

بیست و هشتمین کنفرانس بین‌المللی کامپیوتر انجمن کامپیوتر ایران

تشخیص حمله انکار سرویس توزیع شده مبتنی بر بازتاب در اینترنت وسایل نقلیه با استفاده از یادگیری گروهی

زهرا جانفدا^۱، سید امین حسینی سنو^۲، سمیه سلطانی^۳

^۱ گروه مهندسی کامپیوتر، دانشکده مهندسی، دانشگاه فردوسی مشهد
zahra.janfada@mail.um.ac.ir

^۲ دانشیار، گروه مهندسی کامپیوتر، دانشکده مهندسی، دانشگاه فردوسی مشهد
hosseini@um.ac.ir

^۳ گروه مهندسی کامپیوتر، دانشکده مهندسی، دانشگاه فردوسی مشهد
somayeh.soltani@mail.um.ac.ir

چکیده

امروزه با افزایش تعداد وسایل نقلیه متصل به اینترنت اشیا (IoT)، شبکه‌های اقتضایی خودرو (VANET) در حال تغییر به اینترنت وسایل نقلیه (IoV) هستند. یکی از اهداف مهم اینترنت وسایل نقلیه این است که وسایل نقلیه بتوانند با رانندگان، عابران پیاده، سایر وسایل نقلیه و زیرساخت‌های کنار جاده‌ای بصورت بلادرنگ ارتباط برقرار کنند. اما حمله انکار سرویس توزیع شده (DDoS) یکی از حمله‌های جدی در این محیط محسوب می‌شود. این حمله می‌تواند سرویس‌های اینترنت وسایل نقلیه را مختل کند و باعث ترافیک و تصادفات جاده‌ای شده و ایمنی کاربران را به خطر اندازد. از طرفی، تشخیص حمله انکار سرویس توزیع شده مبتنی بر بازتاب (DrDoS) به دلیل هویت پنهان آن دشوارتر است. بنابراین یک راه حل مبتنی بر یادگیری گروهی برای شناسایی انواع مختلف حمله انکار سرویس توزیع شده مبتنی بر بازتاب در محیط اینترنت وسایل نقلیه پیشنهاد شده است. مدل پیشنهادی از الحاق دو مدل شبکه عصبی کانولوشن تشکیل شده است که این دو مدل با رویکرد بیزی با استفاده از برآوردهای Parzen با ساختار درختی، بهینه سازی شدند. عملکرد مدل پیشنهادی با مجموعه داده جدید CICDDoS2019 ارزیابی شده است. نتایج تجربی نشان می‌دهد که سیستم تشخیص نفوذ پیشنهادی به نرخ صحت ۹۹٪ رسیده است.

کلمات کلیدی

اینترنت وسایل نقلیه، امنیت، حمله انکار سرویس توزیع شده مبتنی بر بازتاب، سیستم تشخیص نفوذ، یادگیری گروهی

می‌دهد. صحت کلی این سیستم به ۹۶٪ با نرخ مثبت کاذب ۰.۶٪ رسیده است.

برخی از محققان از یک شبکه عصبی کانولوشن (CNN^۸) برای شناسایی حملات در اینترنت وسایل نقلیه استفاده کردند. نی و همکاران [10] یک سیستم تشخیص نفوذ مبتنی بر داده با چارچوب شبکه عصبی کانولوشن پیشنهاد دادند که رفتار واحدهای کنار جاده‌ای در اینترنت وسایل نقلیه را در برابر حملات مختلف تجزیه و تحلیل می‌کند. سیستم تشخیص نفوذ پیشنهادی، محدودیت منابع واحدهای داخلی (OBU^۹) وسایل نقلیه را در نظر گرفته است و داده‌های شبکه را از واحدهای کنار جاده‌ای جمع‌آوری می‌کند. در نهایت، صحت معماری عمیق پیشنهادی در مقایسه با شبکه‌های عصبی کم عمق، به ۹۷.۶۰٪ رسیده است. زنگ و همکاران [11] یک چارچوب DeepVCM برای تشخیص ترافیک مخرب در واحدهای داخلی وسایل نقلیه پیشنهاد کردند که از شبکه عصبی کانولوشن و LSTM تشکیل شده است. عملکرد این مدل با دقت، فراخوانی و معیار F1 ارزیابی شده است، اما معیار صحت مورد بررسی قرار نگرفته است.

اکثر سیستم‌های تشخیص نفوذ پیشنهادی از مدل منحصربه‌فردی استفاده کردند که عملکرد پایینی دارد درحالی‌که یادگیری گروهی با استفاده از مزایای این مدل‌ها منحصربه‌فرد موجب بهبود عملکرد مدل نهایی می‌شود. در [12, 13] از یک تکنیک یادگیری گروهی انباشته^{۱۰} برای شناسایی حملات در اینترنت وسایل نقلیه استفاده شده است. نتایج آن‌ها نشان می‌دهد که این تکنیک بسیار بهتر از هر یک از تکنیک‌های یادگیری ماشین فردی عمل می‌کند. همچنین نویسندگان در [14] از یادگیری گروهی توزیع شده برای بهبود تشخیص ناهنجاری‌ها در شبکه خودروبی استفاده کردند و توانستند به معیار F1 ۹۷٪ برسند.

اما تاکنون به تشخیص دقیق انواع حملات انکار سرویس توزیع شده مبتنی بر بازتاب در محیط اینترنت وسایل نقلیه پرداخته نشده است درحالی‌که این حملات مخرب می‌توانند عامل مهم ایمنی را بخطر اندازند. بنابراین در این مقاله یک سیستم تشخیص نفوذ گروهی مبتنی بر شبکه عصبی کانولوشن برای محافظت از اینترنت وسایل نقلیه پیشنهاد شده است. هاپیرپارامترهای مدل‌های شبکه عصبی کانولوشن با رویکرد بیزی با استفاده از برآوردگرهای Parzen با ساختار درختی (BO-TPE^{۱۱}) تنظیم شده‌اند تا مدل یادگیری بهینه را به دست آوریم. کارایی سیستم تشخیص نفوذ پیشنهادی با استفاده از مجموعه داده CICDDoS2019 [۶] ارزیابی می‌شود.

