

A Novel Hybrid Quantum-Classical Optimization Approach for Next-Generation Internet of Things Networks

Shahrzad Sedaghat^{1*}, Mahdi Azadi Motlagh², Amirhossein Jahangir³

¹ Department of Computer Engineering, Faculty of Engineering, Jahrom University, Jahrom, Iran

² Department of Computer Engineering, Jam Faculty of Engineering, Persian Gulf University, Bushehr, Iran

³ Department of Computer Engineering, Sharif University of Technology, Tehran, Iran

Received: 18 October 2025, Revised: 31 January 2026, Accepted: 19 April 2026

Paper type: Research

Abstract

The exponential growth of the Internet of Things (IoT) has introduced significant computational challenges, particularly in optimizing dynamic task allocation within hybrid edge, fog, and cloud networks. The combinatorial nature of this problem often leads to a combinatorial explosion when traditional algorithms are applied to large-scale scenarios, rendering them inefficient in finding optimal or near-optimal solutions. This research proposes a novel quantum-classical hybrid combinatorial optimization framework to address this multi-objective problem, considering conflicting criteria such as latency, energy consumption, and Quality of Service (QoS). The proposed model transforms the task allocation problem into a Quadratic Unconstrained Binary Optimization (QUBO) formulation and leverages the Quantum Approximate Optimization Algorithm (QAOA) for its solution. Numerical simulation results, obtained using the open-source Qiskit simulator, demonstrate that the proposed approach significantly outperforms prior methods based on quantum machine learning and traditional architectures. Comparative analysis reveals that the proposed approach consistently maintains the best solution quality with the gentlest degradation slope as the problem scales. Furthermore, the computational time of this method exhibits a much slower, near-linear growth, in contrast to the exponential growth experienced by traditional algorithms. These findings clearly establish the strategic superiority of quantum optimization for solving complex and large-scale optimization problems in next-generation IoT networks.

Keywords: Internet of Things, Fog Computing, Dynamic Task Allocation, Quantum Optimization, Latency, Energy Consumption, Quality of Service.

* Corresponding Author's email: shsedaghat@jahromu.ac.ir

ارائه روش بهینه‌سازی ترکیبیاتی نوین با رویکرد کوانتومی در شبکه‌های اینترنت اشیاء نسل آینده

شهرزاد صداقت^{۱*}، مهدی آزادی مطلق^۲، امیرحسین جهانگیر^۳

^۱ گروه مهندسی کامپیوتر، دانشکده مهندسی، دانشگاه جهرم، جهرم، ایران

^۲ گروه مهندسی کامپیوتر، دانشکده مهندسی جم، دانشگاه خلیج فارس، بوشهر، ایران

^۳ دانشکده مهندسی کامپیوتر، دانشگاه صنعتی شریف، تهران، ایران.

تاریخ دریافت: ۱۴۰۴/۰۷/۲۶ تاریخ بازبینی: ۱۴۰۴/۱۱/۱۱ تاریخ پذیرش: ۱۴۰۵/۰۱/۳۰

نوع مقاله: پژوهشی

چکیده

اینترنت اشیاء (IoT) با رشد تصاعدی خود، چالش‌های محاسباتی عظیمی را در زمینه بهینه‌سازی تخصیص وظایف پویا در شبکه‌های ترکیبی لبه، مه و ابری به وجود آورده است. ماهیت ترکیبیاتی این مسئله باعث می‌شود که الگوریتم‌های سنتی در مقیاس‌های بزرگ با پدیده انفجار ترکیبیاتی (Combinatorial Explosion) مواجه شوند و در یافتن راه‌حل بهینه یا حتی نزدیک به بهینه، ناکارآمد باشند. در این پژوهش، یک چارچوب بهینه‌سازی ترکیبی کوانتومی-سنتی برای حل این مسئله چندهدفه با در نظر گرفتن معیارهای متضاد مانند تأخیر، مصرف انرژی و کیفیت خدمات (QoS) ارائه شده است. مدل پیشنهادی در این مقاله، مسئله تخصیص وظایف را به فرمول‌بندی بهینه‌سازی دودویی نامقید درجه دوم (QUBO) تبدیل می‌کند و از الگوریتم بهینه‌سازی تقریبی کوانتومی (QAOA) برای حل آن بهره می‌برد. نتایج شبیه‌سازی عددی، که با استفاده از شبیه‌ساز متن‌باز Qiskit انجام شده است، نشان می‌دهد که رویکرد پیشنهادی در مقایسه با روش‌های پیشین مبتنی بر یادگیری ماشین کوانتومی و معماری‌های سنتی، عملکردی به مراتب بهتر ارائه می‌دهد. تحلیل مقایسه‌ای نشان می‌دهد که رویکرد پیشنهادی به طور مداوم بهترین کیفیت راه‌حل را با ملایم‌ترین شیب کاهش، با افزایش مقیاس مسئله، حفظ می‌کند. همچنین، زمان محاسباتی این روش دارای رشدی بسیار آهسته‌تر و نزدیک به خطی است، در حالی که الگوریتم‌های سنتی با رشد نمایی مواجه هستند. این نتایج به وضوح برتری راهبردی بهینه‌سازی کوانتومی را برای حل مسائل بهینه‌سازی پیچیده و بزرگ‌مقیاس در شبکه‌های نسل آینده IoT اثبات می‌کند.

کلیدواژگان: اینترنت اشیاء، محاسبات مه، تخصیص وظایف پویا، بهینه‌سازی کوانتومی، تأخیر، مصرف انرژی، کیفیت خدمات.

* رایانامه نویسنده مسؤول: shsedaghat@jahromu.ac.ir

۱- مقدمه

اینترنت اشیا با اتصال میلیاردها دستگاه هوشمند و تولید انبوه داده، تحولی اساسی در صنایع و زندگی ایجاد کرده است. این رشد، علاوه بر فرصت‌های بزرگ، چالش‌های محاسباتی عظیمی به همراه دارد. مهم‌ترین چالش در این زمینه، مدیریت و بهینه‌سازی منابع در مقیاسی بی‌سابقه است. تخصیص بهینه وظایف محاسباتی به گره‌های پردازشی (لبه (Edge)، مه (Fog) و ابر (Cloud))، مسیریابی داده‌ها و مدیریت مصرف انرژی، همگی ماهیتی ترکیباتی (Combinatorial) دارند و با افزایش دستگاه‌ها و وظایف، فضای جستجو به صورت نمایی رشد می‌کند که به آن انفجار ترکیباتی می‌گویند [۱]. همان‌طور که شکل ۱ نشان می‌دهد، پیچیدگی بهینه‌سازی در IoT تابعی از پارامترهای متعددی همچون تعداد دستگاه‌ها، حجم داده است که با افزایش آنها و توجه به معیارهای کیفیت خدمات (تأخیر، انرژی و ...) منتج به گسترش سریع و غیرخطی فضای جستجو شده و حل بهینه را برای الگوریتم‌های سنتی دشوار می‌سازد. الگوریتم‌های سنتی روی رایانه‌های سنتی، در چنین مقیاسی ناکارآمدند؛ یا در زمان معقول به جواب نمی‌رسند یا به راه‌حل‌های ابتکاری و زیربهینه اکتفا می‌کنند که برای کاربردهای حساس و بی‌درنگ IoT مناسب نیست. این محدودیت محاسبات سنتی، گلوگاهی جدی برای تحقق کامل ظرفیت‌های اینترنت اشیا است.

این مقاله، بهینه‌سازی کوانتومی را به عنوان یک الگوی محاسباتی نوین و راهکاری راهبردی برای غلبه بر این «دیوار پیچیدگی» معرفی می‌کند. محاسبات کوانتومی با بهره‌گیری از اصول مکانیک کوانتوم، مانند برهم‌نهی (Superposition) و درهم‌تنیدگی (Entanglement)، قابلیت حل مسائل بهینه‌سازی ترکیباتی را با سرعتی بسیار فراتر از توانایی قدرتمندترین ابرکامپیوترهای موجود ارائه می‌دهد. هدف اصلی این پژوهش، ارائه یک چارچوب محاسباتی ترکیبی (مختلط) سنتی-کوانتومی است که مسئله تخصیص پویای وظایف در شبکه‌های IoT را به یک مدل بهینه‌سازی قابل حل توسط کامپیوترهای کوانتومی تبدیل می‌کند.

۱-۱- طرح مسئله

در اکوسیستم‌های نوین اینترنت اشیا، به ویژه در معماری‌های مبتنی بر محاسبات مه (Fog Computing)، تصمیم‌گیری تخصیص وظایف محاسباتی (مانند پردازش جریان ویدیویی یا تحلیل داده‌های یک حسگر) میان گره‌های مختلف (لبه، مه یا ابری) یک چالش اساسی است. این تصمیم باید به صورت پویا و با در نظر گرفتن

اهداف گاه تضاد انجام شود. اهداف کلیدی عبارتند از:

- بهینه‌سازی منابع و شبکه: تخصیص بهینه پهنای باند و منابع پردازشی برای به حداقل رساندن تأخیر (Latency) در پردازش و انتقال داده‌ها.
- مدیریت و تحلیل کلان داده‌ها (Big Data): پردازش کارآمد حجم عظیم داده‌های تولیدی برای تحلیل و تصمیم‌های بی‌درنگ، با حداقل مصرف انرژی
- پیچیدگی سیستم‌های سایبرفیزیکی (CPS): هماهنگ‌سازی عملکرد هزاران جزء فیزیکی و دیجیتال برای دستیابی به یک هدف کلی، مانند مدیریت هوشمند ترافیک همراه با تضمین کیفیت خدمات (QoS)

فضای جستجو برای یافتن تخصیص بهینه منابع، مسیریابی داده‌ها و هماهنگ‌سازی عملکرد در چنین مقیاسی، فراتر از توانایی‌های محاسباتی متعارف است. الگوریتم‌های سنتی معمولاً یا به راه‌حل‌های غیربهینه بسنده می‌کنند یا برای یافتن پاسخ بهینه نیازمند زمان‌های غیر عملیاتی هستند. بنابراین تبدیل این چالش عملیاتی به یک مسئله بهینه‌سازی ریاضی قابل حل امری حیاتی است.

