

مقایسه فن های طبقه بندی مورد استفاده برای تشخیص و طبقه بندی نفوذ

شبکه

چکیده

در تحقیق قبلی، یک سیستم ایمنی مصنوعی چندگانه برای شناسایی و طبقه بندی نفوذ شبکه پیشنهاد و آزمایش شد که در آن یک فرایند تشخیص و طبقه بندی چندلایه روی هر عامل برای هر میزبان در شبکه اجرا شد. در این مقاله، ما آزمایش هایی را انجام می دهیم که با طبقه بندی های مختلف طبقه بندی های مناسب را انتخاب کرده و آن ها را مقایسه می کنیم تا دقت تشخیص را افزایش دهیم و اطلاعات بیشتری در مورد ناهنجاری های تشخیصی به دست آوریم. نشان داده خواهد شد که به دلیل نرخ های مختلف طبقه بندی به دست آمده، هیچ طبقه بندی نمی بایست برای تمام انواع حملات استفاده شود. این به خاطر نمایش حملات در مجموعه سلسله و وابستگی بین ویژگی های مورد استفاده برای شناسایی آن ها است. همچنین نشان داده خواهد شد که یک طبقه بندی کننده ساده و اساسی مانند Naive Bayes دارای نتایج طبقه بندی بهتر در مورد حملات کم نشان داده شده است و درخت تصمیم گیری اولیه مانند درخت Naive-Bayes Tree و Best-First نتایج بسیار خوبی نسبت به J48 معروف (اجرای وکا C4.5) و درخت تصمیم گیری Random Forest ارائه می دهد. بر اساس این آزمایش ها و نتایج آن ها، طبقه بندی کننده های Naive Bayes و Best-First برای طبقه بندی ترافیک ناشناخته انتخاب شدند. نشان داده شده است که در مرحله تشخیص 90٪ ناهنجاری ها شناسایی شده و در مرحله طبقه بندی 88٪ از مثبت های کاذب با موفقیت به عنوان اتصالات ترافیکی عادی برچسب گذاری شده و 79٪ از حملات DoS و Probe به درستی توسط NB، NBTree و طبقه بندی کننده BFTree برچسب گذاری شده اند.

کلید واژه ها: تشخیص نفوذ، سیستم های ایمنی مصنوعی، طبقه بندی نفوذ، فراگیری ماشین

1. معرفی

امروزه دستگاه‌های کامپیوتری معمولاً به هم متصل هستند که به دستگاه‌های توزیع‌شده بزرگ وصل هستند که در دنیای محاسبات صنعتی ضروری هستند. دستگاه‌های نرم‌افزاری امروز نیازمند روندهایی مانند اتصالات، هوش و فراگیری هستند که همگی منجر به ایجاد دستگاه‌های چند عامل شد. دستگاه‌های چندگانه رفتار هوشمندانه انسان و نحوه ارتباط انسان‌ها با یکدیگر و با محیط آن‌ها برای دستیابی به اهداف خاص را تقلید می‌کند. یکی از دستگاه‌هایی که می‌تواند به صورت موفقیت‌آمیز و کارآمد به عنوان یک سیستم عامل چندگانه اجرا شود، دستگاه‌های ایمنی مصنوعی (AIS) است. سیستم ایمنی مصنوعی یک منطقه پژوهشی است که شامل ایمنی‌شناسی، علوم رایانه و مهندسی است. با الهام از دستگاه‌های ایمنی طبیعی، سه زمینه اصلی تحقیق تحت AIS قرار می‌گیرند: مدل‌سازی ایمنی، AIS های نظری و AIS های کاربردی. مدل‌سازی ایمنی در مورد مدل‌های ایمنی و شبیه‌سازی سیستم ایمنی است. پژوهش AIS های نظری در مورد توضیح و نفوذ به جنبه‌های نظری الگوریتم‌های AIS، مدل‌های ریاضی و عملکرد و تجزیه و تحلیل پیچیدگی آن‌ها است. در نهایت، تحقیق AIS های کاربردی در مورد توسعه و اجرای الگوریتم‌ها و دستگاه‌های کامپیوتری الهام گرفته از دستگاه‌های ایمنی است که از آن‌ها برای انواع برنامه‌های کاربردی دنیای واقعی استفاده می‌شود.

با توجه به دستگاه‌های کامپیوتری می‌توانیم بفهمیم که مفهوم خود/ غیر خود در قالب فعالیت‌ها و عناصری معمولی/ غیرعادی اعمال می‌شود. دستگاه‌های تشخیص نفوذ (IDS) دستگاه‌های امنیتی قدرتمندی هستند که انواع مختلفی برای اهداف حفاظتی دارند. آن‌ها ابزار امنیتی خاصی را جایگزین نمی‌کنند، بلکه به جای آن، یک خط دفاعی در برابر نفوذها و تهدیدات از داخل سیستم (یک کامپیوتر یا یک شبکه) و همچنین از خارج- درست مانند سیستم ایمنی اضافه می‌کنند. IDS ها می‌توانند به روش‌های مختلف دسته‌بندی شوند، اما اساساً می‌توان آن‌ها را به IDS هایی مبتنی بر سوءاستفاده و ناهنجار تقسیم کرد. IDS های سوءاستفاده که همچنین به عنوان مبتنی بر امضا یا دانش شناخته می‌شوند، بستگی به تشخیص نفوذ با استفاده از الگوهای نشان‌دهنده حملات شناخته‌شده دارد. این الگوها یا امضاها با رویدادها برای یافتن نفوذهای ممکن مقایسه می‌شوند. IDS های غیرمتعارف که همچنین به عنوان IDS های مبتنی بر رفتار شناخته می‌شود، به ساخت یک نمایه بستگی دارد که رفتار طبیعی یک سیستم

را با نظارت بر فعالیت‌های آن در طول زمان نشان می‌دهد. سپس هر انحراف از آن نمایه، یک ناهنجاری است. نمایه‌ها می‌توانند ایستا یا پویا باشند و با استفاده از بسیاری از ویژگی‌های سیستم توسعه می‌یابند.

