

## Precision Improvement of Intrusion Detection System using feature reduction based on Fuzzy Rough Set and Ensemble Classifiers

A. Nasabolhosseini<sup>1</sup>, J. Hamidzadeh<sup>2\*</sup>

1- Faculty of Computer Engineering and Information Technology, Sadjad University of Technology, No. 64  
Jalal Al Ahmad St, Mashhad, Iran.

2\*- Faculty of Computer Engineering and Information Technology, Sadjad University of Technology, No. 64  
Jalal Al Ahmad St, Mashhad, Iran.

<sup>1</sup> a.nasab105@sadjad.ac.ir, <sup>2\*</sup> j\_hamidzadeh@sadjad.ac.ir

Corresponding author address: J. Hamidzadeh, Faculty of Computer Engineering and Information Technology, Sadjad University of Technology, Mashhad, Iran, Post Code: 91881 – 48848.

**Abstract-** In today's world, protecting data against intrusion through the Internet or network is necessary, and various tools have been proposed in this field. Intrusion Detection System has the task of identifying and detecting any unauthorized use of data by investigating network traffic. In these systems, many different methods, especially machine learning algorithms, is used. Various approaches have been proposed to improve these algorithms in the intrusion detection process. Some of these approaches include reducing false alarms, reducing dimensionality, reducing samples, ensemble methods, improving training and test dataset, applying multilevel methods, etc. Some of the ensemble methods proposed by researchers do not consider all aspects of the attack. Some other methods use accuracy metric, which in large and unbalanced data, this criterion makes the detection of low-number attacks difficult. One of the challenges in intrusion detection is the low precision of classifiers in identifying the type of network attacks. The purpose of this paper is to propose an intrusion detection system to improve the precision by using fuzzy rough set theory and weighted classifiers ensemble. In our proposed method, after reducing the features by the fuzzy rough set theory, the classifiers ensemble is used to improve the precision of attack detection. The precision of the proposed method in detecting intrusion behavior assaults was 98.93 on average. Also, on average, the detection rate of DoS, probe, R2L, U2R attacks and normal behavior was 96.85, 93.20, 91.31, 100% and 98.14 respectively. The results of the experiments show that the proposed method has more precision than other methods.

**Keywords-** Intrusion Detection System, Feature Reduction, Ensemble Classifiers, Precision Measure, Fuzzy Rough Set.

## بهبود دقت سامانه تشخیص نفوذ به کمک کاهش ویژگی بر اساس مجموعه فازی ناهموار و ترکیب طبقه‌بندها

سید عادل نسب‌الحسینی<sup>۱</sup>، جواد حمیدزاده<sup>۲\*</sup>

۱- دانشکده مهندسی کامپیوتر و فناوری اطلاعات، دانشگاه صنعتی سجاد، مشهد، ایران.  
۲\* - دانشکده مهندسی کامپیوتر و فناوری اطلاعات، دانشگاه صنعتی سجاد، مشهد، ایران.  
<sup>۱</sup>a.nasab105@sadjad.ac.ir, <sup>۲\*</sup>j.hamidzadeh@sadjad.ac.ir

\* نشانی نویسنده مسئول: جواد حمیدزاده، مشهد، خیابان جلال‌آل احمد ۶۴، دانشگاه صنعتی سجاد، دانشکده مهندسی کامپیوتر و فناوری اطلاعات، کدپستی: ۹۱۸۸۱-۴۸۸۴۸

چکیده- در دنیای امروز، محافظت از داده‌ها در مقابل نفوذ از طریق اینترنت یا شبکه، امری ضروری است و ابزارهای مختلفی در این زمینه ارائه شده‌است. سامانه تشخیص نفوذ با بررسی ترافیک شبکه وظیفه شناسایی و تشخیص هرگونه استفاده غیرمجاز از داده‌ها را دارد. در این سامانه‌ها از روش‌های متعددی به ویژه الگوریتم‌های یادگیری ماشین بهره‌گیری می‌شود و رویکردهای مختلفی از جمله کاهش هشدارهای غلط، کاهش ابعاد، کاهش نمونه‌ها، روش‌های ترکیبی، به‌سازی دادگان آموزشی و آزمون، به‌کارگیری روش‌های چند سطحی و غیره به‌منظور بهبود این الگوریتم‌ها در فرآیند تشخیص نفوذ ارائه شده‌است. برخی از رویکردهای ترکیبی ارائه شده توسط محققان، کلیه جنبه‌های حمله را مورد نظر قرار نمی‌دهد. بعضی از روش‌ها نیز از معیار صحت استفاده می‌کنند که این معیار در داده‌های حجیم و نامتوازن باعث ضعف در تشخیص حمله‌های با تعداد نمونه‌های بسیار کم می‌گردد. یکی از چالش‌ها در تشخیص نفوذ، دقت پایین طبقه‌بندها در شناسایی نوع حملات شبکه است. هدف از این تحقیق، پیشنهاد یک سامانه برای بهبود دقت در تشخیص نفوذ با استفاده از نظریه مجموعه فازی ناهموار و ترکیب وزن دار طبقه‌بندها است. در روش پیشنهادی ما، پس از کاهش ویژگی‌ها توسط نظریه مجموعه فازی ناهموار، از ترکیب طبقه‌بندها برای بهبود دقت در تشخیص حملات استفاده شده‌است. دقت روش پیشنهادی در شناسایی رفتار حمله به طور میانگین به ۹۸/۹۳ رسید و همچنین به طور میانگین میزان شناسایی رفتار عادی ۹۸/۱۴، حمله‌های منع سرویس ۹۶/۸۵ و حمله‌های پویس ۹۳/۲۰ حمله‌های دسترسی از راه دور ۹۱/۳۱ و حمله‌های کاربر به ریشه ۱۰۰ به دست آمد. نتایج حاصل از انجام آزمایش‌ها نشان دهنده برتری روش پیشنهادی نسبت به سایر روش‌های موجود است.

**واژه‌های کلیدی:** سامانه تشخیص نفوذ، کاهش ویژگی، ترکیب طبقه‌بندها، معیار دقت، مجموعه فازی ناهموار.

### ۱- مقدمه

شبکه را به خطر بیندازد و یا کارهایی که منجر به شروع یک خراب‌کاری در شبکه یا رایانه شود؛ مانند شناسایی اولیه اطلاعات در مرحله جمع‌آوری داده به کمک پویس درگاه‌های<sup>۳</sup> رایانه توسط مهاجم که در نهایت منجر به آسیب رساندن به رایانه یا شبکه می‌شود. یک ویژگی مهم سامانه‌های تشخیص نفوذ توانایی آن‌ها در نمایش فعالیت‌های غیرعادی در شبکه است. به عنوان مثال پس از کشف تلاش کاربران برای ورود به محیط‌های غیرمجاز توسط سامانه تشخیص نفوذ، در اولین فرصت هشدارهای لازم به مدیر سایت<sup>۴</sup>

نظر به کاربرد روزافزون شبکه و اینترنت در سراسر جهان میزان آسیب‌پذیری سامانه‌های رایانه‌ای نیز رو به افزایش است. لذا به‌منظور کاهش مخاطرات امنیتی در حوزه فناوری اطلاعات، سامانه‌های تشخیص نفوذ<sup>۱</sup> و جلوگیری از نفوذ<sup>۲</sup> به کمک بشر می‌شتابند. سامانه تشخیص نفوذ یک سامانه دفاعی است که فعالیت‌های مخرب در یک شبکه رایانه‌ای را آشکار می‌کند. در واقع مهم‌ترین مسئله در این سامانه‌ها شناسایی فعالیت‌هایی است که احتمال می‌رود امنیت

مدعی هستند که روش آنها نسبت به سایر روش‌ها برتری دارد. اما در دنیای واقعی برنامه‌ها، میزان صحت هر الگوریتم دارای نوسانات و تغییرات است به عنوان مثال در برخی از موارد ممکن است نتایج یک الگوریتم خیلی خوب یا مناسب نباشد و درجایی دیگر و شرایطی دیگر کاملاً مناسب است که علت آن مربوط به محدودیت‌های ذاتی الگوریتم‌های یادگیری ماشین است و در واقع هیچ روشی در تمام جنبه‌ها از سایر روش‌ها بهتر نخواهد بود. از این رو به منظور به دست آوردن نتایج بهتر، از ترکیب چندین روش و الگوریتم، بهره‌گیری می‌شود.

با توجه به حجم بسیار بالا و غیرتکراری جریان داده‌ها در شبکه استفاده از تمامی ویژگی‌های داده باعث می‌شود که فرآیند تشخیص حملات زمان‌بر شده و کارایی سامانه کاهش یابد. روش‌های مختلفی به منظور کاهش زمان و حجم پردازش و بهبود کارایی این سامانه‌ها توسط محققان پیشنهاد شده است. یکی از روش‌های پیشنهادی کاهش ابعاد بسته‌های اطلاعاتی است. با در نظر گرفتن ابعاد فضای ویژگی<sup>۱۶</sup> در دادگان<sup>۱۷</sup> NSL-KDD که منجر به اشغال منابع زیادی می‌شود در گام اول باید نسبت به کاهش ویژگی‌های موجود اقدام شود [۱۲].

در روش پیشنهادی، با حذف ویژگی‌های غیرضروری به کمک مجموعه فازی ناهموار نسبت به کاهش ابعاد دادگان اقدام نموده و پس از کاهش بار پردازشی، با ترکیب وزن‌دار چندین طبقه‌بند، دقت تشخیص را بهبود دادیم. ساختار ادامه مقاله به شرح ذیل است: در بخش دوم کارهای مرتبط پیشین بررسی شده است. در بخش سوم روش پیشنهادی و قسمت‌های مختلف الگوریتم‌های آن تشریح شده است. نتایج آزمایش‌ها، تحلیل و پیش‌پردازش دادگان به کار رفته در روش پیشنهادی مقاله در بخش چهارم ارائه شده است. نحوه ارزیابی در بخش پنجم توضیح داده شده است و در بخش ششم نتیجه‌گیری و پیشنهادهایی برای کارهای آینده مطرح شده است.

