

Enhancing Edge Computing Efficiency Using Autoencoding

Mahdi Tatar¹, Fateme Nasiri^{2*}

¹Master Student, Islamic Azad University, South Tehran Branch, Tehran, Iran

²Assistant Professor, Islamic Azad University, Yadegar-e-Imam Branch, Tehran, Iran

Received: 21 March 2025, Revised: 04 January 2026, Accepted: 10 February 2026

Paper type: Research

Abstract

The rapid expansion of Internet of Things (IoT) devices has led to a significant increase in the volume of generated data, posing substantial challenges for edge computing environments. Traditional cloud-based computing methods struggle to meet the demands of this technology due to limitations related to latency and privacy. To overcome these challenges, researchers have been exploring innovative solutions to optimize data storage and processing in edge computing environments. In this study, a hybrid approach is introduced that simultaneously leverages Autoencoders (AEs) and Multilayer Perceptrons (MLPs) to enhance data processing efficiency in IoT edge computing. By utilizing the advantages of both architectures, this approach provides a robust model for effectively managing large-scale IoT data. The evaluation results of the proposed method indicate that the model outperforms other approaches, achieving the highest accuracy (0.88), precision (0.75), recall (0.70), and F1-score (0.72). These findings suggest that the proposed solution can serve as an efficient approach for optimizing IoT data processing.

Keywords: Internet of Things, Edge Computing, Data Storage, Autoencoders, Multilayer Perceptrons

* Corresponding Author's email: fatemeh_nsr@yahoo.com

افزایش کارایی محاسبات لبه به کمک رمزگذاری خودکار

مهدی تاتارا^۱، فاطمه نصیری^{۲*}

۱- دانشجوی کارشناسی ارشد، گروه کامپیوتر، واحد تهران جنوب، دانشگاه آزاد اسلامی، تهران، ایران
۲- استادیار، گروه کامپیوتر، واحد یادگار امام، دانشگاه آزاد اسلامی، تهران، ایران

تاریخ دریافت: ۱۴۰۴/۰۱/۰۱ تاریخ بازبینی: ۱۴۰۴/۱۰/۱۴ تاریخ پذیرش: ۱۴۰۴/۱۱/۲۱
نوع مقاله: پژوهشی

چکیده

گسترش سریع دستگاه‌های اینترنت اشیا (IoT) منجر به افزایش چشمگیر حجم داده‌های تولیدی شده است که چالش‌های قابل توجهی را برای محیط‌های محاسباتی لبه ایجاد می‌کند. روش‌های سنتی مبتنی بر رایانش ابری به دلیل محدودیت‌های مربوط به تأخیر و حفظ حریم خصوصی، در پاسخگویی به نیازهای این فناوری با مشکلاتی مواجه هستند. به‌منظور غلبه بر این چالش‌ها، پژوهشگران در جستجوی راه‌حل‌های نوآورانه برای بهینه‌سازی ذخیره‌سازی و پردازش داده‌ها در محیط‌های محاسباتی لبه بوده‌اند. در این مطالعه، یک رویکرد ترکیبی معرفی شده است که از رمزگذارهای خودکار (AES) و پرسپترون‌های چندلایه (MLP) به طور هم‌زمان بهره می‌برد تا کارایی پردازش داده‌ها در محاسبات لبه IoT را بهبود بخشد. این رویکرد با بهره‌گیری از مزایای هر دو معماری، یک مدل قدرتمند برای مدیریت مؤثر داده‌های IoT در مقیاس بزرگ ارائه می‌دهد. نتایج ارزیابی روش پیشنهادی نشان می‌دهد که این مدل با دستیابی به بالاترین دقت (۰,۸۸)، صحت (۰,۷۵)، فراخوانی (۰,۷۰) و امتیاز F1 (۰,۷۲)، در مقایسه با سایر روش‌ها عملکرد بهتری دارد و می‌تواند به‌عنوان یک راهکار کارآمد در بهینه‌سازی پردازش داده‌های IoT مورد استفاده قرار گیرد.

کلیدواژگان: اینترنت اشیا، محاسبات لبه، ذخیره‌سازی داده‌ها، رمزگذارهای خودکار، پرسپترون‌های چندلایه.

* رایانامه نویسنده مسؤل: fatemeh_nsr@yahoo.com

۱- مقدمه

تکراری یا درخواست‌های مکرر، به‌جای ارسال مداوم داده‌ها از ابر، از حافظه پنهان لبه پاسخ داده می‌شوند [۳،۴].

با وجود مزایای آشکار محاسبات لبه‌ای و روش‌های ذخیره‌سازی محلی، مدیریت مؤثر این داده‌ها با توجه به رشد نمایی اطلاعات در دستگاه‌های IoT، چالشی مهم به شمار می‌رود. یکی از رویکردهای جدید برای فائق آمدن بر این چالش، ترکیب ابزارهای یادگیری عمیق در مدیریت داده‌های لبه است. در این راستا، ادغام رمزگذارهای خودکار (AE^۴) و پرسپترون‌های چندلایه (MLP^۵) به‌عنوان راهکاری نوین مطرح می‌شود. رمزگذارهای خودکار قابلیت برجسته‌سازی الگوها و فشرده‌سازی داده‌ها را دارند و با کاهش ابعاد داده، امکان ذخیره‌سازی و بازیابی سریع‌تر و کارآمدتر را فراهم می‌کنند. از سوی دیگر، MLPها با قدرت بالای خود در طبقه‌بندی و تشخیص الگو، می‌توانند در کنار داده‌های فشرده‌شده، فرایندهای تحلیلی پیشرفته را به شکل بهینه‌تری انجام دهند. این هم‌افزایی منجر به ساخت مدلی ترکیبی می‌شود که ضمن حفظ دقت در شناسایی ویژگی‌ها و الگوهای مهم، می‌تواند داده‌های حجیم را در لبه مدیریت کند و نیاز به ارسال تمام اطلاعات به مراکز ابری را کاهش دهد [۵،۶].

