



# Feature Selection and Intrusion Detection in Wireless Sensor Networks with Unsupervised Extreme Learning Machine (UELMM)

Hamid Tabatabaee\* , Samira Hadavi

\*Associate Professor, Department of Computer Engineering, Mashhad Branch, Islamic Azad University, Mashhad, Iran

(Received: 08/01/2024, Revised: 03/04/2024, Accepted: 22/09/2024, Published: 15/12/2024)

DOR: 20.1001.1.20086849.1403.15.4.3.6

## ABSTRACT

Nowadays, network-based computer systems play a vital role in today's modern society, and for this reason, they may be the target of hostility or infiltration. In order to ensure complete security in a computer system connected to the network, using a firewall and other intrusion prevention mechanisms is not always enough. This need has led to the use of other systems called intrusion detection systems. An intrusion detection system can be considered a set of tools, methods, and documents that help identify, determine, and report unauthorized or unapproved activities on the network. Intrusion detection systems are created in the form of software and hardware systems, each with its own advantages and disadvantages. Due to the presence of many features in the data related to intrusion detection systems, this thesis focuses on selecting the desired and effective features using Unsupervised Extreme Learning Machine. A model for data classification is then presented using UELM. To evaluate the performance of the proposed method, the NSL-KDD database is used because it contains more realistic records than other intrusion detection datasets. The test results show that UELM achieves an accuracy of 98.38%, compared to GWO's accuracy of 93.74%. The superiority of UELM in classification and intrusion detection problems is attributed to its robust and generalizable structure as an unsupervised neural network.

**Keywords:** Feature Selection, Artificial Neural Networks, Unsupervised Extreme Learning Machine, Intrusion Detection

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

**Publisher:** Imam Hussein University

 Authors



\* Corresponding Author Email: h\_tabatabaee@mshdiau.ac.ir



دانشگاه غیرعالم



سال پانزدهم، شماره ۴، زمستان ۱۴۰۳، (پیاپی ۶۰): صص ۴۰-۲۵

شاپای چاپی: ۶۹۴۹-۲۰۰۸ | شاپای الکترونیکی: ۸۰۳۰-۲۹۸۰

علمی - پژوهشی

## انتخاب ویژگی و تشخیص نفوذ در شبکه‌های حسگر بی‌سیم با

### استفاده از یادگیری ماشین مفرط بدون نظارت (UELM)

حمید طباطبایی<sup>۱\*</sup>، سمیرا هادوی<sup>۲</sup>

DOR: 20.1001.1.20086849.1403.15.4.3.6

تاریخ پذیرش: ۱۴۰۳/۰۷/۰۱

تاریخ انتشار: ۱۴۰۳/۰۹/۲۵

تاریخ دریافت: ۱۴۰۲/۱۰/۱۸

تاریخ بازنگری: ۱۴۰۳/۰۱/۱۵

#### چکیده

امروزه سیستم‌های کامپیوتری مبتنی بر شبکه، نقش حیاتی در جامعه مدرن امروزی دارند و به همین علت ممکن است هدف دشمن و یا نفوذ قرار گیرند. به منظور ایجاد امنیت کامل در یک سیستم کامپیوتری متصل به شبکه، استفاده از دیوار آتش و سایر مکانیزم‌های جلوگیری از نفوذ همیشه کافی نیست و باید از سیستم‌های دیگری به نام سیستم‌های تشخیص نفوذ استفاده شود. به دلیل وجود مشخصه‌های زیاد در داده‌های مربوط به سیستم‌های تشخیص نفوذ، جهت استفاده از مشخصه‌های مطلوب و موثر از الگوریتم یادگیری ماشین مفرط بدون نظارت استفاده می‌شود. جهت طبقه‌بندی داده‌ها از مدل UELM و ارزیابی عملکرد روش پیشنهادی، از پایگاه داده با رکوردهای واقعی تر NSL-KDD نسبت به سایر مجموعه داده‌گان تشخیص نفوذ، استفاده می‌گردد. نتایج آزمایش‌ها نشان‌دهنده صحت ۹۸/۳۸ UELM در مقایسه با صحت ۹۳/۷۴ GWO است. دلیل این برتری، استفاده از مدل مناسب در مسئله دسته‌بندی، تشخیص نفوذ، ساختار مستحکم و تعمیم‌پذیر شبکه عصبی بدون نظارت می‌باشد.

**کلیدواژه‌ها:** انتخاب ویژگی، شبکه‌های عصبی مصنوعی، ماشین یادگیری مفرط بدون نظارت، تشخیص نفوذ

<sup>۱</sup>دانشیار گروه مهندسی کامپیوتر، واحد مشهد، دانشگاه آزاد اسلامی، مشهد، ایران (h\_tabatabaee@mshdiau.ac.ir) - نویسنده مسئول

<sup>۲</sup>کارشناسی ارشد گروه مهندسی کامپیوتر، واحد مشهد، دانشگاه آزاد اسلامی، مشهد، ایران



\* این مقاله یک مقاله با دسترسی آزاد است که تحت شرایط و ضوابط مجوز Creative Commons Attribution (CC BY) توزیع شده است.

نویسندگان ©

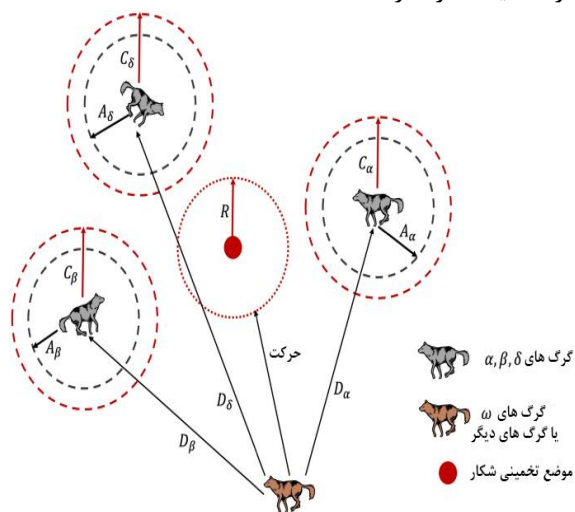
ناشر: دانشگاه جامع امام حسین (ع)

## ۱- مقدمه

تخمین تعداد بهینه ویژگی‌ها یکی از چالش‌های مهم می‌باشد [۳]. در این مقاله از ویژگی‌هایی به عنوان صفات اساسی استفاده می‌شود که دقت تشخیص نفوذ را افزایش دهد و همچنین تاثیر ویژگی‌هایی که انتخاب نشده‌اند را نیز در سیستم تشخیص نفوذ در نظر گرفته می‌شود. با استفاده از ماشین یادگیری مفرط بدون نظارت مدلی برای تشخیص نفوذ در شبکه‌های حسگر بی‌سیم ارائه می‌گردد. همچنین برای کاهش ضعف‌های سیستم‌های تشخیص نفوذ اعم از (افتادن در دام بهینه محلی و همگرایی زودرس الگوریتم‌های فراابتکاری) یک رویکرد جدید برای انتخاب ویژگی و تشخیص هر نوع حمله، پیشنهاد می‌گردد که توسط یادگیری ماشین مفرط بدون نظارت انجام می‌شود. از یادگیری ماشین مفرط بدون نظارت با ضریب تنظیم (رگولاریزیشن) در تشخیص نفوذ با اعمال پارامترهای بهینه به منظور کاهش اثرات منفی پارامترهای غیر بهینه استفاده شده است.

## ۱-۱- الگوریتم بهینه‌سازی گرگ خاکستری

الگوریتم بهینه‌سازی گرگ خاکستری<sup>۱</sup>، الگوریتم فرا ابتکاری الهام گرفته شده از طبیعت است. این الگوریتم از تعدادی مشاهدات درباره زندگی گرگ خاکستری در طبیعت الهام گرفته شده است. در اصل، ایده اصلی الگوریتم رفتار اجتماعی و مکانیزم شکار این گرگ را شبیه‌سازی می‌نماید. در GWO، افراد به چهارگونه به نام‌های آلفا ( $\alpha$ )، بتا ( $\beta$ )، دلتا ( $\delta$ ) و امگا ( $\omega$ ) تقسیم می‌شوند.  $\alpha$  راه‌حل با بالاترین برازندگی را نشان می‌دهد یا به عبارتی بهترین راه‌حل یافت شده تاکنون. بطور مشابه،  $\beta$  و  $\delta$  به ترتیب دومین و سومین بهترین فرد را نشان می‌دهند.  $\omega$  به باقیمانده افراد موجود در جمعیت اشاره دارد [۴].



شکل (۱): مثالی از مکانیزم بهنگام‌سازی موقعیت گرگ‌های  $\omega$  با توجه به گرگ‌های  $\alpha$ ،  $\beta$  و  $\delta$  [۵]


با پیشرفت بیش از پیش فناوری و افزایش روز افزون بهره‌گیری از شبکه‌های کامپیوتری، خطرات حمله به این شبکه‌ها را افزایش داده است [۱]. نفوذ به مجموعه اقدامات غیرقانونی که محرمانگی و یا دسترسی به یک منبع را به خطر می‌اندازد اطلاق می‌گردد. سیستم تشخیص نفوذ را می‌توان مجموعه‌ای از ابزارها، روش‌ها و مدارکی در نظر گرفت که به شناسایی، تعیین و گزارش فعالیت‌های غیرمجاز یا تأیید نشده تحت شبکه، کمک می‌کند. افزایش دسترسی به داده‌ها و پردازش سریع‌تر آن‌ها و در عین حال افزایش حجم داده‌ها و نیاز به فراهم آوردن داده‌ها از منابع مختلف از طریق این شبکه‌ها، منجر به پدید آمدن منابع تهدیدآمیزی می‌گردد که از طریق نقاط ضعف موجود در سیستم‌ها، به استثمار سیستم‌ها و ایجاد اختلال در آن‌ها می‌پردازد. تشخیص و جلوگیری از نفوذ (IDS) امروزه به عنوان یکی از مکانیزم‌های اصلی در برآوردن امنیت شبکه‌ها و سیستم‌های کامپیوتری مطرح است [۲]. بیشتر سیستم‌های تشخیص نفوذ کنونی از تمامی پارامترهای موجود در بسته‌های شبکه برای ارزیابی و کشف الگوهای حملات استفاده می‌نمایند، در صورتی که برخی از این پارامترها غیرمرتبط و زائد می‌باشند. استفاده از تمامی پارامترها باعث می‌شود که فرآیند تشخیص طولانی و کارایی سیستم تشخیص نفوذ تنزل یابد. در واقع چالش اساسی در سیستم تشخیص نفوذ حجم عظیم داده‌هاست. از طرفی با توجه به ترافیک بالا کاهش نرخ هشدار غلط در سیستم تشخیص نفوذ نیز از اهمیت خاصی برخوردار است. تمام سیستم‌های تشخیص نفوذ قادر به تولید هشدار در مورد وقوع نفوذ در شبکه می‌باشند. ولی به علت حجم بالای هشدارهای تولید شده توسط این سیستم‌ها و همچنین تولید هشدارهای اشتباه، این سیستم‌ها قادر به مدیریت و آنالیز هشدارهای تولید شده نمی‌باشند.

امروزه بیشتر رویکردها در تشخیص نفوذ مربوط به مساله انتخاب و یا استخراج ویژگی‌های مهم متمرکز شده است. تعداد ویژگی‌هایی که بهترین دقت را در تشخیص نفوذ دارند، در مجموعه داده‌های مختلف بیشتر به صورت تجربی بدست می‌آید. اما انتخاب ویژگی‌ها ممکن است باعث از دست دادن قسمتی از داده‌ها شود.

