



ارائه راهکاری نوین برای طبقه‌بندی ترافیک رمزنگاری شده با بهره‌گیری از یادگیری عمیق

پویا ربیعی دولت‌آبادی^۱، مصطفی بستام^{۲*}، خدیجه آقاجانی^۲

^۱کارشناسی ارشد گروه مهندسی کامپیوتر، دانشکده فناوری و مهندسی، دانشگاه مازندران، بابلسر، ایران

^۲استادیار گروه مهندسی کامپیوتر، دانشکده فناوری و مهندسی، دانشگاه مازندران، بابلسر، ایران

مقاله پژوهشی

چکیده

تحلیل ترافیک شبکه یکی از ارکان اساسی در بهبود امنیت و مدیریت کارآمد شبکه‌های کامپیوتری است. با توجه به گسترش روزافزون شبکه‌های کامپیوتری و پیچیدگی‌های ترافیک موجود در آن‌ها، شناسایی دقیق و سریع انواع ترافیک از جمله ترافیک رمزنگاری شده، از اهمیت ویژه‌ای برخوردار است. در این راستا، استفاده از تکنیک‌های یادگیری ماشین می‌تواند ابزار قدرتمندی برای تحلیل و شناسایی دقیق الگوهای ترافیکی باشد. این مقاله به بررسی روش‌های پیشرفته شناسایی ترافیک در شبکه‌های کامپیوتری با بهره‌گیری از تکنیک‌های یادگیری ماشین پرداخته است. هدف اصلی این تحقیق، توسعه مدلی کارآمد و دقیق برای شناسایی و طبقه‌بندی انواع مختلف ترافیک شبکه، به‌ویژه ترافیک رمزنگاری شده، است. در این راستا، از مدل یادگیری عمیق VGG16 استفاده شده است. این مدل به دلیل ساختار لایه‌ای عمیق و توانایی تحلیل داده‌های حجیم، عملکرد برجسته‌ای در شناسایی الگوهای پیچیده ترافیک شبکه ارائه داده است. VGG16 قادر است با دقت بالا، انواع مختلف ترافیک شبکه را شناسایی و طبقه‌بندی کند، که این امر منجر به بهبود مدیریت ترافیک در شبکه می‌شود. در سناریوهای بررسی شده در این تحقیق، این مدل توانست دقت ۹۹ درصدی را در شناسایی ترافیک رمزنگاری شده به دست آورد.

تاریخ دریافت:

۱۴۰۳/۹/۲۵

تاریخ پذیرش:

۱۴۰۳/۱۱/۲۷

کلیدواژه‌ها:

یادگیری عمیق، تحلیل ترافیک شبکه، ترافیک رمز شده، مدل VGG16، مدیریت ترافیک شبکه

نویسنده مسئول:

Bastam@umz.ac.ir



: 10.22034/ ABMIR.2025.22525.1084



۱- مقدمه

پیچیده بدون نیاز به رمزگشایی، افزایش دقت در پردازش داده‌های حجیم و پیچیده، و کاهش نیاز به داده‌های برجسب‌دار که در تحلیل ترافیک رمزنگاری شده محدود هستند. این روش‌ها همچنین سریع‌تر و مقیاس‌پذیرتر از روش‌های سنتی هستند و امکان پردازش خودکار ترافیک شبکه را در زمان واقعی فراهم می‌کنند [۴-۹]. یادگیری عمیق، به‌ویژه با استفاده از مدل‌هایی مانند شبکه‌های عصبی کانولوشنی (CNN)، توانایی شناسایی دقیق ویژگی‌های پنهان در داده‌های ترافیکی را دارد و به تحلیل و پیش‌بینی وضعیت شبکه کمک می‌کند. این روش‌ها نه تنها شناسایی ترافیک‌های مخرب را تسهیل می‌کنند، بلکه به بهبود مدیریت منابع شبکه نیز کمک می‌کنند [۱۰-۱۲].

در این مقاله، به‌طور ویژه به تحلیل کاربردهای یادگیری عمیق در شناسایی ترافیک شبکه و چالش‌های موجود در این حوزه خواهیم پرداخت. یکی از مدل‌های برجسته یادگیری عمیق که در این تحقیق مورد استفاده قرار گرفته است، معماری VGG² است. این معماری به‌عنوان یک شبکه عصبی پیچیده و عمیق (CNN) با ساختار لایه‌ای خود، در شناسایی الگوهای پیچیده ترافیکی عملکردی برجسته از خود نشان داده است. نوآوری و دستاورد اصلی این تحقیق، ترکیب مدل VGG16 با داده‌های ترافیکی تصویری (FlowPic) و داده‌های کمکی (Aux) برای شناسایی و طبقه‌بندی دقیق تر ترافیک رمزنگاری شده است. در این تحقیق، داده‌های ترافیکی ابتدا به‌طور عمدی به تصاویر FlowPic تبدیل شده‌اند تا از تکنیک‌های پردازش تصویر و قدرت مدل‌های شبکه عصبی کانولوشنی (CNN) برای شناسایی الگوهای پیچیده ترافیک شبکه بهره‌برداری شود. مدل VGG16، که به‌طور معمول در شناسایی الگوهای پیچیده تصاویر به کار می‌رود، در این تحقیق به‌منظور شناسایی و طبقه‌بندی ترافیک رمزنگاری شده استفاده شده است. تبدیل ترافیک به تصاویر به‌ویژه به شناسایی الگوهای پیچیده کمک می‌کند، اما این تبدیل ممکن است برخی از ویژگی‌های زمانی ترافیک را نادیده بگیرد. برای جبران این نقص، از داده‌های کمکی (Aux) استفاده شده است که ویژگی‌های زمانی ترافیک را پوشش

در دنیای امروز، شبکه‌های کامپیوتری به بخش جدایی‌ناپذیر از زندگی دیجیتال تبدیل شده‌اند و با رشد روزافزون استفاده از اینترنت و ارتباطات آنلاین، حجم داده‌های ترافیکی که در این شبکه‌ها تولید می‌شود، به طرز چشمگیری افزایش یافته است. این داده‌ها نه تنها از نظر حجمی زیاد هستند، بلکه به‌طور عمده ناممکن و از منابع مختلفی چون دستگاه‌ها، برنامه‌های مختلف و سرویس‌های ابری ایجاد می‌شوند. این تنوع در داده‌ها باعث می‌شود که مدیریت و تحلیل ترافیک شبکه به‌ویژه به‌صورت بلادرنگ با چالش‌های پیچیده‌ای مواجه شود. از جمله چالش‌ها می‌توان به شناسایی ترافیک رمزنگاری شده، تشخیص حملات سایبری و مدیریت منابع شبکه اشاره کرد که نیاز به راهکارهای دقیق و سریع دارد [۱].

تحلیل ترافیک شبکه به فرآیند شناسایی و بررسی الگوهای موجود در داده‌های عبوری از شبکه‌ها اشاره دارد. این تحلیل می‌تواند به روش‌های مختلفی انجام شود: ۱- روش‌های سنتی تحلیل ترافیک شبکه و ۲- تحلیل ترافیک رمزنگاری شده.