فرضیه اصلی: بهینه‌سازی کوانتومی به عنوان یک راهکار راهبردی با توجه به محدودیت‌های اساسی محاسبات متعارف، این مقاله فرض می‌کند که بهره‌گیری از بهینه‌سازی کوانتومی می‌تواند راه‌حل مؤثری برای مسائل ترکیباتی بزرگ مقیاس در IoT باشد که به عنوان گلوگاه اصلی کارایی، مقیاس‌پذیری و هوشمندی IoT عمل می‌کنند. چنین رویکردی با استفاده از اصول مکانیک کوانتومی، فضای جستجوی عظیم را به صورت موازی کاوش کرده و راه‌حل‌های بهینه یا نزدیک به بهینه را برای مسائل ظاهراً «غیرقابل حل» به دست می‌آورد.

بنابراین، این موضوع صرفاً یک چالش فنی نیست، بلکه یک ضرورت راهبردی برای آینده اینترنت اشیا است. هدف مقاله، ارائه یک چارچوبی برای ادغام بهینه‌سازی کوانتومی در معماری و مدیریت نسل آینده اینترنت اشیا است که مسئله پیچیده و چندهدفه تخصیص پویای وظایف (Dynamic Task Allocation) را به مدل QUBO تبدیل می‌کند تا بتوان آن را به صورت مستقیم بر روی پردازنده‌های کوانتومی، به‌ویژه با استفاده از الگوریتم‌هایی مانند الگوریتم بهینه‌سازی تقریبی کوانتومی (QAOA)، پیاده‌سازی شود. این رویکرد راه را برای مدیریت بهینه و مقیاس‌پذیر اکوسیستم‌های IoT هموار می‌سازد.

که الگوهای محاسباتی مختلفی مانند رایانش کوانتومی، لبه، و ابری را با هم ترکیب می‌کنند.

۲. رویکردهای کوانتومی برای بهینه‌سازی مصرف انرژی: در این قسمت، تمرکز روی راهکارهایی است که از اصول رایانش کوانتومی برای کاهش مصرف انرژی در شبکه‌های IoT استفاده می‌کنند.

۳. کاهش تأخیر و زمان‌بندی هوشمند وظایف با الهام از کوانتوم: این بخش پژوهش‌هایی را مرور می‌کند که با الهام از رایانش کوانتومی، به دنبال کاهش تأخیر و بهبود زمان‌بندی وظایف در شبکه‌های IoT هستند.



شکل ۱. پیچیدگی بهینه‌سازی در IoT با رشد پارامترهای سیستم

ساختار مقاله به شرح زیر سازماندهی شده است: در بخش دوم، مروری جامع از پژوهش‌های مرتبط صورت می‌گیرد تا محدودیت‌های رویکردهای موجود و شکاف‌های تحقیقاتی در زمینه بهینه‌سازی ترکیبیاتی در شبکه‌های اینترنت اشیا مشخص شود. در بخش سوم، چارچوب ریاضی پیشنهادی برای مسئله بهینه‌سازی چندهدفه تخصیص پویا وظایف ارائه خواهد شد که به تفصیل نشان می‌دهد چگونه مسئله پیچیده مورد نظر به یک مدل QUBO تبدیل می‌شود تا برای حل با الگوریتم‌های کوانتومی مناسب باشد. بخش چهارم به جزئیات پیاده‌سازی چارچوب می‌پردازد و پارامترهای سیستم، وظایف و الگوریتم بهینه‌سازی کوانتومی مورد استفاده در شبیه‌سازی را معرفی می‌کند. همچنین این بخش نتایج شبیه‌سازی‌ها به دقت تحلیل و عملکرد رویکرد پیشنهادی با سایر روش‌های مرسوم مقایسه می‌شود تا برتری آن در مقیاس‌پذیری و کیفیت راه‌حل به اثبات رسد. در پایان، بخش پنجم جمع‌بندی نتایج و مسیرهای آتی پژوهش را ارائه می‌کند.

۲- مرور پژوهش‌های پیشین

این قسمت یک مرور کلی از پژوهش‌های پیشین در مورد اینترنت اشیا، رایانش مه و رایانش کوانتومی ارائه می‌دهد. بررسی جامع این پژوهش‌ها نشان می‌دهد پژوهشگران برای غلبه بر چالش‌های موجود در اینترنت اشیا، به ترکیب رویکردهای مختلف روی آورده‌اند. از جمله این رویکردها می‌توان به ترکیب رایانش مه و رایانش ابری اشاره کرد که منجر به توسعه چارچوب‌ها و الگوریتم‌های جدیدی برای بهینه‌سازی عملکرد سیستم‌ها شده است. در ادامه، سه زمینه کلیدی بررسی می‌شود:

۱. معماری‌های ترکیبی نوین برای نسل آینده اینترنت اشیا: این بخش به بررسی چارچوب‌ها و معماری‌های جدیدی می‌پردازد

۲-۱- معماری‌های ترکیبی نوین برای نسل آینده اینترنت اشیا

در راستای توسعه ساختارهای کارآمد برای اینترنت اشیا، پژوهشگران به ترکیب الگوهای محاسباتی مختلف پرداخته‌اند تا بر چالش‌های موجود غلبه کنند. در همین زمینه، ماهپاترا و همکارانش [۲] چارچوب چندلایه‌ای به نام DIFCoT را برای هماهنگ‌سازی وظایف در محیط‌های IoT ارائه کردند که چالش‌های رایانش مه و ابر را مورد توجه قرار دادند. آنها یک الگوریتم Q-FogSched مبتنی بر QML را برای زمان‌بندی بهینه وظایف توسعه دادند که به‌طور همزمان چندین پارامتر متضاد QoS را بهینه‌سازی می‌کرد و با تمرکز بر کاهش تأخیر، مصرف انرژی و هزینه خدمات، دیدگاهی جامع‌تر از مطالعات پیشین ارائه داد. استفاده از یادگیری ماشین کوانتومی (QML) نیز یک نوآوری قابل توجه است که امکان جستجوی کارآمدتر در فضای راه‌حل‌ها را فراهم کرد. با این حال پیچیدگی محاسباتی الگوریتم و وابستگی عملکرد مدل به کیفیت داده‌های آموزشی، پیاده‌سازی آن را در مقیاس بزرگ یا در گرہ‌های لبه با منابع محدود دشوار می‌سازد.

در تحقیقی دیگر، حسین و همکاران [۳] برای غلبه بر چالش‌های محاسبات ابری سنتی از جمله تأخیر بالا و آسیب‌پذیری‌های امنیتی، الگوی محاسبات ابری کوانتومی لبه (QECC) را معرفی کردند. این معماری با ترکیب توان محاسبات کوانتومی، تأخیر پایین لبه و مقیاس‌پذیری ابر، چارچوبی یکپارچه و نوآورانه ارائه داد. از نقاط قوت این پژوهش، عدم محدود شدن پژوهش به مباحث نظری و ارائه شواهد تجربی از مطالعات واقعی در بنگلادش بود. با این حال، تمرکز محدود بر یک منطقه جغرافیایی و چند حوزه صنعتی خاص و اتکای زیاد به فناوری کوانتومی در حال توسعه، قابلیت تعمیم و پیاده‌سازی عملی مدل را کاهش می‌داد.

۲-۳- کاهش تأخیر و زمان‌بندی هوشمند وظایف با

الهام از محاسبات مکانیک، فیزیک کوانتومی

کاهش تأخیر در کاربردهای حساس به زمان از اهداف کلیدی پژوهش‌های اخیر است. زنبوری و همکاران [۸] طرحی برای زمان‌بندی داده‌های چندرسانه‌ای در شبکه‌های اینترنت اشیا چندرسانه‌ای (IoMT) ارائه کردند که بر پایه معماری محاسبات مه رویکرد ترکیبی مبتنی بر سیستم استنتاج فازی با الگوریتم ژنتیک کوانتومی (QGA) عمل می‌کند. رویکرد آنان با ادغام سه فناوری پیشرفته، چندین معیار عملکردی را به‌طور هم‌زمان بهینه‌سازی می‌کند. با این حال، بی‌توجهی به مصرف انرژی و عملکرد بهتر الگوریتم ژنتیک استاندارد (GA) نسبت به روش پیشنهادی در ارزیابی تأخیر انتقال، از نقاط ضعف روش پیشنهادی است. حسن و همکاران [۹] چارچوبی مبتنی بر ادغام یادگیری عمیق و رایانش کوانتومی برای مدیریت ذخیره‌سازی موقت (Caching) در لبه‌ی شبکه‌های حسگر مبتنی بر محاسبات مه پیشنهاد دادند. نوآوری اصلی آن‌ها، ادغام یادگیری عمیق برای اولویت‌بندی محتوا و پدیده‌های کوانتومی برای ذخیره‌سازی بهینه در یک چارچوب واحد است. اتکای کامل به شبیه‌سازی کوانتومی به دلیل نبود سخت‌افزار واقعی و نبود تحلیل مصرف انرژی، از مهم‌ترین نقاط ضعف آن است.

آهنگر و همکاران [۱۰] یک رویکرد نوین بهینه‌سازی وظایف مبتنی بر الهام از محاسبات کوانتومی را برای محیط‌های محاسبات لبه-مه اینترنت اشیا ارائه دادند. این مدل با ترکیب الگوریتم‌های کوانتومی و شبکه‌های عصبی، چندین معیار از جمله تأخیر و انرژی را هم‌زمان بهینه‌سازی می‌کند. نقطه‌ضعف پژوهش در ماهیت شبیه‌سازی‌شده الگوریتم‌ها و اجرای آن‌ها بر سخت‌افزار سنتی به جای رایانه‌های کوانتومی است. اتکای نتایج به محیط شبیه‌سازی شده نیز قابلیت تعمیم نتایج در محیط‌های واقعی را کاهش می‌دهد.

