

Anomaly Detection in Internet of Things Equipment Traffic with the Approach of Combining Deep Learning Models

V. Yadegari^{1*} , S. Sohrab² , V. Mahmoudian³

¹ PhD Student of Information Technology Management at Allameh Tabatabai University

Email: (*Correspondence: v.yadegari58@yahoo.com)

² Researcher, Qom Higher Education Institute, Qom, Iran. Email: samad_sohrab@yahoo.com

³ Ph.D. student, Faculty of Computer Science, Islamic Azad University, North Tehran Branch, Tehran, Iran

Email: mahmoudian.vahid@gmail.com

ARTICLE INFO

Article history:

Article Type: Research paper

Received: 23 April 2025

Revised: 25 May 2025

Accepted: 08 June 2025

Available online: 22 June 2025

Keywords:

Convolutional Neural Networks

Recurrent Neural Networks



Network Traffic Classification

Deep Learning

Internet of Things (IoT)

ABSTRACT

Network traffic classifiers play a critical role in network monitoring systems by detecting anomalies in network flows based on communication features. This is particularly significant for managing and monitoring Internet of Things (IoT) networks. In this study, a novel method for network traffic classification is proposed, leveraging a combination of deep learning models tailored for IoT traffic. Experimental results demonstrate that the hybrid CNN+RNN-2 model achieves an accuracy of 83.58%, outperforming standalone and other hybrid models. By combining local feature extraction through Convolutional Neural Networks (CNN) and temporal dependency analysis via Recurrent Neural Networks (RNN), the proposed model effectively identifies complex patterns and improves detection accuracy. Furthermore, the results indicate that the CNN+RNN-2 model surpasses traditional supervised, semi-supervised, and unsupervised methods without requiring manual feature engineering. The use of deep learning, with its capability for automatic feature extraction and learning complex patterns, provides a significant advantage over conventional artificial intelligence techniques.

Cite this article: Yadegari, V. , Mahmoudian, V., Sohrab, S.  (2025). Anomaly Detection in Internet of Things Equipment Traffic with the Approach of Combining Deep Learning Models. Journal of Electronic and Cyber Defens. 2025; 13(2):45-55.

DOR: <https://dor.isc.ac/dor/20.1001.1.23224347.1404.13.2.5.2>

© Author(s) retain the copyright and full publishing rights

Publisher: Imam Hossein University.



تشخیص ناهنجاری در ترافیک تجهیزات اینترنت اشیا با رویکرد ترکیب مدل‌های یادگیری عمیق

وحید یادگاری^۱، صمد سهراب^۲، وحید محمودیان^۳

^۱ دانشجوی دکتری، دانشگاه علامه طباطبائی، تهران، ایران، (نویسنده مسئول: v.yadegari58@yahoo.com)

^۲ پژوهشگر، مؤسسه آموزش عالی تعالی قم، قم، ایران (mahmoudian.vahid@gmail.com)

^۳ دانشجوی دکتری، دانشکده کامپیوتر، دانشگاه آزاد اسلامی واحد تهران شمال، تهران، ایران (samad_sohrab@yahoo.com)

مشخصات مقاله

چکیده (استایل عنوان چکیده)

تاریخچه مقاله:

نوع مقاله: علمی پژوهشی

دریافت: ۱۴۰۴/۰۲/۰۳

بازنگری: ۱۴۰۴/۰۳/۰۴

پذیرش: ۱۴۰۴/۰۳/۱۸

ارائه آنلاین: ۱۴۰۴/۰۴/۰۱

کلید واژه‌ها:

شبکه‌های عصبی کانولوشنال

شبکه‌های عصبی بازگشتی

طبقه‌بندی ترافیک شبکه

یادگیری عمیق

اینترنت اشیا

طبقه‌بندی کننده‌های ترافیک شبکه نقش حیاتی در سیستم‌های نظارت بر شبکه‌ها ایفا می‌کنند و وظیفه آن‌ها تشخیص ناهنجاری‌ها در جریان‌های شبکه‌ای بر اساس ویژگی‌های ارتباطی است. این موضوع برای مدیریت و نظارت بر شبکه‌های اینترنت اشیا نیز اهمیت ویژه‌ای دارد. در این مقاله، یک روش نوین برای طبقه‌بندی ترافیک شبکه بر اساس ترکیبی از مدل‌های یادگیری عمیق ارائه شده است که می‌تواند برای طبقه‌بندی ترافیک اینترنت اشیا استفاده شود. نتایج تجربی نشان می‌دهد که مدل ترکیبی CNN+RNN-2 با دقت ۸۳٫۵۸ درصد، عملکرد بهتری نسبت به مدل‌های منفرد و ترکیبی دیگر ارائه می‌دهد. این مدل با ترکیب ویژگی‌های محلی استخراج شده توسط شبکه‌های عصبی کانولوشنال (CNN) و تحلیل وابستگی‌های زمانی توسط شبکه‌های عصبی بازگشتی (RNN)، قادر به شناسایی الگوهای پیچیده‌تری است و دقت تشخیص را بهبود می‌بخشد. همچنین، نتایج به دست آمده نشان می‌دهد که مدل ترکیبی CNN+RNN-2 بدون نیاز به مهندسی ویژگی دستی، نتایج بهتری نسبت به روش‌های کلاسیک نظارت‌شده، نیمه نظارت‌شده و بدون نظارت ارائه می‌دهد. استفاده از یادگیری عمیق به دلیل توانایی آن در استخراج خودکار ویژگی‌ها و یادگیری الگوهای پیچیده، برتری قابل توجهی نسبت به تکنیک‌های سنتی هوش مصنوعی دارد.

استناد: یادگاری، وحید^۱، محمودیان، وحید، سهراب، صمد^۲. تشخیص ناهنجاری در ترافیک تجهیزات اینترنت اشیا با رویکرد ترکیب مدل‌های یادگیری عمیق. پدافند الکترونیک و سایبری. ۱۳ (۲): ۴۵-۵۵. (۱۴۰۴).

DOR: <https://dor.isc.ac/dor/20.1001.1.23224347.1404.13.2.5.2>

© نویسنده (گان) حق نشر و حقوق کامل انتشار را برای خود محفوظ می‌دارند.



ناشر: دانشگاه جامع امام حسین (ع).

OPEN ACCESS

۱- مقدمه

و می‌تواند به‌عنوان یک ابزار کارآمد در سیستم‌های نظارت بر شبکه‌های اینترنت اشیا به کار گرفته شود.

در این پژوهش، علاوه بر مقایسه مدل ترکیبی با مدل‌های پایه، خروجی مدل ترکیبی با سایر مدل‌های موجود در ادبیات نیز مقایسه شده است تا کارایی و دقت مدل پیشنهادی به‌طور جامع‌تری ارزیابی شود.