روش‌های سنتی تحلیل ترافیک معمولاً شامل استفاده از ابزارهای مانیٹورینگ و تحلیل‌گرهای ترافیکی (مانند Wireshark، Tcpdump) برای تجزیه و تحلیل بسته‌ها^۱ هستند. این ابزارها می‌توانند اطلاعاتی نظیر آدرس‌های IP مبدأ و مقصد، پروتکل‌های مورد استفاده، تعداد بسته‌ها و حجم داده‌ها را جمع‌آوری و تحلیل کنند. این روش‌ها برای ترافیک‌های غیر رمزنگاری شده یا ترافیک‌هایی که شفافیت بیشتری دارند مناسب هستند [۲، ۳]. با رشد روزافزون رمزنگاری ترافیک شبکه، تحلیل سنتی ترافیک شبکه با چالش‌های جدیدی مواجه شده است. تحلیل ترافیک رمزنگاری شده (مثل HTTPS، VPN) به دلیل انتقال داده‌ها به‌صورت غیرقابل خواندن، با استفاده از روش‌های سنتی دشوار است. این چالش موجب می‌شود که استفاده از روش‌های مبتنی بر یادگیری ماشینی به‌عنوان یک راهکار ضروری برای تحلیل این نوع ترافیک مطرح شود. تحلیل ترافیک رمزنگاری شده با استفاده از روش‌های یادگیری ماشینی مزایای متعددی دارد، از جمله شناسایی الگوهای

² Visual Geometry Group

¹ Packet-level Analysis

حداقل داده‌های برچسب‌دار دست می‌یابد. این روش شامل دو مرحله است: ابتدا، یک شبکه عصبی کانولوشنی (CNN) بر روی یک مجموعه داده بزرگ بدون برچسب پیش‌آموزش داده می‌شود تا ویژگی‌های آماری مانند میانگین طول بسته‌ها و زمان بین رسیدن بسته‌ها را از ویژگی‌های سری زمانی نمونه‌برداری شده پیش‌بینی کند. این مدل پیش‌آموزش دیده الگوهای عمومی ترافیک را بدون نیاز به داده‌های برچسب‌دار استخراج می‌کند. در مرحله بعد، پارامترهای یاد گرفته شده مدل به یک مجموعه داده کوچک برچسب‌دار منتقل شده و با آن تنظیم دقیق می‌شود که نیاز به برچسب‌گذاری را به‌طور چشمگیری کاهش داده و عملکرد بالایی را حفظ می‌کند. برای بهینه‌سازی تحلیل بسته‌ها، نویسندگان سه تکنیک نمونه‌برداری شامل گام ثابت، تصادفی، و افزایشی را بررسی می‌کنند که بسته‌ها را از بخش‌های مختلف جریان انتخاب می‌کنند، به‌جای اینکه تنها به بسته‌های اولیه تکیه شود. این رویکرد باعث می‌شود مدل الگوهای متنوع ترافیک، از جمله رفتارهای کاربر که در میانه جریان رخ می‌دهد را شناسایی کند. روش پیشنهادی با دقت نزدیک به روش‌های پیشرفته، از جمله دقت ۹۸،۵۳ درصد برای طبقه‌بندی ترافیک QUIC کارایی خود را در سناریوهایی با داده‌های برچسب‌دار محدود نشان داده است.

ایال هورویتز و همکاران [۱۵] روش جدیدی برای طبقه‌بندی ترافیک با استفاده از تقویت‌های mini-FlowPic ارائه دادند که به‌طور مؤثر به چالش کمبود داده‌های برچسب‌دار پاسخ می‌دهد. این روش از FlowPic، یک نمایش تصویری مبتنی بر هیستوگرام دوبعدی از ترافیک شبکه، استفاده کرده و آن را با mini-FlowPics با اندازه کوچک‌تر برای کاهش هزینه‌های محاسباتی گسترش می‌دهد. با بهره‌گیری از یادگیری نمایشی متضاد بدون نظارت از طریق چارچوب SimCLR، این روش مدلی ایجاد می‌کند که در آن نمونه‌های مشابه به هم نزدیک می‌شوند، و امکان طبقه‌بندی تنها با چند نمونه برچسب‌دار در هر کلاس را فراهم می‌سازد. برای بهبود کارایی آموزش، نویسندگان تکنیک‌های تقویتی خاصی را معرفی می‌کنند که رفتارهای شبکه را شبیه‌سازی می‌کند، از جمله تغییرات در زمان رفت و برگشت (RTT)، تغییرات

می‌دهند و به‌طور جامع‌تری مدل را در شناسایی ترافیک رمزنگاری شده تقویت می‌کنند. این تحقیق، با دستیابی به دقت ۹۹،۳۷ درصد در طبقه‌بندی، گامی مهم در ارتقای تحلیل ترافیک رمزنگاری شده به شمار می‌آید. این مدل نه تنها توانسته است دقت شناسایی ترافیک را به‌طور قابل‌توجهی افزایش دهد، بلکه امکان پیش‌بینی و مدیریت بهتر ترافیک در شبکه‌های کامپیوتری را نیز فراهم کرده است.

این مقاله، به شرح ذیل سازمان‌دهی شده است: در بخش ۲، مطالعات پیشین مورد بررسی قرار می‌گیرند تا زمینه‌ای برای درک بهتر پژوهش فراهم گردد. بخش ۳ به رویکرد پیشنهادی تحقیق اختصاص دارد و رویکردهای مختلف طبقه‌بندی ترافیک شبکه با استفاده از یادگیری عمیق تشریح می‌شود. در بخش ۴، نتایج آزمایش‌ها به‌طور کامل ارائه و تحلیل می‌شوند و در نهایت، بخش ۵ به نتیجه‌گیری و پیشنهادهایی برای پژوهش‌های آتی اختصاص دارد.

۲- کارهای مرتبط

ون تانگو و همکاران [۱۳]، روش جدیدی برای طبقه‌بندی ترافیک QUIC^۱ با استفاده از شبکه‌های عصبی کانولوشنی پیشنهاد کرده‌اند. این روش با ترکیب ویژگی‌های مبتنی بر جریان و بسته، شناسایی دقیق سرویس‌های مبتنی بر QUIC مانند Google Hangout، Chat، Voice Calls، YouTube، File Transfer و Google Play Music را ممکن می‌سازد. این رویکرد شامل دو مرحله طبقه‌بندی است: ابتدا از ویژگی‌های مبتنی بر جریان برای طبقه‌بندی گروه‌ها استفاده می‌شود، سپس ویژگی‌های مبتنی بر بسته و شبکه‌های CNN برای طبقه‌بندی دقیق‌تر به کار گرفته می‌شوند. این روش ترافیک رمزگذاری شده را با پیش‌پردازش بسته‌های QUIC، استخراج ویژگی‌های جریان و بسته، و استفاده از CNN برای کاهش ابعاد و طبقه‌بندی به‌طور مؤثر پردازش می‌کند، آن‌ها مقدار F1-Score ۹۹،۲۴ درصد را به‌عنوان نتیجه ارائه داده‌اند.

