

علمی - پژوهشی

تشخیص حملات انکار سرویس با روش یادگیری جمعی

مهدی اسدی^{۱*}، باقر زارعی^۲

۱- استادیار، دانشگاه آزاد اسلامی واحد خامنه ۲- استادیار، دانشگاه آزاد اسلامی واحد شبستر

(دریافت: ۱۴۰۱/۱۲/۲۲، بازنگری: ۱۴۰۲/۰۲/۰۱، پذیرش: ۱۴۰۲/۰۲/۲۲، انتشار: ۱۴۰۲/۰۳/۰۱)

DOR: <https://dor.isc.ac/dor/20.1001.1.26762935.1402.14.1.5.5>

چکیده

در سال‌های اخیر، فضای مجازی مملو از حملات اینترنتی از جمله حملات انکار سرویس، فیشینگ اطلاعات، کلاهبرداری مالی، ارسال هرزنامه ایمیل و غیره شده است. از رایج‌ترین حملات اینترنتی که سبب زیان‌های اقتصادی قابل توجهی به زیرساخت مالی کشورهای مختلف شده است، حملات انکار سرویس است. به‌عنوان یک اقدام پیشگیرانه، سامانه‌های تشخیص نفوذ مجهز به الگوریتم‌های طبقه‌بندی یادگیری ماشین برای تشخیص ناهنجاری‌ها در ترافیک شبکه توسعه داده شده است. این الگوریتم‌های طبقه‌بندی در ارتباط با نوع حمله انکار سرویس، میزان موفقیت متفاوتی در شناسایی این حملات داشته و به کاربران اجازه می‌دهند تا به طور مؤثر بین ترافیک عادی و ترافیک مخرب انکار سرویس با دقت خوبی تمایز قائل شوند. در روش پیشنهادی، سه مرحله برای شناسایی و طبقه‌بندی متداول‌ترین حملات انکار سرویس به کار گرفته شده است. در مرحله اول، پیش‌پردازش داده‌های مجموعه داده واقعی SNMP-MIB برای حذف داده‌های ناقص و مقیاس‌بندی داده‌ها انجام می‌شود. در مرحله دوم با کاهش تعداد متغیرهای مجموعه داده، صرفاً از متغیرهای گروه واسط مجموعه داده استفاده شده که منجر به کاهش زمان تشخیص حملات می‌شود و در مرحله آخر روش یادگیری جمعی نظارتی رأی‌گیری برای تفکیک ترافیک عادی از ترافیک حمله به کار گرفته می‌شود. نتایج نشان می‌دهد که می‌توان ترافیک عادی و ۵ حمله انکار سرویس از مجموعه داده استفاده‌شده را با نرخ دقت ۱۰۰ درصدی تشخیص داد و تنها دقت تشخیص دو حمله UDP Flood و Slowloris به ترتیب با ۹۹/۸۷ و ۹۹/۹۴ درصد، با استفاده از روش پیشنهادی دارای خطای بسیار ناچیزی بوده است.

کلیدواژه‌ها: حمله انکار سرویس، یادگیری ماشین جمعی، تشخیص ناهنجاری شبکه، مجموعه داده SNMP-MIB، ترافیک شبکه، امنیت شبکه

Detection of Denial of Service Attacks by Ensemble Learning Method

M. Asadi¹, B. Zarei

Islamic Azad University, Khameneh Branch, Khameneh, Iran

(Received: 2023/03/11 ; revised: 2023/04/13 ; Accepted: 2023/05/11 ; published: 2023/05/22)

Abstract

In recent years, cyberspace has been filled with cyber-attacks such as denial of service (DoS) attacks, information phishing, financial fraud, spam and so on. One of the most common cyber-attacks that have caused significant economic damage to the financial infrastructure of different countries is denial of service attacks. As a preventive measure, intrusion detection systems equipped with machine learning classification algorithms have been developed to detect anomalies in network traffic. These classification algorithms, depending on the type of DoS attack, have varying degree of success in detecting these attacks and allow users to effectively identify between normal traffic and malicious DoS traffic. In the proposed approach, three steps are used to identify and classify the most common denial of service attacks. The first step is to pre-process the actual SNMP-MIB dataset to scale the data and delete the defective data. In the second stage, by reducing the number of data set features, only the features of the interface group are used, which leads to a reduction in attack detection time. The results show that using the proposed approach, normal traffic and five DoS attacks can be detected from the SNMP-MIB dataset with 100% accuracy rate. Only the detection accuracy of two attacks, UDP Flood and Slowloris, with 99.87 and 99.94% respectively, had a very small error of detection rate.

Keywords: Denial of Service Attack, Ensemble Machine Learning, Network Anomaly Detection, SNMP-MIB Dataset, Network Traffic, Network Security

*Corresponding Author E-mail :mehdi.asadi@iau.ac.ir

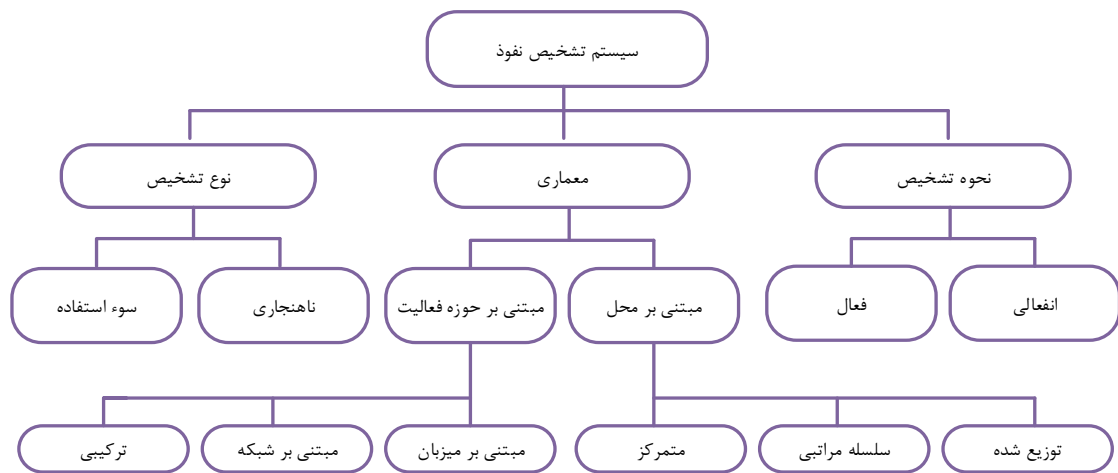
This article is an open-access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license.

۱. مقدمه

می‌شوند [۵]. برای مقابله با این حملات، سیستم تشخیص نفوذ به یکی از اجزای اصلی هر سامانه در شبکه تبدیل شده است. هدف سیستم تشخیص نفوذ، شناسایی درخواست‌های مخرب ورودی به شبکه است [۶-۸].

شکل (۱)، نمای کلی یک سیستم تشخیص نفوذ را نشان می‌دهد. دو روش اصلی برای تشخیص این درخواست‌ها وجود دارد؛ اولین روش که تشخیص ناهنجاری نفوذ^۳ نامیده می‌شود درخواست‌های جدید ورودی به سامانه را با درخواست‌های عادی قبلی مقایسه کرده و ناهنجاری در ترافیک شبکه را تعیین می‌کند، دومین روش که موسوم به تشخیص سوءاستفاده از نفوذ^۴ [۹] است درخواست‌های جدید را با امضاهای حملات شناخته‌شده مقایسه کرده و تعیین می‌کند که آیا الگوی حملات با امضاهای موجود مطابقت دارد یا نه؟

با گسترش اینترنت و جذب بیشتر جنبه‌های زندگی روزمره از هر زمان دیگری، از ارتباطات اجتماعی گرفته تا پرداختی‌های الکترونیکی، تعداد حملات اینترنتی مخرب هم از نظر نوع و هم از نظر تعداد افزایش یافته است؛ بنابراین، نیاز به شناسایی انواع مختلف این حملات و جلوگیری از استفاده آن‌ها از فن‌های مختلف امنیت شبکه بسیار مهم است [۱]. هدف برخی از حملات دسترسی غیرمجاز به دستگاه‌ها و اطلاعات مانند سرریز بافر و حملات بروت فورث^۱ است همچنین در حملات دیگر از قبیل کرم اینترنتی و حملات انکار سرویس^۲، هدف آن است که سامانه‌ها از دسترس خارج شوند [۲-۴]. در بین تمام انواع حملات ذکرشده، حملات انکار سرویس به‌عنوان خطرناک‌ترین و پرکاربردترین حملات مورد استفاده قرار می‌گیرند و سبب ضررهای مالی هنگفتی



شکل ۱. نمای یک سیستم تشخیص نفوذ [۱۰]

از جمله پروتکل کنترل انتقال^۴، پروتکل دیتاگرام کاربر^۵، پروتکل اینترنت^۶، پروتکل پیام کنترلی اینترنت^۷ را نیز جمع‌آوری می‌کند [۱۱]. شکل (۲) چگونگی ترکیب پروتکل ساده مدیریت شبکه با پایگاه اطلاعات مدیریت^۸ را به‌عنوان یک اصل اساسی در هر مدل مدیریت اینترنت نشان می‌دهد. برای استفاده از این حجم زیاد داده، یک سیستم پایگاه داده معروف به پایگاه اطلاعات مدیریت از چندین متغیر مدیریتی برای ذخیره این داده‌ها در قالب آماری استفاده می‌کند. در زمان اتصال پایگاه اطلاعات مدیریت به پروتکل ساده مدیریت شبکه، سیستم مناسبی برای شناسایی و تشخیص انواع حملات مختلف با استفاده از نظارت غیرفعال و جمع‌آوری و ذخیره‌سازی سازمان‌یافته داده‌ها فراهم می‌شود [۹].

هر دو روش اشاره‌شده، برای تشخیص نفوذ، متکی به مجموعه داده‌ای هستند که برای مقایسه با درخواست‌های جدید استفاده می‌کنند. به‌عنوان مثال، هنگام استفاده از داده‌های بسته خام، بار پردازش قابل توجه بوده و منجر به کند شدن زمان تشخیص می‌شود، این امر منجر به توسعه پروتکل‌های مختلف برای نظارت و مدیریت بسته‌های داده از جمله پروتکل اطلاعات مدیریت مشترک^۱، مانیتورینگ از راه دور شبکه^۲ و پروتکل ساده مدیریت شبکه^۳ شده است. پروتکل ساده مدیریت شبکه، اطلاعات دستگاه-ها و تجهیزات مختلف متصل به یک شبکه، اطلاعات مرتبط با لایه‌های مختلف شبکه و همچنین اطلاعات پروتکل‌های مختلف

¹ Brute Force Attacks

² Denial of Service (DoS)

³ Anomaly Intrusion Detection (AID)

⁴ Misuse Intrusion Detection (MID)

⁵ Common Management Information Protocol (CMIP)

⁶ Remote Network Monitoring (RNM)

⁷ Simple Network Management Protocol (SNMP)

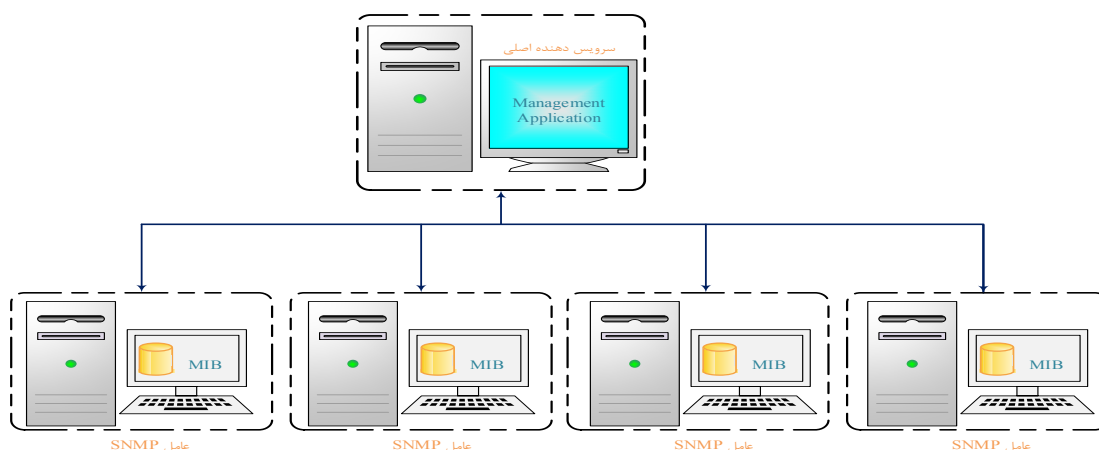
⁴ Transmission Control Protocol (TCP)

⁵ User Datagram Protocol

⁶ Internet Protocol (IP)

⁷ Internet Control Message Protocol (ICMP)

⁸ Management Information Base (MIB)



شکل ۲. معماری مدیریت شبکه [۱۳]

مقایسه با طبقه‌بندی‌کننده‌های یادگیری ماشین و روش‌های ارائه‌شده در مطالعات پیشین در بخش ۵ نمایش داده شده است. در نهایت، نتیجه‌گیری این مقاله در بخش ۶ ارائه شده است.