بهاتیا و همکاران [۱۱] به چالش زمان‌بندی بار در محیط‌های محاسبات مه برای کاربردهای IoT پرداختند. آنها یک تکنیک بهینه‌سازی زمان‌بندی بار مبتنی بر محاسبات کوانتومی (QCi) و یک مدل پیش‌بین مبتنی بر شبکه عصبی کوانتومی (QCi-NN) توسعه دادند. نقطه قوت این پژوهش ایجاد یک چارچوب قدرتمند برای زمان‌بندی بار با ترکیب بهینه‌سازی کوانتومی با یک مدل پیش‌بین است. نادیده گرفتن جنبه‌های امنیتی و اعتماد در یک محیط توزیع‌شده و فاصله گرفتن از پیچیدگی‌های دنیای واقعی با نادیده گرفتن تأخیر شبکه از نقاط ضعف آن است.

اختر و همکاران [۴] نیز در ادامه همین رویکرد، مدل QECC را به‌عنوان الگوی نوین محاسباتی برای IoT معرفی کردند. پژوهش آن‌ها با ادغام سه فناوری کوانتومی، لبه و ابر، چارچوبی جامع برای مقابله با محدودیت‌های محاسبات ابری سنتی ارائه داد و مزایای هر فناوری را در پوشش نقاط ضعف دیگر تبیین کرد. ضعف اصلی پژوهش، به ماهیت نوظهور فناوری‌های کوانتومی و اتکای داده‌های تجربی به یک منطقه خاص جغرافیایی بازمی‌گردد که موجب کاهش تعمیم‌پذیری نتایج و چالش‌های اجرایی در سطح سخت‌افزار و هزینه می‌شود. در نگاهی جامع‌تر، نارنگ و همکاران [۵] در پژوهش خود، به بررسی اصول، چالش‌ها و تعاملات متقابل الگوهای محاسبات کوانتومی، ابری و مه پرداختند. آنها نقش محاسبات مه را به‌عنوان یک الگوی توزیع‌شده برای نزدیک‌تر کردن پردازش به لبه شبکه در کاربردهای IoT را نشان دادند. نقطه قوت این پژوهش در گستردگی و جامعیت آن در سه حوزه فناوری است که آن را به منبع مروری ارزشمند برای محققان تبدیل می‌کند. با این حال، تمرکز بر جنبه‌های توصیفی و نبود مدل تحلیلی یا تجربی عمیق، از محدودیت‌های آن به شمار می‌رود.

۲-۲- رویکردهای کوانتومی برای بهینه‌سازی مصرف

انرژی

محمودی و همکاران [۶] برای مقابله با چالش مصرف انرژی در شبکه‌های IoT، الگوریتمی ابتکاری با الهام از محاسبات کوانتومی جهت انتخاب بهینه سرخوشه‌ها ارائه کردند. در این روش، مفاهیم الگوریتم کرم‌شب‌تاب و بهینه‌سازی ازدحام ذرات (PSO) در چارچوبی کوانتومی ترکیب شده‌اند. مهم‌ترین دستاورد پژوهش، ارائه رویکردی نوآورانه در ترکیب بهینه‌سازی کوانتومی با الگوریتم‌های ابتکاری است. نقطه‌ضعف اصلی این کار، تمرکز تک‌هدفه بر مصرف انرژی و عدم توجه به پارامترهایی نظیر تأخیر و QoS در تابع هدف بهینه‌سازی برای کاربرد در شبکه‌های مدرن IoT باشد.

جانو و همکاران [۷] نیز مسئله مصرف بالای انرژی در IoT را بررسی کردند و الگوریتمی خوشه‌بندی و مسیریابی مبتنی بر بهینه‌سازی کلونی مورچگان (ACO) ارائه دادند که با بهره‌گیری از مفاهیم محاسبات کوانتومی، فرآیند تصمیم‌گیری را بهبود می‌بخشد. نقطه قوت پژوهش، ادغام مفاهیم بهینه‌سازی کوانتومی در ACO بود که توانایی یافتن راه‌حل‌های بهتر از روش‌های سنتی را نشان داد. با این حال، تمرکز بیش‌ازحد بر کاهش انرژی و بی‌توجهی به معیارهای QoS مانند نرخ تحویل بسته و تأخیر، کاربرد آن را در سناریوهای حساس به زمان محدود می‌سازد.

۳- روش‌شناسی، تحلیل و طراحی چارچوب ریاضی بهینه‌سازی چندهدفه پویا پیشنهادی در شبکه‌های IoT با رویکرد کوانتومی

در این بخش، چارچوب پیشنهادی پژوهش به صورت نظام‌مند معرفی می‌گردد. هدف اصلی، ارائه‌ی مدلی ریاضی-کوانتومی برای حل مسئله‌ی تخصیص پویا و چندهدفه‌ی وظایف در بستر اینترنت اشیاء است؛ مسئله‌ای که به دلیل ماهیت ترکیباتی و ابعاد مقیاس‌پذیر آن، در چارچوب روش‌های سنتی بهینه‌سازی با محدودیت‌های جدی مواجه است. بدین منظور، ابتدا ساختار معماری پیشنهادی تبیین می‌شود و در ادامه، فرمول‌بندی ریاضی و کوانتومی آن ارائه خواهد شد. به منظور ایجاد شفافیت و انسجام در ارائه‌ی مدل، مجموعه‌ی نمادها و پارامترهای به کاررفته در این پژوهش در جدول ۲ گردآوری شده است. در ادامه، نخست، معماری پیشنهادی شامل لایه‌های دستگاه، شبکه، محاسبات مه، هماهنگ‌سازی سنتی و پردازش کوانتومی معرفی و نقش هر یک در فرایند بهینه‌سازی تبیین می‌گردد. سپس، فرمول‌بندی ریاضی مسئله‌ی بهینه‌سازی چندهدفه به همراه قیود اصلی آن ارائه می‌شود و چگونگی تبدیل این مدل به قالب QUBO و ساخت هامیلتونی‌نهایی تشریح خواهد شد. در نهایت، فرآیند حل مسئله با استفاده از الگوریتم تقریب‌زنی کوانتومی QAOA در چارچوب مختلط سنتی-کوانتومی تبیین می‌شود.

۳-۱- چارچوب کلی روش‌شناسی پژوهش پیشنهادی

دستورکار راهبردی در حوزه اینترنت اشیاء، بر چالش‌های مهندسی مانند سرعت پردازش، طراحی و اعتبارسنجی سیستم‌ها تمرکز دارد. با این حال، با افزایش نمایی تعداد دستگاه‌ها، هر یک از این «موانع فنی» به یک مسئله بهینه‌سازی در مقیاس عظیم تبدیل می‌شود. برای مثال، مدیریت منابع در شبکه‌ای با میلیاردها گره، دیگر یک مسئله مهندسی صرف نیست، بلکه یک مسئله بهینه‌سازی منابع شبکه با پیچیدگی غیرقابل تصور است.

مسئله اساسی این است که با افزایش تعداد اشیاء و تعاملات میان آن‌ها، پیچیدگی سیستم به صورت انفجار ترکیباتی رشد می‌کند. بهینه‌سازی عملکرد یک اکوسیستم IoT، با میلیون‌ها متغیر وابسته به هم، یک چالش اساسی است. الگوریتم‌های بهینه‌سازی سنتی، در مواجهه با چنین فضای جستجوی وسیعی، یا به زمان بسیار زیادی برای یافتن راه‌حل بهینه نیاز دارند یا به روش‌های ابتکاری متوسل می‌شوند که بهترین پاسخ را تضمین نمی‌کنند. این «دیوار

پیچیدگی» یک مانع بنیادین است که کارایی سیستم‌های نسل آینده IoT را به شدت محدود می‌سازد و ما برای عبور از آن، به یک الگو محاسباتی کاملاً جدید نیازمندیم.

جدول ۲. معرفی نمادها و پارامترهای ریاضی به کار رفته در

روش‌شناسی و چارچوب ریاضی پیشنهادی

دسته	نماد	توضیح
پارامترهای سیستم	t	بازه‌های زمانی گسسته که سیستم در آن عمل می‌کند
	T	مجموعه‌ی کامل وظایف که باید پردازش شوند
	N	مجموعه‌ی گره‌های محاسباتی شامل دستگاه‌های لبه، مه و ابری
پارامترهای وظایف	W_i	حجم کاری محاسباتی وظیفه‌ی T_i بر حسب میلیون دستورالعمل
	d_i	حجم داده‌ی ورودی برای وظیفه‌ی T_i بر حسب مگابایت
	θ_i^{max}	حداکثر تأخیر یا مهلت زمانی قابل قبول برای تکمیل وظیفه‌ی T_i
پارامترهای گره	$\varphi_j(t)$	ظرفیت پردازشی گره V_j در بازه‌ی زمانی t
	ε_j	هزینه‌ی انرژی به ازای هر واحد محاسباتی روی گره V_j
پارامترهای شبکه	$B_{jk}(t)$	پهنای باند موجود بین گره‌های V_k و V_j در بازه‌ی زمانی t وابسته به زمان
	$\lambda_{jk}(t)$	تأخیر ارتباطی بین گره‌های V_k و V_j در بازه‌ی زمانی t
متغیر تصمیم‌گیری	$z_{ij}(t)$	متغیر دودویی: اگر وظیفه‌ی T_i به گره V_j در زمان t تخصیص یابد، مقدار آن ۱ است، در غیر این صورت صفر
توابع هدف	H_l	تابع هزینه‌ی تأخیر کل، شامل زمان انتقال داده و پردازش
	H_e	تابع هزینه‌ی انرژی کل مصرفی برای پردازش وظایف
	H_{QoS}	تابع جریمه QoS که تأخیر بیش از مهلت زمانی را جریمه می‌کند
	H_{obj}	تابع هدف کلی که از ترکیب وزنی توابع تأخیر، انرژی و کیفیت خدمات تشکیل شده است
جملات جریمه (قیود)	Π_{uniq}	قید تخصیص یکتا: جریمه‌ای برای تضمین اینکه هر وظیفه دقیقاً به یک گره تخصیص یابد.
	Π_{cap}	قید ظرفیت گره: جریمه‌ای برای جلوگیری از تخصیص حجم کاری بیش از ظرفیت یک گره
مولفه‌های کوانتومی	H_{QUBO}	هامیلتونی‌نهایی QUBO. ترکیب تابع هدف کلی و جملات جریمه
	H_p	هامیلتونی‌ن مسئله آپزینگ: فرمت نهایی مسئله که به الگوریتم کوانتومی داده می‌شود
	H_M	هامیلتونی‌ن ترکیب‌کننده: عملکردی در الگوریتم QAOA برای کاوش در فضای راه‌حل‌ها
	$ \psi(\gamma, \beta)\rangle$	حالت کوانتومی آزمایشی که به مجموعه‌ای از پارامترهای قابل تنظیم γ و β وابسته است.
	γ, β	بردارهای پارامترهای قابل تنظیم (زوایا)
	P	عمق مدار کوانتومی (تعداد لایه‌ها)