در ادامه، روش تحقیق و جزئیات مدل پیشنهادی، شامل فرایند پیش‌پردازش داده‌ها و معماری مدل ترکیبی CNN+RNN، ارائه می‌شود. سپس، نتایج ارزیابی و مقایسه مدل پیشنهادی با سایر مدل‌های مشابه ارائه می‌گردد. در نهایت، نتیجه‌گیری و پیشنهادهایی برای تحقیقات آینده مطرح خواهد شد.

۲- روش تحقیق

۲-۱- تعاریف پایه

۲-۱-۱- تعریف اینترنت اشیا

اینترنت اشیا یک زیرساخت متصل متشکل از اشیا، افراد، سیستم‌ها، منابع اطلاعاتی و خدمات هوشمند است که به آن‌ها امکان می‌دهد اطلاعات حاصل از دنیای فیزیکی و مجازی را با یکدیگر ترکیب کرده و با استفاده از پردازش‌ها، واکنش‌های مناسب را ایجاد کند [۴].

۲-۱-۲- شبکه‌های عصبی مصنوعی^۳

ساختار مغز انسان از شبکه‌های عصبی طبیعی متشکل از تعداد زیادی واحد ساده به نام نرون^۴ ساخته شده است. نرون‌ها سه نوع جز تشکیل‌دهنده دارند: دندریت‌ها^۵، سوما^۶ و آکسون^۷. هر نرون در داخل خودش با انجام فرایندهای شیمیایی، سیگنالی از خود تولید می‌کند که توسط آکسون نرون به دندریت نرونی دیگر منتقل می‌شود. بر اساس این سیگنال‌های ارسالی، مغز کار خاصی را انجام می‌دهد. شبکه‌های عصبی مصنوعی، یک شبیه‌سازی از ساختار مغز انسان است و بر پایه این فرضیات است:

- پردازش اطلاعات در ساختارهای ساده با تعداد زیاد، به نام نرون‌ها انجام می‌گیرد.
- سیگنال‌ها از طریق اتصالات بین نرون‌های شبکه منتقل می‌شوند.
- هر اتصال، وزن مربوط به خود را دارد که در یک شبکه عصبی این وزن‌ها در سیگنال انتقالی ضرب می‌شوند.
- هر نرون یک تابع فعال‌ساز بر روی جمع وزن‌دار سیگنال‌های ورودی اعمال می‌کند تا سیگنال خروجی را تولید نماید.

طبقه‌بندی ترافیک شبکه اولین گام برای تشخیص ناهنجاری یا سیستم تشخیص نفوذ مبتنی بر شبکه است و نقش مهمی در حوزه امنیت شبکه ایفا می‌کند. در حوزه امنیت شبکه، طبقه‌بندی ترافیک در واقع اولین قدم برای فعالیت‌هایی مانند تشخیص ناهنجاری برای شناسایی استفاده مخرب از منابع شبکه است [۱]. بدیهی است ترافیک اینترنت اشیا به دلیل تعداد زیاد و ناهمگونی دستگاه‌های متصل، چالش‌های جدیدی را برای سیستم‌های مدیریت و نظارت شبکه فعلی ایجاد خواهد کرد. شناسایی دقیق ترافیک شبکه برای اجرای مدیریت مؤثر سیاست و منابع در شبکه‌های اینترنت اشیا بسیار مهم است، زیرا شبکه باید بسته به اطلاعات ترافیک واکنش متفاوتی نشان دهد [۲].

در این پژوهش، یک روش نوین برای طبقه‌بندی ترافیک شبکه با استفاده از ترکیب شبکه‌های عصبی کانولوشنال (CNN) و شبکه‌های عصبی بازگشتی (RNN) ارائه شده است، طبقه‌بندی ارائه‌شده با استفاده از شبکه عصبی کانولوشن^۱ (CNN) داده‌های ترافیک را به‌صورت تصاویر به‌عنوان ورودی مدل داده تزیق می‌گردد. در این روش نیازی به استخراج ویژگی به‌صورت دستی نداشته و ترافیک پس از تبدیل شدن به تصاویر سیاه‌وسفید، به‌عنوان داده‌های ورودی طبقه‌بندی کننده قرار گرفت. برای آموزش مدل از ۱۵۰,۰۰۰ تصویر که هرکدام یک جریان شبکه‌ای هستند، استفاده گردید. مدل با استفاده از داده‌های آموزشی آموزش داده می‌شود. از تابع فعال‌ساز ReLU و تابع ضرر آنتروپی متقاطع استفاده می‌شود [۳]. بهینه‌سازی مدل با استفاده از الگوریتم Adam انجام می‌شود. همان‌طور که اشاره شد روش پیشنهادی یک طبقه‌بندی بر اساس مدل یادگیری عمیق است که از یک شبکه عصبی کانولوشنال تشکیل شده است. در این پژوهش، مقایسه‌ای از نتایج عملکرد برای معماری‌های مختلف ارائه می‌گردد. به‌طور خاص، از شبکه‌های عصبی بازگشتی^۲ (RNN) منفرد، شبکه‌های عصبی کانولوشنال (CNN) منفرد و ترکیب‌های مختلف شبکه‌های عصبی کانولوشنال (CNN) و شبکه‌های عصبی بازگشتی (RNN) در نظر گرفته شده است.

چالش اصلی در تشخیص ناهنجاری‌های ترافیک اینترنت اشیا، پیچیدگی و ناهمگونی داده‌هاست. مدل CNN+RNN-2 با ترکیب ویژگی‌های محلی و زمانی، به‌طور مؤثری این چالش را حل کرده است. این مدل بدون نیاز به مهندسی ویژگی دستی، با استفاده از داده‌های ترافیک تبدیل شده به تصاویر سیاه‌وسفید، قادر به شناسایی دقیق ناهنجاری‌ها است. نتایج نشان می‌دهد که مدل پیشنهادی ارائه‌شده در این مقاله نسبت به روش‌های کلاسیک نظارت شده، نیمه نظارت شده و بدون نظارت عملکرد بهتری دارد

^۳ Artificial Neural Networks

^۴ Neuron

^۵ Dendrites


^۶ Soma

^۷ Axon

^۱ Convolutional Neural Network

^۲ Recurrent Neural Network

مشاهده شده را در خود ضبط می کنند. معماری یک شبکه عصبی بازگشتی در شکل (۲) قابل مشاهده است.