۲. پیشینه تحقیق

از آنجاکه شناسایی ناهنجاری‌ها و تشخیص نفوذ در شبکه بسیار حائز اهمیت است، مطالعات و تحقیقات زیادی در گذشته انجام یافته و مورد ارزیابی قرار گرفته است. اکثر این روش‌ها بر تجزیه و تحلیل داده‌های ترافیک خام بر اساس جریان شبکه، آدرس‌های آی پی، تعداد بسته‌های ردوبدل شده در شبکه، پورت‌ها و سایر ویژگی‌های کلیدی متمرکز بوده‌اند. نوع دیگری از روش برای تشخیص ناهنجاری‌ها استفاده از پایگاه اطلاعات مدیریت پروتکل مدیریت شبکه ساده^۱ به‌عنوان منبع داده است. در این بخش به بررسی تحقیقات پیشین با محوریت تشخیص نفوذ با استفاده از روش پایگاه اطلاعات مدیریت پروتکل مدیریت شبکه ساده می‌پردازیم.

یکی از مطالعات اولیه در این زمینه توسط کابرا و همکاران [۱۴] انجام شده است که از آزمون‌های آماری حاصل از متغیرهای مختلف پایگاه اطلاعات مدیریت برای تشخیص زود هنگام حملات انکار سرویس توزیع شده^۲ استفاده کردند. برای استخراج متغیرها، سه نوع مختلف از حملات انکار سرویس توزیع شده اعمال شده و ۹۱ متغیر پایگاه اطلاعات مدیریت از پنج گروه مختلف (TCP، UDP، IP، ICMP و SNMP) در سمت سیستم مهاجم و نیز در سمت سیستم قربانی مورد بررسی قرار گرفته است. ارزیابی این روش نشان داده است که پیش‌بینی و تشخیص حمله انکار

النایمت و همکاران [۹]، ثابت کردند که ناهنجاری‌های شبکه را می‌توان با استفاده از SNMP-MIB و دسته‌بندی‌کننده‌های مناسب تشخیص داد. آن‌ها از مجموعه داده‌ای با ۳۴ متغیر استفاده کردند که در پنج گروه طبقه‌بندی شده بودند. نتایج به‌دست آمده موفقیت در تشخیص حملات با درصد بالایی را ارائه داده است.

در روش ارائه‌شده، با کاهش فرآیندها و عملیات انجام شده توسط سیستم تشخیص نفوذ برای یادگیری الگوهای ترافیکی و طبقه‌بندی ترافیک شبکه، سرعت تشخیص حملات افزایش یافته است. هدف، افزایش کارایی سیستم تشخیص نفوذ با کاهش منابع مورد نیاز است. هدف از این مقاله تجزیه و تحلیل پرکاربردترین حملات انکار سرویس به‌صورت جداگانه و مقایسه آن‌ها از نظر میزان تشخیص با استفاده از مجموعه داده SNMP-MIB ارائه شده توسط الکساب و همکاران [۱۲] است. در روش پیشنهادی، ابتدا عملیات پیش‌پردازش داده‌ها بر روی مجموعه داده، برای حذف داده‌های پرت انجام می‌شود. در مرحله انتخاب ویژگی‌های تأثیرگذار، با بررسی‌ها و آزمایش‌های مختلف صرفاً از هشت متغیر گروه واسط مجموعه داده به‌جای استفاده از تمامی ۳۴ متغیر مجموعه داده، استفاده می‌شود و در نهایت روش یادگیری رأی‌گیری برای تفکیک ترافیک عادی از ترافیک حمله، مورد استفاده قرار می‌گیرد.

ساختار مقاله در ادامه به شرح زیر است: بخش ۲ مروری بر پژوهش‌های مرتبط را که از یادگیری ماشین در سامانه‌های تشخیص نفوذ استفاده کرده‌اند ارائه می‌دهد. در بخش ۳، مفاهیم پایه همچون حملات انکار سرویس، پروتکل شبکه ساده، یادگیری ماشین و حملات انکار سرویس ارائه شده است. روش پیشنهادی، تشریح مجموعه داده SNMP-MIB، به‌کارگیری یادگیری ماشین و جزئیات پیاده‌سازی در بخش ۴ و نتایج حاصل از آزمایش‌ها و

^۱ SNMP-MIB

^۲ Distributed Denial of Service (DDoS)

استفاده کرده و این متغیرها نیز توسط مدل دوم برای ایجاد یک سیستم تشخیص نفوذ استفاده شده است. همچنین مدل سوم از خروجی مدل دوم آن برای تشخیص بلادرنگ حملات انکار سرویس استفاده کرده است. این سیستم از چهار گروه پایگاه اطلاعات مدیریت مرتبط با حملات ICMP، UDP و TCP-SYN برای آزمایش استفاده کرده و نرخ تشخیص بالای ۹۹/۰۳ را به دست آورده است.

از سوی دیگر، سرونی و همکاران [۲۰] از یک مکانیسم تشخیص غیرمتمرکز دومرحله‌ای بر اساس الگوریتم خوشه‌بندی استفاده کردند. مرحله اول شامل یک مرحله پیش‌پایه بوده که در این مرحله چندین منبع برای جمع‌آوری پارامترهای SNMP-MIB مورد بررسی قرار گرفته است. مرحله دوم مرحله تشخیص ترافیک بود که از پارامترهای مجموعه داده برای طبقه‌بندی ترافیک در ترافیک غیرعادی و ترافیک معمولی استفاده شده است. برای آزمایش مکانیسم تشخیص غیرمتمرکز، سرونی و همکارانش از زیرمجموعه‌ای از مجموعه داده مذکور که مربوط به مکانیسم‌های تشخیص غیرمتمرکز است، استفاده کردند و پس از انجام آزمایش‌ها مشخص شد که الگوریتم دومرحله‌ای پیشنهادی آن‌ها قابلیت شناسایی با موفقیت نفوذهای محتمل را در زیرمجموعه‌ای از مجموعه داده داشته است.

النایمت و همکاران [۹] از فن‌های طبقه‌بندی یادگیری ماشینی همچون جنگل تصادفی، آداپوست و شبکه عصبی چندلایه برای ساخت مدل تشخیص حملات انکار سرویس و حملات بروت فورث بر روی داده‌های پایگاه اطلاعات مدیریت مرتبط با پروتکل مدیریت شبکه ساده استفاده کرده و متغیرهای پایگاه اطلاعات مدیریت را در پنج گروه (ICMP، IP، Interface، TCP و UDP) دسته‌بندی کرده‌اند. از نتایج کار آن‌ها این گونه استنباط شده است که گروه‌های واسط و آی‌پی تنها گروه‌هایی هستند که در بین پنج گروه، بیشترین تأثیر و سایر گروه‌ها کمترین تأثیر را از انواع حملات داشته‌اند. همچنین با استفاده از طبقه‌بندی کننده جنگل تصادفی بالاترین میزان دقت برای گروه آی‌پی به میزان ۱۰۰٪ و برای گروه آی‌پی به میزان ۹۹/۹۳٪ به دست آمده است.

همچنین النایمت و همکاران [۲۱] در مقاله دیگری برای تشخیص ناهنجاری‌های شبکه از طبقه‌بند یادگیری ماشینی LazaY.IBk، روش همبستگی^۳ و الگوریتم Relief برای انتخاب ویژگی‌های تأثیرگذار از پارامترهای مجموعه داده استفاده کرده‌اند. آن‌ها علاوه بر کاهش استفاده از منابع سخت‌افزاری همچون پردازنده و حافظه میزان دقت تشخیص بالایی نیز ارائه داده‌اند.

در تحقیق ارائه‌شده توسط مانا و همکاران [۲۲]، داده‌های مجموعه داده برای شناسایی ناهنجاری‌های حملات انکار سرویس

سرویس توزیع شده قبل از خاموش شدن سیستم قربانی با نرخ مثبت کاذب^۱ تقریبی تنها ۱٪ امکان پذیر بوده است.

در تحقیق ارائه‌شده توسط رحمانی و همکاران [۱۵]، روش پیشنهادی دیگری با استفاده از آزمایش‌های آماری برای تشخیص حملات پیشنهاد شده است. متغیرهای پایگاه اطلاعات مدیریت با نمونه‌برداری از ترافیک شبکه از چهار گروه TCP، UDP، IP و ICMP جمع‌آوری شده است. در هر ۵ ثانیه نمونه‌گیری انجام شده و این روش برای پنج نوع حمله انکار سرویس توزیع شده مورد آزمایش قرار گرفته و میزان دقت بالایی در تشخیص را نشان داده است. سیائو و همکاران [۱۶] نیز از پارامترهای SNMP-MIB برای تشخیص یک نوع خاص از حمله بنام حمله جعلی ARP استفاده کرده‌اند. آن‌ها سه روش متفاوت شامل یک الگوریتم ساده بی‌زی، یک الگوریتم ماشین بردار پشتیبانی و در نهایت یک الگوریتم C4.5 را آزمایش کرده و نتایج این روش‌ها را با همدیگر مقایسه کرده‌اند. آن‌ها از معیارهایی نظیر نرخ مثبت کاذب، میزان دقت^۲ و نرخ از دست‌رفته برای شناسایی نقاط قوت و ضعف هر روش استفاده کرده‌اند. بر اساس نتایج به دست آمده الگوریتم درخت تصمیم C4.5 دارای بالاترین نرخ دقت بوده، در حالی که کمترین میزان دقت مربوط به الگوریتم بی‌زی ساده بود و الگوریتم ماشین بردار پشتیبانی دارای کمترین تعداد هشدارهای کاذب بوده است.

یو و همکاران [۱۷] موفق شده‌اند تا با روش پیشنهادی خود حملات سیل‌آسا را با استفاده از پارامترهای SNMP-MIB و الگوریتم درخت تصمیم C4.5 به میزان ۹۳٪ تشخیص دهند. این پارامترها بر اساس عملکرد حمله سیل‌آسا در محیط شبیه‌سازی به دست آمده و از یک الگوریتم بهبود یافته C4.5 برای طبقه‌بندی انواع مختلف ترافیک و تشخیص حملات سیل‌آسا بر روی پارامترهای تولید شده استفاده می‌کرد.

سرونی و همکاران [۱۸] در تحقیق دیگری از داده‌کاوای توزیع شده جدیدی برای تشخیص نوع خاصی از حمله انکار سرویس توزیع شده استفاده کردند که این روش در یک محیط شبکه شبیه‌سازی شده و بر روی ۱۴ پارامتر مجموعه داده (مرتبط با آی‌پی و تی‌سی‌پی) برای تشخیص حمله انجام شده است. این روش برای محیط‌های آزمایشگاهی غیرمتمرکز ارزیابی شده و میزان تشخیص مطلوبی را ارائه داده است.

