابعاد ترافیک و انتخاب ویژگی از الگوریتم دودویی شده اره ماهی استفاده می شود. در مرحله سوم از ماشین بردار پشتیبان برای تشخیص و طبقه بندی ترافیک شبکه استفاده شده و پارامترهای ماشین بردار پشتیبان را می توان با الگوریتم های جدید مانند بهینه سازی محاسبات ریاضی^۳ [۴۱] بهبود داد. دلیل استفاده از الگوریتم AOA

^۲ Chaotic Honey Badger

^۳ Archimedes optimization algorithm


عادی باشد. هدف از متعادل سازی آن است که خطای طبقه بندی مدل یادگیری یا SVM کاهش داده شود.

(۳) ترافیک شبکه در گره های مه به دو دسته آموزشی و آزمون تقسیم شده و از ترافیک آموزشی برای آموزش روش پیشنهادی استفاده می شود و برای ارزیابی از روش ارزیابی متقاطع با $kfold=10$ استفاده می شود.

(۴) هر گره مه با استفاده از الگوریتم ارمه ماهی انتخاب ویژگی کرده و ویژگی های مهم را انتخاب کرده و از آن ها به عنوان ورودی های SVM استفاده می شوند.

(۵) ماشین بردار پشتیبان با بردار ویژگی بهینه ترافیک شبکه آموزش داده می شود و سپس خطای آن با استفاده از داده های آزمون ارزیابی قرار می شود. در این مرحله برای کاهش خطای بیشتر مدل SVM از الگوریتم AOA به عنوان یک روش فراابتکاری بر پایه عملیات ریاضی استفاده می شود. هدف آن است که پارامترهای مانند نرخ خطا و جریمه در SVM با روش فراابتکاری AOA بهینه سازی شود.

روش پیشنهادی یک سامانه تشخیص نفوذ در معماری توزیع شده مه محاسباتی است و برای تشخیص حملات به شبکه دارای چهار مرحله اصلی زیر است:



(شکل-۷): مراحل تشخیص حملات در شهرهای هوشمند
(Figure-7): Steps to detect attacks in smart cities

- متعادل سازی مجموعه داده با روش GAN
- انتخاب ویژگی در گره های مه با استفاده از الگوریتم ارمه

آن است که پیچیدگی بالایی ندارد و اگر برای بهینه سازی پارامترهای SVM استفاده شود آنگاه زمان یادگیری آن را افزایش قابل توجه نمی دهد. دلیل استفاده از الگوریتم بهینه سازی ارمه ماهی در مرحله انتخاب ویژگی به شرح زیر خلاصه می شود:

- مسئله انتخاب ویژگی بر خلاف بهینه سازی پارامترهای SVM یک مسئله با ابعاد بسیار بیشتر است و از این جهت نیاز به الگوریتم های هوشمندتر به ویژه با رویکرد هوش گروهی دارد.
- الگوریتم بهینه سازی ارمه ماهی با تقسیم جمعیت راه حل ها به دو دسته ارمه ماهی و ساردین می تواند بین جست و جوی اکتشافی یا سراسری و جست و جوی بهره برداری یا محلی توازن ایجاد کند.
- الگوریتم ارمه ماهی از الگوریتم های فراابتکاری رایج مانند بهینه سازی ذرات، الگوریتم خفاش و کرم شب تاب دارای دقت بیشتری برای یافتن جواب بهینه است.

۳- روش پیشنهادی

روش پیشنهادی برای تشخیص حملات به شبکه یک سامانه تشخیص نفوذ بر پایه تئوری بازی، یادگیری عمیق، هوش گروهی و یادگیری ماشین است. در روش پیشنهادی چند مرحله اصلی زیر برای تشخیص ارائه می شود که به شرح زیر است:

- متعادل سازی ترافیک شبکه با استفاده از تئوری بازی و یادگیری عمیق مبتنی شبکه GAN
 - ارائه یک نسخه دودویی و انتخاب ویژگی از الگوریتم ارمه ماهی
 - بهینه سازی پارامترهای SVM با استفاده از الگوریتم AOA
 - یادگیری سامانه تشخیص نفوذ و ارزیابی آن با نمونه های آزمون
- در این بخش روش پیشنهادی برای تشخیص حملات به شبکه ارائه و معرفی می شود و در ابتدا چهارچوب روش پیشنهادی ارائه می شود و در ادامه تلاش می شود تا روابط و معادلات مرتبط توضیح داده شود.

۳-۱- مراحل روش پیشنهادی


مراحل روش پیشنهادی برای تشخیص حملات به اینترنت اشیا و شهر هوشمند مطابق شکل (۶)، نمایش داده شده است که به شرح زیر است:

(۱) ترافیک شبکه در لایه ادراک و حس گر تولید شده و این ترافیک برای گره های مه ارسال می شود. در روش پیشنهادی هر گره مه نقش یک سامانه تشخیص نفوذ به شبکه را بر عهده دارد.

(۲) برای متعادل سازی مجموعه داده از تئوری بازی و شبکه عصبی یادگیری عمیق GAN استفاده می شود و هدف آن است که تعداد نمونه های حمله برابر تعداد نمونه

- بهینه‌سازی پارامترهای SVM با الگوریتم فراابتکاری AOA
- یادگیری ماشین بردار پشتیبان بر اساس ویژگی‌های

مهم انتخاب شده



(شکل-۸): چهارچوب روش پیشنهادی برای تشخیص حملات
(Figure-8): Framework of the proposed method for detecting attacks

۳-۲- چهارچوب روش پیشنهادی


چهارچوب روش پیشنهادی در شکل (۸) برای تشخیص حملات نمایش داده شده است و مراحل آن به شرح زیر است:

- (۱) در ابتدا مجموعه‌ای از ترافیک شبکه به عنوان ورودی و مجموعه داده در نظر گرفته می‌شود.
- (۲) ترافیک شبکه با استفاده از تئوری بازی و روش GAN متعادل‌سازی می‌شود.
- (۳) ترافیک شبکه پیش‌پردازش و نرمال‌سازی می‌شود تا بتوان از ترافیک و نمونه‌های آن برای آموزش و یادگیری استفاده کرد.
- (۴) یک بردار ویژگی از ویژگی‌های ترافیک شبکه در نظر گرفته شده و این بردار ویژگی به عنوان یک عضو الگوریتم ارم‌ماهی کدگذاری می‌شود.

- (۵) در تکرار نخست تعدادی بردار ویژگی تصادفی تعیین شده و هر کدام از این بردارهای دودویی یک عضو الگوریتم ارم‌ماهی است.
- (۶) هر بردار ویژگی و الگوی آن روی مجموعه داده نفوذ به شبکه اعمال شده و مجموعه داده دچار کاهش ابعاد می‌شود.
- (۷) شبکه عصبی مصنوعی به وسیله هر کدام از بردارهای ویژگی آموزش داده می‌شود.
- (۸) خطای طبقه‌بندی ترافیک شبکه در مرحله آموزش و تعداد ویژگی انتخاب شده در هر بردار ویژگی اگر کمینه‌تر باشد آن بردار ویژگی بهینه‌تر است.
- (۹) اگر خطای تشخیص حملات و نفوذ به شبکه کمینه و مطلوب نباشد مراحل بالا مجدد تکرار می‌شود تا بردارهای ویژگی به‌روزرسانی شوند.
- (۱۰) اگر خطای تشخیص حملات و نفوذ به شبکه مطلوب باشد آنگاه هر گره مه از بردار ویژگی بهینه در تکرار آخر برای کاهش دادن ورودی ماشین بردار پشتیبان در تشخیص حملات به شبکه استفاده می‌کند.
- (۱۱) پارامترهای SVM با استفاده از الگوریتم AOA بهینه‌سازی می‌شود.
- (۱۲) مدل SVM بهبودیافته با استفاده از بردار ویژگی بهینه آموزش و برای تشخیص حملات به کار گرفته می‌شود.

