

A Model for Multi-Class Intrusion Detection Using Machine Learning and Dragonfly Feature Selection

M. Niaei, J. Tanha^{*}, G. Shahmohammadi, A. R. Pourebrahimi

^{*} Associate Professor, Faculty of Electrical and Computer Engineering, Tabriz University, Tabriz, Iran

(Received: 08/10/2021, Accepted: 22/06/2022)

ABSTRACT

With the increase of the network services, the number and complexity of attacks in cyberspace has increased. This problem has made network security as one of the most important challenges in the world of information technology. Intrusion detection systems are used as a very important defense method to detect network attacks, to warn network security admins. This research has proposed a model for multi-class intrusion detection system. In this model, the dragonfly algorithm is used for feature selection and the random forest algorithm is used for classification. for data analysis KDD-99 dataset has been used. The model has been tested with different machine learning and deep learning algorithms then the best algorithm has been selected. The accuracy value in the proposed method is 0/9967 The results have been compared with the results of several other studies published in authoritative articles. This comparison shows that the proposed method has a higher accuracy than most other methods.

Keywords: Intrusion Detection, Multi-Class, Feature Selection, Dragonfly Algorithm, Random Forest.

^{*} Corresponding Author Email: Tanha@tabrizu.ac.ir

This article is an open-access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license.

مدلی برای تشخیص نفوذ چندکلاسه با استفاده از یادگیری ماشین و انتخاب ویژگی سنجاک

محمود نیائی^۱، جعفر تنها^۲، غلامرضا شاهمحمدی^۳، علیرضا پورابراهیمی^۴

۱- دانشجوی دکتری رشته مدیریت فناوری اطلاعات، گروه مدیریت فناوری اطلاعات، دانشکده مدیریت و اقتصاد، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ۲- دانشیار، دانشکده مهندسی برق و کامپیوتر، دانشگاه تبریز، تبریز، ۳- دانشیار، دانشکده مهندسی برق و کامپیوتر، دانشگاه ایوانکی، سمنان،

۴- استادیار، دانشکده مدیریت و حسابداری، واحد کرج، دانشگاه آزاد اسلامی، کرج، ایران

(دریافت: ۱۴۰۰/۰۷/۱۶، پذیرش: ۱۴۰۱/۰۴/۰۱)

چکیده

با افزایش خدمات شبکه‌ای، تعداد و پیچیدگی حملات در فضای سایبر افزایش یافته است؛ لذا سامانه‌های تشخیص نفوذ که به‌منظور کشف فعالیت‌های غیرعادی در شبکه‌ها مورد استفاده قرار می‌گیرند، در سال‌های اخیر مورد توجه بسیاری از محققین قرار گرفته است. سیستم‌های تشخیص نفوذ به‌عنوان یک روش دفاعی بسیار مهم برای تشخیص حملات شبکه‌ای، به‌منظور هشدار به مسئولین شبکه یا برنامه‌های کاربردی به کار می‌رود. در این پژوهش، یک مدل برای تشخیص نفوذ چندکلاسه پیشنهاد شده است. در روش پیشنهادی از الگوریتم سنجاک برای انتخاب ویژگی و از الگوریتم جنگل تصادفی به‌منظور دسته‌بندی استفاده شده است. داده‌های به‌کاررفته در پژوهش، مجموعه داده KDD-99 بوده است. مسئله با الگوریتم‌های مختلف یادگیری ماشین و یادگیری عمیق مورد آزمون قرار گرفته و بهترین الگوریتم انتخاب شده است. معیار صحت در روش پیشنهادی مقدار ۰/۹۹۶۷ به دست آمده است. نتایج پژوهش با نتایج چندین پژوهش دیگر که توسط محققان پیشنهاد شده مورد مقایسه قرار گرفته است و این مقایسه نشان می‌دهد که روش پیشنهادی نسبت به اکثر روش‌های دیگر دارای مقدار صحت بالاتری بوده است.

کلیدواژه‌ها: تشخیص نفوذ، چند کلاسه، الگوریتم سنجاک، جنگل تصادفی، انتخاب ویژگی

۱- مقدمه

کار گرفته می‌شود [۲]. همچنین، در این پژوهش به‌منظور تشخیص و دسته‌بندی حملات ترافیک شبکه، از الگوریتم جنگل تصادفی^۴ استفاده شده است. انتخاب این روش، پس از اعمال روش‌های مختلف و آزمون آن‌ها، به دلیل عملکرد مناسب و میزان صحت، دقت و سرعت بالاتر، بوده است. در این تحقیق از مجموعه‌های داده‌های KDD-99 استفاده شده است سیستم موردتحقیق، علاوه بر تشخیص حمله یا غیرحمله بودن ترافیک وارده، توانایی تشخیص نوع حملات را نیز دارد.

در بخش دوم مقاله، پژوهش‌های پیشین بررسی خواهند شد و در بخش سوم الگوریتم‌های روش پیشنهادی معرفی می‌شوند. سپس نتایج تحقیق در بخش چهارم بیان خواهد شد و بخش پنجم به جمع‌بندی روش پیشنهادی می‌پردازد.

۲- پژوهش‌های پیشین

سیستم‌های تشخیص نفوذ را از نظر نوع فناوری تشخیص، می‌توان به روش‌های تشخیص آماری، روش‌های تشخیص مبتنی بر دانش و روش‌های مبتنی بر یادگیری ماشین تقسیم نمود.

مروری بر وقایع و حوادث سال‌های اخیر کشورها، مؤید این واقعیت است که بخش عمده‌ای از تهدیدهای موجود علیه کشورها، برای تسلط بر زیرساخت‌های حیاتی سایبری آنان بوده است؛ بنابراین با توجه به آسیب‌پذیری‌های ذاتی موجود در فضای سایبری و روند روبه‌رشد مهاجرت از دنیای سنتی به این فضا، ریسک سامانه‌های مبتنی بر فناوری اطلاعات که برای کشورها حیاتی هستند، افزایش یافته است. براین اساس ارتقای پایداری عملیاتی و امنیت و مصون‌سازی زیرساخت‌ها به‌ویژه مراکز حیاتی و حساس برای کشورها بسیار حائز اهمیت تلقی می‌شود [۱].

در این پژوهش، یک روش تشخیص نفوذ چندکلاسه^۱ پیشنهاد شده است. این روش از انتخاب ویژگی با الگوریتم سنجاک^۲ استفاده می‌کند. الگوریتم سنجاک که برای اولین بار در سال ۲۰۱۵ ارائه شده است، در مسائل سخت فاقد^۳ راه‌حل به

* رایانامه نویسنده مسئول: Tanha@tabrizu.ac.ir

¹ Multi-Class

² Dragonfly Algorithm

³ NP-Hard

⁴ Random Forest

شده است و ترکیبی از دو نوع یادگیری با برچسب و یادگیری با داده‌های بدون برچسب از کلاس‌های دیگر می‌باشد. نتایج پژوهش فوق با چند روش دیگر مقایسه گردیده و حداکثر مقدار صحت ۰/۹۸۸۴ درصد مربوط به STL گزارش شده است.