بطور خلاصه، این مقاله مشارکت‌های زیر را انجام می‌دهد:

(۱) یک سیستم تشخیص نفوذ مبتنی بر یادگیری گروهی برای تشخیص انواع حملات انکار سرویس توزیع شده مبتنی بر بازتاب در اینترنت وسایل نقلیه پیشنهاد می‌شود. از رویکرد بیزی با استفاده از برآوردگرهای Parzen با ساختار درختی برای رسیدن به بهترین نرخ تشخیص استفاده می‌شود.

(۲) سیستم تشخیص نفوذ پیشنهادی می‌تواند ۸ نوع مهم حمله انکار سرویس توزیع شده مبتنی بر بازتاب از جمله NTP^{۱۲}، SSDP^{۱۳}، LDAP^{۱۴}، DNS^{۱۵}، SNMP^{۱۶}، MSSQL^{۱۷}، NetBIOS^{۱۸} و TFTP^{۱۹} را به طور موثر تشخیص دهد.

(۳) روش پیشنهادی بر روی مجموعه داده CICDDoS2019 ارزیابی می‌شود و عملکرد مدل پیشنهادی با مدل اخیر مقایسه می‌شود. اکثر

اینترنت وسایل نقلیه (IoV^۱) یک نوع خاص از اینترنت اشیا است که دستیابی به مدیریت یکپارچه در حمل و نقل هوشمند و سایر کاربردهای شهر هوشمند را فراهم می‌کند [1]. بهبود ایمنی عابران و رانندگان، نظارت بر ترافیک و راحتی مسافران از اهداف اصلی در طراحی محیط اینترنت وسایل نقلیه است [2].

اما ارتباطات اینترنت وسایل نقلیه در برابر حملات مختلف آسیب‌پذیر هستند. اگر محیط اینترنت وسایل نقلیه توسط حمله نفوذی به خطر بیفتد، می‌تواند عامل ایمنی را به خطر بیندازد زیرا هکرها می‌توانند کنترل مستقیمی بر وسایل نقلیه داشته باشند و منجر به تصادف شوند [3]. بنابراین سیستم‌های تشخیص نفوذ از الزامات اساسی در محیط اینترنت وسایل نقلیه محسوب می‌شوند زیرا وظیفه شناسایی و تشخیص هر گونه استفاده غیرمجاز یا سوءاستفاده از شبکه را بر عهده دارند.

حمله انکار سرویس (DoS^۲) حمله مهمی هست که دردسترس بودن اینترنت وسایل نقلیه را به خطر می‌اندازد. بنابراین یک مشکل جدی است. ارتباطات در برنامه‌های ایمنی و حیاتی اینترنت وسایل نقلیه مهم است و برای جلوگیری از حوادث، به اطلاعات بلادرنگ نیاز است [4]. از سوی دیگر، حمله انکار سرویس توزیع شده (DDoS^۳) نوع شدیدتری از حمله انکار سرویس است که به صورت توزیع شده انجام می‌شود. در یک حمله انکار سرویس توزیع شده، چندین وسیله نقلیه مخرب به گره قانونی حمله می‌کنند و از زمان‌ها و مکان‌های مختلف برای دستیابی به اهداف خود که جلوگیری از دسترسی کاربران به خدمات شبکه است، استفاده می‌کنند [5]. این حمله می‌تواند بر روی وسایل نقلیه یا واحدهای کنار جاده‌ای (RSU^۴) انجام شود.

از طرفی در حمله انکار سرویس توزیع شده مبتنی بر بازتاب (DrDoS^۵)، چندین وسیله نقلیه قربانی بطور ناخواسته اما با هدف مهاجم در حمله انکار سرویس توزیع شده شرکت می‌کنند تا درخواست‌ها را به سمت مقصد ارسال کنند. بنابراین تشخیص این حملات دشوارتر است زیرا هویت مهاجم پنهان است [6].

اخیراً تکنیک‌های یادگیری ماشین و یادگیری عمیق با توجه به کاربرد آن‌ها در امنیت شبکه خودروبی، توجه محققان را به خود جلب کرده است [7]. تکنیک‌های یادگیری عمیق به طور گسترده برای توسعه سیستم‌های تشخیص نفوذ (IDS^۶) استفاده می‌شوند که می‌توانند حملات سایبری مختلف را از ترافیک عادی شبکه تشخیص دهند.


علاوه و همکاران [8] یک سیستم تشخیص نفوذ مبتنی بر شبکه عصبی عمیق (DNN^۷) برای شبکه‌های خودروبی پیشنهاد دادند. این سیستم تشخیص نفوذ پیشنهادی با اسقرار در واحدهای کنار جاده‌ای و دریافت تمام داده‌های همه‌پختی وسایل نقلیه و دسته‌بندی آن‌ها به ترافیک مخرب و عادی، تشخیص ناهنجاری را انجام می‌دهد. برای ارزیابی عملکرد این سیستم تشخیص نفوذ پیشنهادی، سه سناریو، فقط خطا، فقط حمله و ناهنجاری کامل (هم خطا و هم حمله) با ۶ معماری مختلف شبکه عصبی عمیق بررسی شده است. این سیستم به صحت ۹۸٪ دست یافته است. هم‌چنین احمد و همکاران [9] یک سیستم تشخیص نفوذ برای محافظت از درگاه CAN وسایل نقلیه در برابر حملات انکار سرویس و Fuzzy ارائه کردند. معماری VGG استفاده شده و سیستم یادگیری عمیق ارائه شده به طور قابل توجهی نرخ مثبت کاذب را در مقایسه با تکنیک‌های یادگیری ماشین قدیمی کاهش

سیستم‌های تشخیص نفوذ پیشنهادی از مجموعه داده قدیمی برای ارزیابی مدل خود استفاده کردند که موجب ارزیابی نادرست می‌شود. در ادامه، بخش دوم مدل پیشنهادی را تشریح می‌کند. بخش سوم، نتایج ارزیابی این مدل را ارائه و مورد بحث قرار می‌دهد. در نهایت، در بخش چهارم جمع بندی مقاله و نگاه کلی به کارهای آینده را خواهیم داشت.