۳-۳- متعادل‌سازی مجموعه داده


عدم تعادل در یک مجموعه داده زمانی اتفاق می‌افتد که تعداد نمونه‌های یک طبقه مانند طبقه حملات از طبقه عادی کمتر باشد. عدم تعادل مجموعه داده باعث می‌شود تا دقت مدل‌های یادگیری عمیق و ماشین کاهش داده شود. یک روش برای متعادل‌سازی مجموعه داده تشخیص نفوذ که تعداد نمونه‌های حملات آن در کمترین حد است ایجاد نمونه‌های مصنوعی بر اساس نمونه‌های واقعی و اضافه کردن آن‌ها به مجموعه داده است. برای متعادل‌سازی می‌توان از تئوری بازی مبتنی بر یادگیری GAN^۱ مطابق شکل (۹) استفاده کرد [۴۲].



(شکل-۹): عملکرد روش GAN در تولید نمونه‌های مصنوعی برای متعادل‌سازی مجموعه داده [۴۲]
(Figure-9): The performance of the GAN technique in generating synthetic samples for the balancing of the dataset [42]

^۱ Generative adversarial network (GAN)

شایسته در نظر گرفت و اره ماهی ها را می توان جواب های غیر شایسته فرض کرد؛ اره ماهی ان برای یافتن غذا به سمت ساردین ها حمله می کنند و در مرتبه نخست سعی می کنند یک ماهی را زخمی کنند؛ سپس ماهی زخمی را مورد حمله و شکار قرار دهند. رفتار این الگوریتم را می توان در شکل (۱۰) مشاهده کرد.



(شکل ۱۰): حمله اره ماهی ان به سمت ساردین ها [۱۵]
(Figure-10): Sawfish attack towards sardines [15]

در این مسئله هر بردار ویژگی یک ساردین یا اره ماهی است و از طرفی نصف جمعیت بردارهای ویژگی اره ماهی و نصف دیگر ساردین هستند. در این الگوریتم مشاهده می شود که ساردین ها از دست اره ماهی ان فرار کرده و نوعی جست و جوی سراسری یا اکتشافی را انجام می دهند و در مقابل حمله اره ماهی ان به سمت طعمه یا ساردین زخمی نوعی جست و جوی محلی است. علت استفاده از الگوریتم اره ماهی در انتخاب ویژگی به شرح زیر است:

در ابتدا تعدادی بردار ویژگی به صورت اعضای الگوریتم بهینه سازی اره ماهی به عنوان یک الگوریتم فرا ابتکاری مبتنی بر رفتار گروهی و دسته جمعی اره ماهی ان و ساردین ها در نظر گرفته شده و در اینجا یک بردار ویژگی نظیر $F_1^i, F_2^i, \dots, F_k^i$ نشان دهنده عضو i الگوریتم اره ماهی است و در اینجا k برابر تعداد ویژگی های ممکن در مجموعه داده است. می توان یک جمعیت اولیه از بردارهای ویژگی که مقدار آن ها صفر و یک است به عنوان اره ماهی و ساردین در نظر گرفت که در رابطه های (۱) و (۲) به ترتیب بردارهای اره ماهی و ساردین نمایش داده شده است:

$$SF = \begin{bmatrix} SF_{1,1} & SF_{12} & \dots & SF_{1,k} \\ SF_{2,1} & SF_{22} & \dots & SF_{2,k} \\ \vdots & \vdots & \ddots & \vdots \\ SF_{m,1} & SF_{m,2} & \dots & SF_{m,k} \end{bmatrix} \quad (1)$$

در این رابطه SF جمعیت اولیه از بردارهای ویژگی از نوع اره ماهی و به تعداد m است که هر کدام از آن ها دارای k ویژگی است. در رابطه (۲) نیز بردارهای ویژگی از نوع

GAN یک مدل یادگیری بدون نظارت مبتنی بر یادگیری عمیق است که داده های جعلی شبیه به داده های واقعی را با قراردادن یک شبکه عصبی (مولد، G) در مقابل دیگری (تمایزگر، D) تولید می کند. G با هدف تولید داده های جعلی شبیه داده های واقعی آموزش داده می شود، در حالی که D برای تعیین اینکه داده های ایجاد شده به وسیله G در واقع جعلی اند آموزش داده می شود؛ به عبارت دیگر، G و D به روش خصمانه یاد می گیرند. شکل (۹)، ساختار GAN را نشان می دهد و نحوه یادگیری G و D را توضیح می دهد. ابتدا زمانی که G یک بردار نوفه تصادفی را به عنوان ورودی دریافت می کند، داده ها تولید می شوند. هنگامی که داده های تولید شده و واقعی در اختیار D قرار می گیرد، واقعی یا جعلی بودن آن ها را مشخص می کند. G و D برای این نتیجه رقابت می کنند و از آن درس می گیرند؛ به عبارت دیگر، هدف G به حداکثر رساندن احتمالی است که D داده های تولید شده را واقعی تعیین می کند؛ در حالی که هدف D این است که احتمال تشخیص داده های تولید شده را به عنوان جعلی به بیشترین حد برساند. معادله (۱) تابع هدف GAN را برای این فرایند یادگیری نشان می دهد:

(۱)

$$\min_G \max_D V(D, G) = E_{x \sim p_{data}(x)} [\log D(x)] + E_{z \sim p_z(z)} [\log (1 - D(G(z)))].$$

در معادله $p_z(z)$ و $p_{data}(x)$ به ترتیب به داده های واقعی و جعلی اشاره دارند. D داده x را به عنوان مقدار ورودی داده واقعی دریافت می کند و احتمال واقعی بودن داده را خروجی می دهد، $D(x)$. G یک بردار نوفه تصادفی z را به عنوان مقدار ورودی می گیرد و داده های جعلی تولید می کند (z). از آنجایی که هدف D تشخیص مؤثر بین داده های جعلی تولید شده و داده های واقعی است، GAN باید یاد بگیرد که $D(x)$ برابر یک و $D(G(z))$ برابر صفر باشد. از آنجایی که هدف D تشخیص مؤثر بین داده های جعلی تولید شده و داده های واقعی است GAN باید یاد بگیرد که $D(x)$ برابر یک و $D(G(z))$ برابر صفر باشد. به عبارت دیگر، تابع هدف معادله به حداکثر رساندن از منظر D و کمینه سازی از دیدگاه G است.

۳-۴- انتخاب ویژگی پیشنهادی

الگوریتم اره ماهی از رفتار اره ماهی ان و شکار ساردین ها الگوبرداری شده است. در این الگوریتم راه حل های مسئله می توانند ساردین یا اره ماهی باشند. در الگوریتم نصف جمعیت به صورت ساردین است و نصف دیگر راه حل ها به صورت اره ماهی است. ساردین ها را می توان جواب های

ساردین نمایش داده شده است و به طور معمول نصف جمعیت از این نوع بردارهای ویژگی است و تعداد این نوع بردارهای ویژگی برابر n عدد است:

$$S = \begin{bmatrix} S_{1,1} & S_{12} & \dots & S_{1,k} \\ S_{2,1} & S_{22} & \dots & S_{2,k} \\ \vdots & \vdots & \ddots & \vdots \\ S_{n,1} & S_{n,2} & \dots & S_{n,k} \end{bmatrix} \quad (2)$$

برای ارزیابی بردارهای ویژگی از نوع ارهمای یا ساردین نیاز به یک تابع هدف مناسب است که این تابع در رابطه (۳)، ارائه شده است:

$$CostFS = \alpha \cdot \gamma_R(D) + \beta \frac{|R|}{|N|} \quad (3)$$

یک بردار ویژگی نیاز به ارزیابی دقیق دارد تا مشخص شود که تا چه اندازه شایستگی دارد. برای ارزیابی بردارهای ویژگی دو شاخص مهم زیر در نظر گرفته می شود:

- یک بردار ویژگی زمانی شایستگی دارد که خطای تشخیص حملات توسط آن کمینه باشد. به عبارت بهتر هر بردار ویژگی که بتواند ورودی های SVM را به گونه ای کاهش ابعاد دهد که خطای طبقه بندی ترافیک عادی و نرمال توسط آن کمینه شود دارای شایستگی بیشتری است.
- یک بردار ویژگی هر چقدر باعث شود که فضای ویژگی دچار کاهش ابعاد شود و ورودی های SVM را بیشتر کاهش دهد آنگاه شایستگی بیشتری دارد.

