

# ارائه یک روش بر پایه ماشین‌های بردار پشتیبان برای تشخیص رخنه به شبکه‌های رایانه‌ای

نرگس صالح پور<sup>۱</sup>، محمد نظری فرخی<sup>۲</sup> و ابراهیم نظری فرخی<sup>۳</sup>

<sup>۱</sup> کارشناسی ارشد کامپیوتر (نرمافزار)، دانشگاه آزاد اسلامی واحد علوم تحقیقات لرستان، لرستان، ایران.

Salehpour\_Narges@yahoo.com  
M\_Kasitman@yahoo.com

<sup>۲</sup> دانشجوی دکتری مدیریت فناوری اطلاعات، دانشگاه آزاد اسلامی واحد علوم تحقیقات، تهران، ایران.

<sup>۳</sup>E60\_Itmgtn@yahoo.com

## چکیده

سامانه تشخیص رخنه یکی از مهم‌ترین مسائل در تأمین امنیت شبکه‌های رایانه‌ای است. سامانه‌های تشخیص رخنه در جستجوی رفتار مخرب، انحراف الگوهای طبیعی و کشف حملات به شبکه‌های رایانه‌ای هستند. این سامانه‌ها نوع ترافیک مجاز از ترافیک غیرمجاز را تشخیص می‌دهند. از آنجا که امروزه تکنیک‌های داده‌کاوی به منظور تشخیص رخنه در شبکه‌های رایانه‌ای مورد استفاده قرار می‌گیرند، در این پژوهش نیز، روشی مبتنی بر یادگیری ماشین جهت طراحی یک سامانه تشخیص رخنه ارائه شده است. یکی از ویژگی‌های شبکه‌های عصبی و سامانه‌های یادگیری ماشین، آموزش بر اساس داده‌های آموزشی است. در این پژوهش برای تشخیص رخنه از یادگیری ماشین با خاصیت یادگیری روی ویژگی‌ها با استفاده از تئوری راف که دارای ضریب همبستگی بیشتری است، به کار گرفته می‌شود. برای آموزش و ارزیابی روش پیشنهادی از مجموعه داده KDD CUP 99 استفاده شده است. بنابراین دقت روش پیشنهادی را با الگوریتم یادگیری بر پایه تمام ویژگی‌ها، شبکه عصبی خودسازمانده و درخت تصمیم‌گیری مقایسه می‌کند. نتایج شبیه‌سازی نشان می‌دهد، سامانه پیشنهادی مبتنی بر تئوری راف دارای دقت بالا و سرعت تشخیص مناسب است.

وازگان کلیدی: تئوری مجموعه‌های راف، سامانه‌های تشخیص رخنه، ماشین بردار پشتیبان و سامانه‌های یادگیری ماشین.

## ۱ - مقدمه

با وجود اینکه، امروزه تعداد کاربران اینترنت تا ۲۱۴ درصد رشد داشته است و با رشد کاربران اینترنت، رخنه به سامانه‌های رایانه‌ای از طریق شبکه نیز افزایش یافته است، بنابراین امنیت شبکه به یک مسئله جدی برای کاربران شخصی و شرکت‌های بزرگ تبدیل شده است. به طور کلی امنیت، شامل ضدهزارزname، ضدویروس، ورود و خروج حسابرسی‌ها و دیوارهای آتش است که ضدهزارزname بر روی کاربران نهایی تمرکز دارد و رایانه‌هایی را که در هزارزname قرار می‌گیرند، مسدود می‌کند. تکنیک‌های ضدویروس نیز به طور معمول برای شناسایی نرم‌افزار، بلوک و از بین بردن ویروس‌های رایانه‌ای و برنامه‌های مخرب استفاده می‌شوند. یکی دیگر از راههای معمول برای رخنه پیدا کردن به شبکه‌های رایانه‌ای، استفاده از نام کاربری و رمز عبور است که سامانه‌های تشخیص رخنه در مورد چگونگی حمله و یا این‌که چه کسی سعی در رخنه به سامانه را دارد، اطلاعاتی در اختیار کاربر قرار می‌دهد. با توجه به بررسی‌های انجام شده در مرکز سی. اس. آی<sup>۱</sup>، در دوازدهمین کنگره سالانه جرایم رایانه‌ای و بررسی امنیت که با حضور بیش از ۴۰۰ شرکت پیشگام در زمینه امنیت سامانه‌های رایانه‌ای در مؤسسات، نهادهای حکومتی، دانشگاه و... در ایالت متحده آمریکا انجام شده بود، می‌توان دریافت که با افزایش سرمایه‌گذاری بر روی صنعت سامانه‌های رایانه‌ای، میزان حملات به طور چشم‌گیری کاهش یافته است. با توجه به آمار، از سال ۲۰۰۷ تا ۲۰۰۰ استفاده کنندگان از اینترنت به بیش از یک میلیارد می‌رسید.

<sup>۱</sup> CSI

میزان حملات و رخنه در سامانه‌های اطلاعاتی، افزایش یافته است. به‌منظور جلوگیری از سوءاستفاده اطلاعات، امنیت شبکه باید در نظر گرفته شود. مفهوم امنیت به معنای محافظت از:

- **محرمانگی:** محرمانه‌بودن داده‌ها به معنی آن است که داده‌های در حال انتقال در شبکه تنها باید توسط افرادی که به شیوه مناسب، احراز هویت شده‌اند، مورد دستیابی قرار گیرند و داده‌ها از لحظه‌ای که منتقل تا لحظه‌ای که دریافت می‌شوند، نباید هیچ اختلال و فردانی به‌دلیل فعالیت‌های خراب‌کارانه داشته باشند.

- **دستنخوردگی:** اطلاعات ممکن است توسط مهاجم تغییریافته یا نابود شوند.

- **دسترسی‌پذیری:** دسترسی‌پذیری در حالت مشهود به معنای این است که سامانه در مقابل حملات انکار سرویس (DOS)<sup>۱۰</sup>، محافظت باشد [۲۱، ۳۴].

تشخیص رخنه عبارت است از فرایند شناسایی و پاسخ به فعالیت‌های مخرب که به صورت هدفمند، منابع شبکه را مورد تهاجم قرار می‌دهند. اگرچه سطوح بسیاری وجود دارند که از دسترسی به شبکه‌های رایانه‌ای محافظت می‌کنند؛ اما رخنه‌گران راههایی را برای ورود به شبکه می‌یابند تا خسارات عمده‌ای را در سطح شبکه به وجود آورند. هدف سامانه‌های تشخیص رخنه، جلوگیری از حمله نیست؛ بلکه کشف و شناسایی حملات و تشخیص اشکالات امنیتی در شبکه‌های رایانه‌ای و درنهایت، اعلام آن به مدیران سامانه است.

از جمله وظایف سامانه‌های تشخیص رخنه عبارتنداز [۲۲]:  
▪ تأیید خطاهای سامانه؛

- بررسی یک پارچگی سامانه و پرونده‌های داده؛
- تشخیص رفتارهای غیرعادی و نایه‌نهنجار سامانه؛
- شناسایی حملات و هشدارها.

سامانه هشدار چندگانه<sup>۱۱</sup> یکی از سامانه‌های تشخیص رخنه است که به عنوان سامانه خبره شناخته شده است و برای تجزیه و تحلیل داده‌ها مورد استفاده قرار می‌گیرد. یکی دیگر از سامانه‌های تشخیص رخنه، NIDES<sup>۱۲</sup> است که به عنوان سامانه تشخیص رخنه جامع مطرح می‌شود و برای تشخیص ناهنجاری و سوءاستفاده پیاده‌سازی شده است. NIDES، ناهنجاری را با استفاده از پروفایل (نمایه)

در سال ۱۹۸۰ توسط Denning شناخته شد. از جمله سامانه‌های تشخیص تجاری Tripwire<sup>۱</sup>، امنیت مانیتور کین<sup>۲</sup>، پلیس سایبر<sup>۳</sup>، امنیت واقعی<sup>۴</sup>، رنجر شبکه<sup>۵</sup>، سنتراکس<sup>۶</sup>، امنیت سامانه‌های تشخیص رخنه سیسکو<sup>۷</sup>، ازدها<sup>۸</sup>، اینترورت<sup>۹</sup> را می‌توان نام برد. برای اطلاعات بیشتر می‌توان به مراجع [۱، ۴، ۳، ۲] مراجعه کرد. در حال حاضر سیستم‌عامل‌ها و شبکه‌های رایانه‌ای از حس‌گرهای تشخیص رخنه برای شناسایی حملات و رخنه‌گران استفاده می‌کنند. برخی، پاسخ به رخنه‌های غیرقانونی سامانه را پایان دادن اتصال به شبکه در نظر می‌گیرند. نمونه‌هایی از سطح رخنه در شبکه شامل محرومیت از راه دور، ورود تروجان‌ها و جاسوس‌ها به سامانه را می‌توان نام برد [۶، ۵]. هدف اصلی، ارائه یک روش مبتنی بر الگوریتم‌های یادگیری ماشین از مشین‌های بردار پشتیبان، رگرسیون ماشین بردار پشتیبان در تشخیص رخنه است که در این پژوهش به عنوان یادگیری ماشین از آن‌ها استفاده شده است. روش ذکرشده به‌منظور به کارگیری روش‌های تشخیص، جلوگیری از نفوذها از جمله حملات سایبری، ویروس‌ها، کرم‌های رایانه‌ای و غیره است. با بررسی الگوی فعالیت کاربران با استفاده از شبکه‌های عصبی و ماشین‌های بردار پشتیبان بسیاری از نفوذها قابل تشخیص هستند. الگوهای ذخیره شده باید به طور مداوم به روز شوند که این امر مستلزم تخصص و ابزار هوشمند است. ماشین بردار پشتیبان یک ابزار عملی برای مجموعه‌داده‌های بزرگ است که داده‌ها را با تعیین مجموعه‌داده‌های بردار پشتیبان دسته‌بندی می‌کند. هم‌چنین خطای تعیین را نیز به حداقل می‌رسانند. اگرچه ماشین بردار پشتیبان روش امیدوارکننده‌ای برای دسته‌بندی داده‌ها است، اما مشکل اصلی آن پیچیدگی آموزش‌های بسیار، وابسته به مجموعه‌داده‌ها است. برای این منظور از ترکیب تکنیک دیگری به نام تئوری مجموعه‌های راف با الگوریتم‌های یادگیری ماشین برای شناسایی حملات استفاده می‌شود.