با تنوع و پیچیدگی فن‌های حمله، بسیاری از مسائل در رابطه با IDS ها رایج هستند که باید در هنگام ساخت IDS مورد توجه قرار گیرند [17]. شایع‌ترین مسئله، استخراج مجموعه‌ای از قوانین تخصصی است که در اغلب موارد از طریق یک متخصص انسانی به‌خصوص با استفاده از IDS سوءاستفاده به‌روز می‌شود. با تشخیص ناهنجاری، چنین مسئله‌ای با استفاده از نمایش مناسب و تعریف حملات حل می‌شود، بنابراین انواع مختلف حملات می‌تواند با استفاده از مجموعه‌ای محدود از قوانین با تغییرات این قوانین شناسایی شود. یکی دیگر از مسائل، مربوط به آموزش مدل‌های رفتاری است که معمولاً اطلاعات عادی یا دو مجموعه داده‌های عادی و غیرعادی برای آموزش استفاده می‌شود. فن‌های یادگیری ماشینی بیشتر برای آموزش و یادگیری استفاده می‌شود.

در تلاش برای غلبه بر مسائل ذکر شده در بالا، ما یک الگوریتم طبقه‌بندی دولایه با چندعاملی را پیشنهاد کردیم که ناهنجاری‌ها را در یک شبکه تشخیص می‌دهد و طبقه‌بندی می‌کند. IDS سیستم پیشنهادی ترکیبی از الگوریتم ژنتیک با روش انتخاب منفی به‌عنوان اولین لایه شناسایی ناهنجاری‌ها است. سپس طبقه‌بندی کننده‌های انتخاب شده برای ترسیم ناهنجاری‌های شناسایی شده در هر دو ترافیک نرمال و غیرطبیعی آموزش داده می‌شود و به‌کاربرده می‌شود. سیستم ایمنی یک سیستم توزیعی از سلول‌های تخصصی متفاوتی است که دارای تعامل بالا بین اجزای آن برای یک پاسخ هماهنگ است. با توجه به این، بسیاری از رویکردها، اجرای یک AIS را به‌عنوان یک سیستم عامل چندگانه پذیرفته‌اند.

در تحقیقات قبلی که به‌نوعی به سیستم پیشنهاد شده شبیه هستند، هر نوع طبقه‌بندی کننده خاص برای هر نوع حمله مورد استفاده قرار می‌گیرد، یا طبقه‌بندی کننده‌ها- که با استفاده از داده‌های برچسب‌گذاری شده آموزش داده شده‌اند- به‌طور مستقیم به مجموعه داده‌ها برای تشخیص نفوذ و برچسب‌گذاری حملات بدون برچسب اعمال می‌شود. سهم این مقاله این است که برخی تجزیه و تحلیل تطبیقی را برای پاسخ به سؤالات در مورد چگونگی عملکرد سیستم در پارامترهای مختلف انجام دهد و این که چه فن‌هایی برای بهترین نتایج و دلیل استفاده می‌شود. همچنین بررسی خواهد کرد که آیا تغذیه ترافیک عادی به طبقه‌بندی کننده‌ها اهمیت دارد یا خیر.

در یک گزارش از قبل منتشر شده [8] یک سیستم ایمنی مصنوعی چندگانه برای تشخیص و طبقه‌بندی نفوذ شبکه اعمال شد. الگوریتمی که به‌عنوان یک فن سیستم ایمنی مصنوعی اعمال شده است، روش انتخاب منفی است که از الگوریتم ژنتیک استفاده می‌کند. به‌عنوان یک سیستم هوشمند، داده‌کاوی در طول فرایند برای بهترین نتایج استفاده می‌شود. دو طبقه‌بندی کننده برای طبقه‌بندی‌های ناهنجاری، طبقه‌بندی کننده‌های Bayes Naive و Best-First استفاده شد. طبقه‌بندی کننده Bayes Naive برای حملاتی استفاده شد که ارائه کمی در مجموعه داده‌های آموزشی دارند، زیرا آن‌ها ثابت کرده‌اند که نتایج بهتری نسبت به سایر طبقه‌بندی کننده‌ها در آزمایش قبلی داشته‌اند. طبقه‌بندی کننده BFTree برای طبقه‌بندی حملات باقی‌مانده مورد استفاده قرار گرفت، زیرا آن‌ها نتایج بهتری را نسبت به سایر طبقه‌بندی کننده‌های پیچیده‌تر در آزمایش‌ها این مقاله نشان دادند. مقاله به‌صورت زیر مرتب شده است. بخش 2 زمینه‌ای راجع به اصول فن‌های طبقه‌بندی ارائه می‌دهد. در بخش 3 رویکرد پیشنهادی و مدل سیستم با اجزا و مرحله‌های مختلف آن توضیح داده شده است. بخش 4 شامل جزئیات آزمایش و تنظیمات است. نتایج در بخش 5 ارائه شده و مورد بحث قرار می‌گیرد. در نهایت، نتیجه‌گیری با کار بیشتر در بخش 6 ارائه می‌شود.

2. فن‌های طبقه‌بندی داده‌ها

طبقه‌بندی فرآیند اختصاص یک برچسب طبقه به شیء (اشیاء) طبقه‌بندی نشده بر اساس مجموعه‌ای از ویژگی‌های تعریف شده است. یک طبقه‌بندی کننده ابتدا باید آن دانش را با یادگیری ارائه دسته‌ها با استفاده از یک مجموعه داده شده از نمونه‌های طبقه‌بندی شده پیشین دریافت کند. یک طبقه‌بندی کننده می‌تواند به‌عنوان یک پیش‌بینی کننده برای اشیاء طبقه‌بندی نشده یا یک توصیفگر برای اشیاء طبقه‌بندی شده عمل کند. رویکردهای بسیاری مانند درختان تصمیم‌گیری، رویکردهای مبتنی بر قانون، طبقه‌بندی‌های بی‌زیر، شبکه‌های عصبی، طبقه‌بندی کننده‌های ژنتیک، ماشین‌های بردار پشتیبانی و بسیاری دیگر وجود دارد. یک طبقه‌بندی کننده با دقت پیش‌بینی آن، سرعت، استحکام، مقیاس‌پذیری، تفسیرپذیری، سادگی و شاخص‌های کیفیت وابسته به دامنه ارزیابی می‌شود.