می توان مطابق [۴۳] خطای تشخیص حملات و کاهش ابعاد را هم زمان برای ارزیابی بردار ویژگی در نظر گرفت و به ضرایبی وزنی بین صفر و یک آن ها را به عنوان یک تابع هدف ارائه داد. برای سنجش خطای تشخیص حملات به وسیله یک بردار ویژگی مانند FS_i می توان از یک طبقه بندی کننده ساده مانند شبکه عصبی مصنوعی چندلایه استفاده کرد؛ در این حالت بردار ویژگی FS_i روی مجموعه داده نگاشت داده می شود به گونه ای که اگر مؤلفه i ام بردار ویژگی FS_i دارای مقدار یک است از ویژگی i ام به عنوان ورودی شبکه عصبی استفاده می شود. فرض کنید بردار ویژگی FS_i دارای $|FS_i|$ ویژگی باشد که انتخاب شده اند (مقدار این ویژگی ها در بردار ویژگی برابر یک است)؛ از این جهت تعداد ورودی های شبکه عصبی برای این بردار ویژگی برابر $|FS_i|$ خواهد بود. برای ارزیابی بردارهای ویژگی از نوع ارهمای یا ساردین نیاز به یک تابع هدف مناسب است که این تابع در رابطه (۴) ارائه شده است [۴۳]:

$$Cost(FS_i) = \alpha \cdot E(FS_i) + \beta \frac{|FS_i|}{|Dim|} \quad (4)$$

در این رابطه $E(FS_i)$ خطای طبقه بندی ترافیک حملات از ترافیک عادی به وسیله بردار ویژگی FS_i است. $|FS_i|$ نیز برابر تعداد ویژگی های انتخاب شده در بردار ویژگی است که اندازه آن برابر $|Dim|$ است و همچنین α یک عدد تصادفی است که مقدار آن بین صفر و یک است و $\beta = 1 - \alpha$ در نظر گرفته می شود. ضرایب وزنی باعث می شود تا overfitting در مرحله انتخاب ویژگی تا حد زیادی تعدیل شود؛ از طرفی متعادل سازی مجموعه داده با روش GAN آن این چالش را در روش پیشنهادی کم رنگ می کند.

هر بردار ویژگی که این تابع را کمینه کند اگر از نوع ساردین باشد به عنوان ساردین زخمی و اگر از نوع ارهمای باشد آنگاه به عنوان بهینه ترین ارهمای برای حمله به دسته ماهیان ساردین در نظر گرفته می شود. می توان بردارهای ارهمای و ساردین که همگی از نوع بردارهای ویژگی اند را با این تابع هدف ارزیابی کرد و مقدار ارزیابی آن ها را در رابطه های (۵) و (۶) نمایش داد:

$$SF_{fitness} = \begin{bmatrix} CostFS(SF_{1,1}) & SF_{12} & \dots & SF_{1,k} \\ CostFS(SF_{2,1}) & SF_{22} & \dots & SF_{2,k} \\ \vdots & \vdots & \ddots & \vdots \\ CostFS(SF_{m,1}) & SF_{m,2} & \dots & SF_{m,k} \end{bmatrix} \quad (5)$$

$$= \begin{bmatrix} F_{SF_1} \\ F_{SF_2} \\ \vdots \\ F_{SF_m} \end{bmatrix} \quad (6)$$

در روش پیشنهادی، بردار ویژگی از نوع ساردین که بهینه ترین بردار ویژگی از نوع ساردین هاست و بهینه ترین بردار ویژگی ارهمای آن می تواند برای انتخاب مکان حمله بردارهای ویژگی از نوع ارهمای و به مانند رابطه (۷) در نظر گرفته شود:

$$F_{newSF}^i = F_{eliteSF}^i - \lambda_i \left(rand(0,1) \cdot \left(\frac{F_{eliteSF}^i + F_{injuredS}^i}{2} - F_{oldSF}^i \right) \right) \quad (7)$$

در این رابطه، F_{newSF}^i بردار ویژگی به روز شده یک ارهمای، $F_{eliteSF}^i$ بردار ویژگی بهینه ترین ارهمای، $F_{injuredS}^i$ بهینه ترین بردار ویژگی از نوع ساردین، F_{oldSF}^i موقعیت قبلی یک بردار ویژگی از نوع ارهمای،

ممکن است این مقادیر را از حالت دودویی خارج کنند، توابع V و S برای نرمال سازی و بازگرداندن آن ها به بازه $[0,1]$ به کار می روند که بردارهای ویژگی از حالت صفر و یک خارج شوند و مقادیری غیر از صفر یا یک داشته باشند؛ برای مثال عدد هشت در یک بردار ویژگی بی معنی است؛ لذا باید نخست عدد هشت را به بازه $[0,1]$ نرمالیزه کرد و سپس آن را به عدد 0.4 نرمال شود؛ چون به صفر نزدیک تر است می توان آن را صفر در نظر گرفت (ویژگی انتخاب نشده است) و اگر عدد هشت به 0.7 نرمالیزه شود می توان آن را به یک تبدیل کرد (ویژگی انتخاب شده)؛ زیرا 0.7 به یک نزدیک تر است تا صفر. بعد از نرمال سازی مقادیر بردارهای ویژگی با استفاده از توابع انتقالی S و V می توان با اعمال آستانه 0.5 و بر اساس روابط (۱۰) و (۱۱)، مقادیر هر عنصر در بردار را دوباره به حالت صفر یا یک تبدیل کرد [۱۶]:

$$X_i^j(t+1) = \begin{cases} 0 & \text{rand} < T(X_i^j(t+1)) \\ 1 & \text{otherwise} \end{cases} \quad (10)$$

$$X_i^j(t+1) = \begin{cases} \neg X_i^j(t) & \text{rand} < T(X_i^j(t+1)) \\ X_i^j(t) & \text{otherwise} \end{cases}$$

در اینجا، تابع نگاشت و تبدیل می تواند از نوع S یا V باشد و FS_i یک بردار ویژگی است.

۵-۳- طبقه بندی با ماشین بردار پشتیبان

روش ماشین بردار پشتیبان نیز یک روش یادگیری ماشین است که برای طبقه بندی استفاده می شود. در این روش برای یادگیری یک خط جداکننده باید به گونه ای بین دو طبقه داده ها قرار داده شود که کمترین خطا در طبقه بندی به وجود آید. در شکل (۱۱) در این روش خط C به عنوان خط طبقه بندی کننده به کار گرفته می شود و خط A و B نیز ناحیه و مرز این خط را نشان می دهند و هدف آن است که عرض نوار بیشینه شود و به شرط این که تعداد کمتری از نمونه ها به اشتباه در دو طبقه قرار داده شوند.

در شکل (۱۲) در این روش خط C به عنوان خط طبقه بندی کننده به کار گرفته می شود و خط A و B نیز ناحیه و مرز این خط را نشان می دهند و هدف آن است که عرض نوار بیشینه شود، به شرط این که تعداد کمتری از نمونه ها به اشتباه در دو طبقه قرار داده شوند.

$rand(0,1)$ عدد تصادفی یک نواخت بین صفر و یک، λ_i ضریب هم گرایی در تکرار i -ام است که مرتب کاهش خواهد یافت. هر بردار ویژگی از نوع ساردین نیز می تواند تحت تأثیر فرار به روزرسانی شود و برای این منظور از رابطه (۸) استفاده می شود:


(۸)

$$F_{new_S}^i = rand(0,1) \cdot (F_{elite_SF}^i - F_{old_S}^i + AP)$$

در این رابطه $F_{old_S}^i$ و $F_{new_S}^i$ به ترتیب موقعیت جدید یک بردار ویژگی از نوع ساردین و موقعیت پیشین آن بردار ویژگی برای تشخیص حملات به اینترنت اشیا است. در این رابطه، AP را توان حمله اره ماهی آن می گویند که می توان آن را از رابطه (۹) محاسبه کرد:

$$AP = A \cdot (1 - 2 \cdot Itr \cdot \epsilon) \quad (9)$$

A و ϵ پارامترهای ثابت و اولیه توان حمله برای به روزرسانی بردارهای ویژگی از نوع ساردین در نظر گرفته می شوند. هر بردار ویژگی از نوع ساردین یا اره ماهی به ترتیب تحت تأثیر مکانیزم فرار و حمله به روزرسانی شده و موقعیت آن ها دچار تغییر می شود، اما این تغییرات می تواند این بردارهای ویژگی را از حالت دودویی خارج و آن ها را تبدیل به فضای پیوسته که به کمک توابع تبدیل یا انتقال، بردارهای ویژگی را مجدد دودویی و صفر و یک کند. در شکل (۱۱)، دو تابع کاربردی نوع V و S که برای تبدیل فضای ویژگی به کار گرفته می شوند نمایش داده شده است.