شکل (۲): معماری یک شبکه بازگشتی سه لایه [۹]


۴-۱-۲- شبکه های عصبی کانولوشنال (CNN)

شبکه های عصبی کانولوشنال که از آن ها با عنوان شبکه های عصبی پیچشی نیز یاد می شود، نوع خاصی از شبکه های عصبی برای پردازش داده هایی می باشند که دارای یک ساختار مکانی مشخصی هستند [۱۰]. شبکه های عصبی کانولوشنال (CNN) به دلیل توانایی بالای خود در استخراج ویژگی های محلی از داده های تصویری، برای پردازش داده های ساختاریافته مانند تصاویر و ترافیک شبکه بسیار مناسب هستند [۱۱]. این شبکه ها از لایه های کانولوشن برای استخراج ویژگی های تصویر استفاده کرده و برای شناسایی الگوها و اشیاء در تصویر به کار می روند. با استفاده از این شبکه ها، شبکه های عمیق این توانایی را خواهند داشت که داده های مکانی ساختاریافته همانند تصویر و متن را یاد بگیرند؛ این شبکه ها از لایه های کانولوشن برای استخراج ویژگی های تصویر استفاده کرده و برای شناسایی الگوها و اشیاء در تصویر به کار می روند [۱۲]. شبکه های پیچشی به بیانی ساده، شبکه های عصبی هستند که از پیچش^۱ به جای ضرب ماتریس عمومی، حداقل در یکی از لایه های خود استفاده می کنند. شبکه های پیچشی در پردازش تصویر کاربردهای زیادی دارند و در پردازش تصویر عملیات روی پیکسل ها انجام می گیرد [۱۳].

ساختار کلی یک شبکه پیچشی از سه لایه تشکیل شده که عبارتند از: لایه^۲ پیچش^۲، لایه ادغام^۳ و لایه تماماً متصل^۴. لایه پیچش: در این لایه از طریق عملگر ریاضی پیچش، با اعمال روی فیلترها و ماتریس ورودی، ویژگی ها یاد گرفته می شوند. شکل (۳) نمایشی از عملگر پیچش را در یک شبکه عصبی پیچشی نشان می دهد. همان طور که مشاهده می شود ماتریس نقشه ویژگی^۵ 3×4 با اعمال عملگر پیچش با ماتریس هسته ای^۵ در ابعاد 2×2 یک ضرب نقطه به نقطه انجام داده و در پایان خروجی با ابعاد 2×3 داشته است [۷].

با توجه به این فرضیات، الگوی اتصال بین نرون های مختلف شبکه را معماری شبکه و روش تعیین وزن ها بر اتصالات را الگوریتم آموزش شبکه گویند [۱۵]. یک شبکه عصبی از کنار هم قراردادن چندین نرون تشکیل یک لایه را می دهد.

در حالت کلی، معماری یک شبکه عصبی از ۳ لایه تشکیل شده است که عبارتند از: ورود، لایه پنهان و لایه خروج که در شکل (۱) آمده است.



شکل (۱): مدل عمومی از یک شبکه عصبی [۶]

لایه ورودی، اطلاعات را دریافت کرده و یک یا چند لایه پنهان، عمل پردازش را انجام داده و لایه خروجی نتایج را نشان می دهد. با افزایش تعداد لایه های پنهان، شبکه به سمت عمیق شدن سوق پیدا کرده که توانایی حل مسائل پیچیده تر را نسبت به همتایان کم عمق خود دارا است.

۴-۱-۳- شبکه عصبی بازگشتی (RNN)

شبکه های عصبی بازگشتی (RNN) به دلیل داشتن حافظه داخلی، برای پردازش داده های متوالی مانند سری های زمانی و ترافیک شبکه مناسب هستند. این شبکه ها قادر به یادگیری وابستگی های زمانی در داده ها هستند و می توانند الگوهای پیچیده تری را شناسایی کنند. در یک شبکه عصبی معمولی، ورودی ها و خروجی ها با یکدیگر ارتباطی ندارند، اما در بعضی کاربردها مثل پیش بینی کلمه بعدی در یک متن و یا ترجمه آن، نیاز به دانستن ارتباط بین کلمات است که در غیر این صورت، شبکه درست عمل نخواهد کرد. شبکه های عصبی بازگشتی، برای کار با داده های متوالی طراحی شده اند. داده ها در شبکه عصبی بازگشتی به صورت مجموعه ای متوالی از بردارها پردازش می شوند [۷] و در واحدهای پنهان خود دارای یک بردار حالت هستند، که به طور ضمنی حاوی اطلاعاتی در مورد تاریخچه تمامی عناصر متن هستند که به صورت دنباله ای از کلمات هستند [۸]، به طور خلاصه می توان گفت که این شبکه ها در ساختار درونی خود دارای نوعی حافظه بوده که اطلاعات

¹ Convolution

² Convolution Layer

³ Pooling Layer

⁴ Fully Connected Layer

⁵ Kernel

مجموعه داده‌های دیگر از پژوهش‌های مشابه، شامل ترافیک شبکه دستگاه‌های اینترنت اشیا که از طریق دروازه^۴ با استفاده از نرم‌افزارهای Wireshark و dumpcap در شش نوع آزمایش مختلف وارد می‌شوند، گردآوری شده است. این مجموعه داده از دسته‌های مختلف فعالیت دستگاه‌ها از جمله قدرت^۵، زمان بیکار^۶، فعل‌وانفعال^۷، سناریوها^۸، فعال^۹ و حملات^{۱۰} تشکیل شده است. بخش فعل‌وانفعال شامل ترافیک حالت عادی تجهیزات بوده و یکی از کلاس‌ها بوده که با عنوان کلاس Normal برچسب‌گذاری شده و بخش حملات نیز به‌عنوان ترافیک موردحمله از نوع سیل‌آسا^{۱۱} و با عنوان کلاس Flood برچسب‌گذاری گردیده است. همان‌طور که در شکل (۵) قابل مشاهده است، ۸۰ درصد از نمونه‌ها را به‌عنوان مجموعه آموزشی^{۱۲}، ۱۰ درصد به‌عنوان آزمون^{۱۳} و ۱۰ درصد دیگر به‌عنوان ارزیابی^{۱۴} مدل استفاده شده است. در جدول (۱) تعداد نمونه‌ها با جزئیات بیشتر قابل مشاهده است.



شکل (۵): نمودار توزیع داده‌ها

جدول (۱): تعداد نمونه‌های مجموعه داده

عنوان	تعداد	درصد
تعداد کل نمونه‌های آموزشی	۱۲۰ هزار نمونه	۸۰٪
تعداد کل نمونه‌های آزمون	۱۵ هزار نمونه	۱۰٪
تعداد کل نمونه‌های ارزیابی	۱۵ هزار نمونه	۱۰٪

۲-۳- پیش‌پردازش^{۱۵}

طبقه‌بندی ترافیک اولین گام برای تشخیص ناهنجاری شبکه یا سیستم تشخیص نفوذ مبتنی بر شبکه است و نقش مهمی در حوزه امنیت شبکه ایفا می‌کند. ترافیک مشاهده شده در یک سیستم شبکه را می‌توان به‌طور عمده به دو نوع تقسیم کرد:

⁴ Gateway

⁵ Power

⁶ Idle

⁷ Interactions

⁸ Scenarios

⁹ Active

¹⁰ Attack

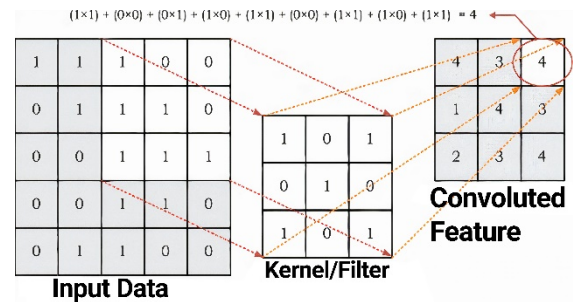
¹¹ Flood

¹² Train

¹³ Test

¹⁴ Validation

¹⁵ Preprocess



شکل (۳): عملیات پیچش [۶]

لایه ادغام: این لایه وظیفه کاهش ابعاد و تعداد پارامترهای شبکه را انجام می‌دهد. ادغام حداکثری^۱ و ادغام میانگین^۲ دو عملگر اصلی این لایه هستند. ادغام حداکثری، بارزترین ویژگی‌ها (بیشترین مقادیر موجود در هر پنجره انتخاب شده) را از نقشه ویژگی استخراج می‌کند. برای مثال در یک تصویر، لبه‌ها را کشف می‌کند. ادغام میانگین مقادیر میانگین پنجره انتخاب شده را استخراج می‌کند. شکل (۴) تفاوت بین ادغام حداکثری و ادغام میانگین را نشان می‌دهد. در شکل برای هر نقشه ویژگی ۴×۴ یک پنجره ۲×۲ اعمال شده، مشاهده می‌گردد که در ادغام حداکثری بزرگ‌ترین مقادیر و در ادغام میانگین، مقادیر میانگین این پنجره‌های انتخاب شده محاسبه می‌شود.

Max pooling

12	20	30	0
8	12	2	0
34	70	37	4
112	100	25	12

20	30
112	37

Avg Pooling

13	8
79	20

شکل (۴): تفاوت ادغام حداکثری و میانگین [۶]

لایه متصل کامل: عملکرد این لایه همانند یک شبکه پرسپترون چندلایه^۳ است که در آن، نرون‌های یک‌لایه به نرون‌های لایه بعدی به‌طور کامل متصل بوده و مشخص می‌کند که کدام ویژگی، بیشترین ارتباط را با یک کلاس خاص دارد. این لایه همان جایی است که طبقه‌بندی در آن اتفاق می‌افتد.

۲-۲- مجموعه داده

برای ارزیابی مدل ترکیبی، از مجموعه داده‌های مختلفی استفاده شده است که شامل مجموعه داده CIC IoT 2022 [۱۳] و

¹ Max Pooling

² Average Pooling

³ Multilayer Perceptron

تبدیل فایل‌های ترافیک به CSV را دارد، درواقع nPrint یک بازنمایی استاندارد از داده‌های ترافیک شبکه است که به‌طور مستقیم با الگوریتم‌های یادگیری ماشین قابل استفاده بوده و جایگزین مهندسی ویژگی^۷ برای طیف گسترده‌ای از مشکلات تحلیل ترافیک است. مطابق تصاویر قابل مشاهده در شکل (۷)، رکوردهای موجود در فایل‌های CSV به تصاویر سیاه‌وسفید در ابعاد ۳۲ در ۳۲ پیکسل تبدیل می‌شوند تا به‌عنوان ورودی به مدل طبقه‌بندی کانولوشن وارد شده و طبقه‌بندی روی تصاویر انجام شود.

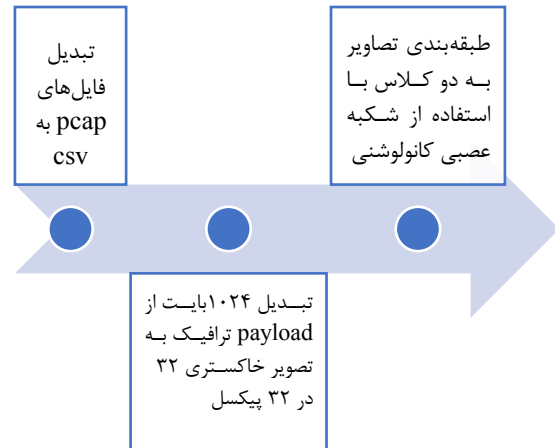


شکل (۷): نمونه تصاویر ۳۲ در ۳۲ پیکسل

۴-۲- مدل پیشنهادی

برای مقایسه مدل ترکیبی، از مدل‌های مختلفی که در پژوهش‌های مشابه استفاده شده‌اند، بهره‌برداری شده است. این مدل‌ها شامل شبکه‌های عصبی کانولوشنل منفرد (CNN)، شبکه‌های عصبی بازگشتی منفرد (RNN)، و مدل‌های ترکیبی دیگر مانند CNN+LSTM و CNN+GRU هستند. مدلی که بهترین عملکرد و دقت تشخیص را داشت ترکیبی از شبکه عصبی کانولوشنل (CNN) [۱۶] و شبکه عصبی بازگشتی (RNN) [۱۷] بوده است. ترکیب شبکه‌های عصبی کانولوشنل (CNN) و شبکه‌های عصبی بازگشتی (RNN) این امکان را می‌دهد که از مزایای هر دو نوع شبکه بهره‌مند شد. شبکه‌های عصبی کانولوشنل ویژگی‌های محلی را استخراج می‌کنند و سپس این ویژگی‌ها به شبکه‌های عصبی بازگشتی ارسال می‌شوند تا ارتباطات زمانی بین ویژگی‌ها تحلیل شوند. این ترکیب باعث می‌شود که مدل ما بتواند الگوهای پیچیده‌تری را شناسایی کند و دقت تشخیص را افزایش دهد. در این قسمت تمامی مدل‌هایی که مورد بررسی قرار گرفته‌اند، بررسی خواهد شد. اولین مدل، یک RNN ساده است. به‌طور خاص، از یک نوع RNN به نام LSTM^۸ [۱۷] استفاده شده که آموزش آن آسان‌تر بوده و مشکل محوشدگی گرادیان نیز حل شده است، یک LSTM با ماتریسی از مقادیر با دو بعد، آموزش داده می‌شود؛ بعد زمانی و بردار ویژگی‌ها. LSTM یک شبکه عصبی (سلول) را با بردارهای ویژگی متوالی زمانی و دو بردار اضافی مرتبط باحالت‌های پنهان داخلی و سلولی آن تکرار می‌کند. حالت پنهان نهایی سلول با مقدار خروجی مطابقت دارد؛ بنابراین، بعد از خروجی یک‌لایه LSTM با اندازه حالت پنهان داخلی آن (واحدهای LSTM) برابر است. در مدل شکل (۸) در انتها چندین لایه کاملاً متصل اضافه می‌گردد.

ترافیک عادی^۱ و ترافیک مخرب^۲ ترافیک غیرضروری از منابع مخرب می‌تواند مشکلات زیادی مانند سیل پهنای باند شبکه^۳، حملات منع سرویس^۴ و مسدود کردن گیرنده ایجاد کند، بنابراین تشخیص چنین ترافیک ناخواسته و طبقه‌بندی ترافیک موردنیاز بسیار مهم است. در شکل (۶) مراحل انجام پیش‌پردازش قابل مشاهده است.



