

A Secure and Reliable Architecture for Managing Health Data in the Internet of Things using Blockchain and Deep Learning

Behnam Rezaei Bezanjan¹, Seyyed Hamid Ghafouri^{2*}, Reza Gholamrezaei³

1. PhD Student, Department of Computer Engineering, Kerman Branch, Islamic Azad University, Kerman, Iran.
2. Assistant Professor, Department of Computer Engineering, Kerman Branch, Islamic Azad University, Kerman, Iran. **Corresponding Author*, Sh.Ghafouri@iau.ac.ir
3. Assistant Professor, Department of Computer Engineering, Kerman Branch, Islamic Azad University, Kerman, Iran.

Abstract

Introduction: The integration of Internet of Things (IoT) devices in the healthcare sector has brought significant advancements in patient care and data management. These technology-driven innovations hold great promise, while simultaneously raising important security concerns, particularly regarding the protection of medical data against potential cyber threats.

Method: In the initial phase, we leverage blockchain-based request and transaction encryption to enhance the security of data transactions, establishing an immutable and transparent framework.

Resultst: is used for attack classification. We compared the performance of the proposed method with three methods: AIBPSF-IoMT, OMLIDS-PB IoT, and AIMMFIDS. We achieved significant improvements in various metrics: accuracy (1%), precision (1%), recalling (1%).

Discussion: This study presents an innovative approach to addressing the critical challenge of medical data security in the Internet of Things landscape. Our method seamlessly integrates blockchain technology and advanced machine learning techniques, providing a robust framework for enhancing the confidentiality and integrity of sensitive healthcare information.

Keywords: Blockchain, Privacy-Preserving, Health Care, Machine Learning, ray Wolf Optimization

یک معماری امن و قابل اعتماد برای مدیریت داده‌های سلامت در اینترنت اشیا با استفاده از بلاک چین و یادگیری عمیق

دوره پنجم، پاییز ۱۴۰۳
شماره سوم، صص: ۸۷-۱۰۰

تاریخ دریافت: ۱۴۰۳/۰۴/۰۳
تاریخ پذیرش: ۱۴۰۳/۰۵/۱۳

بهنام رضائی بزنجانی^۱، سیدحمیدرضا غفوری^{۲*}، رضا غلامرضایی^۳

۱. دانشجوی دکتری، گروه کامپیوتر و فناوری اطلاعات، واحد کرمان، دانشگاه آزاد اسلامی، کرمان، ایران. B.rezai@kmu.ac.ir

۲. استادیار، گروه کامپیوتر و فناوری اطلاعات، واحد کرمان، دانشگاه آزاد اسلامی، کرمان، ایران. (نویسنده مسئول) Sh.Ghafouri@iau.ac.ir

۳. استادیار، گروه کامپیوتر و فناوری اطلاعات، واحد کرمان، دانشگاه آزاد اسلامی، کرمان، ایران. gholamrezaei@iauk.ac.ir

چکیده: ترکیب دستگاه‌های اینترنت اشیا (IoT) در بخش بهداشت و درمان، پیشرفت‌های زیادی در مراقبت از بیمار و مدیریت داده‌ها ایجاد کرده است. این نوآوری‌های مبتنی بر تکنولوژی و عده‌های بزرگی دارند، همزمان نگرانی‌های امنیتی مهمی را نیز به‌ویژه در محافظت از داده‌های پزشکی در برابر تهدیدات سایبری بالقوه ایجاد می‌کنند. با توجه به ماهیت حساس اطلاعات مرتبط با سلامت افراد، نیازمند اقدامات قوی برای تضمین محرمانگی، یکپارچگی و دسترس‌پذیری داده‌های بیمار در محیط‌های پزشکی مبتنی بر اینترنت اشیا است. برای پاسخگویی به نیاز ضروری امنیت بیشتر در سیستم‌های مراقبت بهداشتی مبتنی بر اینترنت اشیا، ما یک روش جامع شامل سه مرحله متمایز را پیشنهاد می‌کنیم. در مرحله اول، از رمزگذاری درخواست و تراکنش مبتنی بر بلاک چین برای تقویت امنیت تراکنش‌های داده استفاده می‌کنیم که یک چارچوب تغییرناپذیر و شفاف را فراهم می‌کند. در مرحله دوم، با استفاده از منابع داده متنوع، بررسی الگوی تشخیص درخواست را برای شناسایی و خنثی کردن تلاش‌های دسترسی غیرمجاز بالقوه معرفی می‌کنیم. در نهایت، مرحله سوم شامل انتخاب ویژگی و شبکه GRU برای افزایش دقت و کارایی تشخیص نفوذ از طریق تکنیک‌های پیشرفته یادگیری ماشین است. ما نتایج شبیه‌سازی روش پیشنهادی را با سه روش مرتبط اخیر به نام‌های AIBPSF-IoMT، OMLIDS-PBIOt و AIMMFIDS مقایسه کردیم. معیارهای ارزیابی شامل نرخ تشخیص، نرخ هشدار کاذب، دقت، بازخوانی و صحت، معیارهای مهم در ارزیابی عملکرد کلی سیستم‌های تشخیص نفوذ هستند. یافته‌های ما نشان می‌دهد که روش پیشنهادی در مقایسه با تمام معیارهای ارزیابی شده، عملکرد بهتری نسبت به روش‌های موجود دارد که برتری آن را در بهبود وضعیت امنیتی سیستم‌های مراقبت بهداشتی مبتنی بر اینترنت اشیا تأیید می‌کند.

واژه‌های کلیدی: بلاک چین، حریم خصوصی، یادگیری عمیق، داده‌های سلامت، یادگیری ماشین.

۱. مقدمه

در سال‌های اخیر، ادغام دستگاه‌های اینترنت اشیا (IoT) در بخش بهداشت و درمان، پیشرفت‌های انقلابی زیادی در صنعت مراقبت بهداشتی و مدیریت داده‌های سلامت به همراه آورده‌است که همزمان نگرانی‌های جدی و مهمی در مورد آسیب‌پذیری‌های امنیتی و تهدیدات سایبری بالقوه را ایجاد می‌کنند. ماهیت حساس اطلاعات مرتبط با سلامت نیازمند اقدامات قوی و فوری برای تضمین محرمانگی، یکپارچگی و در دسترس بودن داده‌های بیمار در محیط‌های پزشکی مجهز به IoT است. [1]

گسترش فناوری‌های اینترنت اشیا (IoT) تحولاتی انقلابی در صنایع مختلف ایجاد کرده و اتصال و سهولت بی‌سابقه‌ای را ارائه داده‌است. با این حال، گسترش سیستم‌های IoT نگرانی‌های را نیز در مورد آسیب‌پذیری امنیتی و حملات سایبری بالقوه ایجاد کرده‌است. [1، 2] برای رسیدگی به این چالش‌ها، محققان به دنبال راه‌حل‌های جدید در تقاطع فناوری بلاک‌چین (BC) و یادگیری عمیق (DL) بوده‌اند تا امنیت و کارایی اکوسیستم‌های IoT را افزایش دهند.

