

Fall 2024, 5 (3), 69-86
DOR:

Received: 9 July 2024
Accepted: 20 Aug 2024

The Integrated Three-dimensional Deep Learning Approach for an Efficient Intrusion Detection System Using Spatiol-Temporal Features

Roya Zareh Farkhady¹, Kambiz Majidzadeh^{2*}, Mohammad Masdari³, Ali Ghaffari⁴

1. Ph.D. Student, Department of Computer Engineering, Urmia Branch, Islamic Azad University, Urmia, Iran.
2. Assistant Professor, Department of Computer Engineering, Urmia Branch, Islamic Azad University, Urmia, Iran:
*Corresponding Author, kambiz.majidzadeh@iau.ac.ir
3. Assistant Professor, Department of Computer Engineering, Urmia Branch, Islamic Azad University, Urmia, Iran
4. Associate Professor, Department of Computer Engineering, Tabriz Branch, Islamic Azad University, Tabriz, Iran

Abstract

Introduction: Intrusion detection systems in network traffic increase network security by detecting abnormal inputs and attacks. Deep learning algorithms are used to learn features in network security for large-scale data. On the other hand, if the input data for a model has high dimensions, there will be more neighbors for each data, which leads to higher accuracy in the model. Simultaneously learning spatial and temporal features for each model is challenging too.

Method: This study presents a method for converting input data into three-dimensional. In the proposed model, Convolution with Short-term Long-term Memory Branches (CLBS3) is used to improve features' spatial learning with three-dimensional input data. In parallel, Short-term Long-term Memory learns hierarchical relationships between different features and extracts temporal features. Finally, the integrated approach of the CLBS3 model uses extracted spatial-temporal features for network data classification

Results: Tests were conducted on the UNSW-NB15 dataset, and performance evaluation of CLBS3 shows that compared to contemporary intrusion detection methods, the proposed model with an accuracy of 98.46% with fewer errors of 1.8% in the UNSW-NB15 dataset provides better performance in intrusion detection.

Discussion: The present study aims to propose CLBS method, which detects attacks by considering the limitations of IoT resources. In order to create an efficient and accurate IDS, the combination of convolution neural networks and Short-term Long-term Memory applied in the fog to separate the attacks from normal traffic. Our proposed method was tested using the UNSW-NB15 dataset, and the results demonstrate enhanced accuracy compared to existing methods, as well as a low false positive rate.

Keywords: Deep learning, convolutional networks, three-dimensional, short-term long-term memory, spatial feature, temporal feature.

رویکرد یادگیری عمیق سه‌بعدی یکپارچه برای سیستم تشخیص نفوذ کارآمد با استفاده از ویژگی‌های فضایی-زمانی

دوره پنجم، پاییز ۱۴۰۳
شماره، صص: ۶۹-۸۶

تاریخ دریافت: ۱۴۰۳/۰۴/۲۹
تاریخ پذیرش: ۱۴۰۳/۰۵/۳۰

رویا زارع فرخادی^۱، کامبیز مجیدزاده^{۲*}، محمد مصدري^۳، علی غفاری^۴

۱- دانشجوی دکتری، گروه کامپیوتر، واحد ارومیه، دانشگاه آزاد اسلامی، ارومیه، ایران، Roya.farkhady@gmail.com

۲- استادیار، گروه کامپیوتر، واحد ارومیه، دانشگاه آزاد اسلامی، ارومیه، ایران، kambiz.majidzadeh@iau.ac.ir

۳- استادیار، گروه کامپیوتر، واحد ارومیه، دانشگاه آزاد اسلامی، ارومیه، ایران، Mo.Masdari@iau.ac.ir

۴- دانشیار، گروه کامپیوتر، واحد تبریز، دانشگاه آزاد اسلامی، تبریز، ایران، A.Ghaffari@iaut.ac.ir

چکیده: سیستم‌های تشخیص نفوذ در ترافیک شبکه با تشخیص ورودی‌های ناهنجار و حمله، امنیت شبکه‌ها را افزایش می‌دهند. الگوریتم‌های یادگیری عمیق به دلیل توانایی یادگیری ویژگی‌ها در امنیت شبکه برای داده‌های مقیاس وسیع مورد استفاده قرار می‌گیرند. از طرفی اگر داده‌های ورودی مدلی، دارای ابعاد بالا با شد به ازای هر داده، هم‌سایگان بیشتری وجود خواهند داشت که همین امر باعث دقت بیشتر در مدل می‌شود. از این رو در این مقاله روشی برای تبدیل داده‌های ورودی به سه‌بعدی ارائه شده است. شبکه‌های عصبی کانولوشن به‌طور مؤثر ویژگی‌های فضایی را به دست می‌آورند، شبکه‌های عصبی حافظه کوتاه‌مدت بلند بهتر برای ویژگی‌های زمانی عمل می‌کنند. یکپارچه‌سازی این مدل‌ها می‌تواند قابلیت بهبود سیستم تشخیص نفوذ مقیاس وسیع را داشته باشد. یادگیری هم‌زمان ویژگی‌های فضایی و زمانی اطلاعات برای هر مدل، امری چالش‌برانگیز است. در مدل پیشنهادی کانولوشن با حافظه طولانی کوتاه‌مدت دوشاخه با داده‌های سه‌بعدی (CLBS3) از یک کانولوشن بهبودیافته با ورودی سه‌بعدی برای یادگیری ویژگی‌های فضایی استفاده می‌شود. به صورت هم‌زمان و موازی، حافظه طولانی کوتاه‌مدت، روابط سلسله‌مراتبی بین ویژگی‌های مختلف را یاد می‌گیرد و ویژگی‌های زمانی را استخراج می‌کند. در نهایت، رویکرد یکپارچه مدل CLBS3 از ویژگی‌های فضایی-زمانی استخراج شده برای دسته‌بندی داده‌های شبکه استفاده می‌کند. آزمون‌ها بر روی مجموعه داده UNSWNB15 انجام شده است و ارزیابی عملکرد CLBS3 نشان می‌دهد که در مقایسه با روش‌های تشخیص نفوذ معاصر، مدل پیشنهادی با دقت ۹۸/۴۶ با تعداد کمتری اشتباهات برابر ۰/۱ در مجموعه داده UNSWNB15 و دقت ۹۸/۲۶ با تعداد کمتری اشتباهات برابر ۰/۲ در مجموعه داده TONIOT عملکرد بهتری در تشخیص نفوذ ارائه می‌دهد. در مجموعه داده UNSWNB15 مدت زمان اجرای مدل برای پردازش داده‌ها برابر با ۸/۱ ثانیه اندازه‌گیری شد. مصرف CPU در طی اجرای مدل برابر با تقریباً ۰٪ گزارش شد. این مقدار نشان می‌دهد که مدل، در شرایط فعلی اجرا، تقریباً هیچ بار پردازشی قابل توجهی بر CPU سیستم وارد نمی‌کند.

واژه‌های کلیدی: یادگیری عمیق، شبکه‌های کانولوشنی، سه‌بعدی، حافظه طولانی کوتاه‌مدت، ویژگی فضایی، ویژگی زمانی.

۱. مقدمه

اخیراً، با توجه به تحولات و پیشرفت فناوری، خدمات آنلاین به‌طور فراوان افزایش یافته‌است. انجام خدمات آنلاین به وجود فناوری‌های شبکه وابسته است. اجزای حیاتی یک شبکه ارتباطی شامل محرمانگی، یکپارچگی و در دسترس بودن هستند و هر فعالیت غیرمعمولی که حداقل یکی از این ویژگی‌ها را نقض کند، به‌عنوان یک حمله به شبکه در نظر گرفته می‌شود؛ بنابراین، برر سی امنیت شبکه امری ضروری و حیاتی است.

سیستم تشخیص نفوذ معمولاً با چارچوب امنیتی شبکه ترکیب می‌شود تا بتواند به تشخیص حملات نفوذی در شبکه کمک کند. این سیستم به‌صورت بازرس عمل می‌کند و تمام بسته‌های ترافیک شبکه را برای یافتن نشانه‌های نفوذ بررسی می‌کند. هرچقدر سیستم تشخیص نفوذ قوی‌تر باشد، می‌تواند اقدامات بیشتری را برای تشخیص نفوذ انجام دهد و پس از تشخیص، به‌صورت خودکار سرور را از وجود نفوذ در شبکه آگاه‌سازد. به‌طور کلی، یک سیستم تشخیص نفوذ از ترکیب مجموعه‌ای از سیاست‌های امنیتی، نرم‌افزار و دستگاه‌های سخت‌افزاری استفاده می‌کند تا نظارت پیشرفته‌تری را فراهم کند.

سیستم تشخیص نفوذ به دودسته کلی تشخیص مبتنی بر امضا و مبتنی بر رفتار تقسیم می‌شود. در سیستم مبتنی بر امضا، در صورتی که بسته ترافیک مشکوک به نفوذ باشد، امضای آن با پایگاه داده امضای حملات مقایسه شده و در صورت تطبیق، سیستم هشدار می‌دهد. این نوع سیستم به‌عنوان تشخیص مبتنی بر دانش نیز شناخته می‌شود، زیرا از پایگاه داده برای تشخیص استفاده می‌کند. این روش دقت بالا در تشخیص با حداقل خطای مثبت دارد ولی در تشخیص حملات جدید و نامعلوم ممکن است دچار مشکل شود. روش مبتنی بر رفتار بسته ترافیک را با الگوهای نرمال مقایسه می‌کند، اما اگر نمونه‌ای حالت نرمال را تقلید کند، قادر به تفکیک حمله وارد شده از حالت نرمال نیست. این روش در تشخیص حملات جدید از روش مبتنی بر امضا بهتر عمل می‌کند. هر یک از این رویکردها قابلیت‌ها و محدودیت‌های خود را دارند، اما ترکیب آن‌ها می‌تواند به‌دقت و کارایی بالاتر در تشخیص حملات کمک کند. مدل تشخیص نفوذ که در این مقاله پیشنهاد شده است، بر اساس ترکیب هر دو رویکرد تشخیص امضا و رفتار است.

رویکردهای سنتی مانند رمزنگاری، دیواره‌های آتش و نرم‌افزارهای مقابله با حملات، ازجمله روش‌های تشخیص حملات بودند؛ اما این روش‌ها در داده‌های با ابعاد کم عملکرد خوبی داشتند، ولی در داده‌های بزرگ‌تر و حملات مکرر مانند حملات انکار سرویس که هرکرا پشت سر هم حمله می‌کنند، قادر به مقابله با این مشکلات نیستند. بیشتر تحقیقات اخیراً از یادگیری ماشین برای تشخیص حملات استفاده کرده‌اند.

بالین‌وجود، الگوریتم‌های معمول یادگیری ماشین محدودیت‌های جدی در یادگیری ویژگی‌های یکپارچه حملات دارند [۱]. به‌علاوه، این

الگوریتم‌ها عملکرد کمتری برای داده‌های با ترافیک نویزی و ابعاد بالا ارائه می‌دهند. الگوریتم‌های یادگیری ماشین که از ترکیب چند روش یادگیری ماشین برای سیستم تشخیص نفوذ استفاده می‌کنند، همچنین با مشکل پیچیدگی بالا روبه‌رو هستند و با داده‌های ابعاد بالا نیز مشکل دارند که باعث کاهش کارایی آن‌ها می‌شود.

اخیراً الگوریتم‌های یادگیری عمیق در تشخیص نفوذ پیشرفت‌های قابل توجهی داشته‌اند. مدل‌های تشخیص نفوذ با استفاده از یادگیری عمیق که دارای ساختار غیرخطی هستند، عملکردهای یادگیری بهتری ارائه کرده و دقت تشخیص نفوذ را افزایش داده‌اند. از مدل‌های غیرخطی رایج می‌توان به شبکه‌های عصبی بازگشتی [۲]، کانولوشنی [۳]، و حافظه طولانی کوتاه‌مدت [۴] اشاره کرد.

مدل‌های مبتنی بر شبکه‌های کانولوشنی از یک معماری مشترک و بی‌تغییر جابه‌جایی بهره می‌برند تا لایه‌های پنهان و ویژگی‌های دیگر را استخراج کنند. آن‌ها از شبکه‌های چندلایه‌ای پرسپترون و شبکه‌های کاملاً متصل برای تعیین کلاس حمله استفاده می‌کنند. با این حال، برخی از این شبکه‌ها به بیش برازش منجر می‌شوند.