نوآوری این پژوهش در ارائه یک مدل یادگیری عمیق ترکیبی نهفته است که از ترکیب قابلیت‌های رمزگذارهای خودکار و MLPها بهره می‌برد. رمزگذارهای خودکار با استخراج ویژگی‌های کلیدی و کاهش بعد داده‌ها، توان پردازشی و پهنای باند موردنیاز را به طور محسوسی کاهش می‌دهند و زمینه را برای طبقه‌بندی دقیق و سریع داده‌ها توسط MLPها فراهم می‌سازند. این رویکرد ترکیبی، افزون بر کاهش هزینه‌های زیرساختی و مصرف انرژی، امکان تصمیم‌گیری آنی و واکنش بلادرنگ را در محیط‌های لبه‌ای مهیا می‌کند. در نتیجه، نه تنها عملکرد بهتری در فشرده‌سازی و ذخیره‌سازی ارائه می‌شود، بلکه دقت بیشتری در تشخیص الگوها و ناهنجاری‌ها نیز به دست می‌آید که در برنامه‌های حساس به خطا و امنیت، امری حیاتی محسوب می‌شود.

بر اساس آنچه گفته شد، هدف اصلی در رایانش لبه‌ای، بهینه‌سازی جریان داده‌ها و کاهش چشمگیر تأخیر در دسترسی و پردازش است. نزدیک‌تر کردن مراکز پردازشی به منبع تولید داده و حذف فاصله‌های طولانی بین کاربر و سرور ابری، کمک می‌کند تا ضمن صرفه‌جویی در مصرف پهنای باند، کیفیت خدمات نیز ارتقا یابد.

با گسترش چشمگیر اینترنت اشیا (IoT^۱) و تولید حجم عظیمی از داده‌ها توسط حسگرها، دستگاه‌ها و برنامه‌های کاربردی مرتبط، ضرورت به‌کارگیری روش‌های بهینه برای پردازش و تحلیل داده‌ها بیش‌ازپیش محسوس شده است. در معماری سنتی، داده‌های جمع‌آوری شده عموماً برای پردازش به مراکز داده ابری ارسال می‌شوند؛ رویکردی که با چالش‌هایی نظیر افزایش ترافیک شبکه، مصرف پهنای باند بالا و تأخیر در دسترسی به داده‌ها مواجه است. به همین دلیل، محاسبات لبه‌ای^۲ به‌عنوان رویکردی نوظهور مطرح شده است که با انتقال پردازش به نزدیک‌ترین نقطه به منبع داده، علاوه بر کاهش فاصله انتقال و زمان پاسخ‌دهی، از سربارهای غیرضروری در ارسال داده‌های حجیم به مرکز نیز جلوگیری می‌کند. این معماری جدید در حوزه‌هایی مانند خودروهای هوشمند، سازمان‌های صنعتی و کاربردهای حساس به تأخیر، اهمیت ویژه‌ای پیدا کرده است و انتظار می‌رود با رشد فناوری‌های آینده همچون شبکه‌های 5G، سهم محاسبات لبه‌ای در اکوسیستم دیجیتال به طرز قابل‌توجهی افزایش یابد. با این حال، یکی از موانع اصلی در توسعه گسترده آن، نیاز به سرمایه‌گذاری و تأمین مالی کافی است که هنوز سازوکار دقیق آن کاملاً روشن نشده است [۱،۲].

از مهم‌ترین بخش‌های محاسبات لبه‌ای می‌توان به مدیریت حافظه پنهان^۳ اشاره کرد. در این رویکرد، داده‌های پرکاربرد یا حساس به تأخیر، به‌جای آنکه از فاصله‌های دور در مرکز داده ابری فراخوانی شوند، در نزدیکی محل تولید یا مصرف ذخیره می‌شوند. نتیجه این عمل، کاهش زمان پاسخ‌دهی، بهبود تجربه کاربر، و همچنین صرفه‌جویی در پهنای باند شبکه است. در محیط‌هایی نظیر IoT یا کاربردهای تحلیلی بلادرنگ که به پردازش سریع و آنی اطلاعات نیاز است، ذخیره‌سازی داده‌ها در حاشیه شبکه، راهکاری کلیدی برای دسترس‌پذیری بالاتر و کاهش هزینه‌ها محسوب می‌شود. به‌عنوان نمونه، در خودروهای هوشمند، بهره‌گیری از محاسبات لبه‌ای و حافظه پنهان، انتقال فوری داده‌های حسگرها و پردازش آن در نزدیکی خودرو را امکان‌پذیر می‌کند و در نتیجه، تصمیم‌گیری‌های حیاتی نظیر ترمز خودکار یا تغییر مسیر در لحظه صورت می‌گیرد. بدین ترتیب، احتمال بروز حوادث در اثر تأخیر در ارسال داده‌ها به مراتب کاهش می‌یابد. مزیت دیگر این روش در کاهش مصرف منابع سرورهای مرکزی نهفته است؛ چراکه محتوای

⁴ Autoencoders

⁵ MultiLayer Perceptron

¹ Internet of Things

² Edge Computing

³ Cache

رشد نمایی ترافیک داده‌های موبایل، ناشی از اپلیکیشن‌های نیازمند کیفیت بالا و دستگاه‌های هوشمند، اهمیت ذخیره‌سازی لبه را افزایش داده است [۱۲]. بخش قابل توجهی از ترافیک شبکه ناشی از داده‌های پرتکرار است که تأثیر مستقیمی بر پهنای باند و تأخیر دسترسی دارد [۱۳]. ذخیره‌سازی داده‌های پرتکرار در لبه، علاوه بر کاهش هزینه انتقال، موجب بهبود زمان پاسخگویی می‌شود. در این راستا، سرورهای لبه با ارائه منابع محاسباتی و ذخیره‌سازی به کاربران کمک می‌کنند تا تجربه کاربری بهتری داشته باشند [۱۴]. به عنوان مثال، سیستم Cachier [۱۵] با توزیع ترافیک بین لبه و ابر، تأخیر را به حداقل می‌رساند، در حالی که حلالی و همکاران [۱۷] سیستمی با نام Agar طراحی کرده‌اند که با برنامه‌ریزی پویا، داده‌های پرتکرار را در لبه ذخیره می‌کند.

در ادامه تحقیقات، تمرکز بر راهکارهای مبتنی بر ارائه‌دهندگان خدمات شکل گرفته است. ژوانیو و همکاران [۱۸] مکانیسمی حراجی برای تخصیص فضای کش به کاربران پیشنهاد کردند، در حالی که شی و همکاران [۱۹] الگوریتمی برای افزایش نرخ اصابت کش معرفی کردند. برخی مطالعات مانند کار لیو و همکاران [۲۰] بر طراحی توابع سودمندی که به محبوبیت ویدئوها و تحرک کاربران آگاه هستند، تمرکز داشته‌اند. همچنین، چن و همکاران [۲۱] معماری SDN جدیدی برای شبکه G5 ارائه دادند که تأخیر کش در سلول‌های کوچک و ماکروسل را تحلیل کرده و رویکرد بهینه ذخیره‌سازی را پیاده‌سازی می‌کند.

