

روش ترکیبی جدیدی مبتنی بر الگوریتم‌های هوشمند SDN-IoT

ذکریا رئیسی، فضل‌الله ادبینیا و مهدی یزدانی دهکردی

اینترنت اشیا فناوری است که هر شیء یا دستگاهی را در هر نقطه از مسیر یا شبکه به دستگاه‌های دیگر متصل می‌کند. تمام اشیای متصل باید در زیست‌بوم^۱ اینترنت اشیا با استفاده از شناسه منحصر به‌فردی آدرس دهنده شوند [۲]. مطالعات گسترشده‌ای در زمینه اینترنت اشیا انجام شده که مرور آنها سه چالش اصلی برای اینترنت اشیا را نشان می‌دهد. اولین چالش، ناهمگونی شبکه است. چالش دوم آن است که اینترنت اشیا نیازمند اتخاذ عماری بسیار گسترشده به‌خصوص در برنامه‌های کاربردی مانند شهرهای هوشمند و شبکه‌های هوشمند می‌باشد. سوم آنکه اینترنت اشیا نیازمند معرفی پروتکل‌های جدیدی برای رسیدگی به مسائل خاص مربوط به محدودیت قدرت و محاسبات حسگرهای شبکه می‌باشد [۳] و [۴].

بررسی ادبیات موضوع نشان می‌دهد که زیرساخت‌های اینترنت اشیای مبتنی بر شبکه‌های نرم‌افزارمحور^۲ (SDN-IoT) می‌تواند به میزان قابل ملاحظه‌ای در مدیریت چالش امنیت، مؤثر واقع شود [۵]. علت این تأثیرات مثبت، عدم وجود آسیب‌پذیری‌ها و چالش‌های شبکه‌های سنتی در محیط SDN می‌باشد. شبکه نرم‌افزارمحور، یک نمونه شبکه‌ای جدید است که انعطاف‌پذیری، قابلیت مقایسه‌پذیری و امنیت را بهمود می‌بخشد [۶] و [۷] و بنابراین می‌تواند تا حدی تأثیرات منفی ناشی از چالش‌های موجود در اینترنت اشیا را مدیریت کند. مطالعات بسیاری در مورد استقرار شبکه‌های نرم‌افزارمحور به‌عنوان یک مدل شبکه‌ای برای اینترنت اشیا انجام شده است [۸] تا [۱۰]. ایده اصلی در شبکه‌های نرم‌افزارمحور، تفکیک صفحه کنترل و داده می‌باشد [۱۱]. صفحه داده برای سوئیچ جریان داده‌هاست؛ در حالی که صفحه کنترل، بخش جدیدی در شبکه را به نام کنترل‌کننده، معرفی می‌کند. صفحه داده شامل دستگاه‌های سخت‌افزاری مانند سوئیچ‌ها، روترهای فایروال‌ها و سیستم‌های تشخیص نفوذ^۳ (IDS) است. این دستگاه‌ها هیچ پردازشی جهت پرکردن جدول صفحه داده نیاز ندارند و منطق شبکه به‌طور مستقل به کنترلر منتقل گردیده است. کنترلر، خدماتی مانند وضعیت شبکه و اطلاعات هم‌بندی^۴ را ارائه می‌دهد و جهت جایه‌جایی اطلاعات از کنترلر به صفحه انتقال و بر عکس، از پروتکلی به نام OpenFlow استفاده می‌شود [۱۲]. با وجود این همچنان امنیت در شبکه‌های نرم‌افزارمحور، یکی از اصلی‌ترین نگرانی‌ها در محیط SDN-IoT می‌باشد.

از یک سو شبکه‌های نرم‌افزارمحور برای حل چالش‌های اینترنت اشیا از قبیل انعطاف‌پذیری و مقایسه‌پذیری، مطرح شده است اما از طرف دیگر، نگرانی‌های ناشی از تأمین امنیت شبکه‌های نرم‌افزارمحور به نگرانی‌های

چکیده: در سال‌های اخیر، کاربرد اینترنت اشیا در جوامع به‌طور گسترشده‌ای رشد یافته و از طرفی، فناوری جدیدی به نام شبکه‌های نرم‌افزارمحور جهت حل چالش‌های اینترنت اشیا پیشنهاد شده است. چالش‌های موقود در این شبکه‌های نرم‌افزارمحور و اینترنت اشیا موجب گردیده که امنیت SDN-IoT به یکی از فرستندهای مهم این شبکه‌ها تبدیل شود. از طرف دیگر، الگوریتم‌های هوشمند موجوب پیشرفت چشم‌گیری شده است. البته سیستم‌های تشخیص نفوذ جهت SDN-IoT، همچنان با چالش نرخ هشدار غلط بالا مواجه هستند. در این مقاله یک روش ترکیبی جدید مبتنی بر الگوریتم‌های هوشمند پیشنهاد شده که جهت دسترسی به نتایج خوبی در زمینه تشخیص نفوذ، الگوریتم‌های نظارتی دروازه بازگشته مکرر و طبق‌بند غیرنظارتی-k-میانگین را ادغام می‌کند. نتایج شبیه‌سازی نشان می‌دهند که روش پیشنهادی با بهره‌گیری مزایایی هر کدام از الگوریتم‌های ادغام‌شده و پوشش معایب یکدیگر، نسبت به روش‌های دیگر مانند روش Hamza دارای دقت پیشتری و بالاخص نرخ هشدار غلط کمتری است. همچنین روش پیشنهادی توانسته نرخ هشدار غلط را به ۱/۱٪ کاهش داده و دقت را در حدود ۹۹٪ حفظ کند.

کلیدواژه: شبکه‌های نرم‌افزارمحور، الگوریتم‌های هوشمند، اینترنت اشیاء، تشخیص نفوذ، یادگیری ماشین.

۱- مقدمه

زیرساخت اینترنت اشیا^۱ (IoT) از تلفن‌های هوشمند گرفته تا شهرهای هوشمند به‌آرامی در حال نفوذ به جنبه‌های متفاوت زندگی بشر است؛ به‌گونه‌ای که طی سال‌های آتی به جزئی جدنشدنی از زندگی بشر تبدیل می‌شود [۱]. همچنین با برنامه‌های گسترشده در راستای بهبود اینترنت اشیاء انتظار می‌رود در سال‌های آتی، استفاده از این فناوری چندین برابر شود. با این حال ماهیت ناهمگن دستگاه‌های اینترنت اشیاء و محدودیت‌های ارتباطی، مدیریت شبکه و امنیت را به یک عمل دشوار برای مجریان آن تبدیل کرده است. در واقع رمزگذاری دادها یا نرم‌افزارهای ضدپیروس نمی‌توانند چالش‌های امنیتی پیچیده این حوزه را مدیریت کنند.

این مقاله در تاریخ ۶ بهمن ماه ۱۴۰۱ دریافت و در تاریخ ۵ خرداد ماه ۱۴۰۲ بازنگری شد.

ذکریا رئیسی، دانشکده مهندسی کامپیوتر ، دانشگاه یزد، یزد، ایران، (email: Zakaria.raisi@stu.yazd.ac.ir)

فضل‌الله ادبینیا، دانشکده مهندسی کامپیوتر ، دانشگاه یزد، یزد، ایران، (email: fadib@yazd.ac.ir)

مهدی یزدانی دهکردی، دانشکده مهندسی کامپیوتر ، دانشگاه یزد، یزد، ایران، (email: yazdian@yazd.ac.ir)

1. Internet of Things

2. Ecosystem

3. Software Defined Network-Internet of Things

4. Intrusion Detection Systems

5. Topology

رویکرد ترکیبی جدید مبتنی بر الگوریتم‌های هوشمند^۳ LSTM و GRU می‌باشد. این مقاله بر چهار محور اصلی بعدی متمرک شده است:

- (۱) کاهش نرخ هشدار غلط و بهبود دقت نتایج خروجی
- (۲) سازگاری روش پیشنهادی با معماری SDN-IoT به طوری که تمام جواب ممکن در این فناوری در نظر گرفته شود.
- (۳) استفاده از مجموعه داده‌ای که متناسب با ویژگی‌های موجود در این فناوری باشد. در واقع در ارزیابی روش پیشنهادی از مجموعه داده‌ای قدری که هیچ شباهتی با ترافیک این فناوری ندارد، استفاده نشده است.
- (۴) قابلیت پیاده‌سازی راحت. بسیاری از روش‌های قبلی از شیوه‌های پیچیده‌ای استفاده می‌کنند که یا به سخت‌افزار اختفای نیاز دارند یا پیاده‌سازی آنها بسیار سخت است.

در ادامه، پیشینه پژوهش به اختصار مرور می‌گردد و سپس در بخش دو روش پیشنهادی و توضیحات مربوط ارائه شده است. در بخش سوم، آزمایش‌هایی جهت ارزیابی کارایی روش پیشنهادی انجام گردیده و نتایج آزمایش‌ها و ارزیابی کارایی بیان شده است. سپس در بخش چهارم، مقایسه‌ای بین روش پیشنهادی و برخی روش‌های پیشین مشابه انجام شده و نهایتاً در بخش پایانی، نتایج حاصل از پژوهش جاری و نمونه‌ای از کارهای آتی بیان گردیده است.

در اینجا به آشنایی با ادبیات موضوع، مروری بر پیشینه پژوهش و شناسایی رویکردهای هوشمند پیشین در زمینه مدیریت چالش امنیت در یک محیط SDN-IoT پرداخته می‌شود.