با توجه به اینکه پردازش داده‌ها با اعداد کار می‌کنند و برخی از مشخصه‌های این مجموعه‌داده دارای مقادیر رشته‌ای هستند، لذا تغییر آن‌ها به مقادیر عددی برای انجام پردازش الزامی می‌باشد. برای تبدیل نوع رشته‌ای به عدد نیز به این صورت عمل می‌شود که به ازای هر نوع یک عدد منحصر به فرد در نظر گرفته می‌شود. بنابراین با توجه به تفاوت داده‌های مربوط به شبکه،

<sup>۱</sup>Gray Wolf Optimization Algorithm

این شبکه‌ها ELM نامیده می‌شوند. ELM بطور گسترده‌ای برای حل مسائل دسته‌بندی و رگرسیون بکار برده می‌شود [۹]. شکل (۲) ساختار شبکه ELM را نشان می‌دهد که لایه ورودی آن تعداد  $D$  نورون و لایه مخفی آن تعداد  $L$  نورون دارد. تعداد نورون‌های لایه خروجی در مسائل طبقه‌بندی برابر با تعداد کلاس‌ها و در مسائل رگرسیون برابر با تعداد متغیرهای خروجی است که در اینجا شبکه دارای  $C$  نورون خروجی است [۱۰].



شکل (۲): نمای کلی از ماشین یادگیری مغرط [۱۱]

## ۱-۵- همه برای برنده<sup>۱۰</sup>

سیستم‌هایی که دارای رویکرد همه برای برنده هستند، به کمک اتصال ماژول‌ها (در محیط‌هایی با طراحی وظیفه محور) کار می‌کنند؛ به گونه‌ای که وقتی یک عمل انجام می‌شود، انجام تمام اقدامات دیگر متوقف می‌شود، بنابراین در یک زمان تنها یک عمل انجام می‌شود. در این رویکرد، عمل برنده تمام قدرت سیستم موتور را می‌گیرد [۱۲].

## ۲- پیشینه پژوهش

اغلب مقالات ارائه شده در خصوص رویکردهای انتخاب ویژگی در زمینه‌های تشخیص نفوذ می‌باشند که بررسی و در قالب جدول (۱) مطرح گردیده است.

## ۱-۲- انتخاب ویژگی

انتخاب ویژگی (با نام انتخاب متغیر<sup>۱</sup> نیز شناخته می‌شود) رویکردی است که بر اساس یکسری از معیارها به انتخاب زیرمجموعه‌ای مناسب از ویژگی‌ها از میان مجموعه‌ی تمام ویژگی‌ها می‌پردازد [۶].

## ۱-۳- شبکه‌های عصبی

امروزه استفاده از هوش مصنوعی جهت تشخیص نفوذ از اهمیت بالایی برخوردار شده است [۲۹]. یکی از مهم‌ترین ویژگی‌های شبکه‌های عصبی مصنوعی که عملکرد آن را به انسان نزدیک‌تر می‌نماید، قدرت یادگیری است. فرآیند یادگیری در شبکه‌های عصبی مصنوعی عبارت است از بهنگام‌سازی معماری شبکه و وزن‌های ارتباطی آن به نحوی است که یک شبکه بتواند یک وظیفه خاص را به صورت کارا انجام دهد. [۷].

## ۱-۴- ماشین یادگیری مغرط

شبکه‌های عصبی پیشخور با یک لایه مخفی یکی از محبوب‌ترین مدل‌های شبکه عصبی هستند که ساختار ساده شامل یک لایه ورودی، یک لایه مخفی و یک لایه خروجی دارند. اثبات شده است که چنین شبکه‌ای با یک لایه مخفی با تعداد دلخواه پارامتر و توابع فعال‌سازی دلخواه می‌تواند تقریب زنده جهانی برای هر تابع پیوسته باشند، این مشخصه در سال ۱۹۸۹ توسط سیبکو<sup>۲</sup> و فوناشی<sup>۳</sup> تایید شد و اخیراً هوآنگ<sup>۴</sup> و بابری<sup>۵</sup> توانایی‌های بالای یادگیریشان را نشان دادند [۸]. با این حال، این نوع از شبکه‌های عصبی از مشکل زمان زیاد فرآیند آموزش رنج می‌برند زیرا الگوریتم یادگیری‌شان براساس روش‌های گرادایانت نزولی<sup>۶</sup> مانند پس‌انتشار خطا<sup>۷</sup> بوده و این الگوریتم‌های یادگیری در مینیمم محلی<sup>۸</sup> گیر می‌افتند. به منظور غلبه بر این مشکل، هوآنگ و همکارانش در سال ۲۰۰۴ تکنیک یادگیری ماشین یادگیری مغرط (ELM)<sup>۹</sup> با هدف کاهش هزینه محاسباتی متحمل شده توسط روش پس‌انتشار خطا در طول فرآیند آموزش را برای شبکه‌های عصبی پیشخور با یک لایه مخفی پیشنهاد کرده اند که

<sup>1</sup>Variable Selectio

<sup>2</sup>Cybenco

<sup>3</sup>Funahashi

<sup>4</sup>Huang

<sup>5</sup>Babri

<sup>6</sup>Gradient Descent Methods

<sup>7</sup>Error Back-Propagation

<sup>8</sup>Local Minima

<sup>9</sup>Extreme Learning Machine (ELM)

<sup>10</sup> winner-Take-All

جدول (۱): خلاصه مقالات بررسی شده در سال‌های اخیر

ردیف	سال انتشار	موضوع مورد بررسی	روش مورد استفاده	مزایا و معایب
۱	۲۰۲۲	مقاله‌ای مروری در خصوص رویکردهای اخیر انتخاب ویژگی برای تشخیص نفوذ [۱۳]	مروری بر پیشرفت‌های اخیر در تکنیک‌های انتخاب ویژگی برای تشخیص و طبقه‌بندی حمله، اعمال شده در ناحیه تشخیص نفوذ با در نظر گرفتن طراحی، منطق، ویژگی‌های فنی و معیارهای ارزیابی رایج ارائه شده است.	بررسی چالش‌های موجود و ارائه رویکرد جدید برای تشخیص نفوذ
۲	۲۰۲۲	ارائه یک مدل انتخاب ویژگی موثر با استفاده از الگوریتم‌های فراابتکاری ترکیبی برای تشخیص نفوذ در اینترنت اشیا [۱۴]	انتخاب ویژگی کارآمد از طریق ترکیبی از انتخاب ویژگی همبستگی همراه با ویژگی‌های پائل شده جنگل (CFS-FPA) به دست می‌آید. تشخیص نفوذ بهبودیافته شامل بهره‌برداری از الگوریتم‌های یادگیری AdaBoosting و بسته‌بندی برای اصلاح چهار طبقه‌بندی‌کننده ماشین بردار پشتیبان، جنگل تصادفی، بیز ساده و k نزدیکترین همسایه است.	+ افزایش دقت و کاهش خطا - پیچیدگی محاسباتی
۳	۲۰۲۲	ارائه یک مدل انتخاب ویژگی موثر با استفاده از الگوریتم‌های فراابتکاری ترکیبی برای تشخیص نفوذ در اینترنت اشیا [۱۵]	روش انتخاب ویژگی جدید را از طریق افزایش عملکرد بهینه ساز Gorilla Troops (GTO) بر اساس الگوریتم برای ازدحام پرنندگان (BSA) ارائه می‌کند. این BSA برای تقویت بهره برداری از عملکرد GTO در GTO-BSA جدید توسعه یافته استفاده می‌شود	+ نرخ هم‌گرایی بهتر و راه‌حل با کیفیت بالاتر - پیچیدگی محاسباتی
۴	۲۰۲۲	ارائه یک نسخه باینری از الگوریتم باروری زمین‌های کشاورزی (FFA) به نام BFFA برای انتخاب ویژگی در بهبود سیستم‌های تشخیص نفوذ [۱۶]	از تابع V شکل برای جابجایی فرآیندهای FFA در فضای باینری استفاده می‌شود روش پیشنهادی بر روی دو مجموعه داده معتبر IDS یعنی UNSW-NB15 و NSL-KDD آزمایش شده و در معیارهای دقت، صحت، Recall و امتیاز F1 با k نزدیکترین همسایه (KNN)، ماشین بردار پشتیبان (SVM)، درخت تصمیم (DT)، جنگل تصادفی (RF) و بیز ساده (NB) مقایسه شده است. [22]. روش [24] پیشنهادی مبتنی بر ترکیب انتخاب ویژگی بر اساس الگوریتم بهینه‌سازی نهنگ و الگوریتم ژنتیک با طبقه‌بندی KNN از نظر معیارهای دقت، نتایج بهتری نسبت به سایر روش‌های قبلی دارد. [23] در سال ۲۰۲۲ اوتیر و همکارانش، رویکردی جدید برای تشخیص نفوذ با استفاده از بهینه‌سازی گرگ خاکستری (GWO) برای حل مشکلات انتخاب ویژگی و ترکیب آن با بهینه‌سازی ازدحام ذرات (PSO) برای استفاده از بهترین مقدار برای به‌روزرسانی اطلاعات هر موقعیت گرگ خاکستری ارائه کرده‌اند. [24].	+ افزایش دقت و کاهش خطا - پیچیدگی محاسباتی
۵	۲۰۲۲	ارائه یک سیستم تشخیص نفوذ مبتنی بر انتخاب ویژگی با استفاده از الگوریتم بهینه‌سازی نهنگ ژنتیکی و طبقه‌بندی مبتنی بر نمونه [۱۷]	در این تحقیق از مجموعه داده‌های استاندارد KDDCUP1999 استفاده شده است که در آن مشخصات مربوط به گره‌های سالم و انواع گره‌های مخرب بر اساس نوع حملات در شبکه ذخیره می‌شود. روش پیشنهادی مبتنی بر ترکیب انتخاب ویژگی بر اساس الگوریتم بهینه‌سازی نهنگ و الگوریتم ژنتیک با طبقه‌بندی KNN از نظر معیارهای دقت، نتایج بهتری نسبت به سایر روش‌های قبلی دارد.	+ افزایش دقت و کاهش خطا - پیچیدگی محاسباتی
۶	۲۰۲۲	ارائه رویکرد بهینه‌سازی برای تشخیص نفوذ با استفاده از بهینه‌سازی گرگ خاکستری (GWO) و ترکیب آن با بهینه‌سازی ازدحام ذرات (PSO) [۱۸]	انتخاب ویژگی و ترکیب آن با بهینه‌سازی ازدحام ذرات (PSO) برای استفاده از بهترین مقدار برای به‌روزرسانی اطلاعات هر موقعیت گرگ خاکستری ارائه کردند. این تکنیک بهترین اطلاعات موقعیت فرد را توسط الگوریتم PSO حفظ می‌کند، که از سقوط الگوریتم GWO به یک بهینه محلی جلوگیری می‌کند.	+ افزایش دقت و کاهش خطا - پیچیدگی محاسباتی
۷	۲۰۲۱	ارائه یک سیستم تشخیص نفوذ پیشرفته (IDS) با استفاده از بهینه‌سازی گرگ خاکستری باینری اصلاح شده با ماشین بردار پشتیبان [۱۹]	در روش پیشنهادی از ۳ گرگ، ۵ گرگ و ۷ گرگ برای یافتن بهترین تعداد گرگ استفاده شد. هدف روش پیشنهادی افزایش دقت تشخیص نفوذ و نرخ تشخیص و کاهش زمان پردازش در محیط WSN از طریق کاهش نرخ آلام‌های کاذب و تعداد ویژگی‌های حاصل از IDSها در محیط WSN است. مجموعه داده NSL KDD'99 برای نشان دادن عملکرد روش پیشنهادی و مقایسه آن با سایر روش‌های موجود استفاده شده است. روش‌های پیشنهادی از نظر دقت، تعداد ویژگی‌ها، زمان اجرا، نرخ هشدار نادرست و نرخ تشخیص ارزیابی می‌شوند.	+ افزایش دقت و کاهش خطا - پیچیدگی محاسباتی
۸	۲۰۲۱	ارائه یک روش انتخاب ویژگی مبتنی بر بهبود الگوریتم جستجوی کلاغ که در سیستم تشخیص نفوذ برای محدود کردن اندازه مجموعه داده [۲۰]	از الگوریتم جستجوی کلاغ در سیستم تشخیص نفوذ به عنوان مدلی برای یافتن زیرمجموعه ویژگی بهینه و جنگل تصادفی به عنوان قضاوت در مورد ویژگی‌هایی که توسط CSA-IDS تولید می‌شوند، استفاده می‌کند. مجموعه داده‌های KDD و UNSW برای ارزیابی مدل پیشنهادی قبلی استفاده می‌شوند. مدل پیشنهادی به دقت ۹۹٫۸۴ درصد برای تشخیص حمله با استفاده از مجموعه داده‌های UNSW دست یافت. به طور مشابه، حملات R2L و U2R دقت ۹۹٫۹۷٪ را برای مجموعه داده NSL-KDD شناسایی کرده‌اند.	+ افزایش دقت و کاهش خطا - پیچیدگی محاسباتی

