

## رویکردی برخط و انطباقی برای شناسایی برنامه‌ها در ترافیک رمزنگاری شده شبکه با استفاده از مدل یادگیری شبکه عصبی عمیق

محمد امین رستگار\*<sup>۸۵</sup>، مسعود نوفرستی<sup>۸۶</sup>

- ۱- دانشکده مهندسی-گروه مهندسی کامپیوتر - واحد علوم تحقیقات- دانشگاه آزاد اسلامی- تهران- ایران.
- ۲- دانشکده مهندسی-گروه مهندسی کامپیوتر - واحد علوم تحقیقات- دانشگاه آزاد اسلامی- تهران- ایران.

پیچیده‌تر یا در مواقعی که داده‌های برچسب‌خورده به‌صورت لحظه‌ای کم هستند، عملکرد بهتری نسبت به طبقه‌بندهای سنتی دارد.

**واژگان کلیدی:** شناسایی برنامه‌های کاربردی، طبقه‌بندی ترافیک شبکه، طبقه‌بندی جریان داده‌ها، شبکه عصبی عمیق

### اطلاعات مقاله

نوع مقاله: مقاله پژوهشی

تاریخ دریافت: ۱۴۰۳/۱۰/۰۳

تاریخ پذیرش: ۱۴۰۳/۱۲/۰۹

### چکیده

با گسترش روزافزون استفاده از رمزنگاری در ترافیک شبکه، به‌ویژه از طریق پروتکل‌هایی مانند TLS و SSL، کارایی روش‌های سنتی شناسایی برنامه‌ها مبتنی بر تحلیل محتوای بسته‌ها به شدت کاهش یافته است. در شبکه‌های مدرن با پهنای باند بالا، شناسایی بلادرنگ و دقیق برنامه‌ها نه تنها با چالش‌هایی از نظر سرعت، حجم و تنوع داده‌ها مواجه است، بلکه هزینه‌بر نیز می‌باشد. در این پژوهش، یک رویکرد تطبیقی برای طبقه‌بندی جریان‌های ترافیکی ارائه می‌شود که با بهره‌گیری از تکنیک بازرسی عمیق بسته‌ها (DPI) به‌عنوان منبع مرجع، مدل طبقه‌بندی را به‌صورت پویا و مداوم به‌روزرسانی می‌کند. در هسته طبقه‌بندی پیشنهادی، از شبکه عصبی عمیق (DNN) به‌عنوان الگوریتم یادگیری بهره گرفته شده که قادر است الگوهای پیچیده و پنهان در ترافیک رمزنگاری شده را با دقت بالا شناسایی کند. ارزیابی تجربی این روش بر روی دو مجموعه داده عمومی ISCX Tor- و ISCX VPN-nonVPN nonTor انجام شده و نتایج به‌دست‌آمده نشان‌دهنده عملکرد بهتر DNN در برخی آزمایش‌ها است که در دسته‌بندی جریان‌های

\* نویسنده مسئول، پست الکترونیکی: [mohammadamin.rastegar@iau.ir](mailto:mohammadamin.rastegar@iau.ir)

## مقدمه

ظرفیت ترافیک شبکه‌ها به طور مستمر در حال افزایش است و امروزه شبکه‌های ۱۰۰ گیگابیتی در مراکز داده به کار گرفته می‌شوند [۱]. این رشد فزاینده، نیاز به تحلیل برخط ترافیک را برای مدیران شبکه بیش از پیش ضروری ساخته است. طی دهه گذشته، طبقه‌بندی ترافیک شبکه به دلایلی همچون پیاده‌سازی مکانیزم‌های تضمین کیفیت خدمات (QoS)، امنیت، نظارت و مهندسی شبکه، توجه ویژه‌ای را به خود جلب کرده است [۲].

امروزه طبقه‌بندی ترافیک شبکه‌های پهن‌بند به صورت بلادرنگ برای سیستم‌های تشخیص نفوذ خودکار جهت شناسایی الگوهای حملات و حملات انکار سرویس حیاتی است [۳]. همچنین این فناوری در خدمات شبکه‌ای، مانند مدیریت تعرفه‌های اینترنتی، برای شناسایی دقیق برنامه‌های مختلف در پهنای باند ضروری می‌باشد.

ترافیک شبکه‌های پهن‌بند را می‌توان به عنوان دنباله‌ای عظیم، نامحدود و پیوسته از جریان‌ها (Flow Stream) مدل کرد [۴]. هر جریان از بسته‌های متوالی با پنج‌تایی یکسان > آپی مبدأ، پورت مبدأ، آپی مقصد، پورت مقصد، پروتکل TCP/UDP < تشکیل می‌شود. از دیدگاه ساختار داده، ترافیک شبکه، یک دنباله نامتناهی از جریان‌هاست که به صورت  $FlowSet = \{f_1, \dots, f_n\}$  نمایش داده می‌شود.