اینترنت اشیا یک فناوری نوظهور است که زیست‌بوم هوشمند را قادر می‌سازد تا فناوری‌های ناهمگن را کنار هم قرار دهد [۱۸] و [۱۹]. طیف گسترده‌ای از دستگاه‌های اینترنت اشیا، دلالت بر وجود احتمال آسیب‌پذیری‌هایی است که از طریق آن می‌توان دستگاه‌ها را به خطر انداخت. با افزایش سریع تعداد دستگاه‌های اینترنت اشیاء، عملکرد شبکه مانند مقیاس‌پذیری، امنیت و حفظ QoS یک مسئله اساسی است و به بخشی از نیازمندی‌های اصلی اینترنت اشیا تبدیل شده است [۲۰] تا [۲۳]. شبکه‌های نرم‌افزارمحور، رویکردی است که جهت مقابله با چالش‌های ناشی از ظهور دستگاه‌های اینترنت اشیا در شبکه در نظر گرفته شده است. شبکه‌های نرم‌افزارمحور با جداسازی صفحه کنترل و صفحه داده، برنامه‌نویسی و انعطاف‌پذیری در مدیریت شبکه را فراهم می‌کنند. هدف از این جداسازی، امکان تنظیم پیکربندی شبکه با انعطاف‌پذیری و برنامه‌نویسی بیشتر است [۲۴].

در حالت کلی می‌توان دلایل ادغام شبکه‌های نرم‌افزارمحور و اینترنت اشیا را به صورت خلاصه در موارد زیر بیان کرد [۷]، [۲۵] و [۲۶]:

- موجب سهولت در جمع‌آوری داده‌ها و تحلیل، تصمیم‌گیری و فرایند کنترل می‌شود.
- منابع شبکه با استفاده از فناوری شبکه‌های نرم‌افزارمحور بهینه شده است. برنامه‌های پرمصرف اینترنت اشیا در یکپارچه‌سازی با شبکه‌های نرم‌افزارمحور، اپراتورهای شبکه را قادر می‌سازد تا کاربران، دستگاه‌ها و گروه‌ها را مدیریت کنند.
- در ادامه این بخش، برخی از کارهای پژوهشی پیشین در زمینه اینترنت اشیا، شبکه‌های نرم‌افزارمحور و SDN-IoT در راستای شناسایی ایده‌های اصلی نهفته در آنها و ویژگی‌های روش‌های تشخیص نفوذ مرور گردیده است.

امنیتی در اینترنت اشیا افزوده شده است؛ لذا نگرانی در مورد برقراری امنیت SDN-IoT به عنوان یکی از نگرانی‌های اصلی در زمینه چالش‌های اینترنت اشیا می‌تواند توجه بسیاری را به خود جلب نماید [۴] و [۱۳]. شبکه‌های نرم‌افزارمحور به خاطر کنترل کننده مرکزی، دید کلی شبکه در راستای سهولت فرایند مدیریت و اجرای سیاست‌ها را فراهم می‌کنند؛ همچنین خطاهای را در زمان پیکربندی و تغییر سیاست‌های شبکه، کاهش و قابلیت همکاری را افزایش می‌دهند. تهدیدات امنیتی، چالشی حیاتی در سیستم‌های شبکه‌های سنتی است و این تهدیدها در شبکه‌های نرم‌افزارمحور تشدید می‌شود. در واقع مزایای این مدل از شبکه با تهدیدهای اضافی همراه است که در شبکه‌های سنتی وجود نداشت. بررسی‌های امنیتی انجام شده بر روی پروتکل OpenFlow نشان می‌دهند که حملات مختلفی در این پروتکل صورت گرفته است. برای مثال، جداول جریان و کانال‌های ارتباطی بین دستگاه‌ها و کنترل کننده می‌توانند تحت تأثیر حملات منع سرویس^۱ (DoS) قرار گیرند. کانال ارتباطی بین کنترلر و سوئیچ با یک اتصال TCP با پروتکل رمزنگاری TLS برای امن کردن کانال ارتباطی شروع می‌شود و بدون یک روش رمزنگاری، ارتباط بین کنترلر و دستگاه‌های انتقال در معرض حملات مرد میانی است [۱۱].

در نمونه مطالعاتی دیگری، Kloti و همکاران [۱۲] یک تحلیل امنیتی بر روی پروتکل OpenFlow انجام داده‌اند. نتایج مطالعات آنها نشان می‌دهد که حمله DoS، کانال‌های ارتباطی و جدول جریان‌ها را تهدید می‌کند. علاوه بر این، حملات دست‌کاری به طور قابل ملاحظه‌ای جداول قوانین را با افزودن قوانین از منابع غیرقابل اعتماد مورد هدف قرار داده است.

مروری بر ادبیات نشان می‌دهد که وجود سیستم‌های تشخیص نفوذ کارآمد در یک محیط SDN-IoT بدليل رشد قابل توجه کاربرد اینترنت اشیا در جنبه‌های متفاوت زندگی و برجسته‌شدن مسئله رعایت امنیت در این گونه محیط‌ها ضروری به نظر می‌رسد. سیستم‌های تشخیص نفوذ، سیستم‌های نرم‌افزاری یا ساخت‌افزاری اختصاص‌داده شده جهت نظارت بر جریان ترافیک در مقابل تهدیدهای امنیتی هستند. سیستم‌های تشخیص نفوذ استاندارد شامل سه مرحله جمع‌آوری اطلاعات از شبکه، تجزیه و تحلیل و سپس پاسخ مناسب در صورت وجود تهدید می‌باشند. همچنین برای تجزیه و تحلیل ترافیک جمع‌آوری شده، سه روش مبتنی بر امضا یا سوءاستفاده، تشخیص غیرعادی^۲ و مبتنی بر پروتکل‌های Stateful وجود دارد.

امنیت داده‌های سایبری همچنان یک چالش برای جامعه یادگیری مانشین به حساب می‌آید؛ زیرا حجم بالای ترافیک، تکیک رفتار غیرعادی از عادی را دشوار می‌کند. در واقع تصمیم‌گیری جهت جداسازی رفتار عادی از غیرعادی، هسته اصلی یک سیستم هوشمند تشخیص نفوذ است و به عنوان مؤلفه‌ای که مسئول اعلام هشدارها در زمان شناسایی تهدیدات بالقوه است در نظر گرفته می‌شود [۱۴]. از طرفی روش‌های سنتی برای انجام این وظیفه، دقت کافی را ندارند. با توجه به این موضوع در سال‌های اخیر، الگوریتم‌های یادگیری مانشین به‌ویژه روش‌های مبتنی بر شبکه‌های عصبی بازگشتی پیشنهاد شده‌اند [۱۵] تا [۱۷].

هدف اصلی مقاله با توجه به ضرورت سیستم‌های تشخیص نفوذ در SDN-IoT، ارائه یک سیستم تشخیص نفوذ کارآمد با به‌کارگیری یک

1. Denial of Service
2. Anomaly

جدول ۱: مقایسه روش‌های مطرح قبلی و ویژگی‌های آنها.

روش	ACC	TPR	FPR	مزایا و معایب
Hamza و همکاران [۲۷]	بالا	-	-	الگوریتم بیز و استفاده از MUD برای به دست آوردن امضای داده‌های طبیعی و غیرطبیعی. کارایی بهتر از Snort دارد. ذکر نکردن مقدار ACC و FP.
Hamza و همکاران [۲۹]	۹۷,۵	۷۲,۳	۲,۶	استفاده از MUD که نیاز به سخت‌افزار اختصاصی دارد و همچنین استفاده از الگوریتم به صورت ترکیبی که بسیار وقت‌گیر می‌باشد. این در حالیست که TPR بسیار پایین است.
Silveira و همکاران [۳۲]	۹۳	-	۶	روش پیشنهادی با رگرسیون منطقی دقت خوبی دارد؛ اما FPR نیز بالاست.
Wani و همکاران [۳۳]	۹۵,۹	۹۶,۴	۷	الگوریتم MLP دقت بالا دارد؛ ولی همچنان FPR بالاست و فقط جهت شناسایی حمله DDOS است.
روش پیشنهادی	۹۹	۹۹	۱/۱	دقت و TPR بالا، FPR بسیار پایین و مدت زمان آموزش کم از مزایای روشن پیشنهادی است.

نرم‌افزار محور را برای شناسایی و کاهش DDOS در شبکه‌های اینترنت اشیا ارائه دادند. روشن پیشنهادی آنها جهت شناسایی حملات با استفاده از MLP آموزش دیده و سپس عمل دسته‌بندی حملات را انجام می‌دهد. نویسنده‌گان اظهار داشته‌اند که روشن پیشنهادی آنها دقتش در حدود ۹۹٪ و FNR و FPR به ترتیب ۷٪ و ۳٪ ارائه نموده است.

Novaes و همکاران [۳۴] برای بررسی و شناسایی حملات منع سرویس توزیع شده و حملات Portscan در محیط‌های شبکه‌های نرم‌افزار، روشن LSTM-FUZZY را ارائه دادند. این سیستم دارای سه مرحله مجزای تعیین خصوصیات، تشخیص ناهنجاری و کاهش آنهاست. نتایج ارزیابی نشان‌دهنده کارایی قابل قبول رویکرد نویسنده‌گان در مدیریت شبکه، شناسایی و کاهش وقوع حملات است.

Xu و همکاران [۳۵] یک استراتژی دفاع حمله DDOS را بر اساس طبقه‌بندی ترافیک پیشنهاد کردند. برای بهبود انعطاف‌پذیری و کاهش بار شبکه‌های نرم‌افزار محور در برابر حملات، DDOS از معماری مجازی‌سازی عملکرد شبکه (SDNFV) و استراتژی طبقه‌بندی ترافیک استفاده کرده است. نویسنده‌گان در مژاول تشخیص حمله با کمک یادگیری تقویتی، الگوریتم طبقه‌بندی جنگل تصادفی را بهبود داده‌اند؛ به طوری که دقتش مژاول طبقه‌بندی به ۹۹,۵٪ رسیده است.

Khan و همکاران [۳۶] مقایسه‌ای بین الگوریتم‌های مختلف یادگیری ماشینی انجام داده‌اند که می‌تواند برای شناسایی و پیش‌بینی هر گونه داده مخرب یا غیرعادی برای مجموعه داده‌ای از ویژگی‌های محیطی ایجاد شده استفاده کردد. نویسنده‌گان اظهار داشته‌اند که در آزمایش‌های خود به دقتش حدود ۹۶,۵٪ و زمان اجرای کمتر از ۰,۲ ثانیه دست یافته‌اند.

