

An Intrusion Detection System in Computer Networks using the Firefly Algorithm and the Fast Learning Network

Samira Rajabi, Shahram Jamali, Javad Javidan

Department of Computer Engineering University of Mohaghegh Ardabili, Ardabil, Iran

Samira_61R@yahoo.com, jamali@uma.ac.ir, javidan@uma.ac.ir

Abstract

Due to extensive use of communication networks and the ease of communicating via wireless networks, these types of networks are increasingly considered. Usability in any environment without the need for monitoring and environmental engineering of these networks, have been caused increasing use of it in various fields. It also caused the emergence security problems in the sending and receiving of information that the intrusion detection has been raised as the most important issue. Hence, Network intrusion detection system (NIDS) is the process of identifying malicious activity in a network by analyzing the network traffic behavior. Wireless sensor network is a special type of wireless network is composed of sensors that are responsible for the task of collecting information from the environment. This wireless networks because of the limitation of resources, mobility and critical tasks are relatively high vulnerabilities in comparison to other network. There are several ways to secure a wireless network but those ways are not able to detect the majority of attacks. In addition, due to the limited power wireless sensor nodes, the use of observer nodes to permanent monitoring in wireless sensor networks in order to prevention and detection intrusion and attacks has practically impossible. Therefore, forecasting and intrusion detection systems play an important role in providing security in wireless sensor networks that can involve a wide range of attacks. Traffic behavior in the network has many features and dimensions, so dimensionality reduction plays a vital role in IDS, since detecting anomalies from high dimensional network traffic feature is time-consuming process. Feature selection influences the speed of the analysis and detection. For this purpose, in this project, a new approach is proposed to predict the intrusion of wireless networks using firefly based feature selection and fast learning network. Selected features in the feature selection phase are used as inputs to the fast learning network to analyze the intrusion of the network in real-time. According to the simulation results in this thesis it can be said that the fast neural network method continues training so as to avoid overfitting error. While neural networks further learns training set features until the training process is completed. Thus, the occurrence of overfitting phenomenon in neural networks is common. Therefore, the proposed method overall shows better performance than the neural network method in predicting new attacks on the network.

Keywords: Network Intrusion Detection System, Feature Subset Selection, Firefly Optimization Algorithm, Fast Learning neural network.



یک سیستم تشخیص نفوذ شبکه های کامپیوتری با استفاده از الگوریتم کرم شب تاب و شبکه یادگیری سریع

سمیرا رجبی^۱، شهرام جمالی^۲، جواد جاویدان^۳

^۱ دانشجوی کارشناسی ارشد، گروه آموزشی مهندسی برق و کامپیوتر، دانشگاه محقق اردبیلی، اردبیل،
samira_61R@yahoo.com

^۲ دانشیار، گروه آموزشی مهندسی برق و کامپیوتر، دانشگاه محقق اردبیلی، اردبیل
jamali@uma.ac.ir

^۳ دانشیار، گروه آموزشی مهندسی برق و کامپیوتر، دانشگاه محقق اردبیلی، اردبیل
javidan@uma.ac.ir

چکیده

با توجه به گستردگی استفاده از شبکه های ارتباطی و سهولت برقراری ارتباط از طریق شبکه های کامپیوتری، این نوع از شبکه ها بیش از پیش مورد توجه قرار گرفته اند که باعث مطرح شدن مسئله های امنیتی در زمینه ارسال و دریافت اطلاعات شده که تشخیص نفوذ به عنوان مهم ترین مسئله مطرح شده است. تشخیص نفوذ شبکه فرایند شناسایی فعالیت های مخرب در یک شبکه با تحلیل رفتار ترافیک شبکه است. این شبکه ها به دلیل بی سیم بودن، محدودیت منابع، تحرک و پویایی و وظایف مهم و بحرانی که دارند، نسبت به شبکه های دیگر دارای آسیب پذیری نسبتاً بالایی هستند. علاوه بر این با توجه به انرژی محدود گره های بی سیم، استفاده از گره های ناظر برای نظارت دائمی در شبکه های بی سیم به منظور جلوگیری و کشف نفوذ و حملات را در این نوع از شبکه ها عملاً غیرممکن کرده است. از این رو سیستم های پیش بینی و تشخیص نفوذ در شبکه (NIDS) نقش مهمی در ایجاد امنیت در شبکه های بی سیم بر عهده دارند و می توانند محدوده وسیعی از حملات را در برگیرند. رفتار ترافیکی در شبکه دارای ویژگی ها و ابعاد زیادی است، بنابراین کاهش ابعاد نقش حیاتی در NIDS بازی می کند، زیرا شناسایی ناهنجاری ها از ویژگی ترافیک شبکه با ابعاد بزرگ، فرایند زمان گیر است. انتخاب ویژگی بر سرعت تجزیه و تحلیل و تشخیص تأثیر می گذارد. به همین منظور در این پژوهش برای پیش بینی نفوذ در شبکه های بی سیم رویکرد جدیدی با استفاده از انتخاب زیرمجموعه ویژگی مبتنی بر الگوریتم کرم شب تاب و شبکه یادگیری عصبی سریع ارائه می شود. ویژگی های منتخب در مرحله انتخاب زیرمجموعه ویژگی ها، به عنوان ورودی به شبکه یادگیری عصبی سریع مورد استفاده قرار می گیرد تا در زمان بلادرنگ تحلیلی از نفوذها در شبکه صورت گیرد. با توجه به نتایج شبیه سازی در این پایان نامه می توان گفت روش شبکه های عصبی سریع آموزش را تا جایی ادامه می دهد که از بروز خطای overfitting جلوگیری به عمل آید در صورتی که شبکه های عصبی تا کامل شدن روند آموزش، ویژگی های نمونه های آموزشی را بیشتر یاد می گیرد. بنابراین بروز پدیده Overfitting در شبکه های عصبی طبیعی است. از این رو روش پیشنهادی در مجموع عملکرد بهتری نسبت به روش شبکه های عصبی در تشخیص گره های سالم و حملات جدید در شبکه را نشان می دهد.

کلمات کلیدی

سیستم تشخیص نفوذ در شبکه، انتخاب زیرمجموعه ویژگی، الگوریتم بهینه سازی کرم شب تاب، یادگیری سریع

و از طریق لینک های بی سیم به یکدیگر متصل شده اند. هر گره می تواند به عنوان یک سیستم نهایی عمل کند علاوه بر آن می تواند در نقش یک روتر بسته ها را ارسال کند [۱]. هنگامی که یک گره مبدأ قصد انتقال اطلاعات به یک گره مقصد را دارد بسته ها بین گره های میانی انتقال می یابند و بنابراین

۱- مقدمه

شبکه های کامپیوتری به وسیله مجموعه ای از میزبان های سیار تشکیل یافته اند



بدین منظور در روش پیشنهادی از رویکرد انتخاب زیرمجموعه ویژگی مبتنی بر الگوریتم کرم شب تاب به منظور تعیین ویژگی‌های با اهمیت و مرتبط با برچسب کلاس استفاده شده است [۱۷]. ویژگی‌های باقیمانده از این مرحله که به عنوان خروجی الگوریتم شب تاب نتیجه شده است، به عنوان ورودی شبکه یادگیری سریع مورد استفاده در روش پیشنهادی، به منظور افزایش دقت طبقه بندی نمونه‌های آموزشی و تعیین برچسب نمونه‌های تست در نظر گرفته می‌شود.

در ادامه مقاله، در بخش ۲ برخی از سیستم‌های تشخیص نفوذ در شبکه های کامپیوتری بررسی خواهند شد. در بخش ۳ جزئیات روش پیشنهادی ارائه خواهد شد. در بخش ۴ به مدل سازی و ارزیابی عملکرد روش پیشنهادی خواهیم پرداخت. در نهایت در بخش ۵ نتیجه گیری مقاله و کارهای آینده بیان خواهد شد.