مدل‌های تشخیص نفوذ بر پایه شبکه‌های عصبی بازگشتی برای پردازش دنباله‌های طولانی مدت داده‌های ترافیک ورودی، از ساختار شبکه عصبی پیشر و حافظه داخلی استفاده می‌کنند. این مدل‌ها برای کنترل وضعیت عملکرد و بهبود نرخ یادگیری از حلقه‌های بازخورد استفاده می‌کنند. حافظه طولانی کوتاه‌مدت یک مدل شبکه عصبی بازگشتی است که می‌تواند برای تشخیص نفوذ در دنباله‌های داده‌های ترافیک استفاده شود. این مدل شامل اتصالات بازخوردی است که برای شناسایی نفوذ با ویژگی‌های زمانی مناسب هستند. ساختار عمیق غیرخطی شبکه‌های عصبی کانولوشنی و حافظه طولانی کوتاه‌مدت به استخراج ویژگی‌های ترافیک‌های شبکه کمک می‌کند. شبکه‌های عصبی کانولوشنی با یادگیری ویژگی‌های فضایی عمیق از طریق همبستگی‌های فضایی و با نرخ یادگیری سریع، دقت شناسایی بالایی ارائه می‌دهند؛ اما اثبات شده است که شبکه‌های عصبی کانولوشنی به‌طور خودکار ویژگی‌های زمانی را یاد نمی‌گیرند و نیاز به یک ساختار اضافی برای یادگیری وابستگی‌های طولانی مدت در ویژگی‌های زمانی دارند. حافظه طولانی کوتاه‌مدت یک کلاس ویژه از شبکه‌های عصبی بازگشتی است که می‌تواند ویژگی‌های زمانی از ترافیک‌های شبکه را از طریق حافظه طولانی کوتاه‌مدت خود به‌طور مؤثرتر یاد بگیرد. با این وجود، شبکه حافظه طولانی کوتاه‌مدت نیازمند زمان بیشتر برای آموزش است و نسبت به شبکه‌های عصبی کانولوشنی به منابع بیشتری نیاز دارد و دانش محدودی از اطلاعات گذشته دارد [۵]، [۶].

تحقیقات نشان می‌دهد که شبکه‌های عصبی کانولوشنی دارای کارایی بالا و زمان آموزش سریع است، درحالی که حافظه طولانی کوتاه‌مدت دارای پردازش دقیق و مؤثر ویژگی‌های زمانی است. ادغام این دو مدل می‌تواند به بهترین نحو از مزایا هرکدام استفاده کند و حتی بر غلبه بر محدودیت‌های آن‌ها کمک کند.

بر همین اساس یک مدل یادگیری عمیق ترکیبی در این مقاله پیشنهاد شده است که در آن شبکه‌های کانولوشنی و حافظه طولانی کوتاه‌مدت به صورت موازی برای استخراج ویژگی‌های فضایی - زمانی مجموعه داده‌ها مدل می‌شوند.

بیشتر مقالات شبکه‌های عصبی عمیق را به صورت یک‌بعدی طراحی و پیاده‌سازی کرده‌اند، این در حالی است که تبدیل داده‌ها به سه‌بعدی برتری قابل توجهی نسبت به حالت یک‌بعدی دارد که این مفهوم و برتری در مدل پیشنهادی ما ایجاد شده است. شبکه‌های کانولوشنی سه‌بعدی دارای دقت بیشتری نسبت به بُرداری و دوبعدی هستند. چون در این شبکه‌ها امکان استفاده از جزئیات بیشتری در تصمیم‌گیری وجود دارد. با توجه به اینکه در مسئله تشخیص نفوذ در شبکه، دقت تشخیص پارامتر مهمی است، بنابراین از تبدیل سه‌بعدی ورودی در جهت افزایش دقت استفاده شده است.

در روش پیشنهادی، ابتدا داده‌های یک‌بعدی با استفاده از تکنیک جایگشت به داده‌های دوبعدی تبدیل می‌شوند و سپس با استفاده از لایه‌های شبکه کانولوشنی دوبعدی با اندازه هسته یک، داده‌ها به داده‌های سه‌بعدی تبدیل می‌شوند. در گام بعدی، از جداکننده کانال‌ها و تکنیک جایگشت برای ایجاد دوشاخه متفاوت استفاده می‌شود و سپس داده‌های سه‌بعدی توسط دوشاخه متفاوت لایه‌های شبکه کانولوشنی و لایه‌های شبکه عصبی بازگشتی استخراج ویژگی می‌شوند. در این مقاله، موارد زیر ایجاد شده است:

- تبدیل داده‌های ورودی به داده‌های سه‌بعدی
- استفاده از تکنیک‌های جداکننده کانال‌ها و تکنیک جایگشت برای ایجاد دوشاخه متفاوت
- ترکیب روش شبکه عصبی کانولوشن و حافظه طولانی کوتاه‌مدت در دوشاخه موازی
- استخراج ویژگی‌های فضایی و زمانی
- افزایش دقت تشخیص و کاهش نرخ مثبت کاذب
- مقایسه مدل پیشنهادی با سیستم‌های جدید تشخیص نفوذ در شبکه‌های اینترنت اشیا

مقاله به صورت مرور کارهای پیشین در بخش دوم و توضیح روش پیشنهادی و پیاده‌سازی‌های آن در بخش سوم بیان شده است. نتایج عملکرد و بررسی مقایسه‌ای در بخش چهارم تشریح شده‌اند. در بخش پنجم تحلیل مدیریت و نرخ خطا و در بخش ششم تحلیل مصرف منابع پردازشی و حافظه روش پیشنهادی بررسی شده است، در بخش هفتم نتیجه‌گیری و پیشنهادها برای آینده ذکر شده‌اند.

۲. کارهای پیشین

تحقیقات بسیار زیادی برای تشخیص نفوذ در شبکه‌ها با استفاده از روش‌های یادگیری ماشین و یادگیری عمیق انجام شده است. در این بخش، بررسی شده است که چگونه این روش‌ها می‌توانند بهبود بخشی در تشخیص نفوذ داشته باشند. سه دسته اصلی شامل روش‌های مبتنی بر یادگیری ماشین، روش‌های مبتنی بر ترکیب روش‌های یادگیری

ماشین و روش‌های مبتنی بر یادگیری عمیق بررسی شده است. البته فقط به بررسی چند نمونه اخیر پرداخته شده است.

۲.۱. روش‌های مبتنی بر یادگیری ماشین

در دهه گذشته، استفاده از الگوریتم‌های یادگیری ماشین و یادگیری عمیق برای مدل‌های تشخیص نفوذ به طور قابل توجهی افزایش یافته است. توانایی ارائه پیش‌بینی دقیق با استفاده از یادگیری ویژگی‌های مؤثر، از مزایای اصلی این مدل‌های دستگاه‌های تشخیص نفوذ بوده است. بیشتر مدل‌های سیستم‌های تشخیص نفوذ موجود بر اساس مدل‌های یادگیری نظارت شده ساخته شده‌اند. در این قسمت به برخی از این تحقیقات اشاره شده است. ماشین بردار پشتیبان به طور گسترده برای این دستگاه‌ها استفاده می‌شود. در مطالعه [۷] نویسندگان از ماشین بردار پشتیبان با افزایش ویژگی برای تشخیص نفوذ استفاده کردند و آن را بر روی مجموعه داده NSL-KDD با دقت ۹۹/۱۸٪، نرخ تشخیص ۹۹/۸۵٪ و نرخ اشتباه ۲/۹۶٪ ارزیابی کردند. همچنین، در مطالعه [۸] از مدل مبتنی بر ماشین بردار پشتیبان برای تشخیص نفوذ استفاده شد که بر روی مجموعه داده AWID بررسی شد و دقت ۹۹/۲۵٪ و نرخ خطای مثبت کاذب ۱/۲٪ داشت.

در مطالعه [۹] از مدل k نزدیکترین همسایه برای ساخت فیلتر هشدار مدل سیستم تشخیص نفوذ استفاده شد که بر روی مجموعه داده DARPA1999 با دقت ۸۸/۶٪ تست شد. همچنین در مطالعه [۱۰] نیز از k نزدیکترین همسایه برای مدل سیستم تشخیص نفوذ از طریق انتخاب ویژگی تحلیل اصلی مؤلفه برای مجموعه داده ADFA-LD استفاده شد و دقت ۹۹/۵٪، نرخ واقعی مثبت ۹۹/۸٪، نرخ واقعی منفی ۹۹/۷٪، نرخ خطای مثبت کاذب ۰/۳٪ و نرخ خطای منفی کاذب ۰/۲٪ را به دست آورد.

در مطالعه [۱۱] الگوریتم K-means برای تشخیص نفوذ از مجموعه داده KDD99 اعمال شد و دقت تشخیص ۹۹/۸٪ و نرخ خطای مثبت کاذب ۰/۳٪ به دست آمد. سیستم‌های تشخیص نفوذ در مطالعه [۱۲] با استفاده از جنگل‌های تصادفی پیاده‌سازی شدند و به دقت ۹۹/۶۷٪ و نرخ خطای مثبت کاذب ۰/۸٪ بر روی مجموعه داده NSL-KDD به دست آوردند. در مطالعه [۱۳] از درخت تصمیم برای تشخیص نفوذ استفاده شد و در مجموعه داده KDD99 نفوذها با دقت ۸۸٪ شناسایی شدند. در مطالعه [۱۴] از رگرسیون لجستیک بر روی مجموعه داده NSL-KDD استفاده شد و حملات با دقت ۹۷/۵٪ شناسایی شدند. با اینکه الگوریتم‌های یادگیری ماشین می‌توانند نرخ دقت کلی بالایی را به دست آورند، اما برای بسیاری از انواع حملات، به خصوص U2R و R2L نرخ تشخیص پایینی دارند. همچنین تعادل بین مثبت و منفی‌های کاذب در بیشتر روش‌ها نامتقارن است، به طوری که مثبت‌های کاذب با کاهش منفی‌های کاذب افزایش می‌یابند.

۲.۲. روش‌های مبتنی بر ترکیب روش‌های یادگیری ماشین

بعضی از تحقیقات از الگوریتم‌های یادگیری ماشین ترکیبی و پیشرفته بهره گرفتند تا میزان مثبت‌های کاذب را کاهش دهند. در مطالعه [۱۵]، یک سیستم تشخیص نفوذ با استفاده از ترکیب ماشین بردار پشتیبان و نزدیک‌ترین همسایه طراحی شد که با دقت $89/02\%$ و نرخ خطا 12% بر روی مجموعه داده KDD99 مورد ارزیابی قرار گرفت. در مطالعه [۱۶] ماشین بردار پشتیبان و ژنتیک با یکدیگر ترکیب و برای تشخیص نفوذ استفاده شدند. این مدل بر روی مجموعه داده KDD99 توسعه یافت و با $96/61\%$ دقت، $0/07\%$ منفی‌های کاذب و $3/39\%$ مثبت‌های کاذب و $2/4\%$ نرخ خطا به دست آمد. در مطالعه [۱۷] یک سیستم تشخیص نفوذ مبتنی بر ماشین بردار پشتیبان و C5 پیشنهاد شد که دقت 94% به دست آمد.

تکنیک‌های تشخیص نفوذ مبتنی بر یادگیری ماشین پیشرفته شامل تکنیک‌های مبتنی بر شبکه‌های عصبی است. محققان در مطالعه [۱۸] از شبکه‌های عصبی مصنوعی بر مجموعه داده ترافیک شبکه معتبر استفاده کردند و دقت 98% ، حساسیت 95% را به دست آوردند. در مطالعه [۱۹] از شبکه‌های عصبی مصنوعی چندکلاسه متوالی روی KDD99 با دقت $98/25\%$ ، نرخ مثبت‌های کاذب $3/77\%$ و نرخ منفی‌های کاذب $1/26\%$ و روی مجموعه داده UNSWNB15 با دقت $86/4\%$ و نرخ مثبت‌های کاذب $2/8\%$ درصد استفاده شد. محققان از مدل یکپارچه‌شده از شبکه‌های عصبی با انتخاب ویژگی مبتنی بر همبستگی بر روی مجموعه داده‌های NSL-KDD و UNSWNB15 برای تشخیص نفوذ در [۲۰] استفاده کردند. این شبکه عصبی با دقت $98/45\%$ بر روی مجموعه داده NSL-KDD و دقت $96/4\%$ برای UNSWNB15 به دست آمد.

با وجود اینکه الگوریتم‌های یادگیری ماشین ترکیبی و پیشرفته بهینه‌تر از الگوریتم‌های ماشین معمولی عمل می‌کنند، اما محدودیت‌هایی در انتقال مجموعه داده‌های بزرگ وجود دارد. این محدودیت‌ها به دلیل معماری کم‌عمق الگوریتم‌هاست که توانایی آن‌ها در استخراج ویژگی‌های عمیق از داده‌های شبکه را کاهش می‌دهد.

۲.۳. روش‌های مبتنی بر یادگیری عمیق

تعداد زیادی تحقیق با استفاده از الگوریتم‌های یادگیری عمیق برای تشخیص نفوذ انجام شده است. همان‌طور که قبلاً بیان شد، استخراج ویژگی‌های فضایی-زمانی می‌تواند به طرز قابل توجهی باعث بهبود در تشخیص نفوذ شود، اما این چالش‌های خود را دارد. به همین دلیل، در این بخش به بررسی تحقیقاتی که از شبکه‌های کانولوشنی و حافظه طولانی کوتاه‌مدت استفاده کرده‌اند، پرداخته شده است.

در چند سال اخیر، در زمینه تشخیص نفوذ در شبکه‌های اینترنت اشیا، مدل‌های یادگیری عمیق مختلفی معرفی شده‌اند. اکثر کارهای اخیر بر روی دسته‌بندی دودویی بر مجموعه داده‌های مختلف با نتایج موفق تمرکز دارند. با این حال، اکثر این تحقیقات نمی‌توانند هم دقت

بیشتری داشته باشند و هم امتیاز F1 بالا را حفظ کنند و هم منفی کاذب را کاهش دهند.

