

## Improving Data Query and Ensuring Security in Mobile Vehicular Networks Using Deep Learning and Blockchain

S.E. Dashti<sup>1</sup>, F. Moayyedi<sup>2</sup>

<sup>1</sup> Department of Electrical and Computer Engineering, Jahrom Branch, Islamic Azad University, Jahrom, Iran

<sup>2</sup> Department of Electrical and Computer Engineering, Larestan University, Iran

### ABSTRACT

### RESEARCH PAPER

Received: 2025-8-5  
Accepted: 2025-11-9

#### KEYWORDS:

Deep Learning,  
Blockchain,  
Mobile Vehicular Network,  
Data Management,  
Data Security.

<sup>1</sup> Corresponding author:

 Seyedbrahim.dashti@iau.ac.ir

**Background and Objectives:** With the expansion of Vehicular Ad-hoc Networks (VANETs), the need for fast and secure data access has increased. Cloud-based solutions suffer from high latency, and edge computing methods face limitations in storage and management. Furthermore, most prior research has focused solely on either reducing latency or enhancing security. This paper aims to propose an innovative hybrid model for the simultaneous optimization of latency and security in data caching and retrieval for VANETs. **Methods:** To achieve this, an integrated framework based on edge computing, deep learning, and blockchain is proposed. An LSTM network is used to predict traffic patterns and data popularity to optimize cache placement at edge nodes. Additionally, a blockchain with a Proof-of-Authority (PoA) consensus mechanism and smart contracts is employed for the secure and decentralized storage of critical data and metadata. The performance of the proposed model was evaluated using latency, security, and scalability metrics and compared with Tabu Search, CCS-AGP, and Random Caching methods. **Findings:** The proposed model significantly reduced delay (by 10% to 30% compared to baseline methods). The use of blockchain introduced only an 8% additional delay while elevating security to a "very high" level. The system demonstrated stability and scalability under increasing numbers of nodes and data volume. Simulation results indicated that the combination of deep learning and blockchain achieves an optimal balance between performance and security.

**Conclusion:** The intelligent integration of deep learning (for predictive caching optimization) and blockchain technology (for security and decentralization) at the network edge establishes an optimal balance between performance (low latency) and security. This framework can serve as a robust foundation for developing intelligent transportation systems, smart cities, and future sensitive IoT applications.

Copyright © Author(s).



## نشریه تخصصی آرمان پردازش، دوره ۶، شماره ۳، سال ۱۴۰۴

فصلنامه تخصصی آرمان پردازش  
(APJ)Homepage: [www.armanprocessjournal.ir](http://www.armanprocessjournal.ir)بهبود پرس و جوی داده‌ها و حفظ امنیت در شبکه‌های وسایل نقلیه با استفاده از  
یادگیری عمیق و بلاکچینسید ابراهیم دشتی<sup>۱\*</sup>، فاطمه مویدی<sup>۲</sup>

۱ گروه برق و کامپیوتر، واحد جهرم، دانشگاه آزاد اسلامی، جهرم، ایران

۲ گروه برق و کامپیوتر، مجتمع آموزش عالی لارستان، ایران

## چکیده

**پیشینه و اهداف:** با گسترش شبکه‌های وسایل نقلیه (VANETs)، نیاز به دسترسی سریع و ایمن به داده‌ها افزایش یافته است. راه‌حل‌های مبتنی بر ابر به دلیل تأخیر بالا و روش‌های محاسبات لبه به دلیل محدودیت‌های ذخیره‌سازی و مدیریت، پاسخگوی کامل این نیازها نیستند. همچنین، اغلب پژوهش‌های پیشین تنها بر کاهش تأخیر یا افزایش امنیت متمرکز بوده‌اند. هدف این مقاله، ارائه یک مدل ترکیبی نوآورانه برای بهینه‌سازی همزمان تأخیر و امنیت در ذخیره‌سازی و بازیابی داده‌های VANETs است.

**روش‌ها:** برای دستیابی به این هدف، یک چارچوب یکپارچه مبتنی بر محاسبات لبه، یادگیری عمیق و زنجیره بلوکی پیشنهاد شده است. از شبکه LSTM برای پیش‌بینی الگوهای ترافیک و محبوبیت داده‌ها به منظور بهینه‌سازی محل ذخیره‌سازی (کش) در گره‌های لبه استفاده شد. همچنین، از یک زنجیره بلوکی با مکانیزم اجماع PoA و قراردادهای هوشمند برای ذخیره‌سازی امن و غیرمتمرکز داده‌های حیاتی و متادیتا بهره گرفته شد. عملکرد مدل پیشنهادی با معیارهای تأخیر، امنیت و مقیاس‌پذیری ارزیابی و با روش‌های Tabu Search، CCS-AGP و Random Caching مقایسه شد.

**یافته‌ها:** مدل پیشنهادی تأخیر را به طور قابل توجهی کاهش داده (۱۰٪ تا ۳۰٪ نسبت به روش‌های مورد مقایسه) است. استفاده از زنجیره بلوکی تنها ۸٪ تأخیر اضافی ایجاد کرد در حالی که امنیت را به سطح «بسیار بالا» رساند. و سیستم در برابر افزایش تعداد گره‌ها و حجم داده‌ها پایدار و مقیاس‌پذیر عمل کرد. نتایج شبیه‌سازی نشان داد که ترکیب یادگیری عمیق و زنجیره بلوکی توازن بهینه‌ای بین عملکرد و امنیت برقرار می‌کند.

**نتیجه‌گیری:** ترکیب هوشمندانه یادگیری عمیق (برای پیش‌بینی و بهینه‌سازی کش) و فناوری زنجیره بلوکی (برای تأمین امنیت و غیرمتمرکزسازی) در لبه شبکه، توازن بهینه‌ای بین عملکرد (کاهش تأخیر) و امنیت برقرار می‌کند. این چارچوب می‌تواند پایه‌ای قوی برای توسعه سامانه‌های حمل‌ونقل هوشمند، شهرهای هوشمند و کاربردهای حساس آینده در اینترنت اشیا باشد.

## مقاله پژوهشی

## واژگان کلیدی:

یادگیری عمیق،  
زنجیره بلوکی،  
مدیریت داده،  
شبکه‌های وسایل نقلیه متحرک،  
امنیت داده.

نویسنده مسئول:  
seyedebrahim.dashti@iau.ac.ir

## ۱- مقدمه

با پیشرفت روزافزون فناوری‌های هوشمند و ارتباطی، شبکه‌های وسایل نقلیه به یکی از اجزای اصلی سیستم‌های حمل‌ونقل هوشمند تبدیل شده‌اند [۱-۲]. این شبکه‌ها با فراهم کردن بستری برای تبادل اطلاعات بین وسایل نقلیه و زیرساخت‌های مرتبط، نقشی حیاتی در بهبود ایمنی، کاهش ترافیک، و بهینه‌سازی مصرف سوخت ایفا می‌کنند [۳-۴]. با این حال، چالش‌های متعددی همچنان در این حوزه وجود دارد که از جمله مهم‌ترین آن‌ها می‌توان به تأخیر در بازیابی داده‌ها و محدودیت‌های امنیتی در مدیریت داده‌ها اشاره کرد. داده‌هایی که توسط این شبکه‌ها به اشتراک گذاشته می‌شوند، نیازمند تحلیل سریع و همچنین حفاظت از حریم خصوصی و یکپارچگی هستند [۵-۶]. روش‌های سنتی ذخیره‌سازی مبتنی بر ابر، به دلیل فاصله زیاد میان وسایل نقلیه و خدمت دهنده‌ها، نمی‌توانند پاسخگوی نیازهای زمانی و امنیتی کاربران باشند. این روش‌ها اغلب باعث افزایش تأخیر و کاهش کیفیت خدمات می‌شوند. در مقابل، محاسبات لبه به‌عنوان یک راه‌حل کارآمد، با انتقال پردازش و ذخیره‌سازی داده‌ها به نزدیک‌ترین نقاط به کاربران، امکان کاهش تأخیر و بهبود زمان پاسخگویی را فراهم کرده است [۷]. اما این روش نیز به دلیل محدودیت‌های ذخیره‌سازی و مدیریت توزیع‌شده، نیازمند بهبود و توسعه است تا بتواند به طور موثرتری نیازهای متغیر شبکه‌های وسایل نقلیه را برآورده کند. از سوی دیگر، زنجیره بلوکی با ارائه یک ساختار غیرمتمرکز و ایمن، می‌تواند حریم خصوصی و امنیت داده‌ها را تضمین کرده و از دستکاری یا دسترسی غیرمجاز جلوگیری کند. این ترکیب نوآورانه می‌تواند زمینه‌ساز تحولی اساسی در مدیریت داده‌های شبکه‌های وسایل نقلیه باشد [۷].