۲- کارهای مرتبط

نیاز به خدمات همیشه با سرعت بالا برای خدمات شبکه ای برای کسب و کار و سایر سرویس های شبکه، از ملزومات شبکه بوده و نیازی به تأکید بیش از حد ندارد. سیستم های تشخیص نفوذ (IDS) یک ابزار مهم برای حفاظت از شبکه هستند [۱۸]. سیستم های تشخیص نفوذ (IDS) تجزیه و تحلیل مسیرهای ورود گره ها به سیستم را در ارتباط با سیستم های حفاظت شده، بررسی می کنند و تصمیم می گیرند که آیا این مسیرهای ورود به سیستم حاوی گره هایی از یک حمله است یا نه. اگر سیستم تشخیص نفوذ یک حمله را تشخیص دهد، هشدار را افزایش می دهد. به طور سنتی، سیستم های تشخیص نفوذ از بازرسی عمیق بسته ها یا تجزیه و تحلیل پروتکل های وضعیتی برای شناسایی حملات در ترافیک شبکه استفاده می کنند. بازرسی عمیق بسته زمانی که ترافیک شبکه رمزگذاری می شود امکان پذیر نیست. همچنین بازرسی کامل اجزای کامپیوتری پرهزینه است و می تواند در شبکه های با سرعت بالا به یک مشکل بزرگ تبدیل شود. تجزیه و تحلیل کامل پروتکل ها برای تعیین ویژگی ها و محدوده هر یک از نفوذها در نظر گرفته می شود. تکنیک های تجزیه و تحلیل پروتکل نیز می توانند به صورت محاسباتی پرهزینه باشند [۱۱].

در [۷] یک مدل یادگیری توسعه یافته برای شبکه یادگیری عصبی سریع (FLN) مبتنی بر بهینه سازی ازدحام ذرات^۲ (PSO) پیشنهاد شده است و به نام PSO-FLN نام گذاری شده است. این مدل بر روی مسئله تشخیص نفوذ و اعتبار سنجی بر اساس مجموعه داده معروف KDD99 اعمال شده است. در [۱۷] روشی را با به کارگیری الگوریتم کرم شب تاب مبتنی بر روش های فیلتر و Wrapper توسعه یافته است که بر سرعت تجزیه و تحلیل مدل طبقه بندی تأثیر می گذارد. ویژگی های حاصل از این گام انتخاب ویژگی، به طبقه بندی C4.5 و شبکه های بیزین^۳ (BN) با مجموعه داده KDD CUP 99 منتهی می شود. در [۱۵]، یک سیستم تشخیص نفوذ جدید مبتنی

جستجو و ایجاد سریع یک مسیر از مبدأ به گره مقصد برای شبکه های کامپیوتری سیار امری حیاتی است [۲]. توپولوژی شبکه های کامپیوتری سیار ممکن است به طور متناوب و در نتیجه جابجایی گره ها تغییر یابد، بنابراین با این تکنولوژی گره ها می توانند به راحتی خود را با همسایگان محلی تغییر دهند [۳-۵]. هنگامی که بحث شبکه های بی سیم مطرح می شود بحث امنیت و جلوگیری از حملات بسیار مشکل تر می شود و این مشکل در شبکه های کامپیوتری سیار نیز چندین برابر است [۶، ۷].

نفوذ گره های مخرب در میان گره های این شبکه می تواند موجب تضعیف و یا تخریب بسته های اطلاعاتی انتقال یافته شود و تمام یا قسمتی از اطلاعات مورد نیاز از بین برود. در نتیجه کارایی کل سیستم تهدید شده و ممکن است نتایج به گونه دیگری مورد تفسیر قرار گیرند [۸-۱۰]. بنابراین جلوگیری و کشف نفوذها و حملات در شبکه های کامپیوتری به یک امر حیاتی و چالشی جدی تبدیل شده است. از این رو سیستم های تشخیص نفوذ نقش مهمی در ایجاد امنیت در شبکه های بی سیم بر عهده دارند و می توانند محدوده وسیعی از حملات را در برگیرند [۱۱].

سیستم های تشخیص نفوذ به منظور تعیین این که فعالیت کاربر تحت نظارت یا فعالیت ترافیک شبکه، مخرب است یا خیر، تلاش می کنند [۱۲، ۱۳]. اگر در طی دوره نظارت یک حمله مخرب شناسایی شود، هشدار ایجاد می شود. تکنیک های مختلفی برای IDS ها برای تشخیص حمله مانند تشخیص آنومالی یا امضاء حمله وجود دارد که نکته قابل ذکر این است که موفقیت IDS بستگی به تکنیک های مورد استفاده دارد [۱۴]. یکی از عوامل اصلی که اثربخشی IDS را بر عهده دارد، کیفیت ساخت ویژگی و الگوریتم انتخاب ویژگی است. به منظور بهبود کارایی کلی IDS، کاهش تعداد ویژگی های قابل استفاده ترافیکی شبکه، بدون تأثیر بر روی دقت طبقه بندی، مورد نیاز است [۱۵].

از این رو در این تحقیق روشی برای سیستم تشخیص نفوذ در شبکه بر اساس ترکیب انتخاب زیرمجموعه ویژگی مبتنی بر الگوریتم کرم شب تاب و شبکه یادگیری عصبی سریع^۴ ارائه شده است. روش پیشنهادی از مجموعه داده های آموزشی به دست آمده از مجموعه داده ها KDD Cup [۱۶] برای تعیین الگوهای شناسایی نفوذ در شبکه و از مجموعه داده های تست تهیه شده از هم این مجموعه داده ها، به منظور ارزیابی مدل استفاده خواهد نمود. در روش پیشنهادی با توجه به تنوع و تعداد ویژگی های رفتار کاربران و ترافیک شبکه، انتخاب زیرمجموعه ویژگی ها در راستای افزایش دقت طبقه بندی مدل ضروری به نظر می رسد. هدف انتخاب زیرمجموعه ویژگی ها، حذف ویژگی ها و صفات نامرتب و افزونه است تا به این طریق علاوه بر کاهش بعد داده ها و کاهش پیچیدگی اجرایی و فضای سیستم، بتوان دقت طبقه بندی را افزایش داده و با سرعت بالا و هزینه کمتری داده ها را طبقه بندی نمایم. علاوه بر این انتخاب زیرمجموعه ای از ویژگی ها می تواند وابستگی ضمنی میان داده ها و برچسب کلاس این داده ها را تشخیص دهد تا طبقه بندی نمونه های تست که در آینده به مدل اضافه خواهند شد به راحتی صورت گیرد.



و یا سوئیچ برای مسیریابی استفاده نمی کنند، خود گره‌ها در عمل مسیریابی شرکت می کنند. هر گره می تواند در نقش یک روتر، بسته‌ها را در مسیر بین مبدأ و مقصد ارسال نماید، حضور یک گره مخرب در بین گره‌های موجود در شبکه می تواند موجب اختلال در روند ارسال و دریافت بسته‌های اطلاعاتی شود، وجود یک حمله در این نوع شبکه‌ها می تواند به نابودی شبکه بیانجامد [۲۳، ۲۴]. از این رو در این تحقیق روشی برای سیستم تشخیص نفوذ در شبکه بر اساس ترکیب انتخاب زیرمجموعه ویژگی مبتنی بر الگوریتم کرم شب تاب و شبکه یادگیری عصبی سریع ارائه شده است. در ادامه این فصل به بررسی اجمالی انتخاب زیرمجموعه ویژگی‌ها، الگوریتم کرم شب تاب، شبکه‌های عصبی، شبکه عصبی با یادگیری سریع و توصیف روش پیشنهادی خواهیم پرداخت.