شهباز رضایی و شین لئو [۱۴]، یک روش یادگیری نیمه‌نظارت شده برای طبقه‌بندی ترافیک شبکه پیشنهاد می‌کنند که با استفاده از مجموعه داده‌های بدون برچسب برای پیش‌آموزش، به دقت بالا با

² Round Trip Time

¹ Quick UDP Internet Connections



رفتارهای جدید برنامه‌ها ضعف دارند، به‌ویژه زمانی که این الگوها در داده‌های آموزشی نمایان نیستند. همچنین، ادغام وابستگی‌های متنی و زمانی در یک چارچوب یکپارچه کمتر مورد توجه قرار گرفته است. این شکاف‌ها نیاز به توسعه چارچوبی را برجسته می‌کند که نه تنها دقت و کارایی را ارتقا دهد، بلکه از تکنیک‌های پیشرفته برای پوشش‌دهی بهتر به تنوع ترافیک رمزنگاری‌شده استفاده کند و محدودیت‌های موجود را کاهش دهد.

در پژوهشی که اخیراً انجام شده [۱۷]، طبقه‌بندی ترافیک شبکه رمزگذاری شده Tor و غیر Tor-بررسی شده است. این تحقیق بر ویژگی‌های خاص ترافیک Tor تمرکز دارد که به دلیل استفاده از رمزگذاری لایه‌ای چندگانه، از ترافیک‌های دیگر متمایز می‌شود. در ابتدا، فرض بر این بود که تفاوت قابل توجهی بین بسته‌های رمزگذاری شده Tor و غیر Tor-وجود ندارد. اما تحلیل آماری نشان داد که این دو نوع ترافیک ویژگی‌های متمایز دارند، به‌ویژه در نمایش‌های هگزادسیمال. در این مطالعه، الگوریتم‌های یادگیری برای طبقه‌بندی ترافیک بر اساس ویژگی‌های استخراج‌شده از بسته‌های رمزگذاری شده استفاده شدند. نتایج نشان می‌دهند که روش‌های سنتی در تمایز بین داده‌های رمزگذاری شده یک‌لایه و سه‌لایه مشکل دارند، درحالی‌که روش پیشنهادی با شناسایی الگوهای هگزادسیمالی، دقت بالایی در طبقه‌بندی ترافیک Tor از سایر ترافیک‌های رمزگذاری‌شده به دست می‌آورد. مقاله [۱۸] دو تکنیک نوین افزایش داده را معرفی می‌کند که هدف آن‌ها بهبود طبقه‌بندی ترافیک اینترنت رمزگذاری شده است. نویسندگان به چالش‌هایی اشاره می‌کنند که ناشی از توسعه سریع پروتکل‌ها و رمزگذاری است و منجر به محدودیت دسترسی به مجموعه داده‌های آموزشی می‌شود. تکنیک میانگین‌گیری با ترکیب میانگین نمونه‌ها در یک کلاس، نمونه‌های مصنوعی جدیدی تولید می‌نماید و تنوع مجموعه داده را افزایش می‌دهد. آزمایش‌های انجام‌شده روی مجموعه داده‌های آکادمیک و تجاری نشان‌دهنده بهبود عملکرد مدل‌ها است. یافته‌ها تأکید دارند که این روش‌ها می‌توانند محدودیت‌های داده‌های موجود را رفع نمایند و دقت طبقه‌بندی ترافیک رمزگذاری‌شده را افزایش دهند. جدول ۱ به‌طور خلاصه مطالعات انجام‌شده را بررسی و مدل پیشنهادی را با آن‌ها مقایسه

زمانی، و از دست دادن بسته‌ها، که عملکردی بهتر از تقویت‌های تصویری سنتی ارائه می‌دهد. این مطالعه اثربخشی این روش را در مجموعه داده‌هایی مانند QUIC و ISCX نشان می‌دهد که به‌دقتی تا ۹۴٫۵ درصد دست می‌یابد. این نوآوری راه‌حلی عملی و مقیاس‌پذیر برای طبقه‌بندی ترافیک رمزگذاری‌شده، به‌ویژه در سناریوهایی با کمبود داده‌های برجسب‌دار، ارائه می‌کند.

در مقاله [۱۶]، FlowPic به‌عنوان یک روش نوآورانه برای طبقه‌بندی ترافیک رمزگذاری‌شده و شناسایی اپلیکیشن‌ها معرفی شده است. در این روش، داده‌های جریان شبکه به هیستوگرام‌های دوبعدی تبدیل می‌شوند که FlowPic نامیده شده و به یک شبکه عصبی کانولوشنی برای طبقه‌بندی وارد می‌شوند. این هیستوگرام‌ها با ترسیم اندازه بسته‌ها در مقابل زمان رسیدن آن‌ها ساخته شده و ویژگی‌های زمانی و اندازه‌ای ترافیک را ثبت می‌کنند. این نمایه جدید نیاز به ویژگی‌های دستی‌سازی‌شده را حذف کرده و از توانایی‌های تکنیک‌های طبقه‌بندی تصویر بهره می‌برد. این مطالعه نشان می‌دهد که FlowPic می‌تواند با چالش‌های مختلفی از جمله دسته‌بندی ترافیک، شناسایی اپلیکیشن و تکنیک‌های رمزگذاری مانند VPN و Tor به‌خوبی مقابله کند. نتایج چشمگیری از جمله دقت ۹۹٫۷ درصد برای طبقه‌بندی اپلیکیشن‌های VoIP و ویدیو بر روی ترافیک VPN و بیش از ۹۶ درصد برای دسته‌بندی ترافیک غیر-VPN به‌دست آمده است. مهم‌تر از همه، این روش حتی برای اپلیکیشن‌ها و انواع ترافیکی که در مرحله آموزش دیده نشده‌اند، عملکرد قابل‌اعتمادی دارد و توانایی تعمیم‌دهی بالا بدون نیاز به آموزش اضافی را نشان می‌دهد. این رویکرد گامی مهم در طبقه‌بندی ترافیک رمزگذاری‌شده است که هم مسائل مربوط به حریم خصوصی و هم کارایی محاسباتی را مدنظر قرار داده است.

درمجموع باوجود پیشرفت‌های چشمگیر در طبقه‌بندی ترافیک رمزنگاری‌شده، برخی چالش‌ها همچنان پابرجا هستند. یکی از مسائل اصلی، از دست رفتن بخشی از اطلاعات در فرآیندهایی مانند تبدیل داده‌ها به تصاویر در روش‌هایی مانند FlowPic است که می‌تواند بر دقت نهایی مدل تأثیر بگذارد. علاوه بر این، مدل‌های موجود اغلب در تعمیم‌پذیری به الگوهای ترافیکی ناشناخته یا

به‌دقت ۹۹,۳۷ درصد در شناسایی ترافیک رمزنگاری شده نسبت به کارهای پیشین پیشرفت چشمگیری را نشان می‌دهد.

