

# یک سامانه تشخیص نفوذ برای شهرهای هوشمند با استفاده از شبکه عصبی و الگوریتم ارده‌ماهی

زهره سرحدی<sup>۱\*</sup>، مهدی خزاعی پور<sup>۲</sup>

دانشجوی دکترا، گروه مهندسی کامپیوتر، دانشکده فنی و مهندسی، واحد بیرجند، دانشگاه آزاد اسلامی، بیرجند، ایران<sup>۱</sup>

استادیار، گروه مهندسی کامپیوتر، دانشکده فنی و مهندسی، واحد بیرجند، دانشگاه آزاد اسلامی، بیرجند، ایران<sup>۲</sup>

## چکیده

اینترنت اشیا (IoT) شبکه‌ای گستردۀ از اشیاء 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 ارده‌ماهی، 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 مجموعه‌داده NSL-KDD در نرم‌افزار MATLAB. دقیق‌ترین دقت ۹۹.۱۲ درصد، حساسیت ۹۸.۹۲ 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 ارده‌ماهی، انتخاب ویژگی.

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

Zahra Sarhadhi<sup>1\*</sup>, Mehdi khazaiepoor<sup>2</sup>

PhD student, Computer Engineering Department, Technical and Engineering Faculty,  
Birjand Branch, Islamic Azad University, Birjand, Iran<sup>1\*</sup>

Assistant Professor, Department of Computer Engineering, Technical and Engineering  
Faculty, Birjand Branch, Islamic Azad University, Birjand, Iran<sup>2</sup>

### 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

• تاریخ ارسال مقاله: ۱۴۰۲/۲/۷ • تاریخ پذیرش: ۱۴۰۴/۴/۲۹

• تاریخ انتشار: ۱۴۰۴/۶/۲۲ • نوع مطالعه: پژوهشی

سال ۱۴۰۴ شماره ۲ پیاپی ۶۴

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<sup>۳</sup> 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 دیوال آتش گزارش دهد.<sup>[۵]</sup>

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 آن که برای این هدف طراحی شده باشند. در اینترنت اشیا ارتشم باتنت‌ها<sup>۴</sup> [۶] نقش مخربی علیه سرویس‌های ارائه‌دهنده خدمات دارد. در اینترنت اشیا و شهرهای هوشمند انواع ویروس و بدافزار<sup>۵</sup> [۷] می‌تواند اشیای هوشمند را آلوده کند و این اشیای هوشمند نقش حمله‌کننده را بر عهده خواهد داشت. یکی از انواع حملاتی که می‌تواند در اینترنت اشیا، آسیب زیادی به زیرساخت‌ها وارد کند، حملات رد سرویس خدمات توزیع شده<sup>۶</sup> 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.<sup>[۸]</sup>

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<sup>۱</sup> [۱] و شهرهای هوشمند<sup>۲</sup> [۲] یک موضوع مداوم در حال توسعه و در حال ظهرور است. پیشرفت بیشتر فناوری‌ها منجر به آسیب‌پذیری بیشتر و افزایش تهدید حملات به شبکه می‌شود و باعث می‌شود نوع حملات نیز پیشرفت‌هشود. 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 چندجایی را از مجموعه‌های حس‌گر خود مانند شتاب‌سنج، ژیروسکوپ و سامانه موقعیت‌یابی جهانی ارائه می‌کنند.<sup>[۳]</sup>.

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٪ درصد از کل ترافیک شبکه را ترافیک انسانی تشکیل می‌دهد. در میان ترافیک تولیدشده به وسیله ماشین‌ها، ترافیک مخرب ۲۵٪ درصد از کل ترافیک شبکه را تشکیل می‌دهد.<sup>[۴]</sup> 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؛

<sup>1</sup> Internet of Things

<sup>2</sup> Smart cities

<sup>3</sup> Intrusion detection systems (IDS)

<sup>4</sup> Botnet

<sup>5</sup> Malware

<sup>6</sup> 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 پیشینه‌پژوهش ارائه می‌شود و در بخش سوم نیز روش پیشنهادی برای تشخیص حملات به اینترنت اشیا با الگوریتم ارمه‌ماهی 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- پیشینه‌پژوهش

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

### ۲-۱- اینترنت اشیا

اینترنت اشیا به‌طور گسترده به عنوان یکی از رایج‌ترین انقلاب‌های فناوری در دو دهه گذشته در نظر گرفته می‌شود. دستگاه‌های اینترنت اشیا بیشتر به عنوان 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 به سرعت در حال رشد است و به ارتباطات ماشین به ماشین متکی است و از پشتۀ پروتکل اینترنت<sup>۸</sup> برای برقراری ارتباط سرتاسری<sup>۹</sup> استفاده می‌کند. در ساده‌ترین عبارت، اینترنت اشیا به عنوان شبکه‌ای متشكل از میلیاردها دستگاه تلقی می‌شود که می‌تواند اطلاعات را حس کرده و فعال کند و به یک سامانه مرکز منقل کند. امروزه دستگاه‌ها و برنامه‌های IoT در حوزه‌های مختلفی مانند ترابری، خرد فروشی، مراقبت‌های بهداشتی، شبکه شهر هوشمند، حمل و نقل 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 آکنون از جمعیت جهان فراتر رفته و پیش‌بینی می‌شود تا سال ۲۰۲۵ به هشتاد میلیارد دستگاه برسد. به منظور اطمینان از قابلیت همکاری، مقیاس‌پذیری و قابلیت اطمینان سامانه‌های اینترنت اشیا بررسی دقیق‌تری از پشتۀ 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 بگیرید 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 به کار گرفته شده است می‌توان به شبکه عصبی مصنوعی<sup>۱</sup> [۹]، ماشین بردار پشتیبان<sup>۲</sup> [۱۰] و جنگل تصادفی<sup>۳</sup> [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 مرکز نشود. یک روش برای آن که خطای خروجی روش‌های یادگیری ماشین در تشخیص حملات کاهش داده شود، استفاده از انتخاب ویژگی<sup>۴</sup> 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<sup>۵</sup> [۱۳] و الگوریتم بهینه‌سازی ذرات<sup>۶</sup> [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 ارمه‌ماهی<sup>۷</sup> [۱۵] انجام می‌شود؛ سپس از طبقه‌بندی کننده 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 نویسنده‌گان در این مقاله در موارد زیر خلاصه شده است:

- ارائه یک نسخه دودویی از الگوریتم ارمه‌ماهی 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 ارمه‌ماهی در انتخاب ویژگی

<sup>۱</sup> Artificial neural network

<sup>۲</sup> Support vector machines (SVMs)

<sup>۳</sup> Random forest

<sup>۴</sup> Feature selection

<sup>۵</sup> Genetic algorithm

<sup>۶</sup> Particle swarm optimization algorithm

<sup>۷</sup> Sailfish optimization algorithm

<sup>8</sup> Internet Protocol Stack

<sup>9</sup> end-to-end communication

شخصی، لپتاپ‌ها، تلفن‌های همراه و تبلت‌ها) کل پشتۀ TCP/IP را بر اساس مدل اتصال سامانه‌های باز پیاده‌سازی می‌کند؛ با این حال، به دلیل منابع محدود موجود در IP دستگاه‌های اینترنت اشیا، بر حسب معمول یک پشتۀ IP سبک وزن 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 پشتۀ 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 به وسیله حسگرهای گردآوری کرده و به کمک 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.