در این راستا، استفاده از تکنولوژی‌های پیشرفته نظیر یادگیری عمیق و زنجیره بلوکی می‌تواند راه‌حل‌های موثری برای رفع این چالش‌ها ارائه دهد. یادگیری عمیق با تحلیل و پیش‌بینی دقیق الگوهای ترافیکی و رفتار کاربران، می‌تواند بهینه‌سازی منابع ذخیره‌سازی و پردازش را تسهیل کند [۱۱]. در سال‌های اخیر، پژوهش‌های متعددی برای بهینه‌سازی ذخیره‌سازی و پردازش داده‌ها در شبکه‌های وسایل نقلیه انجام شده است. این تحقیقات

عمدتاً بر کاهش تأخیر، بهبود استفاده از منابع ذخیره‌سازی و افزایش کارایی تمرکز داشته‌اند. با این حال، هر یک از این پژوهش‌ها محدودیت‌هایی داشته‌اند که نیاز به راه‌حل‌های جامع‌تر را برجسته می‌کند [۹]. به طور مثال در مدل بهینه‌سازی پرس‌وجوی داده در محیط‌های لبه، از الگوریتم جستجوی تابو برای کاهش تأخیر و بهبود کارایی پرس‌وجو استفاده می‌شود و چالش اصلی آن پیچیدگی در پیاده‌سازی و مصرف منابع بالا است. در ذخیره‌سازی محتوای مبتنی بر یادگیری تقویتی چندعامله، از یادگیری تقویتی برای بهبود ذخیره‌سازی داده‌ها در شبکه‌های لبه بهره برده می‌شود و چالش اصلی آن توپولوژی پیچیده شبکه است. در چارچوب ذخیره‌سازی محتوا با الگوریتم جستجوی کوکو، برای کاهش تأخیر و هزینه‌های ذخیره‌سازی از الگوریتم بهینه‌سازی می‌شود و چالش اصلی آن محدودیت ذخیره‌سازی روی دستگاه‌های منفرد است. در تخلیه وظایف و جایگزینی خدمات در شبکه‌های لبه، یادگیری تقویتی عمیق با الگوریتم‌های بهینه‌سازی برای بهبود تخلیه وظایف ترکیب می‌شوند و چالش اصلی آن نیاز به انعطاف‌پذیری بالا برای مدیریت وظایف پویا است.

بیشتر پژوهش‌ها تنها بر یکی از جنبه‌های بهینه‌سازی مانند کاهش تأخیر یا بهبود ذخیره‌سازی تمرکز داشته‌اند. تحقیقات کمی به ترکیب تکنولوژی‌های پیشرفته مانند یادگیری عمیق و زنجیره بلوکی برای ارائه یک راه‌حل جامع پرداخته‌اند [۱۴]. مدل پیشنهادی این مقاله با ترکیب یادگیری عمیق و زنجیره بلوکی، به‌طور هم‌زمان امنیت و کارایی را بهبود بخشیده است و شکاف‌های موجود در تحقیقات پیشین را پوشش می‌دهد.

اصلی‌ترین نوآوری این مقاله، ارائه یک چارچوب یکپارچه است که برای اولین بار مدل پیش‌بینی LSTM (از خانواده یادگیری عمیق) را با فناوری زنجیره بلوکی برای حل چالش‌های شبکه‌های وسایل نقلیه متحرک (VANETs) ترکیب می‌کند. این ترکیب به صورت هم‌زمان دو هدف متضاد «کاهش تأخیر» و «افزایش امنیت» را محقق می‌سازد. بهینه‌سازی هوشمند کش با استفاده از شبکه LSTM برای پیش‌بینی دقیق الگوهای ترافیکی و محبوبیت محتوای داده‌ها، بر اساس تاریخچه درخواست‌ها، این پیش‌بینی به سیستم این امکان را می‌دهد که به‌طور هوشمندانه تصمیم بگیرد کدام داده‌ها را در کدام گره‌های لبه (Edge Nodes) و در چه زمانی کش

شده است. پژوهش‌هایی مانند "Hou et al., 2018" نشان داده‌اند که با انتقال پردازش داده‌ها به نزدیک‌ترین نقاط ممکن (یعنی خدمت دهنده‌های لبه)، می‌توان تأخیر را به‌طور چشم‌گیری کاهش داد. با این حال، محدودیت‌های ذخیره‌سازی و نیاز به هماهنگی بین گره‌ها همچنان از چالش‌های اصلی این رویکرد محسوب می‌شوند [15]. استفاده از مدل‌های یادگیری عمیق، به‌ویژه شبکه‌های عصبی بازگشتی (RNN) و مدل‌های بلندمدت-کوتاه‌مدت (LSTM)، امکان پیش‌بینی دقیق الگوهای ترافیکی در داده را فراهم کرده است. پژوهش‌هایی نظیر "Zhang et al., 2020" نشان داده‌اند که یادگیری عمیق می‌تواند رفتار کاربران و حجم داده‌ها را پیش‌بینی کرده و از این طریق منابع شبکه را بهینه کند [12-15]. زنجیره بلوکی به‌عنوان یک فناوری نوظهور در مدیریت داده‌ها، قابلیت‌های متعددی برای تضمین امنیت و یکپارچگی داده‌ها ارائه می‌دهد. پژوهش‌هایی مانند "Wang et al., 2022" نشان داده‌اند که با استفاده از مکانیزم اجماع و قراردادهای هوشمند، می‌توان از دستکاری داده‌ها جلوگیری کرد و دسترسی غیرمجاز را محدود نمود. با این حال، استفاده از زنجیره بلوکی در محیط‌های لبه همچنان با چالش‌هایی مانند مصرف بالای منابع همراه است [10]. نقاط ضعف تحقیقات پیشین این است که گرچه پژوهش‌های متعددی به بررسی کاهش تأخیر [3] یا افزایش امنیت پرداخته‌اند، اما ترکیب این دو هدف به‌صورت یکپارچه و کارآمد کمتر مورد توجه قرار گرفته است. علاوه بر این، بیشتر مدل‌های موجود بر روی یکی از این دو جنبه تمرکز دارند [3] و نیاز به رویکردهایی که به‌طور همزمان امنیت و عملکرد را بهبود دهند، به‌وضوح احساس می‌شود.

یادگیری عمیق یکی از شاخه‌های یادگیری ماشین است که از شبکه‌های عصبی با لایه‌های متعدد برای تحلیل داده‌ها و شناسایی الگوهای پیچیده استفاده می‌کند [15]. این روش به دلیل توانایی بالای آن در پردازش حجم زیاد داده و پیش‌بینی دقیق، در کاربردهای متعددی نظیر پردازش تصویر، تحلیل زبان و پیش‌بینی سری‌های زمانی استفاده می‌شود. ویژگی‌های کلیدی یادگیری عمیق شامل قابلیت یادگیری خودکار، یعنی نیازی به ویژگی‌های دستی طراحی شده نیست و دقت بالا به ویژه در مسائل پیچیده و غیرخطی و هم‌چنین انعطاف‌پذیری که قابل استفاده در دامنه‌های متنوعی از مسائل است [16]. زنجیره بلوکی یک فناوری توزیع‌شده و ایمن است که برای ذخیره‌سازی داده‌ها و اجرای تراکنش‌ها بدون

کند تا تأخیر دسترسی به حداقل برسد. تضمین امنیت و یکپارچگی داده‌ها با زنجیره بلوکی با استفاده از زنجیره بلوکی به‌عنوان یک لایه امنیتی غیرمتمرکز برای ذخیره‌سازی ایمن داده‌های حیاتی و حساس. به کارگیری قراردادهای هوشمند (Smart Contracts) برای اعتبارسنجی خودکار داده‌ها و جلوگیری از دستکاری و دسترسی غیرمجاز. استفاده از مکانیزم اجماع Proof of Authority (PoA) که نسبت به مدل‌های رایجی مانند Proof of Work مصرف منابع کمتری دارد و برای محیط لبه مناسب‌تر است.

در نتیجه، نوآوری اصلی این مقاله نه در ارائه یک فناوری کاملاً جدید، بلکه در ترکیب هوشمندانه و یکپارچه‌سازی دو فناوری پیشرفته (یادگیری عمیق و زنجیره بلوکی) در یک معماری خاص برای حل یک مشکل عملی در شبکه‌های وسایل نقلیه است که منجر به دستیابی همزمان به دو هدف کلیدی کاهش تأخیر و افزایش امنیت شده است. در این مقاله، یک مدل بهینه‌سازی جدید برای مدیریت و بازیابی داده‌ها در شبکه‌های وسایل نقلیه ارائه شده است. مدل پیشنهادی از شبکه‌های عصبی عمیق برای پیش‌بینی دقیق الگوهای درخواست داده‌ها استفاده کرده و با بهره‌گیری از زنجیره بلوکی امنیت و یکپارچگی داده‌ها را تضمین می‌کند. این رویکرد ترکیبی، علاوه بر کاهش تأخیر در بازیابی داده‌ها، امکان مدیریت توزیع‌شده و انعطاف‌پذیر داده‌ها را فراهم می‌آورد. ساختار این مقاله به‌صورت زیر است: در بخش دوم، پیشینه تحقیق مرتبط با چالش‌ها و راه‌حل‌های موجود بررسی می‌شود. بخش سوم به تشریح جزئیات روش پیشنهادی شامل استفاده از یادگیری عمیق و زنجیره بلوکی می‌پردازد. در بخش چهارم، نتایج شبیه‌سازی‌ها و ارزیابی عملکرد مدل ارائه می‌شود و در نهایت، در بخش پنجم، نتیجه‌گیری و پیشنهادات برای تحقیقات آینده مطرح خواهد شد.

## ۲- پیشینه تحقیق

شبکه‌های وسایل نقلیه به‌عنوان یکی از فناوری‌های کلیدی در سیستم‌های حمل‌ونقل هوشمند، با چالش‌های متعددی مواجه هستند. این چالش‌ها شامل تأخیر در بازیابی داده‌ها است به این دلیل که فاصله زیاد بین وسایل نقلیه و خدمت دهنده‌های مرکزی، ممکن است باعث به‌وجود آمدن تأخیر قابل‌توجهی در دسترسی به داده‌ها باشد. یا مثلاً در امنیت و حریم خصوصی، داده‌های حساس که توسط وسایل نقلیه گردآوری می‌شوند، نیازمند حفاظت در برابر دسترسی‌های غیرمجاز و تضمین صحت هستند [8]. محاسبات لبه به‌عنوان یک راه‌حل برای کاهش تأخیر در بازیابی داده‌ها معرفی

که مطالعات مرتبط با زنجیره بلوکی بر کاهش تأخیر در شبکه‌ها تمرکز کمتری داشته‌اند [1-18]. این مقاله تلاش دارد تا با یکپارچه‌سازی این دو فناوری، به طور جامع به چالش‌های اساسی موجود در شبکه‌های وسایل نقلیه پاسخ دهد و شکاف‌های موجود در تحقیقات را کم کند. ادغام تکنیک‌های یادگیری عمیق با ساختارهای مبتنی بر زنجیره بلوکی می‌تواند نه تنها در مدیریت شبکه‌های وسایل نقلیه، بلکه در سایر کاربردهای اینترنت اشیا (IoT) نیز به کار رود. به‌طور خاص، استفاده از این رویکرد در زمینه‌هایی نظیر مدیریت انرژی هوشمند و حمل‌ونقل پایدار، افق‌های جدیدی را پیش روی محققان قرار می‌دهد و می‌تواند پتانسیل آینده تحقیقات باشد. مدل پیشنهادی در این مقاله با ترکیب یادگیری عمیق برای پیش‌بینی دقیق و استفاده از زنجیره بلوکی برای تضمین امنیت، یک رویکرد نوآورانه برای مدیریت داده‌های شبکه‌های وسایل نقلیه ارائه می‌دهد. این ترکیب باعث کاهش تأخیر، افزایش امنیت و بهبود کلی عملکرد شبکه خواهد شد.

