

# Improving the Accuracy of the Intrusion Detection System in the IoT by Machine Learning and Clustering Algorithms

Javad Pashaei Barbin<sup>1\*</sup>, Mahdi Jalali<sup>2</sup>

1. Assistant Professor, Department of Computer Engineering, Naghadeh Branch, Islamic Azad University, Naghadeh, Iran. \*Corresponding Author, [javad.pashaei@iaui.ac.ir](mailto:javad.pashaei@iaui.ac.ir)
2. Assistant Professor, Department of Electrical Engineering, Naghadeh Branch, Islamic Azad University, Naghadeh, Iran.

## Abstract

**Introduction:** The recent rise of the Internet of Things (IoT) has led to increasing attacks in IoT. Manufacturers of IoT devices are interested in reducing costs by ignoring security regulations that cause widespread damage and impede the growth of the IoT. The proliferation of IoT-based attacks will continue as long as IoT manufacturers incorporate accountability and security mechanisms into their devices. The proliferation of IoT-based attacks will continue as long as IoT manufacturers incorporate accountability and security mechanisms into their devices. Until then, the Internet of Things has the potential to become an environment for future cyber-attacks, which will pose great challenges.

**Method:** In this research, the solutions for establishing security in the Internet of Things have been investigated and have provided a solution based on the combination of support vector machine and K-means algorithm. First, preprocessing is applied to the data set and the data that has no effect on the result are deleted. Then, the support vector machine algorithm is applied to the data set and the intrusion or non-intrusion status is determined. This proposed method achieves better results by applying k-means to the data set, and the combination of support vector machine algorithms and k-means improves the accuracy of the proposed method.

**Results:** The results showed that the proposed method is more efficient than previous methods. this study sought to improve the security challenge in wireless sensor networks. The proposed method of this research is to use a combination of support vector machine and chi-mean, which showed very good performance compared to previous methods. According to the studies and the proposed method, it can be found that the best method in detecting and detecting intrusion is the use of K-Means algorithm, which can be achieved with 98.35% accuracy using the support vector machine method and K-Means algorithm.

**Discussion:** The most important criterion for determining the performance of an algorithm is the Accuracy criterion. This criterion calculates the total accuracy of a category. This criterion indicates what percentage of the total data set is properly categorized. This criterion is the evaluation based on the accuracy and the accuracy of the proposed method is better than the previously presented methods.

**Keywords:** Intrusion detection, Machine Learning, Data Mining, Support vector Machine, K-Means.

## بهبود دقت سیستم تشخیص نفوذ در اینترنت اشیا با استفاده از الگوریتم‌های یادگیری ماشین و خوشه‌بندی

دوره پنجم، پاییز ۱۴۰۳  
شماره دوم، صص: ۵۷-۵۴

تاریخ دریافت: ۱۴۰۳/۰۴/۰۲  
تاریخ پذیرش: ۱۴۰۳/۰۵/۱۳

جواد پاشائی بارین<sup>۱\*</sup>، مهدی جلالی<sup>۲</sup>

۱- استادیار، گروه کامپیوتر، واحد نقده، دانشگاه آزاد اسلامی، نقده، ایران. (نویسنده مسئول)

[javad.pashaei@iau.ac.ir](mailto:javad.pashaei@iau.ac.ir)

۲- استادیار، گروه برق، واحد نقده، دانشگاه آزاد اسلامی، نقده، ایران.

**چکیده:** افزایش استفاده از اینترنت اشیا منجر به افزایش حملات در این شبکه‌ها شده است. سازندگان دستگاه‌های اینترنت اشیا علاقه‌مند به کاهش هزینه‌ها با نادیده گرفتن مقررات امنیتی هستند که باعث آسیب گسترده و مانع از رشد اینترنت اشیا می‌شود. گسترش حملات مبتنی بر اینترنت اشیا تا زمانی ادامه خواهد داشت که سازندگان اینترنت اشیا مکانیزم‌های پاسخگویی و امنیتی را در دستگاه‌های خود بگنجانند. تا آن زمان، اینترنت اشیا این پتانسیل را دارد که به محیطی برای حملات سایبری آینده تبدیل شود که چالش‌های بزرگی را به همراه خواهد داشت. از این رو، در این تحقیق راهکارهای برقراری امنیت اینترنت اشیا بررسی شده و راه‌حلی مبتنی بر ترکیب ماشین بردار پشتیبان و الگوریتم k-means ارائه شده است. نتایج نشان می‌دهد که دقت روش پیشنهادی 98.35 درصد است که کارآمدی روش پیشنهادی را نشان می‌دهد و قابلیت پیاده‌سازی برای تشخیص خطا به صورت عملی را دارد.