جدول (۱): خلاصه مقالات بررسی شده در سال‌های اخیر

ردیف	سال انتشار	موضوع مورد بررسی	روش مورد استفاده	مزایا و معایب
۹	۲۰۲۱	ارائه یک سیستم تشخیص نفوذ هوشمند مبتنی بر ناهنجاری برای شبکه اینترنت اشیاء با استفاده از الگوریتم‌های گرگ خاکستری، بهینه‌سازی ازدحام ذرات و جنگل تصادفی [۲۱]	از داده‌های آموزشی و برچسب داده‌ها KDD-Cup'99 با الگوریتم جنگل تصادفی استفاده شده است. پس از آن از داده‌های آزمایشی استفاده می‌شود. از داده‌های ذخیره شده در مرحله آموزش استفاده می‌شود که در واقع یک کپی از داده‌ها است، به طوری که در هنگام انجام مرحله آزمون، می‌توان همان داده‌های آموزشی را با طبقه‌بندی با استفاده از الگوریتم PSO مقایسه کرد. دقت روش پیشنهادی در این مقاله به ۹۷ درصد رسید. با روش پیشنهادی سرعت یادگیری بسیار افزایش یافته و دقت قابل قبولی دارد	+ افزایش دقت و کاهش خطا - پیچیدگی محاسباتی
۱۰	۲۰۲۱	ارائه یک رویکرد جدید تشخیص نفوذ شبکه اینترنت اشیاء مبتنی بر شبکه عصبی کانولوشن <sup>۱</sup> و بهینه‌سازی ازدحام ذرات تطبیقی [۲۲]	الگوریتم PSO با تغییر وزن اینرسی برای بهینه‌سازی تطبیقی پارامترهای ساختار CNN یک بعدی استفاده می‌شود. مقدار تابع زبان متقاطع آنتروپی، که از اولین آموزش CNN به دست می‌آید، به عنوان مقدار برازندگی PSO در نظر گرفته می‌شود. نتایج شبیه‌سازی نشان می‌دهد که تکلیف چند نوع تشخیص حمله نفوذ شبکه اینترنت اشیاء بر اساس الگوریتم APSO-CNN مؤثر و قابل اعتماد است	+ افزایش دقت و اثربخشی - پیچیدگی محاسباتی
۱۱	۲۰۲۱	ارائه یک روش مؤثر انتخاب ویژگی مبتنی بر الگوریتم ژنتیک برای سیستم‌های تشخیص نفوذ [۲۳]	روش انتخاب ویژگی مبتنی بر الگوریتم ژنتیک (GA) بهبود یافته، به نام انتخاب ویژگی مبتنی بر GA (GbFS)، برای افزایش دقت طبقه‌بندی کننده ارائه می‌دهد. ایمن‌سازی شبکه از حملات سایبری یک وظیفه حیاتی است و باید تقویت شود. مقایسه‌ای نیز با روش‌های استاندارد انتخاب ویژگی انجام می‌شود. نتایج نشان می‌دهد که دقت با استفاده از GbFS به حداکثر دقت ۹۹/۸۰ درصد دست می‌یابد	+ افزایش دقت و کاهش خطا - پیچیدگی محاسباتی
۱۲	۲۰۲۱	ارائه یک سیستم تشخیص نفوذ مبتنی بر طبقه‌بندی کننده ژنتیک - فازی برای تشخیص حملات مخرب [۲۴]	یک مدل جدید به نام سیستم تشخیص نفوذ مبتنی بر رویکرد ترکیبی (GA-Fuzzy) برای مدیریت مجموعه داده‌های NSL-KDD با حجم زیاد برای تشخیص حملات مؤثر و کاهش نرخ هشدار طبقه‌بندی اشتباه پیشنهاد شده است. که کارایی را بهبود می‌بخشد و به دقت تشخیص ۹۹/۹۶٪ و نرخ هشدار نادرست ۰/۰۴٪ می‌رسد	+ افزایش دقت - پیچیدگی محاسباتی
۱۳	۲۰۲۱	یک سیستم تشخیص نفوذ اصلاح‌شده با استفاده از الگوریتم کرم شبتاب در محیط ابری [۲۵]	IDS پیشنهادی امنیت کار بر روی ایده انتخاب ویژگی را فراهم می‌کند. نویسندگان یک الگوریتم کرم شبتاب اصلاح شده تهیه کرده‌اند که به عنوان یک روش انتخاب ویژگی ماهر عمل می‌کند و مجموعه داده NSL-KDD را قادر می‌سازد تا فضای ذخیره‌سازی کمتری را با کاهش ابعاد و همچنین زمان آموزش کمتر با دقت طبقه بندی بیشتر مصرف کند	+ افزایش دقت و کارایی - پیچیدگی محاسباتی
۱۴	۲۰۲۱	ارائه یک سیستم تشخیص نفوذ برای پیشرفت الگوریتم‌های یادگیری عمیق مبتنی بر زیرساخت اینترنت اشیاء [۲۶]	رویکرد پیشنهادی، توسعه یک سیستم چارچوب قوی برای تشخیص نفوذ بر اساس محیط اینترنت اشیاء است. مجموعه داده IoTID20 برای توسعه سیستم پیشنهادی استفاده شد. این مجموعه داده جدید از زیرساخت اینترنت اشیاء ایجاد شده است. در این چارچوب، سه الگوریتم یادگیری عمیق پیشرفته برای طبقه‌بندی نفوذ استفاده شده، شبکه عصبی کانولوشن (CNN)، حافظه کوتاه‌مدت بلند مدت (LSTM) و ترکیب شبکه عصبی کانولوشن با حافظه کوتاه‌مدت (CNN-LSTM). برای بهبود سیستم پیشنهادی، از روش بهینه‌سازی ازدحام ذرات (PSO) برای انتخاب ویژگی‌های مرتبط از مجموعه داده شبکه استفاده شد.	+ افزایش دقت و اثربخشی - پیچیدگی محاسباتی
۱۵	۲۰۲۰	ارائه یادگیری ماشین مغرط مبتنی بر انتخاب ویژگی بدون نظارت را برای خوشه‌بندی [۲۷]	با به حداقل رساندن نرم 1_1,2 وزن خروجی، انتخاب ویژگی را انجام می‌دهد و نتایج خوشه‌بندی توسط ترکیب ویژه محاسبه می‌شود. با حل مسئله بهینه‌سازی فرموله شده به روشی تکراری، دقت خوشه‌بندی را بهبود می‌بخشد.	+ افزایش دقت و اثربخشی - بیش برآزش
۱۶	۲۰۲۰	ارائه یک سیستم تشخیص نفوذ مشارکتی بهینه شده (OCIDS) برای شبکه‌های حسگر بی سیم [۲۸]	از الگوریتم بهینه‌سازی کلونی زنبورهای مصنوعی بهبود یافته برای بهینه‌سازی IDS سلسله مراتبی اعمال شده در WSN ها با توجه به دقت تشخیص نفوذ و همچنین مصرف منابع محدود استفاده می‌کند. علاوه بر این، سیستم پیشنهادی الگوریتم ماشین بردار پشتیبانی وزنی را برای بهبود دقت تشخیص و کاهش نرخ هشدار کاذب بهینه می‌کند.	+ افزایش دقت و اثربخشی - پیچیدگی محاسباتی
۱۷	۲۰۲۴	تشخیص نفوذ با نزول شیب تصادفی برای سیستم تشخیص حمله در	این تحقیق رویکرد جدیدی از سیستم تشخیص نفوذ (IDS) به نام SG-IDS را پیشنهاد می‌کند که از الگوریتم‌های نزول شیب تصادفی	+ دقت بهبود یافته نسبت به روش‌های پیشرفته موجود.

<sup>1</sup> Convolutional Neural Network (CNN)

جدول (۱): خلاصه مقالات بررسی شده در سال‌های اخیر

ردیف	سال انتشار	موضوع مورد بررسی	روش مورد استفاده	مزایا و معایب
		شبکه‌های حسگر بی‌سیم با استفاده از یادگیری ماشین [۳۰]	(SGD) و بیز ساده گاوسی (GNB) برای بهبود تشخیص نفوذ در شبکه‌های حسگر بی‌سیم (WSN) استفاده می‌کند.	+ کاهش پیچیدگی محاسباتی به دلیل انتخاب ویژگی با استفاده از PCA و SVD. + قابل اعمال بر روی هر دو شبکه WSN و شبکه‌های IoMT - نیاز به تنظیم دقیق پارامترها برای عملکرد بهینه. - احتمال overfitting (برازش بیش از حد) در صورتی که داده‌های آموزشی نماینده سناریوهای دنیای واقعی نباشند.
۱۸	۲۰۲۳	سیستم تشخیص نفوذ با استفاده از الگوریتم‌های طبقه‌بندی ژنتیکی عصبی فازی (FNGCA) و بهینه‌سازی اجتماع ذرات مبتنی بر قانون (RBPSO) در شبکه‌های حسگر بی‌سیم [۳۱]	بهینه‌سازی اجتماع ذرات مبتنی بر قانون (RBPSO) برای انتخاب ویژگی و الگوریتم طبقه‌بندی ژنتیکی عصبی فازی (FNGCA) برای طبقه‌بندی	+ کاهش مصرف انرژی، بهبود امنیت ارتباطات، افزایش نرخ تشخیص، ارتباط قابل اعتماد - افزایش پیچیدگی، هزینه محاسباتی بالاتر
۱۹	۲۰۲۳	تشخیص نفوذ مبتنی بر انتخاب ویژگی با بهینه‌سازی چندهدفه اجتماع ذرات (PSO) برای شبکه‌های حسگر بی‌سیم مبتنی بر اینترنت اشیا (IoT) [۳۲]	بهینه‌سازی چندهدفه اجتماع ذرات هوشمند (IMOPSO) و ماشین بردار پشتیبان چند کلاسه مبتنی بر قانون (rule-based MSVM)	+ دقت و نرخ تشخیص بالاتر. + نرخ مثبت کاذب پایین‌تر. + انتخاب ویژگی کارآمدتر. - الگوریتم پیچیده‌تر. - نیاز به منابع محاسباتی بیشتر.
۲۰	۲۰۲۴	یک رویکرد پیش‌بینی مبتنی بر موقعیت برای کشف و پیشگیری از نفوذ امنیت سایبری با استفاده از الگوریتم‌های یادگیری ماشین و یادگیری عمیق در شبکه‌های حسگر بی‌سیم مبتنی بر صنعت ۴.۰ [۳۳]	پرسپترون چند لایه، رمزگذار خودکار، درخت تصمیم	+ اولویت‌بندی هوشمند، سیستم پیشگیری پیش‌فعال، رویکرد چند معیاره - نیاز به داده آموزشی، ممکن است برای همه انواع حملات مناسب نباشد
۲۱	۲۰۲۳	الگوریتم بهینه‌سازی باینری شامپانزه با تشخیص نفوذ مبتنی بر یادگیری ماشین برای ایمن‌سازی شبکه‌های حسگر بی‌سیم تحت پوشش اینترنت اشیا [۳۴]	الگوریتم باینری بهینه‌سازی شامپانزه (BCOA) برای انتخاب ویژگی و ماشین یادگیری شدید با تنظیم هزینه بر اساس کلاس (CCR-ELM) برای طبقه‌بندی	+ BCOA الگوریتمی ساده، قوی و با سرعت همگرایی بالا است. + CCR-ELM در رسیدگی به مسائل عدم تعادل کلاس (class imbalance) مؤثر است. + رویکرد پیشنهادی به دقت بالایی در تشخیص نفوذ دست می‌یابد. - BCOA ممکن است مستعد بهینه‌های محلی (local optima) باشد. - CCR-ELM نیازمند تنظیم دقیق پارامترها است.
۲۲	۲۰۲۴	تشخیص نفوذ سایبری در شبکه‌های حسگر بی‌سیم با استفاده از تکنیک ترکیبی کاهش ویژگی با روش‌های هوش مصنوعی و یادگیری ماشین [۳۵]	خوشه‌بندی K-means، انتخاب ویژگی بر اساس gain اطلاعات، متوازن‌سازی داده با SMOTE-based ENN، شبکه عصبی عمیق پیش‌رو (DFNN)	+ دقت بالا، عملکرد بهبود یافته نسبت به روش‌های سنتی یادگیری ماشین - نیاز به داده برجسته‌گذاری شده، پرهزینه از نظر محاسباتی