Abdullahi و همکاران [۳۷] یک بررسی سیستماتیک از حملات تشخیص امنیت سایبری در اینترنت اشیا را با استفاده از روشن‌های هوش مصنوعی ارائه داده‌اند. نویسنده‌گان معتقد‌اند که با توجه به توسعه سریع اینترنت اشیا در حوزه‌های مختلف، مقدار زیادی داده به طور مداوم تولید می‌شود که نیاز به تمرکز بیشتر بر حریم خصوصی و امنیت دارند. آنها در بررسی خود از الگوریتم‌های SVM، RNN و RF استفاده کرده‌اند و به نتایج قابل قبولی دست یافته‌اند.

خلاصه‌ای از روشن‌های مطرح قبلی و مقایسه آنها در جدول ۱ نشان داده شده است.

۲- روشن پیشنهادی

شبکه نرم‌افزار محور، نمونه‌ای از شبکه‌های جدید است و انعطاف‌پذیری، قابلیت مقایس‌پذیری و امنیت را بهبود می‌بخشد؛ لذا می‌تواند چالش‌های موجود در IoT را مانند امنیت حل کند. سیستم‌های تشخیص نفوذ، سیستم‌های نرم‌افزاری یا سخت‌افزاری اختصاص داده شده برای نظارت بر جریان ترافیک در مقابل تهدیدهای امنیتی هستند. با توجه به ضرورت

Hamza و همکاران [۲۷] در روشن پیشنهادی خود سعی می‌کنند تا سیاست‌های MUD را به قوانین جریان ترجمه کنند که می‌تواند با استفاده از SDN اجرا شود و حملاتی را بدون نیاز به IDS شناسایی کند. در این مقاله نویسنده‌گان سیستمی را ایجاد می‌کنند که سیاست‌های MUD را به قوانین جریان‌ها ترجمه می‌کند که به صورت فعال در سوئیچ‌های شبکه پیکربندی می‌شوند و همچنین بر اساس اتصالات زمان اجرای DNS اضافه می‌شوند.

Shravanya و همکاران [۲۸] روشن پیشنهادی خود را در ایجاد یک معماری امن برای کنترل کننده شبکه‌های نرم‌افزار محور در نظر گرفته‌اند که در برابر حمله DoS قوی باشد. در واقع در این نوع حملات، سوئیچ شبکه‌های نرم‌افزار محور مانند یک میزبان حمله کننده و کنترل کننده بعد از پیاده‌سازی معماری مورد نظر و الگوریتم‌های درخت تصمیم و KNN به دقتش در حدود ۹۹٪ دست پیدا کرده‌اند.

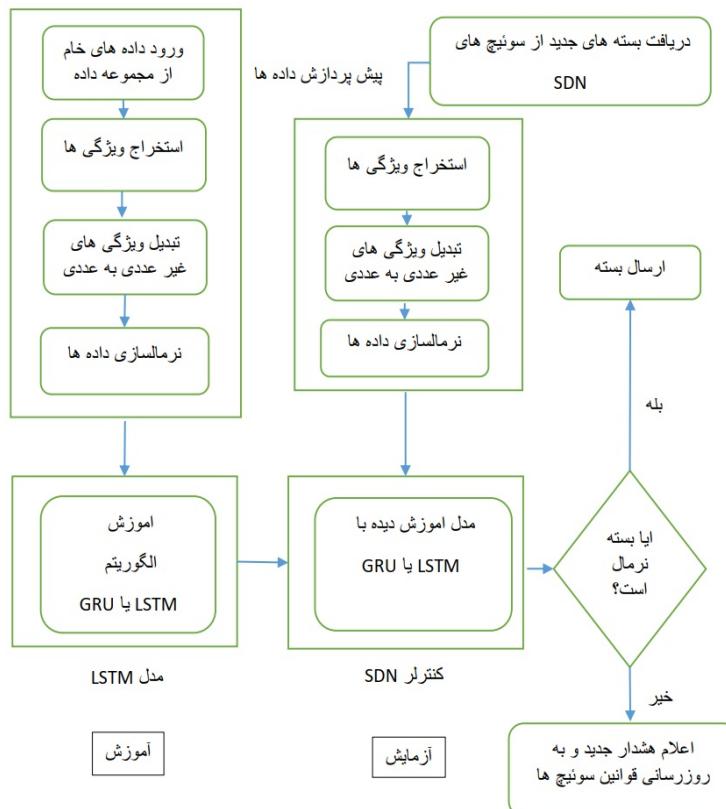
Hamza و همکاران [۲۹] جهت مقایسه از الگوریتم Snort استفاده کرده‌اند. این مقایسه نشان می‌دهد که Snort از میان ۴۰ نوع حمله موجود، فقط قادر است که ۲ تا از آنها را تشخیص دهد؛ زیرا امضا برای حملات دیگر در Snort وجود ندارد و نمی‌تواند بقیه حملات را تشخیص دهد. روشن پیشنهادی در مقایسه با Snort در مقابل حملات جدید بسیار خوب عمل کرده و توانسته دقتش در حدود ۹۹٪ داشته باشد.

Meidan و همکاران [۳۰] سه الگوریتم LGBM، SVM و DNN را در نظر گرفته‌اند و با استفاده از داده‌های حاصل از دستگاه‌های اینترنت اشیا، این الگوریتم‌ها را آموزش داده‌اند. همچنین معيارهای ارزیابی در این مقاله عبارتند از اندازه طبقه‌بند، مدت زمان آموزش طبقه‌بند، مدت زمان آموزش هر جریان از مجموعه داده و FPR. نویسنده‌گان اظهار داشته‌اند که الگوریتم LGBM بهترین عملکرد را ارائه کرده است.

Salman و همکاران [۳۱] یک چارچوب امنیتی را برای تشخیص ترافیک مخرب ارائه داده‌اند که جهت شناسایی نوع ترافیک ایجاد شده و شناسایی حملات شبکه استفاده گردیده است. نویسنده‌گان مقایسه‌ای بین الگوریتم‌های مختلف یادگیری ماشین و جنگل تصادفی انجام داده و اظهار داشته‌اند که بهترین نتیجه برای تشخیص غیرعادی ترافیک با دقتش ۹۷٪ به دست آمده است.

Silveira و همکاران [۳۲] یک سیستم تشخیص نفوذ مبتنی بر امضا را با جایگذاری الگوریتم‌های جنگل تصادفی، رگرسیون منطقی و گرادیان تقویتی در کنترلر پیاده‌سازی نمودند. سپس مجموعه داده‌های موجود را با استفاده از سوئیچ‌ها انتقال داده تا عمل تشخیص انجام شود. نویسنده‌گان اظهار داشته‌اند که نتایج، دقتش بالای ۹۳٪ نرخ هشدار کاذب (FAR) را نشان می‌دهند.

Wani و همکاران [۳۳] یک مکانیزم امنیتی مبتنی بر شبکه



شکل ۱: معماری سیستم تشخیص نفوذ پیشنهادی.

تحت تأثیر قرار می‌گیرند. همچنین وزن‌های شبکه توسط محاسباتی که بر روی تمام دنباله رخ می‌دهد، تأثیر می‌بذیرند که این بهمنزله حافظه بلندمدت است [۱۵]. در شبکه RNN، شبکه در هر گام زمانی از ابتدا بازنویسی می‌شود؛ اما یک شبکه LSTM دارای توانایی تصمیم‌گیری نسبت به حفظ حافظه فعلی از طریق دروازه‌های موجود می‌باشد. یعنی اگر واحد LSTM، ویژگی مهمی در دنباله ورودی گام‌های ابتدایی تشخیص دهد، آن گاه به سادگی می‌تواند این اطلاعات را طی مسیر طولانی منتقل کند. بدین ترتیب LSTM و استگاهای بلندمدت احتمالی را دریافت و حفظ می‌نماید و از طرف دیگر قادر است مشکل محوشدن گرادیان را که در شبکه‌های عصبی وجود دارد مدیریت کند [۱۶]. محوشدن گرادیان، مشکلی است که در هنگام آموزش شبکه‌های عصبی مصنوعی با استفاده از روش یادگیری پس از انتشار خطا یا همان مبتنی بر گرادیان، انفاق می‌افتد. در این نوع روش‌ها به منظور به روزرسانی پارامترهای شبکه عصبی از گرادیان استفاده می‌شود و هر پارامتر با توجه به میزان اثری که در نتیجه نهایی شبکه دارد مورد تغییر قرار می‌گیرد. این کار با استفاده از مشتق جزئی تابع خطا نسبت به هر پارامتر در هر تکرار فرایند آموزش صورت می‌پذیرد. مشکل محوشدن گردیدگی در واقع اشاره به این مسئله دارد که مقادیر گرادیان‌ها با حرکت به سمت ابتدای شبکه تدریجاً به حدی کوچک می‌شوند که تغییرات خاصی روی وزن‌ها صورت نمی‌گیرد و به این علت، فرایند آموزش شدیداً کند می‌شود؛ بنابراین این مسئله در بدترین حالت باعث توقف فرایند آموزش می‌گردد و به واسطه عمق زیاد شبکه رخ می‌دهد. برای حل این مشکل، LSTM با استفاده از مقادیر حالت مخفی، توابع فعال ساز را به شکلی تحت تأثیر قرار می‌دهد که وزن‌ها به واسطه تمام دنباله و نه یک ورودی، تحت تأثیر قرار گیرند. معماری سیستم تشخیص نفوذ پیشنهادی در شکل ۱ آمده است. همان‌طور که مشاهده می‌شود در ابتدا ویژگی‌های موجود در مجموعه داده استخراج می‌گردد و سپس داده‌های غیر عددی به داده‌های عددی تبدیل

سیستم‌های تشخیص نفوذ در SDN-IoT، یک سیستم تشخیص نفوذ با استفاده از الگوریتم هوشمند برای این محیط پیشنهاد شده است. بنابراین پژوهش جاری از یک رویکرد ترکیبی جدید مبتنی بر الگوریتم‌های هوشمند برای سیستم تشخیص نفوذ کارآمد در SDN-IoT استفاده کرده است. رویکرد پیشنهادی مقاله، الگوریتم‌های LSTM و GRU را جهت دستیابی به نتایج دقیق‌تر و کاهش نرخ هشدار خطأ ادغام نموده و در ادامه رویکرد پیشنهادی در دو بخش مجزا تشریح شده است.