چالش اصلی در ذخیره‌سازی لبه از دیدگاه ارائه‌دهندگان خدمات، دستیابی به حداکثر درآمد در عین تضمین تأخیر کم برای کاربران است. در این راستا، پژوهشگران مدل‌های برنامه‌ریزی ریاضی برای بهینه‌سازی انتخاب داده‌های کش شده در سرورهای لبه ارائه داده‌اند. این مدل‌ها معمولاً تابع هدفی دارند که شامل دو بخش اصلی است: نخست، سود ناشی از پاسخگویی سریع‌تر و دوم، هزینه‌های مرتبط با ذخیره‌سازی و انتقال داده. تخمین صحیح محبوبیت داده‌ها یکی از چالش‌های اساسی این حوزه است، زیرا روند تقاضای کاربران پویا بوده و تحت تأثیر عوامل مختلفی قرار دارد. تکنیک‌هایی مانند PHT و نسخه‌های بهبودیافته آن امکان نظارت بر تغییرات درخواست‌ها را فراهم می‌کنند، اما همچنان پژوهش‌های بیشتری در این زمینه مورد نیاز است.

یکی از رویکردهای نوظهور برای بهبود سامانه‌های لبه، استفاده از تکنیک‌های یادگیری عمیق است که امکان تحلیل سریع داده‌های عظیم را فراهم می‌کند [۲۲]. با توسعه فناوری IoT و افزایش دستگاه‌های لبه‌ای، نیاز به روش‌های هوشمند برای مدیریت شبکه

بدین منظور، پژوهش حاضر تلاش دارد تا ضمن ارائه مدل یادگیری عمیق ترکیبی، رویکردی کارآمد برای ذخیره‌سازی و پردازش داده‌ها در لبه IoT ارائه کند و با کاهش زمان پاسخ و افزایش مقیاس‌پذیری، نیازهای روزافزون دنیای دیجیتال را برآورده سازد. در همین راستا، می‌توان کاهش مصرف پهنای باند، بهبود سرعت و دقت در تحلیل داده‌ها، و تسریع فرایند تصمیم‌گیری را به عنوان مهم‌ترین اهداف این تحقیق برشمرد. همچنین انتظار می‌رود که ادغام AEها و MLPها منجر به افزایش دقت و دقت در پیش‌بینی روندها و ناهنجاری‌ها در جریان داده‌های IoT شده و آن را به ابزاری ارزشمند برای مدیریت داده‌ها و تصمیم‌گیری موثر تبدیل کند.

۲- پیشینه پژوهش

با گسترش روزافزون دستگاه‌های هوشمند و ورود فناوری‌هایی مانند اینترنت اشیا (IoT)، حجم عظیمی از داده‌ها در لبه شبکه تولید می‌شود که پردازش مؤثر آن‌ها به یک چالش اساسی تبدیل شده است. کشورهای پیشرو مانند آمریکا و چین با پژوهش‌های گسترده در زمینه محاسبات لبه و ذخیره‌سازی توزیع‌شده، تلاش کرده‌اند تا کیفیت خدماتی مانند ویدئوهای آنلاین، بازی‌های ابری و رانندگی خودران را بهبود بخشند. در این راستا، مفهوم پردازش لبه به عنوان رویکردی برای انتقال ظرفیت‌های محاسباتی و ذخیره‌سازی به نزدیک‌ترین نقطه به کاربران مطرح شده است که موجب کاهش تأخیر و مصرف پهنای باند شبکه می‌شود. از آنجاکه داده‌های پرتکرار باعث افزایش بار شبکه می‌شوند، راهکارهای کش کردن داده‌های محبوب در سرورهای لبه برای کاهش انتقال مداوم داده‌ها از ابر بسیار مورد توجه قرار گرفته‌اند. در سال‌های اخیر، این حوزه با رشد سریع فناوری مورد توجه پژوهشگران بسیاری قرار گرفته است.

در تحقیقات اولیه، تمرکز بر طراحی مکانیزم‌های کش مشترک در سرورهای لبه بوده است. تران و همکاران [۷] چارچوبی ارائه کردند که با استفاده از پخش ویدئو با نرخ بیت تطبیقی، ذخیره ویدئوها را به عنوان یک مسئله بهینه‌سازی برنامه‌ریزی خطی عدد صحیح مدل‌سازی می‌کند، اما تخمین محبوبیت داده‌ها در آن مشخص نشده است. جورج و همکاران [۸] استراتژی کش ویدئویی مشترکی را بر اساس توزیع محبوبیت ویدئو و احتمال درخواست کاربران ارائه دادند. ژانگ و همکاران [۹] ذخیره‌سازی مشارکتی را با تمرکز بر کاهش تأخیر و خوشه‌بندی سرورها بررسی کردند، در حالی که غرایبه و همکاران [۱۰] الگوریتمی آنلاین برای حداقل‌سازی هزینه‌های ارائه‌دهندگان محتوا پیشنهاد دادند. همچنین، روش PHT [۱۱] تغییرات درخواست‌ها را رصد کرده و با تحلیل تغییر جمعی، محبوبیت داده‌ها را تخمین می‌زند.

برای ارزیابی روش پیشنهادی در یک محیط واقعی، یک مجموعه داده باینری طراحی شده است که قابلیت نمایش دستگاه‌های IoT در حالات مختلف، مانند عملکرد عادی و غیرعادی، را دارد. تولید تصادفی داده‌ها موجب می‌شود که در هر اجرا مقادیر اندکی متفاوت باشند و این ویژگی به تقلید از تنوع واقعی در قرائت‌های حسگر کمک می‌کند. این مجموعه داده شامل داده‌های مصنوعی IoT است که با بهره‌گیری از توابع تصادفی کتابخانه NumPy تولید شده‌اند. به طور دقیق، مجموعه داده‌ای متشکل از ۱۰۰۰ نمونه (به صورت پیش‌فرض) و ۲۰ ویژگی ایجاد شده است. ویژگی‌های ورودی (X) شامل اعداد اعشاری تصادفی هستند که از طریق تابع np.random.rand تولید شدند، در حالی که متغیر هدف (y) به صورت یک برچسب طبقه‌بندی باینری (۰ یا ۱) با استفاده از تابع np.random.randint تعیین شد.