تعداد زیادی تحقیق با استفاده از الگوریتم‌های یادگیری عمیق برای تشخیص نفوذ انجام شده است. در مطالعه [۲۱] از یک سیستم تشخیص نفوذ مبتنی بر شبکه‌های عصبی کانولوشن برای تشخیص حملات انکار سرویس استفاده شد که با دقت 99% بر روی مجموعه داده KDD99 و با دقت $91/5\%$ بر روی مجموعه داده CSE-CIC-IDS2018 عملکرد قابل قبولی داشت. در مطالعه [۲۲] یک سیستم تشخیص نفوذ مبتنی بر شبکه‌های عصبی کانولوشن و ژنتیک برای مجموعه داده NSL-KDD ارائه شد که حملات با دقت $98/2\%$ تشخیص داده شدند. در مطالعه [۲۳] از یک شبکه عصبی حافظه طولانی کوتاه‌مدت برای سیستم تشخیص نفوذ استفاده شد که بر روی مجموعه داده CIDDS با دقت 85% آزمایش شد. در مطالعه [۲۴] از یک شبکه عصبی حافظه طولانی کوتاه‌مدت دووجهی برای مجموعه داده ADFA با دقت 90% استفاده کردند. در مطالعه [۲۵] یک شبکه عصبی حافظه طولانی کوتاه‌مدت بر روی مجموعه داده ISCX-UNB با دقت 97% استفاده کردند. علاوه بر شبکه‌های عصبی کانولوشنی و شبکه‌های عصبی بازگشتی/حافظه طولانی کوتاه‌مدت، بسیاری از الگوریتم‌های یادگیری عمیق دیگر نیز به صورت جداگانه یا به همراه الگوریتم‌های دیگر برای تشخیص نفوذ استفاده شده‌اند. با این حال، شبکه‌های عصبی کانولوشنی و حافظه طولانی کوتاه‌مدت همیشه در بیشتر مجموعه داده‌های نفوذ، بهترین تشخیص حمله را ارائه کرده‌اند. آن‌ها همچنین از محدودیت‌های خاصی که در بخش قبل ذکر شده‌اند رنج می‌برند. برای کاهش محدودیت‌های آن‌ها، برخی نویسندگان تلاش کرده‌اند با استفاده از مدل‌های ترکیبی یا مدل‌های یکپارچه اقدام کنند [۲۶]. نویسندگان در مطالعه [۲۷] شبکه عصبی کانولوشنی حافظه طولانی کوتاه‌مدت برای مدل سیستم تشخیص نفوذ توسعه دادند که بر روی مجموعه داده ISCX-UNB با دقت $97/29\%$ آزمایش شد. همان‌طور که قبلاً توضیح داده شد، استخراج ویژگی‌های فضایی-زمانی می‌تواند به طرز قابل توجهی تشخیص نفوذ را بهبود بخشد اما این چالش زیادی دارد. نویسندگان در مطالعه [۲۸] از شبکه عصبی عمیق برای یادگیری ویژگی‌های فضایی-زمانی استفاده کردند. این روش بر روی مجموعه داده DARPA1998 و ISCX2012 با دقت $99/8\%$ و $99/6\%$ اعمال شد. به همین ترتیب، در مطالعه [۲۹] مدل ترکیبی از شبکه‌های عصبی کانولوشن برای تشخیص نفوذ توسعه داده شد. این مدل بر روی مجموعه داده UNSWNB15 تست شد و دقت $95/6\%$ به دست آورد. با این حال، هر دو این مدل‌ها دچار محدودیت‌هایی در مدیریت مجموعه داده‌های نامتعادل هستند. با در نظر گرفتن محدودیت‌های روش‌های پیشین در تعادل بین دقت و امتیاز f1 و کاهش نرخ مثبت کاذب مدل CLBS3 در این مقاله پیشنهاد شد. همچنین در این مدل با بهره‌گیری از مزایای هر دو مدل شبکه‌های عصبی کانولوشنی و حافظه طولانی کوتاه‌مدت برای تشخیص نفوذ سیستم قادر به تشخیص امضا و رفتار است. این کار به‌ویژه

در محیط‌هایی که به دلیل اجرای هم‌زمان برنامه‌های چندگانه، الگوهای ترافیک متعددی تجربه می‌کند، مفید خواهد بود.


با توجه به اینکه روش پیشنهادی بر اساس تشخیص NIDS در IoT است، در جدول ۱ تحلیل مقایسه‌ای از کارهای قبلی که از روش یادگیری عمیق برای تشخیص نفوذ در اینترنت اشیا در لایه شبکه استفاده کرده‌اند، انجام شده است. در تمامی روش‌های موردبررسی، از یادگیری عمیق نظارت شده استفاده شده است. جدول ۱ براساس زمان انتشار روش‌ها تنظیم شده است.

جدول ۱: مقایسه روش‌های تشخیص نفوذ در اینترنت اشیا بر اساس یادگیری عمیق					
ردیف	مرجع	سال	مدل	دقت	مجموعه داده
۱	[۳۰]	۲۰۱۶	ANN	۹۹	شبه‌سازی شده
۲	[۳۱]	۲۰۱۷	GRNN	۹۸/۹۱	KDDCUP99
۳	[۳۲]	۲۰۱۸	ANN	۸۹	UNSW-NB-15
۴	[۳۳]	۲۰۱۸	DT+NB+ANN	۹۸/۹۷	UNSWNB15
۵	[۳۴]	۲۰۱۸	LSTM	۹۵	UNSWNB-15
۶	[۳۵]	۲۰۱۹	ANN	۹۹/۸۶	KDD CUP99
۷	[۳۶]	۲۰۱۹	ANN	۱۰۰	N_BaIoT
۸	[۳۷]	۲۰۲۰	BILSTM	۹۹/۵۷ ۸۵/۵۹	NSL KDD UNSWNB15
۹	[۳۸]	۲۰۲۰	DT+NB+ANN	۹۹	Modbus network traffic
۱۰	[۳۹]	۲۰۲۰	LCNN + GRNN	۹۱	NSL-KDD
۱۱	[۴۰]	۲۰۲۰	CNN + LSTM	۹۴/۸۰	N_BaIoT
۱۲	[۴۱]	۲۰۲۱	bFNN + mFNN	۹۹/۹۶	BOTIOT
۱۳	[۴۲]	۲۰۲۳	CNN+GRU	۹۹/۹۲	Kddcup99
۱۴	[۴۲]	۲۰۲۳	CNN+LSTM	۹۹/۹۵	Kddcup99
۱۵	[۴۳]	۲۰۲۳	ANN-ICA	۹۰	Kddcup99
۱۶	[۴۴]	۲۰۲۱	FUZZY	۹۱/۲۶	Kddcup99

۳. روش پیشنهادی

در این بخش، هدف طراحی یک سیستم تشخیص نفوذ در شبکه‌های اینترنت اشیا، با استفاده از روش‌های یادگیری عمیق به صورت سه‌بعدی است. در مدل پیشنهادی، از تکنیک‌های مختلفی استفاده شده تا دقت و قدرت مدل افزایش یابد. روش جدید یادگیری عمیق سه‌بعدی مبتنی بر تقسیم‌کننده شاخه برای تشخیص نفوذ در شبکه‌های اینترنت اشیا

این مقاله بر تمرکز دسته‌بندی دودویی با استفاده از شبکه‌های کانولوشنی و حافظه طولانی کوتاه‌مدت با تنظیم ورودی سه‌بعدی به نام CLBS3 معرفی شده است. در شکل ۱، مراحل مختلف مدل پیشنهادی به‌طور کلی نشان داده شده است که از سه بخش اصلی تشکیل شده است. در بخش اول، مجموعه داده UNSW-NB 15 و TONIOT برای تشخیص نفوذ استفاده شده است. در بخش دوم، از تکنیک‌های پیش‌پردازش برای آماده‌سازی داده‌ها استفاده شده است. بخش سوم به چارچوب اصلی مدل پیشنهادی به همراه تکنیک‌های جداکننده کانال، نگاشت و لایه‌های مختلف یادگیری عمیق برای استخراج ویژگی می‌پردازد. در ادامه، هر یک از مراحل مدل پیشنهادی در زیر بخش‌های جداگانه توضیح داده شده و جزئیات کامل در هر بخش آمده است.




شکل ۱: فلوچارت تشخیص نفوذ مدل CLBS3

۳.۱. پیش‌پردازش

داده‌های اولیه ممکن است حاوی اطلاعات نامعلوم و اغتشاش بوده که بی‌تردید بر کارایی مدل تأثیرگذار خواهد بود. مدل ارائه شده نیازمند به‌کارگیری چندین مرحله پیش‌پردازش پیش از استفاده از فن‌های یادگیری عمیق است. این فرآیندهای پیش‌پردازش به بهبود کیفیت

داده‌های مربوط به اینترنت اشیا، ارتقای دقت مدل ارائه شده و کاهش پیچیدگی محاسبات کمک می‌کنند. مراحل آماده‌سازی داده شامل دو مرحله کلیدی و پاک‌سازی و تبدیل داده‌ها است. پس از اجرای این مراحل،



شکل ۲: تبدیل داده‌ها در مرحله آماده‌سازی

۳.۱.۱ پاک‌سازی داده‌ها

گام نخست در فرایند پیش‌پردازش داده‌ها معمولاً به پاک‌سازی داده‌ها اختصاص دارد. این مرحله شامل فرآیندهایی نظیر دور ریختن داده‌های بی‌ربط، حذف داده‌های تکراری، تکمیل اطلاعات ناقص و مواردی از این دست است.

• حذف داده‌های بی‌ربط

منظور از داده‌های بی‌ربط داده‌هایی هستند که وجود آن ویژگی تأثیری در یادگیری مدل نخواهد داشت و از نظر فراوانی مقادیر آن ویژگی می‌توان آن را تشخیص داد. یکی از روش‌های رایج برای حذف داده‌های بی‌ربط استفاده از خصوصیت منحصربه‌فرد بودن است بدین صورت که اگر مقادیر یک ویژگی فقط یک مقدار باشد و به عبارتی واریانس آن خیلی کم باشد، آن ویژگی از مجموعه داده حذف خواهد شد. اگر واریانس یک ویژگی برابر تعداد رکوردهای یک مجموعه داده باشد نیز آن ویژگی از مجموعه ویژگی‌ها حذف می‌شود مانند ویژگی id در مجموعه داده UNSWNB15 که شماره ردیف را نگهداری می‌کند.

• داده‌های مفقود شده

برخی از ویژگی‌های بعضی از نمونه‌های مجموعه داده ممکن است دارای مقادیر خالی باشد. این امر به دلیل عوامل زیادی مثل ایجاد نویز در سیستم با از قلم افتادن در درج مقادیر ویژگی‌ای اتفاق بیافتند. مدیریت و رفع مشکل داده‌های مفقود شده حائز اهمیت است، چراکه مدل‌های پیشنهادی و الگوریتم‌های دیگر نمی‌توانند با وجود داده‌های گمشده به درستی آموزش ببینند.

در این مقاله، برای جلوگیری از تأثیر منفی مقادیر گمشده بر مدل، تمامی مقادیر خالی در دیتاست با مقدار مناسبی جایگزین می‌شوند. به این صورت که اگر یک ستون شامل داده‌های متنی (رشته‌ای) باشد، از مقدار مد (mode) آن ستون استفاده می‌کنیم و اگر داده‌ها عددی باشند، از میانگین (mean) آن ستون استفاده می‌شود.

۳.۱.۲ تبدیل داده‌ها

همه داده‌ها آماده برای به کارگیری در مدل پیشنهادی و دیگر روش‌های مقایسه‌ای می‌شوند. در ادامه این مراحل توضیح داده شده است.

تبدیل داده‌های بی‌معنا و تبدیل داده‌ها به قالب مناسب برای تجزیه و تحلیل است. این مرحله شامل نرمال‌سازی داده‌های عددی در مقیاس مشترک، رمزگذاری متغیرهای طبقه‌بندی یا اعمال تبدیل‌های ریاضی برای دستیابی به خواص توزیع بهتر است. با تبدیل داده‌ها اطمینان داده می‌شود که ویژگی‌های مختلف در مقیاس قابل مقایسه هستند و سوگیری‌هایی را که ممکن است بر تجزیه و تحلیل تأثیر بگذارند حذف می‌شود. تأثیر مراحل تبدیل داده‌ها بر روی تعداد ویژگی‌ها در شکل ۲ نشان داده شده است.