۳-۱-۱- مرحله اول: تحلیل معماری

برای درک عمیق‌تر چالش‌ها، باید معماری لایه‌ای IoT را تحلیل کنیم. این معماری به طور کلی شامل لایه‌هایی است که هر یک چالش‌های بهینه‌سازی خاص خود را دارند که مستقیماً به مدل‌سازی ریاضی این پژوهش مرتبط است:

- لایه دستگاه (Device Layer): این لایه شامل اشیاء فیزیکی، حسگرها و عملگرهاست. این دستگاه‌ها منشأ تولید وظایف هستند که نیازمند پردازش می‌باشند. هر وظیفه $T(i)$ دارای مشخصاتی مانند حجم کاری محاسباتی (W_i) و حجم داده ورودی (d_i) است. چالش اصلی در این لایه، مدیریت انرژی و ارتباطات کم‌مصرف در دستگاه‌های ناهمگون است.
- لایه شبکه (Network Layer): این لایه مسئولیت اتصال و انتقال داده‌ها را بر عهده دارد. چالش‌های کلیدی آن که مستقیماً در مدل ما لحاظ شده‌اند، شامل مقیاس‌پذیری عظیم و مدیریت منابع شبکه است. پهنای باند موجود بین گره‌های محاسباتی ($B_{jk}(t)$) و تأخیر ارتباطی ($\lambda_{jk}(t)$) پارامترهای پویایی هستند که باید در بهینه‌سازی تخصیص وظایف برای کاهش تأخیر کل (H_i) در نظر گرفته شوند.
- لایه پشتیبانی از خدمات (Service Support Layer): این لایه که اغلب در قالب معماری محاسبات مه پیاده‌سازی می‌شود، خدمات محاسباتی را برای برنامه‌های کاربردی فراهم می‌کند. این لایه شامل مجموعه‌ای از گره‌های محاسباتی (N) شامل دستگاه‌های لبه، گره‌های مه و سرورهای ابری با ظرفیت‌های پردازشی ($\Phi_j(t)$) و هزینه‌های انرژی (ε_j) متفاوت و متغیر در زمان است. چالش اصلی در این لایه، تصمیم‌گیری بهینه برای تخصیص هر وظیفه به مناسب‌ترین گره محاسباتی است تا اهداف چندگانه (انرژی، تأخیر و کیفیت خدمات) به طور همزمان بهینه شوند.
- لایه کاربرد (Application Layer): این لایه شامل برنامه‌های نهایی است که نیازمندی‌های کیفی را تعریف می‌کند. برای مثال، یک برنامه سلامت هوشمند ممکن است برای وظایف تحلیل داده‌های حیاتی خود، یک مهلت زمانی (حداکثر تأخیر قابل قبول $\theta^{\max}$) داشته باشد. این نیازمندی در مدل ما توسط تابع جریمه کیفیت خدمات (H_{QoS}) نمایندگی می‌شود تا اطمینان حاصل شود که راه‌حل‌های بهینه، این محدودیت‌های عملیاتی را برآورده می‌کنند.

۳-۱-۲- مرحله دوم: فرمول‌بندی ریاضی و تبدیل به

QUBO

تحلیل معماری لایه‌ای IoT نشان می‌دهد که چالش اصلی، یک مسئله بهینه‌سازی ترکیبی پیچیده است: تخصیص پویای وظایف چندهدفه (Dynamic Multi-Objective Task Allocation). با وجود میلیاردها دستگاه که به طور مداوم وظایف پردازشی تولید می‌کنند، یافتن پیکربندی بهینه برای تخصیص این وظایف به گره‌های محاسباتی (به منظور حداقل کردن تأخیر، مصرف انرژی و رعایت کیفیت خدمات) یک چالش عظیم است.

چالش سنتی: این مسئله را می‌توان به عنوان یک مسئله بهینه‌سازی با متغیرهای تصمیم‌گیری دودویی ($z_{ij}(t)$) فرمول‌بندی کرد. فضای جستجوی این مسئله به صورت نمایی با افزایش تعداد وظایف و گره‌ها رشد می‌کند. الگوریتم‌های سنتی در این مقیاس، به دلیل حجم عظیم محاسبات، ناکارآمد بوده و به راه‌حل‌های تقریبی و ناکارآمد بسنده می‌کنند.

راه‌حل کوانتومی: این پژوهش، مسئله بهینه‌سازی فوق را به صورت یک مدل QUBO فرمول‌بندی می‌کند. این فرمول‌بندی، که تابع هدف کلی (H_{obj}) و قیود مسئله (مانند تخصیص یکتا و ظرفیت گره) را در یک هامیلتونین واحد (H_{QUBO}) ترکیب می‌کند، ذاتاً برای حل توسط الگوریتم‌های کوانتومی مناسب است. الگوریتم‌هایی مانند QAOA قادرند فضای راه‌حل‌های بسیار بزرگ این مسائل را به طور همزمان کاوش کرده و راه‌حل‌های نزدیک به بهینه را با سرعتی بسیار بالاتر از روش‌های سنتی بیابند. این رویکرد، راه را برای مدیریت کارآمد و هوشمند منابع در مقیاس عظیم اکوسیستم‌های آینده اینترنت اشیاء هموار می‌سازد.

برای روشن‌تر شدن مراحل اصلی این رویکرد مختلط کوانتومی-سنتی، شکل ۲ روندنا جامعی از فرآیند تبدیل مسئله به فرمول QUBO و سپس حل آن با استفاده از الگوریتم QAOA را به تصویر می‌کشد.

۳-۲- معماری پیشنهادی شبکه: سیستم مختلط

اینترنت اشیاء-مه-ابر با قابلیت بهینه‌سازی کوانتومی

این معماری از پنج لایه اصلی تشکیل شده است که هر یک وظایف مشخصی را بر عهده دارند و به صورت یکپارچه با یکدیگر در ارتباط هستند تا مسئله پیچیده «تخصیص پویای وظایف چندهدفه» را حل کنند.


- اجزاء: زیرساخت‌های ارتباطی متنوع مانند 5G/6G، Wi-Fi، LoRaWAN و شبکه‌های سیمی.
- مدل‌سازی پویایی شبکه: این لایه وضعیت پویای شبکه را که در مدل ریاضی با پارامترهای وابسته به زمان تعریف شده، نمایندگی می‌کند: پهنای باند موجود بین گره‌ها ($B_{jk}(t)$) و تأخیر ارتباطی ($\lambda_{jk}(t)$).
- اهمیت در تابع هدف: این پارامترها مستقیماً در محاسبه بخش انتقال داده از تابع هزینه تأخیر کل (H_1) استفاده می‌شوند و نقشی حیاتی در بهینه‌سازی دارند.

لایه ۳: لایه محاسبات مه (Fog Computing / Service Support Layer): این لایه، یک سطح میانی از منابع پردازشی توزیع شده است که بین لایه دستگاه و ابر قرار دارد و برای کاهش تأخیر و پردازش بی‌درنگ طراحی شده است.

- اجزاء: مجموعه‌ای از گره‌های مه و سرورهای لایه قدرتمند. در مدل پیشنهادی، این‌ها بخشی از مجموعه گره‌های محاسباتی (N) هستند.
- محل اجرای وظایف: این گره‌ها کاندیدای اصلی برای اجرای وظایف پردازشی هستند. تصمیم‌گیری اصلی، یعنی تخصیص وظیفه T_i به گره V_j در زمان t متغیر $z_{ij}(t)$ در این لایه اعمال می‌شود.
- منابع محاسباتی پویا: هر گره دارای ظرفیت پردازشی ($\varphi_j(t)$) و هزینه انرژی (ϵ_j) متغیر است که در توابع هزینه تأخیر (H_1) و انرژی (H_e) و همچنین قید ظرفیت گره (Π_{cap}) نقش کلیدی ایفا می‌کنند.
- اجرای سیاست: پس از اینکه راه حل بهینه توسط سیستم مشخص شد، این لایه مسئولیت دارد که سیاست تخصیص را اجرا کند.

لایه ۴: لایه هماهنگ‌سازی و بهینه‌سازی سنتی (Cloud / Classical Orchestration Layer): این لایه به عنوان مغز متفکر مرکزی سیستم عمل می‌کند. به دلیل قدرت محاسباتی بالا، وظیفه مدیریت کلان سیستم و آماده‌سازی مسئله بهینه‌سازی را بر عهده دارد.

- اجزاء: سرورهای قدرتمند و مراکز داده در ابر
- جمع‌آوری وضعیت سیستم: این لایه به طور مداوم وضعیت تمام لایه‌های زیرین را پایش می‌کند: وظایف جدید، $\varphi_j(t)$ ، $B_{jk}(t)$ و $\lambda_{jk}(t)$
- ساخت تابع هدف و قیود: با استفاده از داده‌های جمع‌آوری شده، توابع هدف چندگانه (H_e ، H_1 و H_{QoS}) و جملات جریمه (Π_{cap} و Π_{uniq}) را بر اساس فرمول‌بندی ریاضی پیشنهادی



شکل ۲. روندنمای کلی رویکرد مختلط کوانتومی-سنتی برای حل مسئله تخصیص وظایف پویا در IoT

لایه ۱، لایه دستگاه (Device Layer): این لایه، لایه فیزیکی و پایه‌ای اینترنت اشیا است که مستقیماً با دنیای واقعی در تعامل است.

