

Summer 2024, 5 (2), 71-80
DOR:

Received: 16 Apr 2024
Accepted: 4 Jun 2024

مقاله پژوهشی

Hybrid Intrusion Detection System: Leveraging XGBoost, Genetic Algorithms and k-Means Clustering

Ladan Riazi*

Assistant Professor, Department of Information Technology Management, Science and Research Branch, Islamic Azad University, Tehran, Iran. *Corresponding Author, ladan.riazi@srbiau.ac.ir

Abstract

Introduction: The proliferation of internet applications has led to an interconnected digital landscape where network security is a paramount concern. Intrusion detection systems (IDS) play a critical role in safeguarding networks by identifying and mitigating unauthorized access and malicious activities. This research proposes a novel IDS framework that integrates XGBoost, k-Means clustering, and genetic algorithms to enhance intrusion detection capabilities.

Method: The proposed IDS framework commences with data preprocessing to ensure compatibility with machine learning algorithms. Subsequently, k-Means clustering is employed to group unlabeled data, generating valuable insights that augment the dataset. To optimize feature selection, a genetic algorithm is integrated into the framework. This algorithm iteratively evaluates feature subsets using XGBoost to identify the most informative features for intrusion detection.

Results: The efficacy of the proposed IDS was evaluated using the NSL-KDD dataset. Comparative analysis with established methods, including decision trees, XGBoost, KNN, and random forests, demonstrated the superior performance of the proposed approach in terms of precision, recall, and F1-score.

Discussion: The integration of XGBoost, k-Means clustering, and genetic algorithms in the proposed IDS framework offers significant advantages. k-Means clustering provides valuable insights into unlabeled data, while genetic algorithms enable efficient feature selection. The empirical results underscore the effectiveness of the proposed approach in accurately detecting intrusions in computer networks.

Keywords: Intrusion Detection, Computer Networks, XGBoost, Clustering, k-Means, Genetic Algorithm.

سیستم تشخیص نفوذ ترکیبی با استفاده از الگوریتم‌های XGBoost، ژنتیک و خوشه‌بندی k-Means

دوره پنجم، تابستان ۱۴۰۳
شماره دوم، صص: ۷۱-۸۰

تاریخ دریافت: ۱۴۰۳/۰۱/۲۸
تاریخ پذیرش: ۱۴۰۳/۰۳/۱۵

لادن ریاضی*

استادیار، گروه مدیریت فناوری اطلاعات، دانشکده مدیریت و اقتصاد، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران. (نویسنده مسئول)
ladan.riazi@srbiau.ac.ir

چکیده: گسترش برنامه‌های کاربردی اینترنتی منجر به ایجاد یک فضای دیجیتالی به هم پیوسته شده‌است که در آن امنیت شبکه یک نگرانی اساسی است. سیستم‌های تشخیص نفوذ (IDS) با شناسایی و کاهش دسترسی‌های غیرمجاز و فعالیت‌های مخرب، نقش مهمی در حفاظت از شبکه‌ها ایفا می‌کنند. در این تحقیق یک چارچوب جدید برای سیستم‌های مذکور با استفاده از ادغام الگوریتم‌های XGBoost، خوشه‌بندی k-Means و الگوریتم‌های ژنتیک پیشنهاد شده‌است. چارچوب IDS پیشنهادی با پیش‌پردازش داده‌ها برای اطمینان از سازگاری با الگوریتم‌های یادگیری ماشین آغاز می‌شود. سپس، خوشه‌بندی k-Means برای گروه‌بندی داده‌های بدون برچسب اعمال می‌شود و درک مناسبی از مجموعه داده حاصل می‌گردد. برای بهینه‌سازی انتخاب ویژگی، یک الگوریتم ژنتیک نیز در چارچوب پیشنهادی گنجانده شده‌است. این الگوریتم به‌طور مکرر زیر مجموعه‌های ویژگی را با استفاده از الگوریتم XGBoost ارزیابی می‌کند تا ارزشمندترین ویژگی‌ها را برای تشخیص نفوذ شناسایی کند. کارایی IDS پیشنهادی با استفاده از مجموعه داده NSL-KDD ارزیابی شد. در تجزیه و تحلیل مقایسه‌ای صورت گرفته با سایر روش‌های موجود، از جمله درختان تصمیم، XGBoost، KNN و جنگل‌های تصادفی، رویکرد پیشنهادی عملکرد برتری را از نظر معیارهای Precision، Recall و F1-Score نشان داد.

واژه‌های کلیدی: تشخیص نفوذ در شبکه‌های کامپیوتری، الگوریتم XGBoost، خوشه‌بندی، الگوریتم k-Means.

۱. مقدمه

روند روبه رشد استفاده از شبکه‌های کامپیوتری به خصوص اینترنت، مهارت روبه رشد کاربران و مهاجمان این شبکه‌ها و وجود نقاط آسیب‌پذیری مختلف در نرم‌افزارها، موجب شده‌است که ایمن‌سازی سیستم‌ها و شبکه‌های کامپیوتری، نسبت به گذشته از اهمیت بیشتری برخوردار باشد. وقتی یک سیستم کامپیوتری به یک شبکه متصل می‌شود، در معرض ریسک بالایی قرار می‌گیرد. از جمله تهدیداتی که برای یک سیستم کامپیوتری وجود دارد، ویروس‌ها و نفوذها هستند [۱]. ظهور دستگاه‌های جدیدی که از اینترنت به عنوان ابزار اصلی خود استفاده می‌کنند، امنیت شبکه را به یکی از مهم‌ترین حوزه‌های امروزی در جهان تبدیل کرده‌است. نفوذ در محیط محاسباتی بسیار رایج است و باعث ایجاد مشکلات زیادی برای افراد، مشاغل خصوصی یا دولتی می‌شود که فکر می‌کنند اطلاعات خود را خصوصی نگه می‌دارند. در نتیجه، امنیت داده‌ها به یک موضوع برجسته تبدیل شده‌است که باید به شیوه‌ای فوری مورد توجه قرار گیرد [۲]. روزانه میلیون‌ها رایانه قربانی رویه‌ای می‌شوند که باعث می‌شود کسب‌وکارها با افشای اطلاعات خصوصی‌شان در معرض رقابت‌های شرکتي، سرمایه و اعتبار خود را از دست بدهند. در نتیجه، امنیت شبکه برای کاربران کامپیوتر و سازمان‌ها بسیار مهم شده‌است. برای جلوگیری از دسترسی غیرمجاز به سیستم‌ها، تعداد زیادی ابزار نفوذ ایجاد شده‌است که امکان ردیابی، نظارت، دسترسی و شناسایی ترافیک ناخواسته در یک شبکه یا یک دستگاه را فراهم می‌کند. در این ابزارهای متعدد نفوذ که در اوایل دهه ۲۰۰۰ معرفی شدند، عمده‌ترین ابزارهای مورد استفاده سیستم‌های پیشگیری از نفوذ و سیستم‌های تشخیص نفوذ هستند [۳].