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 به منظور اطمینان از مقیاس‌پذیری بازار است. به طور 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 پشتۀ 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



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

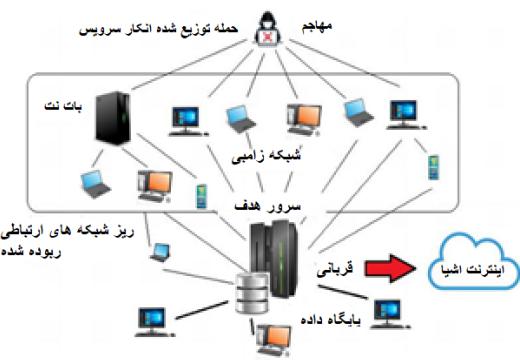
## ۲- حملات به شبکه اینترنت اشیا

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



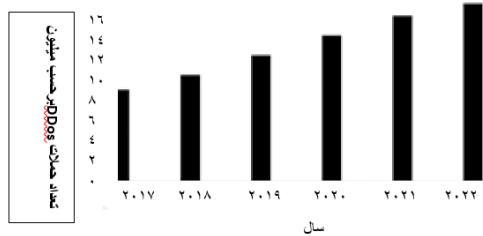
شکل-۲): سه معماری مطرح در اینترنت اشیا [۱۶]  
(Figure -2): three proposed architectures in the Internet of Things[16]

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 سیکو 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 سیکو 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 تریابیت 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 services in the Internet of Thing [19]



(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]

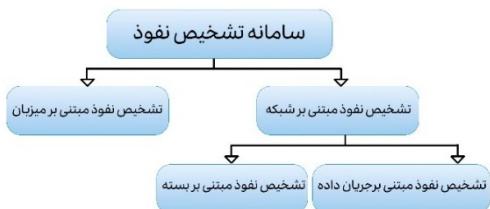
کمک می‌کنند، ویژگی‌های امنیتی ناچیز یا بسیار محدودی دارند؛ علاوه بر این، بسیاری از دستگاه‌های اینترنت اشیا دارای یک کلید ثابت یا نام کاربری و رمز عبور پیش‌فرض با کد سخت هستند که کاربر نمی‌تواند آن‌ها را تغییر دهد. این تله‌های امنیتی، بهره‌برداری از این دستگاه‌های نامن اینترنت اشیا و کنترل آن‌ها را برای هکرها آسان می‌کند. روندهای اخیر نشان می‌دهد که با افزایش سریع تعداد دستگاه‌های نامن اینترنت اشیا، حملات سایبری روزبه‌روز 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 امنیت ضعیف یا آسیب‌پذیر را جستجو 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 دهنند. 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 ظهر 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 تقليد‌کنندگان 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 AWS، GitHub 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

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

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؛ درنتیجه، 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 امکان پذیر است [۲۷].



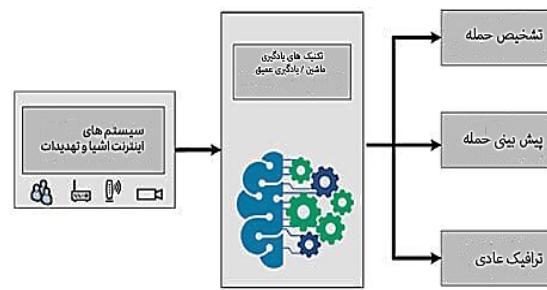
(شکل-۶): دسته‌بندی انواع سامانه‌های تشخیص نفوذ [۲۷]  
(Figure-6): Classification of types of intrusion detection systems [27]

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 مجموعه‌داده NSL-KDD نشان داد که مدل پیشنهادی دقیق 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 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 خطأ 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 مجموعه‌داده NSL-KDD،

حمله است. مژول 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 مژول جمع‌آوری داده‌ها، ترافیک ورودی هر بخش از اینترنت اشیا را می‌توان جمع‌آوری و بررسی کرد تا ترافیک عادی از ناهنجاری یا حمله شناخته شود. مژول 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 نرم‌افزار یا مشکوک قرار داده شود.

## ۴-۲- 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

فصلنامه



پژوهش به کار رفته 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 دقیق 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. چهار چوب پیشنهادی با چهار مجموعه داده سامانه تشخیص نفوذ در دسترس عموم، یعنی 2012 DDoS، ISCX-IDS، CICIDS2017 و CICIDS2018 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 دوستطحی امن را بر اساس یک شبکه بهبودیافتدۀ 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 پیشنهاده 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 CICIDS2017 استفاده شده است. نتایج نشان می‌دهد که مدل یادگیری عمیق در پیش‌بینی حملات با مجموعه داده‌های CICIDS2017 عالی بود و نرخ از دستدادن دقت ۱۰۲.۰۰٪ است.

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

BoT-IoT UNSW-NB15 و CICIDS-2017 شده است. نتایج آزمایش‌ها نشان داد سامانه تشخیص نفوذ آنها از روش‌های بهینه‌سازی ذرات و کلونی زنبور عسل در مرحله انتخاب ویژگی دقیق تر 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 انباسته-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 دستدادن 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 فرالبتکاری 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 [۴۰] یک سامانه تشخیص نفوذ شبکه مبتنی بر یادگیری عمیق با استفاده از استراتژی بهینه‌سازی آشوفته<sup>۲</sup> ارائه شده است. پس از پیش‌پردازش، مجموعه‌داده‌های نامتعادل با استفاده از رویکرد نمونه‌گیری مصنوعی توسعه یافته متعادل می‌شوند و پس از متعادل‌سازی، ویژگی‌های مجموعه‌داده 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 مجموعه‌داده TON-IOT برای ارزیابی استفاده می‌شود. نتایج آزمایش‌ها نشان می‌دهد که مدل پیشنهادی در مجموعه‌داده TON-IOT به دقت ۹۸.۷۶ درصد دست یافته است. در جدول (۱)، کارهای مرتبط با تشخیص حملات با مزايا 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 جستجو 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 مجموعه‌داده، 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 مجموعه‌داده‌های 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 اردهای 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<sup>۳</sup> [۴۱] بهبود داد. دلیل استفاده از الگوریتم AOA