(شکل ۱۱): به ترتیب از راست به چپ، توابع تبدیل انتخاب

ویژگی از نوع V و S [۱۶]

(Figure-11): right to the left, the transformation functions of feature selection from type of V and S [16]

این دو تابع در واقع دارای بردی محدود به بازه 0 و 1 است و می تواند اعداد پیوسته بردارهای ویژگی را به این بازه نگاشت دهند. نقش تابع S و V آن است که مقادیر بردارهای ویژگی بعد از به روزرسانی به وسیله الگوریتم ماهی در بازه صفر تا یک نرمالیزه شوند؛ به عبارت بهتر بردارهای ویژگی در الگوریتم اره ماهی شامل مقادیر دودویی صفر و یک هستند که به ترتیب نشان دهنده عدم انتخاب و انتخاب ویژگی اند؛ از آن جا که به روزرسانی ها

$$(w \times \Phi(xi)) \geq \rho - \xi_{ii} = 1, 2, \dots, l \xi_i \geq 0$$

اگر w و ρ در این مسئله حل شوند، تابع تصمیم‌گیری به صورت معادله (۱۶) ارائه می‌شود:

$$f(x) = \text{sign}((w \times \Phi(x)) - \rho) \quad (16)$$

برای بهبود عملکرد ماشین بردار پشتیبان می‌توان پارامترهای آن مانند نرخ خطا و ضریب جریمه را به عنوان یک عضو جمعیت الگوریتم فراابتکاری در نظر گرفت و سپس در ادامه با این الگوریتم فراابتکاری، پارامترهای SVM را بهینه‌سازی کرد. برای حل این مسئله از الگوریتم AOA استفاده می‌شود که بر اساس چهار عمل‌گر ضرب، تقسیم، جمع و ضرب به دنبال بهینه‌سازی جواب‌ها و پارامترهای SVM است. در الگوریتم AOA در هر تکرار پارامترهای MOA و MOP به ترتیب مانند معادله (۱۷) و (۱۸) به‌روزرسانی شوند:

$$MOA(C_Iter) = Min + C_Iter \times \left(\frac{Max - Min}{M_Iter} \right) \quad (17)$$

$$(18)$$

$$MOP(C_Iter) = 1 - \frac{C_Iter^{\frac{1}{\alpha}}}{M_Iter^{\frac{1}{\alpha}}}$$

Max و Min به ترتیب بیشینه و کمینه پارامترهای MOA و MOP است. C_Iter شمارنده تکرار الگوریتم AOA است و M_Iter بیشترین تکرار این الگوریتم است. ضریب MOP بر حسب پارامتر α تعیین و ضریب α در حدود پنج تنظیم می‌شود. برای انجام جست‌وجوی اکتشافی از معادله (۱۹) استفاده می‌شود. یک عدد تصادفی بین صفر و یک برای هر راه‌حل تولید می‌شود و اگر این عدد تصادفی کمتر از ۰.۵ باشد از عمل‌گر تقسیم و در غیراین صورت از عمل‌گر ضرب برای به‌روزرسانی پارامترهای SVM استفاده می‌شود:


$$(19)$$

$$x_{i,j}(C_Iter + 1) = \begin{cases} best(x_j) \div (MOP + \epsilon) \times ((UB_j - LB_j) \times \mu + LB_j) & rand > 0.5 \\ best(x_j) \times MOP \times ((UB_j - LB_j) \times \mu + LB_j) & rand \leq 0.5 \end{cases}$$

$best(x_j)$ بهینه‌ترین راه‌حل یا بهینه‌ترین پارامترهای SVM است. UB_j و LB_j به ترتیب محدود بالا و پایین بعد j -ام یک مجموعه پارامتر SVM است. μ یک پارامتر ثابت عددی است. ϵ یک عدد بسیار کوچک برای جلوگیری از تقسیم بر صفر است. برای به‌روزرسانی پارامترهای SVM از معادله (۲۰)، استفاده می‌شود.

$$(20)$$

$$x_{i,j}(C_Iter + 1) = \begin{cases} best(x_j) - MOP \times ((UB_j - LB_j) \times \mu + LB_j) & rand > 0.5 \\ best(x_j) + MOP \times ((UB_j - LB_j) \times \mu + LB_j) & rand \leq 0.5 \end{cases}$$



(شکل-۱۲): روش طبقه‌بندی ماشین بردار پشتیبان [۲۶]
(Figure-12): Support vector machine classification technique [۲۶]

طبقه‌بندی‌کننده SVM نمونه‌ها را به یک فضای مشخصه ابعادی بزرگ (از طریق یک هسته) تبدیل و مکان مناسب ابرصفحه^۱ مرزی را تعیین که داده‌های آموزشی را تقسیم می‌کند. ایجاد ابرصفحه در SVM باید از قانون رابطه (۱۲) طبقه‌بندی پیروی کند:

$$f(x) = (W, x) + b \quad (12)$$

که در آن w بردار نرمال و b یک اصطلاح بایاس است. SVM ابرصفحه را برای یافتن یک طبقه‌بندی خطی با بهینه‌سازی قاعده f تنظیم می‌کند. این قانون طبقه‌بندی می‌تواند برای اختصاص یک برچسب به نمونه آزمایشی x استفاده شود. اگر نتیجه $f(x)$ کمتر از صفر باشد، به عنوان نفوذ طبقه‌بندی می‌شود، در غیر این صورت به عنوان نرمال طبقه‌بندی می‌شود. نتیجه $f(x)$ می‌تواند شرایط طبقه‌بندی را روشن کند به گونه‌ای که در طبقه نرمال مثبت و در طبقه نفوذ منفی در نظر گرفته می‌شود. سامانه تشخیص نفوذ SVM یک طبقه را می‌توان به صورت نگاشت داده‌ها در بردار ویژگی H با استفاده از یک تابع هسته مناسب بیان کرد؛ سپس تلاش می‌کند تا بردارهای نگاشت‌شده را از مبدأ با یک حاشیه مشخص جدا کند، رابطه (۱۳).

$$f(x) = \begin{cases} +1, & \text{if } x \in \text{Normal} \\ -1, & \text{if } x \in \text{Intrusion} \end{cases} \quad (13)$$

در مرحله دوم از یک طبقه SVM، فرض کنید x_1 $x_2, \dots, x_l$ نمونه‌های آموزشی متعلق به یک طبقه X باشند، که در آن X زیرمجموعه‌ای از مجموعه داده است. فرض کنید $\Phi: X \rightarrow H$ یک نقشه هسته باشد که نمونه‌های آموزشی را به فضای دیگری تبدیل می‌کند؛ سپس برای جداکردن مجموعه داده از مبدأ باید مسئله برنامه‌نویسی درجه دوم رابطه (۱۴) را حل کند:

$$(14)$$

$$\min \frac{1}{2} \|w\|^2 + \frac{1}{Vl} \sum_{i=1}^l \xi_i - p$$

$$(w \times \Phi(xi)) \geq \rho - \xi_{ii} = 1, 2, \dots, l \xi_i \geq 0$$

که شرایط آن در معادله (۱۵)، تعریف شده است.

$$(15)$$

^۱ Hyperplane

۴- تجزیه و تحلیل

در این بخش به تجزیه و تحلیل روش پیشنهادی برای تشخیص حملات پرداخته شده است و روش پیشنهادی مورد ارزیابی قرار می گیرد.