۱-۲ معماری رویکرد پیشنهادی

یک شبکه عصبی بازگشتی^۱ (RNN) سنتی اگر به اندازه کافی بزرگ باشد از نظر تئوری باید قادر به تولید دنباله‌های پیچیده باشد؛ اما در عمل مشاهده می‌شود که این شبکه برای یادگیری دنباله‌های طولانی مدت به مشکل بر می‌خورد. در واقع این ویژگی باعث می‌شود یک شبکه عصبی بازگشتی سنتی در مدل سازی ساختارهای بلندمدت، ضعیف عمل کند. این فراموشی باعث می‌گردد تا این نوع از شبکه‌ها در زمان تولید دنباله‌ها در معرض ناپایداری قرار گیرند. در واقع اگر پیش‌بینی‌های شبکه، تنها وابسته به چند ورودی اخیر باشد، شناسی بسیار کمی برای تصحیح و جبران اشتباهات گذشته توسط شبکه وجود دارد. مشکل ناپایداری به طور ویژه در زمان مواجهه با داده اعشاری، وخیم می‌شود؛ زیرا پیش‌بینی‌ها می‌توانند از دامنه‌ای که داده‌های آموزشی بر روی آن قرار گرفته‌اند، فاصله بگیرند.

استفاده از حافظه می‌تواند به عنوان راه حل بهمراه تأثیرگذارتری نسبت به بقیه راه حل‌ها مطرح گردد. LSTM یک معماری شبکه عصبی بازگشتی است که برای ذخیره‌سازی و دسترسی بهتر به اطلاعات نسبت به نسخه سنتی آن، طراحی شده و به‌گونه‌ای عمل می‌کند که مقادیر نورون‌های لایه مخفی توسط فعال‌سازهای محلی که نزدیک به آنهاست،

$$c_t = f_t c_{t-1} + i_t \bar{c}_t \quad (5)$$

$$h_t = o_t \tanh c_t \quad (6)$$

در (۱) تا (۶) i_t ، f_t و o_t به ترتیب دروازه ورودی، فراموشی و خروجی و b_i ، b_f و b_o نیز مقادیر ثابتی هستند که به آنها بایاس گفته می‌شود. همچنین σ و \bar{c}_t به ترتیبتابع سیگموئید و حالت سلول کاندیدا را نشان می‌دهد و h_t خروجی سلول در مرحله t است. پارامترهای قابل تنظیم در واقع ماتریس‌های w و v هستند.

الگوریتم LSTM دارای پیچیدگی زمانی بالایی است؛ لذا برای حل این مشکل، ادغام الگوریتم‌های LSTM و GRU پیشنهاد شده است. شبکه عصبی GRU بهبودیافته، شبکه عصبی LSTM است. شبکه عصبی GRU پس از تنظیم مجدد دروازه، اطلاعات را پردازش نموده و زمان آموزش را کاهش می‌دهد. بدین منظور، این شبکه عصبی تعداد دروازه‌های LSTM را از ۳ دروازه به ۲ دروازه کاهش می‌دهد. در واقع روش GRU با LSTM فرق زیادی ندارد و فقط تعداد دروازه‌ها را کاهش داده و وظایف هر کدام از دروازه‌ها را در حد امکان در یکدیگر ادغام کرده است [۳۸] و [۳۹]. دروازه‌های بهروزرسانی و تنظیم مجدد در GRU به صورت (۷) تا (۱۱) محاسبه شده است

$$l_u = \sigma(w_u[x_t + c_{t-1}] + b_u) \quad (7)$$

$$l_r = \sigma(w_r[x_t + c_{t-1}] + b_r) \quad (8)$$

$$c_t = l_u \bar{c}_t + (1 - l_u) c_{t-1} \quad (9)$$

$$o_t = \text{softmax}(w_o c_t + b_o) \quad (10)$$

$$\bar{c}_t = \tanh(w_c[x_t] + l_r c_{t-1} + b_c) \quad (11)$$

در (۷) تا (۱۱)، l_u و l_r به ترتیب دروازه‌های بهروزرسانی و تنظیم مجدد و همچنین w_u ، w_r و w_c وزن‌های شبکه عصبی هستند.

محوشدگی گردایان، مشکلی است که هنگام آموزش شبکه‌های عصبی مصنوعی با استفاده از روش یادگیری پسانشار خطا یا همان مبتنی بر گردایان اتفاق می‌افتد. جهت رفع مشکل محوشدگی گردایان می‌توان از راهلهای بعدی استفاده کرد:

- مقداردهی اولیه وزن‌ها به طوری که احتمال رخدادن محوشدگی گردایان کمینه شود.

- استفاده از شبکه عصبی Echo State IRNN یا

- استفاده از شبکه‌های عصبی بازگشتی LSTM و GRU که دقیقاً برای این موضوع طراحی شده‌اند و در روش پیشنهادی از این مورد استفاده شده است.

در روش پیشنهادی در این مقاله، بعد از آنکه داده‌ها با استفاده از ترکیب الگوریتم‌های LSTM و GRU آموزش دیدند، داده‌های جدید را برای انجام عمل پیش‌بینی دریافت می‌کنند. لذا بعد از عمل رگرسیون، به کارگیری یک طبقه‌بند کارآمد برای طبقه‌بندی پیش‌بینی‌های انجام شده، ضروری بنتظر می‌رسد.

۳- پیاده‌سازی و نتایج تجربی

در این بخش مقاله، مطالب مربوط به پیاده‌سازی روش پیشنهادی و نتایج تجربی آزمایش‌های انجام شده برای ارزیابی کارایی روش پیشنهادی ارائه گردیده و برای درک بهتر مطالب، این بخش در دو زیربخش مجزا سازمان‌دهی شده است.

می‌گردد. در گام بعدی داده‌ها با اعمال روش نمره استاندارد^۱ نرمال‌سازی می‌شود و الگوریتم LSTM جهت آموزش داده‌های نرمال‌سازی شده مورد استفاده قرار می‌گیرد. با ورود بسته‌های ناشاخته به سوئیچ‌های شبکه، این بسته‌ها برای کنترل کننده ارسال می‌شوند و بعد از استخراج ویژگی‌ها و انجام پیش‌پردازش روی مدل آموزش دیده، مشخص می‌گردد که آیا بسته انجام شده بر روی مدل آموزش دیده، باشد به مقصود مورد دریافت شده نرمال است یا مخرب. اگر بسته نرمال باشد به مقصد مورد نظر خود ارسال شده و قوانین بر روی سوئیچ‌ها تغییر پیدا می‌کند؛ ولی اگر بسته مخرب باشد، هشداری برای مدیر شبکه ارسال شده و آدرس IP مورد نظر نیز به عنوان حمله کننده، شناسایی می‌شود. بنابراین دریافت بسته جدید از این میزبان نیز با تغییر قوانین در سوئیچ‌ها متوقف می‌گردد.

۲- الگوریتم‌های پایه LSTM

RNN توسعه یا نوعی از شبکه عصبی RNN است. در واقع RNN سنتی از حافظه کوتاه‌مدت در صورتی که توالی طولانی باشد رنج می‌برد و طبقه‌بند برای حمل اطلاعات از مراحل قبلی تا موارد بعدی دچار مشکل می‌شود. بنابراین شبکه عصبی مکرر از مشکل گردایان رنج می‌برد و LSTM به عنوان یک راه حل طراحی شده است. این الگوریتم لایه‌های پنهان با بلوک‌های حافظه جایگزین شده‌اند که مشکل فراموشی در یادگیری الگوی دنبالهای طولانی حل شده است. LSTM در معماری پایه خود، مفهوم استفاده از مکانیزم دروازه را برای واحدهای تنظیم کننده جریان اطلاعات در نظر می‌گیرد. مکانیزم دروازه شامل سه دروازه یعنی ورودی، خروجی و دروازه فراموشی است و این دروازه‌ها وظیفه دارند که تصمیم بگیرند کدام توالی داده برای ذخیره یا دورانداختن مناسب است. دروازه‌های ورودی و خروجی، جریان اطلاعات ورودی و خروجی سلول‌ها را کنترل می‌کنند. علاوه بر این اگر اطلاعات نامناسب باشد، دروازه فراموشی برای تنظیم مجدد اطلاعات حالت قبلی خود وارد عمل می‌شود [۷].

۳- الگوریتم‌های مورد استفاده (GRU و LSTM)

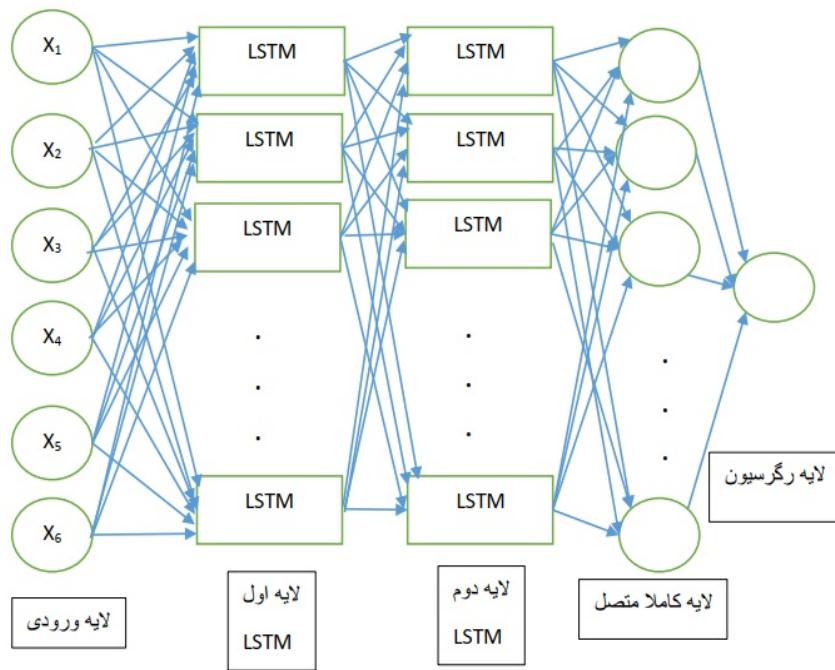
یک مشکل در آموزش معماری اولیه RNN، وابستگی بسیار طولانی مدت به توالی است که یادگیری مؤثر را دشوار می‌کند. این مسئله می‌تواند زمینه‌ساز انگیزه اصلی برای به کارگیری شبکه‌های نوع LSTM باشد. LSTM سعی می‌کند با معروفی دروازه‌ها، مکانیزم‌هایی در شبکه‌های عصبی عمیق ایجاد کند که مجاز هستند تا مشخص کنند که چه اطلاعاتی را پردازش کنند. در یک سلول LSTM سه دروازه ورودی، فراموش و خروجی وجود دارد. دروازه فراموشی می‌کند کدام قسمت از ورودی، اجزه ورود به سلول را دارد. دروازه فراموشی با کنترل وضعیت داخلی سلول تعیین می‌کند کدام بخش باید به روزرسانی شود. سرانجام، دروازه خروجی آنچه را که به خارج از سلول بر روی خط لوله خروجی رانده می‌شود، کنترل می‌کند. معمول ترین قوانین به روزرسانی برای یک سلول LSTM به صورت (۱) تا (۶) تعریف می‌شود