می‌کند. مقایسه نتایج مدل پیشنهادی با روش‌های اخیر در تحلیل ترافیک رمزنگاری شده نشان می‌دهد که استفاده از یادگیری عمیق و ترکیب داده‌های تصویری و کمکی (Aux) توانسته است دقت مدل را به‌طور قابل‌توجهی افزایش دهد. این تحقیق با دستیابی

جدول ۱: مقایسه مدل پیشنهادی با مطالعات پیشین در زمینه تحلیل ترافیک رمزنگاری شده

ویژگی‌ها / روش‌ها	ون تانگو و همکاران [۱۳]	کورود [۱۷]	زبون و همکاران [۱۸]	شاپیرا و همکاران [۱۶]	هوروویتز و همکاران [۱۵]	شهباز رضایی و شین لنو [۱۴]	مدل پیشنهادی
پشتیبانی و استفاده از داده‌های کمکی	X	X	X	X	X	X	✓
کارایی در داده‌های برچسب‌دار محدود	✓	X	X	X	✓	✓	✓
پشتیبانی از انتقال یادگیری	X	X	X	X	X	X	✓
مقیاس‌پذیری	✓	X	✓	✓	✓	✓	✓
تعمیم‌پذیری به ترافیک ناشناخته	X	X	X	X	✓	✓	✓
مدیریت تغییرات شبکه	X	X	✓	✓	✓	✓	✓
از دست رفتن اطلاعات در پیش‌پردازش	X	X	X	X	X	X	✓

مدل، بیان خواهد شد. هدف از این بخش، تشریح مراحل آماده‌سازی داده‌ها، پیاده‌سازی مدل و ترکیب اطلاعات به‌منظور دستیابی به نتایج دقیق‌تر در تحلیل ترافیک شبکه است. در مرحله اول، عملیات پیش‌پردازش داده بر روی یک فایل متنی ۱,۵ گیگابایتی دربرگیرنده مجموعه داده^۱ UCDAVIS19 [۲۲] انجام خواهد شد. در این راستا، داده‌های متنی به فرمت CSV تبدیل می‌شوند که برای تحلیل‌های بعدی بسیار مناسب‌تر است. همچنین در این مرحله، داده‌ها برای کاهش حجم و تمرکز بر جزئیات مهم‌تر فیلتر می‌شوند؛ به‌عنوان مثال، بازه‌های زمانی مشخص (۱۵ ثانیه^۲ [۱۸-۲۰]) از داده‌ها استخراج می‌گردند که این تکنیک در

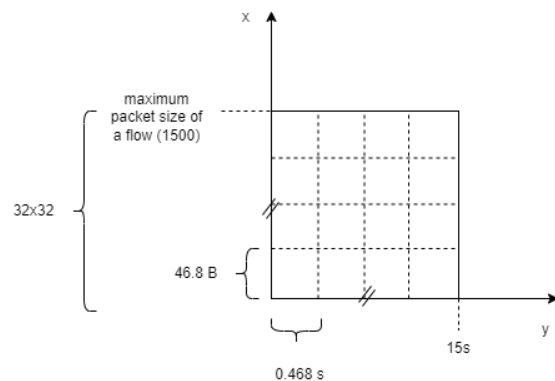
۳- رویکرد پیشنهادی

در این بخش، رویکردهای مختلفی که در این تحقیق برای شناسایی و طبقه‌بندی ترافیک شبکه با استفاده از یادگیری عمیق به کار گرفته شده‌اند، به‌تفصیل شرح داده می‌شود. ابتدا فرآیند پیش‌پردازش داده‌ها و آماده‌سازی مجموعه داده توضیح داده می‌شود. سپس، دو نوع داده اصلی شامل داده‌های تصویری (FlowPic) و داده‌های کمکی (Aux) معرفی می‌شوند که به‌طور هم‌زمان برای تقویت قابلیت مدل در شناسایی دقیق‌تر ترافیک شبکه، به‌ویژه ترافیک رمزنگاری شده، استفاده شده‌اند. در ادامه، جزئیات معماری شبکه عصبی VGG16 و نحوه ترکیب این داده‌ها برای بهبود عملکرد

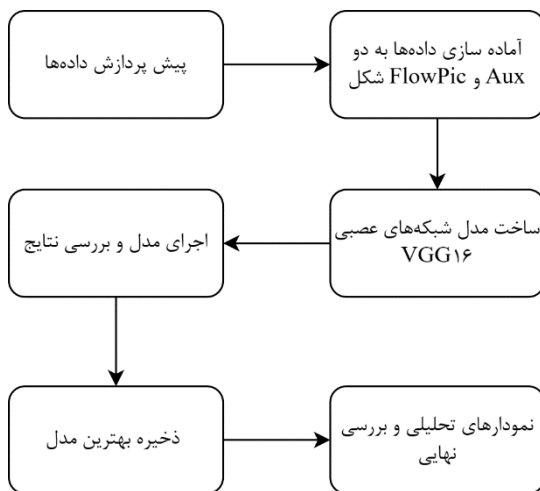
^۲ زمان ۱۵ ثانیه مطابق با پژوهش‌های مشابه انتخاب گردیده است.

^۱ Dataset

است، این دو ویژگی پردازش می‌شوند تا اطلاعات آماری مفیدی به دست آید. به‌طور خاص، برای هر بازه، چهار شاخص حداکثر (Max)، حداقل (Min)، انحراف معیار (Std)، و میانگین (Avg) محاسبه می‌شوند. این محاسبات برای هر دو ویژگی زمان و اندازه بسته انجام می‌شود، که در مجموع ۸ ویژگی عددی جدید تولید می‌کند. این ویژگی‌ها به‌صورت یکپارچه ذخیره شده و به مجموعه داده‌ای موسوم به Aux تبدیل می‌شوند که نمایی خلاصه و مفید از جریان‌های داده ارائه می‌دهد.



شکل (۱): شمای تشکیل FlowPic



شکل (۲): فلوچارت کلی

هدف از تولید داده‌های Aux، ارائه اطلاعات عددی تکمیلی به مدل است که رفتار کلی جریان‌ها، از جمله تغییرات زمانی و حجمی، را به‌خوبی نشان می‌دهد. این داده‌ها در کنار داده‌های تصویری (FlowPic) به مدل یادگیری عمیق کمک می‌کنند تا علاوه بر تحلیل الگوهای تصویری، از اطلاعات عددی و تحلیلی برای بهبود

کاربردهایی مانند پردازش صوت و ویدیو رایج است. برای درک و پیش‌بینی رفتار ترافیک شبکه و بهبود الگوریتم‌های مدیریت ترافیک، تحلیل دقیق زمان شروع جریان اهمیت بسزایی دارد در واقع رفتار منحصر به فرد ترافیک هر جریان عمدتاً به بازه زمانی شروع جریان وابسته است [۲۱]. این وابستگی ناشی از ماهیت پویا و متغیر ترافیک شبکه است، که در آن عوامل مختلفی مانند شرایط لحظه‌ای شبکه، تعداد اتصالات هم‌زمان، میزان ازدحام، و اولویت‌بندی بسته‌ها بر رفتار جریان تأثیر می‌گذارند [۲۳]. پس از پردازش و فیلترسازی که به‌منظور کاهش پیچیدگی داده‌ها و بهبود عملکرد مدل‌های یادگیری ماشین انجام می‌شود. داده‌ها را به شکل ساختاریافته و تمیز آماده می‌کند، داده‌های مختلف باهم ترکیب یا هماهنگ می‌شوند تا یک مجموعه داده یکپارچه و ساختاریافته ایجاد شود.

