

بررسی رویکردهای یادگیری ماشین در امنیت اینترنت اشیا

وصال فیروزی*، داود بهره پور

¹ گروه کامپیوتر، واحد مشهد، دانشگاه آزاد اسلامی، مشهد، ایران. V.firoozi@mshdiau.ac.ir

² گروه کامپیوتر، واحد مشهد، دانشگاه آزاد اسلامی، مشهد، ایران. Bahrepour@mshdiau.ac.ir

چکیده

اینترنت اشیا بسیاری از جنبه های زندگی مدرن را پوشش داده است و از مراقبت های بهداشتی و حمل و نقل گرفته تا اتوماسیون خانگی و سیستم های کنترل صنعتی را متحول کرده است. با این حال، افزایش تعداد دستگاه های متصل منجر به افزایش تهدیدات امنیتی شده است. برای کاهش این تهدیدات، تکنیک های مختلف یادگیری ماشین و یادگیری عمیق بمنظور شناسایی حملات امنیتی اینترنت اشیا پیشنهاد شده اند. در این مطالعه تکنیک های یادگیری ماشین را دسته بندی کرده و به مرور اجمالی مطالعات انجام شده در رابطه با امنیت اینترنت اشیا در هر دسته می پردازیم. در نهایت موضوعات باز و چالش هایی که نیاز به توجه محققان این رشته دارند، معرفی می شود. این تحقیق پتانسیل قابل توجه رویکردهای یادگیری ماشین را در تقویت امنیت اینترنت اشیا روشن می کند و در نتیجه بینش های ارزشمندی را به محققان حوزه امنیت اینترنت اشیا ارائه می دهد.

واژه های کلیدی: امنیت، اینترنت اشیا، یادگیری عمیق، یادگیری ماشین.

1. مقدمه

اینترنت اشیا¹ (IoT) به شبکه‌ای از دستگاه‌های متصل به اینترنت، مانند تلفن‌های هوشمند، دستگاه‌های خانه هوشمند، حسگرهای صنعتی و دستگاه‌های پزشکی اشاره دارد [1]. اینترنت اشیا الگویی است که ارتباط طیف وسیعی از اشیاء و وسایل روزمره را در بر می‌گیرد. اشیا یا «چیزها» می‌توانند شامل حسگرها، پوشیدنی‌ها، لوازم خانگی، وسایل نقلیه و موارد دیگر باشند که همگی قادر به جمع‌آوری و تبادل داده‌ها با یکدیگر و با اینترنت هستند [2]. اینترنت اشیا در حوزه‌های مختلف کاربرد دارد و به طور مداوم با پیشرفت فناوری در حال گسترش است [3]. پیش‌بینی‌ها رشد قابل توجه در تعداد دستگاه‌های اینترنت اشیا در سرتاسر جهان را نشان می‌دهد، به طوری که تخمین‌ها حاکی از افزایش تقریباً سه برابری از 9/7 میلیارد دستگاه در سال 2020 به بیش از 29 میلیارد دستگاه تا سال 2030 است. طبق یک گزارش تحقیقات بازار، پیش‌بینی می‌شود که بازار جهانی امنیت اینترنت اشیا از سال 2022 تا 2027 رشد قابل توجهی داشته باشد. عواملی مانند افزایش تعداد دستگاه‌های اینترنت اشیا، تکثیر محاسبات ابری و نیاز به اقدامات امنیتی سختگیرانه باعث افزایش تقاضا برای راه حل‌های امنیتی اینترنت اشیا می‌شود [4].



شکل 1- حوزه های مختلف کاربردی اینترنت اشیا

برنامه های کاربردی اینترنت اشیا در دامنه‌های مختلفی قرار دارند و تطبیق پذیری و پتانسیل خود را به نمایش می‌گذارند. شکل 1، نمونه‌هایی از این کاربردها را نشان می‌دهد. برنامه‌های کاربردی متنوع اینترنت اشیا نمونه‌ای از پذیرش و تأثیر گسترده فناوری اینترنت اشیا در بخش‌های مختلف است [5]. در خانه‌های هوشمند دستگاه‌های اینترنت اشیا می‌توانند به طور یکپارچه نور، دما، امنیت و سرگرمی را مدیریت کنند و راحتی و اتوماسیون را فراهم کنند [6]. در زمینه شهرهای هوشمند، حسگرهای اینترنت اشیا نقش مهمی در نظارت و بهینه‌سازی ترافیک، کیفیت هوا، مدیریت زباله و سایر سیستم‌های شهری ایفا می‌کنند و به افزایش کارایی و پایداری کمک می‌کنند. در حوزه مراقبت‌های بهداشتی از دستگاه‌های پوشیدنی اینترنت اشیا و دستگاه‌های پزشکی برای نظارت مستمر سلامت، مشاوره از راه دور، و تسهیل درمان، ترویج خدمات مراقبت‌های بهداشتی شخصی و از راه دور استفاده می‌کند [6]. در کشاورزی با استفاده از حسگرها و دستگاه‌های اینترنت اشیا بر شرایط خاک، رشد

¹ Internet of Things

محصول و الگوهای آب و هوا نظارت می کنند و اینترنت اشیا کشاورزان را قادر می سازد تا تکنیک های کشاورزی دقیق را پیاده سازی کنند و عملکرد را بهبود بخشند [7].

در حوزه اتوماسیون صنعتی، حسگرها و دستگاه های اینترنت اشیا در نظارت و کنترل ماشین آلات و تجهیزات، بهینه سازی عملیات و به حداقل رساندن زمان خرابی کمک می کنند [8]. علاوه بر این، ظهور خودروهای متصل و مجهز به اتصال به اینترنت، به وسایل نقلیه اجازه می دهد تا با سایر دستگاه ها، شبکه ها و خدمات ارتباط برقرار کنند. این خودروها داده ها را جمع آوری و انتقال می دهند، دسترسی از راه دور به کنترل های وسیله نقلیه ارائه می کنند و طیف وسیعی از خدمات را به رانندگان و مسافران ارائه می کنند و تجربه کلی رانندگی را بهبود می بخشند. همچنین صنایع از این فناوری برای به حداکثر رساندن عملکردهای تجاری خود با رویکردهای هوشمندسازی و هوش تجاری استفاده می کنند.

اساسی ترین نیاز در شبکه اینترنت اشیا محافظت از کل سیستم ها، برنامه ها و دستگاه های متصل است. حجم عظیم کارهای شبکه اینترنت اشیا چالش های جدیدی را در حوزه های مختلفی از جمله مدیریت دستگاه، مدیریت داده، محاسبات، امنیت و حریم خصوصی و غیره معرفی می کند. با رشد اینترنت اشیا، نگرانی های امنیتی و تهدیدات بالقوه مختلفی مطرح می شود [9].

سیستم های اینترنت اشیا به دلیل ویژگی های منحصر به فرد خود، مانند تعداد زیاد دستگاه های درگیر، تنوع پروتکل های ارتباطی و قالب های داده، و نیاز به ارتباطات بلادرنگ، چالش های امنیتی متعددی را ارائه می کنند [10]. نادیده گرفته شدن حفره ها و قصورهای امنیتی در این فناوری، صنایع را با حملات سایبری مواجه می کند [11]. برخی از مهم ترین چالش های امنیتی در سیستم های اینترنت اشیا عبارتند از: امنیت دستگاه، امنیت داده ها، امنیت ارتباطات، حریم خصوصی، امنیت میان افزار و امنیت زنجیره تامین [12].