۳-۲- روش‌شناسی

در محیط‌های محاسبات لبه، دستگاه‌های IoT عموماً با محدودیت‌های متعددی از جمله توان پردازشی محدود، فضای ذخیره‌سازی اندک، محدودیت مصرف انرژی و گوناگونی قالب داده روبه‌رو هستند. این مسائل در هنگام پیاده‌سازی الگوریتم‌های یادگیری ماشینی یا عمیق نمود بیشتری پیدا می‌کنند، چرا که حجم بالای داده‌ها و نیاز به تحلیل بلادرنگ فشار زیادی بر منابع دستگاه‌های لبه وارد می‌سازد. از این‌رو، هدف اصلی پژوهش حاضر توسعه رویکردی است که بتواند ضمن کاهش حجم داده‌ها و تسهیل ذخیره‌سازی، پردازش آن‌ها را نیز تسریع کند. بدین منظور، رویکرد پیشنهادی از تلفیق قابلیت فشرده‌سازی رمزگذارهای خودکار (Autoencoders) با توانمندی طبقه‌بندی پرسپترون چندلایه (MLP) شکل گرفته است تا هم کارایی ذخیره‌سازی داده‌ها و هم قابلیت تشخیص الگو افزایش یابد.

در فاز نخست، داده‌ها از دستگاه‌های لبه یا شبیه‌سازهای IoT گردآوری می‌شوند. این داده‌ها می‌توانند شامل اطلاعات حسی (دمای محیط، رطوبت، داده‌های ویدئویی، صوتی و غیره) یا وقایع امنیتی باشند. برای آماده‌سازی این داده‌های خام جهت استفاده در مدل ترکیبی، چند مرحله پیش‌پردازش ضروری است: حذف نویز و مقادیر پرت، نرمال‌سازی یا مقیاس‌گذاری ویژگی‌ها، و در صورت لزوم استفاده از روش‌های کاهش ابعاد نظیر PCA. با این اقدامات، ورودی مدل از نظر شکل و دامنه مقدراری، استاندارد و همگن می‌شود. افزون بر آن، داده‌های باکیفیت و کامل، کمک می‌کنند تا در مرحله آموزش، اتلاف طبقه‌بندی یا بازسازی کمتر باشد و قابلیت تعمیم مدل افزایش یابد.

بیشتر احساس می‌شود [۲۳]. برخی از مکانیزم‌های ذخیره‌سازی سنتی ممکن است توانایی تطبیق با پویایی داده‌ها را نداشته باشند، لذا ترکیب هماهنگ میان لبه و ابر مطرح شده است [۲۴]. در این رویکرد، داده‌های پرتکرار در نزدیک‌ترین نقطه به کاربران ذخیره می‌شوند که علاوه بر کاهش تأخیر، نسبت بار سرور را نیز بهینه می‌کند. پژوهش‌های اخیر در یادگیری عمیق نشان داده‌اند که این فناوری می‌تواند الگوهای مصرف کاربران را شناسایی کرده و تقاضا را پیش‌بینی کند [۲۵]. این پیشرفت‌ها نقش مهمی در بهبود کیفیت تجربه کاربری و بهره‌وری شبکه ایفا می‌کنند.

در سال‌های اخیر، پژوهش‌های متعددی به بررسی هوش لبه و تشخیص ناهنجاری در شبکه‌های IoT پرداخته‌اند. ژو و همکاران (۲۰۲۱) در مطالعه‌ای جامع، مؤلفه‌های اصلی هوش لبه شامل ذخیره‌سازی، آموزش، استنتاج و انتقال پردازش به لبه را بررسی کرده‌اند [۲۶]. همچنین، اولاج و محمود (۲۰۲۲) یک مدل یادگیری عمیق جدید برای تشخیص ناهنجاری در شبکه‌های IoT ارائه کرده‌اند که ترکیبی از شبکه‌های عصبی بازگشتی (LSTM, BiLSTM, GRU) با شبکه‌های عصبی کانولوشن (CNN) است. مدل‌های پیشنهادی آن‌ها عملکرد بهتری نسبت به روش‌های پیشین داشته‌اند [۲۷]. در این راستا، ابوزیتا و همکاران (۲۰۲۳) یک خودرزمگذار کاهش نویز طراحی کرده‌اند که ویژگی‌های مقاوم را استخراج و دقت تشخیص داده‌های مخرب را بهبود می‌بخشد [۲۸]. همچنین، رفیق و همکاران (۲۰۲۴) بر نیاز به مجموعه داده‌های متنوع، آزمایش‌های بلادرنگ و مقیاس‌پذیری بیشتر سیستم‌ها تأکید کرده‌اند [۲۹]. در نهایت، ونگ و همکاران (۲۰۲۵) یک روش مبتنی بر خودرزمگذار GRU و بهینه‌سازی BO-TPE معرفی کرده‌اند که قابلیت اطمینان در محاسبات مه خودرویی را بهبود می‌بخشد [۳۰].

در مجموع، ذخیره‌سازی لبه با ترکیب روش‌های مبتنی بر یادگیری عمیق و رویکردهای مبتنی بر محاسبات توزیع‌شده می‌تواند به طور قابل توجهی کیفیت خدمات دیجیتال را افزایش دهد. علاوه بر این، تحقیقات در حوزه تشخیص ناهنجاری‌های IoT نیز نشان می‌دهد که مدل‌های یادگیری عمیق می‌توانند نقش مهمی در بهبود امنیت و کارایی سیستم‌های شبکه ایفا کنند. آینده این حوزه نیازمند توسعه مدل‌های هوشمندتر و بهینه‌سازی ساختارهای ذخیره‌سازی برای پاسخگویی به رشد مداوم داده‌ها است.

۳- مواد و روش‌ها

۳-۱- مجموعه داده

عملکرد (مانند کمترین اتلاف بازسازی) و در نهایت ادغام آن با MLP برای انجام طبقه‌بندی یا وظایف پیش‌بینی است. داده‌های فشرده و پردازش شده در نهایت در فضای ذخیره‌سازی بهینه در لبه نگهداری می‌شوند. برای ارزیابی کارایی، معیارهایی نظیر دقت طبقه‌بندی، سرعت پردازش، کاهش حجم داده، میزان تأخیر پاسخ و مصرف منابع سنجش می‌شوند. همچنین نتایج حاصل با روش‌های جداگانه AE و MLP یا سایر روش‌های پایه مقایسه می‌گردد.