در مقاله ارائه‌شده توسط النایمت و همکاران [۱۹] مجموعه پارامترهای مجموعه داده و روش یادگیری ماشینی برای ساخت یک سیستم تشخیص نفوذ دارای سه مدل استفاده شده است. ماژول اول از الگوریتم‌های C4.5، الگوریتم انتخاب ویژگی و الگوریتم RIPPER برای انتخاب متغیرهای برتر پایگاه اطلاعات مدیریت

^۱ False Positive Rate

^۲ Accuracy Rate

^۳ Correlation

۳-۱. حملات انکار سرویس

روش‌های زیادی از جمله از شنود، فیشینگ^۴ و تزریق اس کیوال^۵ برای به خطر انداختن شبکه وجود دارد. با این حال، یکی از روش‌های مورد استفاده مهاجمان، حمله انکار سرویس است. در مواردی که هدف حملات دیگر ممکن است برای دستیابی به دسترسی غیرمجاز یا داده‌های محافظت شده باشد، حملات انکار سرویس قصد دارند عملکرد شبکه یا خدماتی را که ارائه می‌دهد را مختل کنند. حمله انکار سرویس مجموعه اقداماتی است که مانع از انجام وظایف شبکه‌ها، منابع شبکه و کاربران مجاز آن شبکه‌ها می‌شود. برای دستیابی به این هدف، حمله انکار سرویس، منابع متعددی از شبکه را مورد هدف قرار داده و به خطر می‌اندازد. اولین منبع مورد حمله، پهنای باند شبکه است به طوری که حمله، اتصال بین یک سرور وب و تجهیزات آن که به آن متصل می‌شوند را هدف قرار داده و یا اتصال بین سرور وب و اینترنت جهانی را هدف قرار می‌دهد. دومین منبعی که حمله انکار سرویس می‌تواند هدف قرار دهد منابع سامانه کامپیوتری است، به طوری که درخواست‌های بسیار زیادی را به صورت مستمر به سامانه ارسال کرده و مانع از پاسخگویی به کاربران مجاز واقعی می‌شود. آخرین هدف برای حمله انکار سرویس منابع کاربردی و برنامه است که حمله با کل سامانه کاری ندارد و فقط یک برنامه خاص از آن سیستم را از دسترس خارج می‌کند.

در این بخش، انواع مختلف حملات انکار سرویس که اغلب توسط هکرها و مهاجمان مورد استفاده قرار می‌گیرند بررسی و ارائه می‌شود [۲۴]:

❖ حمله جعلی SYN: این حمله، اصلی‌ترین حمله سیل‌آسا است که جداول سرویس‌دهنده‌هایی را که ارتباطات را با مشتریان مدیریت می‌کنند، مورد هدف قرار می‌دهد. در این حمله از پروتکل دستکانی^۶ سه‌طرفه در درخواست‌های اتصال پروتکل کنترل انتقال استفاده می‌شود. روش دستکانی عادی سه‌طرفه با ارسال درخواست TCP-SYN توسط مشتری آغاز شده، سرویس‌دهنده با پیام SYN-ACK پاسخ می‌دهد و در نهایت مشتری یک بسته پاسخ را برای تأیید اتصال ارسال می‌کند. فعالیتی که در حمله جعلی SYN انجام می‌شود بدین گونه است که با آدرس آی پی مبدأ جعلی درخواست‌های TCP-SYN زیادی به سمت سرور ارسال می‌شود که سرویس‌دهنده درخواست SYN-ACK را به آن‌ها ارسال می‌کند. این کار سبب دو واکنش می‌شود؛ اولین مورد این است که تعداد زیادی درخواست TCP-SYN بدون دریافت بسته‌های پاسخ مناسب در جدول ذخیره می‌شوند؛ زیرا آدرس‌های آی پی جعلی به

در شبکه استفاده شده است. در روش ارائه شده توسط آن‌ها سه الگوریتم یادگیری ماشین جنگل تصادفی^۱، درخت تصمیم J48 و درخت REP برای طبقه‌بندی داده‌ها و دو الگوریتم ارزیابی ویژگی InfoGain و ReliefF برای انتخاب ویژگی‌های تأثیرگذار استفاده شده است. طبقه‌بندی کننده‌ها و انتخاب ویژگی‌ها بر روی داده‌ها و پارامترهای گروه آی پی اعمال شده و نتایج به دست آمده نشان داده که بیشترین دقت در تمام گروه‌های آی پی، زمانی است که از طبقه‌بندی کننده درخت REP استفاده شده است.

راجاسکار و ماگودیسواران [۲۳] با استفاده از روش‌های یادگیری ماشین بر روی مجموعه داده SNMP-MIB، مکانیسم مؤثری برای شناسایی و طبقه‌بندی حملات انکار سرویس توزیع شده ارائه داده‌اند. بدین منظور، پایگاه اطلاعات مدیریت برای طبقه‌بندی حملات مرتبط با پروتکل مدیریت شبکه ساده در نظر گرفته شده است. آن‌ها از شبکه عصبی بازگشتی دروازه‌ای^۲ مبتنی بر طبقه‌بندی کننده میانگین وزنی ویژگی دو جهت^۳ (GRU) (BWFA) به عنوان طبقه‌بندی کننده پیشنهادی برای نرخ تشخیص بالا و دقت در تشخیص حملات انکار سرویس توزیع شده استفاده کرده‌اند. برای انتخاب ویژگی‌های بهینه برای شناسایی حملات، آن‌ها از الگوریتم بهینه‌سازی ازدحام سالپ پیشرفته استفاده کرده و با استفاده از طبقه‌بندی کننده‌های مختلف، مطالعه دقیقی در مورد اثربخشی مجموعه داده در تشخیص حملات انکار سرویس توزیع شده ارائه داده‌اند. یافته‌های تجربی آن‌ها نشان می‌دهد که روش‌های یادگیری ماشینی در شناسایی و طبقه‌بندی حملات با نرخ دقت بالاتر بسیار مؤثر بوده است.

با توجه به اینکه سرعت تشخیص حملات انکار سرویس بسیار حائز اهمیت است و نیز دقت بالا برای تشخیص این حملات در محیط‌هایی همچون مراکز مالی و نظامی بسیار مهم است با انتخاب ۸ ویژگی گروه واسط بجای استفاده از ۳۴ ویژگی مجموعه داده SNMP-MIB، علاوه بر بالابردن سرعت، دقت بالایی نیز با به کارگیری تعداد ویژگی‌های کمتر و استفاده از روش جمعی حاصل شده است که با پیاده‌سازی آن نسبت به روش‌های پیشین و مطرح شده عملکرد بهتر و بالاتری ارائه کرده است.

۳. مفاهیم پایه

در ادامه به مباحثی همچون حملات انکار سرویس و انواع آن، پروتکل مدیریت شبکه ساده و الگوریتم‌های یادگیری ماشین پرداخته می‌شود.

^۴ Phishing

^۵ SQL Injections

^۶ Handshake Protocol

^۱ Random Forest

^۲ Gated Recurrent Unit Neural Network

^۳ Bidirectional Weighted Feature Averaging

روش Slowloris در اینجا است که در این حمله درخواست‌های پروتکل انتقال ابر متن کامل است؛ یعنی دارای فیلد طول محتوای پیام ارسال شده به درخواست را نشان می‌دهد؛ باین حال، محتوا بسیار آهسته با نرخ یک بایت در هر دو دقیقه تحویل داده می‌شود و در نهایت بار بسیار زیادی بر روی سرور می‌دهند اعمال می‌شود تا فعالیت سرور می‌دهنده توسط درخواست‌های پروتکل ناتمام مختل شود.

❖ حمله ICMP Echo: در شبکه‌های TCP/IP درخواست‌های Echo به طور مرتب برای تشخیص درگاه‌ها استفاده می‌شوند. مهاجمان و هکرها، درخواست‌های Echo و بسته‌های ICMP رو به سمت سرور می‌دهند ارسال می‌کنند و دسترسی مؤثر هر سرور می‌گیرند به سرور می‌دهنده را دشوار می‌کند. مدیران سامانه‌ها معمولاً این پروتکل را با دیوار آتش یا سامانه‌های تشخیص نفوذ محدود می‌کنند. حمله بروت فورث: این حمله به‌عنوان یک روش ساده برای دورزدن گذرواژه مورداستفاده قرار می‌گیرد، اما از آن به‌عنوان یک حمله انکار سرور نیز استفاده می‌شود با این حمله درخواست‌های احراز هویت گذرواژه به‌صورت سیل آسا به سمت سرور می‌دهنده ارسال می‌شود تا منابع آن به پایان برسد.

۳-۲. پروتکل مدیریت شبکه ساده (SNMP)

این پروتکل در لایه کاربرد شبکه برای کنترل بهتر و نظارت و تجزیه و تحلیل ترافیک یک شبکه خاص توسعه داده شده است که شامل دو زیرسیستم (۱) عامل پروتکل مدیریت شبکه ساده و (۲) مدیر پروتکل مدیریت شبکه ساده است که در شکل (۳) نشان داده شده است. عامل پروتکل مدیریت شبکه ساده بر روی دستگاه‌هایی که قصد نظارت بر روی آن‌ها را دارد تعبیه می‌شود و داده‌ها را از شبکه آن دستگاه جمع‌آوری کرده و در پایگاه اطلاعات مدیریت ذخیره می‌کند.

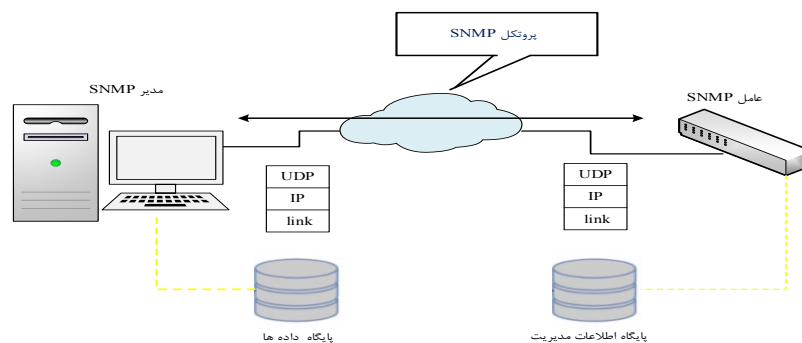
درخواست‌های SYN-ACK که سرور می‌دهنده ارسال می‌کند نمی‌تواند پاسخ دهد. دومین مورد اینکه برای هر درخواستی (SYN-ACK) که سرور می‌دهنده ارسال می‌کند، مکانی برای تأیید پاسخ در نظر گرفته شده و سبب ایجاد سربرار می‌شود. این موارد سبب می‌شود تا جدول سرور می‌دهنده با درخواست‌های ناقص TCP-SYN و SYN-ACK پر شود و نتواند سایر درخواست‌های اتصال مشتری را برآورده کند.

❖ حمله ارسال سیل آسای پروتکل دیپتاگرام کاربر^۱: این حمله یک درگاه خاص در سیستم یا سرور می‌دهنده قربانی را هدف قرار می‌دهد، سپس درگاه موردنظر را با بسته‌های پروتکل دیپتاگرام کاربر غرق می‌کند تا بیشتر از ظرفیت درگاه بسته‌ها بارگذاری شود و سرور می‌دهنده را خاموش کند.

❖ حمله ارسال سیل آسای پروتکل انتقال ابر متن^۲: حمله‌ای مبتنی بر پروتکل انتقال ابر متن است که با به‌کارگیری بات‌های متعددی که به وب سرور می‌دهنده نفوذ می‌کنند تا وظایف پروتکل انتقال ابر متن را انجام دهند منابع سرور می‌دهنده منجمله اطلاعات موجود در حافظه را تخلیه می‌کند.

❖ حمله Slowloris: یکی دیگر از حملات مبتنی بر پروتکل انتقال ابر متن است که در این حمله، مهاجم چندین اتصال به سرور می‌دهنده را بر اساس درخواست‌های ناقص پروتکل انتقال ابر متن ایجاد می‌کند، برای جلوگیری از قطع شدن این اتصالات، پیام‌های پی‌درپی برای زنده نگه‌داشتن اتصال ارسال می‌شود، این مداومت در به‌کارگیری تمامی اتصالات، یک سرور می‌دهنده را مشغول کرده و سبب رد سرور به سایر اتصالات می‌شود.