۲- راهکار پیشنهادی

در این مقاله، یک سیستم تشخیص نفوذ مبتنی بر یادگیری گروهی برای شناسایی انواع مختلف حمله انکار سرویس توزیع شده مبتنی بر بازتاب در اینترنت وسایل نقلیه پیشنهاد شده است. چارچوب سیستم تشخیص نفوذ پیشنهادی ما از الحاق دو شبکه عصبی کانولوشن متفاوت تشکیل شده است که هشت نوع حمله انکار سرویس توزیع شده مبتنی بر بازتاب (NTP، SSDP، DNS، LDAP، NetBIOS، MSSQL، TFTP) را شناسایی می‌کند. حملات انکار سرویس توزیع شده مبتنی بر بازتاب با استفاده از پروتکل‌های لایه انتقال، از جمله TCP، UDP یا ترکیبی از هر دو رخ می‌دهند. حملات MSSQL و SSDP از دسته حملات مبتنی بر TCP و حملات NTP و TFTP از دسته حملات مبتنی بر UDP هستند. همچنین حملاتی مانند DNS، LDAP، NETBIOS و SNMP می‌توانند با استفاده از TCP یا UDP انجام شوند.

شکل ۱ معماری این چارچوب را نشان می‌دهد. همانطور که شکل ۱ نشان می‌دهد، بسته‌ها در محیط اینترنت وسایل نقلیه به تصاویر تبدیل می‌شوند و پس از برچسب‌گذاری، توسط دو شبکه عصبی کانولوشن متفاوت آموزش داده می‌شوند. سپس این دو شبکه توسط روش BO-TPE، یک روش تنظیم خودکار هایپرپارامترها، بهینه می‌شوند. در نهایت مدل یادگیری گروهی با الحاق این دو شبکه بهینه، تشکیل می‌شود و بسته‌های مخرب در اینترنت وسایل نقلیه را شناسایی می‌کند.



شکل (۱): چارچوب سیستم تشخیص نفوذ پیشنهادی مبتنی بر یادگیری گروهی

۲-۱- پیش پردازش داده‌ها

برای توسعه سیستم تشخیص نفوذ پیشنهادی برای اینترنت وسایل نقلیه، از مجموعه داده CICDDoS2019 [6] استفاده شده است که حملات انکار سرویس توزیع شده را به دودسته مبتنی بر بازتاب و مبتنی بر انقضا دسته‌بندی کرده است. این مجموعه داده توسط مؤسسه امنیت سایبری کانادا (CIC) و دانشگاه نیوبرانزویک (UNB) جمع‌آوری شده است و یکی از جدیدترین مجموعه داده‌های مربوط به نفوذ است. اما این مجموعه داده از مشکل کلاس نامتعادل رنج می‌برد که ممکن است بر عملکرد مدل‌ها تأثیر بگذارد [15]. علاوه بر این، بسیاری از بسته‌ها در مجموعه داده نامتعادل

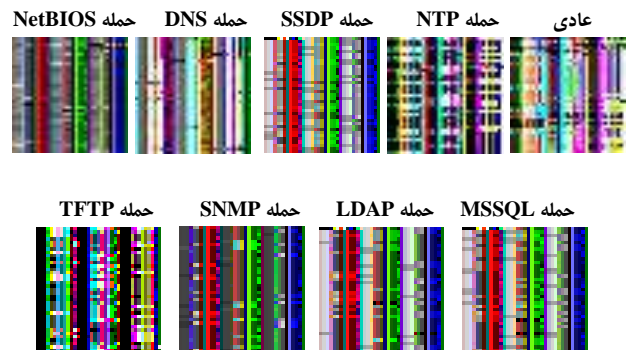
ممکن است به قدرت محاسباتی و زمان پردازش بالایی نیاز داشته باشند. بنابراین، ما به‌طور تصادفی تعداد مساوی از انواع حملات انکار سرویس توزیع شده مبتنی بر بازتاب را از مجموعه داده CICDDoS 2019 انتخاب کردیم. از آنجایی که کمترین میزان ترافیک عادی برای یک حمله انکار سرویس توزیع شده، ۲۹۸۰۸ نمونه است، ما به همین اندازه از هر نوع حمله انکار سرویس توزیع شده مبتنی بر بازتاب، انتخاب کردیم.

برای پیش پردازش بسته‌ها، از Dropna به منظور پاکسازی داده‌ها از مقادیر از دست‌رفته، استفاده کردیم. سپس داده‌ها را به فرم‌های تصویر تبدیل کردیم زیرا مدل‌های شبکه عصبی کانولوشن عملکرد بهتری روی تصاویر دارند [16].

فرآیند تبدیل داده‌ها با نرمال سازی داده‌ها شروع می‌شود. از آنجایی که مقادیر پیکسل تصاویر از ۰ تا ۲۵۵ هست، داده‌های شبکه نیز باید به مقیاس ۰-۲۵۵ نرمال سازی شوند. در میان تکنیک‌های نرمال سازی، min-max و کمی^{۲۰} دو موردی هستند که معمولاً استفاده می‌شوند تا مقادیر داده را به همان محدوده تبدیل کنند. نرمال سازی min-max به خوبی با موارد پرت^{۲۱} برخورد نمی‌کند و ممکن است باعث شود که اکثر نمونه داده‌ها مقادیر بسیار کمی داشته باشند، بنابراین از نرمال سازی کمی در مدل پیشنهادی خود استفاده کردیم. روش نرمال سازی کمی، توزیع ویژگی‌ها را به یک توزیع نرمال تبدیل می‌کند و دوباره مقادیر ویژگی‌ها بر اساس توزیع نرمال محاسبه می‌شود [17]. از این رو، اکثر مقادیر متغیر نزدیک به مقادیر میانه هستند، که در رسیدگی به موارد پرت موثر است.