2.1. طبقه‌بندی کننده Bayes Naïve

این مطلب تئوری Bayes را با فرضیه‌های استقلال قوی به‌عنوان یک طبقه‌بندی کننده ساده احتمالی اعمال می‌کند. فرض بر این است که وجود یا فقدان یک ویژگی مستقل از وجود یا فقدان ویژگی‌های دیگر است - ویژگی‌ها نامرتب هستند که اجرای آن‌ها ساده، بهینه و درست است. اگر برخی اطلاعات و داده‌های آموزشی داشته باشیم، می‌توان از طبقه‌بندی کننده NB استفاده کرد و ما باید احتمالات را از داده‌های محدود برآورد کنیم. مزیت اصلی آن این است که زمان زیادی برای آموزش نیاز ندارد.

2.2. درختان تصمیم‌گیری

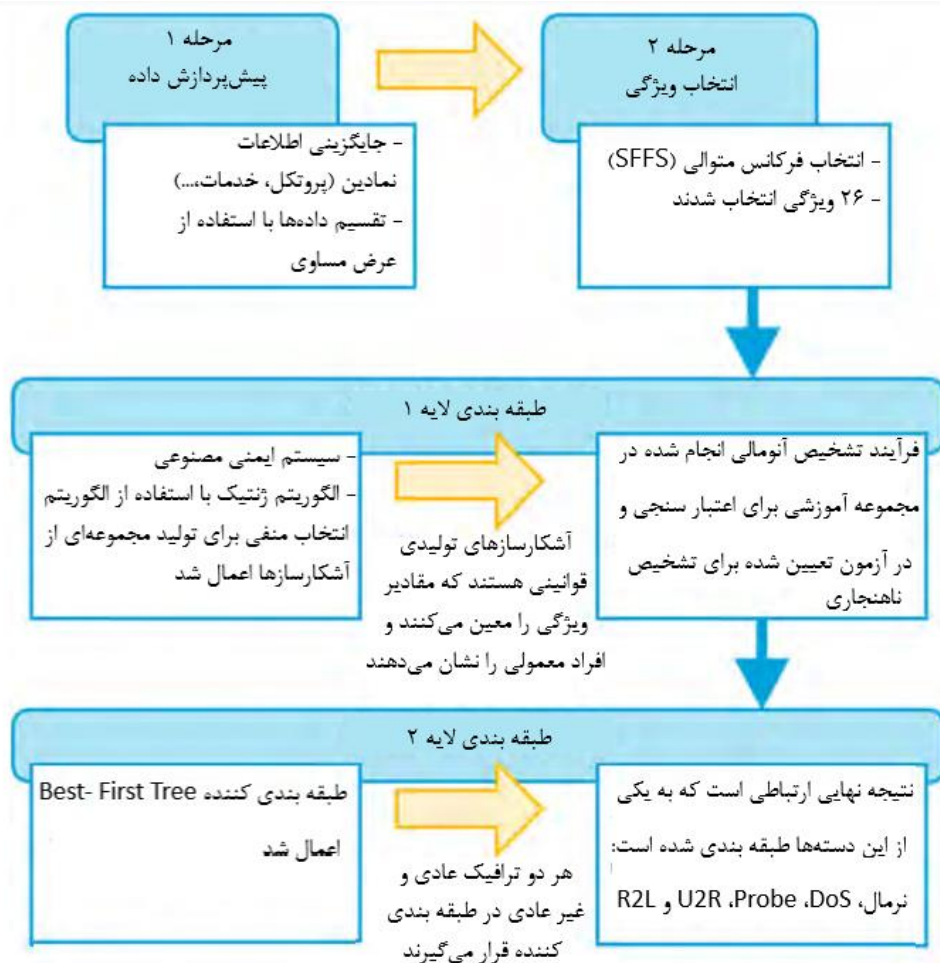
درختان تصمیم‌گیری نمایش ساختاری یک مجموعه داده را تشکیل می‌دهند. یک گره یک تصمیم را از تعدادی از گزینه‌ها می‌سازد و هر گره نهایی یک طبقه‌بندی خاص را نشان می‌دهد. DT ها (درختان تصمیم‌گیری) ابزارهایی بسیار قدرتمند هستند زیرا آن‌ها سریع هستند و عملکرد معقولی دارند. DT های مورد استفاده در این تحقیق BFTree، NBTree، J48 و RFT هستند. BFTree (Best-First Tree) گره‌های خود را در بهترین حالت اول، برخلاف DT های استاندارد گسترش می‌دهد که در حالت عمق اول گسترش می‌یابد. بهترین گرهی که همیشه برای اولین بار گسترش یافته است، گرهی است که منجر به حداکثر کاهش ناخالصی می‌شود. (Naive Bayes NBTree) از یک تابع نقشه‌برداری برای فهرست داده‌های با ابعاد بزرگ استفاده می‌کند و باید یک تابع محاسباتی سبک و کم باشد؛ بنابراین، این مقادیر می‌تواند مرتب‌شده و بعداً در ساختار یک‌بعدی نهایی استفاده شود. J48 (نشان‌دهنده وکا C4.5 DT) گره‌های خود را در حالت عمق اول گسترش می‌دهد. این یک الگوریتم یادگیری تحت نظارت است که نقشه‌برداری را از مقادیر ویژگی به طبقات می‌آموزد و سپس این نقشه‌برداری به نمونه‌های ناشناخته جدید اعمال می‌شود. RFT (Forests Forest Random) شامل ایجاد مجموعه‌ای از درختان طبقه‌بندی است که بر اساس مجموعه‌های تصادفی داده‌ها محاسبه می‌شوند. این کار با استفاده از پیش‌بینی کننده‌های انتخاب‌شده به‌صورت تصادفی برای هر تقسیم در هر درخت انجام می‌شود.