شکل (۶): مراحل پیش‌پردازش

پیش‌پردازش مجموعه داده مورد استفاده [۱۴] شامل فرایند تبدیل ترافیک خام که از شبکه اینترنت اشیاء که با کمک نرم‌افزار وایرشارک^۵ جمع‌آوری شده است. داده‌ها به سه دسته تقسیم شده‌اند: ۸۰٪ برای آموزش، ۱۰٪ برای آزمون، و ۱۰٪ برای ارزیابی مدل که به تصاویر سیاه‌وسفید تبدیل شده‌اند. از این تصاویر برای طبقه‌بندی ترافیک شبکه و ورودی مدل استفاده می‌شود [۱۵].

از آنجایی که ترافیک خام شبکه‌ها معمولاً در قالب فایل‌های pcap یا pcapng ذخیره می‌شود، نمی‌توان آن را مستقیماً به شبکه عصبی وارد کرد و مدل شبکه عصبی مستلزم یکنواخت بودن طول داده‌های ورودی است، اما طول ترافیک خام شبکه یکنواخت نیست؛ بنابراین، برای تبدیل ترافیک خام شبکه به فرمت تصویر سیاه‌وسفید که به‌عنوان ورودی مدل استفاده می‌شود، نیاز به پیش‌پردازش داده‌ها است و سپس روش‌های مربوطه برای آموزش، آزمون و ارزیابی مدل برای دستیابی به هدف طبقه‌بندی ترافیک، فراخوانی می‌شود. فرایند پیش‌پردازش عمده‌تاً شامل تقسیم ترافیک، تمیز کردن ترافیک، ترکیب مجدد ترافیک و تبدیل ترافیک است.

همان‌طور که اشاره شد فایل‌های ترافیک از نوع pcap هستند که ابتدا باید به CSV^۶ تبدیل شده و فیلدهای مؤثر آن استخراج گردد. برای انکار از نرم‌افزار nPrint [۱۴] استفاده شده که وظیفه

^۱ Normal

^۲ Malign

^۳ Flood

^۴ Denial of Service


^۵ Wireshark

^۶ Comma-Separated Values

^۷ Feature Engineering

^۸ Long Short Term Memory (LSTM)


در نهایت، مدل معرفی شده در شکل (۱۰) مدلی از ترکیب یک CNN و دو LSTM ایجاد شد. هنگامی که چندین لایه LSTM به هم متصل می‌شوند، علاوه بر این، برای انواع مختلف لایه‌هایی که قبلاً ارائه شد، از چند لایه اضافی استفاده می‌شود: نرمال‌سازی دسته‌ای، حداکثر ادغام و لایه‌های حذف تصادفی یک‌لایه با حذف (تنظیم روی صفر) درصدی از خروجی‌ها از لایه قبلی، منظم سازی^۲ (تعمیم نتایج برای داده‌های دیده نشده) را فراهم می‌کند [۱۲]. این اقدام ظاهراً بی‌معنی، شبکه را وادار کرده که بیش‌از حد بر هیچ ورودی خاصی تکیه نکند، با بیش‌برازش^۳ مقابله کند و تعمیم‌سازی را بهبود بخشد. ادغام حداکثری^۴ [۱۹] نوعی لایه کانولوشن بوده که تفاوت در فیلتر استفاده شده است. در ادغام حداکثری از فیلتر انتخاب مقادیر حداکثر استفاده گردیده که بیشترین مقدار ناحیه تصویری را که فیلتر روی آن اعمال می‌شود را انتخاب می‌کند. اندازه فضای خروجی و تعداد ویژگی‌ها و پیچیدگی محاسباتی شبکه را کاهش می‌دهد. مشابه لایه حذف تصادفی، یک لایه ادغام حداکثری منظم‌سازی را فراهم می‌کند. نرمال‌سازی دسته‌ای همگرایی آموزش را سریع‌تر کرده و می‌تواند نتایج عملکرد را بهبود بخشد [۲۰]. این کار با نرمال‌سازی در زمان آموزش، هر ویژگی در سطح دسته‌ای و مقیاس بندی مجدد بعدی، با در نظر گرفتن کل مجموعه داده آموزشی انجام می‌شود. میانگین و واریانس آموزش داده شده، جایگزین آن‌هایی می‌شود که در سطح دسته‌ای احصاء گردیده‌اند.



شکل (۱۰): مدل یادگیری عمیق (CNN) و دو لایه LSTM [۱۸]


۳- ارزیابی

روش پیشنهادی، ترکیبی از شبکه‌های عصبی کانولوشنال (CNN) و دو شبکه عصبی بازگشتی (RNN) است که به‌طور خاص برای تشخیص ناهنجاری‌های ترافیک اینترنت اشیا طراحی شده است. شبکه‌های عصبی کانولوشنال به دلیل توانایی بالای خود در استخراج ویژگی‌های محلی از داده‌های تصویری، برای پردازش داده‌های ساختاریافته مانند تصاویر و ترافیک شبکه بسیار مناسب هستند. از سوی دیگر، شبکه‌های عصبی بازگشتی به دلیل داشتن حافظه داخلی، برای پردازش داده‌های متوالی مانند سری‌های زمانی و ترافیک شبکه مناسب هستند؛ بنابراین



شکل (۸): مدل یادگیری عمیق RNN [۱۸]

در شکل (۹) یک شبکه CNN قابل مشاهده است. CNNها ابتدا برای پردازش تصویر به‌عنوان یک مدل الهام گرفته شده از بیولوژیک برای انجام طبقه‌بندی تصویر استفاده می‌شدند، جایی که مهندسی ویژگی به‌طور خودکار توسط شبکه به لطف عملکرد هسته (فیلتر) انجام می‌شد که الگوهای ثابت مکان را از تصویر استخراج می‌کند. متصل کردن چندین لایه کانولوشن امکان استخراج خودکار ویژگی‌های پیچیده را فراهم می‌کند. از این روش پردازش تصویر برای اعمال تکنیک در مجموعه داده‌های بسیار متفاوت استفاده شده است. برای انجام این کار، ماتریس تشکیل شده توسط سری‌های زمانی، بردارهای ویژگی را به‌عنوان یک تصویر در نظر می‌گیرد. پیکسل‌های تصویر به‌صورت محلی در ارتباط هستند. به‌طور مشابه، بردارهای ویژگی مرتبط با شکاف‌های زمانی متوالی، یک رفتار محلی همبسته را نشان می‌دهند که اجازه این قیاس را اتخاذ می‌کند. هر لایه کانولوشن یک آرایه چندبعدی^۱ تولید می‌کند که در آن ابعاد تصویر کاهش می‌یابد، اما در همان زمان، یک بعد جدید تولید می‌شود که اندازه این بعد برابر با تعداد فیلترهای اعمال شده بر روی تصویر است. لایه‌های متوالی کانولوشن باعث کاهش بیشتر ابعاد تصویر و افزایش اندازه ابعاد جدید تولید شده می‌شود. برای تکمیل مدل، لازم است تنسور را به بردار تبدیل کرد که می‌تواند ورودی لایه‌های کاملاً متصل نهایی باشد. برای انجام این تبدیل می‌توان یکدست تانسور ساده انجام داد.