<sup>2</sup> Chaotic Honey Badger

<sup>3</sup> Archimedes optimization algorithm

در شبکه اینترنت اشیا ارائه شده است. در این مطالعه تکnik بهینه‌سازی سلسه‌مراتب شرکتی<sup>۱</sup> برای انتخاب ویژگی‌های مهم از پایگاه‌های داده استفاده می‌شود. راه حل پیشنهادی مبتنی بر بهینه‌سازی عقاب طلایی سیستم فازی چندلایه پرسپترون رابط فازی حریم خصوصی و امنیت را در زیرساخت شبکه حرفای بهبود می‌بخشد. آن‌ها روش خود را روی دو مجموعه‌داده NSL-KDD و UNSW-NB15 اجرا و بررسی کردند 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

پژوهش	روش	مزایا	معایب
[28]	الگوریتم بهبود یافته گرگ حاکستری همراه با انتخاب Random ویژگی و Fores	بهبود سرعت طبقه‌بندی دقیق بالا کاهش نرخ خطای منفی کاذب (FN) و مثبت کاذب (FP)	عدم آزمون روی داده‌های دنیای واقعی و جدی
[29]	ترکیبی از الگوریتم PCA + شبکه عصبی (CNN) + پیچشی یادگیری عمیق	کاهش ابعاد داده ورودی اندک دقیق بالا	مدل پیچیده
[30]	ترکیب الگوریتم بهینه‌سازی ذرات و بهینه‌ساز پرده‌گان و گوریل	از روش‌های زمان افزایش سربار انتخاب ویژگی	دقیق تر است
[31]	تقویتی و انتخاب ویژگی انتخاب ویژگی مبتنی بر یادگیری تقویتی عمیق	هشتاد درصد از ویژگی هل اضافی را حذف می‌کند	عدم انتخاب ویژگی هوشمندانه
[32]	مدل گیری عمیق LSTM: انباسته:	دقیق بالا	عدم متعادل‌سازی مجموعه‌داده
[33]	نمونه‌گیری مجدد داده‌ها با یادگیری عمیق	متعادل‌سازی مجموعه‌داده و افزایش دقیق یادگیری	عدم انتخاب ویژگی هوشمندانه
[34]	مدل‌هایی LSTM, GRU و RNN	دقیق بالا	پیچیدگی مدل قابل توجه است
[35]	شبکه عصبی پیچیده عمیق	دقیق بیشتر از CNN	عدم تعادل مجموعه‌داده و عدم کاهش ابعاد ورودی بدون انتخاب ویژگی هوشمندانه
[36]	تشخیص نفوذ خودکار مبتنی بر SDN با یادگیری عمیق	دقیق تشخیص ۹۶ درصد و دقیق ۹۸.۴ درصد	عدم بهینه‌سازی پارامترها
[37]	تشخیص حملات مبتنی بر یادگیری عمیق با پایه‌گذاری LSTM	دقیق GRU و LSTM در تشخیص حملات ترکیبی	عدم تشخیص حملات در زمان واقعی
[38]	متعادل‌سازی ترافیک شبکه با روش SMOTE	نرخ ازدستدادن اندک در حدود ۰.۰۱۰۲ است	متعادل‌سازی به SMOTE روش ضعیف است
[39]	تکیک بهینه‌سازی سلسه‌مراتب شرکتی و یادگیری عمیق فازی PSO	دقیق بیشتر از GA الگوریتم	قطعیت کم در روش‌های فازی
[40]	یادگیری عمیق با استفاده از استراتژی بهینه‌سازی آشفته	دقیق مدل پیش‌بینی ۹۸.۷۶ درصد	عدم تعادل ویژگی مجموعه‌داده

<sup>1</sup> Corporate Hierarchy optimization (CHO)

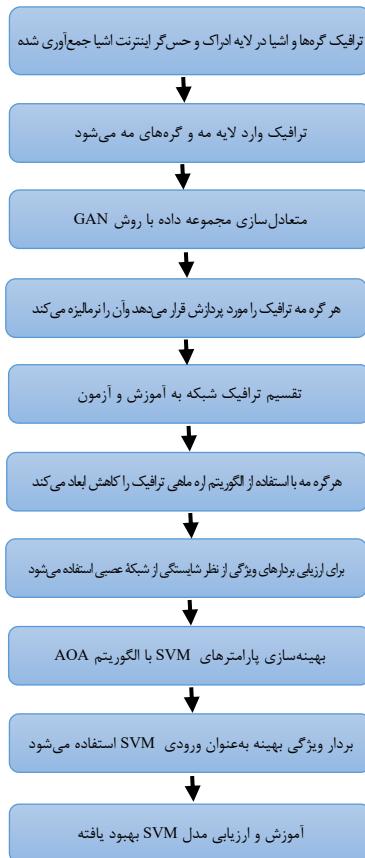
عادی باشد. هدف از متعادل‌سازی آن است که خطای طبقه‌بندی مدل یادگیری یا SVM کاهش داده شود.

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 ارمه‌های 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 فرالبتکاری بر پایه عملیات ریاضی استفاده می‌شود. هدف آن است که پارامترهای مانند نرخ خطای خطا و جریمه در SVM با روش فرالبتکاری 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 ارمه‌های 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 ارمه‌هایی در مرحله انتخاب ویژگی به شرح زیر خلاصه می‌شود:

▪ مسئله انتخاب ویژگی برخلاف 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 ارمه‌هایی با تقسیم جمعیت راه حل‌ها به دو دسته ارمه‌های و ساردنین می‌تواند بین جست‌وجوی اکتشافی یا سراسری و جست‌وجوی بهره‌برداری یا محلی توازن ایجاد کند.

الگوریتم ارمه‌هایی از الگوریتم‌های فرالبتکاری رایج مانند بهینه‌سازی ذرات، الگوریتم خفash 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 چهار مرحله اصلی زیر برای تشخیص حملات به شبکه با استفاده از تئوری بازی و یادگیری عمیق مبتنی شبکه GAN

▪ ارائه یک نسخه دودویی و انتخاب ویژگی از الگوریتم ارمه‌هایی AOA

▪ بهینه‌سازی پارامترهای SVM با استفاده از الگوریتم 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.