برای پیاده‌سازی عملی چارچوب پیشنهادی، از محیط پایتون (نسخه ۳،۹) و کتابخانه‌هایی مانند NumPy، TensorFlow و PyTorch استفاده شده است. این کتابخانه‌ها امکان ساخت و آموزش شبکه‌های عمیق نظیر رمزگذار خودکار (AE) و پرسپترون چندلایه (MLP) را فراهم می‌کنند. پس از آموزش مدل بر روی داده‌های واقعی یا شبیه‌سازی شده، دقت طبقه‌بندی و نسبت فشرده‌سازی بررسی شده و با مدل‌های رقیب مقایسه می‌شود. انتظار می‌رود که روش پیشنهادی، با ترکیب رمزگذارهای خودکار و شبکه‌های عصبی پرسپترون چندلایه، علاوه بر کاهش حجم داده‌های ذخیره‌شده در لبه، منجر به پردازش سریع‌تر شود. این ویژگی، در کنار کاهش تبادل داده با سرور ابری، باعث صرفه‌جویی در مصرف انرژی، کاهش هزینه پهنای باند و بهبود کیفیت خدمات در سامانه‌های IoT خواهد شد.

برای ارزیابی عملکرد روش پیشنهادی، از معیارهای مختلفی استفاده می‌شود. مهم‌ترین معیارهای ارزیابی شامل دقت (Accuracy)، صحت (Precision)، فراخوانی (Recall) و امتیاز F1 هستند که در ادامه تعریف می‌شوند. دقت (Acc) به صورت نسبت تعداد نمونه‌هایی که مدل به درستی طبقه‌بندی کرده است (شامل کلاس‌های دارای خطا و فاقد خطا) به کل نمونه‌ها تعریف می‌شود:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (6)$$

صحت (Precision) نسبت پیش‌بینی‌های مثبت واقعی را از کل پیش‌بینی‌های مثبت مدل نشان می‌دهد:

$$Precision = \frac{TP}{TP + FP} \quad (7)$$

فراخوانی (Recall) که با نام حساسیت یا نرخ مثبت واقعی نیز شناخته می‌شود، نشان‌دهنده نسبت پیش‌بینی‌های مثبت واقعی از کل موارد مثبت واقعی است:

$$Recall = \frac{TP}{TP + FN} \quad (8)$$

امتیاز F1، میانگین هارمونیک دقت و فراخوانی است که به تعادل بین این دو معیار کمک می‌کند. این معیار به‌ویژه زمانی مفید است که توزیع کلاس‌ها نامتعادل باشد:

در مدل پیشنهادی، رمزگذار خودکار وظیفه اصلی کاهش ابعاد و فشرده‌سازی را بر عهده دارد. این شبکه شامل دو بخش رمزگذار و رمزگشا است. رمزگذار داده ورودی x را به یک فضای پنهان با ابعاد پایین‌تر z نگاشت می‌کند و سپس رمزگشا از روی z سعی می‌کند خروجی بازسازی شده را تولید نماید. تابع هزینه رمزگذار خودکار، اتلاف بازسازی زیر است:

$$L = \|y - x\|^2 \quad (1)$$

رمزگذار x را با استفاده از یک شبکه عصبی $f(x)$ ترسیم می‌کند. رمزگشا با استفاده از شبکه عصبی دیگر $g(z)$ را به y نگاشت می‌کند. روابط ریاضی MLP به این صورت است. اجازه دهید x ورودی، h فعال‌سازی لایه پنهان و y خروجی باشد.

$$y = \sigma(W'h + b'), h = \sigma(Wx + b) \quad (2)$$

حرکت روبه‌جلو محاسبه می‌کند. جایی که W ماتریس وزن، b بایاس و σ تابع فعال‌سازی است. MLP یاد می‌گیرد که اتلاف طبقه‌بندی را به حداقل برساند:

$$L = L(y, \hat{y}) \quad (3)$$

مدل ترکیب رمزگذارهای خودکار + MLP از رمزگذارهای خودکار برای کاهش ابعاد و ویژگی و MLP برای طبقه‌بندی استفاده می‌کند: رمزگذار خودکار داده‌های ورودی با ابعاد بالا را به فضای پنهان با ابعاد پایین‌تر کاهش می‌دهد.

سپس MLP نمایش‌های کدگذاری شده را طبقه‌بندی می‌کند.

رابطه ریاضی رمزگذار خودکار به صورت زیر است.

$$\min_{\theta} L_{ae} = E[\|y - f(g(z))\|^2] \quad (4)$$

MLP به حداقل می‌رساند:

$$\min_{\theta} L_{mlp} = E[L(y, g(f(x)))] \quad (5)$$

بدین ترتیب، با تلفیق AE و MLP، هم فشرده‌سازی داده‌ها و هم تشخیص الگوی آن‌ها به صورت مؤثر در دستگاه‌های لبه انجام می‌شود.

در فلوچارت مدل پیشنهادی، ابتدا داده‌ها از حسگرها جمع‌آوری و در لبه ذخیره می‌شوند. سپس فرایند فشرده‌سازی و استخراج ویژگی روی داده‌ها اعمال می‌گردد تا حجم آن‌ها کاهش یابد و ویژگی‌های مؤثر شناسایی شوند. در ادامه، آموزش مدل رمزگذارهای خودکار و MLP صورت می‌گیرد تا الگوها و روابط حاکم در داده‌ها فراگرفته شود. گام بعدی، انتخاب رمزگذار خودکار مؤثر بر اساس معیارهای

پیشنهادی، کارایی کمتری از خود نشان داده است. علت این موضوع را می‌توان در مشکلات مربوط به یادگیری طولانی‌مدت RNN مانند محو شدن گرادیان جستجو کرد که ممکن است بر دقت مدل تأثیر بگذارد.

بررسی این نتایج نشان می‌دهد که روش پیشنهادی از نظر تمامی معیارهای ارزیابی عملکرد برتری داشته است. دقت این روش (۰,۸۸) نسبت به RNN (۰,۸۴) و CNN (۰,۸۲) بالاتر است که نشان‌دهنده توانایی بهتر آن در تشخیص صحیح داده‌ها می‌باشد. همچنین، صحت روش پیشنهادی (۰,۷۵) در مقایسه با RNN (۰,۷۱) و CNN (۰,۶۵) بهبود قابل توجهی داشته است که نشان می‌دهد مدل توانسته است در طبقه‌بندی داده‌های مثبت عملکرد بهتری داشته باشد. در مورد فراخوانی، مقدار ۰,۷۰ برای روش پیشنهادی به دست آمده است که از RNN (۰,۶۹) اندکی بهتر و از CNN (۰,۶۸) بالاتر است. همچنین، امتیاز F1 که تعادل بین صحت و فراخوانی را نمایش می‌دهد، در روش پیشنهادی ۰,۷۲ بوده که نسبت به دو مدل دیگر (۰,۶۶) مقدار بیشتری دارد.