پس از نرمال سازی داده‌ها، نمونه داده‌ها به تصاویری بر اساس برچسب زمانی و تعداد ویژگی‌های مجموعه داده تبدیل می‌شوند. هر تصویر یک تصویر مربع رنگی با سه کانال آبی، سبز و قرمز است. مجموعه داده CICDDoS2019 دارای ۸۰ ویژگی است، بنابراین هر بسته به تصویری به شکل ۳*۸۰*۸۰ تبدیل می‌شود. اگر تمام نمونه‌های یک تصویر، معمولی باشند آن تصویر به عنوان عادی برچسب‌گذاری می‌شود. از طرف دیگر، اگر تصویر دارای نمونه حمله باشد به عنوان همان نوع حمله‌ای که بیشترین نمونه را دارد، برچسب‌گذاری می‌شود.

پس از تبدیل داده‌ها، تصاویر آماده آموزش توسط مدل‌های مبتنی بر شبکه عصبی کانولوشن هستند. نمونه‌های هر کلاس از حمله DrDoS در شکل ۲ نشان داده شده است. همانطور که شکل ۲ نشان می‌دهد نمونه‌های مخرب و نمونه‌های عادی دارای الگوهای ویژگی متفاوت هستند در حالی که انواع مختلف حمله انکار سرویس توزیع شده مبتنی بر بازتاب دارای الگوهای ویژگی مشابه هستند.



شکل (۲): نمونه تصاویر هر کلاس از حمله انکار سرویس توزیع شده مبتنی بر بازتاب

۲-۲- مدل های شبکه عصبی کانولوشن بهینه

شبکه عصبی کانولوشن زیرگروهی از شبکه های عصبی است که به دقت بالایی در دسته بندی تصاویر رسیده است [11]. شبکه عصبی کانولوشن به طور خودکار ویژگی های مهم را تشخیص می دهد و لایه های کانولوشنی آن بدون از دست دادن اطلاعات، ابعاد بالای تصاویر را کاهش می دهند. همچنین لایه های ادغام آن تعداد پارامترهای یادگیری را کاهش داده و از بیش برآزش جلوگیری می کنند.

دو مدل مختلف شبکه عصبی کانولوشن با تعداد لایه های متفاوت برای یادگیری گروهی انتخاب شده اند. این دو مدل ساختار مشابهی دارند، با این تفاوت که مدل ۲ دارای لایه های کانولوشنی بیشتری است که در جدول ۱ توضیح داده شده است. داشتن چندین لایه کانولوشنی که در امتداد عمق دو مدل قرار گرفته اند، به مدل ها اجازه می دهد تا ویژگی های سطح بالا (نه فقط لبه ها و گوشه ها) را از تصاویر ورودی استخراج کنند. همچنین استفاده از دو لایه کانولوشنی متوالی در مدل ۲، باعث می شود نمایش بهتری از تصویر، بدون از دست دادن سریع تمام اطلاعات مکانی داشته باشیم. جدول ۱ ساختار این دو مدل را توضیح می دهد. تعداد نورون ها در هر لایه در پراتنژ نشان داده شده است.

جدول (۱): چیدمان لایه ها در دو مدل پایه برای یادگیری گروهی

لایه ها	مدل ۱	مدل ۲
لایه ۱	Conv(16)	Conv(16)
لایه ۲	Maxpooling	Maxpooling
لایه ۳	Conv(256)	Conv(128)
لایه ۴	Maxpooling	Maxpooling
لایه ۵	Conv(512)	Conv(256)
لایه ۶	GlobalAveragePooling	Maxpooling
لایه ۷	Dense(512)	Conv(512)
لایه ۸	Dropout	Conv(512)
لایه ۹	Dense(9)	GlobalAveragePooling
لایه ۱۰	-	Dense(512)
لایه ۱۱	-	Dropout
لایه ۱۲	-	Dense(9)

در هر دو مدل ۱ و ۲، از فعال ساز واحد خطی اصلاح شده (ReLU) استفاده شده است زیرا به جلوگیری از رشد نمایی در محاسبات مورد نیاز برای راه اندازی شبکه عصبی کمک می کند [12]. همچنین استفاده از لایه ادغام میانگین جهانی^{۳۳} بجای لایه مسطح^{۳۳} به جلوگیری از بیش برآزش مدل ها کمک می کند زیرا هیچ پارامتری برای بهینه سازی در لایه ادغام میانگین جهانی وجود ندارد. لایه مسطح به سادگی یک نقشه ویژگی چند بعدی را با چیدمان مجدد عناصر به یک بعدی تبدیل می کند. در حالی که لایه ادغام میانگین جهانی از یک پنجره تجزیه کننده استفاده می کند که در سراسر نقشه ویژگی حرکت می کند و داده ها را با میانگین کردن آن جمع می کند.

همچنین از آنتروپی متقاطع طبقه ای^{۳۴} به عنوان تابع ضرر برای محاسبه تفاوت بین توزیع های احتمال استفاده شده است. از آنجایی که ما بیش از دو کلاس داریم، تابع ضرر آنتروپی متقاطع طبقه ای بهترین انتخاب است. سپس

از Adam به عنوان بهینه ساز برای کاهش تابع ضرر و ارائه دقیق ترین نتایج ممکن استفاده کردیم؛ زیرا این بهینه ساز بسیار سریع است.

مشابه سایر مدل های یادگیری عمیق، مدل های شبکه عصبی کانولوشن دارای تعدا زیادی هایپر پارامتر هستند که نیاز به تنظیم دارند. این هایپر پارامترها را می توان به هایپر پارامترهای طراحی مدل و هایپر پارامترهای آموزش مدل دسته بندی کرد [18]. هایپر پارامترهای طراحی مدل، هایپر پارامترهایی هستند که باید در فرآیند طراحی مدل تنظیم شوند. در چارچوب دو مدل ارائه شده، هایپر پارامترهای طراحی مدل شامل نرخ یادگیری و نرخ ریزش^{۳۵} هستند. از سوی دیگر، هایپر پارامترهای آموزش مدل برای متعادل کردن سرعت آموزش و عملکرد مدل استفاده می شوند؛ که شامل اندازه دسته^{۳۶}، تعداد دوره ها^{۳۷} و صبر توقف زودهنگام^{۳۸} هستند. هایپر پارامترهای فوق تاثیر مستقیمی بر ساختار، اثربخشی و کارایی مدل های شبکه عصبی کانولوشن دارند.