بدون یک سیستم قابل اعتماد، برنامه های کاربردی اینترنت اشیا، نمی توانند نیازهای مردم و جامعه را برآورده کنند و ممکن است تمام کارایی خود را از دست بدهند. به طور معمول، سیستم های اینترنت اشیا در چندین لایه، از جمله لایه ادراک یا حس، شبکه و ارتباطات داده لایه میان افزار یا لایه پشتیبانی و لایه کاربردی کار می کنند. هر یک از این لایه ها دارای مجموعه منحصر به فردی از وظایف و فناوری های مرتبط برای انجام در یک برنامه اینترنت اشیا هستند و هر لایه مجموعه جدیدی از مسائل و خطرات امنیتی را به همراه دارد. به عنوان مثال، حمله انکار سرویس² (DDoS)، حملات جعل سرویس، پرازیت، استراق سمع، دستکاری داده ها، حملات مخرب و غیره رایج ترین حملات اینترنت اشیا هستند [13]. بنابراین، بسته به ماهیت مسائل امنیتی، راه حل های بالقوه امنیتی اینترنت اشیا مانند احراز هویت، کنترل دسترسی، پیش بینی تهدید و خطر، تجزیه تحلیل بدافزار، تشخیص ناهنجاری یا نفوذ، و پیشگیری و غیره می تواند مفید باشد. پرداختن به این چالش ها نیازمند یک رویکرد چند لایه است که شامل پروتکل های امنیتی قوی، به روز رسانی مکرر نرم افزار، و نظارت و آزمایش مداوم برای شناسایی و رسیدگی به آسیب پذیری ها در صورت بروز می شود [14].

با توجه به ازدیاد تهدیدات و حملات امنیتی و پیچیدگی در حوادث امنیتی، تکنیک های مرسوم برای مقابله با آنها دیگر موثر نیستند. بنابراین یک سیستم امنیتی هوشمند مبتنی بر فناوری های مدرن که بتواند این نگرانی های امنیتی را برطرف کند، برای محافظت از نسل بعدی سیستم اینترنت اشیا ضروری است.

² Distributed denial-of-service

هوش مصنوعی یکی از مهم ترین فناوری ها برای توسعه سیستم های هوشمند است و به عنوان بخشی از انقلاب صنعتی چهارم [15] نیز در نظر گرفته می شود. بنابراین، با استفاده از دانش هوش مصنوعی، به ویژه یادگیری ماشین و یادگیری عمیق، می توان با ناهنجاری ها یا فعالیت های مخرب نامطلوب در اینترنت اشیا مقابله کرد.

به طور معمول، مدل های یادگیری عمیق و یادگیری ماشین شامل مجموعه ای از قوانین، روش ها یا توابع انتقال پیچیده هستند که بینش های مفید یا الگوهای داده ای جالب را از داده های امنیتی استخراج می کنند. بنابراین، می توان از مدل های امنیتی حاصل برای آموزش ماشین ها برای پیش بینی تهدیدها یا خطرات در مراحل اولیه، یا شناسایی ناهنجاری ها در اینترنت اشیا برای توسعه یک سیاست دفاعی مناسب استفاده کرد. تکنیک های یادگیری ماشین که معمولاً برای جنبه های امنیتی و تشخیص حملات به کار می روند شامل درخت های تصمیم، جنگل های تصادفی، K نزدیک ترین همسایه ها و ماشین های بردار پشتیبان می شود. اثربخشی این رویکردها به شدت به کیفیت مجموعه داده اتخاذ شده برای اهداف آموزش و ارزیابی بستگی دارد. برای ارزیابی عملکرد مدل های یادگیری ماشین، معیارهای عملکرد متنوعی از جمله دقت، یادآوری، امتیاز F1 استفاده می شود [16]. در یادگیری عمیق معماری های مختلف یادگیری عمیق مانند پرسپترون چند لایه^۳ (MLP)، شبکه های عصبی کانولوشن^۴ (CNN)، شبکه های عصبی تکراری^۵ (RNN)، شبکه های باور عمیق^۶ (DBN)، یا شبکه های ترکیبی می توانند برای مدل سازی امنیت اینترنت اشیا استفاده شوند [17].

با توجه به اهمیت روش های یادگیری ماشین در امنیت اینترنت اشیا، در این تحقیق، مطالعات انجام شده در زمینه استفاده از یادگیری ماشین برای افزایش امنیت اینترنت اشیا دسته بندی می شود و چالش های موجود در این زمینه معرفی می گردد. در ادامه این مقاله در بخش 2 مروری بر کارهای مرتبط انجام می شود. چالش های پیش روی، همچنین فرصت های مطالعاتی آینده دستورالعمل های آینده، در بخش 3 بیان می شود، و در بخش 4 مقاله جمع بندی می شود.

2. مرور کارهای پیشین

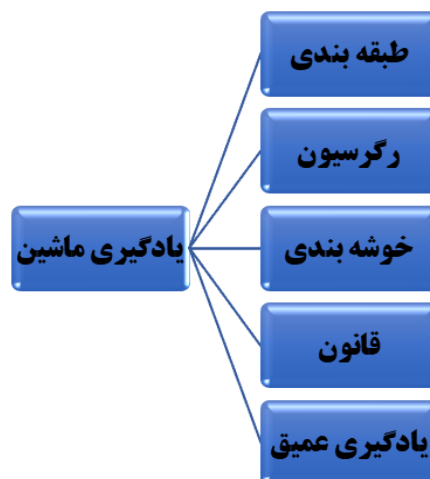
تکنیک های یادگیری ماشین و یادگیری عمیق به هوش مصنوعی معروف هستند که می توانند به دستگاه های اینترنت اشیا کمک کنند تا با کمک داده های آموزشی، بیاموزند و رفتار کنند. مدل های یادگیری اغلب از مجموعه ای از قوانین، رویه ها یا «عملکردهای انتقال» پیچیده تشکیل شده اند که ممکن است برای کشف روندهای مربوط به حوادث امنیتی در داده های اینترنت اشیا، و همچنین شناسایی و پیش بینی رفتار مورد استفاده قرار گیرند [18]. در نتیجه، در زمینه اینترنت اشیا، هم یادگیری ماشین و هم یادگیری عمیق می توانند در شبکه های پویا اینترنت اشیا بدون نیاز به دخالت انسان یا کاربر عمل کنند. تحقیقات اخیر به طور فزاینده ای بر اثربخشی الگوریتم های یادگیری ماشین و یادگیری عمیق برای مبارزه با این نفوذ و فعالیت بدخواهانه متمرکز شده است. در این بخش به بررسی این الگوریتم ها و همچنین کاربرد و کارایی آنها در امنیت اینترنت اشیا می پردازیم. برای این منظور مطابق شکل 2، تکنیک های یادگیری ماشین را به شش گروه دسته بندی کرده مطالعه نمودیم.

³ Multi-layer perceptron

⁴ Convolutional neural networks

⁵ Recurrent neural networks

⁶ Deep belief networks



شکل 2- دسته بندی تکنیک های یادگیری ماشین

1-2 طبقه بندی

به فرایند تشخیص، درک و دسته بندی اشیا و ایده ها به دسته های موجود و تعریف شده به عنوان زیردسته ای از جامعه فعلی، در یادگیری ماشین طبقه بندی می گویند. به کمک مجموعه داده های آموزشی از پیش طبقه بندی شده، برنامه های طبقه بندی در یادگیری ماشین، آموزش می بینند و با استفاده از گستره وسیعی از الگوریتم ها، مجموعه داده ها را می توانند به دسته های مرتبط و معنی دار، طبقه بندی کنند. در زمینه یادگیری ماشین، روش های طبقه بندی به طور گسترده مورد استفاده قرار می گیرند. از طبقه بندی در امنیت اینترنت اشیا معمولاً به برای پیش بینی یک مقدار/رده گسسته ثابت، مانند نتیجه [ناهنجاری، عادی] استفاده می شود.