۳-۱- پیش پردازش داده‌ها

در سال‌های اخیر انواع مدل‌های طبقه‌بندی توسعه یافته‌اند که با انجام فرآیند آموزشی روی داده‌ها، قادر به طبقه‌بندی و پیش‌بینی داده‌های تست و موارد ناشناخته برای سیستم می باشند. نکته قابل توجه در این میان، نوع داده مورد استفاده برای هر یک از انواع مدل هاست. در واقع هر مدل با نوع داده خاصی سروکار دارد و به طبقه‌بندی نوع خاصی از داده‌ها می پردازد. برای استفاده از مدل‌ها و بهره‌گیری از نتایج خروجی از مدل نیاز به آماده‌سازی داده‌ها در قالب خاص مدل است. فرآیند آماده‌سازی داده‌ها برای هر مدل پیش‌پردازش داده‌ها نام دارد. پیش‌پردازش داده‌ها دارای گام‌های متعددی است که در این تحقیق دو نمونه از این گام‌های پیش‌پردازشی مورد نیاز است که در ادامه توضیح داده می‌شود [۲۵].

۳-۲- انتخاب زیرمجموعه ویژگی‌ها


گام پیش‌پردازشی که در این تحقیق مورد استفاده قرار گرفته است انتخاب زیرمجموعه‌ای از صفت‌هاست که با برچسب کلاس ارتباط مستقیم دارند [۲۵]. با توجه به اینکه مجموعه داده‌های مربوط به تشخیص نفوذ KDD دارای ۴۱ ویژگی در سه دسته ویژگی‌های پایه اتصالات تکي TCP، ویژگی‌های محتوایی با اتصالات پیشنهادی توسط دامنه دانش و ویژگی‌های ترافیک محاسبه شده با استفاده از پنجره زمانی دوتایی‌ای توزیع شده‌اند. این تعداد زیاد صفت‌ها می تواند موجب پیچیدگی مدل طبقه‌بندی مورد استفاده شود. از این رو باید تعدادی از این صفت‌ها که توزیع نامتوازن داشته و در تعیین برچسب کلاس نمونه‌ها تأثیر چندانی ندارند، طی گام پیش‌پردازشی انتخاب زیرمجموعه ویژگی‌ها حذف شوند.

هدف گام پیش‌پردازشی انتخاب زیرمجموعه ویژگی‌ها حذف ویژگی‌ها و صفت‌های نامرتب و افزونه است تا به این طریق علاوه بر کاهش بعد داده‌ها و کاهش پیچیدگی اجرایی و فضایی سیستم، بتوان دقت طبقه‌بندی را افزایش داده و با سرعت بالا و هزینه کمتری داده‌ها را طبقه‌بندی نمایم. علاوه بر این انتخاب زیرمجموعه‌ای از داده‌ها می تواند وابستگی ضمنی میان داده‌ها و

بر ترکیبی از یک شبکه عصبی چندلایه و یک کلونی زنبور عسل مصنوعی و الگوریتم‌های خوشه‌بندی فازی ارائه شده است. بسته‌های ترافیکی شبکه عادی و غیرعادی توسط شبکه عصبی شناسایی می شوند، در عین حال آموزش آن با استفاده از الگوریتم کلونی زنبور عسل توسط بهینه‌سازی مقادیر وزن و پیوند بایاس انجام می شود. در [۱۹] یک رویکرد بهینه برای ساخت سیستم تشخیص نفوذ در شبکه بر اساس شبکه عصبی پرسرو با استفاده از الگوریتم یادگیری پیشرفته ارائه کرده‌اند و یک معماری جدید برای شبکه استفاده کرده‌اند. این رویکرد برای اولین بار بر تولید تمام ترکیبات ممکن از مقادیر مناسب پارامترهای موجود در ساخت چنین طبقه‌بندی، یا تأثیر عملکرد آن در تشخیص ناهنجاری، نظیر انتخاب ویژگی، نرمال‌سازی داده‌ها، معماری شبکه عصبی و تابع فعال‌سازی، متکی است. در [۲۰] استفاده از روش‌های یادگیری تنبل برای بهبود عملکرد کلی IDS را پیشنهاد شده است. یک روش اندیس گذاری مبتنی بر وزن مکاشفه‌ای برای غلبه بر نقص پیچیدگی جستجوی که ذاتاً در یادگیری تنبل وجود دارد، استفاده شده است. IBk و LWL، دو الگوریتم معروف یادگیری تنبل هستند که بر روی مجموعه داده NSL-KDD برای شبیه‌سازی یک سناریو در دنیای واقعی و مقایسه عملکرد نسبی آن با hw-IBk اعمال شده‌اند. در [۲۱] برای شناسایی و یا جلوگیری از حملات شبکه، یک سیستم تشخیص نفوذ شبکه با الگوریتم یادگیری ماشین برای رسیدن به دقت بهتر و سرعت تشخیص سریع‌تر ارائه نموده‌اند. استفاده از یادگیری ماشینی یکی دیگر از مزیت‌های عمده‌ای است که در آن دانش پیشرفته به اندازه مدل لیست سیاه و سفید مورد نیاز نیست. ماشین‌های یادگیری شدید^۴ (ELMs) شبکه‌های عصبی مصنوعی تک لایه هستند که نیازی به تکرار آموزش ندارند. بنابراین، سرعت یادگیری آن‌ها سریع است و سرعت در موفقیت سیستم‌های تشخیص نفوذ شبکه بسیار مهم است و برای آن‌ها واکنش سریع و مؤثر دفاع می کنند. در [۲۲] یک روش یادگیری نیمه نظارتی مبتنی بر فازی را با استفاده از نمونه‌های بدون برچسب با کمک الگوریتم یادگیری نظارت شده برای بهبود عملکرد طبقه‌بندی برای سیستم تشخیص نفوذ ارائه شده است. یک شبکه عصبی پیش رو یکپارچه برای به دست آوردن بردار عضویت فازی آموزش داده شده است و طبقه‌بندی نمونه (دسته‌های کم، متوسط و زیاد فازی) در نمونه‌های بدون برچسب با استفاده از مقدار فازی انجام می شود. طبقه بند پس از ترکیب هر دسته به طور جداگانه در مجموعه آموزش اصلی، آموزش مجدد روی داده‌ها انجام می دهد. [۲۲].

۳-۳ روش پیشنهادی

شبکه‌های بی سیم با توپولوژی متغیر و بدون وجود زیرساخت مشخص، دائماً در معرض حملات توسط گره‌های مخرب قرار دارند. دسترسی آسان به شبکه‌ها و امکان اتصال سریع به سایر گره‌ها باعث شده این نوع از شبکه‌ها مستعد حملات باشند. این شبکه‌ها اغلب بدون برنامه‌ریزی قبلی ایجاد می شوند و برای مدت کوتاهی نیاز به برقراری امنیت دارند. از آنجایی که شبکه‌های موردی سیار بدون زیرساخت هستند و از هیچ تجهیزاتی مثل روتر



شکل (۱): ساختار شبکه یادگیری عصبی سریع [۲۹]

همان طور که اشاره شده است، FLN از نظر عدم وجود وزن، توزیع یا انتساب مطلوب شبیه به یادگیری ماشین خبره (ELM) است. در نتیجه، دقت کلی ANN کاهش خواهد یافت مگر اینکه یک روش مناسب برای انتخاب وزن ها، اعمال شود. FLN بهینه شده توسط PSO در این روش بر اساس انتخاب وزن با استفاده از بهینه سازی ازدحام ذرات آموزش دیده است. بهینه سازی مبتنی بر PSO از FLN بر اساس طراحی ذره ای است که یک راه حل کاندیدا از وزن FLN را نشان می دهد. یک مشکل خاص در انجام بهینه سازی، نیاز به انتخاب هر دو مقدار وزن و تعداد نورون هایی است که در لایه پنهان برای افزایش دقت مورد نیاز است. این بدان معنی است که تعداد نورون های پنهان راه حل در FLN متغیر است و برای غلبه بر این مشکل، حداکثر تعداد نورون ها برای طول ذره در نظر گرفته شده است. برای تابع فعال سازی، خروجی نورون های لایه پنهان استفاده شده است [۲۹].