استفاده گسترده از اینترنت منجر به افزایش تصاعدي حجم اطلاعات مبادله شده بین دستگاه‌های مختلف و تعداد روش‌های جدید حملات شبکه شده‌است. روش‌های مرسوم مانند فایروال که بر فیلتر کردن داده‌ها متمرکز است، ممکن است برای شناسایی به موقع انواع حملات مناسب نباشد. برای مدیریت مؤثر و شناسایی به موقع این نوع حملات، سیستم‌های تشخیص نفوذ مبتنی بر الگوریتم‌های یادگیری ماشینی برای پردازش کارآمد حجم زیادی از داده‌ها برای شناسایی هرگونه فعالیت مخرب بسیار مؤثر هستند. سیستم‌های تشخیص نفوذ مبتنی بر یادگیری ماشینی برای تجزیه و تحلیل تمام فعالیت‌های شبکه برای هرگونه رفتار مخرب استفاده می‌شود [۴].

از آنجاکه رشد سریع در استفاده از شبکه‌های کامپیوتری منجر به مسائل مربوط به حفظ در دسترس بودن، یکپارچگی و محرمانه بودن شبکه می‌شود، این امر مدیران شبکه را ملزم به اتخاذ انواع مختلفی از سیستم‌های تشخیص نفوذ می‌کند که به نظارت بر ترافیک شبکه برای فعالیت‌های غیرمجاز و مخرب کمک می‌کند. سیستم تشخیص نفوذ، ترافیک جاری در شبکه را از طریق سیستم‌های رایانه‌ای برای جستجوی فعالیت‌های مخرب و تهدیدات بررسی می‌کند و در صورت یافتن آن تهدیدها، هشدار ارسال می‌کند. برای این منظور، در این تحقیق، مدلی

پیشنهاد می‌شود که برای حل مسئله تشخیص نفوذ در شبکه‌های کامپیوتری از تلفیق روش‌های XGBoost و خوشه‌بندی kMeans استفاده می‌کند. در روش پیشنهادی این تحقیق kMeans برای خوشه‌بندی و اضافه کردن اطلاعات جدید به مجموعه داده استفاده خواهد شد. روش XGBoost برای شناسایی و طبقه‌بندی ترافیک به کار گرفته می‌شود. برای بهبود عملکرد سیستم پارامترهای XGBoost تنظیم شده و ویژگی‌های مؤثر با استفاده از الگوریتم ژنتیک تعیین خواهد شد. در انتها تجزیه و تحلیل دقیق روش پیشنهادی و تعدادی از تکنیک‌های یادگیری ماشینی انجام می‌شود و کارایی روش پیشنهادی مورد بررسی قرار می‌گیرد. بخش‌های باقی‌مانده از این کار به شرح زیر است: بخش ۲ کار مرتبط را توضیح می‌دهد. بخش ۳ مدل ترکیبی پیشنهادی را مورد بحث قرار می‌دهد. جزئیات آزمایشی، بحث در مورد نتایج و به دنبال آن مقایسه با رویکردهای موجود در بخش ۴ ارائه شده‌است. در نهایت نتیجه‌گیری و کارهای آتی در بخش‌های ۵ و ۶ ارائه شده‌است.

۲. پژوهش‌های مرتبط

با وجود پیشرفت‌های اخیر، سیستم‌های تشخیص نفوذ فعلی نیز مشکلاتی را در افزایش دقت تشخیص، افزایش سطوح هشدار کاذب و شناسایی فعالیت‌های مشکوک تجربه می‌کنند. به منظور پرداختن به این مسائل و ساختن یک سیستم تشخیص نفوذ مؤثر، محققان زیادی بر طراحی سیستم‌های تشخیص نفوذ متکی به رویکردهای یادگیری ماشینی تمرکز کردند. در پروژه [۵] از الگوریتم سنجاقک برای انتخاب ویژگی و از الگوریتم جنگل تصادفی به منظور دسته‌بندی استفاده شد. داده‌های به کار رفته در پژوهش، مجموعه داده KDD-99 بود و عملیات متوازن سازی در آن استفاده شد. مسئله با الگوریتم‌های مختلف یادگیری ماشینی و یادگیری عمیق مورد آزمون قرار گرفت و بهترین الگوریتم انتخاب شد. در این تحقیق مقدار صحت در روش پیشنهادی مقدار ۸۳.۹۹ به دست آمد.

در تحقیق [۶] یک مدل ترکیبی IDS ارائه شد که به ادغام انتخاب ویژگی، طبقه‌بندی و بهینه‌سازی هایپرپارامترها پرداخته‌است. ابتدا، ویژگی‌های انبوه اولیه جداگانه و به روش‌های اطلاعات متقابل اصلاح شده (MMI)، الگوریتم ژنتیک (GA) و آزمون F تحلیل واریانس وارد شدند و پس از آن اشتراک‌گیری از خروجی آن‌ها به عنوان ویژگی‌های نهایی مؤثر و کاهش یافته صورت پذیرفت. در ادامه، یک طبقه‌بند ترکیبی CNN و LSTM به کار گرفته شد که هایپرپارامترهای آن توسط یک الگوریتم بهینه‌سازی به نام گرگ خاکستری-نهنگ با جابجایی تصادفی (RS-GWO-WOA) تعیین شد. این روش بر روی مجموعه داده NSL-KDD اعمال شد و به دقت ۷۶.۵۲٪ رسید.

در مقاله [۷] روشی با استفاده از الگوریتم درخت تصمیم J48 ارائه شده‌است که می‌تواند نرخ تشخیص ترافیک نرمال و نرخ تشخیص حملات نوع (Denial of Service attack) DOS را در شبکه به بیش از ۹۹٪ برساند. در این تحقیق از مجموعه داده KDD CUP 99 که

مجموعه داده استاندارد جهت آزمایش روش‌های تشخیص نفوذ به شبکه‌های کامپیوتری می‌باشد جهت آموزش و آزمایش استفاده شد. نرخ تشخیص ترافیک نرمال و حملات نوع DOS در این روش با استفاده از روش‌های کاهش ویژگی در مقایسه با دیگر روش‌های مطرح‌شده، افزایش یافت.