در مرحله بعد، داده‌ها به دودسته Aux و FlowPic تقسیم می‌شوند. FlowPic یک نمایش تصویری از جریان داده‌ها است. بدین شکل که جریان داده تنها با سه ویژگی در شبکه، به روی دو محور زمان و اندازه بسته، نقش می‌گیرد. ویژگی اول زمان رسیدن بسته، ویژگی دوم اندازه بسته و ویژگی سوم، تعداد بسته در واحد زمان مشخص شده، است. محور زمان در نهایت ۱۵ ثانیه را نشان می‌دهد اما محور اندازه بسته، با توجه به هر جریان متغیر بوده و توزیع متفاوتی را برای هر جریان ارائه می‌دهد. به‌طور مثال اگر در یک جریان اندازه ماکسیمم یک بسته ۱۰۰۰ بایت باشد، مقیاس محور با این اندازه تنظیم می‌شود و چنانچه ماکسیمم یک بسته در یک جریان ۱۵۰۰ بایت باشد نیز مقیاس با این اندازه منطبق می‌شود. در نهایت این تصاویر در اندازه ۳۲*۳۲ تولید می‌شوند. برای رسیدن به این اندازه می‌بایست اندازه نهایی هر محور به ۳۲ تقسیم شود تا اندازه هر قسمت از پیکسل‌ها مشخص گردد. در اینجا با توجه به اینکه زمان همواره در آستانه ۱۵ ثانیه است. هر قسمت زمانی در تصاویر جریان ما حدود ۴۵۸ هزارم ثانیه را نشان می‌دهد. شکل ۱ ساختار FlowPic را نشان می‌دهد.

داده‌های Aux به‌عنوان یک مجموعه داده کمکی از دو ویژگی اصلی زمان (Time) و اندازه بسته‌ها (Packet Size) استخراج شده است. برای هر جریان داده که به بازه‌های ۱۵ ثانیه‌ای تقسیم شده

ترافیک رمزنگاری شده استفاده شده است. داده‌های ترافیکی با استفاده از روش FlowPic به تصاویر تبدیل شده‌اند که ویژگی‌های مهم ترافیک را به‌طور تصویری نمایش می‌دهند. این ویژگی‌ها امکان شناسایی دقیق‌تر الگوهای ترافیک را فراهم می‌کنند که VGG16 قادر به تحلیل آن‌ها به‌طور مؤثر است. استفاده از شبکه VGG16 در این مدل به دلیل توانایی بالای آن در استخراج ویژگی‌های پیچیده از داده‌های تصویری مانند تصاویر تولید شده توسط FlowPic است. معماری ساده و مؤثر VGG16 با لایه‌های کانولوشنی کوچک (3×3) به‌صورت متوالی، امکان شناسایی تدریجی ویژگی‌ها را فراهم می‌کند و برای تحلیل الگوهای پیچیده ترافیک رمزنگاری شده مناسب است. این شبکه به دلیل عملکرد اثبات شده در وظایف طبقه‌بندی و توانایی تطبیق با داده‌های تصویری، انتخابی ایده‌آل برای شناسایی الگوهای موجود در ترافیک رمزنگاری شده است. تبدیل داده‌های ترافیکی به تصاویر FlowPic ممکن است برخی ویژگی‌های زمانی ترافیک را نادیده بگیرد. به‌منظور جبران این نقص، در این تحقیق از داده‌های کمکی (Aux) استفاده کرده‌ایم که ویژگی‌های زمانی ترافیک را پوشش می‌دهند. این داده‌های کمکی به مدل این امکان را می‌دهند که رفتارهای پویای شبکه را نیز تحلیل کرده و در نتیجه شناسایی دقیق‌تری از ترافیک رمزنگاری شده انجام دهد.

۲-۳ مدل پیشنهادی

در مدل پیشنهادی، داده‌های کمکی (AUX) نقش مهمی در غنی‌سازی ویژگی‌های ورودی برای بهبود دقت مدل ایفا می‌کنند. همان‌طور که در ابتدای این بخش توضیح داده شد، ابتدا داده‌های AUX وارد یک لایه Flatten می‌شوند تا به یک بردار یک‌بعدی تبدیل شوند. این مرحله تضمین می‌کند که داده‌ها برای پردازش در لایه‌های بعدی مناسب باشند. سپس این بردار از یک لایه Dense عبور می‌کند، که با اعمال یک ترکیب خطی و غیرخطی، ویژگی‌های کلیدی را از این داده‌ها استخراج و بهینه می‌کند. در ادامه، خروجی حاصل از داده‌های AUX با خروجی داده‌های تصویری، که از بخش دیگری از مدل (شبکه CNN مانند VGG16) به‌دست آمده است، ترکیب می‌شود. این ترکیب با استفاده از عملیات Concatenate انجام می‌شود که باعث ادغام


پیش‌بینی‌ها بهره‌مند شود. به‌این‌ترتیب، Aux و FlowPic یک نمای مکمل و جامع از داده‌ها فراهم می‌کنند که به یادگیری و تصمیم‌گیری دقیق‌تر مدل کمک می‌کند. در واقع در این مقاله سعی شده است تا ترافیک شبکه متعلق به هر جریان تبدیل به تصویر شود و با استفاده از روش‌های مؤثر و کارا در پردازش تصویر، ترافیک شبکه رمز شده متعلق به هر جریان شناسایی شود. شکل ۲، یک نمای شماتیک از رویکرد پیشنهادی در این مقاله است.

۱-۳ شبکه عصبی VGG16

در این تحقیق، به‌منظور تحلیل ترافیک شبکه از شبکه عصبی کانولوشنی (CNN) استفاده شده است. به‌طور معمول، شبکه‌های CNN برای پردازش داده‌هایی با ویژگی‌های مکانی طراحی می‌شوند. در این مقاله، ترافیک شبکه ابتدا به تصاویر FlowPic تبدیل شده‌اند که ویژگی‌های زمانی و اندازه‌ای بسته‌ها را در هر بازه زمانی خاص نمایش می‌دهند. این تصاویر به‌عنوان ورودی به شبکه CNN داده می‌شوند تا مدل بتواند الگوهای پیچیده ترافیک رمزنگاری شده را شناسایی کند. این رویکرد به‌ویژه برای شناسایی رفتارهای پیچیده ترافیک شبکه در طول زمان مؤثر است، زیرا تصاویر FlowPic اطلاعات زمانی ترافیک را به‌طور تصویری نمایان می‌کنند، درحالی‌که ویژگی‌های مربوط به اندازه بسته‌ها نیز در آن‌ها قابل مشاهده است.

VGG16 یک شبکه عصبی پیچشی (CNN) است که در سال ۲۰۱۴ توسط کارن سیمونیان و اندرو زیسرمن از دانشگاه آکسفورد معرفی شد. این مدل با استفاده از ۱۳ لایه کانولوشنی و ۳ لایه کاملاً متصل، در مجموع ۱۶ لایه، به دقت ۹۲٫۷٪ در تشخیص تصاویر مجموعه داده ImageNet دست‌یافت. ویژگی بارز VGG16 استفاده از فیلترهای کوچک 3×3 در تمام لایه‌های کانولوشنی است که امکان استخراج ویژگی‌های پیچیده را فراهم می‌کند. باوجود تعداد بالای پارامترها (حدود ۱۳۸ میلیون)، این مدل به‌طور گسترده در وظایف مختلف بینایی کامپیوتر مانند طبقه‌بندی تصاویر و استخراج ویژگی‌ها مورد استفاده قرار گرفته است [۲۳، ۲۴]. باوجود اینکه مدل VGG16 به‌طور معمول در زمینه بینایی کامپیوتر برای شناسایی تصاویر حیوانات در ImageNet استفاده می‌شود، در این تحقیق از این مدل برای شناسایی الگوهای پیچیده در

به‌طور طبیعی نتایج بهتری ارائه کردند، اما در مقایسه با روش‌های پیشین و پژوهش‌های دیگر محققین، نتایج آن‌ها نیز چشمگیر نبودند. با توجه به دقت‌های بالایی که دیگر محققین بر روی این دیتاست به دست آورده بودند و الهام از روش‌های موفق بر روی دیتاست‌های دیگر، در نهایت آزمایش این شبکه و ادغام آن با داده‌هایی که قبلاً در پژوهش‌های دیگر نادیده گرفته می‌شد، توانست نتیجه قابل قبولی ارائه دهد.