مقایسه عملکرد کلی مدل‌ها نشان می‌دهد که روش پیشنهادی در تمامی معیارهای مورد ارزیابی عملکرد بهتری داشته و به‌عنوان کاراترین مدل در این پژوهش شناخته می‌شود. این برتری به‌ویژه در دقت و صحت مشاهده می‌شود که دو معیار مهم در ارزیابی مدل‌های یادگیری ماشین محسوب می‌شوند. همچنین، در معیارهای فراخوانی و امتیاز F1 نیز روش پیشنهادی توانسته است تعادل مطلوبی را میان کاهش خطای نوع اول (False Positive) و افزایش قابلیت شناسایی نمونه‌های صحیح برقرار کند. از سوی دیگر، روش‌های CNN و RNN هرچند توانسته‌اند نتایج قابل قبولی ارائه دهند، اما به دلیل محدودیت‌های ساختاری خود، در مقایسه با روش پیشنهادی عملکرد ضعیف‌تری داشته‌اند.

یکی از دلایل برتری روش پیشنهادی نسبت به CNN و RNN را می‌توان در نحوه ترکیب ویژگی‌های فضایی و زمانی در این مدل جستجو کرد. CNN اگرچه در پردازش ویژگی‌های تصویری عملکرد خوبی دارد، اما قادر به درک روابط متوالی بین داده‌ها نیست. در مقابل، RNN وابستگی زمانی داده‌ها را در نظر می‌گیرد، اما در پردازش ویژگی‌های پیچیده تصویری ضعف‌هایی دارد. روش پیشنهادی با بهره‌گیری از نقاط قوت هر دو مدل و ترکیب آن‌ها توانسته است عملکرد بالاتری را ارائه دهد. این یافته‌ها نشان می‌دهد که استفاده از یک مدل ترکیبی که بتواند هر دو جنبه فضایی و زمانی داده‌ها را مدیریت کند، می‌تواند به بهبود دقت و صحت طبقه‌بندی داده‌ها منجر شود.

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (9)$$

این معیارها به مقایسه روش پیشنهادی با سایر روش‌های موجود کمک کرده و عملکرد آن را از جنبه‌های مختلف ارزیابی می‌کنند.

۴- نتایج

نتایج به دست آمده از اجرای روش پیشنهادی نشان‌دهنده عملکرد قابل توجه آن در مقایسه با سایر روش‌های مورد بررسی است. معیارهای ارزیابی شامل دقت (Accuracy)، صحت (Precision)، فراخوانی (Recall) و امتیاز F1 بودند که به ترتیب مقادیر ۰,۸۸، ۰,۷۵، ۰,۷۰ و ۰,۷۲ را برای روش پیشنهادی نشان دادند. این مقادیر نشان می‌دهند که روش ارائه شده توانسته است در تشخیص صحیح داده‌ها و کاهش خطا عملکرد مطلوبی داشته باشد. برای درک بهتر این نتایج و مقایسه آن با سایر مدل‌های یادگیری ماشین، به‌ویژه CNN و شبکه‌های عصبی بازگشتی (RNN)، بررسی جامعی از عملکرد هر مدل انجام شد. مقایسه‌ی این روش‌ها از آن جهت حائز اهمیت است که امکان ارزیابی دقیق‌تر مزایا و محدودیت‌های هر کدام را فراهم می‌کند و به تصمیم‌گیری در انتخاب مدل مناسب کمک می‌نماید.

CNN یکی از پرکاربردترین مدل‌های یادگیری عمیق در پردازش تصویر و بینایی کامپیوتری است. این شبکه شامل چندین لایه پردازشی از جمله لایه‌های کانولوشن، لایه‌های ادغام و لایه‌های کاملاً متصل است. این ساختار به شبکه CNN اجازه می‌دهد که ویژگی‌های پیچیده تصاویر را استخراج و تحلیل کند. نتایج به دست آمده از اجرای این روش نشان داد که دقت آن ۰,۸۲، صحت ۰,۶۵، فراخوانی ۰,۶۸ و امتیاز F1 برابر با ۰,۶۶ است. این مقادیر نشان می‌دهد که هرچند شبکه‌ی CNN عملکرد مناسبی در پردازش داده‌ها دارد، اما در مقایسه با روش پیشنهادی، نتوانسته است به همان سطح دقت و صحت دست یابد. دلیل این امر را می‌توان در محدودیت‌های ذاتی CNN جستجو کرد که در آن ارتباطات زمانی بین داده‌ها کمتر مورد توجه قرار می‌گیرد.

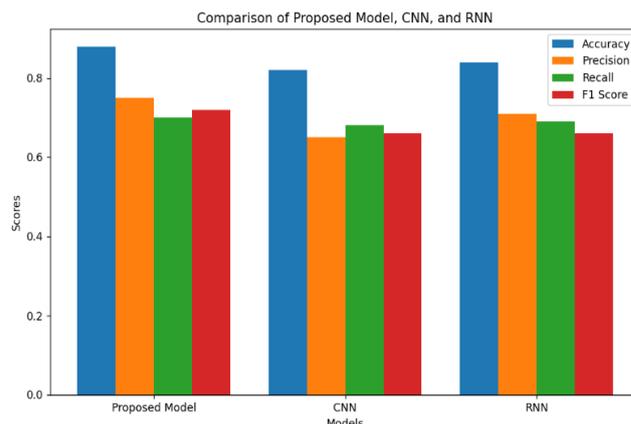
RNN یکی دیگر از مدل‌های یادگیری عمیق است که برای پردازش داده‌های متوالی و سری‌های زمانی طراحی شده است. برخلاف شبکه‌های عصبی معمولی که داده‌ها را به صورت مستقل پردازش می‌کنند، RNN قابلیت حفظ اطلاعات پیشین را دارد و از این طریق به بهبود پیش‌بینی‌ها در مسائل دارای وابستگی زمانی کمک می‌کند. اجرای این روش نشان داد که مقدار دقت برابر با ۰,۸۴، صحت ۰,۷۱، فراخوانی ۰,۶۹ و امتیاز F1 نیز ۰,۶۶ است. اگرچه عملکرد RNN نسبت به CNN بهبود یافته است، اما همچنان در مقایسه با روش

شده است.