در تحقیق [۸] مدلی پیشنهاد می‌گردد که الگوریتم‌های مختلف دسته‌بندی را روی مجموعه داده خود آزمایش کرده و نتایج شبیه‌سازی را نشان می‌دهد. بین تمامی الگوریتم‌ها، الگوریتم J48 دارای بالاترین مقدار درستی به میزان $85/49\%$ ، دارای بالاترین میزان دقت به مقدار $86/57\%$ و دارای بالاترین مقدار یادآوری به مقدار $86/57\%$ می‌باشد. نوآوری اصلی در این تحقیق، استفاده از الگوریتم‌های مدل کامل و مدل قانون محور است. در تحقیقات خارجی نیز فرگ و همکاران [۹] مروری بر الگوریتم‌های یادگیری عمیق سیستم‌های تشخیص نفوذ و مجموعه داده‌های تشخیص هرزنامه ارائه کردند و به این نتیجه رسیدند که مدل‌های یادگیری عمیق می‌توانند بهتر از مدل‌های یادگیری ماشین سنتی و متنی برای تشخیص نفوذ و هرزنامه عمل کنند.

در تحقیق [۱۰] بر اساس آزمایش‌ها و تحلیل‌های مقایسه‌ای انجام‌شده برای ویژگی‌های بهینه‌سازی ازدحام ذرات (PSO) و Xgboost، مدل PSO-Xgboost پیشنهاد شد که با توجه به دقت طبقه‌بندی بالاتر آن نسبت به سایر مدل‌های جایگزین مانند Xgboost، Random Forest، Bagging و آداپوست نتایج مناسبی را داشته‌است. نتایج تجربی نشان داد که مدل PSO-Xgboost در دقت، یادآوری، میانگین کلان (ماکرو) و میانگین دقت متوسط، به‌ویژه هنگام شناسایی گروه‌های اقلیت حملات از سایر مدل‌های مقایسه‌ای بهتر عمل می‌کند. در مقاله [۱۱] یک مدل یادگیری ماشین مبتنی بر PCA برای طبقه‌بندی مجموعه داده‌های سیستم تشخیص نفوذ پیشنهاد شد. نتایج تجربی این تحقیق، این واقعیت را تأیید می‌کند که مدل پیشنهادی بهتر از مدل‌های یادگیری ماشین پایه موجود عمل می‌کند. دشموخ و همکاران [۱۲] حمله خاص مسیریابی را در یک محیط اینترنت اشیا گزارش کردند. این تحقیق بر روی شناسایی موقعیت نفوذگر و هشدار به مدیر شبکه متمرکز شد. شناسایی گره‌های همسایگی و استخراج تأثیر تهدید از دستاوردهای این پژوهش به شمار می‌رود. در تحقیق [۱۳] یک شبکه عصبی بازگشتی کانولوشن برای ساخت یک سیستم تشخیص نفوذ ترکیبی مبتنی بر یادگیری عمیق که حملات را از طریق یک شبکه شناسایی می‌کند، استفاده شد. برای افزایش کارایی سیستم تشخیص نفوذ و قابلیت پیش‌بینی، شبکه عصبی کانولوشن برای جمع‌آوری ویژگی‌های محلی به کار می‌رود در حالی که یک شبکه عصبی تکراری لایه‌ای عمیق ویژگی‌های سیستم تشخیص نفوذ شبکه هیبریدی مبتنی بر یادگیری عمیق (HDLNIDS) را استخراج می‌کند. آزمایش‌ها با استفاده از داده‌های معیار CICIDS-2018، برای تعیین اثربخشی سیستم پیشنهادی انجام شد و دقت متوسط $98,90\%$ درصد در تشخیص حملات مخرب به دست آمد.

در تحقیق مانیموراگان و همکاران [۱۴] برای افزایش دقت و کاهش نرخ هشدار نادرست (FAR) در مسئله تشخیص نفوذ از الگوریتم بهینه‌سازی جستجوی کلاغ و سیستم استنتاج عصبی فازی تطبیقی (CSO-ANFIS) استفاده شد. نتایج آزمایش‌ها تشخیص نفوذ این تحقیق مناسب و کارآمدتر گزارش شد. در مقاله گلرنگ و همکاران [۱۵]، یک رویکرد ترکیبی چندهدفه برای شناسایی مؤثر حملات در شبکه پیشنهاد شد. نتایج آزمایش‌ها نشان داد که چارچوب پیشنهادی در مقایسه با راه‌حل‌های موجود در ادبیات به نتایج بهتری دست یافت. در مقاله [۱۶]، یک سیستم تشخیص نفوذ مبتنی بر یادگیری عمیق برای تشخیص حمله ارائه شد. این مدل با مجموعه داده‌های ترافیک زمان واقعی CICIDS2018 و Edge-IIoT آموزش داده شد. عملکرد مدل هنگام آموزش و آزمایش با مجموعه داده‌ها، به ترتیب به میزان دقت $99,64\%$ و 100% دست یافت. در جدول ۱ خلاصه اطلاعات مربوط به تعدادی از کارهای پیشین مرتبط آورده شده‌است. در این روش‌ها از مجموعه داده‌های متنوعی برای بررسی روش‌های پیشنهادی استفاده شده‌است.

در مقاله [۱۷]، یک سیستم تشخیص نفوذ دولایه مبتنی بر طبقه بند KNN برای جداسازی ترافیک عادی از حمله و شبکه مصنوعی پرسپترون چندلایه برای تشخیص نوع حمله ارائه شد. در مجموعه داده KDD-CUP 99 نتایج آزمایش بیانگر دقت $99,743\%$ بود.

در مقاله [۱۸]، از الگوریتم فراابتکاری رقابت امپریال (ICA) برای آموزش شبکه‌های عصبی استفاده و نشان داده شد که این الگوریتم در زمینه تشخیص نفوذ در سیستم اینترنت اشیا، می‌تواند عملکرد بسیار بهتری از منظر سرعت و دقت نسبت به روش‌های آموزشی کلاسیک داشته‌باشد. نتایج نشان داد روش پیشنهادی این تحقیق دارای دقت 90% می‌باشد که در مقایسه با روش شبکه عصبی کلاسیک که دارای دقت 75% درصد بوده عملکرد بهتری دارد.