## ۲- کارهای انجام شده

در این روزها بسیاری از محققان برای توسعه سامانه‌های تشخیص نفوذ تلاش می‌کنند. از این رو الگوریتم‌های فراوانی از جمله داده‌کاوی، یادگیری ماشین، نظریه اطلاعات، محاسبات نرم، روش‌های آماری و غیره برای بهبود عملکرد IDS ارائه شده است. در اکثر روش‌ها به منظور کاهش زمان و بار محاسباتی، قبل از اجرای الگوریتم اصلی پیش‌پردازی انجام می‌شود. کاهش ابعاد دادگان یکی از موثرترین روش‌ها به منظور بهبود اجرای الگوریتم‌ها است.

ارسال خواهد شد. علاوه بر آن یک سامانه تشخیص نفوذ این توانایی را دارد که بتواند حملات و یا نفوذهایی که از داخل و یا خارج از یک سازمان به شبکه آن انجام می‌شود را شناسایی نماید. سه نوع سامانه تشخیص نفوذ در شبکه‌های رایانه‌ای مورد استفاده قرار می‌گیرد:

۱- سامانه‌های تشخیص نفوذ مبتنی بر میزبان<sup>۵</sup>  
این نوع سامانه اطلاعات جمع‌آوری شده از یک میزبان شامل ساختار فایل و رفتار برنامه‌های خاص را تحلیل می‌کند [۹، ۱۰].

۲- سامانه تشخیص نفوذ مبتنی بر شبکه<sup>۶</sup> (متمرکز)  
این سامانه داده‌های ترافیک شبکه را برای تشخیص رفتارهای مشکوک مانند حمله‌های منع سرویس<sup>۷</sup>، پویش درگاه‌ها و یا حتی حمله برای نفوذ به رایانه‌ها را تحلیل می‌کند بدین منظور جهت شناسایی نفوذ آدرس آی‌پی<sup>۸</sup> و سرآیند<sup>۹</sup> لایه انتقال همه بسته‌های داده توسط NIDS کنترل می‌شود [۱۰]. در این سامانه کل سربرار تحلیل داده‌ها بر عهده ایستگاه پایه می‌باشد.

۳- سامانه تشخیص نفوذ توزیع شده<sup>۱۰</sup> که در آن از ترکیب دونوع قبلی HIDS و NIDS- استفاده می‌شود و به نوعی بار پردازشی بر روی رایانه‌های درون شبکه توزیع می‌شود. این نوع سامانه انرژی زیادی در کل شبکه مصرف می‌کند.

به طور کلی سه روش مختلف برای تشخیص حملات در سامانه‌های تشخیص نفوذ وجود دارد:

۱- تشخیص مبتنی بر امضاء<sup>۱۱</sup> (در برخی از مقالات با عنوان تشخیص سوءاستفاده از آن نام برده شده است)

در این روش، حمله‌های شناخته شده -یعنی حمله‌هایی که تاکنون حداقل یک بار انجام شده‌اند- به راحتی از روی الگوی تعریف شده آن‌ها قابل شناسایی‌اند اما نقطه ضعف این روش عدم تشخیص حمله‌های ناشناخته یا همان حمله روز صفر<sup>۱۲</sup> است.

۲- تشخیص رفتار غیرعادی<sup>۱۳</sup> (در برخی از مقالات با عنوان تشخیص ناهنجاری از آن نام برده شده است)

در این روش الگوی رفتارهای غیرحمله برای سامانه تعریف می‌شود و رفتارهای غیر از آن به عنوان حمله شناسایی می‌شوند. نقطه ضعف این روش نیز در تولید حد بالایی از هشدارهای اشتباه<sup>۱۴</sup> است.

۳- روش‌های ترکیبی<sup>۱۵</sup> که در واقع از هر دو روش اول و دوم به صورت هم‌زمان استفاده می‌کند [۱۱]. در واقع ترکیب دو روش نتیجه بهتری در بردارد اما هزینه محاسباتی زیادی را به سامانه تحمیل می‌کند [۱۰].

با توجه به شرایط مختلف شبکه محلی موردنظر یکی از سه روش بالا مورد استفاده قرار می‌گیرد.

در سال‌های اخیر الگوریتم‌های زیادی مبتنی بر یادگیری ماشین به منظور شناسایی حملات استفاده شده است و هر یک از الگوریتم‌ها

## ۲-۱- کاهش ویژگی

در مقاله [۱۳]، روشی با عنوان انتخاب نمونه حاشیه ترکیب<sup>۱۸</sup> ارائه شده است. در این مقاله نشان داده شده است که برای استفاده از دادگان بزرگ در الگوریتم‌های یادگیری ماشین، به پیش‌پردازش و حذف نمونه‌های غیرضروری نیاز است. در این مقاله به منظور کاهش بار سیستم از پردازش دادگان، از الگوریتم جنگل تصادفی استفاده شده است. روش پیشنهادی آن‌ها قادر بود تا دادگان بزرگ را با یک زمان پردازش معقول و تاثیر بسیار ناچیز در بازدهی طبقه‌بندی، کوچک‌سازی کند. نویسندگان در مقاله [۱۴]، یک روش انتخاب ویژگی را برای سیستم‌های تشخیص نفوذ با استفاده از دادگان NSL-KDD ارائه کردند. در مقاله [۱۵]، دادگان NSL-KDD را برای سیستم تشخیص نفوذ با روش مبتنی بر الگوریتم‌های دسته‌بندی تحلیل نمودند.

در مقاله [۱۶]، روش خوشه‌بندی K-means را که از رویکرد مبتنی بر امضاء تبعیت می‌کند به منظور کاهش نرخ منفی غلط<sup>۱۹</sup>، در سیستم‌های تشخیص نفوذ ارائه نمودند.

مقاله [۱۷] تشخیص نفوذ از روی شناسایی رفتار غیرعادی را توسعه داده و روش جدیدی جهت محاسبه خارج از محدوده<sup>۲۰</sup> به همین نام (روش شناسایی خارج از محدوده) ارائه نموده است. نویسندگان این مقاله سعی کردند تا دقت مداوم شناسایی حملات کم تکرار را افزایش دهند.

در مقاله [۱۸] روشی را به نام OS-ELM<sup>۲۱</sup> ارائه نمودند و مشکلات امنیتی زیادی از جمله حجم دادگان ترافیک شبکه، انتخاب ویژگی، صحت پایین تشخیص و نرخ بالای هشدارهای غلط را جهت ارزیابی نتایج مدنظر قرار دادند. در مقاله [۱۹] معیارهای فاصله و تشابه را در تشخیص رفتارهای غیرعادی شبکه مورد بررسی قرار دادند.

در مقاله [۲۰] الگوریتم کاهش ویژگی تعمیم یافته‌ای با استفاده از نظریه مجموعه فازی ناهموار ارائه شد که خصوصیات داده‌ها و نیازهای کاربر در کاربردهای واقعی را به صورت هم‌زمان در نظر می‌گرفت. نویسندگان در این مقاله نشان دادند که شاخص تعیین‌کننده کاهش ویژگی باید به هر دو موضوع داده‌ها و خواسته‌های کاربر مرتبط باشد.

در مقاله [۲۱] روشی با عنوان سیستم تشخیص نفوذ شبکه عصبی محرمانه (CNN-IDS)<sup>۲۲</sup> ارائه شد. در ابتدا ویژگی‌های اضافی و بی‌ربط از داده‌های ترافیک شبکه با استفاده از روش‌های کاهش ابعاد مختلف حذف شدند. نویسندگان از روش یادگیری با ناظر استفاده نمودند. آنها به منظور کاهش هزینه محاسبات حالت بردار ترافیک اصلی را به حالت تصویری تبدیل نمودند. آنها از دادگان KDD-CUP99 جهت ارزیابی بازدهی روش پیشنهادی در آزمایش‌های خود

استفاده نمودند. نتایج آزمایش‌ها بهبود صحت و نرخ هشدارهای غلط را نسبت به الگوریتم‌های سنتی نشان داد. داده‌های ورودی مناسب برای روش آنها داده‌های دوبعدی بود.

## ۲-۲- ترکیب طبقه‌بندها

در مقاله [۲۲] یک روش ترکیبی دوسطحی برای تشخیص نفوذ ارائه شده است که به صورت بالقوه امکان شناسایی حمله‌های شناخته‌شده و ناشناخته را با نرخ پایینی از مثبت‌های غلط<sup>۲۳</sup> دارد. در مقاله [۲۳] یک سیستم تشخیص نفوذ چند سطحی برای تشخیص رفتارهای غیرعادی شبکه ارائه شده است. در مقاله [۲۴] الگویی از برنامه‌ریزی عدد صحیح<sup>۲۴</sup> موسوم به (IWIRI)<sup>۲۵</sup> ارائه شد. این روش می‌تواند هنگامی که داده‌های جدید اضافه می‌شود بدون نیاز به محاسبه مجدد کل دادگان، کمترین تعداد قوانین ویژگی را برای تصمیم‌گیری پیدا نموده و تجمیع وزن ویژگی‌ها و تناوب اشیا برای جستجوی قوانین بهینه در حالتی که اشیا اضافه شود را محاسبه کند؛ الگوریتم پیشنهادی این مقاله نیازمند این بود که جدول داده‌ها کامل و بدون کسر مقادیر ویژگی‌های شرط<sup>۲۶</sup> باشد.

در مقاله [۲۵] یک سیستم جدید تشخیص نفوذ شبکه ترکیبی چند سطحی ارائه شد که از ترکیب الگوریتم‌های ماشین‌بردار پشتیبان<sup>۲۷</sup> و ماشین‌یادگیری بی‌نهایت<sup>۲۸</sup> جهت کاهش نرخ FA و بهبود صحت تشخیص بهره می‌برد.