**واژه‌های کلیدی:** تشخیص نفوذ، یادگیری ماشین، داده‌کاوی، ماشین بردار پشتیبان، k-means.

## ۱. مقدمه

اینترنت اشیا برای اولین بار توسط کوین اشتون در سال ۱۹۹۹ استفاده شد که در آن همه چیز، از جمله اشیاء بی‌جان، هویت دیجیتالی خود را دارد و به رایانه‌ها اجازه می‌دهد تا آن‌ها را سازماندهی و مدیریت کنند. در آینده‌ای نه چندان دور، بسیاری از کاربردهای اینترنت اشیا در خانه‌های هوشمند، کارخانه‌های هوشمند، مزارع هوشمند، دفاتر هوشمند، سیستم‌های حمل و نقل هوشمند، بیمارستان‌های هوشمند، دانشگاه‌های هوشمند و غیره به هم متصل شده و توسط فناوری اطلاعات مورد استفاده قرار خواهند گرفت [۱].

اینترنت اشیا<sup>۱</sup> (IoT) در حال حاضر یک الگوی محبوب است که دنیایی را متصور می‌باشد که در آن انواع اشیاء فیزیکی به اینترنت متصل شده و قادر به برقراری ارتباط و همکاری با یکدیگر برای رسیدن به اهداف مشترک هستند. این ارتباط فراتر از ارتباطات ماشین به ماشین<sup>۲</sup> (M2M) است، زیرا تمام داده‌های سگرها یا فرستنده‌ها از طریق اینترنت یا اینترنت به سرورها ارسال می‌شوند و گیرنده‌ها (داشبورد یا برنامه‌ها) داده‌های مورد نیاز را از سرورها دریافت می‌کنند. در ارتباط ماشین به ماشین، دستگاه‌ها به یکدیگر متصل می‌شوند و عملاً داده‌های زیادی بین دستگاه‌ها رد و بدل نمی‌شود و جایی برای ذخیره داده‌ها وجود ندارد [۲]. با رشد روزافزون اینترنت اشیا و کاربردهای آن در جامعه، اهمیت امنیت اطلاعات به طور فزاینده‌ای به عنوان بخش کلیدی این حوزه مورد توجه قرار گرفته است. چالش‌ها در حوزه‌های امنیت و حریم خصوصی، از جمله مقاومت در برابر حمله، احراز هویت داده‌ها و کنترل دسترسی حریم خصوصی کاربران، باید در حین مطالعه مورد توجه قرار گیرند، در حالی که محدودیت‌های شدید در منابع محاسباتی، قدرت، حافظه مصرف انرژی، هزینه و ناهمگونی پروتکل‌ها و دستگاه‌ها نیز غالب هستند [۳]. یکی از رایج‌ترین حملات، حملات انکار سرویس<sup>۳</sup> (DOS) و حملات انکار سرویس توزیع شده<sup>۴</sup> (DDoS) است. تعداد حملات انکار سرویس در سال ۲۰۱۵ در سه ماهه اول سال نسبت به سال قبل ۳۴ درصد افزایش یافته و تعداد حملات به بیش از ۵ گیگابایت در ثانیه رسیده است. حملات به سرورهای وب‌سایت‌های مهم مانند توییتر، آمازون و نیویورک تایمز، باعث توجه بیشتر کارشناسان و متخصصان به این حملات شده است [۴].

ظهور اخیر اینترنت اشیا (IoT) منجر به افزایش حملات DDoS مبتنی بر اینترنت اشیا شده و با ظهور اینترنت اشیا (IoT) پتانسیل حملات DDoS افزایش یافته است. سازندگان دستگاه‌های اینترنت اشیا علاقه‌مند به کاهش هزینه‌ها با نادیده گرفتن مقررات امنیتی هستند که باعث آسیب گسترده و مانع از رشد اینترنت اشیا می‌شود. افزایش حملات DDoS مبتنی بر اینترنت اشیا، که در سال‌های اخیر شاهد آن بوده‌ایم، احتمالاً تا زمانی ادامه خواهد داشت که سازندگان اینترنت اشیا، مسئولیت و مکانیسم‌های امنیتی را در دستگاه‌های خود بگنجانند. تا

آن زمان، اینترنت اشیا پتانسیل تبدیل شدن به محیطی برای حملات سایبری آینده را دارد و چالش‌های بزرگی را ایجاد می‌کند [۵]. یکی دیگر از جنبه‌های مهم امنیت اینترنت اشیا، امنیت تجهیزات در دنیای واقعی است. افزایش عظیم حملات انکار سرویس توزیع شده در اینترنت اشیا، نگرانی‌های جدی را برای کاربران این شبکه‌ها به وجود آورده است. علاوه بر این، محدودیت‌های منابع محدودیت‌هایی را بر اقدامات امنیتی اعمال می‌کند که می‌تواند در دستگاه‌های هوشمند گنجانده شوند. این نیز یکی از نگرانی‌های جدی در مورد محیط اینترنت اشیا و انگیزه تحقیقات بیشتر در مورد سیستم‌های سبک وزن است [۶].

