

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 توزیع شده^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 شده است 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 فناوری‌ها 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؛

¹ Internet of Things

² Smart cities

³ Intrusion detection systems (IDS)

⁴ Botnet

⁵ Malware

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

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 نتیجه‌گیری 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 به‌طور گسترده به‌عنوان یکی از رایج‌ترین انقلاب‌های فناوری در دو دهه گذشته در نظر گرفته می‌شود. دستگاه‌های اینترنت اشیا بیشتر به‌عنوان دستگاه‌های محاسباتی با قابلیت‌های سنجش، قدرت محاسباتی داخلی و شبکه‌ای مجهز به اینترنت برای برقراری ارتباط با یکدیگر تلقی می‌شوند. این حوزه فناوری، یکی از حوزه‌هایی است که به‌سرعت در حال رشد است و به ارتباطات ماشین به ماشین متکی است و از پشته پروتکل اینترنت^۸ برای برقراری ارتباط سرتاسری^۹ استفاده می‌کند. در ساده‌ترین عبارت، اینترنت اشیا به‌عنوان شبکه‌ای متشکل از میلیاردها دستگاه تلقی می‌شود که می‌تواند اطلاعات را حس کرده و فعال کند و به یک سامانه متمرکز منتقل کند. امروزه دستگاه‌ها و برنامه‌های IoT در حوزه‌های مختلفی مانند ترابری، خرده‌فروشی، مراقبت‌های بهداشتی، شبکه شهر هوشمند، حمل‌ونقل هوشمند و مدیریت بلایا مستقر و استفاده شده‌اند.

با وجود پیشرفت‌های فناوری در این حوزه‌های فردی، ناهمگونی دستگاه‌های اینترنت اشیا و وجود چالش‌های استانداردسازی اشیا هنوز مورد توجه قرار نگرفته است. با وجود فقدان استانداردها، سامانه‌های اینترنت اشیا در حال حاضر با سرعت خیره‌کننده‌ای در حال گسترش‌اند. سامانه‌های اینترنت اشیا اکنون از جمعیت جهان فراتر رفته و پیش‌بینی می‌شود تا سال ۲۰۲۵ به هشتاد میلیارد دستگاه برسد. به‌منظور اطمینان از قابلیت همکاری، مقیاس‌پذیری و قابلیت اطمینان سامانه‌های اینترنت اشیا، بررسی دقیق‌تری از پشته فناوری مورد نیاز است. برآوردها نشان می‌دهد که در سال ۲۰۲۵ تعداد کل نصب

شهرهای هوشمند نیاز به سامانه‌های 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 روش‌های یادگیری ماشین و یادگیری عمیق است. از جمله روش‌های یادگیری که برای تشخیص حملات به‌کار گرفته شده است می‌توان به شبکه عصبی مصنوعی^۱ [۹]، ماشین بردار پشتیبان^۲ [۱۰] و جنگل تصادفی^۳ [۱۱] اشاره کرد؛ هر کدام از این روش‌ها تلاش دارند تا الگوی حملات به شبکه را تشخیص دهند و حملات مخرب را به دیوار آتش گزارش دهند. یکی از چالش‌های مهم روش‌های یادگیری ماشین آن است که روی همه ویژگی‌ها آموزش داده می‌شوند و این موضوع باعث می‌شود که یادگیری روی ویژگی‌های مهم متمرکز نشود. یک روش برای آن که خطای خروجی روش‌های یادگیری ماشین در تشخیص حملات کاهش داده شود، استفاده از انتخاب ویژگی^۴ است [۱۲]. انتخاب ویژگی باعث می‌شود که ورودی‌های یادگیری ماشین نیز کاهش داده شود و این موضوع باعث می‌شود 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 بهینه‌سازی ذرات^۶ [۱۴] است. در این پژوهش برای تشخیص حملات به شبکه اینترنت اشیا از یک روش دو مرحله‌ای استفاده می‌شود. در روش پیشنهادی در ابتدا مرحله انتخاب ویژگی با الگوریتم اره ماهی^۷ [۱۵] انجام می‌شود؛ سپس از طبقه‌بندی‌کننده شبکه عصبی برای تحلیل ترافیک شبکه استفاده می‌شود. سامانه پیشنهادی مورد نظر از این جهت مزیت دارد که مفاهیم هوش گروهی را با شبکه عصبی ترکیب می‌کند 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
- متعادل‌سازی مجموعه داده با تئوری بازی و یادگیری عمیق مبتنی بر روش GAN
- بهینه‌سازی فرآپارامترهای SVM با الگوریتم بهینه‌سازی 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 شده است [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 دسترس بودن 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 شده است [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]

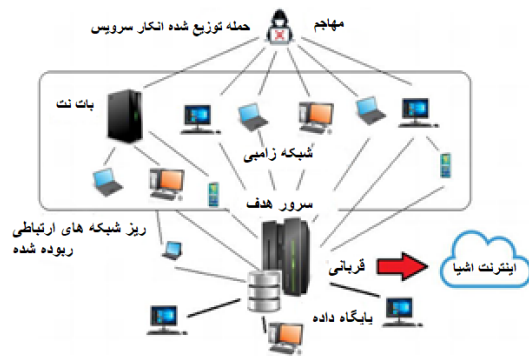
۲-۲- حملات به شبکه اینترنت اشیا

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 بوده است؛ در نتیجه، این پیشرفت در فناوری محاسباتی، به دستگاه‌های هوشمند این قابلیت را داده است 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 شده‌است. 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 اشیا [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 ماژول 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 نامن اینترنت اشیا و کنترل آن‌ها را برای هکرها آسان می‌کند. روندهای اخیر نشان می‌دهد که با افزایش سریع تعداد دستگاه‌های نامن 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 نامن اینترنت اشیا، بلکه تهدیدی حیاتی برای کل اینترنت است. با ظهور حمله بات‌نت Mirai در سال ۲۰۱۶، حملات بات‌نت IoT به‌طور 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 تقلیدشده 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 شده‌است 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

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 اشیاء 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 اشیاء [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 اشیاء، 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

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 متاهیورستیک 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 اشیاء 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،

پژوهش به کاررفته است، 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 شده است. 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 ISCX-IDS 2012، 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 شده است. این پژوهش یک سامانه تشخیص نفوذ خودکار دوسطحی امن را بر اساس یک شبکه بهبود یافته 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 شده است. 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 شده است. 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 شده است. نتایج نشان می‌دهد که مدل یادگیری عمیق در پیش‌بینی حملات با مجموعه داده‌های CICIDS 2017 عالی بود و نرخ از دست دادن ۰.۰۱۰۲ است.