2.3. فرایندهای چندلایه

اگر نمونه‌های ارائه‌شده را نتوان به‌صورت خطی جدا کرد، فرایندهای چندلایه (MLP) مورد استفاده قرار می‌گیرند. MLP ها شبکه‌های عصبی ارسالی هستند که شامل تعداد زیادی از عصب‌های متصل شده هستند که به واحدهای ورودی، واحدهای خروجی و واحدهای مخفی در بین آنها تقسیم می‌شوند. وزن‌های اختصاص داده‌شده برای ارتباطات با استفاده از الگوریتم بازگشت عقب (BP) برآورد می‌شود. مقادیر وزن، عملکرد شبکه عصبی را تعریف می‌کنند.

3. سیستم تشخیص و طبقه‌بندی دولایه

سیستم چندلایه‌ای که قبلاً پیشنهاد شده بود از دولایه تشکیل شده است که پیش از یک مرحله پیش‌پردازش می‌آیند. لایه اول - لایه تشخیص - روش انتخاب منفی را با استفاده از الگوریتم ژنتیک برای تشخیص نفوذ انحراف استفاده می‌کند، جایی که ردیاب‌ها برای شناسایی فعالیت‌های طبیعی آموزش می‌بینند تا هرگونه تفاوت (بیش از یک آستانه مشخص) را به‌عنوان یک ناهنجاری تشخیص دهند. لایه دوم - لایه طبقه‌بندی - از یک طبقه‌بندی کننده برای برچسب‌گذاری ترافیک با طبقه مناسب برای دسته‌های حمله و به حداقل رساندن هشدارهای نادرست استفاده می‌کند. هم ترافیک عادی و هم غیرعادی به طبقه‌بندی کننده داده می‌شود. روند در شکل 1 نشان داده شده است.



شکل 1. مدل تشخیص و طبقه‌بندی ناهنجاری‌های دولایه.

3.1. مرحله پیش‌پردازش داده

پیش‌پردازش داده‌ها شامل جایگزینی داده‌های نمادین مانند پروتکل و خدمات با مقادیر مجزا/کامل و تقسیم‌بندی مقادیر به همگن و در حوزه‌ای محدود است. الگوریتم Binning Width برابر استفاده شد و مقادیر اصلی با اعداد باین مربوط به دامنه آن‌ها جایگزین شدند. اطلاعات بیشتر در مقاله قبلی موجود است.

3.2. مرحله انتخاب ویژگی

همان‌طور که در مقاله قبلی ما [4] بیان شده است، روش انتخابی فرکانس متوالی (SFFS) استفاده و 26 ویژگی انتخاب شد که مربوط به برای یافتن الگوریتم انتخاب ویژگی با بهترین نتایج بود. ویژگی‌های انتخاب‌شده توسط SFFS بهترین نتایج دقیق را به دست آورد.

3.3. لایه 1: تولید ردیاب‌ها و تشخیص ناهنجاری

این لایه GADG (الگوریتم ژنتیک برای تولید ردیاب‌ها) است - همچنین در [4] - برای تولید ردیاب‌ها برای فرآیند تشخیص نفوذ انحرافی استفاده شده است. در این فرآیند، آشکارسازهای ناهنجاری با استفاده از GA و کاربرد مفهوم NSA تولید می‌شوند - تولید آشکارسازهایی که با نمایش اتصالات عادی آشنا هستند، قادر به تشخیص بین عادی و غیرطبیعی هستند. ردیاب‌های یا قوانین تولیدشده اساساً مقادیر ویژگی‌های انتخاب شده هستند که به‌طور صحیح اتصالات طبیعی را نشان می‌دهند؛ بنابراین، ابتدا جمعیت مورداستفاده برای تولید این آشکارسازها با انتخاب تصادفی از اتصالات معمول در مجموعه داده پر شده است. دو اندازه‌گیری مسافت به‌طور جداگانه اعمال شده است - هندسه اقلیدسی و مین کاوسکی - و گروه آشکارساز تولیدشده توسط هر اندازه‌گیری مسافت آزمایش و مقایسه می‌شود.

جدول 1 توزیع پرونده‌های NSL-KDD.

	Total records	Normal	DoS	Probe	U2R	R2L
Train_20%	25192	13449 53.39%	9234 36.65%	2289 9.09%	11 0.04%	209 0.83%
Train_All	125973	67343 53.46%	45927 36.456%	11656 9.25%	52 0.04%	995 0.79%
Test+	22544	9711 43.08%	7458 33.08%	2421 10.74%	200 0.89%	2754 12.22%

در پایان فرآیند تولید آشکارسازها، آشکارسازهای بالغ به سیستم برای شروع فرآیند جداسازی خود از غیر خود آزاد می‌شوند. آشکارسازها از مقادیر برای ویژگی‌های انتخاب شده برای نمایش عناصر خودی تشکیل شده است. آشکارسازهای تولیدشده از مرحله قبل از طریق داده‌های آزمایش برای شروع فرآیند تشخیص ناهنجاری اجرا می‌شوند. نتایج به‌دست‌آمده از [4] در لایه بعدی - لایه طبقه‌بندی - برای طبقه‌بندی ناهنجاری‌های تشخیص داده‌شده وارد می‌شود، همان‌طور که در زیر با جزئیات توضیح داده شده است.