عمیق برای پیش‌بینی الگوهای ترافیکی و شناسایی داده‌های حیاتی استفاده می‌شود.

لایه زنجیره بلوکی که در این لایه برای ذخیره‌سازی ایمن داده‌ها و مدیریت توزیع‌شده طراحی شده است. تمام داده‌های حساس در این لایه ثبت و ایمن‌سازی می‌شوند.

۲- استفاده از یادگیری عمیق که برای پیش‌بینی دقیق‌تر، از مدل LSTM استفاده شده است. این مدل‌ها قابلیت تحلیل سری‌های زمانی و شناسایی الگوهای پیچیده ترافیکی را دارند. داده‌های جمع‌آوری‌شده از وسایل نقلیه به عنوان ورودی به مدل داده می‌شوند و خروجی شامل پیش‌بینی‌های مربوط به ترافیک و نیازهای ذخیره‌سازی است.

۴- هماهنگی بین لایه‌ها که برای اطمینان از عملکرد هماهنگ سیستم، پروتکل‌های ارتباطی بین لایه‌های مختلف طراحی شده‌اند. این پروتکل‌ها تضمین می‌کنند که داده‌ها به صورت ایمن و با کمترین تأخیر بین لایه‌ها منتقل شوند.

### ۳-۱ معماری سیستم پیشنهادی

نیاز به واسطه طراحی شده است. این فناوری بر اساس ساختاری از بلوک‌ها که به صورت زنجیره‌ای به یکدیگر متصل هستند عمل می‌کند. هر بلوک شامل اطلاعات تراکنش‌ها و یک درهم‌سازی منحصر به فرد است که تغییر ناپذیری و امنیت داده‌ها را تضمین می‌کند. مکانیزم‌های اجماع نظیر اثبات کار (PoW) و اثبات سهام (PoS) به عنوان روش‌های اصلی برای تأیید تراکنش‌ها و حفظ یکپارچگی زنجیره بلوکی عمل می‌کنند. مزایای کلیدی زنجیره بلوکی شامل امنیت بالا، یعنی داده‌ها در برابر دستکاری و حملات محافظت می‌شوند. شفافیت، یعنی تمامی تراکنش‌ها به صورت عمومی قابل مشاهده هستند. و غیرمتمرکز بودن، یعنی نیاز به واسطه‌ها حذف می‌شود [17]. این دو فناوری در ترکیب با یکدیگر می‌توانند به حل چالش‌های اساسی در مدیریت داده‌های شبکه‌های وسایل نقلیه کمک کنند، جایی که امنیت، تأخیر کم و دقت پیش‌بینی اهمیت بالایی دارند. اکثر مطالعات موجود، به‌جای استفاده از ترکیبی از رویکردها، تنها بر روی بهینه‌سازی یک بخش خاص متمرکز شده‌اند. برای مثال، مدل‌های مبتنی بر یادگیری عمیق به چالش‌های مربوط به امنیت کمتر توجه داشته‌اند، در حالی

### ۳- مدل پیشنهادی

جزئیات مدل پیشنهادی را در قسمت زیر بیان شده است و در ادامه با جزئیات تشریح شده است.

۱- معماری سیستم پیشنهادی: معماری کلی سیستم در مدل پیشنهادی برای بهبود عملکرد پیش‌بینی و امنیت در سیستم‌های مدیریت داده‌های توزیع‌شده طراحی شده است. این مدل شامل سه لایه کلیدی و دو مؤلفه اصلی (یادگیری عمیق و زنجیره بلوکی) است که به صورت یکپارچه عمل می‌کنند. لایه وسایل نقلیه که در این لایه، وسایل نقلیه داده‌های محیطی و عملیاتی را گردآوری کرده و به لایه لبه ارسال می‌کنند. لایه محاسبات لبه که این لایه وظیفه پیش‌پردازش و تحلیل داده‌ها را بر عهده دارد. از مدل‌های یادگیری ۳- پیاده‌سازی زنجیره بلوکی، زنجیره بلوکی به عنوان یک زیرساخت توزیع‌شده برای مدیریت ایمن داده‌ها به کار گرفته شده است. این زیرساخت شامل قراردادهای هوشمند برای اجرای خودکار فرآیندهای ذخیره‌سازی و بازیابی داده‌ها است. همچنین، مکانیزم اجماع برای اطمینان از صحت و یکپارچگی داده‌ها استفاده می‌شود.

از ذخیره سازی، توسط گره های شبکه تأیید می شوند تا صحت و یکپارچگی آن ها تضمین شود. مزایای آن، افزایش امنیت و جلوگیری از دستکاری داده ها و کاهش خطر از دست رفتن داده ها به دلیل ذخیره سازی توزیع شده است.

لایه وسیله نقلیه و جریان داده ها و هماهنگی بین لایه ها در این لایه، وسایل نقلیه داده های محیطی و عملیاتی (مانند اطلاعات ترافیکی، مکان، سرعت، و شرایط محیطی) را جمع آوری می کنند. این داده ها از طریق حسگرهای تعبیه شده در وسایل نقلیه به لایه لبه ارسال می شوند.

داده ها ابتدا از لایه وسایل نقلیه گردآوری شده و به لایه محاسبات لبه منتقل می شوند. پس از تحلیل و پیش بینی، داده های حساس به لایه زنجیره بلوکی ارسال شده و در صورت نیاز بازبایی می شوند. برای اطمینان از انتقال داده ها بدون خطر و با حداقل تأخیر، از پروتکل های ارتباطی ایمن استفاده می شود. مزایای آن، اطمینان از هماهنگی بین لایه ها و مدیریت یکپارچه داده ها با کمترین تأخیر و بالاترین امنیت است.



شکل ۱- معماری سیستم پیشنهادی

وظایف اصلی آن است که ذخیره و پاسخ به پرس و جوی داده های محیطی و عملیاتی وسایل نقلیه با توجه به الگوهای ترافیکی، مکان جغرافیایی، سرعت، و شرایط محیطی بصورت مناسب صورت گیرد. ابزارهای مورد استفاده در آن، حسگرهای IoT و دستگاه های متصل که در وسایل نقلیه تعبیه شده اند. نحوه ارتباطات این گونه است که داده ها از طریق پروتکل های ارتباطی ایمن و سریع به لایه لبه منتقل می شوند. این لایه به عنوان نقطه آغازین جمع آوری داده ها عمل می کند. سیستم پیشنهادی شامل سه لایه کلیدی است که با استفاده از مؤلفه های یادگیری عمیق و زنجیره بلوکی، بهبود قابل توجهی در پیش بینی و مدیریت داده ها ارائه می دهد. معماری سیستم به شرح زیر است:

#### لایه محاسبات لبه (Edge Computing Layer)

این لایه مسئولیت پردازش و تحلیل داده های جمع آوری شده را بر عهده دارد. وظایف اصلی آن، پیش پردازش داده ها است، یعنی داده ها پیش از ورود به مدل یادگیری عمیق استانداردسازی و نوین گیری می شوند. مورد بعدی تحلیل و پیش بینی از مدل های یادگیری عمیق (Deep Learning)، به ویژه LSTM، برای تحلیل سری های زمانی و پیش بینی الگوهای ترافیکی و محبوبیت داده ها استفاده می شود و مورد آخر شناسایی داده های حیاتی، یعنی داده هایی که برای ذخیره سازی ضروری هستند، شناسایی و به لایه زنجیره بلوکی ارسال می شوند. مزایای لایه محاسبات، کاهش تأخیر به دلیل پردازش نزدیک به منبع داده و بهبود دقت پیش بینی با استفاده از مدل های پیشرفته یادگیری عمیق می باشد.

#### لایه زنجیره بلوکی (Blockchain Layer)

این لایه به عنوان زیرساختی ایمن و توزیع شده برای ذخیره سازی و مدیریت داده ها عمل می کند. وظایف اصلی آن شامل ذخیره سازی ایمن، یعنی اینکه داده های حیاتی با استفاده از مکانیزم های هش گذاری، به بلاک ها تبدیل و ذخیره می شوند. مورد بعدی قراردادهای هوشمند (Smart Contracts) برای اعتبارسنجی داده ها و اجرای خودکار فرآیندهای ذخیره سازی و بازبایی استفاده می شوند. مورد آخر هم مکانیزم اجماع است که تمامی داده ها قبل

### ۲-۳ مدل ریاضی و الگوریتم های پیشنهادی

در ادامه ساختار کلی روش پیشنهادی در شکل ۲ آورده شده است و ادامه هر قسمت و ارتباط بین اجزا با جزئیات بررسی شده است.