چندین تکنیک طبقه بندی محبوب، مانند k نزدیک ترین همسایه [19]، ماشین های بردار پشتیبان [20]، تقویت تطبیقی [21] و درخت تصمیم [22]، یادگیری مجموعه ای مانند جنگل های تصادفی [23]، وجود دارد. k نزدیک ترین همسایه یک الگوریتم یادگیری ماشین است که معمولاً در وظایف رگرسیون و طبقه بندی استفاده می شود. کارکرد این الگوریتم بر اساس اصل شباهت است که در آن نمونه ها بر اساس شباهت ویژگی های آنها با نمونه های شناخته شده طبقه بندی می شوند. در k نزدیک ترین همسایه، کلاس یا مقدار یک نمونه معین بر اساس نزدیک ترین همسایه ها تعیین می شود. مقدار k معمولاً به صورت تجربی انتخاب می شود و می تواند بر عملکرد الگوریتم تأثیر بگذارد. سپس کلاس نمونه جدید با اکثریت رای k نزدیک ترین همسایه آن تعیین می شود [19]. ماشین های بردار پشتیبان یک الگوریتم یادگیری نظارت شده معروف است که به طور گسترده در یادگیری ماشین برای کارهای طبقه بندی و رگرسیون استفاده می شود. ماشین های بردار پشتیبان بر اساس اصول کمینه سازی ریسک ساختاری و بعد عمل می کند. هدف اصلی الگوریتم ماشین های بردار پشتیبان شناسایی یک ابر صفحه بهینه است که به طور موثر طبقات متمایز از داده ها را با به حداکثر رساندن حاشیه بین نزدیک ترین نقاط از هر کلاس، که به عنوان بردارهای پشتیبان نامیده می شوند، جدا می کند [20]. تقویت تطبیقی چندین یادگیرنده ضعیف را با تنظیم مکرر وزن ها بر روی نمونه های طبقه بندی شده اشتباه به یادگیرندگان قوی ترکیب می کند [21]. درخت تصمیم از مدل های یادگیری ماشینی همه کاره است که برای مسائل طبقه بندی و رگرسیون از جمله شناسایی باتنت اینترنت اشیا قابل استفاده می باشد. الگوریتم به صورت بازگشتی داده های ورودی را بر اساس قوانین تصمیم گیری به زیرمجموعه های کوچکتر تقسیم می کند

تا زمانی که هر زیر مجموعه به یک کلاس یا مقدار منطبق شود. هدف درختان تصمیم، به حداکثر رساندن اطلاعات در طول انتخاب ویژگی است [22].

الگوریتم های طبقه بندی می توانند حوادث امنیتی را به منظور رسیدگی به مسائل مختلف امنیتی اینترنت اشیا، از جمله تشخیص نفوذ یا حمله، تجزیه و تحلیل بدافزار، و تشخیص ناهنجاری یا تقلب در اینترنت اشیا، دسته بندی کند. به عنوان مثال، تکنیک طبقه بندی ماشین بردار پشتیبان در پروفایل رفتار غیرعادی دستگاه های اینترنت اشیا [24] و برای شناسایی بدافزارهای اندرویدی و ارائه خدمات اینترنت اشیا قابل اعتماد [25] استفاده می شود. تکنیک جنگل تصادفی برای تشخیص ناهنجاری ها [26]، حمله انکار سرویس [27]، سرویس تشخیص نفوذ در اینترنت اشیا [28]، تشخیص ناهنجاری شهر هوشمند [29] و غیره استفاده می شود.

2-2 رگرسیون

رگرسیون یکی از اصولی ترین روش های آماری است و در تحلیل داده های آماری به عنوان ابزار مهم مورد استفاده قرار می گیرد. با استفاده از رگرسیون، می توانیم بهترین مدلی که توصیف کننده رابطه بین متغیرهاست را پیدا کنیم. این مدل به ما این امکان را می دهد تا پیش بینی های دقیق تری در مورد متغیرهای وابسته براساس متغیرهای مستقل داشته باشیم. یک کار رگرسیونی به عنوان پیش بینی یک مقدار پیوسته یا عددی، مانند تأثیر حملات تعریف می شود. مدل رگرسیون برای پیش بینی کمی حملات یا پیش بینی تأثیر یک حمله، مانند کرم ها، ویروس ها یا سایر نرم افزارهای مخرب مفید است [30]. به طور مشابه، یک مدل امنیتی کمی، به عنوان مثال، فیشینگ در یک دوره خاص یا پارامترهای بسته شبکه، تکنیک های رگرسیون می تواند مفید باشد [31]. چندین تکنیک رگرسیون رایج مانند خطی، لجستیک، چند جمله ای، ریج، کمند، درخت های رگرسیون، مؤلفه های اصلی، شبکه الاستیک، پواسون، دوجمله ای منفی، گام به گام، رگرسیون حداقل مربعات جزئی [32] و غیره وجود دارد که می توان از آنها برای ایجاد امنیت کمی استفاده کرد. با توجه به اصل کار آنها در یادگیری ماشین مدل کنید. به عنوان مثال، مدل مبتنی بر رگرسیون خطی برای شناسایی منشأ حمله سایبری [33] و تحلیل رگرسیون چندگانه برای همبستگی ویژگی های انسانی و اهداف رفتار امنیت سایبری استفاده می شود. به طور مشابه، روش های منظم سازی رگرسیون مانند Lasso، Ridge، یا ElasticNet، می توانند تجزیه و تحلیل حملات امنیتی را برای دستیابی به نتیجه بهتر با توجه به ابعاد بالای داده های امنیتی اینترنت اشیا تقویت کنند [34]. یک روش مبتنی بر رگرسیون لجستیک برای شناسایی بات نت های مخرب اینترنت اشیا [35] استفاده می شود. رگرسیون لجستیک یک الگوریتم یادگیری ماشینی اساسی است که به طور گسترده در برنامه های کاربردی مختلف از جمله شناسایی بات نت اینترنت اشیا استفاده می شود. به دلیل سادگی، کارایی و تفسیر پذیری آن مورد توجه قرار گرفته است. ایده اصلی رگرسیون لجستیک، پیش بینی احتمال یک نتیجه باینری بر اساس متغیرهای ورودی است، مانند تعیین اینکه آیا دستگاهی به یک بات نت آلوده شده است یا خیر. این پیش بینی با استفاده از تابع سیگموئید مدل سازی می شود. بنابراین، می توان نتیجه گرفت که تکنیک های رگرسیون را می توان برای ساخت مدل پیش بینی و طبقه بندی شده برای هوش امنیتی اینترنت اشیا استفاده کرد.

3-2 تکنیک های خوشه بندی

خوشه بندی یکی دیگر از کارهای رایج در یادگیری ماشین، برای تحلیل داده های امنیتی اینترنت اشیا است که یادگیری بدون نظارت بشمار می رود. در این تکنیک گروه هایی از مجموعه ای از نقاط داده را بر اساس شباهت و عدم شباهت در داده های امنیتی تولید شده توسط دستگاه های اینترنت اشیا از منابع مختلف، خوشه بندی یا ایجاد کند. بنابراین، خوشه بندی می تواند به کشف الگوها و ساختارهای پنهان در داده ها کمک کند و امکان تشخیص ناهنجاری ها یا حملات در اینترنت اشیا را فراهم کند. پارتیشن، سلسله مراتب، نظریه فازی، توزیع، چگالی، نظریه گراف، گرید، نظریه فراکتال و سایر دیدگاه ها می توانند برای خوشه بندی داده ها استفاده شوند [36]. K-means [37]، K-medoids [38]، پیوند تکی، پیوند کامل، خوشه بندی تجمعی، DBSCAN، OPTICS، مدل مخلوط گوسی [36]، مفاهیم رایج الگوریتم های خوشه بندی است و این تکنیک های خوشه بندی را می توان برای حل مشکلات مختلف امنیتی اینترنت اشیا استفاده کرد. الگوریتم K-Means، مجموعه داده بدون برچسب را به عنوان ورودی می گیرد، مجموعه داده را به تعداد k خوشه تقسیم می کند و روند را تکرار می کند تا زمانی که بهترین خوشه ها را پیدا نکند الگوریتم ادامه پیدا می کند. مقدار k باید در این الگوریتم از پیش تعیین شده باشد این الگوریتم داده ها را به یک خوشه اختصاص می دهد به طوری که مجموع فاصله مربع شده بین نقاط داده و مرکز گروه (میانگین محاسبه تمام نقاط داده ای که به آن خوشه تعلق دارند) در حداقل باشد. هرچه تنوع کمتری در خوشه ها داشته باشیم، نقاط داده در یک خوشه همگن (مشابه) هستند [37]. الگوریتم K-Medoids که بهبود یافته الگوریتم K-Means است، عملکردی بسیار شبیه به الگوریتم K-Means دارد، با این تفاوت که در الگوریتم K-Medoids به جای استفاده از میانگین، از خود نمونه ها برای مرکز ثقل و نمایندگی خوشه ها استفاده می شود. با انتخاب نمونه های واقعی جهت نمایش یک خوشه، حساسیت روش نسبت به نمونه های نویز و خارج از محدوده کاهش می یابد [38].