• کدگذاری

همه ورودی‌های استفاده شده در متدهای یادگیری ماشین و مدل مورد نظر باید در قالب آرایه‌هایی از اعداد صحیح یا اعداد ممیزی شناور باشند. البته، در داده‌های موجود ممکن است ویژگی‌هایی با نوع دسته‌بندی شده وجود داشته باشند که نیاز به تبدیل به نوع دیگری در این مرحله دارند. دو روش متداول برای این تبدیل، استفاده از روش‌های کدگذاری برچسب و کدگذاری وان هات می‌باشد. استفاده از روش کدگذاری وان هات می‌تواند به دلیل افزایش بیش از حد تعداد ویژگی‌ها به نسبت تعداد دسته‌ها، کمتر کارآمد باشد. در این تحقیق روش‌های مختلف کدگذاری بررسی شد که در قسمت ارزیابی نمایش داده شده است و در بین آن‌ها روش کدگذاری برچسب موجود در کتابخانه sklearn برای تغییر ویژگی‌های با نوع رشته‌ای یا دسته‌بندی شده بهترین دقت را در مجموعه داده‌های مورد بررسی داشت.

• نرمال‌سازی

برای دستیابی به نتایج دقیق‌تر، لازم است که بازه مربوط به ویژگی‌های مختلف، به نحوی با یکدیگر یکسان و یا نزدیک شوند. برای این منظور از روش‌های نرمال‌سازی استفاده می‌شود. روش‌های مختلفی برای نرمال‌سازی وجود دارد که در مقالات و تحقیقات مورد استفاده قرار می‌گیرد. تکنیک‌های مختلفی برای نرمال‌سازی داده‌ها وجود دارد مانند min-max, z-score, tanh,

نرمال سازی یک فرایند است که در آن، داده‌های مربوط به هر ویژگی به گونه‌ای تغییر مقیاس یا تبدیل می‌شوند که در یک بازه خاص قرار بگیرند. در این مقاله تمامی این روش‌ها برای نرمال سازی اعمال شد و تأثیر هر یک بر دقت مدل ارزیابی شد که در قسمت ارزیابی نتایج به دست آمده گزارش شده است. طبق نتایج به دست آمده روش min-max بهترین دقت را داشته است و برای روش پیشنهادی از این روش نرمال سازی استفاده شده است.

روش حداقل-حداکثر یکی از روش‌های معمول برای تغییر داده‌ها به یک مقیاس و بازه نوین است که با استفاده از فرمول ۱ محاسبه می‌شود:

$$X_{norm} = \frac{X_i - \min(X_i)}{\max(X_i) - \min(X_i)} \quad (1)$$

X_i نشان دهنده ارزش ویژگی عددی برای نمونه i است، $\max$ و $\min$ نشان دهنده حداقل و حداکثر ارزش‌های ویژگی‌های عددی می‌باشند. با استفاده از مقیاس بندی، تمامی ویژگی‌ها در دو مجموعه داده ادیری در بازه صفر تا یک تبدیل می‌شوند.

۳.۲. مدل CLBS3

روش‌های یادگیری عمیق به صورت گسترده در زمینه‌های مختلف از جمله سیستم‌های تشخیص نفوذ به کار گرفته شدند. مزیت اصلی روش‌های یادگیری عمیق استخراج ویژگی‌های مختلف از داده‌های چندبُعدی است. شبکه‌های عصبی کانولوشن و حافظه طولانی کوتاه مدت دو روش مهم در یادگیری عمیق هستند.

با تحلیل روش‌های قبلی، مشخص شد که در اکثر روش‌ها تعادل بین دقت و امتیاز F1 وجود ندارد. برای رسیدن به این تعادل و کاهش نرخ مثبت کاذب، مدل CLBS3 در این مقاله پیشنهاد شده است. این مدل با استفاده از ویژگی‌های شبکه‌های عصبی کانولوشن و حافظه طولانی کوتاه مدت برای تشخیص نفوذ، قادر به تشخیص امضا و رفتار است. این کار به خصوص در محیط‌هایی که الگوهای ترافیک متعددی وجود دارد، مفید است. مقاله بر تمرکز دسته بندی دودویی با استفاده از شبکه‌های کانولوشن و حافظه طولانی کوتاه مدت با تنظیم ورودی سه بُعدی تمرکز دارد. در نهایت، یک مدل ترکیبی برای تشخیص حمله با دقت و امتیاز F1 قابل توجه ارائه می‌دهد و نرخ مثبت کاذب را به صورت چشمگیری کاهش می‌دهد.

طبق معماری مدل پیشنهادی CLBS3 در شکل ۳، داده‌های دوبُعدی با استفاده از تکنیک لایه‌های کانولوشن دو بُعدی به داده‌های سه بُعدی تبدیل می‌شوند این مزیت این امکان را به مدل پیشنهادی می‌دهد که از روش‌های تقسیم کننده شاخه‌ای و تکنیک جایگشت استفاده کند تا عملکرد را بهبود بخشد. همچنین، تکنیک جایگشت مدل پیشنهادی باعث ترکیب موازی لایه‌های کانولوشن و لایه‌های حافظه طولانی کوتاه مدت می‌شود که از مزایای هر دو نوع لایه استفاده می‌کند. لایه‌های کانولوشن بیشتر برای استخراج ویژگی‌های مکانی و لایه‌های حافظه طولانی کوتاه مدت بیشتر برای استخراج ویژگی‌های زمانی استفاده می‌شوند. در این روش، ابتدا داده‌های یک بُعدی به

داده‌های دوبُعدی $n \times n$ تبدیل می‌شوند و سپس با استفاده از لایه‌های شبکه کانولوشن دوبُعدی با اندازه هسته یک، داده‌ها به داده‌های سه بُعدی تبدیل می‌شوند. در مرحله بعدی، از جداکننده کانال‌ها و تکنیک جایگشت برای ایجاد دو شاخه متفاوت استفاده می‌شود و سپس داده‌های سه بُعدی توسط دو شاخه متفاوت از لایه‌های شبکه کانولوشن و لایه‌های شبکه عصبی بازگشتی استخراج ویژگی می‌شوند.

مدل پیشنهادی CLBS3 دارای ویژگی‌های زیر است:

- تبدیل داده‌ها از یک بُعد به دو بُعد و سپس سه بُعد بدون از دست رفتن ویژگی‌های پایه
- پیچیدگی محاسباتی کم به نسبت داده‌های سه بُعدی عمومی
- دقت تشخیص بالا با توجه به ترکیب لایه‌های بازگشتی و کانولوشن
- دقت تشخیص بالا با توجه به داده‌های سه بُعدی
- استفاده از تکنیک‌های جداکننده کانال‌ها و تکنیک جایگشت برای ایجاد دو شاخه متفاوت
- استفاده از لایه‌های کانولوشن برای استخراج ویژگی‌های مکانی

استفاده از لایه‌های بازگشتی برای استخراج ویژگی‌های زمانی شبکه‌های کانولوشن سه بُعدی برای تشخیص الگوها در داده‌های سه بُعدی استفاده می‌شوند. این شبکه‌ها با استفاده از عملیات کانولوشن، تشخیص و استخراج ویژگی‌های مهم را از داده‌های سه بُعدی انجام می‌دهند. دقت این شبکه‌ها نیز برای تشخیص الگوها و ویژگی‌های مختلف در داده‌های سه بُعدی بسیار بالاست از این رو تغییر دیدگاه شبکه عصبی و تبدیل ورودی داده‌های شبکه به بردارهای سه بُعدی می‌تواند دقت طبقه بندی را افزایش دهد. به عنوان مثال، در یک مدل با ۶۴ ویژگی در ورودی، در صورت نمایش به صورت برداری، هر ویژگی حداکثر دارای دو همسایه است. در نمایش دوبُعدی این تعداد همسایگان به ۸ می‌رسد. با استفاده از مثلاً فیلتر $3 \times 3 \times 3$ ، فرمت ورودی می‌تواند به سه بُعدی تغییر یابد و تعداد همسایگان به ۲۶ برسد. با افزایش تعداد همسایگان، اطلاعات بیشتری در دسترس شبکه قرار می‌گیرد که همین امر باعث می‌شود دقت شبکه افزایش یابد. بدیهی است که زمان آموزش و پیچیدگی نیز افزایش خواهد یافت. اگرچه امکان استفاده مستقیم از فیلترهای همگرا در ایجاد داده‌های سه بُعدی وجود دارد، اما در روش CLBS3 از یک تکنیک ساده بر اساس دو بُعدی برای ایجاد داده‌های سه بُعدی استفاده شده است. این روش نسبت به روش سه بُعدی معمولی پیچیدگی کمتری دارد.

در مدل CLBS3، به جای حرکت دادن بردار ورودی شبکه در فضای سه بُعدی و استفاده از فیلتر کانولوشن سه بُعدی بر روی آن، ابتدا یک لایه انتقال (یک لایه کانولوشن دوبُعدی با اندازه فیلتر یک) اعمال می‌شود. ورودی به بردار سه بُعدی تبدیل می‌شود. این مدل از دو روش جابجایی برای استخراج اطلاعات همبستگی مفید استفاده می‌کند. اگر ورودی مدل $S \times L$ باشد، با استفاده از روش پیشنهادی، ورودی به ابعاد $S \times \sqrt{[L]}$

([L]) $\times\sqrt{}$ تغییر می‌کند که S تعداد رکوردها و L تعداد ویژگی‌های ورودی است. شکل ۴ روش اولین جابجایی را نشان می‌دهد. به عنوان مثال، مجموعه داده UNSWNB15 حاوی ۴۳ ویژگی است. با استفاده از مدل پیشنهادی تبدیل به ورودی $\sqrt{43} \times \sqrt{43}$ خواهد شد؛ بنابراین، ۴۳ ویژگی اصلی تبدیل به ۴۹ ویژگی می‌شود که ۶ ویژگی جدید اضافه شده با صفر مقداردهی می‌شوند. این مدل شبکه کانولوشنی، سطرهای مربوط به هر کانال ورودی را می‌گیرد، آن‌ها را حرکت می‌دهد و آن‌ها را به عنوان یک کانال واحد در خروجی قرار می‌دهد؛ بنابراین، ورودی شبکه یک ماتریس $7 \times 7 \times 2$ است و خروجی آن ماتریس $7 \times 2 \times 7$ است که در شکل ۴ نشان داده شده است. نوع دوم جابه‌جایی در شکل ۵ نشان داده شده است. این نوع جابه‌جایی یک ورودی $7 \times 7 \times 2$ را، با تغییر مکان ستون‌های متناظر با هر کانال ورودی و قراردادن آن‌ها به عنوان یک کانال به $7 \times 7 \times 2$ تبدیل می‌کند. این دو نوع نگاشت باعث نزدیک شدن ویژگی‌های دوردست در فضای کانال می‌شوند و باعث می‌شود اطلاعات همبستگی از پارامترهای دوردست در داده‌های تغییر یافته استخراج شود.

شکل ۴ نشان‌دهنده عملکرد مدل عمیق CLBS3 پیشنهادی بر روی مجموعه داده UNSWNB15 است که شامل قابلیت‌های زیر است:


۱- **آماده‌سازی داده:** یک نمایش دوبعدی از بردار ورودی به عنوان ورودی مدل پیشنهادی استفاده می‌شود. لایه انتقال با چهار فیلتر کانولوشن به اندازه استاندارد ۱ اعمال می‌شود. ورودی به چهار کانال ارسال می‌شود که به دو بخش مساوی تقسیم شده و به دوشاخه مدل ما تغذیه می‌شود. کانال‌های آبی و نارنجی به شاخه دوم منجر می‌شوند در حالی که کانال‌های زرد و سبز به شاخه اول می‌روند. هر

شاخه از یکی از انواع جابجایی مشخص شده برای استخراج داده‌های همبستگی مهم‌تر، استفاده می‌کند.

۲- **شاخه اول:** شاخه اول جابجایی خطی را بر روی ورودی انجام می‌دهد و به بردار ورودی $7 \times 2 \times 7$ تبدیل می‌شود که به عنوان ورودی یک شبکه کانولوشنی در نظر گرفته می‌شود. شبکه کانولوشن جدید شامل دو لایه با یک فیلتر و ۲۵۶ کانال به اندازه ۲ و یک فیلتر به اندازه ۱ است. این شبکه شامل یک لایه تخته‌کننده و یک لایه کاملاً متصل به ۵۱۲ با تابع فعالیست RELUE است. تمرکز این شاخه بیشتر بر استخراج ویژگی‌های فضای است. شبکه‌های کانولوشن در تشخیص ویژگی‌های محلی بهتر عمل می‌کنند.

۳- **شاخه دوم:** شاخه دوم از جابجایی ستونی شبکه کانولوشن دوبعدی استفاده می‌کند و ورودی را به یک ماتریس سه‌بعدی به اندازه $7 \times 7 \times 2$ تبدیل می‌کند. این ماتریس سه‌بعدی به عنوان ورودی شبکه حافظه طولانی کوتاه مدت در نظر گرفته می‌شود. خروجی شبکه حافظه طولانی کوتاه مدت یک لایه کاملاً متصل به اندازه ۵۱۲ با تابع فعالیست RELUE است. تمرکز این شاخه بیشتر بر استخراج ویژگی‌های زمانی است.

۴- **لایه آخر:** بر روی خروجی هر دو شاخه اعمال می‌شود و به عنوان یک لایه پیوندی عمل کرده و مسئول دسته‌بندی خروجی است؛ بنابراین، ورودی را به یک بردار یک‌بعدی که خروجی را نشان می‌دهد تبدیل می‌کند. تابع فعالیست SOFTMAX برای دسته‌بندی دودویی و تشخیص حمله استفاده می‌شود. در این لایه از بهینه‌ساز Adam و نرخ یادگیری ۰/۲ استفاده می‌شود.