- اجزاء: میلیاردها دستگاه هوشمند شامل حسگرها، عملگرها و دستگاه‌های لایه کم‌مصرف.
- تولید وظایف (Tasks): این دستگاه‌ها منشأ تولید وظایف T_i هستند. برای مثال، یک دوربین نظارت تصویری وظیفه «تحلیل جریان ویدئویی» را دارد یا یک حسگر صنعتی وظیفه «پایش ارتعاشات» را به عهده دارد.
- تولید داده: هر وظیفه دارای پارامترهای مشخصی است که در این لایه تعریف می‌شوند: حجم کاری محاسباتی W_i و حجم داده ورودی d_i .
- چالش اصلی: مدیریت انرژی و ارتباطات کم‌مصرف، همانطور که در بخش «کالبدشکافی معماری» به آن اشاره شده است.
- لایه ۲: لایه شبکه (Network Layer): این لایه مسئولیت برقراری ارتباط و انتقال داده بین تمامی گره‌های محاسباتی در لایه‌های مختلف را بر عهده دارد.

ایجاد می‌کند.

○ فرمول‌بندی هامیلتونین نهایی (QUBO): مهم‌ترین وظیفه این لایه، ترکیب تابع هدف کلی (H_{obj}) و جملات جریمه برای ساخت هامیلتونین نهایی ($H_{QUBO} = H_{obj} + p_1$) است. این فرآیند شامل تبدیل قیود غیرخطی مانند $\max(0, \dots)$ با استفاده از متغیرهای کمکی (Ancillary Variables) به یک فرمول دقیق QUBO است.

○ حلقه بهینه‌سازی سنتی: این لایه، بهینه‌سازی سنتی مانند L-BFGS-B که در متن به آن اشاره شده را اجرا می‌کند. این بهینه‌سازی پارامترهای γ و β را برای الگوریتم کوانتومی تنظیم می‌کند.

لایه ۵: پردازش کوانتومی (Quantum Processing Unit - QPU) این لایه یک منبع محاسباتی تخصصی است که برای حل مسائل بهینه‌سازی ترکیبیاتی که در لایه قبل فرمول‌بندی شده‌اند، به کار گرفته می‌شود. این لایه می‌تواند یک سرویس ابری کوانتومی (Quantum Cloud Service) باشد.

- اجزاء: یک کامپیوتر کوانتومی یا شبیه‌ساز کوانتومی که قادر به اجرای الگوریتم QAOA است.
- عملکرد (بخش کوانتومی حلقه مختلط):

۱- دریافت مسئله: هامیلتونین مسئله H_p که معادل H_{QUBO} در فرمت آیزینگ است را به همراه پارامترهای γ و β از لایه هماهنگ‌سازی دریافت می‌کند.

۲- اجرای مدار QAOA: مدار کوانتومی را برای آماده‌سازی حالت $|\psi(\gamma, \beta)\rangle$ و اندازه‌گیری مقدار مورد انتظار هامیلتونین $\langle \psi | H_p | \psi \rangle$ اجرا می‌کند. این فرآیند، کاوش همزمان در فضای جستجوی عظیم مسئله را که به دلیل انفجار ترکیبیاتی به وجود آمده، ممکن می‌سازد.

۳- بازگرداندن نتیجه: نتیجه اندازه‌گیری (یک مقدار عددی اسکالر) را به لایه هماهنگ‌سازی سنتی باز می‌گرداند.

۳-۳- جریان کاری یکپارچه و اجرای چارچوب پیشنهادی

معماری پیشنهادی بر اساس یک حلقه بهینه‌سازی مختلط عمل می‌کند که ماهیت راهبردی پژوهش را دارد:

۱. شروع چرخه: سیستم در لایه هماهنگ‌سازی (لایه ۴)

وضعیت کلی شبکه اینترنت اشیاء (لایه‌های ۱ تا ۳) را دریافت می‌کند.

۲. فرمول‌بندی سنتی: هماهنگ‌ساز مسئله تخصیص وظایف فعلی را به یک هامیلتونین H_{QUBO} تبدیل می‌کند.

۳. برون‌سپاری کوانتومی: هماهنگ‌ساز، H_{QUBO} را به پردازنده کوانتومی (لایه ۵) ارسال کرده و درخواست اجرای یک مرحله از الگوریتم QAOA با پارامترهای γ و β را می‌دهد.

۴. محاسبه کوانتومی: پردازنده کوانتومی نتیجه را محاسبه کرده و به هماهنگ‌ساز باز می‌گرداند.

۵. بهینه‌سازی سنتی: بهینه‌ساز سنتی در لایه ۴، با استفاده از نتیجه دریافت شده، پارامترهای γ و β را به‌روزرسانی می‌کند تا در مرحله بعد نتیجه بهتری حاصل شود.

۶. تکرار: مراحل ۳ تا ۵ تا زمان همگرایی و یافتن راه حل بهینه (حالتی با کمترین انرژی که متناظر با بهترین پیکربندی $Z_{ij}(t)$ است) تکرار می‌شوند.

۷. اعمال سیاست: پس از یافتن راه حل بهینه، لایه هماهنگ‌سازی این سیاست تخصیص وظایف را به گره‌های مه (لایه ۳) ابلاغ می‌کند تا اجرا شود.

۳-۴- چارچوب ریاضی بهینه‌سازی چندهدفه پویا در شبکه‌های IoT

برای فراتر رفتن از یک مدل ایستا و ساده، ما یک مسئله بهینه‌سازی تخصیص وظایف پویا و چندهدفه را در یک محیط محاسبات مه در بستر IoT مدلسازی ریاضی می‌کنیم. این مدل، تغییرات زمانی شبکه و اهداف متضاد (مانند کمینه‌سازی تأخیر و مصرف انرژی) را به طور همزمان در نظر می‌گیرد.

۳-۴-۱- تعریف پارامترها و متغیرهای سیستم

فرض کنید سیستم ما در بازه‌های زمانی گسسته $t \in \{1, 2, \dots, K\}$ عمل می‌کند.

- مجموعه وظایف: $T = \{\tau_1, \tau_2, \dots, \tau_N\}$
- مجموعه گره‌های محاسباتی: $N = \{v_1, v_2, \dots, v_M\}$ شامل دستگاه‌های لبه، گره‌های مه و سرورهای ابری

پارامترهای وظایف:

- ω_i : حجم کاری محاسباتی وظیفه τ_i مثلاً بر حسب میلیون دستورالعمل
- d_i : حجم داده ورودی برای وظیفه τ_i بر حسب مگابایت

$$H_{QoS} = \sum_t \sum_i \sum_j z_{ij}(t) \cdot \max(0, \left(\frac{d_i}{\beta_{0j}(t)}\right) + \left(\frac{\omega_i}{\phi_j(t)}\right) - \theta_i^{max}) \quad (3)$$

تابع ۳ به عنوان یک قید نرم (Soft Constraint) عمل می‌کند. استفاده از تابع $\max(0, \dots)$ تضمین می‌کند که جریمه تنها زمانی اعمال شود که زمان تکمیل وظیفه (مجموع زمان پردازش و انتقال) از مهلت زمانی مجاز (D_{max}) بیشتر شود. اگر وظیفه زودتر از مهلت تمام شود، هیچ پاداشی در نظر گرفته نمی‌شود و مقدار این جمله صفر خواهد بود. این رویکرد در بهینه‌سازی چندهدفه بسیار کارآمد است، زیرا به جای رد کامل یک راه‌حل به دلیل نقض جزئی یک قید، میزان نامطلوب بودن آن را به صورت یک هزینه کمی‌سازی کرده و به الگوریتم اجازه می‌دهد تا بین پابندی به مهلت‌های زمانی و بهینه بودن سایر اهداف (مانند انرژی و تأخیر کل) یک تعادل برقرار کند. با استفاده از روش مجموع وزنی (Weighted Sum Method)، تابع هدف کلی را می‌سازیم:

$$H_{obj} = \mu_L \cdot H_L + \mu_E \cdot H_E + \mu_Q \cdot H_{QoS} \quad (4)$$

که در آن μ_L ، μ_E و μ_Q ضرایب وزنی نرمال شده هستند که اهمیت نسبی هر هدف را مشخص می‌کنند.

۳-۴-۳- مدلسازی ریاضی قیود به عنوان جملات جریمه

برای تبدیل مسئله به فرمت QUBO، قیود باید به صورت جملات جریمه به تابع هدف اضافه شوند. الف) قید تخصیص یکتا: هر وظیفه در هر بازه زمانی باید دقیقاً به یک گره تخصیص یابد.

$$\Pi_{uniq} = \sum_i (1 - \sum_j z_{ij}(t))^2 \quad (5)$$

ب) قید ظرفیت گره: مجموع حجم کاری تخصیص یافته به یک گره نباید از ظرفیت پردازشی آن فراتر رود.

$$\Pi_{cap} = \sum_{t,j} [\max(0, \sum_i z_{ij}(t) \cdot \omega_i - \phi_j(t))^2] \quad (6)$$

معادله ۶ یک چالش کلیدی در تبدیل مسئله به فرمت QUBO را نشان می‌دهد. عبارت $[\max(0, \dots)]^2$ یک عبارت غیرخطی و غیرچندجمله‌ای است. برای تبدیل دقیق این قید به یک فرمول QUBO که تنها شامل متغیرهای دودویی و جملات درجه دوم (کوادراتیک) است، باید از متغیرهای کمکی استفاده کرد. این متغیرهای کمکی، میزان تخطی از ظرفیت پردازشی را به صورت یک نمایش باینری کدگذاری می‌کنند و به ما اجازه می‌دهند تا این قید پیچیده را به صورت یک چندجمله‌ای کوادراتیک دقیق بازنویسی کنیم. این مرحله برای اطمینان از صحت و دقت مدل QUBO نهایی ضروری است و اطمینان می‌دهد که راه‌حل‌های

- θ_i^{max} : حداکثر تأخیر قابل قبول برای تکمیل وظیفه τ_i مهلت زمانی.