شاخص خوشه را از خروجی با هر دو محدودیت غیر منفی و متعامد محاسبه می‌گردد. گام‌های روش پیشنهادی به صورت زیر شرح داده می‌شود:

جدول (۲): گام‌های روش پیشنهادی

ردیف	گام	ردیف	گام
۱	ورود دادگان	۴	دسته بندی و تشخیص نفوذ
۲	بهبود تابع هدف یادگیری ماشین مغرط بدون نظارت	۵	محاسبه معیار ارزیابی
۳	انتخاب ویژگی		

### ۳-۱- ورود داده

مجموعه داده مورد استفاده در این پژوهش مجموعه داده  $NSL-KDD$  است

### ۳-۲- تابع هدف (انتخاب ویژگی)

یادگیری بی نظارت مبتنی بر این فرضیه است: اگر دو نقطه  $x_1$  و  $x_2$  نزدیک هم باشند، احتمال‌های شرطی آن‌ها  $P(y|x_1)$  و  $P(y|x_2)$  باید مشابه باشند. برای اجرای این فرض بر داده‌ها، رابطه‌ی (۱) بدست آورده می‌شود:

$$L_m = \frac{1}{2} \sum_{i,j} w_{ij} \|P(y|x_i) - P(y|x_j)\|^2 \quad (1)$$

در فرآیند خوشه‌بندی دو معیار مورد استفاده قرار می‌گیرد شباهت و فاصله در ماشین یادگیری مغرط بدون نظارت و رابطه (۱) رابطه نشان می‌دهد براساس احتمالات کدام ورودی به کدام خروجی تعلق خواهد داشت به عبارتی عمل خوشه بندی صورت می‌پذیرد.

که در آن  $w_{ij}$  شباهت بین  $x_1$  و  $x_2$  است، که می‌توان آن را با تابع گوسین  $\exp(-\|x_i - x_j\|^2 / 2\sigma^2)$  حساب کرد. به دلیل اینکه محاسبه‌ی احتمال‌های شرطی سخت است، رابطه‌ی (۲) می‌تواند رابطه‌ی فوق را تقریب بزند.

$$\hat{L}_m = Tr(\hat{Y}^T L \hat{Y}) \quad (2)$$

که در آن  $Tr(\cdot)$  اثر ماتریس را نشان می‌دهد،  $\hat{Y}$  پیش‌بینی‌های مجموعه داده بدون برچسب است،  $L = D - W$  گراف لاپلاسی است و  $D$  ماتریس قطری با عناصر قطری  $D_{ii} = \sum_{j=1}^u w_{ij}$  است. در یادگیری بی نظارت، مجموعه داده  $X = \{x_i\}_{i=1}^N$  بدون برچسب است. مسئله بهینه‌سازی ماشین یادگیری مغرط بدون نظارت برای انتخاب ویژگی به صورت (۳) فرموله می‌شود:

$$\min_{\beta, F} \|\bar{H}\beta - F\|_F^2 + \lambda_1 \|\beta\|_{2,1} + \lambda_2 \frac{R}{2} Tr[\beta^T \bar{H}^T L \bar{H} \beta] \quad (3)$$

s. t  $F \in [0, 1]^{n \times c}$

### ۳- روش پیشنهادی

با توجه به اینکه پردازش داده‌ها با اعداد کار می‌کنند و برخی از مشخصه‌های این مجموعه داده دارای مقادیر رشته‌ای هستند، لذا تغییر آن‌ها به مقادیر عددی برای انجام پردازش الزامی می‌باشد. برای تبدیل نوع‌های رشته‌ای به عدد نیز به این صورت عمل می‌شود که به ازای هر نوع یک عدد منحصر به فرد در نظر گرفته می‌شود. گام اول در ایجاد هر مدلی مبتنی بر تکنیک‌های داده کاوی، مرحله پیش پردازش داده‌ها می‌باشد. این مرحله شامل نرمال سازی و درهم ریختن داده‌ها می‌باشد. در مرحله بعد با استفاده از ماشین یادگیری مغرط بدون نظارت ویژگی‌های مطلوب استخراج می‌شود. در برخی از مجموعه داده‌ها تعداد ویژگی‌ها زیاد می‌باشند و ممکن است برخی از این ویژگی‌ها در طبقه بندی داده‌ها نقشی نداشته باشند. بنابراین نیاز است که زیرمجموعه‌ای از بهترین ویژگی‌ها انتخاب شوند. روشی که برای انتخاب ویژگی‌ها در این پژوهش در نظر گرفته شده است، براساس اندازه گیری توزیع ویژگی‌ها عمل می‌کند. به این صورت که در تکرارهای متوالی ویژگی‌های سنجیده شده توسط یادگیری ماشین مغرط بدون نظارت شناسایی شده و از آن‌ها در ساخت راه حل‌های جدید استفاده می‌شود. بعد از انتخاب ویژگی‌ها دادگان خوشه بندی می‌شوند. در مرحله آخر، خوشه بندی داده‌ها با ویژگی‌های استخراج شده محاسبه می‌شود. منظور از تعداد ویژگی‌ها مشخص کردن تعداد ویژگی‌های انتخابی از کل ویژگی‌ها در مجموعه داده می‌باشد. بعد از تعیین ویژگی‌های مطلوب نهایی، صحت خوشه بندی ویژگی‌های انتخاب شده توسط یادگیری ماشین مغرط بدون نظارت نشان داده می‌شود.

روش پیشنهادی و مقاله [۳۶] هر دو در مورد تشخیص نفوذ در شبکه‌های حسگر بی سیم می‌باشند. اما این مقاله رویکردی جدید برای انتخاب ویژگی و تشخیص نفوذ با استفاده از ماشین یادگیری افراطی بدون نظارت (UELM) ارائه می‌دهد در حالی که مقاله [۳۶] از الگوریتم بهینه سازی گرگ خاکستری (GWO) برای انتخاب ویژگی در سیستم‌های تشخیص نفوذ و از رویکرد یادگیری با نظارت تمرکز دارد.

داده‌های عمومی توزیع‌های پیچیده متفاوتی در فضاهای اصلی خود دارند، خواص مشابه نمونه‌های داده را نمی‌توان به راحتی آشکار کرد. بنابراین، معمولاً خوشه بندی داده‌های عمومی به شدت به ویژگی‌های اصلی آنها بستگی دارد. لذا ابتدا از نگاهت غیر خطی برای تبدیل داده‌ها به یک فضای پنهان استفاده می‌گردد که در آن ویژگی‌های مشابه نمونه‌ها را می‌توان با ویژگی‌ها نشان داد. سپس، ویژگی‌های انتخاب شده می‌توانند نشانگر خوشه را در فضای خروجی تقریب بزنند. علاوه بر این، از منظم سازی منیفولد برای حفظ هندسه ذاتی فضای خروجی به صورت مشابه در فضای اصلی استفاده می‌شود. در نهایت،



پارامترهای نورون های اولیه به طور تصادفی نیازی به تغییر ندارند. ماتریس داده اصلی  $X$  فقط برای ساختن نرمال شده  $\bar{H}$  و ماتریس لاپلاسیان  $L$  استفاده می شود که در طول فرآیند آموزش ثابت هستند. ایده کلیدی روش پیشنهادی یادگیری وزن های خروجی بین لایه پنهان و لایه خروجی است، به طوری که خروجی  $\bar{H}\beta$  می تواند نسخه ماتریس نشانگر خوشه  $F$  را تقریب بزند زیرا میانگین مربعات خطای بین آن ها به حداقل می رسد.

که در آن  $\bar{H}$  و  $\beta$  به ترتیب نورون های پنهان نرمال شده و وزن های خروجی ماشین یادگیری مفرط بدون نظارت هستند،  $R$  ضریب تنظیم (رگولاریزیشن) خطاهای آموزش،  $L$  ماتریس لاپلاسیان از پیش تعریف شده و  $F$  ماتریس نشانگر خوشه است. ابتدا، نورون های تصادفی در لایه پنهان، داده های اصلی را با نگاشت غیرخطی گسترش می دهند و مجموعه ویژگی های بزرگ  $H$  را تولید می کنند که سپس به میانگین صفر نرمال می شود.