شکل ۳: معماری مدل CLBS3

ToN-IoT	UNSW-NB15	مجموعه داده
۳۰۰۰۰۰	۱۶۴۶۷۳	تعداد رکوردهای نرمال
۱۶۱۰۱۴۳	۹۳۰۰۰	تعداد رکوردهای حمله
۴۲	۴۵	تعداد کل ویژگی ها
۲	۲	تعداد کلاس طبقه بندی

• مجموعه داده ToN-IoT

تمام نمونه های داده در مجموعه داده ToN-IoT از ۴۵ ویژگی تشکیل شده است. ۴۳ ویژگی اول برای صفت ها استفاده می شود و ویژگی ۴۴ ام با عنوان عادی بدون حمله و یا حمله، برچسب گذاری می شود و ویژگی آخر با عنوان بدون حمله یا نوع حمله ها برچسب گذاری شده است. مجموعه داده ای که برای آموزش و تست استفاده شده است شامل ۴۶۱۰۴۳ رکورد داده شبکه است. ۳۰۰۰۰۰ رکورد از آن ها عادی است و ۱۶۱۰۴۳ رکورد، بیانگر حمله است.

• مجموعه داده UNSW-NB15

مجموعه داده UNSW-NB15 که در آزمایشگاه امنیت سایبری استرالیا ایجاد شده، برای تولید و شبیه سازی داده های واقعی و به روز طراحی شده است. این مجموعه داده شامل ۴۹ ویژگی است که توسط دوازده الگوریتم برای ایجاد برچسب های کلاس تولید شده اند. بخشی از این داده ها به دو بخش مجزا تقسیم می شود: یک بخش برای آموزش با ۱۷۵۳۴۱ رکورد و دیگری برای تست با ۸۲۳۳۲ رکورد که هر دو شامل نمونه هایی از رفتارهای معمولی و انواع مختلف حملات هستند. هر مجموعه داده دارای ۴۵ ویژگی است. از این ۴۵ ویژگی، ۴۳ ویژگی برای توصیف صفات به کار می روند، ویژگی ۴۴ به عنوان نرمال یا حمله برچسب گذاری می شود و آخرین ویژگی نیز نوع نرمال یا حمله را مشخص می کند.

۴.۲ معیارهای ارزیابی

در این بخش، معیارهای مختلف برای ارزیابی عملکرد مدل پیشنهادی و سایر الگوریتم های مقایسه ای معرفی می شود. با توجه به مسئله طبقه بندی، چهار معیار از رایج ترین معیارهای اعتبارسنجی شامل دقت، امتیاز $f1$ ، نرخ مثبت کاذب^۲ و نرخ منفی کاذب^۳ با ماتریس درهم ریختگی قابل تعریف است.


بر اساس ماتریس درهم ریختگی، مثبت واقعی^۴ نشان دهنده تعداد نمونه های ترافیک حملاتی است که به درستی توسط مدل پیشنهادی طبقه بندی شده اند. منفی واقعی^۵ نمونه ترافیک عادی را نشان می دهد که به درستی توسط مدل پیشنهادی طبقه بندی شده اند. مثبت کاذب^۶ تعداد نمونه ترافیک های عادی هستند، اما به اشتباه توسط مدل پیشنهادی به عنوان نمونه حمله طبقه بندی شده اند. منفی کاذب^۷ تعداد نمونه ترافیک ها حملاتی هستند، اما به اشتباه توسط مدل پیشنهادی به عنوان نمونه ترافیک عادی طبقه بندی شده اند.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$


$$F1 - score = 2 * \frac{precision * recall}{precision + recall}$$

$$FPR = \frac{FP}{FP + TN}$$

$$FNR = \frac{FN}{TP + FN}$$



شکل ۴: جایگشت نوع اول



شکل ۵: جایگشت نوع دوم

۴. ارزیابی و نتایج

مدل CLBS3 پیشنهادی با پایتون پیاده سازی و ارزیابی شده است. آزمایش ها برای مقایسه عملکرد این مدل بر روی مجموعه داده UNSWNB15 و TONIOT انجام شده است. در این بخش ابتدا مجموعه داده های استفاده شده برای ارزیابی معرفی می شوند. سپس معیارهای ارزیابی مورد استفاده معرفی می شود. در ادامه، از روش پیشنهادی برای تشخیص نفوذ در مجموعه داده تعریف شده با هدف افزایش دقت استفاده می شود. مقایسه ها با مدل های ترکیبی شامل مدل های شبکه های کانولوشنی [۲۱]، حافظه طولانی کوتاه مدت [۲۳]، کانولوشنی و حافظه طولانی کوتاه مدت [۲۷]، شبکه عصبی عمیق [۲۸]، و ترکیب شبکه های کانولوشنی و حافظه طولانی کوتاه مدت [۴۵] بر اساس تحقیقات قبلی صورت گرفته است. علاوه بر این، عملکرد شبکه کانولوشنی بهبود یافته جدید نیز به صورت جداگانه ارزیابی شده و با مدل یکپارچه پیشنهادی CLBS3 مقایسه می شود.

۴.۱ مجموعه داده ها

در این مقاله، برای ارزیابی عملکرد مدل پیشنهادی و الگوریتم های دیگر در مسئله تشخیص نفوذ شبکه های اینترنت اشیا، دو مجموعه داده معتبر مورد استفاده قرار می گیرد. این مجموعه داده ها دارای ویژگی های منحصر به فرد برای تشخیص حملات سایبری در شبکه های اینترنت اشیا می باشند. این دو مجموعه داده شامل ToN-IoT، UNSW-NB 15 و هستند که تعداد نمونه های آن ها در جدول ۲ نشان داده شده است. در ادامه، توضیحات مختصری در مورد هر مجموعه داده ذکر شده است.

جدول ۲: مشخصات مجموعه داده ها

۴.۳ تنظیم پارامترها

در مدل یادگیری عمیق، هایپر پارامترها مواردی هستند که تأثیر بسیار زیادی بر عملکرد و دقت مدل دارند. تنظیم و بهینه‌سازی هایپر پارامترها بسیار مهم است و برای به دست آوردن یک مدل یادگیری عمیق با دقت بالا، نیاز است که این هایپر پارامترها به درستی تنظیم شوند. با تغییر پارامترهای مهم، عملکرد سیستم تشخیص نفوذ به طور قابل توجهی تغییر می‌کند. تأثیر تغییر هر یک از پارامترهای مهم به طور خلاصه در این بخش نشان داده شده است. می‌توان هایپر پارامترهای دخیل را در دو بخش مجزا توضیح داد.

- بهینه‌سازی هایپر پارامترهای مدل پیشنهادی با استفاده از Optuna

در این مقاله، برای بهبود عملکرد مدل شبکه عصبی کانولوشنی، از بهینه‌سازی هایپر پارامترها استفاده شده است. مدل ما روی داده‌های UNSW-NB15 آموزش داده شده و ابزار Optuna برای یافتن بهترین مقادیر هایپر پارامترها به کار رفته است Optuna. از روش بهینه‌سازی بیزی استفاده می‌کند که به طور کارآمد مقادیر مختلف هایپر پارامترها را بررسی کرده و بهترین ترکیب را برای رسیدن به حداکثر دقت انتخاب می‌کند.

Optuna از یک فرآیند هوشمندانه بهینه‌سازی استفاده می‌کند که در آن به جای بررسی تمام ترکیبات ممکن، ترکیب‌های امیدوارکننده را براساس نتایج قبلی انتخاب می‌کند. در این روش، Optuna با استفاده از توزیع احتمالات بیزی و یادگیری از نتایج هر آزمایش، ترکیب‌های جدیدی از هایپر پارامترها را پیش‌بینی می‌کند که احتمالاً دقت بالاتری دارند. نحوه عملکرد optuna به صورت زیر است:

۱- آغاز با نمونه‌های تصادفی: در ابتدای کار، Optuna با بررسی تعدادی ترکیب تصادفی از هایپر پارامترها، نتایج اولیه را جمع‌آوری می‌کند.

۲- مدل‌سازی توزیع احتمالاتی بیزی: پس از دریافت نتایج اولیه، Optuna بر اساس مدل بیزی، توزیعی از احتمال موفقیت هر ترکیب را بر اساس نتایج قبلی ایجاد می‌کند.

۳- انتخاب ترکیبات جدید با جستجوی کارآمد Optuna: با استفاده از الگوریتم‌های جستجو، ترکیب‌های جدیدی را از این توزیع احتمالاتی انتخاب می‌کند که شانس بیشتری برای بهبود دقت مدل دارند.

۴- تکرار و بهبود تدریجی: در هر مرحله از جستجو، نتایج به مدل احتمالاتی اضافه می‌شود و Optuna به تدریج به ترکیب‌هایی نزدیک می‌شود که بالاترین دقت را دارند.

این رویکرد بیزی باعث می‌شود که Optuna بدون نیاز به آزمون همه ترکیبات، بهینه‌ترین مقادیر را پیدا کند و از نظر زمان و منابع محاسباتی بسیار کارآمد باشد.

در مدل پیشنهادی، شش هایپر پارامتر اصلی زیر برای بهینه‌سازی در نظر گرفته شدند. بازه‌های تعریف شده برای هر یک از هایپر پارامترها بر اساس تجربیات مقالات قبلی و تجربه است. این هایپر پارامترها به طور مستقیم بر دقت و کیفیت یادگیری مدل تأثیر می‌گذارند:

۱- تعداد فیلترها در لایه کانولوشن: این پارامتر مشخص می‌کند که چند ویژگی از ورودی توسط لایه کانولوشن استخراج شود. برای این پارامتر، بازه‌ای بین ۳۲ تا ۶۴ انتخاب شده است. افزایش تعداد فیلترها می‌تواند مدل را قادر به یادگیری ویژگی‌های پیچیده‌تر کند.

۲- اندازه فیلتر این پارامتر اندازه هر فیلتر را مشخص می‌کند. برای اندازه فیلتر بازه‌ای بین ۳ تا ۵ در نظر گرفته شد که اندازه‌های کوچک‌تر باعث استخراج ویژگی‌های جزئی‌تر و اندازه‌های بزرگ‌تر باعث تعمیم‌دهی بیشتر می‌شوند.

۳- تعداد گره‌ها در لایه Dense: این پارامتر نشان‌دهنده تعداد گره‌های لایه چگال (Dense) است که می‌تواند قدرت یادگیری مدل را در مراحل پایانی شبکه افزایش دهد. بازه انتخابی بین ۶۴ تا ۱۰۲۴ تنظیم شده است.

۴- نرخ Dropout: روشی برای جلوگیری از بیش برازش است که باعث می‌شود برخی از گره‌ها به طور تصادفی در زمان آموزش غیرفعال شوند. این نرخ در بازه ۰.۱ تا ۰.۵ انتخاب شد که مقادیر بالاتر باعث کاهش بیش برازشی می‌شود.

۵- نرخ یادگیری: نرخ یادگیری میزان تغییرات وزن‌ها را در هر به‌روزرسانی مدل تعیین می‌کند. برای این پارامتر از بازه‌ی ۰.۰۰۱ تا ۰.۱، به صورت لگاریتمی استفاده شد که مقدار بالاتر منجر به یادگیری سریع‌تر و مقادیر کمتر منجر به یادگیری آهسته‌تر ولی پایدارتر می‌شوند. ۶- انتخاب بهینه‌ساز: برای بهینه‌سازی وزن‌ها، دو الگوریتم پرکاربرد SGD و Adam در نظر گرفته شده‌اند.

در این بهینه‌سازی، تعداد تکرارها برای Optuna برابر با ۲۰ تنظیم شده است؛ یعنی ابزار Optuna صد ترکیب مختلف از مقادیر هایپر پارامترها را به طور هوشمندانه انتخاب و آزمایش می‌کند تا بهترین نتایج به دست آید. همچنین، برای هر ترکیب از هایپر پارامترها، مدل به مدت ۵۰ دوره (epoch) روی داده‌های آموزشی آموزش داده می‌شود. این تعداد از epoch ها اجازه می‌دهد که مدل به خوبی آموزش ببیند، اما از طرفی باعث افزایش زمان اجرای برنامه نیز می‌شود.

Optuna پس از آزمایش ۲۰ ترکیب مختلف از مقادیر هایپر پارامترها، ترکیبی از مقادیر را به عنوان بهترین مجموعه بهینه‌یافته پیشنهاد می‌دهد. این ترکیب با بیشترین دقت ممکن در داده‌های آزمایشی به عنوان بهترین حالت انتخاب می‌شود

جدول ۳، تأثیر هر یک از هایپر پارامترها را روی نتیجه نهایی مدل نشان می‌دهد با استفاده از بهینه‌سازی بیزی در Optuna، به مجموعه‌ای از مقادیر هایپر پارامترها دست‌یافتیم که بالاترین دقت ممکن را برای مدل ما فراهم کردند. نتایج نشان‌دهنده موفقیت این روش در تعیین مقادیر بهینه و همچنین ارزشمندی آن در جلوگیری از آزمایش‌های دستی و زمان‌بر هایپر پارامترها است. بهترین دقت برای زمانی است که تعداد ۴۵ فیلتر به اندازه ۳ در شبکه کانولوشنی داشته باشیم و تعداد گره‌های لایه dense برابر ۱۲۷ باشد. با بهینه‌ساز adam و نرخ یادگیری ۰.۰۰۸۲ بیشترین دقت برابر ۹۷/۳ درصد و کمترین زمان برابر ۱۵۸

ثانیه به دست آمده است. بنابراین برای اجرای مدل هایپرپارامترها با این مقادیر تنظیم شده اند.