۳-۵- الگوریتم کرم شب تاب

الگوریتم کرم شب تاب (FA) به عنوان یکی از روش های جدید هوش مصنوعی در این تحقیق مورد استفاده قرار گرفته است. این الگوریتم از رفتار اجتماعی کرم های شب تاب الهام گرفته شده است. این روش نیز مانند بقیه روش های بهینه سازی هوشمند، با جمعیت اولیه ای از حشرات آغاز می شود. در این روش حشرات دوهدهو با هم مقایسه شده و حشره ای که جذابیت کمتری دارد به سمت حشره جذاب تر حرکت می کند. نهایتاً یک حشره به عنوان جذاب ترین حشره انتخاب می شود که همان پاسخ بهینه ای مسئله مورد نظر می باشد.

بررسی مکان و اندازه بهینه واحدهای تولید پراکنده، با ملاحظات فنی و اقتصادی به صورت هم زمان در کنار یکدیگر توسط یک الگوریتم بهینه سازی مناسب می تواند نقش بسزایی را در افزایش سود اقتصادی واحدهای تولید پراکنده داشته از طرفی باعث افزایش کیفیت توان ارائه شده به مشتری گردد. الگوریتم کرم شب تاب یک الگوریتم بر مبنای هوش مصنوعی می باشد که اولین بار در سال ۲۰۰۸ توسط Xin-She Yang مطرح شد این الگوریتم

برچسب کلاس این داده ها را تشخیص داد تا طبقه بندی نمونه های تست که در آینده به مدل اضافه خواهند شد به راحتی صورت گیرد. از این رو در این تحقیق ویژگی های غیر مرتبط و صفت های که تغییرات زیادی در نمونه ها ندارند و طبیعتاً تأثیر چندانی در برچسب کلاس نمی توانند داشته باشند، حذف می شوند تا از تحمیل پیچیدگی اضافی بر مدل طبقه بندی پیشنهادی جلوگیری شود [۲۶].

۳-۳- نرمال سازی داده ها

با توجه به مجموعه ویژگی های انتخاب شده به عنوان معیار شباهت در بخش قبلی، می توان دید که بازه توزیع داده ها در این مجموعه ویژگی ها متفاوت از هم است. طبیعی است که اگر برد مقادیر صفت های داده در معیارهای شباهت متفاوت باشد، در این صورت صفتی که حوزه مقادیر بزرگتری دارد، سایر صفت ها را تحت تأثیر قرار داده و بر روی عملکرد مدل طبقه بندی مورد استفاده مؤثرتر خواهد بود. این تأثیر می تواند دقت طبقه بندی را کاهش داده و موجب پیش بینی نادرست نمونه های تست شود. برای حل این مشکل از نرمال سازی داده ها در مجموعه داده آموزش و تست استفاده می شود [۲۷]. نرمال سازی داده ها موجب نگاشت مقادیر در بازه صفر و یک می شود که تأثیر منفی ویژگی ها با مقادیر بیشتر روی دقت طبقه بندی را از بین می برد. از روابط نرمال سازی معروف موجود در نشریات می توان به نرمال سازی گاوسی و نرمال سازی min-max اشاره کرد که در این تحقیق از نرمال سازی min-max استفاده شده است. در رابطه (۱) نرمال سازی min-max به شرح زیر نشان داده شده است [۲۸]:

$$\min - \max \text{ normalization} = \frac{(x_{i,j} - x_{\min})}{(x_{\max} - x_{\min})} \quad (1)$$

که در آن $x_{i,j}$ مقادیر هر ویژگی به ازای هریک از نمونه ها و x_{\min} کوچک ترین مقدار برای یک ویژگی و x_{\max} بزرگ ترین مقدار برای یک ویژگی است.

۳-۴- شبکه یادگیری عصبی سریع

شبکه یادگیری عصبی سریع (FLN) یک اتصال موازی از یک شبکه تک لایه پیشرو و یک شبکه عصبی ۳ لایه شامل لایه های ورودی، پنهان و خروجی است. FLN، یک شبکه عصبی مصنوعی است که یک شبکه عصبی دوطرفه موازی (DPFNN) می باشد، که با استفاده از یک رویکرد تحلیلی به نام روش کمترین مربع در شکل (۱) نشان داده شده است.

FLN اساساً یک شبکه پیش رو موازی است. این یک اتصال موازی FNN چند لایه و FNN تک لایه را توصیف می کند. همان طور که قبلاً بحث شد، اطلاعات خارجی دوباره کدگذاری شده از گره های پنهان، همراه با اطلاعات خارجی خود، به طور مستقیم از گره های ورودی به گره خروجی از DFNNs ارسال می شود.



در الگوریتم کرم شب تاب مقادیر α ، β_0 و γ ثابت در نظر گرفته می شوند. α و β_0 در بازه $[0, 1]$ و γ در بازه $[0, \infty)$ انتخاب می شود. فلوجارت این الگوریتم در شکل (۲) نشان داده شده است.

۴- پیاده سازی

به منظور پیاده سازی روش پیشنهادی از نرم افزار MATLAB نسخه ۲۰۱۵ استفاده شده است. در این تحقیق داده های استاندارد kddcup.data موجود در مخزن داده استاندارد UCI به کار گرفته شده است. در روش کاهش بعد کرم شب تاب، ابتدا ویژگی های پیوسته مربوط به مجموعه داده جدا شده است. سپس به ازای مقادیر درون هر یک از ویژگی ها، کمترین و بیشترین مقدار ویژگی به منظور نرمال سازی بر طبق (۱) مقادیر درون ویژگی محاسبه شده است. پس از نرمال سازی داده های در ویژگی های پیوسته، این داده های به عنوان ورودی به الگوریتم کرم شب تاب ارائه می شود. وظیفه الگوریتم کرم شب تاب در این مقاله یافتن ارتباط بین ویژگی ها با برچسب کلاس مربوط به داده ها در مجموعه داده آموزشی است. در واقع کرم های شب تاب با توجه به تابع ارزیابی بر طبق (۴)، همبستگی بین ویژگی ها و کلاس داده ها را از طریق

که شباهت بسیار زیادی به الگوریتم PSO دارد از رفتار جمعی کرم های شب تاب در فرایند جفت یابی استفاده می کند.

انتشار نور کرم های شب تاب منظره ی شگفت انگیزی در آسمان برخی از نواحی معتدل مثل تایلند و برخی قسمت های آفریقا ایجاد می کند. بیش از دو هزار شب پره با یک ریتم خاصی به گسیل نور می پردازند. توابع زیادی را می توان از این سیستم اطلاع رسانی مورد بررسی قرار داد اما تابع جذب حشرات دیگر برای جفت یابی مدنظر ما در این الگوریتم می باشد. آهنگ گسیل نور مدت زمان گسیل نور و شدت نوردهی از عوامل متفاوت در جذب حشره نر یا ماده خواهد بود. برای توسعه الگوریتم کرم شب تاب معمولاً از سه قانون ایده آل ساز استفاده می کنند:

- ۱- همه شب پره ها تک جنسی هستند: به طوری که یک شب پره قادر به جذب سایر شب پره ها صرف نظر از جنسیت آن خواهد بود.
- ۲- جذابیت هر شب پره نسبت به میزان نوردهی آن مشخص خواهد شد به نحوی که شب پره با نور کمتر به سمت شب پره با نور بیشتر حرکت خواهد کرد و اگر جذابیت یکسان باشد حرکت تصادفی خواهد بود.
- ۳- نورانیت هر شب پره با تابع هدف تعریف شده خواهد بود [۳۰].