فناوری BC که در ابتدا به عنوان چارچوب زیربنایی برای ارزهای دیجیتال طراحی شده بود، به عنوان یک رویکرد قوی و غیرمتمرکز برای ایمن‌سازی تراکنش‌های داده ظهور کرد. [3] کاربرد آن در حوزه IoT پارادایم جدیدی را معرفی می‌کند که در آن اعتماد، شفافیت و تغییرناپذیری نقش‌های اساسی در محافظت از اطلاعات حساس ایفا می‌کنند. مطالعات اخیر مانند [4] GT x Chain و AIBPSF- [5] IoMT توسعه معماری‌های امن و هوشمند BC IoT را نشان می‌دهند که از تکنیک‌های پیشرفته از جمله شبکه‌های عصبی گرافی و هوش مصنوعی برای تقویت یکپارچگی شبکه‌های IoT استفاده می‌کنند. از سوی دیگر، DL به دلیل دقت بی‌نظیر خود در تحلیل داده و تشخیص الگو، توجه بسیاری در حوزه‌های مختلف جلب کرده‌است [6,7] با کاربردهایی در حوزه‌های بهداشت، پردازش تصویر پزشکی و امنیت سایبری [8، 9]، الگوریتم‌های DL توانایی خود را در حل چالش‌های پیچیده نشان داده‌اند. ادغام BC و DL در تحقیقات اخیر مورد بررسی قرار گرفته‌است تا از نقاط قوت هر دو فناوری برای افزایش امنیت و قابلیت‌های پیش‌بینی استفاده شود [10، 11]

این مقاله رویکرد نوآورانه‌ای برای رسیدگی به چالش‌های امنیتی داده‌های پزشکی در چشم‌انداز اینترنت اشیا معرفی می‌کند. روش ما به طور یکپارچه فناوری بلاک‌چین و تکنیک‌های پیشرفته یادگیری ماشین را ادغام می‌کند. به‌طور خاص، (GRU) واحد بازگشتی دروازه دار (چارچوبی قوی برای افزایش محرمانگی و یکپارچگی اطلاعات حساس سهم اصلی این مطالعه به شرح زیر است:

تقویت امنیت داده‌های پزشکی: ما یک روش نوآورانه پیشنهاد می‌کنیم که فناوری بلاک‌چین را با شبکه GRU سبک شده ادغام

مراقبتی فراهم می‌کند. یک رویکرد جامع با سه مرحله متمایز برای پاسخگویی به نیاز فوری بهبود امنیت در سیستم‌های مراقبت بهداشتی مبتنی بر اینترنت اشیا پیشنهاد گردید. در مرحله اول، ما قابلیت اطمینان دستگاه‌های IoT را از طریق تخمین اعتماد مبتنی بر شهرت و ذخیره‌سازی داده خارج از زنجیره ارزیابی کردیم. مرحله دوم از فناوری بلاک‌چین برای جلوگیری از حملات و تأیید اعتبار داده‌ها استفاده می‌کند. در مرحله سوم، از هوش مصنوعی، به‌ویژه GRU سبک‌شده، برای طبقه‌بندی حملات استفاده می‌شود. جنبه‌های منحصر به فرد ادغام:

ادغام GRU با بلاک‌چین رویکرد نوآورانه‌ای است که از نقاط قوت هر دو فناوری بهره‌می‌برد. در حالی که بلاک‌چین امنیت و تغییرناپذیری داده‌ها را تضمین می‌کند، GRU در مدیریت داده‌های ترتیبی برتری دارد و آن را برای تشخیص الگوها و ناهنجاری‌های داده‌های بهداشتی بسیار مؤثر می‌سازد.

توانایی GRU سبک‌شده در پردازش داده‌ها دقت و قابلیت اطمینان تشخیص حملات را بهبود می‌بخشد و از روش‌های سنتی یادگیری ماشین که وابستگی‌های زمانی در داده‌ها را در نظر نمی‌گیرد، بهتر عمل می‌کند.

فناوری بلاک‌چین با غیرمتمرکز کردن ذخیره داده‌ها و ارائه یک دفتر کل شفاف و ضد دستکاری، یک لایه امنیتی اضافه می‌کند که به طور قابل توجهی یکپارچگی و اعتماد به داده‌ها را افزایش می‌دهد.

با وجود راه‌حل‌های ارائه‌شده توسط محققان، هنوز مشکلاتی وجود دارد که باید بررسی و حل شود. ما این مشکلات را در بخش ۱.۱ بیان کرده‌ایم.

لازم به توضیح است این مقاله توسعه‌ای از مقاله [1] که در ژورنال "Supercomputing" در سال ۲۰۲۴ منتشر شده‌است می‌باشد که ما در این تحقیق برخی الگوریتم‌ها و تکنیک‌ها را مورد بررسی و پژوهش قرار داده‌ایم.

2. بیان مسأله

با وجود پیشرفت‌های قابل توجه در این زمینه، چندین مسئله بحرانی همچنان حل‌نشده باقی مانده‌است از جمله ناتوانی در پیش‌بینی حملات جدید: تکنیک‌های یادگیری ماشین سنتی، گرچه دقیق هستند، اما به دلیل انطباق محدود با الگوهای حمله جدید و پیچیده، قادر به شناسایی تهدیدات جدید و پیچیده نیستند. [4-1] فقدان تعمیم‌پذیری: تحقیقات قبلی معمولاً بر طیف محدودی از انواع حملات متمرکز بوده‌است که تشخیص جامع الگوهای مختلف حمله را مانع شده و شکاف‌های امنیتی قابل توجهی را ایجاد می‌کند [10، 20، 22]

3. مشارکت اصلی ما

ما یک روش نوآورانه پیشنهاد می‌کنیم که فناوری بلاک‌چین را با شبکه GRU سبک‌شده ادغام می‌کند تا حریم خصوصی و امنیت داده‌ها را افزایش دهد، که به‌طور خاص برای مقابله با مشکل تشخیص تهدیدات جدید و پیچیده طراحی شده‌است.

جلوگیری از بیش برآزش و کاهش زمان آموزش: روش ما از یک رویکرد انتخاب ویژگی استفاده می کند که از بیش برآزش جلوگیری می کند و زمان آموزش و آزمایش شبکه GRU را بدون حفظ دقت بالا کاهش می دهد. این به طور مستقیم با چالش تعمیم پذیری محدود با بهبود کارایی و انطباق پذیری مدل مقابله می کند.

پیش بینی انواع مختلف حمله: روش پیشنهادی بر روی دو مجموعه داده مختلف ارزیابی شده است و عملکرد برتر در پیش بینی بیش از ده نوع حمله مختلف را نشان می دهد، بنابراین پوشش گسترده تر و جامع تر تهدیدات بالقوه را تضمین می کند. جدول ۱ مقایسه روش های قبلی با روش پیشنهادی را نشان می دهد. برخی اختصارات در متن استفاده شده است.

جدول ۱: مقایسه روش های قبلی و روش جدید

نرخ خطا	نرخ تشخیص	دقت	F1 امتیاز	فراخوانی	صحت	متد
X	✓	✓	X	X	✓	[11]
X	✓	✓	X	X	✓	[33]
✓	X	✓	X	✓	X	[35]
✓	✓	✓	✓	✓	✓	روش پیشنهادی

جدول ۲: توضیح اختصارات

شرح	نماد	شرح	نماد
شبکه های عصبی بازگشتی	RNN	اینترنت اشیا	IoT
مثبت واقعی	TP	واحد بازگشتی دروازه دار	GRU
مثبت کاذب	TN	اینترنت اشیا وسیله نقلیه	IoV
منفی واقعی	FP	ذخیره سازی بهینه داده های پویا	ODDS
منفی کاذب	FN	الگو ریتم بهینه سازی گرگ خاکستری	GWO
یادگیری عمیق	DL	یادگیری ماشین	ML
اینترنت اشیا داده های پزشکی	IoMT	بلاک چین	BC