❖ حمله Slowpost: حمله‌ای تقریباً مشابه به حمله Slowloris است. Slowpost یکی دیگر از حملات مبتنی بر پروتکل انتقال ابر متن است که درخواست‌های پروتکل انتقال ابر متن را به سرور می‌دهنده قربانی ارسال می‌کند، تفاوت این روش حمله با



شکل ۳. پروتکل SNMP و زیرسیستم‌های آن [۱۳]

^۱ User Datagram Protocol (UDP)

^۲ Hyper Text Transfer Protocol (HTTP)

در روش‌های یادگیری ماشین جمعی، اجزای سازنده (مدل-های پایه) با یکدیگر ترکیب می‌شوند تا مدل‌های پیچیده‌تری ایجاد کنند. در اغلب اوقات مدل‌های پایه به تنهایی عملکرد خوبی ندارند؛ زیرا بایاس یا واریانس بالا دارند.

در روش یادگیری ماشین جمعی، برای ایجاد یک مدل، ابتدا مدل‌های پایه انتخاب می‌شود. در بسیاری از موارد از یک مدل یادگیری پایه یکتا استفاده می‌شود، بنابراین تعدادی مدل پایه یکسان وجود دارد و با روش‌های مختلف آموزش داده می‌شوند که به آن مدل‌های جمعی همگون^۶ [۲۶] می‌گویند. در روش دیگر، انواع مختلفی از مدل‌های یادگیری پایه استفاده می‌شود که به مدل‌های جمعی ناهمگون^۷ موسوم هستند. نکته مهم در انتخاب مدل‌های پایه، ترکیب منطقی و منسجم^۸ با یکدیگر است؛ یعنی اگر مدل پایه‌ای با بایاس کم و واریانس بالا انتخاب شود، باید از یک روش جمعی که تمایل به کاهش واریانس دارد استفاده شود، در حالی که اگر مدل‌های پایه با واریانس کم و بایاس بالا انتخاب شود، باید از روشی که تمایل به کاهش بایاس دارد، استفاده شود. سه روش کلی برای ترکیب مدل‌های پایه وجود دارد:

❖ روش بسته‌بندی^۹: در این روش از مدل‌های پایه همگون استفاده می‌شود، آموزش مدل‌ها به صورت مستقل از یکدیگر و به حالت موازی است و برای ترکیب مدل‌ها با یکدیگر از فرآیند میانگین‌گیری قطعی^{۱۰} استفاده می‌شود. الگوریتم جنگل تصادفی^{۱۱} نمونه‌ای از این دسته است.

❖ روش تقویتی^{۱۲}: در این روش نیز همانند روش بسته‌بندی مدل‌های پایه همگون مورد استفاده قرار می‌گیرد و به صورت دنباله‌ای و با یک روش تطبیقی^{۱۳} آموزش داده می‌شوند (یک مدل پایه وابسته به مدل قبل از خود است) و با یک استراتژی قطعی ترکیب می‌شوند. الگوریتم آدا بوست^{۱۴} نمونه‌ای از این دسته است.

❖ روش پشته‌سازی^{۱۵}: این روش از مدل‌های پایه ناهمگون استفاده می‌کند که آموزش به صورت موازی بوده و با آموزش یک متامدل^{۱۶} بر روی خروجی‌های پیش‌بینی شده مدل‌های

مدیر پروتکل مدیریت شبکه ساده این اطلاعات را از عامل پروتکل مدیریت شبکه ساده درخواست کرده و از آن برای ارائه تعدادی از وظایف مدیریت شبکه از جمله پیکربندی، اقدامات امنیتی و نظارت بر عملکرد و خطاها استفاده می‌کند. سه نسخه از پروتکل مدیریت شبکه ساده وجود دارد که هر کدام ویژگی‌های متفاوتی دارند که نسخه سوم آن با ویژگی‌های امنیتی بیشتری طراحی شده است و امن‌ترین نسخه این پروتکل محسوب می‌شود.

۳-۳. یادگیری ماشین

یادگیری ماشین، فنی برای تجزیه و تحلیل داده‌ها است که شامل ساخت و تطبیق مدل‌هایی است که به برنامه‌ها اجازه می‌دهند از طریق تجربه آموزش داده شوند. یادگیری ماشین شامل تولید الگوریتم‌هایی است که مدل‌های خود را برای بهبود توانایی آن‌ها در پیش‌بینی تطبیق می‌دهند [۲۵].

زمانی که یک فن یادگیری ماشین از مجموعه داده برچسب-گذاری شده برای آموزش الگوریتم استفاده می‌کند، یادگیری ماشین نظارتی نامیده می‌شود. دسته‌بندی، نوعی فن یادگیری ماشین نظارتی است که میزان دقت بالای آن سبب می‌شود تا در تعدادی از سامانه‌های تشخیص نفوذ برای دسته‌بندی ترافیک عادی از ترافیک غیرعادی با میزان موفقیت بالا مورد استفاده قرار گیرد. یادگیری جمعی^۱ حوزه‌ای در یادگیری ماشین است که در آن فن‌هایی مطرح شده است که به کمک آن‌ها از چندین مدل به صورت ترکیبی و هم‌زمان جهت تصمیم‌گیری استفاده می‌شود تا توان مدل در تخمین خروجی داده بالا برده شود.

در مدل‌های یادگیری ماشین ترکیبی یا مدل‌های جمعی، چندین مدل یادگیری‌های ضعیف^۲ یا مدل‌های پایه^۳ در حل یک مسئله برای دستیابی به نتایج مطلوب باهم ترکیب و آموزش داده شده می‌شوند. زمانی که مدل‌های ضعیف به صورت مناسب با یکدیگر ترکیب شوند مدل‌های دقیق‌تری می‌تواند تولید شود. در مدل‌های یادگیری ماشین جمعی، انتخاب مدل‌های پایه در دستیابی به نتایج مناسب بسیار حائز اهمیت است. انتخاب این مدل‌ها به متغیرهای زیادی از جمله مقادیر داده‌ها، فرضیه توزیع داده‌ها و ابعاد داده‌ها وابسته است. بایاس^۴ کم و واریانس^۵ کم، دو ویژگی اساسی و بااهمیت برای داشتن مدلی مناسب هستند.

⁶ Homogenous

⁷ Heterogeneous

⁸ Coherent

⁹ Bagging

¹⁰ Deterministic averaging process

¹¹ Random Forest

¹² Boosting

¹³ Adaptive

¹⁴ AdaBoost

¹⁵ Stacking

¹⁶ Meta-Model

¹ Ensemble learning

² Weak learner

³ Base models

⁴ Bias

⁵ Variance

- عادی‌سازی^۸: از عادی‌سازی برای مقیاس‌بندی هر سطر از داده، برای اینکه دارای طول یک باشد، استفاده می‌شود. این روش اساساً برای مجموعه داده‌های پراکنده^۹ که در آن تعداد صفر زیادی داریم مفید است.
- استانداردسازی^{۱۰}: برای تبدیل ویژگی‌های داده توسط یک توزیع گوسی^{۱۱} استفاده می‌شود. این روش میانگین و انحراف از معیار^{۱۲} را به یک توزیع گوسی استاندارد با میانگین صفر و یک تبدیل می‌کند.

در مدل پیشنهادی یادگیری جمعی رأی‌گیری، در مرحله پیش‌پردازش، داده‌های ناقص در مجموعه داده MIP-SNMP بررسی و حذف شده و همچنین با روش مقیاس‌بندی مینیمم - ماکزیمم با کمک کلاس MinMaxScaler از کتابخانه پایتون scikit-learn، داده‌ها مقیاس‌بندی مجدد می‌شود. در این روش مقیاس‌بندی ویژگی، مقیاس ویژگی‌ها بین صفر تا یک تنظیم می‌شود که با رابطه (۱) قابل محاسبه است [۲۵]:

$$x' = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (۰)$$

با این روش، همه داده‌های یک ویژگی در مجموعه داده، بین صفر و یک تنظیم می‌شوند. در مرحله انتخاب و کاهش ویژگی از زیرمجموعه داده واسط و متغیرهای این گروه بجای استفاده از تمامی ویژگی‌ها و متغیرهای مجموعه داده استفاده می‌شود؛ چون این ویژگی‌ها میزان همبستگی^{۱۳} بالایی نسبت به سایر ویژگی‌ها در مرحله انتخاب ویژگی از خود نشان داده‌اند. ویژگی‌هایی که بر اساس ماتریس همبستگی به‌عنوان ویژگی‌های برتر انتخاب می‌شوند، بسته به مقدار ضریب همبستگی و معیاری که برای بررسی همبستگی استفاده می‌شود، متفاوت است [۲۸]. در ادامه به برخی از معیارهای معمول برای بررسی همبستگی ویژگی‌ها در راستای انتخاب ویژگی‌های برتر، اشاره می‌شود.

- ضریب همبستگی پیرسون^{۱۴}: در این معیار، ضریب همبستگی پیرسون بین هر دو ویژگی محاسبه می‌شود که مقدار آن بین ۱- تا ۱ است. ویژگی‌هایی که ضریب همبستگی پایین دارند (نزدیک به صفر)، باهم هیچ همبستگی معناداری ندارند. ویژگی‌هایی که ضریب همبستگی بالا دارند (مثبت یا منفی)،

پایه، ترکیب می‌شوند. برای نمونه، در یک مسئله دسته‌بندی می‌توان از یک دسته‌بند کای نزدیک‌ترین همسایه^۱، یک درخت تصمیم^۲ و یک شبکه عصبی^۳ به‌عنوان مدل‌های پایه استفاده کرده و یک شبکه عصبی را به‌عنوان متامدل به کار گرفت. ورودی شبکه عصبی، خروجی سه مدل پایه بوده و پیش‌بینی نهایی بر اساس نتایج شبکه عصبی انجام می‌شود.

روش‌های بسته‌بندی برای ایجاد مدل‌های جمعی با واریانس کمتر نسبت به مدل‌های پایه خود، تمرکز دارند. ولی روش‌های تقویتی و پشته‌سازی تلاش می‌کنند تا مدلی قوی‌تر با میزان بایاس کمتر نسبت به مدل‌های پایه خود ایجاد کنند که امکان کاهش میزان واریانس نیز وجود دارد.

۴. روش پیشنهادی

روش پیشنهادی از روش یادگیری جمعی رأی‌گیری برای بهبود دقت و صحت در تشخیص حملات انکار سرویس استفاده می‌کند. روش پیشنهادی در سه مرحله کار می‌کند. همان‌طور که در مقدمه نیز اشاره شد، مدل پیشنهادی شامل مرحله پیش‌پردازش داده‌ها، مرحله انتخاب و کاهش ویژگی و درنهایت مرحله پیش‌بینی و تشخیص حملات است. چارچوب مدل پیشنهادی در زیر بخش‌های بعدی مورد بحث قرار می‌گیرد. مدل پیشنهادی در شکل (۴) نشان داده شده است.