جدول ۱: خلاصه اطلاعات تعدادی از روش‌های مرتبط

تحقیق	روش	مجموعه داده	ارزیابی
Mozafari, 2016	J48	DARPA	دقت، $86,57\%$
Najafi Mohsen, 2015	درخت تصمیم J48	KDD CUP 99	دقت 99%
Mazloum, 2022	CNN-LSTM	NSL-KDD	دقت، $76,52\%$
Niai, 2022	Dragonfly و جنگل تصادفی	KDD-9	صحت، $83,99\%$
Ferrag et al, 2020	مدل CNN	CSE-CIC-IDS2018 Bot-IoT	نرخ تشخیص کلی $97,28\%$ نرخ تشخیص کلی $97,01\%$
Bhattacharya et al, 2020	XGBoost-Firefly	intrusion detection system (IDS)	دقت $99,9\%$
Qazi, 2023	HDLNIDS	CICIDS-2018	دقت $98,90\%$


Hnante, 2023	یادگیری عمیق	CICIDS2018 Edge_IIoT و	دقت ۹۹,۶۴٪
Kaffash et al, 2024	MLP-KNN	KDD-CUP 99	دقت ۹۹,۷۴۳٪
Nazarpour et al, 2023	NN-ICA	KDD-CUP	دقت ۹۰٪

۳. روش پیشنهادی

سیستم پیشنهادی این تحقیق از ترکیب الگوریتم‌های K-Means و XGboost برای تشخیص نفوذ استفاده می‌کند. در این تحقیق از روش Successive halving برای تنظیم پارامترها استفاده می‌شود. نحوه عملکرد سیستم پیشنهادی در شکل ۱ آمده است.

روش مدنظر در این پژوهش متشکل از الگوریتم‌های مختلف هوش مصنوعی می‌باشد. در ابتدا با دریافت داده، پیش‌پردازش لازم بر روی آن‌ها صورت می‌گیرد تا داده‌های مورد بررسی برای استفاده در روش‌های یادگیری ماشین آماده شوند. در ادامه با اعمال روش خوشه‌بندی K-Means، اقدام به خوشه‌بندی داده‌ها می‌شود. در این بخش بر چسب‌های مجموعه داده نادیده گرفته می‌شود و از آن در روش K-Means استفاده نمی‌شود. به این ترتیب در حقیقت مجموعه داده‌ها به عنوان داده‌های بدون برچسب در نظر گرفته می‌شود. پس از اعمال روش K-Means، شماره مربوط به هریک از خوشه‌های حاصل به عنوان یک ویژگی اضافه به مجموعه داده مورد بررسی اضافه می‌شود.

با توجه به اینکه از روش دسته‌بندی XGBoost در گام بعدی استفاده می‌شود، ابتدا با روش نصف کردن پی‌درپی، پارامترهای مناسب برای روش XGBoost تعیین می‌شود. در ادامه به منظور اعمال فرآیند انتخاب ویژگی از ویژگی‌های مجموعه داده موردنظر، روش ژنتیک اعمال می‌شود و هر بار، جایگشت متفاوتی از زیرمجموعه ویژگی‌های مجموعه داده مورد بررسی، ارزیابی می‌شود و بهترین نتایج حاصل گزارش می‌شود.



شکل ۱: عملکرد سیستم پیشنهادی

۱.۳. الگوریتم XGBoost

در معادله (۱) که تابع هدف XGBoost را نشان می‌دهد، عبارت $L(y_i, \hat{y}_i)$ تابع ضرر است که در آن y_i ارزش واقعی و $\hat{y}_i$ ارزش پیش‌بینی مدل است. تابع ضرر می‌تواند مربع انحرافات $\hat{y}_i$ پیش‌بینی از y_i واقعی باشد. $\Omega(f_i)$ نیز یک عبارت منظم‌سازی است برای جریمه کردن پیچیدگی مدل جهت جلوگیری از برازش بیش از حد (over fitting).

$$Obj(t) = \sum_{i=1}^n L(y_i, \hat{y}_i) + \sum_{i=1}^n \Omega(f_i) \quad (1)$$

در معادله (۲) که عبارت منظم‌سازی را نمایش می‌دهد، γ ضریب جریمه اندازه درخت است که در تعداد برگ‌های درخت یعنی T ضرب می‌شود و اندازه درخت را کنترل می‌کند. λ نیز ضریب جریمه وزن برگ است که در نرم دو (L_2) وزن برگ‌ها ضرب می‌شود. w نیز وزنی است که به هر برگ اختصاص دادیم.

$$\Omega(f_i) = \gamma T + \frac{1}{2} \lambda \sum_{i=1}^T w_j^2 \quad (2)$$

بعد از t تکرار، مدل پیش‌بینی به صورت معادله (۳) نوشته می‌شود:

$$\hat{y}_i^{(t)} = \hat{y}_i^{(t-1)} + f_t(x_i) \quad (3)$$

بنابراین تابع هدف به شکل معادله (۴) درمی‌آید:

$$Obj(t) = \sum_{i=1}^n L(y_i, \hat{y}_i^{(t-1)} + f_t(x_i)) + \Omega(f_t) \quad (4)$$

XGBoost متفاوت با GBDT^۱ است. می‌تواند تابع ضرر را بر اساس مشتق دوم فرمول تیلور گسترش دهد به‌طوری‌که تابع هدف جدید به دست آمده نرخ همگرایی سریع‌تر و دقت بالاتری نسبت به GBDT اصلی داشته باشد. بر این اساس تابع هدف نهایی به شکل معادله (۵) نوشته می‌شود:

$$Obj(t) \cong \sum_{i=1}^n [L(y_i, \hat{y}_i^{(t-1)}) + g_i f_t(x_i) + \frac{1}{2} h_i f_t^2(x_i)] + \Omega(f_t) \quad (5)$$

$$g_i = \frac{\partial (L(y_i, \hat{y}_i^{(t-1)}))}{\partial \hat{y}_i^{(t-1)}} \quad (6)$$

$$h_i = \frac{\partial^2 (L(y_i, \hat{y}_i^{(t-1)}))}{\partial \hat{y}_i^{(t-1)}} \quad (7)$$

که در آن g_i و h_i همان‌طور که در معادله‌های (۶) و (۷) داده شده به ترتیب مشتقات اول و دوم تابع ضرر $L(\phi)$ هستند.