از نمونه های خوشه بندی در امنیت اینترنت اشیا می توان به استفاده از الگوریتم K-Means در روش پیشنهادی بنام "پروفایل" اشاره کرد که رفتار غیرعادی دستگاه های اینترنت اشیا را تشخیص می داد [24]. در [39] الگوریتم K-Medoids را با استفاده از روشهای فراابتکاری بهبود دادند و از آن برای تشخیص نفوذ در ابزارهای اینترنت اشیا بهره بردند. در [40] یک رویکرد مبتنی بر آستانه پویا با استفاده از خوشه بندی داده ها را برای تشخیص موارد پرت یا نویز در داده ها پیشنهاد شده است. در [41]، یک رویکرد خوشه بندی فازی در تشخیص نفوذ اینترنت اشیا استفاده می شود. برای تجزیه و تحلیل داده های گزارش سیستم برای برنامه های کاربردی امنیت سایبری، رویکردهای خوشه بندی برای استخراج بینش یا دانش مفید مفید است. بنابراین، با کشف الگوها و ساختارهای پنهان در داده های امنیتی اینترنت اشیا، تکنیک های خوشه بندی می توانند نقش مهمی را از طریق اندازه گیری شباهت یا عدم تشابه رفتاری برای حل مشکلات امنیتی مختلف مانند تشخیص بیرونی، تشخیص ناهنجاری، استخراج امضا، تشخیص تقلب، تشخیص حمله و غیره در حوزه اینترنت اشیا سایبری ایفا کنند.

2-4 تکنیک های مبتنی بر قانون

یک سیستم مبتنی بر قانون، سیستمی است که قوانین را برای تصمیم گیری هوشمندانه اعمال می کند. این سیستم قوانین را از داده ها استخراج می کند و می تواند هوش انسانی را تقلید کند [42]. سیستم های مبتنی بر قانون می توانند نقش مهمی در امنیت اینترنت اشیا از طریق یادگیری قوانین امنیتی یا خط مشی از داده ها ایفا کنند. یادگیری قوانین انجمنی یک روش برجسته برای کشف ارتباط یا قوانین در میان مجموعه ای از ویژگی های موجود در یک مجموعه داده امنیتی در زمینه یادگیری ماشینی است. انواع مختلفی از قوانین تداعی در این حوزه پیشنهاد شده است، مانند الگوهای مکرر [43]، مبتنی بر درخت، مبتنی بر منطق، قوانین فازی [44]، باور قانون [45] و غیره. تکنیک های یادگیری قوانین مانند AIS، Apriori [46]، Apriori-TID و Apriori-Hybrid [47]، FP-Tree [47]، وجود دارند که می توانند برای حل مشکلات امنیتی اینترنت اشیا و تصمیم گیری هوشمند استفاده شود. به عنوان مثال، تشخیص نفوذ شبکه مبتنی بر الگوریتم قانون کاوی در [48] ارائه شده است. علاوه بر این، قوانین تداعی فازی برای ساختن یک سیستم تشخیص نفوذ مبتنی بر قانون استفاده می شود [49]. برای تجزیه و تحلیل فعالیت های بدافزار اینترنت اشیا، یک مطالعه مبتنی بر قوانین مرتبط با درخت FP در [50] انجام شده است. اگرچه اتخاذ یک رویکرد مبتنی بر قانون آسان است، اما به دلیل ایجاد تعداد زیادی تداعی یا الگوهای مکرر بسته به مقادیر حمایت و اطمینان، و در نتیجه، مدل را پیچیده می کند. یک مدل ارتباط موثر می تواند این موضوع را به حداقل برساند. به عنوان مثال، نویسندگان در [51]، یک رویکرد یادگیری قوانین را ارائه می کنند که به طور موثر قوانین ارتباطی را که غیر زائد و قابل اعتماد هستند کشف می کند. قوانین همچنین می توانند برای ساختن سیستم های مبتنی بر دانش یا سیستم های خبره مبتنی بر قانون برای حل مشکلات امنیتی پیچیده تر در اینترنت اشیا استفاده شوند. هر یک از این سیستم ها شامل مجموعه ای از قوانین خط مشی برای تعریف محدوده فعالیت هایی است که باید در یک شبکه مجاز باشند، که در آن هر قانون به طور صریح مجاز است یا رد می شود. حتی حملات روز صفر جدیدی که از کنترل های مبتنی بر قانون استفاده می کنند یا نظارت بر سیاست های امنیتی را فیلتر می کنند، مسدود می شوند.

2-5 رویکردهای مبتنی بر شبکه عصبی عمیق

یادگیری عمیق زیرمجموعه ای از یادگیری ماشینی است که از شبکه عصبی مصنوعی توسعه یافته است، که یک معماری محاسباتی برای یادگیری از داده ها با ترکیب سطوح پردازشی متعدد، مانند لایه های ورودی، پنهان و خروجی در یک واحد شبکه ارائه می دهد [52]. بنابراین، تکنیک های یادگیری عمیق قادر به یادگیری از داده های امنیتی اینترنت اشیا از طریق این لایه ها هستند و به دلیل ماهیت جذب دانش در معماری عمیق، به عنوان روش های یادگیری سلسله مراتبی شناخته می شوند. یادگیری عمیق در موقعیت های مختلف، به ویژه زمانی که از مجموعه داده های امنیتی عظیم یاد می گیرد، از الگوریتم های یادگیری ماشینی معمولی بهتر عمل می کند. دستگاه های مبتنی بر اینترنت اشیا و برنامه ها یا سیستم های آنها مقدار زیادی داده امنیتی در محیط اینترنت اشیا تولید می کنند. در نتیجه، بسته به مجموعه داده ها، رویکردهای یادگیری عمیق ممکن است نتایج

بهتری ارائه دهند. بسته به ویژگی ها و ماهیت داده های امنیتی، معماری های مختلف یادگیری عمیق مانند MLP، CNN، DBN، RNN، یا شبکه های ترکیبی می توانند برای مدل سازی امنیت اینترنت اشیا استفاده شوند [17].

MLP یا پرسپترون چند لایه: یک MLP که اغلب به عنوان یک شبکه عصبی مصنوعی پیشخور شناخته می شود، بلوک اصلی ساختمان شبکه عصبی است. الگوریتم های یادگیری عمیق یک MLP معمولی شامل یک لایه ورودی، یک یا چند لایه پنهان و یک یا چند لایه خروجی است. هر گره در یک لایه از طریق زنجیره ای از اتصالات به وزن خاصی در لایه بعدی متصل می شود. وزنها به طور داخلی توسط MLP به روزرسانی و تنظیم می شوند، زیرا مدل از طریق فرآیند پس از انتشار توسعه می یابد. از شبکه MLP و LSTM برای تشخیص نفوذ در شبکه اینترنت اشیا با استفاده از مجموعه داده CICDDoS2019 در [53] استفاده شده است. یک چارچوب برای تجزیه و تحلیل بدافزارهای اندرویدی در [54] با استفاده از یادگیری عمیق پیشنهاد شده است. در [55] برای شناسایی ترافیک مخرب بات تنها از یادگیری عمیق استفاده شد.