۳-۵-۱- جذابیت و حرکت حشرات

دو موضوع مهم در این الگوریتم، عبارت اند از: ۱- تغییرات شدت روشنایی ۲- فرموله کردن جذابیت. به منظور سادگی معمولاً فرض می شود که جذابیت حشرات با شدت روشنایی آن ها بیان می شود. شدت روشنایی نیز متناسب با برآزندگی حشره می باشد.

در حالت کلی جذابیت پارامتری نسبی بوده و از دید حشرات دیگر سنجیده می شود. همچنین به فاصله حشرات از یکدیگر نیز بستگی دارد. در رابطه (۲) جذابیت با تغییرات فاصله حشرات به صورت زیر نشان داده شده است:

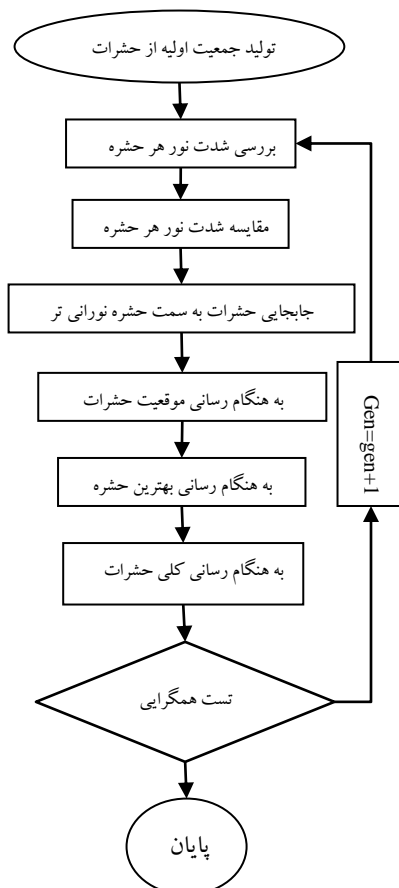
$$\beta = \beta_0 \cdot e^{-\gamma \cdot r} \quad (2)$$

که در آن β_0 بیانگر ماکزیمم جذابیت بوده و مقداری در بازه $[0, 1]$ دارد. γ نیز بیانگر ضریب جذب می باشد و مقداری در بازه $[0, \infty)$ دارد. r بیانگر فاصله حشرات بوده و به عنوان مثال در مقیاس دوبرعدی فاصله حشره i ام از حشره j ام به صورت رابطه (۳) محاسبه می شود:

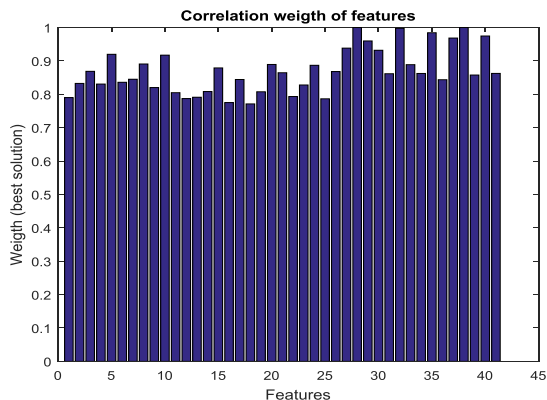
$$r_{ij} = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2} \quad (3)$$

حرکت حشره i ام به سمت حشره j ام نیز از رابطه (۴) به دست می آید:


$$X_i = X_i + \beta \cdot e^{-\gamma \cdot r} (X_j - X_i) + \alpha \cdot (\text{rand} - 0.5) \quad (4)$$



شکل (۲): فلوجارت عملکرد الگوریتم کرم شب تاب [۳۰]



شکل (۳): نمودار وزن همبستگی ویژگی‌ها به برجسب کلاس



شکل (۴): شبکه‌های عصبی پیشنهادی

جدول (۱): خروجی الگوریتم کرم شپ‌تاب

Feature number	Firefly weight	Feature number	Firefly weight	Feature number	Firefly weight
۱	۰/۴۸	۱۴	۰/۵۹	۲۷	۰/۵۷
۲	۰/۵۴	۱۵	۰/۵۷	۲۸	۰/۳۵
۳	۰/۴۴	۱۶	۰/۵۷	۲۹	۰/۰۹۸
۴	۰/۴۹	۱۷	۰/۵۷	۳۰	۰/۱۳
۵	۰/۵۳	۱۸	۰/۶۰	۳۱	۰/۲۰
۶	۰/۵۸	۱۹	۰/۸۹	۳۲	۰/۱۹
۷	۰/۴۹	۲۰	۰/۴۵	۳۳	۰/۶۰
۸	۰/۵۱	۲۱	۰/۱۱۸	۳۴	۰/۷۴
۹	۰/۴۶	۲۲	۰/۸۲	۳۵	۰/۴۴
۱۰	۰/۵۴	۲۳	۰/۷۳	۳۶	۰/۴۶
۱۱	۰/۵۶	۲۴	۰/۴۰	۳۷	۰/۴۱
۱۲	۰/۴۸	۲۵	۰/۹۱	۳۸	۰/۵۲
۱۳	۰/۵۹	۲۶	۰/۸۹	-	-

در نهایت مقدار وزن برای هر یک از کلاس‌ها از لایه میانی به لایه خارجی ارسال می‌شود. با اعمال این وزن‌ها در مقادیر صفت‌ها، در صورتی که نتایج در آستانه مشخص شده صدق کنند، به کلاس مربوط به وزن‌ها اختصاص می‌یابند. در واقع می‌توان گفت نتایج حاصل از ضرب وزن‌ها در مقادیر صفت یک نمونه برای هر یک از کلاس‌ها بیشتر باشد، نمونه مورد نظر به آن کلاس اختصاص خواهد یافت.

۴-۱- ارزیابی روش پیشنهادی

برای سنجش دقت مدل پیشنهادی در این تحقیق، نرخ پیش‌بینی صحیح نمونه‌ها در مراحل آموزش مدل روی داده‌های آموزشی، اعتبار سنجی و

محاسبه حرکت حشرات بر طبق (۲) فاصله حشرات بر طبق (۳) بررسی می‌کنند. کرم‌های شپ‌تاب بر اساس مقادیر ویژگی و همبستگی هر یک از ویژگی‌ها با برجسب کلاس، به سمت ویژگی‌های مؤثر جمع شده‌اند. بنابراین ویژگی‌های مهم برای طبقه‌بندی نفوذ در شبکه را می‌توان بر اساس خروجی الگوریتم بهینه‌سازی کرم شپ‌تاب پیشنهادی تعیین کرد.

همان‌طور که در جدول (۱) نشان داده شده است، مقادیر وزن همبستگی برای هر یک از ویژگی‌ها محاسبه شده است. بیشترین مقدار مربوط به ویژگی‌هایی است که بیشترین همبستگی را به برجسب کلاس دارند. همچنین شکل (۳) نمودار میله‌ای مربوط به وزن همبستگی ویژگی‌ها به برجسب کلاس را نشان می‌دهد.