با ظهور یادگیری عمیق (Deep Learning) و موفقیت آن در حوزه‌های مختلف از جمله بینایی ماشین و پردازش زبان طبیعی، توجه به این تکنیک در حوزه شبکه نیز افزایش یافته است [۵]. به‌ویژه در طبقه‌بندی ترافیک شبکه، استفاده از شبکه‌های عصبی عمیق (DNN) امکان استخراج خودکار الگوهای پیچیده را از ویژگی‌های خام فراهم کرده و عملکرد مدل‌های طبقه‌بندی را در سناریوهای پویا و داده‌های رمزنگاری شده بهبود داده است [۶].

به طور کلی سه روش اصلی در ادبیات طبقه‌بندی ترافیک شبکه وجود دارد:

۱. روش مبتنی بر پورت: که با توجه به شماره پورت‌های استاندارد عمل می‌کند. مطالعاتی مانند [۷]. نشان داده‌اند که این روش امروزه کارایی لازم را ندارد.
۲. روش مبتنی بر محتوای بسته‌ها (DPI) که با بررسی محتوای بسته‌ها و تطبیق الگوها عمل می‌کند. اگرچه این روش، دقت بالایی دارد، اما در شبکه‌های واقعی با محدودیت‌هایی مواجه است.

۳. روش‌های مبتنی بر یادگیری ماشین و یادگیری عمیق: که از ویژگی‌های آماری مستقل از پورت و محتوای بسته‌ها استفاده می‌کند. این روش‌ها نه تنها هزینه محاسباتی کمتری نسبت به DPI دارند، بلکه توانایی طبقه‌بندی ترافیک رمزنگاری‌شده را نیز دارا می‌باشند. به‌ویژه، شبکه‌های عصبی عمیق (DNN) با قابلیت استخراج ویژگی‌های سطح بالا از داده‌های خام، دقت طبقه‌بندی را در محیط‌های پویا افزایش داده‌اند.

ویژگی‌های پویا و متنوع شبکه‌های امروزی، باعث تغییرات مداوم در الگوهای ترافیک می‌شود، بنابراین، الگوریتم‌های طبقه‌بندی باید بتوانند به صورت پویا با این تغییرات سازگار شده و داده‌های قدیمی غیرمرتبط را کنار بگذارند [۷].

در این پژوهش، یک روش انطباقی و برخط برای طبقه‌بندی ترافیک شبکه ارائه می‌شود که از تکنیک‌های یادگیری عمیق بهره می‌برد. روش پیشنهادی از چهار ماژول اصلی تشکیل شده است:

۱. استخراج ویژگی‌ها: تشخیص جریان‌ها و نگهداری ساختار داده FlowSet
۲. بازرسی عمیق بسته‌ها (DPI): تولید برجسب‌ها برای جریان‌های ترافیکی
۳. پردازش جریان: مدیریت جریان‌ها بین ماژول‌ها.
۴. طبقه‌بندی جریان: ساخت و به‌روزرسانی تابع طبقه‌بندی.

در ماژول طبقه‌بندی، از شبکه‌های عصبی عمیق (DNN) به عنوان مدل پایه استفاده شده است. این شبکه‌ها با استفاده از چندین لایه پنهان، توانایی شناسایی الگوهای پیچیده و غیرواضح در داده‌های جریان را دارند و نسبت به مدل‌های کلاسیک، عملکرد بهتری در مواجهه با داده‌های متغیر و رمزنگاری شده نشان می‌دهند.

در این پژوهش، یک چارچوب انطباق‌پذیر و برخط برای طبقه‌بندی ترافیک شبکه ارائه شده است که با هدف پاسخ‌گویی به چالش‌های ناشی از تغییرات پویا در الگوهای ترافیکی طراحی گردیده است. این چارچوب با ترکیب تکنیک‌های یادگیری عمیق و پردازش جریانی، قادر است به صورت لحظه‌ای، جریان‌های شبکه را تحلیل کرده و با دقت بالا به طبقه‌بندی آن‌ها بپردازد. یکی از نوآوری‌های کلیدی این روش، به‌کارگیری شبکه‌های عصبی عمیق (DNN) در بخش طبقه‌بندی جریان‌هاست که موجب بهبود چشم‌گیر دقت و کارایی مدل به‌ویژه در مواجهه با ترافیک‌های رمزنگاری‌شده شده است. همچنین، چارچوب پیشنهادی بر روی مجموعه داده‌های استاندارد و رایج در حوزه ترافیک شبکه، مورد ارزیابی قرار گرفته و نتایج نشان می‌دهد که رویکرد پیشنهادی، نه تنها عملکرد قابل

(meta-event) تعریف می‌شود و روابط بین این فرا-رویدادها برای استخراج رفتار کاربران نهایی مورد استفاده قرار می‌گیرد.