چنانچه مشاهده می‌شود، در برخی مقالات تشخیص نفوذ به‌صورت باینری بررسی شده‌اند و توانایی تشخیص نوع حمله را نداشته‌اند. همچنین در اکثر مقالات فقط معیار صحت^۲ محاسبه شده است.

به‌منظور رفع موارد فوق، در پژوهش حاضر روشی موردبررسی قرار گرفته که بتواند نوع حملات را نیز مشخص نماید. همچنین معیارهای دقت، بازخوانی و F1-Score نیز محاسبه شده و با چندین الگوریتم یادگیری ماشین و عمیق مورد مقایسه قرار گیرد. در این پژوهش از یک روش جدید انتخاب ویژگی استفاده شده تا حجم محاسبات و زمان اجرای روش تا اندازه زیادی کاهش یابد. در ضمن، چنانچه در بخش چهار مشاهده خواهد شد نتایج روش پیشنهادی از نتایج حاصل از اکثر پژوهش‌های انجام‌شده بهتر بوده است.

۳- روش پیشنهادی

سیستم‌های تشخیص نفوذ که با رویکردهای معمول یادگیری ماشین ارائه می‌شود، اغلب دارای مشکلاتی هستند، مانند مشکل انتخاب ویژگی توسط افراد خبره یا مشکل کاهش ابعاد برای حذف نویز در برخورد با داده‌های با ابعاد بسیار زیاد که معمولاً منجر به حذف اطلاعات قابل توجهی از مجموعه‌داده‌ها می‌شود. همچنین در مواردی که متغیرهای ترافیک شبکه پیچیده و تعداد آن‌ها بسیار زیاد باشد.

برای کاهش مشکلات فوق، در این پژوهش روشی پیشنهاد شده که ویژگی‌ها با استفاده از یک الگوریتم فراابتکاری^۳ به نام الگوریتم سنجاقک انتخاب می‌شوند. همچنین دسته‌بندی حملات با استفاده از الگوریتم جنگل تصادفی صورت می‌پذیرد. در ادامه این بخش، ابتدا مجموعه‌داده‌های مورد استفاده معرفی و سپس الگوریتم سنجاقک و جنگل تصادفی تشریح و در نهایت الگوریتم مدل پیشنهادی معرفی شده است.

۳-۱- معرفی مجموعه‌داده

در این پژوهش، از مجموعه‌داده KDD-99 استفاده شده است. این مجموعه‌داده یکی از پر استفاده‌ترین مجموعه‌داده‌ها در زمینه تشخیص نفوذ است که به‌صورت عمومی در دسترس می‌باشد. KDD-99 که توسط آزمایشگاه ام‌آی‌تی لینکلن جمع‌آوری شده،

استفاده از تکنیک‌های یادگیری ماشین برای تشخیص ناهنجاری، مبتنی بر ساختن مدلی است که توسط آموزش روی مجموعه‌داده‌های قبلی به دست می‌آید. چنین مدلی قابلیت تعمیم روی نمونه‌های بعدی را دارد و می‌تواند با کارایی بالایی برای دسته‌بندی نمونه‌های جدید مورد استفاده قرار گیرد [۳].

در منبع شماره [۴] از یک روش ترکیبی برای تشخیص نفوذ استفاده شده است. در این پژوهش از ترکیب درخت تصمیم و جنگل تصادفی استفاده شده که توانایی انجام رگرسیون و طبقه‌بندی را دارد. سادگی برنامه‌نویسی، تمایل به غیرخطی بودن و محدود کردن شرایط با استفاده از درخت تصمیم ممکن است. مقدار صحت به‌دست‌آمده در این روش ۰/۹۷ می‌باشد.

در منبع [۵] ابتدا داده‌ها با استفاده از درخت سلسله‌مراتبی به دسته‌هایی تقسیم شده‌اند، سپس با استفاده از الگوریتم SVM داده‌های نرمال و مشکوک به حمله، تشخیص داده می‌شود. صحت در این مقاله مقدار ۰/۹۶۷۷ محاسبه شده است.

در سال ۲۰۲۰ پژوهشگر [۶]، برای تشخیص نفوذ، از روش یادگیری CNN و DNN روی مجموعه‌داده NSL-KDD به‌صورت چند کلاس استفاده کرده‌اند. حداکثر مقادیر به‌دست‌آمده در این بررسی، صحت ۰/۷۷۶۹، دقت ۰/۷۳۹۲، بازخوانی ۰/۵۲۸۶ و F1-Score برابر با ۰/۵۳۵۲ برای CNN بوده است.

در پژوهشی دیگر در سال ۲۰۱۹، از روش تشخیص ویژگی‌ها به‌منظور کشف نفوذ استفاده شده است. در این روش ابتدا با استفاده از روش فیلتر FGLCC و خوشه‌بندی، ویژگی‌ها تشخیص داده می‌شوند، سپس با استفاده از روش درخت تصمیم‌گیری در ارتباط با داده‌های عادی و یا نفوذ تصمیم‌گیری انجام می‌شود. در این روش از مجموعه‌داده KDD استفاده شده و دقت نهایی ۰/۹۵۰۳ درصد گزارش شده است [۷].

در مقاله‌ای دیگر، چوداری و همکارانشان [۸] از یک شبکه عصبی عمیق بر روی مجموعه‌داده KDD-99 و دو مجموعه‌داده دیگر به‌صورت باینری استفاده کرده‌اند. در این پژوهش مجموعه‌داده KDD-99 و دو مجموعه‌داده دیگر مورد بررسی قرار گرفته و مقدار صحت نهایی در این روش ۰/۹۶۰۳ درصد محاسبه شده است. لازم به ذکر است که این پژوهش، توانایی تشخیص نفوذ و عدم نفوذ را در سیستم داشته و نوع حمله در آن تشخیص داده نمی‌شود.

در سال ۲۰۱۵ در یک پژوهش دیگر [۹]، از روش یادگیری STL^۱ بر روی مجموعه‌داده NSL-KDD هم به‌صورت باینری و هم چند کلاس استفاده کرده است. یادگیری STL نوعی یادگیری ماشین است که توسط محققان استنفورد در سال ۲۰۰۷ معرفی

^۲ Accuracy

^۳ Meta-heuristic Algorithms

^۱ Self-taught learning

$$S_i = -\sum_{j=1}^N X - X_j \quad (1)$$

که X موقعیت فعلی سنجاکف، X_j موقعیت همسایه X بوده و N اندازه فضای موجود است.