نویسندگان مقاله به منظور ارزیابی میزان کارایی مدل خود از الگوریتم ELM پایه و الگوریتم خوشه‌بندی K-means اصلاح‌شده بر روی دادگان KDD cup 1999 استفاده کردند و نشان دادند که روش پیشنهادی آن‌ها به طرز رضایت‌بخشی بازدهی بالاتری نسبت به الگوریتم‌های SVM و ELM چند سطحی داشته است.

در مقاله [۲۶] روش جدیدی از ترکیب الگوریتم انتخاب ویژگی با استفاده از ماشین بردار پشتیبان چندکلاسه و نزدیک‌ترین همسایه K ام ارائه شد نویسندگان مقاله جهت بهبود عملکرد روش خود از الگوریتم بهینه‌سازی ازدحام ذرات افزایشی<sup>۲۹</sup> استفاده کردند. هدف آن‌ها بهبود صحت طبقه‌بندی سامانه تشخیص نفوذ بود و برای اجرای آزمایش‌ها از پنج زیرمجموعه تصادفی دادگان KDD Cup99 استفاده کردند. آن‌ها همچنین بر انتخاب ویژگی چند سطحی در بخش پیش‌پردازش دادگان تمرکز نمودند.

در مقاله [۲۷] روشی برای تشخیص نفوذ از ترکیب طبقه‌بندها همراه با الگوریتم خفاش ارائه شد. نویسندگان از زیرمجموعه‌های تصادفی ماشین یادگیری بی‌نهایت به عنوان طبقه‌بند پایه استفاده نمودند و به منظور بهبود نتایج از یک روش مبتنی بر الگوریتم خفاش جهت هرس ترکیب استفاده کردند. آن‌ها جهت بهبود طبقه‌بند در الگوریتم خفاش از یک تابع تناسب مبتنی بر صحت و تنوع استفاده کردند و

عمیق استفاده شد. آنها یک الگوریتم رای‌گیری انطباقی به نام درخت چندگانه ارائه نمودند و به منظور بهبود نتایج شناسایی حملات از روش رای‌گیری استفاده نمودند و دریافتند که کیفیت ویژگی‌های داده عامل مهمی برای تعیین اثر تشخیص است. آنها از دادگان NSL-KDD در آزمایش‌های خود استفاده نمودند و موفق شدند صحت الگوریتم نهایی رای‌گیری را به ۸۵/۲ برسانند.

نویسندگان مقاله [۸] یک الگوی تشخیصی برای حملات شناخته‌شده و ناشناخته از طریق روشی جدید و غیرپارامتری بیزی ارائه کردند. طرح آنها با عنوان (InBGG-Fs) [۲۶] به سادگی قابل تعمیم به فناوری اینترنت اشیا و به‌ویژه مناسب جهت برنامه‌های تحت وب شهر هوشمند بود. در روش آنها یادگیری از روی الگوی فعالیت‌های عادی و حمله از طریق استنتاج مبتنی بر الگوریتم بیز بر روی مدل ترکیبی تعمیم‌یافته گاوسی با کران نامحدود انجام می‌شد. در روش آنها به منظور خوشه‌بندی بهتر وزن ویژگی‌ها، پارامترهای مدل و تعداد خوشه‌ها بصورت هم‌زمان سنجیده می‌شد. آنها از انتخاب ویژگی در روش خود استفاده نموده و روش را توسط چند دادگان از جمله KDDCup'99 بررسی کردند. نتایج به دست آمده نشان از کارایی روش در تشخیص حملات مختلف داشت. یکی از معیارهای ارزیابی روش معیار صحت (Accuracy) بود که میزان صحت شناسایی حملات روش آنها ۸۴/۰۶ درصد بود.

### ۲-۳- جمع‌بندی

در سال‌های اخیر الگوریتم‌های فراوانی مبتنی بر روش‌های تشخیص ناهنجاری و سوءاستفاده به‌منظور شناسایی حملات استفاده شده است. هر یک از الگوریتم‌ها در شرایط خاصی، خروجی و نتیجه بهتری را نسبت به سایر روش‌ها در تشخیص نفوذ داشته است البته در دنیای واقعی میزان صحت هر الگوریتم دارای نوسانات و تغییراتی است که دلیل آن محدودیت‌های ذاتی الگوریتم‌های یادگیری ماشین است و هیچ روشی در تمامی جنبه‌ها از سایر روش‌ها بهتر عمل نکرده است پس کافیست به‌منظور به دست آوردن نتایج بهتر از ترکیب چندین الگوریتم و روش بهره‌گیری شود تا از برآیند نتایج آنها و همچنین نقاط قوت هر برنامه در شرایط خاص آن استفاده گردد. همچنین با توجه به کارهای انجام‌شده گذشته، استفاده از داده‌ها در آموزش و آزمایش طبقه‌بندها بدون پیش‌پردازش، نه تنها حجم و زمان پردازش را افزایش خواهد داد بلکه ممکن است باعث افت نتیجه خروجی در آنها گردد. لذا با پیش‌پردازش مناسب می‌توان تنها از نمونه‌ها و ویژگی‌های موردنیاز در دادگان استفاده نمود و نتایج بهتر را در زمان کمتری به دست آورد [۲۹].

برای انجام آزمایش‌ها از سه دادگان عمومی KDD99، NSL-KDD و Kyoto استفاده کردند. نتایج آنها نشان می‌داد که زیرمجموعه‌های تصادفی، قدرت و صحت شناسایی به‌وسیله الگوریتم ELM ارائه شده را بهبود داده است.

در مقاله [۶] سامانه تشخیص نفوذ شبکه مبتنی بر ترکیب طبقه‌بندها ارائه شد. هدف نویسندگان بهبود صحت طبقه‌بندی بود. آنها نشان دادند که اگر میانگین مقدار بهره اطلاعاتی<sup>۲۷</sup> بین ویژگی‌هایی که در ترکیب قرار گرفته‌اند بین ۰/۴۵ تا ۰/۲۵ باشد آنگاه میزان صحت طبقه‌بندی ترکیب حداکثر ۰/۹ خواهد بود. آنها سیستم تشخیص نفوذ شبکه مبتنی بر الگوریتم Adaboost ارائه نمودند و هدف آنها یافتن راهی بود که به کمک آن قبل از پیاده‌سازی روش بتوانند میزان بهبود صحت تشخیص حملات را تخمین بزنند. آنها از دادگان NSL-KDD برای اجرای آزمایش‌های خود استفاده کردند و مرز بین رفتار عادی با حمله Neptune را به کمک ترکیب طبقه‌بندها تعیین نمودند. روش آنها در واقع جامع نبود و نمی‌توانست تخمینی از سایر حمله‌ها ارائه نماید و معیار موردنظر در این روش نیز صحت تشخیص بود.

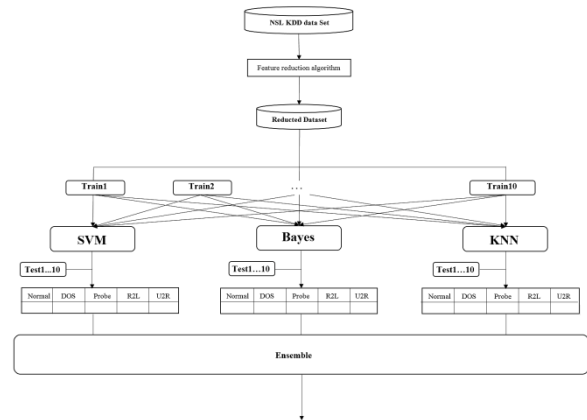
به‌تازگی در مقاله [۷] روشی ارائه شد که در آن از الگوریتم‌های شبکه‌های عصبی، درخت تصمیم و رگرسیون محاسباتی جهت تشخیص رفتار غیرعادی بر روی شبکه‌های کامپیوتری استفاده می‌شد. نویسنده مقاله به‌منظور تقویت عملکرد روش، الگوریتم‌ها را با یکدیگر ترکیب نموده و از رویکرد رای اکثریت جهت افزایش صحت تشخیص طبقه‌بندی بر روی مجموعه‌های تصادفی از دادگان KDD Cup99 استفاده نمود؛ اما روش او صرفاً توانایی طبقه‌بندی داده‌ها را در ۲ کلاس حمله و عادی داشت.

در مقاله [۲۸] از ترکیب طبقه‌بندها برای تشخیص نفوذ شبکه مبتنی بر رفتار غیرعادی در حالت با ناظر استفاده شد. تمرکز روش نویسندگان بر روی مشکلات ترکیب طبقه‌بندهای یادگیری ماشین در حالت‌های مختلف بود. آنها برای بهبود نتایج از ۵ الگوریتم استفاده کرده و میزان عملکرد طبقه‌بندها و توانایی یادگیری آنها را روی دادگان UNSW و NB15 مورد تحلیل و بررسی قرار دادند. آنها از معیارهای صحت و ROC جهت ارزیابی روش خود استفاده نمودند. آزمایش‌های آنها در نرم‌افزار متلب ۲۰۱۵ اجرا شد و رفتار طبقه‌بندها بیشتر در حوزه شناسایی ناهنجاری در شبکه مورد مقایسه و ارزیابی قرار گرفت. طبق نتایج آنها الگوریتم‌های bagged tree و gentle boost بالاترین و الگوریتم rusboost کمترین نرخ صحت و ROC را به دست آوردند.

در مقاله [۵] یک روش یادگیری ترکیبی تطبیقی ارائه شد و از الگوریتم‌های درخت تصمیم، ماشین بردار پشتیبان، رگرسیون منطقی نزدیک ترین همسایه K ام، جنگل تصادفی و شبکه عصبی

### ۳- مدل پیشنهادی

در شکل شماره ۱ طرح کلی الگوریتم پیشنهادی ارائه شده است. در اجرای این پروژه ابتدا دادگان ورودی توسط الگوریتم کاهش ویژگی به یک مجموعه داده با صفات کمتر تبدیل شد. سپس دادگان جدید جهت طبقه‌بندی به پنج طبقه‌بند از سه نوع مختلف داده شد. در مدل پیشنهادی از ترکیب پنج طبقه‌بند SVM، Bayes، با هسته هرمیت [۳۰]، SVM(RBF)، 3-NN و 7-NN استفاده شده است. میزان وزن هر الگوریتم بر اساس نتایج شناسایی در مراحل آموزش محاسبه شد. توضیح اینکه در شکل ارائه شده به دلیل کمبود فضا فقط سه نوع الگوریتم نمایش داده شده است و امکان نمایش پنج طبقه‌بند وجود نداشت. به منظور تست کامل الگوریتم‌ها توسط دادگان، آموزش طبقه‌بندها به روش 10-fold cross validation انجام شد.