شکل (۵): نقشه گرمایی تشخیص ویژگی‌ها در هر بلوک

۴- ارزیابی مدل


مجموعه داده استفاده‌شده در این پژوهش UCDAVIS19 است [۱۴]. این مجموعه داده که در آزمایشگاه دانشگاه کالیفرنیا، دیویس جمع‌آوری شده است، اطلاعاتی از پنج سرویس محبوب گوگل (Google Drive، YouTube، Google Docs، Google Music و Search) را شامل می‌شود. داده‌ها با استفاده از سیستم‌های مختلف شامل ویندوز ۷، ۸، ۱۰ و اوبونتو ۱۶.۴ و ۱۷ گردآوری شده‌اند. برای شبیه‌سازی رفتار انسانی، اسکریپت‌هایی با ابزارهای Selenium WebDriver و AutoIt نوشته شده است که امکان جمع‌آوری حجم زیادی از داده را بدون نیاز به تلاش دستی فراهم می‌کند. در مرحله پیش‌پردازش، تمامی ترافیک‌های خارج از دسته‌بندی مشخص شده حذف و جریان‌های داده برچسب‌گذاری شده‌اند، این مجموعه داده با مقایسه روش‌های نظارت کامل و

اطلاعات متنوع از دو منبع مختلف می‌گردد. این رویکرد به مدل امکان می‌دهد که نه تنها از ویژگی‌های غنی موجود در داده‌های تصویری بهره‌برداری کند، بلکه اطلاعات تکمیلی و زمینه‌ای موجود در داده‌های AUX را نیز در تصمیم‌گیری نهایی لحاظ کند. این ادغام داده‌ها یک مرحله کلیدی در طراحی مدل است که با هدف تقویت یادگیری و افزایش دقت در شناسایی و طبقه‌بندی ترافیک رمزنگاری‌شده انجام می‌شود. شکل ۲ مدل پیشنهادی را نشان می‌دهد.



شکل (۳): مدل پیشنهادی

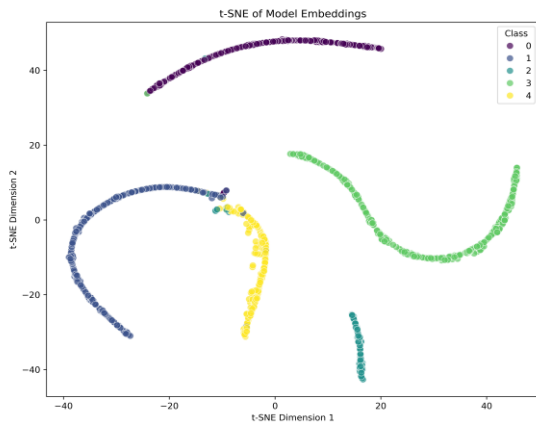
ورودی مدل به‌صورت تصاویر (FlowPic) بوده و با توجه به ساختار شبکه عصبی VGG در پنج بلوک، عملیات استخراج ویژگی انجام می‌گیرد و سپس بعد از ورود داده‌های AUX و ادغام جواب نهایی در پنج کلاس موجود در مجموعه داده UCDAVIS19 طبقه‌بندی می‌گردد. همان‌طور که قبلاً اشاره شد، تصاویر دارای ابعاد ۳۲*۳۲ بوده نمای از تبدیل جریان‌ها به FlowPic در شکل ۴ آمده است.



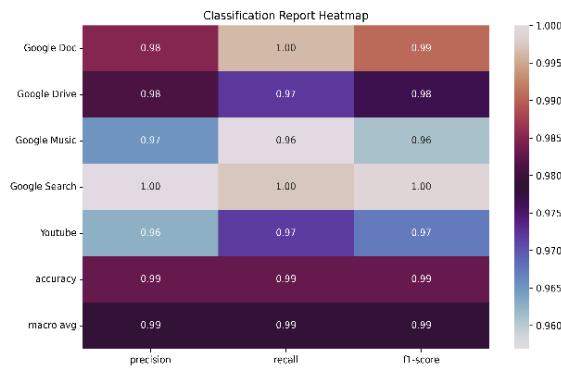
شکل (۴): نمای از FlowPic ایجادشده

انتخاب این شبکه به‌طور اتفاقی نبوده است و بر اساس آزمایش‌های قبلی و نیازهای خاص، داده‌ها به این شبکه اختصاص یافته است. روش‌هایی مانند Naïve Bayes، به دلیل عدم در نظر گرفتن وابستگی‌های میان داده‌ها، نتوانستند نتایج مطلوبی در این آزمایش ارائه دهند؛ زیرا ماهیت داده‌های استفاده‌شده ذاتاً وابسته است. روش‌های دیگری مانند درخت تصمیم و جنگل‌های تصادفی

شکل (۷): ماتریس سردرگمی



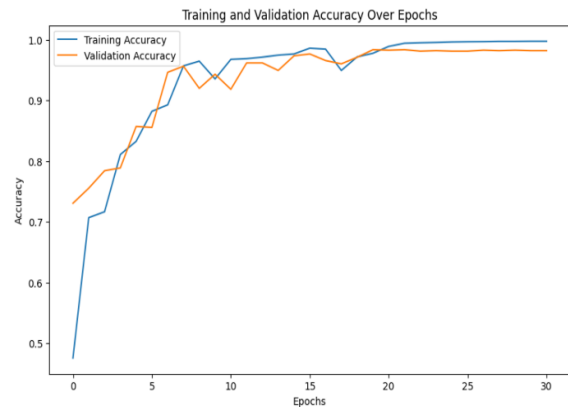
شکل (۸): نمودار t-SNE لایه انتهایی




شکل (۹): نمودار نقشه-گرمایی ارزیابی مدل

برای ارزیابی مدل، از ماتریس سردرگمی استفاده شده است که به‌طور دقیق نحوه پیش‌بینی‌ها را در هر کلاس نمایش می‌دهد و به شناسایی کلاس‌هایی که مدل در آن‌ها عملکرد ضعیف‌تری دارد، کمک می‌کند (شکل ۷). علاوه بر این، نمودار t-SNE برای تجسم داده‌ها در فضای دوبعدی به‌کاررفته است تا نشان دهد مدل چگونه ویژگی‌های مختلف را از هم تفکیک می‌کند (شکل ۸). همچنین، مقادیر Recall، F1-score و Precision در قالب یک نقشه‌گرمایی در شکل ۹ نمایش داده شده‌اند. این معیارها نمای کلی از تعادل بین دقت و پوشش مدل ارائه می‌دهند و به مقایسه عملکرد مدل در کلاس‌های مختلف کمک می‌کنند. ترکیب این ابزارها به شناسایی