۴. کارهای مرتبط

با گسترش فناوری های مانند داده های بزرگ، رایانش ابری و اینترنت اشیا، اطلاعات شخصی و داده های حساس بیشتری در شبکه ذخیره می شوند. این نه تنها خطر دسترسی غیرقانونی و سرقت داده ها را افزایش می دهد، بلکه خسارات بالقوه حملات سایبری را نیز جدی تر می کند. چگونگی بهبود دقت و توانایی پاسخ دهی بلادرنگ ادراک امنیت سایبری (CSP) در محیط های شبکه پیچیده، به موضوعی ترند در تحقیقات فعلی تبدیل شده است. تحقیقات موجود نشان می دهد که فناوری یادگیری عمیق دارای طیف گسترده ای از چشم اندازهای کاربردی در حوزه امنیت سایبری است، که در آن شبکه های عصبی کانولوشنال (CNN) و شبکه های عصبی بازگشتی (RNN) به دلیل مزایای آن ها در استخراج ویژگی و تحلیل سری های زمانی، محبوب ترین ها در حوزه CSP شده اند. با این حال، با وجود عملکرد عالی CNNها در پردازش داده های تصویر و دنباله، یک مدل واحد CNN

هنوز در مواجهه با تهدیدات چندبعدی در محیط های شبکه پیچیده، محدودیت هایی دارد. [37] در سال های اخیر چندین روش با استفاده از DL و BC برای حفظ امنیت و حریم خصوصی داده ها پیشنهاد شده است. در این بخش، کارهای مرتبط را بررسی و مقایسه می کنیم. یک رویکرد پیشرفته برای تشخیص حملات با نت در سیستم های IoT صنعتی در [15] پیشنهاد شده است. روش آن ها از DL چندلایه استفاده می کند و یک استراتژی پیشگیرانه برای کاهش تهدیدات امنیتی در ارتباطات بی سیم و محیط های محاسبات موبایل را نشان می دهد. این مطالعه بر تقویت پایداری سیستم های IoT صنعتی در برابر تهدیدات سایبری در حال تحول، به ویژه تهدیدات مرتبط با حملات بات نت، تمرکز دارد. در [16]، نویسندگان روش جدیدی به نام BlockMedCare، یک سیستم مراقبت بهداشتی جدید که IoT، BC و سیستم فایل بین سیاره ای (IPFS) را ادغام می کند، معرفی کردند. کار آن ها به مسائل امنیتی مدیریت داده در مراقبت های

بهداشتی با استفاده از فناوری BC می پردازد. این سیستم هدف دارد یکپارچگی و محرمانگی داده‌های بهداشتی را تضمین کند و به بحث گسترده تر در مورد افزایش امنیت در انفورماتیک سلامت کمک می کند. یک روش رمز گذاری و احراز هویت سبک توزیع شده با مصرف انرژی کم در [17] ارائه شده است که برای افزایش امنیت در ارتباطات IoT طراحی شده است. در تحقیق دیگری [25]، نویسندگان مدل‌های پرتگاه مبتنی بر محلی سازی ترکیبی را برای ایمن سازی مهاجرت داده در مراکز ابری پیشنهاد کرده اند. این کار بر افزایش امنیت فرآیندهای انتقال داده در محیط‌های ابری تمرکز دارد. با استفاده از یک رویکرد محلی سازی ترکیبی، این مطالعه به پرتگاه‌ها می پردازد و به امنیت کلی مهاجرت داده در مراکز ابری کمک می کند. در [26]، با استفاده از یک رویکرد مبتنی بر بلاکچین توزیع شده، یک چارچوب محافظتی برای سیستم‌های قدرت مدرن در برابر حملات سایبری معرفی شده است. این کار حول محور تقویت امنیت سایبری سیستم‌های قدرت مدرن با استفاده از فناوری BC می چرخد. این چارچوب با استفاده از اقدامات حفاظت از داده توزیع شده و امن، از سیستم‌های قدرت در برابر تهدیدات سایبری محافظت می کند. نویسندگان یک معماری ناقل داده

۵. روش پیشنهادی

ظهور تکنولوژی‌های جدید در جهت بازسازی روش‌های نو برای مقاصد پزشکی و سلامت به شدت در حال تکامل است با این حال، با گسترش دستگاه‌های متصل و تبادل یکپارچه داده‌های پزشکی، نگرانی اصلی تضمین امنیت و حریم خصوصی اطلاعات حساس می شود. این مقاله به بررسی یک رویکرد جامع برای حفظ امنیت داده های پزشکی در چارچوب IoT می پردازد. با بررسی هم افزایی فناوری BC، روش گرگ خاکستری بهینه شده برای انتخاب ویژگی و شبکه GRU، سبک شده که با هم تلفیق شده و در آن قصد داریم یک استراتژی یکپارچه را تشریح کنیم که نه تنها محرمانگی و یکپارچگی داده‌های پزشکی را تقویت می کند، بلکه تاب‌آوری کل اکوسیستم مراقبت بهداشتی را در برابر

انعطاف پذیر و مقرون به صرفه برای قراردادهای هوشمند در بلاک چین ارائه می دهند [27]. با تمرکز بر کاربردهای قرارداد هوشمند، این مطالعه به مسائل مقیاس پذیری و هزینه در سیستم‌های مبتنی بر بلاک چین می پردازد. معماری پیشنهادی کارایی و مقرون به صرفه بودن ناقل‌های داده در اجرای قراردادهای هوشمند را افزایش می دهد. در [28]، یک چارچوب تشخیص حمله توزیع شده مبتنی بر یادگیری نیمه نظارتی برای اینترنت اشیا پیشنهاد شده است. این چارچوب با استفاده از تکنیک های یادگیری نیمه نظارتی به بهبود تشخیص حمله در محیط‌های IoT کمک می کند. این رویکرد با استفاده از داده‌های برچسب دار و بدون برچسب، پایداری تشخیص حمله در سناریوهای IoT توزیع شده را افزایش می دهد. یک سیستم تشخیص نفوذ مبتنی بر DL در [29] معرفی شده است. با تمرکز بر امنیت شبکه، از تکنیک‌های DL برای تقویت تشخیص نفوذ استفاده می کند. این مطالعه با پرداختن به چالش های ایجاد شده توسط مخالفان و افزایش قابلیت های DL در کاربرد های امنیتی، به حوزه تشخیص نفوذ کمک می کند.

تهدیدات سایبری که در حال تحول است را تضمین می کند. در این کار یک سیستم تشخیص نفوذ ترکیبی ارائه شده است که بر اساس تکنیک‌های یادگیری ماشین/یادگیری عمیق می باشند. رویکرد پیشنهادی بر پایه استفاده از شبکه عصبی بازگشتی دروازه دار (GRU) در ترکیب با الگوریتم گرگ خاکستری (GWO) (GRU-GWO) استوار است. از یک تکنیک فراابتکاری (GWO) برای کاهش بعد و پیچیدگی ویژگی‌ها با استخراج زیرمجموعه‌ای از ویژگی‌ها با عملکرد برتر از مجموعه داده‌های NSL-KDD و UNSW-NB15 برای تحلیل شبکه ترافیک استفاده می کند. برای هر مجموعه داده، زیرمجموعه‌ای از ویژگی‌ها از کل مجموعه انتخاب شد.