پارامترهای گره‌های محاسباتی (وابسته به زمان):

- $\phi_j(t)$: ظرفیت پردازشی گره v_j در بازه زمانی t مثلاً بر حسب میلیون دستورالعمل بر ثانیه.
 - ε_j : هزینه انرژی به ازای هر واحد محاسباتی روی گره v_j
- پارامترهای شبکه (وابسته به زمان):

- $\beta_{jk}(t)$: پهنای باند موجود بین گره‌های v_j و v_k در بازه زمانی t بر حسب مگابیت بر ثانیه.
- $\lambda_{kj}(t)$: تأخیر ارتباطی بین گره‌های v_j و v_k در بازه زمانی t .

در نظر گرفتن وابستگی پارامترهای گره و شبکه به زمان $\phi_j(t)$ و $\beta_{jk}(t)$ یکی از جنبه‌های کلیدی این مدل است. این ویژگی به ما اجازه می‌دهد تا شرایط پویای یک محیط محاسبات مه واقعی را مدلسازی کنیم؛ شرایطی که در آن ظرفیت پردازشی یک گره به دلیل بارهای کاری دیگر یا پهنای باند شبکه به دلیل ترافیک متغیر، در طول زمان نوسان می‌کند. این رویکرد پویا، مدل را از تحلیل‌های ایستا فراتر برده و به بهینه‌سازی تخصیص وظایف در شرایط عملی و متغیر نزدیک‌تر می‌کند.

متغیر تصمیم‌گیری دودویی (Binary Decision Variable):

- $z_{ij}(t)$: یک متغیر دودویی است که اگر وظیفه τ_i در بازه زمانی t به گره v_j تخصیص یابد، مقدار آن یک و در غیر این صورت صفر است.

۳-۴-۲- مدلسازی ریاضی تابع هدف چندوجهی (Multi-Objective Function)

ما سه هدف متضاد را بهینه‌سازی می‌کنیم: تأخیر کل، مصرف انرژی کل و QoS. الف) تابع هزینه تأخیر کل (H_L): تأخیر کل برای یک وظیفه شامل زمان انتقال داده و زمان پردازش است.

$$H_L = \sum_{t,i,j} z_{ij}(t) \cdot \left[\frac{d_i}{\beta_{0j}(t)} + \frac{\omega_i}{\phi_j(t)} \right] \quad (1)$$

در اینجا β_{0j} پهنای باند از منبع وظیفه تا گره j است.

ب) تابع هزینه انرژی کل (H_E):

$$H_E = \sum_t \sum_i \sum_j z_{ij}(t) \cdot (\omega_i \cdot \varepsilon_j) \quad (2)$$

ج) تابع جریمه کیفیت خدمات (H_{QoS}): تابع ۲، تخصیص‌هایی را که به مهلت زمانی وظیفه نزدیک یا از آن فراتر می‌روند، جریمه می‌کند.

نهایی، ظرفیت پردازشی هیچ کدام از گره‌ها را نقض نخواهند کرد.

۴-۴-۳- ساخت هامیلتونین نهایی QUBO

هامیلتونین نهایی که باید کمینه شود، از ترکیب تابع هدف و جملات جریمه با ضرایب جریمه بزرگ (ρ_1, ρ_2) تشکیل می‌شود:

$$H_{QUBO} = H_{obj} + \rho_1 \Pi_{uniq} + \rho_2 \Pi_{cap} \quad (7)$$

در فرمول ۷، ρ_1 و ρ_2 ضرایب جریمه هستند که مقادیر مثبت و بزرگی دارند. انتخاب صحیح این ضرایب حیاتی است. این مقادیر باید به اندازه‌ای بزرگ باشند که هرگونه نقض قیود (عدم تخصیص یکتا یا فراتر رفتن از ظرفیت گره) منجر به افزایش شدید انرژی هامیلتونین شود و چنین راه‌حلی را به شدت جریمه کند. در واقع، این ضرایب باید تضمین کنند که حالت پایه Ground State هامیلتونین، که متناظر با راه‌حل بهینه است، الزاماً یک راه‌حل امکان‌پذیر (Feasible) باشد که تمام قیود را ارضا می‌کند. مقدار آن‌ها معمولاً بر اساس مقیاس مقادیر H_{obj} تنظیم می‌شود تا از غلبه کامل جملات جریمه بر تابع هدف اصلی جلوگیری شود.

در فرمول ۷ H_{QUBO} یک چندجمله‌ای درجه دوم و بالاتر از متغیرهای دودویی $Z_{ij}(t)$ است. (عبارت‌های درجه بالاتر را می‌توان با معرفی متغیرهای کمکی به درجه دوم کاهش داد). هامیلتونین پیچیدگی‌های ذاتی مسئله، یعنی ماهیت پویا، اهداف چندگانه و قیود منابع را در خود جای داده و یک مدل بسیار واقعی‌تر برای بهینه‌سازی در سیستم‌های IoT مدرن است.

۴-۴-۵- نگاشت به الگوریتم‌های کوانتومی پیشرفته

(QAOA)

هامیلتونین H_{QUBO} سپس به یک هامیلتونین مسئله آیزینگ (Ising Problem Hamiltonian)، که با H_P نمایش می‌دهیم نگاشت می‌شود. در الگوریتم QAOA، هدف یافتن حالت پایه (Ground State، H_P) است. این کار از طریق یک فرآیند بهینه‌سازی مختلط انجام می‌شود:

۱. آماده‌سازی حالت اولیه: سیستم با n کیوبیت که n تعداد

کل متغیرهای $Z_{ij}(t)$ است، در حالت برهم‌نهی یکنواخت $|+\rangle^{\otimes n}$ آماده می‌شود.

۲. اعمال گیت‌های پارامتری: یک سری از عملگرهای یونیتی به صورت متناوب بر روی حالت اعمال می‌شوند:

$$|\psi(\gamma, \beta)\rangle = \left(\prod_{k=1}^p e^{-i\beta_k H_M} e^{-i\gamma_k H_P} \right) |+\rangle^{\otimes n} \quad (8)$$

H_P هامیلتونین مسئله که ما ساختیم و $H_M = \sum_k \sigma_x^k$ هامیلتونین

ترکیب‌کننده (Mixing Hamiltonian) که معمولاً مجموع عملگرهای پاولی X است. γ و β بردارهایی از پارامترهای (زوایی) قابل تنظیم و p عمق مدار کوانتومی (تعداد لایه‌ها) هستند. در این فرآیند، دو هامیلتونین نقش‌های مکملی را ایفا می‌کنند. هامیلتونین مسئله H_P که از مدل QUBO ما ساخته شده است، فضای مسئله را کدگذاری می‌کند و عملگر مربوط به آن $e^{-i\gamma_k H_P}$ سیستم را به سمت حالت‌هایی با انرژی کمتر (یعنی راه‌حل‌های بهتر برای مسئله) سوق می‌دهد. در مقابل، هامیلتونین ترکیب‌کننده (H_M) که معمولاً مستقل از مسئله است، به سیستم اجازه می‌دهد تا از کمینه‌های محلی (local minima) فرار کرده و فضای راه‌حل‌ها را به طور کامل کاوش کند. عملگر آن $e^{-i\beta_k H_M}$ انتقال بین حالت‌های مختلف محاسباتی را ممکن می‌سازد.

بهینه‌سازی سنتی: مقدار امید $\langle \psi(\gamma, \beta) | H_P | \psi(\gamma, \beta) \rangle$ اندازه‌گیری می‌شود. سپس یک بهینه‌ساز سنتی مانند L-BFGS-B پارامترهای γ و β را طوری تنظیم می‌کند که این مقدار امید کمینه شود. این فرآیند تا رسیدن به همگرایی تکرار می‌شود. این حلقه بهینه‌سازی، ماهیت مختلط کوانتومی-سنتی الگوریتم QAOA را نشان می‌دهد. بخش کوانتومی (اجرای مدار روی کامپیوتر کوانتومی) برای آماده‌سازی حالت $\psi(\gamma, \beta)$ و اندازه‌گیری امید ریاضی $\langle H_P \rangle$ استفاده می‌شود، در حالی که بخش سنتی الگوریتم بهینه‌سازی مانند L-BFGS-B از نتایج این اندازه‌گیری‌ها برای یافتن مجموعه بهتری از پارامترهای γ و β بهره می‌برد. این چرخه تکرار شونده، هسته اصلی الگوریتم‌های کوانتومی متغیر (Variational Quantum Algorithms) است. مدلسازی ریاضی پیشرفته ارائه شده در این پژوهش به طور مستقیم به ساختار الگوریتم‌های کوانتومی مدرن مانند QAOA نگاشت می‌شود و نشان می‌دهد که چگونه قدرت محاسبات کوانتومی می‌تواند برای حل مسائل بسیار پیچیده و عملی در نسل آینده اینترنت اشیاء به کار گرفته شود.

۴- شبیه‌سازی، تحلیل نتایج و بحث مقایسه‌ای عملکرد

این بخش به تحلیل و تفسیر نتایج به‌دست‌آمده از مقایسه‌ی چندین رویکرد مختلف برای بهینه‌سازی تخصیص وظایف می‌پردازد. این تحلیل بر اساس چندین نمودار انجام شده که عملکرد هر الگوریتم را از ابعاد گوناگونی همچون کیفیت راه‌حل، زمان محاسباتی، پویایی سیستم و توانایی در مدیریت هم‌زمان چندین هدف متضاد ارزیابی می‌کند. در ادامه، هر یک از این مقایسه‌ها به تفصیل بررسی می‌شوند تا نقاط قوت و ضعف هر رویکرد مشخص شود.

۴-۱- تنظیمات شبیه‌سازی و معیارهای ارزیابی

برای ارزیابی جامع عملکرد رویکرد پیشنهادی، سه پژوهش پیشین که بیشترین شباهت را به چارچوب مفهومی و اهداف این مقاله داشتند و بر حل چالش‌های مشابه در شبکه‌های اینترنت اشیا با بهره‌گیری از معماری‌های ترکیبی نوین مختلط تمرکز داشتند، جهت مقایسه انتخاب شدند.