## ۲- سامانه‌های تشخیص رخنه

با گسترش روزافزون تبادل اطلاعات و سامانه‌های برخط،

<sup>1</sup> Tripwire

<sup>2</sup> Kane Security monitor

<sup>3</sup> Cyber cop

<sup>4</sup> Real Secure

<sup>5</sup> NetRanger

<sup>6</sup> Centrax

<sup>7</sup> Cisco Secure IDS

<sup>8</sup> Dragon

<sup>9</sup> Intruvert

### ■ تشخیص مبتنی بر امضا<sup>۳</sup>

در این روش الگوهای رخنه از پیش‌ساخته شده و به صورت قانونی نگه‌داری می‌شوند. تشخیص دهنده دارای پایگاه داده‌ای از امضاهای الگوهای حمله است. البته این روش قادر به تشخیص نفوذ‌های شناخته شده است؛ و در صورت بروز حمله جدید در سطح شبکه قادر به شناسایی نیست. تشخیص بر اساس امضا، ساده‌ترین روش است؛ زیرا در شناسایی تهدیداتی که از قبل شناخته شده باشند، بسیار مؤثر است و در مورد شناسایی حملاتی که از قبل شناخته شده نیستند، به طور کامل غیر مؤثر است. یکی از معروف‌ترین امضاهای مبتنی بر سامانه‌های تشخیص رخنه، کامپلیتلی<sup>۴</sup> است.

### ■ تشخیص مبتنی بر ناهنجاری

تشخیص مبتنی بر ناهنجاری عبارت است از مقایسه رویدادهای مشاهده شده با فعالیت‌های نرمال، تا میزان تفاوت آن‌ها مشخص شود. برای تشخیص ناهنجاری باید الگوهای خاصی را پیدا کرد و رفتارهایی که از الگو پیروی می‌کنند، عادی و رویدادهای انحرافی به عنوان ناهنجاری تشخیص داده می‌شوند. ویژگی اصلی تشخیص مبتنی بر ناهنجاری این است که برای حملات ناشناخته و جدید نیز مؤثر است [۳۲].

## ۲-۱- سامانه‌های تشخیص رخنه، بر اساس منابع دریافتی اطلاعات

به منظور شناسایی و تشخیص فعالیت‌های غیرمجاز رایانه براساس منابع دریافت اطلاعات سامانه‌های تشخیص رخنه به دو دسته تقسیم می‌شوند:

### ■ سامانه‌های مبتنی بر میزبان<sup>۵</sup>

در این سامانه‌ها اطلاعات از چندین میزبان جمع‌آوری و به میزبان مرکزی ارسال می‌شود. در میزبان مرکزی عملیات پیچیده‌تر انجام می‌شود. سامانه‌های تشخیص رخنه مبتنی بر میزبان از رخدادهای سامانه و اطلاعات مربوط به برنامه‌های کاربردی به عنوان منابع اطلاعاتی استفاده می‌کنند. منابع اطلاعاتی که در سامانه‌های مبتنی بر میزبان نظارت می‌کنند، عبارت‌اند از [۳۲]:

تشخیص می‌دهد. نمایه‌ها در واقع الگوهای عادی فعالیت‌های سامانه را ارائه می‌دهند. به طور معمول پروفایل‌ها در NIDES یک‌بار در روز تغییرات جدید را به روز می‌کنند.

جیمز اندرسون رخنه را به دو دسته رخنه داخلی و خارجی تقسیم کرد. آقای اندرسون بر روی مجموعه‌ای از رکوردهایی که رفتار غیرمعمول سامانه را بیان می‌کرد، مانند استفاده از زمان غیرمجاز، دفعات استفاده غیرمجاز و الگوی غیرمعمول از ارجاع به برنامه‌ها و داده‌ها، متوجه شد. وی همچنین در مورد مشکلات دسترسی کاربران مجاز به اطلاعات حیاتی سامانه، نیز هشدار داد و معلوم شد که تشخیص استفاده غیرمجاز از رکوردهای امنیتی، کار سختی است [۲۳].

## ۲-۱- انواع سامانه‌های تشخیص رخنه از نظر واکنش

سامانه‌های تشخیص رخنه از نظر نوع واکنش به دو دسته تقسیم می‌شوند:

### ■ سامانه تشخیص رخنه مبتنی بر انفعال

با توجه به این که سامانه‌های تشخیص نفوذ برای کمک به مدیران امنیتی سامانه در جهت کشف رخنه و حمله به کار گرفته می‌شوند، بنابراین این سامانه‌ها فقط حملات را شناسایی و پیغام لازم را به مدیر اعلام می‌کنند.

### ■ سامانه تشخیص رخنه مبتنی بر عکس العمل<sup>۶</sup>

این سامانه‌ها علاوه بر شناسایی حملات به مدیر سامانه پیغام می‌دهند. همچنین راه ارتباطی فرستنده مورد نظر را نیز به شبکه مسدود می‌کنند و نمی‌گذارند هیچ بسته‌ای از طرف IP<sup>۷</sup> به شبکه وارد شود [۳۷].

## ۲-۲- سامانه‌های تشخیص رخنه از نظر نوع تشخیص

روش‌های تشخیص سوءاستفاده برای به رسمیت شناختن الگوی حملات شناخته می‌شوند. از جمله روش‌های تشخیص رخنه، از نظر نوع تشخیص به دو دسته تقسیم می‌شوند:

<sup>1</sup>Reactive IDS

<sup>2</sup>Internet Protocol

دسترس نیست. مقدار بعدی بر اساس موقعیت فعلی  
ورودی پیش‌بینی می‌شود.<sup>[۲۰]</sup>

- سامانه پرونده

- رویدادهای شبکه

- فراخوانی‌های شبکه

سامانه‌های مبتنی بر میزبان فعالیت‌های مجاز بر روی رایانه میزبان را شناسایی و حملات را تشخیص می‌دهند.

#### ■ سامانه‌های مبتنی بر شبکه<sup>۱</sup>

در این سامانه‌ها، بر پروندها و داده‌های مربوط به ترافیک شبکه، سایر اجزای شبکه و سامانه‌های کنترل امنیت مانند دیوارهای آتش نظارت دارند. سامانه‌های مبتنی بر شبکه، بسته‌های عبوری در سطح شبکه را به عنوان منبع اطلاعات جمع‌آوری می‌کنند و احتمال آسیب‌رساندن به شبکه را کاهش می‌دهند. سامانه‌های تشخیص رخنه مبتنی بر شبکه، اطلاعات ترافیک شبکه را مورد تجزیه و تحلیل قرار می‌دهند.<sup>[۳۲,۲۴]</sup>

پروژه<sup>۲</sup> DIDS، توسط انجمن‌ها و سازمان‌های امنیتی و نظامی آمریکا تحت حمایت قرار گرفت و زیر نظر مستقیم نیروی هوایی، آژانس امنیت ملی و وزارت انرژی به انجام رسید. معماری این سامانه توسط استیو ماها<sup>۳</sup> ارائه شد. نخستین تلاش در جهت استفاده از منابع و اطلاعات میزبان و شبکه به طور همزمان، برای تشخیص رخنه بود.<sup>[۲۵]</sup>

### ۳- تکنیک‌های یادگیری ماشین

تکنیک‌های یادگیری ماشین به توانایی یک برنامه رایانه‌ای برای یادگیری و افزایش عملکرد آن در قالب مجموعه‌ای از

وظایف در زمان را گویند. یادگیری ماشین به دو دسته، یادگیری با نظارت و یادگیری بدون نظارت تقسیم می‌شوند.