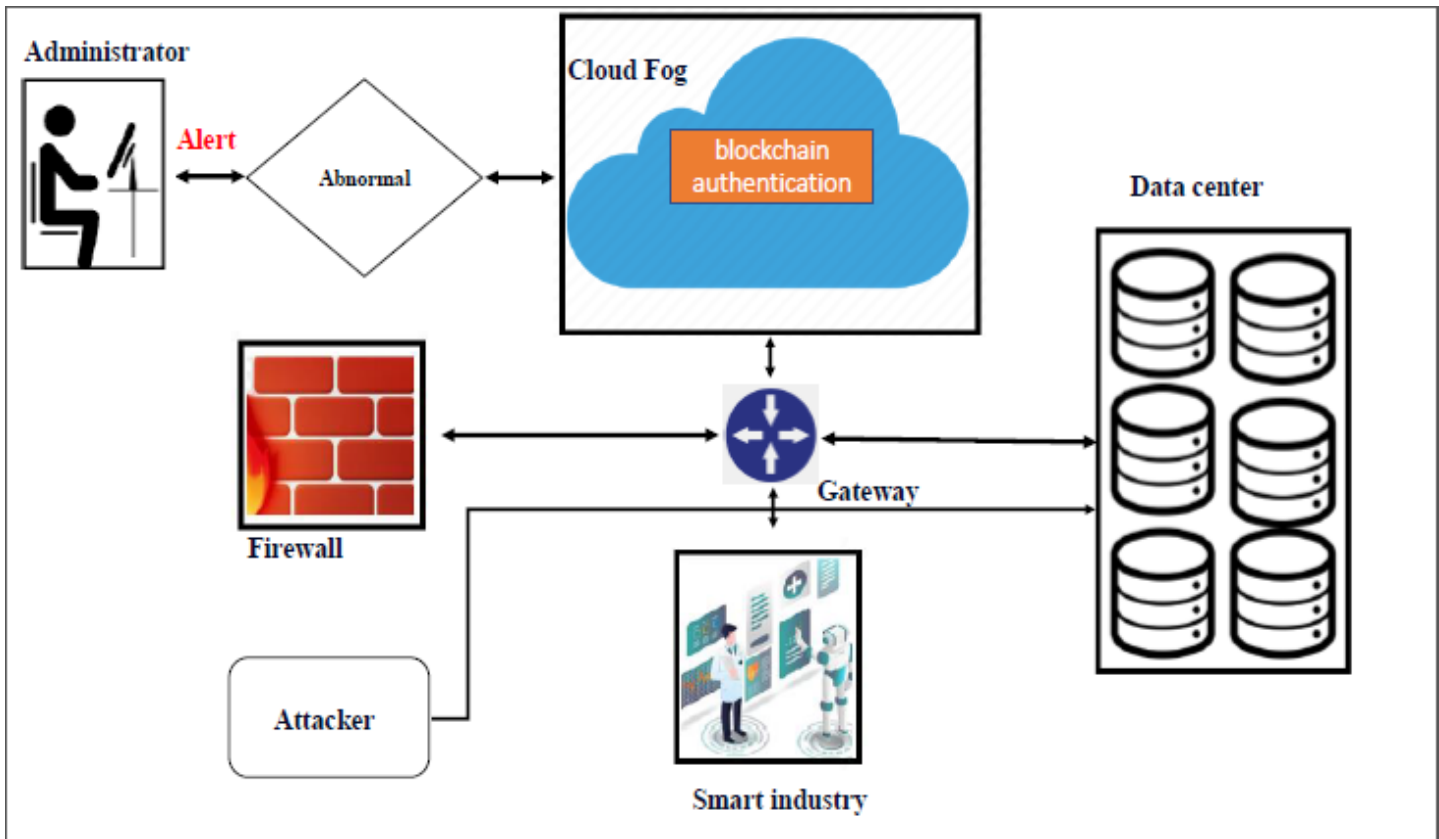


Figure 1: Framework of the proposed method

۵.۱. اجرای الگوریتم GWO

۱. **ابتدا سازی جمعیت گرگ ها:** یک جمعیت اولیه از گرگ ها در فضای جستجو ایجاد می شود، هر گرگ یک مجموعه از پارامترهای مدل را نشان می دهد.
۲. **به روز رسانی موقعیت گرگ ها:** با استفاده از قوانین به روز رسانی GWO، موقعیت گرگ ها را در هر تکرار به روز رسانی می شود.
۳. **گرگ ها:** عملکرد هر گرگ را با ارزیابی آن بر روی داده های آموزشی ارزیابی می شود.
۴. **توقف:** به این فرآیند ادامه می دهیم تا یک شرط توقف مانند رسیدن به تعداد مشخصی تکرار یا کاهش خطا به زیر یک آستانه مشخص برآورده می شود.

چارچوب روش پیشنهادی (شکل ۱) شامل دو جزء است. قابلیت همکاری عامل امنیتی هوش مصنوعی فعال شده توسط بلاکچین در یک فرآیند سه مرحله ای نشان داده شده است: فاز ۱: رمزگذاری درخواست و تراکنش فعال شده توسط بلاکچین: این فاز تضمین می کند که همه درخواست ها و تراکنش ها با استفاده از سکو بلاکچین امضا و تأیید می شوند. این چارچوب تغییر ناپذیر و شفاف برای تراکنش های داده ایمن فراهم می کند. فاز ۲: الگوریتم ویژگی ها قبل از آموزش مدل با استفاده از GWO اصلاح شده انتخاب می شوند. این مرحله برای افزایش دقت و کارایی سیستم تشخیص نفوذ بسیار مهم است. ویژگی های انتخاب شده سپس توسط شبکه GRU شده پردازش می شوند که در مورد مشروعیت درخواست ها تصمیم گیری می کند. در ادامه اجرای الگوریتم فرآیند کاری و آموزش مدل دروازه بازگشتی را شرح می دهیم.

۲.۵. آموزش مدل GRU

حس گرها، دستگاه‌های پوشیدنی و سایر دستگاه‌های متصل جمع‌آوری می‌شود.

پیش‌پردازش داده‌ها: داده‌های جمع‌آوری شده ممکن است حاوی نویز، مقادیر گم‌شده یا ناسازگاری باشند. بنابراین، قبل از استفاده از داده‌ها، باید آن‌ها را تمیز و نرمال‌سازی کرده و مقادیر گم‌شده را پر کرد.

مرحله ۳: استخراج ویژگی‌های مرتبط: از داده‌های پیش‌پردازش شده، ویژگی‌های مهمی که برای تشخیص ناهنجاری یا مدل‌سازی پیش‌بینی‌کننده مفید هستند، استخراج می‌شوند. این ویژگی‌ها می‌توانند آماری، زمانی یا مبتنی بر فرکانس باشند.

انتخاب ویژگی و کاهش ابعاد: پس از استخراج ویژگی‌ها، ویژگی‌های مهم‌تر انتخاب می‌شوند و ابعاد فضای ویژگی کاهش می‌یابد تا کارایی مدل یادگیری ماشین بهبود یابد.

مرحله ۴: آموزش مدل یادگیری ماشین تقسیم داده‌ها به مجموعه آموزش و آزمون: داده‌های آماده‌شده به دو مجموعه تقسیم می‌شوند: مجموعه آموزش برای آموزش مدل و مجموعه آزمون برای ارزیابی عملکرد مدل.

آموزش مدل بر روی داده‌های آموزش: مدل یادگیری ماشین با استفاده از داده‌های آموزشی آموزش داده می‌شود. در این مرحله، پارامترهای مدل به گونه‌ای تنظیم می‌شود که خطای بین خروجی پیش‌بینی شده و خروجی واقعی به حداقل برسد.

اعتبارسنجی مدل با استفاده از روش‌های اعتبارسنجی متقابل: عملکرد مدل آموزش دیده با استفاده از تکنیک‌های اعتبارسنجی متقابل مانند اعتبارسنجی متقاطع k برابر ارزیابی می‌شود. این کار برای جلوگیری از بیش‌برازش مدل و ارزیابی توانایی تعمیم مدل به داده‌های جدید انجام می‌شود.

مرحله ۵: استقرار مدل آموزش دیده بر روی دستگاه‌های لبه: مدل آموزش دیده بر روی دستگاه‌های لبه مانند دروازه‌های IoT یا دستگاه‌های موبایل مستقر می‌شود. این کار به پردازش داده‌ها در زمان واقعی و کاهش تأخیر کمک می‌کند.