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

CICIDS-2017، UNSW-NB15 و BoT-IoT پیاده‌سازی شده است. 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 شده است. 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 شده است. 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 شده است که ویژگی‌های بدون زمینه به آن داده می‌شود و مجموعه داده CICIDS2017 به دست می‌آید؛ این سامانه همچنین می‌تواند در محیط‌های مختلف بدون از دست دادن 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 شده است. در این پژوهش یک روش نمونه‌گیری مجدد داده‌ها در ترکیب با مدل‌های مختلف یادگیری عمیق برای کاهش مشکل عدم تعادل طبقه پیشنهاد شده است. مدل پیشنهادی بر روی مجموعه داده معیار NSL-KDD 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 شده است. 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

در شبکه اینترنت اشیا ارائه شده است. در این مطالعه تکنیک بهینه‌سازی سلسله‌مراتب شرکتی^۱ برای انتخاب ویژگی‌های مهم از پایگاه‌های داده استفاده می‌شود. راه‌حل پیشنهادی مبتنی بر بهینه‌سازی عقاب طلایی سیستم فازی چندلایه پرسپترون رابط فازی حریم خصوصی و امنیت را در زیرساخت شبکه حرفه‌ای بهبود می‌بخشد. آن‌ها روش خود را روی دو مجموعه داده NSL-KDD و UNSW-NB15 اجرا و بررسی کرده‌اند و نتایج نشان داده‌است 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 داده‌های دنیای واقعی و جدی | بهبود سرعت طبقه‌بندی دقت بالا کاهش نرخ خطای منفی کاذب (FN) و مثبت کاذب (FP) | الگوریتم بهبودیافته گرگ خاکستری همراه با انتخاب ویژگی و Fores Random | [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 روش‌های بهینه‌سازی ذرات و کلونی زنبور عسل دقیق‌تر است | ترکیب الگوریتم بهینه‌ساز پرندگان و گوریل | [30] |
| عدم انتخاب ویژگی هوشمندانه | هشتاد درصد از ویژگی‌های اضافی را حذف می‌کند | تقویتی و انتخاب ویژگی انتخاب ویژگی مبتنی بر یادگیری تقویتی عمیق | [31] |
| عدم متعادل‌سازی مجموعه داده | دقت بالا | مدل‌گیری عمیق انباشته: LSTM | [32] |
| عدم انتخاب ویژگی هوشمندانه | متعادل‌سازی مجموعه داده و افزایش دقت یادگیری | نمونه‌گیری مجدد داده‌ها با یادگیری عمیق | [33] |
| پیچیدگی مدل قابل توجه است | دقت بالا | مدل‌هایی 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 بهینه‌سازی 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] |
| متعادل‌سازی به روش SMOTE ضعیف است | نرخ از دست دادن اندک در حدود ۰.۰۱۰۲ است | متعادل‌سازی ترافیک شبکه با روش SMOTE | [38] |
| قطعیت کم در روش‌های فازی | دقت بیشتر از الگوریتم GA, PSO | تکنیک بهینه‌سازی سلسله‌مراتب شرکتی و یادگیری عمیق فازی | [39] |
| عدم تعادل ویژگی در مجموعه داده | دقت مدل پیش‌بینی ۹۸.۷۶ درصد | یادگیری عمیق با استفاده از استراتژی بهینه‌سازی آشفته | [40] |

در [۴۰] یک سامانه تشخیص نفوذ شبکه مبتنی بر یادگیری عمیق با استفاده از استراتژی بهینه‌سازی آشفته^۲ ارائه شده است. پس از پیش‌پردازش، مجموعه داده‌های نامتعادل با استفاده از رویکرد نمونه‌گیری مصنوعی توسعه یافته متعادل می‌شوند و پس از متعادل‌سازی، ویژگی‌های مجموعه داده با استفاده از تجزیه و تحلیل مؤلفه اصلی به کمک هسته برداشته می‌شوند. ویژگی‌های بهینه به وسیله الگوریتم بهینه‌سازی انتخاب می‌شوند؛ پس از استخراج همه ویژگی‌های مورد نیاز، حملات به وسیله مدل Dugat-LSTM طبقه‌بندی می‌شوند. در این پژوهش از مجموعه داده TON-IOT برای ارزیابی استفاده می‌شود. نتایج آزمایش‌ها نشان می‌دهد 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 آن‌ها بررسی شده است.

بررسی کارهای مرتبط در زمینه تشخیص نفوذ به شبکه نشان می‌دهد که این روش‌ها از چالش‌های زیر رنج می‌برند:

- در برخی از سامانه‌های تشخیص نفوذ از سازوکار امضا و فهرست سیاه استفاده شده است، اما این روش‌ها به حافظه زیادی نیاز دارند و از طرفی زمان جست‌وجو در آن‌ها قابل توجه است و توانایی تشخیص حملات جدید را ندارند.

- روش‌های اکتشافی یکی دیگر از روش‌های توسعه سامانه‌های 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.