(الف) یادگیری با نظارت: این الگوریتم به ازای هر ورودی دارای یک مقدار خروجی و یا تابع مشخص است. هدف سامانه یادگیری، به دست آوردن فرضیه‌ای است که تابع یا رابطه بین ورودی و خروجی را حدس بزند. الگوریتم‌های یادگیری با نظارت به مجموعه‌ای از نمونه‌ها به نام مجموعه آموزش نیاز دارند. شبکه‌های عصبی مصنوعی، الگوریتم‌های خوشبندی k-means، شبکه‌های بیزین<sup>۴</sup> و ماشین بردار پشتیبان از جمله الگوریتم‌های یادگیری با نظارت می‌باشند.<sup>[۶]</sup>

(ب) یادگیری بدون نظارت: در این الگوریتم فقط مقدار ورودی‌ها مشخص است و اطلاعاتی در مورد خروجی در

<sup>1</sup> Network intrusion detection system

<sup>2</sup> Distributed IDS

<sup>3</sup> Steve Maha

<sup>4</sup> Bayesian

**۳-۱- الگوریتم ماشین بردار پشتیبان**  
ماشین بردار پشتیبان یکی از روش‌های یادگیری با نظارت است. مبنای کار ماشین بردار پشتیبان بر مبنای دسته‌بندی خطی داده‌ها است. در تقسیم خطی داده‌ها سعی بر انتخاب خطی است که حاشیه اطمینان بیشتری داشته باشد. ویژگی مهم ماشین بردار پشتیبان این است که برخلاف سایر شبکه‌های عصبی دیگر مانند<sup>۵</sup> MLP، RBF به جای این که خطای مدل‌سازی و طبقه‌بندی را کم کنند، آن‌ها خطرپذیری عملیاتی را به عنوانتابع هدف در نظر می‌گیرند و مقدار بهینه آن را محاسبه می‌کنند. ماشین بردار پشتیبان با استفاده از کرنل غیرخطی قادر به تصمیم‌گیری غیرخطی نیز است. انتخاب کرنل مناسب برای ماشین بردار پشتیبان، منجر به برتری آن نسبت به سایر رویکردهای مبتنی بر تصمیم‌گیری خطی شده است.<sup>[۸,۹]</sup>؛ لذا استفاده از تکنیک‌های داده‌کاوی برای سامانه‌های تشخیص رخنه به این دلیل است که قادر به پیش‌بینی فعالیت‌های نفوذگران هستند.<sup>[۷]</sup>

**۳-۱-۱- انواع مدل‌های بردار پشتیبان**  
مدل‌های بردار پشتیبان به دو گروه عمده تقسیم می‌شوند:  
■ مدل طبقه‌بندی ماشین بردار پشتیبان<sup>۶</sup>  
■ مدل رگرسیون بردار پشتیبان

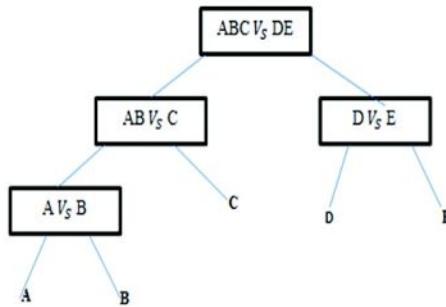
مدل طبقه‌بندی ماشین بردار پشتیبان جهت حل مسائل طبقه‌بندی داده‌هایی که در طبقه‌های مختلف قرار می‌گیرند، استفاده می‌شود. همچنین مدل رگرسیون پشتیبان نیز در حل مسائل پیش‌بینی کاربرد دارد. همان‌گونه که بیان شد، ماشین بردار پشتیبان مبتنی بر ساختار خطر است و از تئوری آموزش آماری برگرفته شده است.<sup>[۱۱]</sup>

الگوریتم ماشین بردار پشتیبان در الگوریتم‌های تشخیص الگو دسته‌بندی می‌شود و در هرجایی که نیاز به تشخیص الگو یا دسته‌بندی اشیا در طبقه‌های خاص باشد، از آن استفاده می‌شود. در الگوریتم ماشین بردار پشتیبان، هدف، انتخاب بهترین خط است، از این‌جهت که کمترین میزان خطا برای طبقه‌بندی داده‌ها را داشته باشد. این روش را به الگویی

<sup>5</sup> Multi Layer Perceptron

<sup>6</sup> Support vector classification

عادی و حمله تقسیم می‌کند. بنابراین در مراحل بعدی نیز همین چرخه برای چهار نوع حمله دیگر انجام می‌شود. با توجه به درخت زیر، پنج گروه از داده‌ها به صورت A.B.C.D.E فرض شده است. در شکل (۱۶-۳) ابتدا دو گره از داده‌ها که بیشترین فاصله را از هم دارند به دو گروه جدا تقسیم می‌شوند؛ به عنوان مثال A تا E به دو گروه تقسیم می‌شوند. فاصله سایر گروه‌ها یعنی B و C و D از A و E اندازه گرفته می‌شود و هر کدام از این دو که نزدیک‌تر بود در گروه آن‌ها قرار می‌گیرد. همان‌طور که در درخت مشاهده می‌کنید، فاصله B و C به A نزدیک‌تر بوده است. بنابراین در یک گروه قرار می‌گیرند و فاصله D به E نزدیک‌تر بوده است. بنابراین این دو نیز در یک گروه قرار می‌گیرند. این فرآیند برای تمام زیردرخت‌ها ادامه می‌یابد تا تمام گره‌ها از هم جدا شوند، بدین ترتیب پنج گروه از داده‌ها از هم جدا می‌شوند و امکان طبقه‌بندی و تشخیص وجود دارد. با این وجود از ماشین‌های بردار پشتیبان دودویی به کمک درخت‌های تصمیم‌گیری برای حل مسئله‌ای با چند طبقه از داده‌ها استفاده می‌شود. البته هدف، کاهش زمان آموزش مدل‌ها و افزایش عملکرد تشخیص است.



(شکل ۱): روش جداسازی داده‌ها [۳۳].

ژانگ<sup>۴</sup> و وانگ برای بهینه‌سازی ساختار کرنلی ماشین بردار پشتیبان، ویژگی‌های اضافی و اثرات منفی را کشف و شناسایی کردند. همچنین برای بهینه‌سازی اطلاعات کرنل ماشین بردار پشتیبان، کارایی پارامتر تابع یادگیری ماشین بردار پشتیبان را افزایش دادند که این امر منجر به حل مشکلات در محاسبات می‌شود [۲۷].

استفاده از الگوریتم ژنتیک و ماشین بردار پشتیبان نیز برای تشخیص خودکار مجموعه‌ای از ویژگی‌ها مناسب است. انتخاب ویژگی‌های مهم به منظور افزایش قابلیت تعمیم و

از فضای F که به طور معمول دارای ابعاد بزرگی است، تبدیل می‌کند. همچنین تعمیم خطا ماشین بردار پشتیبان به مشخصات هندسی داده‌های آموزشی نه به ابعاد ورودی بستگی دارد. از جمله کاربردهای ماشین بردار پشتیبان، شبیه‌سازی مسیر، پیش‌بینی کیفیت، بهینه‌سازی زمان پیوند اعضا، تشخیص چهره، طبقه‌بندی ژن‌های سرطان و تجزیه و تحلیل بحران اقتصادی ارز و کاهش هزینه است [۳، ۱۲، ۱۳].

امروزه ماشین بردار پشتیبان به یک روش محبوب در مدل‌سازی تبدیل شده است که باعث کاهش زمان آموزش می‌شود. هدف استفاده از ماشین بردار پشتیبان در سامانه‌های تشخیص رخنه، جدا کردن الگوهای طبیعی از نفوذی و همچنین دارای عملکرد بهتری در تشخیص حملات DOS و حملات کاوشی<sup>۱</sup> (Prob) است [۱۴، ۱۵].

### ۲-۳- به کار گیری ماشین‌های بردار پشتیبان با دیگر تکنیک‌های داده‌کاوی

درخت‌های تصمیم روشنی برای نمایش یک سری از قوانین هستند که منتهی به یک رده یا مقدار می‌شوند. یکی از تفاوت‌های بین روش‌های ساخت درخت تصمیم این است که این فاصله چگونه اندازه گیری می‌شود. درخت‌های تصمیمی که برای پیش‌بینی متغیرهای دسته‌ای استفاده می‌شوند، درخت‌های طبقه‌بندی<sup>۲</sup> نامیده می‌شوند؛ زیرا نمونه‌ها را در دسته‌ها یا رده‌ها قرار می‌دهند. درخت‌های تصمیمی که برای پیش‌بینی متغیرهای پیوسته استفاده می‌شوند، درخت‌های رگرسیون نامیده می‌شوند [۲۶].

ماشین‌های بردار پشتیبان برای پایه درختان تصمیم‌گیری یکی از روش‌هایی است که مولای<sup>۳</sup> و همکارانش به آن اشاره کردند [۳۳]. بدین ترتیب در جهت حل مسائل از داده‌ها با طبقه‌های گوناگون استفاده می‌شود. ترکیب مدل‌های مختلف، سرعت و عملکرد بهتری در مقایسه با مدل‌های تصمیم‌گیری با مدل‌های یادگیری به صورت منفرد دارد؛ در این مقایسه از پنج مدل ماشین بردار پشتیبان برای پنج گروه از داده‌ها بر چسب‌گذاری شده استفاده می‌شود. این داده‌ها شامل چهار گروه از حملات و یک گروه از داده‌های سالم یا عادی است. پنجم الگوی استخراج شده در هر داده را به دو طبقه

<sup>1</sup> Probing<sup>2</sup> Classification<sup>3</sup> Mulay



(شکل ۲): فرآیند تشخیص رخنه توسط ماشین بردار پشتیبان [۳۱]

### ۴-۳- روند کار ماشین بردار پشتیبان

حل معادله پیدا کردن خط بهینه برای داده ها، به وسیله روش های برنامه نویسی درجه دوم<sup>۱</sup> از جمله روش های شناخته شده ای است که به صورت محدود شده می باشد.