روش‌های پیش‌پردازش داده که در ادامه معرفی می‌شوند، جهت تولید داده برای الگوریتم‌های یادگیری ماشین، می‌توانند روی مجموعه داده اعمال شوند. این روش‌ها عبارت‌اند از:

- مقیاس‌بندی^۴: مجموعه داده استفاده‌شده از ویژگی‌هایی با مقیاس متغیر تشکیل شده است، اما نمی‌توان چنین داده‌ای به الگوریتم یادگیری ماشین داد، چون به مقیاس‌بندی مجدد نیاز خواهد داشت. مقیاس‌بندی مجدد داده، این تضمین را به وجود می‌آورد که ویژگی‌ها در مقیاس مشابه قرار گیرند و ویژگی‌ها در بازه بین صفر و یک مجدداً مقیاس‌بندی می‌شوند. مقیاس‌بندی بر اساس سه روش زیر انجام می‌پذیرد:

۱- مقیاس‌بندی مینیمم - ماکزیمم^۵

۲- مقیاس‌بندی استاندارد^۶

۳- مقیاس‌بندی منسجم^۷

⁷ Robust Scaling

⁸ Normalization

⁹ Sparse

¹⁰ Standardization

¹¹ Gaussian distribution

¹² Standard Deviation

¹³ Correlation

¹⁴ Pearson Correlation Coefficient

¹ K-Nearest neighbor (KNN)

² Decision Tree (DT)

³ Neural Network (NN)

⁴ Scaling

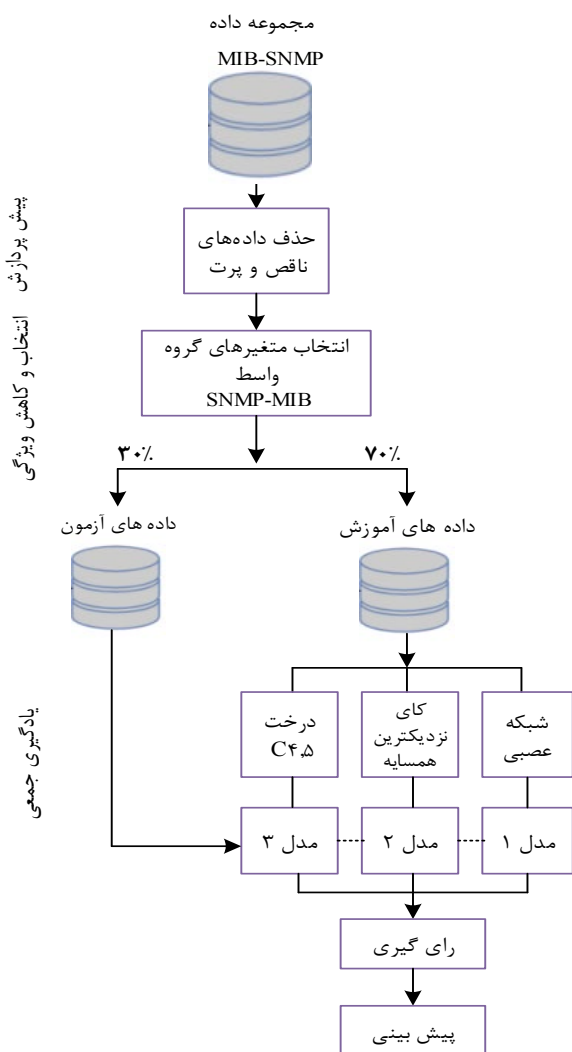
⁵ Min Max Scaling

⁶ Standard Scaling

رأی گیری نتایج سه مدل، بررسی و با روش حداکثر رأی گیری^۴ یا همان انتخاب رأی بیش از دو ماشین یادگیر، پیش بینی ترافیک حمله یا عادی بادقت بالا انجام می شود.

۵. نتایج و اعتبارسنجی

آزمایش های پیاده سازی شده در این مقاله باهدف آزمایش تعدادی از حملات رایج سیل آسای انکار سرویس توسط روش پیشنهادی و تعدادی از طبقه بندی کننده های یادگیری ماشین مطرح بکار گرفته شده در سامانه های تشخیص نفوذ انجام شده است.



شکل ۴. مدل پیشنهادی

۵-۱. جزئیات پیاده سازی

دستگاهی با پردازنده اینتل Core i7-2670QM با سرعت ۲/۲ گیگاهرتز، حافظه اصلی ۸ گیگابایت، کارت گرافیکی انویدیا جیفورس ۵۴۰ با ۲ گیگابایت حافظه و سیستم عامل ویندوز ۷ (۶۴

باهم همبستگی معنادار دارند. ویژگی هایی که ضریب همبستگی با مقدار بیشتر از ۱ یا کمتر از -۱ دارند، وجود خطا در داده ها را نشان می دهند [۲۸].

- ضریب همبستگی رتبه اسپیرمن^۱: در این معیار، ضریب همبستگی بین هر دو ویژگی محاسبه می شود. این معیار برای داده هایی با توزیع نامنظم استفاده می شود. ویژگی هایی که ضریب همبستگی رتبه اسپیرمن بالا دارند، باهم همبستگی معنادار دارند [۲۸].

- اندازه همبستگی: در این معیار، برای هر ویژگی، مجموع مقادیر مطلق ضرایب همبستگی آن با دیگر ویژگی ها محاسبه شده و ویژگی هایی که بیشترین مجموع را دارند، به عنوان ویژگی های برتر شناخته می شوند؛ چراکه با دیگر ویژگی ها بیشترین همبستگی را دارند [۲۸].

در کل، انتخاب ویژگی های برتر بر اساس ماتریس همبستگی بسته به نوع داده، معیارهای بررسی همبستگی و هدف موردنظر ممکن است متفاوت باشد. در این مقاله از روش همبستگی پیرسون به دلیل سادگی پیاده سازی استفاده شده است. در بخش ۵-۲ ضرایب همبستگی تمامی ویژگی ها با ویژگی کلاس و برچسب مجموعه داده محاسبه و ارائه شده است.

تقسیم بندی داده ها برای مرحله آموزش به میزان ۷۰ درصد از داده ها و ۳۰ درصد باقی مانده برای مرحله آزمایش انجام می شود. استفاده از روش های یادگیری جمعی از جمله روش رأی گیری با توجه به استفاده از چندین روش یادگیری ماشین تکی، می تواند بر مسائلی از جمله بایاس و واریانس بالا فائق آیند و دقت بالایی نسبت به استفاده تک ماشین یادگیری ارائه دهند. ترکیب های متفاوتی با تعداد متنوع از الگوریتم ها و روش ها برای ایجاد یک روش جمعی رأی گیری می توان انتخاب کرد. در این مقاله، با توجه به انجام آزمایش های متعدد و انتخاب الگوریتم های مختلف یادگیری، به دلیل به دست آمدن میزان دقت بالا توسط سه الگوریتم یادگیری شبکه عصبی (تعداد هشت گره ورودی برابر با تعداد ویژگی های واسط و استفاده از یک لایه مخفی^۲، نرخ یادگیری ۰/۳ و تابع فعال سازی سیگمید^۳ با تعداد ۵۰۰ تکرار)، کای نزدیک ترین همسایه و درخت تصمیم C4.5 که در شکل (۴) نشان داده شده است از این الگوریتم ها در مرحله یادگیری استفاده می شود و سه مدل تولید شده و داده های آزمایش به عنوان ورودی به این مدل ها وارد شده و نهایتاً با استفاده از روش یادگیری جمعی

^۱ Spearman Rank Correlation Coefficient

^۲ Hidden Layer

^۳ Sigmoid

^۴ Max-Voting

در این مقاله با توجه به سهولت پیاده‌سازی، روش همبستگی پیرسون برای محاسبه ضرایب همبستگی تمامی ویژگی‌ها با ویژگی برچسب و کلاس مجموعه داده استفاده شده است که میزان ضرایب در شکل (۵) ارائه شده است. با توجه به بالابودن میزان همبستگی تمامی ویژگی‌های واسط مجموعه داده، این گروه از ویژگی‌ها که از خصوصیات مرتبط با بسته‌های ردوبدل شده در شبکه استخراج شده‌اند انتخاب شده‌اند. شایان ذکر است که برخی دیگر از ویژگی‌های همچون tcpEstabResets یا tcpRetransSegs نیز میزان همبستگی خوبی با ویژگی کلاس دارند؛ ولی در این مقاله با توجه به انتخاب ویژگی‌ها و پیاده‌سازی روش پیشنهادی بر روی ویژگی‌های واسط مشخص شد این داده‌ها می‌توانند در شناسایی حملات ترافیکی شبکه نسبت به سایر ویژگی‌ها و ترکیب‌های مختلف عملکرد بهتری داشته باشند.

بیتی) برای انجام آزمایش‌ها مورداستفاده قرار گرفته است. الگوریتم شبکه عصبی و طبقه‌بندی‌کننده‌های یادگیری ماشین با استفاده از زبان برنامه‌نویسی پایتون نسخه ۳/۸ در محیط ژوپیتر نوت بوک [۲۶] پیاده‌سازی و آموزش داده شده است. آزمایش‌های مختلفی برای تعیین پارامترهای تنظیم مطلوب برای این طبقه‌بندی‌کننده‌ها انجام شده است.

۵-۲. مجموعه داده


در این مقاله از مجموعه داده SNMP-MIB [۱۲] استفاده شده است که این مجموعه داده دارای ۳۴ ویژگی و ۴۹۹۸ رکورد ترافیکی شبکه است و که پنج گروه در جدول (۱) و در ۸ دسته ترافیک عادی و حمله در جدول (۲) ارائه شده، تقسیم‌بندی شده است.

جدول ۱. رکوردهای ترافیک شبکه در مجموعه داده SNMP-MIB

ردیف	نوع ترافیک	زیر نوع	تعداد رکوردها
۱	عادی	Normal	۶۰۰
۲	حمله انکار سرویس	TCP-SYN	۹۶۰
۳		UDP-flood	۷۷۳
۴		ICMP-ECHO	۶۳۲
۵		HTTP-flood	۵۷۳
۶		Slowloris	۷۸۰
۷		Slowpost	۴۸۰
۸	حمله	Brute Force	۲۰۰
مجموع			۴۹۹۸

جدول ۲. مجموعه داده SNMP-MIB

گروه واسط (Interface)	گروه UDP	گروه ICMP	گروه TCP	گروه IP
ifInOctets	udpInDatagrams	icmpInMsgs	tcpOutRsts	ipInReceives
ifOutOctets	udpOutDatagrams	icmpInDestUnreachs	tcpInSeg	ipInDelivers
ifOutDiscards	udpInErrors	icmpOutMsgs	tcpOutSegs	ipOutRequests
ifInUcastPkts	udpNoPorts	icmpOutDestUnreachs	tcpPassiveOpens	ipOutDiscards
ifInNUcastPkts	-	icmpInEchos	tcpRetransSegs	ipInDiscards
ifInDiscards	-	icmpOutEchoReps	tcpCurrEstab	ipForwDatagrams
ifOutUcastPkts	-	-	tcpEstabResets	ipOutNoRoutes
ifOutNUcastPkts	-	-	tcpActiveOpens	ipInAddrErrors



شکل ۵. ضریب همبستگی ویژگی‌ها با ویژگی کلاس مجموعه داده

۳-۵. ارزیابی عملکرد و نتایج

برای ارزیابی روش رأی گیری پیشنهادی و طبقه بندی کننده های دیگر از روش اعتبارسنجی متقابل^۱ با K-fold=۵ استفاده شد. با این روش میزان عملکرد روش ارائه شده به صورت دقیق تر مورد ارزیابی قرار گرفت. میانگین نتایج، با ۲۰ بار آزمایش بر روی مجموعه داده محاسبه شده و برای روش پیشنهادی و طبقه بندی کننده های دیگر ارائه شده است.

۵-۳-۱. سنجه های ارزیابی

ارزیابی کارایی^۲ از مهم ترین مراحل پس از ساخت مدل است. در طبقه بندی کننده های یادگیری ماشین برای ارزیابی عملکرد هر یک از آن ها، سنجه هایی از جمله نرخ صحت^۳، نرخ تشخیص^۴ یا نرخ بازخوانی^۵، نرخ هشدار نادرست^۶ استفاده می شود. این سنجه ها توسط عناصر ماتریس آشفتگی^۷ تعیین می شوند که در جدول (۳) نمایش داده شده و در ادامه نحوه محاسبه هر یک از آن ها بررسی شده است [۲۵].