۲.۳. الگوریتم k-Means

یکی از روش‌های معروفی که در دیدگاه خوشه‌بندی مطرح می‌باشد، الگوریتم k-Means است. این روش با مقداری مشخص برای k تعداد دسته‌ها شروع و سعی می‌کند که مجموعه‌ای از نمونه‌های مشخص را در این K گروه دسته‌بندی کند طوری‌که فرضیات موردنظر، رعایت شوند. لازم به ذکر است که معیار تخصیص هر نمونه به یک کلاس نیز در این روش حداقل مسافت اقلیدسی هر نمونه از نقطه میانی (مرکزی یا نماینده) هر کلاس یا دسته است. مراحل مهمی که در این الگوریتم طی می‌گردد به‌طور خلاصه به شرح ذیل می‌باشد [۱۷].

۱. تشکیل K کلاس یا دسته به صورت $\{C_1, C_2, \dots, C_K\}$ برای خوشه‌بندی m نمونه از مجموعه M .
۲. محاسبه بردار Z_j بر اساس رابطه زیر که نشان‌دهنده مرکز یا نماینده هر دسته C_j می‌باشد.

$$Z_j = \frac{\sum_{x \in C_j} x}{\#C_j} \quad \text{for } j = 1, 2, \dots, K \quad (8)$$

- در این رابطه، x نشان‌دهنده بردار نمونه‌ای است که در C_j عضو می‌باشد و $\#C_j$ نشان‌دهنده تعداد j عضو می‌باشند. لازم به ذکر است که رابطه بالا برای محاسبه مرکز نمونه‌هایی می‌باشد که در کلاس C هر دسته در خلال حل استفاده می‌شود و در شروع الگوریتم معمولاً K نمونه تصادفی انتخاب و به‌عنوان مرکز هر دسته در نظر گرفته می‌شوند.
۳. محاسبه تابع هدف ناشی از دسته‌بند $\{C_1, C_2, \dots, C_K\}$ بر اساس رابطه زیر که به محاسبه مجموع فواصل نمونه‌ها از مرکز دسته‌ها می‌پردازد.

$$f(C_1, C_2, \dots, C_K) = \sum_{j=1}^K \sum_{x \in C_j} |x - Z_j|^2 \quad (9)$$

۴. کمینه نمودن تابع هدف رابطه بالا و یافتن دسته‌بندی مناسب روی مجموعه M با تعداد دسته K .

۳.۳. نحوه انتخاب پارامترها

در این تحقیق از روش Successive halving یعنی نصف کردن پی‌درپی برای جستجوی فضای پارامتر برای بهینه‌سازی پارامترهای مدل یادگیری استفاده شده است. استراتژی جستجو در اولین تکرار، شروع به ارزیابی همه نامزدها (ترکیب پارامترها) با مقدار کمی از منابع (تعداد نمونه آموزشی) می‌کند. تعداد محدودی از بهترین نامزدها برای تکرار بعدی انتخاب می‌شوند و منابع بیشتری به آن‌ها اختصاص داده می‌شود. فقط زیرمجموعه‌ای از نامزدها تا آخرین تکرار زنده می‌مانند. این‌ها نامزدهایی هستند که دائماً در بین نامزدهای دارای رتبه برتر در همه تکرارها رتبه‌بندی می‌شوند.

۴.۳. انتخاب ویژگی

در این پژوهش از روش ژنتیک برای انتخاب زیرمجموعه‌ای از داده‌ها استفاده می‌شود. به کمک روش ژنتیک می‌توان زیرمجموعه‌های مختلف مجموعه داده موردنظر را بررسی و بهترین نتایج را گزارش کرد. به این ترتیب در الگوریتم ژنتیک سیستم پیشنهادی هر راه‌حل یا فرد نشان‌دهنده تعدادی ویژگی است که برای به دست آوردن میزان مطلوبیت آن مدل Xgboost برای ویژگی‌های متناظر ایجاد می‌شود و دقت مدل پیشنهادی به‌عنوان میزان تابع تناسب برای فرد موردنظر ثبت می‌شود. در نهایت کروموزوم با بیشترین تناسب به‌عنوان بهترین راه‌حل شناخته می‌شود. این کروموزوم بهترین ویژگی‌های ممکن را شناسایی کرده است و مدلی که با استفاده از این ویژگی‌ها ساخته شود بالاترین کارایی را ارائه خواهد داد. درواقع در الگوریتم ژنتیک پیشنهاد شده هدف یافتن کروموزومی است که بهترین زیرمجموعه از ویژگی‌ها را نشان می‌دهد و تناسب هر کروموزوم با بررسی دقت پیاده‌سازی روش Xgboost در نظر گرفتن ویژگی‌های متناظر با کروموزوم مربوطه به دست می‌آید.

۵.۳. روش‌های ارزیابی سیستم پیشنهادی

در ادامه با استفاده از روش ارزیابی صحت^۲ و بازخوانی^۳ داده‌های دسته‌بندی شده و دقت^۴ نهایی دسته‌بندی انجام شده الگوریتم مورد ارزیابی قرار می‌گیرد [۲]. این معیارها به صورت زیر تعریف می‌شوند:

دقت برابر است با تعداد اسناد بازیابی شده مرتبط تقسیم بر تعداد کل اسناد بازیابی شده.

بازخوانی برابر است با تعداد اسناد بازیابی شده مرتبط تقسیم بر تعداد کل اسناد مرتبط واقعی در پایگاه داده.

برای بررسی بهتر سیستم پیشنهادی و ویژگی‌هایی که این سیستم دارد نتایج به دست آمده برای معیارهای ارزیابی مختلف با نتایج به دست آمده از روش‌های پایه مقایسه می‌شود و مزایا و معایب آن‌ها مشخص می‌شود.

۶.۳. مجموعه داده مورد بررسی

مجموعه داده‌های مورد استفاده در این مطالعه NSL-KDD است که در بسیاری از مطالعات تشخیص نفوذ استفاده می‌شود. این پایگاه داده حاوی حجم زیادی از داده‌های مربوط به حملات مختلف است که در محیط شبیه‌سازی شده یک شبکه کامپیوتری در نیروی هوایی آمریکا جمع‌آوری شده است. این داده‌ها حاصل ۹ هفته ترافیک‌های به دست آمده در این شبکه است. داده‌ها در مجموعه داده NSL-KDD به عنوان عادی یا به عنوان یکی از ۲۴ نوع مختلف حمله برچسب‌گذاری می‌شوند. این ۲۴ حمله را می‌توان به چهار کلاس طبقه‌بندی کرد: DoS, Probe, R2L و U2R

در حملات DoS (Denial of Service) تلاشی مخرب برای مسدود کردن منابع و سرویس‌های یک سیستم یا شبکه صورت می‌گیرد. در حملات نوع Probe، اطلاعات مربوط به آسیب‌پذیری‌های احتمالی سیستم هدف جمع‌آوری می‌شود و بعداً برای حمله به سیستم‌ها استفاده می‌شود.