- روش‌های یادگیری ماشین و یادگیری عمیق توانایی تشخیص حملات پیچیده را دارند، اما این روش‌ها تعادل در مجموعه داده، انتخاب ویژگی و بهینه‌سازی پارامترهای مدل‌های یادگیری را ندارند.

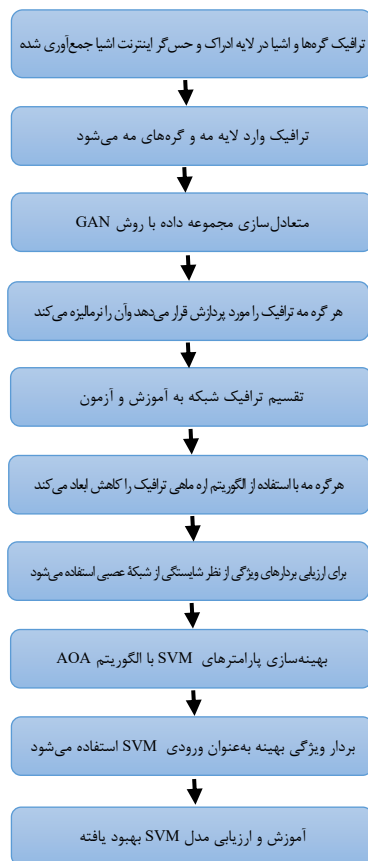
برای تشخیص نفوذ دقیق در این مقاله و رفع این چالش‌ها یک سامانه تلفیقی هوش گروهی و یادگیری ماشین ارائه می‌شود. برای رفع چالش عدم تعادل در مجموعه داده‌های تشخیص نفوذ از تئوری بازی و شبکه عصبی GAN استفاده می‌شود و در مرحله بعدی برای کاهش ابعاد ترافیک و انتخاب ویژگی از الگوریتم دودویی شده اره‌ماهی استفاده می‌شود. در مرحله سوم از ماشین بردار پشتیبان برای تشخیص و طبقه‌بندی ترافیک شبکه استفاده شده و پارامترهای ماشین بردار پشتیبان را می‌توان با الگوریتم‌های جدید مانند بهینه‌سازی محاسبات ریاضی^۳ [۴۱] بهبود داد. دلیل استفاده از الگوریتم AOA

² Chaotic Honey Badger

³ Archimedes optimization algorithm

¹ Corporate Hierarchy optimization (CHO)

عادی باشد. هدف از متعادل‌سازی آن است که خطای طبقه‌بندی مدل یادگیری یا SVM کاهش داده شود. (۳) ترافیک شبکه در گره‌های مه به دو دسته آموزشی و آزمون تقسیم شده و از ترافیک آموزشی برای آموزش روش پیشنهادی استفاده می‌شود و برای ارزیابی از روش ارزیابی متقاطع با $kfold=10$ استفاده می‌شود. (۴) هر گره مه با استفاده از الگوریتم اره ماهی انتخاب ویژگی کرده و ویژگی‌های مهم را انتخاب کرده و از آن‌ها به عنوان ورودی‌های SVM استفاده می‌شوند. (۵) ماشین بردار پشتیبان با بردار ویژگی بهینه ترافیک شبکه آموزش داده می‌شود و سپس خطای آن با استفاده از داده‌های آزمون ارزیابی قرار می‌شود. در این مرحله برای کاهش خطای بیشتر مدل SVM از الگوریتم AOA به عنوان یک روش فرابتنکاری بر پایه عملیات ریاضی استفاده می‌شود. هدف آن است که پارامترهای مانند نرخ خطا و جریمه در SVM با روش فرابتنکاری AOA بهینه‌سازی 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

- متعادل‌سازی مجموعه داده با روش GAN
- انتخاب ویژگی در گره‌های مه با استفاده از الگوریتم اره ماهی

آن است که پیچیدگی بالایی ندارد و اگر برای بهینه‌سازی پارامترهای SVM استفاده شود آنگاه زمان یادگیری آن را افزایش قابل توجه نمی‌دهد. دلیل استفاده از الگوریتم بهینه‌سازی اره ماهی در مرحله انتخاب ویژگی به شرح زیر خلاصه می‌شود:

- مسئله انتخاب ویژگی بر خلاف بهینه‌سازی پارامترهای SVM یک مسئله با ابعاد بسیار بیشتر است و از این جهت نیاز به الگوریتم‌های هوشمندتر به ویژه با رویکرد هوش گروهی دارد.
- الگوریتم بهینه‌سازی اره ماهی با تقسیم جمعیت راه‌حل‌ها به دو دسته اره ماهی و ساردین می‌تواند بین جست‌وجوی اکتشافی یا سراسری و جست‌وجوی بهره‌برداری یا محلی توازن ایجاد کند.
- الگوریتم اره ماهی از الگوریتم‌های فرابتنکاری رایج مانند بهینه‌سازی ذرات، الگوریتم خفاش و کرم‌شب‌تاب 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 می‌شود که به شرح زیر است:

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

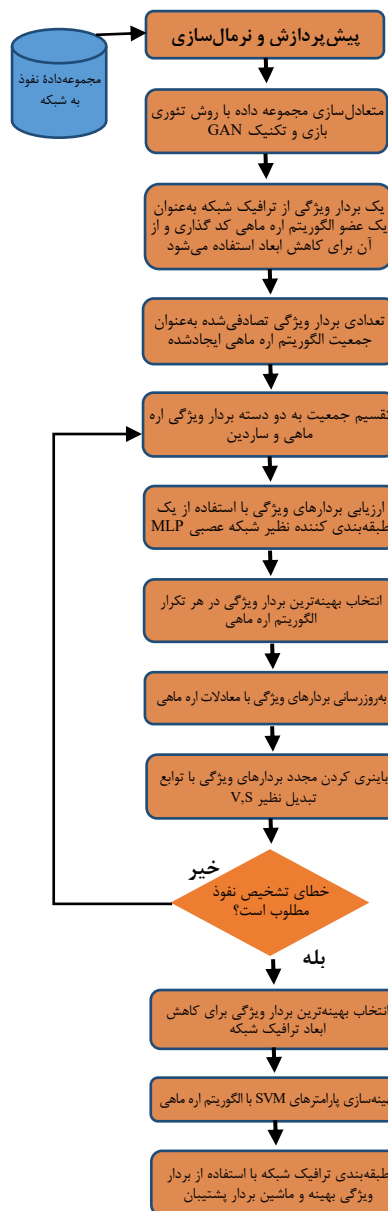
۳-۱- مراحل روش پیشنهادی

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 حس‌گر تولید شده و این ترافیک برای گره‌های مه ارسال می‌شود. در روش پیشنهادی هر گره مه نقش یک سامانه تشخیص نفوذ به شبکه را بر عهده دارد.

(۲) برای متعادل‌سازی مجموعه داده از تئوری بازی و شبکه عصبی یادگیری عمیق GAN استفاده می‌شود و هدف آن است که تعداد نمونه‌های حمله برابر تعداد نمونه

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



(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 شده‌است و مراحل آن به شرح زیر است:
- ۱) در ابتدا مجموعه‌ای از ترافیک شبکه به‌عنوان ورودی و مجموعه‌داده 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 به‌عنوان یک عضو الگوریتم آره‌ماهی کدگذاری می‌شود.

- ۵) در تکرار نخست تعدادی بردار ویژگی تصادفی تعیین شده و هر کدام از این بردارهای دودویی یک عضو الگوریتم آره‌ماهی است.
- ۶) هر بردار ویژگی و الگوی آن روی مجموعه‌داده نفوذ به شبکه اعمال شده و مجموعه‌داده 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 انتخاب‌شده 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 کاهش‌دادن 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 به‌کار گرفته می‌شود.

۳-۳- متعادل‌سازی مجموعه‌داده

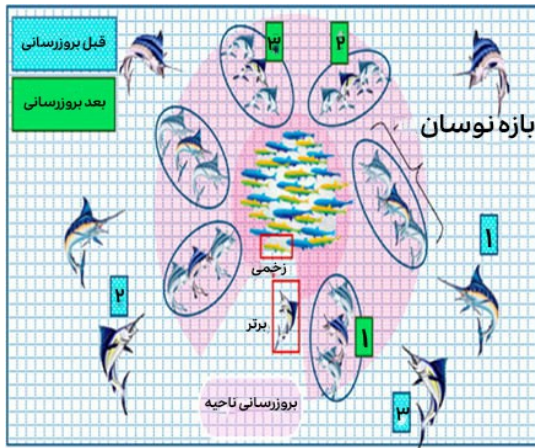
عدم تعادل در یک مجموعه‌داده زمانی اتفاق می‌افتد که تعداد نمونه‌های یک طبقه مانند طبقه حملات از طبقه عادی کمتر باشد. عدم تعادل مجموعه‌داده باعث می‌شود تا دقت مدل‌های یادگیری عمیق و ماشین کاهش داده شود. یک روش برای متعادل‌سازی مجموعه‌داده تشخیص نفوذ که تعداد نمونه‌های حملات آن در کمترین حد است ایجاد نمونه‌های مصنوعی بر اساس نمونه‌های واقعی و اضافه‌کردن آن‌ها به مجموعه‌داده 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 مجموعه‌داده [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 فراابتکاری 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:

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

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:

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

در معادله $p_{data}(x)$ و $p_z(z)$ 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 شده‌است و به‌طور معمول نصف جمعیت از این نوع بردارهای ویژگی است و تعداد این نوع بردارهای ویژگی برابر n عدد است:

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

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

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

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 می‌شود:

- یک بردار ویژگی زمانی شایستگی دارد که خطای تشخیص حملات توسط آن کمینه باشد. به عبارت بهتر هر بردار ویژگی که بتواند ورودی‌های SVM را به‌گونه‌ای کاهش ابعاد دهد که خطای طبقه‌بندی 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 ورودی‌های SVM را بیشتر کاهش دهد آنگاه شایستگی بیشتری دارد.

می‌توان مطابق [۴۳] خطای تشخیص حملات و کاهش ابعاد را هم‌زمان برای ارزیابی بردار ویژگی در نظر گرفت و به ضرایبی وزنی بین صفر و یک آن‌ها را به‌عنوان یک تابع هدف ارائه داد. برای سنجش خطای تشخیص حملات به‌وسیله یک بردار ویژگی مانند FS_i می‌توان از یک طبقه‌بندی‌کننده ساده مانند شبکه عصبی مصنوعی چندلایه استفاده کرد؛ در این حالت بردار ویژگی FS_i روی مجموعه داده نگاشت داده می‌شود به گونه‌ای که اگر مؤلفه z ام بردار ویژگی FS_i دارای مقدار یک است از ویژگی z ام به‌عنوان ورودی شبکه عصبی استفاده می‌شود. فرض کنید بردار ویژگی FS_i دارای $|FS_i|$ ویژگی باشد که انتخاب شده‌اند (مقدار این ویژگی‌ها در بردار ویژگی برابر یک است)؛ از این جهت تعداد ورودی‌های شبکه عصبی برای این بردار ویژگی برابر $|FS_i|$ خواهد بود. برای ارزیابی بردارهای ویژگی از نوع اره‌ماهی یا ساردین نیاز به یک تابع هدف مناسب است که این تابع در رابطه (۴) ارائه شده‌است [۴۳]:

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

در این رابطه $E(FS_i)$ خطای طبقه‌بندی ترافیک حملات از ترافیک عادی به وسیله بردار ویژگی FS_i است. $|FS_i|$ نیز برابر تعداد ویژگی‌های انتخاب‌شده 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 می‌شود. ضرایب وزنی باعث می‌شود تا overfitting در مرحله انتخاب ویژگی تا حد زیادی تعدیل شود؛ از طرفی متعادل‌سازی مجموعه داده با روش GAN آن چالش را در روش پیشنهادی کم‌رنگ می‌کند.