۲- تابع سرعت^{۱۰}: این تابع سرعت سنجاکفها را با توجه به سنجاکفهای همسایه به صورت (۲) محاسبه می کند.

$$A_i = \frac{\sum_{j=1}^N V_j}{N} \quad (2)$$

که V_j سرعت زامین سنجاکف می باشد.

۳- تابع انسجام^{۱۱}: این تابع به صورت (۳) پیوستگی همسایهها را محاسبه می کند.

$$C_i = \frac{\sum_{j=1}^N X_j}{N} - X \quad (3)$$

که در آن X_j موقعیت سنجاکف همسایه X را نشان می دهد.

۴- تابع تمایل^{۱۲}: این تابع، جذب سنجاکف به سمت منبع غذایی را نشان می دهد که به صورت (۴) محاسبه می شود.

$$F_i = X + - X \quad (4)$$

که $X +$ موقعیت منبع غذایی را نشان می دهد.

۵- تابع فرار^{۱۳}: رفتار طبیعی که هر سنجاکف برای زنده ماندن در مقابل نفوذ دشمن انجام می دهد. این تابع را در (۵) می توان مشاهده کرد.

$$E_i = X - + X \quad (5)$$

که در آن $X -$ موقعیت دشمن را بیان می کند.

در الگوریتم سنجاکف، ابتدا بردارهای موقعیت و گام، به طور تصادفی و با توجه به حد پایین و بالای متغیرها مقداردهی می شوند. سپس در هر تکرار، بهترین موقعیت و گام سنجاکفها، پی در پی به روزرسانی می شوند. برای به روزرسانی بردار موقعیت سنجاکف، از بردار گام (مرحله) ΔX و بردار موقعیت فعلی، استفاده می شود. بردار گام، جهت حرکت سنجاکف را نشان می دهد که به صورت (۶) محاسبه می شود.

$$\Delta X_{t+1} = (sS_i + aA_i + cC_i + fF_i + eE_i) + wX_t \quad (6)$$

که پارامترهای e, w, a, c, s, f بردارهای وزن می باشند. همچنین

یک نسخه از مجموعه داده DARPA-1998 می باشد. این مجموعه داده شامل حدود ۵ میلیون رکورد می باشد. هر نمونه داده، دارای ۴۱ ویژگی می باشد که تعداد ۳۸ ویژگی به صورت عددی بوده و ۳ ویژگی به صورت غیر عددی می باشند [۱۰].

این مجموعه داده برای تشخیص حملات ممانعت از سرویس^۱، جستجوگر^۲، R2L^۳ و U2R^۴ مورد استفاده قرار می گیرد.

۳-۲- الگوریتم انتخاب ویژگی سنجاکف

مشکل بعضی از کاربردهای یادگیری ماشین، تعداد زیاد ویژگی هایی می باشد که علی رغم نداشتن ارزش اطلاعاتی مناسب، بار محاسباتی بالایی را به سیستم تحمیل می کنند. اگرچه امروزه با ظهور کامپیوترهای سریع و منابع ذخیره سازی بزرگ این مشکل به چشم نمی آید ولی از طرف دیگر، مجموعه های داده ای بسیار بزرگ برای مسائل جدید باعث شده است که همچنان پیدا کردن یک الگوریتم دقیق تر برای انتخاب ویژگی، اهمیت داشته باشد.

از انواع الگوریتم های انتخاب ویژگی که در پژوهشها از آنها استفاده می شود، می توان به انتخاب ویژگی با استفاده از الگوریتم کلونی زنبور عسل^۵، الگوریتم ژنتیک^۶، الگوریتم کرم شب تاب^۷ و الگوریتم فاخته^۸ اشاره نمود [۱۱].

انتخاب ویژگی در این پژوهش با استفاده از الگوریتم سنجاکف می باشد. این روش پس از مطالعه بر روی مقالات مربوط به الگوریتم سنجاکف و مقایسه با سایر الگوریتم های انتخاب ویژگی، برگزیده شده است.

الگوریتم فراابتکاری سنجاکف در سال ۲۰۱۵ به عنوان یک الگوریتم بهینه سازی پیشنهاد شده است. این الگوریتم که بر اساس رفتار سنجاکف طبیعی طراحی شده است، رفتار هوشمندانه یک سنجاکف بر پنج اصل استوار می باشد. این اصول عبارتند از: «اجتناب از برخورد با سایر افراد همسایه»، «تنظیم سرعت با توجه به موقعیت سایر افراد همسایه»، «تمایل سنجاکف به سمت مرکز ثقل همسایه ها»، «جذب به سمت منبع غذایی» و «فرار از دشمن». براین اساس در الگوریتم سنجاکف پنج تابع تعریف شده و مورد استفاده قرار گرفته است [۲]:

۱- تابع جداسازی^۹: زمانی اتفاق می افتد که سنجاکفها برای جلوگیری از برخورد با همسایگان از آن تبعیت می کنند. رابطه ریاضی این تابع به صورت (۱) می باشد.

¹ Denial of service(DOS)