### 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:

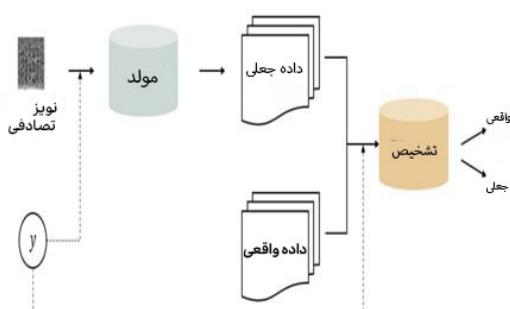
۱) ترافیک شبکه در لایه ادراک و حس‌گر تولید شده و این ترافیک برای گره‌های مه ارسال می‌شود. در روش پیشنهادی هر گره مه نقش یک سامانه تشخیص نفوذ به شبکه را بر عهده دارد.

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

- ۵) در تکرار نخست تعدادی بردار ویژگی تصادفی تعیین شده و هر کدام از این بردارهای دودویی یک عضو الگوریتم ارمه‌ماهی 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 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 بردار ویژگی بهینه آموزش و برای تشخیص حملات به کار گرفته می‌شود.

### ۳-۳- متعادل‌سازی مجموعه‌داده

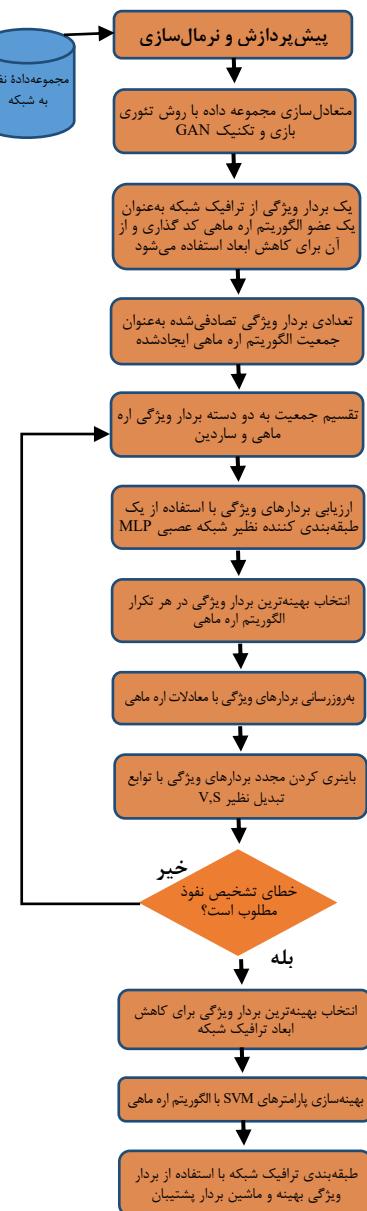
عدم تعادل در یک مجموعه‌داده زمانی اتفاق می‌افتد که تعداد نمونه‌های یک طبقه مانند طبقه حملات از طبقه عادی کمتر باشد. عدم تعادل مجموعه‌داده باعث می‌شود تا دقیق مدل‌های یادگیری عمیق و ماشین کاهش داده شود. یک روش برای متعادل‌سازی مجموعه‌داده تشخیص نفوذ که تعداد نمونه‌های حملات آن در کمترین حد است ایجاد نمونه‌های مصنوعی بر اساس نمونه‌های واقعی و اضافه کردن آنها به مجموعه‌داده است. برای متعادل‌سازی می‌توان از تئوری بازی مبتنی بر یادگیری GAN<sup>1</sup> 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]

<sup>1</sup> Generative adversarial network (GAN)

- بهینه‌سازی پارامترهای SVM با الگوریتم فرابتکاری AOA
- یادگیری ماشین بردار پشتیبان بر اساس ویژگی‌های مهم انتخاب شده



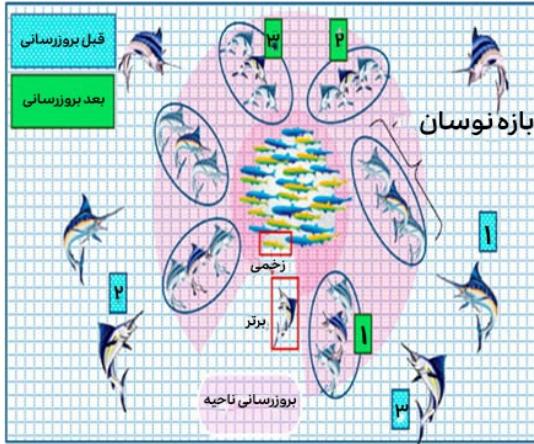
(شکل-۸): چهارچوب روش پیشنهادی برای تشخیص حملات  
 (Figure-8): Framework of the proposed method for detecting attacks

### ۲-۳- 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 مجموعه‌های از ترافیک شبکه به عنوان 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 به عنوان یک عضو الگوریتم ارمه‌ماهی کد گذاری می‌شود.

شایسته در نظر گرفت و ارهماهی‌ها را می‌توان جواب‌های غیر شایسته فرض کرد؛ ارهماهی‌ان برای باقتن غذا به سمت ساردين‌ها حمله می‌کنند و در مرتبه نخست سعی می‌کنند یک ماهی را زخمی کنند؛ سپس ماهی زخمی را مورد حمله و شکار قرار دهند. رفتار این الگوریتم را می‌توان در شکل (۱۰) مشاهده کرد.



(شکل-۱۰): حمله ارهماهی‌ان به سمت ساردين‌ها [۱۵]  
(Figure-10): Sawfish attack towards sardines [15]

در این مسئله هر بردار ویژگی یک ساردين‌ها یا ارهماهی است و از طرفی نصف جمعیت بردارهای ویژگی ارهماهی و نصف دیگر ساردين‌ها هستند. در این الگوریتم مشاهده می‌شود که ساردين‌ها از دست ارهماهی ان فرار کرده و نوعی جستجوی سراسری یا اکتشافی را انجام می‌دهند و در مقابل حمله ارهماهی ان به سمت طعمه یا ساردين زخمی نوعی جستجوی محلی است. علت استفاده از الگوریتم ارهماهی در انتخاب ویژگی به شرح زیر است: در ابتداء تعدادی بردار ویژگی به صورت اعضای الگوریتم بهینه‌سازی ارهماهی به عنوان یک الگوریتم فرالبتکاری مبتنی بر رفتار گروهی و دسته‌جمعی ارهماهی ان و ساردين‌ها در نظر گرفته شده و در اینجا یک بردار ویژگی  $F_k^i, F_1^i, F_2^i, \dots, F_k^i$  نشان‌دهنده عضو  $i$  الگوریتم ارهماهی است و در اینجا  $k$  برابر تعداد ویژگی‌های ممکن در مجموعه داده است. می‌توان یک جمعیت اولیه از بردارهای ویژگی که مقدار آنها صفر و یک است به عنوان ارهماهی و ساردين در نظر گرفت که در رابطه‌های (۱) و (۲) به ترتیب بردارهای ارهماهی و ساردين نمایش داده شده‌است:

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

در این رابطه  $SF$  جمعیت اولیه از بردارهای ویژگی از نوع ارهماهی و به تعداد  $m$  است که هر کدام از آنها دارای  $k$  ویژگی است. در رابطه (۲) نیز بردارهای ویژگی از نوع

GAN یک مدل یادگیری بدون نظارت مبتنی بر یادگیری عمیق است که داده‌های جعلی شبیه به داده‌های واقعی را با قراردادن یک شبکه عصبی (مولد، G) در مقابل دیگری (تمایزگر، D) تولید می‌کند. G با هدف تولید داده‌های جعلی شبیه داده‌های واقعی آموزش داده می‌شود، در حالی که D برای تعیین اینکه داده‌های ایجادشده به وسیله G در واقع جعلی‌اند آموزش داده می‌شود؛ به عبارت دیگر، G و D به روش خصمانه یاد می‌گیرند. شکل (۹)، ساختار GAN را نشان می‌دهد و نحوه یادگیری G و D را توضیح می‌دهد. ابتدا زمانی که G یک بردار نوفة تصادفی را به عنوان ورودی دریافت می‌کند، داده‌ها تولید می‌شوند. هنگامی که داده‌های تولیدشده و واقعی در اختیار D قرار می‌گیرد، واقعی یا جعلی بودن آنها را مشخص می‌کند. G و D برای این نتیجه رقابت می‌کنند و از آن درس می‌گیرند؛ به عبارت دیگر، هدف G به حداقل رساندن احتمالی است که D داده‌های تولیدشده را واقعی تعیین می‌کند؛ در حالی که هدف D این است که احتمال تشخیص داده‌های تولیدشده را به عنوان جعلی به بیشترین حد برساند. معادله (۱) تابع هدف GAN را برای این فرایند یادگیری نشان می‌دهد:

(۱)

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

در معادله  $p_{\text{data}}(x)$  و  $p_z(z)$  به ترتیب به داده‌های واقعی و جعلی اشاره دارند. D داده  $x$  را به عنوان مقدار ورودی داده واقعی دریافت می‌کند و احتمال واقعی بودن داده را خروجی می‌دهد.  $D(x)$  یک بردار نوفة تصادفی را به عنوان مقدار ورودی می‌گیرد و داده‌های جعلی تولید می‌کند ( $z$ ). از آنجایی که هدف D تشخیص مؤثر بین داده‌های جعلی تولیدشده و داده‌های 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 داده‌های جعلی تولیدشده و داده‌های 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 حداقل رساندن از منظر D و کمینه سازی از دیدگاه G است.

### ۴-۳-انتخاب ویژگی پیشنهادی

الگوریتم ارهماهی از رفتار ارهماهی ان و شکار ساردين‌ها الگوبرداری شده‌است. در این الگوریتم راه حل‌های مسئله می‌توانند ساردين یا ارهماهی باشند. در الگوریتم نصف جمعیت به صورت ساردين است و نصف دیگر راه حل‌ها به صورت ارهماهی است. ساردين‌ها را می‌توان جواب‌های

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 انتخاب شده در بردار ویژگی است که اندازه آن برابر  $|Dim|$  است و همچنین  $\alpha$  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 این چالش را در روش پیشنهادی کمزنگ می‌کند.

هر بردار ویژگی که این تابع را کمینه کند اگر از نوع ساردين باشد به عنوان ساردين زخمی و اگر از نوع ارهماهی باشد آنگاه به عنوان بهینه‌ترین ارهماهی برای حمله به دسته ماهیان ساردين در نظر گرفته می‌شود. می‌توان بردارهای ارهماهی و ساردين 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:

(۵)

$$SF_{fitness} = \begin{bmatrix} CostFS(SF_{1,1}) & SF_{12} & \dots & SF_{1,k} \\ CostFS(SF_{2,1}) & SF_{22} & \dots & SF_{2,k} \\ \vdots & \vdots & \vdots & \vdots \\ CostFS(SF_{m,1}) & SF_{m,2} & \dots & SF_{m,k} \end{bmatrix} = \begin{bmatrix} F_{SF_1} \\ F_{SF_2} \\ \vdots \\ F_{SF_m} \end{bmatrix}$$

(۶)

$$S_{fitness} = \begin{bmatrix} CostFS(S_{1,1}) & S_{12} & \dots & S_{1,k} \\ CostFS(S_{2,1}) & S_{22} & \dots & S_{2,k} \\ \vdots & \vdots & \vdots & \vdots \\ CostFS(S_{n,1}) & S_{n,2} & \dots & S_{n,k} \end{bmatrix} = \begin{bmatrix} F_{S_1} \\ F_{S_2} \\ \vdots \\ F_{S_n} \end{bmatrix}$$

در روش پیشنهادی، بردار ویژگی از نوع ساردين که بهینه‌ترین بردار ویژگی از نوع ساردين‌هاست 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:

(۷)

$$F_{new\_SF}^i = F_{elite\_SF}^i - \lambda_i \left( rand(0,1) \cdot \frac{(F_{elite\_SF}^i + F_{injured\_S}^i)}{2} - F_{old\_SF}^i \right)$$

در این رابطه،  $F_{new\_SF}^i$  بردار ویژگی به روز شده یک ارهماهی،  $F_{elite\_SF}^i$  بردار ویژگی بهینه‌ترین ارهماهی،  $F_{injured\_S}^i$  بهینه‌ترین بردار ویژگی از نوع ساردين،  $F_{old\_SF}^i$  موقعیت قبلی یک بردار ویژگی از نوع ارهماهی،

ساردين 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:

$$S = \begin{bmatrix} S_{1,1} & S_{12} & \dots & S_{1,k} \\ S_{2,1} & S_{22} & \dots & S_{2,k} \\ \vdots & \vdots & \ddots & \vdots \\ S_{n,1} & S_{n,2} & \dots & S_{n,k} \end{bmatrix} \quad (۲)$$