هر بردار ویژگی که این تابع را کمینه کند اگر از نوع ساردین باشد به‌عنوان ساردین زخمی و اگر از نوع اره‌ماهی باشد آنگاه به‌عنوان بهینه‌ترین اره‌ماهی برای حمله به دسته ماهیان ساردین در نظر گرفته می‌شود. می‌توان بردارهای اره‌ماهی و ساردین که همگی از نوع بردارهای ویژگی‌اند را با این تابع هدف ارزیابی کرد و مقدار ارزیابی آن‌ها را در رابطه‌های (۵) و (۶) نمایش داد:

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

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

در روش پیشنهادی، بردار ویژگی از نوع ساردین که بهینه‌ترین بردار ویژگی از نوع ساردین‌هاست و بهینه‌ترین بردار ویژگی اره‌ماهی آن می‌تواند برای انتخاب مکان حمله بردارهای ویژگی از نوع اره‌ماهی 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 به‌روزشده یک اره‌ماهی، $F_{eliteSF}^i$ بردار ویژگی بهینه‌ترین اره‌ماهی، $F_{injuredS}^i$ بهینه‌ترین بردار ویژگی از نوع ساردین، F_{oldSF}^i موقعیت قبلی یک بردار ویژگی از نوع اره‌ماهی،

ممکن است این مقادیر را از حالت دودویی خارج کنند، توابع و V برای نرمال‌سازی و بازگرداندن آن‌ها به بازه $[0,1]$ به کار می‌روند 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 بی‌معنی 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 اگر عدد هشت به عدد 0.4 نرمال شود؛ چون به صفر نزدیک‌تر است می‌توان آن را صفر در نظر گرفت (ویژگی انتخاب نشده‌است) و اگر عدد هشت به 0.7 نرمالیزه شود می‌توان آن را به یک تبدیل کرد (ویژگی انتخاب شده)؛ زیرا 0.7 به یک نزدیک‌تر است تا صفر. بعد از نرمال‌سازی مقادیر بردارهای ویژگی با استفاده از توابع انتقالی S و V می‌توان 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]:

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

$$X_i^j(t+1) = \begin{cases} \neg X_i^j(t) & \text{rand} < T(X_i^j(t+1)) \\ X_i^j(t) & \text{otherwise} \end{cases} \quad (11)$$

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

۵-۳- طبقه‌بندی با ماشین بردار پشتیبان

روش ماشین بردار پشتیبان نیز یک روش یادگیری ماشین است که برای طبقه‌بندی استفاده می‌شود. در این روش برای یادگیری یک خط جداکننده باید به‌گونه‌ای بین دو طبقه داده‌ها قرار داده شود که کمترین خطا در طبقه‌بندی به‌وجود آید. در شکل (۱۱) در این روش خط C به‌عنوان خط طبقه‌بندی‌کننده به‌کار گرفته می‌شود و خط A و B نیز ناحیه و مرز این خط را نشان می‌دهند و هدف آن است که عرض نوار بیشینه شود و به شرط این‌که تعداد کمتری از نمونه‌ها به‌اشتباه در دو طبقه قرار داده شوند.

در شکل (۱۲) در این روش خط C به‌عنوان خط طبقه‌بندی‌کننده به‌کار گرفته می‌شود و خط A و B نیز ناحیه و مرز این خط را نشان می‌دهند و هدف آن است که عرض نوار بیشینه شود، به شرط این‌که تعداد کمتری از نمونه‌ها به‌اشتباه در دو طبقه قرار داده شوند.

$rand(0,1)$ عدد تصادفی یک‌نواخت بین صفر و یک، λ_i ضریب هم‌گرایی در تکرار i -ام است که مرتب کاهش خواهد یافت. هر بردار ویژگی از نوع ساردین نیز می‌تواند تحت تأثیر فرار به‌روزرسانی شود و برای این منظور از رابطه (۸) استفاده می‌شود:

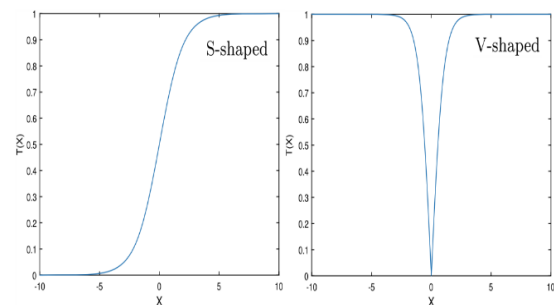
(۸)

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

در این رابطه $F_{old_S}^i$ و $F_{new_S}^i$ به‌ترتیب 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 حمله‌ارمه‌های آن می‌گویند که می‌توان آن را از رابطه (۹) محاسبه کرد:

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

A و ϵ پارامترهای ثابت و اولیه‌توان حمله برای به‌روزرسانی بردارهای ویژگی از نوع ساردین در نظر گرفته می‌شوند. هر بردار ویژگی از نوع ساردین یا ارمه‌های به‌ترتیب تحت تأثیر مکانیزم فرار و حمله به‌روزرسانی شده و موقعیت آن‌ها دچار تغییر می‌شود، اما این تغییرات می‌تواند این بردارهای ویژگی را از حالت دودویی خارج و آن‌ها 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 به‌کار گرفته می‌شوند نمایش داده شده‌است.