بهینه سازی هایپر پارامترها (HPO)^{۳۹} یک فرآیند خودکار تنظیم هایپر پارامترهای مدل های یادگیری عمیق با استفاده از تکنیک های بهینه سازی هست [18]. در میان تکنیک های بهینه سازی مورد استفاده برای مسائل بهینه سازی هایپر پارامترها، مدل بیزی می تواند بهترین هایپر پارامترها را در زمان کمتر (در تکرارهای کمتر) نسبت به جستجوی شبکه ای و جستجوی تصادفی پیدا کند؛ زیرا اساس مدل های بیزی، به روز رسانی دانش پیشین با استفاده از اطلاعات جدید، به منظور تولید دانش پسین است.

در اینجا ما از مدل بیزی با استفاده از الگوریتم برآوردگرهای Parzen با ساختار درختی (TPE) استفاده کردیم که به مقادیر اولیه یا مجموعه های آموزشی نیاز ندارد و قادر به یافتن هایپر پارامترهای بهتر است. روش TPE، نمونه پارامترهای جدید را جمع آوری می کند و توزیع قبلی را با نمونه پارامترهای داده شده در هر تکرار تعریف می کند، و سپس نمونه ای با بالاترین پیشرفت را برای تکرار بعدی انتخاب می کند [19]. در ابتدا، TPE فضای پارامتر را به طور تصادفی جستجو می کند. سپس، نمونه های جمع آوری شده به دو گروه تقسیم می شوند: گروه اول بهترین نمونه پارامترهایی هستند که توسط تابع هزینه ارزیابی می شوند، و گروه دوم، بخش باقی مانده است که برای مدل سازی احتمال استفاده می شوند. ایده اصلی این است که مجموعه ای از پارامترها را انتخاب می کند که احتمال بیشتری در گروه اول دارند. بهبود مورد انتظار (EI)^{۴۰} در هر تکرار توسط رابطه زیر محاسبه می شود:

$$E(I) = \frac{l(x)}{g(x)} \quad (1)$$

که در آن $l(x)$ و $g(x)$ به ترتیب احتمال در گروه اول و دوم هستند. TPE به تست هر نمونه پارامتر نیاز ندارد و همچنین از تست پارامترهایی که احتمالاً عملکرد پایینی در مقایسه با سایر پارامترها دارند صرف نظر می کند، که منجر به کاهش پیچیدگی محاسباتی می شود.

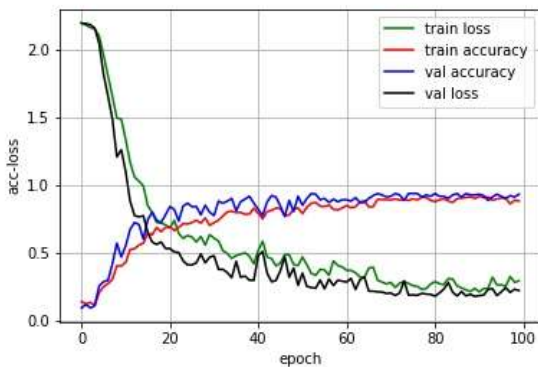
جدول ۲، محدوده جستجوی اولیه و مقادیر بهینه هایپر پارامترهای دو مدل شبکه عصبی کانولوشن را با استفاده از BO-TPE نشان می دهد. پس از بهینه سازی هایپر پارامترها، از این دو مدل بهینه به عنوان یادگیرندگان پایه برای ساخت مدل پیشنهادی مبتنی بر یادگیری گروهی استفاده می شود.

جدول (۲): تنظیم های پارامترهای دو مدل پایه

های پارامتر	محدوده جستجو	مقدار بهینه برای مدل (۱)	مقدار بهینه برای مدل (۲)
تعداد دوره	[۵, ۱۰۰]	۶۰	۷۰
اندازه دسته	[۳۲, ۱۲۸]	۱۲۸	۱۲۸
نرخ یادگیری	(۰.۰۰۱, ۰.۱)	۰.۰۰۴	۰.۰۰۲
نرخ ریزش	(۰.۲, ۰.۸)	۰.۵	۰.۴
صبر توقف زود هنگام	[۲, ۱۰]	۵	۴

ما از ۸۰ درصد داده‌ها برای آموزش و ۲۰ درصد آن برای تست استفاده کردیم. همچنین از اعتبار سنجی متقابل پنج برابری^{۳۱} برای جلوگیری از بیش برآزش در طول فرایند آموزش مدل پیشنهادی استفاده شده است. در روش اعتبارسنجی متقابل پنج برابری، مجموعه داده آموزشی به طور تصادفی به ۵ زیر نمونه با حجم یکسان تبدیل می‌شود که ۴ زیر نمونه به عنوان مجموعه داده آموزشی و یک زیر نمونه به عنوان مجموعه داده اعتبارسنجی در نظر گرفته می‌شود.

به منظور ارزیابی دقیق و کامل سیستم تشخیص نفوذ پیشنهادی، تمامی معیارهای مهم از جمله (۱) صحت، (۲) دقت، (۳) فراخوانی، (۴) معیار F (۵) نرخ مثبت کاذب، (۶) نرخ منفی کاذب^{۳۲} و (۷) نرخ مثبت واقعی^{۳۳} مورد استفاده قرار گرفتند. علاوه بر این، برای ارزیابی کارآمد مدل پیشنهادی، زمان تست هر بسته نیز در نظر گرفته شده تا حملات مخرب در زمان کمتری شناسایی شود.



شکل (۳): نمودارهای صحت و ضرر به دوره در مدل پیشنهادی

همانطور که در جدول ۳ مشاهده می‌کنید مدل پیشنهادی می‌تواند ۸ نوع مهم حمله انکار سرویس توزیع شده مبتنی بر بازتاب (NTP، SSDP، LDAP، DNS، SNMP، MSSQL، NetBIOS و TFTP) را با دقت بالایی تشخیص دهد.