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

$$CostFS = \alpha \cdot \gamma_R(D) + \beta \frac{|R|}{|N|} \quad (۳)$$

یک بردار ویژگی نیاز به ارزیابی دقیق دارد تا مشخص شود که تا چه اندازه شایستگی دارد. برای ارزیابی بردارهای ویژگی دو شاخصه 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 به عنوان یک تابع هدف ارائه داد. برای سنجش خطای تشخیص حملات به وسیله 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 مجموعه‌داده نگاشت داده می‌شود به‌گونه‌ای که اگر مؤلفه زام بردار ویژگی  $FS_i$  دارای مقدار یک است از ویژگی زام به عنوان 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 ساردين نیاز به یک تابع هدف مناسب است که این تابع در رابطه (۴) ارائه شده است [۴۳]:

$$Cost(FS_i) = \alpha \cdot E(FS_i) + \beta \frac{|FS_i|}{|Dim|} \quad (۴)$$

فصلنی



ممکن است این مقادیر را از حالت دودویی خارج کنند، توابع و V برای نرمال‌سازی و بازگرداندن آن‌ها به بازه [۰,۱] 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 [۰,۱] نرمالیزه کرد و سپس آن را به عدد ۰ یا یک نگاشت داد؛ برای مثال اگر عدد هشت به عدد ۴ نرمال شود؛ چون به صفر نزدیک‌تر است می‌توان آن را صفر در نظر گرفت (ویژگی انتخاب نشده‌است) و اگر عدد هشت به ۷ نرمالیزه شود می‌توان آن را به یک تبدیل کرد (ویژگی انتخاب شده)؛ زیرا ۷ به یک نزدیک‌تر است تا صفر. بعد از نرمال‌سازی مقادیر بردارهای ویژگی با استفاده از توابع انتقالی S و V می‌توان با اعمال آستانه ۰.۵ و بر اساس روابط (۱۰) و (۱۱)، مقادیر هر عنصر در بردار را دوباره به حالت صفر یا یک تبدیل کرد [۱۶]:

(۱۰)

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

(۱۱)

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

در اینجا، تابع نگاشت و تبدیل می‌تواند از نوع S یا V باشد و FS<sub>i</sub> یک بردار ویژگی است.

### ۳-۵-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 به گونه‌ای بین دو طبقه داده‌ها قرار داده شود که کمترین خطأ در طبقه‌بندی به وجود آید. در شکل (۱۱) در این روش خط C به عنوان خط طبقه‌بندی‌کننده به کار 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 این که تعداد کمتری از نمونه‌ها به اشتباہ در دو طبقه قرار داده شوند.

در شکل (۱۲) در این روش خط C به عنوان خط طبقه‌بندی‌کننده به کار 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 این که تعداد کمتری از نمونه‌ها به اشتباہ در دو طبقه قرار داده شوند.

rand(0,1) عدد تصادفی یکنواخت بین صفر و یک، λ<sub>i</sub> ضریب هم‌گرایی در تکرار i-ام است که مرتب کاهش خواهد یافت. هر بردار ویژگی از نوع ساردين نیز می‌تواند تحت تأثیر فوار به روزرسانی شود و برای این منظور از رابطه (۸) استفاده می‌شود:

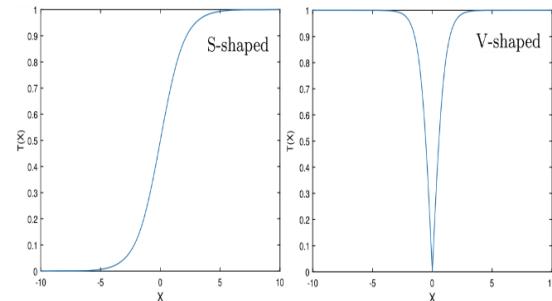
(۸)

$$F_{new\_S}^i = rand(0,1). (F_{elite\_SF}^i - F_{old_S}^i + AP)$$

در این رابطه F<sub>old\_S</sub><sup>i</sup> و F<sub>new\_S</sub><sup>i</sup> به ترتیب موقعیت جدید یک بردار ویژگی از نوع ساردين و موقعیت پیشین آن بردار ویژگی برای تشخیص حملات به اینترنت اشیا است. در این رابطه، AP را توان حمله ارمه‌های ان می‌گویند که می‌توان آن را از رابطه (۹) محاسبه کرد:

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

A و ε پارامترهای ثابت و اولیه توان حمله برای به روزرسانی بردارهای ویژگی از نوع ساردين در نظر گرفته می‌شوند. هر بردار ویژگی از نوع ساردين یا ارمه‌های به ترتیب تحت تأثیر مکانیزم فوار و حمله به روزرسانی 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 کنند. در شکل (۱۱)، دوتابع کاربردی نوع V و S که برای تبدیل فضای ویژگی به کار گرفته می‌شوند نمایش داده شده‌است.



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 درواقع دارای بردی محدود به بازه [-۱, ۱] است و می‌تواند اعداد پیوسته بردارهای ویژگی را به این بازه نگاشت دهنده. 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 ارمه‌های شامل مقادیر دودویی صفر و یک هستند که به ترتیب نشان‌دهنده عدم انتخاب و انتخاب ویژگی‌اند؛ از آن‌جا که به روزرسانی‌ها

$$(w \times \Phi(x_i)) \geq \rho - \xi i = 1, 2, \dots, l \xi i$$

$\geq 0$

اگر  $w$  و  $\rho$  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 خطای و ضریب جریمه را به عنوان یک عضو جمعیت الگوریتم فرالبتکاری در نظر گرفت و سپس در ادامه با این الگوریتم فرالبتکاری، 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:

$$(17)$$

$$MOA(C\_Iter) = Min + C\_Iter \times \left( \frac{Max - Min}{M\_Iter} \right) \quad (18)$$

$$MOP(C\_Iter) = 1 - \frac{C\_Iter^{\frac{1}{\alpha}}}{M\_Iter^{\frac{1}{\alpha}}}$$

و  $Min$  و  $Max$  به ترتیب بیشینه و کمینه پارامترهای MOP و MOA است.  $C\_Iter$  شمارنده تکرار الگوریتم MOA است و  $M\_Iter$  بیشترین تکرار این الگوریتم است. ضریب MOP بر حسب پارامتر  $\alpha$  تعیین و ضریب آلفا در حدود پنج تنظیم می‌شود. برای انجام جستجوی اکتشافی از معادله (۱۹) استفاده می‌شود. یک عدد تصادفی بین صفر و یک برای هر راه حل تولید می‌شود و اگر این عدد تصادفی کمتر از  $5\%$  باشد از عمل‌گر تقسیم و در غیراین صورت از عمل‌گر ضرب برای بهروزرسانی پارامترهای SVM استفاده می‌شود:

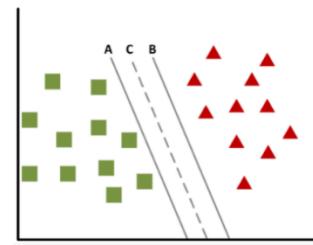
$$(19)$$

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

بهینه‌ترین راه حل یا بهینه‌ترین پارامترهای  $best(x_j)$  است.  $UB_j$  و  $LB_j$  به ترتیب محدود بالا و پایین بعد از یک مجموعه پارامتر SVM است.  $\mu$  یک پارامتر و ثابت عددی است.  $\varepsilon$  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