شکل ۱: ساختار کلی الگوریتم پیشنهادی

### ۳-۱- کاهش ابعاد

پژوهش‌ها در حوزه کاهش ویژگی‌ها نشان داده است که انتخاب مجموعه‌ای کمتر از ویژگی‌های اولیه ضمن کاهش بار پردازشی و افزایش سرعت اجرای برنامه‌ها، سبب بهبود نتایج در الگوریتم‌های یادگیری ماشین می‌شود [۲۱].

نظریه مجموعه ناهموار<sup>۳۲</sup> در سال ۱۹۸۰ توسط آقای پاولاک پیشنهاد شد [۳۱]. این دیدگاه به‌نوعی توسعه مفهوم نظریه مجموعه‌ها برای مطالعه بر روی سامانه‌های هوشمندی است که در آن‌ها عدم قطعیت و ابهام وجود دارد [۳۲]. یکی از مهم‌ترین ویژگی‌های این نظریه یافتن مجموعه کمینه از داده‌ها است که برای طبقه‌بندی مفید است (مانند کاهش ابعاد و تعداد اطلاعات). روش‌های مبتنی بر این نظریه پس از تحلیل اطلاعات پنهان در داده‌ها، اطلاعات غیرمرتبط از مجموعه دادگان را حذف می‌نمایند. اطلاعات ورودی فازی ناهموار به‌صورت جدول‌های ویژگی و مقدار در اختیار است.

اگر جدول T را به‌صورت  $T(U, A, C, D)$  در نظر بگیریم به‌گونه‌ای که:  $U$  مجموعه اشیا،  $A$  ویژگی‌ها،  $C$  ویژگی‌های شرطی و  $D$  ویژگی‌های تصمیم‌گیری باشند و  $C, D \subseteq A$  برای هر مجموعه ویژگی  $P$  زیرمجموعه  $A$  رابطه تفکیک‌ناپذیری به‌صورت زیر تعریف می‌شود:

$$IND(P) = \{(x, y) \in U \times U : \forall a \in P, a(x) = a(y)\} \quad (1)$$

حال اگر  $X \subseteq U$  و  $P \subseteq C$  باشند تقریب بالا و پایین  $X$  با توجه به  $P$  مساوی است با:

$$\underline{P}X = \{x \in U : [x]_{IND(P)} \subseteq X\} \quad (2)$$

$$\overline{P}X = \{x \in U : [x]_{IND(P)} \cap X \neq \emptyset\} \quad (3)$$

درجایی که

$$[x]_{IND(P)} = \{y \in U : a(y) = a(x), \forall a \in P\} \quad (4)$$

کلاس هم‌ارزی  $x$  در  $IND(P)$  باشد.

منطقه مثبت  $P$  از  $D$  مجموعه‌ای از اشیا مجموعه جهانی  $U$  است که می‌توانند به یک کلاس خاص از  $IND(P)$  تعلق داشته و ویژگی‌هایی از  $P$  را در خود داشته باشند. مطابق فرمول ذیل به دست می‌آید.

$$POS_P(D) = \bigcup_{x \in U} \underline{P}x \quad (5)$$

و مقدار وابستگی  $D$  روی  $P$  به‌صورت زیر محاسبه می‌شود:

$$\gamma_P(D) = \frac{|POS_P(D)|}{|U|} \quad (6)$$

ویژگی  $a \in C$  در مجموعه  $P$  غیرضروری گوئیم هرگاه

$$\gamma_P(D) = \gamma_{P-a}(D) \quad (7)$$

در غیر این صورت این ویژگی با توجه به  $D$  روی مجموعه  $P$  ضروری است؛ و یک مجموعه دلخواه  $B \subseteq C$  ضروری است اگر تمام ویژگی‌های آن ضروری باشد [۳۳].

از تعاریف بالا یک مجموعه کمینه از ویژگی‌ها به‌صورت ذیل تعریف می‌شود:

یک مجموعه از ویژگی‌ها  $R \subseteq C$  مجموعه کمینه  $C$  خواهد بود اگر  $R$  مستقل بوده و  $POS_C(D) = POS_R(D)$  به‌عبارت‌دیگر، مجموعه کمینه مجموعه‌ای از ویژگی‌هایی است که بخش‌های مختلف ایجادشده توسط  $C$  را پوشش دهد.

### ۳-۲- الگوریتم کاهش ویژگی

فرض کنیم سامانه اطلاعاتی به صورت  $IS = (U, W, A, V, F)$  تعریف شده است [۳۴].  $U$  و  $W$  مجموعه‌های محدود عمومی باشند.  $A$  ویژگی‌ها،  $V$  کلاس‌ها و  $F$  یک تابع از  $U$  به مجموعه توانی از  $W$  باشد.

گام اول: خواندن ویژگی  $A$  از  $U$  و  $W$

گام دوم: محاسبه  $IND(B)$

گام سوم: محاسبه  $(D_k) * IND(B)$  برای هر  $U/D \in D_k$

طبقه‌بندها را می‌توان به دو روش ادغام و انتخاب با یکدیگر ترکیب نمود. در حالت ادغام پس از آموزش و انجام آزمون هر یک از طبقه‌بندها، با وزن‌دهی به آن‌ها میزان تأثیر آن طبقه‌بند را در تصمیم‌گیری نهایی مشخص می‌کنیم. در حالت انتخاب از برآیند خروجی یا همان رأی اکثریت چند طبقه‌بند جهت تصمیم‌گیری استفاده می‌کنیم. در روش پیشنهادی این مقاله نخست میزان دقت هر یک از طبقه‌بندها را به صورت مجزا محاسبه نموده و جهت رأی‌گیری نهایی ترکیب، به هر طبقه‌بند یک وزن اختصاص می‌دهیم بر این اساس ترکیب طبقه‌بندهای مورداستفاده در سامانه گروهی از نوع قابل‌آموزش<sup>۳۵</sup> است [۳۵]. الگوریتم‌های مورد استفاده در روش پیشنهادی شامل SVM، KNN و Bayes هستند. در این مقاله از ترکیب در سطح داده و ترکیب در سطح طبقه‌بندی استفاده شده است [۳۵].

#### ۴- دادگان

با توجه به پیشرفت‌های روزافزون فناوری اطلاعات، حجم پردازش و تحلیل داده‌ها افزایش یافته‌است. الگوریتم‌های یادگیری ماشین مانند ماشین‌های بردارپشتیبان، نزدیک‌ترین همسایه K ام<sup>۳۶</sup>، شبکه‌های عصبی مصنوعی و غیره راه‌حل مؤثری برای سازمان‌دهی و استخراج داده‌های مفید از داده‌های موجود فراهم نموده‌اند. روش‌های موجود قادر به کار کردن با حجم وسیع داده‌ها در زمان پردازشی معقول نیستند [۱۳].

در سامانه تشخیص نفوذ دادگان KDD cup 99 به‌عنوان اولین دادگان توسط بسیاری از محققان مورداستفاده قرار گرفت. [۳۶] این دادگان متشکل از ۷ هفته آموزش<sup>۳۷</sup> و دو هفته آزمایش<sup>۳۸</sup> داده‌های ترافیک شبکه به کمک نرم‌افزار Tcpdump data بوده و در مجموع دارای ۷ میلیون رکورد است [۳۷]. اما حجم بسیار بالای این دادگان باعث شد تا به منظور کاهش زمان و بارپردازشی الگوریتم‌ها، دادگانی با حجم کمتر از روی آن تحت عنوان NSL-KDD ایجاد نمایند. در اجرای روش پیشنهادی این مقاله از دادگان NSL-KDD<sup>۳۹</sup> [۳۸] استفاده شد. تعداد نمونه‌های این دادگان ۱۲۵۹۷۳ رکورد است. با توجه به جداول شماره ۱، ۲ و ۳، به دلیل وجود ۴۱ ویژگی و همچنین ۴۰ کلاس مختلف در ابتدا دادگان می‌بایست مورد پیش‌پردازش<sup>۴۰</sup> قرار می‌گرفت. در جداول شماره ۲ و ۳ لیست ویژگی‌ها و کلاس‌های دادگان مورداستفاده نشان داده شده است.