CNN یا شبکه های عصبی کانولوشن: CNN طراحی سنتی شبکه عصبی را بهبود می بخشد و شامل لایه های کانولوشن، لایه های ادغام و لایه های کاملاً متصل است. هر یک از این سطوح پارامترهای بهینه شده را در نظر می گیرد و پیچیدگی را کاهش می دهد. CNN همچنین برای رفع مشکل برازش بیش از حد که می تواند در شبکه MLP اتفاق بیفتد، از انصراف استفاده می کند. در سال های اخیر معمولاً در زمینه های متعددی مانند پردازش زبان طبیعی، تجزیه و تحلیل صدا، پردازش تصویر و سایر داده های همبسته خودکار استفاده می شود، زیرا از ساختار دوبعدی داده های ورودی بهره می برد. CNN در حوزه امنیت اینترنت اشیا نیز مورد استفاده قرار گرفته است. استفاده از یک مدل یادگیری عمیق مبتنی بر CNN برای تشخیص نفوذ، مانند حملات انکار سرویس [56]، برای شناسایی بدافزار [57]، تشخیص بدافزار اندروید [58] استفاده شده است. در محیط اینترنت اشیا، برخی از مدل های یادگیری عمیق مبتنی بر CNN با معماری سبک می توانند محاسبات را کاهش داده و عملکرد بالاتری را با منابع محدود ارائه دهند.

RNN یا شبکه عصبی بازگشتی: یک RNN نوع دیگری از شبکه عصبی است که در آن اتصالات بین گره ها یک نمودار جهتدار را در امتداد یک دنباله زمانی تشکیل می دهند. مدل RNN که از شبکه های عصبی پیشخور مشتق شده است، می تواند توالی های با طول ورودی های متغیر را با استفاده از حالت داخلی یا حافظه آنها پردازش کند. استفاده از مدل RNN برای امنیت اینترنت اشیا و همچنین پردازش زبان طبیعی و تشخیص صدا به دلیل ظرفیت آن برای مدیریت موثر داده های متوالی امکان پذیر است. دستگاه های اینترنت اشیا مقدار قابل توجهی از داده های متوالی را از چندین منبع تولید می کنند، مانند جریان های ترافیک شبکه، داده های وابسته به زمان و غیره. هنگامی که الگوهای رفتاری تهدید وابسته به زمان هستند، استفاده از اتصالات مکرر می تواند به شبکه های عصبی کمک کند تا نگرانی های امنیتی را شناسایی کنند. دلیل این امر این است که دارای مشخصه ای به نام حافظه کوتاه مدت طولانی^۷ (LSTM) است که به آن اجازه می دهد ورودی های قبلی را حفظ کند و آن را به یک مدل بسیار مفید برای پیش بینی سری های زمانی تبدیل می کند. چنین شبکه بازگشتی مبتنی بر مدل

⁷ Long Short Term Memory

LSTM می تواند برای چندین هدف در حوزه امنیت، مانند تشخیص نفوذ [53]، برای شناسایی و طبقه بندی برنامه های مخرب [59] و غیره استفاده شود.

علاوه بر این مدل های یادگیری عمیق، مدل های شبکه ترکیبی مانند مجموعه طبقه بندی کننده ها، شبکه LSTM با ترکیب CNN نیز می تواند برای شناسایی حملات اینترنت اشیا مانند شناسایی بدافزار، فیشینگ و شناسایی و کاهش حملات بات نت استفاده شود. سایر مدل های یادگیری عمیق، مانند مدل امنیتی مبتنی بر شبکه باور عمیق، ممکن است برای امنیت اینترنت اشیا استفاده شود [60]. در جدول 1، نحوه استفاده از روش های مختلف یادگیری ماشین از جمله یادگیری عمیق برای حل مسائل امنیتی مختلف در حوزه اینترنت اشیا را خلاصه کرده ایم. بنابراین، ما می توانیم استنباط کنیم که تکنیک های ماشینی یا یادگیری عمیق ذکر شده در بالا، و همچنین انواع آن ها یا رویکردهای سبک وزن اصلاح شده، می توانند نقش مهمی در تحلیل های امنیتی مبتنی بر داده در محیط اینترنت اشیا ایفا کنند.

جدول 1- خلاصه ای از الگوریتم های یادگیری ماشین در امنیت اینترنت اشیا

منبع	هدف	الگوریتم	تکنیک
[24]	طبقه بندی رفتار غیرعادی دستگاه های اینترنت اشیا	ماشین بردار پشتیبان	طبقه بندی
[25]	شناسایی بدافزارهای اندرویدی و ارائه خدمات اینترنت اشیا قابل اعتماد	ماشین بردار پشتیبان	
[26]	تشخیص ناهنجاری ها	جنگل تصادفی	
[27]	حمله انکار سرویس	جنگل تصادفی	
[28]	سرویس تشخیص نفوذ در اینترنت اشیا	جنگل تصادفی	
[29]	تشخیص ناهنجاری شهر هوشمند	جنگل تصادفی	
[34]	تحلیل حملات امنیتی	منظم سازی رگرسیون	رگرسیون
[35]	برای شناسایی بات نت های مخرب	رگرسیون لجستیک	
[24]	پروفایل رفتار غیرعادی دستگاه های اینترنت اشیا	k-Means	خوشه بندی
[39]	تشخیص نفوذ در ابزارهای اینترنت اشیا	k-medoids	
[40]	تشخیص موارد پرت یا نویز در داده ها	آستانه پویا	
[41]	تشخیص نفوذ اینترنت اشیا	خوشه بندی فازی	
[48]	تشخیص نفوذ در شبکه	قانون کاوی	قانون
[49]	سیستم تشخیص نفوذ	قوانین تداعی فازی	
[51]	کشف قوانین ارتباطی قابل اعتماد	یادگیری قوانین	
[54]	تحلیل بدافزارهای اندرویدی	MLP	شبکه عصبی عمیق
[55]	شناسایی ترافیک مخرب بات نتها	MLP	
[56]	تشخیص حملات انکار سرویس	CNN	
[57]	شناسایی بدافزار	CNN	
[58]	تشخیص بدافزار اندروید	CNN	
[53]	تشخیص نفوذ	LSTM	
[59]	برای شناسایی و طبقه بندی برنامه های مخرب	LSTM	

3. موضوعات باز و چالش ها

در این بخش، ما چالش های موجود و همچنین جهت های آینده تحقیقات برای ایمن سازی شبکه ها و سیستم های اینترنت اشیا تحلیل می شود. کارایی یک راه حل امنیتی اینترنت اشیا مبتنی بر یادگیری ماشین یا یادگیری عمیق اساساً توسط ماهیت و ویژگی های داده ها و عملکرد الگوریتم های یادگیری تعیین می شود. تکنیک های یادگیری ماشین و یادگیری عمیق گوناگونی برای ارزیابی داده ها و استخراج بینش ها وجود دارد. بنابراین، انتخاب یک الگوریتم یادگیری مناسب برای برنامه مورد نیاز در امنیت اینترنت اشیا ممکن است چالش برانگیز باشد. دلیل این موضوع این است که بر اساس کیفیت داده، نتایج الگوریتم های یادگیری مختلف ممکن است متفاوت باشد. اگر الگوریتم یادگیری نادرست انتخاب شود، ممکن است نتایج غیرمنتظره ای به دست آید که منجر به هدر رفتن زحمت و دقت مدل می شود. به همین ترتیب، داده های امنیتی غیرضروری اینترنت اشیا و نویزها و داده های پرت، ممکن است موجب پردازش های زائد و نتایج نادرست شود. اگر داده های اینترنت اشیا نامناسب باشند، مانند نماینده نبودن، کیفیت پایین، ویژگی های نامربوط، یا مقدار نامناسب برای آموزش، مدل های امنیتی یادگیری ماشین یا یادگیری عمیق ممکن است بی ارزش شود یا دقت کمتری داشته باشند. فرصت ها و جهت های تحقیق آینده در حوزه امنیت اینترنت اشیا شامل موارد زیر است:

- در دنیای اینترنت اشیا، جمع آوری داده های امنیتی آسان نیست. ویژگی های پویای اینترنت اشیا، مانند ناهمگنی، حجم بزرگ داده ها و فراوانی از حوزه های مختلف کار جمع آوری داده ها را پیچیده می کند. برای تحلیل بیشتر، جمع آوری و مدیریت داده های مرتبط تولیدشده توسط اینترنت اشیا برای برنامه های هدف، مانند امنیت در برنامه های شهر هوشمند، برای تسهیل تحقیقات بیشتر حیاتی است. بنابراین، هنگام کار با داده های تولیدشده توسط اینترنت اشیا، نیاز به تجزیه و تحلیل عمیق تری از روش های جمع آوری داده وجود دارد.