جدول ۳. ماتریس آشفتگی با دو کلاس

		کلاس پیش بینی شده ^۸	
		مثبت	کاذب
کلاس واقعی ^۹	مثبت	مثبت درست (TP)	مثبت کاذب (FP)
	کاذب	منفی کاذب (FN)	منفی درست (TN)

- مثبت درست (TP): تعداد نمونه های حمله که به درستی به عنوان نمونه های حمله و مخرب تشخیص داده می شوند.
- مثبت کاذب (FP): تعداد نمونه های عادی که به اشتباه به عنوان نمونه های حمله تشخیص داده می شوند.
- منفی درست (TN): تعداد نمونه های عادی که به درستی به عنوان نمونه های عادی تشخیص داده می شوند.
- منفی کاذب (FN): تعداد نمونه های حمله که به اشتباه به عنوان نمونه های عادی تشخیص داده می شوند.
- ✓ صحت: میزان پیش بینی های صحیح تمام نمونه ها را نشان می دهد [۲۵]

$$Accuracy (ACC) = \frac{TP + TN}{TP + TN + FP + FN} \quad (۰)$$

✓ دقت: میزان نمونه های عادی که به درستی به عنوان نمونه عادی طبقه بندی شده اند را نشان می دهد [۲۵].

$$Precision = \frac{TP}{TP + FP} \quad (۰)$$

✓ نرخ تشخیص یا نرخ بازخوانی: میزان نمونه های حمله ای است که به درستی به عنوان یک نمونه حمله پیش بینی شده است [۲۵].

$$Recall or True Positive Rate (TPR) = \frac{TP}{TP + FN} \quad (۰)$$

✓ میانگین هارمونی: سنجه ای برای اندازه گیری دقت آزمون انجام شده است. برای محاسبه این سنجه از دو سنجه بازخوانی و دقت آزمون استفاده می شود [۲۵].

$$F-Measure or F1 = \frac{2 * (Precision * Recall)}{Precision + Recall} \quad (۰)$$

✓ نرخ هشدار نادرست: میزان نمونه های عادی که به اشتباه به عنوان نمونه حمله طبقه بندی شده اند را نشان می دهد [۲۵].

^۱ Cross Validation (CV)

^۲ Performance Evaluation

^۳ Accuracy

^۴ True Positive Rate (TPR) or Detection Rate

^۵ Recall

^۶ False Alarm Rate (FAR)

^۷ Confusion Matrix

^۸ Predicted Class

^۹ Actual Class

جدول ۷. مقایسه میزان بازخوانی روش‌های مختلف بر اساس ترافیک موجود در مجموعه داده با تمامی ویژگی‌ها

مرجع	ترافیک / روش	Noram1	TCP-SYN	UDP Flood	ICMP ECHO	HTTP Flood	Slowloris	Slowpost	Bruteforce
[۱۱]	آدابوست	۹۹/۹۸	۹۸/۰۰	۹۷/۸۵	۹۹/۹	۹۹/۴۸	۹۸/۸۴	۹۹/۸۶	۱۰۰
	جنگل تصادفی	۹۹/۹	۹۹/۸۸	۹۹/۸۸	۹۹/۷	۹۹/۷	۹۹/۹۴	۱۰۰	۱۰۰
	پرسپترون چندلایه	۹۹/۸۶	۹۹/۵۶	۹۹/۴۶	۹۹/۵۶	۹۹/۵۶	۹۸/۸۵	۹۹/۷۹	۹۸/۰۰
[۲۳]	GRU-BWFA	۹۹/۹۶	۹۹/۹۶	۹۹/۹۶	۹۹/۷	۹۹/۷	۱۰۰	۱۰۰	۱۰۰
	روش رأی‌گیری	۱۰۰	۹۹/۹۶	۱۰۰	۹۹/۷۸	۹۹/۷۸	۱۰۰	۹۹/۹۲	۱۰۰

همچنین تشخیص ترافیک عادی، برابر با ۱۰۰ درصد بوده است و میزان بازخوانی نسبت به روش GRU-BWFA [۲۳] در مجموع بهتر عمل کرده و تنها در تشخیص حمله Slowpos به میزان ۰/۰۸ درصد عملکرد ضعیف تری داشته است. با در نظر گرفتن موارد و اینکه سنجه میانگین هارمونی از سنجه‌های دقت و بازخوانی محاسبه می‌شود میزان میانگین هارمونی ارائه شده در جدول (۸) نیز بیانگر بالا بودن میزان تشخیص حملات انکار سرویس و همچنین میزان تشخیص ترافیک عادی نسبت به سایر روش‌های مطرح شده در مقاله است.

با در نظر گرفتن تمامی ۳۴ ویژگی مجموعه داده، نتایج به دست آمده از جدول (۶) نشان می‌دهد که دقت روش پیشنهادی در تشخیص تمامی حملات و همچنین تشخیص ترافیک عادی، ۱۰۰ درصد موفق عمل کرده است و همچنین روش GRU-BWFA [۲۳] نیز عملکرد ۱۰۰ درصدی در دقت تشخیص از خود نشان داده است.

با در نظر گرفتن تمامی ویژگی‌های مجموعه داده، با توجه به نتایج جدول (۷)، میزان سنجه بازخوانی روش پیشنهادی در تشخیص حملات Bruteforce, Slowloris, UDP Flood و

جدول ۸. مقایسه میزان میانگین هارمونی روش‌های مختلف بر اساس ترافیک موجود در مجموعه داده با تمامی ویژگی‌ها

مرجع	ترافیک / روش	Noram1	TCP-SYN	UDP Flood	ICMP ECHO	HTTP Flood	Slowloris	Slowpost	Bruteforce
[۱۱]	آدابوست	۹۹/۹۰	۹۹/۰۰	۹۷/۸۵	۹۹/۹۱	۹۹/۷۴	۹۹/۳۲	۹۹/۸۸	۱۰۰
	جنگل تصادفی	۹۹/۸۵	۹۹/۸۹	۹۹/۸۹	۹۹/۸۹	۹۹/۸۵	۹۹/۸۵	۱۰۰	۱۰۰
	پرسپترون چندلایه	۹۹/۸۱	۹۹/۵۶	۹۹/۴۶	۹۹/۵۶	۹۹/۷۸	۹۹/۰۳	۹۹/۷۹	۹۲/۷۴
[۲۳]	GRU-BWFA	۹۹/۹۸	۹۹/۹۸	۹۹/۹۸	۹۹/۹۸	۹۹/۸۵	۱۰۰	۱۰۰	۱۰۰
	روش رأی‌گیری	۱۰۰	۹۹/۹۸	۱۰۰	۱۰۰	۹۹/۸۹	۱۰۰	۹۹/۹۶	۱۰۰

شکل‌های (۶) تا (۹)، نتایج حاصل از عملکرد روش پیشنهادی و روش‌های ارائه شده در مراجع [۱۱] و [۲۳] را در سه سنجه دقت، بازخوانی و میانگین هارمونی نشان می‌دهند.

در ادامه نتایج آزمایش‌ها بر اساس ویژگی‌های انتخاب شده (ویژگی‌های واسط SNMP-MIB) از مجموعه داده بر اساس روش‌های مختلف ارائه می‌شود. جداول (۹) تا (۱۱) و همچنین

جدول ۹. مقایسه میزان دقت روش‌های مختلف بر اساس ترافیک موجود در مجموعه داده با ویژگی‌های واسط

مرجع	ترافیک / روش	Noram1	TCP-SYN	UDP Flood	ICMP ECHO	HTTP Flood	Slowloris	Slowpost	Bruteforce
[۱۱]	آدابوست	۱۰۰	۱۰۰	۹۷/۳۴	۹۹/۸۷	۱۰۰	۱۰۰	۹۹/۹۳	۱۰۰
	جنگل تصادفی	۱۰۰	۱۰۰	۹۹/۸۶	۱۰۰	۱۰۰	۱۰۰	۹۹/۹۴	۱۰۰
	پرسپترون چندلایه	۱۰۰	۹۸/۱۳	۹۸/۶۷	۹۸/۱۷	۱۰۰	۹۸/۷۲	۹۹/۳۲	۸۹/۷۶
[۲۳]	GRU-BWFA	۱۰۰	۹۹/۸۷	۹۹/۹۱	۹۹/۸۹	۱۰۰	۱۰۰	۱۰۰	۱۰۰
	روش رأی‌گیری	۱۰۰	۱۰۰	۹۹/۹۴	۱۰۰	۱۰۰	۱۰۰	۹۹/۹۷	۱۰۰

جدول ۱۰. مقایسه میزان بازخوانی روش‌های مختلف بر اساس ترافیک موجود در مجموعه داده با ویژگی‌های واسط

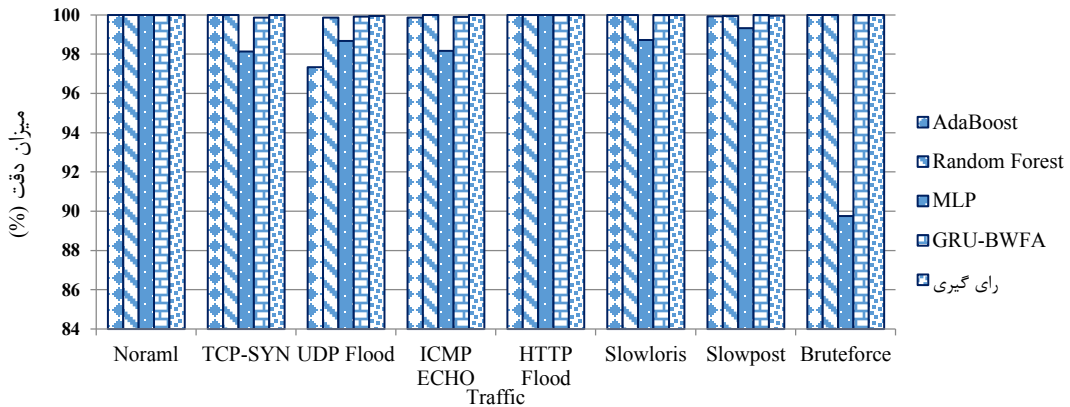
مرجع	ترافیک / روش	Noraml	TCP-SYN	UDP Flood	ICMP ECHO	HTTP Flood	Slowloris	Slowpost	Bruteforce
[۱۱]	آدابوست	۱۰۰	۹۸/۴۱	۱۰۰	۹۹/۵۷	۱۰۰	۱۰۰	۱۰۰	۱۰۰
	جنگل تصادفی	۱۰۰	۱۰۰	۱۰۰	۹۹/۵۹	۱۰۰	۱۰۰	۱۰۰	۱۰۰
	پرسپترون چندلایه	۱۰۰	۹۹/۹۸	۹۹/۴۹	۹۵/۶۰	۹۸/۰۱	۹۹/۹۹	۱۰۰	۹۷/۲۷
[۲۳]	GRU-BWFA	۱۰۰	۱۰۰	۱۰۰	۹۹/۸۹	۱۰۰	۱۰۰	۱۰۰	۱۰۰
	روش رأی‌گیری	۱۰۰	۱۰۰	۱۰۰	۹۹/۹۱	۱۰۰	۱۰۰	۹۹/۹۸	۱۰۰

جدول ۱۱. مقایسه میزان میانگین هارمونی روش‌های مختلف بر اساس ترافیک موجود در مجموعه داده با ویژگی‌های واسط