۴-۱- مجموعه داده

مجموعه داده NSL-KDD به عنوان یکی از بهترین مجموعه داده های مرتبط با تشخیص نفوذ به شبکه در نظر گرفته می شود. این مجموعه داده در ابتدا توسط استولفا^۱ و همکاران با آنالیز اطلاعات ردوبدل شده در شبکه نیروی هوایی آمریکا در یکی از پایگاه های آن گردآوری شده است. این مجموعه داده اعتبار بالایی برای سنجش دقت الگوریتم های تشخیص نفوذ به شبکه و اینترنت اشیا دارد؛ زیرا تنوعات گسترده ای را شامل می شود؛ در کل می توان گفت که مجموعه داده مورد نظر اعتبار و محبوبیت بالایی دارد و در بسیاری از پژوهش ها مورد استفاده قرار می گیرد. این مجموعه داده سه ویژگی ممتاز زیر را در خود نهفته دارد:

- تلفیقی از ترافیک عادی و مشکوک است که می توان با تجزیه و تحلیل ویژگی های آن الگوهای ترافیک شبکه را شناسایی و از آن برای طبقه بندی ترافیک شبکه استفاده کرد.
- در این مجموعه داده ترافیک مبتنی بر زمان در شبکه نیز مورد توجه قرار گرفته است؛ به گونه ای که در این مجموعه داده، داده ها به مرور زمان گردآوری شده اند و تنها مختص یک لحظه یا یک برش زمانی نیستند.
- در این مجموعه داده ترافیک مبتنی بر میزبان نیز مورد توجه قرار گرفته به این صورت که ترافیک شبکه تنها بر روی یک میزبان گردآوری نشده است؛ بلکه در میزبان های مختلف گردآوری شده است.

مجموعه داده تشخیص نفوذ به شبکه یا KDD، ۴۱ ویژگی مختلف و متنوع دارد که به درکل ۳۴ عدد از آن ها عددی و مابقی از نوع غیر عددی است. در این مجموعه داده مشاهده شده که سه نوع ویژگی کلی به کار گرفته شده که در زیر به آن ها اشاره شده است:

- ویژگی های اساسی^۲: این گروه از ویژگی ها در واقع تمام ویژگی هایی را که می تواند از یک ارتباط و ترافیک TCP-IP^۳ استخراج شوند شامل می شود. شناسایی این مجموعه ویژگی ها نیاز به زمان کمابیش طولانی دارد؛ زیرا برخی از این ویژگی ها به مرور زمان در شبکه تشخیص داده شده و گردآوری می شوند.

¹ Stolfo


² Basic features

³ Transmission Control Protocol-Internet Protocol

▪ ویژگی های محتوایی: حملات از نوع U2R و R2L برخلاف حملات نوع DOS و Prob فاقد هر گونه الگوی ترتیبی و منظم هستند؛ زیرا به این دلیل که حملات DOS و Prob در یک مقطع زمانی کوتاه شروع و بعد از مدتی به پایان می رسند و این در حالی است که حملات نوع U2R و R2L در بخش داده بسته ارسالی به شبکه جاسازی می شوند و به طور عادی تنها یک ترافیک را درگیر می کنند، اما حملات نوع DOS و Prob تعداد بیشتری ترافیک را شامل می شوند.

▪ ویژگی های ترافیکی: این ویژگی ها تنها ترافیک را در زمانی فعلی یا در یک بازه کوتاه مورد توجه قرار می دهند و به دو نوع ویژگی های ترافیک میزبان و ویژگی های ترافیک سرویس دسته بندی می شوند که به ترتیب ناظر بر ترافیک وارد شده به یک میزبان و یا یک سرویس عملیاتی اند.

در این مجموعه داده به طور کلی چهار نوع حمله تعریف شده و هر حمله نیز خود دارای تعداد زیادی زیرحمله است. در حملات نوع پوششی مهاجم اطلاعاتی را به کمک پوشش^۴ سرویس ها یا پورت های رایانه به دست می آورد و بر اساس این اطلاعات سعی می کند به شبکه نفوذ و در آن اختلال ایجاد کند. در این نوع از حملات مهاجم می تواند برای نفوذ به شبکه از روش های مهندسی اجتماعی^۵ نیز استفاده تا بتواند از اطلاعات افراد و کاربران درون شبکه برای نفوذ به شبکه استفاده کند. مطالعات مطابق شکل (۱۳)، نشان می دهد که در بین مجموعه داده های مختلف دو مجموعه داده KDD و NSL-KDD دارای بیشترین سهم در ارزیابی سامانه های تشخیص نفوذ به شبکه است. در شکل (۱۴)، چند رکورد از مجموعه داده NSL-KDD برای تشخیص حملات نمایش داده شده است و مشاهده می شود که ۴۱ ویژگی از نوع ورودی است و ویژگی آخر نیز می تواند حمله یا عادی بودن ترافیک را نشان دهد.



(شکل-۱۳): سهم مجموعه داده NSK-KDD در میان سایر مجموعه داده های تشخیص نفوذ [۲۲]
(Figure-13): Share of NSK-KDD dataset among other intrusion detection dataset[22]

⁴ Scan

⁵ Social engineering



(شکل-۱۴): ویژگی‌های مجموعه داده NSK-KDD در تشخیص حملات به شبکه [۲۳]
(Figure-14): Features of the NSK-KDD dataset in detecting network attacks[23]

۴-۳- آزمایش‌ها و بحث

در پیاده‌سازی‌ها هفتاد درصد از نمونه‌ها آموزشی و سی درصد از نمونه‌ها از نوع آزمون در نظر گرفته می‌شوند. اعتبارسنجی متقاطع روشی است که در یادگیری ماشین برای ارزیابی عملکرد یک مدل بر روی داده‌های دیده نشده استفاده می‌شود. این شامل تقسیم داده‌های موجود به چند زیرمجموعه، استفاده از یکی از این نمونه‌ها به عنوان مجموعه اعتبارسنجی و آموزش مدل بر روی نمونه‌های باقی‌مانده است؛ این فرایند چندین بار تکرار می‌شود و هر بار از یک fold متفاوت به عنوان مجموعه اعتبارسنجی استفاده می‌شود؛ در نهایت نتایج حاصل از هر مرحله اعتبارسنجی برای تولید تخمین قوی‌تری از عملکرد مدل میانگین می‌شود. اعتبارسنجی متقاطع مرحله مهمی در فرایند یادگیری ماشین است و به اطمینان از این‌که مدل انتخاب‌شده برای استقرار قوی است و به خوبی به داده‌های جدید تعمیم می‌یابد کمک می‌کند. در روش پیشنهادی از اعتبارسنجی متقاطع با $k=10$ استفاده می‌شود. تعداد رکوردهای به کاررفته برای ارزیابی آزمایش‌ها پنجاه هزار ترافیک تنظیم شده است که توسط روش GAN این مجموعه داده متعادل‌سازی شده و ۲۵ هزار نمونه از نوع حمله و ۲۵ هزار دیگر از نوع ترافیک عادی است. محدوده نرمال‌سازی شده در بازه $[0, 1]$ است و اندازه جمعیت و تعداد تکرار الگوریتم ارمه‌ماهی به ترتیب برابر بیست و پنجاه است. تعداد آزمایش‌ها برای محاسبه میانگین شاخص‌ها برابر سی آزمایش است. تعداد لایه‌های پنهان در شبکه عصبی برابر دو و تعداد نورون‌های هر لایه برابر ۴۱ عدد و این تعداد برابر تعداد ویژگی‌های اولیه مجموعه داده NSL-KDD است. برای طبقه‌بندی نهایی از ماشین بردار پشتیبان با کرنل خطی^۸، بازگشتی^۹، چند

^۸ Linear
^۹ RBF

۴-۲- شاخص‌های ارزیابی

برای ارزیابی سامانه تشخیص نفوذ پیشنهادی از شاخص‌های طبقه‌بندی مطرح مانند دقت^۱، حساسیت^۲ و صحت^۳ استفاده می‌شود که ضابطه آن‌ها به ترتیب در رابطه‌های (۲۱، ۲۲ و ۲۳) فرموله شده است. برای محاسبه این شاخص‌ها نیاز است که از شاخص‌های اولیه مثبت واقعی^۴، منفی واقعی^۵، مثبت کاذب^۶ و منفی کاذب^۷ استفاده شود:

(۲۱)

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN}$$

(۲۲)

$$Sensitivity = \frac{TP}{TP + FN}$$

(۲۳)

$$Precision = \frac{TP}{TP + FP}$$

در این معادلات TP نشان می‌دهد ترافیک از نوع حمله است و روش پیشنهادی به درستی آن را از نوع حمله تشخیص داده است. در اینجا TN نشان می‌دهد ترافیک نرمال و روش پیشنهادی آن را به درستی از نوع نرمال تشخیص داده است و FP نشان می‌دهد ترافیک به غلط حمله تشخیص داده شده و FN نیز نشان می‌دهد ترافیک به اشتباه نرمال تشخیص داده شده است.