جدول ۳: تنظیم هایپرپارامترها و زمان

زمان	دقت	بهینه ساز	نرخ یادگیری	dropout	گره	اندازه فیلتر	id
212	0.68	adam	0.0485	0.410	840	5	1
192	0.958	sgd	0.0193	0.286	648	5	2
183	0.969	adm	0.0091	0.1472	193	5	3
207	0.844	sgd	0.00024	0.160	508	5	4
208	0.846	sgd	0.00034	0.3887	397	5	5
201	0.922	sgd	0.0016	0.286	341	3	6
203	0.927	sgd	0.00155	0.2077	462	5	7
188	0.968	adm	0.00025	0.12581	393	3	8
190	0.951	adm	0.04161	0.3911	75	3	9
187	0.961	sgd	0.0609	0.3083	293	4	10
158	0.973	adm	0.00082	0.187	127	3	11
210	0.759	sgd	0.0001	0.1336	208	5	12
162	0.971	adm	0.0028	0.238	173	3	13
184	0.967	adm	0.00811	0.454	71	4	14
183	0.969	adm	0.0094	0.228	188	4	15
182	0.969	adm	0.0076	0.2503	186	4	16
180	0.962	adm	0.023	0.2080	145	3	17
160	0.971	adm	0.0027	0.3149	238	4	18
162	0.970	adm	0.00169	0.333	257	3	19
186	0.968	adm	0.007	0.35957	262	4	20

• هایپر پارامترهای اجرا

برای اعتبارسنجی مجموعه داده ها، اعتبارسنجی متقابل k-fold انجام شده است. بهترین عملکرد در پنجاه درصد داده های آموزشی و پنجاه درصد داده های آزمایشی به دست آمده است. حداقل تعداد تکرار تنظیم شده در هر اجرا برابر با ۱۰۰ در نظر گرفته شده است.

در حین اجرای روش های یادگیری، وجود پارامترهای تصادفی باعث تولید مقادیر متفاوت و متغیر شده است؛ بنابراین، برای هر مورد، اجراها به صورت ۱۰ بار (هر بار به مدت ۱۰۰ دور) انجام شده است و میانگین نتایج این اجراها به عنوان جواب نهایی در نظر گرفته می شود.

۴،۴ نتایج ارزیابی

اطلاعات اولیه ممکن است حاوی اطلاعات نامعلوم و همراه نویز با شند که بدون شک بر کارایی مدل تأثیرگذار خواهد داشت. مدل ارائه شده نیازمند به کارگیری چندین مرحله پیش پردازش قبل از استفاده از تکنیک های CLBS3 است. این فرآیندهای پیش پردازش به بهبود کیفیت داده های مربوط به اینترنت اشیا، افزایش دقت مدل ارائه شده و کاهش پیچیدگی محاسبات کمک می کنند. سه مرحله اصلی پیش پردازش شامل پاک سازی، رمزنگاری و نرمال سازی داده ها هستند که در بخش ۳،۱ شرح داده شده اند. در مرحله نرمال سازی از تکنیک های مختلف نرمال سازی استفاده شده است. جدول ۴ مقادیر نرمال سازی

داده ها برای تکنیک های نرمال سازی مختلف را نشان می دهد. تکنیک های نرمال سازی مورد استفاده شامل نرمال سازی حداقل-حداکثر، نرمال سازی z-score و نرمال سازی تانژانت هیپربولیک هستند. نتایج نشان می دهد که روش نرمال سازی حداقل-حداکثر دقت بهتری را به دست آورده است؛ بنابراین، در مرحله پیش پردازش از روش حداقل-حداکثر برای نرمال سازی داده ها استفاده شده است.


جدول ۴: نرمال سازی داده ها با تکنیک های نرمال سازی مختلف

مجموعه داده	تکنیک های نرمال سازی	مجموعه داده		
		دقت	صحت	امتیاز f1
TONIOT	Min-max	۹۴/۸	۹۲/۱۵	۹۳/۲
	z-score	۸۵/۸	۸۳/۹۶	۸۴/۱۲
	tanh	۹۳/۲	۸۸/۱۳	۹۲/۹
UNSWNB15	Min-max	۹۲/۹۷	۹۳/۱۵	۹۳/۱
	z-score	۹۱/۲۵	۹۲/۴	۹۳
	tanh	۸۹/۳	۹۰	۹۳/۴

در ادامه این بخش مدل پیشنهادی CLBS3 بر روی مجموعه داده UNSWNB15 و TONIOT ارزیابی می شود. دو معیار اصلی دسته بندی شامل دقت و امتیاز f1 و همچنین دو معیار مهم دیگر یعنی FNR و FPR برای مقایسه مدل پیشنهادی با سایر روش ها در نظر گرفته شده است. از تکنیک اعتبارسنجی متقابل k-fold برای اعتبارسنجی مدل پیشنهادی و سایر مدل ها استفاده شده است تا نشان داده شود که مدل پیشنهادی تا چه اندازه در داده های تست متفاوت، نتایج پایداری دارد. نتایج آزمایش تکنیک اعتبارسنجی K-Fold بر روی مجموعه داده UNSWNB15 نشان می دهد که مدل پیشنهادی در ۱۰ تکرار مختلف، در ۵۰ درصد داده های آزمایشی عملکرد بهتری دارد. بدین ترتیب نتایج اعتبارسنجی روی مجموعه داده های IToN-IoT، UNSWNB15، به ترتیب در شکل ۶ و ۷ آورده شده است

شکل ۸ ماتریس درهم ریختگی روش CLBS3 را در مجموعه داده UNSWNB15 نشان می دهد. ماتریس درهم ریختگی گویای دقت بالا در تشخیص است. با استفاده از این ماتریس، می توان به راحتی دقت الگوریتم در تشخیص حمله ها را محاسبه کرد و عملکرد الگوریتم را ارزیابی کرد. در این ماتریس، مثبت واقعی نشان دهنده تعداد مواردی است که الگوریتم به درستی حمله را تشخیص داده است که ۵۹۲۱۴ نمونه است، منفی کاذب نشان دهنده تعداد مواردی است که حمله وجود داشته اما الگوریتم آن را به عنوان حمله تشخیص نداده است که ۴۶۹ نمونه است، مثبت کاذب نشان دهنده تعداد مواردی است که الگوریتم به اشتباه حالتی که حمله نبوده است را حمله تشخیص داده است که ۱۰۵۱ نمونه است و منفی درست نشان دهنده تعداد مواردی است که الگوریتم به درستی عدم حمله را تشخیص داده است که ۲۶۹۳۷ مورد است. در روش های مورد مقایسه با وجود اینکه دقت مدل بالا است ولی تعداد رکوردهای منفی کاذب خیلی بیشتر است در حالی که در حالت حمله

هر چقدر حملات به درستی تشخیص داده شوند نشان دهنده قوی بودن مدل است. با تحلیل ماتریس درهم‌ریختگی می‌توان نتیجه گرفت که مقدار کم FPR در الگوریتم پیشنهادی باعث دقت بالا در دسته‌بندی دودویی می‌شود؛ بنابراین، می‌توان گفت که مدل پیشنهادی بهتر از مدل‌های دیگر برای مجموعه داده‌های مورد بررسی عمل می‌کند.




شکل ۸: ماتریس درهم‌ریختگی مجموعه داده UNSWNB15

برای مقایسه روش پیشنهادی، جدول ۵ نتایج ارزیابی روش پیشنهادی را بر روی مجموعه داده UNSWNB-15 نسبت به مدل‌های شبکه‌های کانولوشنی [۲۱]، حافظه طولانی کوتاه‌مدت [۲۳]، کانولوشنی و حافظه طولانی کوتاه‌مدت [۲۷]، شبکه عصبی عمیق [۲۸]، و ترکیب شبکه‌های کانولوشنی و حافظه طولانی کوتاه‌مدت [۴۵] نشان می‌دهد. در انتخاب الگوریتم‌های مورد مقایسه سعی شده است، الگوریتم‌هایی انتخاب شوند که از ترکیب شبکه‌های کانولوشنی و حافظه کوتاه بلندمدت استفاده کنند و خود روش‌های مورد مقایسه نیز در تحقیقاتشان با روش‌های قدیمی بیشتری مقایسه شده باشند. از جدول ۵ مشخص است که روش پیشنهادی عملکرد قابل مقایسه‌ای نسبت به مدل‌های موجود دارد. تمام مدل‌های مقایسه شده دقت تقریباً بالایی دارند ولی معمولاً توازن بین دقت و امتیاز F1 وجود ندارد. به عنوان نمونه مطالعه [۲۸] دارای دقت بیشتر ولی FPR بیشتر نیز هست یا مطالعه [۲۳] توازن بین دقت و امتیاز F1 وجود ندارد. مدل پیشنهادی بالاترین دقت و اندازه‌گیری F را دارد و در عین حال مقادیر کمی از FNR را نیز دارد.


جدول ۵: مقایسه مدل پیشنهادی با روش‌های دیگر در مجموعه

داده UNSWNB15

FNR	FPR	امتیاز F1	دقت	مدل	مرجع
۱۷/۴۵	۱۷/۸	۹۴/۲۵	۹۲/۸۵	CNN	[۲۱]
۷	۱۱/۵۵	۹۶/۳۷	۹۳	LSTM	[۲۳]
۴/۴۵	۹/۸	۹۴/۷۸	۹۴/۷۵	CONV-LSTM	[۲۷]
۶/۶۷	۱۱/۷	۹۵/۶۷	۹۵	DNN	[۲۸]
۴/۱۲	۵/۰۳	۹۷/۵۱	۹۴/۶۷	OCNN	[۴۵]
۳/۶۹	۶/۷۵	۹۸/۰۵	۹۶/۲۲	HMLSTM	
۳/۶۷	۵/۸۷	۹۸/۱۳۲	۹۶/۳۳	OCNN-HMLSTM	
۰/۷۹	۳/۷	۹۷/۹۹	۹۸/۴	CLBS3	روش پیشنهادی




الف - معیارهای دسته‌بندی




ب- معیارهای خطا

شکل ۶: بررسی کارایی TONIOT با مدل CLBS



الف - معیارهای دسته‌بندی



ب- معیارهای خطا

شکل ۷: بررسی کارایی UNSWNB15 با مدل CLBS

مقایسه مدل پیشنهادی CLBS3 با مدل‌های پیشرفته دیگر بر روی مجموعه داده TON-IOT در جدول ۶ نشان می‌دهد که مدل پیشنهادی در معیار دقت نسبت به مدل‌های دیگر عملکرد بهتری داشته‌است. البته در معیارهای دیگر عملکرد الگوریتم پیشنهادی به‌طور میانگین حدود ۹۸ است که عملکرد بالایی الگوریتم پیشنهادی را بر روی مجموعه داده TON-IOT ثابت می‌کند. چندین روش اخیر نیز بر روی مجموعه داده UNSWNB15 در جدول ۶ آمده‌است. نتایج ارزیابی، برتری روش پیشنهادی را در چهار معیار ارزیابی مهم نشان می‌دهد.