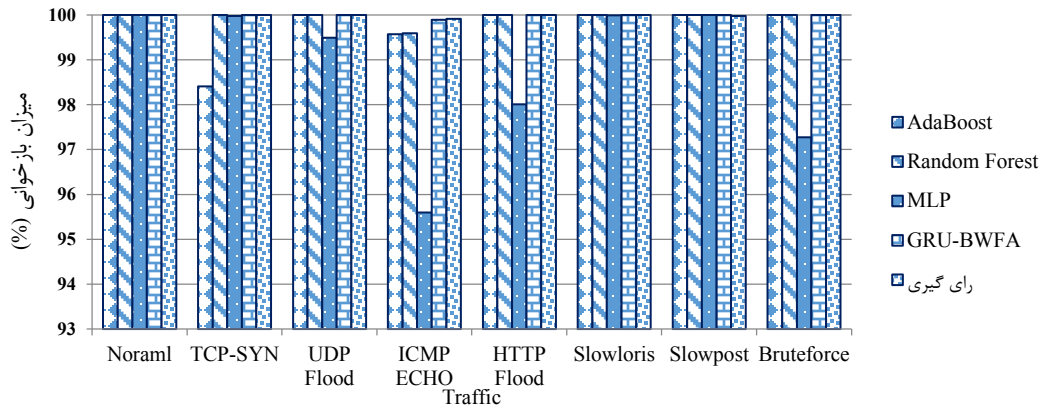
مرجع	ترافیک / روش	Noraml	TCP-SYN	UDP Flood	ICMP ECHO	HTTP Flood	Slowloris	Slowpost	Bruteforce
[۱۱]	آدابوست	۱۰۰	۹۹/۲۰	۹۸/۶۵	۹۹/۷۲	۱۰۰	۱۰۰	۹۹/۹۶	۱۰۰
	جنگل تصادفی	۱۰۰	۱۰۰	۹۹/۹۳	۹۹/۷۹	۱۰۰	۱۰۰	۹۹/۹۷	۱۰۰
	پرسپترون چندلایه	۱۰۰	۹۹/۰۵	۹۹/۰۸	۹۶/۸۷	۹۹/۰۰	۹۹/۳۵	۹۹/۶۶	۹۳/۳۶
[۲۳]	GRU-BWFA	۱۰۰	۹۹/۹۳	۹۹/۹۵	۹۹/۸۹	۱۰۰	۱۰۰	۱۰۰	۱۰۰
	روش رأی‌گیری	۱۰۰	۱۰۰	۹۹/۹۷	۹۹/۹۵	۱۰۰	۱۰۰	۹۹/۹۷	۱۰۰

بازخوانی کمتری داشته است. سنجه میانگین هارمونی، سنجه مناسبی برای ارزیابی مدل‌ها و روش‌های یادگیری ماشین است و در این مقاله نیز میزان این سنجه برای روش پیشنهادی و روش‌های ارائه‌شده در مقالات [۱۱] و [۲۳] محاسبه و در جدول (۱۱) نمایش داده شده است. در این سنجه روش پیشنهادی در ترافیک عادی و حملات TCP-SYN، HTTP Flood، Slowloris و Bruteforce میزان ۱۰۰ درصدی ارائه داده و در حمله Slowpost ۰/۰۳ درصد نسبت به روش GRU-BWFA مقدار کمتری داشته و در حملات UDP Flood و ICMP ECHO نیز به ترتیب مقادیر ۹۹/۹۷ درصد و ۹۹/۹۵ درصد را ارائه داده است که این مقادیر نیز بیانیگر میزان تشخیص بالای این حملات توسط روش پیشنهادی است.

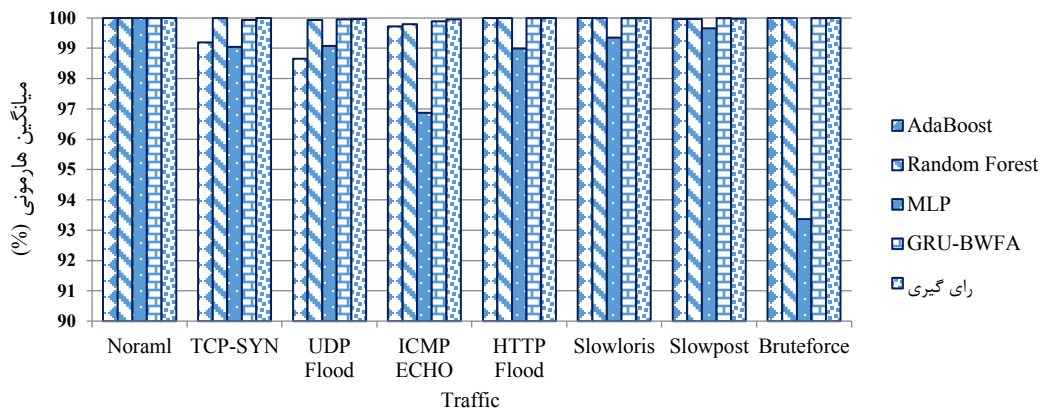
همان‌گونه که در جدول (۹) مشاهده می‌شود میزان دقت به‌دست‌آمده از روش پیشنهادی در تشخیص ترافیک عادی و ترافیک حملات، عملکرد بسیار خوبی نشان داده و به‌جز حملات ارسال انبوه UDP و Slowpost در سایر ترافیک‌ها دقت ۱۰۰ درصدی نشان داده است و تنها در حمله Slowpost میزان دقت کمتری به میزان ۰/۰۳ درصد نسبت به روش GRU-BWFA ارائه داده است. در جدول (۱۰) میزان بازخوانی به‌دست‌آمده از روش پیشنهادی در تشخیص ترافیک عادی و ترافیک حملات نشان داده شده است در این سنجه نیز روش پیشنهادی عملکرد خوبی نشان داده و به‌جز حملات Slowpost و ICMP-ECHO در سایر ترافیک‌ها میزان ۱۰۰ درصدی نشان داده است و تنها در حمله Slowpost ۰/۰۲ درصد نسبت به روش GRU-BWFA



شکل ۶. میزان دقت برای ترافیک عادی و ترافیک حملات در روش پیشنهادی و روش‌های مختلف بر اساس ویژگی‌های واسط



شکل ۷. میزان بازخوانی برای ترافیک عادی و ترافیک حملات در روش پیشنهادی و روش‌های مختلف بر اساس ویژگی‌های واسط



شکل ۸. میزان میانگین هارمونی برای ترافیک عادی و ترافیک حملات در روش پیشنهادی و روش‌های مختلف بر اساس ویژگی‌های واسط

بیشتر از آن‌ها و میزان دقت، بازخوانی و میانگین هارمونی بالاتری در زمان نسبتاً کمتری نسبت به روش ارائه شده توسط راجاسکار و همکاران [۲۳] دست‌یافت که این نتایج بیانگر تأثیرگذار بودن استفاده از روش پیشنهادی در تشخیص ترافیک حمله از ترافیک عادی است.

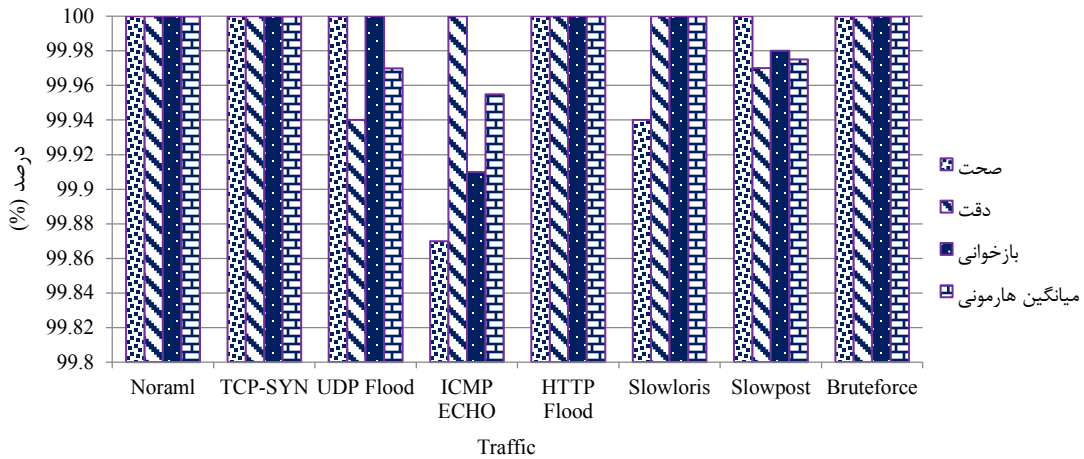
برای مشخص شدن معیارهای ارزیابی بر اساس ترافیک عادی و ترافیک حملات انکار سرویس جدول (۱۲) و شکل (۹) ارائه شده است. نتایج نشان می‌دهند که با روش پیشنهادی می‌توان به میزان دقت، بازخوانی و میانگین هارمونی بسیار بالایی نسبت به روش‌های ارائه شده توسط الحیدری و همکاران [۱۱] با زمان کمی

جدول ۱۲. مقایسه کلی معیارهای ارزیابی روش پیشنهادی بر اساس ترافیک موجود (عادی و حملات) در مجموعه داده با ویژگی‌های واسط

Bruteforce	Slowpost	Slowloris	HTTP Flood	ICMP ECHO	UDP Flood	TCP-SYN	Noraml	ترافیک / معیارهای ارزیابی
۱۰۰	۱۰۰	۹۹/۹۴	۱۰۰	۹۹/۸۷	۱۰۰	۱۰۰	۱۰۰	صحت
۱۰۰	۹۹/۹۷	۱۰۰	۱۰۰	۱۰۰	۹۹/۹۴	۱۰۰	۱۰۰	دقت
۱۰۰	۹۹/۹۸	۱۰۰	۱۰۰	۹۹/۹۱	۱۰۰	۱۰۰	۱۰۰	بازخوانی
۱۰۰	۹۹/۹۷	۱۰۰	۱۰۰	۹۹/۹۵	۹۹/۹۷	۱۰۰	۱۰۰	میانگین هارمونی

علی‌رغم اختلاف کم در زمان آموزش و زمان آزمایش روش‌های بررسی شده بر روی مجموعه داده آموزش (۷۰ درصد داده انتخاب شده از مجموعه داده) و مجموعه داده آزمایش (۳۰ درصد داده انتخاب شده از مجموعه داده)، روش پیشنهادی می‌تواند با میزان صحت و دقت بالاتری در زمان مناسب حملات انکار سرویس را در شبکه با انتخاب ویژگی‌های واسط مجموعه داده شناسایی کند.

در نهایت جدول (۱۳) زمان آموزش و زمان آزمایش روش‌های بررسی شده بر روی مجموعه داده SNMP-MIB را در مقایسه با روش پیشنهادی ارائه می‌دهد. در اینجا زمان آموزش و زمان آزمایش روش‌های بررسی شده و روش پیشنهادی بر روی مجموعه داده با تمامی ویژگی‌ها و مجموعه داده تنها دارای ویژگی‌های واسط انتخاب شده در این مقاله مورد بررسی قرار گرفته است. با توجه به زمان‌های به دست آمده می‌توان به این نتیجه رسید که



شکل ۹. معیارهای صحت، دقت، بازخوانی و میانگین هارمونی برای ترافیک عادی و ترافیک حملات در روش پیشنهادی بر اساس ویژگی‌های واسط

حملات انکار سرویس انتخاب شود. همچنین در روش پیشنهادی با توجه به اینکه هشت ویژگی از ۳۴ ویژگی موجود در مجموعه داده انتخاب شده است می‌توان مشاهده کرد که میزان استفاده از حافظه اصلی سامانه کمتر شده و از نظر استفاده از حافظه نیز کارایی سامانه بهبود داده شده است.

همان گونه که در جدول (۱۳) مشاهده می‌شود بهترین زمان آموزش و آزمایش توسط الگوریتم شبکه عصبی پرسپترون چندلایه ارائه شده است؛ ولی با توجه به میزان صحت و دقت به دست آمده از روش پیشنهادی با اختلاف زمانی بسیار کم نسبت به الگوریتم شبکه عصبی پرسپترون چندلایه، روش پیشنهادی می‌تواند راهکار مناسبی برای استفاده در سامانه‌های شناسایی

جدول ۱۳. مقایسه زمان آموزش و زمان آزمایش روش‌های مختلف

روش	با تمامی ویژگی‌ها		با ویژگی‌های واسط (۸ ویژگی)	
	زمان آموزش	زمان آزمایش	زمان آموزش	زمان آزمایش
آداپوست	۴/۰۱۶۱	۰/۲۹۹۲	۰/۹۶۵۰	۰/۰۶۲۲
جنگل تصادفی	۳/۹۳۰۹	۰/۲۹۴۳	۰/۸۷۹۰	۰/۰۵۷۶
پرسپترون چندلایه	۳/۱۹۳۶	۰/۱۷۲۷	۰/۶۳۷۱	۰/۰۳۶۰۱
روش رأی‌گیری پیشنهادی	۳/۲۲۶۷	۰/۱۷۷۹	۰/۶۵۸۳	۰/۰۳۶۲۴

مدت زمان آزمایش روش پیشنهادی در مقایسه با طبقه‌بندهای دیگر بکار گرفته شده در مقاله ارائه شده توسط الحیدری و همکاران [۱۱] بسیار نزدیک و اختلاف زمانی آن‌ها قابل چشم‌پوشی است ولی نتایج ارائه شده توسط روش پیشنهادی برای تشخیص حملات انکار سرویس نسبت سایر الگوریتم‌ها بهتر بود. الگوریتم شبکه عصبی چندلایه نیز سرعت مناسبی در مراحل آموزش و آزمایش داشت ولی به نتایج ضعیف‌تری نسبت به سایر روش‌ها دست یافت.