^۱ Accuracy
^۲ Sensitivity
^۳ Precision
^۴ True positive (TP)
^۵ True negative (TN)
^۶ False positive (FP)
^۷ False negative (FN)

جمله‌ای^۱ و گوسین^۲ استفاده می‌شود. در جدول (۲)، متوسط شاخص‌های دقت، حساسیت و صحت روش پیشنهادی به‌ازای کرنل‌های مقایسه‌شده است. در نمودار شکل (۱۵)، شاخص دقت، حساسیت و صحت روش پیشنهادی به‌ازای کرنل‌های مختلف نمایش داده شده‌است. آزمایش‌ها در محیط برنامه‌نویسی متلب نشان می‌دهد، دقت، حساسیت و صحت روش پیشنهادی به‌ازای کرنل گوسین بیشترین مقدار ممکن است و دارای مقادیر ۹۹.۱۲ درصد، ۹۸.۹۲ درصد و ۹۸.۹۶ درصد است.

آزمایش‌ها نشان می‌دهد کمترین دقت، حساسیت و صحت روش پیشنهادی به‌ازای کرنل خطی است. اگر از ماشین بردار پشتیبان استفاده نشود و برای طبقه‌بندی از شبکه عصبی نیز استفاده شود، آن‌گاه شاخص دقت، حساسیت و صحت به‌ترتیب تا حدود ۹۸.۸۳ درصد، ۹۸.۲۴ درصد و ۹۸.۱۶ درصد کاهش خواهد یافت. علت آن‌که روش پیشنهادی به‌ازای کرنل گوسین بهتر عمل کرده و خطای تشخیص نفوذ را بیشتر کاهش داده آن است که مسئله تشخیص نفوذ یک مسئله پیچیده است و فضای ویژگی آن خطی نیست؛ لذا برای طبقه‌بندی و تشخیص نفوذ در کرنل گوسین که غیرخطی است، بهتر جواب می‌دهد. برای آزمایش‌ها و مقایسه‌ها می‌توان نتایج پژوهش را با مطالعه در پژوهش [۲۴] که سال ۲۰۲۱ انجام شده‌است، مورد ارزیابی قرار داد. در نمودار شکل (۱۶)، روش پیشنهادی در تشخیص حملات با درخت تصمیم‌گیری J48، جنگل تصادفی RF و شبکه عصبی چند لایه MLP مورد مقایسه قرار گرفته و ارزیابی شده‌است. ارزیابی‌ها نشان می‌دهد دقت روش پیشنهادی به‌دلیل انتخاب ویژگی دارای دقتی برابر ۹۹.۱۲ درصد است و این در حالی است که دقت روش درخت تصمیم‌گیری J48، جنگل تصادفی RF و شبکه عصبی چند لایه MLP به‌ترتیب برابر ۸۱.۰۵ درصد، ۸۰.۶۷ درصد و ۷۷.۴۱ درصد و روش پیشنهادی نسبت به این روش‌ها دارای دقت بیشتری است؛ به عبارت بهتر آزمایش‌ها نشان داد، ماشین بردار پشتیبان در ترکیب با اره‌ماهی نسبت به این روش‌ها در تشخیص حملات دقت بیشتری دارد.

برای ارزیابی منصفانه می‌توان روش پیشنهادی را با نتایج مطالعه [۲۵] که دارای سازوکار انتخاب ویژگی هستند، مطابق نمودار شکل (۱۷)، با هم مقایسه کرد.

آزمایش‌ها نشان می‌دهد کمترین دقت، حساسیت و صحت روش پیشنهادی به‌ازای کرنل خطی است. اگر از ماشین بردار پشتیبان استفاده نشود و برای طبقه‌بندی از شبکه عصبی نیز استفاده شود، آن‌گاه شاخص دقت،

حساسیت و صحت به‌ترتیب تا حدود ۹۸.۸۳ درصد، ۹۸.۲۴ درصد و ۹۸.۱۶ درصد کاهش خواهد یافت. علت آن‌که روش پیشنهادی به‌ازای کرنل گوسین بهتر عمل کرده و خطای تشخیص نفوذ را بیشتر کاهش داده آن است که مسئله تشخیص نفوذ یک مسئله پیچیده است و فضای ویژگی آن خطی نیست؛ لذا برای طبقه‌بندی و تشخیص نفوذ در کرنل گوسین که غیرخطی است، بهتر جواب می‌دهد. برای آزمایش‌ها و مقایسه‌ها می‌توان نتایج پژوهش را با مطالعه در پژوهش [۲۴] که سال ۲۰۲۱ انجام شده‌است مورد ارزیابی قرار داد. در نمودار شکل (۱۶)، روش پیشنهادی در تشخیص حملات با درخت تصمیم‌گیری J48، جنگل تصادفی RF و شبکه عصبی چند لایه MLP مورد مقایسه قرار گرفته و ارزیابی شده‌است. ارزیابی‌ها نشان می‌دهد دقت روش پیشنهادی به‌دلیل انتخاب ویژگی دارای دقتی برابر ۹۹.۱۲ درصد و این در حالی است که دقت روش درخت تصمیم‌گیری J48، جنگل تصادفی RF و شبکه عصبی چند لایه MLP به‌ترتیب برابر ۸۱.۰۵ درصد، ۸۰.۶۷ درصد و ۷۷.۴۱ درصد است و روش پیشنهادی نسبت به این روش‌ها دارای دقت بیشتری است؛ به عبارت بهتر آزمایش‌ها نشان داد ماشین بردار پشتیبان در ترکیب با اره‌ماهی نسبت به این روش‌ها در تشخیص حملات دقت بیشتری دارد.

برای ارزیابی منصفانه می‌توان روش پیشنهادی را با نتایج مطالعه [۲۵] که دارای سازوکار انتخاب ویژگی هستند مطابق نمودار شکل (۱۸)، با هم مقایسه کرد.


در این نمودار، روش پیشنهادی با روش‌های یادگیری عمیق مانند LSTM-RNN، LSTM، AE-CNN، GA-ELM، CNN-LSTM، ELM و ELM در شاخص دقت مقایسه شده‌است. آزمایش‌ها نشان می‌دهند دقت LSTM-RNN، LSTM، AE-ELM، CNN-LSTM، GA-ELM، LSTM، ELM برای تشخیص حملات به‌ترتیب برابر ۹۳.۹۹ درصد، ۹۴.۱۱ درصد، ۹۶.۹۳ درصد، ۹۸.۹۰ درصد، ۹۹.۷۰ درصد، ۹۸.۹۴ درصد است و دقت روش پیشنهادی با کرنل گوسین برای تشخیص حملات برابر ۹۹.۱۲ درصد است. علت آن‌که روش پیشنهادی نسبت به روش‌های یادگیری عمیق در تشخیص حملات دارای دقت بیشتری است آن است که روش پیشنهادی در مرحله نخست مجموعه‌داده را با روش GAN متعادل‌سازی کرده و این عامل دقت مدل SVM را افزایش می‌دهد و از طرفی با الگوریتم AOA پارامترهای SVM بهینه‌سازی شده و ورودی‌های SVM نیز با الگوریتم اره‌ماهی بهینه شده‌است تا یادگیری روی ویژگی‌های اساسی انجام شود که در شکل (۱۹) قابل مشاهده است.