**۴-۳-۱- مدل طبقه بندی ماشین بردار پشتیبان**  
فرض کنید تعدادی از بردارهای ویژگی یا الگوهای آموزشی به صورت  $\{x_1, x_2, \dots, x_n\}$  وجود داشته باشد که هر کدام یک بردار ویژگی  $d$  بعدی می باشند. با برچسب  $y_i$  به طوری که  $y_i \in \{-1, +1\}$  است.



(شکل ۳): تعدادی نمونه آموزشی در فضای دو بعدی.

پایه معادلات ماشین بردار پشتیبان به صورت دوطبقه تعریف می شود که هدف حل یک مسئله دسته بندی دوطبقه به صورت بهینه است. مجموعه داده ها به وسیله خط از یکدیگر جدا می شوند. ماشین بردار پشتیبان، خط پذیری عدم طبقه بندی را به صورت یکسری کمیت های عددی بیان و سپس مقدار

<sup>4</sup> Quadratic Programming

سرعت بخشیدن به فرآیند یادگیری و بهبود الگو است. محاسبه فرآیند فیتنس<sup>۲</sup>، انتخاب کراس آور<sup>۳</sup> و جهش برای اجرای حداکثر تعداد نسل میسر است. با نخبه گرایی در هر نسل، بهترین رشته برای آن نسل ایجاد می شود. بتایرانی محل به دست آمده، بهترین مجموعه دسته بندی است [۲۸]. مدل پیشرفته ماشین بردار پشتیبان با کرنل تابع وزن دار، دارای عملکرد بهتری، نسبت به ماشین بردار پشتیبان معمولی است. الگوریتم جدید ماشین بردار پشتیبان با توجه به سطوح وزنی برای رتبه بندی ویژگی های تشخیص رخنه داده مورد استفاده قرار می گیرند. برای تشخیص رخنه، دقت، زمان محاسبه و میزان خطا بسیار کمتر است. شکل کلی کرنل تابع جدید به صورت رابطه (۱)

$$f(x) = \text{sign} \left( \sum_{i=1}^L \alpha_i y_i k(w_{xi}, w_x) + b \right) \quad (1)$$

تابع ذکر شده برای پیدا کردن وزن با حداکثر حاشیه ابر صفحه به منظور جدا کردن دو طبقه بر مبنای تفکیک کننده غیر خطی است. در رابطه (۱)،  $L$  تعداد رکوردهای آموزش و  $y_i \in \{-1, 1\}$  بر چسب اطلاعات آموزش داده شده است که  $\alpha_i \leq 0$  و  $b$  بردار پشتیبان بر اساس وزن است [۲۹]. پیاده سازی سامانه های تشخیص رخنه با استفاده از ماشین بردار پشتیبان احتمال خطر، خطای تعیین و خطای آموزش را کاهش می دهد. روش PCNN<sup>۴</sup> (اجزای اصلی شبکه های عصبی) مبتنی بر الگوریتم تشخیص رخنه، هشدارهای اشتباه را کاهش می دهد. هم چنین استخراج ویژگی از طریق PCNN، عملکردهای تشخیص رخنه مبتنی بر ماشین بردار پشتیبان را نیز بهبود می بخشد. با این وجود استخراج ویژگی، کار آمدترین روش برای تقویت عملکرد سامانه تشخیص رخنه است [۳۰].

### ۳-۳- فرآیند تشخیص رخنه با استفاده از ماشین بردار پشتیبان

روند تشخیص رخنه توسط ماشین بردار پشتیبان در شکل ۲ نشان داده شده است. با استخراج ویژگی، داده ها به نمونه های آموزشی و نمونه های آزمون تقسیم می شوند. با توجه به این که نمونه های آموزشی برای تشخیص، توسط ماشین بردار پشتیبان و نمونه های آزمون برای به دست آوردن دقت تشخیص از مدل ماشین بردار پشتیبان استفاده می کنند [۳۱].

### ۳-۵-۳- مدل رگرسیون بردار پشتیبان خطی

یک دیگر از انواع ماشین‌های بردار پشتیبان، رگرسیون بردار پشتیبان است. در سال ۱۹۹۷، وینیک با همکاری Steven Smola و Golowich، رگرسیون بردار پشتیبان را پیشنهاد دادند [۳۵]. رگرسیون بردار پشتیبان، درواقع تعیینی است بر آن ایده‌ای که ماشین‌های بردار پشتیبان برای طبقه‌بندی دودویی دارند. ماشین‌های بردار پشتیبان مبتنی بر ورودی‌ها در فضای  $d$  بعدی هستند و خروجی‌های آن در حالت کلی دو حالت است؛ اما در اینجا فرض بر این است که خروجی‌های ما بیش از دو مقدار و در حالت کلی بی‌نهایت مقدار است. به عبارتی خروجی‌ها به شکل حقیقی هستند. رگرسیون بردار پشتیبان در زمینه‌های مختلف سری‌های زمانی و مالی، پیش‌بینی، تقریب و تجزیه و تحلیل‌های پیچیده و انتخاب توابع به کار گرفته می‌شود.

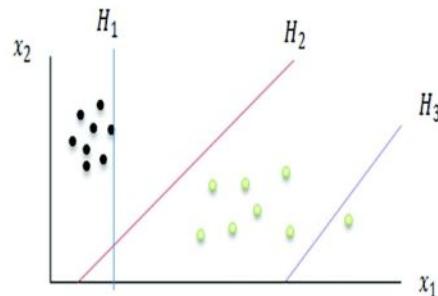
رابطه (۲) تفاوت ماشین بردار پشتیبان و رگرسیون بردار پشتیبان را نشان می‌دهد. در این رابطه،  $x_i$  نمایان‌گر ورودی در فضای  $d$  بعدی در ماشین بردار پشتیبان و رگرسیون بردار پشتیبان است.  $t_i$  نمایان‌گر خروجی است که در ماشین بردار پشتیبان، خروجی‌ها به صورت دودویی ( $+1$  و  $-1$ ) نشان داده می‌شوند؛ اما در رگرسیون بردار پشتیبان، خروجی‌ها در بازه مجموعه اعداد حقیقی هستند.

رابطه (۲)

$$\text{SVM}(x_i, t_i) \begin{cases} x_i \in \mathbb{R}^d \\ t_i \in \{-1, +1\} \end{cases} \quad \text{SVR}(x_i, t_i) \begin{cases} x_i \in \mathbb{R}^d \\ t_i \in \mathbb{R} \end{cases}$$

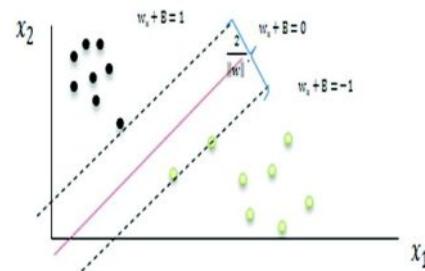
در صورتی که یک نقطه وجود داشته باشد، معادله خط دقیقی که از آن می‌گذرد  $b = w^T x + b$  است و دو خط تقریبی در آن وجود دارد. هدف در اینجا استفاده از این خطوط‌های تقریبی است. حال با فرض این که به جای یک نقطه، چند نقطه داشته باشیم، در رگرسیون بردار پشتیبان باید نواری را به دست آوریم که این نقاط را پوشش دهنده و نقاط در آن قرار گیرند. در شکل ۶ بین دو شکل (ب) و (ج)، شکل (ب) بهتر است که با یک نوار خطی می‌توان سه نقطه را پوشش داد؛ اما در شکل (ج)، نوار تفکیک کننده مناسبی نیست؛ بنابراین هدف، پیدا کردن بهترین تفکیک کننده‌ای است که بهترین عمل پوشش را انجام دهد.

کمینه را از بین آنها حساب می‌کند؛ اما شبکه عصبی MLP زمانی که تفکیک درست باشد، مقدار خطای تفکیک را نیز کمینه می‌کند و آن را به عنوان یک راه حل در نظر می‌گیرد. از آنجاکه مجموعه داده‌های آموزشی دارای برچسب می‌باشد و بواسیله تفکیک کننده، نقاط متعلق به دو طبقه از یکدیگر تفکیک می‌شوند؛ به این تفکیک کننده مرز تصمیم‌گیری گفته می‌شود. شکل ۴ به تعدادی از مرازهای تصمیم‌گیری اشاره دارد.



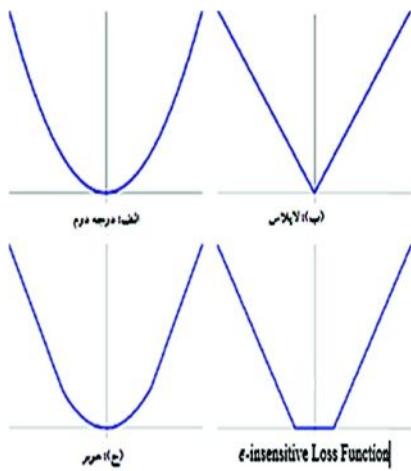
(شکل ۴): مرز تصمیم‌گیری [۱۶].