3.4. لایه دوم: استفاده از دسته‌بندی کننده‌ها برای دسته‌بندی حملات

پس از مرحله تشخیص ناهنجاری، اتصالات به‌عنوان عادی یا غیرطبیعی برچسب‌گذاری شده‌اند، اما نوع حمله مشخص نشده است. طبقه‌بندی کننده باید برای برچسب‌گذاری حملات با دسته خاص خود استفاده شود. بسیاری

از طبقه‌بندی کننده‌ها مورد آزمایش و مقایسه قرار گرفتند. این طبقه‌بندی کننده‌ها عبارت‌اند از Bayes Naive، RFT، J48، BFTree، Decisions Trees - NBTree و شبکه‌های عصبی چندلایه Perceptron. در لایه طبقه‌بندی، هم ترافیک عادی و هم غیرعادی به‌صورت جداگانه طبقه‌بندی می‌شوند. برای ترافیک غیرعادی، ناهنجاری‌ها باید به‌عنوان یکی از دسته‌های حمله موجود در مجموعه داده، یا به‌عنوان عادی اگر آن مثبت کاذب باشد، برچسب‌گذاری شوند. برای ترافیک عادی، از طریق طبقه‌بندی انجام می‌شود، به‌طوری‌که اگر یک ناهنجاری به‌عنوان یک منفی نادرست شناسایی شود، به‌عنوان یک حمله به‌درستی با برچسب دسته درست برچسب‌گذاری می‌شود. مدل پیشنهادی به‌عنوان یک سیستم چند عامل در [8] اجرا شد.

4. آزمایش‌ها

این آزمایش با استفاده از مجموعه داده‌های ارزیابی NSL-KDD [21] IDS انجام شد. در تحقیقات پیشین، مجموعه داده KDD Cup 99 [15] بیشترین داده‌های معیار کاربردی برای ارزیابی عملکرد دستگاه‌های تشخیص نفوذ مبتنی بر شبکه بود. مشخص شد که مشکلاتی وجود دارد که الگوریتم یادگیری را منحرف می‌کند و نتایج به دلیل کپی کردن سوابق خود در هر دو مجموعه داده‌های آموزشی و آزمایشی نادرست است. مجموعه داده KDD Cup نیز برای ارزیابی بسیار وسیع است، بنابراین معمولاً بخش‌های کوچکی از داده‌ها برای ارزیابی مورد استفاده قرار می‌گیرند که منجر به نتایج نادرست نیز می‌شود؛ بنابراین، گروه محققین پرونده‌های اضافی را حذف کرده و مجموعه داده‌ها را به‌صورت متناسب برای به کسب تعادل انتخاب کردند و این امر به مجموعه داده NSL-KDD منجر شد. این تحقیق توسط بسیاری از محققین مورد استفاده قرار گرفته است، زیرا تعداد رکوردها برای داده‌های آموزشی و آزمون بسیار کمتر است، بنابراین کل مجموعه‌ها می‌توانند در آزمایش‌ها مورد استفاده قرار گیرند. چهار نوع عمومی حملات در مجموعه داده وجود دارد: رد خدمات (DOS)، کاوشگر، کاربر به ریشه (U2R) و دور به نزدیک (R2L). جدول 1 توزیع سوابق عادی و حملات در مجموعه داده NSL-KDD را نشان می‌دهد.

بعضی از مراحل برای آماده‌سازی فرآیند نیاز به تعدیل تنظیمات خود در عامل اصلی برای کسب بهترین نتایج در عوامل آشکارساز دارد. این مقادیر بهترین نتایج را با ویژگی‌های انتخاب‌شده توسط SFFS در آزمایش قبلی نشان داده‌شده در [5] ارائه داد. در آزمایش، 26 ویژگی توسط SFFS انتخاب شد. برای طبقه‌بندی کننده‌ها، داده‌های

Train_20% برای آموزش استفاده شد، زیرا طبقه‌بندی کننده‌ها نشان داد که نتایج بسیار خوبی بدون نیاز به استفاده از تمام سوابق اطلاعات آموزشی به دست می‌دهد، همان‌طور که در [6،7] ثابت شده است. طبقه‌بندی کننده‌های اعمال شده در این آزمایش‌ها از طریق ابزارهای Weka استفاده شد [24].

5. نتایج و بحث

دو مجموعه نتیجه از مرحله اول داریم، یکی مجموعه‌ای است که توسط آشکارسازهای تولیدشده با استفاده از اندازه‌گیری فاصله‌ای اقلیدسی و مجموعه‌ای دیگر توسط آشکارسازهای تولیدشده با استفاده از اندازه‌گیری فاصله Minkowski - هم برای مجموعه آموزشی و مجموعه آزمایش به دست می‌آید. فقط نتایج مجموعه آزمایش از طریق طبقه‌بندی کننده‌ها اجرا می‌شود.

برای نتایج اقلیدس، 12889 ناهنجاری شناسایی شد و طبقات واقعی آن‌ها عبارت‌اند از: 1567 اتصالات طبیعی، 6894 اتصالات حمله DoS، 2295 ارتباطات حمله کاوشگر، 159 ارتباطات حمله اتصال U2R و 1974 اتصالات حمله R2L. از سوی دیگر، 9655 مورد طبیعی شناخته شدند و طبقات واقعی آن‌ها عبارت‌اند از: 8144 اتصالات طبیعی، 564 اتصالات حمله DoS، 126 اتصال حمله کاوشگر، 41 اتصال حمله U2R و 780 اتصال حمله R2L. برای نتایج Minkowski، 13239 ناهنجاری شناسایی شده و طبقات واقعی آن‌ها عبارت‌اند از: 1718 اتصالات طبیعی، 6939 اتصالات حمله DoS، 2303 ارتباطات حمله کاوشگر، 159 اتصال حمله U2R و 2120 اتصالات حمله R2L. از سوی دیگر، 9305 مورد طبیعی تشخیص داده شد و طبقات واقعی آن‌ها عبارت‌اند از: 7993 اتصالات طبیعی، 519 اتصال حمله DoS، 118 اتصال حمله کاوشگر، 41 اتصال حمله U2R و 634 اتصال حمله R2L.