طبقه‌بندی کننده SVM نمونه‌ها را به یک فضای مشخصه ابعادی بزرگ (از طریق یک هسته) تبدیل و مکان مناسب ابرصفحه<sup>۱</sup> 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 قاعدة  $f$  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 به‌گونه‌ای 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 نگاشت شده 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 جاکردن مجموعه داده از مبدأ باید مسئله برنامه‌نویسی درجه دوم رابطه (۱۴) را حل کند:

$$(14)$$

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

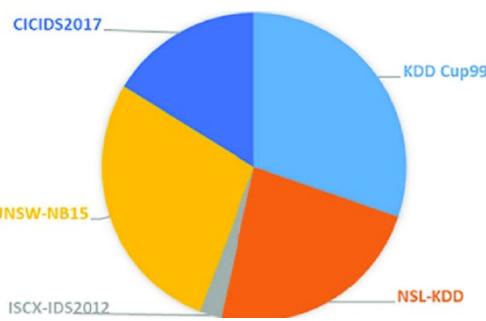
$$(w \times \Phi(x_i)) \geq \rho - \xi_i = 1, 2, \dots, l \xi i \geq 0$$

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

$$(15)$$

<sup>۱</sup> Hyperplane

- 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 رسدند 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 زیر حمله است. در حملات نوع پویشی مهاجم اطلاعاتی را به کمک پویش<sup>۴</sup> 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<sup>۵</sup> 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 NSL-KDD و 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 NSL-KDD در میان سایر مجموعه داده های تشخیص نفوذ [۲۲]  
 (Figure-13): Share of NSL-KDD dataset among other intrusion detection dataset[22]

<sup>4</sup> Scan  
<sup>5</sup> Social engineering

## 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<sup>۱</sup> و همکاران با آنالیز اطلاعات رو بدل 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؛ درکل 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 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<sup>۲</sup>: این گروه از ویژگی ها در واقع تمام ویژگی هایی را که می تواند از یک ارتباط و ترافیک TCP-IP<sup>۳</sup> 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.

<sup>1</sup> Stolfa

<sup>2</sup> Basic features

<sup>3</sup> Transmission Control Protocol-Internet Protocol



(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 متقطع 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؛ درنهایت نتایج حاصل از هر مرحله اعتبارسنجی برای تولید تخمین قوی‌تری از عملکرد مدل میانگین می‌شود. اعتبارسنجی متقطع مرحله مهمی در فرایند یادگیری ماشین است و به اطمینان از این‌که مدل انتخاب شده برای استقرار قوی است و به خوبی به داده‌های جدید تعمیم می‌باید کمک می‌کند. در روش پیشنهادی از اعتبارسنجی متقطع با  $k=10$  استفاده می‌شود. تعداد رکوردهای به کاررفته برای ارزیابی آزمایش‌ها پنجاه‌هزار 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 ارهماهی 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<sup>۸</sup>، بازگشتی<sup>۹</sup>، چند

<sup>8</sup> Linear  
<sup>9</sup> RBF

### ۴-۴-شاخص‌های ارزیابی

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

<sup>1</sup> Accuracy

<sup>2</sup> Sensitivity

<sup>3</sup> Precision

<sup>4</sup> True positive(TP)

<sup>5</sup> True negative(TN)

<sup>6</sup> False positive(FP)

<sup>7</sup> False negative(FN)



حساسیت و صحت بهترین ترتیب تا حدود ۹۸.۸۳ درصد، ۹۸.۲۴ درصد و ۹۸.۱۶ درصد کاهش خواهد یافت. علت آن که 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 تشخیص نفوذ 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 تصمیم‌گیری J48، جنگل تصادفی RF و شبکه عصبی چندلایه MLP مورد مقایسه قرار گرفته و ارزیابی شده است. 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 بهترین 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 GA، LSTM-RNN، LSTM، AE-CNN، CNN-LSTM، ELM و CNN-ELM در شاخص دقت مقایسه شده است. آزمایش‌ها نشان می‌دهند دقت AE-CNN، CNN-LSTM، GA-ELM، LSTM-RNN، LSTM و ELM برای تشخیص حملات بهترین برابر ۹۳.۹۹ درصد، ۹۹.۷۰ درصد، ۹۶.۹۳ درصد، ۹۸.۹۰ درصد، ۹۴.۱۱ 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 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 شده است تا یادگیری روی ویژگی‌های اساسی انجام شود که در شکل (۱۹) قابل مشاهده است.

جمله‌ای<sup>۱</sup> و گوسین<sup>۲</sup> استفاده می‌شود. در جدول (۲)، متوسط شاخص‌های دقت، حساسیت و صحت روش پیشنهادی بهازای کرنل‌های مقایسه شده است. در نمودار شکل (۱۵)، شاخص دقت، حساسیت و صحت روش پیشنهادی بهازای کرنل‌های مختلف نمایش داده شده است. آزمایش‌ها در محیط برنامه‌نویسی متلب نشان می‌هد، دقت، حساسیت و صحت روش پیشنهادی بهازای کرنل گوسین بیشترین مقدار ممکن است و دارای مقدادر 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 بهترین ترتیب تا حدود ۹۸.۸۳ درصد، ۹۸.۲۴ درصد و ۹۸.۱۶ درصد کاهش خواهد یافت. علت آن که 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 شده است، 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 شده است. ارزیابی‌ها نشان می‌دهند دقت روش پیشنهادی بهدلیل انتخاب ویژگی دارای دقتی برابر ۹۹.۱۲ درصد است و این در حالی است که دقت روش درخت تصمیم‌گیری J48 بهترین 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 (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،

<sup>1</sup> Polynomial

<sup>2</sup> Gaussian

(جدول-۲): شاخص دقت، حساسیت و صحت بهازای کرنل‌های مختلف

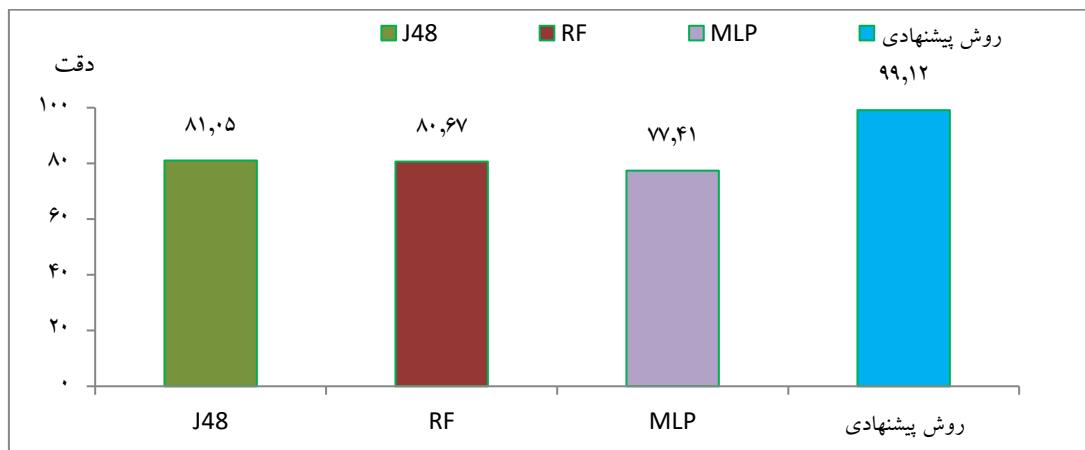
(Table-2): Accuracy, sensitivity and accuracy index for different kernels