$$i_t = \sigma(w_i x_t + v_i h_{t-1} + b_i) \quad (1)$$

$$f_t = \sigma(w_f x_t + v_f h_{t-1} + b_f) \quad (2)$$

$$o_t = \sigma(w_o x_t + v_o h_{t-1} + b_o) \quad (3)$$

$$\bar{c}_t = \tanh(w_c x_t + v_c h_{t-1} + b_c) \quad (4)$$



شکل ۲: معماری LSTM پیاده‌سازی شده در روش پیشنهادی.

جدول ۳: ابرپارامترهای اصلی جهت بهینه‌سازی GRU.

ابرپارامترها	دامنه	مقدار انتخاب شده
تعداد لایه‌های مخفی	۵، ۴، ۳، ۲، ۱	۲
Batch size	۸۰، ۵۰، ۴۰، ۳۰، ۲۰، ۱۰	۸۰
نرخ یادگیری	۰.۰۱، ۰.۰۰۵، ۰.۰۱	۰.۰۱
LSTM unit number	۲۵۶، ۱۲۸، ۶۴، ۳۲	۱۲۸ تا ۶۴
Dropout	۰.۱، ۰.۰۵، ۰.۰۲	۰.۰۲
Gradient threshold	۰.۰۱، ۰.۰۳، ۰.۰۲، ۰.۰۱	۰.۰۱

جدول ۲: ابرپارامترهای اصلی برای بهینه‌سازی LSTM.

ابرپارامترها	دامنه	مقدار انتخاب شده
تعداد لایه‌های مخفی	۵، ۴، ۳، ۲، ۱	۲
Batch size	۸۰، ۵۰، ۴۰، ۳۰، ۲۰، ۱۰	۸۰
نرخ یادگیری	۰.۰۰۱، ۰.۰۰۰۵، ۰.۰۰۱	۰.۰۱
LSTM unit number	۲۵۶، ۱۲۸، ۶۴، ۳۲	۱۲۸ تا ۶۴
Dropout	۰.۱، ۰.۰۵، ۰.۰۲	۰.۰۲
Gradient threshold	۰.۰۱، ۰.۰۳، ۰.۰۲، ۰.۰۱	۰.۰۱

معماری GRU مشابه معماری LSTM است و لایه‌های موجود در آن هیچ فرقی ندارند. تنها تفاوت آن، وجود گره‌های GRU به جای گره‌های LSTM است. معماری این گره‌ها باعث کاهش مدت زمان آموزش می‌شود و سبب این که در آموزش LSTM وجود دارد در این معماری وجود ندارد. در جدول ۳ ابرپارامترهای موجود در بهینه‌سازی الگوریتم GRU نشان داده است.

در بهینه‌سازی این پارامترها، استفاده از برخی الگوریتم‌های تکاملی می‌تواند مفید باشد؛ اما این روش‌ها وقت‌گیر هستند و لذا به روزرسانی این ابرپارامترها و انتخاب مقدار بهینه به صورت آزمون و خطا می‌تواند از نظر زمان به صرفه باشد؛ زیرا انتخاب مقدار نزدیک به مقدار بهینه نیز کافی است و دقت الگوریتم زیاد تغییر نمی‌کند. جهت محاسبه خطای زمان‌های مختلف و به روزرسانی مقادیر وزن‌ها ازتابع خطای استفاده شده است. محاسبه خطای به صورت (۱۲) است

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (12)$$

در واقع برای مقایسه نتایج پیش‌بینی شده با مقادیر اصلی و کاهش خطای (۱۲) استفاده شده است. هدف اصلی در تعریف تابع RMSE، حداقل‌سازی خطای است. در (۱۲) y_i و \hat{y}_i به ترتیب مقادیر واقعی و پیش‌بینی شده هستند.

۳-۱-k میانگین

رگرسیون، یک روش برای پیش‌بینی و خوشبندی، یک روش برای طبقه‌بندی است که افراد (نقاط داده) را به گروه‌های مختلف (خوشبندی)

۱-۳ پیاده‌سازی روش پیشنهادی

جهت پیاده‌سازی روش پیشنهادی از محیط برنامه‌نویسی متلب نسخه ۲۰۲۰ بر روی سیستمی با مشخصات Intel Core i7-۲۶۲۰M CPU و RAM ۶ GB استفاده شده است. در واقع ابزار متلب با توجه به پشتیبانی بسیار قوی از الگوریتم‌های هوشمند مورد استفاده قرار گرفته و همچنین این نرم‌افزار، کتابخانه‌های جدید یادگیری ماشین را به خوبی پشتیبانی می‌کند.

۱-۳-۱ LSTM

در روش پیشنهادی، استفاده از الگوریتم‌های LSTM و GRU برای آموزش شبکه و استفاده از k -میانگین برای طبقه‌بندی داده‌است. معماری LSTM پیاده‌سازی شده در روش پیشنهادی در شکل ۲ نشان داده شده و همچنین ابرپارامترهای اصلی برای بهینه‌سازی LSTM در جدول ۲ آمده است.

۱-۳-۲ GRU

در مقایسه با LSTM، GRU می‌تواند ضمن بهبود ساختار کنترل گیت، مشکل گرادیان در RNN را حل کند. از آنجا که تعداد دروازه‌ها از ۳ به ۲ تغییر یافته است، پارامترهای آموزش کاهش یافته و در نتیجه سرعت آموزش افزایش پیدا می‌کند. GRU از دو متشکل از یک تابع سیگموئید و یک عمل ضرب برای کنترل انتخاب اطلاعات استفاده می‌نماید.

۱-۲-۳ مجموعه داده

علی‌رغم بعضی اقدامات، هنوز دو مجموعه داده NSL-KDD و KDDCUP۹۹ مشکلاتی دارند. در سال‌های اخیر، برخی از محققان مشاهده کرده‌اند که نقص این دو مجموعه داده تأثیر منفی بر عملکرد طبقه‌بندی سیستم‌های تشخیص نفوذ خواهد داشت. اول اینکه کمبود نمونه‌های حملات سطح پایین که در شبکه‌های امروزی رایج است، وجود دارد. در واقع حملات سطح پایین به تدریج با گذشت زمان، خصوصیت خود را از دست داده و به ترافیک عادی تبدیل می‌شوند که نوعی حمله پنهانی هستند. دوم اینکه مجموعه داده‌ای آزمایشی این دو مجموعه داده، شامل بخشی از داده‌های جدید هستند و منجر به افزایش نرخ هشدار غلط می‌شوند. سوم اینکه با تغییر محیط شبکه با گذشت زمان، داده‌های زاید زیادی در این دو مجموعه داده وجود دارد که بسیار نامعمول به نظر می‌رسند. به‌طور خلاصه، اگرچه این دو مجموعه داده، سه‌هم قابل توجهی در توسعه تشخیص نفوذ داشته‌اند، اکنون برای بازتاب فضای واقعی شبکه کافی نیستند [۴۱] و بنابراین در این پژوهش از مجموعه داده عمومی UNSW-NB۱۵ استفاده می‌شود که توسط آزمایشگاه مرکز امنیت سایری استرالیا (ACCS) ایجاد گردیده است. رفتارهای غیرطبیعی در UNSW-NB۱۵ به ۹ دسته اصلی تقسیم می‌شوند و هر کلاس رفتار غیرطبیعی نیز به رفتارهای خاص حمله داده تقسیم می‌گردد. حملات موجود در مجموعه داده UNSW-NB۱۵ در جدول ۴ نشان داده شده و همچنین تعداد داده‌های استفاده‌شده جهت آموزش و آزمایش شبکه در جدول ۵ آمده است.

مجموعه داده UNSW-NB۱۵ دارای تعداد ویژگی‌های زیادی است؛ اما چون قرار است که ترافیک حمله این مجموعه داده با ترافیک نرمال مجموعه داده SDN-IoT ادغام شود در این مجموعه داده، ویژگی‌های مشترک یعنی زمان ارسال، آدرس مبدأ، آدرس مقصد، نوع پروتکل و طول پسته انتخاب می‌شوند. در مجموعه داده‌ها - با توجه به اینکه ویژگی نوع پروتکل از نوع رشته است - برای تبدیل این ویژگی به صورت صحیح به شکل بعدی عمل می‌شود. در ابتدا به جای اسامی هر کدام از پروتکل‌ها از اعداد صحیح در جدول ۶ که نگاشت نوع پروتکل در مجموعه داده‌ها به عدد صحیح را نشان می‌دهد، استفاده شده است. همچنین نقطه‌ای را که در بین آدرس‌ها و زمان‌ها وجود دارد حذف کرده و سپس با استفاده از نرمال‌سازی، همه ستون‌ها به روزرسانی شده است.