- مقادیر مبهم بسیار، مقدارهای گم شده، داده های پرت، و داده های نادرست ممکن است در داده های امنیتی تاریخی یا خام اینترنت اشیا کشف شود. متدهای یادگیری ماشین یا یادگیری عمیق در امنیت اینترنت اشیا تأثیر قابل توجهی بر کیفیت داده و دسترسی به آموزش دارند. بنابراین، تمیز کردن و پیش پردازش داده های مختلف امنیتی تولیدشده در محیط اینترنت اشیا کاری چالش برانگیز است. برای استفاده کارآمد از الگوریتم های یادگیری در حوزه امنیت اینترنت اشیا، بهبود روش های فعلی یا توسعه روش های جدید آماده سازی داده مورد انتظار است.

- برای یک راه حل امنیتی اینترنت اشیا موثر باید محدودیت ها یا قابلیت های دستگاه ها و سیستم های اینترنت اشیا که مدل های امنیتی مبتنی بر یادگیری استفاده می شود، در نظر گرفته شود. بنابراین، لازم است که یک توازن میان امنیت و قابلیت های دستگاه ها در زمینه ذخیره سازی داده، محاسبه، پردازش داده، تصمیم گیری، و منابع ارتباطی وجود داشته باشد. بنابراین، یک بررسی عمیق برای کشف مهمترین روش های یادگیری ماشین یا یادگیری عمیق مورد نیاز است.

- توجه به این نکته مهم است که انتخاب تکنیک اغلب به ویژگی های مجموعه داده و مبادله مطلوب بین دقت و پیچیدگی محاسباتی بستگی دارد. به دلیل تعداد زیاد فرایندهای تکراری، تکنیک های یادگیری کلاسیک به صورت مستقیم برای دستگاه های اینترنت اشیا در شرایط مختلف قابل اجرا نیست. به عنوان مثال، روش یادگیری قانون انجمن، در یک سیستم مبتنی بر قواعد، ممکن است تولید مجدد زائد از داده های امنیتی اینترنت اشیا را استخراج کند که فرایند تصمیم گیری را پیچیده و ناکارآمد می کند. بنابراین، نیاز به درک بهتر از مزایا و محدودیت های روش های یادگیری موجود وجود دارد، که باعث به وجود آمدن روش های بهبود یافته جدید یا توسعه روش های جدید یادگیری می شود.

- علیرغم پیشرفت قابل توجهی که در تکنیک های تشخیص مبتنی بر یادگیری ماشین به دست آمده است، اذعان به چالش های مداوم در این حوزه مهم است. ماهیت پویا محیط های اینترنت اشیا، پیچیدگی روزافزون حملات و مسائل امنیتی و محدودیت های منابع دستگاه های اینترنت اشیا همچنان موانعی را برای دستیابی به تشخیص دقیق و بلادرنگ ایجاد می کنند.

- با توجه به پیشرفت هایی که در بدافزارها و حملات رخ می دهد، یک روند رفتاری جدید و کارا برای پیش بینی یا شناسایی حملات در امنیت اینترنت اشیا مورد نیاز است. بنابراین، به جای مدنظر گرفتن تحلیل داده های سنتی، ایده تحلیل داده های اخیر، یعنی بینش یا دانش استخراج شده بر اساس الگوهای فعلی ممکن است در موارد مختلف مناسب تر باشد. بنابراین، یک چالش دشوار دیگر، پیشنهاد راه حل های سبک وزن جدید برای دستگاه های اینترنت اشیا است که الگوهای داده فعلی را در نظر بگیرند و در نهایت یک مدل امنیتی اینترنت اشیا بر پایه داده های جدید بسازند.

- با توجه به مزایایی که هر کدام از روشها دارند، ترکیب روشها و ارائه راه حلها و روشهای ترکیبی و قوی تر برای افزایش امنیت در اینترنت اشیا پیشنهاد می شود.

از آنجایی که محققان و متخصصان به کشف رویکردها و استراتژی های نوآورانه یادگیری ماشین ادامه می دهند، پرداختن به این چالش ها برای افزایش بیشتر امنیت و انعطاف پذیری سیستم های اینترنت اشیا ضروری است. تحقیقات آینده باید بر روی توسعه مدل های یادگیری ماشین تطبیقی و مقیاس پذیر تمرکز کند که می تواند به طور موثر موضوعات امنیتی در حال تکامل را شناسایی و کاهش دهد و در عین حال محدودیت های منابع دستگاه های اینترنت اشیا را در نظر بگیرد. علاوه بر این، تلاش های مشترک بین محققان، متخصصان صنعت و سیاست گذاران برای ایجاد چارچوب های ارزیابی استاندارد، اشتراک گذاری مجموعه داده های معیار، و ترویج اتخاذ راه حل های موثر تشخیص مبتنی بر یادگیری ماشین در استقرار اینترنت اشیا در دنیای واقعی مورد نیاز است.

تکنیک های تشخیص مبتنی بر یادگیری ماشین و یادگیری عمیق برای افزایش امنیت و انعطاف پذیری اکوسیستم های اینترنت اشیا با افزایش تعداد دستگاه های اینترنت اشیا ضروری هستند. این روش ها در حل مسائل امنیتی مؤثر هستند، زیرا تشخیص تهدید، شناسایی ناهنجاری ها و تشخیص الگو را بطور بلادرنگ ارائه می دهند. انعطاف پذیری آنها اثربخشی مداوم در برابر تهدیدات جدید را تضمین می کند و کاهش مثبت کاذب از استفاده قانونی از دستگاه محافظت می کند. علاوه بر این، آنها مسائل مربوط به حریم خصوصی را حل می کنند و به راحتی متناسب با سناریوی توسعه اینترنت اشیا مقیاس می شوند. راه حل های امنیتی مبتنی بر یادگیری ماشین نقشی کلیدی در تضمین امنیت و طول عمر دستگاه های اینترنت اشیا با ارائه روشهای نگهداری پیش بینی شده، قابلیت همکاری و اطمینان کاربر دارند. برای پیشگیری از تهدیدهای امنیتی جدید، تحقیق و توسعه مداوم ضروری است.

4. جمع بندی و نتیجه گیری

در حال حاضر، اینترنت اشیا در صنایع مختلف، استفاده می شود و توسعه راه حل های جدید را امکان پذیر می کند. تلاش های متعددی برای استفاده از این فناوری در حوزه های مختلف صورت گرفته و انتظار می رود راه حل های جدید تا چند سال آینده سیستم های موجود را بهبود بخشند. تکنیک های یادگیری ماشین و یادگیری عمیق با دقت بهبود یافته می توانند حجم زیادی از داده ها را تجزیه و تحلیل کنند و الگوها و ناهنجاری هایی را که ممکن است توسط تکنیک های سنتی نادیده

گرفته شوند، شناسایی کنند، که در نتیجه باعث بهبود دقت و افزایش کارایی آنها در افزایش امنیت اینترنت اشیا می شود. این تکنیک ها مزایای قابل توجهی را برای شناسایی و پیشگیری از حملات اینترنت اشیا ارائه می دهند و امکان شناسایی و پاسخ سریع تر، دقیق تر و کارآمدتر به تهدیدات امنیتی را فراهم می کنند. این تحقیق یک مرور اجمالی و بررسی از راه حل های یادگیری ماشین برای امنیت اینترنت اشیا ارائه کرد. تمرکز اصلی بر روشها، منابع، برنامه ها، و چالش های باز در این زمینه بود. در نهایت، چالش های موجود بیان گردید و جهت های آینده تحقیقاتی مشخص شد. بنابراین چه ذکر شد، کارهای آینده باید به داده های جمع آوری شده از دستگاه های متعدد، حجم داده ها و ویژگی های توصیفی متعدد، و حمله های مختلف توجه کنند. در طولانی مدت، نیاز به بررسی حملات با توجه به عملکرد الگوریتم ها و ابزارها و امکانات دستگاه های اینترنت اشیا وجود دارد. علاوه بر این، یک تجزیه و تحلیل عمیق در مورد اینکه چگونه پلتفرم های آزمایشی واقع گرا می توانند باعث نمایان سازی، تحلیل، یکپارچگی های بیشتر، و جمع آوری معیارهای عملیاتی شوند، بنیانی برای تحقیقات آینده است.