در ادامه ساختار فرمول‌های مربوط به LSTM و نحوه استفاده از آن‌ها در مسئله بهینه‌سازی ذخیره‌سازی داده‌ها در محیط لبه تشریح می‌شود:

یک سلول LSTM از سه گیت (gate) اصلی، گیت فراموشی (Forget Gate)، گیت ورودی (Input Gate) و گیت خروجی (Output Gate) تشکیل می‌شود. فرمول‌های هر بخش بصورت زیر تعریف می‌شود.

الف) گیت فراموشی ( $f_t$ ): تصمیم می‌گیرد چه اطلاعاتی از حافظه طولانی مدت دور ریخته شود.

$$f = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (1)$$

- $W_f$ : وزن‌های گیت فراموشی
- $h_{t-1}$ : حالت پنهان در زمان  $t-1$
- $x_t$ : ورودی فعلی
- $b_f$ : بایاس گیت فراموشی
- $\sigma$ : تابع سیگموئید (بین ۰ و ۱)

ب) گیت ورودی ( $i_t$ ): تصمیم می‌گیرد چه اطلاعات جدیدی ذخیره شود.

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (2)$$

این فرمول‌ها داده‌های ترافیکی را تحلیل کرده و مقادیر پیش‌بینی‌شده‌ای برای مدیریت بهتر ذخیره سازی ارائه می‌دهند.

$$\tilde{C}_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (3)$$

ج) به‌روزرسانی حالت حافظه:

$$C_t = f \cdot C_{t-1} + i \cdot \tilde{C}_t \quad (3)$$

د) گیت خروجی ( $o_t$ ):

تصمیم می‌گیرد چه اطلاعاتی به خروجی ارسال شود.

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (4)$$

$$h_t = o_t \cdot \tanh(C_t) \quad (5)$$

۳. تطبیق با مسئله ذخیره‌سازی:

در مسئله ما:

۱. ورودی ( $x_t$ ):



شکل ۲-فلوچارت روش پیشنهادی

۱-پیش‌بینی داده‌های ترافیکی

برای پیش‌بینی داده‌های ترافیکی مدل‌های یادگیری عمیق LSTM بصورت زیر پیشنهاد شده است.

۱. پیش‌بینی محبوبیت داده‌ها: از مدل LSTM برای پیش‌بینی محبوبیت آینده داده‌ها بر اساس تاریخچه درخواست‌ها استفاده می‌شود.

۲. بهینه‌سازی تخصیص ذخیره‌سازی: از خروجی LSTM برای تعیین داده‌های پرترفدار و تخصیص آن‌ها به خدمت دهنده‌های لبه استفاده می‌شود.

۳. انتخاب خدمت دهنده‌های بهینه با در نظر گرفتن تأخیر انتقال و ظرفیت خدمت دهنده‌ها، دو خدمت دهنده بهینه برای هر داده انتخاب می‌شوند.

- تاریخچه درخواست‌های داده‌ها ( $QU_{j,i}$ ) در ۱۰ گام زمانی قبلی

- به صورت ماتریس با ابعاد (۱، ۱۰) برای هر داده

۲. پیش‌بینی ( $\hat{h}_t$ ):

- محبوبیت پیش‌بینی شده برای داده در گام زمانی بعدی

- استفاده برای رتبه‌بندی داده‌ها

۳. حالت پنهان ( $h_t$ ):

- الگوهای یادگرفته شده از رفتار درخواستهای کاربران که شامل ۲ لایه پنهان ( لایه پنهان اول با ۱۲۸ نورون و لایه پنهان دوم با ۶۴ نورون) است.

۴. محاسبات پیش‌بینی محبوبیت:

برای هر داده  $d_i$ :

$$QU^t + 1 = LSTM(QU^t - 9, QU^t - 8, \dots, QU^t) \quad (6)$$

۵. تابع بهینه‌سازی:

اعتبارسنجی داده‌ها با قراردادهای هوشمند :

$$\text{Store in Block} \rightarrow \text{IF valid(data) : SmartContract} \quad (10)$$

پارامترهای فنی زنجیره بلوکی به کار رفته در مدل پیشنهادی به شرح زیر می باشد:

۱. الگوریتم درهم‌سازی (Hash Algorithm): از تابع درهم‌سازی SHA-256 استفاده شده است تا امنیت و یکپارچگی داده‌ها تضمین شود.

۲. مکانیزم اجماع (Consensus Mechanism): از Proof of Authority (PoA) استفاده شده تا مصرف منابع کاهش یابد و سرعت تراکنش‌ها افزایش یابد.

۳. نانس (Nonce): مقدار نانس به صورت تصادفی تولید و در هر بلوک ذخیره می‌شود تا از حملات تکرار جلوگیری شود.

۴. مهر زمانی (Timestamp): هر بلوک دارای یک مهر زمانی دقیق (با دقت نانو ثانیه) است تا ترتیب بلوک‌ها به درستی حفظ شود.

۵. سایز بلوک (Block Size): سایز هر بلوک ۲ مگابایت در نظر گرفته شده تا تعادل بین کارایی و امنیت برقرار شود.

۶. بازه زمانی ایجاد بلوک (Block Time): هر بلوک به طور متوسط هر ۵ ثانیه ایجاد می‌شود.

پس از پیش‌بینی محبوبیت، تابع هدف به این شکل خواهد بود:

$$\text{Minimize } Tt = i = 1 \sum_{m=j=1}^n T_{ij} \cdot QU^j \cdot x_{ij} \quad (6)$$

با قیود:

$$\sum m_{xij} \leq Q_j \quad \forall j \quad (7)$$

$$\sum n_{xij} = 2 \quad \forall i \quad (8)$$

۲- ذخیره‌سازی امن با زنجیره بلوکی

درهم‌سازی گذاری داده‌ها: هر داده  $d_i$  به یک درهم‌سازی

$H(d_i)$  تبدیل شده و در زنجیره بلوکی ذخیره می‌شود.

$$S = H(d_i) \quad (9)$$

۷. قرارداد هوشمند (Smart Contract): پیشنهاد می‌شود

قراردادهای هوشمند با زبان Solidity نوشته شود و روی ماشین مجازی اتریوم (EVM) اجرا شوند.

۸. ساختار داده‌ای بلوک (Block Structure): هر بلوک شامل،

شماره بلوک (Block Index)، درهم‌سازی بلوک قبلی

(Previous Hash)، درهم‌سازی تراکنش‌ها (Merkle Root)، مهر

زمانی (Timestamp)، نانس (Nonce)، لیست تراکنش‌ها

(Transactions) می باشد.

۹. مدیریت کلیدها (Key Management): از الگوریتم ECDSA

(منحنی بیضوی) برای امضای دیجیتال و احراز هویت استفاده می‌شود.

۱۰. ذخیره‌سازی داده‌ها (Data Storage): داده‌ها به صورت off-chain

در پایگاه داده توزیع شده (مانند IPFS) ذخیره شده و تنها

درهم‌سازی آن‌ها در زنجیره بلوکی ثبت می‌شود.

۳- هماهنگی بین لایه‌ها

الگوریتم زیر برای هماهنگی ایمن و سریع بین لایه‌ها طراحی شده است:

۱. لایه وسایل نقلیه پرس و جویها و داده‌ها را گردآوری و به

لایه لبه ارسال می‌کند.

۲. لایه لبه داده‌ها را تحلیل کرده و بر اساس الگوهای

پیش‌بینی شده پرس و جویها را پاسخ و داده‌های مورد نیاز به

لایه زنجیره بلوکی ارسال می‌کند.

۳. لایه زنجیره بلوکی داده‌ها را اعتبارسنجی و ذخیره می‌کند و

در صورت نیاز آن‌ها را بازیابی می‌نماید.

۴- فرمول محاسبه تأخیر

برای ارزیابی کارایی سیستم پیشنهادی، تأخیر کل به صورت زیر محاسبه شده است.

تأخیر انتقال داده ها

$$transfer^T = \sigma \cdot s \cdot h \quad (11)$$

$$process^T = \frac{task^C}{server^C} \quad (12)$$

تأخیر کل :

$$total^T = process^T + transfer^T \quad (13)$$

ورودی شامل داده‌های تاریخی از وسایل نقلیه است. مدل LSTM با استفاده از گیت‌های حافظه، الگوهای پیچیده ترافیکی را تحلیل و محبوبیت داده‌ها را پیش‌بینی می‌کند. جزئیات الگوریتم در الگوریتم ۱ ارائه شده است.

جایی که  $h$  تعداد پرش بین گره‌ها،  $s$  اندازه داده، و  $\sigma$  ضریب تأخیر انتقال است. تأخیر پردازش:

۱- الگوریتم پیش‌بینی محبوبیت داده‌ها با یادگیری عمیق:

برای پیش‌بینی محبوبیت داده‌ها، از مدل LSTM استفاده شده است. این الگوریتم مراحل زیر را دنبال می‌کند:

```
Algorithm: Data Popularity Prediction
Input: Historical data X = {x1, x2, ..., xt}
Output: Predicted data popularity Y = {y1, y2, ..., yt+1}

1. Initialize LSTM model with parameters (Wf, Wi, Wo, Wc, bf, bi, bo, bc)
2. For each time step t:
  a. Compute forget gate: ft = sigmoid(Wf * [ht-1, xt] + bf)
  b. Compute input gate: it = sigmoid(Wi * [ht-1, xt] + bi)
  c. Compute candidate memory: Ct = tanh(Wc * [ht-1, xt] + bc)
  d. Update cell state: Ct = ft * Ct-1 + it * Ct
  e. Compute output gate: ot = sigmoid(Wo * [ht-1, xt] + bo)
  f. Update hidden state: ht = ot * tanh(Ct)
3. Predict popularity: Y = ht
```