پیاده‌سازی استنباط محلی برای تشخیص ناهنجاری: مدل مستقر شده برای تشخیص ناهنجاری‌های داده‌های ورودی در زمان واقعی

- **آموزش مدل GRU با پارامترهای بهینه:** مدل GRU را با استفاده از پارامترهای بهینه یافت شده توسط GWO آموزش می‌دهیم.
- **ابتدا سازی GRU:** وزن‌های GRU به صورت تصادفی مقدار دهی اولیه می‌شود.
- **آموزش GRU:** GRU با استفاده از BPTT روی داده‌های آموزشی آموزش داده می‌شود.
- **بهینه سازی پارامترهای با GWO:** برای بهینه سازی پارامترهای GRU استفاده می‌شود. هر گرگ یک مجموعه از پارامترهای GRU را نشان می‌دهد و GWO به تدریج به سمت بهترین مجموعه پارامترهای همگرا می‌شود.
- **آموزش مجدد GRU:** GRU با پارامترهای بهینه شده مجدداً آموزش داده می‌شود
- **تکرار مراحل ۳ و ۴:** مراحل ۳ و ۴ تا رسیدن به هم‌گرایی یا دستیابی به عملکرد رضایت‌بخش تکرار می‌شوند.

۳.۵. مراحل الگوریتم پیشنهادی

الگوریتم پیشنهادی یک رویکرد جامع برای ایجاد یک سیستم امنیتی پیش‌بینی‌کننده مبتنی بر هوش مصنوعی و بلاک‌چین است که به‌طور خاص برای داده‌های پزشکی IoT طراحی شده‌است. در ادامه، هر مرحله از این الگوریتم مفصل توضیح داده می‌شود

مرحله ۱: راه‌اندازی بلاک‌چین ایجاد شبکه بلاک‌چین: در این مرحله، یک شبکه بلاک‌چین جدید ایجاد می‌شود. بلاک‌چین به عنوان یک دفتر کل توزیع شده عمل می‌کند و تمام تراکنش‌ها و داده‌ها را به صورت امن و شفاف ثبت می‌کند.

تعریف قراردادهای هوشمند: قراردادهای هوشمند برنامه‌های کامپیوتری هستند که مستقیماً در بلاک‌چین اجرا می‌شوند. در این مرحله، قراردادهای هوشمندی تعریف می‌شوند که قوانین و مقررات مربوط به یکپارچگی و امنیت داده‌ها را اجرا می‌کنند. این قراردادهای تضمین می‌کند که داده‌ها به صورت ایمن ذخیره و پردازش شوند

مرحله ۲: جمع‌آوری داده جمع‌آوری داده از دستگاه‌های IoT
پزشکی: داده‌ها از طیف وسیعی از دستگاه‌های IoT پزشکی مانند

استفاده می‌شود. هرگونه انحراف از الگوهای نرمال به عنوان یک ناهنجاری علامت‌گذاری می‌شود

مرحله ۶: یکپارچه‌سازی بلاک‌چین ثبت ناهنجاری‌های تشخیص داده شده و داده‌های دستگاه بر روی بلاک‌چین: هنگامی که یک ناهنجاری تشخیص داده می‌شود، اطلاعات مربوط به آن (مانند شناسه دستگاه، زمان و نوع ناهنجاری) بر روی بلاک‌چین ثبت می‌شود. این کار تضمین می‌کند که داده‌ها غیرقابل تغییر و شفاف باشند.

استفاده از قراردادهای هوشمند برای ایجاد هشدار و پاسخ‌های خودکار: قراردادهای هوشمند می‌تواند بر اساس ناهنجاری‌های ثبت شده

فعال شوند و هشدارها را برای کاربر ارسال کنند یا پاسخ‌های خودکار را اجرا کنند. این پاسخ‌ها ممکن شامل فعال کردن پروتکل‌های امنیتی، اطلاع‌دادن به پرسنل پزشکی یا انجام اقدامات اصلاحی دیگر باشد. این الگوریتم یک رویکرد جامع برای ایجاد یک سیستم امنیتی پیش‌بینی کننده برای داده‌های پزشکی IoT ارائه می‌دهد. با ترکیب قدرت هوش مصنوعی و بلاک‌چین، این سیستم قادر است ناهنجاری‌ها را دقیق تشخیص دهد، یکپارچگی داده‌ها را حفظ کند و پاسخ‌های خودکار را برای اطمینان از امنیت داده‌های پزشکی فعال کند.

۶.۲. معیارهای عملکرد

۶.۱. ارزیابی و نتایج

۶.۲.۱. دقت (precision): این معیار سنجش نشان می‌دهد که یک مدل چقدر می‌تواند موارد مثبت را درست شناسایی کند، بدون اینکه موارد منفی کاذب (false positive) را در نظر بگیرد. به عبارت دیگر، دقت بیانگر آن است که چه درصدی از پیش‌بینی‌های مثبت مدل، واقعاً درست هستند.

$$Prec. = \frac{TP}{FP + TP} \quad (1)$$

نتایج شبیه‌سازی روش پیشنهادی بر روی دو مجموعه داده مجزا، UNSW-NB15 [30] و UNSW-NB15 [33] و ارزیابی شده است. در ادامه، نتایج با یافته‌های کارهای قبلی که به عنوان [11]، [33] و [35] ذکر شده مقایسه می‌شود. این تحلیل مقایسه‌ای با هدف سنجش اثربخشی و عملکرد روش پیشنهادی در مقایسه با رویکردهای موجود بر روی مجموعه داده‌های WUSTLEHMS-2020، UWSN و NSL-KDD انجام می‌شود.

۶.۲.۴. بازخوانی (Recall): این معیار سنجش نشان می‌دهد که یک مدل چقدر می‌تواند تمام موارد مثبت واقعی را به درستی شناسایی کند. به عبارت دیگر، بازخوانی بیانگر آن است که چه درصدی از موارد مثبت واقعی توسط مدل به عنوان مثبت پیش‌بینی شده‌اند.

$$Rec. = \frac{TP}{FP + FN} \quad (4)$$

۶.۱. تنظیمات آزمایشی

آزمایش‌ها بر روی سیستمی با پردازنده Intel Core i7-10700K با ۸ هسته و ۱۶ رشته با فرکانس پایه ۳٫۸۰ گیگاهرتز انجام شد. این سیستم به ۳۲ گیگابایت رم DDR4 و یک SSD NV Me 1 تراپایتی برای ذخیره‌سازی مجهز بود. در مرحله انتخاب ویژگی، از الگوریتم بهینه‌سازی گرگ خاکستری (GWO) با اندازه جمعیت 25 و حداکثر 50 تکرار استفاده شد.

۶.۲.۵. نرخ تشخیص (Detection Rate): معیاری است که به طور گسترده در زمینه‌های مختلف مانند پزشکی، مهندسی، علوم کامپیوتر و... برای سنجش عملکرد سیستم‌ها یا مدل‌ها در شناسایی موارد مثبت واقعی استفاده می‌شود. این معیار به عنوان **نرخ مثبت واقعی (True Positive Rate)** و **حساسیت (Sensitivity)** نیز شناخته می‌شود.

$$Accuracy = \frac{TP + TN}{Total\ Instances} \quad (3)$$

۶.۲.۶. F1-Score: این معیار سنجش میانگین وزنی بین دقت و بازخوانی است. F1-Score به شما کمک می‌کند تا تعادلی بین این دو معیار مهم ایجاد کنید.

$$F1-Score = \frac{2 \times Prec. \times Rec.}{Prec. + Rec.} \quad (2)$$

۶.۲.۳. دقت (Accuracy): معیاری است که میزان درستی کلی پیش‌بینی‌ها را اندازه‌گیری می‌کند.