در شکل ۴ تفکیک کننده  $H_3$ ، دو طبقه را به درستی طبقه‌بندی نمی‌کند؛ بنابراین تفکیک کننده  $H_3$ ، تفکیک کننده مطلوبی نیست؛ اما دو تفکیک کننده  $H_1$  و  $H_2$  دارای خط‌پذیری عملیاتی هستند که  $H_2$  نیز دارای خط‌پذیری عملیاتی کمتری نسبت به  $H_1$  است. به عبارتی  $H_2$  در شکل بالا، نقطه تعادل سامانه است. به هر یک از اعضای طبقه، بردار پشتیبان گویند. نزدیک‌ترین عضو در هر طبقه سعی بر دور کردن خط تفکیک کننده از خود را دارد. حاشیه مرز به کوتاه‌ترین فاصله میان نزدیک‌ترین نقطه در هر دو طرف نیم‌صفحه اشاره می‌کند. در شکل ۵ به تطور بدیهی قابل شهود و از نظر ریاضی نیز قابل اثبات است که تفکیک کننده، حداقل خطا را پیدا می‌کند [۱۶].



(شکل ۵): تفکیک کننده مطلوب [۱۶].

به عنوان تابع جریمه قوی محسوب می‌شود و تابع جریمه در قسمت (د) تابع جریمه<sup>۲</sup> است که دارای خواص زمانی مطلوب است [۱۷]. در واقع این میزان جریمه یک تابع جریمه به شکل  $L_{\epsilon}$  است.



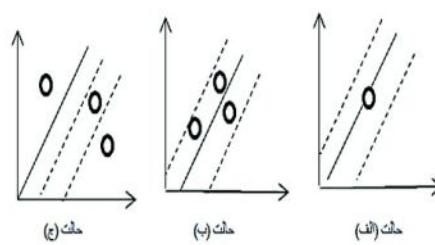
(شکل ۸): انواع توابع جریمه [۱۷].

**۳-۶-۳- تئوری مجموعه‌های راف**  
تئوری مجموعه‌های راف یا آر. اس. تی<sup>۳</sup> توسط پژوهشگر لهستانی به نام پاولاک در سال ۱۹۸۲ معرفی شد [۱۸]. از آنجاکه پژوهش‌های نخستین در زمینه تئوری مجموعه‌های راف به زبان لهستانی منتشر شد؛ لذا نظر پژوهش‌گران علوم رایانه و ریاضیات در سطح بین‌الملل را جلب نکرد و توجه چندانی به این تئوری صورت نگرفت. در اوخر دهه هشتاد ۱۹۹۲ این تئوری در سطح جهانی مطرح شد و در سال ۱۹۹۵ نخستین کنفرانس علمی تئوری مجموعه‌های راف به صورت بین‌المللی در لهستان برگزار شد. در سال ۱۹۹۵ از سوی ACM<sup>۴</sup> به عنوان موضوع نوظهور در علم رایانه معرفی شد. از آن پس تئوری مجموعه‌های راف به عنوان یک ابزار محاسباتی جدید برای برخورد با شرایط مبهم و عدم قطعیت شناخته شد. این امر می‌تواند برای تحلیل اطلاعات غیردقیق متناقض و ناکامل به کار گرفته شود. امروزه تئوری مجموعه‌های راف به عنوان ابزاری قدرتمند برای استنتاج داده‌ها و تحلیل و پیش‌بینی تصمیمات داده‌کاوی سامانه‌های خبره و سامانه‌های پشتیبانی تصمیم و بسیاری از زمینه‌های دیگر شناخته شده است.

<sup>2</sup>  $\epsilon$ -insensitive Loss Function

<sup>3</sup> Rough Set Theory

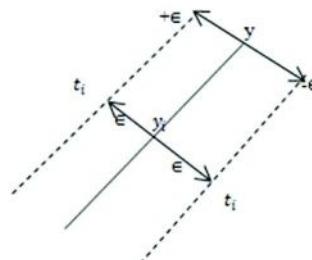
<sup>4</sup> Association for computing machinery



(شکل ۶): یافتن بهترین خط تقریبی در رگرسیون بردار پشتیبان.

بنابراین در شکل (ج) نقاطی که در نوار قرار ندارند، باید جریمه شوند.

تفاوت  $t_i$  و  $y_i$  در شکل (۷) این است که  $t_i$  مقدار تقریبی، اما  $y_i$  یک مقدار دقیق است. یعنی با فرض این که رگرسیون خطی  $y_i = w^T x_i + b \approx t_i$  باشد.

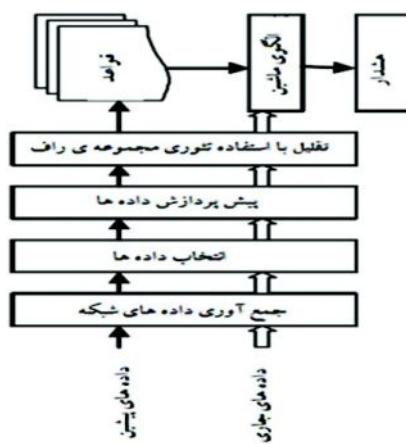


(شکل ۷): بازه مطلوب تفکیک‌کننده در رگرسیون بردار پشتیبان.

به این نکته باید توجه کرد که هرچه  $\|w\|$  کم‌تر باشد مدل، یک مدل ساده‌تری است. با وجود بی‌شمار نقطه، باید تفکیک‌کننده‌ای را پیدا کرد که دارای تقریب دقیق‌تری باشد. با توجه به شکل ۷ در صورتی یک نقطه در نظر گرفته شود و خطی که از آن می‌گذرد، رسم شود. اگر نقطه به طور دقیق روی خط نباشد، مشکلی وجود ندارد و می‌توان این خط را تحمل کرد؛ به این حد  $\epsilon$  می‌گویند. این بازه به عنوان یک بازه مطلوب است؛ یعنی مادامی که داده‌ها در این نوار هستند، این مدل برای داده‌ها مورد قبول است؛ اما اگر داده‌ها خارج از این فضای باشند، خطای آن بیشتر از  $\epsilon$  می‌شود. درنتیجه باید آن‌ها را به نحوی جریمه کرد. چهار نوع از توابع جریمه در شکل ۶ نشان داده شده است.

تابع جریمه در شکل ۸ قسمت (الف) مربوط به معیار خطای در حداقل مربعات است. تابع جریمه در قسمت (ب) تابع جریمه لابلás<sup>۱</sup> است که به نقاط دورافتاده حساس است. تابع جریمه در قسمت (ج) به عنوان تابع جریمه هوبر

<sup>1</sup> Laplace



شکل ۹: سامانه تشخیص رخنه مبتنی بر تئوری مجموعه راف [۱۹].

## ۴- یافته‌های پژوهش و الگوریتم پیشنهادی

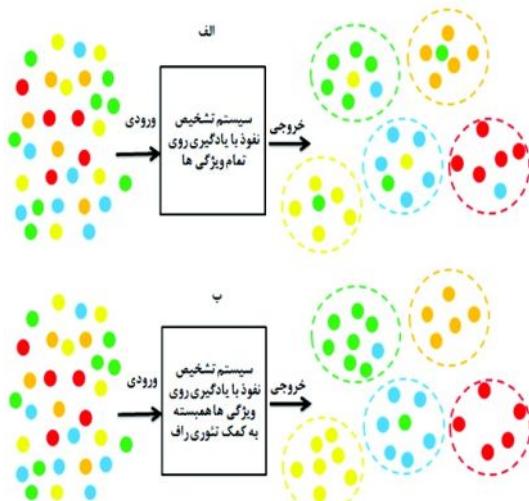
الگوریتم پیشنهادی برای سامانه تشخیص رخنه در شبکه‌های رایانه‌ای مورد استفاده قرار می‌گیرد. در این الگوریتم با استفاده از یادگیری مبتنی بر مашین و پیش‌پردازش بر اساس تئوری راف بررسی می‌شود که یک سامانه ترکیبی بر اساس درجه همبستگی برحسب مهم‌ترین ویژگی‌ها در حملات به کار گرفته می‌شود تا دقت و سرعت یادگیری ماشین بیشتر شود. در روش‌های مشابه با یادگیری ماشین روی تمام ویژگی‌ها، عملیات پردازش انجام می‌گیرد. با استفاده از این روش بر اساس تمام ویژگی‌های ترافیک شبکه عصبی مبتنی بر یادگیری ماشین، تصمیم می‌گیرد که کدام داده آزمون متعلق به کدام خوشه (حمله) است. به کارگیری این روش‌ها خالی از ایجاد نیست. یکی از مهم‌ترین ایرادهای استفاده از ویژگی‌هایی است که در تعیین نوع حمله نقشی ندارند. این اصر منجر به کاهش دقت یادگیری ماشین می‌شود. از طرف دیگر پردازش، به کارگیری داده‌ها و ویژگی‌هایی که نقش مهمی در طبقه‌بندی ندارند، تشخیص رخنه و سرعت یادگیری را نیز کاهش می‌دهند. در این پژوهش سعی کردیم با یک روش جدید، تئوری راف را با یادگیری ماشین ترکیب کنیم. از آنجاکه این تئوری با تحلیل جدول‌های داده سروکار دارد و جدول‌های داده نیز توسط اندازه‌گیری یا افراد متخصص و آگاه حاصل می‌شوند، هدف اصلی از تحلیل مجموعه راف به دست آوردن مفاهیم تقریبی از داده‌های اکتسابی است. این

تئوری مجموعه‌های راف را می‌توان به تحلیل‌های تصمیم‌گیری و تحلیل‌های غیر تصمیم‌گیری تقسیم کرد. تحلیل‌های غیر تصمیم‌گیری به طور عمده، فشرده‌کردن اطلاعات، تقلیل اطلاعات، خوشبندی، کشف الگو و نظایر آن را شامل می‌شود. درواقع کارکرد اصلی این دسته از تحلیل‌ها آن است که ویژگی‌های غیرضروری را حذف و با فشرده‌کردن و تقلیل داده‌ها، امکان تحلیل بهتر داده‌ها را فراهم کند. تحلیل‌های تصمیم‌گیری نیز به کشف و استخراج قوانین تصمیم کمک می‌کنند [۳۶]. این تئوری با تحلیل جدول‌های داده سروکار دارد. مجموعه راف یکی از ابزارهای ریاضی است که قادر به توجیه عدم قطعیت و ابهام است. مجموعه راف الگوهای خاص در داده‌های ناقص را از متابع اطلاعاتی کشف می‌کند؛ همچنین برای طیف گسترده‌ای از برنامه‌های کاربردی مربوط به تشخیص الگو، پردازش تصویر، انتخاب ویژگی، محاسبات عصبی، به عنوان تجزیه و تحلیل کننده چند منبع داده، کشف دانش از داده‌هایی با ابعاد بالا و سامانه‌های اطلاعاتی توزیع و پشتیبانی تصمیم‌گیری استفاده می‌شود [۱۸].