همان‌طور که در شکل (۳) نشان داده شده است، با تعیین آستانه‌ای می‌توان ویژگی‌های مربوط مهم را در مجموعه داده‌های مربوط به تشخیص نفوذ در شبکه، تعیین کرد. مقدار این آستانه باید طوری انتخاب شود که داده‌های کاهش یافته به عنوان نمایندگی داده‌های اصلی در نظر گرفته شده و دقت تشخیص نفوذ در شبکه را تحت تأثیر خود قرار ندهد. از این‌رو در مقاله مقدار آستانه $\alpha=0.9$ برای انتخاب ویژگی‌ها استفاده شده است. در واقع ویژگی‌هایی که وزن همبستگی بیشتر از ۰.۹ دارند در مجموعه داده‌ها باقی‌مانده و مابقی ویژگی‌های از مجموعه داده حذف می‌شوند. این مقدار آستانه بر اساس شبیه‌سازی و تعیین بیشترین دقت ویژگی‌های باقیمانده صورت گرفته است. بر این اساس تعداد ۱۱ ویژگی با اهمیت به منظور کشف نفوذ در شبکه‌های بی‌سیم باقی‌مانده و مابقی حذف می‌شوند. ویژگی‌های باقیمانده به عنوان ورودی شبکه‌های عصبی و شبکه یادگیری عصبی سریع پیشنهادی مورد استفاده قرار می‌گیرد.

در شبکه‌های عصبی مصنوعی مجموعه داده‌ها به سه قسمت آموزشی، اعتبار سنجی و تست تقسیم می‌شود. بخش اعتبار سنجی برای سنجش عملکرد مدل در ازای داده‌های آموزشی است. شبکه‌های عصبی مصنوعی در لایه میانی بر اساس صفات داده‌های آموزشی، مدلی را آموزش می‌دهد. اعتبار این مدل در مرحله اول از طریق قسمتی از داده‌ها که اعتبار سنجی نامیده می‌شود، انجام می‌گیرد. زمانی که دقت عملکرد مدل آموزشی برای داده‌های آموزشی در حد قابل قبولی باشد، دقت عملکرد مدل برای داده‌های تست و داده‌های ناشناخته، از طریق دیگر قسمت داده‌ها که تست نامیده می‌شود، مورد سنجش قرار می‌گیرد. شکل (۴) شبکه‌های عصبی توسعه یافته در این تحقیق را نشان می‌دهد.

همان‌طور که در شکل (۴) نشان داده شده است، شبکه‌های عصبی مورد استفاده برای این تحقیق شامل سه لایه ورودی، میانی و خروجی است که تعداد گره‌ها در لایه ورودی برابر با تعداد ویژگی‌های مورد استفاده بعد از اعمال گام پیش‌پردازشی و کاهش ابعاد با استفاده از الگوریتم بهینه‌سازی کرم شپ‌تاب است.

مقادیر وزن کلاس‌ها در لایه‌های میانی بر اساس تابع آموزشی یادشده بررسی می‌شود و برای هر یک از ویژگی‌ها وزنی به لایه بعدی انتقال می‌یابد.



افزایش عملکرد سیستم تشخیص نفوذ در شبکه، مراحل آموزشی را تا حدی که دقت موردنظر به دست آید ادامه می‌دهد. از این رو نمودار دقت روش پیشنهادی نسبت به روش شبکه‌های عصبی مصنوعی مقدار بهتری دارد. در واقع روش پیشنهادی توانسته است، درصد بیشتری از گره‌های حمله و گره‌های سالم را به درستی تشخیص دهد.

۴-۲- مقایسه روش پیشنهادی با روش‌های پیشین

پس از ارزیابی روش پیشنهادی با استفاده از معیارهای مرسوم در زمینه سیستم‌های تشخیص نفوذ در شبکه، حال نوبت به مقایسه روش پیشنهادی با سایر روش‌های پیشین به منظور بررسی میزان بهبود روش پیشنهادی نسبت و سایر روش‌هاست. با توجه به اهمیت سیستم‌های تشخیص نفوذ در شبکه که در فصل‌های قبلی نیز اشاره شد، محققان زیادی در این زمینه تلاش کرده‌اند که در ادامه روش پیشنهادی را به منظور بررسی نقاط ضعف و قوت آن با برخی از این روش‌ها مقایسه خواهیم کرد. از آنجایی که تلاش بیشتر سیستم‌های تشخیص نفوذ در شبکه در راستای افزایش دقت پیش‌بینی گره‌های مخرب در شبکه است، پس مقایسه‌ها بر پایه معیارهای ماتریس آشفتگی که شامل نرخ طبقه‌بندی، نرخ تشخیص، دقت، حساسیت، نرخ تشخیص خطا و معیار F می‌باشد، استوار است. از این رو در جدول (۳) مقایسه روش پیشنهادی با روش‌های پیشین [۲۹، ۳۳، ۳۴] نشان داده شده است.

همان‌طور که در جدول (۳) نشان داده شده است، روش پیشنهادی از روش‌های پیشین از لحاظ زمان و نرخ خطای منفی و معیار حساسیت عملکرد بهتری دارد و در کل با سایر سیستم‌های تشخیص نفوذ قابل مقایسه است.

۵- نتیجه

جولوگیری و کشف نفوذها و حملات در شبکه‌های حسگر بی‌سیم به یک امر حیاتی و چالشی جدی تبدیل شده است. از سوی دیگر با توجه به انرژی محدود گره‌های حسگر بی‌سیم، استفاده از گره‌های ناظر برای نظارت دائمی در شبکه‌های حسگر بی‌سیم به منظور جولوگیری و کشف نفوذ و حملات را در این نوع از شبکه‌ها عملاً غیرممکن کرده است. از این رو راه‌حلی برای غلبه بر این مشکل، امروزه بحث سیستم‌های کنترلی و نظارت از راه دور بر مباحث موردعلاقه در زمینه‌های مختلف تبدیل شده است. نظارت از راه دور بر عملکرد و رفتار گره‌های موجود در شبکه‌های حسگر بی‌سیم علاوه بر تشخیص گره‌های مخرب و بدرفتار درون شبکه، می‌تواند به پیش‌بینی رفتار گره‌های بدرفتار در آینده نیز بیانجامد. از این رو در این پژوهش برای غلبه بر این مشکل از یک روش ترکیبی بر اساس انتخاب زیرمجموعه ویژگی مبتنی بر الگوریتم کرم شب‌تاب و شبکه یادگیری عصبی سریع استفاده شد. نتایج آزمایش‌ها نشان می‌دهد که دقت عملکرد روش پیشنهادی ۹۹.۹٪ بوده است که این مقدار در حد بالایی بوده و با سایر روش‌های پیشین قابل مقایسه است.

آزمایشی در مراحل تکرار مدل، مورد بررسی قرار می‌گیرد. بدین منظور ماتریسی با عنوان ماتریس آشفتگی^۵ رسم می‌شود که در آن تعداد داده‌های درست طبقه‌بندی شده در مقابل داده‌های غلط طبقه‌بندی شده در مراحل آموزش، اعتبار سنجی و آزمایش داده‌ها مشخص می‌شود [۳۱، ۳۲]. این ماتریس شامل چهار عنصر مثبت صحیح^۶ (TP)، مثبت کاذب^۷ (FP)، منفی صحیح^۸ (TN) و منفی کاذب^۹ (FN) به شرح زیر است:

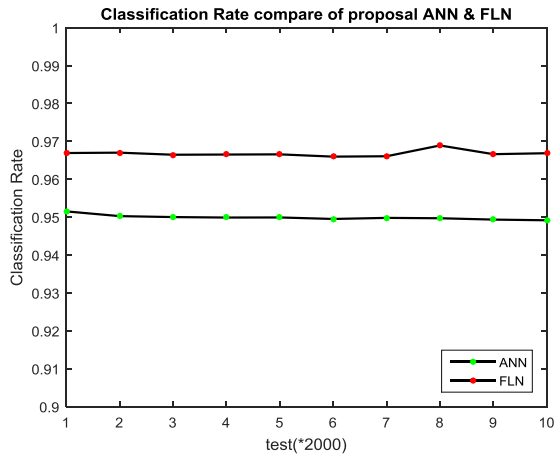
- TP: گره‌های سالم که کلاس واقعی آن‌ها نیز سالم است.
- TN: گره‌های نفوذ که کلاس واقعی آن‌ها سالم است.
- FP: گره‌های نفوذ که کلاس واقعی آن‌ها نفوذ است.
- FN: گره‌های سالم که کلاس واقعی آن‌ها نفوذ است.