#### ۴-۱- پیش‌پردازش

مطابق با جداول شماره ۱ و ۲ تعداد کلاس‌ها در این دادگان ۴۰ عدد است که یک کلاس رفتار عادی یا همان رفتار غیرحمله و ۳۹

گام چهارم: محاسبه ماتریس  $C_{ij}$  برای پارامترهای تصمیم‌گیری گام پنجم: تشکیل ویژگی‌های کلیدی با استفاده از هسته گام ششم: حذف آیتم‌هایی که مقدار  $C_{ij}$  آن‌ها مساوی NULL است. یا بدون هم‌پوشانی غیر صفر با هسته گام هفتم: تعیین کردن  $f_D$  (IS) گام هشتم: محاسبه  $g_D$  (IS) با استفاده از  $f_D$  (IS) گام نهم: یافتن مجموعه کمینه ویژگی‌ها با استفاده از  $g > 0.6$  گام دهم: تعیین مجموعه کمینه ویژگی‌ها برای حمله نوع i

#### ۳-۳- طبقه‌بندهای مورداستفاده

در روش پیشنهادی ما چندین نوع متفاوت از سه طبقه‌بند بیز، ماشین بردار پشتیبان و نزدیک‌ترین همسایه K ام مورد استفاده قرار گرفتند و نتایج بهتر برای انتخاب بهترین نوع مدنظر قرار گرفت. طبقه‌بند ماشین بردار پشتیبان برای انواع مختلف داده طراحی شده است اما یکی از مشکلات آن در آزمایش‌های انجام شده ما سرعت کم پاسخ‌دهی الگوریتم مذکور بود که وقت زیادی را در آزمایش‌ها می‌گرفت. در اجرای آزمایش‌ها پس از استفاده از چندین الگوریتم ماشین بردار پشتیبان از نوع هسته RBF مانند Fit-Svm، Svm train و LIBSvm از نوع خاصی از هسته طبقه‌بند ماشین بردار پشتیبان با نام هسته Hermite-Chebyshev جهت افزایش سرعت اجرای الگوریتم طبقه‌بندی استفاده شد [۳۰]. این نوع الگوریتم با توجه به رابطه زیر تعداد نقاط بردار پشتیبان را کاهش داده و نسبت به روش‌های قبلی سریع‌تر عمل می‌کند.

$$k(x, z) = \prod_{j=1}^d \sum_{i=0}^n He_i(x_j) He_i(z_j) \quad (8)$$

که در آن  $He_n(x)$  چندجمله‌ای متعامد هرमित<sup>۳۳</sup> است که به روش زیر تعیین می‌شود:

$$He_n(x) = (-1)^n e^{\frac{x^2}{2}} \frac{d^n}{dx^n} e^{-\frac{x^2}{2}} \quad (9)$$

#### ۳-۴- ترکیب طبقه‌بندها

الگوریتم‌های مختلفی در حوزه یادگیری ماشین برای سامانه‌های تشخیص نفوذ ارائه شده‌است. در این پروژه خروجی سامانه شامل ۲ کلاس (رفتار عادی و حمله) یا ۵ کلاس (رفتار عادی، Probe، DOS، R2L و U2R) است. با بررسی کلی می‌توان دریافت که هر الگوریتم در شناسایی برخی از انواع حمله‌ها دقت بیشتر و در برخی دیگر دقت کمتری دارد. یک راهکار برای رسیدن به دقت بالاتر به کارگیری روش‌های ترکیبی<sup>۳۴</sup> است. روش‌هایی که در آن‌ها k طبقه‌بند یاد گرفته شده باهم ترکیب می‌شوند تا الگوی قوی‌تری را ایجاد کنند. در نتیجه دقت مدل ترکیبی از هر کدام از مدل‌های اولیه بیشتر است.

$$f_{com} = Vote(f_1, f_2, \dots, f_k) \quad (10)$$

جدول ۳: لیست ویژگی‌های دادگان NSL-KDD

ردیف	نام ویژگی	نوع / مقادیر ویژگی
۱	duration	real
۲	protocol_type	'tcp','udp','icmp'
۳	service	'aol','auth','bgp','courier','csnet_ns','ctf','daytime','discard','domain','domain_u','echo','eco_i','ecr_i','efs','exec','finger','ftp','ftp_data','gopher','harvest','hostnames','http','http_2784','http_443','http_8001','imap4','IRC','iso_tsap','klogin','kshell','ldap','link','login','mtp','name','netbios_dgm','netbios_ns','netbios_ssn','netstat','nnsd','nntp','ntp_u','other','pm_dump','pop_2','pop_3','printer','private','red_i','remote_job','rje','shell','smtp','sql_net','ssh','sunrpc','supdup','systat','telnet','tftp_u','tim_i','time','urh_i','urp_i','uucp','uucp_path','vmnet','whois','X11','Z39_50'
۴	flag	'OTH','REJ','RSTO','RSTOS0','RSTR','S0','S1','S2','S3','SF','SH'
۵	src_bytes	real
۶	dst_bytes	real
۷	land	'0','1'
۸	wrong_fragment	real
۹	urgent	real
۱۰	hot	real
۱۱	num_failed_logins	Real
۱۲	logged_in	'0','1'
۱۳	num_compromised	real
۱۴	root_shell	real
۱۵	su_attempted	real
۱۶	num_root	real
۱۷	num_file_creations	real
۱۸	num_shells	real
۱۹	num_access_files	real
۲۰	num_outbound_cmds	real
۲۱	is_host_login	'0','1'
۲۲	is_guest_login	'0','1'
۲۳	count	real
۲۴	srv_count	real
۲۵	serror_rate	real
۲۶	srv_serror_rate	real
۲۷	rerror_rate	real
۲۸	srv_rerror_rate	real
۲۹	same_srv_rate	real
۳۰	diff_srv_rate	real
۳۱	srv_diff_host_rate	real
۳۲	dst_host_count	real
۳۳	dst_host_srv_count	real
۳۴	dst_host_same_srv_rate	real
۳۵	dst_host_diff_srv_rate	real
۳۶	dst_host_same_src_port_rate	real
۳۷	dst_host_srv_diff_host_rate	real
۳۸	dst_host_serror_rate	real
۳۹	dst_host_srv_serror_rate	real
۴۰	dst_host_rerror_rate	real
۴۱	dst_host_srv_rerror_rate	real

کلاس دیگر مربوط به حملات است. در سامانه‌های تشخیص نفوذ حملات به چهار دسته‌بندی تقسیم می‌شوند. این دسته‌بندی در جدول شماره ۲ نمایش داده شده است.

جدول ۱: لیست کلاس‌ها در دادگان NSL-KDD

ردیف	نام کلاس	تعداد	نوع کلاس
۱	Normal	۱	رفتار عادی
۲	Neptune, warezmaster, snmpgetattack, processtable, guess_passwd, satan, mscan, saint, smurf, apache2, buffer_overflow, back, pod, httptunnel, nmap, ipsweep, snmpguess, udpstorm, mailbomb, portsweep, multihop, sendmail, loadmodule, xterm, worm, teardrop, rootkit, xlock, xsnoop, sqlattack, ftp_write, imap, land, phf, perl, warezclient, named, ps, ftp_write	۳۹	حمله

جدول ۲: لیست دسته‌بندی نوع حملات در دادگان NSL-KDD

کلاس حمله	نوع حمله	تعداد
DoS	Back, Land, Neptune, Pod, Smurf, Teardrop, Apache2, Udpstorm, Processtable, Worm	۱۰
Probe	Satan, Ipsweep, Nmap, Portsweep, Mscan, Saint	۶
R2L	Guess_Password, Ftp_write, Imap, Phf, Multihop, Warezmaster, Warezclient, Spy, Xlock, Xsnoop, Snmpguess, Snmpgetattack, Httptunnel, Sendmail, Named, ftp_write	۱۶
U2R	Buffer_overflow, Loadmodule, Rootkit, Perl, Ssqlattack, Xterm, Ps	۷

مطابق با جداول شماره ۱ و ۳ با توجه به تعداد ۴۱ ویژگی به‌منظور پایین‌آوردن بار پردازشی برنامه، ویژگی‌ها را به کمک ترکیب الگوریتم آنتروپی و مجموعه فازی ناهموار کاهش دادیم. برای این منظور دو روش انتخاب ویژگی<sup>۴۱</sup> و استخراج ویژگی<sup>۴۲</sup> وجود دارد. در روش پیشنهادی ما انتخاب ویژگی به کمک مجموعه فازی ناهموار موردتوجه قرار گرفت تا با حذف ویژگی‌هایی که تأثیر چندانی در تعیین کلاس حملات ندارند دادگان مناسب‌تری مورد استفاده قرار گیرد. از سوی دیگر با تبدیل دادگان به دو نوع ۲ کلاسه -شامل حمله<sup>۴۳</sup> و عدم حمله<sup>۴۴</sup> - ۵ کلاسه -شامل عدم حمله و ۴ کلاس حمله منع سرویس<sup>۴۵</sup>، حمله پویس<sup>۴۶</sup>، حمله کاربر به ریشه<sup>۴۷</sup> و حمله دسترسی از راه دور<sup>۴۸</sup> - دو دادگان ایجاد نمودیم تا بتوانیم روش پیشنهادی را هم از لحاظ شناسایی و عدم شناسایی نفوذ و هم از لحاظ شناسایی نوع حملات بررسی نماییم.



## ۵-۱- ارزیابی

در جدول شماره ۶ ماتریس درهم‌ریختگی ارائه شده است که در آن چهار جزء اصلی تعیین‌کننده جهت ارزیابی معیارهای مختلف، به‌منظور ارزیابی سامانه‌های تشخیص نفوذ نشان داده شده‌اند. در روش پیشنهادی آزمایش‌ها را با سه معیار مختلف مورد بررسی قرار دادیم؛ اما با توجه به اینکه هدف اصلی مقاله بهبود دقت در سامانه‌های تشخیص نفوذ است، معیار دقت<sup>۵۰</sup> بیشتر مورد توجه قرار گرفته است.

جدول ۶: ماتریس درهم‌ریختگی برای سامانه تشخیص نفوذ [۱]

		کلاس‌های تخمینی	
		حمله	عادی
کلاس‌های واقعی	حمله	TP	FN
	عادی	FP	TN

TP: حمله توسط طبقه‌بند به درستی شناسایی شده است.  
 FP: رفتار عادی توسط طبقه‌بند به اشتباه حمله شناسایی شده است.  
 FN: حمله توسط طبقه‌بند به اشتباه رفتار عادی شناسایی شده است.  
 TN: رفتار عادی توسط طبقه‌بند به درستی شناسایی شده است.