۶. نتیجه‌گیری

کارهای متعددی در تشخیص حملات انکار سرویس در شبکه‌های کامپیوتری انجام یافته است، با این حال، با توجه به استفاده از این حملات در سامانه‌های مالی، تنوع و تعداد این نوع از حملات روزبه‌روز افزایش چشمگیری داشته است. دقت تشخیص بالای حملات و نیز مدت زمان تشخیص آن‌ها از جمله چالش‌هایی است

۵-۳-۳. تحلیل نتایج

با بررسی کلی نتایج می‌توان توانایی روش پیشنهادی بر پایه یادگیری ماشین رأی‌گیری را نسبت به سایر روش‌ها و الگوریتم‌های طبقه‌بندی مشاهده کرد. این روش عملکرد مناسبی را نسبت به سایر الگوریتم‌های یادگیری ماشین بررسی شده در تفکیک ترافیک عادی از ترافیک حملات (مخرب) ارائه داد. زمان آموزش و آزمایش روش پیشنهادی نیز در مجموع با توجه به میزان دقت بالای آن قابل قبول بود. در طبقه‌بند جنگل تصادفی و روش GRU-BWFA علی‌رغم دستیابی به نتایج خوب در نرخ دقت، نرخ بازخوانی و میانگین هارمونی، مدت زمان آموزش و آزمایش بسیار بالا بوده و عملکرد زمانی بسیار ضعیف‌تری نسبت به سایر الگوریتم‌ها ارائه داد؛ بنابراین، با توجه به این نقطه‌ضعف، کاربرد این طبقه‌بندها بر روی مجموعه داده SNMP-MIB برای تشخیص حملات انکار سرویس مناسب نخواهد بود.

- [9] Al-Naymat, G.; Al-Kasassbeh, M.; Al-Hawari, E. "Exploiting SNMP-MIB Data to Detect Network Anomalies using Machine Learning Techniques"; SAI Intelligent Systems Conference, 2018, 991–1004.
- [10] Pathan, A.-S. K. "The State of the Art in Intrusion Prevention and Detection"; Auerbach Publications, 2014. <http://doi.org/10.1201/b16390>.
- [11] Alhaidari, S.; Alharbi, A.; Alshaikhsaleh, M.; Zohdy, M.; Debnath, D. "Network Traffic Anomaly Detection Based on Viterbi Algorithm using SNMP-MIB Data"; Third Int. Conf. Information System and Data Mining, 2019, 92–97. <http://doi.org/10.1145/3325917.3325928>.
- [12] Al-Kasassbeh, M.; Al-Naymat, G.; Al-Hawari, E. "Towards Generating Realistic SNMP-MIB Dataset for Network Anomaly Detection"; Int. J. Comput. Sci. Inform. Secur. 2016, 14, 1162-1185.
- [13] Abushwereb, M.; Mustafa, M.; Al-Kasassbeh, M.; Qasaimeh, M. "Attack Based DoS Attack Detection using Multiple Classifier" arXiv Prepr. arXiv2001.05707, 2020.
- [14] Cabrera, J. B. D.; Lewis, L.; Qin, X.; Lee, W.; Mehra, R. K. "Proactive Intrusion Detection and Distributed Denial of Service Attacks: A Case Study in Security Management"; J. Network Syst. Manage. 2002, 10, 225–254. <http://doi.org/10.1023/A:1015910917349>.
- [15] Rahmani, C.; Sharifi, M.; Tafazzoli, T. "An Experimental Analysis of Proactive Detection of Distributed Denial of Service Attacks"; IIT Kanpur Hackers Workshop (ITKHACK04) 2004, 37–44.
- [16] Hsiao, H.-W.; Lin, C. S.; Chang, S.-Y. "Constructing an ARP Attack Detection System with SNMP Traffic Data Mining"; 11th Int. Conf. Electronic Commerce 2009, 341–345. <http://doi.org/10.1145/1593254.1593309>.
- [17] Yu, J.; Kang, H.; Park, D.; Bang, H.-C.; Kang, D. W. "An In-Depth Analysis on Traffic Flooding Attacks Detection and System using Data Mining Techniques"; Journal of Systems Architecture, 2013, 59, 1005–1012. <http://doi.org/10.1016/j.sysarc.2013.08.008>.
- [18] Cerroni, W.; Moro, G.; Pirini, T.; Ramilli, M. "Peer-to-Peer Data Mining Classifiers for Decentralized Detection of Network Attacks"; Twenty-Fourth Australasian Database Conference, 2013, 101–107.
- [19] Namvarasl S.; Ahmadzadeh, M. "A Dynamic Flooding Attack Detection System Based on Different Classification Techniques and using SNMP-MIB Data"; Int. J. Comput. Netw. Commun. Secur. 2014, 2, 9, 279–284.
- [20] Cerroni, W.; Moro, G.; Pasolini, R.; Ramilli, M. "Decentralized Detection of Network Attacks Through P2P Data Clustering of SNMP Data"; Comput. Secur. 2015, 52, 1–16. <http://doi.org/10.1016/j.cose.2015.03.006>.
- [21] Al-Naymat, G.; Hambouz, A.; Alkasassbeh, M. "Evaluating the Impact of Feature Selection Methods on SNMP-MIB Interface Parameters to Accurately Detect Network Anomalies"; IEEE International Symposium on Signal Processing and Information Technology, 2019, 1–6. <http://doi.org/10.1109/ISSPIT47144.2019.9001882>.
- [22] Manna A.; Alkasassbeh, M. "Detecting Network Anomalies using Machine Learning and SNMP-MIB Dataset with IP Group"; 2nd International Conference on New Trends in Computing Sciences (ICTCS), 2019, 1–5. <http://doi.org/10.1109/ICTCS.2019.8923043>.
- [23] Rajasekar P.; Magudeeswaran, V. "GRU-BWFA Classifier for Detecting DDoS Attack within SNMP-MIB Dataset"; Wireless Pers. Commun., 2021. <http://doi.org/10.21203/rs.3.rs-848205/v1>.

که منجر به ارائه روش‌های متعددی شده است. در این مقاله سعی شده است با استفاده از پیش‌پردازش داده‌های مجموعه داده SNMP-MIB و انتخاب ویژگی‌های تأثیرگذار به همراه به کارگیری روش یادگیری جمعی رأی‌گیری حملات انکار سرویس را شناسایی کرد. عملکرد روش تشخیص پیشنهادشده با مقالات ارائه‌شده توسط الحیدری و همکاران [۱۱] و راجاسکار و همکاران [۲۳] مقایسه شده است و نتایج نشان می‌دهد که روش پیشنهادی، میزان دقت، صحت، بازخوانی و میانگین هارمونی بالایی را نسبت به روش‌های مذکور ارائه می‌دهد. با توجه به اینکه در بیشتر معیارهای ارزیابی روش پیشنهادی مقادیر بهتری ارائه داده است این امیدواری را می‌دهد تا بتوان با این روش انواع حملات انکار سرویس ناشناخته و جدید را نیز شناسایی کرد. مطالعات آتی در راستای گسترش و به کارگیری روش‌های انتخاب ویژگی‌های تأثیرگذار برای بالابردن نرخ دقت و صحت تشخیص حملات انکار سرویس در مجموعه داده‌های دیگر و همچنین کاهش خطای تشخیص در روش پیشنهادی خواهد بود.

۷. مراجع‌ها

- [1] Husák, M.; Komárková, J.; Bou-Harb E.; Čeleda, P. "Survey of Attack Projection, Prediction, and Forecasting in Cyber Security"; IEEE Commun. Surv. Tutor. 2018, 21, 1, 640–660. <http://doi.org/10.1109/COMST.2018.2871866>.
- [2] J. Yu, H. Lee, M.-S. Kim, and D. Park, "Traffic Flooding Attack Detection with SNMP MIB using SVM"; Comput. Commun., 2008, 31, 17, 4212–4219. <http://doi.org/10.1016/j.comcom.2008.09.018>.
- [3] _Asadi, M.; Parsa, S.; Jabreil Jamali, M. A.; Majidnezhad, V. "P2P Botnet Detection Using Deep Learning Method"; Electronic and Cyber Defense 2020, 8, 1–14. (In Persian). <https://dor.isc.ac/dor/20.1001.1.23224347.1399.8.2.1.3>
- [4] Alipour, M. M.; Shokrollahi, S. "The Presentation of a New Defense Framework Against the Distributed Denial of Service Attacks Using the Software Defined Network"; Adv. Defence Sci. & Technol. 2021, 12, 273–284. (In Persian)
- [5] Alkasassbeh, M.; Al-Naymat, G.; Hassanat, A.; Almseidin, M. "Detecting Distributed Denial of Service Attacks using Data Mining Techniques"; Int. J. Adv. Comput. Sci. Appl. 2016, 7, 436–445. <http://doi.org/10.14569/IJACSA.2016.070159>.
- [6] Thakkar, A.; Lohiya, R. "A Survey on Intrusion Detection System: Feature Selection, Model, Performance Measures, Application Perspective, Challenges, and Future Research Directions"; Artif. Intell. Rev. 2022, 55, 453–563. <http://doi.org/10.1007/s10462-021-10037-9>.
- [7] Asadi, M. "Detecting IoT Botnets Based on the Combination of Cooperative Game Theory with Deep and Machine Learning Approaches"; J. Ambient Intell. Hum. Comput. 2021, 13, 5547-5561. <http://doi.org/10.1007/s12652-021-03185-x>.
- [8] Asadi, M.; Parsa, S.; Jabreil Jamali, M. A.; Majidnezhad, V. "Detecting Botnet by using Particle Swarm Optimization Algorithm Based on Voting System"; Future Gener. Comput. Syst. 2020, 107, 95–111. <http://doi.org/10.1016/j.future.2020.01.055>.

- [27] Petrakova, A.; Affenzeller, M.; Merkurjeva, G. "Heterogeneous versus Homogeneous Machine Learning Ensembles"; *Inf. Technol. Manage. Sci.* 2015, 18, 135–140. <http://doi.org/10.1515/itms-2015-0021>.
- [28] Asuero, A. G.; Sayago, A.; González, A. G. "The Correlation Coefficient: An Overview"; *Crit. Rev. Anal. Chem.* 2006, 36, 41-59. <http://doi.org/10.1080/10408340500526766>.
- [24] Shiravi, A.; Shiravi, H.; Tavallae, M.; Ghorbani, A. A. "Toward Developing a Systematic Approach to Generate Benchmark Datasets for Intrusion Detection"; *Comput. Secur.*, 2012, 31, 357–374. <http://doi.org/10.1016/J.COSE.2011.12.012>.
- [25] Alpaydin E. "Machine Learning: The New AI"; MIT press, 2016. <http://doi.org/10.7551/mitpress/13811.001.0001>.
- [26] Ding, S.; Hu, S.; Pan, J.; Li, X.; Li, G.; Liu, X. "A Homogeneous Ensemble Method for Predicting Gastric Cancer Based on Gastroscopy Reports"; *Expert Syst.* 2020, 37, 3, e12499. <http://doi.org/10.1111/exsy.12499>.