از آنجا که ردیاب‌های Minkowski میزان تشخیص بهتری را ارائه کردند، آزمایش با استفاده از این نتایج تشخیصی ادامه یافت. معیارهای ارزیابی مورد استفاده برای ارزیابی بهتر IDS عبارت‌اند از دقت، فراخوانی و نمره F. دقت بالاتر بدان معنی است که سیستم تنها قادر به تشخیص حملات بود، فراخوانی بیشتر نشان می‌دهد که سیستم قادر به شناسایی تمام حملات بوده و نمره F بالاتر نشان‌دهنده صحت بیشتر تشخیص حملات، بر اساس دقت و مقادیر فراخوانی است. آن‌ها به صورت زیر محاسبه می‌شوند.

$$\text{دقت} = \frac{TP}{TP + FP} \quad (1)$$

$$\text{فراخوانی} = \frac{TP}{TP + FN} \quad (2)$$

$$F = 2 * \frac{\text{دقت} * \text{فراخوانی}}{\text{دقت} + \text{فراخوانی}} \quad (3)$$

TP (مثبت واقعی) تعداد حملات درست شناسایی شده/ دسته‌بندی شده است، FP (مثبت کاذب) تعداد اتصالات عادی است که به اشتباه به عنوان حملات برچسب‌گذاری شده‌اند و FN (منفی کاذب) تعداد اتصالات نامناسب است که به اشتباه به عنوان عادی نام‌گذاری شده‌اند.

5.1. نتایج طبقه‌بندی کننده‌ها

طبقه‌بندی کننده‌ها یک‌بار با استفاده از تنها 20 درصد مجموعه آموزشی و بار دیگر با استفاده از تمام مجموعه آموزشی آموزش دیده بودند. جدول 2 مقادیر دقت و فراخوانی برای هر طبقه‌بندی کننده را روی ترافیک ناهنجار حاصل از آشکارسازهای Minkowski نشان می‌دهد.


می‌توانیم درک کنیم که مقادیر دقت زیاد هستند که نشان‌دهنده این است که بیشتر حملات شناسایی شده، در واقع اتصالات غیرمعمول هستند، در حالی که به علت تعداد زیاد حملات شناسایی شده به عنوان اتصالات معمول، مقادیر یادآوری آن چنان زیاد نیستند. شکل 2 اطلاعات مربوط به نتایج طبقه‌بندی ترافیک ناهنجار را برای آشکارسازهای Minkowski برای هر دسته حمله نشان می‌دهد.

همان‌طور که نتایج نشان می‌دهد، DoS با MLP بهتر دسته‌بندی شده است. حملات کاوشگر به ترتیب با BFTree با تمام اطلاعات آموزشی و NB با 20٪ از اطلاعات آموزشی بهتر طبقه‌بندی می‌شوند. NB بهترین طبقه‌بندی کننده برای حملات R2L است و برای حملات U2R با استفاده از تمام اطلاعات آموزشی همراه با J48 با استفاده از 20٪ اطلاعات آموزشی است. شکل 3 نتایج طبقه‌بندی ترافیک عادی را نشان می‌دهد که ترافیک طبیعی طبقه‌بندی برای پیدا کردن منفی‌های کاذب و نام‌گذاری آن‌ها با دسته حمله درست آن‌ها طبقه‌بندی می‌شود.

جدول ۲

مقادیر دقت و فراخوانی به دست آمده از طبقه بندی ترافیک ناهنجار معین شده توسط ردیابهای Minkowski.

طبقه بندی کننده	TP	FP	FN	دقت	یادآوری	نمره F
Using all of the train data records						
NB	7027	1264	2534	84.75%	73.50%	78.73%
BFTree	6744	121	4454	98.24%	60.23%	74.67%
J48	6580	156	4493	97.68%	59.42%	73.90%
MLP	6842	102	4322	98.53%	61.29%	75.57%
NBTree	6627	105	4309	98.44%	60.60%	75.02%
RFT	6690	113	4663	98.34%	58.93%	73.69%
Using 20% of the train data records						
NB	6271	1297	2677	82.86%	70.08%	75.94%
BFTree	6874	136	3954	98.06%	63.48%	77.07%
J48	6822	105	4351	98.48%	61.06%	75.38%
MLP	6691	123	4260	98.19%	61.10%	75.33%
NBTree	6506	114	4392	98.28%	59.70%	74.28%
RFT	6608	100	4730	98.51%	58.28%	73.24%




شکل ۲ طبقه بندی نتایج در ترافیک غیرعادی

می توانیم از طریق نتایج متوجه شویم که برای حملات غیرقانونی که به طور عادی شناخته شده اند، آن ها به شرح زیر طبقه بندی می شوند: DOS ها با استفاده از تمام داده های آموزشی با RFTree طبقه بندی می شوند و J48 و

BFTree با استفاده از 20 درصد اطلاعات آموزشی، با توجه به این که توسط BFTree و RFTree، حملات U2R به ترتیب با استفاده از تمام داده‌های آموزشی و J48 با استفاده از 20٪ اطلاعات آموزشی طبقه‌بندی می‌شوند و حملات R2L به‌طور کامل توسط NB طبقه‌بندی می‌شوند.

اضافه کردن حملات به‌طور صحیح از ترافیک شناسایی عادی به TP اصلی شناسایی شده در ترافیک غیرعادی طبقه‌بندی شده (FN تبدیل به TP)، مقادیر دقت و فراخوانی به شرح زیر است -جدول 3. طبقه‌بندی کننده‌های NBtree و BFTree دارای بالاترین مقادیر دقت هستند، درحالی که طبقه‌بندی کننده‌های NB و BFTree دارای بالاترین مقدار یادآوری هستند که بدان معنی است که NB و BFTree قادر به شناسایی حملات بیشتر هستند، اما NBTree و BFTree تعداد مثبت کاذب کمتری دارند و بیشتر آنچه آن‌ها شناسایی کرده‌اند، واقعاً غیرعادی هستند. از این رو می‌بینیم که بالاترین مقدار F-Score متعلق به طبقه‌بندی کننده NB و سپس طبقه‌بندی کننده BFTree است. این به دلیل توانایی طبقه‌بندی کننده NB برای شناسایی حملات R2L و U2R است که تقریباً توسط طبقه‌بندی‌های دیگر، در هر دو ترافیک غیرطبیعی و معمولی، شناسایی نشده است.