۲-۲-۳ معیارهای ارزیابی

در این مقاله برای ارزیابی، پارامترهای TNR , TPR , FPR , FNR و ACC ، محاسبه و هر کدام از این معیارها در ادامه توصیف شده است. - معیار TNR : معیاری است جهت نشان‌دادن نمونه‌هایی که سیستم آنها را به‌اشتباه، عضو دسته منفی تشخیص داده است؛ در حالی که این نمونه‌ها عضو دسته مثبت هستند. این معیار با کمک (۱۳) محاسبه می‌شود. در (۱۳)، TN تعداد مواردی است که در آن هر دو کلاس واقعی و پیش‌بینی شده، منفی هستند. همچنین FP تعداد مواردی است که در آن کلاس واقعی داده‌ها منفی است؛ اما کلاس پیش‌بینی شده، مثبت است

$$TNR = \frac{TN}{TN + FP} \quad (13)$$

1. True Negative
2. False Positive

جدول ۴: حملات موجود در مجموعه داده UNSW-NB۱۵

برچسب	اندازه	توزیع (%)
Normal	۵۶۰۰۰	۳۱۹۴
Backdoor	۱۷۴۶	۱
Analysis	۲۰۰	۱۱۴
Fuzzers	۱۸۱۸۴	۱۰۳۰
Shellcode	۱۱۳۳	۰۶۵
Reconnaissance	۱۰۴۹۱	۵۹۸
Exploits	۳۳۳۹۳	۱۹۰۴
DoS	۱۲۲۶۴	۶۹۹
Worms	۱۳۰	۰۰۷
Generic	۴۰۰۰	۲۲۸۱
Total	۱۷۵۳۴۱	۱۰۰

طبقه‌بندی می‌کند و الگوریتمی مؤثر برای داده‌های با حجم زیاد است. خوشبندی یک روش داده‌کاوی بدون نظارت است و این بدان معناست که این نوع الگوریتم‌ها به مجموعه داده‌ای آموزشی نیاز ندارند. از محبوب‌ترین روش‌های خوشبندی، خوشبندی مبتنی بر بخش‌بندی و مبتنی بر سلسه‌مراتب است. خوشبندی k -میانگین که در آن k تعداد خوشبندی را نشان می‌دهد، نوعی خوشبندی مبتنی بر بخش‌بندی است. در خوشبندی k -میانگین، هر خوشبندی توسط مرکز (یا میانگین) نقاط داده در خوشبندی تعريف می‌شود.

جهت شروع فرایند خوشبندی، k -میانگین ابتدا به انتخاب مقدار k یا همان تعداد خوشبندی‌ها نیاز دارد و سپس k نقطه داده به عنوان مرکز اصلی انتخاب می‌شود. می‌توان k مرکز را به صورت تصادفی یا بر اساس توزیع داده انتخاب کرد. بعد از آن فاصله هر نقطه داده تا هر مرکز محاسبه می‌شود و یک نقطه داده، عضو خوشبندی است که از همه خوشبندی‌های دیگر به آن نزدیک‌تر است. هنگامی که همه نقاط داده درون یک خوشبندی قرار می‌گیرند، مرکز نقاط یک خوشبندی مجدد محاسبه می‌شود. فواصل هر نقطه داده تا هر مرکز جدید نیز محاسبه می‌شود و به دنبال آن دسته‌بندی مجدد نقاط بر اساس خوشبندی‌ها بر اساس قانون کمترین فاصله، انجام می‌شود [۴۰].

روش‌ها و الگوریتم‌های متعددی برای تبدیل داده‌ها به گروه‌های هم‌شکل یا مشابه وجود دارد. الگوریتم k -میانگین یکی از ساده‌ترین الگوریتم‌ها در داده‌کاوی به خصوص در حوزه یادگیری نظارت‌نشده است. درجه پیچیدگی محاسباتی این الگوریتم برابر با $O(n^{dk+1})$ است که n تعداد اشیاء، d بعد ویژگی‌ها و k تعداد خوشبندی‌ها می‌باشد. همچنین پیچیدگی زمانی برای این الگوریتم برابر با $O(nkdi)$ است که البته منظور از i تعداد تکرارهای الگوریتم برای رسیدن به جواب بهینه است. با توجه به اینکه بعد از پیش‌بینی داده‌ها توسط LSTM و GRU داده‌های جدید دارای ۱ ویژگی و ۲ خوشبندی هستند، پیچیدگی زمانی و محاسباتی بسیار کم است. از طرف دیگر با توجه به آنکه داده‌های مورد استفاده در این مرحله به صورت منظم هستند، انتخاب مرکز اولیه که یکی از مشکلات این الگوریتم است دیگر تأثیر زیادی نخواهد داشت.

۲-۳ نتایج تجربی

جهت ارزیابی روش پیشنهادی، برخی آزمایش‌ها، انجام و سپس نتایج آنها گزارش شده است. این بخش مقاله در سه زیربخش سازمان‌دهی گردیده است.

جدول ۵: مجموعه داده‌های استفاده شده برای آموزش و آزمایش شبکه.

نام مجموعه داده	داده‌های طبیعی	داده‌های غیرطبیعی	تعداد داده‌های آموزشی	تعداد داده‌های آزمایشی	توزیع داده‌ها
SI-dataset	۳۰۰۰	۱۵۰۰۰	۳۱۵۰۰	۱۳۵۰۰	۷۰٪ آموزشی ۳۰٪ آزمایشی
SI-UNSW-dataset	۳۰۰۰	۱۵۰۰۰	۳۱۵۰۰	۱۳۵۰۰	۷۰٪ آموزشی ۳۰٪ آزمایشی

جدول ۶: نگاشت نوع پروتکل در مجموعه داده‌ها به عدد صحیح.

پروتکل	شماره تخصیص یافته	پروتکل	شماره تخصیص یافته	پروتکل	شماره تخصیص یافته
BJNP	۱	DIAMETER	۲۲	PKIX-CRL	۴۳
DHCP	۲	DISTCC	۲۳	RSL	۴۴
DNS	۳	ESP	۲۴	RSVP	۴۵
HTTP	۴	Gearman	۲۵	SAB	۴۶
ICMP	۵	GQUIC	۲۶	SIP	۴۷
IGMPv۲	۶	GSMTAP	۲۷	SSDP	۴۸
MDNS	۷	GTP	۲۸	SSL	۴۹
NTP	۸	HTTP/XML	۲۹	SSLv۲	۵۰
SSH	۹	ICP	۳۰	STUN	۵۱
SSHv۲	۱۰	IGMPv۳	۳۱	TCPCL	۵۲
TCP	۱۱	IPv۴	۳۲	TFP over TCP	۵۳
TLSv۱.۲	۱۲	ISAKMP	۳۳	TLSv۱	۵۴
UDP	۱۳	LISP	۳۴	TLSv۱.۲	۵۵
KNXnet/IP	۱۴	MIH	۳۵	TLSv۱.۳	۵۶
ADwin Config	۱۵	MPTCP	۳۶	UDPENCAP	۵۷
AJP۱۳	۱۶	NBNS	۳۷	WOW	۵۸
ASAP	۱۷	NDPS	۳۸	XMPP/XML	۵۹
AX۴۰۰۰	۱۸	NVMe/TCP	۳۹	Ospf	۶۰
BFD Control	۱۹	OCSP	۴۰	Rdp	۶۱
BROWSER	۲۰	OpcUa	۴۱		
DCERPC	۲۱	PCEP	۴۲		

$$FPR = \frac{FP}{FP + TN} \quad (16)$$

- معیار دقت یا ACC : دقت معیاری برای بررسی میزان خوب بودن یک الگوریتم است و به صورت (۱۷) محاسبه می‌شود

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} \quad (17)$$

۳-۲-۳ ارزیابی روش پیشنهادی

در این بخش، کارایی روش پیشنهادی با انجام آزمایش‌های متعدد ارزیابی شده و جهت ارزیابی هر کدام از الگوریتم‌های LSTM و GRU دو آزمایش متفاوت انجام گردیده است. در آزمایش اول برای هر کدام از این الگوریتم‌ها، مجموعه داده SI در مرحله آموزش و مجموعه داده SI-UNSW در مرحله آزمون استفاده شده است. در آزمایش دو، مجموعه داده SI-UNSW در مرحله آموزش و مجموعه داده SI در مرحله آزمون مورد استفاده قرار گرفته و نتایج آزمایش اول و دوم برای الگوریتم‌های LSTM و GRU در جداول ۷ و ۸ ارائه شده است. در این جداول در آزمایش ۱ از مجموعه داده‌های مشابه، جهت آموزش و آزمون استفاده شده است؛ یعنی داده‌های استفاده شده جهت آموزش و آزمون از یک مجموعه داده هستند.

- معیار پوشش (TPR (*Recall*)): این معیار میزان حساسیت یک روش در تشخیص موارد مثبت است. در (۱۴) TP مواردی است که کلاس واقعی و پیش‌بینی شده، هر دو مثبت هستند و نیز FN مواردی است که در آن موارد کلاس واقعی داده‌ها مثبت است؛ اما کلاس پیش‌بینی شده، منفی است

$$TPR = \frac{TP}{TN + FP} \quad (14)$$

- معیار FNR : این معیار نشان‌دهنده مواردی است که دسته‌بند، آنها را عضو دسته منفی تشخیص داده است؛ در حالی که آنها عضو دسته مثبت هستند. این معیار با (۱۵) محاسبه می‌شود

$$FNR = \frac{FN}{FN + TP} \quad (15)$$

- معیار FPR : این معیار نشان‌دهنده مواردی است که دسته‌بند، آنها را مثبت تشخیص داده است؛ در حالی که آنها عضو دسته منفی هستند و به صورت (۱۶) محاسبه می‌شود

1. True Positive
2. False Negative

جدول ۷: نتایج آزمایش اول و دوم برای الگوریتم‌های LSTM.