معیار دقت (Precision):

از حاصل تقسیم تشخیص‌های صحیح حمله به کل رفتارهایی که به‌عنوان حمله شناسایی شده‌اند به دست می‌آید.

$$\text{Precision} = \frac{TP}{TP+FP} \quad (11)$$

معیار نرخ تشخیص (Detection Rate):

از حاصل تقسیم حمله‌های صحیح تشخیص داده‌شده به کل حمله‌ها به دست می‌آید.

$$\text{DR} = \frac{TP}{TP+FN} \quad (12)$$

معیار نرخ هشدارهای غلط (False Alarm Rate):

از حاصل تقسیم رفتارهای عادی که به اشتباه حمله تشخیص داده‌شده‌اند به کل رفتارهای عادی شبکه به دست می‌آید.

$$\text{FAR} = \frac{FP}{TN+FP} \quad (13)$$

در آزمایش‌های انجام‌شده، مشاهده شد که الگوریتم SVM در بهبود معیار دقت و همچنین کاهش FA نسبت به دو الگوریتم Bayes و KNN بهتر عمل کرده است؛ اما سرعت عملکرد این الگوریتم به‌ویژه در شناسایی نوع حملات نسبت به دو الگوریتم دیگر بسیار کندتر بوده و همچنین در خصوص نرخ تشخیص، طبقه‌بندهای Bayes و KNN نسبت به طبقه‌بند SVM قوی‌تر عمل کردند.

به‌منظور کاهش ویژگی از دو روش آنترویی<sup>۴۹</sup> و آنترویی فازی استفاده شد -که نتایج مشابهی داشتند- و تعداد ۳۲ ویژگی که در تعیین کلاس رفتار تأثیری نداشتند حذف شدند.

با توجه به حجم بالای دادگان برای اجرای الگوریتم از روش Ivote Bagging [۳۹] دادگان را به قسمت‌های ۱۰۰۰۰ نمونه‌ای تقسیم نموده (آخرین قسمت ۵۹۷۳ رکورد) و به ترتیب به‌عنوان داده‌های ورودی به الگوریتم کاهش ویژگی دادیم. همچنین برای اطمینان از صحت عملکرد پس از اتمام کار بازه‌های بینابین هم به ورودی الگوریتم داده شد مثلاً از داده شماره ۳۵۰۰۰ تا ۴۵۰۰۰ و در نهایت با حذف ویژگی‌های بی‌اهمیت از دادگان موجود دادگان جدیدی با تعداد ۷ ویژگی ایجاد شد. در تعداد کل رکوردها تغییری ایجاد نشد و ۱۲۵۹۷۳ رکورد جهت آموزش الگوریتم‌ها مورداستفاده قرار گرفت. پس از اجرای الگوریتم آنترویی فازی بر روی دادگان NSL-KDD، در حالت ۲ کلاسی ویژگی‌های ۳،۴،۵،۲۳،۳۲،۳۳ و در حالت ۵ کلاسی صفات ۳،۴،۵،۲۳،۳۳ به‌عنوان ویژگی‌های تعیین‌کننده کلاس نمونه انتخاب شدند. از تجمیع صفات به دست آمده در دو حالت، دادگانی با ۷ ویژگی از ۴۱ ویژگی موجود به دست آمد که در جدول ۴ ذکر شده است.

جدول ۴: لیست ویژگی‌های انتخاب‌شده توسط الگوریتم آنترویی فازی

تعداد کلاس	شماره ویژگی‌ها
دو کلاسی	۳،۴،۵،۲۳،۳۲،۳۳
پنج کلاسی	۳،۴،۵،۲۳،۳۳،۳۵
ویژگی‌های نهایی منتخب	۳،۴،۵،۲۳،۳۲،۳۳،۳۵

پس از آماده‌سازی دادگان به منظور آموزش و ارزیابی طبقه‌بندهای انتخاب‌شده به روش 10-fold در ۱۰ مرحله مختلف هر بار یک‌دهم دادگان جهت آزمون جدا شد و نه‌دهم دیگر جهت آموزش طبقه‌بندها مورد استفاده قرار گرفت که میانگین نتایج اجرای الگوریتم در جدول شماره ۵ قابل مشاهده است.

جدول ۵: میانگین نتایج اجرای الگوریتم 10-fold بر الگوریتم پیشنهادی

رفتار	عادی	DoS	Probe	R2L	U2R
میانگین نتایج روش پیشنهادی	۰/۹۷۹	۰/۹۶۵	۰/۹۲۸	۰/۹۱۰	۰/۵۰۲

## ۵- نتایج آزمایش‌ها

در این بخش نتایج آزمایش‌های انجام‌شده در جداول نشان داده شده است. آزمایش‌ها در حالت یادگیری با ناظر در نرم‌افزار متلب ۲۰۱۸ بر روی یک سرور با ۱۶ هسته پردازشگر و مقدار ۱۰۰ گیگابایت رم و همچنین سیستم عامل ویندوز سرور ۲۰۱۲ انجام شد؛ که نتایج ارزیابی آن بر اساس میزان دقت، نرخ تشخیص و هشدارهای اشتباه در جداول ارائه شده است.

جدول ۹: نتایج میزان دقت، نرخ تشخیص و نرخ هشدارهای غلط الگوریتم‌ها پس از کاهش ویژگی با دادگان ۲ کلاسی

معیار ارزیابی			ردیف	الگوریتم‌های طبقه‌بندی
FAR	DR	Precision		
0.089	75.85	99.865%	1	SVM
0.014	75.163	99.977	2	
0.044	75.849	99.932	3	
0.029	76.424	99.955	4	
0.059	76.725	99.911	5	
0.014	75.844	99.977	6	
0.044	75.869	99.932	7	
0.023	77.01	99.944	8	
0.018	76.853	99.890	9	
0.043	75.680	99.974	10	
0.999%	99.9%	96.34%	1	Bayes
1	99.9	96.86	2	
1	99.9	96.26	3	
0.999	99.9	96.68	4	
1	99.9	96.32	5	
1	99.9	96.29	6	
0.003	99.97	96.68	7	
0.999	99.8	96.36	8	
1	99.8	96.92	9	
0.001	99.48	95.97	10	
0.404%	99.627%	99.543%	1	KNN
0.686	99.812	99.222	2	
0.443	99.691	99.486	3	
0.415	99.555	99.521	4	
0.459	99.658	99.471	5	
0.428	99.657	99.503	6	
0.507	99.576	99.425	7	
0.636	99.554	99.265	8	
0.505	99.608	99.422	9	
0.398	99.673	99.536	10	
0.089	75.85	99.865%	1	روش پیشنهادی
0.014	75.163	99.977	2	
0.044	75.849	99.932	3	
0.029	76.424	99.955	4	
0.059	76.725	99.911	5	
0.014	75.844	99.977	6	
0.044	75.869	99.932	7	
0.023	77.01	99.944	8	
0.018	76.853	99.890	9	
0.043	75.680	99.974	10	

با مشاهده جدول ۱۰ می‌توان دریافت که شناسایی حملات R2L و U2R که تعداد نمونه‌های آنها در دادگان نسبت به سایر حملات بسیار کم‌تر بوده است، نتایج ضعیف‌تری داشته است. طبقه‌بند KNN نسبت به دو طبقه‌بند دیگر نتایج بهتری داشته است. لذا به منظور بهبود عملکرد این طبقه‌بند در شناسایی دو حمله مذکور - که در نهایت منجر به بهبود نتایج ترکیب خواهد شد - ضمن استفاده از دادگان جدید با ۹ ویژگی تعداد نمونه‌های آموزش و آزمون و همچنین تعداد همسایه‌های (عدد K در الگوریتم KNN) را تغییر دادیم. پس از تکرار آزمایش‌ها با دادگان ۹ ویژگی نتایج بهینه روی الگوریتم KNN با مقادیر مختلف K به دست آمد که پس از اعمال

در حالت به‌کارگیری دادگان ۵ کلاسی، شرایط متفاوت است. در جدول شماره ۷ تعداد نمونه‌های موجود از هر یک از کلاس‌ها در حالت ۵ کلاسی نشان داده شده است.

جدول ۷: تعداد نمونه‌های موجود از هر کدام از کلاس‌ها در دادگان

کلاس داده	Normal	DOS	Probe	R2L	U2R
تعداد	۶۷۳۴۳	۴۵۹۲۷	۱۱۶۵۶	۹۹۵	۵۲

مطابق با جدول شماره ۷ با توجه به تعداد بسیار کم نمونه‌های دو کلاس R2L و U2R، طبقه‌بندها این دو کلاس را با درصد کمتری شناسایی می‌کردند. در جدول شماره ۹ نتایج آزمایش‌های انجام‌شده بر روی دادگان نشان داده شده است.

همان‌گونه که از جدول شماره ۹ قابل استنباط است طبقه‌بند ماشین بردار پشتیبان در حالت ۲ کلاسی نسبت به سایر طبقه‌بندها عملکرد بهتری داشته است و با توجه به وزن‌دهی طبقه‌بندها نتایج طبقه‌بند مذکور در طبقه‌بند ترکیبی هم مشاهده می‌گردد. همچنین با توجه به جدول ۱۰ در حالت ۵ کلاسی طبقه‌بند KNN در معیار دقت نسبت به سایر طبقه‌بندها بهتر عمل نموده است که نتایج آن در طبقه‌بند ترکیبی (روش پیشنهادی) نیز مشاهده می‌گردد. با بررسی نتایج مدل پیشنهادی در نرم‌افزار متلب مشاهده شد که میزان دقت سامانه در حالت دو کلاسی به‌طور میانگین ۹۹/۹۳۶ درصد و در حالت ۵ کلاسی به‌طور میانگین در شناسایی رفتار نرمال ۹۹/۶۷۲ درصد و حمله DOS حدود ۹۹/۳۹۴ درصد و حمله Probe حدود ۹۶/۸۶۷ درصد و حمله‌های R2L و U2R به ترتیب ۸۱/۴۳۷ و ۶۰ درصد بود.

طبق اطلاعات جداول ۷ و ۱۰ با توجه به تعداد کم نمونه‌های حمله‌های U2R و R2L نسبت به کل نمونه‌ها، طبقه‌بندها در شناسایی این دو نوع حمله ضعیف عمل کردند و می‌توان نتیجه گرفت که آموزش طبقه‌بندها برای شناسایی دو حمله مذکور کافی نبوده - است لذا به منظور بهبود این موضوع مجدداً الگوریتم کاهش ویژگی را فقط برای نمونه‌های این دو نوع حمله در دادگان اولیه (شامل ۴۱ ویژگی) به‌صورت مجزا تکرار کردیم که در نتیجه دو ویژگی دیگر نیز به مجموع ویژگی‌های مهم افزوده شد و در نهایت یک دادگان با ۹ ویژگی مطابق جدول ۸ ایجاد شد.