۱. اختر و همکاران [۴]: این پژوهش به دلیل معرفی مدل QECC برای رفع محدودیت‌های محاسبات ابری سنتی و ارائه یک الگو محاسباتی جدید، بیشترین ارتباط را با مقاله اصلی دارد. آنها نیز، بر سه فناوری محاسبات کوانتومی، لبه و ابر را در یک چارچوب جامع برای غلبه بر پیچیدگی‌های محاسباتی در IoT ادغام کرده‌اند.

۲. حسین و همکاران [۳]: این پژوهش نیز الگو QECC ارائه نموده و بر چالش‌های تأخیر بالا و آسیب‌پذیری‌های امنیتی در کاربردهای IoT تمرکز دارد. ادغام سه لایه فناوری (کوانتوم، لبه، ابر) و پشتیبانی از نتایج با داده‌های تجربی رویکرد آن را به کاربردهای عملی و مقاله حاضر نزدیک‌تر می‌کند.

۳. ماهاپاترا و همکارانش [۲]: این پژوهش با ارائه چارچوب چندلایه DIFCoT و یک الگوریتم مبتنی بر یادگیری ماشین Q-FogSched، به بهینه‌سازی تخصیص وظایف در محیط‌های IoT با در نظر گرفتن چندین پارامتر متضاد مانند تأخیر، مصرف انرژی و هزینه می‌پردازد. تمرکز آن بر بهره‌گیری از قدرت محاسبات کوانتومی برای حل مسائل بهینه‌سازی ترکیباتی، آن را به یک نمونه مقایسه‌ای قوی تبدیل می‌کند.

برای تضمین اعتبار و تکرارپذیری، تمامی پارامترهای کلیدی شبیه‌سازی با دقت تنظیم و در جدول ۳ ارائه شده‌اند تا امکان بازتولید نتایج فراهم شود. تحلیل نتایج نشان می‌دهد رویکرد پیشنهادی در بهینه‌سازی چندهدفه عملکرد برتری نسبت به سه پژوهش مقایسه‌ای دارد که جزئیات در بخش نتایج ذکر شده است. لازم به توضیح است در این پژوهش از یک مجموعه وظیفه استاندارد و از پیش تعریف شده استفاده نشده است. در عوض، وظایف به صورت مصنوعی و بر اساس پارامترهای واقع‌گرایانه جدول ۳ تولید شده‌اند. این پارامترها، از جمله حجم کاری محاسباتی و حجم داده ورودی، با الهام از کاربردهای واقعی اینترنت اشیا مانند پردازش جریان ویدئو و تحلیل داده‌های حسگرها استخراج شده‌اند. معماری شبکه IoT مورد استفاده در شبیه‌سازی‌ها نیز بر اساس مدل چندلایه‌ای (دستگاه، مه، ابر) است که به طور کامل در بخش ۳-۲ (معماری پیشنهادی شبکه) تشریح شده است.

جدول ۳. مشخصات و مقادیر پارامترهای سیستم برای شبیه‌سازی

مقدار و واحد	نماد	دسته پارامترها
10,20 گره	N	پارامترهای سیستم
۱ تا ۱۰ میلیون دستورالعمل	W_i	پارامترهای وظایف
۱ تا ۵ مگابایت	d_i	
۱۰۰ تا ۱۰۰۰ میلیون دستورالعمل بر ثانیه	φ_j	پارامترهای گره‌ها
۱ تا ۱۰ میکروژول بر دستورالعمل	ε_j	
۱۰ تا ۱۰۰ مگابیت بر ثانیه	B_{ijk}	پارامترهای شبکه
۵ تا ۲۰ میلی‌ثانیه	λ_{ijk}	
0.8	A	ضرایب وزنی
0.2	B	
۴ تا ۸	P	پارامترهای الگوریتم کوانتومی
۱۰، ۵۰، ۱۰۰، ۲۰۰، ۳۰۰، ۴۰۰، ۵۰۰	N_{tasks}	پارامترهای ارزیابی
نسخه ۰.۴۵	Qiskit	شبیه‌ساز
Intel Core i7-11800H	پردازنده	مشخصات سیستم
۳۲ گیگابایت	حافظه رم	
Ubuntu 22.04 LTS	سیستم‌عامل	
نسخه ۳.۹	پایتون	زبان برنامه نویسی


مشخصات گره‌های محاسباتی (با ظرفیت پردازشی مشابه Raspberry Pi) و پارامترهای شبکه (پهنای باند مبتنی بر استانداردهای WiFi/5G همان‌طور که در جدول ۳ مشخص شده، برای ایجاد یک محیط شبیه‌سازی پویا و واقع‌گرا تنظیم شده‌اند. این رویکرد مبتنی بر تولید داده‌های مصنوعی بر اساس پارامترهای مشخص، تکرارپذیری آزمایش‌ها را تضمین می‌کند و در عین حال امکان ارزیابی عملکرد رویکردها را در مقیاس‌های مختلف فراهم می‌آورد.

۴-۲- ارزیابی عملکرد و مقیاس‌پذیری الگوریتم‌ها


تحلیل نمودار عملکرد در شکل ۳ نمایش داده شده است، نشان می‌دهد با افزایش نمایی پیچیدگی مسئله (انفجار ترکیباتی)، کیفیت راه‌حل تمام روش‌ها کاهش می‌یابد؛ با این حال، شیب این کاهش بیانگر مقیاس‌پذیری هر رویکرد است. رویکرد پیشنهادی مبتنی بر QAOA، به طور مداوم بهترین عملکرد را با ملایم‌ترین شیب به ثبت رسانده است که ناشی از طراحی تخصصی آن برای حل مستقیم مسائل بهینه‌سازی ترکیباتی مدل شده به فرمت QUBO است و توانایی برتر آن در حفظ کیفیت راه‌حل در مقیاس‌های بزرگ است.

این ویژگی، QAOA را به یک راهکار کلیدی با توانایی مدیریت فضای جستجوی وسیع تبدیل کرده و فرضیه اصلی پژوهش مبنی بر کارآمدی بهینه‌سازی کوانتومی تأیید می‌کند. در مقابل،

پژوهش با تبدیل مستقیم مسئله به یک QUBO و حل آن از طریق QAOA، برتری کوانتومی در بهینه‌سازی را دارد. این الگوریتم‌ها ذاتاً برای کاوش فضاهای جستجوی عظیم طراحی شده‌اند و با استفاده از اصول برهم‌نهی و درهم‌تنیدگی کوانتومی، قادرند فضای مسئله را به صورت موازی کاوش کرده و بسیار سریع‌تر به سمت راه‌حل بهینه همگرا شوند. رشد زمان محاسباتی برای این راهکار بسیار آهسته و نزدیک به یک خط با شیب کم است. این مقیاس‌پذیری برتر به عنوان یک اثبات مفهوم عمل کرده و نشان می‌دهد که با افزایش حجم مسئله، الگوریتم‌های سنتی به سرعت غیرقابل استفاده می‌شوند، در حالی که رویکرد کوانتومی پیشنهادی، رشد بسیار کند و مدیریت‌شده‌ای خواهد داشت. این نتیجه‌گیری، اعتبار راهبردی بهینه‌سازی کوانتومی برای حل مسائل پیچیده در مقیاس‌های بزرگ را اثبات می‌کند.



شکل ۳. مقایسه زمان محاسباتی با افزایش حجم مسئله (تعداد وظایف)




شکل ۴. تحلیل مقایسه‌ای عملکرد الگوریتم‌های بهینه‌سازی برای تخصیص وظایف

چارچوب‌های QECC ارائه‌شده توسط حسین و همکاران و اختر و همکاران، اگرچه عملکردی بهتر از روش‌های سنتی دارند و در مقیاس‌های کوچک نیز عملکردی نزدیک به رویکرد پیشنهادی دارند اما به دلیل فقدان کارایی متمرکز در موتور بهینه‌سازی درونی، با افزایش مقیاس مسئله، شکاف عملکردی محسوس با QAOA دارند و این امر بر نقش تعیین‌کننده الگوریتم بهینه‌سازی مرکزی نسبت به معماری قدرتمند تأکید دارد. از سوی دیگر، رویکرد Q-FogSched ماهاپاترا و همکاران که بر پایه QML است، در مقیاس کوچک رقابتی عمل می‌کند، اما در مواجهه با مسائل ترکیبیاتی خالص و فضای جستجوی گسترده، در تعمیم‌بخشی فراتر از داده‌های آموزشی خود با چالش مواجه شده و با افزایش شدید حجم مسئله، شیب منحنی عملکرد آن تندتر و کیفیت راه‌حل آن با سرعت بیشتری کاهش می‌یابد، چرا که دستیابی به راه‌حل بهینه ریاضی در آن مانند یک الگوریتم مستقیم مانند QAOA تضمین شده نیست. در نهایت، همواری منحنی‌ها حاصل فرآیند میانگین‌گیری در شبیه‌سازی‌ها بر روی ده‌ها اجرا با شرایط اولیه متفاوت است تا نوسانات آماری حذف و روند اصلی هر الگوریتم آشکار گردد.