## ۲. مطالعات پیشین

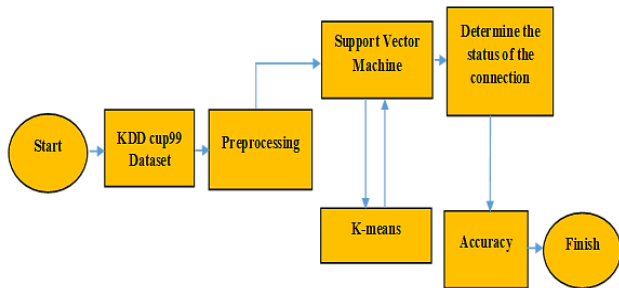
سال ۲۰۱۹، سهیب حنیف و همکاران روشی برای تشخیص نفوذ اینترنت اشیا با استفاده از شبکه‌های عصبی مصنوعی در مجموعه داده UNSW-15 ارائه کرده‌اند. دستگاه‌های اینترنت اشیا به دلیل قدرت کم، نیازهای محاسباتی پایین و محیط کنترل‌شده، با حملات سایبری زیادی مواجه می‌شوند. پیاده‌سازی سیستم تشخیص حمله بسیار دشوار است. این مقاله یک شبکه عصبی مصنوعی را برای شناسایی حملات IoT برای حل مشکلات احراز هویت پیشنهاد می‌کند. شبکه‌های عصبی مصنوعی شامل لایه‌های ورودی، خروجی و پنهان هستند. تکنیک پیشنهادی قادر به تشخیص موثر حملات است و دقت متوسط ۸۴٪ با میانگین ضریب خطای مثبت ۸٪ را ارائه می‌دهد [۷].

سال ۲۰۲۰، رحمان و همکاران یک سیستم تشخیص نفوذ مبتنی بر یادگیری ماشین برای شهرهای هوشمند با اینترنت اشیا معرفی کردند. با رشد دستگاه‌های متصل، استفاده از سیستم‌های تشخیص نفوذ افزایش یافته است. این مقاله محدودیت سیستم تشخیص نفوذ را برای دستگاه‌های با منابع محدود با پیشنهاد دو روش، به نام نیمه توزیع‌شده و توزیع‌شده، که استخراج ویژگی و انتخاب را ترکیب می‌کنند، توصیف می‌کند. به منظور توزیع وظایف محاسباتی، مدل‌های یادگیری ماشین موازی مبتنی بر مجموعه داده‌های حمله تقسیم‌بندی شده، توسعه داده شده‌اند. بر اساس مقایسه آثار موجود، نتایج عددی نشان می‌دهد که روش پیشنهادی دارای دقت تشخیص قابل مقایسه با سیستم‌های تشخیص نفوذ بوده و کارایی آن از نظر زمان و دقت بهتر است [۸].

نادیا چابونی و همکاران روشی را با استفاده از یادگیری ماشین لبه برای سیستم‌های تشخیص و پیشگیری از نفوذ ارائه دادند. در این مقاله، یک سیستم تشخیص و پیشگیری از نفوذ برای لایه سرویس توسط استاندارد oneM2M معرفی شده است. این یک سیستم تشخیص نفوذ برای خدمات oneM2M مبتنی بر یادگیری ماشین لبه است. تمرکز آزمایش‌ها بر کاهش ابعاد ویژگی‌ها در یادگیری ماشین و اندازه مدل‌های آموزشی است [۹].

سال ۲۰۱۹، عبدالعزیز الدیاز و همکاران روشی را با استفاده از الگوریتم‌های پیشگیری از نفوذ برای بهبود امنیت سایبری در اینترنت

پیشنهادی که مبتنی بر ترکیبی از روش‌های ماشین بردار پشتیبان و k-means در تشخیص نفوذ در اینترنت اشیا توضیح داده می‌شود. (شکل ۱)



شکل ۱: فلوچارت روش پیشنهادی

ابتدا پیش پردازش روی مجموعه داده اعمال شده و داده‌هایی که تأثیری در نتیجه ندارند، حذف می‌شوند. سپس الگوریتم ماشین بردار پشتیبان بر روی مجموعه داده اعمال شده و وضعیت نفوذ یا عدم نفوذ مشخص می‌شود. این روش پیشنهادی با اعمال k-means به مجموعه داده‌ها به نتایج بهتری دست می‌یابد و ترکیب الگوریتم‌های ماشین بردار پشتیبان و k-means دقت روش پیشنهادی را بهبود می‌بخشد.