شکل (۹): مدل یادگیری عمیق (CNN) [۱۶]

^۲ Regularization

^۳ Overfitting

^۴ Max Pooling

^۱ Tensor

ما کارآمد نبوده‌اند بنابراین هر کدام از این مدل‌ها به‌تنهایی قادر به تشخیص ناهنجاری‌ها هستند، اما دقت تشخیص آن‌ها نسبت به مدل ترکیبی ارائه شده در این مقاله کمتر است؛ زیرا نتایج ارزیابی همانند جدول شماره ۴ است.

جدول (۲): جزئیات مدل‌های شبکه عصبی برای طبقه‌بندی ترافیک

نام	جزئیات معماری	مدل
CNN+RNN-2	Conv(32,4,2,1,V)-BN-Conv(64,4,2,1,V)-BN-LSTM(100)-DR(0.2)-FC(100)-DR(0.4)-FC(108)	مدل ترکیبی از شبکه عصبی کانولوشنال (CNN) و شبکه عصبی بازگشتی (RNN)
CNN-1	Conv(32,4,2,1,V)-MaxPool(3,2,1,V)-BN-Conv(64,4,2,1,V)-MaxPool(3,2,1,V)-BN-FC(200)-FC(108)	شبکه عصبی کانولوشنال (CNN)
RNN-1	LSTM(100)-FC(100)-FC(108)	شبکه عصبی بازگشتی (RNN)
CNN+LSTM	Conv(32,4,2,1,V)-BN-Conv(64,4,2,1,V)-BN-LSTM(100)-DR(0.2)-FC(100)-DR(0.4)-FC(108)	مدل ترکیبی از شبکه عصبی کانولوشنال (CNN) و شبکه عصبی بازگشتی (LSTM)
CNN+GRU	Conv(32,4,2,1,V)-BN-Conv(64,4,2,1,V)-BN-GRU(100)-DR(0.2)-FC(100)-DR(0.4)-FC(108)	مدل ترکیبی از شبکه عصبی کانولوشنال (CNN) و شبکه عصبی بازگشتی [۲۱]

جدول (۳): معیارهای ارزیابی مدل‌ها

مدل	دقت	امتیاز F1	صحت	فراخوان
CNN+RNN-2	۰.۸۳۵۸	۰.۸۱۷۰	۰.۸۲۷۹	۰.۸۳۸۸
CNN-1	۰.۸۱۰۲	۰.۷۸۰۹	۰.۷۸۴۳	۰.۸۱۰۲
RNN-1	۰.۷۸۵۵	۰.۷۴۳۳	۰.۷۵۰۰	۰.۷۸۵۵
CNN+LSTM	۰.۸۲۵۰	۰.۸۰۵۰	۰.۸۱۵۰	۰.۸۳۰۰
CNN+GRU	۰.۸۲۰۰	۰.۸۰۰۰	۰.۸۱۰۰	۰.۸۲۵۰

لایه‌های کانولوشنال ویژگی‌های محلی را استخراج می‌کنند و سپس این ویژگی‌ها به لایه‌های بازگشتی ارسال می‌شوند تا ارتباطات زمانی بین ویژگی‌ها تحلیل شوند. با بررسی نتایج به‌دست‌آمده از CNN-1 منفرد، CNN+RNN-2 بهترین نتایج را برای مدل CNN+RNN-2 ارائه می‌دهد که در معادله‌های (۱ تا ۴) نحوه محاسبه معیارهای ارزیابی قابل مشاهده است. در تمامی مراحل آموزش مدل، آموزش با تعداد دوره^۱ بین ۶۰ تا ۹۰ انجام گردید که ۱۰ دوره آخر تابع ضرر^۲ را بهبود بخشیده که با توقف زود هنگام انجام شد. برای تابع فعال‌ساز^۳ از تابع یک‌سوساز خطی^۴ (ReLU) استفاده گردیده است و در آخرین لایه از تابع فعال‌ساز Softmax با تابع ضرر آنتروپی متقاطع^۵ و بهینه‌ساز با گرادینت کاهشی نزولی^۶ (SGD) و آدام^۷ (Adam) انجام شد. جدول (۲) جزئیات معماری مدل شبکه‌های عصبی را نشان داده شده است.

$$Accuracy = \frac{TP+TN}{TP+FN+TN+FP} \quad (۱)$$

$$Precision = \frac{TP}{TP+FP} \quad (۲)$$

$$Recall = \frac{TP}{TP+FN} \quad (۳)$$

$$F1 - Score = \frac{2 \times Precision \times recall}{Precision + recall} \quad (۴)$$

مدل با استفاده از داده‌های آزمون و ارزیابی می‌شود. جدول (۳) معیارهای ارزیابی مدل‌ها که شامل دقت^۸، امتیاز F1^۹، صحت^{۱۰} و فراخوان^{۱۱} را نشان می‌دهد.

۴- مقایسه با تحقیقات مشابه

در پژوهش حاضر، مدل ترکیبی CNN+RNN-2 با سایر مدل‌های ارائه شده در ادبیات مقایسه گردیده است. برای مثال، در مقاله لی و وانگ [۲۲]، تشخیص بی‌درنگ ترافیک شبکه بر اساس شبکه‌های عصبی کانولوشنال (CNN) منفرد بررسی شده است. این مدل‌ها به دلیل توانایی در استخراج ویژگی‌های مکانی، در تشخیص ناهنجاری‌ها موفق بوده‌اند، اما به دلیل عدم تحلیل وابستگی‌های زمانی، در مقایسه با مدل پیشنهادی ما، دقت کمتری داشته‌اند. در مقابل، پژوهش دوان و همکاران [۲۳] از طبقه‌بندی کننده‌های باقیمانده چند مقیاسی استفاده کرده‌اند که بر پایه شبکه‌های عصبی بازگشتی (RNN) منفرد طراحی شده است. اگرچه این مدل‌ها قادر به تشخیص وابستگی‌های زمانی هستند، اما در استخراج ویژگی‌های محلی به‌اندازه مدل ترکیبی

¹ Epoch

² Loss Function

³ Activation Function

⁴ Rectified Linear Unit (ReLU)