جدول (۶): مقایسه مدل پیشنهادی DLBS-3D با مدل‌های

پیشرفته دیگر بر روی مجموعه داده TON-IOT

مرجع	الگوریتم	دقت	صحت	یادآوری	امتیاز F1
[۴۶]	DT	۸۸/۶۷	۸۴/۸۲	۸۲/۲۹	۸۳/۵۴
	NB	۷۴/۱۳	۶۰/۹۸	۷۱/۴۴	۶۵/۷۷
	RF	۹۳/۹۴	۸۶/۸۸	۹۷/۳۲	۹۱/۸۱
	Ensemble	۹۶/۳۵	۹۰/۵۴	۹۹/۹۸	۹۵/۰۳
[۴۷]	DNRANN-1	۹۹/۱۵	۹۹/۲۳	۹۹/۰۷	۹۹/۲۷
	DNRANN-2	۹۹/۲۰	۹۸/۹۱	۹۸/۸۶	۹۸/۸۸
	DNRANN-3	۹۸/۱۷	۹۸/۸۹	۹۸/۸۳	۹۸/۸۶
[۴۸]	DFF+AE	۹۶/۹۳	-	۹۸/۲۵	۹۸
	CNN+LDA	۹۷/۶۰	-	۹۹/۴۶	۹۹
	RNN+PCA	۹۶/۱۳	-	۹۶/۹۰	۹۸
	LR+LDA	۹۷/۶۸	-	۹۹/۵۹	۹۹
	DT+AE	۹۸/۲۳	-	۹۸/۲۸	۹۹
	NB+PCA	۹۷/۹۴	-	۹۹/۸۲	۹۹
[۴۹]	LSTM-400	۹۶/۵۲	-	۹۸/۳	۹۷/۳
	LSTM-500	۹۶/۵۶	-	۹۷/۳	۹۷/۳۵
	CLBS3 (روش پیشنهادی)	۹۸/۲	۹۸/۲۱	۹۸/۲۶	۹۸/۲۷

جدول (۷): مقایسه مدل پیشنهادی CLBS3 با مدل‌های پیشرفته

دیگر بر روی مجموعه داده UNSWNB15

مرج ع	الگوریتم	دقت	صحت	یادآوری	امتیاز F1
[۵۰]	GWO-PSO-RF	۸۴/۴۶	۸۰/۸۵	۷۹/۴۳	۷۹/۰۱
	MOPSO-Levy-KNN	۸۷/۱۲	۸۵/۷۸	۸۶/۶۵	۸۷/۳۴
	AAFSa with GA-FR	۹۴/۴۸	۹۴/۲۹	۹۴/۲۶	۹۴/۴۲
[۴۸]	DFF+LDA	۹۸/۳۴	-	۹۹/۸۸	۸۵/۰
	CNN+LDA	۹۸/۲۸	-	۹۹/۸۹	۸۵
	RNN+LDA	۹۸/۳۱	-	۹۸/۸۸	۸۵
	LR+FULL	۹۸/۴۷	-	۹۸/۸۸	۸۶
	DT+ FULL	۹۹/۲۷	-	۹۱/۵۸	۹۲
	NB+LDA	۹۸/۳۴	-	۹۸/۳۹	۸۵
[۵۱]	LSTM	۹۱/۱۴	-	-	-
	CNN	۹۰/۰۹	-	-	-
	CNN LSTM	۹۳/۲۱	-	-	-
[۵۲]	Simple RNN	۸۷/۰۷	-	-	-
	LSTM	۸۵/۰۸	-	-	-
	GRU	۸۸/۴۲	-	-	-
	CLBS3 روش پیشنهادی	۹۸/۴	۹۷/۸	۹۸/۷۸	۹۷/۹۹

۵. تحلیل مدیریت و نرخ خطا

در این مقاله نتایج به‌دست‌آمده از ارزیابی مدل پیشنهادی حاکی از کارایی و دقت آن در شناسایی حملات و تفکیک آن‌ها از ترافیک عادی است. مقادیر به‌دست‌آمده برای نرخ مثبت کاذب نرخ منفی کاذب به ترتیب برابر با ۳,۷۶٪ و ۰,۷۹٪ هستند.

نرخ مثبت کاذب به درصد مواردی اشاره دارد که مدل به‌اشتباه ترافیک عادی را به‌عنوان حمله شناسایی کرده‌است. مقدار ۳,۷۶٪ برای FPR نشان‌دهنده این است که از هر ۱۰۰ مورد ترافیک عادی، تقریباً ۳,۷۶ مورد به‌اشتباه به‌عنوان حمله شناسایی شده‌اند. این نرخ نسبتاً پایین به این معناست که مدل ما توانسته‌است ترافیک عادی را به‌طور مؤثری از حملات متمایز کند. کاهش تعداد هشدارهای کاذب نه‌تنها به کاهش بار بر روی گروه‌های امنیتی کمک می‌کند، بلکه موجب افزایش اعتبار سیستم نیز می‌شود. در دستگاه‌های امنیتی، وجود هشدارهای کاذب می‌تواند منجر به کاهش توجه و اعتبار گروه‌های امنیتی نسبت به هشدارها شود، بنابراین مدیریت این نرخ اهمیت زیادی دارد.

نرخ منفی کاذب به درصد حملات واقعی اشاره دارد که مدل قادر به شناسایی آن‌ها نبوده‌است. مقدار ۰,۷۹٪ برای نرخ منفی کاذب به این

معناست که از هر ۱۰۰ حمله واقعی، تنها حدود ۰,۷۹ مورد به‌اشتباه شناسایی نشده‌اند. این نرخ بسیار پایین نشان‌دهنده توانایی بالای مدل در شناسایی حملات واقعی است. در زمینه اینترنت اشیا، جایی که تهدیدات ممکن است جدی باشند، توانایی شناسایی صحیح حملات بسیار حیاتی است. یک نرخ منفی کاذب پایین به این معناست که سیستم می‌تواند به‌طور مؤثر و سریع به تهدیدات پاسخ دهد و از وقوع خسارات بیشتر جلوگیری کند.

مدیریت خطا در مدل‌های تشخیص نفوذ به فرایندهایی اطلاق می‌شود که هدف آن کاهش نرخ‌های مثبت کاذب و منفی کاذب است. در این مقاله، برای مدیریت خطا از تنظیم هایپرپارامترها و dropout استفاده شده است. از روش بیزین برای بهینه‌سازی هایپرپارامترهای مدل استفاده کردیم. این روش به ما این امکان را می‌دهد که ترکیب بهینه پارامترها را شناسایی کنیم. به عنوان مثال، با تنظیم مناسب نرخ یادگیری و تعداد لایه‌های مدل، توانستیم دقت آن را بهبودبخشیم و در نتیجه، نرخ‌های خطا را کاهش دهیم.

برای جلوگیری از بیش‌برازش، از تکنیک Dropout بهره‌برداری کردیم. این تکنیک با حذف تصادفی برخی از نورون‌ها در هر دوره آموزش، به مدل کمک می‌کند تا به ویژگی‌های خاص وابسته نشود. این فرایند به بهبود قابلیت تعمیم‌پذیری مدل و کاهش نرخ منفی کاذب کمک کرده است.

نتایج نشان‌دهنده عملکرد مطلوب مدل در شناسایی حملات در محیط اینترنت اشیا است. با کاهش نرخ‌های مثبت و منفی کاذب، مدل ما توانسته است به بهینه‌سازی قابل توجهی دست یابد. با توجه به نتایج به‌دست آمده، می‌توان گفت که مدل ما می‌تواند به‌عنوان ابزاری مؤثر در تشخیص نفوذ در IoT مورد استفاده قرار گیرد و به تقویت امنیت دستگاه‌های IoT کمک کند.

۶. تحلیل مصرف منابع پردازشی و حافظه مدل پیشنهادی

این بخش برای ارزیابی کارایی مدل و اطمینان از مناسب بودن آن برای دستگاه‌های اینترنت اشیا (IoT) که معمولاً از منابع سخت‌افزاری محدودی برخوردارند، اهمیت زیادی دارد. نتایج آزمایش مصرف منابع پردازشی و حافظه مدل پیشنهادی بر روی مجموعه داده unswbn15 را می‌توان به‌صورت زیر دسته‌بندی کرد:

زمان اجرا: مدت زمان اجرای مدل برای پردازش داده‌ها برابر با ۸۱/ ثانیه اندازه‌گیری شد. این زمان اجرا نشان‌دهنده سرعت مناسبی برای مدل است که در کاربردهای IoT می‌تواند به معنای پردازش تقریبی در زمان واقعی یا نزدیک به آن باشد. زمان اجرای کم، از نظر بهره‌وری انرژی و پاسخ‌دهی سریع در دستگاه‌های IoT که باید به وقایع شبکه به‌سرعت واکنش نشان دهند، بسیار مطلوب است.

مصرف پردازنده: مصرف CPU در طی اجرای مدل برابر با تقریباً صفر درصد گزارش شد. این مقدار نشان می‌دهد که مدل، در شرایط فعلی اجرا، تقریباً هیچ بار پردازشی قابل توجهی بر CPU سیستم وارد نمی‌کند. این

می‌تواند به دلیل بهینه‌سازی‌های مدل و پردازش توسط بخش‌هایی از GPU یا استفاده از واحدهای محاسباتی دیگر باشد که بار پردازشی کمتری بر CPU دارند. برای دستگاه‌های IoT که اغلب پردازنده‌های با توان کم دارند، مصرف پایین CPU یک مزیت بزرگ محسوب می‌شود.

مصرف حافظه: مصرف حافظه در طول اجرای مدل به‌طور متوسط برابر با ۱۳/۷۰۳۴۰۷ مگابایت بود. این مقدار نسبتاً پایین نشان می‌دهد که مدل فضای حافظه زیادی را برای نگهداری پارامترها و محاسبات میانی اشغال نمی‌کند. چنین مصرف حافظه‌ای برای دستگاه‌های IoT که محدودیت‌های حافظه دارند، مزیت بزرگی است و نشان می‌دهد که مدل می‌تواند در چنین دستگاه‌هایی بدون نگرانی از مصرف بیش از حد حافظه، به‌راحتی اجرا شود.

اوج مصرف حافظه: اوج مصرف حافظه مدل در طی اجرای آزمایش‌ها به ۴۷/۰۷۹۸۷ مگابایت رسید. این مقدار حداکثر حافظه‌ای است که مدل در زمان بارگیری و پردازش اطلاعات نیاز دارد. این افزایش لحظه‌ای در مصرف حافظه به دلیل ذخیره‌سازی موقت نتایج میانی در برخی از لایه‌های مدل، مانند لایه‌های کانولوشن و LSTM است. با این حال، اوج مصرف حافظه نیز همچنان در حد معقولی باقی مانده است و نشان می‌دهد که مدل در استفاده از حافظه بهینه عمل می‌کند.

مصرف RAM سیستم: میزان مصرف RAM کلی سیستم در طول اجرای مدل به ۲۰۵۸/۲۹۳۲۴۸ مگابایت رسید. این مقدار شامل حافظه‌ای است که سیستم‌عامل و سایر فرآیندها نیز اشغال کرده‌اند. این میزان مصرف نشان می‌دهد که مدل در زمان اجرا حجم معقولی از RAM را مصرف می‌کند و با توجه به محدودیت‌های سخت‌افزاری IoT، می‌توان آن را برای دستگاه‌های IoT با ظرفیت حافظه مشابه مناسب در نظر گرفت.

این نتایج بیانگر آن است که مدل پیشنهادی برای کاربردهای IoT از نظر مصرف منابع پردازشی و حافظه بهینه طراحی شده و می‌تواند در محیط‌هایی با محدودیت‌های سخت‌افزاری اجرا شود. این مدل ضمن بهره‌وری بالا، بار پردازشی کمی بر CPU دارد، حافظه زیادی اشغال نمی‌کند و زمان اجرای کوتاهی دارد که همگی ویژگی‌های مناسبی برای دستگاه‌های IoT به شمار می‌آیند.

۷. نتیجه‌گیری

در این مقاله یک رویکرد یادگیری عمیق سه‌بعدی جدید مبتنی بر تقسیم شاخه‌ای برای سیستم تشخیص نفوذ در شبکه‌های اینترنت اشیا به نام CLBS3 پیشنهاد شد. در ابتدا داده‌های یک‌بعدی شبکه‌های اینترنت اشیا با تکنیک فیلتر لایه‌های کانولوشنی به داده‌های سه‌بعدی تبدیل شد و سپس از جداکننده کانال‌ها و تکنیک جایگشت برای ایجاد دو شاخه متفاوت و موازی استفاده شد. در مدل پیشنهادی CLBS3 از ترکیب موازی لایه‌های کانولوشنی و لایه‌های حافظه کوتاه‌مدت طولانی برای بهره‌برداری از مزایای هر دو مدل استفاده شده است. لایه‌های کانولوشنی برای استخراج ویژگی‌های مکانی به‌صورت سراسری و محلی