در حملات R2L (Remote to Local)، توانایی غیرمجاز برای ریختن بسته‌های داده به سیستم راه دور از طریق شبکه و دسترسی به عنوان کاربر یا روت برای انجام فعالیت‌های غیرمجاز وجود دارد. در حملات U2R (User to Root)، مهاجمان به عنوان یک کاربر عادی به سیستم دسترسی پیدای می‌کنند و آسیب‌پذیری‌ها را برای به دست آوردن امتیازات مدیریتی می‌شکنند.

محیط پیاده‌سازی داده‌ها محیط برنامه‌نویسی پایتون بود.

۷.۳. آماده‌سازی داده‌ها

آماده‌سازی داده‌ها فرآیند پاک‌سازی و تبدیل داده‌های خام قبل از پردازش و تجزیه و تحلیل است. این یک مرحله مهم قبل از پردازش است و اغلب شامل قالب‌بندی مجدد داده‌ها، انجام اصلاحات در داده‌ها و ترکیب مجموعه داده‌ها برای غنی‌سازی داده‌ها است. آماده‌سازی داده‌ها با انجام تبدیل ویژگی با کدگذاری One-hot، نرمال‌سازی با روش Z-score و محدود کردن حالات حمله و نرمال به ۵ مورد انجام شد. داده‌ها در یک کلاس عادی و چهار کلاس حمله طبقه‌بندی می‌شوند. چهار کلاس حمله با عنوان‌های DoS, Probe, R2L و U2R گروه‌بندی می‌شوند.

۴. نتایج

برای بررسی بهتر نتایج حاصل از سیستم پیشنهادی، ابتدا به بیان نتایج حاصل از اعمال مدل‌های مختلف بر روی مجموعه داده خواهیم پرداخت. مدل‌های مورد بررسی در این پژوهش، شامل روش‌های درخت تصمیم، XGBoost، KNN و جنگل تصادفی می‌باشد. معیارهای مختلفی برای مقایسه این روش‌ها مورد بررسی قرار گرفته‌اند که شامل Recall و F1-Score می‌باشند.

۱.۴. نتایج اعمال الگوریتم‌های مختلف


در این بخش نتایج به دست آمده از اعمال روش درخت تصمیم، Knn، XGBoost، بر روی مجموعه داده NSL-KDD نشان داده شده است. جدول ۲ نتایج به دست آمده از اعمال روش درخت تصمیم، Knn، XGBoost، در معیارهای ارزیابی Recall، Precision و F1-Score را به ترتیب در کلاس‌های Dos، Normal، Probe، R2L و U2R نشان می‌دهد.

جدول ۲: نتایج به دست آمده از اعمال روش‌های مختلف


درخت تصمیم	precision	recall	f1-score	
Dos	94.74%	78.73%	86.00%	
Normal	69.61%	93.42%	79.78%	
Probe	57.99%	66.25%	61.85%	
R2L	84.82%	11.55%	20.34%	
U2R	58.06%	26.87%	36.73%	
accuracy				75.49%
XGBoost				
Dos	96.25%	74.71%	84.13%	
Normal	73.74%	95.27%	83.13%	
Probe	76.28%	70.01%	73.01%	
R2L	13.79%	7.53%	9.74%	
U2R	4.88%	26.87%	8.26%	
accuracy				74.84%
kNN				
Dos	94.55%	79.58%	86.43%	
Normal	66.89%	92.92%	77.78%	
Probe	70.93%	69.64%	70.28%	
R2L	80.20%	5.83%	10.87%	
U2R	38.46%	29.85%	33.61%	
accuracy				75.25%
جنگل تصادفی				
Dos	97.14%	68.95%	80.65%	
Normal	60.52%	98.99%	75.12%	
Probe	92.18%	47.25%	62.48%	
R2L	0.00%	0.00%	0.00%	
U2R	0.00%	0.00%	0.00%	
accuracy				71.06%

طبق نتایج جدول ۲، میزان دقت (Accuracy) کلی به دست آمده از اعمال درخت تصمیم بر روی این مجموعه داده برابر با ۷۵/۴۹٪ می‌باشد. میزان دقت کلی حاصل از اعمال XGBoost بر روی این مجموعه داده برابر با ۷۴/۸۴٪ می‌باشد. به این ترتیب می‌توان دریافت که در مورد این مجموعه داده دقت کلی روش درخت تصمیم از XGBoost بیشتر است. میزان دقت کلی با اعمال جنگل تصادفی بر روی این مجموعه داده برابر با ۷۱/۰۶٪ می‌باشد که بدترین میان دقت در بین تمامی روش‌های بررسی شده است. میزان دقت کلی kNN بر روی این مجموعه داده برابر با ۷۵/۲۵٪ می‌باشد.


نتایج ثبت شده در جدول می‌توان دریافت روش‌های درخت تصمیم، XGBoost و kNN عملکرد خوبی از خود نشان داده‌اند. در فرآیند توسعه روش پیشنهادی عملکرد این روش‌ها در بخش طبقه‌بندی سیستم مورد بررسی قرار گرفت و روش XGBoost بیشترین بهبود را با تنظیم پارامترها به دست آورد و به عنوان روش یادگیری در سیستم پیشنهادی به کار گرفته شد.



شکل ۲: مقایسه روش پیشنهادی با سایر راهکارها در شناسایی حمله DoS با توجه به معیار Precision



شکل ۳: مقایسه روش پیشنهادی با سایر راهکارهای موردبررسی برای شناسایی حمله DoS با توجه به معیار Recall



شکل ۴: مقایسه روش پیشنهادی با سایر راهکارهای موردبررسی برای شناسایی حمله DoS با توجه به معیار F1-Score

مقایسه روش پیشنهادی با سایر راهکارهای موردبررسی برای شناسایی حمله DoS با توجه به معیار Accuracy در شکل ۵ نشان داده شده است.

۲.۴. پارامترهای تعیین شده به کمک روش Successive halving

این تحقیق برای بهینه‌سازی XGBoost از روش Successive halving بهره‌برده است. پارامترها نیز $n_estimators$ ، $min_samples_split$ ، $min_samples_leaf$ و max_depth می‌باشند.