نتایج آزمایش با مجموعه داده‌های آموزش						
نتایج آزمایش با مجموعه داده‌های آزمایش						
F1	Precision	TNR	TPR	FNR	FPR	ACC
۹۹/۱	۹۹/۴	۹۸/۹	۹۸/۸	۱/۱	۱/۱	۹۸/۸
۹۹/۸	۹۹/۷	۹۹/۴	۹۹/۹	۰/۱	۰/۵	۹۹/۷
۹۷/۸	۹۹/۹	۹۹/۹	۹۵/۸	۴/۱	۰/۰۷	۹۷/۱

جدول ۸: نتایج آزمایش اول و دوم برای الگوریتم‌های GRU.

نتایج آزمایش با مجموعه داده‌های آموزش						
نتایج آزمایش با مجموعه داده‌های آزمایش						
F1	Precision	TNR	TPR	FNR	FPR	ACC
۹۹/۲	۹۹/۴	۹۸/۸	۹۹	۰/۹	۱/۱	۹۹
۹۹/۹	۱	۱	۹۹/۹	۰/۰۷	۰	۹۹/۹
۹۶/۸	۹۹/۲	۹۸/۳	۹۴/۵	۵/۵	۱/۶	۹۵/۶

جدول ۹: نتایج مقایسه کارایی روش پیشنهادی و سایر روش‌های مشابه.

روش	ACC	TPR	FPR	MZIا و معایب
Silveira و همکاران [۳۲]	۹۳	-	۶	روش پیشنهادی با رگرسیون منطقی دقت خوبی دارد؛ اما FPR نیز بالاست.
Wani و همکاران [۳۳]	۹۵/۹	۹۶/۴	۷	الگوریتم MLP دقت بالایی دارد؛ اما همچنان FPR بالاست و فقط جهت شناسایی حمله DDoS است.
Hamza و همکاران [۴۰]	بالا	-	-	الگوریتم بیز و استفاده از MUD برای بهدست آوردن اضایای داده‌های طبیعی و غیرطبیعی و نیز کارایی بهتر از Snort ذکر نکردن مقدار FP و ACC
Hamza و همکاران [۴۱]	۹۷/۵	۷۲/۳	۲/۴	استفاده از MUD که نیاز به سخت‌افزار اضافی دارد و همچنین استفاده از ۴ الگوریتم به صورت ترکیبی که بسیار وقت‌گیر می‌باشد؛ این در حالیست که TPR بسیار پایین است.
روش پیشنهادی	۹۹	۹۹	۱/۱	دقت و TPR بالا، FPR بسیار پایین و مدت زمان آموزش کمتر از MZIا روش پیشنهادی است.

در سرآیند جریان‌ها، سیستم تشخیص نفوذ، آموزش مجدد می‌بیند. در واقع ابیندا در مرحله اول با PCA تعداد ویژگی‌ها کاهش می‌یابد و سپس با استفاده از X-means با انتخاب الگوریتم‌های فرایند کلاس‌بندی انجام شده و سپس خروجی هر دو مرحله در اختیار الگوریتم‌های boundary detection و Zنجیره مارکوف برای خوشه‌بندی نهایی قرار می‌گیرد. همان طور که مشاهده می‌شود این روش از دو مرحله استفاده می‌کند که برای محیط SDN-IoT مناسب نیست؛ زیرا دستگاه‌های اینترنت اشیا در مدت زمان بسیار کوتاه، ترافیک بسیار زیادی تولید می‌کنند و سوئیچ‌های شبکه در خواسته‌های زیادی را برای کنترل می‌فرستند که با دو مرحله کردن فرایند شناسایی با تأخیر مواجه می‌شود. از طرفی دیگر هنوز استاندارد اضافه کردن MUD به دستگاه‌های اینترنت اشیا رواج پیدا نکرده است.

۵- نتیجه‌گیری و پژوهش‌های آتی

در این مقاله، یک روش جدید ترکیبی با بهره‌مندی از MZIا استراتژی به کارهای در الگوریتم‌های یادگیری ماشین LSTM و GRU در راستای بهبود عملکرد یک سیستم تشخیص نفوذ در محیط SDN-IoT، پیشنهاد و سه ویژگی مهم در روش پیشنهادی بیان شده است:

- روش پیشنهادی با درنظرگرفتن ترافیک بسیار زیاد دستگاه‌های اینترنت اشیا، زمان پاسخ سیستم تشخیص نفوذ به سوئیچ‌ها و ... پیشنهاد شده است.

- استفاده از مجموعه داده مرتبط با ترافیک SDN-IoT: مزور ادبیات نشان می‌دهد که در اغلب پژوهش‌های موجود SDN-IoT، توجه خاصی نسبت به استفاده از مجموعه داده‌های بهروزنشده است.
- قابلیت پیاده‌سازی راحت و بدون نیاز به سخت‌افزارهای خاص: متساقانه در بسیاری از پژوهش‌ها نسبت به سهولت پیاده‌سازی روش‌ها به صورت عملی، توجه نشده است.

همان طور که نتایج آزمایش‌ها در جداول ۷ و ۸ نشان داده است، الگوریتم GRU و LSTM تقریباً دارای نتایج یکسانی بوده‌اند به جز زمان آموزش که GRU حدود ۳۰٪ از الگوریتم LSTM بهتر بوده است.

در آزمایش ۲، ابیندا داده‌ها با مجموعه داده SI آموزش دیده و سپس با مجموعه داده UNSW مورد آزمایش قرار گرفته‌اند. در واقع در مجموعه داده آزمون، حملات جدیدی وجود دارند که در داده‌های آموزشی، وجود نداشته‌اند. هدف اصلی در این آزمایش، بررسی شبکه برای حملات جدید بوده که نتایج، دققی در حدود ۹۹/۹٪ را نشان می‌دهند.

در آزمایش ۳، ابیندا داده‌ها با مجموعه داده SI-UNSW آموزش دیده و سپس با مجموعه داده SI مورد آزمون قرار گرفته‌اند. همچنین نتایج ارزیابی الگوریتم‌ها نشان می‌دهند که بر عکس آزمایش ۲، در اینجا دقیق کاهش یافته و FNR نیز افزایش داشته است. در واقع دلیل این امر آن است که ترافیک غیرنرم‌مالی که در مرحله آزمایش مورد استفاده قرار گرفته است از همان شبکه‌ای که داده‌های نرم‌مال به دست آمدند به وجود آمده؛ اما در مرحله آموزش مورد استفاده قرار نگرفته و این موضوع باعث شده که شبکه، این داده‌ها را تا حدی شبیه داده‌های نرم‌مال شناسایی کند؛ هرچند دقیق و بقیه معیارهای ارزیابی هنوز مناسب بوده و جهت شناسایی حملاتی که در مرحله آموزش استفاده نشده‌اند بسیار عالی عمل کرده‌اند.

۶- مقایسه روش پیشنهادی با سایر روش‌ها

در این بخش، مقایسه کارایی روش پیشنهادی و سایر روش‌های قبلی مشابه انجام شده و سپس نتایج مقایسه در جدول ۹ ارائه گردیده است. در این جدول، مقایسه‌ای بین روش پیشنهادی و روش‌های دیگر انجام شده و همان طور که مشاهده می‌شود، روش Zhang و همکاران [۴۱] با استفاده از مشخصات موجود در MUD هر دستگاه، سیستم تشخیص نفوذ آموزش می‌بیند. سپس در مرحله دیگری با استفاده از ویژگی‌های موجود

- [18] S. K. Tayyaba, M. A. Shah, O. A. Khan, and A. W. Ahmed, "Software defined network (SDN) based internet of things (IoT) a road ahead," in *Proc. of the International Conf. on Future Networks and Distributed Systems*, Article ID: 15, 8 pp., Cambridge, UK, 19-20 Jul. 2017.
- [19] R. Bhatia, S. Benno, J. Esteban, T. V. Lakshman, and J. Grogan, "Unsupervised machine learning for network-centric anomaly detection in IoT," in *Proc. of the 3rd ACM Context Workshop on Big Data, Machine Learning and Artificial Intelligence for Data Communication Networks*, pp. 42-48, Orlando, FL, USA, 9-9 Dec. 2019.
- [20] D. Arellanes and K. K. Lau, "Evaluating IoT service composition mechanisms for the scalability of IoT systems," *Future Generation Computer Systems*, vol. 108, pp. 827-848, Mar. 2020.
- [21] S. Bera, S. Misra, and A. V. Vasilakos, "Software-defined networking for internet of things: a survey," *IEEE Internet of Things J.*, vol. 4, no. 6, pp. 1994-2008, Aug. 2017.
- [22] M. Singh and G. Baranwal, "Quality of Service (QoS) in internet of things," in *Proc. 3rd Int. Conf. on Internet of Things: Smart Innovation and Usages, IoT-SIU'18*, 6 pp., Bhimtal, India, 23-24 Feb. 2018.
- [23] T. A. Nguyen, D. Min, and E. Choi, "A hierarchical modeling and analysis framework for availability and security quantification of IoT infrastructures," *Electronics*, vol. 9, no. 1, Article ID: 155, Jan. 2020.
- [24] R. Swami, M. Dave, and V. Ranga, "Voting-based intrusion detection framework for securing software-defined networks," *Concurrency and Computation: Practice and Experience*, vol. 32, no. 24, Article ID: e5927, 25 Dec. 2020.
- [25] I. Rabet, et al., "SDMob: SDN-based mobility management for IoT networks," *J. of Sensor and Actuator Networks*, vol. 11, no. 1, Article ID: 8, 2022.
- [26] B. Alzahrani and N. Fotiou, "Enhancing internet of things security using software-defined networking," *J. of Systems Architecture*, vol. 110, Article ID: pp. 101779, Nov. 2020.
- [27] A. Hamza, H. H. Gharakheili, and V. Sivaraman, "Combining MUD policies with SDN for IoT intrusion detection," in *Proc. of the Workshop on IoT Security and Privacy*, 7 pp., Budapest, Hungary, 20-20, Aug. 2018.
- [28] G. Shravanya, N. H. Swati, R. P. Rustagi, and O. Sharma, "Securing distributed SDN controller network from induced DoS attacks," in *Proc., IEEE International Conf. on Cloud Computing in Emerging Markets, CCEM'19*, pp. 9-16, Bengaluru, India, 19-20 Sept. 2019.
- [29] A. Hamza, H. H. Gharakheili, T. A. Benson, and V. Sivaraman, "Detecting volumetric attacks on IoT devices via SDN-based monitoring of mud activity," in *Proc. of the ACM Symp. on SDN Research*, pp. 36-48, San Jose, CA, USA, 3-4 Apr. 2019.
- [30] C. Xu, H. Lin, Y. Wu, X. Guo, and W. Lin, "An SDN FV-based DDoS defense technology for smart cities," *IEEE Access*, vol. 7, pp. 137856-137874, 2019.
- [31] O. Salman, I. H. Elhajj, A. Chehab, and A. Kayssi, "A machine learning based framework for IoT device identification and abnormal traffic detection," *Trans. on Emerging Telecommunications Technologies*, vol. 33, no. 3, Article ID: e3743, Mar. 2022.
- [32] F. A. F. Silveira, F. Lima-Filho, F. S. D. Silva, A. D. M. B. Junior, and L. F. Silveira, "Smart detection-IoT: a DDoS sensor system for Internet of Things," in *Proc. Int. Conf. on Systems, Signals, and Image Processing, IWSSIP'20*, pp. 343-348, Niteroi, Brazil, 1-3 Jul. 2020.
- [33] A. Wani and S. Revathi, "DDoS detection and alleviation in IoT using SDN (SDN IoT-DDoS-DA)," *J. of the Institution of Engineers (India): Series B*, vol. 101, no. 3, pp. 117-128, Apr. 2020.
- [34] M. P. Novaes, L. F. Carvalho, J. Lloret, and M. L. Proenca, "Long short-term memory and fuzzy logic for anomaly detection and mitigation in software-defined network environment," *IEEE Access*, vol. 8, pp. 83765-83781, 2020.
- [35] Y. Meidan, et al., "A novel approach for detecting vulnerable IoT devices connected behind a home NAT," *Computers & Security*, vol. 97, Article ID: 101968, Oct. 2020.
- [36] S. H. Khan, A. R. Arko, and A. Chakrabarty, "Anomaly detection in IoT using machine learning," In: S. Misra, A. K. Tyagi, V. Piuri, and L. Garg (Eds.), *Artificial Intelligence for Cloud and Edge Computing Springer, Chap*, pp. 237-254, 2022.
- [37] M. Abdullahi, et al., "Detecting cybersecurity attacks in internet of things using artificial intelligence methods: a systematic literature review," *Electronics*, vol. 11, no. 2, Article ID: e3743198, 2022.
- [38] M. V. Assis, L. F. Carvalho, J. Lloret, and M. L. Proenca Jr, "A GRU deep learning system against attacks in software defined networks," *J. of Network and Computer Applications*, vol. 177, Article ID: 102942, 2021.