² Probe

³ User to Root

⁴ Remote to Local

⁵ Bee optimization Algorithm

⁶ Genetic Algorithm

⁷ Firefly optimization Algorithm

⁸ Cuckoo optimization Algorithm

⁹ Separation

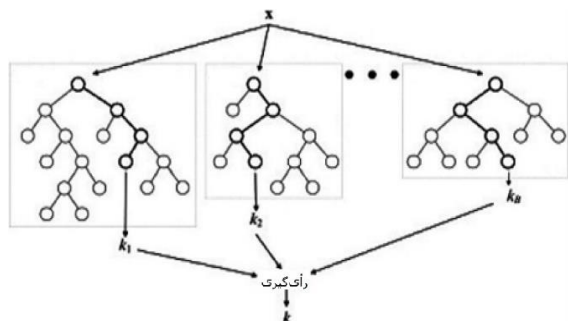
¹⁰ Alignment

¹¹ Cohesion

¹² Attraction

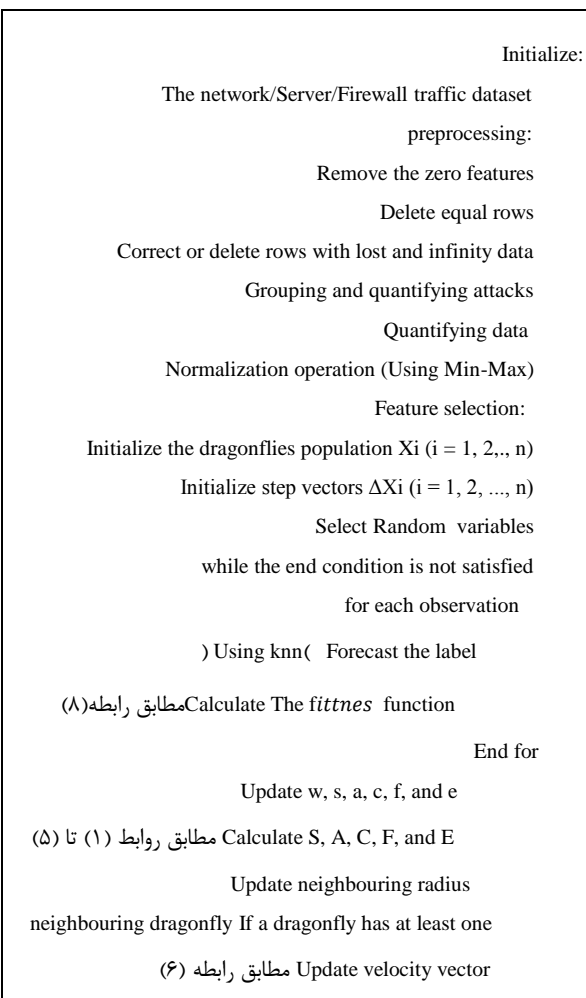
¹³ Escape

الگوریتم، قابل استفاده برای رگرسیون و دسته‌بندی، محدود بودن تعداد پارامترها و آسان بودن استفاده از آن نام برد. عملکرد یک الگوریتم جنگل تصادفی در شکل (۱) مشاهده می‌شود [۱۳].



شکل (۱). نحوه عملکرد جنگل تصادفی

لازم به ذکر است در پژوهش حاضر به منظور انتخاب الگوریتم دسته‌بندی، اکثر الگوریتم‌های یادگیری ماشین و یادگیری عمیق مورد آزمایش قرار گرفته و پس از مقایسه نتایج، الگوریتم جنگل تصادفی به عنوان سریع‌ترین و بهترین الگوریتم انتخاب شده است. شبه کد مدل پیشنهاد شده در این پژوهش مطابق نمودار شماره (۱) می‌باشد.



موقعیت سنجاکک‌ها با استفاده از (۷) به‌روزرسانی می‌شود.

$$X_{t+1} - X_t = \Delta X_{t+1} \quad (7)$$

که در آن پارامتر t تعداد تکرارها را نشان می‌دهد.

در فرایند انتخاب ویژگی، یک سنجاکک ویژگی‌هایی را به صورت تصادفی انتخاب و با استفاده از الگوریتم KNN، برای هر نمونه با ویژگی‌های جدید، دسته موردنظر را پیش‌بینی می‌کند. شبیه‌ترین نمونه‌ها در این پیش‌بینی، با استفاده از محاسبه فاصله منهن (بین ترافیک برجسب نزده و برجسب زده شده) انجام می‌گردد. سپس با توجه به وضعیت همسایه‌ها، در خصوص دسته موردنظر تصمیم‌گیری می‌کند.

این پیش‌بینی، با ویژگی‌های انتخاب شده برای تمام نمونه‌ها انجام می‌شود سپس مقدار نمونه‌های پیش‌بینی شده، با مقدار برجسب واقعی مقایسه می‌شود اگر برابر باشند، خروجی (۱) و در غیر این صورت خروجی (۰) را برمی‌گرداند. این عملیات برای تمام نمونه‌ها صورت می‌پذیرد و تعداد آن‌ها محاسبه و سنجاککی که مجموعه نمونه‌های درست بیشتری را پیش‌بینی کرده باشد به عنوان BF^1 انتخاب می‌شود.

هنگامی که هیچ راه‌حل همسایه‌ای وجود نداشته باشد، برای افزایش تصادفی بودن، سنجاکک‌ها باید از یک پیاده‌روی تصادفی برای پرواز در سراسر فضای جستجو استفاده کنند.

در مرحله بعد مطابق روابط (۶) و (۷) سنجاکک‌ها جابه‌جا و مجدداً BF محاسبه شده و با مقادیر قبلی مقایسه می‌گردد. الگوریتم به تعداد مشخص (که توسط محقق انتخاب می‌گردد) تکرار شده و سنجاککی که دارای بالاترین BF است انتخاب می‌شود و ویژگی‌هایی که آن سنجاکک انتخاب نموده ویژگی‌های بهینه خواهند بود [۱۲].

۳-۳- الگوریتم جنگل تصادفی

الگوریتم جنگل تصادفی متشکل از چندین الگوریتم درخت تصمیم می‌باشد. به عبارت دیگر در این الگوریتم، برای آموزش داده‌ها چندین درخت ساخته می‌شود که در هر کدام از آن‌ها ترتیب قرار گرفتن ویژگی‌ها در اعماق درخت، به صورت تصادفی تعیین می‌گردد.

جنگل تصادفی پیش‌بینی را از هر درخت و بر اساس اکثریت آرا پیش‌بینی می‌کند و نتیجه نهایی را به عنوان خروجی در نظر می‌گیرد. تعداد بیشتر درختان در جنگل منجر به دقت بالاتری می‌شود.

یکی از پارامترهای مهم و تأثیرگذار در جنگل تصادفی، تعداد درخت‌های تولید شده می‌باشد. از مزایای الگوریتم جنگل تصادفی می‌توان به پاسخگویی بهتر در داده‌های با حجم بالا، پایداری

¹ Best Fitness

$$\text{Precision} = \frac{TP}{TP+FP} \quad (۹)$$

معیار فراخوانی^۷: این معیار، درصد نفوذهای واقعی پوشش داده شده توسط سیستم را مشخص می‌کند. این معیار با رابطه (۱۰) محاسبه می‌شود.

$$\text{Recall} = \frac{Tp}{TP + FN} \quad (۱۰)$$

معیار F1-score نیز میانگین دقت و فراخوانی می‌باشد که با رابطه (۱۱) محاسبه می‌گردد.

$$F1_Score = \frac{2 \cdot \text{Recall} \cdot \text{Precision}}{\text{Recall} + \text{Precision}} \quad (۱۱)$$

TP^۸ - تعداد حملاتی که به‌عنوان حمله طبقه‌بندی شدند.

TN^۹ - تعداد رکوردهای نرمال که به‌عنوان نرمال طبقه‌بندی شدند.

FP^{۱۰} - تعداد حملاتی که به‌عنوان نرمال طبقه‌بندی شده‌اند.

FN^{۱۱} - تعداد رکوردهای نرمال که به‌عنوان حمله طبقه‌بندی شدند [۱۴].

۴-۱- پیش‌پردازش داده‌ها

در مرحله پیش‌پردازش داده‌ها، ابتدا ویژگی‌هایی که تمام مقادیر آن‌ها صفر بود و همچنین داده‌های گم‌شده^{۱۲} و داده‌هایی که مقداری برای آن‌ها ثبت نشده بود (دارای سلول‌های خالی) حذف شدند، سپس ویژگی‌های protocol_type و service و flag که مقدار آن‌ها غیر عددی می‌باشد، به مقادیر عددی تبدیل شدند. در ادامه ترافیک به‌صورت چهار گروه حمله و یک گروه نرمال عددی شدند. سپس برای یکسان کردن مقیاس داده‌ها و نرمال‌سازی^{۱۳} آن‌ها، از روش کمترین-بیشترین استفاده شد.