$n_estimators$: تعداد مراحل تقویتی برای انجام است. تعداد زیاد این عملگر معمولاً عملکرد بهتری را به همراه دارد. مقادیر باید در محدوده $[1, inf]$ باشد.

$min_samples_split$: یعنی حداقل تعداد نمونه موردنیاز برای تقسیم یک گره داخلی. اگر int ، مقادیر باید در محدوده $[2, inf]$ باشد. $min_samples_leaf$: حداقل تعداد نمونه موردنیاز برای قرار گرفتن در یک گره برگ است. یک نقطه تقسیم در هر عمق تنها در صورتی در نظر گرفته می‌شود که حداقل نمونه‌های آموزشی $min_samples_leaf$ در هر یک از شاخه‌های چپ و راست باقی‌ماند. این مورد ممکن است اثر هموار سازی مدل را به خصوص در رگرسیون داشته باشد. اگر int ، مقادیر باید در محدوده $[1, inf]$ باشد.

max_depth : حداکثر عمق برآوردهای رگرسیون فردی. حداکثر عمق تعداد گره‌ها را در درخت محدود می‌کند. این پارامتر باید برای بهترین عملکرد تنظیم شود. بهترین مقدار به تعامل متغیرهای ورودی بستگی دارد. مقادیر باید در محدوده $[1, inf]$ باشد.


در این تحقیق، مقادیر به دست آمده به کمک روش successive halving، برای پارامترهای $n_estimators$ ، $min_samples_split$ ، $min_samples_leaf$ و max_depth به ترتیب برابر با ۱۵۶، ۲، ۱ و ۴ می‌باشد. (جدول ۳)

جدول ۳: نتایج اعمال روش پیشنهادی

	Precision	recall	f1-score	
Dos	98.15%	80.18%	87.37%	
Normal	76.24%	96.47%	85.24%	
Probe	81.19%	73.43%	76.21%	
R2L	86.35%	26.72%	29.57%	
U2R	65.13%	33.84%	41.68%	
accuracy				78.92%

طبق جدول ۳، روش پیشنهادی در این پژوهش، نسبت به سایر راهکارهای موردبررسی، دقت بالاتری برای شناسایی حالات حمله و نرمال ارائه می‌دهد. برای تصویر سازی بهتر نتایج حاصل از پیاده سازی، نمودار میله‌ای برای حمله DoS با توجه به معیارهای مختلف در ادامه نشان داده شده است.

مقایسه روش پیشنهادی با سایر راهکارهای موردبررسی برای شناسایی حمله DoS با توجه به معیار Precision در شکل ۲ نشان داده شده است.



شکل ۵: مقایسه روش پیشنهادی با سایر راهکارهای مورد بررسی برای شناسایی حمله DoS با توجه به معیار Accuracy

در جدول ۴، نتایج مقایسه روش مطرح شده در این پژوهش و راهکار پژوهش [۱۸] از منظر معیار F-Measure ارائه شده است. این تحقیق نیز نتایج خود را روی چهار کلاس مختلف مجموعه داده NSL-KDD جداگانه ثبت کرده است. مقایسه نشان می‌دهد راهکار پیشنهادی تحقیق حاضر در زمینه حملات U2R، DOS، Normal و عملکرد بهتری دارد.

جدول ۴: مقایسه معیار F-Measure در سیستم پیشنهادی و روش

ارائه شده در مقاله [۱۸]		
سیستم پیشنهادی	روش ارائه شده مقاله [۱۸]	دسته رکورد
87.37%	77.19%	تست DoS
41.68%	14.17%	تست U2R
29.57%	39%	تست R2L
76.21%	76.40%	تست Probe
85.24%	75.33%	تست Normal

۵. نتیجه گیری

سیستم‌های تشخیص نفوذ، وظیفه شناسایی و تشخیص هرگونه استفاده غیرمجاز از سیستم و سوءاستفاده یا آسیب‌رسانی توسط هر دودسته کاربران داخلی و خارجی را بر عهده دارند. تشخیص و جلوگیری از نفوذ امروزه به عنوان یکی از مکانیزم‌های اصلی در برآوردن امنیت شبکه‌ها و سیستم‌های رایانه‌ای مطرح است و عموماً در کنار دیوارهای آتش و به صورت مکمل امنیتی برای آن‌ها مورد استفاده قرار می‌گیرند. سیستم‌های تشخیص نفوذ به صورت سامانه‌های نرم‌افزاری و سخت‌افزاری ایجاد شده‌اند و هر کدام مزایا و معایب خاص خود را دارند. سرعت و دقت از مزایای سیستم‌های سخت‌افزاری است و عدم شکست امنیتی آن‌ها توسط نفوذ گران، قابلیت دیگر این گونه سیستم‌ها می‌باشد؛ اما استفاده آسان از نرم‌افزار، قابلیت سازگاری در شرایط نرم‌افزاری و تفاوت سیستم‌های عامل مختلف، عمومیت بیشتری را به سامانه‌های نرم‌افزاری می‌دهد و عموماً این گونه سیستم‌ها انتخاب مناسب‌تری هستند. با توجه به اهمیت این موضوع در این پژوهش به ارائه راهکاری مبتنی بر تلفیق

روش‌های XGBoost و خوشه‌بندی kMeans برای تشخیص نفوذ در شبکه‌های کامپیوتری پرداخته شد.

طبق پیاده سازی صورت گرفته و نتایج حاصل، اعمال روش تلفیقی XGBoost و خوشه‌بندی kMeans با در نظر گرفتن ملاحظات مطرح شده، منجر به دستیابی به نتایج مناسبی می‌شود. همچنین بهره‌گیری از روش ژنتیک به شناسایی ویژگی‌های مهم‌تر در مجموعه داده کمک می‌کند.

در این آزمایش سیستم پیشنهادی و روش مطرح شده در پژوهش [۱۸] مقایسه شده‌اند. اقدام و همکاران در سال ۲۰۱۶ با بهره‌گیری از الگوریتم کلونی مورچه، راهکاری برای تعیین بهترین ویژگی‌ها در مسئله نفوذ به سیستم‌های کامپیوتری ارائه داده‌اند. برای ارزیابی روش مطرح شده در پژوهش [۱۸] از مجموعه داده NSL-KDD بهره برده شده است.