نتایج ارزیابی نشان می‌دهند که روش پیشنهادی، نتایج خوبی در زمینه تشخیص نفوذ در محیط SDN-IoT دارد. عدم وجود یک مجموعه داده استاندارد جهت آموزش روش‌های پیشنهادی در این زمینه، چالشی است که می‌تواند پژوهشگران را سردرگم کند؛ بنابراین ارائه یک مجموعه داده استاندارد مناسب با SDN-IoT می‌تواند انجام پژوهش در این زمینه را تسهیل نماید. همچنین برای کارهای آتی می‌توان از الگوریتم‌های دیگر یادگیری ماشین مانند CNN، DNN، RBM و ... استفاده کرد. در واقع الگوریتم‌های بازگشتی در آموزش وقت‌گیر هستند؛ لذا ارائه یک روش که بتواند مدت زمان آموزش را کاهش دهد می‌تواند مفید واقع شود.

مراجع

- J. Gubbi, R. Buyya, S. Marusic, and M. Palaniswami, "Internet of Things (IoT): a vision, architectural elements and future directions," *Future Generation Computer Systems*, vol. 29, no. 7, pp. 1645-1660, Sep. 2013.
- R. Kushwah, P. K. Batra, and A. Jain, "Internet of things architectural elements, challenges and future directions," in *Proc. 6th Int. Conf. on Signal Processing and Communication, ICSC'20*, 5 pp., Noida, India, 5-7 Mar. 2020.
- A. Koohang, C. S. Sargent, J. H. Nord, and J. Paliszkiewicz, "Internet of Things (IoT): from awareness to continued use," *International J. of Information Management*, vol. 62, Article ID: 102442-, Feb. 2020.
- U. Farooq, N. Tariq, M. Asim, T. Baker, and A. Al-Shamma'a, "Machine learning and the internet of things security: solutions and open challenges," *J. of Parallel and Distributed Computing*, vol. 162, pp. 89-104, Apr. 2022.
- P. Mishra, A. Biswal, S. Garg, R. Lu, M. Tiwary, and D. Puthal, "Software defined internet of things security: properties, state of the art, and future research," *IEEE Wireless Communications*, vol. 27, no. 3, pp. 10-16, Jun. 2020.
- A. E. Omolara, et al., "The internet of things security: a survey encompassing unexplored areas and new insights," *Computers & Security*, vol. 112, Article ID: 102494, Jan. 2022.
- X. Guo, H. Lin, Z. Li, and M. Peng, "Deep-reinforcement-learning-based QoS-aware secure routing for SDN-IoT," *IEEE Internet of Things J.*, vol. 7, no. 7, pp. 6242-6251, Dec. 2019.
- P. K. Sharma, J. H. Park, Y. S. Jeong, and J. H. Park, "SHSec: SDN based secure smart home network architecture for internet of things," *Mobile Networks and Applications*, vol. 24, pp. 913-924 2018.
- S. Rathore, B. W. Kwon, and J. H. Park, "BlockSeclIoTNet: blockchain-based decentralized security architecture for IoT network," *J. of Network and Computer Applications*, vol. 143, pp. 167-177, Oct. 2019.
- H. Honar Pajoh, M. Rashid, F. Alam, and S. Demidenko, "Multi-layer blockchain-based security architecture for internet of things," *Sensors*, vol. 21, no. 3, Article ID: 772, 2021.
- A. Dawoud, S. Shahristani, and C. Raun, "Deep learning and software-defined networks: towards secure IoT architecture," *Internet of Things*, vol. 3-4, pp. 82-89, Oct. 2018.
- N. McKeown, et al., "OpenFlow: enabling innovation in campus networks," *ACM Sigcomm Computer Communication Review*, vol. 38, no. 2, pp. 69-74, Apr. 2008.
- M. Babiker Mohamed, et al., "A comprehensive survey on secure software-defined network for the Internet of Things," *Trans. on Emerging Telecommunications Technologies*, vol. 33, no. 1, Article ID: e4391, Jan. 2022.
- D. Sovilj, P. Budnarain, S. Sanner, G. Salmon, and M. Rao, "A comparative evaluation of unsupervised deep architectures for intrusion detection in sequential data streams," *Expert Systems with Applications*, vol. 159, Article ID: 113577, Nov. 2020.
- C. W. Chang, C. Y. Chang, and Y. Y. Lin, "A hybrid CNN and LSTM-based deep learning model for abnormal behavior detection," *Multimedia Tools and Applications*, vol. 81, no. 2, pp. 1-19, Apr. 2022.
- K. Smagulova and A. P. James, "A survey on LSTM memristive neural network architectures and applications," *the European Physical J. Special Topics*, vol. 228, no. 10, pp. 2313-2324, Oct. 2019.
- N. Alqudah, M. Y. Qussai, "Machine learning for traffic analysis: a review," *Procedia Computer Science*, vol. 170, pp. 911-916, 2020.

فضل الله ادینیا در سال ۱۳۶۵ مدرک کارشناسی مهندسی کامپیوتر خود را از دانشگاه صنعتی اصفهان و در سال ۱۳۶۸ مدرک کارشناسی ارشد مهندسی برق خود را از دانشگاه صنعتی شریف و در سال ۱۳۷۸ مدرک دکترای مهندسی کامپیوتر خود را از دانشگاه برنام آلمان دریافت نمود. هم‌اکنون دانشیار دانشکده مهندسی کامپیوتر دانشگاه یزد می‌باشد. زمینه‌های تحقیقاتی مورد علاقه ایشان عبارتند از: شبکه‌های کامپیوتری، مکان‌یابی در شبکه‌ها، امنیت رایانه و شبکه، زنجیره بلوکی و سیستم‌های توزیعی است.

مهدی بزدان دهکردی مدرک کارشناسی مهندسی کامپیوتر گرایش نرم‌افزار را در سال ۱۳۸۵ از دانشگاه یزد و مدرک کارشناسی ارشد و دکترای خود را بهترتبی در سال‌های ۱۳۸۸ و ۱۳۹۴ در رشته مهندسی کامپیوتر گرایش هوش مصنوعی از دانشگاه شیراز اخذ کرد. وی از سال ۱۳۹۴ در دانشکده مهندسی کامپیوتر دانشگاه یزد مشغول به فعالیت گردید و در حال حاضر عضو هیأت علمی این دانشکده می‌باشد. زمینه‌های پژوهشی مورد علاقه ایشان بینایی ماشین، یادگیری عمیق و تحلیل داده است.

- [39] A. S. Alshra'a, A. Farhat, and J. Seitz, "Deep learning algorithms for detecting denial of service attacks in software-defined networks," *Procedia Computer Science*, vol. 191pp. 254-263, 2021.
- [40] A. Likas, N. Vlassis, and J. J. Verbeek, "The global k-means clustering algorithm," *Pattern Recognition*, vol. 36, no. 2, pp. 451-461, Feb. 2003.
- [41] 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, Article ID: 101681, Feb. 2020.

ذکریا رئیسی در سال ۱۳۹۴ مدرک کارشناسی مهندسی کامپیوتر خود را از دانشگاه سیستان و بلوچستان و در سال ۱۳۹۹ مدرک کارشناسی ارشد مهندسی فناوری اطلاعات خود را از دانشگاه یزد دریافت نمود. زمینه‌های علمی مورد علاقه نامبرده شامل موضوعاتی مانند شبکه‌های کامپیوتری، امنیت شبکه، سیستم‌های توزیعی و مدیریت شبکه‌های کامپیوتری می‌باشد.