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
گوسمین	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



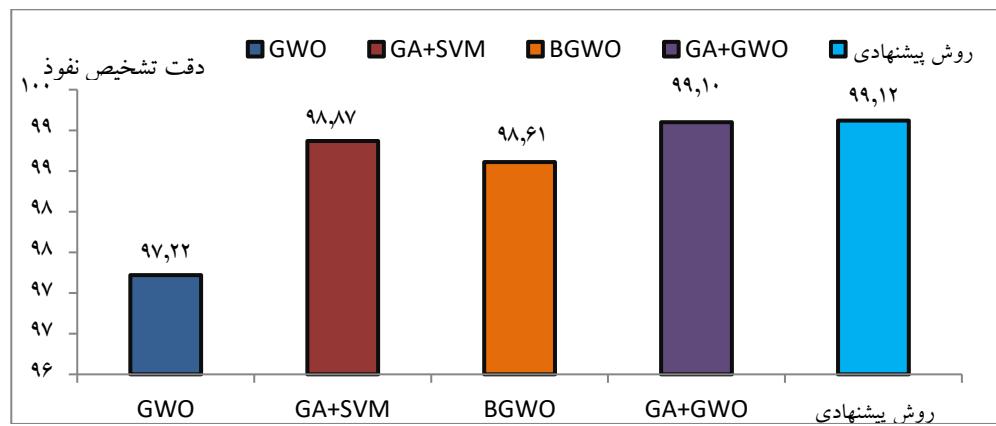
(شکل-۱۶): مقایسه دقت روش پیشنهادی با سه روش یادگیری ماشین

(Figure-16): Comparison of the accuracy of the proposed method with three machine learning methods



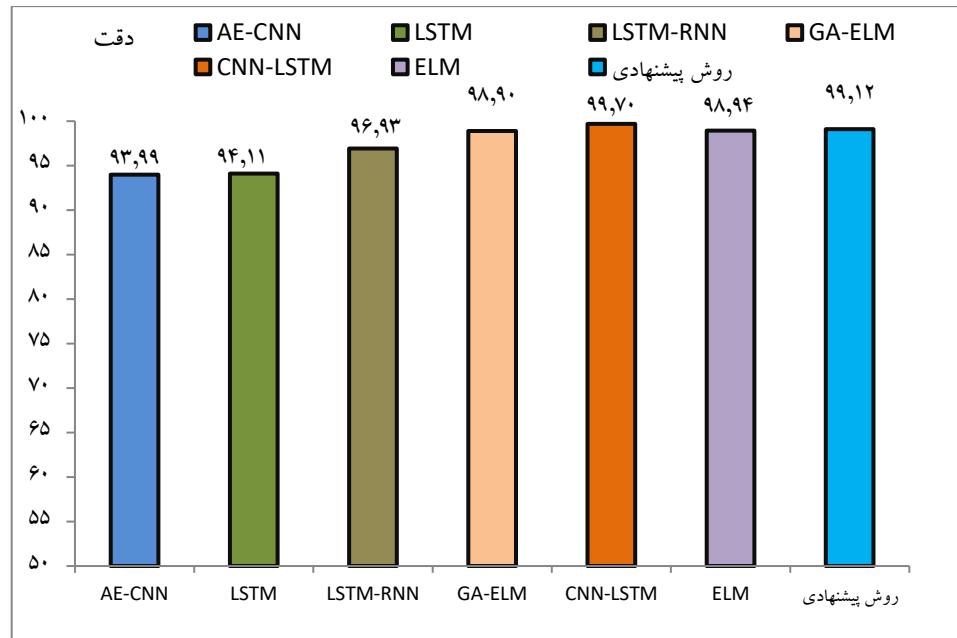
(شکل-۱۷): ارزیابی شاخص دقت، حساسیت و صحت روش پیشنهادی با کرنل‌های مختلف

(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 ظهرور و توسعه فناوری‌های فرایند کسب و کار جدید را از طریق شبکه‌ای از رایانه‌ها و دستگاه‌هایی که قادر به برقراری ارتباط و تعامل با یکدیگرند، ممکن کرده است. در آنجا که تعداد حملات سایبری به سامانه‌های اینترنت اشیا به سرعت و به‌طور گسترده افزایش می‌یابد، افراد و کسب و کارها با طیف گسترده‌ای از چالش‌های مرتبه با اعتبر، 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 می‌کند. 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.

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

## 6-Reference

## 6-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. Ariantri, “Comparison between Support Vector

فنون  
ی



- [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، «[۲۸] ارائه یک مدل فراابتکاری تشخیص نفوذ به کمک انتخاب ویزگی مبتنی بر بهینه سازی گرگ حاکستری بهبودیافته و جنگل تصادفی»، *فصلنامه پژوهش علوم و داده‌ها*، دوره ۲۰، شماره ۱، ص ۱۳۳-۱۴۴، ۱۴۰۲.
- [29] 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 پژوهش علوم و داده‌ها*، دوره ۲۱، شماره ۳، ص ۲۲۳-۱۴۰۱.
- [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.
- [33] 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. Diaz, "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 دکترا مهندسی کامپیوتر نرمافزار دانشگاه آزاد واحد بیرجند است. زمینه پژوهشی ایشان شبکه حسگر بیسیم، یادگیری عمیق، شبکه عصبی و هوش مصنوعی و الگوریتم‌های فرآبتكاری است.  
نشانی رایانمۀ ایشان عبارت است از:

Z.sarhadi@iau.ac.ir



**مهردی 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 دکترا را در دانشگاه آزاد کرمان به پایان رسانده است. ایشان عضو هیأت علمی دانشگاه آزاد اسلامی واحد بیرجند و مدیرگروه دانشکده کامپیوتر این دانشگاه هستند. زمینه پژوهشی ایشان شبکه عصبی، هوش مصنوعی و یادگیری عمیق است.  
نشانی رایانمۀ ایشان عبارت است از:

Mkhazaiepoor@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.

فصلنامه

سال ۱۴۰۴ شماره ۲ پیاپی ۶۴

۶۴