۵- نتیجه گیری

روش پیشنهادی در این پژوهش، با بهره‌گیری از ترکیب AEs و MLP ها، عملکرد بهتری نسبت به رویکردهای مبتنی بر CNN و RNN ارائه می‌دهد. بر اساس معیارهای ارزیابی، این مدل با دقت ۰,۸۸ از CNN (۰,۸۲) و RNN (۰,۸۴) فراتر رفته و همچنین، صحت بالاتری (۰,۷۵) در مقایسه با ۰,۶۵ برای CNN و ۰,۷۱ برای RNN دارد که نشان‌دهنده توانایی بالاتر در تشخیص صحیح موارد مثبت است. درحالی‌که میزان فراخوانی روش پیشنهادی (۰,۷۰) کمی بیشتر از RNN (۰,۶۹) است، امتیاز F1 برابر با ۰,۷۲ است که نسبت به CNN (۰,۶۶) و RNN (۰,۶۶) تعادل بهتری میان دقت و یادآوری ایجاد می‌کند. این نتایج نشان می‌دهند که مدل ترکیبی AEs-MLP، علاوه بر کاهش حجم داده‌های پردازش‌شده در لبه شبکه، توانسته است کارایی محاسباتی و دقت تشخیص را بهبود دهد. در نتیجه، این روش می‌تواند به‌عنوان یک راهکار بهینه برای پردازش داده‌های IoT در محیط‌های محاسباتی لبه مورد استفاده قرار گیرد.

در راستای توسعه و بهبود این روش، چندین پیشنهاد تحقیقاتی برای آینده قابل‌بررسی است. افزایش بهره‌وری محاسباتی از طریق بهینه‌سازی مدل ترکیبی AEs-MLP می‌تواند منجر به کاهش مصرف منابع پردازشی و افزایش سرعت تحلیل داده‌ها در دستگاه‌های لبه شود. کاهش تأخیر پردازش یکی دیگر از مسیرهای تحقیقاتی مهم است، چراکه استقرار مدل در نزدیکی منبع داده باعث واکنش سریع‌تر سیستم‌ها و کاهش تأخیر در کاربردهای بلادرنگ می‌شود. بهبود امنیت و حریم خصوصی با استفاده از روش‌هایی مانند یادگیری فدرال نیز می‌تواند اهمیت بالایی داشته باشد، زیرا پردازش داده‌ها در لبه بدون نیاز به ارسال اطلاعات حساس به سرورهای مرکزی، امنیت را افزایش می‌دهد. علاوه بر این، پیشرفت‌های سخت‌افزاری نظیر توسعه شتاب‌دهنده‌های ویژه هوش مصنوعی (NPU و TPU) امکان اجرای بهینه مدل‌های ترکیبی AEs-MLP را بر روی دستگاه‌های لبه فراهم می‌کند. در نهایت، گسترش کاربردهای عملی در حوزه‌هایی مانند شهرهای هوشمند، سیستم‌های مراقبت سلامت، مدیریت صنعتی، و وسایل نقلیه خودران می‌تواند زمینه‌های جدیدی برای توسعه این روش ایجاد کند. این پیشنهادها نشان می‌دهند که ادغام رمزگذارهای خودکار و پرسپترون‌های چندلایه می‌تواند به بهبود کارایی محاسبات لبه و مدیریت داده‌های IoT در مقیاس وسیع کمک کند.



شکل ۱. مقایسه نتایج روش پیشنهادی در مقایسه با CNN و RNN

در نهایت، مقایسه این سه مدل و نتایج حاصل از آن تأیید می‌کند که روش پیشنهادی در مقایسه با CNN و RNN از نظر دقت، صحت، فراخوانی و امتیاز F1 برتری دارد. این موضوع اهمیت استفاده از معماری‌های ترکیبی و پیشرفته‌تر در حوزه یادگیری عمیق را برجسته می‌کند. یافته‌های این پژوهش می‌تواند به محققان و فعالان حوزه یادگیری ماشین کمک کند تا در انتخاب مدل مناسب برای کاربردهای مختلف تصمیم‌گیری بهتری داشته باشند. همچنین، پیشنهاد می‌شود که در پژوهش‌های آینده، روش پیشنهادی با سایر مدل‌های پیشرفته یادگیری عمیق نیز مقایسه شود تا میزان کارایی و تعمیم‌پذیری آن در شرایط گوناگون بهتر بررسی گردد.

برای پیاده‌سازی معماری ترکیبی، از یک خود رمزگذار (Autoencoder) سه‌لایه‌ای برای فشرده‌سازی و استخراج نمایش‌های پنهان و از یک پرسپترون چندلایه (MLP) برای طبقه‌بندی استفاده شده است. Encoder شامل لایه‌های Dense با اندازه‌های ۶۴ و ۳۲ و در نهایت لایه کدگذاری می‌باشد. Decoder متقارن با Encoder بوده و بازسازی ورودی را با مینیمم‌سازی میانگین مربعات خطا (MSE) انجام می‌دهد. نمایش پنهان خروجی Encoder، به‌عنوان ورودی MLP قرار می‌گیرد. MLP شامل دو لایه مخفی (۳۲ و ۱۶ نود) و یک نود خروجی با فعال‌سازی Sigmoid برای طبقه‌بندی دودویی است.

آموزش در دو مرحله انجام می‌پذیرد: ابتدا خود رمزگذار به‌صورت غیر نظارتی با هدف کمینه‌سازی خطای بازسازی آموزش داده می‌شود؛ سپس، نمایش‌های کدگذاری‌شده جهت آموزش طبقه‌بند مورد استفاده قرار می‌گیرند. در ادامه برای بهبود عملکرد، کل شبکه با حداقل‌سازی تابع هزینه طبقه‌بندی (Binary Cross-Entropy) یا تابع ترکیبی به‌صورت end-to-end تنظیم دقیق می‌شود. بهینه‌سازی با Adam و نرخ یادگیری اولیه انجام شده و برای جلوگیری از بیش‌برازش از Dropout، L2-regularization و Early-stopping استفاده