جدول (۳): شبه کد روش پیشنهادی

The UFSELM algorithm.	
<p><b>Input:</b> Normalized data <math>X \in \mathbb{R}^{n \times d}</math>, Laplacian matrix <math>L \in \mathbb{R}^{n \times n}</math>, Number of clusters <math>c</math>, Number of neurons <math>m</math>, Trade-off parameters <math>\lambda_1</math> and <math>\lambda_2</math>, Number of iterations <math>t</math>.</p> <p><b>Output:</b> Cluster indicator matrix <math>F \in \mathbb{R}^{n \times c}</math>.</p> <ol style="list-style-type: none"> <li>1. Begin</li> <li>2. Initialize the cluster indicator matrix <math>F</math> by k-Means clustering on <math>X</math>.</li> <li>3. Generate input weights and biases of hidden neurons randomly and calculate the centered hidden layer output matrix <math>\hat{H}</math>.</li> <li>4. Initialize <math>B \in \mathbb{R}^{m \times m}</math> as an identity matrix.</li> <li>5. Compute <math>Q</math> by <math>Q = \hat{H}^T \hat{H} + \lambda_1 B + \lambda_2 \hat{H}^T L \hat{H}</math></li> <li>6. Repeat</li> <li>7. Update <math>\beta = Q^{-1} \hat{H} F</math></li> <li>8. foreach diagonal element of <math>B</math> do</li> <li>9. Update <math>B_{ii} = \frac{1}{\sqrt{\beta_i^T \beta_i + \epsilon}}</math></li> <li>10. end</li> <li>11. Update by <math>Q = \hat{H}^T \hat{H} + \lambda_1 B + \lambda_2 \hat{H}^T L \hat{H}</math></li> <li>12. Update <math>F</math> by solving problem</li> <li>13. Until Reaching <math>t</math>-th iteration.;</li> <li>14. End</li> </ol>	
UFSELM الگوریتم	
<p>ورودی <math>X \in \mathbb{R}^{n \times d}</math> ماتریس داده ورودی</p> <p>ماتریس لاپلاسیان <math>L \in \mathbb{R}^{n \times n}</math></p> <p><math>c</math> تعداد کلاس / خوشه</p> <p><math>m</math> ابعاد لایه پنهان</p> <p><math>\lambda_1</math> and <math>\lambda_2</math> پارامترهای مصالحه</p> <p><math>t</math> تعداد تکرار</p> <p><b>Output:</b> <math>F \in \mathbb{R}^{n \times c}</math> ماتریس خوشه شاخص (ویژگی).</p>	<ol style="list-style-type: none"> <li>۱۵. شروع</li> <li>۱۶. ماتریس نشانگر خوشه <math>F</math> را با خوشه بندی k-Means روی <math>X</math> راه اندازی کنید.</li> <li>۱۷. وزن های ورودی و بایاس های نورون های پنهان را به طور تصادفی ایجاد کنید و ماتریس خروجی لایه پنهان مرکزی <math>H</math> را محاسبه کنید.</li> <li>۱۸. <math>B</math> به عنوان یک ماتریس مورب مقداردهی اولیه می شود.</li> <li>۱۹. محاسبه کنید <math>Q</math> بوسیله <math>Q = \hat{H}^T \hat{H} + \lambda_1 B + \lambda_2 \hat{H}^T L \hat{H}</math></li> <li>۲۰. تکرار کردن</li> <li>۲۱. بروزرسانی <math>\beta = Q^{-1} \hat{H} F</math></li> <li>۲۲. برای هر عنصر مورب <math>B</math></li> <li>۲۳. بروزرسانی کنید <math>B_{ii} = \frac{1}{\sqrt{\beta_i^T \beta_i + \epsilon}}</math></li> <li>۲۴. پایان</li> <li>۲۵. بروزرسانی بوسیله <math>Q = \hat{H}^T \hat{H} + \lambda_1 B + \lambda_2 \hat{H}^T L \hat{H}</math></li> <li>۲۶. بروزرسانی <math>F</math></li> <li>۲۷. رسیدن تا تکرار نهایی <math>t</math>.</li> <li>۲۸. پایان</li> </ol>

اگر دو نمونه داده ورودی نزدیک به یکدیگر باشند، برچسب‌های مربوطه آنها به نسبت نزدیک هستند. بنابراین، منظم‌سازی منیفولد در اینجا برای حفظ هندسه ذاتی توزیع داده استفاده می‌گردد. برای به حداقل رساندن پارامتر تنظیم، ماتریس وزن‌های خروجی باید به گونه‌ای تنظیم شود که خروجی  $\bar{H}\beta$  دارای هندسه ذاتی مشابه با ماتریس ورودی  $X$  باشد. همانطور که مسئله فرموله شده است، هدف ماشین یادگیری بدون نظارت برای انتخاب ویژگی، یادگیری خوشه‌بندی با تنظیم وزن‌های خروجی برای انتخاب ویژگی‌هاست تا خروجی ماشین یادگیری بدون نظارت بتواند ماتریس نشانگر خوشه را با ساختار هندسی مشابه داده‌های اصلی تقریب کند.

### ۳-۳- بهینه‌سازی متناوب (انتخاب ویژگی و دسته‌بندی)

بهینه‌سازی متناوب برای حل مسئله بهینه‌سازی فرمول‌بندی شده اتخاذ شده است. هنجار  $L_{2,1}$  را می‌توان به شکل  $\text{Tr}[\beta^T B \beta]$  بیان کرد که در آن  $B$  یک ماتریس مورب با  $B_{ii} = \frac{1}{\sqrt{\beta_i^T \beta_i + \epsilon}}$  است. سپس مسئله بهینه‌سازی به رابطه (۴)

$$\min_{\beta, F} \|\bar{H}\beta - F\|_F^2 + \lambda_1 \text{Tr}[\beta^T B \beta] + \lambda_2 \text{Tr}[\beta^T \bar{H}^T L \bar{H} \beta] \quad (4)$$

تبدیل می‌شود:

برای حل مسئله فرمول‌بندی شده، ابتدا نشانگر خوشه‌ای  $F$  اولیه از خوشه‌بندی  $k$ -Means بر روی داده‌های اصلی به دست می‌آید. با ثابت بودن  $F$ ، می‌توان با تنظیم مشتق رابطه (۳-۲) برابر با صفر، جواب بهینه را به دست آورد.

$$2\bar{H}^T(\bar{H}\beta - F) + 2\lambda_1 B \beta + 2\lambda_2 \bar{H}^T L \bar{H} \beta = 0 \quad (5)$$

بدین ترتیب،

$$\beta = Q^{-1} \bar{H}^T F \quad (6)$$

که در آن  $Q = \bar{H}^T \bar{H} + \lambda_1 B + \lambda_2 \bar{H}^T L \bar{H}$  یک ماتریس متقارن است. اشاره شد که  $B$  به عنوان یک ماتریس مورب مقداردهی اولیه می‌شود و در هر تکرار پس از به‌روزرسانی  $\beta$  به روز می‌شود. تابع زیان (۳-۴) را می‌توان به صورت بازنویسی کرد:

در ماشین یادگیری بدون نظارت هنجار وزن‌های خروجی  $\beta$  به حداقل می‌رسد تا حاشیه‌های جداکننده دو کلاس مختلف در فضای ویژگی به حداکثر برسد. علاوه بر این، مجموعه ویژگی‌های بزرگ تولید شده توسط لایه پنهان احتمالاً از ویژگی‌های بی‌ارزش تشکیل شده است. برای گرفتن مجموعه ویژگی‌هایی که عملکرد بهتری را به دست می‌آورند، هنجار  $L_{2,1}$  را اتخاذ می‌کنیم. هنجار  $L_{2,1}$  یک ماتریس به عنوان هنجار  $L_1$  هنجارهای  $L_2$  هر ردیف از ماتریس تعریف می‌شود. برای بسیاری از ویژگی‌های بی‌اهمیت اتفاق می‌افتد که تمام وزن‌های مربوط به یک ویژگی فردی به طور همزمان به صفر کاهش می‌یابد، زمانی که هنجار  $L_{2,1}$  ماتریس وزن‌های خروجی به حداقل برسد. با باقی گذاشتن تنها تعداد کمی از ردیف‌های غیرصفر، مهم‌ترین ویژگی‌ها انتخاب می‌شوند. بنابراین، برای جاسازی انتخاب ویژگی در فرمول مسئله و افزایش حاشیه‌های جداکننده، ماتریس وزن خروجی  $L_{2,1}$  را به تابع بهینه‌سازی اضافه می‌گردد. دو عبارت اول با هم یک مدل رگرسیون پراکنده را تشکیل می‌دهند. پراکندگی توسط پارامتر مبادله  $\lambda_1$  کنترل می‌شود، اگر مقدار  $\lambda_1$  بسیار بزرگ بود، تمام عناصر  $\beta$  به صفر نزدیک می‌شوند.

جدول (۴): معرفی نمادها

نماد	تعریف	نماد	تعریف
$n$	تعداد نمونه‌ها	خروجی ماتریس مرکزی لایه پنهان	$H \in \mathbb{R}^{n \times m}$
$c$	تعداد کلاس / خوشه	وزن لایه خروجی	$\beta \in \mathbb{R}^{m \times c}$
$d$	ابعاد لایه ورودی	ماتریس لاپلاسیان	$L \in \mathbb{R}^{n \times n}$
$m$	ابعاد لایه پنهان	ماتریس همانی	$I$
$X \in \mathbb{R}^{n \times d}$	ماتریس داده ورودی	پارامترهای مصالحه	$\lambda_1, \lambda_2$
$Y \in \mathbb{R}^{n \times c}$	ماتریس برچسب کلاسی	خروجی ماتریس لایه پنهان	$H \in \mathbb{R}^{n \times c}$
$F \in \mathbb{R}^{n \times c}$	ماتریس خوشه شاخص (ویژگی)		

مجموعه داده *NSL-KDD* نسبت به سایر مجموعه داده‌ها در سیستم تشخیص نفوذ از رکوردهای واقعی تری برخوردار است. در واقع، *NSL-KDD* برخی مشکلات مجموعه داده اصلی *KDD99* مثل رکوردهای افزونه و تکراری در مجموعه آموزش و آزمون را که باعث انحراف طبقه‌بندی به سمت نمونه‌های تکراری می‌شود را رفع کرده است. مجموعه داده *NSL-KDD* شامل ۴۱ ویژگی و ۵ کلاس است که یک کلاس نرمال و ۴ نوع کلاس حمله در آن وجود دارد که کلاس‌های حمله عبارت هستند از: *U2R*, *Dos*, *R2L*, *Probing* در ادامه این چهار کلاس حمله معرفی می‌شوند.

**حملات انکار سرویس<sup>۱</sup>:** در این حملات منابع سیستم بیش از حد مورد استفاده قرار می‌گیرد و باعث می‌شود که درخواست‌های نرمال برای در اختیار گرفتن منابع رد شود. مهاجمان برخی محاسبات را که وظیفه رسیدگی به درخواست‌های قانونی را دارند، از کاربران سلب می‌کنند. یعنی به عبارتی سرویس‌دهنده را از پاس‌گویی خارج می‌کنند.

جدول (۵): جزئیات مجموعه داده

تعداد داده آزمون	تعداد داده آموزش	کلاس <i>NSL-KDD</i>
۹۷۱۱	۶۷۳۴۳	نرمال
۷۴۵۸	۴۵۹۲۷	<i>DoS</i>
۲۴۲۱	۱۱۶۵۶	<i>PRB</i>
۲۷۵۴	۹۹۵	<i>R2L</i>
۲۰۰	۵۲	<i>U2R</i>

**حملات کاربر به ریشه<sup>۲</sup>:** در این حملات مهاجم به حساب کاربری بر روی سیستم دسترسی پیدا می‌کند و به سیستم آسیب می‌رساند. در این حمله مهاجم با استفاده از روش‌هایی مانند مهندسی اجتماعی به یک حساب کاربری عادی دسترسی پیدا می‌کند و سپس با استفاده از آسیب‌پذیری‌های موجود، امتیاز یک کاربر ارشد را به دست می‌آورد.

**حملات حمله راه دور به نزدیک<sup>۳</sup>:** در این حملات مهاجم با نفوذ غیرمجاز از راه دور به ماشین قربانی شروع به سوءاستفاده از حساب قانونی کاربر کرده و اقدام به ارسال بسته بر روی شبکه می‌کند. مهاجم با استفاده از روش آزمون و خطا و توسط اسکریپت‌های خودکار یا روش‌های دیگر اقدام به حدس‌زدن کلمه عبور قربانی می‌کند.