کاذب (False Positives) تمایل دارد. این معیار با فرمول (۱۸) که در متن اصلی ذکر شده، محاسبه می‌شود.

$$DR = \frac{TP}{TP + FN} \quad (5)$$

۶,۲,۶. نرخ هشدار اشتباه (False Alarm Rate) معیاری است که نشان می‌دهد یک سیستم یا مدل چقدر در تشخیص موارد مثبت

$$FAR = \frac{FP}{FP + TN} \quad (6)$$

جدول ۵ و ۶ روش‌های مختلف را از نظر دقت، فراخوانی، در مجموعه داده UNSW-NB15 مقایسه می‌کنند.

دقت: توانایی شبکه دروازه بازگشتی در پردازش و درک از وابستگی‌های زمانی را افزایش می‌دهد و منجر به بهبود عملکرد پیش‌بینی می‌شود. در نتیجه، مدل پیشنهادی مداوم دقت بالاتری نسبت به سایر رویکردهای به دست می‌آورد.

۷. تجزیه و تحلیل نتایج

روش پیشنهادی، همراه با سایر روش‌های ارزیابی شده، متریک‌های عملکرد بالاتری را در مجموعه داده NSL-KDD نسبت به مجموعه داده UNSW-NB15 نشان می‌دهد.

نمرات دقت، فراخوانی در جدول ۳ و ۴ آمده است، روش پیشنهادی و سایر روش‌ها در مجموعه داده NSL-KDD نسبت به مجموعه داده UNSW-NB15 عملکرد بهتری داشته‌اند. دلیل این امر تعداد بالای حملات در مجموعه داده UNSW-NB15 است که پیچیده‌تر از داده‌های NSL-KDD است. تکنیک انتخاب ویژگی که در این مقاله استفاده کردیم، به GRU سبک شده قدرت تعمیم خوبی بخشید.

جدول 3: نمرات دقت روش‌های مختلف اعمال شده بر روی مجموعه داده NSL-KDD

نوع حمله	روش پیشنهادی	AIBPSF-IoMT	OMLIDS-PBIoT	AIMMFIDS
DoS	94.2	93.2	91.4	88.7
R2L	95.6	95.4	93.3	90.9
Probe	96.8	94.1	91.7	89.8
U2R	94.9	91.8	89.7	88.2
Normal	95.1	95.9	93.8	91.8
Average	95.3	94.4	92.2	90.3

جدول 4: نمرات فراخوانی روش‌های مختلف اعمال شده بر روی مجموعه داده NSL-KDD

نوع حمله	روش پیشنهادی	AIBPSF-IoMT	OMLIDS-PBIoT	AIMMFIDS
DoS	94.1	93.2	91.4	88.7
R2L	95.2	95.4	93.3	90.9
Probe	94.2	94.1	91.7	89.8
U2R	92.1	91.8	89.7	88.2
Normal	96.1	95.9	93.8	91.8

Average	94.3	94.4	92.2	90.3
---------	-------------	------	------	------

جدول 5: نمرات دقت روش های مختلف اعمال شده بر روی مجموعه داده UNSW-NB15

نوع حمله	روش پیشنهادی	AIBPSF-IoMT	OMLIDS-PBIoT	AIMMFIDS
Backdoor	93.1	94.2	92.3	90.2
Worms	95.7	96.4	94.1	92.1
Shellcode	95.2	94.7	92.9	93.0
Exploits	92.3	93.5	91.7	89.3
Fuzzers	96.9	95.9	94.6	91.3
DoS	94.9	94.8	92.8	91.2
Reconnaissance	94.2	94.2	92.5	90.3
Analysis	97.1	95.8	94.3	92.1
Generic	95.0	94.7	93.4	91.2
Normal	95.2	94.8	92.8	91.3
Average	94.9	94.7	93.1	91.1

جدول 6: نمرات فراخوانی روش های مختلف اعمال شده بر روی مجموعه داده UNSW-NB15

نوع حمله	روش پیشنهادی	AIBPSF-IoMT	OMLIDS-PBIoT	AIMMFIDS
Backdoor	93.9	92.3	90.2	88.4
Worms	95.4	94.5	92.1	90.2
Shellcode	95.2	93.4	91.3	88.9
Exploits	94.3	91.3	89.6	87.5
Fuzzers	96.1	95.1	92.6	90.8
DoS	95.3	92.9	91.4	89.1
Reconnaissance	94.3	92.1	90.2	88.7
Analysis	95.1	94.2	92.3	90.3
Generic	91.3	92.9	91.2	88.8
Normal	94.9	92.7	90.6	88.7
Average	94.5	93.1	91.2	89.1

نتایج آزمایش های نرخ تشخیص و نرخ هشدار کاذب در درصد های مختلف حمله در جدول 7 و 8 نشان داده شده است. در تمام مقادیر AP، روش پیشنهادی عملکردی بهتر از سایر روش ها دارد. به عنوان مثال، در AP=30، نرخ تشخیص تنظیم شده 94.3٪ است که از OMLIDS-، AIBPSF-IoMT (94.8%)، از OMLIDS-PBIoT (95.8%)، AIBPSF-IoMT (96.2%) و AIMMFIDS (92.8%) کاهش داشت.

جدول 7: نرخ تشخیص روش های مختلف اعمال شده بر روی مجموعه داده NSL-KDD

نوع حمله	AP=30	AP=40	AP=50	AP=60	AP=70	AP=80
روش پیشنهادی	97.6	97.0	95.3	90.1	88.2	84.3
AIBPSF-IoMT	95.8	94.1	91.9	89.7	84.7	82.2
OMLIDS-PBIoT	96.2	92.7	89.7	86.3	82.5	80.8
AIMMFIDS	93.7	92.65	88.5	85.3	81.8	79.2

نوع حمله	AP=30	AP=40	AP=50	AP=60	AP=70	AP=80
روش پیشنهادی	94.3	95.2	92.8	91.3	87.7	84.6
AIBPSF-IoMT	94.8	92.7	90.3	88.2	84.3	81.2
OMLIDS-PBIOt	94.6	91.6	88.5	84.7	83.0	80.8
AIMMFIDS	92.8	92.6	87.9	85.3	79.8	77.5

جدول 9 تحلیل مقایسه‌ای بین روش پیشنهادی و سه روش موجود: AIBPSF-IoMT، OMLIDS-PBIOt و AIMMFIDS ارائه می‌دهد. معیارهای ارزیابی شامل دقت، فراخوانی، صحت، F1-score، نرخ تشخیص و نرخ هشدار کاذب هستند. این جدول به وضوح عملکرد برتر روش پیشنهادی را در همه معیارها، به ویژه در دستیابی به نرخ تشخیص بالا و نرخ هشدار کاذب پایین نشان می‌دهد، که برای

تشخیص موثر نفوذ در محیط‌های IoT بسیار مهم هستند. این ارزیابی بر روی مجموعه داده WUSTL-EHMS-2020 که برای کار پزشکی ارائه شده است، انجام شد.

جدول 9. تحلیل مقایسه‌ای روش پیشنهادی و روش های موجود در مجموعه داده WUSTL-EHMS-2020.