مراجع

- [16] E. Zeydan, E. Bastug, M. Bennis, M. A. Kader, I. A. Karatepe, A. S. Er, and M. Debbah, "Big data caching for networking: Moving from cloud to edge," *IEEE Communications Magazine*, vol. 54, no. 9, pp. 36-42, 2016.
- [17] R. Halalai, P. Felber, A.-M. Kermarrec, and F. Taïani, "Agar: A caching system for erasure-coded data," in *2017 IEEE 37th International Conference on Distributed Computing Systems (ICDCS)*. IEEE, 2017, pp. 23-33.
- [18] X. Cao, J. Zhang, and H. V. Poor, "An optimal auction mechanism for mobile edge caching," in *2018 IEEE 38th International Conference on Distributed Computing Systems (ICDCS)*. IEEE, 2018, pp. 388-399.
- [19] X. Zhang and Q. Zhu, "Collaborative hierarchical caching over 5g edge computing mobile wireless networks," in *2018 IEEE International Conference on Communications (ICC)*. IEEE, 2018, pp. 1-6.
- [20] W. Liu, Y. Jiang, S. Xu, G. Cao, W. Du, and Y. Cheng, "Mobility-aware video prefetch caching and replacement strategies in mobile-edge computing networks," in *2018 IEEE 24th International Conference on Parallel and Distributed Systems (ICPADS)*. IEEE, 2018, pp. 687-694.
- [21] M. Chen, Y. Qian, Y. Hao, Y. Li, and J. Song, "Data-driven computing and caching in 5g networks: Architecture and delay analysis," *IEEE Wireless Communications*, vol. 25, no. 1, pp. 70-75, 2018.
- [22] Xia, Xiaoyu, et al. "Graph-based data caching optimization for edge computing." *Future generation computer systems* 113 (2020): 228-239.
- [23] Liu, Ying, et al. "Data caching optimization in the edge computing environment." *IEEE Transactions on Services Computing* (2020)
- [24] Safavat, Sunitha, Naveen Naik Sapavath, and Danda B. Rawat. "Recent advances in mobile edge computing and content caching." *Digital Communications and Networks* 6.2 (2020): 189-194.
- [25] Wang, Xiaofei, et al. "In-edge ai: Intelligentizing mobile edge computing, caching and communication by federated learning." *Ieee Network* 33.5 (2019): 156-165.
- [26] Xu, D., Li, T., Li, Y., Su, X., Tarkoma, S., Jiang, T., ... & Hui, P. (2021). Edge intelligence: Empowering intelligence to the edge of network. *Proceedings of the IEEE*, 109(11), 1778-1837.
- [27] Ullah, I., & Mahmoud, Q. H. (2022). Design and development of RNN anomaly detection model for IoT networks. *IEEE Access*, 10, 62722-62750.
- [28] Abusitta, A., de Carvalho, G. H., Wahab, O. A., Halabi, T., Fung, B. C., & Al Mamoori, S. (2023). Deep learning-enabled anomaly detection for IoT systems. *Internet of Things*, 21, 100656.
- [29] Rafique, S. H., Abdallah, A., Musa, N. S., & Murugan, T. (2024). Machine learning and deep learning techniques for internet of things network anomaly detection—current research trends. *Sensors*, 24(6), 1968.
- [30] Wang, Y., Qin, G., & Liang, Y. (2025). A reliability anomaly detection method based on enhanced GRU-Autoencoder for Vehicular Fog Computing services. *Computers & Security*, 150, 104217.
- [1] Veeramachaneni, V. (2025). Edge Computing: Architecture, Applications, and Future Challenges in a Decentralized Era. *Recent Trends in Computer Graphics and Multimedia Technology*, 7(1), 8-23.
- [2] Alnoman, A., Sharma, S. K., Ejaz, W., & Anpalagan, A. (2019). Emerging edge computing technologies for distributed IoT systems. *IEEE Network*, 33(6), 140-147.
- [3] Torabi, H., Khazaei, H., & Litoiu, M. (2024, May). A Learning-Based Caching Mechanism for Edge Content Delivery. In *Proceedings of the 15th ACM/SPEC International Conference on Performance Engineering* (pp. 236-246).
- [4] Malandrino, F., Chiasserini, C. F., & Dell'Aera, G. M. (2021). Edge-powered assisted driving for connected cars. *IEEE Transactions on Mobile Computing*, 22(2), 874-889.
- [5] Adeniyi, O., Sadiq, A. S., Pillai, P., Aljaidi, M., & Kaiwartya, O. (2024). Securing mobile edge computing using hybrid deep learning method. *Computers*, 13(1), 25.
- [6] Bourechak, A., Zedadra, O., Kouahla, M. N., Guerrieri, A., Seridi, H., & Fortino, G. (2023). At the confluence of artificial intelligence and edge computing in iot-based applications: A review and new perspectives. *Sensors*, 23(3), 1639.
- [7] T. Tran and D. Pompili, "Adaptive bitrate video caching and processing in mobile-edge computing networks," *IEEE Transactions on Mobile Computing*, 2018.
- [8] J. George and S. Sebastian, "Cooperative caching strategy for video streaming in mobile networks," in *Emerging Technological Trends (ICETT)*, International Conference on. IEEE, 2016, pp. 1-7.
- [9] S. Zhang, P. He, K. Suto, P. Yang, L. Zhao, and X. Shen, "Cooperative edge caching in user-centric clustered mobile networks," *IEEE Transactions on Mobile Computing*, vol. 17, no. 8, pp. 1791-1805, 2018.
- [10] A. Gharaibeh, A. Khreishah, B. Ji, and M. Ayyash, "A prov- ably efficient online collaborative caching algorithm for multicell-coordinated systems," *IEEE Transactions on Mobile Computing*, vol. 15, no. 8, pp. 1863-1876, 2016.
- [11] H. Mouss, D. Mouss, N. Mouss, and L. Sefouhi, "Test of page-hinckley, an approach for fault detection in an agro-alimentary production system," in *2004 5th Asian Control Conference (IEEE Cat. No. 04EX904)*, vol. 2. IEEE, 2004, pp. 815-818.
- [12] A. Maskooki, G. Sabatino, and N. Mitton, "Analysis and performance evaluation of the next generation wireless networks," in *Modeling and Simulation of Computer Networks and Systems*. Elsevier, 2015, pp. 601-627.
- [13] X. Xia, F. Chen, G. Cui, M. Abdelrazek, J. Grundy, H. Jin, and Q. He, "Budgeted data caching based on k-median in mobile edge computing," in *27th IEEE International Conference on Web Services*. IEEE, 2020.
- [14] W. Shi and S. Dustdar, "The promise of edge computing," *Computer*, vol. 49, no. 5, pp. 78-81, 2016.
- [15] U. Drolia, K. Guo, J. Tan, R. Gandhi, and P. Narasimhan, "Cachier: Edge-caching for recognition applications," in *2017 IEEE 37th International Conference on Distributed Computing Systems (ICDCS)*. IEEE, 2017, pp. 276-286.