این شکل است که انتقال داده ها بین لایه ها با استفاده از پروتکل های ارتباطی ایمن و سریع انجام می شود. جزئیات عملیاتی آن این چنین است که لایه وسایل نقلیه داده ها را گردآوری کرده و به لایه لبه منتقل می کند. لایه لبه داده ها را تحلیل کرده و تصمیمات مربوط به ذخیره سازی را می گیرد. لایه زنجیره بلوکی داده های حساس را به صورت ایمن ذخیره و مدیریت می کند. هرگونه بازیابی یا به روزرسانی داده ها به صورت خودکار بین لایه ها هماهنگ می شود.

```
Algorithm: Layer Communication Protocol
Input: Data from Vehicle Layer, Prediction from Edge Layer
Output: Secure and coordinated data flow

1. Vehicle Layer:
  a. Collect environmental and operational data D.
  b. Send data D to Edge Layer.

2. Edge Layer:
  a. Preprocess data D.
  b. Predict data patterns using LSTM model.
  c. Send critical data and predictions to Blockchain Layer.

3. Blockchain Layer:
  a. Validate data with consensus mechanism.
  b. Store validated data securely.
  c. Respond to queries with stored data.

4. Ensure secure data flow between layers using encryption.
```

الگوریتم ۳- هماهنگی بین لایه ها

در ادامه الگوریتم اجزای کل برنامه را در الگوریتم ۴ مشاهده می نمایید.

```
Algorithm: Proposed System Workflow
Input: Data collected from vehicles
Output: Efficient storage, prediction, and retrieval of data

1. Data Collection:
  a. Vehicle Layer collects data D = {d1, d2, ..., dn}.
  b. Send data D to Edge Layer.

2. Data Analysis:
  a. Edge Layer preprocesses data.
  b. Run LSTM model to predict traffic patterns and data popularity.
  c. Identify critical data for caching.

3. Secure Storage:
  a. Compute hash for critical data: H(D).
  b. Validate hash using SmartContract.
  c. Store data securely in Blockchain Layer.

4. Data Retrieval:
  a. On user query, search Blockchain Layer for relevant data.
  b. Return data if available; else fetch from external sources.
```

۴- الگوریتم کلی عملکرد سیستم پیشنهادی

الگوریتم ۱- پیش بینی محبوبیت داده ها با یادگیری عمیق

جزئیات عملیاتی الگوریتم به این صورت است که داده های خام پیش پردازش می شوند (حذف داده های ناقص یا نویزدار). مدل های یادگیری عمیق داده ها را تحلیل کرده و خروجی شامل پیش بینی های ترافیکی، تقاضای ذخیره سازی، و شناسایی داده های حساس است. خروجی تحلیل برای تصمیم گیری های بعدی به لایه زنجیره بلوکی ارسال می شود.

۲- الگوریتم ذخیره سازی امن داده با زنجیره بلوکی:

برای مدیریت ایمن داده ها، از زیرساخت زنجیره بلوکی و قراردادهای هوشمند استفاده شده است. الگوریتم پیشنهادی در الگوریتم ۲ تشریح شده است. شرح این الگوریتم به این شکل است که داده های حساس شناسایی شده در مرحله قبل، به لایه زنجیره بلوکی منتقل می شوند تا به صورت ایمن ذخیره شوند. جزئیات عملیاتی آن این چنین است که برای هر داده، یک درهم سازی منحصر به فرد محاسبه می شود. قرارداد هوشمند صحت داده را بررسی می کند. اگر داده معتبر باشد، درهم سازی در یک بلاک ذخیره می شود و مکانیزم اجماع نیز تضمین می کند که داده ها بدون هیچ گونه تغییر در زنجیره بلوکی ذخیره شوند.

```
Algorithm: Secure Data Storage with Blockchain
Input: Data D = {d1, d2, ..., dn}, Consensus Mechanism
Output: Securely stored data hashes in blockchain
```

```
1. For each data item di in D:
  a. Compute hash: Hi = Hash(di)
  b. Validate data with SmartContract:
     If SmartContract.validate(Hi) == True:
       Add Hi to blockchain block
     Else:
       Reject data di
2. Broadcast the block to network nodes for consensus
3. Once consensus is achieved, store block in blockchain
```

الگوریتم ۲- ذخیره سازی

۳- الگوریتم هماهنگی بین لایه ها

برای ارتباط ایمن و سریع بین لایه ها، پروتکل هماهنگی بین لایه های وسایل نقلیه، لبه و زنجیره بلوکی طراحی شده است. این الگوریتم در الگوریتم ۳ شرح داده شده است. شرح این الگوریتم به

- (۴) حداکثر تعداد هاپ بین خدمت دهندهها ( $h_{max}$ ): مقدار این پارامتر از ۱ تا ۱۴ هاپ تغییر کرد تا سناریوهای مختلف بررسی شوند ضریب تأخیر انتقال در دامنه همکاری ( $\sigma_1$ ): برابر با ۰,۱ تنظیم شد.
- (۵) ضریب تأخیر انتقال بین دامنه همکاری و ابر ( $\sigma_2$ ): برابر با ۲,۰ تعیین شد.
- (۶) ظرفیت محاسباتی خدمت دهندههای لبه ( $BS_j$ ): توان پردازشی هر خدمت دهنده لبه بین ۳۰ تا ۴۰ گیگاهرتز بود.
- (۷) بار کاری هر وظیفه: میزان پردازش مورد نیاز برای هر درخواست بین ۰,۵ تا ۱,۵ گیگاسایکل بود.
- معیارهای ارزیابی

عملکرد مدل پیشنهادی بر اساس معیارهای زیر ارزیابی شد:

- (۱) زمان تأخیر متوسط درخواستها: میانگین زمان مورد نیاز برای پردازش و پاسخگویی به هر درخواست.
- (۲) کاهش تأخیر انتقال داده: میزان کاهش تأخیر نسبت به مدل‌های موجود شامل Random Caching (RC) و Partitioned Group Caching Strategy (CCS-AGP).
- (۳) پایداری در برابر افزایش بار شبکه: توانایی مدل در حفظ عملکرد مطلوب با افزایش تعداد گره‌ها یا حجم درخواستها.
- (۴) مصرف منابع: میزان مصرف ظرفیت ذخیره‌سازی و پردازش خدمت دهندههای لبه.

فرآیند شبیه‌سازی

- (۱) توزیع داده‌ها: داده‌ها بر اساس توزیع Zipf بین خدمت دهندههای لبه توزیع شدند. داده‌های پرتکرار برای پیش‌کش انتخاب شدند.
- (۲) انتخاب گره‌های کش: از یادگیری عمیق برای انتخاب گره‌های بهینه برای ذخیره داده‌ها استفاده شد.
- (۳) شبیه‌سازی درخواستها: ۱۰۰,۰۰۰ درخواست در دامنه همکاری تولید شد و زمان تأخیر برای هر درخواست در شرایط مختلف اندازه‌گیری گردید.
- (۴) مقایسه عملکرد: مدل پیشنهادی با سه مدل دیگر، یعنی Tabu Search، RC و CCS-AGP، از لحاظ معیارهای تأخیر و کارایی مقایسه شد.
- هدف این آزمایش بررسی تأثیر ظرفیت کش خدمت دهندههای لبه بر تأخیر انتقال داده‌ها در سیستم پیشنهادی و مقایسه عملکرد آن

#### • نقاط قوت سیستم پیشنهادی

- (۱) کاهش تأخیر: استفاده از یادگیری عمیق برای پیش‌بینی داده‌ها، زمان موردنیاز برای تحلیل و پردازش داده‌ها را کاهش داده و باعث بهینه‌سازی ذخیره‌سازی و پاسخ به پرس و جوها شده است.
- (۲) امنیت بالا: ذخیره‌سازی داده‌ها در زنجیره بلوکی و استفاده از قراردادهای هوشمند، یکپارچگی و امنیت داده‌ها را تضمین کرده است.
- (۳) هماهنگی و مقیاس‌پذیری: سیستم پیشنهادی با استفاده از پروتکل‌های ایمن و مقیاس‌پذیر، قابلیت گسترش در محیط‌های پویا و پیچیده را دارد.

مدل پیشنهادی برای بهبود پرس و پاسخ و مدیریت داده‌های گردآوری‌شده از وسایل نقلیه و ذخیره‌سازی ایمن آن‌ها، از ترکیب فناوری‌های یادگیری عمیق و زنجیره بلوکی در یک معماری سه‌لایه استفاده می‌کند. این سیستم به گونه‌ای طراحی شده است که تأخیر پرس و پاسخ‌ها را به حداقل برساند، امنیت داده‌ها را تضمین کند و مقیاس‌پذیری را در محیط‌های پیچیده ارائه دهد.

#### ۴- ارزیابی

برای ارزیابی مدل پیشنهادی، آزمایش‌ها در یک محیط شبیه‌سازی دقیق طراحی و اجرا شدند. این بخش تنظیمات شبیه‌سازی، معیارهای ارزیابی و نتایج به‌دست‌آمده را به تفصیل توضیح می‌دهد.

#### تنظیمات آزمایش

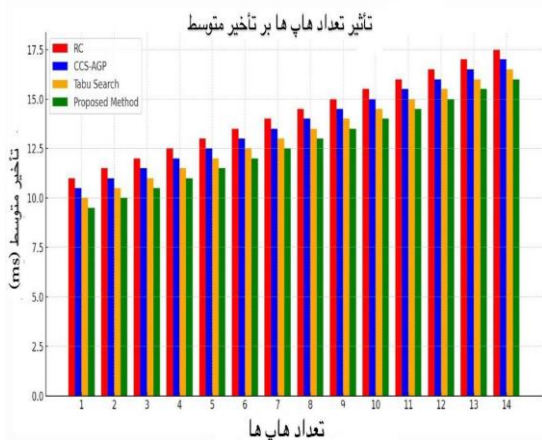
آزمایش‌ها در یک محیط شبیه‌سازی انجام شدند که با استفاده از پایتون ۳,۶ و کتابخانه‌های یادگیری عمیق و مدیریت زنجیره بلوکی پیاده‌سازی شده بود. پارامترهای اصلی شبیه‌سازی عبارتند از:

- (۱) تعداد خدمت دهندههای لبه ( $N$ ): تعداد خدمت دهندههای لبه در هر دامنه همکاری بین ۵ تا ۳۰ خدمت دهنده تنظیم شده است.
- (۲) تعداد کل درخواستها ( $QU$ ): در هر شبیه‌سازی، ۱۰۰,۰۰۰ درخواست توسط کاربران ارسال شد.
- (۳) ظرفیت کش خدمت دهندههای لبه ( $C$ ): ظرفیت کش هر خدمت دهنده لبه بین ۲ تا ۲۰ واحد تعریف شد.