در ادامه این مسیر، [۹] روشی مبتنی بر یادگیری عمیق برای شناسایی کاربرد و توصیف ترافیک شبکه ارائه کردند که در آن فرایندهای استخراج ویژگی و طبقه‌بندی در قالب یک چارچوب یکپارچه پیاده‌سازی شده است. آن‌ها دو مدل مختلف شامل خودرمزگذار انباشته (SAE) و شبکه عصبی پیچشی (CNN) را در این چارچوب به کار گرفته و روش خود را بر روی مجموعه‌داده‌های ISCX و Tor ارزیابی کردند. در این پژوهش، مدل CNN موفق به کسب امتیاز ۰/۹۱ برابر با ۰/۸۷ برای شناسایی کاربرد و ۰/۸۷ برای توصیف نوع ترافیک شده است.

تکنیک‌های بررسی عمیق بسته‌ها (DPI) ترافیک شبکه را بر اساس امضاهای برنامه‌ها پردازش کرده و اطلاعاتی درباره رفتارهای اخیر ارائه می‌دهند. در این راستا، [۷] رویکردی مبتنی بر جریان و مبتنی بر DPI برای طبقه‌بندی جریان‌های شبکه ارائه دادند که هدف آن شناسایی برنامه‌های جدید و به‌روزرسانی تطبیقی مدل طبقه‌بندی است. این روش، جریان‌ها را به صورت آنلاین با استفاده از تکنیک DPI برچسب‌گذاری کرده و مدل طبقه‌بندی را به‌طور متناسب به‌روزرسانی می‌کند. رویکرد پیشنهادی با استفاده از ابزار MOA پیاده‌سازی شده و بر روی چندین مجموعه‌داده ارزیابی شده است. در این مطالعه، استفاده از الگوریتم‌های طبقه‌بندی جریان Adaptive Random Forest و Knn با PAW باعث افزایش دقت در طبقه‌بندی مجموعه‌داده‌ها شده است.

یکی از چالش‌های اصلی در مدیریت داده‌های دورافتاده (Outlier) در شبکه‌های پهن‌بند، نبود هیچ‌گونه اطلاعات قبلی در مورد جریان‌های ورودی آینده است. [۱۰]. با معرفی ساختار داده‌ای «فرا-رویدادهای گسترش یافته» (extended-meta-events) بر روی پنجره لغزان، الگوریتم خوشه‌بندی برخطی را برای جریان‌های شبکه‌ای در محیط‌های پهن‌بند پیشنهاد دادند. این الگوریتم برای استخراج تدریجی اطلاعات از حجم بالای ترافیک پیوسته طراحی شده است، به طوری که برخی از داده‌های دورافتاده پیش از تحلیل رفتار شبکه، فیلتر می‌شوند. در این روش، مفهوم «بافر» در ساختار فرا-رویدادهای گسترش یافته، برای مدیریت Outlierها در نظر گرفته شده و داده‌های دورافتاده‌ای که با هیچ‌یک از فرا-رویدادهای موجود سازگاری ندارند، در بافری کلی به نام «پنجره» نگهداری می‌شوند.

در شبکه‌های پهن‌بند، تحلیل تطبیقی رفتار متغیر شبکه اهمیت بالایی دارد. در این راستا، [۱۰]. روش ACoPE به‌عنوان یک رویکرد

قبولی در طبقه‌بندی بلادرنگ دارد، بلکه در شرایط واقعی و پیچیده نیز قابل اطمینان است.

### مروری بر کارهای مرتبط

در سال‌های اخیر، استفاده از روش‌های یادگیری ماشین برای طبقه‌بندی ترافیک شبکه مورد توجه گسترده‌ای قرار گرفته است. با این حال، مسئله‌ی شناسایی کاربرد و توصیف دقیق ترافیک رمزنگاری شده هنوز به‌صورت کامل در ادبیات پژوهشی پوشش داده نشده است.

در پژوهش [۲]. کارایی ویژگی‌های زمانی مبتنی بر جریان را برای شناسایی ترافیک VPN و Tor بررسی کرده‌اند. آن‌ها با استفاده از سه الگوریتم J۴۸، جنگل تصادفی (Random Forest) و KNN، ویژگی‌های زمانی را بر روی مجموعه‌داده‌های عمومی ISCX-VPN و nonVPN و Tor-nonTor ارزیابی کردند. نتایج آن‌ها نشان داد که این ویژگی‌ها برای توصیف ترافیک رمزنگاری شده بسیار مؤثرند.

در پژوهش دیگری [۸]. از الگوریتم‌های یادگیری ماشین برای شناسایی برنامه‌هایی نظیر فیس‌بوک، توئیتر، اسکایپ و غیره استفاده کردند. آن‌ها چهار الگوریتم طبقه‌بندی مختلف (J۴۸، Random Forest، KNN و Bayes Net) را روی مجموعه‌ای متشکل از ۱۱۱ ویژگی، آزمایش کردند. نتایج نشان داد که الگوریتم KNN با  $k=1$  دقت ۹۳/۹۴٪ را برای مجموعه‌داده ISCX و Random Forest دقت ۹۰/۸۷٪ را برای مجموعه داده داخلی آن‌ها ارائه داده است. آن‌ها همچنین موفق به کاهش تعداد ویژگی‌ها به ۱۲ ویژگی مؤثر برای هر مجموعه داده بدون کاهش دقت شدند.