### ۱.۳. مجموعه داده

با توجه به حجم بالای داده‌ها در پایگاه داده kdd.data\_10\_percent، از ۱۰ درصد رکوردها به‌عنوان نمونه آموزشی استفاده می‌شود. این پایگاه شامل ۴۹۴۰۲۱ رکورد ارتباطی است که شامل هر چهار نوع حمله ذکر شده می‌باشد. این چهار دسته از حملات شامل ۲۲ نوع حمله و یک حالت عادی است. علاوه بر این پایگاه داده، یک پایگاه داده آزمایشی نیز وجود دارد که شامل ۳۱۱۰۲۹ رکورد است که نشان‌دهنده ۳۷ نوع حمله و یک حالت عادی است. در نتیجه ۱۵ حمله بیشتر از پایگاه داده آموزشی دارد. شکل‌های ۲ و ۳ نحوه توزیع حملات در پایگاه داده را نشان می‌دهد. با توجه به نرخ پایین برخی از حملات نسبت به سایر حملات در پایگاه داده، در صد پراکندگی آن‌ها صفر است. شرح کامل ویژگی‌های مورد استفاده در پایگاه داده در جدول زیر قابل مشاهده است.

اشیا مدرن ارائه کردند. اینترنت اشیا یک الگوی به سرعت در حال تکامل است که پتانسیل تغییر تعاملات سازمان‌ها و افراد را دارد. این فناوری در زمینه‌های مختلف از جمله سلامت، یادگیری و آموزش، مدیریت منابع و پردازش اطلاعات کاربردهای فراوانی دارد. یک تکنیک پیشگیری برای بهبود امنیت سایبری در دستگاه‌های IoT در برابر حملات DDoS پیشنهاد شده است. رویکرد پیشنهادی مبتنی بر تجزیه و تحلیل حملات پهن باند است که در درجه اول بر روی DDoS تمرکز دارد و عملکرد شبکه را کاهش می‌دهد [۱۰].


در تحقیقی که اخیراً در زمینه عملکرد سیستم تشخیص نفوذ، به منظور بررسی تأثیر رفتار سیستم تشخیص سوء استفاده و همچنین تشخیص ناهنجاری با استفاده از منطق فازی مبتنی بر دستگاه آلفا ارائه شده است نتایج به دست آمده میزان دقت را تا ۹۱/۲۶ درصد و تشخیص هشدارهای کاذب را تا میزان ۹۰/۹۶ درصد نشان داده است [۱۱].

سال ۲۰۱۴، ناپاکی و کومار یک چارچوب تشخیص DDoS مبتنی بر میزبان به نام BRAIN، با در نظر گرفتن کوتاه‌ترین زمان شناسایی حملات DDoS، پیشنهاد کردند. این روش تشخیص DDoS بر اساس مدل تصمیم‌گیری تکامل مصنوعی فازی پیشنهاد شده است. آن‌ها همچنین چندین آزمایش را برای نشان دادن برتری مدل پیشنهادی خود نسبت به سایر الگوریتم‌های تشخیص DDoS انجام داده‌اند. در این مقاله حملات DDoS به سه سطح تقسیم می‌شود و که از این سطوح اطلاعات حمله برای شناسایی پارامترهای روش تشخیص DDoS استفاده می‌کنند. نتایج نشان می‌دهد که افزودن سخت‌افزار برای تشخیص به‌طور قابل توجهی دقت را افزایش می‌دهد. آن‌ها معتقدند که چارچوب پیشنهادی برای تشخیص DDoS کم هزینه، سازگار و بسیار دقیق با دقت ۹۹٫۸ درصد است [۱۲].

سال ۲۰۱۷، چانگ‌لانگ بین و همکاران نحوه مدل سازی سیستم تشخیص نفوذ مبتنی بر یادگیری عمیق را بررسی کردند و یک روش یادگیری عمیق برای تشخیص نفوذ با استفاده از شبکه‌های عصبی تکراری پیشنهاد کردند. علاوه بر این، آن‌ها عملکرد مدل را در کلاس‌های باینری و چندکلاسه و تعداد نوروها و تأثیرات یادگیری مختلف بر عملکرد مدل پیشنهادی مطالعه کرده‌اند. روش کار با شبکه‌های عصبی مصنوعی، جنگل‌های تصادفی، ماشین‌های بردار پشتیبان و سایر روش‌های یادگیری ماشینی پیشنهاد شده توسط محققان قبلی مقایسه شده است. نتایج تجربی نشان می‌دهد که مدل پیشنهادی برای مدل سازی یک مدل طبقه‌بندی با دقت بالا مناسب است و عملکرد آن بهتر از روش‌های طبقه‌بندی یادگیری ماشین سنتی می‌باشد [۱۳].