این تأخیر به دلیل عدم تمرکز روی تحلیل داده های محبوب و مدیریت بهینه ذخیره سازی است.

با افزایش ظرفیت کش خدمت دهندهای لبه، تأخیر انتقال در همه روش ها کاهش یافته است. دلیل این موضوع، توانایی ذخیره داده های بیشتری در خدمت دهندهای نزدیک به کاربر است که نیاز به انتقال داده های بیشتر از ابر را کاهش می دهد. روش پیشنهادی (Proposed Method) به دلیل پیش بینی دقیق تر داده های محبوب و مدیریت بهینه ذخیره سازی، در تمامی ظرفیت ها بهترین عملکرد را از نظر کاهش تأخیر نشان داده است. در مقایسه با روش Tabu Search، روش پیشنهادی تأخیر را به طور متوسط تا ۱۰٪ بیشتر کاهش داده است.

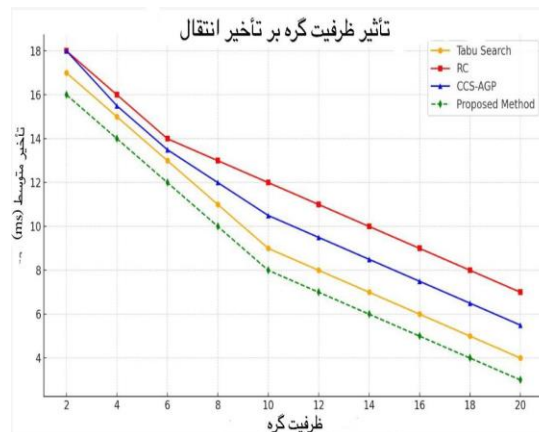
نتایج نشان می دهد که روش پیشنهادی با ترکیب یادگیری عمیق و زنجیره بلوکی، راه حلی کارآمد برای کاهش تأخیر انتقال داده ها و بهبود عملکرد سیستم در محیط های توزیع شده ارائه می دهد. این روش می تواند به عنوان یک مدل بهینه برای مدیریت داده ها در شبکه های پیچیده مورد استفاده قرار گیرد. آزمایش بعد برای بررسی تأثیر تعداد پرس های حداکثری بین گره ها (hmax) بر تأخیر پرس و جوی داده ها انجام شده است. نتایج به دست آمده، عملکرد روش پیشنهادی (Proposed Method) را در مقایسه با سه روش دیگر (Random Caching)، RC، CCS-AGP و الگوریتم جست و جوی نشان می دهد.



شکل ۴- تأثیر تعداد نودها بر تأخیر متوسط

روش پیشنهادی در تمامی مقادیر  $h_{max}$  کمترین تأخیر را نسبت به سایر روش ها نشان داده است. کاهش تأخیر به دلیل استفاده از یادگیری عمیق برای پیش بینی دقیق تر داده ها و

با سه روش موجود، یعنی Tabu Search، CCS-AGP و RC (Random Caching) است. این مقایسه (شکل ۳) نشان می دهد که روش پیشنهادی چگونه با استفاده از یادگیری عمیق و زنجیره بلوکی می تواند تأخیر انتقال را کاهش دهد و بهره وری سیستم را بهبود بخشد.



شکل ۳- تأثیر ظرفیت گره بر تأخیر انتقال

روش پیشنهادی عملکرد بهتری نسبت به سایر روش ها در تمام نقاط ظرفیت کش نشان داده است.

کاهش تأخیر در این روش به دلیل ترکیب پیش بینی دقیق داده های محبوب توسط یادگیری عمیق و ذخیره سازی امن و بهینه داده ها در زنجیره بلوکی است. عملکرد بهتر این روش نشان می دهد که استفاده از مکانیزم های پیشرفته مدیریت داده ها باعث کاهش مراجعه های غیرضروری به ابر و انتقال های تکراری شده است.

الگوریتم جست و جوی تابو که در یکی از مقاله های مورد مقایسه به عنوان رویکرد اصلی معرفی شده است، تأخیر کمتری نسبت به CCS-AGP و RC دارد اما همچنان در تمامی نقاط ظرفیت کش تأخیر بیشتری نسبت به روش پیشنهادی نشان می دهد. نقطه ضعف این روش در عدم استفاده از پیش بینی های یادگیری عمیق برای مدیریت بهتر داده ها است.

روش CCS-AGP در مقایسه با RC بهبود قابل توجهی در کاهش تأخیر نشان می دهد، اما عدم توجه به تحلیل دقیق محبوبیت داده ها باعث عملکرد ضعیف تر آن نسبت به روش پیشنهادی و Tabu Search شده است.

RC (Random Caching) این روش به دلیل ذخیره سازی تصادفی داده ها، بیشترین تأخیر را در تمام نقاط ظرفیت کش نشان می دهد.

• تأثیر تعداد پرش‌ها (hmax):

با افزایش تعداد پرش‌ها، تأخیر در تمامی روش‌ها افزایش یافته است. دلیل این افزایش، فاصله بیشتر بین گره‌ها و نیاز به انتقال داده در مسافت‌های طولانی‌تر است. روش پیشنهادی با حفظ ذخیره‌سازی بهینه و پیش‌بینی دقیق، کمترین تأخیر را در تمامی مقادیر  $h_{max}$  نشان داده است. روش پیشنهادی در مقایسه با Tabu Search، تأخیر را به‌طور متوسط ۵٪ تا ۱۰٪ کاهش داده است. در مقایسه با CCS-AGP و RC، این کاهش به ترتیب ۱۵٪ تا ۲۰٪ و ۲۵٪ تا ۳۰٪ بوده است.

می‌دهد که روش پیشنهادی به دلیل استفاده از یادگیری عمیق برای پیش‌بینی داده‌ها و زنجیره بلوکی برای ذخیره‌سازی امن، در تمامی سناریوها کمترین تأخیر را با وجود حفظ امنیت ارائه می‌دهد. این روش نه تنها در مقایسه با روش Tabu Search عملکرد بهتری دارد، بلکه نسبت به سایر روش‌های موجود نیز بهبود قابل توجهی را در کاهش تأخیر نشان می‌دهد.

(Proposed Method) در مقایسه با سایر روش‌ها چگونه عمل می‌کند.

ذخیره‌سازی بهینه داده‌ها با استفاده از زنجیره بلوکی است. با افزایش تعداد پرش‌ها (hmax)، تأخیر به تدریج افزایش یافته اما همچنان از سایر روش‌ها بهتر عمل می‌کند.

CCS-AGP


این روش در مقایسه با RC عملکرد بهتری دارد اما همچنان تأخیر بیشتری نسبت به روش پیشنهادی و Tabu Search دارد. دلیل این امر عدم استفاده بهینه از پیش‌بینی و ذخیره‌سازی دقیق داده‌ها است.

RC (Random Caching)

بیشترین تأخیر در تمامی مقادیر  $h_{max}$  مربوط به این روش است. این تأخیر به دلیل ذخیره‌سازی تصادفی داده‌ها و عدم استفاده از مکانیزم‌های بهینه‌سازی است.

کاهش تأخیر مؤثر: استفاده از پیش‌بینی داده‌ها و ذخیره‌سازی هوشمندانه، تأثیر چشم‌گیری در کاهش تأخیر داشته است. انعطاف‌پذیری در برابر افزایش تعداد پرش‌ها: روش پیشنهادی حتی در مقادیر بالای  $h_{max}$  نیز عملکرد پایدار و بهینه‌ای دارد.

مقیاس‌پذیری: این روش می‌تواند در شبکه‌های بزرگ‌تر و پیچیده‌تر نیز با حفظ کارایی به کار گرفته شود. این آزمایش نشان هدف این آزمایش بررسی تأثیر تعداد گره‌ها (Nodes) در شبکه بر تأخیر انتقال داده‌ها است. این تحلیل نشان می‌دهد که با افزایش تعداد گره‌ها، تأخیر چگونه تغییر می‌کند و روش پیشنهادی

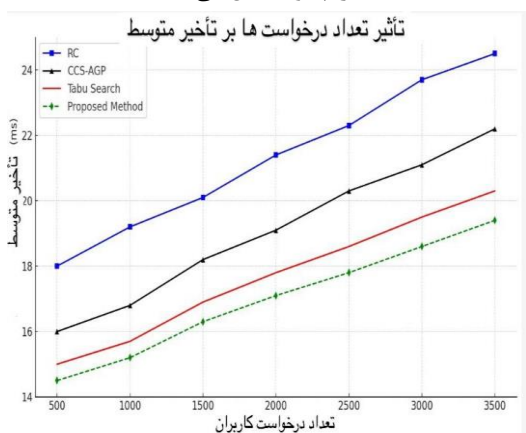


شکل ۵- تأثیر تعداد گره بر تأخیر متوسط

روش پیشنهادی در تمامی مقادیر تعداد گره‌ها، کمترین تأخیر انتقال را نشان داده است. این کاهش تأخیر به دلیل مدیریت بهینه

داده‌ها با یادگیری عمیق و استفاده از زنجیره بلوکی برای ذخیره‌سازی توزیع‌شده و امن است. حتی با افزایش تعداد گره‌ها، روش پیشنهادی عملکرد پایداری دارد و تأخیر را به‌طور میانگین

روش (Random Caching) RC بدترین عملکرد را دارد، زیرا هیچ مکانیزم بهینه سازی برای ذخیره سازی داده ها ارائه نمی دهد. روش CCS-AGP به دلیل مکانیزم محدود ذخیره سازی، تأخیر بیشتری نسبت به Tabu Search و روش پیشنهادی دارد. این آزمایش نشان می دهد که روش پیشنهادی (Proposed Method) در تمامی مقادیر تعداد گره ها عملکرد بهتری نسبت به سایر روش ها دارد. این روش نه تنها تأخیر انتقال داده ها را کاهش می دهد، بلکه با افزایش تعداد گره ها، کارایی خود را حفظ می کند. این نتایج نشان می دهد که روش پیشنهادی شما می تواند به عنوان یک راه حل کارآمد و مقیاس پذیر در شبکه های بزرگ و پیچیده مورد استفاده قرار گیرد. این آزمایش برای بررسی تأثیر تعداد محتواها (Contents) بر تأخیر انتقال داده ها در شبکه انجام شده است. هدف این است که نشان داده شود چگونه افزایش تعداد محتواها بر کارایی سیستم و تأخیر انتقال داده ها تأثیر می گذارد و روش پیشنهادی (Proposed Method) در مقایسه با روش های دیگر چگونه عمل می کند.