حال پس از استخراج پارامترهای ماتریس آشفتگی، می‌توان معیارهای ارزیابی را بر اساس ماتریس آشفتگی به دست آورد. این معیارها شامل دقت، حساسیت، صحت، نرخ طبقه‌بندی، نرخ تشخیص، نرخ خطای مثبت و معیار F را به دست آورد. شکل (۵) مقایسه ماتریس آشفتگی مربوط به روش پیشنهادی و شبکه عصبی را نشان می‌دهد.

همان‌طور که در شکل (۵) نشان داده شده است، در روش پیشنهادی ۹۶.۷ درصد از کل داده‌ها در مجموعه داده که شامل داده‌های آموزشی، اعتبار سنجی و آزمایشی است، به درستی طبقه‌بندی شده‌اند. این در حالی است که شبکه عصبی در مجموع ۹۴.۹ درصد داده‌ها به درستی طبقه‌بندی کرده است. در جدول (۲) مقایسه مقادیر مربوط به روش پیشنهادی و شبکه عصبی نشان داده شده است.

همان‌طور که در جدول (۲) نشان داده شده است، روش پیشنهادی از لحاظ معیارهای ارزیابی نسبت به شبکه عصبی عملکرد بهتری دارد. در شکل (۶) نمودار مربوط به مقایسه معیار نرخ طبقه‌بندی (دقت) بین روش پیشنهادی و شبکه عصبی در ده مرحله از Cross-validation 10-fold نشان داده شده است. نرخ طبقه‌بندی در روش پیشنهادی به صورت نرخ تشخیص گره‌های سالم و گره‌های مخرب در میان تمام گره‌های موجود در مجموعه داده است.

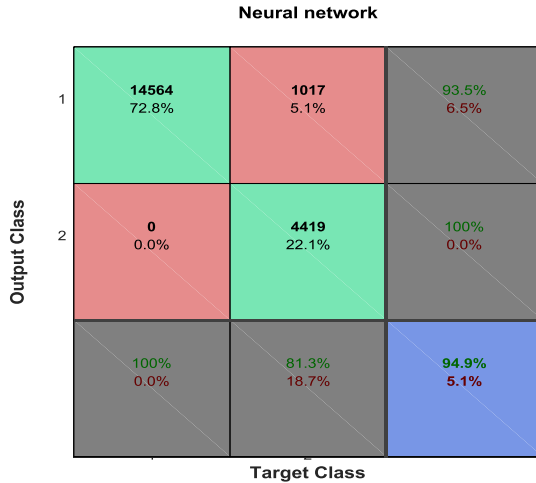
همان‌طور که در شکل (۶) نشان داده شده است، روش پیشنهادی از لحاظ نرخ طبقه‌بندی (دقت) نسبت به روش شبکه عصبی بهبود داشته است. در روش شبکه‌های عصبی با توجه به این که روند آموزش به صورت کامل صورت می‌گیرد، ممکن است مدل دچار Overfitting شود. در این پدیده مدل تمرکز خود را بر روی نمونه‌های آموزشی منعطف می‌کند و تمامی ویژگی‌ها و روابط بین نمونه‌های آموزشی را فرامی‌گیرد و دقت آن در طبقه‌بندی نمونه‌های آموزشی به حداکثر مقدار خود می‌رسد. حال آنکه زمانی که نمونه‌های تستی جدید که قبلاً مدل آن‌ها را مشاهده نکرده است، وارد سیستم می‌شود، ممکن است مدل در تشخیص روابط بین ویژگی‌های نمونه‌های جدید که متفاوت از نمونه‌های آموزشی است، دقت کافی را نداشته و عملکرد سیستم کاهش یابد. بنابراین روش پیشنهادی به منظور جولوگیری از Overfitting و



شکل (۶): مقایسه نرخ طبقه‌بندی (دقت) روش پیشنهادی و شبکه عصبی

جدول (۲) : مقادیر مربوط به معیارهای ارزیابی

معیار	روش پیشنهادی	شبکه عصبی
CR (Accuracy)	٪۹۹/۶۸	٪۹۴/۹۲
FPR	٪۰/۰۴۳۱	٪۰/۰۶۵۳
TPR	٪۹۹/۹۵	٪۹۸/۳۲
Precision	٪۹۵/۶۹	٪۸۱/۲۹
DR (Recall)	٪۹۹/۸۲	٪۱۰۰
F-measure	٪۹۷/۷۱	٪۸۹/۶۸



شکل (۵): مقایسه ماتریس آشفتگی روش پیشنهادی و شبکه عصبی

جدول (۳) : مقادیر مربوط به معیارهای ارزیابی

Time (s)	F-measure	DR (Recall)	Precision	TNR	FPR	CR (Accuracy)	معیار
۷۴/۴۸۱۴	٪۹۷/۷۱	٪۹۹/۸۲	٪۹۵/۳۳	٪۹۹/۹۵	٪۰/۰۴۳۱	٪۹۶/۶۸	روش پیشنهادی
۸۷/۳۰۶۴	٪۸۹/۶۸	٪۱۰۰	٪۸۱/۲۹	٪۹۸/۳۲	٪۰/۰۶۵۳	٪۹۴/۹۲	شبکه عصبی
۲۳۹/۹۶	٪۹۸/۴۸	٪۹۹/۱۳	٪۹۸/۳۳	٪۹۹/۰۸	٪۰/۰۹۲	٪۹۸/۹۲	روش ساخت افزایش تطبیقی (CAI)
۲۹۳۹/۸۸	٪۹۹	٪۹۹/۲۴	٪۹۹/۷۸	٪۹۸/۸۶	٪۱/۱۴	٪۹۹/۰۴	ماشین پشتیبان بردار (SVM)
۷۶۲۲/۱۵	٪۹۹/۱۱	٪۹۸/۶۳	٪۹۹/۰۸	٪۹۹/۱۵	٪۰/۰۸۵	٪۹۹/۱۴	شبکه پرسپترون چندلایه (MLP)
-	٪۹۷/۱۹	٪۹۵/۸۲	٪۹۸/۶۱	٪۹۹/۹۲	٪۰/۰۷۶۶	٪۹۵/۴	HSO based FLN
-	٪۹۲/۱۷	٪۹۲/۷۴	٪۹۱/۶۱	٪۸۹/۹۹	٪۰/۰۰۰۱	٪۹۱/۴۸	ATLBO based FLN
-	٪۹۶/۶۴	٪۹۴/۷۴	٪۹۸/۶۱	٪۹۹/۸۳	٪۰/۰۱۶۶	٪۹۵/۳۵	GA based FLN
-	٪۹۵/۹۹	٪۹۳/۶۴	٪۹۸/۴۵	٪۹۹/۸۲	٪۰/۰۱۷۸	٪۹۵/۷۱	PSO based FLN
۲۰۴۶۰۰	٪۹۷/۴۷	٪۹۷/۹۱	٪۹۷/۸۱	٪۹۹/۷۹	٪۰/۰۲۱	٪۹۷/۹۰	DBN
۲۴۴۶	٪۹۸/۱۵	٪۹۷/۸۵	٪۹۹/۹۹	٪۹۹/۷۸	٪۰/۰۲۱۵	٪۹۷/۸۵	S-NDAE