با ورود یادگیری عمیق به این حوزه، [۵] برای نخستین بار استفاده از روش‌های انتها به انتها (End-to-End) با استفاده از شبکه عصبی پیچشی یک‌بعدی (۱D-CNN) را برای طبقه‌بندی ترافیک رمزنگاری شده پیشنهاد دادند. این روش نیز با استفاده از مجموعه‌داده ISCX ارزیابی شده و نشان داد که دقت الگوریتم در شناسایی ترافیک VPN نسبت به ترافیک غیر-VPN بهتر است.

جریان بی‌پایان ترافیک ورودی، محیطی پویا با تغییرات غیرمنتظره ایجاد می‌کند که مستلزم به کارگیری روش‌های تحلیلی برای پاسخ‌گویی به چالش‌های پردازش در شبکه‌های پهن‌بند است، از جمله یادگیری افزایشی، پردازش برخط و مدیریت داده‌های دورافتاده (Outlier). [۴]. تعریفی رسمی از یک سیستم شناسایی رفتار برای شبکه‌های پهن‌بند ارائه دادند. با در نظر گرفتن محدودیت‌های موجود در سیستم‌های شناسایی رفتار، آن‌ها روشی را پیشنهاد کردند که در آن ساختاری داده‌ای به نام «فرا-رویداد»

TCP/UDP را دارد و ۸۳ ویژگی آماری را برای هر جریان تولید می‌کند.

## ۲. بازرسی عمیق درون خطی بسته‌ها (Inline Deep Packet Inspector)

این ماژول با تطبیق بسته‌های ورودی هر جریان، با الگوهای از پیش تعریف شده، اقدام به شناسایی برنامه یا سرویس مرتبط می‌نماید. خروجی حاصل از این فرایند، به صورت برجسب‌هایی از برنامه‌های شناسایی شده است که در مرحله آموزش مدل طبقه‌بندی به کار گرفته می‌شوند. در واقع، ماژول DPI نقش یک منبع قابل اعتماد برای تولید داده‌های برجسب‌خورده را ایفا می‌کند و با فراهم‌سازی داده‌های دقیق و معتبر، زمینه‌ساز بهبود عملکرد و دقت طبقه‌بندی یادگیری عمیق می‌شود.

## ۳. پردازش جریان‌ها (Stream Processor)

ماژول پردازش جریان، مسئول نگهداری صفی از جریان‌ها است که برخی از آن‌ها دارای برجسب DPI هستند. این ماژول شامل یک صف FIFO بدون حافظه است. هنگامی که صف پر می‌شود، سیگنال توقف برای ماژول استخراج ویژگی ارسال می‌شود و پس از خالی شدن صف، مجدداً فعال می‌گردد. در صورتی که نمونه‌های کافی برای آموزش و آزمون در دسترس نباشد، ماژول طبقه‌بندی نیز متوقف می‌شود و سپس با تأمین نمونه‌ها دوباره فعال می‌گردد.

## ۴. طبقه‌بندی مبتنی بر شبکه عصبی عمیق (DNN)

در این مؤلفه، یک شبکه عصبی عمیق (DNN) به عنوان هسته، طبقه‌بندی استفاده می‌شود. این شبکه با استفاده از زوج‌های (flow, label) که توسط DPI برجسب‌گذاری شده‌اند، آموزش داده می‌شود و تابع طبقه‌بندی CFT را به صورت تدریجی به روز می‌کند. معماری شبکه، شامل چندین لایه کاملاً متصل (fully connected) و تابع فعال‌سازی ReLU است که به کمک تکنیک‌هایی مانند دراپ‌آوت و نرمال‌سازی دسته‌ای، دقت و تعمیم‌پذیری مدل افزایش یافته است.

شبکه عصبی طراحی شده، توانایی کار در دو حالت جریانی (Stream Mode) و دسته‌ای (Batch Mode) را دارد. در حالت جریانی، مدل به صورت برخط با داده‌های جدید به روزرسانی می‌شود و در حالت دسته‌ای، آموزش به صورت نوبتی با استفاده از مجموعه‌های آموزشی انجام می‌شود. به کارگیری DNN باعث شده تا مدل، به صورت خودکار روابط پیچیده بین ویژگی‌ها و نوع ترافیک

نیمه‌نظارتی تطبیقی برای اجرای سیاست‌های پیچیده معرفی شده است. این روش با شناسایی روابط میان جریان‌های ترافیکی و به کارگیری کنترل آماری فرایند، تغییرات رفتاری را شناسایی و از اطلاعات ماژول DPI برای سازگاری با تغییرات استفاده می‌کند. ارزیابی ACoPE در سناریوهای مختلف، نظیر برنامه‌های پرتراфик، برنامه‌های تغییر یافته، و حملات توزیع شده منع سرویس، اثربخشی آن را در اجرای سیاست‌های پیچیده و تطبیق با تغییرات رفتاری نشان می‌دهد.