روش CCS-AGP تأخیر کمتری نسبت به RC دارد اما همچنان در مقایسه با Tabu Search و روش پیشنهادی، تأخیر بیشتری دارد. عملکرد این روش به دلیل ذخیره سازی غیربهینه داده ها محدود شده است. روش Random Caching یا RC در تمامی مقادیر تعداد محتواها، بیشترین تأخیر را نشان می دهد. دلیل این تأخیر، ذخیره سازی تصادفی داده ها و عدم استفاده از الگوریتم های بهینه سازی است.

۰.۵ میلی ثانیه کمتر از Tabu Search کاهش می دهد. روش الگوریتم جست و جوی تابو عملکرد نسبتاً خوبی دارد اما تأخیر بیشتری نسبت به روش پیشنهادی دارد. کاهش تأخیر این روش با افزایش تعداد گره ها، به دلیل توزیع بهتر داده ها در گره های اضافی است.

#### CCS-AGP

این روش تأخیر کمتری نسبت به RC دارد اما همچنان در رتبه سوم قرار می گیرد. عدم استفاده از پیش بینی های یادگیری عمیق و ذخیره سازی بهینه داده ها باعث شده است که عملکرد آن نسبت به Tabu Search و روش پیشنهادی ضعیف تر باشد.

#### RC (Random Caching)

این روش بیشترین تأخیر را در تمامی تعداد گره ها نشان می دهد. دلیل این تأخیر ذخیره سازی تصادفی داده ها و عدم بهینه سازی مکان ذخیره داده ها در گره ها است.

#### • تأثیر تعداد گره ها

با افزایش تعداد گره ها از ۵ به ۳۰، تأخیر در تمامی روش ها کاهش یافته است. دلیل این کاهش، افزایش منابع توزیع شده برای ذخیره سازی و دسترسی سریع تر به داده ها است. روش پیشنهادی با استفاده از تحلیل دقیق داده ها و توزیع مناسب، به طور متوسط ۱۰٪ بهتر از Tabu Search و ۱۵٪ بهتر از CCS-AGP عمل کرده است. حتی در تعداد گره های بالاتر (۲۵ و ۳۰)، روش پیشنهادی همچنان برتری خود را حفظ کرده است.

#### مقایسه روش ها

#### شکل ۶- تعداد درخواست کاربران بر تأخیر متوسط

روش پیشنهادی در تمامی مقادیر تعداد محتواها، کمترین تأخیر انتقال را نشان داده است. این برتری به دلیل مدیریت بهینه داده ها با یادگیری عمیق و ذخیره سازی توزیع شده و کارآمد در زنجیره بلوکی است و با افزایش تعداد محتواها، تأخیر روش پیشنهادی به طور خطی افزایش یافته اما همچنان بهتر از سایر روش ها عمل کرده است. روش Tabu Search که عملکرد قابل قبولی دارد اما تأخیر بیشتری نسبت به روش پیشنهادی دارد و با افزایش تعداد محتواها، تأخیر به تدریج افزایش یافته است، اما به دلیل عدم پیش بینی دقیق داده های محبوب، بهینه ترین روش نیست.

تأثیر تعداد محتواها این گونه است با افزایش تعداد محتواها، تأخیر در تمامی روش‌ها به صورت خطی افزایش یافته است. دلیل این افزایش، نیاز به مدیریت و انتقال حجم بیشتری از داده‌ها در شبکه است. روش پیشنهادی در تمامی مقادیر تعداد محتواها، تأخیر را به طور میانگین ۵٪ تا ۱۰٪ کمتر از Tabu Search کاهش داده است. در مقایسه با-CCS AGP و RC، این کاهش به ترتیب ۱۵٪ تا ۲۰٪ و ۲۰٪ تا ۲۵٪ بوده است و این روش پیشنهادی کمترین تأخیر را دارد و برای مدیریت حجم بالای داده‌ها مناسب است. روش RC در مدیریت حجم داده‌های زیاد بسیار ناکارآمد است و عملکرد ضعیفی نشان داده است به علت‌هایی همچون ۱- کاهش تأخیر که استفاده از یادگیری عمیق و زنجیره بلوکی باعث شده تأخیر انتقال داده‌ها به حداقل برسد. ۲- مقیاس‌پذیری که روش پیشنهادی با افزایش تعداد محتواها، کارایی خود را حفظ کرده و عملکرد پایدار را ارائه داده است. ۳- مدیریت بهینه داده‌ها که پیش‌بینی داده‌های محبوب، ذخیره‌سازی هوشمندانه، دسترسی سریع‌تر به داده‌ها را تضمین کرده است.

این آزمایش نشان می‌دهد که روش پیشنهادی (Proposed Method) در تمامی مقادیر تعداد محتواها عملکرد بهتری نسبت به سایر روش‌ها دارد. این روش توانسته است با ترکیب یادگیری عمیق و زنجیره بلوکی، تأخیر انتقال داده‌ها را کاهش داده و مقیاس‌پذیری سیستم را بهبود بخشد. نتایج نشان می‌دهد که این روش برای مدیریت حجم بالای محتواها در شبکه‌های پیچیده و بزرگ مناسب است. در این مقاله، یک مدل ترکیبی مبتنی بر یادگیری عمیق و زنجیره بلوکی برای مدیریت داده‌ها در شبکه‌های وسایل نقلیه ارائه شد. هدف اصلی این مدل کاهش تأخیر، بهبود کارایی و تضمین امنیت داده‌ها بود. نتایج آزمایش‌ها نشان داد که مدل پیشنهادی توانسته است در مقایسه با روش‌های موجود مانند Tabu Search, CCS-AGP و RC عملکرد بهتری داشته باشد.

بررسی تاثیر استفاده از زنجیره بلوکی بر تاخیر افزودن لایه‌های امنیتی مانند زنجیره بلوکی، به دلیل ماهیت توزیع‌شده و مکانیزم‌های اجماع، می‌تواند بر عملکرد (مانند تأخیر) سیستم تأثیر بگذارد و زمان را بالاتر ببرد. با این حال، مدل پیشنهادی با یک معماری یکپارچه و بهینه‌شده طراحی شده است تا این چالش را به حداقل برساند. در ادامه به صورت ساختاریافته به این موضوع می‌پردازیم:

۱. بهینه‌سازی معماری برای کاهش سربار (overhead) زنجیره بلوکی - در مدل پیشنهادی، از زنجیره بلوکی نه برای تمام داده‌ها، بلکه تنها برای ذخیره‌سازی داده‌های حیاتی و حساس (مانند درهم‌سازی داده‌ها، کلیدهای احراز هویت، و لاگ‌های دسترسی) استفاده شده است. - حجم عمده داده‌ها (مانند محل کش) در لایه لبه و با استفاده از یادگیری عمیق مدیریت می‌شود که تأخیر بسیار پایینی دارد. - این رویکرد ترکیبی باعث می‌شود سربار مربوط به زنجیره بلوکی تنها بر بخش کوچکی از عملیات اعمال شود.

۲. استفاده از مکانیزم اجماع سبک‌وزن (Lightweight Consensus) - به جای مکانیزم‌های پرمصرفی مانند Proof of Work (PoW)، از یک مکانیزم اجماع امن و کارا مانند Proof of Authority (PoA) استفاده شده است. - این مکانیزم‌ها برای محیط‌های لبه (Edge) و وسایل نقلیه که منابع محدودی دارند، بهینه‌سازی شده‌اند و تأخیر و مصرف منابع را به شدت کاهش می‌دهند.

۳. جبران سربار زنجیره بلوکی با بهینه‌سازی یادگیری عمیق - بخش اصلی بهینه‌سازی عملکرد (کاهش تأخیر) در مدل پیشنهادی، توسط پیش‌بینی‌های بسیار دقیق یادگیری عمیق (مدل LSTM) حاصل می‌شود.

- با پیش‌بینی دقیق الگوهای دسترسی به داده و کش کردن هوشمند، تعداد دسترسی‌های غیرضروری به داده‌های امن‌شده توسط زنجیره بلوکی به حداقل می‌رسد. این امر سربار کلی سیستم را جبران می‌کند.

۴. نتایج کمی: در ادامه با شبیه‌سازی و مقایسه دو سناریو با زنجیره بلوکی و بدون زنجیره بلوکی نشان داده ایم کارایی مدل پیشنهادی در مجموع بهتر است روشهای سنتی و قبلی هستند که به طور جداگانه امنیت و عملکرد را در سیستم اعمال می‌نمایند. در ادامه به بررسی سناریویی می‌پردازیم که مدل پیشنهادی با فعال‌سازی زنجیره بلوکی و بدون فعال‌سازی زنجیره بلوکی را مقایسه می‌کند.