در این پژوهش پس از انجام مراحل پیش‌پردازش، به دلیل کم بودن مشاهدات در برخی از کلاس‌ها، از وزن‌دهی به کلاس‌ها استفاده شده است. در وزن‌دهی کلاس‌ها، به نسبت تعداد مشاهدات هر کلاس، به آن‌ها وزن اختصاص می‌یابد تا کلاس‌های اقلیت نیز در پیش‌بینی نقش داشته باشند. لازم به ذکر است در برخی از پژوهش‌ها روش‌هایی مانند نمونه‌گیری افزایشی یا کاهش‌ی به کار برده می‌شوند، لیکن در این پژوهش از این روش‌ها استفاده نشده است.

Update position vector مطابق رابطه (۷)
Else
Update the position vector using Lévy flight
End if
Check and correct the new positions based on the boundaries of variables
Calculate the values of all dragonflies
Name the biggest fitness function, best Fitness
End while
Choose the features of the best dragonfly
Classify types of attacks using Random forest Algorithm
End.

نمودار (۱). شبه کد روش پیشنهادی

چنانچه در نمودار (۱) مشاهده می‌شود، داده‌های خام پس از پیش‌پردازش و یکسان کردن مقیاس داده‌ها از طریق روش کمترین-بیشترین^۱، با استفاده از الگوریتم سنجاقک انتخاب ویژگی شده و سپس نتایج از طریق الگوریتم جنگل تصادفی دسته‌بندی می‌شوند.

۴-۲- آزمایش‌ها و نتایج

این بخش شامل نتایج پیش‌پردازش داده‌ها، ویژگی‌های انتخاب شده و نتایج عملیات دسته‌بندی حملات می‌باشد و در انتها مقایسه نتایج روش پیشنهادی با سایر روش‌های موجود در این زمینه بیان شده است. لازم به ذکر است سیستم رایانه مورد استفاده در این پژوهش، دارای پردازنده Core i5 و مقدار ۸ گیگابایت RAM بوده و از ابزارهای پایتون در محیط Colab و Matlab 2020 b استفاده شده است.

در این پژوهش از معیارهای صحت^۲، دقت^۳، میزان بازخوانی^۴، F1-Score و همچنین معیار زمان برای ارزیابی الگوریتم‌ها استفاده شده است.

معیار صحت^۵: این معیار تعداد پیش‌بینی درست از تعداد کل پیش‌بینی‌ها را نشان می‌دهد و با رابطه (۸) محاسبه می‌گردد.

$$\text{Accuracy} = \frac{TP+TN}{TP+FP+TN+FN} \quad (۸)$$

معیار دقت^۶: معیاری است که نشان می‌دهد در نمونه‌های مختلف، پیش‌بینی‌ها به چه میزان واقعاً درست بوده‌اند. این معیار به‌صورت (۹) قابل محاسبه می‌باشد.

⁷ Recall

⁸ True Positive

⁹ True Negative

¹⁰ False Positive

¹¹ False Negative

¹² Missing Data

¹³ Normalization

¹ Min-Max

² Accuracy

³ Precision

⁴ Recall

⁵ Accuracy

⁶ Precision

جدول (۳). زمان اجرای الگوریتم‌ها قبل از انتخاب ویژگی

الگوریتم	زمان آموزش	زمان آزمایش
LR	۳۲	۰/۱۲
DT	۴/۵	۰/۰۹
KNN	۱۰/۱۲	۰/۸۱
RF	۳/۲	۰/۰۱
GB	۷/۸	۰/۱۲
RNN	۱۳۹	۱
GRU	۲۸۵	۱
LSTM	۴۱۸	۱

در جدول شماره (۴) میانگین حسابی نتایج معیارهای F1-Score، بازخوانی و دقت روش‌های بررسی شده، قبل از انتخاب ویژگی مشاهده می‌شود.

جدول (۴). میانگین نتایج F1-Score، بازخوانی و دقت الگوریتم‌ها قبل از انتخاب ویژگی

الگوریتم	میانگین F1-Score	میانگین بازخوانی	میانگین دقت
LR	۰/۳۵۴	۰/۳۹	۰/۴۷
DT	۰/۵۱	۰/۷۶	۰/۳۹
KNN	۰/۸	۰/۷۱	۰/۸۷
RF	۰/۷۶	۰/۸۲	۰/۸۳۷
GB	۰/۷۵	۰/۷۸	۰/۸۰۹
RNN	۰/۴	۰/۷۹	۰/۵۶
GRU	۰/۷۶	۰/۶۹	۰/۵۱
LSTM	۰/۶۵	۰/۸	۰/۴۵

روش پیشنهادی در این پژوهش استفاده از انتخاب ویژگی سنجاک در مجموعه داده می‌باشد که به صورت زیر انجام شده است.

۴-۳ - نتایج انتخاب ویژگی سنجاک

اجرای عملیات انتخاب ویژگی سنجاک، در مجموعه داده، پس از ۴ بار تکرار و تعداد ۵ سنجاک و انتخاب $KNN=5$ ، موجب انتخاب ۱۹ ویژگی با بیشترین اولویت شد که در مقایسه با سایر ویژگی‌ها با دقت $99/08$ برنده شدند. زمان موردنیاز برای اجرای این الگوریتم، حدود 699 ثانیه بوده است. گزارش انتخاب ویژگی‌ها در جدول شماره (۵) نشان داده شده‌اند.

۴-۲ - نتایج الگوریتم‌های یادگیری بر روی داده‌های اولیه (قبل از اعمال روش پیشنهادی)

در این مرحله، ابتدا داده‌های به دست آمده، به دو گروه ویژگی‌ها (X) و برچسب‌ها (Y) تقسیم شدند و سپس تعداد یک درصد از سطرهای مجموعه داده به طور تصادفی برگزیده شدند. این انتخاب به شکلی بوده که به تناسب، ترکیبی از تمام انواع برچسب‌ها انتخاب شده باشند. این برچسب‌ها به صورت X_{train} ، y_{train} و X_{test} و y_{test} نام گذاری گردیدند.

در مرحله بعد الگوریتم‌های یادگیری بر روی X_{train} و y_{train} مجموعه داده اعمال و نتایج صحت، دقت، میانگین تقریبی، بازخوانی و زمان اجرا محاسبه گردید که در جداول شماره (۱) تا (۴) درج شده‌اند.

جدول (۱). نتایج صحت الگوریتم‌ها قبل از انتخاب ویژگی

الگوریتم	LR	DT	KNN	RF	GB
صحت	۰/۸۴۷۹	۰/۷۰۲۴	۰/۸۹۱۳	۰/۹۰۰۲	۰/۸۳۱۹

چنانچه در جدول شماره (۱) دیده می‌شود مقدار صحت مربوط به الگوریتم جنگل تصادفی بیشتر از بقیه الگوریتم‌های یادگیری ماشین مورد آزمایش محاسبه شده است. در روش‌های عمیق بازگشتی RNN، GRU و LSTM نیز آرگومان‌های مختلف آزمایش و بهترین مقادیر به صورت جدول شماره (۲) به دست آمده‌اند.