## روش پیشنهادی مبتنی بر طبقه‌بندی جریانی با DPI و DNN

در این پژوهش، رویکردی نوین ارائه شده است که با بهره‌گیری هم‌زمان از تکنیک‌های بازرسی عمیق بسته‌ها (DPI) و الگوریتم‌های یادگیری عمیق مبتنی بر شبکه عصبی (DNN)، به طبقه‌بندی جریانی ترافیک شبکه می‌پردازد. در این چارچوب، برجسب‌های استخراج شده توسط ماژول DPI به عنوان داده‌های حقیقت مینا (ground truth) مورد استفاده قرار می‌گیرند تا مدل طبقه‌بندی به صورت پیوسته آموزش دیده و به روزرسانی شود. این ترکیب، امکان شناسایی دقیق و تطبیقی برنامه‌ها را در مواجهه با ترافیک رمزنگاری شده و متغیر فراهم می‌سازد.

فرض کنیم در زمان  $t$ ، تابع طبقه‌بندی CFT برای نگاشت جریان‌ها به برجسب‌ها در اختیار باشد. رویکرد پیشنهادی برای هر جریان  $flow \in FlowSet$ ، یک برجسب  $label \in LabelSet$  تخصیص می‌دهد که رابطه آن به صورت  $(flow, label) \in CF_t$  تعریف می‌شود. به منظور به روزرسانی انطباقی تابع طبقه‌بندی، خروجی‌های ماژول DPI برای تولید  $CF_{t+1}$  استفاده می‌شوند:

$$CF_{t+1} = Update(CF_t, application) \quad (1)$$

چارچوب پیشنهادی از چهار ماژول اصلی تشکیل شده است:

## ۱. استخراج ویژگی‌ها (Feature Extractor)

در این مؤلفه، ترافیک شبکه پردازش شده و جریان‌ها (flows) ساخته می‌شوند. برای هر جریان، ویژگی‌هایی آماری مانند تعداد بسته‌ها، حجم داده، مدت زمان جریان و نرخ ارسال محاسبه می‌شود. ساختار هر جریان به صورت زیر در نظر گرفته می‌شود:

$$f = \langle source-IP, source-port, destination-IP, destination-port, TCP/UDP protocol, fe_1, \dots, fe_m \rangle \quad (2)$$

برای استخراج جریان‌ها از ترافیک، ابزار CICFlowMeter مورد استفاده قرار گرفته است که توانایی شناسایی جریان‌های

استفاده در محیط‌های عملیاتی مختلف است و با تغییرات الگوی ترافیک، عملکرد خود را حفظ می‌کند.

### نتایج ارزیابی

در این مطالعه، نتایج الگوریتم DNN با پنج الگوریتم مختلف طبقه‌بندی مورد ارزیابی قرار گرفته‌اند که عبارتند از: Naive Bayes (NB)، Hoeffding Adaptive Random Tree (HAT)، Hoeffding Tree (HT) و Adaptive Random Forest (ARF). برای ارزیابی این الگوریتم‌ها، از روش «آزمون دوره‌ای نگه‌داشته شده» استفاده شده است که طی آن داده‌ها به صورت پیوسته وارد سیستم شده و در فواصل زمانی معین با مدل ارزیابی می‌شوند.

داده‌های استفاده شده برای آموزش و ارزیابی، از دو دیتاست عمومی و شناخته شده در حوزه تحلیل ترافیک شبکه استخراج شده‌اند: دیتاست UNB ISCX VPN-nonVPN و دیتاست UNB ISCX Tor-nonTor. این دیتاست‌ها شامل ترافیک شبکه مربوط به کاربردهای مختلف از جمله مرور، انتقال فایل، چت، ایمیل، P2P، استریمینگ و تماس صوتی هستند. برای مثال در دیتاست VPN-nonVPN، برنامه‌هایی مانند Skype، Facebook، Hangouts، AIM و BitTorrent در دسته‌های مختلف حضور دارند. دسته‌بندی برنامه‌ها در این دو مجموعه داده در جدول ۱ نشان داده شده است.

برای سنجش کیفیت طبقه‌بندی، از سه معیار رایج ارزیابی استفاده شده است: دقت (Accuracy)، صحت (Precision) و فراخوانی (Recall). معیار دقت میزان کلی صحت عملکرد الگوریتم را نشان می‌دهد و از نسبت مجموع نمونه‌های درست‌شناخته شده به کل نمونه‌ها محاسبه می‌شود. دقت عملیاتی نشان‌دهنده نسبت نمونه‌های صحیح شناسایی شده به کل نمونه‌های شناسایی شده در یک کلاس خاص است، در حالی که فراخوانی، توانایی الگوریتم در شناسایی تمام نمونه‌های واقعی یک کلاس را نشان می‌دهد.