تشخیص رخنه مبتنی بر تئوری مجموعه راف فرایندی تعاملی و تکرارشونده شامل مراحل زیر است:

- ۱- جمع‌آوری داده‌های شبکه
- ۲- انتخاب داده‌ها: هدف از این مرحله انتخاب جداول، سامانه اطلاعاتی و ویژگی‌های حملات است.
- ۳- پیش‌پردازش داده‌ها: این مرحله شامل پردازش اطلاعات ناقص است. به عنوان مثال، برخی داده‌ها که اطلاعات کافی را ندارند، با استفاده از تئوری مجموعه راف سوابق ناقص آن حذف می‌شوند.
- ۴- تقلیل: این مرحله در تئوری مجموعه راف منجر به تولید قوانین و الگوهای طبیعی و غیرطبیعی در شبکه می‌شود. اگر مشخصه یک زیرمجموعه  $C$  از  $A-B$  باشد از ویژگی‌های  $A-B$  چشم‌پوشی می‌شود. تقلیل، مانند زیرمجموعه‌ای است که شامل حداقل ویژگی‌های غیرضروری نباشد. با این وجود، سامانه‌های تشخیص رخنه با استفاده از تئوری مجموعه راف منجر به تشخیص دقت، پردازش داده و کاهش هشدار اشتباه می‌شود [۹].

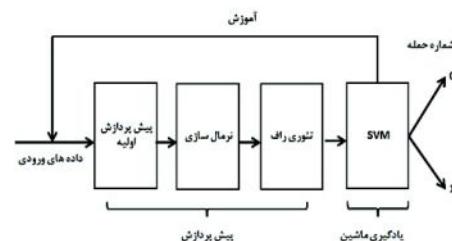
در این پژوهش، از دادگان ۱۰ درصد از مجموعه پوشش‌های دادگان KDD CUP 99 استفاده شده است. برای آزمایش از پنچاه درصد کل دادگان، حدود هفتاد درصد به داده‌های آموزشی و سی درصد به داده‌های آزمون اختصاص داده شده است. مجموعه یادگیری شامل دو مجموعه است: مجموعه نخست از تمام ویژگی‌ها و مجموعه دوم یادگیری، فقط بر حسب ویژگی‌هایی است که در تئوری راف عنوان شده است. برای مجموعه آموزشی نخست زمان زیادی صرف یادگیری می‌شود و یادگیری ماشین مجبور به استفاده از ویژگی‌هایی است که همبستگی زیادی با حملات ندارند. این یادگیری درواقع یادگیری با داده‌های پرت است و تأثیر منفی روی دقت سامانه تشخیص رخنه می‌گذارد. در مجموعه آموزشی دوم فقط از ویژگی‌هایی که در تئوری راف ثابت شده است که دارای همبستگی بالایی با حملات هستند، استفاده می‌شود. استفاده از این روش، منجر به کاهش ابعاد مجموعه آموزشی و افزایش سرعت تشخیص رخنه می‌شود. به علت حذف ویژگی‌های پرت (مانند حذف نوفر)، در اکثر موارد دقت تشخیص رخنه بالا می‌رود. در شکل (۱۲) نمایی از این روش نمایش داده می‌شود:



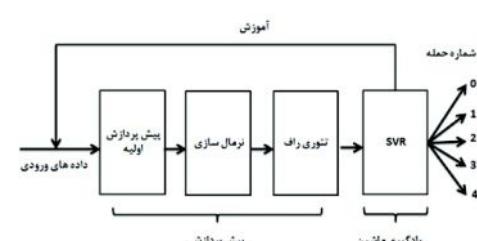
(شکل ۱۲): الف. خوشبندی سامانه تشخیص رخنه با استفاده از یادگیری ماشین روی تمام ویژگی‌ها را نشان می‌دهد در قسمت ب. یادگیری ماشین بجای استفاده از تمام ویژگی‌ها از ویژگی‌های مهمی که در تئوری راف به دست آمده استفاده کرده است با این روش سرعت آموزش و تشخیص بالا می‌رود و به علت حذف ویژگی‌های کم اهمیت میزان خطای خوشبندی کاهش یافته است. در شکل ب. خوشبندی دقیق تری نسبت به حالت الف ایجاد شده است.

تئوری، یک ابزار قدرتمند ریاضی برای استدلال در موارد ابهام و غیرقطعی است که روش‌هایی را برای زدودن و کاستن اطلاعات داشت نامریوط یا مازاد بر نیاز از پایگاه‌های داده‌ها مهیا می‌سازد. در این فرایند حذف داده‌های زائد بر مبنای آموزش، وظيفة اصلی سامانه است و بدون از دستدادن داده‌های اساسی پایگاه داده‌ها صورت می‌پذیرد. بنابراین از تقلیل اطلاعات، مجموعه‌ای از قواعد تشخیص شده و پرمغنا حاصل می‌شود که کار تصمیم‌گیرنده را بسیار ساده‌تر می‌کند. در حقیقت می‌توان گفت که مجموعه راف با کاهش فضای داده‌ها و برگزیدن ویژگی‌های مهم، یک نگاشت از فضای داده‌های خام را به فضای سماتیک (مفاهیم) انجام می‌دهد. الگوریتم پیشنهادی با استفاده از تئوری راف تمام ویژگی‌های یک حمله را به تعدادی از مهم‌ترین ویژگی‌های حملات نگاشت می‌دهد.

درواقع در مرحله پیش‌پردازش علاوه‌بر هنجارسازی، درجه‌ای از میزان همبستگی را بر اساس تئوری راف به کار می‌بریم که بر اساس مهم‌ترین ویژگی‌ها در یادگیری ماشین، نظری ماشین بردار پشتیبان به کار گرفته می‌شود. در شکل ۱۰ دیاگرام کلی سامانه پیشنهادی برای دسته‌بندی در دو طبقه (حمله) معرفی می‌شود. البته بهدلیل این که اگر تعداد طبقه‌های حملات بیشتر از دو عدد باشد (در روش پیشنهادی پنج دسته داریم) بهتر است از حالت چند طبقه ماشین بردار پشتیبان (رگرسیون بردار پشتیبان) استفاده کنیم. در شکل ۱۱ این سامانه پیشنهادی با پنج طبقه‌بندی حمله نشان داده شده است.



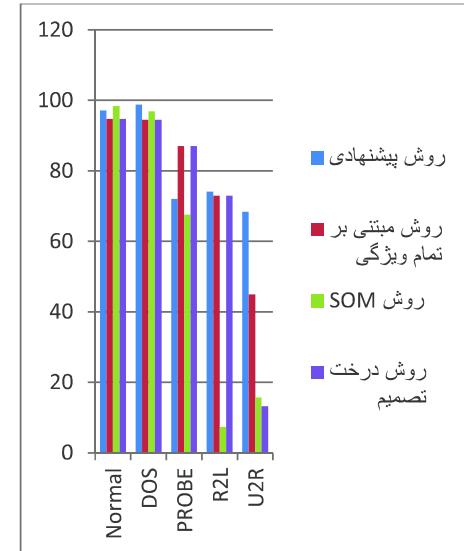
(شکل ۱۰): سامانه پیشنهادی تشخیص رخنه با دو طبقه‌بندی.



(شکل ۱۱): سامانه پیشنهادی تشخیص رخنه با پنج طبقه‌بندی.

## ۵- ارزیابی روش پیشنهادی

جدول ۱ میزان دقت تشخیص الگوریتم پیشنهادی با سه روش تشخیص رخنه برای پنج حمله اصلی را مقایسه می‌کند. در این مقایسه‌ها تعداد رکوردهای آموزشی دو هزار رکورد است. از اطلاعات جدول ۱ مشخص است که الگوریتم پیشنهادی در تشخیص حملات Normal بهتر از الگوریتم یادگیری بر مبنای تمام ویژگی‌ها و درخت تصمیم‌گیری است؛ ولی اندکی از تشخیص رخنه شبکه عصبی SOM کمتر است. بنابراین میزان دقت الگوریتم پیشنهادی در تشخیص حملات DOS از تمام الگوریتم‌های جدول ۱ بهتر عمل می‌کند؛ اما میزان دقت تشخیص حملات Probe از تشخیص رخنه شبکه عصبی SOM بیشتر است. در مورد حملات R2L و U2R نیز نتایج الگوریتم پیشنهادی از سه روش دیگر بهتر عمل می‌کنند.