¹ Polynomial


² Gaussian

(جدول-۲): شاخص دقت، حساسیت و صحت به ازای کرنل های مختلف
(Table -2): Accuracy, sensitivity and accuracy index for different kernels

نوع کرنل	دقت	حساسیت	صحت
خطی	۹۸.۳۳	۹۸.۱۲	۹۸.۰۸
بازگشتی	۹۸.۷۲	۹۸.۷۵	۹۷.۹۸
چند جمله ای	۹۸.۶۳	۹۸.۳۵	۹۸.۲۱
گوسین	۹۹.۱۲	۹۸.۹۲	۹۸.۹۶
SVM بدون	۹۸.۵۳	۹۸.۲۴	۹۸.۱۶



(شکل-۱۵): ارزیابی شاخص دقت، حساسیت و صحت روش پیشنهادی با کرنل های مختلف
(Figure-15): Evaluation of the index of accuracy, sensitivity and accuracy of the proposed method with different kernels




(شکل-۱۶): مقایسه دقت روش پیشنهادی با سه روش یادگیری ماشین
(Figure-16): Comparison of the accuracy of the proposed method with three machine learning methods




(شکل-۱۷): ارزیابی شاخص دقت، حساسیت و صحت روش پیشنهادی با کرنل‌های مختلف

(Figure-17): Evaluation of the index of accuracy, sensitivity and accuracy of the proposed method with different kernels



(شکل-۱۸): مقایسه دقت تشخیص حملات در روش پیشنهادی با روش‌های انتخاب ویژگی

(Figure-18): Comparison of attack detection accuracy in the proposed method with feature selection methods



(شکل-۱۹): مقایسه شاخص دقت روش پیشنهادی با چند روش یادگیری عمیق

(Figure-19): Comparison of the accuracy index of the proposed method with several deep learning methods

۵- نتیجه‌گیری و کارهای آینده

اینترنت اشیا در عصر مدرن ظهور و توسعه فناوری‌های فرایند کسب‌وکار جدید را از طریق شبکه‌ای از رایانه‌ها و دستگاه‌هایی که قادر به برقراری ارتباط و تعامل با یکدیگرند، ممکن کرده‌است. در آنجا که تعداد حملات سایبری به سامانه‌های اینترنت اشیا به سرعت و به‌طور گسترده افزایش می‌یابد، افراد و کسب‌وکارها با طیف گسترده‌ای از چالش‌های مرتبط با اعتبار، تأمین مالی و عملیات تجاری مواجه‌اند. حملات به شبکه اینترنت اشیا بسیار پیچیده شده‌است و می‌تواند سرویس‌های کاربردی شبکه را با اختلال مواجه سازد. در این شبکه، در بیشتر موارد تعداد زیادی شیء هوشمند به بدافزار آلوده می‌شود و هر کدام از آن‌ها علیه سرویس‌های شبکه اقدام به حمله می‌کنند. برای تشخیص حملات به شبکه اینترنت اشیا نیاز به سامانه‌های هوشمند تشخیص نفوذ به شبکه است. سامانه‌های تشخیص نفوذ یکی از مؤثرترین روش‌ها برای محافظت از سامانه‌های IoT در برابر طیف وسیعی از حملات هستند.

امروزه تروش‌های یادگیری ماشین به‌طور گسترده برای بهبود عملکرد سامانه تشخیص نفوذ استفاده شده‌است، اما هنوز نتوانسته‌اند به سطح مطلوبی از دقت دست یابند. برای اینکه سامانه تشخیص نفوذ مؤثر باشد، نه تنها باید بتواند بین ترافیک قانونی و مخرب در طول فرایند تجزیه و تحلیل ترافیک شبکه تمایز قائل شود، بلکه باید قادر باشد تشخیص دهد که چه نوع حمله‌ای در سامانه محافظت‌شده در حال انجام است. در این پژوهش برای تشخیص حملات به‌صورت دقیق و هوشمند یک سامانه تشخیص نفوذ با هوش گروهی ارمه‌های و ماشین بردار پشتیبان ارائه شده‌است. نقش الگوریتم ارمه‌های در روش پیشنهادی، انتخاب ویژگی‌های مهم برای به‌کارگیری در ماشین بردار پشتیبان برای مقابله با نفوذ است. در روش پیشنهادی برای افزایش دقت ماشین بردار پشتیبان مجموعه داده با روش یادگیری عمیق GAN متعادل‌سازی می‌شود و سپس برای افزایش دقت مدل، پارامترهای SVM به‌وسیله الگوریتم AOA بهینه‌سازی می‌شود. آزمایش‌ها نشان داد پیشنهادی با کرنل گوسین دارای کارایی بیشتری و دقت روش دقت، حساسیت و صحت به‌ترتیب برابر ۹۹.۱۲ درصد، ۹۸.۹۲ درصد و ۹۸.۹۶ درصد است. روش پیشنهادی در تشخیص حملات از درخت تصمیم‌گیری، جنگل تصادفی و شبکه عصبی چندلایه دقت بیشتری دارد. روش پیشنهادی در شاخص دقت نسبت به روش‌های یادگیری عمیق AE-CNN،

LSTM، LSTM-RNN، GA-ELM، CNN-LSTM و ELM دقت بیشتری دارد. روش پیشنهادی نسبت به چند روش انتخاب ویژگی مانند الگوریتم ژنتیک و الگوریتم گرگ خاکستری دارای دقت بیشتری است. استفاده از شبکه عصبی LSTM و CNN به جای شبکه MLP برای تشخیص حملات از پژوهش‌ها و کارهای آینده ما است.

6-Reference

۶-مراجع

- [1] Z. Abou El Houda, B. Brik, and L. Khoukhi, "Why Should I Trust Your IDS?": An Explainable Deep Learning Framework for Intrusion Detection Systems in Internet of Things Networks," *IEEE Open Journal of the Communications Society*, vol. 3, pp. 1164–1176, 2022.
- [2] M. M. Rashid et al., "Adversarial Training for Deep Learning-based Cyberattack Detection in IoT-based Smart City Applications," *Computers & Security*, p. 102783, 2022.
- [3] N. Al-Taleb and N. A. Saqib, "Towards a Hybrid Machine Learning Model for Intelligent Cyber Threat Identification in Smart City Environments," *Applied Sciences*, vol. 12, no. 4, p. 1863, 2022.
- [4] R. Zhao, Y. Mu, L. Zou, and X. Wen, "A Hybrid Intrusion Detection System Based on Feature Selection and Weighted Stacking Classifier," *IEEE Access*, vol. 10, pp. 71414–71426, 2022.
- [5] E. Mahdavi, A. Fanian, A. Mirzaei, and Z. Taghiyarrenani, "ITL-IDS: Incremental Transfer Learning for Intrusion Detection Systems," *Knowledge-Based Systems*, vol. 253, p. 109542, 2022.
- [6] A. K. Zamani and A. Chapnevis, "BotNet Intrusion Detection System in Internet of Things with Developed Deep Learning," *arXiv preprint*, arXiv:2207.04503, 2022.
- [7] A. A. R. Melvin et al., "Dynamic malware attack dataset leveraging virtual machine monitor audit data for the detection of intrusions in cloud," *Trans. Emerging Telecommunications Technologies*, vol. 33, no. 4, e4287, 2022.
- [8] K. Malik et al., "Lightweight Internet of Things Botnet Detection Using One-Class Classification," *Sensors*, vol. 22, no. 10, p. 3646, 2022.
- [9] D. B. Mandru et al., "Assessing deep neural network and shallow for network intrusion detection systems in cyber security," in *Computer Networks and Inventive Communication Technologies*, Springer, Singapore, 2022, pp. 703–713.
- [10] Z. Rustama and N. P. A. A. Ariantari, "Comparison between Support Vector