جدول ۱: دسته‌بندی داده‌های در مجموعه داده ISCX VPN-nonVPN

کاربرد	دسته‌بندی
HTTPS	Browsing
Skype, SFTP, FTPS, SCP	File Transfer
Facebook, Hangouts, Skype, AIM, IC	Chat
SMTP, POP3, IMAP	Email
Bittorrent	P2P
YouTube, Vimeo	Streaming
Hangout, Skype voice call, Voip bust	VoIP

را یاد بگیرد و در طبقه‌بندی ترافیک‌های رمزنگاری شده عملکرد بالایی داشته باشد.

در این پژوهش، شبکه عصبی عمیق (DNN) به عنوان طبقه‌بند اصلی در ماژول طبقه‌بندی جریان‌ها مورد استفاده قرار گرفته است. دلیل اصلی انتخاب این مدل، توانایی آن در یادگیری روابط غیرخطی و پیچیده میان ویژگی‌های آماری جریان‌های شبکه و برچسب‌های مربوط به برنامه‌های کاربردی است؛ قابلیت‌هایی که به‌ویژه در مواجهه با ترافیک‌های رمزنگاری شده یا داده‌هایی با ابعاد بالا اهمیت پیدا می‌کند.

ورودی به مدل DNN برداری از ویژگی‌های آماری استخراج شده از جریان‌های شبکه است. این ویژگی‌ها توسط ابزار CICFlowMeter از ترافیک شبکه به دست می‌آیند و شامل اطلاعاتی نظیر مدت زمان جریان، تعداد بسته‌ها، حجم کل داده‌های ارسال و دریافت شده، میانگین طول بسته‌ها و نرخ ارسال داده هستند. برای افزایش کارایی مدل، تنها زیرمجموعه‌ای از این ویژگی‌ها که بیشترین تأثیر را در طبقه‌بندی دارند، انتخاب می‌شوند.

معماری شبکه عصبی مورد استفاده شامل چندین لایه کاملاً متصل (fully connected) است. لایه ورودی مطابق با تعداد ویژگی‌ها تعریف شده و در لایه‌های میانی، از توابع فعال‌سازی ReLU و لایه‌های Dropout برای جلوگیری از بیش‌برازش استفاده شده است. همچنین، در انتهای شبکه لایه‌ای با تابع Softmax برای خروجی چندکلاسه وجود دارد که برچسب احتمالی هر جریان را تعیین می‌کند. نرمال‌سازی ویژگی‌ها و استفاده از Batch Normalization در لایه‌های داخلی، موجب تسریع هم‌گرایی و افزایش پایداری آموزش می‌شود.

فرایند آموزش مدل با داده‌های دارای برچسب که از ماژول بازرسی عمیق بسته‌ها (DPI) به دست می‌آیند، به صورت دوره‌ای و پیوسته انجام می‌شود. این آموزش بر اساس تابع هزینه Cross-Entropy و با استفاده از الگوریتم Adam صورت می‌گیرد. در معماری پیشنهادی، مدل DNN قابلیت به‌روزرسانی تدریجی نیز دارد، به گونه‌ای که می‌تواند در طول زمان، خود را با الگوهای جدید ترافیکی وفق دهد.

استفاده از DNN در طبقه‌بندی جریان‌های شبکه، دقت طبقه‌بندی را به طور قابل توجهی افزایش می‌دهد و توانایی شناسایی برنامه‌ها در سناریوهای پیچیده و در حضور رمزنگاری را فراهم می‌سازد. همچنین، این مدل به دلیل ساختار تعمیم‌پذیر خود، به راحتی قابل

جدول زیر نتایج الگوریتم های مختلف را نشان می دهد.

یادآوری	صحت		دقت		بندی	
	عده داده	عده داده	عده داده	عده داده	عده داده	عده داده
	VP	Tc	VP	Tc	VP	Tc
NB	۴۱	۴۲	۳۷	۶۲	۸۶	۸۶
RHT	۴۳	۷۰	۵۱	۸۳	۹۴	۹۴
HAT	۳۶	۶۱	۴۴	۶۷	۹۱	۹۱
HT	۳۹	۷۶	۳۸	۸۴	۸۷	۸۷
ARI	۵۶	۷۳	۷۳	۸۲	۹۷	۹۷
DNN	۷۷	۶۸	۸۱	۹۴	۹۶	۹۶

در ارزیابی عملکرد الگوریتم های طبقه بندی جریان های ترافیکی رمزنگاری شده، نتایج نشان می دهد که شبکه عصبی عمیق (DNN) عملکرد بهتری نسبت به سایر الگوریتم ها داشته است. بر روی مجموعه داده VPN-nonVPN، این مدل توانسته با ثبت دقت ۹۶ درصد، صحت ۸۱ درصد و یادآوری ۷۷ درصد، بهترین نتایج را به دست آورد. این نشان می دهد که DNN توانایی بالایی در شناسایی دقیق و درست برنامه ها حتی در شرایطی که داده ها پیچیده یا به صورت بلادرنگ هستند، دارد.