(شکل ۱۴): مقایسه دقت انواع حملات با الگوریتم یادگیری بر پایه روش پیشنهادی، تمام ویژگی‌ها، شبکه عصبی SOM و درخت تصمیم‌گیری بر اساس نمودارهای میله‌ای.

از تحلیل نمودارهای شکل (۱۳) و شکل (۱۴) نشان داده می‌شود که دقت الگوریتم پیشنهادی از الگوریتم یادگیری بر پایه تمام ویژگی‌ها، شبکه عصبی SOM و درخت تصمیم‌گیری در حملات DOS، PROBE و U2R بیشتر است. همچنین تشخیص در حملات normal اندکی از روش SOM کمتر است؛ ولی در حملات R2L، U2R و PROBE، تشخیص رخنه حملات کمتر از روش‌های دیگر دارد. میزان دقت در صورتی بیشتر می‌شود که الگوریتم یادگیرنده بیشتر آموزش داده شود.

### ۵-۱- تشخیص حمله بر روی حملة Back

الگوریتم روش پیشنهادی بر روی حمله Back پس از

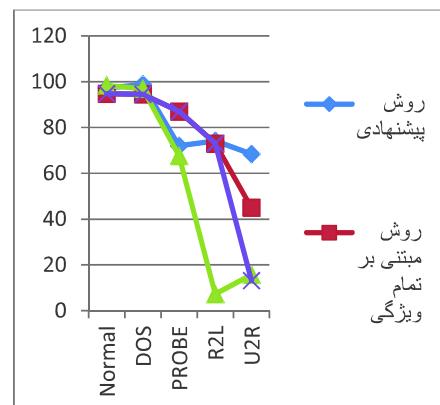
بیستبار آموزش به صورت شکل زیر است:

نمودار نخست در شکل ۱۵ ، حمله نوع صفر را که به عنوان حمله Back شناخته می‌شود، نشان می‌دهد که مشتمل بر خطای زیادی نیست. خطای نوع صفر دارای دقت بالایی است. بنابراین حملات از صفر تا دو هزار از نوع حمله صفر شناخته می‌شوند. با این وجود در نمودار دوم خطاهای نوع صفر به طور دقیق طبقه‌بندی می‌شوند. نمودار سوم نیز تعدادی از حملات را که درست تشخیص داده شده است در طبقه صفر تا دو هزار قرار داده است؛ همچنین میانگین خطای نشان می‌دهد.

(جدول ۱): محاسبه دقت تشخیص در چهار روش مورد بررسی در پژوهش.

نام حمله	درخت تصمیم‌گیری	شبکه عصبی SOM	تمام ویژگی‌ها	روش پیشنهادی
Normal	۹۴/۵۰	۹۸/۴۰	۹۴/۷۳	۹۷/۱۴
Dos	۹۷/۱۰	۹۶/۹۰	۹۴/۵۱	۹۸/۸۳
Probe	۸۳/۳۰	۶۷/۶۰	۸۷	۷۲
R2L	۸/۴۰	۷/۳۰	۷۳	۷۴/۱۵
U2R	۱۳/۲۰	۱۵/۷۰	۴۵	۹۸/۴۲

نمودار شکل (۱۱) و (۱۲)، نمودار مقایسه دقت الگوریتم پیشنهادی، الگوریتم یادگیری بر پایه تمام ویژگی‌ها، شبکه عصبی SOM و درخت تصمیم‌گیری بهتر ترتیب توسط خطوط پیوسته و نمودارهای میله‌ای نشان داده شده‌اند.

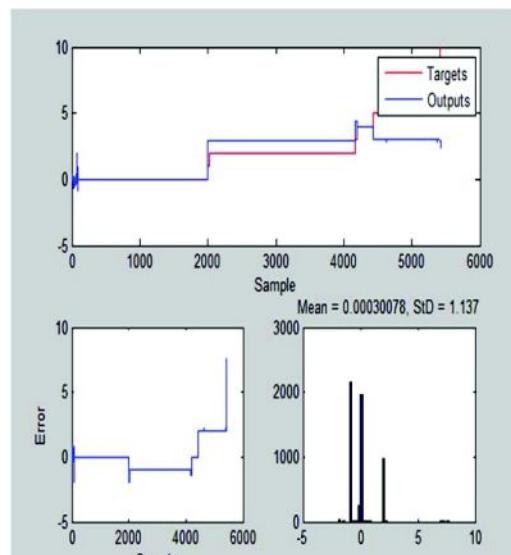


(شکل ۱۳): مقایسه دقت انواع حملات با الگوریتم یادگیری بر پایه روش پیشنهادی، تمام ویژگی‌ها، شبکه عصبی SOM.

دارند، برای آموزش در نظر گرفتیم. به عبارتی این روش پیشنهادی، یادگیری را روی تمام ویژگی‌ها انجام نمی‌دهد؛ بلکه بر روی ویژگی‌هایی که دارای ضریب همبستگی بیشتری هستند انجام می‌شود. این تکنیک، ابعاد ویژگی را کاهش می‌دهد؛ این کاهش باعث می‌شود سرعت یادگیری و تشخیص رخنه افزایش یابد. با این سازوکار، سامانه تشخیص رخنه پیشنهادی ما به سمت یک سامانه تشخیص رخنه با سرعت بالا در زمان اجرا حرکت می‌کند. ما در این پژوهش میزان دقیق روش پیشنهادی را با الگوریتم یادگیری بر پایه تمام ویژگی‌ها، شبکه عصبی SOM و درخت تصمیم‌گیری مقایسه کردیم. نتایج نشان داد که میزان دقیق الگوریتم پیشنهادی از الگوریتم یادگیری بر پایه تمام ویژگی‌ها، شبکه عصبی SOM و درخت تصمیم‌گیری در حملات U2R، DOS و R2L بیشتر است و در حملات normal اندکی تشخیص آن از روش SOM کمتر است؛ ولی در حملات Probe میزان دقیق، کمتر از روش‌های دیگر است. روش پیشنهادی به علت کاهش ابعاد یادگیری، دارای سرعت تشخیص رخنه بیشتری نسبت به الگوریتم یادگیری بر پایه تمام ویژگی‌ها است. الگوریتم پیشنهادی، مقدار DR بیشتری نسبت به روش الگوریتم یادگیری بر پایه تمام ویژگی‌ها دارد و مقدار FAR روش پیشنهادی اندکی بیشتر از الگوریتم یادگیری بر پایه تمام ویژگی‌ها است.

## ۷- پژوهش‌ها و پیشنهادهای آینده

در این پژوهش نشان دادیم که الگوریتم پیشنهادی دارای سرعت بالایی برای آموزش و تشخیص رخنه است. دقیق الگوریتم پیشنهادی ما بالا است؛ ولی برای کاربردهای عملی پیشنهاد می‌کنیم که الگوریتم پیشنهادی ما به عنوان ورودی شبکه قرار گیرد و در صورتی که ترافیکی را به عنوان حمله تشخیص داد؛ این ترافیک را هشدار اعلام نکند؛ سپس ترافیک را تحويل یک سامانه تشخیص رخنه مبتنی بر یادگیری ماشین با داده‌های آموزشی زیاد کند. با این سازوکار اگر ترافیکی از نظر سامانه پیشنهادی، حمله تشخیص داده شود، هشدارها فعال نمی‌شوند؛ بلکه یک شناسی دیگر به این ترافیک داده می‌شود که در یک سامانه سخت‌گیرانه‌تر عادی بودن خود را ثابت نماید. برتری این سامانه ترکیبی این است که سرعت کلی سامانه تشخیص رخنه برای ترافیک‌های عادی کم نمی‌شود، از طرفی در این سامانه پیشنهادی ترکیبی، تعداد هشدارهای اشتباہ کم می‌شود، بدون اینکه سرعت تشخیص کاهش یابد. درواقع از



(شکل ۱۵): استفاده از روش پیشنهادی بر روی حمله Back.