⁵ Cross Entropy Loss

⁶ Stochastic Gradient Descent

⁷ Adam

⁸ Accuracy

⁹ F1-Score

¹⁰ Precision

¹¹ Recall

جدول (۴): نتایج ارزیابی مدل‌های مقاله‌های نمونه

فراخوان	صحت	امتیاز F1	دقت	مدل	ارجاع
-----	۰.۹۸۵	۰.۹۸۴	۰.۹۸۵	<i>Flow Transformer</i>	[۲۴]
۰.۹۹۹۳	۰.۹۹۹۳	۰.۹۹۹۳	۰.۹۹۹۳	<i>FFNN</i>	[۲۵]
۰.۹۹۸۹	۰.۹۹۸۹	۰.۹۹۸۹	۰.۹۹۸۹	<i>LSTM</i>	
۰.۹۶۴۲	۰.۹۶۴۲	۰.۹۶۴۲	۰.۹۶۴۲	<i>RandNN</i>	
۰.۸۳۷۸	۰.۸۱۷۰	۰.۸۳۷۹	۰.۸۳۵۸	<i>CNN+RNN-2</i>	پیشنهادی
۰.۸۱۰۲	۰.۷۸۴۳	۰.۷۸۰۹	۰.۸۱۰۲	<i>CNN-1</i>	تست مدل
۰.۷۸۵۵	۰.۷۵۰۰	۰.۷۴۳۳	۰.۷۸۵۵	<i>RNN-1</i>	تست مدل
۰.۸۳۰۰	۰.۸۱۵۰	۰.۸۰۵۰	۰.۸۲۵۰	<i>CNN+LSTM</i>	تست مدل
۰.۸۲۵۰	۰.۸۱۰۰	۰.۸۰۰۰	۰.۸۲۰۰	<i>CNN+GRU</i>	تست مدل

مزیت اصلی مدل *CNN+RNN-2* در توانایی ترکیب ویژگی‌های محلی و زمانی است که از طریق شبکه‌های کانولوشنال و بازگشتی به دست می‌آید. این مدل به‌طور مؤثری الگوهای پیچیده‌تری را شناسایی می‌کند و در تمامی معیارهای ارزیابی مانند دقت، صحت، فراخوان و امتیاز F1 عملکرد بهتری نسبت به مدل‌های منفرد دارد. به‌طور خاص، مدل پیشنهادی، دقت ۸۳.۵۸٪ و امتیاز $F1$ 81.70% را به دست آورده است که به‌طور معناداری بالاتر از مدل‌های منفرد ذکر شده در پژوهش‌های مشابه است.

تحلیل‌های آماری انجام‌شده نشان می‌دهد که بهبودهای حاصل‌شده در مدل پیشنهادی به‌صورت آماری معنادار هستند. آزمون‌های آماری مختلف تأیید می‌کنند که تفاوت‌های مشاهده‌شده در عملکرد مدل‌ها به دلیل ویژگی‌های ذاتی مدل

ترکیبی ما است و نه به دلیل تغییرات تصادفی در داده‌ها. این تحلیل‌ها نشان می‌دهند که مدل *CNN+RNN-2* از نظر تئوری و عملی برتری قابل‌توجهی نسبت به مدل‌های موجود دارد و می‌تواند به‌عنوان یک روش مؤثر برای طبقه‌بندی ترافیک اینترنت اشیا مورد استفاده قرار گیرد.

۵- نتیجه‌گیری

ترکیب شبکه عصب کانولوشنال (RNN) و شبکه‌های عصبی بازگشتی (RNN) در مدل *CNN+RNN-2*، توانسته است به‌طور مؤثری ناهنجاری‌های ترافیک اینترنت اشیا را با دقت بالا تشخیص دهد. این مدل با ترکیب ویژگی‌های محلی استخراج‌شده توسط CNN و تحلیل وابستگی‌های زمانی توسط RNN، قادر به شناسایی الگوهای پیچیده‌تری است و باعث بهبود عملکرد در معیارهای ارزیابی مانند دقت، صحت، فراخوان و امتیاز F1 شده است. به‌طور خاص، این مدل توانست در مجموعه داده‌های مختلف از جمله CIC IoT 2022، عملکرد برتری نسبت به مدل‌های منفرد مانند *CNN-1* و *RNN-1* و همچنین مدل‌های ترکیبی دیگر مانند *CNN+LSTM* و *CNN+GRU* نشان دهد. [۲۶] و [۲۷]. تحلیل‌های آماری انجام‌شده بر روی نتایج نشان‌دهنده‌ی بهبودهای معنادار آماری در عملکرد مدل پیشنهادی در مقایسه با سایر مدل‌های موجود است. آزمون‌های آماری مختلف تأیید کرده‌اند که این بهبودها ناشی از ویژگی‌های ذاتی مدل ترکیبی ارائه شده در این پژوهش است. این نتایج نشان می‌دهند که روش پیشنهادی می‌تواند به‌عنوان یک ابزار کارآمد و مؤثر برای طبقه‌بندی ترافیک شبکه‌های اینترنت اشیا به کار گرفته شود، به‌ویژه در شرایطی که داده‌ها به‌صورت متوالی و با پیچیدگی بالا هستند.

در نهایت، مزیت دیگر مدل پیشنهادی این است که بدون نیاز به مهندسی ویژگی دستی، و تنها با تعداد کمی از ویژگی‌ها، به نتایج مطلوب دست‌یافته است. ویژگی‌های مؤثر به‌صورت خودکار توسط لایه‌های کانولوشنال استخراج می‌شوند و نیازی به تکیه بر آدرس‌های IP یا داده‌های اصلی نیست که احتمالاً محرمانه یا رمزگذاری شده هستند. این امر باعث می‌شود که مدل پیشنهادی در مواجهه با ترافیک ناشناخته و داده‌های جدید، قابلیت تعمیم بهتری داشته باشد و بتواند به‌عنوان یک راهکار مؤثر در سیستم‌های نظارت بر شبکه‌های اینترنت اشیا استفاده شود.

۶- پیشنهادها برای تحقیقات آینده

۱. بهبود مدل: تحقیقات آینده می‌تواند بر روی بهبود مدل *CNN+RNN-2* با استفاده از تکنیک‌های پیشرفته‌تر یادگیری عمیق و بهینه‌سازی تمرکز کند.

[11] N. Mahmoodi, H. Shirazi, M. Fakhredanesh, and K. Dadashtabar Ahmadi, "Improving the performance of the convolutional neural network using incremental weight loss function to deal with class imbalanced data," *Electronic and Cyber Defense*, vol. 11, no. 4, pp. 34-17, 2024. (persian) <https://dor.isc.ac/dor/20.1001.1.23.224347.1402.11.4.2.9>

[12] M. Toğaçar, B. Ergen, and Z. Cömert, "Detection of lung cancer on chest CT images using minimum redundancy maximum relevance feature selection method with convolutional neural networks," *Biocybernetics and Biomedical Engineering*, vol. 40, no. 1, pp. 23-39, 2020.