(شکل ۱۱-): به‌ترتیب 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 می‌تواند اعداد پیوسته بردارهای ویژگی را به این بازه نگاشت دهند. نقش تابع S و V آن است که مقادیر بردارهای ویژگی بعد از به‌روزرسانی به‌وسیله الگوریتم ماهی در بازه صفر تا یک نرمالیزه شوند؛ به عبارت بهتر بردارهای ویژگی در الگوریتم ارمه‌های شامل مقادیر دودویی صفر و یک هستند که به‌ترتیب نشان‌دهنده عدم انتخاب و انتخاب ویژگی‌اند؛ از آن‌جا که به‌روزرسانی‌ها

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

$$\geq 0$$

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) به روزرسانی 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 آلفا 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 و 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 [۲۶] technique

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 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:

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

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

$$(w \times \Phi(xi)) \geq \rho - \xi_{ii} = 1, 2, \dots, l \xi_i \geq 0 \quad (15)$$

¹ 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 می‌گیرد.

۴-۱- مجموعه داده

مجموعه داده NSL-KDD به عنوان یکی از بهترین مجموعه داده‌های مرتبط با تشخیص نفوذ به شبکه در نظر گرفته می‌شود. این مجموعه داده در ابتدا توسط استولفا^۱ و همکاران با آنالیز اطلاعات ردوبدل شده در شبکه نیروی هوایی آمریکا در یکی از پایگاه‌های آن گردآوری شده است. این مجموعه داده اعتبار بالایی برای سنجش دقت الگوریتم‌های تشخیص نفوذ به شبکه و اینترنت اشیا دارد؛ زیرا تنوعات گسترده‌ای را شامل می‌شود؛ در کل می‌توان گفت که مجموعه داده مورد نظر اعتبار و محبوبیت بالایی دارد و در بسیاری از پژوهش‌ها مورد استفاده قرار می‌گیرد. این مجموعه داده سه ویژگی ممتاز زیر را در خود نهفته دارد:

▪ تلفیقی از ترافیک عادی و مشکوک است که می‌توان با تجزیه و تحلیل ویژگی‌های آن الگوهای ترافیک شبکه را شناسایی و از آن برای طبقه‌بندی ترافیک شبکه استفاده کرد.

▪ در این مجموعه داده ترافیک مبتنی بر زمان در شبکه نیز مورد توجه قرار گرفته است؛ به گونه‌ای که در این مجموعه داده، داده‌ها به مرور زمان گردآوری شده‌اند 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 میزبان‌های مختلف گردآوری شده است.

مجموعه داده تشخیص نفوذ به شبکه یا KDD، ۴۱ ویژگی مختلف و متنوع دارد که به در کل ۳۴ عدد از آن‌ها 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 آن‌ها اشاره شده است:

▪ ویژگی‌های اساسی^۲: این گروه از ویژگی‌ها در واقع تمام ویژگی‌هایی را که می‌تواند از یک ارتباط و ترافیک TCP-IP^۳ استخراج شوند شامل می‌شود. شناسایی این مجموعه ویژگی‌ها نیاز به زمان کمابیش طولانی دارد؛ زیرا برخی از این ویژگی‌ها به مرور زمان در شبکه تشخیص داده شده و گردآوری می‌شوند.

¹ Stolfo


² Basic features

³ Transmission Control Protocol-Internet Protocol

▪ ویژگی‌های 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 می‌رسند و این در حالی است که حملات نوع U2R و R2L در بخش داده بسته ارسالی به شبکه جاسازی می‌شوند و به طور عادی تنها یک ترافیک را درگیر می‌کنند، اما حملات نوع DOS و Prob تعداد بیشتری ترافیک را شامل می‌شوند.

▪ ویژگی‌های ترافیکی: این ویژگی‌ها تنها ترافیک را در زمانی فعلی یا در یک بازه کوتاه مورد توجه قرار می‌دهند و به دو نوع ویژگی‌های ترافیک میزبان و ویژگی‌های ترافیک سرویس دسته‌بندی می‌شوند که به ترتیب ناظر بر ترافیک وارد شده به یک میزبان و یا یک سرویس عملیاتی‌اند.

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 سرویس‌ها یا پورت‌های رایانه به دست می‌آورد و بر اساس این اطلاعات سعی می‌کند به شبکه نفوذ و در آن اختلال ایجاد کند. در این نوع از حملات مهاجم می‌تواند برای نفوذ به شبکه از روش‌های 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 می‌دهد که در بین مجموعه داده‌های مختلف دو مجموعه داده KDD و NSL-KDD دارای بیشترین سهم در ارزیابی سامانه‌های تشخیص نفوذ به شبکه است. در شکل (۱۴)، چند رکورد از مجموعه داده NSL-KDD برای تشخیص حملات نمایش داده شده است و مشاهده می‌شود که ۴۱ ویژگی از نوع ورودی است و ویژگی آخر نیز می‌تواند حمله یا عادی بودن ترافیک را نشان دهد.



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

⁴ Scan

⁵ Social engineering

حساسیت و صحت به ترتیب تا حدود ۹۸.۸۳ درصد، ۹۸.۲۴ درصد و ۹۸.۱۶ درصد کاهش خواهد یافت. علت آن که روش پیشنهادی به ازای 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 طبقه بندی و تشخیص نفوذ در کرنل گوسین که غیرخطی است، بهتر جواب می دهد. برای آزمایش ها و مقایسه ها می توان نتایج پژوهش را با مطالعه در پژوهش [۲۴] که سال ۲۰۲۱ انجام شده است مورد ارزیابی قرار داد. در نمودار شکل (۱۶)، روش پیشنهادی در تشخیص حملات با درخت تصمیم گیری J48، جنگل تصادفی RF و شبکه عصبی چندلایه MLP مورد مقایسه قرار گرفته و ارزیابی شده است. ارزیابی ها نشان می دهد دقت روش پیشنهادی به دلیل انتخاب ویژگی دارای دقتی برابر ۹۹.۱۲ درصد و این در حالی است که دقت روش درخت تصمیم گیری J48، جنگل تصادفی RF و شبکه عصبی چند لایه MLP به ترتیب برابر ۸۱.۰۵ درصد، ۸۰.۶۷ درصد و ۷۷.۴۱ درصد است و روش پیشنهادی نسبت به این روش ها دارای دقت بیشتری است؛ به عبارت بهتر آزمایش ها نشان داد ماشین بردار پشتیبان در ترکیب با اره ماهی نسبت به این روش ها در تشخیص حملات دقت بیشتری دارد.