شکل ۳ طبقه‌بندی نتایج در ترافیکی عادی


جدول 3 مقادیر دقت و فراخوانی به دست آمده از طبقه بندی ترافیک غیرطبیعی و نرمال که توسط ردیاب‌های

Minkowski شناسایی شده‌اند.

Classifier	TP	FP	FN	Precision	Recall	F-Score
Using all of the train data records						
NB	7702	1264	1859	85.90%	80.56%	83.14%
BFTree	7180	121	4018	98.34%	64.12%	77.63%
J48	6976	156	4097	97.81%	63.00%	76.64%
MLP	7004	102	4160	98.56%	62.74%	76.67%
NBTree	6950	105	3986	98.51%	63.55%	77.26%
RFT	7199	113	4154	98.45%	63.41%	77.14%
Using 20% of the train data records						
NB	7025	1297	1923	84.41%	78.51%	81.35%
BFTree	7398	136	3430	98.19%	68.32%	80.58%
J48	7320	105	3853	98.59%	65.52%	78.72%
MLP	6846	123	4105	98.24%	62.51%	76.41%
NBTree	6826	114	4072	98.36%	62.64%	76.53%
RFT	7095	100	4243	98.61%	62.58%	76.57%

طبقه بندی کننده NB همچنین قادر به برچسب گذاری بیشتر حملات کاوشگر بود که به طور غلط به عنوان معمولی نسبت به سایر طبقه بندی کننده‌ها برچسب گذاری می‌شد. بر اساس میزان کاربرد داده‌ها برای آموزش، طبقه بندی کننده‌های NB و NBTree نتایج بهتری ارائه دادند، زمانی که تمام مجموعه داده‌های آموزشی مورد استفاده قرار گرفت، در حالی که BFTree و J48 هنگامی که تنها 20٪ از داده‌های آموزشی مورد استفاده قرار گرفت، نتایج بهتری ارائه دادند. نتایج RFTree و MLP در هر دو مورد نتایج نزدیک به هم داشتند.

داده‌های عادی توسط همه طبقه بندی کننده‌ها به جز طبقه بندی کننده NB شناسایی و دسته بندی شدند (تقریباً تمام ترافیک عادی). برای ارتباطات غیرمعمول، برخی از آن‌ها شناسایی شدند و برخی نیز بسته به ارائه آن‌ها در مجموعه داده و وابستگی بین ویژگی‌ها شناسایی نشدند.



شکل 4. نتایج طبقه بندی کلی - ردیاب‌های Minkowski

6. نتیجه‌گیری

در این مقاله، یک سیستم تشخیص نفوذ ترکیبی و سلسله مراتبی ارائه شده که مبتنی بر مفاهیم ایمنی است. طبقه‌بندی کننده‌های مختلف برای یافتن بهترین طبقه‌بندی کننده برای کسب اطلاعات بیشتر در مورد حملات شناخته شده و پیش‌بینی دسته حملات ناشناخته مورد آزمایش و مقایسه قرار گرفتند. می‌توانیم درک کنیم که به‌طور کلی، درخت‌های تصمیم‌گیری بهترین نتایج را ارائه می‌دهند، اما با توجه به هر دسته، طبقه‌بندی کننده‌ها نتایج مختلفی بر اساس ارائه این دسته‌ها در مجموعه داده‌ها و وابستگی بین ویژگی‌ها دارند. طبقه‌بندی کننده NB دارای بهترین نتایج در مورد حملات کم ارائه شده مانند R2L و U2R است. FT نتایج بسیار خوبی داشت، اما مدت‌زمان زیادی برای آموزش ساخت درختان تصادفی برای تصمیم‌گیری طبقه‌بندی نیاز داشت. NBTree و BFTree امتیازات بالاتری نسبت به J48 و RFTree داشتند؛ کاربرد آن‌ها بهتر است، زیرا زمان کمتری برای آموزش را نیاز دارند و در موارد ارائه بالای طبقات، تنها 20 درصد مجموعه آموزشی برای ارائه نتایج بسیار خوب کافی است. MLP بهترین نمرات را در طبقه‌بندی uhnd و DoS برای ارائه بالای آن‌ها در مجموعه آموزشی به دست آورد، اما در موارد حملات U2R و R2L نمی‌تواند آن‌ها را طبقه‌بندی کند - در بیشتر موارد صفر درصد به‌درستی طبقه‌بندی شدند.

می‌توانیم نتیجه‌گیری کنیم که نیازی به استفاده از طبقه‌بندی کننده‌های پیچیده برای کسب نمرات طبقه‌بندی بالا نیست - NB نرخ‌های تشخیص بالا در موارد دسته‌های حمله کم ارائه شده به دست می‌دهد. همچنین، یک طبقه‌بندی کننده تنها برای استفاده و برچسب‌گذاری و پیش‌بینی دسته‌های حملات کافی نیست، طبقه‌بندی کننده‌های چندگانه باید مورد استفاده قرار گیرند تا دقت طبقه‌بندی را افزایش دهند. اگر 20 درصد از اطلاعات آموزشی برای ارائه نمرات بالا کافی است - حتی اگر کمی کمتر از مورد کاربرد تمام اطلاعات آموزشی - سپس زمان کمتر برای آموزش در این مورد بهتر است. همان مجموعه ویژگی‌ها از طریق کل فرایند استفاده شده و نتایج رضایت‌بخش را به دست آورده است، بنابراین نیازی به یک مجموعه ویژگی خاص برای هر دسته حمله نیست. شاید برای طبقه‌بندی نوع حمله خاص تحت برچسب بزرگ دسته حمله مورد نیاز باشد که جزو کار آینده برای بالا بردن نتایج سیستم خواهد بود. همان‌طور که در شکل 4 نشان داده شده است، طبقه‌بندی ترافیک شناسایی شده

به‌طور عادی نتایج کلی طبقه‌بندی را افزایش داده است. این مورد می‌تواند برای تحقیقات آینده در نظر گرفته شود تا حملات رفتاری را به‌طور خاص در ترافیک شناسایی شده به‌صورت عادی شناسایی کند.