### ۳. روش پیشنهادی

پس از بررسی روش‌های مورد استفاده در سیستم‌های تشخیص نفوذ که عمدتاً روش‌های یادگیری ماشین هستند، در این بخش روش



شکل ۴: داده‌ها در فضای دوبعدی

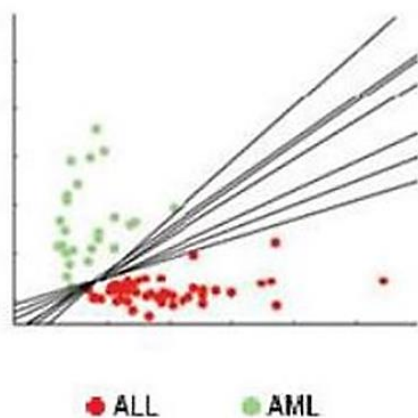
این دو کلاس را می‌توان با یک خط از هم جدا کرد که در شکل ۵ دیده می‌شود و بر این اساس تکلیف نقطه مجهول نیز مشخص می‌شود. این نقطه بخشی از کلاس ALL است.



شکل ۵: طبقه‌بندی خطی در فضای دوبعدی


۲.۲.۳. هایپرپلان با حداکثر حاشیه

هدف ماشین بردار پشتیبان جداسازی دو کلاس ALL و AML در فضای دوبعدی با یک خط است. خطوط زیادی وجود دارد که این کار را انجام می‌دهند. شکل ۶ نمای این خطوط را نشان می‌دهد.



شکل ۶: خطوط متمایزکننده دو کلاس

سوال این است که کدام یک از این خطوط بهتر از خطوط جداکننده دیگر است؟ الگوریتم SVM خط وسط را به عنوان ابر صفحه جداکننده



شکل ۲: پراکندگی حملات در پایگاه داده

Value	Proportion	%	Count
strurl	58.84		280790
neptune	21.7		107201
normal	19.60		97278
back	0.45		2203
saturn	0.32		1589
ipsweep	0.25		1247
portsweep	0.21		1046
warezclient	0.21		1020
teardrop	0.2		979
pool	0.05		264
nmap	0.05		231
guess_passwd	0.01		53
buffer_overflow	0.01		30
land	0.0		21
warezmaster	0.0		20
nmap	0.0		12
rootkit	0.0		10
loadmodule	0.0		9
ftp_write	0.0		8
multihop	0.0		7
phf	0.0		4
perl	0.0		3
spy	0.0		2

شکل ۳: نرخ و درصد حملات در پایگاه داده

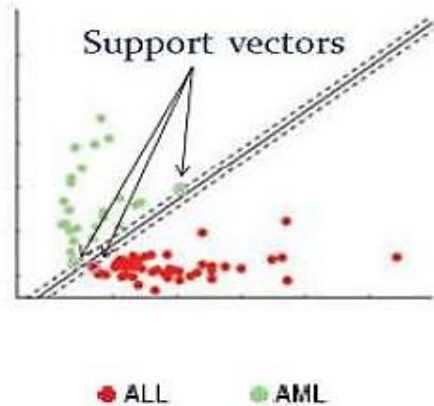
## ۲.۲.۳. ماشین بردار پشتیبانی

ماشین بردار پشتیبانی، که به اختصار SVM<sup>۵</sup> نامیده می‌شود، یک الگوریتم کامپیوتری است که به عنوان مثال نحوه اختصاص برجسب‌های مرتبط به اشیاء مختلف را یاد می‌گیرد. هدف این الگوریتم شنا سایی و تمایز الگوهای پیچیده در داده‌ها است که بسته به کاربرد در خوشه‌بندی، طبقه‌بندی، رتبه‌بندی، پاکسازی و غیره استفاده می‌شود. ماشین بردار پشتیبان به طور کلی از چهار مفهوم اساسی تشکیل شده است: ابر جداکننده، ابر حاشیه حداکثر، حاشیه نرم و عملکرد هسته.