**حملات حملات پویشی<sup>۴</sup>:** در این حملات شبکه و یا میزبان برای جمع‌آوری اطلاعات و یافتن آسیب‌پذیری‌های شناخته شده پویش می‌شود. یک حمله کاوش به عنوان نخستین گام یک

$$\begin{aligned} & \text{Tr}[(\beta^T \bar{H}^T - F^T)(\bar{H}\beta - F) + \lambda_1 \beta^T B \beta \\ & + \lambda_2 \beta^T \bar{H}^T L \bar{H} \beta] \\ & = \text{Tr}[\beta^T \bar{H}^T \bar{H} \beta - \beta^T \bar{H}^T F \\ & - F^T \bar{H} \beta + F^T F + \lambda_1 \beta^T B \beta \\ & + \lambda_2 \beta^T \bar{H}^T L \bar{H} \beta] \\ & = \text{Tr}[\beta^T (\bar{H}^T \bar{H} + \lambda_1 B \\ & + \lambda_2 \bar{H}^T L \bar{H}) \beta - \beta^T \bar{H}^T F \\ & - F^T \bar{H} \beta + F^T F] \quad (\gamma) \end{aligned}$$

با جایگزینی رابطه (۶) و  $Q = \bar{H}^T \bar{H} + \lambda_1 B + \lambda_2 \bar{H}^T L \bar{H}$  در رابطه (۷):

$$\begin{aligned} & \text{Tr}[F^T \bar{H} Q^{-1} (\bar{H}^T \bar{H} + \lambda_1 B \\ & + \lambda_2 \bar{H}^T L \bar{H}) Q^{-1} \bar{H}^T F \\ & - 2F^T \bar{H} Q^{-1} \bar{H}^T F + F^T F] \\ & = \text{Tr}[F^T (\bar{H} Q^{-1} Q Q^{-1} \bar{H}^T \\ & - 2\bar{H} Q^{-1} \bar{H}^T + I_c) F] \\ & = \text{Tr}[F^T (\bar{H} Q^{-1} \bar{H}^T - 2\bar{H} Q^{-1} \bar{H}^T \\ & + I_c) F] \\ & = \text{Tr}[F^T (I_c \\ & - \bar{H} Q^{-1} \bar{H}^T) F] \end{aligned} \quad (۸)$$

بنابراین، مسئله بهینه‌سازی با توجه به  $F$  تبدیل می‌شود:

$$\begin{aligned} & \min_F \text{Tr}[F^T (I_c - \bar{H} Q^{-1} \bar{H}^T) F] \\ & s. t \quad F \in [0, 1]^{n \times c} \end{aligned} \quad (۹)$$

که می‌توان با تجزیه ویژه ماتریس  $I_c - \bar{H} Q^{-1} \bar{H}^T$  را حل کرد. بردارهای ویژه  $C$  مربوط به کوچکترین مقادیر ویژه  $C$  ستون‌های  $F$  هستند، جایی که  $C$  تعداد خوشه‌هاست.

$$(I_c - \bar{H} Q^{-1} \bar{H}^T) v = \mu v \quad (۱۰)$$

فرض کنید  $v_1, v_2, \dots, v_c$  بردارهای ویژه نرمال شده مربوط به کوچکترین مقادیر ویژه  $C$  از رابطه (۱۰) باشد. راه‌حل رابطه (۹) بصورت (۱۱) خواهد بود:

$$F = [v_1^T, v_2^T, \dots, v_c^T]^T \quad (۱۱)$$

برای برآورده کردن محدودیت  $F \in [0, 1]^{n \times c}$  - winner-take-all برای هر ردیف از  $F$  اعمال می‌شود. به طور خاص، تمام عناصر  $F$  روی صفر تنظیم می‌شوند به جز حداکثر عنصر در هر ردیف که یا مقدار یک تنظیم شده است.

#### ۴- محاسبه معیار ارزیابی

معیارهای ارزیابی مورد استفاده در این پژوهش معیار صحت، نرخ صحیح مثبت است.

#### ۴-۱- مجموعه داده

مجموعه داده مورد استفاده در این پژوهش مجموعه داده *NSL-KDD* است که جزئیات آن به شرح زیر است:

<sup>۱</sup> DOS

<sup>۲</sup> U2R

<sup>۳</sup> R2L



<sup>۴</sup> Probing

## جدول (۶): مقایسه صحت نتایج روش پیشنهادی و الگوریتم

بهینه‌سازی گرگ خاکستری

مجموعه داده	معیار ارزیابی	الگوریتم گرگ خاکستری	روش پیشنهادی
NSL-KDD	Accuracy	۹۳/۷۴	۹۸/۳۸
	Sensitivity	۰/۸۴۷۵	۰/۸۶۵۹

نمودار ستونی مقایسه صحت، نرخ صحیح مثبت و نرخ صحیح منفی روش پیشنهادی با الگوریتم گرگ خاکستری بر روی مجموعه داده NSL-KDD در شکل (۳) نشان داده شده است.



شکل (۳): نمودار مقایسه صحت و نرخ صحیح مثبت روش پیشنهادی با الگوریتم گرگ خاکستری

حمله واقعی به شبکه یا میزبان در نظر گرفته می‌شود. هر چند به وسیله این حملات هیچ آسیب مستقیمی به سیستم وارد نمی‌شود، اما این حملات باید جدی گرفته شود زیرا ممکن است مهاجم به وسیله این حملات پویشی اطلاعات مهمی برای انجام حملات بسیار خطرناک در سیستم به دست آورد.

## ۴-۲- معیار ارزیابی

به منظور ارزیابی روش پیشنهادی و مقایسه با سایر روش‌ها از دو معیار متداول استفاده شد که هر کدام به شرح زیر است:

**معیار اول:** صحت<sup>۱</sup>، عبارت از میزان نزدیکی مقدار اندازه‌گیری شده به مقدار صحیح است؛ به عبارت دیگر از همخوانی یک مقدار آزمایشی یا میانگین چند سنجش با یک مقدار نظری (حقیقی) یک کمیت، صحت به دست می‌آید. دو مقدار  $TP$  و  $TN$  مهم‌ترین مقادیری هستند که در یک مسئله دو دسته‌ای باید بیشینه شوند:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (12)$$

**معیار دوم:** معیار حساسیت<sup>۲</sup> به عنوان (نرخ صحیح مثبت) در نظر گرفته می‌شود. معیار حساسیت ارزیابی می‌کند که چقدر مدل توانایی شناسایی سوابق غیرطبیعی را دارا می‌باشد. حساسیت بالاتر یک دسته‌بندی بهتر را نشان می‌دهد. این عبارت معمولاً از نسبت نمونه‌های صحیح دسته‌بندی شده به کل نمونه‌ها حاصل می‌شود. میزان صحیح مثبت بیشتر یعنی میزان حساسیت بیشتر که منجر به دقت بیشتر هم خواهد شد. معادله حساسیت به شرح (۱۳) خواهد بود:

$$Sensitivity = \frac{TP}{TP + FN} \quad (13)$$

## ۴-۳- محیط شبیه‌سازی

روش پیشنهادی و الگوریتم گرگ خاکستری در نرم‌افزار متلب ۲۰۱۴ در سیستم عامل ویندوز ۱۱ - ۶۴ بیت با پردازنده Intel® Core™ i7 2.8 GHz با رم ۱۶ GB پیاده‌سازی و اجرا گردیده است.

## ۴-۴- ارزیابی نتایج

در این بخش به ارزیابی روش پیشنهادی به منظور بدست‌آوردن بیشتر میزان صحت، بر روی دادگان مورد نظر، پرداخته می‌شود. نتایج بدست‌آمده از روش‌های پیشنهادی و الگوریتم بهینه‌سازی گرگ خاکستری توسط معیار ارزیابی در جدول (۶) نمایش داده شده است.

<sup>1</sup> Accuracy

<sup>2</sup> Sensitivity

استحکام بهتر می‌باشد. به عنوان کارهای آتی پیشنهاد می‌گردد در صورت زیاد بودن تعداد ویژگی‌ها و ناهمگن بودن داده‌ها و لزوم شناسایی برخط، از روش‌های طبقه‌بندی ترکیبی به همراه الگوریتم‌های بهینه‌سازی پارامترهای اولیه استفاده کرد و همچنین شبکه عصبی ماشین یادگیری مفرط بدون نظارت به دلیل تعیین تصادفی پارامترهای گره‌های لایه پنهان و وزن لایه ورودی ممکن است بعضی از پارامترهای غیر بهینه تولید کند که در عملکرد و ثبات شبکه تاثیرگذار است. بدین منظور استفاده از رویکردهایی نظیر آشوب و کوانتوم جهت مقداردهی اولیه این پارامترها می‌تواند یکی از راه‌های مقابله با این مشکل باشد. در نهایت، اعمال روش پیشنهادی بر روی مسائل علمی-مهندسی و واقعی برای بررسی هر چه بیشتر روش ارائه شده و همچنین بررسی تعمیم‌پذیری هر چه بیشتر روش ارائه شده در حل سایر مسائل می‌تواند چالش‌های پیش رو را نمایان و برطرف سازد.

## ۵- مراجع

- [1] T. Saranya, S. Sridevi, C. Deisy, Tran Duc Chung, and MKA Ahamed Khan, "Performance analysis of machine learning algorithms in intrusion detection system: A review," *Procedia Computer Science*, vol. 171, pp. 1251-1260, 2020. DOI:10.1016/j.procs.2020.04.133.
- [2] Lansky, Jan, Saqib Ali, Mokhtar Mohammadi, Mohammed Kamal Majeed, Sarkhel H. Taher Karim, Shima Rashidi, Mehdi Hosseinzadeh, and Amir Masoud Rahmani. "Deep learning-based intrusion detection systems: a systematic review." *IEEE Access* 9 (2021): 101574-101599. doi.org/10.1109/ACCESS.2021.3097247.
- [3] Al-Daweri, Muataz Salam, Khairul Akram Zainol Ariffin, Salwani Abdullah, and Mohamad Firham Efendy Md. Senan. "An analysis of the KDD99 and UNSW-NB15 datasets for the intrusion detection system." *Symmetry* 12, no. 10 (2020): 1666. doi.org/10.3390/sym12101666.
- [4] Al-Tashi, Qasem, Helmi Md Rais, Said Jadid Abdulkadir, Seyedali Mirjalili, and Hitham Alhussian. "A review of grey wolf optimizer-based feature selection methods for classification." *Evolutionary Machine Learning Techniques: Algorithms and Applications* (2020): 273-286. DOI:10.1007/978-981-32-9990-0\_13.
- [5] Mirjalili, Seyedali, Ibrahim Aljarah, Majdi Mafarja, Ali Asghar Heidari, and Hossam Faris. "Grey wolf optimizer: theory, literature review, and application in computational fluid dynamics problems." *Nature-inspired optimizers: Theories, literature reviews and applications* (2020): 87-105. https://doi.org/10.1007/978-3-030-12127-3\_6.
- [6] Hancer, Emrah, Bing Xue, and Mengjie Zhang. "A survey on feature selection approaches for clustering." *Artificial Intelligence Review* 53 (2020): 4519-4545. https://doi.org/10.1007/s10462-019-09800-w.
- [7] Gawlikowski, Jakob, Cedrique Rovile Njietcheu Tassi, Mohsin Ali, Jongseok Lee, Matthias Humt, Jianxiang Feng, Anna Kruspe et al. "A survey of uncertainty in deep neural networks." *arXiv preprint arXiv:2107.03342* (2021). https://doi.org/10.48550/arXiv.2107.03342.
- [8] Ding, Shifei, Xinzheng Xu, and Ru Nie. "Extreme learning machine and its applications." *Neural Computing and Applications* 25 (2014): 549-556. DOI:10.1007/s00521-013-1522-8.
- [9] Huang, Guang-Bin, Qin-Yu Zhu, and Chee-Kheong Siew. "Extreme learning machine: theory and applications." *Neurocomputing* 70, no. 1-3 (2006): 489-501. https://doi.org/10.1016/j.neucom.2005.12.126
- [10] Huang, Gao, Guang-Bin Huang, Shiji Song, and Keyou You. "Trends in extreme learning machines: A review." *Neural Networks* 61, pp. 32-48, 2015.