References

- [1] U. Aickelin, J. Greensmith, J. Twycross, Immune system approaches to intrusion detection – a review, in: *Artificial Immune Systems*, Springer, Berlin, Heidelberg, 2004, pp. 316–329.
- [2] J.R. Anderson, Knowledge compilation: the general learning mechanism, in: R.S. Michalski, R.S. Michalski, T.M. Mitchell (Eds.), *Machine Learning: An Artificial Intelligence Approach 2*, Morgan Kaufmann, 1986.
- [3] A.S.A. Aziz, A.T. Azar, A.E. Hassanien, S.E.O. Hanafi, Continuous features discretization for anomaly intrusion detectors generation, in: *WSC17 2012 Online Conference on Soft Computing in Industrial Applications*, 2012.
- [4] A.S.A. Aziz, A.T. Azar, A.E. Hassanien, S.E.O. Hanafi, Genetic algorithm with different feature selection techniques for anomaly detectors generation, in: *2013 Federated Conference on Computer Science and Information Systems*, FedCSIS, IEEE, 2013, pp. 769–774.
- [5] A.S.A. Aziz, A.T. Azar, A.E. Hassanien, S.E.O. Hanafi, Genetic algorithm with different feature selection techniques for anomaly detectors generation, in: *2013 Federated Conference on Computer Science and Information Systems*, FedCSIS, IEEE, 2013, pp. 769–774.
- [6] A.S.A. Aziz, A.E. Hassanien, A.T. Azar, S.E.O. Hanafi, Machine learning techniques for anomalies detection and classification, in: *Advances in Security of Information and Communication Networks*, Springer, Berlin, Heidelberg, 2013, pp. 219–229.
- [7] A.S.A. Aziz, A.E. Hassanien, S.E.O. Hanafi, M.F. Tolba, Multi-layer hybrid machine learning techniques for anomalies detection and classification approach, in: *2013 13th International Conference on Hybrid Intelligent Systems*, HIS, IEEE, 2013, pp. 216–221.
- [8] A.S.A. Aziz, S.E.O. Hanafi, A.E. Hassanien, Multi-agent artificial immune system for network intrusion detection and classification, in: *International Joint Conference SOCO'14–CISIS'14–ICEUTE'14*, in: *Advances in Intelligent Systems and Computing*, vol. 299, Springer International Publishing, 2014, pp. 145–154.
- [9] R. Caruana, A. Niculescu-mizil, An empirical comparison of supervised learning algorithms, in: *Proceedings of the 23rd International Conference on Machine Learning*, ACM, 2006, pp. 161–168.
- [10] H. Chauhan, V. Kumar, S. Pundir, E.S. Pilli, A comparative study of classification techniques for intrusion detection, in: *2013 International Symposium on Computational and Business Intelligence*, ISCBI, IEEE, 2013, pp. 40–43.
- [11] D. Dasgupta, S. Yu, F. Nino, *Advances in artificial immune systems: models and applications*, *Appl. Soft Comput.* 11 (2) (2011) 1574–1587.
- [12] S. Ganapathy, K. Kulothungan, S. Muthurajkumar, M. Vijayalakshmi, P. Yogesh, A. Kannan, Intelligent feature selection and classification techniques for intrusion detection in networks: a survey, *EURASIP J. Wirel. Commun. Netw.* 2013 (1) (2013) 1–16.
- [13] P. Garcia-Teodora, J. Diaz-Verdejo, G. Macia-Fernandez, E. Vazquez, Anomaly-based network intrusion detection: techniques, systems and challenges, *Comput. Secur.* 28 (1–2) (2009) 18–28.
- [14] M.S. Hoque, Md. Mukit, Md. Bikas, A. Naser, An implementation of intrusion detection system using genetic algorithm, In arXiv preprint arXiv:1204.1336, 2012.
- [15] KDD Cup'99 intrusion detection data set, Available on: <http://kdd.ics.uci.edu/databases/kddcup99/kddcup99.html>, October 2007.
- [16] G. Kim, S. Lee, S. Kim, A novel hybrid intrusion detection method integrating anomaly detection with misuse detection, *Expert Syst. Appl.* 41 (4) (2014) 1690–1700.
- [17] H.J. Liao, K.Y. Tung, C.H. Richard Lin, C.Y. Lin, Intrusion detection system: a comprehensive review, *J. Netw. Comput. Appl.* 36 (2012) 16–24.

- [18] S. Misra, S.C. Misra, I. Woungang, Selected Topics in Communication Networks and Distributed Systems, World Scientific, 2010.
- [19] Z. Muda, W. Yassin, M.N. Sulaiman, N.I. Udzir, Intrusion detection based on K-means clustering and Naïve Bayes classification, in: 2011 7th International Conference on Information Technology in Asia, CITA 11, IEEE, 2011, pp. 1–6.
- [20] L. Noriega, Multilayer Perceptron Tutorial, School of Computing, Staffordshire University, 2005.
- [21] NSL-KDD intrusion detection data set, Available on: <http://iscx.ca/NSL-KDD/>, March 2009.
- [22] S.K. Sharma, P. Pandey, S.K. Tiwari, M.S. Sisodia, An improved network intrusion detection technique based on k-means clustering via Naïve Bayes classification, in: 2012 International Conference on Advances in Engineering, Science and Management, ICAESM, IEEE, 2012, pp. 417–422.
- [23] C. So-In, N. Mongkonchai, P. Aimtongkham, N. Wijitsopon, K. Rujirakul, An evaluation of data mining classification models for network intrusion detection, in: 2014 Fourth International Conference on Digital Information and Communication Technology and Its Applications, DICTAP, IEEE, 2014, pp. 90–94.
- [24] Weka 3: data mining software in Java, Available on <http://www.cs.waikato.ac.nz/~ml/weka/>.