- and *Communication Networks*, vol. 8, pp. 3883-3895, 2015.
- [۱۰] G. Serpen and E. Aghaei, "Host-based misuse intrusion detection using PCA feature extraction and kNN classification algorithms," *Intelligent Data Analysis*, vol. 22, pp. 1101-1114, ۲۰۱۸.
- [۱۱] Y. Y. Aung and M. M. Min, "An analysis of K-means algorithm based network intrusion detection system," *Advances in Science, Technology and Engineering Systems Journal*, vol. 3, pp. 496-501, 2018.
- [۱۲] N. Farnaaz and M. Jabbar, "Random forest modeling for network intrusion detection system," *Procedia Computer Science*, vol. 89, pp. 213-217, 2016.
- [۱۳] K. Peng, V. C. Leung, L. Zheng, S. Wang, C. Huang, and T. Lin, "Intrusion detection system based on decision tree over big data in fog environment," *Wireless Communications and Mobile Computing*, vol. 2018, p. 4680867, 2018.
- [۱۴] E. Besharati, M. Naderan, and E. Namjoo, "LR-HIDS: logistic regression host-based intrusion detection system for cloud environments," *Journal of Ambient Intelligence and Humanized Computing*, vol. 10, pp. 3669-3692, 2019.
- [۱۵] S. Teng, N. Wu, H. Zhu, L. Teng, and W. Zhang, "SVM-DT-based adaptive and collaborative intrusion detection," *IEEE/CAA Journal of Automatica Sinica*, vol. 5, pp. 108-118, 2017.
- [۱۶] P. Tao, Z. Sun, and Z. Sun, "An improved intrusion detection algorithm based on GA and SVM," *Ieee Access*, vol. 6, pp. 13624-13631, 2018.
- [۱۷] A. Khraisat, I. Gondal, P. Vamplew, J. Kamruzzaman, and A. Alazab, "A novel ensemble of hybrid intrusion detection system for detecting internet of things attacks," *Electronics*, vol. 8, p. 1210, 2019.
- [۱۸] A. Shenfield, D. Day, and A. Ayesh, "Intelligent intrusion detection systems using artificial neural networks," *Ict Express*, vol. 4, pp. 95-99, 2018.
- [۱۹] M. M. Baig, M. M. Awais, and E.-S. M. El-Alfy, "A multiclass cascade of artificial neural network for network intrusion detection," *Journal of Intelligent & Fuzzy Systems*, vol. 32, pp. 2875-2883, 2017.
- [۲۰] I. Sumaiya Thaseen, J. Saira Banu, K. Lavanya, M. Rukunuddin Ghalib, and K. Abhishek, "An integrated intrusion detection system using correlation-based attribute selection and artificial neural network," *Transactions on Emerging Telecommunications Technologies*, vol. 32, p. e4014, 2021.
- [۲۱] J. Kim, J. Kim, H. Kim, M. Shim, and E. Choi, "CNN-based network intrusion detection against denial-of-service attacks," *Electronics*, vol. 9, p. 916, 2020.
- [۲۲] M. T. Nguyen and K. Kim, "Genetic convolutional neural network for intrusion detection systems," *Future Generation Computer Systems*, vol. 113, pp. 418-427, 2020.
- [۲۳] S. A. Althubiti, E. M. Jones, and K. Roy, "LSTM for anomaly-based network intrusion detection," in *2018 28th International telecommunication networks and applications conference (ITNAC)*, 2018, pp. 1-3.
- [۲۴] A. Chawla, P. Jacob, B. Lee, and S. Fallon, "Bidirectional LSTM autoencoder for sequence based anomaly detection in cyber security," *International Journal of Simulation-Systems, Science & Technology*, vol. 20, pp. 1-6, 2019.
- [۲۵] M. Amar and B. E. Ouahidi, "Weighted LSTM for intrusion detection and data mining to prevent attacks," *International Journal of Data Mining, Modelling and Management*, vol. 12, pp. 308-329, 2020.
- و لایه های حافظه کوتاه مدت طولانی به شتر برای استخراج ویژگی های زمانی یا به صورت توالی استفاده شد. در نهایت مدل CLBS3 بر روی مجموعه داده UNSW-NB15 و TONIOT مورد آزمایش قرار گرفت.
- نتایج آزمایش های مختلف نشان می دهد که مدل پیشنهادی در معیارهای نرخ تشخیص بالا، دقت بالا و نرخ مثبت کاذب به ۹۸/۴۶٪، ۹۷/۹۹٪ و ۰،۰۳۲ در UNSW-NB15 و ۹۸/۲٪ و ۹۸٪ و ۰/۰۰۲۸ در TONOT پیدا کرده است که عملکرد بالای آن در تشخیص حملات را اثبات می کند. طراحی و پیاده سازی مدل برای حالت چندکلاسه، همچنین استفاده از تکنیک های بهینه سازی هایپر پارامترها مدل پیشنهادی CLBS3 به کارهای آینده واگذار می شود.
- نتایج بیانگر آن است که مدل پیشنهادی برای کاربردهای IoT از نظر مصرف منابع پردازشی و حافظه بهینه طراحی شده و می تواند در محیط هایی با محدودیت های سخت افزاری اجرا شود. این مدل ضمن بهره وری بالا، بار پردازشی کمی بر CPU دارد، حافظه زیادی اشغال نمی کند و زمان اجرای کوتاهی دارد که همگی ویژگی های مناسبی برای دستگاه های IoT به شمار می آیند.

مراجع

- [۱] P. Mishra, V. Varadharajan, U. Tupakula, and E. S. Pilli, "A detailed investigation and analysis of using machine learning techniques for intrusion detection," *IEEE communications surveys & tutorials*, vol. 21, pp. 686-728, 2018.
- [۲] L. O. Anyanwu, J. Keengwe, and G. A. Arome, "Scalable intrusion detection with recurrent neural networks," in *2010 Seventh International Conference on Information Technology: New Generations*, 2010, pp. 919-923.
- [۳] Z. X. Yang, X. L. Qin, W. R. Li, and Y. J. Yang, "A DDoS detection approach based on CNN in cloud computing," *Applied Mechanics and Materials*, vol. 513, pp. 579-584, 2014.
- [۴] R. C. Staudemeyer, "Applying long short-term memory recurrent neural networks to intrusion detection," *South African Computer Journal*, vol. 56, pp. 136-154, 2015.
- [۵] H. K. Maragheh, F. S. Gharehchopogh, K. Majidzadeh, and A. B. Sangar, "A Hybrid Model Based on Convolutional Neural Network and Long Short-Term Memory for Multi-label Text Classification," *Neural Processing Letters*, vol. 56, p. 42, 2024/02/16 2024.
- [۶] H. Ebrahimi, K. Majidzadeh, and F. Soleimani Gharehchopogh, "Integration of deep learning model and feature selection for multi-label classification," *International Journal of Nonlinear Analysis and Applications*, vol. 13, pp. ۲۰۲۲, ۲۸۸۳-۲۸۷۱.
- [۷] H. Wang, J. Gu, and S. Wang, "An effective intrusion detection framework based on SVM with feature augmentation," *Knowledge-Based Systems*, vol. 136, pp. 130-139, 2017.
- [۸] M. Usha and P. Kavitha, "Anomaly based intrusion detection for 802.11 networks with optimal features using SVM classifier," *Wireless Networks*, vol. 23, pp. 2431-2446, 2017.
- [۹] W. Meng, W. Li, and L. F. Kwok, "Design of intelligent KNN-based alarm filter using knowledge-based alert verification in intrusion detection," *Security*

- Emerging Technologies in Computing (AETiC)*, Print ISSN, pp. 2516-0281, 2020.
- [۴۰] G. D. L. T. Parra, P. Rad, K.-K. R. Choo, and N. Beebe, "Detecting Internet of Things attacks using distributed deep learning," *Journal of Network and Computer Applications*, vol. 163, p. ۲۰۲۰, ۱۰۲۶۶۲.
- [۴۱] I. Ullah and Q. H. Mahmoud, "Design and development of a deep learning-based model for anomaly detection in IoT networks," *IEEE Access*, vol. 9, pp. 103906-103926, 2021.
- [۴۲] M. Roknaldini and E. Noroozi, "Presenting A Hybrid Method of Deep Neural Networks to Prevent Intrusion in Computer Networks," *Intelligent Multimedia Processing and Communication Systems (IMPCS)*, vol. 4, pp. 57-65, 2023.
- [۴۳] M. Nazarpour, N. Nezafati, and S. Shokouhyar, "Using the Modified Colonial Competition Algorithm to Increase the Speed and Accuracy of the Intelligent Intrusion Detection System," *Intelligent Multimedia Processing and Communication Systems (IMPCS)*, vol. 4, pp. 1-10, 2023.
- [۴۴] A. Ghaffari and R. Hossinnezhad, "Intrusions detection system in the cloud computing using heterogeneity detection technique," *Intelligent Multimedia Processing and Communication Systems (IMPCS)*, vol. 3, pp. 37-46, 2022.
- [۴۵] P. R. Kanna and P. Santhi, "Unified deep learning approach for efficient intrusion detection system using integrated spatial-temporal features," *Knowledge-Based Systems*, vol. 226, p. 107132, 2021.
- [۴۶] P. Kumar, G. P. Gupta, and R. Tripathi, "An ensemble learning and fog-cloud architecture-driven cyber-attack detection framework for IoMT networks," *Computer Communications*, vol. 166, pp. 110-124, 2021.
- [۴۷] S. Latif, Z. e Huma, S. S. Jamal, F. Ahmed, J. Ahmad, A. Zahid, et al., "Intrusion detection framework for the internet of things using a dense random neural network," *IEEE Transactions on Industrial Informatics*, vol. 18, pp. 6435-6444, 2021.
- [۴۸] M. Sarhan, S. Layeghy, N. Moustafa, M. Gallagher, and M. Portmann, "Feature extraction for machine learning-based intrusion detection in IoT networks," *Digital Communications and Networks*, 2022.
- [۴۹] R. A. Elsayed, R. A. Hamada, M. I. Abdalla, and S. A. Elsaid, "Securing IoT and SDN systems using deep-learning based automatic intrusion detection," *Ain Shams Engineering Journal*, vol. 14, p. 102211, 2023.
- [۵۰] R. Anushiya and V. Lavanya, "A new deep-learning with swarm based feature selection for intelligent intrusion detection for the Internet of things," *Measurement: Sensors*, vol. 26, p. 100700, 2023.
- [۵۱] R. Zhao, G. Gui, Z. Xue, J. Yin, T. Ohtsuki, B. Adebisi, et al., "A novel intrusion detection method based on lightweight neural network for internet of things," *IEEE Internet of Things Journal*, vol. 9, pp. 9960-9972, 2021.
- [۵۲] S. M. Kasongo, "A deep learning technique for intrusion detection system using a Recurrent Neural Networks based framework," *Computer Communications*, vol. 199, pp. 113-125, 2023.
- [۲۶] S. N. M. Khosroshahi, S. N. Razavi, A. Babazadeh Sangar, and K. Majidzadeh, "Offline Identification of the Author using Heterogeneous Data based on Deep Learning," *Computational Intelligence in Electrical Engineering*, vol. 13, pp. 115-134, 2022.
- [۲۷] M. A. Khan, M. R. Karim, and Y. Kim, "A scalable and hybrid intrusion detection system based on the convolutional-LSTM network," *Symmetry*, vol. 11, p. 583, 2019.
- [۲۸] W. Wang, Y. Sheng, J. Wang, X. Zeng, X. Ye, Y. Huang, et al., "HAST-IDS: Learning hierarchical spatial-temporal features using deep neural networks to improve intrusion detection," *IEEE access*, vol. 6, pp. 1792-1806, 2017.
- [۲۹] J. Zhang, Y. Ling, X. Fu, X. Yang, G. Xiong, and R. Zhang, "Model of the intrusion detection system based on the integration of spatial-temporal features," *Computers & Security*, vol. 89, p. 101681, 2020.
- [۳۰] J. Canedo and A. Skjellum, "Using machine learning to secure IoT systems," in *2016 14th annual conference on privacy, security and trust (PST)*, 2016, pp. 219-222.
- [۳۱] M. K. Putchala, "Deep learning approach for intrusion detection system (ids) in the internet of things (iot) network using gated recurrent neural networks (gru)," Wright State University, 2017.
- [۳۲] M. Mohammadi, A. Al-Fuqaha, S. Sorour, and M. Guizani, "Deep learning for IoT big data and streaming analytics: A survey," *IEEE Communications Surveys & Tutorials*, vol. 20, pp. 2923-2960, 2018.
- [۳۳] N. Moustafa, B. Turnbull, and K.-K. R. Choo, "An ensemble intrusion detection technique based on proposed statistical flow features for protecting network traffic of internet of things," *IEEE Internet of Things Journal*, vol. 6, pp. 4815-4830, 2018.
- [۳۴] B. Roy and H. Cheung, "A deep learning approach for intrusion detection in internet of things using bi-directional long short-term memory recurrent neural network," in *2018 28th international telecommunication networks and applications conference (ITNAC)*, 2018, pp. 1-6.
- [۳۵] T. S. Fatayer and M. N. Azara, "IoT secure communication using ANN classification algorithms," in *2019 International Conference on Promising Electronic Technologies (ICPET)*, 2019, pp. ۱۴۶-۱۴۲.
- [۳۶] Y. N. Soe, Y. Feng, P. I. Santosa, R. Hartanto, and K. Sakurai, "A sequential scheme for detecting cyber attacks in IoT environment," in *2019 IEEE Intl Conf on Dependable, Autonomic and Secure Computing, Intl Conf on Pervasive Intelligence and Computing, Intl Conf on Cloud and Big Data Computing, Intl Conf on Cyber Science and Technology Congress (DASC/PiCom/CBDCCom/CyberSciTech)*, 2019, pp. 238-244.
- [۳۷] Z. Ma, J. Li, Y. Song, X. Wu, and C. Chen, "Network intrusion detection method based on FCWGAN and BiLSTM," *Computational Intelligence and Neuroscience*, vol. 2022, p. 6591140, 2022.
- [۳۸] M. Saharkhizan, A. Azmoodeh, A. Dehghantanha, K.-K. R. Choo, and R. M. Parizi, "An ensemble of deep recurrent neural networks for detecting IoT cyber attacks using network traffic," *IEEE Internet of Things Journal*, vol. 7, pp. 8852-8859, 2020.
- [۳۹] R. A. Ramadan and K. Yadav, "A novel hybrid intrusion detection system (IDS) for the detection of internet of things (IoT) network attacks," *Annals of*

⁴ True Positive(TP)

⁵ True Negative(TN)

⁶ False Negative(FN)

¹ Convolutional neural network and Long Short Term Memory

Branch Splitter with three dimensions' data(CLS3)

² False Positive Rate (FPR)

³ False Negative Rate (FNR)