متد	دقت (%)	صحت (%)	فراخوانی (%)	F1-امتیاز (%)	نرخ تشخیص (%)	نرخ هشدار کاذب (%)
متد پیشنهادی	98.3	97.8	98.5	98.1	97.6	1.2
AIBPSF-IoMT	95.5	94.2	95.8	95.0	94.7	2.5
OMLIDS-PBIOt	96.1	95.0	96.3	95.6	95.2	2.0
AIMMFIDS	94.8	93.5	95.0	94.2	93.8	3.0

۸. بحث

نتایج کارایی یادگیری عمیق ترکیبی پیشنهادی را نشان می‌دهد که شامل انتخاب ویژگی همراه با شبکه GRU برای ارائه تشخیص نفوذ بهبود یافته و دقیق با استفاده از روش‌های یادگیری ماشین است. برای آزمایش این روش، آن را با سه روش جدید دیگر در این زمینه مقایسه کردیم:

Matlob و همکاران [۳۸] مطالعه‌ای را پیشنهاد کردند که بر اهمیت در نظر گرفتن توالی تراکنش‌ها برای درک دقیق تر فعالیت‌های کلاهبرداری تأکید می‌کند. استفاده از مفاهیم استخراج توالی به این روش اجازه داد تا توالی‌های مشترک با الگوهای مختلف ایجاد کند. این انعطاف پذیری باعث افزایش انطباق پذیری مدل با سناریوهای متنوع و پیچیده مراقبت‌های بهداشتی شد. تنظیم دقیق موتور قوانین برای دقیقاً ضبط و نمایش توالی‌های قانونی و همزمان شناسایی ناهنجاری‌ها یک چالش بود. یافتن تعادل مناسب بین تولید و نگهداری قوانین برای اثربخشی این روش بسیار مهم بود.

نتایج نشان می‌دهد که ما همواره در دقت، صحت، فراخوانی و امتیاز F1، به طور قابل توجهی بهتر از دیگران عمل می‌کنیم.

AIBPSF-IoMT، OMLIDS-PBIOt و AIMMFIDS

نتایج نشان می‌دهد که ما همواره در دقت، صحت، فراخوانی و امتیاز F1، به طور قابل توجهی بهتر از دیگران عمل می‌کنیم.

Amponsah و همکاران [۴۰] رویکرد پیشگامانه‌ای را برای تشخیص کلاهبرداری در سیستم‌های مراقبت بهداشتی معرفی کردند که هدف آن کاهش کلاهبرداری به روشی ایمن و شفاف است. این

سیستم اثربخشی خود را در تشخیص دقیق فعالیت‌های کلاهبرداری در پردازش ادعاهای مراقبت‌های بهداشتی با دقت طبقه‌بندی بالا نشان داد. مقیاس‌پذیری سیستم پیشنهادی ممکن است به دلیل پردازش حجم زیادی از داده‌ها در سیستم‌های مراقبت بهداشتی به یک چالش تبدیل شود. اطمینان از عملکرد و پاسخگویی بهینه، به‌ویژه در سناریوهای بزرگ‌مقیاس، به‌عنوان یک جنبه چالش‌برانگیز در نظر گرفته شد.

عملکرد روش پیشنهادی را با سه روش AIBPSF- OMLIDS-PBIOt، IoMT و AIMMFIDS مقایسه کردیم. برای تأیید اثربخشی آن، چارچوب با مدل‌های امنیتی پیشرفته مقایسه شد. نتایج بهبود قابل توجهی را در چندین معیار نشان داد: افزایش 1٪ در دقت، صحت و فراخوان شد. در مطالعات آینده، تلاش‌های تحقیقاتی ما بر تقویت سیستم در برابر تهدیدهای نوظهور، به‌ویژه حملات خصمانه، تمرکز خواهد کرد. برای دستیابی به این هدف، قصد داریم از تکنیک‌های موازی سازی GPU برای افزایش سرعت محاسبات و اطمینان از درک عمیق‌تر از فرآیندهای تصمیم‌گیری سیستم و افزایش مقاومت آن در برابر سوءاستفاده‌های بالقوه استفاده کنیم.

Delal و همکاران [۳۹] رویکردی مبتنی بر الگوریتم XGBoost را به کار گرفتند و اهمیت تنظیم ابر پارامترها را برای بهبود عملکرد پیش‌بینی نشان دادند. این مطالعه در بهینه‌سازی XGBoost برای پیش‌بینی کلاهبرداری در خدمات پرداخت مالی کمک کرد. این رویکرد اثربخشی خود را در تشخیص فعالیت‌های کلاهبرداری در تراکنش‌های مالی دنیای واقعی نشان داد و پتانسیل راه‌حل‌های هوشمند را برای کمک قابل توجه به تشخیص کلاهبرداری در دامنه‌های مختلف برجسته کرد. علاوه بر این، اطمینان از مقیاس‌پذیری و قابلیت کاربردی بلادرنگ تکنیک ترکیبی پیشنهادی برای مدیریت حجم عظیمی از تراکنش‌های آنلاین و فعالیت‌های مالی یک مانع بالقوه بود که نیاز به توجه دقیق برای پیاده‌سازی عملی داشت.

۹. نتیجه گیری

این مقاله رویکردی نوآورانه برای رسیدگی به چالش حیاتی امنیت داده‌های پزشکی در چشم‌انداز اینترنت اشیا ارائه می‌دهد. روش ما فناوری بلاک چینو تکنیک‌های پیشرفته یادگیری ماشین را یکپارچه ترکیب می‌کند و چارچوبی قوی برای افزایش محرمانگی و یکپارچگی اطلاعات حساس مراقبتی فراهم می‌کند. ما رویکرد جامعی با سه مرحله مجزا برای پاسخگویی به نیاز فوری بهبود امنیت در سیستم‌های مراقبت بهداشتی مبتنی بر اینترنت اشیا پیشنهاد کردیم. در مرحله اول، ما قابلیت اطمینان دستگاه‌های اینترنت اشیا را از طریق ذخیره‌سازی داده خارج از زنجیره ارزیابی کردیم. مرحله دوم از فناوری بلاک چین برای جلوگیری از حملات و تأیید اعتبار داده‌ها استفاده می‌کند. در مرحله سوم، از هوش مصنوعی برای طبقه‌بندی حملات استفاده می‌شود. ما

References:

1. Bezanjani, B. R., Ghafouri, S. H., & Gholamrezaei, R. (2024). Fusion of machine learning and blockchain-based privacy-preserving approach for healthcare data in the Internet of Things. *The Journal of Supercomputing*, 1-29.
2. Saheed, Y. K., & Misra, S. (2024). A voting gray wolf optimizer-based ensemble learning models for intrusion detection in the Internet of Things. *International Journal of Information Security*, 1-25.
3. Saheed, K.Y., Usman, A.A., Sukat, F.D., & Abdulrahman, M. (2023). A novel hybrid autoencoder and modified particle swarm optimization feature selection for intrusion detection in the internet of things network. *Frontiers of Computer Science*.
4. Khubrani, M. M. (2023). Artificial Rabbits Optimizer with Deep Learning Model for Blockchain-Assisted Secure Smart Healthcare System. *International Journal of Advanced Computer Science and Applications*, 14(9).
5. Cai, J., Liang, W., Li, X., Li, K., Gui, Z., & Khan, M. K. (2023). GTxChain: a secure IoT smart blockchain architecture based on graph neural network. *IEEE Internet of Things Journal*.
6. Kumar, P., Kumar, R., Srivastava, G., Gupta, G. P., Tripathi, R., Gadekallu, T. R., & Xiong, N. N. (2021). PPSF: A privacy-preserving and secure framework using blockchain-based machine-learning for IoT-driven smart cities. *IEEE*