۶. کارهای آتی

در این تحقیق راهکاری با استفاده از ترکیب روش‌های XGBoost، KMeans و الگوریتم ژنتیک برای حل مسئله تشخیص نفوذ ارائه شده است. با این حال با توجه به اهمیت و ویژگی‌های خاص این مسئله، پیدا کردن روش‌های به روز پیوسته مورد نیاز است. از آنجاکه با تمرکز بر ویژگی‌های مهم، عملکرد پیش‌بینی و استحکام و قابلیت تفسیر مدل افزایش می‌یابد، توجه به این بخش و به کار بردن سایر روش‌های موجود اهمیت زیادی دارد. برای ادامه این پژوهش می‌توان از سایر روش‌های بهینه‌سازی به جای روش ژنتیک بهره برد. روش‌های بهینه‌سازی تکاملی متعددی ارائه شده است از جمله الگوریتم بهینه‌سازی ازدحام ذرات، جستجوی هارمونی، گرگ خاکستری، وال، ممتیک و

از تکنیک‌های یادگیری جمعی نیز می‌توان برای بهبود نتایج کمک گرفت. از جمله روش‌های جمعی شناخته شده، روش بگینگ و پشته سازی می‌باشد که امکان بهبود عملکرد دسته‌بندی‌های ضعیف‌تر را فراهم می‌کند.

در این پژوهش به دلیل در اختیار نبودن مجموعه داده‌های داخلی، از داده‌های موجود در وب استفاده شده است. برای رفع این محدودیت، پژوهشگران می‌توانند با بررسی بیشتر، تأمین کنندگان داده‌ها در حوزه امنیت داخل کشور را شناسایی نموده و در صورت امکان از راهکار پیشنهادی بر روی داده‌های داخلی بهره‌برند. علاوه بر این، توسعه ارزیابی‌های فعلی با استفاده از ترافیک شبکه اصلی برای نشان دادن ارزش مدل پیشنهادی یکی از مواردی است که در ادامه می‌توان به آن پرداخت.

References

- [1] H. N. Mohsenabad, A. Asghari, "Intrusion detection in computer networks using data mining techniques based on feature selection," The first international conference on new research achievements in electrical and computer

- [12] S. Deshmukh-Bhosale, S.S. Sonavane, "A real-time intrusion detection system for wormhole attack in the RPL based Internet of Things," *Procedia Manufacturing*, vol. 32, pp. 840-847, 2019.
- [13] E.U.H. Qazi, M.H. Faheem, T. Zia, "HDLNIDS: hybrid deep-learning-based network intrusion detection system" *Applied Sciences*, 13(8), p.4921, 2023.
- [14] S. Manimurugan, M. Al-qdah, M. Mustaffa, C. Narmatha, R. Varatharajan, "Intrusion detection in networks using crow search optimization algorithm with adaptive neuro-fuzzy inference system," *Microprocessors and Microsystems*, vol. 79, p. 103261, 2020.
- [15] A. Golrang, A. Mohammadi Golrang, S. Yildirim Yayilgan, O. Elezaj, "A novel hybrid IDS based on modified NSGAI-ANN and random forest," *Electronics*, vol. 9, no. 4, p. 577, 2020.
- [16] V. Hnamte, H. Jamal, "DCNNBiLSTM: An efficient hybrid deep learning-based intrusion detection system", *Telematics and Informatics Reports* 10 (2023): 100053.
- [17] A. Kaffash, S.R. Kamel, M. Kheirabadi, "An Effective and Lightweight Intrusion Detection for IoT based on Fog and Cloud using KNN Classification," *intelligent multimedia processing and communication systems(IMPCS)*, 5 (2), 55-64, 2024.
- [18] 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)*, 4 (1), 1-10, 2023.
- [19] S. S. Ghanadpour, A. Hezarkhani, "Investigating the behavior of copper element with respect to molybdenum, lead and zinc elements in Perkam porphyry copper deposit in Kerman province, using K-Means method," *Advanced applied geology*, vol. 3, No. 1, pp. 43-53, 2013. [Persian]
- [20] M. H. Aghdam, P. Kabiri, "Feature selection for intrusion detection system using ant colony optimization," *International Journal of Network Security*, Vol.18, no.3, PP.420-432, 2016
- engineering, Amirkabir University, Tehran, 2016 <https://civilica.com/doc/496737> [Persian]
- [2] T. Fawcett, "An introduction to ROC analysis," *Pattern recognition letters*, vol. 27, no. 8, pp. 861-74, 2006.
- [3] S. Thapa, M. Akalanka, "The role of intrusion detection/prevention systems in modern computer networks: A review," In *Conference: Midwest Instruction and Computing Symposium (MICS)*, vol. 53, pp. 1-14. 2020.
- [4] M.K. Yadav, K.P. Sharma, "Intrusion Detection System using Machine Learning Algorithms: A Comparative Study," In *2021 2nd International Conference on Secure Cyber Computing and Communications (ICSCCC)*, pp. 415-420. IEEE, 2021.
- [5] M. Niai, J. Tannah, G. Shahmohammadi, A. Pourabrahimi, A Model for Multi-Class Intrusion Detection Using Machine Learning and Dragonfly Feature Selection, *Scientific Journal of Electronic & Cyber Defense*, Vol. 10, No. 3, Autumn 2022, Serial No. 39.
- [6] J. Mazloum, H. Begdali, Integrated optimal hybrid deep neural network with feature selection for intrusion detection system in cyber attacks, *electronic and cyber defense*, 2022 [Persian]
- [7] H. Najafi Mohsen Abad, M. Ketabi, intrusion detection in computer networks using data mining techniques, the third international conference on recent innovations in electrical and computer engineering, Tehran, 2015 [Persian] <https://civilica.com/doc/576765>
- [8] M. Mozafari, Development of an intrusion detection system (IDS) in computer networks using Bayesian networks, 2016. [Persian]
- [9] M. A. Ferrag, L. Maglaras, S. Moschoyiannis, H. Janicke, "Deep learning for cyber security intrusion detection: approaches, datasets, and comparative study," *Journal of Information Security and Applications*, vol. 50, Article ID 102419, 2020.
- [10] J. Hui, Z. He, G. Ye, and H. Zhang, "Network intrusion detection based on PSO-XGBoost model," *IEEE Access* vol. 8, pp. 58392-58401, 2020.
- [11] S. Bhattacharya, P. K. R. Maddikunta, R. Kaluri, S. Singh, T. R. Gadekallu, M. Alazab, U. Tariq, "A novel PCA-firefly based XGBoost classification model for intrusion detection in networks using GPU," *Electronics*, vol. 9, no. 2, p. 219, 2020.

پی‌نوشت

³ Recall⁴ Accuracy¹ Gradient Boosting Decision Tree² Precision