ما آزمایش‌های خود را با استفاده از کتابخانه‌های Scikit-learn و Keras در پایتون انجام دادیم. و از آنجایی که روش الحاق موجب افزایش زمان آموزش مدل می‌شود، از Google colab برای آموزش سریع‌تر مدل پیشنهادی خود استفاده کردیم؛ زیرا دارای GPU قدرتمند (Tesla K80) و پردازنده Intel Xeon با دو هسته ۲.۲۰ گیگاهرتز است. در آزمایش‌های ما، تعداد دوره‌ها برابر با ۱۰۰ در نظر گرفته شده است تا روند آموزش مدل پیشنهادی کامل شود؛ سپس با استفاده از توقف زود هنگام، پس از بهبود عملکرد مدل در مجموعه داده اعتبارسنجی، آموزش مدل متوقف می‌شود تا از بیش برآزش جلوگیری شود. همچنین اندازه دسته برابر ۱۲۸ موجب افزایش سرعت آموزش می‌شود؛ زیرا دسته‌های بزرگتر مراحل جستجوی کمتری را برای حل بهینه انجام می‌دهند.

همانطور که در شکل ۳ نشان داده شده است مدل پیشنهادی دارای صحت ۹۹.۸٪ است؛ نمودارهای قرمز و آبی به ترتیب صحت آموزش و اعتبارسنجی و نمودارهای سبز و مشکی به ترتیب تابع ضرر آموزش و اعتبارسنجی را نشان می‌دهند. فاصله بین نمودارهای صحت آموزش و اعتبارسنجی در دوره‌های پایانی، بیش برآزش را نشان می‌دهد؛ اگر فاصله

۲-۳- مدل پیشنهادی مبتنی بر یادگیری گروهی

یادگیری گروهی تکنیکی است که چند مدل یادگیری پایه را برای ساخت یک مدل گروهی با عملکرد بهبود یافته ادغام می‌کند. یادگیری گروهی به طور گسترده‌ای در مشکلات تجزیه و تحلیل داده‌ها مورد استفاده قرار می‌گیرد زیرا مجموعه‌ای از چند یادگیرنده بهتر از یادگیرنده‌های مجرد عمل می‌کنند [13]. الحاق [20] یکی از استراتژی‌های گروهی برای مدل‌های یادگیری عمیق است که می‌تواند بالاترین ویژگی‌ها را برای ساختن یک مدل جامع و جدید ترکیب کند.

مدل پیشنهادی ما به کمک روش الحاق و با استفاده از آخرین لایه متراکم (Dense) دو شبکه عصبی کانولوشن بهینه ساخته شده است. هدف یک شبکه عصبی کانولوشن الحاق شده، استخراج بالاترین ویژگی‌های ایجاد شده از لایه متراکم بالای مدل‌های شبکه عصبی کانولوشن پایه است و از عملیات الحاق برای ادغام همه ویژگی‌ها در یک لایه الحاق جدید استفاده می‌کند. پس از لایه الحاق، با استفاده از لایه‌های حذفی، متراکم و softmax، مدل جدید مبتنی بر یادگیری گروهی ساخته می‌شود. استفاده از لایه‌های حذفی با کاهش ویژگی‌های اضافی به جلوگیری از بیش برآزش مدل پیشنهادی ما کمک می‌کنند. در نهایت، لایه متراکم به همراه softmax، لایه دسته‌بندی مدل پیشنهادی را به منظور برگرداندن احتمال‌های هر کلاس تشکیل می‌دهند.

از آنجایی که مدل ۲ ما لایه‌های کانولوشنی بیشتری نسبت به مدل ۱ دارد، باعث می‌شود ویژگی‌های سطح پایین بیشتری را یاد بگیرد و در دسته‌بندی چندگانه به نتایج بهتری دست یابد، اما زمان تشخیص حملات را افزایش می‌دهد. بنابراین با الحاق این دو مدل، مصالحه‌ای بین زمان تشخیص و نرخ تشخیص ایجاد کردیم و عملکرد مدل نهایی را بهبود بخشیدیم.

پیچیدگی محاسباتی روش الحاق $O(NF)$ است که N تعداد نمونه داده‌ها، و F تعداد کل ویژگی‌های استخراج شده از لایه‌های متراکم مدل‌های پایه است.

۳- ارزیابی مدل پیشنهادی

مدل پیشنهادی بر روی مجموعه داده CICIDDoS2019 ارزیابی شده است. این مجموعه داده، جدید و مربوط به سال ۲۰۱۹ است. بنابراین برخلاف سایر مقالات که از مجموعه داده‌های قدیمی (از جمله NSL-KDD، KDD99 و UNSW-NB15) استفاده کردند [11, 21]؛ ارزیابی صحیح تری از مدل پیشنهادی خود خواهیم داشت.

بیشتر باشد، بیش‌برازش بیشتر است. اما همانطور که شکل ۳ نشان می‌دهد، ما کمترین بیش‌برازش را داریم.

جدول (۳): ارزیابی کارایی مدل پیشنهادی

کلاس	دقت	فراخوانی	معیار F	میانگین صحت	زمان تست هر بسته (ثانیه)
عادی	۱.۰۰	۱.۰۰	۱.۰۰		
حمله NTP	۱.۰۰	۱.۰۰	۱.۰۰		
حمله SSDP	۰.۹۷۶۷۴	۱.۰۰	۰.۹۸۸۲۴		
حمله DNS	۱.۰۰	۱.۰۰	۱.۰۰		۰.۰۶۴
حمله NetBIOS	۱.۰۰	۱.۰۰	۱.۰۰		۰.۹۹۸۱۹
حمله MSSQL	۱.۰۰	۰.۹۰۹۰۹	۰.۹۵۲۳۸		
حمله LDAP	۰.۹۶۲۹۶	۱.۰۰	۰.۹۸۱۱۳		
حمله SNMP	۱.۰۰	۱.۰۰	۱.۰۰		
حمله TFTP	۱.۰۰	۱.۰۰	۱.۰۰		

اکثر مقالاتی که به تشخیص حملات در اینترنت وسایل نقلیه پرداختند، حملات مخرب انکار سرویس توزیع شده را در نظر نگرفتند [8,13,21-24]. هم‌چنین مقاله [9] از مجموعه داده CAN-intrusion استفاده می‌کند که می‌تواند صرفاً حملات انکار سرویس در گذرگاه CAN وسایل نقلیه را تشخیص دهد، درحالی‌که که تشخیص حملات جدی انکار سرویس توزیع شده نیاز به دید وسیع تری از شبکه خودرویی و مجموعه داده جامع‌تری دارد.