[13] M. Hassani and E. Sarmadi, "A recommender system using a support vector machine and the TOPSIS model in the Internet of Things," *Electronic and Cyber Defense*, vol. 11, no. 4, pp. 61-73, 2024. (persian) <https://dor.isc.ac/dor/20.1001.1.23.224347.1402.11.4.5.2>

[14] P. Pietrzak, P. Pietrzak, and M. Wolkiewicz, "Microcontroller-Based Embedded System for the Diagnosis of Stator Winding Faults and Unbalanced Supply Voltage of the Induction Motors," *Energies*, vol. 17, no. 2, p. 387, 2024.

[15] H. Tanha and M. Abbasi, "Identify malicious traffic on IoT infrastructure using neural networks and deep learning," *Electronic and Cyber Defense*, vol. 11, no. 2, pp. 1-13, 2023. (persian) <https://dor.isc.ac/dor/20.1001.1.23.224347.1402.11.2.1.4>

[16] I. AlMohimeed, "Epilepsy Seizure Identification Using the One Dimensional Convolutional Neural Network from Electroencephalogram Signals," in *2024 2nd International Conference on Networking and Communications (ICNWC)*, 2024: IEEE, pp. 1-6.

[17] W. Hardy, L. Chen, S. Hou, Y. Ye, and X. Li, "DL4MD: A deep learning framework for intelligent malware detection," in *Proceedings of the International Conference on Data Science (ICDATA)*, 2016: The Steering Committee of The World Congress in Computer Science, Computer ..., p. 61.

[18] Y. Zhang, Q. Huang, W. Sun, F. Chen, D. Lin, and F. Chen, "Research on lung sound classification model based on dual-channel CNN-LSTM algorithm," *Biomedical Signal Processing and Contr*

[19] *ol*, vol. 94, p. 106257, 2024.

[20] A. Qayyum, S. M. Anwar, M. Awais, and M. Majid, "Medical image retrieval using deep convolutional neural network," *Neurocomputing*, vol. 266, pp. 8-20, 2017.

[21] M. Mohammadrezaei, "Detecting Fake Accounts in Social Networks Using Principal Components Analysis and Kernel Density Estimation Algorithm (A Case Study on the Twitter Social Network)," *Electronic and Cyber Defense*, vol. 9, no. 3, pp. 109-123,

۲. گسترش به مجموعه داده‌های جدید: بررسی عملکرد مدل بر روی مجموعه داده‌های جدید و متنوع‌تر می‌تواند به تعمیم‌پذیری و کارایی بیشتر مدل کمک کند.

۳. کاربردهای عملی: توسعه کاربردهای عملی مدل در سیستم‌های نظارت بر شبکه‌های اینترنت اشیا و بررسی تأثیر آن بر بهبود امنیت و مدیریت شبکه.

۷- مراجع

- [1] B. Kaur and V. Dhir, "Internet of things: Vision, challenges and future scope," *International Journal of Advanced Research in Computer Science*, vol. 8, no. 4, pp. 40-43, 2017.
- [2] T. Fougeroux, A. Douyere, P. O. L. de Peslouan, N. M. Murad, S. Oree, and J.-L. Dubard, "Circuit Model of Rectennas Array for Estimating Microwave Energy Harvesting in Presence of Mutual Coupling Between Elements," in *10ième Journées Nationales sur la Récupération et le Stockage de l'Energie (JNRSE 2021)*, 2021, p. 2.
- [3] M. Lee, "Mathematical analysis and performance evaluation of the gelu activation function in deep learning," *Journal of Mathematics*, vol. 2023, no. 1, p. 4229924, 2023.
- [4] F. Masoodi and B. A. Pandow, "Internet of things: Financial perspective and its associated security concerns," *International Journal of Electronic Finance*, vol. 10, no. 3, pp. 145-158, 2021.
- [5] A. Sivanathan, "IoT behavioral monitoring via network traffic analysis," *arXiv preprint arXiv:2001.10632*, 2020.
- [6] X. Zhao, L. Wang, Y. Zhang, X. Han, M. Deveci, and M. Parmar, "A review of convolutional neural networks in computer vision," *Artificial Intelligence Review*, vol. 57, no. 4, p. 99, 2024.
- [7] A. Kumar and T. J. Lim, "Early detection of Mirai-like IoT bots in large-scale networks through sub-sampled packet traffic analysis," in *Advances in Information and Communication: Proceedings of the 2019 Future of Information and Communication Conference (FICC)*, Volume 2, 2020: Springer, pp. 847-867.
- [8] B. Wang, Y. Dou, Y. Sang, Y. Zhang, and J. Huang, "IoTCMal: Towards a hybrid IoT honeypot for capturing and analyzing malware," in *ICC 2020-2020 IEEE International Conference on Communications (ICC)*, 2020: IEEE, pp. 1-7.
- [9] E. Nichani, A. Damian, and J. D. Lee, "Provable guarantees for nonlinear feature learning in three-layer neural networks," *Advances in Neural Information Processing Systems*, vol. 36, 2024.
- [10] A. E. Omolara, A. Alabdulatif, O. I. Abiodun, M. Alawida, A. Alabdulatif, and H. Arshad, "The internet of things security: A survey encompassing unexplored areas and new insights," *Computers & Security*, vol. 112, p. 102494, 2022.

- [26] S. A. Bakhsh, M. A. Khan, F. Ahmed, M. S. Alshehri, H. Ali, and J. Ahmad, "Enhancing IoT network security through deep learning-powered Intrusion Detection System," *Internet of Things*, vol. 24, p. 100936, 2023.
- [27] M. Karami and M. Mosleh, "Providing a behavioral malware detection system based on the function of hardware counters using a neural network optimized with a dragonfly algorithm," *Electronic and Cyber Defense*, vol. 9, no. 2, pp. 9-16, 2021.(persian).
- [28] K. D. T. Nguyen, T. M. Tuan, S. H. Le, A. P. Viet, M. Ogawa, and N. Le Minh, "Comparison of three deep learning-based approaches for IoT malware detection," in 2018 10th international conference on Knowledge and Systems Engineering (KSE), 2018: IEEE, pp. 382-388.
- 2021.(persian).<https://dor.isc.ac/dor/20.1001.1.23224347.1400.9.3.9.0>
- [22] G. N. Arzhantseva, C. H. Cashen, D. Gruber, and D. Hume, "Characterizations of Morse quasi-geodesics via superlinear divergence and sublinear contraction," *Documenta Mathematica*, vol. 22, pp. 1193-1224, 2017.
- [23] H. Liu and H. Wang, "Real-Time Anomaly Detection of Network Traffic Based on CNN," *Symmetry*, vol. 15, no. 6, p. 1205, 2023.
- [24] X. Duan, Y. Fu, and K. Wang, "Network traffic anomaly detection method based on multi-scale residual classifier," *Computer Communications*, vol. 198, pp. 206-216, 2023.
- [25] R. Zhao et al., "A novel traffic classifier with attention mechanism for industrial internet of things," *IEEE Transactions on Industrial Informatics*, vol. 19, no. 11, pp. 10799-10810, 2023.