### ۱.۲.۳. هایپرپلان جداکننده

هایپرپلان اساساً اصطلاحی است که فضای بالای سه بعدی را پوشش می‌دهد. در فضای یک بعدی هایپرپلان فقط یک نقطه، در فضای دوبعدی یک خط و در فضای سه بعدی یک صفحه و در فضای بیش از سه بعدی یک ابر صفحه است. اما برای راحتی، همه اینها هایپرپلان نامیده می‌شود. شکل ۴ را در نظر بگیرید، در این شکل در کلاس‌های ALL و AML فضای دوبعدی با ناحیه مربوط به ALL در پایین شکل و بالای شکل داریم. همچنین یک نقطه رنگی در نزدیکی کلاس ALL وجود دارد که کلاس آن مشخص نیست و باید طبقه‌بندی شود.

انتخاب می‌کند. به عبارت دیگر، خطی را انتخاب می‌کند که حداکثر فاصله را از هر کلاس داشته باشد. این خط در شکل ۷ مشاهده می‌شود.

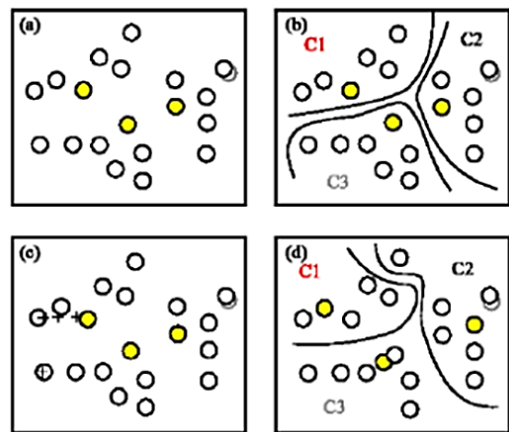


شکل ۷: خطوط متمایزکننده دو کلاس با استفاده از بردار پشتیبان

#### ۴. الگوریتم k-means

مراحل الگوریتم k-means به صورت زیر است:

- ۱- ابتدا K نقطه به عنوان نقاط مراکز خوشه انتخاب می‌شوند.
- ۲- هر نمونه داده به خوشه‌ای اختصاص داده می‌شود که مرکز آن کمترین فاصله را با آن داده دارد.
- ۳- سپس میانگین را محاسبه کرده و یک مرکز جدید برای هر خوشه قرار داده می‌شود.
- ۴- مراحل ۲ و ۳ تکرار می‌شود تا زمانی که دیگر تغییری در مراکز خوشه‌ها ایجاد نشود.



شکل ۸: فرآیند خوشه‌بندی با استفاده از k-means (الف) تعیین مرکزیت اولیه (ب) اختصاص نمونه‌ها (ج) محاسبه میانگین خوشه‌ها (د) خوشه‌های جدید

باتوجه به معایبی که این الگوریتم دارد می‌تواند در برخی از کاربردها پاسخ قابل قبولی ارائه دهد. این معایب عبارتند از: وابستگی به مراکز اولیه، وابستگی به تعداد خوشه‌ها و علف‌های هرز.

#### ۵. نتایج و بحث

ابتدا مشخصات سیستم کامپیوتری که شبیه‌سازی با آن انجام شده است معرفی و مجموعه داده‌ها شرح داده می‌شود، سپس پیاده‌سازی توصیف شده و در نهایت ارزیابی انجام کار ارائه می‌گردد.

##### ۱.۵. مشخصات سیستم

این پروژه بر روی سیستمی با مشخصات زیر انجام شده است:

CPU: سری Corei5 اینتل

ظرفیت حافظه رم: ۴ گیگابایت

ظرفیت هارد: ۵۰۰ گیگابایت

##### ۲.۵. معرفی مجموعه داده

در سال‌های ۱۹۹۸ و ۱۹۹۹، مجموعه استاندارد از داده‌ها برای مقایسه و ارزیابی سیستم‌های تشخیص نفوذ، از جمله انواع نفوذها در یک سیستم شبیه‌سازی شده نظامی توسعه یافت. داده‌های این پایگاه داده از داده‌های خام TCP در شبکه LAN نیروی هوایی ایالات متحده در طول ۹ هفته استخراج شده است. پایگاه داده به دست آمده بسیار بزرگ بوده و شامل یک بخش داده‌های آموزشی و یک بخش داده‌های آزمایشی است. بخش داده‌های آموزشی شامل تقریباً ۵ میلیون رکورد داده و بخش داده‌های آزمون شامل حدود ۲ میلیون رکورد داده است. در عمل ۱۰٪ از داده‌ها برای سیستم‌های تشخیص نفوذ استفاده می‌شود و این پایگاه داده به صورت kdd (data\_10\_percent) نمایش داده می‌شود. این پایگاه دارای ۵ نوع داده مختلف شامل ۴ نوع حمله و یک سری داده معمولی می‌باشد. ۴ نوع حمله نیز خود شامل زیرمجموعه‌ای از انواع مختلف حملات هستند. ده درصد از پایگاه داده خود حدود پانصد هزار داده است و تعداد زیادی است که معمولاً در سیستم‌های تشخیص همه این داده‌ها استفاده نمی‌شود. زیرا هر یک از رکوردهای داده دارای ۴۱ ویژگی مختلف است. اگر بخواهیم از کل این ده درصد پایگاه داده استفاده کنیم، آموزش سیستم تشخیص نفوذ زمان زیادی می‌برد. یکی از کارهای انجام شده در این پروژه، انتخاب مجموعه‌ای مناسب از این پایگاه داده است که حجم آن زیاد نباشد و شامل انواع مختلف حملات و به تعداد مناسب باشد.