جدول (۲). نتایج صحت روش‌های عمیق بازگشتی قبل از مراحل انتخاب ویژگی

الگوریتم	RNN	GRU	LSTM
لایه پنهان	۲	۲	۲
تعداد نود	۵۱۲-۵۱۲	۵۱۲-۵۱۲	۵۱۲-۵۱۲
نرخ یادگیری	3e-4	3e-4	3e-4
تعداد تکرار	۵	۵	۵
فعال سازی	Relu – SoftMax	Relu – SoftMax	Relu – SoftMax
Batch	۶۴	۶۴	۶۴
Verbose	۲	۲	۲
ACC	۰/۷۵	۰/۷۱۹	۰/۸

چنانچه از جدول شماره (۲) و مقایسه آن با جدول شماره (۱) مشاهده می‌شود، صحت مربوط به جنگل تصادفی بهتر می‌باشد. مدت زمان اجرای الگوریتم‌های مورد بررسی قبل از اعمال روش پیشنهادی در جدول شماره (۳) نشان داده شده است.

چنانچه در نمودار (۲) مشاهده می‌شود دسته‌بندی جنگل تصادفی با استفاده از مجموعه داده انتخاب شده، بالاترین صحت را به دست آورده است. در جدول شماره (۸)، زمان اجرای الگوریتم‌ها پس از انتخاب ویژگی مشاهده می‌شود.

جدول (۸). زمان اجرای الگوریتم‌ها پس از انتخاب ویژگی

الگوریتم	زمان آموزش	زمان آزمایش
LR	۲۷	۰/۰۸
DT	۳/۸	۰/۰۳
KNN	۷/۵	۰/۵۹
روش پیشنهادی	۱/۲۸	۰/۰۰۹
GB	۶/۹	۰/۰۲
RNN	۶۹	۱
GRU	۳۱۸	۱
LSTM	۴۰۱	۱

در جدول شماره (۹) میانگین مقادیر F1-Score، بازخوانی و دقت الگوریتم‌های یادگیری پس از انتخاب ویژگی به ثبت رسیده است.

جدول (۹). نتایج میانگین بازخوانی، F1-Score و دقت الگوریتم‌های یادگیری پس از انتخاب ویژگی

الگوریتم	میانگین F1-Score	میانگین بازخوانی	میانگین دقت
LR	۰/۴۱۲	۰/۳۹	۰/۴۷
DT	۰/۵۴۸	۰/۸۸	۰/۴
KNN	۰/۸۴	۰/۸۵۵	۰/۱۸
روش پیشنهادی	۰/۸۷۱	۰/۸۵۶	۰/۸۹
GB	۰/۷۷	۰/۸	۰/۸۵۴
RNN	۰/۵۷۷	۰/۸۱۳	۰/۵۶
GRU	۰/۷۸	۰/۸۱۹	۰/۵۲۱
LSTM	۰/۶۶	۰/۸۷۳	۰/۶۳۵

چنانچه در جدول شماره (۹) مشاهده می‌شود مقادیر F1-Score، بازخوانی و دقت در اکثر الگوریتم‌ها علی‌الخصوص در الگوریتم جنگل تصادفی (روش پیشنهادی) افزایش داشته است.

در نمودار شماره (۳) نتایج به دست آمده از مقادیر دقت الگوریتم‌های اجرا شده با داده‌های اولیه (پس از مراحل پیش‌پردازش) و داده‌های نهایی (پس از انتخاب ویژگی) مقایسه شده‌اند.

جدول (۵). ویژگی‌های انتخاب شده توسط الگوریتم سنجاقک

ویژگی‌های انتخاب شده	F1	F2	F3	F4	F5
۱	۲	۳	۴	۵	۸
F6	F7	F8	F9	F10	F11
۹	۱۰	۱۳	۱۴	۱۵	۱۷
F12	F13	F14	F15	F16	F17
۱۸	۲۰	۲۱	۲۳	۲۷	۳۳
F18	F19				
۳۴	۳۸				

در جدول (۵) ویژگی nام مجموعه داده جدید، با متغیر Fn نشان داده شده و عدد متناظر با آن شماره ویژگی در مجموعه داده اولیه می‌باشد.

۴-۴- نتایج الگوریتم‌های یادگیری (پس از انتخاب ویژگی)

در این مرحله، الگوریتم انتخاب ویژگی سنجاقک بر روی داده‌ها اعمال شده است. چنانچه در جدول شماره (۵) دیده می‌شود، تعداد ویژگی‌ها به ۱۹ ویژگی کاهش یافته است. الگوریتم‌های یادگیری بر روی داده‌های نهایی اعمال و نتیجه روش‌ها در جداول شماره (۶) تا (۹) ثبت گردیده است.

جدول (۶). نتایج صحت پس از مراحل انتخاب ویژگی

الگوریتم	LR	DT	KNN	روش پیشنهادی	GB
صحت	۰/۹۱۵۶	۰/۷۲۰۱	۰/۹۷۹	۰/۹۹۶۷	۰/۹۲۲۹


همچنین، الگوریتم‌های یادگیری عمیق نیز با داده‌های جدید آزمایش شدند، در این مرحله برای آزمایش سیستم، از تعداد ۱۰ تکرار استفاده شد تا اگر پتانسیل بهبود وجود دارد مشخص گردد. لیکن مشاهده شد که با تکرارهای زیاد نیز، مقدار صحت تاندازه‌ای افزایش یافته و پس از آن مجدداً افت پیدا می‌کند. این نتایج در جدول شماره (۷) نشان داده شده است.

جدول (۷). نتایج صحت الگوریتم‌های عمیق پس از مراحل انتخاب ویژگی

الگوریتم	RNN	GRU	LSTM
صحت	۰/۷۹	۰/۷۷۶	۰/۷۸

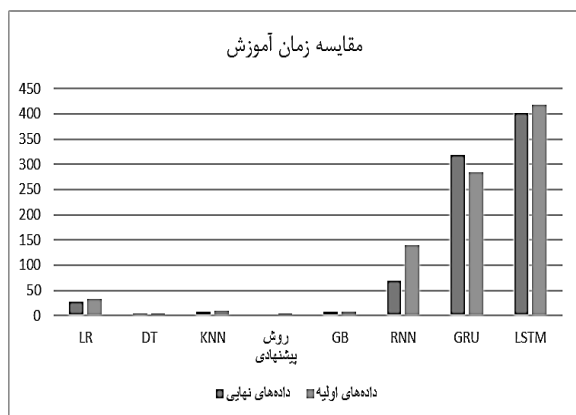
مقایسه نتایج صحت الگوریتم‌ها با داده‌های اولیه و داده‌های نهایی (روش پیشنهادی) در نمودار شماره (۲) نشان داده شده است.