برای ارزیابی منصفانه می توان 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 روش های یادگیری عمیق مانند AE-CNN، LSTM، LSTM-RNN، GA-ELM، CNN-LSTM، ELM و ELM در شاخص دقت مقایسه شده است. آزمایش ها نشان می دهند دقت AE-CNN، LSTM، LSTM-RNN، GA-ELM، CNN-LSTM و ELM برای تشخیص حملات به ترتیب 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 آن که روش پیشنهادی نسبت به روش های یادگیری عمیق در تشخیص حملات دارای دقت بیشتری است آن است که روش پیشنهادی در مرحله نخست مجموعه داده را با روش GAN متعادل سازی کرده و این عامل دقت مدل SVM را افزایش می دهد و از طرفی با الگوریتم AOA پارامترهای SVM بهینه سازی شده و ورودی های SVM نیز با الگوریتم اره ماهی بهینه شده است تا یادگیری روی ویژگی های اساسی انجام شود که در شکل (۱۹) قابل مشاهده است.

جمله ای^۱ و گوسین^۲ استفاده می شود. در جدول (۲)، متوسط شاخص های دقت، حساسیت و صحت روش پیشنهادی به ازای کرنل های مقایسه شده است. در نمودار شکل (۱۵)، شاخص دقت، حساسیت و صحت روش پیشنهادی به ازای کرنل های مختلف نمایش داده شده است. آزمایش ها در محیط برنامه نویسی متلب نشان می دهد، دقت، حساسیت و صحت روش پیشنهادی به ازای کرنل گوسین بیشترین مقدار ممکن است و دارای مقادیر ۹۹.۱۲ درصد، ۹۸.۹۲ درصد و ۹۸.۹۶ درصد است.

آزمایش ها نشان می دهد کمترین دقت، حساسیت و صحت روش پیشنهادی به ازای کرنل خطی است. اگر از ماشین بردار پشتیبان استفاده نشود و برای طبقه بندی از شبکه عصبی نیز استفاده شود، آن گاه شاخص دقت، حساسیت و صحت به ترتیب تا حدود ۹۸.۸۳ درصد، ۹۸.۲۴ درصد و ۹۸.۱۶ درصد کاهش خواهد یافت. علت آن که روش پیشنهادی به ازای 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 طبقه بندی و تشخیص نفوذ در کرنل گوسین که غیرخطی است، بهتر جواب می دهد. برای آزمایش ها و مقایسه ها می توان نتایج پژوهش را با مطالعه در پژوهش [۲۴] که سال ۲۰۲۱ انجام شده است، مورد ارزیابی قرار داد. در نمودار شکل (۱۶)، روش پیشنهادی در تشخیص حملات با درخت تصمیم گیری J48، جنگل تصادفی RF و شبکه عصبی چند لایه MLP مورد مقایسه قرار گرفته و ارزیابی شده است. ارزیابی ها نشان می دهد دقت روش پیشنهادی به دلیل انتخاب ویژگی دارای دقتی برابر ۹۹.۱۲ درصد است و این در حالی است که دقت روش درخت تصمیم گیری J48، جنگل تصادفی RF و شبکه عصبی چندلایه MLP به ترتیب برابر ۸۱.۰۵ درصد، ۸۰.۶۷ درصد و ۷۷.۴۱ درصد و روش پیشنهادی نسبت به این روش ها دارای دقت بیشتری است؛ به عبارت بهتر آزمایش ها نشان داد، ماشین بردار پشتیبان در ترکیب با اره ماهی نسبت به این روش ها در تشخیص حملات دقت بیشتری دارد.

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

آزمایش ها نشان می دهد کمترین دقت، حساسیت و صحت روش پیشنهادی به ازای کرنل خطی است. اگر از ماشین بردار پشتیبان استفاده نشود و برای طبقه بندی از شبکه عصبی نیز استفاده شود، آن گاه شاخص دقت،


¹ Polynomial

² Gaussian

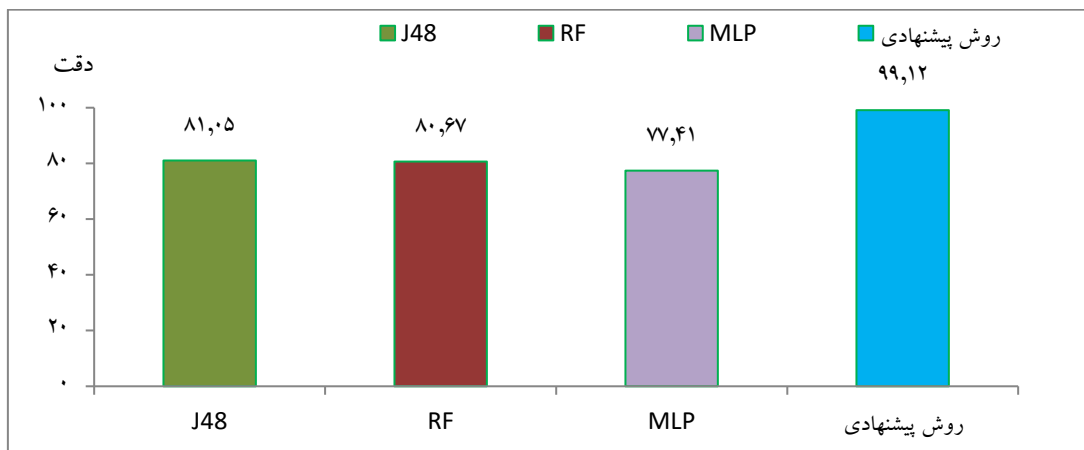


(جدول-۲): شاخص دقت، حساسیت و صحت به ازای کرنل‌های مختلف
 (Table -2): Accuracy, sensitivity and accuracy index for different kernels