منابع

- [1] Lin, J., Yu, W., Zhang, N., Yang, X., Zhang, H., Zhao, W., "A survey on internet of things: Architecture, enabling technologies, security and privacy, and applications.," *IEEE Internet Things J.*, vol. 4, no. 5, p. 1125–1142, 2017.
- [2] Alabdulatif, Ali, Thilakarathne, Nalin N., Lawal, Zulkarnain K., Fahim, Kareem E., Zakari, Rabiul Y., "Internet of nano-things (IoNT): A comprehensive review from architecture to security and privacy challenges.," *Sensors*, vol. 23, no. 5, p. 2807, 2023.
- [3] Plageras, Andreas P, Psannis, Kostas E, Stergiou, Christos, Wang, Haoxiang, Gupta, Brij B., "Efficient IoT-based sensor BIG data collection–processing and analysis in smart buildings.," *Future Gener. Comput. Syst.*, vol. 82, p. 349–357, 2018.
- [4] Statista Research Department, "Global IoT Security Market Size 2022–2027.," Statista, , Retrieved from <https://www.statista.com/statistics/1362333/global-iotsecurity-market-value/>, 2023.
- [5] Nazir, A., He, J., Zhu, N., Wajahat, A., Ma, X., Ullah, F., ... & Pathan, M. S., "Advancing IoT security: A systematic review of machine learning approaches for the detection of IoT botnets.," *Journal of King Saud University-Computer and Information Sciences*, 2023.
- [6] Almazrouei, Essa, Shubair, Raed M., Saffre, Fabrice, "Internet of nanothings: Concepts and applications," *arXiv preprint arXiv:1809.08914*, 2018.
- [7] Maksimović, Milica, "The roles of nanotechnology and internet of nano things in healthcare transformation.," *Tecnológicas*, vol. 20, no. 40, p. 139–153, 2017.
- [8] Miraz, Mahdi H., Ali, Md S., Excell, Peter S., Picking, Richard, "Internet of nano-things, things and everything: future growth trends.," *Future Internet*, vol. 10, no. 8, p. 68, 2018.
- [9] Sarker, I. H., Khan, A. I., Abushark, Y. B., & Alsolami, F., "Internet of things (iot) security intelligence: a comprehensive overview, machine learning solutions and research directions.," *Mobile Networks and Applications*, vol. 28, no. 1, pp. 296–312, 2023.
- [10] Zafar, Saad, Nazir, Muhammad, Sabah, Ali, Jurcut, Anca Daniela, "Securing biocyber interface for the internet of bio-nano things using particle swarm optimization and artificial neural networks-based parameter profiling.," *Comput. Biol. Med.*, vol. 136, 2021.
- [11] Memos, Vasileios A, Psannis, Kostas E, Ishibashi, Yutaka, Kim, Byung-Gyu, Gupta, Brij B., "An efficient algorithm for media-based surveillance system (EAMSuS) in IoT smart city

- framework.," *Future Gener. Comput. Syst.* , vol. 83, p. 619–628, 2018.
- [12] Zheng, Shijun, Yang, Xiaowei., "Dynashield: Reducing the cost of DDoS defense using cloud services.," *In: Proceedings of the 11th USENIX Workshop on Hot Topics in Cloud Computing (HotCloud 19)*. *USENIX, Boston, MA, USA*, 2019.
- [13] Syeda Manjia Tahsien, Hadis Karimipour, and Petros Spachos., " Machine learning based solutions for security of internet of things (iot): A survey.," *Journal of Network and Computer Applications*, vol. 161, 2020.
- [14] Hu, Jui-Wen, Yeh, Li-Yuan, Liao, Shih-Wei, Yang, Chia-Shiang., "Autonomous and malware-proof blockchain-based firmware update platform with efficient batch verification for Internet of Things devices.," *Comput. Secur.* , vol. 86, p. 238–252, 2019.
- [15] Iqbal H Sarker, Md Hasan Furhad, and Raza Nowrozy, "Ai-driven cybersecurity: an overview, security intelligence modeling and research directions.," *SN Computer Science*, vol. 2, no. 3, 2021.
- [16] Mao, Jiaxin, Bian, Jiang, Tian, Wei, Zhu, Shuyuan, Wei, Tingting, Li, An, Liang, Zhong., "Phishing page detection via learning classifiers from page layout feature.," *EURASIP J. Wireless Commun. Networking* , vol. 1, pp. 1-14, 2019.
- [17] I. H. Sarker., " Deep learning: A comprehensive overview on techniques, taxonomy, applications and research directions.," *SN Computer Science*, 2021.
- [18] Sumeet Dua and Xian Du. , "Data mining and machine learning in cybersecurity.," *CRC press*, 2016.
- [19] David W Aha, Dennis Kibler, and Marc K Albert., "Instance-based learning algorithms.," *Machine learning*, vol. 6, no. 1, pp. 37-66, 1991.
- [20] Leevy, Jennifer L., Khoshgoftaar, Taghi M., Hancock, Jeffrey., "Feature evaluation for IoT botnet traffic classification.," *Int. J. Internet Things Cyber-Assur.* , vol. 2, no. 1, pp. 87-102, 2022.
- [21] Ferreira, A. J., & Figueiredo, M. A. , "Boosting algorithms: A review of methods, theory, and applications.," *Ensemble machine learning: Methods and applications*, pp. 35-85, 2012.
- [22] Charbuty, B., & Abdulazeez, A., "Classification based on decision tree algorithm for machine learning.," *Journal of Applied Science and Technology Trends*, vol. 2, no. 1, pp. 20-28, 2021.
- [23] Sun, Z., Wang, G., Li, P., Wang, H., Zhang, M., & Liang, X. , "An improved random forest based on the classification accuracy and correlation measurement of decision trees.," *Expert Systems with Applications*, vol. 237, 2024.
- [24] Soo-Yeon Lee, Sa-rang Wi, Eunil Seo, Jun-Kwon Jung, and Tai-Myoung Chung., "Profiot: Abnormal behavior profiling (abp) of iot devices based on a machine learning approach.," *In 2017 27th International Telecommunication Networks and Applications Conference*, 2017.
- [25] Hyo-Sik Ham, Hwan-Hee Kim, Myung-Sup Kim, and Mi-Jung Choi. , "Linear svm-based android malware detection for reliable iot services.," *Journal of Applied Mathematics*, 2014.
- [26] Biswas, P., & Samanta, T. , "Anomaly detection using ensemble random forest in wireless sensor network.," *International Journal of Information Technology*, vol. 13, no. 5, pp. 2043-2052, 2021.
- [27] Najar, A. A., & Manohar Naik, S. , "DDoS attack detection using MLP and Random Forest Algorithms.," *International Journal of Information Technology*, vol. 14, no. 5, pp. 2317-2327, 2022.