عملکرد روش پیشنهادی با الگوریتم بهینه‌سازی گرگ خاکستری برای مسئله انتخاب ویژگی و دسته‌بندی بر روی مجموعه‌داده *NSL-KDD* مورد بررسی و مقایسه قرار گرفت. نتایج آزمایش‌ها در جدول (۶) نشان‌دهنده صحت ۹۸/۳۸ و نرخ صحیح مثبت ۰/۸۶۵۹ روش پیشنهادی در مقایسه با صحت ۹۳/۷۴ و نرخ صحیح مثبت ۰/۸۴۷۵ الگوریتم بهینه‌سازی گرگ خاکستری است. دلیل این برتری استفاده از ماشین یادگیری مفرط بدون نظارت و ساختار تعمیم‌پذیر این شبکه عصبی بدون نظارت است. در خصوص مقادیر بدست آمده از معیارهای ارزیابی می‌توان اثبات نمود که پدیده بیش‌برازش رخ نداده است؛ علت این امر را می‌توان اینگونه توجیه کرد ابتدا اینکه بیش‌برازش به پدیده نامطلوبی در آمار گفته می‌شود که در آن درجه آزادی مدل بسیار بیشتر از درجه آزادی واقعی انتخاب شده و در نتیجه اگرچه مدل روی داده استفاده شده برای یادگیری بسیار خوب نتیجه می‌دهد، اما بر روی داده جدید دارای خطای زیاد است و اینکه از جمله دلایل اصلی ایجاد بیش‌برازش می‌توان به پیچیدگی بیش از حد مدل، بیش از حد بودن تعداد ویژگی‌های مجموعه‌داده و برابر بودن ویژگی‌ها با نمونه‌ها، حجم بسیار کم مجموعه‌داده و وجود نویز اشاره کرد. رویکرد ارائه شده از پیچیدگی کمتری برخوردار بوده و به دلیل استفاده از ضریب تنظیم مشکل بیش‌برازش حل شده و با توجه شرح جزئیات مجموعه‌داده می‌توان دریافت که مجموعه‌داده از حجم کم و تعداد ویژگی برابر با نمونه‌های مجموعه‌داده برخوردار نبوده و از طرفی چون رویکرد انتخاب ویژگی استفاده شده است وجود نویز در دادگان هم بطور قطع رد می‌شود. دلیل این امر این است که روش پیشنهادی می‌تواند تعمیم‌پذیری بهتری برای مسئله انتخاب ویژگی، دسته‌بندی و تشخیص نفوذ تولید نماید و این مسئله سبب شده است تا در مسئله دسته‌بندی مکانیسم استفاده از الگوریتم ماشین یادگیری مفرط بدون نظارت برای انتخاب ویژگی و آموزش شبکه و روش رتبه‌بندی عملکرد بهتر و استحکام بیشتر نتایج روش پیشنهادی را نشان می‌دهد.

## ۴-۵- جمع‌بندی و کارهای آتی

نتایج آزمایش‌ها نشان‌دهنده صحت ۹۸/۳۸ و نرخ صحیح مثبت ۰/۸۶۵۹ و نرخ صحیح منفی ۰/۷۰۷۹ روش پیشنهادی در مقایسه با صحت ۹۳/۷۴ و نرخ صحیح مثبت ۰/۸۴۷۵ و نرخ صحیح منفی ۰/۶۲۶۷ الگوریتم بهینه‌سازی گرگ خاکستری است. دلیل این برتری استفاده از UELM در مسئله دسته‌بندی و تشخیص نفوذ و ساختار مستحکم و تعمیم‌پذیر این شبکه عصبی بدون نظارت است. در ارزیابی با مجموعه‌داده *NSL-KDD* برای دسته‌بندی، روش پیشنهادی عملکرد تعمیم‌پذیری بهتری در مقایسه با روش الگوریتم بهینه‌سازی گرگ خاکستری داشته و همچنین از نظر

- [23] Halim, Zahid, Muhammad Nadeem Yousof, Muhammad Waqas, Muhammad Sulaiman, Ghulam Abbas, Masroor Hussain, Iftekhar Ahmad, and Muhammad Hanif. "An effective genetic algorithm-based feature selection method for intrusion detection systems." *Computers & Security* 110 (2021): 102448 , <https://doi.org/10.1016/j.cose.2021.102448>.
- [24] Pradeep Mohan Kumar, K., M. Saravanan, M. Thenmozhi, and K. Vijayakumar. "Intrusion detection system based on GA-fuzzy classifier for detecting malicious attacks." *Concurrency and Computation: Practice and Experience* 33, no. 3 (2021): e5242 , <https://doi.org/10.1002/cpe.5242>.
- [25] Ghosh, Partha, Dipankar Sarkar, Joy Sharma, and Santanu Phadikar. "An intrusion detection system using modified-firefly algorithm in cloud environment." *International Journal of Digital Crime and Forensics (IJDCF)* 13, no. 2 (2021): 77-93 , DOI:10.4018/IJDCF.2021030105.
- [26] Alkahtani, Hasan, and Theyazn HH Aldhyani. "Intrusion detection system to advance internet of things infrastructure-based deep learning algorithms." *Complexity* 2021 (2021) , DOI:10.1155/2021/5579851.
- [27] Chen, Jichao, Yijie Zeng, Yue Li, and Guang-Bin Huang. "Unsupervised feature selection based extreme learning machine for clustering." *Neurocomputing* 386 (2020): 198-207 , [doi.org/10.1016/j.neucom.2019.12.065](https://doi.org/10.1016/j.neucom.2019.12.065).
- [28] Elsaid, Shaimaa Ahmed, and Nouf Saleh Albatati. "An optimized collaborative intrusion detection system for wireless sensor networks." *Soft Computing* 24, no. 16 (2020): 12553-12567 , <https://doi.org/10.1007/s00500-020-04695-0>.
- [29] همایون، حامد، دهقانی، مهدی، اکبری، حمید، مروری تحلیل ترافیک شبکه گمنام‌ساز پارس با استفاده از یادگیری ماشین. *پدافند غیرعامل*، صص ۱۷-۱۰، شماره ۱۳ (۲)، ۱۴۰۰.
- [30] H. M. Saleh, H. Marouane, and A. Fakhfakh, "Stochastic Gradient Descent Intrusions Detection for Wireless Sensor Network Attack Detection System Using Machine Learning," *IEEE Access*, vol. 12, no. December 2023, pp. 3825–3836, 2024, doi: 10.1109/ACCESS.2023.3349248.
- [31] S. Subramani and M. Selvi, "Intrusion detection system using RBPSO and fuzzy neuro-genetic classification algorithms in wireless sensor networks," *Int. J. Inf. Comput. Secur.*, vol. 20, no. 3–4, pp. 439–461, 2023, doi: 10.1504/IJICS.2023.128857.
- [32] S. Subramani and M. Selvi, "Multi-objective PSO based feature selection for intrusion detection in IoT based wireless sensor networks," *Optik (Stuttg.)*, vol. 273, no. December 2022, p. 170419, 2023, doi: 10.1016/j.jpleo.2022.170419.
- [33] F. Al-Quayed, Z. Ahmad, and M. Humayun, "A Situation Based Predictive Approach for Cybersecurity Intrusion Detection and Prevention Using Machine Learning and Deep Learning Algorithms in Wireless Sensor Networks of Industry 4.0," *IEEE Access*, vol. 12, no. February, pp. 34800–34819, 2024, doi: 10.1109/ACCESS.2024.3372187.
- [34] M. Aljebreen et al., "Binary Chimp Optimization Algorithm with ML Based Intrusion Detection for Secure IoT-Assisted Wireless Sensor Networks," *Sensors*, vol. 23, no. 8, 2023, doi: 10.3390/s23084073.
- [35] M. H. Behiry and M. Aly, "Cyberattack detection in wireless sensor networks using a hybrid feature reduction technique with AI and machine learning methods," *J. Big Data*, vol. 11, no. 1, 2024, doi: 10.1186/s40537-023-00870-w.
- [36] L. Dhanabal and S. P. Shantharajah, "A Study on NSL-KDD Dataset for Intrusion Detection System Based on Classification Algorithms," *Int. J. Adv. Res. Comput. Commun. Eng.*, vol. 4, no. 6, pp. 446–452, 2015, doi: 10.17148/IJARCC.2015.4696.
- <https://doi.org/10.1016/j.neunet.2014.10.001>
- [11] Wang, Jian, Siyuan Lu, Shui-Hua Wang, and Yu-Dong Zhang. "A review on extreme learning machine." *Multimedia Tools and Applications* 81, no. 29 (2022): 41611-41660 , <https://doi.org/10.1007/s11042-021-11007-7>
- [12] Schilling, M., Paskarbit, J., Hoinville, T., Hüffmeier, A., Schneider, A., Schmitz, J., Cruse, H. (Sept. 17 2013). A hexapod walker using a heterarchical structure for action selection. *Frontiers in Computational Neuroscience*, 7. doi:10.3389/fncom.2013.00126
- [13] Maldonado, Javier, María Cristina Riff, and Bertrand Neveu. "A review of recent approaches on wrapper feature selection for intrusion detection." *Expert Systems with Applications* (2022): 116822 , <https://doi.org/10.1016/j.eswa.2022.116822>.
- [14] Mhawi, Doaa N., Ammar Aldallal, and Soukeana Hassan. "Advanced feature-selection-based hybrid ensemble learning algorithms for network intrusion detection systems." *Symmetry* 14, no. 7 (2022): 1461 , <https://doi.org/10.3390/sym14071461>.
- [15] Kareem, Saif S., Reham R. Mostafa, Fatma A. Hashim, and Hazem M. El-Bakry. "An effective feature selection model using hybrid metaheuristic algorithms for iot intrusion detection." *Sensors* 22, no. 4 (2022): 1396 , <https://doi.org/10.3390/s22041396>.
- [16] Naseri, Touraj Sattari, and Farhad Soleimanian Gharehchopogh. "A Feature Selection Based on the Farmland Fertility Algorithm for Improved Intrusion Detection Systems." *Journal of Network and Systems Management* 30, no. 3 (2022): 1-27 , DOI:10.3390/math10152675
- [17] Mojtahedi, Amir, Farid Sorouri, Alireza Najafi Souha, Aidin Molazadeh, and Saeedeh Shafaei Mehr. "Feature Selection-based Intrusion Detection System Using Genetic Whale Optimization Algorithm and Sample-based Classification." *arXiv preprint arXiv:2201.00584* (2022).
- [18] Otair, Mohammed, Osama Talab Ibrahim, Laith Abualigah, Maryam Altalhi, and Putra Sumari. "An enhanced grey wolf optimizer based particle swarm optimizer for intrusion detection system in wireless sensor networks." *Wireless Networks* 28, no. 2 (2022): 721-744 , DOI:10.1007/s11276-021-02866-x.
- [19] Safaldin, Mukaram, Mohammed Otair, and Laith Abualigah. "Improved binary gray wolf optimizer and SVM for intrusion detection system in wireless sensor networks." *Journal of ambient intelligence and humanized computing* 12, no. 2 (2021): 1559-1576 , DOI:10.1007/s12652-020-02228-z.
- [20] Khanna, Ashish, Poonam Rani, Puneet Garg, Prakash Kumar Singh, and Aditya Khamparia. "An Enhanced Crow Search Inspired Feature Selection Technique for Intrusion Detection Based Wireless Network System." *Wireless Personal Communications* (2021): 1-18 , DOI:10.1007/s11277-021-08766-9.
- [21] Keserwani, Pankaj Kumar, Mahesh Chandra Govil, Emmanuel S. Pilli, and Prajval Govil. "A smart anomaly-based intrusion detection system for the Internet of Things (IoT) network using GWO-PSO-RF model." *Journal of Reliable Intelligent Environments* 7, no. 1 (2021): 3-21 , DOI: <https://doi.org/10.58325/ijiset.003.01.0073>.
- [22] Kan, Xiu, Yixuan Fan, Zhijun Fang, Le Cao, Neal N. Xiong, Dan Yang, and Xuan Li. "A novel IoT network intrusion detection approach based on adaptive particle swarm optimization convolutional neural network." *Information Sciences* 568 (2021): 147-162 , <https://doi.org/10.1016/j.ins.2021.03.060>.