| نوع کرنل | دقت | حساسیت | صحت |
|-------------|-------|--------|-------|
| خطی | ۹۸.۳۳ | ۹۸.۱۲ | ۹۸.۰۸ |
| بازگشتی | ۹۸.۷۲ | ۹۸.۷۵ | ۹۷.۹۸ |
| چند جمله‌ای | 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 کرنل‌های مختلف
 (Figure-15): Evaluation of the index of accuracy, sensitivity and accuracy of the proposed method with different kernels

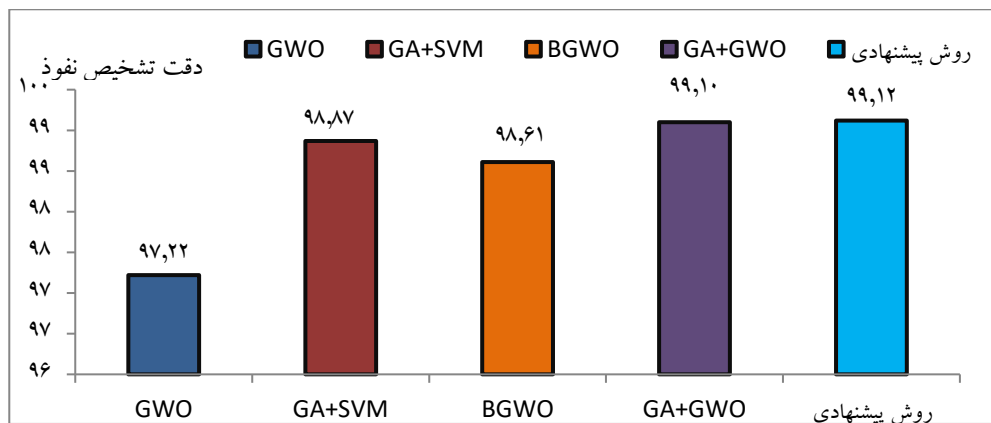


(شکل-۱۶): مقایسه دقت روش پیشنهادی با سه روش یادگیری ماشین
 (Figure-16): Comparison of the accuracy of the proposed method with three machine learning methods



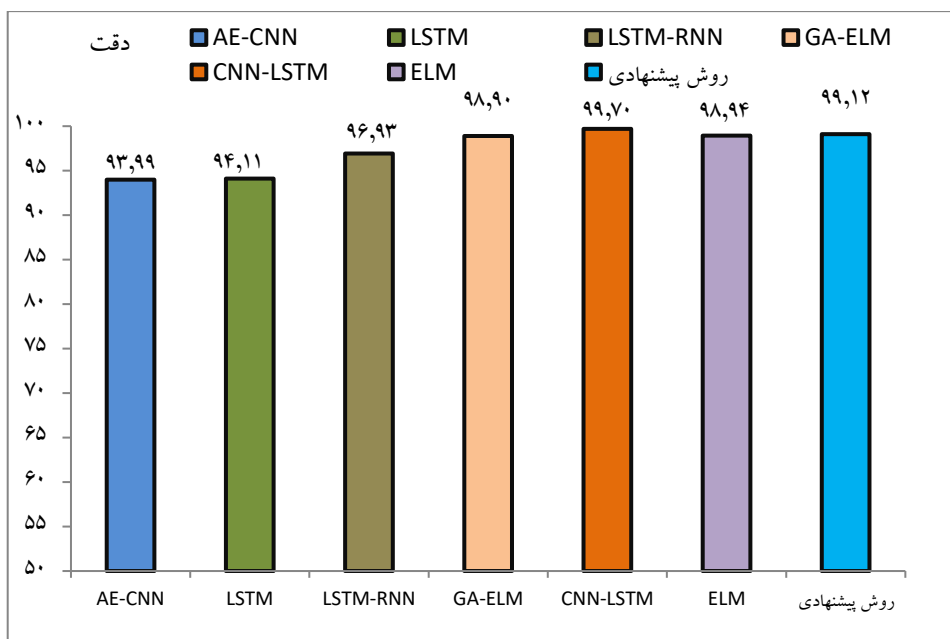
(شکل-17): ارزیابی شاخص دقت، حساسیت و صحت روش پیشنهادی با کرنل‌های مختلف

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



(شکل-18): 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-19): 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

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 به صورت دقیق و هوشمند یک سامانه تشخیص نفوذ با هوش گروهی ارم‌ماهی و ماشین بردار پشتیبان ارائه شده‌است. نقش الگوریتم ارم‌ماهی 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 به ترتیب 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.

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، «ارانه 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 نرم‌افزار را در دانشگاه سیستان و بلوچستان و کارشناسی ارشد مهندسی کامپیوتر نرم‌افزار را در دانشگاه آزاد اسلامی

واحد زاهدان به پایان رساند. وی هم اکنون دانشجوی دکترای مهندسی کامپیوتر نرم‌افزار دانشگاه آزاد واحد بیرجند است. زمینه پژوهشی ایشان شبکه حسگر بیسیم، یادگیری عمیق، شبکه عصبی و هوش مصنوعی و الگوریتم‌های 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:

Mkhazaiepoor@iau.ir

- [33] A. Abdelkhalik 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.