نیمه‌نظارت، فرصت ارزشمندی برای تحقیق در زمینه تحلیل ترافیک شبکه و یادگیری ماشین فراهم می‌کند. مطابق با شکل ۵ در لایه‌های اولیه (ردیف اول یعنی Block1)، شبکه ویژگی‌های ساده و ابتدایی مثل لبه‌ها، بافت‌ها و الگوهای ساده را شناسایی می‌کند. نقشه‌های گرمایی این لایه‌ها معمولاً نواحی گسترده‌ای از تصویر را پوشش می‌دهند و تمرکز خاصی روی بخش‌های کوچک‌تر ندارند. در لایه‌های میانی (مثل Block2، Block3)، شبکه ویژگی‌های پیچیده‌تری مثل اشکال و ساختارهای جزئی‌تر را شناسایی می‌کند. نقشه‌های گرمایی در این لایه‌ها به‌مرور متمرکزتر شده و بخش‌های خاص‌تری از تصویر را برجسته می‌کنند. اما در لایه‌های عمیق‌تر (مثل Block4، Block5)، شبکه بر ویژگی‌های سطح بالاتری تمرکز می‌کند که به‌طور مستقیم با دسته مرتبط هستند. این اظهارات با توجه به نتایج به‌دست‌آمده از شکل، قابل استنباط است. دقت مدل در این روش به ۹۸,۳۷ درصد رسیده است که نسبت به مدل‌های قبلی افزایش داشته است. نمودار دقت داده تست و اعتبار سنجی در شکل ۶ آمده است.



شکل (۶): نمودار دقت مدل



برخی چالش‌ها مانند محدودیت‌های محاسباتی ناشی از استفاده از مدل‌های پیچیده مانند VGG16 و نیاز به مجموعه داده‌های باکیفیت بالا، همچنان وجود دارند. برای رفع این چالش‌ها، پیشنهاد می‌شود که در آینده از تکنیک‌های فشرده‌سازی مدل و یادگیری انتقالی برای کاهش هزینه‌های محاسباتی و افزایش مقیاس‌پذیری استفاده شود. در مجموع، این پژوهش با معرفی روش جدید و اثربخش در تحلیل ترافیک شبکه، گامی مهم در ارتقای دقت و کارایی سیستم‌های شناسایی شبکه برداشته و می‌تواند زمینه‌ساز پیشرفت‌های بیشتری در این حوزه باشد.

۶- نتیجه‌گیری

در این تحقیق، رویکرد پیشنهادی برای طبقه‌بندی ترافیک رمزنگاری شده با استفاده از شبکه عصبی عمیق VGG16، ترکیب داده‌های تصویری و کمکی، توانسته است دقت مدل را به ۹۹,۳۷ درصد برساند. این روش به‌طور مؤثر به شناسایی ترافیک رمزنگاری شده پرداخته و بهبود قابل توجهی در دقت و کارایی سیستم‌های شناسایی ترافیک شبکه ایجاد کرده است. به‌طور خاص، استفاده از داده‌های کمکی Aux به مدل امکان داد تا از الگوهای زمانی و حجمی داده‌ها برای پیش‌بینی دقیق‌تر بهره‌برداری کند. با وجود دقت بالای مدل، محدودیت‌هایی مانند پیچیدگی محاسباتی مدل و نیاز به داده‌های باکیفیت بالا همچنان وجود دارد. این چالش‌ها می‌توانند بر مقیاس‌پذیری مدل در محیط‌های بزرگ تأثیرگذار باشند. پیشنهاد می‌شود که در آینده از تکنیک‌های فشرده‌سازی مدل و یادگیری انتقالی برای کاهش هزینه‌های محاسباتی استفاده شود. به‌طور کلی، این پژوهش می‌تواند به‌عنوان پایه‌ای برای توسعه روش‌های جدید در تحلیل و مدیریت شبکه‌های پیچیده مورد استفاده قرار گیرد. در آینده، می‌توان با بهره‌گیری از تکنیک‌های بهینه‌سازی مدل و روش‌های یادگیری نیمه‌نظارتی یا بدون‌نظارت، این پژوهش را بهبود بخشید و قابلیت‌های آن را برای کاربردهای عملی در مقیاس بزرگ‌تر توسعه داد.

نقاط قوت و ضعف مدل در طبقه‌بندی و بهبود عملکرد آن کمک کرده است.

۵- نتایج

در جدول شماره ۲ مقایسه دقت‌های به‌دست‌آمده با برخی از روش‌های مرتبط آورده شده است.

جدول (۲): دقت‌های پژوهش‌های مختلف

مرجع	روش	دقت	دیتاست
مدل پیشنهادی	VGG16	۹۹/۳۷	UCDAVIS19
ون تانگو - ۲۰۱۸	CNN	۹۸/۲۴	UCDAVIS19
شهباز رضایی - ۲۰۲۰	CNN	۹۸/۵۳	UCDAVIS19
ایال هورویتز - ۲۰۲۲	SimCLR	۹۸/۷	UCDAVIS19

تحلیل یافته‌های این پژوهش نشان می‌دهد که استفاده از معماری عمیق شبکه عصبی VGG16 در ترکیب با تکنیک‌های پیش‌پردازش داده مانند تولید داده‌های FlowPic و Aux، منجر به دقت بالای ۹۹,۳۷ درصد در طبقه‌بندی ترافیک شبکه شده است. این دقت نه تنها از روش‌های پیشین مانند شبکه‌های CNN سنتی و SimCLR بالاتر است، بلکه کاربردپذیری این روش در سناریوهای پیچیده‌تر را نیز تضمین می‌کند. یکی از نقاط قوت برجسته این پژوهش، استفاده از داده‌های کمکی Aux برای غنی‌سازی ورودی مدل و بهبود عملکرد آن است. داده‌های Aux با ارائه اطلاعات آماری مانند حداکثر، حداقل، میانگین، و انحراف معیار در بازه‌های زمانی مشخص، امکان تحلیل دقیق‌تر و پیش‌بینی بهتر الگوهای پیچیده را فراهم کرده است. این روش ترکیبی، نمایشی جامع‌تر از داده‌ها ارائه می‌دهد و نشان می‌دهد که تلفیق ویژگی‌های عددی و تصویری می‌تواند مزایای قابل توجهی در تحلیل داده‌ها داشته باشد. همچنین، مقایسه با پژوهش‌های پیشین نشان می‌دهد که این رویکرد در پردازش ترافیک شبکه و طبقه‌بندی دقیق‌تر داده‌های رمزگذاری شده بسیار مؤثر بوده است. برای مثال، نتایج این پژوهش در مقایسه با سایر پژوهش‌ها پیشرفت محسوسی را نشان می‌دهد. این دستاورد به دلیل بهره‌گیری بهینه از تکنیک‌های یادگیری عمیق و ترکیب داده محوری به‌دست‌آمده است. با این حال،