مقایسه مقادیر صحت



نمودار (۲). مقایسه نتایج صحت الگوریتم‌ها با داده‌های اولیه و داده‌های نهایی

چنانچه در نمودار شماره (۵) دیده می‌شود، مقدار F1-Score در روش پیشنهادی نسبت به سایر روش‌ها بالاتر می‌باشد و این روش نسبت به داده‌های اولیه، افزایش داشته است. زمان اجرای الگوریتم‌ها در نمودار شماره (۶) مورد مقایسه قرار گرفته است.



نمودار (۶). مقایسه مدت‌زمان اجرا با داده‌های اولیه و داده‌های نهایی

چنانچه در نمودار (۶) معلوم است، زمان آموزش روش پیشنهادی نسبت به بقیه الگوریتم‌ها کمتر بوده و نسبت به داده‌های اولیه کاهش یافته است.


۴-۵ - مقایسه نتایج روش پیشنهادی با پژوهش‌های پیشین

به‌منظور مقایسه نتایج روش پیشنهادی با نتایج پژوهش‌های مشابه، برخی از این پژوهش‌ها انتخاب و نتایج کسب شده در جدول (۱۰) مورد مطالعه قرار گرفته‌اند.


منبع شماره [۴] که از ترکیب درخت تصمیم و جنگل تصادفی برای تشخیص نفوذ استفاده نموده است، معیار صحت را ۰/۹۷ گزارش نموده است که در مقایسه با روش پیشنهاد شده در پژوهش حاضر مقدار کمتری می‌باشد، در منبع فوق معیارهای دیگر مورد بررسی قرار نگرفته است.

مقدار صحت در مقاله [۵] ۰/۹۶۷۷ محاسبه شده است. در این پژوهش که از الگوریتم SVM استفاده شده، معیارهای دقت، بازخوانی، میانگین تقریبی و سایر مقادیر محاسبه نشده‌اند.

در پژوهش [۶] که یادگیری CNN به‌صورت چند کلاس به کار گرفته شده است، مقادیر صحت ۰/۷۷۶۹، دقت ۰/۷۳۹۲، بازخوانی ۰/۵۲۸۶ و F1-Score ۰/۵۳۵۲ را به‌عنوان حداکثر معیارها گزارش شده است. با مقایسه نتایج پژوهش حاضر و این مقادیر، مشاهده می‌شود که تمامی مقادیر نسبت به مقاله فوق ارتقا یافته‌اند.

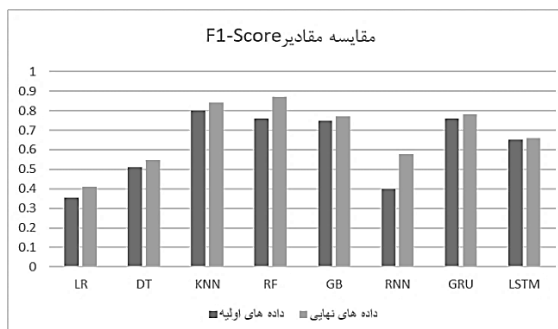


نمودار (۳). مقایسه نتایج دقت الگوریتم‌ها با داده‌های اولیه و داده‌های نهایی در نمودار شماره (۳) مشاهده می‌شود که مقدار دقت در روش پیشنهادی نسبت به داده‌های قبل از انتخاب ویژگی بهبود یافته و نسبت به سایر روش‌ها نیز مقدار بالاتری را به خود اختصاص داده است. نمودار شماره (۴) نتایج مقادیر بازخوانی الگوریتم‌ها را قبل و بعد از مراحل انتخاب ویژگی نشان می‌دهد.



نمودار (۴). مقایسه نتایج بازخوانی الگوریتم‌ها با داده‌های اولیه و داده‌های نهایی

در نمودار شماره (۴) دیده می‌شود که مقدار بازخوانی روش پیشنهادی نسبت به داده‌های اولیه رشد داشته است. البته این مقدار، نسبت به سایر الگوریتم‌ها بالاترین مقدار را به خود اختصاص نداده است. نمودار شماره (۵) مقادیر F1-Score الگوریتم‌ها قبل و بعد از مراحل انتخاب ویژگی را نشان می‌دهد.



نمودار (۵). مقایسه نتایج F1-Score با داده‌های اولیه و داده‌های نهایی

جدول (۱۰). مقایسه نتایج پژوهش با نتایج پژوهش‌های پیشین بر روی مجموعه داده‌های مشابه

شماره ارجاع	روش یادگیری	سال ارائه	مجموعه داده	معیار ارزیابی	مقدار
[۴]	DT-RF		KDD-CUP99	صحت	۰/۹۷
[۵]	SVM		KDD-CUP99	صحت	۰/۹۶۷۷
[۶]	CNN		NSL-KDD	صحت	۰/۷۷۶۹
				دقت	۰/۷۳۹۲
				بازخوانی	۰/۵۲۸۶
	F1-Score				۰/۵۳۵۲
[۷]	DT FGLCC		NSL-KDD	صحت	۰/۹۵۰۳
[۸]	DL		KDD-CUP99	صحت	۰/۹۶۳
[۹]	STL		NSL-KDD	صحت	۰/۹۸۸۴
روش پیشنهادی	جنگل تصادفی و انتخاب ویژگی سنجاکف		KDD99	صحت	۰/۹۹۶۷
				دقت	۰/۸۹
				بازخوانی	۰/۸۵۶
				F1-Score	۰/۸۷۱

۵- نتیجه‌گیری و پیشنهادها

در این پژوهش مدل روش پیشنهادی به‌عنوان یک مدل تشخیص نفوذ با استفاده از الگوریتم سنجاکف برای انتخاب ویژگی و الگوریتم جنگل تصادفی به‌منظور دسته‌بندی پیشنهاد شد. این روش بر روی مجموعه داده معتبر KDD-99 اعمال شده و با چندین روش شاخص یادگیری ماشین و یادگیری عمیق مقایسه گردیده است. نتایج معیارهای ارزیابی‌ها نشان می‌دهند که سیستم پیشنهادی، معیارهای صحت، دقت، بازخوانی و F1-Score بالاتری نسبت به سایر الگوریتم‌های اجرا شده، داشته و زمان کمتری نیز در اجرای سیستم صرف نموده است. به‌طوری که با دسته‌بندی الگوریتم جنگل تصادفی، پیش از اعمال انتخاب ویژگی، معیار صحت ۰/۹۰۰۲ بوده و معیارهای دقت، F1-Score و بازخوانی، به‌ترتیب دارای میانگین ۰/۷۶ و ۰/۸۲ و ۰/۸۳۷ بوده‌اند که با اعمال انتخاب ویژگی در روش پیشنهادی، معیار صحت به مقدار ۰/۹۹۶۷ ارتقا یافته و سایر مقادیر نیز به ترتیب به نتایج ۰/۸۹ و ۰/۸۵۶ و ۰/۸۷۱ رسیده‌اند. چنانچه ملاحظه می‌شود تمامی معیارها نسبت به مقادیر قبل از اعمال روش، ارتقا یافته‌اند. در ضمن با توجه به جدول (۱۰) نتایج روش پیشنهاد شده، نسبت به اکثر مطالعات پیشین افزایش داشته است.