خوبی و همکاران [15] به تشخیص حملات انکار سرویس توزیع شده مبتنی بر بازتاب در شبکه هوشمند پرداختند و با استفاده از یادگیری گروهی مبتنی بر پشته (stacking) به صحت ۹۳.۴٪ دست یافتند. همانطور که جدول ۴ نشان می‌دهد مدل پیشنهادی ما توانسته انواع حملات انکار سرویس توزیع شده مبتنی بر بازتاب را با میانگین صحت ۹۹.۸٪ تشخیص دهد. نتایج مدل پیشنهادی ما نشان می‌دهد که مدل‌های یادگیری گروهی مبتنی بر الحاق از سایر مدل‌های یادگیری گروهی بهتر عمل می‌کنند. از طرفی دیگر، مدل [۱۵] زمان تشخیص را برای تشخیص بلادرنگ حملات مخرب انکار سرویس در نظر نگرفته است.

جدول (۴): مقایسه مدل پیشنهادی با سیستم تشخیص نفوذ موجود

روش	صحت	نرخ منفی کاذب	نرخ مثبت کاذب	نرخ مثبت واقعی
مدل پیشنهادی ما	۰.۹۹۸	۰.۰۱۰	۰.۰۰۱	۰.۰۹۸
[۱۵]	۰.۹۳۴	۰.۰۴۱	۰.۰۸۹	۰.۰۹۶

نویسندگان در [25] با کمک ماشین قوی Raspberry Pi3 به زمان تست ۱.۸ میلی‌ثانیه و [8] با کمک پردازنده قوی Nvidia Jetson Nano به زمان تست ۰.۲۹۹ میلی‌ثانیه رسیدند؛ ما با توجه به محدودیت‌های Google Colab توانستیم در زمان نسبتاً کمی بسته‌های مخرب را شناسایی کنیم. هم‌چنین در محیط اینترنت وسایل نقلیه، امکان استفاده از پردازنده‌های قوی و گران قیمت در تمام وسایل نقلیه و زیرساخت‌های کنارجاده‌ای برای تشخیص بسته‌های مخرب وجود ندارد. بنابراین زمان تست بسته‌ها باید با توجه به محدودیت منابع وسایل نقلیه در نظر گرفته شود.

۴- نتیجه‌گیری

در حال حاضر بسیاری از نویسندگان بر روی محیط اینترنت وسایل نقلیه به دلیل نقش مهم آن در ارائه کاربردهای حمل و نقل هوشمند از جمله مدیریت ترافیک و ایمنی راننده تمرکز کردند. اما حملات مختلفی ممکن است در اینترنت وسایل نقلیه رخ دهد و موجب نارضایتی کاربران و ناکارآمدی شبکه شود که از مهم‌ترین آن‌ها می‌توان به حمله انکار سرویس توزیع شده اشاره کرد که در دسترس بودن شبکه را به خطر می‌اندازد.

در دسترس نبودن خدمات اینترنت وسایل نقلیه، برنامه‌های کاربردی مبتنی بر ایمنی را مختل می‌کند و می‌تواند جان انسان‌ها را به خطر بیندازد. از طرفی حملات انکار سرویس توزیع شده مبتنی بر بازتاب نوع شدیدتر حمله انکار سرویس توزیع شده محسوب می‌شوند و تشخیص آن به دلیل هویت پنهان مهاجم دشوارتر است. تاکنون کارهای تحقیقاتی موجود به تشخیص دقیق انواع این حملات در محیط اینترنت وسایل نقلیه نپرداختند.

بنابراین، یک راه‌حل مبتنی بر یادگیری گروهی برای شناسایی انواع مختلف حمله انکار سرویس توزیع شده مبتنی بر بازتاب در محیط اینترنت وسایل نقلیه پیشنهاد شده است. سیستم تشخیص نفوذ پیشنهادی می‌تواند ۸ نوع مهم این حمله را به طور موثر تشخیص دهد. طبق مدل پیشنهادی، بسته‌ها در محیط اینترنت وسایل نقلیه به تصاویر تبدیل می‌شوند و پس از برچسب‌گذاری، توسط دو شبکه عصبی کانولوشن متفاوت آموزش داده می‌شوند. سپس این دو شبکه توسط روش BO-TPE، یک روش تنظیم خودکار هایپر پارامترها، بهینه می‌شوند. در نهایت مدل یادگیری گروهی با الحاق این دو شبکه بهینه، تشکیل می‌شود و بسته‌های مخرب در اینترنت وسایل نقلیه را شناسایی می‌کند. عملکرد مدل پیشنهادی با مجموعه داده جدید CICIDDos2019 ارزیابی شده است. هم‌چنین همه معیارهای ارزیابی برای ارزیابی کامل و دقیق مدل پیشنهادی مورد استفاده قرار گرفتند. نتایج، کارایی بالای سیستم تشخیص نفوذ پیشنهادی را نشان می‌دهد.

در نتیجه، با شناسایی به موقع و دقیق حملات انکار سرویس توزیع شده مبتنی بر بازتاب، می‌توانیم از شبکه اینترنت وسایل نقلیه محافظت کنیم تا محیط امن‌تر و مطمئن‌تری برای کاربران فراهم شده و از همه مهم‌تر جان کاربران نجات یابد. در کارهای آینده سعی داریم چارچوب خود را برای تشخیص حملات انکار سرویس توزیع شده مبتنی بر انقضا گسترش دهیم.

مراجع

- [1] Ang, L.-M., et al., *Deployment of IoV for smart cities: Applications, architecture, and challenges*. IEEE access, 2018. 7: p. 6473-6492.
- [2] Sharma, S. and B. Kaushik, *A survey on internet of vehicles: Applications, security issues & solutions*. Vehicular Communications, 2019. 20: p. 100182.
- [3] Sharma, S. and A. Kaul, *A survey on Intrusion Detection Systems and Honeypot based proactive security mechanisms in VANETs and VANET Cloud*. Vehicular communications, 2018. 12: p. 138-164.
- [4] Gao, Y., et al., *A distributed network intrusion detection system for distributed denial of service attacks in vehicular ad hoc network*. IEEE Access, 2019. 7: p. 154560-154571.