References

- [1] A. R. Bahlali, A. Bachir, and A. Cheriet, "Malicious encrypted network traffic detection using deep auto-encoder with a custom reconstruction loss," in *2023 International Symposium on Networks, Computers and Communications (ISNCC)*, 2023.
- [2] J. Cao et al., "An improved network traffic classification model based on a support vector machine," *Symmetry*, vol. 12, no. 2, p. 301, 2020, doi: 10.3390/sym12020301.
- [3] P. Choorod, T. J. Bauer, and A. Aßmuth, "Distinguishing Tor from other encrypted network traffic through character analysis," *arXiv preprint arXiv:2405.09412*, 2024.
- [4] Y. Cui and A. Li, "Research on network encrypted traffic detection technology based on CNN + LSTM," in *2024 2nd International Conference on Signal Processing and Intelligent Computing (SPIC)*, 2024.
- [5] L. Deri and F. Fusco, "Using deep packet inspection in cybertraffic analysis," in *2021 IEEE International Conference on Cyber Security and Resilience (CSR)*, 2021, doi: 10.1109/CSR51186.2021.9527976.
- [6] C. Hardegen et al., "Predicting network flow characteristics using deep learning and real-world network traffic," *IEEE Trans. Netw. Serv. Manage.*, vol. 17, no. 4, pp. 2662–2676, 2020.
- [7] E. Horowicz, T. Shapira, and Y. Shavitt, "Self-supervised traffic classification: Flow embedding and few-shot solutions," *IEEE Trans. Netw. Serv. Manage.*, 2024, doi: 10.1109/TNSM.2024.3366848.
- [8] E. Horowicz, T. Shapira, and Y. Shavitt, "A few shots traffic classification with mini-flowpic augmentations," in *Proc. 22nd ACM Internet Measurement Conference*, 2022, doi: 10.1145/3517745.3561436.
- [9] S. Li et al., "Network traffic prediction based on the feature of newly-generated network flows," in *2022 IFIP Networking Conference (IFIP Networking)*, 2022.
- [10] X. Liu et al., "Mal-lightDet: A light method to detect malicious encrypted traffic based on machine learning," in *Proc. 4th Int. Conf. Control, Robotics and Intelligent System*, 2023, doi: 10.1145/3622896.3622907.
- [11] Y. Liu et al., "Encrypted malicious traffic detection based on graph convolutional network and temporal dissection," in *2024 27th Int. Conf. Comput. Supported Cooperative Work in Design (CSCWD)*, 2024.
- [12] M. Lotfollahi et al., "Deep packet: A novel approach for encrypted traffic classification using deep learning," *Soft Comput.*, vol. 24, no. 3, pp. 1999–2012, 2020, doi: 10.1007/s00500-019-04030-2.
- [13] S. Mascarenhas and M. Agarwal, "A comparison between VGG16, VGG19 and ResNet50 architecture frameworks for image classification," in *2021 Int. Conf. Disruptive Technol. for Multi-Disciplinary Res. and Appl. (CENTCON)*, 2021.
- [14] S. Rezaei, B. Kroencke, and X. Liu, "Large-scale mobile app identification using deep learning," *IEEE Access*, vol. 8, pp. 348–362, 2019.
- [15] T. Shapira and Y. Shavitt, "FlowPic: A generic representation for encrypted traffic classification and applications identification," *IEEE Trans. Netw. Serv. Manage.*, vol. 18, no. 2, pp. 1218–1232, 2021, doi: 10.1109/TNSM.2021.3071441.
- [16] M. Shen et al., "Machine learning-powered encrypted network traffic analysis: A comprehensive survey," *IEEE Commun. Surveys Tuts.*, vol. 25, no. 1, pp. 791–824, 2022, doi: 10.1109/COMST.2022.3208196.
- [17] G. Siracusano et al., "Re-architecting traffic analysis with neural network interface cards," in *Proc. 19th USENIX Symp. Netw. Syst. Design and Implementation (NSDI 22)*, 2022.
- [18] L. Swarup, "Encrypted traffic analysis for malware detection using deep learning," in *2023 IEEE Int. Conf. ICT in Business Industry & Government (ICTBIG)*, 2023.
- [19] V. Tong et al., "A novel QUIC traffic classifier based on convolutional neural networks," in *2018 IEEE Global Communications Conference (GLOBECOM)*, 2018.
- [20] A. Finamore, C. Wang, J. Krolkowski, J. M. Navarro, F. Chen, and D. Rossi, "Curated UCDAVIS19 dataset for replication: Contrastive learning and data augmentation in traffic classification using a Flowpic input representation," Figshare, Oct. 2023. [Online]. Available: <https://doi.org/10.6084/m9.figshare.23538141>.
- [21] J. Xing and C. Wu, "Detecting anomalies in encrypted traffic via deep dictionary learning," in *IEEE INFOCOM 2020–IEEE Conf. Comput. Commun. Workshops (INFOCOM WKSHPS)*, 2020.
- [22] X. Yang, N. Angkawisittpan, and X. Feng, "Analysis of an enhanced random forest algorithm for identifying encrypted network traffic," *EUREKA: Physics and Engineering*,



- no. 5, pp. 201–212, 2024,
doi: 10.21303/2461-4262.2024.003372.
- [23] N. Zhou, “Image recognition in depth: Comparative study of CNN and pre-trained VGG16 architecture for classification tasks,” in *Proc. Second Int. Conf. Physics, Photonics, and Optical Engineering (ICPPOE 2023)*, 2024, doi: 10.1117/12.3026829.
- [24] Y. Zion, P. Aharon, R. Dubin, A. Dvir, and C. Hajaj, “Enhancing encrypted internet traffic classification through advanced data augmentation techniques,” *arXiv preprint arXiv:2407.16539*, 2024.

A Novel Approach for Encrypted Traffic Classification Using Deep Learning

Rabiei Dolatabadi Pooya¹, Bastam Mostafa^{2*}, Aghajani Khadijeh²

¹M.Sc Computer Engineering, Faculty of Technology and Engineering, University of Mazandaran, Babolsar, Iran

²Assistant Professor Department of Computer Engineering, Faculty of Technology and Engineering, University of Mazandaran, Babolsar, Iran

Article Information

Original Research Paper

Received:

2024 December 15

Accepted:

2025 February 15

Keywords:

Deep Learning, Network Traffic Analysis, Encrypted Traffic, VGG16 model, Network Traffic Management

Corresponding Author*:

Bastam@umz.ac.ir

Abstract

Network traffic analysis is a fundamental pillar in enhancing the security and efficient management of computer networks. Given the rapid growth of computer networks and the increasing complexity of their traffic, accurate and fast identification of various types of traffic, including encrypted traffic, has become crucial. In this context, the use of machine learning techniques offers a powerful tool for analyzing and accurately identifying traffic patterns. This paper examines advanced methods for traffic identification in computer networks using machine learning techniques. The primary goal of this research is to develop an efficient and accurate model for identifying and classifying various types of network traffic, particularly encrypted traffic. To achieve this, the deep learning model VGG16 was utilized. Due to its deep layered architecture and capability to analyze large volumes of data, VGG16 demonstrated outstanding performance in identifying complex network traffic patterns. It can accurately detect and classify different types of network traffic, thereby improving traffic management within networks. In the scenarios evaluated in this study, the model achieved a remarkable accuracy of 99% in identifying encrypted traffic.

 : 10.22034/ ABMIR.2025.22525.1084

E-ISSN: [2821-2037](https://doi.org/10.22034/ABMIR.2025.22525.1084)

/The Author 2024. Published by Yazd University This is an open access article under the CC BY 4.0 License (<https://creativecommons.org/licenses/by/4.0/>).