- [28] Pramilarani, K., & Kumari, P. V., "Cost based Random Forest Classifier for Intrusion Detection System in Internet of Things.," *Applied Soft Computing*, 2023.
- [29] Alrashdi, I., Alqazzaz, A., Aloufi, E., Alharthi, R., Zohdy, M., & Ming, H. , "Ad-iot: Anomaly detection of iot cyberattacks in smart city using machine learning.," *In 2019 IEEE 9th Annual Computing and Communication Workshop and Conference* , 2019.
- [30] Venkatesh Jaganathan, Priyesh Cherurveetil, and Premapriya Muthu Sivashanmugam., " Using a prediction model to manage cyber security threats.," *The Scientific World Journal*, 2015.
- [31] Iqbal H Sarker, ASM Kayes, Shahriar Badsha, Hamed Alqahtani, Paul Watters, and Alex Ng. , "Cybersecurity data science: an overview from machine learning perspective.," *Journal of Big Data*, vol. 7, no. 1, pp. 1-29, 2020.
- [32] Ian H Witten, Eibe Frank, Leonard E Trigg, Mark A Hall, Geo_rey Holmes, and Sally Jo Cunningham. , "Weka: Practical machine learning tools and techniques with java implementations.," 1999.
- [33] Lalou, M., Kheddouci, H., & Hariri, S. , "Identifying the cyber attack origin with partial observation: a linear regression based approach.," *In 2017 IEEE 2nd International Workshops on Foundations and Applications of Self* Systems (FAS* W)* , 2017.
- [34] Desta Haileselassie Hagos, Anis Yazidi, _ivind Kure, and Paal E Engelstad. , "Enhancing security attacks analysis using regularized machine learning techniques.," *In 2017 IEEE 31st International Conference on Advanced Information Networking and Applications (A)*, 2017.
- [35] Gatea, M. J., & Hameed, S. M., "An Internet of Things Botnet Detection Model Using Regression Analysis and Linear Discrimination Analysis," *Iraqi Journal of Science*, pp. 4534-4546, 2022.
- [36] Ezugwu, A. E., Ikotun, A. M., Oyelade, O. O., Abualigah, L., Agushaka, J. O., Eke, C. I., & Akinyelu, A. A., "A comprehensive survey of clustering algorithms: State-of-the-art machine learning applications, taxonomy, challenges, and future research," *Engineering Applications of Artificial Intelligence*, vol. 110, 2022.
- [37] N. Wiroonsri, "Clustering performance analysis using a new correlation-based cluster validity index. ," *Pattern Recognition*, vol. 145, 2024.
- [38] Lenssen, L., & Schubert, E. , "Medoid Silhouette clustering with automatic cluster number selection.," *Information Systems*, vol. 120, 2024.
- [39] Garg, S., Kaur, K., Batra, S., Kaddoum, G., Kumar, N., & Boukerche, A., " A multi-stage anomaly detection scheme for augmenting the security in IoT-enabled applications. ," *Future Generation Computer Systems*, vol. 104, pp. 105-118, 2020.
- [40] I. H. Sarker, "A machine learning based robust prediction model for real-life mobile phone data.," *Internet of Things*, vol. 5, pp. 180-193, 2019.
- [41] Liqun Liu, Bing Xu, Xiaoping Zhang, and Xianjun Wu., " An intrusion detection method for internet of things based on suppressed fuzzy clustering.," *EURASIP Journal on Wireless Communications and Networking*, vol. 1, no. 113, 2018.
- [42] I. H. Sarker., " Data science and analytics: An overview from data-driven smart computing, decision-making and applications perspective.," *SN Computer Science*, 2021.
- [43] Arora, P., Saxena, S., & Chopra, D., " Generalized association rules for er models by using mining operations on fuzzy datasets. ," *Recent Progress in Science and Technology*,. vol. 6, 2023.

- [44] Soni, H. K., Sharma, S., & Jain, M. , "Frequent pattern generation algorithms for Association Rule Mining: Strength and challenges.," *In 2016 International conference on electrical, electronics, and optimization techniques (ICEEOT)* , 2016.
- [45] Lajoie, S. P., & Poitras, E., "Technology-Rich Learning Environments: Theories and Methodologies for Understanding Solo and Group Learning. ," *In Handbook of educational psychology (pp. 630-653). Routledge.*, 2024.
- [46] Lu, Y., & Sarmiento, E., "Apriori Optimization Model for the Intervention Strategies in Educational Model with Sentimental-Based Learning Analytics.," *International Journal of Intelligent Systems and Applications in Engineering*, , vol. 12, no. 6, pp. 466-480., 2024.
- [47] Jiawei Han, Jian Pei, and Yiwen Yin. , "Mining frequent patterns without candidate generation.," *In ACM Sigmod Record*, vol. 29, pp. 1-12, 2000.
- [48] Mayank Swarnkar and Neminath Hubballi., " Ocpad: One class naive bayes classi_er for payload based anomaly detection.," *Expert Systems with Applications*, vol. 64, pp. 330-339, 2016.
- [49] Arman Tajbakhsh, Mohammad Rahmati, and Abdolreza Mirzaei., " Intrusion detection using fuzzy association rules.," *Applied Soft Computing*, vol. 9, no. 2, pp. 462-469, 2009.
- [50] Seiichi Ozawa, Tao Ban, Naoki Hashimoto, Junji Nakazato, and Jumpei Shimamura. , "A study of iot malware activities using association rule learning for darknet sensor data.," *International Journal of Information Security*, vol. 19, no. 1, pp. 83-92, 2020.
- [51] Iqbal H Sarker and ASM Kayes, "Abc-ruleminer: User behavioral rule-based machine learning method for context-aware intelligent services.," *Journal of Network and Computer Applications*, vol. 168, 2020.
- [52] Bhalodia, R., Elhabian, S., Adams, J., Tao, W., Kavan, L., & Whitaker, R. , "DeepSSM: A blueprint for image-to-shape deep learning models. ," *Medical Image Analysis*, 91, 103034., vol. 91, 2024.
- [53] Shewale, Y., Kumar, S., & Banait, S., "Machine Learning Based Intrusion Detection in IoT Network Using MLP and LSTM.," *International Journal of Intelligent Systems and Applications in Engineering*, vol. 11, no. 7, pp. 210-223., 2023.
- [54] ElMouatez Billah Karbab, Mourad Debbabi, Abdelouahid Derhab, and Djedjiga Mouheb., " Maldozer: Automatic framework for android malware detection using deep learning.," *Digital Investigation*, 24:S48{S59, 2018., vol. 24, pp. 548-S59, 2018.
- [55] Kornyo, O., Asante, M., Opoku, R., Owusu-Agyemang, K., Tei-Partey, B., Baah, E. K., & Boadu, N., "Botnet Attacks Classification in AMI Networks with Recursive Feature Elimination (RFE) and Machine Learning Algorithms. ," *Computers & Security*, 2023.
- [56] Bambang Susilo and Riri Fitri Sari., "Intrusion detection in iot networks using deep learning algorithm.," *Information*, vol. 11, no. 5, 2020.
- [57] Khan, S. H., Alahmadi, T. J., Ullah, W., Iqbal, J., Rahim, A., Alkahtani, H. K., ... & Almagrabi, A. O., " A new deep boosted CNN and ensemble learning based IoT malware detection.," *Computers & Security*, vol. 133, 2023.
- [58] Yuan, Z., Lu, Y., Wang, Z., & Xue, Y., "Droid-sec: deep learning in android malware detection.," *In Proceedings of the 2014 ACM conference on SIGCOMM*, 2024.
- [59] Jeon, J., Jeong, B., Baek, S., & Jeong, Y. S., "Hybrid malware detection based on bi-lstm and spp-net for smart iot. ," *IEEE Transactions on Industrial Informatics*, vol. 18, no. 7, pp. 4830-

- 4837, 2021.
- [60] Balakrishnan, N., Rajendran, A., Pelusi, D., & Ponnusamy, V., "Deep Belief Network enhanced intrusion detection system to prevent security breach in the Internet of Things.," *Internet of things*, vol. 14, 2021.
- [61] George H John and Pat Langley., " Estimating continuous distributions in bayesian classifiers.," *In Proceedings of the Eleventh conference on Uncertainty in artificial intelligence.*, pp. 338-345. , 1995.
- [62] S. Sathiya Keerthi, Shirish Krishnaj Shevade, Chiranjib Bhattacharyya, and Karuturi Radha Krishna Murthy., "Improvements to platt's smo algorithm for svm classifier design.," *Neural computation*, vol. 13, no. 3, pp. 637-649, 2001.
- [63] Mayank Swarnkar and Neminath Hubballi. , "Ocpad: One class naive bayes classifier for payload based anomaly detection.," *Expert Systems with Applications*, vol. 64, pp. 330-339, 2016.