## ۶- نتیجه‌گیری

در این پژوهش روشی مبتنی بر یادگیری ماشین، جهت طراحی یک سامانه تشخیص رخنه ارائه شده. یکی از ویژگی‌های شبکه‌های عصبی و سامانه‌های یادگیری ماشین، آموزش بر اساس داده‌های آموزشی است. این پژوهش از سامانه‌های تشخیص رخنه مبتنی بر یادگیری ماشین با خاصیت یادگیری روی ویژگی‌هایی که با تئوری راف دارای بیشترین ضریب همبستگی هستند، استفاده کرد. همچنین از داده‌گان KDD CUP 99 استفاده می‌شود. این دادگان دارای تعداد زیادی رکورد که هر رکورد معرف یک ترافیک شبکه است. هر رکورد شامل ۴۱ ویژگی است. این داده‌گان از روی شبکه رایانه‌ای یکی از پایگاه‌های هوایی آمریکا که از نوع TCP است به مدت ۹ هفته گردآوری است. مدت زمان جمع‌آوری اطلاعات یادگیری حدود هفت هفته و مدت زمان گردآوری داده‌های آرمنون حدود دو هفته به طول انجامید. این دادگان شامل ۲۲ حمله و یک حالت عادی است. این ۲۳ حمله، خود به پنج گروه اصلی R2L, U2R, DOS و Probe, normal تقسیم می‌شوند. سامانه پیشنهادی متشكل از تعداد دو هزار رکورد به شکل تصادفی جهت آموزش شبکه عصبی مبتنی بر یادگیری ماشین است. همچنین تعدادی از رکوردهای دادگان به عنوان داده‌های آزمایشی استفاده شد. روش کار ما در این پژوهش به دو صورت می‌باشد: ابتدا از دو هزار رکوردی که برای آموزش در نظر گرفته شده اس؛ تنها رکوردهایی را که با استفاده از تئوری راف، بیشترین همبستگی را به یک حمله خاص

- [12] D.Meyer, "Support Vector Machines," pp. 1-8, 2012.
- [13] R. x. ZHANG, Z.r.DENG, and G. J. ZHI, "Intrusion Detection based on SVM and decision fusion," pp. 87-90, 2010.
- [14] S. Mukkamala, G. Janoski, and A. Sung, "Intrusion Detection Using Neural Networks and Support Vector Machines," Department of Computer Science New Mexico Institute of Mining and Technology, pp. 1702-1707, 2002.
- [15] S. J. Horng, M.Y.Su, Y. H. Chen, T. W. Kao, R. J. Chen, J. L. Lai, et al., "A novel intrusion detection system based on hierarchical clustering and support vector machines," Department of Computer Science and Information Engineering, pp. 306–313, 2011.
- [16] Prateek and D. S. K. Jena, "Intrusion Detection Using Self-Training Support Vector Machines," pp. 1-35, 2013.
- [17] S. R. Gunn, "Support Vector Machines for Classification and Regression," pp. 1-66, 1998.
- [18] Y. Qian, H. Zhang, Y. Sang, and J. Liang, "Multigranulation decision-theoretic rough sets," International Journal of Approximate Reasoning, vol. 55, pp. 225–237, 2014.
- [19] X. Wang, F. He, and L. Liu, "Application of Rough Set Theory to Intrusion Detection System," pp. 562-565, 2007.
- [20] G. Kumar, K. Kumar, and M. Sachdeva, "The use of artificial intelligence based techniques for intrusion detection: a review," pp. 369–387, 2010.
- [21] C. Bitter, J. North, D. Elizondo, and T. Watson, "An Introduction to the Use of Neural Networks for Network Intrusion Detection," pp. 5-24, 2012.
- [22] N. B. Idris and B. Shanmugam, "Artificial Intelligence Techniques Applied to Intrusion Detection," pp. 52-55, 2005.
- [23] J.P.Anderson, "Computer Security threat Monitoring And Surveillance," pp. 1-56, 1980
- [24] G. Wang, J. Hao, J. Ma, and L.Huang, "A new approach to intrusion detection using Artificial Neural Networks andfuzzy clustering," pp. 6225–6232, 2010.
- یک فیلتر دولایه برای حملات استفاده می‌کنیم. لایه نخستین این فیلتر، سامانه پیشنهادی این پژوهش است. اگر در لایه نخستین، ترافیک به عنوان حمله تشخیص داده شد این ترافیک مسدود و تحويل لایه دوم داده می‌شود. اگر لایه دوم احساس کرد که این حمله نیست، از حالت مسدود خارج و در غیر این صورت هشدارهای لازم صادر می‌شود.

## مراجع

- [1] R.A.Kemmerer and G.Vigna, "Intrusion Detection:A Brief History and Overview," pp. 27-30, 2002.
- [2] E. Beqiri, "Neural Networks for Intrusion Detection Systems," pp. 156–165, 2009.
- [3] S. Zhao, Regina, and Saskatchewan, "Intrusion detection using the support vector machine enhanced with a feature-weight kernel," pp. 1-83, 2007.
- [4] R. Richardson, "Computer Crime and Security Survey," pp. 1-30, 2007
- [5] N. B. Idris and B. Shanmugam, "Artificial Intelligence Techniques Applied to Intrusion Detection," pp. 52-55, 2005.
- [6] Prateek and D. S. K. Jena, "Intrusion Detection Using Self-Training Support Vector Machines," pp. 1-35, 2013.
- [7] A. M. Chandrashekhar and K. Raghuveer, "Amalgamation of K-means Clustering Algorithm with Standard MLP and SVM Based Neural Networks to Implement Network Intrusion Detection System," vol. 2, pp. 273-283, 2014.
- [8] W.C.Hong,"Traffic flowforecastingbyseasonalSVRwithchaoticsimulated annealing algorithm," vol. 74, pp. 2096–2107, 2011.
- [9] V. N. Vapnik, "The Nature of Statistical Learning Theory," 1999.
- [10] B. E. Boser, I. M. Guyon, and V. N. Vapnik, "A Training Algorithm for Optimal Margin Classifiers" pp. 144-152, 1992.
- [11] V. N. Vapnik, "Statistical Learning Theory " 1998.

تشخیص رخنه، ”نوآوری در مهندسی کامپیوتر و فناوری،“ تنکابن، ۱۳۹۲، ۵ صفحه.



**نرگس صالح‌پور، هم‌اکنون در دانشگاه علمی کاربردی لرستان فعالیت می‌کند. مدرک‌های کارданی، کارشناسی و کارشناسی ارشد در رشته کامپیوتر (نرم‌افزار) را به ترتیب در دانشگاه علمی کاربردی لرستان، جهاد دانشگاهی لرستان و دانشگاه آزاد اسلامی واحد علوم تحقیقات لرستان، در سال‌های ۸۶، ۸۹ و ۹۳ دریافت کرده است. زمینه‌پژوهشی اوی، سامانه‌های تشخیص نفوذ با استفاده از تکنیک‌های داده‌کاوی است.**



**محمد نظری فرخی، مدرک‌های کارشناسی و کارشناسی ارشد خود را به ترتیب از دانشگاه پیام نور لرستان، ایران و دانشگاه آزاد اسلامی واحد علوم و تحقیقات لرستان در سال‌های ۸۹ و ۹۴ دریافت کرده است. زمینه‌پژوهشی اوی سامانه‌های هوشمند است.**



**ابراهیم نظری فرخی، مدرک‌های کارشناسی، کارشناسی ارشد و دکترای خود را از دانشگاه آزاد اسلامی واحد علوم تحقیقات تهران، در سال‌های ۸۳، ۸۶ و ۹۳ دریافت کرده است. زمینه‌های پژوهشی اوی سامانه‌های هوشمند و داده‌کاوی می‌باشد. همچنین ایشان عضو باشگاه پژوهشگران دانشگاه آزاد اسلامی واحد علوم تحقیقات می‌باشد و در حال حاضر نیز در دانشگاه تدریس می‌نماید.**

[25] S. R. Snapp, J. Brentano, T. L. G. G. V. Dias, C. L. H. L. T. Heberlein, K. N. Levitt, B. Mukherjee, S. E. Smahal,, D. M. T. T. Grance, and D. Mansur4, "DIDS (Distributed Intrusion Detection System) - Motivation Architecture, and An Early Prototype ", pp. 167-176, 1991.

[26] [ R. E. j. Kennedy<sup>"</sup> , Particle swarm optimization," in Neural Networks, Perth, WA 1995, pp. 1942 - 1948 .

[27] J. Chen, "Study on an Improved SVM Model for Intrusion Detection," pp. 275-280, 2012.

[28] S. Saha, A. S. Sairam, and A. Ekbal, "Genetic Algorithm Combined with Support Vector Machine for Building an Intrusion Detection System," pp. 566-572, 2012.

[29] J. T. Yao, S. Zhao, and L. Fan, "An Enhanced Support Vector Machine Model for Intrusion Detection," pp. 538-543, 2006.

[30] H. H. Gao, H. H. Yang, and X.Y.Wang, "Principal Component Neural Networks Based Intrusion Feature Extraction and Detection Using SVM," pp. 21-27, 2005.

[31] G. Xiaoqing, G. Hebin, and C. Luyi, "Network Intrusion Detection Method Based on Agent and SVM," pp. 1-4, 2010.

[32] M. K. Asif, T. A. Khan, and S. Yakoob, "Network Intrusion Detection and its Strategic Importance," pp. 140-144, 2013.

[33] S. A. Mulay, P. R. Devale, and G. V. Garje, "Intrusion Detection System using Support Vector Machineand Decision Tree," vol. 3, pp. 40-43, 2010.

[34] S. Mike, "Network Security Principles and Practices, Chapter 14," 2002

[۳۵] م. میرزائی و م. رحمانی، ”تشخیص رخنه در شبکه‌های رایانه‌ای با رگرسیون بردار پشتیبان،“ نوآوری در مهندسی کامپیوتر و فناوری، تنکابن، ۱۳۹۲، ۷ صفحه.

[۳۶] ت. کریمی و م. صادقی مقدم، مجموعه‌های راف و مجموعه‌های خاکستری(مبانی، کاربرد، نرمافزار)، تهران: موسسه کتاب مهریان نشر، تابستان ۱۳۹۳، ۱۶۶ صفحه.

[۳۷] م. میرزائی و م. رحمانی، ”بررسی معماری‌های سرویس