این تحقیق با استفاده از زبان برنامه‌نویسی متلب و ارزیابی‌ها بر روی پایگاه داده KDD 99 CUP انجام شده است. پایگاه داده مورد استفاده در این تحقیق پایگاه داده‌ای است که سال ۱۹۹۹ توسط دارپا ارائه شده است و یکی از معتبرترین پایگاه‌های داده برای آزمایش سیستم‌های تشخیص نفوذ شناخته می‌شود. این پایگاه داده که KDDCup99 نام دارد توسط آزمایشگاه MIT لینکلن در دسترس محققان قرار گرفته است.

##### ۳.۵. پیاده‌سازی

در قسمت اول، کدهای مربوط به خواندن و بارگذاری پایگاه داده در محیط متلب انجام می‌شود و سپس اطلاعات از پایگاه داده خوانده شده و به فرمت قابل فهم محیط متلب تبدیل می‌شود و در نهایت در یک فایل ذخیره می‌شود. در این فایل کد مربوط به حملات به صورت زیر تعریف شده است:

جدول ۳: ارزیابی روش پیشنهادی بر اساس میزان تشخیص

Method	Detection Rate
GWOSVM (7 Wolves) [14]	96%
PSO [14]	93%
Proposed method	99.12%

### ۶. نتیجه

استفاده از اینترنت اشیا و شبکه‌های حسگر بی‌سیم به دلیل عملکرد خوب آن در مکان‌های مختلف مانند خانه، شهر و ... روزبه‌روز در حال افزایش است، اما این شبکه‌ها از نظر امنیتی با چالش مواجه هستند و هر لحظه ممکن است حملاتی رخ دهد. برای این منظور، این مطالعه به دنبال بهبود چالش امنیتی در شبکه‌های حسگر بی‌سیم است. روش پیشنهادی این تحقیق استفاده از ترکیب ماشین بردار پشتیبان و  $k$ -mean می‌باشد که نسبت به روش‌های قبلی عملکرد خوبی دارد. نتایج نشان می‌دهد که دقت روش پیشنهادی 98.35 درصد است. می‌توان سیستم پیشنهادی را با توجه به اینکه از مجموعه داده‌های واقعی در محیط‌های عملیاتی موجود برای تشخیص خطاها استفاده می‌کند، عملاً پیاده‌سازی کرد.

### References

- [1] M. Bauer, and J.W. Walewski, "The IoT Architectural Reference Model as Enabler, in Enabling Things to Talk," 2013, Springer. p. 17-25.
- [2] E. De Coninck, et al., "Distributed neural networks for Internet of Things," the Big-Little approach. in International Internet of Things Summit. 2015. Springer.
- [3] J.Cañedo, and A. Skjellum, "Using machine learning to secure IoT systems. in Privacy, Security and Trust (PST)," 2016 14th Annual Conference on. 2016. IEEE.
- [4] S. Mansfield-Devine, "The growth and evolution of DDoS" Network Security, 2015. 2015(10): p. 13-20.
- [5] M. Nazarpour, N. Nezafati, S. Shokouhyar, 'Using the Modified Colonial Competition Algorithm to Increase the Speed and Accuracy of the Intelligent Intrusion Detection System', Intelligent Multimedia Processing and Communication Systems (IMPCS), 2023, 4(1), pp. 1-10. [Persian].
- [6] V. Adat, and B. Gupta, "Security in Internet of Things: issues, challenges, taxonomy, and architecture" Telecommunication Systems, 2018. 67(3): p. 423-441.
- [7] S. Hanif, T. Ilyas and M. Zeeshan, "Intrusion Detection In IoT Using Artificial Neural Networks On UNSW-15 Dataset," 2019 IEEE 16th International Conference on Smart Cities: Improving Quality of Life Using ICT & IoT and AI (HONET-ICT), 2019, pp. 152-156, doi: 10.1109/HONET.2019.8908122.
- [8] M. A. Rahman, et al, "Scalable machine learning-based intrusion detection system for IoT-enabled smart cities," Sustainable Cities and Society 61: 102324.
- [9] N. Chaabouni, M. Mosbah, A. Zemmari and C. Sauvignac, "A OneM2M Intrusion Detection and Prevention System based on Edge Machine Learning," NOMS 2020 - 2020 IEEE/IFIP Network Operations and Management Symposium, 2020, pp. 1-7, doi: 10.1109/NOMS47738.2020.9110473.
- [10] A. Aldaej, "Enhancing Cyber Security in Modern Internet of things (IoT) Using Intrusion Prevention Algorithm for IoT (IPAI)," in IEEE Access, doi: 10.1109/ACCESS.2019.2893445.
- [11] M. Akhlaghpour, 'Providing a Solution Based on Fuzzy Logic to Reduce False Positive Alarms in The Intrusion Detection System', Intelligent Multimedia Processing and Communication Systems (IMPCS), 2(4), 2021, pp. 45-50. [Persian].