همچنین، سرعت اجرای روش پیشنهادی نیز نسبت به قبل از تغییرات داده شده بر روی داده‌ها ارتقا یافته است. البته با توجه به متفاوت بودن سخت‌افزار مورد استفاده در سایر پژوهش‌ها، مقایسه زمان کدهای اجرا شده با آن‌ها قابل استناد نمی‌باشد، لیکن مقایسه زمان روش‌های مختلف بکار رفته در این پژوهش که در نمودار (۶) قابل مشاهده است، حاکی از سرعت بالای روش پیشنهادی نسبت به الگوریتم‌های دیگر می‌باشد.

در پژوهش [۷] که از روش فیلتزر FGLCC و خوشه‌بندی، ویژگی‌ها تشخیص داده شده و با استفاده از الگوریتم درخت تصمیم دسته‌بندی انجام می‌شود، صحت نهایی ۰/۹۵۰۳ درصد گزارش شده است.

روش مورد استفاده در منبع [۸] شبکه عصبی عمیق^۱ بوده که به‌صورت باینری بر روی مجموعه داده KDD99 و دو مجموعه داده دیگر استفاده شده است که مقدار صحت آن بر روی مجموعه داده فوق، ۰/۹۶۳ بوده که پایین‌تر از مقدار صحت در روش پیشنهاد شده در این پژوهش می‌باشد.

پژوهشگر در منبع [۹] از یادگیری STL^۲ هم به‌صورت باینری و هم با پنج کلاس بر روی مجموعه داده NSL-KDD استفاده نموده است. حداکثر مقدار محاسبه شده برای معیار صحت ۰/۹۸۸۴ بوده که کمتر از مقدار صحت روش پیشنهادی بوده است.

چنانچه در جدول شماره (۱۰) مشاهده می‌شود اکثر پژوهش‌های مشابه، از معیار صحت به‌منظور ارزیابی استفاده نموده‌اند و معیارهای دیگر مورد محاسبه قرار نگرفته است. مقدار صحت در روش پیشنهادی، نسبت به پژوهش‌های عنوان شده، مقادیر بالاتری را کسب کرده است. همچنین میانگین صحت پژوهش‌های ذکر شده با مجموعه داده KDD99 و مشابه آن، مقدار ۰/۹۳۶۱ بوده است که از مقدار صحت روش پیشنهادی پایین‌تر می‌باشد.

^۱ Deep neural Network

^۲ Self-taught learning

- در نهایت برای پژوهش‌های آینده، با توجه به عدم توازن در مجموعه داده‌های موجود، پیشنهاد می‌شود عملیات متوازن‌سازی داده‌ها بر روی مجموعه داده KDD-99 انجام شود. در ضمن با توجه به اهمیت موضوع تشخیص و پیش‌بینی هدف و مقصد مهاجم، توصیه می‌شود در تحقیقات آینده، سیستم تشخیص و پیش‌بینی مقاصد حمله (بر اساس نوع حمله تشخیص داده شده در این پژوهش) مورد مطالعه قرار گیرد. همچنین پیشنهاد می‌شود سیستم توصیه‌گر مدیر شبکه، بر اساس خروجی روش پیشنهادی و نقشه شبکه، بررسی گردد.
- ### ۶- مراجع
- [7] Mohammadi, S., "Cyber intrusion detection by combined feature selection algorithm," *Journal of information security and applications*, 44, pp. 80-88, 2019.
 - [8] Choudhary, S. & N. Kesswani, "Analysis of KDD-Cup'99, NSL-KDD and UNSW-NB15 datasets using deep learning in IoT," *Procedia Computer Science*, 167, pp. 1561-1573, 2020.
 - [9] Javaid, A., "A deep learning approach for network intrusion detection system," *Eai Endorsed Transactions on Security and Safety*, 3(9), p. e2, 2016.
 - [10] Aishwarya, C., "Intrusion Detection System using KDD Cup 99 Dataset," *International Journal of Innovative Technology and Exploring Engineering (IJITEE)*, 9(4), pp. 3169-3171, 2020.
 - [11] Singh Panwar, S., Y. Raiwani, & L.S. Panwar. "Evaluation of network intrusion detection with features selection and machine learning algorithms on CICIDS-2017 dataset," in *International Conference on Advances in Engineering Science Management & Technology (ICAESMT)-2019*, Uttaranchal University, Dehradun, India. 2019.
 - [12] Mafarja, M.M., "Binary dragonfly algorithm for feature selection," in *2017 International conference on new trends in computing sciences (ICTCS)*. 2017. IEEE.
 - [13] Farnaaz, N. & M. Jabbar, "Random forest modeling for network intrusion detection system," *Procedia Computer Science*, 89, pp. 213-217, 2016.
 - [14] Junker, M., R. Hoch, & A. Dengel. "On the evaluation of document analysis components by recall, precision, and accuracy," in *Proceedings of the Fifth International Conference on Document Analysis and Recognition. ICDAR'99 (Cat. No. PR00318)*. 1999. IEEE.
 - [1] Hindy, H. & L. Jain, "A taxonomy and survey of intrusion detection system design techniques, network threats and datasets," *International Journal of Innovative Technology and Exploring Engineering (IJITEE)*, 5(2), pp. 298-309, 2018.
 - [2] Mirjalili, S., "Dragonfly algorithm: a new meta-heuristic optimization technique for solving single-objective, discrete, and multi-objective problems," *Neural Computing and Applications*, 27(4), pp. 1053-1073, 2016.
 - [3] Yahalom, R., "Improving the effectiveness of intrusion detection systems for hierarchical data. Knowledge-Based Systems," *International Journal of Innovative Technology and Exploring Engineering (IJITEE)*, 5(4), pp. 59-69, 2019.
 - [4] Farnaaz, N. & M. Jabbar, "Random forest modeling for network intrusion detection system. *Procedia Computer Science*," 89, pp. 213-217, 2016.
 - [5] Kuang, F., W. Xu, & S. Zhang, "A novel hybrid KPCA and SVM with GA model for intrusion detection. *Applied Soft Computing*," 18, pp. 178-184, 2014.
 - [6] Faker, O. & E. Dogdu. "Intrusion detection using big data and deep learning techniques," in *Proceedings of the 2019 ACM Southeast Conference*, 2019.