- [21] Shu, J., et al., *Collaborative intrusion detection for VANETs: A deep learning-based distributed SDN approach*. IEEE Transactions on Intelligent Transportation Systems, 2020. 22(7): p. 4519-4530.
- [22] Zhou, M., et al., *Distributed collaborative intrusion detection system for vehicular Ad Hoc networks based on invariant*. Computer Networks, 2020. 172: p. 107174.
- [23] Sunny, J., S. Sankaran, and V. Saraswat. *A hybrid approach for fast anomaly detection in controller area networks*. in 2020 IEEE International Conference on Advanced Networks and Telecommunications Systems (ANTS). 2020. IEEE.
- [24] Gonçalves, F., J. Macedo, and A. Santos. *Intelligent Hierarchical Intrusion Detection System for VANETs*. in 2021 13th International Congress on Ultra Modern Telecommunications and Control Systems and Workshops (ICUMT). 2021. IEEE.
- [25] Yang, L. and A. Shami, *A Transfer Learning and Optimized CNN Based Intrusion Detection System for Internet of Vehicles*. arXiv preprint arXiv:2201.11812, 2022.
- [5] Adhikary, K., et al., *Evaluating the performance of various machine learning algorithms for detecting DDOS attacks in vanets*. International Journal of Control Automation, 2019. 12(5): p. 478-486.
- [6] Sharafaldin, I., et al. *Developing realistic distributed denial of service (DDoS) attack dataset and taxonomy*. in 2019 International Carnahan Conference on Security Technology (ICCST). 2019. IEEE.
- [7] Zhang, J., et al., *Intrusion detection system using deep learning for in-vehicle security*. Ad Hoc Networks, 2019. 95: p. 101974.
- [8] Alladi, T., et al., *DeepADV: A Deep Neural Network Framework for Anomaly Detection in VANETs*. IEEE Transactions on Vehicular Technology, 2021. 70(11): p. 12013-12023.
- [9] Ahmed, I., A. Ahmad, and G. Jeon, *Deep Learning-based Intrusion Detection System for Internet of Vehicles*. IEEE Consumer Electronics Magazine, 2021.
- [10] Nie, L., et al., *Data-driven intrusion detection for intelligent Internet of vehicles: A deep convolutional neural network-based method*. IEEE Transactions on Network Science and Engineering, 2020. 7(4): p. 2219-2230.
- [11] Zeng, Y., et al. *Deepvcm: a deep learning based intrusion detection method in vanet*. in 2019 IEEE 5th intl conference on big data security on cloud (BigDataSecurity), IEEE intl conference on high performance and smart computing,(HPSC) and IEEE intl conference on intelligent data and security (IDS). 2019. IEEE.
- [12] Yang, L., et al. *Tree-based intelligent intrusion detection system in internet of vehicles*. in 2019 IEEE global communications conference (GLOBECOM). 2019. IEEE.
- [13] Yang, L., A. Moubayed, and A. Shami, *MTH-IDS: a multitiered hybrid intrusion detection system for Internet of vehicles*. IEEE Internet of Things Journal, 2021. 9(1): p. 616-632.
- [14] A. Ghaleb, F., et al., *Misbehavior-aware on-demand collaborative intrusion detection system using distributed ensemble learning for VANET*. Electronics, 2020. 9(9): p. 1411.
- [15] Khoei, T.T., et al. *Ensemble learning methods for anomaly intrusion detection system in smart grid*. in 2021 IEEE International Conference on Electro Information Technology (EIT). 2021. IEEE.
- [16] Hussain, F., et al. *IoT DoS and DDoS attack detection using ResNet*. in 2020 IEEE 23rd International Multitopic Conference (INMIC). 2020. IEEE.
- [17] Lokman, S.-F., et al. *The Impact of Different Feature Scaling Methods on Intrusion Detection for in-Vehicle Controller Area Network (CAN)*. in International Conference on Advances in Cyber Security. 2020. Springer.
- [18] Yang, L. and A. Shami, *On hyperparameter optimization of machine learning algorithms: Theory and practice*. Neurocomputing, 2020. 415: p. 295-316.
- [19] Jiang, B., et al., *Attention-LSTM architecture combined with Bayesian hyperparameter optimization for indoor temperature prediction*. Building and Environment, 2022. 224: p. 109536.
- [20] Rahimzadeh, M. and A. Attar, *A modified deep convolutional neural network for detecting COVID-19 and pneumonia from chest X-ray images based on the concatenation of Xception and ResNet50V2*. Informatics in medicine unlocked, 2020. 19: p. 100360.

پانویس ها

- ¹ Internet of Vehicles
- ² Denial of Service
- ³ Distributed Denial of Service
- ⁴ Roadside Unite
- ⁵ Distributed Reflection-based Denial of Service
- ⁶ Intrusion Detection System
- ⁷ Deep Neural Network
- ⁸ Convolutional Neural Network
- ⁹ On-Board Unite
- ¹⁰ Stacked
- ¹¹ Bayesian Optimization-Tree Parzen Estimator
- ¹² Network Time Protocol
- ¹³ Simple Service Discovery Protocol
- ¹⁴ Lightweight Directory Access Protocol
- ¹⁵ Domain Name System
- ¹⁶ Simple Network Management Protocol
- ¹⁷ Microsoft Structured Query Language
- ¹⁸ Network Basic Input/Output System
- ¹⁹ Trivial File Transfer Protocol
- ²⁰ Quantile
- ²¹ Outliers
- ²² GlobalAveragePooling
- ²³ Flatten
- ²⁴ Categorical cross entropy
- ²⁵ Dropout rate
- ²⁶ Batchsize
- ²⁷ Epochs
- ²⁸ Early stopping patience
- ²⁹ Hyper Parameter Optimization
- ³⁰ Expected Improvement
- ³¹ Five-fold cross validation
- ³² False positive rate
- ³³ False negative rate
- ³⁴ True positive rate