در مجموعه داده Tor-nonTor نیز DNN همچنان عملکرد قابل قبولی دارد و با دقت ۹۴ درصد، صحت ۶۸ درصد و یادآوری ۸۵ درصد، از سایر روش ها پیشی گرفته است. تفاوت در مقدار صحت بین دو مجموعه داده (VPN) و (Tor) را می توان به پیچیدگی بیشتر ترافیک در شبکه ی Tor نسبت داد که باعث کاهش نسبی صحت شده است. با این وجود، مقدار بالای یادآوری در این مجموعه داده بیانگر توانایی بالای DNN در شناسایی نمونه های مثبت واقعی است، حتی اگر درصدی از نمونه ها به اشتباه نیز طبقه بندی شده باشند.

در مقایسه با روش های کلاسیک مانند Naive Bayes (NB) و Hoeffding Tree (HT)، عملکرد DNN به مراتب پایدارتر و دقیق تر است. برای مثال، در مجموعه VPN، NB تنها به دقت ۸۶ درصد رسیده و صحت آن ۳۷ درصد گزارش شده است، که نشان دهنده ضعف آن در دسته بندی صحیح جریان ها در حضور داده های پیچیده است. همچنین الگوریتم هایی مانند Adaptive Random Forest (ARF) نیز عملکرد مناسبی داشته اند و در برخی معیارها مانند دقت در مجموعه VPN (۹۷ درصد) به نتایج خوبی دست یافته اند، ولی همچنان در ترکیب کلی معیارها نسبت به DNN پایین تر هستند.

به طور کلی، تحلیل نتایج نشان می دهد که استفاده از شبکه عصبی عمیق به عنوان طبقه بند یادگیرنده، در کنار به روزرسانی انطباقی مدل با بهره گیری از داده های مرجع حاصل از بازرسی عمیق

بسته ها (DPI)، رویکردی مؤثر برای طبقه بندی دقیق جریان های رمزنگاری شده در شبکه های مدرن به شمار می رود.

### نتیجه گیری و پیشنهادات

در سامانه های تحلیل ترافیک شبکه به صورت بلادرنگ، شناسایی دقیق و درون خطی (inline) برنامه های کاربردی شبکه از اهمیت بالایی برخوردار است. با توجه به این که شبکه های با پهنای باند بالا محیط هایی پویا و با جریان بی پایانی از ترافیک ایجاد می کنند، در این مقاله یک رویکرد نوین برای طبقه بندی جریان ترافیک شبکه ارائه شده که از تکنیک بازرسی عمیق بسته ها (DPI) برای تشخیص اولیه برنامه های کاربردی بهره می برد و به طور تطبیقی مدل طبقه بندی را به روزرسانی می کند. این سامانه از چهار ماژول اصلی شامل استخراج کننده ویژگی (Feature Extractor)، بازرسی درون خط بسته ها (Inline Deep Packet Inspector)، پردازشگر جریان (Stream Processor) و طبقه بند جریان (Stream Classifier) تشکیل شده است.

در کنار روش های طبقه بندی کلاسیک، تمرکز ویژه ای بر به کارگیری شبکه های عصبی عمیق (DNN) به عنوان طبقه بند اصلی جریان ها انجام شده است. شبکه های DNN به دلیل توانایی بالا در استخراج ویژگی های غیر خطی و پیچیده از داده ها، قادرند الگوهای پنهان در جریان های رمزنگاری شده یا غیر استاندارد را نیز با دقت بالا شناسایی کنند. در این معماری، ویژگی های استخراج شده از جریان های شبکه به صورت برداری به مدل DNN منتقل می شوند و طبقه بندی به صورت بلادرنگ صورت می گیرد. مدل DNN می تواند با ساختارهایی مانند Fully Connected Networks یا ترکیب آن با AutoEncoderها یا CNNهای یک بعدی توسعه داده شود تا هم دقت طبقه بندی و هم انعطاف پذیری مدل در مواجهه با تغییرات ترافیکی حفظ شود.

پایه سازی این سامانه با استفاده از ابزار MOA صورت گرفته و ارزیابی آن بر روی دو مجموعه داده عمومی-UNB ISCX VPN و nonVPN و UNB ISCX Tor-nonTor انجام شده است. در ارزیابی صورت گرفته، استفاده از DNN در برخی آزمایش ها نشان داد که در دسته بندی جریان های پیچیده تر یا در مواقعی که داده های برچسب خورده به صورت لحظه ای کم هستند، عملکرد بهتری نسبت به طبقه بندهای سنتی دارد.

در ادامه این پژوهش، هدف ما کاهش سربار پردازش DPI با کاهش نسبت ترافیکی است که باید توسط این ماژول بررسی شود. بدین منظور، سامانه می تواند نرخ خطای طبقه بندی را بررسی کرده

enforcement in high-bandwidth networks," *Computer Networks*, vol. ۱۶۶, ۱۰۶۹۴۳, ۲۰۲۰.