- Transactions on Network Science and Engineering*, 8(3), 2326-2341.
7. Shrestha, A., & Mahmood, A. (2019). Review of deep learning algorithms and architectures. *IEEE access*, 7, 53040-53065.
 8. Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., ... & Farhan, L. (2021). Review of deep learning: Concepts, CNN architectures, challenges, applications, future directions. *Journal of big Data*, 8, 1-74.
 9. Ayyoubzadeh, S. M., Ayyoubzadeh, S. M., Zahedi, H., Ahmadi, M., & Kalhori, S. R. N. (2020). Predicting COVID-19 incidence through analysis of google trends data in Iran: data mining and deep learning pilot study. *JMIR public health and surveillance*, 6(2), e18828.
 10. Ahmad, R. W., Salah, K., Jayaraman, R., Yaqoob, I., Ellahham, S., & Omar, M. (2021). The role of blockchain technology in telehealth and telemedicine. *International journal of medical informatics*, 148, 104399.
 11. Alshammari, B. M. (2023). AIBPSF-IoMT: Artificial Intelligence and Blockchain-Based Predictive Security Framework for IoMT Technologies. *Electronics*, 12(23), 4806.
 12. Afaq, Y., & Manocha, A. (2023). Blockchain and Deep Learning Integration for Various Application: A Review. *Journal of Computer Information Systems*, 1-14.
 13. Shafay, M., Ahmad, R. W., Salah, K., Yaqoob, I., Jayaraman, R., & Omar, M. (2023). Blockchain for deep learning: review and open challenges. *Cluster Computing*, 26(1), 197-221.
 14. Mudassir, M., Unal, D., Hammoudeh, M., & Azzedin, F. (2022). Detection of botnet attacks against industrial IoT systems by multilayer deep learning approaches. *Wireless Communications and Mobile Computing*, 2022.
 15. Azbeg, K., Ouchetto, O., & Andaloussi, S. J. (2022). BlockMedCare: A healthcare system based on IoT, Blockchain and IPFS for data management security. *Egyptian Informatics Journal*, 23(2), 329-343.
 16. Sudhakaran, P. (2022). Energy efficient distributed lightweight authentication and encryption technique for IoT security. *International Journal of Communication Systems*, 35(2), e4198.
 17. Yin, C., Zhang, S., Wang, J., & Xiong, N. N. (2020). Anomaly detection based on convolutional recurrent autoencoder for IoT time series. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 52(1), 112-122.
 18. Xu, Z., Liang, W., Li, K. C., Xu, J., & Jin, H. (2021). A blockchain-based roadside unit-assisted authentication and key agreement protocol for internet of vehicles. *Journal of Parallel and Distributed Computing*, 149, 29-39.
 19. Liang, W., Ning, Z., Xie, S., Hu, Y., Lu, S., & Zhang, D. (2021). Secure fusion approach for the internet of things in smart autonomous multi-robot systems. *Information Sciences*, 579, 468-482.
 20. Khalaf, O. I., & Abdulsahib, G. M. (2021). Optimized dynamic storage of data (ODSD) in IoT based on blockchain for wireless sensor networks. *Peer-to-Peer Networking and Applications*, 14, 2858-2873.
 21. Srinivasu, P. N., Bhoi, A. K., Nayak, S. R., Bhutta, M. R., & Woźniak, M. (2021). Blockchain technology for secured healthcare data communication among the non-terminal nodes in IoT architecture in 5G network. *Electronics*, 10(12), 1437.
 22. Zhang, J. (2021). Distributed network security framework of energy internet based on internet of things. *Sustainable Energy Technologies and Assessments*, 44, 101051.
 23. Zheng, Z., Xie, S., Dai, H. N., Chen, W., Chen, X., Weng, J., & Imran, M. (2020). An overview on smart contracts: Challenges, advances and platforms. *Future Generation Computer Systems*, 105, 475-491.
 24. Li, Y., Chen, C., Liu, N., Huang, H., Zheng, Z., & Yan, Q. (2020). A blockchain-based decentralized federated learning framework with committee consensus. *IEEE Network*, 35(1), 234-241.
 25. Philip, A. O., & Saravanaguru, R. K. (2020). Secure incident & evidence management framework (SIEMF) for internet of vehicles using deep learning and blockchain. *Open Computer Science*, 10(1), 408-421.
 26. AlKadi, O., Moustafa, N., Turnbull, B., & Choo, K. K. R. (2019). Mixture localization-based outliers models for securing data migration in cloud centers. *IEEE Access*, 7, 114607-114618.
 27. Liang, G., Weller, S. R., Luo, F., Zhao, J., & Dong, Z. Y. (2018). Distributed blockchain-based data protection framework for modern power systems against cyber attacks. *IEEE Transactions on Smart Grid*, 10(3), 3162-3173.
 28. Liu, X., Muhammad, K., Lloret, J., Chen, Y. W., & Yuan, S. M. (2019). Elastic and cost-effective data carrier architecture for smart contract in blockchain. *Future Generation Computer Systems*, 100, 590-599.
 29. Rathore, S., & Park, J. H. (2018). Semi-supervised learning based distributed attack detection framework for IoT. *Applied Soft Computing*, 72, 79-89.
 30. Wang, Z. (2018). Deep learning-based intrusion detection with adversaries. *IEEE Access*, 6, 38367-38384.
 31. Mirjalili, S., & Lewis, A. (2016). The whale optimization algorithm. *Advances in engineering software*, 95, 51-67.

32. Tavallaee, M., Bagheri, E., Lu, W., & Ghorbani, A. A. (2009, July). A detailed analysis of the KDD CUP 99 data set. In *2009 IEEE symposium on computational intelligence for security and defense applications* (pp. 1-6). Ieee.
33. Moustafa, N., & Slay, J. (2015, November). UNSW-NB15: a comprehensive data set for network intrusion detection systems (UNSW-NB15 network data set). In *2015 military communications and information systems conference (MilCIS)* (pp. 1-6). IEEE.
34. Al-Qarafi, A., Alrowais, F., S. Alotaibi, S., Nemri, N., Al-Wesabi, F. N., Al Duhayyim, M., ... & Al-Shabi, M. (2022). Optimal machine learning based privacy preserving blockchain assisted internet of things with smart cities environment. *Applied Sciences*, *12*(12), 5893.
35. Alohal, M. A., Al-Wesabi, F. N., Hilal, A. M., Goel, S., Gupta, D., & Khanna, A. (2022). Artificial intelligence enabled intrusion detection systems for cognitive cyber-physical systems in industry 4.0 environment. *Cognitive Neurodynamics*, *16*(5), 1045-1057.
36. Hady, A. A., Ghubaish, A., Salman, T., Unal, D., & Jain, R. (2020). Intrusion detection system for healthcare systems using medical and network data: A comparison study. *IEEE Access*, *8*, 106576-106584.
37. Huang, Y., Zhao, Z., & Shi, C. (2024). Network Security Perception System Integrating Improved CNN Algorithm and Improved GRU Algorithm. IEEE Access.
38. Matloob, S. A. Khan, R. Rukaiya, M. A. K. Khattak and A. Munir, "A sequence mining-based novel architecture for detecting fraudulent transactions in healthcare systems", IEEE Access, vol. 10, pp. 48447- 48463, 2022.##
39. Matloob, S. A. Khan, R. Rukaiya, M. A. K. Khattak and A. Munir, "A sequence mining-based novel architecture for detecting fraudulent transactions in healthcare systems", IEEE Access, vol. 10, pp. 48447- 48463, 2022.S. Dalal, B. Seth, M. Radulescu, C. Secara and C. Tolea, "Predicting fraud in financial payment services through optimized hyperparameter-tuned XGBoost model", Mathematics, vol. 10, no. 24, 4679, 2021. .
40. I. Matloob, S. A. Khan, R. Rukaiya, M. A. K. Khattak and A. Munir, "A sequence mining-based novel architecture for detecting fraudulent transactions in healthcare systems", IEEE Access, vol. 10