- Express, 2019. **5**(1): p. 56-59.
- [16] Dhanalakshmi, K. and B. Kannapiran, *Analysis of KDD CUP Dataset Using Multi-Agent Methodology with Effective Fuzzy Based Intrusion Detection System*. Journal of Applied Security Research, 2017. **12**(3): p. 424-439.
- [17] Selvakumar, B. and K. Muneeswaran, *Firefly algorithm based feature selection for network intrusion detection*. Computers & Security, 2019. **81**: p. 148-155.
- [18] Abedin, M., et al. *Performance Analysis of Anomaly Based Network Intrusion Detection Systems*. in *The 43rd IEEE Conference on Local Computer Networks (LCN)*. 2018. IEEE Computer Society.
- [19] Chiba, Z., et al., *A novel architecture combined with optimal parameters for back propagation neural networks applied to anomaly network intrusion detection*. Computers & Security, 2018. **75**: p. 36-58.
- [20] Gupta, A. and A. Dubey, *A Survey on Various Applications and Blackhole Attack in Mobile Ad Hoc Network*. Recent Trends in Parallel Computing, 2018. **5**(1): p. 1-6.
- [21] Chellam, A., L. Ramanathan, and S. Ramani, *Intrusion Detection in Computer Networks using Lazy Learning Algorithm*. Procedia computer science, 2018. **132**: p. 928-936.
- [22] Ashfaq, R.A.R., et al., *Fuzziness based semi-supervised learning approach for intrusion detection system*. Information Sciences, 2017. **378**: p. 484-497.
- [23] Karatas, G. and O.K. Sahingoz. *Neural network based intrusion detection systems with different training functions*. in *2018 6th International Symposium on Digital Forensic and Security (ISDFS)*. 2018. IEEE.
- [24] Giokas, I., *Systems and methods for self-tuning network intrusion detection and prevention*. 2016, Google Patents.
- [25] Al-Utaibi, K.A. and E.-S.M. El-Alfy, *Intrusion detection taxonomy and data preprocessing mechanisms*. Journal of Intelligent & Fuzzy Systems, 2018. **34**(3): p. 1369-1383.
- [26] Madbouly, A.I. and T.M. Barakat, *Enhanced relevant feature selection model for intrusion detection systems*. International Journal of Intelligent Engineering Informatics, 2016. **4**(1): p. 21-45.
- [27] Protić, D. and M. Stanković, *Anomaly-Based Intrusion Detection: Feature Selection and Normalization Influence to the Machine Learning Models Accuracy*. European Journal of Engineering and Formal Sciences, 2018. **2**(3): p. 101-106.
- [28] Jain, Y.K. and S.K. Bhandare, *Min max normalization based data perturbation method for privacy protection*. International Journal of Computer & Communication Technology, 2011. **2**(8): p. 45-50.
- [29] Ali, M.H., et al., *A new intrusion detection system based on fast learning network and particle swarm optimization*. IEEE Access, 2018. **6**: p. 20255-20261.
- [30] Tilahun, S.L., J.M.T. Ngnotchouye, and N.N. Hamadneh, *Continuous versions of firefly algorithm: A review*. Artificial Intelligence Review, 2019. **51**(3): p. 445-492.
- [31] Jamali, S. and Y.D. Navaei, *A two-level Product*
- مراجع
- [1] Liu, X., et al., *Information-centric mobile ad hoc networks and content routing: a survey*. Ad Hoc Networks, 2017. **58**: p. 255-268.
- [2] Rosas, E., et al., *Survey on simulation for mobile ad-hoc communication for disaster scenarios*. Journal of Computer Science and Technology, 2016. **31**(2): p. 326-349.
- [3] Rastegari, S., P. Hingston, and C.-P. Lam, *Evolving statistical rulesets for network intrusion detection*. Applied soft computing, 2015. **33**: p. 348-359.
- [4] Young, C., et al., *Survey of Automotive Controller Area Network Intrusion Detection Systems*. IEEE Design & Test, 2019.
- [5] Fotohi, R. and S. Jamali, *A comprehensive study on defence against wormhole attack methods in mobile Ad hoc networks*. International journal of Computer Science & Network Solutions, 2014. **2**: p. 37-56.
- [6] Liu, G., Z. Yan, and W. Pedrycz, *Data collection for attack detection and security measurement in mobile ad hoc networks: A survey*. Journal of Network and Computer Applications, 2018. **105**: p. 105-122.
- [7] Gupta, A.M.V., *Comprehensive survey on Blackhole attack with various Detection/Prevention techniques in Ad-hoc network*. International Journal of Applied Engineering Research, 2019. **14**(8): p. 2009-2017.
- [8] Yeruru, S.V. and T.R. Rangaswamy, *An Anomaly-Based Intrusion Detection System with Multi-Dimensional Trust Parameters for Mobile Ad Hoc Network*. International Journal of Intelligence Engineering and Systems, 2017. **10**(4): p. 81-90.
- [9] Rajalakshmi, D. and K. Meena, *A Survey of intrusion detection with higher malicious misbehavior detection in Manet*. International journal of civil engineering and technology, 2017. **8**.
- [10] Jamali, S. and V. Shaker, *Defense against SYN flooding attacks: a particle swarm optimization approach*. Computers & Electrical Engineering, 2014. **40**(6): p. 2013-2025.
- [11] Babasaheb, D.R. and I. Raman. *Survey on Fault Tolerance and Security in Mobile Ad Hoc Networks (MANETs)*. in *2018 3rd International Conference for Convergence in Technology (I2CT)*. 2018. IEEE.
- [12] Soms, N. and P. Malathi, *Evolution of Intrusion Detection System in MANETs—A Survey*. International Journal of Innovations & Advancement in Computer Science (IJIACS), 2017. **6**(5).
- [13] Jamali, S. and R. Fotohi, *DAWA: Defending against wormhole attack in MANETs by using fuzzy logic and artificial immune system*. the Journal of Supercomputing, 2017. **73**(12): p. 5173-5196.
- [14] Scholar, M.T., S. GORAKHPUR, and I.C. Choubey, *A survey on malicious nodes in mobile ad hoc network*. Journal of Network Communications and Emerging Technologies (JNCET) www.jncet.org, 2016. **6**(3).
- [15] Hajimirzaei, B. and N.J. Navimipour, *Intrusion detection for cloud computing using neural networks and artificial bee colony optimization algorithm*. ICT



- Recommender for E-commerce Sites by Using Sequential Pattern Analysis*. International Journal of Integrated Engineering, 2016. **8**(1).
- [32] Jamali, S. and G. Shaker, *PSO-SFDD: Defense against SYN flooding DoS attacks by employing PSO algorithm*. Computers & Mathematics with Applications, 2012. **63**(1): p. 214-221.
- [33] Gurung, S., M.K. Ghose, and A. Subedi, *Deep Learning Approach on Network Intrusion Detection System using NSL-KDD Dataset*. International Journal of Computer Network and Information Security (IJCNIS), 2019. **11**(3): p. 8-14.
- [34] Wang, C.-R., et al., *Network intrusion detection using equality constrained-optimization-based extreme learning machines*. Knowledge-Based Systems, 2018. **147**: p. 68-80.

زیر نویس ها

-
- ¹ Fast Learning Neural Network
² Particle swarm optimization
³ Bayesian Networks
⁴ Extreme learning machines
⁵ Confusion Matrix
⁶ True Positive
⁷ False Positive
⁸ True Negative
⁹ False Negative