جدول ۸: لیست ویژگی‌های انتخاب‌شده توسط الگوریتم


آنتروپی فازی برای دو حمله R2L و U2R

تعداد کلاس	شماره ویژگی‌ها
حمله‌های R2L و U2R	۶،۳،۲
ویژگی‌های نهایی منتخب	۳۵،۳۳،۳۲،۲۳،۶،۵،۴،۳،۲

تغییرات بر روی میزان تقسیم داده‌های آموزش و آزمون نتایج آن در جداول ۱۱ و ۱۲ قابل مشاهده است.

جدول ۱۰: نتایج میزان شناسایی کلاس‌های مختلف حمله توسط طبقه‌بندها بر اساس معیار دقت در حالت ۵ کلاسی


طبقه‌بند	کلاس ردیف					
	Normal	DOS	Probe	R2L	U2R	
SVM	86.58	94.95	64.44	50	50	1
	86.81	94.73	65.24	50	50	2
	92.39	94.94	68.23	50	50	3
	86.32	94.78	67.51	50	50	4
	86.74	94.38	67.09	50	50	5
	86.75	94.4	66.69	50	50	6
	88.36	94.81	66.86	50	50	7
	86.27	94.9	67.74	50	50	8
	86.3	94.87	67.55	50	50	9
	86.83	94.76	67.57	50	50	10
Bayes	82.43	63.17	64.27	4.57	0.61	1
	83.92	64.16	63.88	5.48	0.28	2
	82.46	62.83	63.49	5.37	0.46	3
	83.79	64.24	65.81	5.6	0.27	4
	82.64	63.96	64.08	5.84	0.3	5
	83.01	64.02	62.74	5.56	0.26	6
	83.4	64.1	65.14	5.29	0.28	7
	83.15	63.89	65.18	5.48	0.24	8
	83.73	64.34	64.3	5.63	0.37	9
	83.7	63.68	64.13	4.81	0.55	10
KNN	98.62	99.48	97.69	78.94	50	1
	98.82	99.41	96.74	82.89	100	2
	98.59	99.48	96.52	80	50	3
	98.89	98.89	96.58	76.62	50	4
	98.9	99.66	96.96	83.09	100	5
	98.7	99.44	96.64	83.54	50	6
	98.5	99.38	97.05	78.65	50	7
	98.63	99.44	96.46	83.52	50	8
	98.66	99.31	96.64	88.37	50	9
	98.41	99.45	97.39	78.75	50	10
ترکیب روش پیشنهادی	98.62	99.48	97.69	78.94	50	1
	98.82	99.41	96.74	82.89	100	2
	98.59	99.48	96.52	80	50	3
	98.89	98.89	96.58	76.62	50	4
	98.9	99.66	96.96	83.09	100	5
	98.7	99.44	96.64	83.54	50	6
	98.5	99.38	97.05	78.65	50	7
	98.63	99.44	96.46	83.52	50	8
	98.66	99.31	96.64	88.37	50	9
	98.41	99.45	97.39	78.75	50	10



شکل ۲: نمودار نرخ شناسایی حملات برای ۵ کلاس، ۹ ویژگی توسط SVM در حالات مختلف تعداد داده‌های آموزش و آزمون

جدول ۱۲: نرخ شناسایی حملات با الگوریتم 7-NN و در حالت تغییر میزان داده‌های آموزش و آزمون

Normal	مقدارها به درصد					Class	features	test	train	KNN (K = 7)
	DoS	Probe	R2L	U2R						
99.65	99.22	97.15	93.99	61.40	5	9	0.3	0.7		
99.64	99.25	97.26	94.92	66.67	5	9	0.25	0.75		
99.67	99.27	97.25	95.16	74.47	5	9	0.2	0.8		
99.68	99.22	97.30	94.44	90.91	5	9	0.15	0.85		
99.68	99.20	97.42	96.00	92.00	5	9	0.1	0.9		
99.70	99.43	96.95	93.95	100	5	9	0.05	0.95		



شکل ۳: نرخ شناسایی حملات برای ۵ کلاس، ۹ ویژگی توسط KNN در حالات مختلف تعداد داده‌های آموزش و آزمون

همان‌گونه که در جدول شماره ۱۱ مشاهده می‌شود الگوریتم 3-NN در حالتی که مجموعه آموزش ۹۵ درصد و مجموعه آزمون ۵ درصد از کل داده‌ها باشد در شناسایی رفتار عادی (۹۹/۷۹) و همچنین حملات DoS (۹۹/۵۲) بهترین عملکرد را نشان داد. مطابق جدول ۱۲ الگوریتم 7-NN نیز با همین درصد از مجموعه آموزش و آزمون نرخ شناسایی حمله U2R را تا صد درصد بهبود داد، همچنین همان‌طور که در شکل‌های شماره ۲ و ۳ مشاهده می‌شود با افزایش میزان داده‌های آموزش، بهبود قابل توجهی در عملکرد طبقه‌بند KNN جهت شناسایی حمله U2R حاصل شد.

در جدول شماره ۱۳ نتیجه مقایسه میزان تشخیص روش پیشنهادی با برخی از سایر روش‌های ارائه‌شده که براساس معیار دقت روی دادگان NSL-KDD آزمایش شده است را مشاهده می‌کنید. نتایج

جدول ۱۱: نرخ شناسایی حملات با الگوریتم 3-NN و در حالت تغییر میزان داده‌های آموزش و آزمون

Normal	مقدارها به درصد					Class	features	test	train	KNN (K = 3)
	DoS	Probe	R2L	U2R						
99.74	99.35	97.67	95.46	64.13	5	9	0.3	0.7		
99.74	99.41	97.66	96.14	56.12	5	9	0.25	0.75		
99.74	99.37	97.60	96.37	61.84	5	9	0.2	0.8		
99.75	99.35	97.79	96.07	68.97	5	9	0.15	0.85		
99.75	99.33	97.70	96.08	69.77	5	9	0.1	0.9		
99.79	99.52	97.52	96.27	73.68	5	9	0.05	0.95		

دوسطحی در ترکیب طبقه‌بندها را به منظور بهبود عملکرد روش پیشنهادی بررسی نمود.

بدست آمده برتری میزان دقت تشخیص حملات را نسبت به سایر روش‌های ارائه شده بر روی دادگان NSL-KDD نشان می‌دهد.

### مراجع

جدول ۱۳: مقایسه نتایج به‌دست‌آمده از روش پیشنهادی با سایر روش‌های ارائه‌شده براساس معیار دقت (Precision) و دادگان NSL-KDD

شماره مرجع	مؤلف	نتیجه	روش پیشنهادی
[۲]	(Tama and Rhee 2017)	99.8 (دو کلاسی)	99.93
[۳]	(AMINI, REZAEE et al. 2014)	87.6(Normal) 96.2(DoS) 83.3(Probe) 77.4(R2L) 81.4(U2R)	98.14 96.85 93.20 91.31 100
[۴]	(Dhaliwal, Nahid et al. 2018)	98.41 (دو کلاسی)	99.93
[۵]	(Gao, Shan et al. 2019)	94.93(Normal) 84.37(DoS) 87.11(Probe) 55.27(R2L) 25.00(U2R)	98.14 96.85 93.20 91.31 100
[۶]	(Mkuzangwe and Nelwamondo 2017)	85.17	99.93
[۷]	(Mirza 2018)	97.41	99.93
[۸]	(Alhakami, ALharbi et al. 2019)	81.50	99.93

[1] E. Alpaydin, *Introduction to machine learning*: MIT press, 2009.

[2] B. A. Tama and K.-H. Rhee, "Performance evaluation of intrusion detection system using classifier ensembles," *International Journal of Internet Protocol Technology*, vol. 10, pp. 22-29, 2017.

[3] M. AMINI, N. J. REZAEE, and E. HADAVANDI, "Effective intrusion detection with a neural network ensemble using fuzzy clustering and stacking combination method," *Journal of Computing and Security*, vol. 1, pp. 293-305, 2014.

[4] S. Dhaliwal, A.-A. Nahid, and R. Abbas, "Effective intrusion detection system using XGBoost," *Information*, vol. 9, p. 149, 2018.

[5] X. Gao, C. Shan, C. Hu, Z. Niu, and Z. Liu, "An Adaptive Ensemble Machine Learning Model for Intrusion Detection," *IEEE Access*, vol. 7, pp. 82512-82521, 2019.

[6] N. N. Mkuzangwe and F. Nelwamondo, "Ensemble of classifiers based network intrusion detection system performance bound," in *Systems and Informatics (ICSAI), 2017 4th International Conference on*, 2017, pp. 970-974.

[7] A. H. Mirza, "Computer network intrusion detection using various classifiers and ensemble learning," in *2018 26th Signal Processing and Communications Applications Conference (SIU)*, 2018, pp. 1-4.

[8] W. Alhakami, A. ALharbi, S. Bourouis, R. Alroobaea, and N. Bouguila, "Network Anomaly Intrusion Detection Using a Nonparametric Bayesian Approach and Feature Selection," *IEEE Access*, vol. 7, pp. 52181-52190, 2019.

[9] J. Ryan, M.-J. Lin, and R. Miikkulainen, "Intrusion detection with neural networks," *Advances in neural information processing systems*, pp. 943-949, 1998.

[10] C. Modi, D. Patel, B. Borisaniya, H. Patel, A. Patel, and M. Rajarajan, "A survey of intrusion detection techniques in cloud," *Journal of Network and Computer Applications*, vol. 36, pp. 42-57, 2013.

[11] O. Depren, M. Topallar, E. Anarim, and M. K. Ciliz, "An intelligent intrusion detection system (IDS) for anomaly and misuse detection in computer networks," *Expert systems with Applications*, vol. 29, pp. 713-722, 2005.