و تنها در صورت نیاز، ترافیک را به ماژول DPI ارسال نماید. همچنین، لازم است این سامانه در یک محیط واقعی با پهنای باند بالا به صورت آزمایشی پیاده سازی شده و عملکرد آن در شناسایی درون خط و تطبیقی برنامه‌های کاربردی به صورت عملی ارزیابی شود. بهره‌گیری بیشتر از معماری‌های DNN در سطح عملیاتی نیز می‌تواند باعث بهبود چشم‌گیر عملکرد سیستم شود.

## منابع

[۱]. R. Manivannan, S. Senthilkumar, "Intrusion detection system for network security using novel adaptive recurrent neural network-based fox optimizer concept," *International Journal of Computational Intelligence Systems*, vol. ۱۸, No. ۱, p. ۳۷, ۲۰۲۰.

[۲]. G. Draper-Gil, A. H. Lashkari, M. S. I. Mamun, A. A. Ghorbani, "Characterization of encrypted and VPN traffic using time-related features," *Proceedings of the ۲nd International Conference on Information Systems Security and Privacy (ICISSP)*, pp. ۴۰۷-۴۱۴, ۲۰۱۶.

[۳]. M. Noferesti, R. Jalili, "Inline high-bandwidth network analysis using a robust stream clustering algorithm," *IET Information Security*, vol. ۱۳, No. ۵, pp. ۴۸۶-۴۹۵, ۲۰۱۹.

[۴]. M. Noferesti, R. Jalili, "HB<sup>۲</sup>DS: A behavior-driven high-bandwidth network mining system," *Journal of Systems and Software*, vol. ۱۲۷, pp. ۲۶۶-۲۷۷, ۲۰۱۷. <https://doi.org/10.1016/j.jss.2016.09.004>

[۵]. W. Wang, M. Zhu, J. Wang, X. Zeng, Z. Yang, "End-to-end encrypted traffic classification with one-dimensional convolution neural networks," ۲۰۱۷ *IEEE International Conference on Intelligence and Security Informatics (ISI)*, pp. ۴۳-۴۸, ۲۰۱۷. <https://doi.org/10.1109/ISI.2017.8004862>

[۶]. V. Tong, C. Dao, H. A. Tran, D. Tran, H. T. T. Binh, N. T. Hoang, T. X. Tran, "Encrypted Traffic Classification Through Deep Domain Adaptation Network With Smooth Characteristic Function," *IEEE Transactions on Network and Service Management*, ۲۰۲۰.

[۷]. Z. Nazari, M. Noferesti, R. Jalili, "DSCA: An inline and adaptive application identification approach in encrypted network traffic," In *Proceedings of the ۳rd international conference on cryptography, security and privacy*, pp. ۳۹-۴۳, ۲۰۱۹.

[۸]. B. Yamansavascilar, M. A. Guvensan, A. G. Yavuz, M. E. Karsligil, "Application identification via network traffic classification." ۲۰۱۷ *International Conference on Computing, Networking and Communications (ICNC)*, pp. ۸۴۳-۸۴۸, ۲۰۱۷. <https://doi.org/10.1109/ICNC.2017.7876241>

[۹]. S. Mali, M. Gujral, A. K. Cherukuri, M. G. Ms, "Encrypted Network Traffic Classification Using Intelligent Techniques," *Cureus*, vol. ۲, No. ۱, ۲۰۲۰.

[۱۰]. M. Noferesti, R. Jalili, "ACoPE: An adaptive semi-supervised learning approach for complex-policy

# An Online and Adaptive Approach for Identifying Applications in Encrypted Network Traffic Using a Deep Neural Network Learning Model

Mohammad Amin Rastegar\*, Masoud Noferesti

۱- Faculty of Engineering-Department of Computer Engineering-Sciences and Research Branch- Islamic Azad University- Tehran- Iran..

۲- Faculty of Engineering-Department of Computer Engineering-Sciences and Research Branch- Islamic Azad University- Tehran- Iran

## Abstract

With the growing use of encryption in network traffic, especially through protocols like TLS and SSL, the effectiveness of traditional application identification methods based on packet content analysis has significantly declined. In modern high-bandwidth networks, real-time and accurate application identification faces challenges not only in terms of speed, volume, and traffic diversity but also due to high resource costs. This study presents an adaptive approach for traffic stream classification that dynamically and continuously updates the classification model by leveraging Deep Packet Inspection (DPI) as a reference source. At the core of the proposed classifier, a Deep Neural Network (DNN) learning algorithm is employed, capable of accurately identifying complex and hidden patterns in encrypted traffic. The proposed method is empirically evaluated on two public datasets, ISCX VPN-nonVPN and ISCX Tor-nonTor, and the results indicate that DNN performs better in certain scenarios—particularly in classifying more complex flows or when real-time labeled data is scarce—compared to traditional classifiers.

**Keywords:** Application Identification, Network Traffic Classification, Stream Classification, Deep Neural Network