کد حمله DOS شماره ۱ و حمله U2R شماره ۲، حمله R2L شماره ۳، حمله PROB شماره ۴ و در نهایت وضعیت غیرحمله یا NORMAL با شماره ۵ مشخص می‌شود. ۷۰ درصد داده‌ها برای آموزش و ۳۰ درصد برای آزمایش انتخاب می‌شوند. پس از اجرا تعداد داده‌های آموزشی ۳۴۵۸۱۴ و تعداد داده‌های آزمایش ۱۴۸۲۰۷ می‌باشد. حملات نیز از ۱ تا ۵ دسته بندی می‌شوند. انتخاب ویژگی توسط الگوریتم K-means انجام و نتایج وارد SVM می‌شود. از تابع Confusion یا تابع خالی بودن و سردرگمی برای تشخیص صحیح نتایج استفاده شده است. سپس با استفاده از داده‌های آموزشی مدل مورد نظر را آموزش می‌دهیم و پس از آموزش کامل مدل را با استفاده از داده‌های آزمون ارزیابی می‌کنیم. در این بخش، الگوریتم پیشنهادی از نظر پارامترهای نرخ تشخیص، دقت و نرخ هشدار نادرست با الگوریتم‌های موجود مقایسه می‌شود. معیارهای مختلف مورد استفاده برای این منظور، بررسی عملکرد و نتایج تجربی به شرح زیر است:

۱- نرخ تشخیص (DR)

۲- نرخ هشدار نادرست (FAR)

۳- مثبت کاذب (FP)

۴- منفی کاذب (FN)

۵- مثبت واقعی (TP)

۶- منفی واقعی (TN)

معیارهای ارزیابی به صورت زیر محاسبه می‌گردد:

$$Detection\ Rate = \frac{TP}{TP + FP} \quad (1)$$

$$False\ Alarm\ Rate = \frac{FP}{TN + FP} \quad (2)$$

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (3)$$

### ۴.۵. ارزیابی روش پیشنهادی

مهمترین معیار برای تعیین عملکرد یک الگوریتم، معیار دقت است. این معیار، دقت کلی یک دسته را محاسبه می‌کند و نشان می‌دهد که چند درصد از کل مجموعه داده‌ها به درستی طبقه بندی شده است. معیار ارزیابی بر اساس دقت نشان داده شده در رابطه (۳) است و دقت روش پیشنهادی بهتر از روش‌های ارائه شده قبلی است.

جدول ۱: ارزیابی روش پیشنهادی بر اساس دقت

Method	Accuracy
GWOSVM (7 Wolves) [14]	96%
PSO [14]	89%
Proposed method	98.35%

جدول ۲: ارزیابی روش پیشنهادی بر اساس هشدار کاذب

Method	False Alarm
GWOSVM (7 Wolves) [14]	3%
PSO [14]	26%
Proposed method	1.47 %

- [12] R.S. Nayaki, and A.S. Kumar, "An Analysis of DDoS Attack Detection and Mitigation Using Machine Learning System," International Journal on Recent and Innovation Trends in Computing and Communication, 2017. 5(10): p. 80-82.
- [13] C. Yin, et al., "A deep learning approach for intrusion detection using recurrent neural networks," IEEE Access, 2017. 5: p. 21954-21961.
- [14] M. Safaldin, M. Otair, and L. Abualigah, "Improved binary gray wolf optimizer and SVM for intrusion detection system in wireless sensor networks," J Ambient Intell Human Comput 12, 1559-1576 (2021). <https://doi.org/10.1007/s12652-020-02228-z>

## پی‌نوشت

<sup>4</sup> Distributed Denial Of Service

<sup>5</sup> Support Vector Machine

<sup>1</sup> Internet Of Things

<sup>2</sup> Machine to Machine

<sup>3</sup> Denial Of Service