[12] D. M. Farid, L. Zhang, A. Hossain, C. M. Rahman, R. Strachan, G. Sexton, et al., "An adaptive ensemble classifier for mining concept drifting data streams," *Expert Systems with Applications*, vol. 40, pp. 5895-5906, 2013.

[13] M. Saidi, M. E. A. Bechar, N. Settouti, and M. A. Chikh, "Instances selection algorithm by ensemble margin," *Journal of Experimental & Theoretical Artificial Intelligence*, pp. 1-22, 2017.

[14] H.-s. Chae, B.-o. Jo, S.-H. Choi, and T. Park, "Feature Selection for Intrusion Detection using NSL-KDD," *Recent Advances in Computer Science*, ISBN, pp. 978-960, 2015.

[15] L. Dhanabal and D. S. Shantharajah, "A Study on NSL-KDD Dataset for Intrusion Detection System Based on Classification Algorithms," *International Journal of Advanced Research in Computer and Communication Engineering*, vol. 4, pp. 446-452, 2015.

[16] S. Duque and M. N. bin Omar, "Using Data Mining Algorithms for Developing a Model for Intrusion Detection System (IDS)," *Procedia Computer Science*, vol. 61, pp. 46-51, 2015.

[17] J. Jabez and B. Muthukumar, "Intrusion Detection System (IDS): Anomaly detection using outlier detection approach," *Procedia Computer Science*, vol. 48, pp. 338-346, 2015.

[18] R. Singh, H. Kumar, and R. Singla, "An intrusion detection system using network traffic profiling and online sequential extreme learning machine," *Expert Systems with Applications*, vol. 42, pp. 8609-8624, 2015.

[19] D. J. Weller-Fahy, B. J. Borghetti, and A. A. Sodemann, "A survey of distance and similarity measures used within network

### ۶- نتیجه‌گیری و کارهای آینده

در این تحقیق یک سامانه تشخیص نفوذ برای بهبود دقت با استفاده از ترکیب وزن دار طبقه‌بندها پیشنهاد شد. به منظور ترکیب طبقه‌بندها از روش ادغام استفاده کردیم. نتیجه تصمیم‌گیری بر اساس رأی وزن دار طبقه‌بندها تعیین شده است. به‌منظور کاهش بار محاسباتی، قبل از استفاده از دادگان ویژگی‌های آن را به کمک الگوریتم‌های یادگیری ماشین کاهش دادیم. آزمایش‌ها حدود ۱۰ بار تکرار شدند. الگوریتم آنتروپی در مجموعه فازی ناهموار به‌منظور کاهش ویژگی و انتخاب ویژگی‌های مهم به‌کارگیری شد. جهت طبقه‌بندی از سه الگوریتم SVM، KNN و Bayes استفاده شد.

نتایج نشان می‌دهد دقت الگوریتم پیشنهادی در حالت دو کلاسی و در سه کلاس از حالت ۵ کلاسی نسبت به سایر روش‌های ارائه‌شده اخیر بالاتر بوده است و هر الگوریتمی که بتواند نتایج بهتری در شناسایی حملات داشته باشد قابل به‌کارگیری در این روش نیز خواهد بود. برای کارهای آینده، می‌توان بهبود آموزش طبقه‌بندها با استفاده از روش یادگیری عمیق<sup>۵</sup> و به‌کارگیری شیوه شناسایی

- [29] G. Chandrashekar and F. Sahin, "A survey on feature selection methods," *Computers & Electrical Engineering*, vol. 40, pp. 16-28, 2014.
- [30] V. H. Moghaddam and J. Hamidzadeh, "New Hermite orthogonal polynomial kernel and combined kernels in Support Vector Machine classifier," *Pattern Recognition*, vol. 60, pp. 921-935, 2016.
- [31] Z. Pawlak, "Rough sets," *International Journal of Parallel Programming*, vol. 11, pp. 341-356, 1982.
- [32] W.-Z. Wu, J.-S. Mi, and W.-X. Zhang, "Generalized fuzzy rough sets," *Information sciences*, vol. 151, pp. 263-282, 2003.
- [33] F. Fazayeli, L. Wang, and J. Mandziuk, "Feature selection based on the rough set theory and expectation-maximization clustering algorithm," in *International Conference on Rough Sets and Current Trends in Computing*, 2008, pp. 272-282.
- [34] S. Muthurajkumar, K. Kulothungan, M. Vijayalakshmi, N. Jaisankar, and A. Kannan, "A rough set based feature selection algorithm for effective intrusion detection in cloud model," in *Proceedings of the international conference on advances in communication, network, and computing*, 2013, pp. 8-13.
- [35] L. I. Kuncheva, *Combining pattern classifiers: methods and algorithms*: John Wiley & Sons, 2004.
- [36] J. McHugh, "Testing intrusion detection systems: a critique of the 1998 and 1999 darpa intrusion detection system evaluations as performed by lincoln laboratory," *ACM Transactions on Information and System Security (TISSEC)*, vol. 3, pp. 262-294, 2000.
- [37] S. Revathi and A. Malathi, "Network Intrusion Detection Based On Fuzzy Logic," *International Journal of Computer Application*, vol. 1, pp. 143-149, 2014.
- [38] "NSL-KDD Dataset," U. O. N. Brunswick, Ed., ed.
- [39] S. B. Kotsiantis, "Bagging and boosting variants for handling classifications problems: a survey," *The Knowledge Engineering Review*, vol. 29, pp. 78-100, 2014.
- intrusion anomaly detection," *IEEE Communications Surveys & Tutorials*, vol. 17, pp. 70-91, 2015.
- [20] X. Jia, L. Shang, B. Zhou, and Y. Yao, "Generalized attribute reduct in rough set theory," *Knowledge-Based Systems*, vol. 91, pp. 204-218, 2016.
- [21] Y. Xiao, C. Xing, T. Zhang, and Z. Zhao, "An Intrusion Detection Model Based on Feature Reduction and Convolutional Neural Networks," *IEEE Access*, vol. 7, pp. 42210-42219, 2019.
- [22] C. Guo, Y. Ping, N. Liu, and S.-S. Luo, "A two-level hybrid approach for intrusion detection," *Neurocomputing*, vol. 214, pp. 391-400, 2016.
- [23] S.-Y. Ji, B.-K. Jeong, S. Choi, and D. H. Jeong, "A multi-level intrusion detection method for abnormal network behaviors," *Journal of Network and Computer Applications*, vol. 62, pp. 9-17, 2016.
- [24] C.-C. Huang, T.-L. B. Tseng, and C.-Y. Tang, "Feature extraction using rough set theory in service sector application from incremental perspective," *Computers & Industrial Engineering*, vol. 91, pp. 30-41, 2016.
- [25] W. L. Al-Yaseen, Z. A. Othman, and M. Z. A. Nazri, "Multi-level hybrid support vector machine and extreme learning machine based on modified K-means for intrusion detection system," *Expert Systems with Applications*, vol. 67, pp. 296-303, 2017.
- [26] M. Rajasekaran and A. Ayyasamy, "A Novel Ensemble Approach for Effective Intrusion Detection System," in *Recent Trends and Challenges in Computational Models (ICRTCCM), 2017 Second International Conference on*, 2017, pp. 244-250.
- [27] Y. Shen, K. Zheng, C. Wu, M. Zhang, X. Niu, and Y. Yang, "An Ensemble Method based on Selection Using Bat Algorithm for Intrusion Detection," *The Computer Journal*, vol. 61, pp. 526-538, 2017.
- [28] V. Timčenko and S. Gajin, "Ensemble classifiers for supervised anomaly based network intrusion detection," in *Intelligent Computer Communication and Processing (ICCP), 2017 13th IEEE International Conference on*, 2017, pp. 13-19.

## زیر نویس‌ها:

- |  |  |
|--|--|
| 27 - Support vector machine(SVM)   | 1 - Intrusion Detection System(IDS)                          |
| 28 - Extreme Learning Machine(ELM)   | 2 - Intrusion Prevention System(IPS)                         |
| 29 - Incremental Particle Swarm Optimization(IPSO)   | 3 - Port scanning  |
| 30 - Information Gain  | 4 - Network administrator                                    |
| 31 - Infinite bounded generalized Gaussian mixture with feature selection                                      | 5 - Host based IDS(HIDS)                                     |
| 32 - Rough Set   | 6 - Network based IDS(NIDS)                                  |
| 33 - Hermite orthogonal polynomials  | 7 - Denial of Service(DoS)                                   |
| 34 - Ensemble method   | 8 - IP(Internet Protocol)                                    |
| 35 - Trainable ensembles   | 9 - Header   |
| 36 - K Nearest Neighbor  | 10 - Distributed Intrusion Detection System(DIDS)            |
| 37 - Training  | 11 - Signature based detection                               |
| 38 - Testing   | 12 - Zero day attack   |
| 39 - <a href="https://iscxdownloads.cs.unb.ca/iscxdownloads">https://iscxdownloads.cs.unb.ca/iscxdownloads</a> | 13 - Anomaly based detection                                 |
| 40 - Preprocessing   | 14 - False Alarm(FA)   |
| 41 - Feature selection   | 15 - Hybrid method   |
| 42 - Feature extraction  | 16 - Feature space   |
| 43 - Attack  | 17 - Dataset   |
| 44 - Normal  | 18 - Ensemble Margin Instance Selection(EMIS)                |
| 45 - Denial Of Service(DOS)  | 19 - False negative(FN)                                      |
| 46 - Probe   | 20 - Outlier computation-based                               |
| 47 - User to Root(U2R)   | 21 - Online sequential extreme learning machine              |
| 48 - Remote to Local(R2L)  | 22 - Convolutional neural network–intrusion detection system |
| 49 - Entropy   | 23 - False positive  |
| 50 - Precision   | 24 - Integer-programming                                     |
| 51 - Deep learning   | 25 - Incremental weight incorporated rule identification     |
|  | 26 - Condition attributes                                    |