- [23] M. Almiani et al., "Deep recurrent neural network for IoT intrusion detection system," *Simulation Modelling Practice and Theory*, vol. 101, p. 102031, 2020.
- [24] A. O. Alzahrani and M. J. Alenazi, "Designing a Network Intrusion Detection System Based on Machine Learning for Software Defined Networks," *Future Internet*, vol. 13, no. 5, p. 111, 2021.
- [25] A. Davahli, M. Shamsi, and G. Abaei, "Hybridizing genetic algorithm and grey wolf optimizer to advance an intelligent and lightweight intrusion detection system for IoT wireless networks," *J. Ambient Intell. Humaniz. Comput.*, vol. 11, no. 11, pp. 5581–5609, 2020.
- [26] R. Yao et al., "Intrusion detection system in the advanced metering infrastructure: a cross-layer feature-fusion CNN-LSTM-based approach," *Sensors*, vol. 21, no. 2, p. 626, 2021.
- [27] E. Altulaihan, M. A. Almaiah, and A. Aljughaiman, "Anomaly Detection IDS for Detecting DoS Attacks in IoT Networks Based on Machine Learning Algorithms," *Sensors*, vol. 24, no. 2, p. 713, 2024.
- [28] محمدی، شهریار، خلعتبری، احمد، باباگلی، مهدی، «رانه یک مدل فراابتکاری تشخیص نفوذ به کمک انتخاب ویژگی مبتنی بر بهینه سازی گرگ خاکستری بهبودیافته و جنگل تصادفی»، فصلنامه پردازش علائم و داده‌ها، دوره ۲۰، شماره ۱، صص ۱۳۳–۱۴۴، ۱۴۰۲.
- [28] Sh. Mohammadi, A. Khalatbari, and M. Babagoli, "Proposing a Meta-heuristic Model of Intrusion Detection Using feature Selection Based on Improved Gray Wolf Optimization and Random Forest," *Signal Data Processing*, pp. 133–144, 2023.
- [29] تیموری، احمد، دی پیر، محمود، «سامانه دو سطحی تشخیص نفوذ برای شبکه اینترنت اشیا مبتنی بر یادگیری عمیق»، فصلنامه پردازش علائم و داده‌ها، دوره ۲۱، شماره ۳، صص ۲۲–۳، ۱۴۰۱.
- [29] A. Teymoori and M., Deypir "Two-level intrusion detection system for Internet of Things network based on deep learning," *Signal Data Process.*, vol. 3, no. 1, pp. 3–22, 2024.
- [30] S. S. Kareem et al., "An effective feature selection model using hybrid metaheuristic algorithms for iot intrusion detection," *Sensors*, vol. 22, no. 4, p. 1396, 2022.
- [31] K. Ren, Y. Zeng, Z. Cao, and Y. Zhang, "ID-RDRL: a deep reinforcement learning-based feature selection intrusion detection model," *Scientific Reports*, vol. 12, no. 1, p. 15370, 2022.
- [32] J. Figueiredo, C. Serrão, and A. M. de Almeida, "Deep learning model transposition for network intrusion detection systems," *Electronics*, vol. 12, no. 2, p. 293, 2023.
- Machine and Fuzzy Kernel C-Means as Classifiers for Intrusion Detection System using Chi-Square Feature Selection," in *AIP Conf. Proc.*, vol. 20214, no. 2018, 2023.
- [11] T. Wu et al., "Intrusion detection system combined enhanced random forest with SMOTE algorithm," *EURASIP J. Adv. Signal Process.*, vol. 2022, no. 1, pp. 1–20, 2022.
- [12] M. Jeyaselvi et al., "A highly secured intrusion detection system for IoT using EXPSO-STFA feature selection for LAANN to detect attacks," *Cluster Computing*, pp. 1–16, 2022.
- [13] D. Aksu and M. A. Aydin, "MGA-IDS: Optimal feature subset selection for anomaly detection framework on in-vehicle networks-CAN bus based on genetic algorithm and intrusion detection approach," *Computers & Security*, vol. 118, p. 102717, 2022.
- [14] M. Ajdani, A. Noori, and H. Ghaffary, "Providing a Consistent Method to Model the Behavior and Modelling Intrusion Detection Using A Hybrid Particle Swarm Optimization-Logistic Regression Algorithm," *Security and Communication Networks*, 2022.
- [15] S. Shadravan, H. R. Naji, and V. K. Bardsiri, "The Sailfish Optimizer: A novel nature-inspired metaheuristic algorithm for solving constrained engineering optimization problems," *Eng. Appl. Artif. Intell.*, vol. 80, pp. 20–34, 2019.
- [16] O. Ali et al., "A Comprehensive Review of Internet of Things: Technology Stack, Middlewares, and Fog/Edge Computing Interface," *Sensors*, vol. 22, no. 3, p. 995, 2022.
- [17] F. Hussain et al., "A Two-Fold Machine Learning Approach to Prevent and Detect IoT Botnet Attacks," *IEEE Access*, vol. 9, pp. 163412–163430, 2021.
- [18] S. M. Sajjad et al., "Detection and Blockchain-Based Collaborative Mitigation of Internet of Things Botnets," *Wireless Communications and Mobile Computing*, 2022.
- [19] J. E. M. Díaz, "Internet of things and distributed denial of service as risk factors in information security," in *Bioethics in Medicine and Society*, IntechOpen, 2020.
- [20] R. Vishwakarma and A. K. Jain, "A survey of DDoS attacking techniques and defence mechanisms in the IoT network," *Telecommunication Systems*, vol. 73, no. 1, pp. 3–25, 2020.
- [21] J. Asharf et al., "A review of intrusion detection systems using machine and deep learning in internet of things: Challenges, solutions and future directions," *Electronics*, vol. 9, no. 7, p. 1177, 2020.
- [22] Z. K. Maseer et al., "Benchmarking of machine learning for anomaly based intrusion detection systems in the CICIDS2017 dataset," *IEEE Access*, vol. 9, pp. 22351–22370, 2021.



زهرا سرحدی تحصیلات کارشناسی

مهندسی کامپیوتر نرم افزار را در
دانشگاه سیستان و بلوچستان و
کارشناسی ارشد مهندسی کامپیوتر
نرم افزار را در دانشگاه آزاد اسلامی

واحد زاهدان به پایان رساند. وی هم اکنون دانشجوی
دکترای مهندسی کامپیوتر نرم افزار دانشگاه آزاد واحد
بیرجند است. زمینه پژوهشی ایشان شبکه حسگر
بسیستم، یادگیری عمیق، شبکه عصبی و هوش مصنوعی
و الگوریتم های فراابتکاری است.

نشانی رایانامه ایشان عبارت است از:

Z.sarhadi@iau.ac.ir



مهدی خزاعی پور تحصیلات

کارشناسی مهندسی کامپیوتر را در
دانشگاه آزاد اسلامی مشهد و
کارشناسی ارشد را در دانشگاه آزاد
اسلامی واحد علوم و تحقیقات تهران و

دکترای را در دانشگاه آزاد کرمان به پایان رسانده است.
ایشان عضو هیأت علمی دانشگاه آزاد اسلامی واحد
بیرجند و مدیر گروه دانشکده کامپیوتر این دانشگاه
هستند. زمینه پژوهشی ایشان شبکه عصبی، هوش
مصنوعی و یادگیری عمیق است.

نشانی رایانامه ایشان عبارت است از:

Mkhazaeipoor@iau.ir

- [33] A. Abdelkhalek and M. Mashaly, "Addressing the class imbalance problem in network intrusion detection systems using data resampling and deep learning," *The Journal of Supercomputing*, vol. 79, no. 10, pp. 10611–10644, 2023.
- [34] P. Sanju, "Enhancing intrusion detection in IoT systems: A hybrid metaheuristics-deep learning approach with ensemble of recurrent neural networks," *Journal of Engineering Research*, vol. 11, no. 4, pp. 356–361, 2023.
- [35] V. Hnamte and J. Hussain, "Dependable intrusion detection system using deep convolutional neural network: A novel framework and performance evaluation approach," *Telematics and Informatics Reports*, vol. 11, p. 100077, 2023.
- [36] R. A. Elsayed, R. A. Hamada, M. I. Abdalla, and S. A. Elsaid, "Securing IoT and SDN systems using deep-learning based automatic intrusion detection," *Ain Shams Engineering Journal*, vol. 14, no. 10, p. 102211, 2023.
- [37] M. Nanjappan et al., "DeepLG SecNet: utilizing deep LSTM and GRU with secure network for enhanced intrusion detection in IoT environments," *Cluster Computing*, pp. 1–13, 2024.
- [38] E. Osa, P. E. Orukpe, and U. Iruansi, "Design and implementation of a deep neural network approach for intrusion detection systems," *e-Prime – Advances in Electrical Engineering, Electronics and Energy*, vol. 7, p. 100434, 2024.
- [39] S. S. Shankar et al., "A novel optimization based deep learning with artificial intelligence approach to detect intrusion attack in network system," *Education and Information Technologies*, vol. 29, no. 4, pp. 3859–3883, 2024.
- [40] R. Devendiran and A. V. Turukmane, "Dugat-LSTM: Deep learning based network intrusion detection system using chaotic optimization strategy," *Expert Systems with Applications*, vol. 245, p. 123027, 2024.
- [41] F. A. Hashim et al., "Archimedes optimization algorithm: a new metaheuristic algorithm for solving optimization problems," *Applied Intelligence*, vol. 51, pp. 1531–1551, 2021.
- [42] G. Eom and H. Byeon, "Searching for Optimal Oversampling to Process Imbalanced Data: Generative Adversarial Networks and Synthetic Minority Over-Sampling Technique," *Mathematics*, vol. 11, no. 16, p. 3605, 2023.
- [43] J. Tanha and Z. Zarei, "The Bombus-terrestris bee optimization algorithm for feature selection," *Applied Intelligence*, vol. 53, no. 1, pp. 470–490, 2023.