جدول ۱: مقایسه کمی الگوریتم‌های مختلف از نظر تأخیر و امنیت

معیار / الگوریتم	RC	CCS-AGP	Tabu Search	پیشنهادی (بدون زنجیره بلوکی)	پیشنهادی (با زنجیره بلوکی)
تأخیر متوسط (ms)	۴۵۰	۳۸۰	۳۲۰	۲۵۰	۲۷۰
امنیت داده	پایین	متوسط	متوسط	پایین	بسیار بالا
مصرف منابع	پایین	متوسط	بالا	متوسط	متوسط-بالا
مقیاس پذیری	متوسط	خوب	خوب	عالی	خوب
انکارناپذیری (Non-Rep)	خیر	خیر	خیر	خیر	بله
تمرکززدایی	خیر	خیر	خیر	خیر	بله

این جدول، معیارهای کلیدی ارزیابی شامل تأخیر، امنیت، مصرف منابع، مقیاس پذیری، انکارناپذیری و تمرکززدایی را برای پنج الگوریتم مورد بررسی مقایسه می‌کند. ردیف اول این جدول به وضوح نشان می‌دهد که الگوریتم پیشنهادی حتی با وجود سربار زنجیره بلوکی، از نظر تأخیر عملکرد بهتری نسبت به تمام روش‌های پایه (مانند Tabu Search, RC, CCS-AGP) دارد. هزینه تأخیر اضافی ناشی از زنجیره بلوکی تنها ۸٪ (از ۲۵۰ به ۲۷۰ میلی ثانیه) است. این هزینه بسیار ناچیزی برای دستیابی به امنیت و غیرمتمرکزسازی کامل است.

روش پیشنهادی (بدون زنجیره بلوکی): این حالت نشان‌دهنده قدرت خالص مدل پیش‌بینی یادگیری عمیق (LSTM) در بهینه‌سازی کش است. همانطور که داده‌ها نشان می‌دهد، این مدل کمترین تأخیر و بهترین مقیاس‌پذیری را دارد. اما نقطه ضعف آن، نادیده گرفتن ملاحظات امنیتی است.

### ۵- نتیجه‌گیری

در این پژوهش، یک چارچوب بهینه‌سازی نوین مبتنی بر ترکیب یادگیری عمیق و فناوری زنجیره بلوکی برای ارتقاء کارایی و امنیت پرس‌وجوی داده‌ها در شبکه‌های وسایل نقلیه ارائه گردید. مدل پیشنهادی با بهره‌گیری از LSTM قادر به پیش‌بینی دقیق الگوهای تقاضای داده و شناسایی محتوای حیاتی بوده و در ادامه، با استفاده از ساختار غیرمتمرکز زنجیره بلوکی و قراردادهای هوشمند، امکان ذخیره‌سازی ایمن، بازبازی مطمئن و مدیریت توزیع‌شده داده‌ها را فراهم آورده است. نتایج حاصل از شبیه‌سازی‌های گسترده در محیط‌های متنوع نشان داد که مدل پیشنهادی به طور معناداری موجب کاهش تأخیر در پاسخگویی به درخواست‌ها (در حدود ۱۰٪ تا ۳۰٪ نسبت به روش‌های مرسوم نظیر Tabu Search، CCS-AGP و RC) شده و در عین حال، سطح بالایی از یکپارچگی، امنیت و مقیاس‌پذیری را حفظ کرده است. همچنین، پایداری عملکرد مدل در شرایط بار بالا و تنوع در توپولوژی شبکه، نشان‌دهنده قابلیت تعمیم‌پذیری آن در محیط‌های واقعی و پیچیده شبکه‌های حمل‌ونقل هوشمند می‌باشد.

روش پیشنهادی (با زنجیره بلوکی) - مدل نهایی: این ستون، مدل کامل پیشنهادی این مقاله را نشان می‌دهد. ترکیب هوشمندانه یادگیری عمیق و زنجیره بلوکی باعث شده است تا:

- \* تأخیر تنها ۸٪ (۲۰ میلی ثانیه) نسبت به حالت بدون زنجیره بلوکی افزایش یابد، اما همچنان از تمام روش‌های پایه بهتر است.
- \* امنیت به سطح «بسیار بالا» ارتقا یابد که ناشی از تغییرناپذیری، شفافیت و cryptographic hashing در زنجیره بلوکی است.
- \* ویژگی‌های کلیدی انکارناپذیری (امضاء دیجیتال تراکنش‌ها) و تمرکززدایی (حذف نقطه شکست مرکزی) به طور کامل اضافه شوند.
- \* مصرف منابع نسبت به Tabu Search کمتر و در حد «متوسط-بالا» باشد.

این مدل می‌تواند مبنایی برای توسعه سامانه‌های پیشرفته در حوزه اینترنت اشیا، شهرهای هوشمند و سیستم‌های حمل‌ونقل نسل آینده قرار گیرد. در مسیر توسعه‌های آتی، پیشنهاد می‌گردد این چارچوب با زیرساخت‌های ارتباطی نسل ششم (G6)، الگوریتم‌های اجماع سبک و مدل‌های هوشمند تصمیم‌گیری ترکیب شده تا بهینه‌سازی همزمان کارایی، امنیت و بهره‌وری انرژی در شبکه‌های توزیع‌شده تحقق یابد.

این جدول به وضوح نشان می‌دهد که مدل پیشنهادی این مقاله، یک پیشرفت کیفی محسوب می‌شود. بر خلاف روش‌های سنتی که همواره یک مبادله (Trade-off) آشکار بین امنیت و عملکرد وجود دارد،

- IEEE publication Computer Networks. Vol. 274.
- [11] Zhou, X., et al, Optimizing task migration decisions in vehicular edge computing via vehicular micro clouds (VMCs), 2024, TU Berlin Technical Report.
- [12] Wang, X., Han, Y., Wang, C., Zhao, Q., Chen, X., & Chen, M, In-edge AI: Intelligentizing mobile edge computing, caching and communication by federated learning. 2024, IEEE Network, 33(5).
- [13] Liu, Z., et al. Blockchain-based deep learning for secure and efficient data management in vehicular networks. 2023, IEEE Access.
- [14] Al-Fuqaha, A., et al, Integrating blockchain and deep learning for autonomous vehicular systems. 2023, Elsevier.
- [15] Bishop, C. M., & Bishop, H. Deep Learning: Foundations and Concepts. 2023, Springer Nature.
- [16] Lim, B., & Zohren, S, Time-series forecasting with deep learning: a survey. Philosophical Transactions of the Royal Society A, 2023, 379(2194), 20200209.
- [17] Gervais, A., Karame, G. O., & Capkun, S. (2023). Blockchain Security and Privacy: A Survey. ACM Computing Surveys.
- [18] K. Li, Y. Chen, and W. Li, Blockchain and Deep Learning for Secure Energy Management in Smart Grids, 2022, in IEEE Transactions on Industrial Informatics, vol. 18, no. 5, pp. 3345-3356.

همچنین برای کارهای آینده می توان از شبیه‌سازهای حرکت مانند SUMO برای تولید trace‌های واقعی‌تر استفاده کرد.

## مراجع

- [1] Zheng, Y., Chen, Y., Tan, C., Yang, Y., Shu, C., & Chen, L, Optimization model for vehicular network data queries in edge environments. 2024, Journal of Cloud Computing.
- [2] Shen, J., Lin, Y., Zhang, W., Zhang, Y., Shu, F., & Li, J, Content caching-assisted vehicular edge computing using multi-agent graph attention reinforcement learning. 2024, IEEE Transactions on Vehicular Technology. Advance online publication. <https://doi.org/10.1109/TVT.2024.3479290>
- [3] Mushtaq, A., & Algarni, A. D, Cooperative content caching framework using cuckoo search optimization in vehicular edge networks. 2023, Applied Sciences, 13(2), 780. <https://doi.org/10.3390/app13020780>
- [4] Li, Z., Yang, C., Huang, X., Zeng, W., & Xie, S, CoOR: Collaborative task offloading and service caching replacement for vehicular edge computing networks, 2023, IEEE Transactions on Vehicular Technology PP(99), p: 1-6
- [5] Liu, M., Li, D., Wu, H., Lyu, F., & Shen, X, Cooperative edge-cloud caching for real-time sensing big data search in vehicular network. 2021, In Proc. IEEE ICC, Montréal, Canada.
- [6] Dai, Y., Xu, D., Zhang, K., Maharjan, S., & Zhang, Y, Deep reinforcement learning and permissioned blockchain for content caching in vehicular edge computing and networks. 2020, IEEE Transactions on Vehicular Technology, 69(4), p. 4312 - 4324
- [7] Wang, W., Wu, Q., Fan, Q., Zhao, Q., Wang, J., Zhang, C., & Letaief, K. B, Optimizing age of information in vehicular edge computing with federated graph neural network multi-agent reinforcement learning. 2024, arXiv Preprint, arXiv:2407.02342.
- [8] Wu, Q., Zhao, Y., Fan, Q., Fan, P., Wang, J., & Zhang, C, Mobility-aware cooperative caching in vehicular edge computing based on asynchronous federated and deep reinforcement learning. 2022, arXiv Preprint, arXiv:2208.01219.
- [9] Shao, X., et al, Content caching solution tailored for vehicular edge cloud computing integrating deep reinforcement learning and Informer. 2024, Computers & Electrical Engineering.
- [10] Lang, P and T, Daxin, Han X. , Zhang P., Duan X., Zhou J., L. V. C.M., Towards 6G vehicular networks: Vision, technologies, and open challenges. (2024).