کدهای شبیه سازی	کدهای شبیه سازی (ادامه)
<pre> clc clear close all  [data, lbl] = PrepareData('KDDData.txt'); rmv_id = []; for i = 1:size(data,2)     if numel(unique(data(:,i)))==1         rmv_id = [rmv_id i];     end end data(:,rmv_id) = [];  data = mapminmax(data',0,1)';  [nD,nFea] = size(data);  % initialize parameters nPop = 20; lb = 0; ub = 1; Max_iter = 10;  %Create data test and train cv = cvpartition(lbl,'holdout',0.2);  dataTrain = data(cv.training,:); lblTrain = lbl(cv.training);  dataTest = data(cv.test,:); <b>CODE-PAPER</b> lblTest = lbl(cv.test);  % initialize alpha, beta, delta, gama, teta Alpha.pos = zeros(1,nFea); Alpha.score = -inf;  Beta.pos = zeros(1,nFea); Beta.score = -inf;  Delta.pos = zeros(1,nFea); Delta.score = -inf;  Gamma.pos = zeros(1,nFea); Gamma.score = -inf;  Teta.pos = zeros(1,nFea); Teta.score = -inf;  %Initialize the positions of search agents indiv.pos = []; indiv.score = []; Pop = repmat(indiv,1,nPop); for i=1:nPop     while(1)         sol = round(lb+(ub-lb)*rand(1,nFea));         if sum(sol)&gt;0             break         end     end     Pop(i).pos = sol; end </pre>	<pre> rnd = rand; if rnd&lt;(1/5)     Pop(i).pos(j) = X1(j); elseif rnd&gt;=(1/5) &amp;&amp; rnd&lt;(2/5)     Pop(i).pos(j) = X2(j); elseif rnd&gt;=(2/5) &amp;&amp; rnd&lt;(3/5)     Pop(i).pos(j) = X3(j); elseif rnd&gt;=(3/5) &amp;&amp; rnd&lt;(4/5)     Pop(i).pos(j) = X4(j); else     Pop(i).pos(j) = X5(j); end  end  while(sum(Pop(i).pos)==0)     sol = round(lb+(ub-lb)*rand(1,nFea));     Pop(i).pos = sol;     if sum(sol)&gt;0         break     end end iter = iter+1; end  sol = Alpha.pos; nf_sel = sum(sol==1);  dataTrain = dataTrain(:, sol==1); dataTest = dataTest(:, sol==1);  SVMModel = fitsvm(dataTrain,lblTrain);  prlbl_Tr = predict(SVMModel,dataTrain); Cmat_train = confusionmat(lblTrain,prlbl_Tr); TP = Cmat_train(1,1); TN = Cmat_train(2,2); FP = Cmat_train(2,1); FN = Cmat_train(1,2); Accuracy_train = (TP+TN)/(FP+FN+TP+TN); DetectionRate_train = TP/(TP+FN); FalseAlarm_train = FP/(TN+FP);  prlbl_te = predict(SVMModel,dataTest); Cmat_test = confusionmat(lblTest,prlbl_te); TP = Cmat_test(1,1); TN = Cmat_test(2,2); FP = Cmat_test(2,1); FN = Cmat_test(1,2); Accuracy_test = (TP+TN)/(FP+FN+TP+TN); DetectionRate_test = TP/(TP+FN); FalseAlarm_test = FP/(TN+FP);  clc disp('Result of KDDData') disp('=====') =====)  Acc = mean(Accuracy_test)*100; fprintf('Accuracy = %2.4f \n', Acc) </pre>

کدهای شبیه سازی	کدهای شبیه سازی (ادامه)
<pre> iter = 0; % Loop counter % Main loop while iter&lt;Max_iter     for i = 1:nPop         % Calculate objective function for each search agent         Pop(i).score =         CalFitness(Pop(i).pos,dataTrain,lblTrain);          % Update Alpha, Beta, Delta, Gamma and Teta         if Pop(i).score&gt;Alpha.score             Alpha = Pop(i); % Update alpha         end          if Pop(i).score&lt;Alpha.score &amp;&amp;         Pop(i).score&gt;Beta.score             Beta = Pop(i); % Update beta         end          if Pop(i).score&lt;Alpha.score &amp;&amp;         Pop(i).score&lt;Beta.score &amp;&amp; Pop(i).score&gt;Delta.score             Delta = Pop(i); % Update delta         end          if Pop(i).score&lt;Alpha.score &amp;&amp;         Pop(i).score&lt;Beta.score &amp;&amp; Pop(i).score&lt;Delta.score         &amp;&amp; Pop(i).score&gt;Gamma.score             Gamma = Pop(i); % Update gamma         end          if Pop(i).score&lt;Alpha.score &amp;&amp;         Pop(i).score&lt;Beta.score &amp;&amp; Pop(i).score&lt;Delta.score         &amp;&amp; Pop(i).score&gt;Gamma.score &amp;&amp;         Pop(i).score&gt;Teta.score             Teta = Pop(i); % Update teta         end     end      a = 2-iter*((2)/Max_iter); % a decreases linearly from     2 to 0      % Update the Position of search agents including     omegas     for i=1:nPop         X1 = zeros(1,nFea);         X2 = zeros(1,nFea);         X3 = zeros(1,nFea);         X4 = zeros(1,nFea);         X5 = zeros(1,nFea);         for j=1:nFea              r1 = rand(); % r1 is a random number in [0,1]             r2 = rand(); % r2 is a random number in [0,1]             A1 = 2*a*r1-a; %eq3             C1 = 2*r2; %eq4             D_alpha = abs(C1*Alpha.pos(j)-Pop(i).pos(j));             %eq9             cstep_alpha = 1/(1+exp(-10*(A1*D_alpha)));             bstep_alpha = 0;             if cstep_alpha&gt;=rand                 bstep_alpha = 1;             end             if (Alpha.pos(j)+bstep_alpha)&gt;=1                 X1(j) = 1;             end         end     end </pre>	<pre> Sensitivity = mean(DetectionRate_test); fprintf('Sensitivity = %2.4f \n', Sensitivity)  Specificity = mean(FalseAlarm_test); fprintf('Specificity = %2.4f \n', Specificity)  <b>CODE-PROPOSED</b> clc clear close all  load('KDDData.mat')  lambda1 = 0.01; % trade-off parameter lambda2 = 0.001; % trade-off parameter m = 30; % number of neurons E = 0.001; tmax = 10; % number of iterations  nC = numel(unique(lbl)); % number of clusters ub = 1; lb = -ub;  grp = unique(lbl); data = mapminmax(data', -1, 1)'; %Normalized data [n, d] = size(data);  Q = 10^-2; % param of the pair-wise similarity: W  dis = pdist2(data, data); W = exp(-dis.^2./(2*Q^2)); W = W-diag(diag(W)); D = diag(sum(W)); L = D-W;  for nEpoch = 1:2      % Initialize the cluster indicator matrix F by K-means     clustering on X     predLbl = kmeans(data, nC);     F = zeros(n, nC);     for i = 1:nC         F(predLbl==i, i) = 1;     end      % Generate input weights and biases of hidden neurons     randomly     W = lb+(ub-lb)*rand(m,d);     B = lb+(ub-lb)*rand(m,1);      % Calculate the centered hidden layer output matrix H'     H = calculate_H(B, W, data, n);     Ht = (eye(n)-1/n*ones(n)*ones(n))*H;      % Initialize B as an identity matrix.     B = eye(m);      % Compute Q     Q = Ht'*Ht+lambda1*B+lambda2*Ht'*L*Ht;      for t = 1:tmax          % Update beta         beta = Q^-1*Ht'*F;     end </pre>



کدهای شبیه سازی	کدهای شبیه سازی (ادامه)
<pre> r1 = rand(); r2 = rand(); A2 = 2*a*r1-a; %eq3 C2 = 2*r2; %eq4 D_beta = abs(C2*Beta.pos(j)-Pop(i).pos(j)); %eq10 cstep_beta = 1/(1+exp(-10*(A2*D_beta))); bstep_beta = 0; if cstep_beta&gt;=rand     bstep_beta = 1; end if (Beta.pos(j)+bstep_beta)&gt;=1     X2(j) = 1; end  r1 = rand(); r2 = rand(); A3 = 2*a*r1-a; %eq3 C3 = 2*r2; %eq4 D_delta = abs(C3*Delta.pos(j)-Pop(i).pos(j)); %eq11 cstep_delta = 1/(1+exp(-10*(A3*D_delta))); bstep_delta = 0; if cstep_delta&gt;=rand     bstep_delta = 1; end if (Delta.pos(j)+bstep_delta)&gt;=1     X3(j) = 1; end  r1 = rand(); % r1 is a random number in [0,1] r2 = rand(); % r2 is a random number in [0,1] A4 = 2*a*r1-a; %eq3 C4 = 2*r2; %eq4 D_gamma = abs(C4*Gamma.pos(j)- Pop(i).pos(j)); %eq9 cstep_gamma = 1/(1+exp(- 10*(A4*D_gamma))); bstep_gamma = 0; if cstep_gamma&gt;=rand     bstep_gamma = 1; end if (Gamma.pos(j)+bstep_gamma)&gt;=1     X4(j) = 1; end  r1 = rand(); % r1 is a random number in [0,1] r2 = rand(); % r2 is a random number in [0,1] A5 = 2*a*r1-a; %eq3 C5 = 2*r2; %eq4 D_teta = abs(C5*Gamma.pos(j)-Pop(i).pos(j)); %eq9 cstep_teta = 1/(1+exp(-10*(A5*D_teta))); bstep_teta = 0; if cstep_teta&gt;=rand     bstep_teta = 1; end if (Teta.pos(j)+bstep_teta)&gt;=1     X5(j) = 1; end </pre>	<pre> % foreach diagonal element of B do for i = 1: m     B(i, i) = 1/sqrt(beta(i,:)*beta(i,:)'+E); end  % Compute Q Q = Ht'*Ht+lambda1*B+lambda2*Ht'*L*Ht;  % Update F by solving problem (14) tmp = eye(n)-Ht*Q^-1*Ht'; [eigVec, eigVal]= eig(tmp); eigVal = real(eigVal); eigVec = real(eigVec);  [eigVal_sor, idSort] = sort(diag(eigVal)); V = eigVec(:, idSort(1:nC)); [~, predLbl] = max(V, [], 2); F = zeros(n, nC); for i = 1:nC     F(predLbl==i, i) = 1; end end  Cmat = confusionmat(lbl,predLbl); TP = Cmat(1,1); TN = Cmat(2,2); FP = Cmat(2,1); FN = Cmat(1,2);  Sensitivity(nEpoch) = TP/(TP+FN); Specificity(nEpoch) = FP/(TN+FP); Acc(nEpoch) = cluster_acc(lbl,predLbl); end  clc disp('Result of KDDData') disp('=====')  Acc = mean(Acc); fprintf('Accuracy = %2.4f \n', Acc)  Sensitivity = mean(Sensitivity); fprintf('Sensitivity = %2.4f \n', Sensitivity)  Specificity = mean(Specificity); fprintf('Specificity = %2.4f \n', Specificity) </pre>