نمودار ارائه شده در شکل ۴، زمان اجرای سه رویکرد حل مسئله بهینه‌سازی تخصیص وظایف را به صورت لگاریتمی مقایسه می‌کند. محور افقی بیانگر تعداد وظایف و محور عمودی نشان‌دهنده زمان محاسباتی مورد نیاز برای یافتن راه‌حل است. تحلیل کلی نمودار نشان می‌دهد که با افزایش حجم مسئله، تفاوت چشمگیری در مقیاس‌پذیری و کارایی این سه رویکرد وجود دارد؛ روش پیشنهادی کوانتومی، رشدی بسیار آهسته و نزدیک به خطی را نشان می‌دهد، در حالی که روش‌های سنتی با رشد نمایی و رویکرد یادگیری ماشین کوانتومی رشد چندجمله‌ای با درجه بالا دارند. این شکاف عملکردی، با بزرگ‌تر شدن ابعاد مسئله به صورت نمایی افزایش یافته و برتری راهبردی الگوریتم‌های کوانتومی را اثبات می‌کند. راهکارهای سنتی ارائه شده توسط حسین و اختر و همکارانشان، پدیده انفجار ترکیبیاتی را به وضوح به تصویر می‌کشند. با افزایش تعداد دستگاه‌ها و وظایف، فضای جستجو به صورت نمایی رشد کرده و زمان اجرا از چند ثانیه به هزاران ثانیه افزایش می‌یابد که بیانگر دیوار پیچیدگی مسائل NP-hard است. در مقابل، رویکرد ماهاپاترا و همکارانش با بهره‌گیری از QML، اگرچه عملکرد بهتری نسبت به روش‌های کاملاً سنتی از خود نشان می‌دهد اما هنگام ترکیب با شبکه‌های عصبی از نظر محاسباتی بسیار سنگین و فرآیندهای آموزش و جستجوی زمان‌بری دارند و در نتیجه منحنی آن با رشد سریع چندجمله‌ای مواجه است و نشان می‌دهد که بر چالش مقیاس‌پذیری غلبه نکرده است. در نهایت، راهکار پیشنهادی این

یادگیری تقویتی عمیق الهام‌گرفته از کوانتوم (QDRL) است، سریع‌ترین زمان اجرا (۲۸,۱ ثانیه) را دارد. اما در اکثر معیارهای عملکردی ضعیف‌ترین نتایج را ارائه می‌دهد: بالاترین مصرف انرژی، بالاترین نرخ نقض QoS و بالاترین مقدار تابع هدف. این امر نشان‌دهنده این است که Q-FogSched، در حالی که در سرعت پیشنهاد است، در دستیابی به بهینگی جامع و توازن بین اهداف چندانگانه، نیازمند بهبود است؛ الگوریتم‌های DRL ممکن است بهینگی را فدای سرعت کنند.

نمودار شکل ۶، عملکرد چهار الگوریتم مختلف در بهینه‌سازی هم‌زمان دو معیار متضاد میانگین تأخیر کل و مصرف انرژی کل را نشان می‌دهد. این نمایش که تحت عنوان جبهه پارتو شناخته می‌شود، کارایی راهکارهای گوناگون را ارزیابی می‌کند، به طوری که الگوریتم برتر، منحنی‌ای را ایجاد می‌کند که به مبدأ مختصات، یعنی نقطه بهینه با کمترین انرژی و تأخیر، نزدیک‌تر باشد.



شکل ۵. مقایسه عملکرد الگوریتم‌ها در بهینه‌سازی چندهدفه تأخیر و مصرف انرژی



شکل ۶. مقایسه عملکرد پویایی سیستم در مدیریت تأخیر وظایف تحت تغییرات ناگهانی بار شبکه


در راستای ارزیابی کارایی رویکرد پیشنهادی مبتنی بر QAOA در تخصیص وظایف IoT، عملکرد آن بر اساس معیارهای میانگین تأخیر کل، مصرف انرژی کل، نرخ نقض QoS و مقدار نهایی تابع هدف با سه پژوهش دیگر مقایسه شده است که نتایج در شکل ۵ نمایش داده شده است. این تحلیل بر پایه خروجی یک سناریوی با ۱۰۰ وظیفه و ۲۰ گره محاسباتی صورت گرفته است. میانگین تأخیر کل (۱۲۵,۵ میلی‌ثانیه)، کمترین مقدار را دارد که نشان‌دهنده توانایی بالا در پردازش و انتقال سریع داده‌هاست. مصرف انرژی کل (۴۵۰,۲ ژول)، کمترین میزان را ثبت کرده که حیاتی برای اکوسیستم‌های IoT کم‌مصرف است. نرخ نقض QoS (۲,۱٪) حداقل میزان را دارد که تضمین‌کننده کیفیت بالای خدمات و پایداری سیستم است. مقدار تابع هدف (۶۸۰,۸) پایین‌ترین مقدار را به خود اختصاص داده که موفقیت QAOA را در یافتن تعادل بهینه بین اهداف متضاد تأیید می‌کند. با این حال، زمان اجرای QAOA با ۴۵,۳ ثانیه، بالاترین مقدار را نشان می‌دهد. این موضوع منطقی است؛ زیرا QAOA یک الگوریتم مختلط کوانتومی-سنتی است که شامل یک حلقه بهینه‌سازی سنتی تکراری برای تنظیم پارامترها بر اساس نتایج محاسبات کوانتومی است. این فرآیند تکراری و نیاز به هماهنگی بین پردازنده‌های سنتی و کوانتومی، سربار زمانی ایجاد می‌کند، اما به یافتن راه‌حل‌های با کیفیت‌تر منجر می‌شود. سایر الگوریتم‌ها که اغلب ابتکاری (مانند ژنتیک یا بهینه‌سازی ازدحام ذرات) هستند، به سرعت به راه‌حل‌های «خوب» همگرا می‌شوند اما تضمینی برای یافتن بهینه سراسری ندارند، به همین دلیل کیفیت راه‌حل نهایی آن‌ها (مقدار تابع هدف) ضعیف‌تر از QAOA است و توازن کمتری در بهینه‌سازی چندهدفه نشان می‌دهند. پژوهش اختر و همکاران بر ادغام محاسبات کوانتومی، لبه‌ای و ابری برای حل چالش‌های IoT تمرکز دارد. تأخیر، انرژی و نرخ نقض QoS آن اگرچه از روش‌های سنتی بهتر است، اما به اندازه QAOA بهینه نیست. زمان اجرای آن رویکردهای ابتکاری یا الگوریتم‌های کوانتومی با عمق مدار کمتر باشد که سریع‌تر به نتیجه می‌رسند اما لزوماً بهینه‌ترین پاسخ را نمی‌یابند. پژوهش حسین و همکاران بالاترین تأخیر (۱۴۵,۱ میلی‌ثانیه) را ثبت کرده است که نشان‌دهنده چالش‌ها در دستیابی به زمان پاسخ‌دهی سریع در این پیاده‌سازی خاص است. مصرف انرژی و نرخ نقض QoS آن نیز از QAOA و اختر بالاتر است. با این حال، زمان اجرای آن با ۳۲,۵ ثانیه، سریع‌ترین در بین روش‌های کوانتومی است. این سرعت بالا ممکن است نتیجه استفاده از رویکردی تهاجمی‌تر یا تمرکز بیشتر بر سرعت پردازش به جای بهینه‌سازی جامع باشد. پژوهش ماهاپاترا و همکاران که بر پایه

یک بازه زمانی صد ثانیه‌ای و در شرایط تغییر ناگهانی شبکه ارزیابی می‌کند. روند کلی حاکم بر نمودار، سه مرحله متمایز را به تصویر می‌کشد: یک دوره ابتدایی با عملکرد پایدار، یک نقطه بحران در ثانیه ۴۰ که با جهش شدید تأخیر همراه است، و یک فاز بازیابی که در آن تفاوت کلیدی میان رویکردها آشکار می‌گردد. در بازه زمانی پیش از بحران (۰ تا ۴۰ ثانیه)، تمامی راهکارهای پویا عملکردی مطلوب با تأخیر پایین از خود نشان می‌دهند. در این میان، راهکار پیشنهادی با بهره‌گیری از بهینه‌سازی پویا و چندهدفه مبتنی بر QAOA، با ثبت تأخیر ۲۲ میلی‌ثانیه، بهترین عملکرد را داراست که نشان‌دهنده توانایی آن در یافتن راه‌حل‌های بهینه برای مسائل ترکیبیاتی حتی در شرایط پایدار است. در مقایسه با سایر پژوهش‌ها در این فاز، رویکرد ماهاپاترا و همکارانش که بر QML استوار است، با تأخیر ۲۸ میلی‌ثانیه عملکردی بسیار نزدیک و قابل توجه دارد، هرچند ممکن است به دلیل ماهیت یادگیری، بهینگی آن اندکی کمتر از حل مستقیم مسئله بهینه‌سازی باشد. به دنبال آن، راهکارهای حسین و همکاران و اختر و همکاران که چارچوب QECC را معرفی کرده‌اند، با ثبت تأخیرهای ۳۵ و ۳۸ میلی‌ثانیه، عملکردی بهتر از تخصیص ایستا از خود نشان می‌دهند اما در بهینه‌سازی تأخیر به اندازه راهکار پیشنهادی دقیق نیستند. در نهایت، راهکار تخصیص ایستا به دلیل عدم تطبیق با پویایی اولیه شبکه، با تأخیر ۴۵ میلی‌ثانیه، ضعیف‌ترین عملکرد را در حالت پایه دارد. نقطه عطف شبیه‌سازی در ثانیه ۴۰ رخ می‌دهد، جایی که یک تغییر ناگهانی نظیر کاهش ۷۰ درصدی پهنای باند، منجر به جهشی چشمگیر در میانگین تأخیر تا حدود ۲۰۰ میلی‌ثانیه برای تمام راهکارها می‌شود. این افت ناگهانی پهنای باند به صورت عمده در شبیه‌سازی لحاظ شده است تا قابلیت تطبیق‌پذیری و سرعت بازیابی هر الگوریتم در مواجهه با شرایط بحرانی شبکه به چالش کشیده شود. این شوک اولیه، که ناشی از ایجاد یک گلوگاه جدی در سیستم و اشباع صف‌هاست، تأثیر خود را بر تمامی روش‌ها، صرف‌نظر از سطح هوشمندی آن‌ها، اعمال می‌کند. تفاوت بنیادین میان راهکارها در فاز پس از بحران، یعنی از ثانیه ۵۰ به بعد، نمایان می‌شود. راهکار تخصیص ایستا به دلیل ماهیت غیرانطباقی خود، قادر به واکنش به شرایط جدید نبوده و با ارسال مداوم وظایف به گره اشباع‌شده، تأخیر را در سطح بحرانی ۲۱۰ میلی‌ثانیه باقی نگه می‌دارد که ضعف اصلی این رویکرد را آشکار می‌سازد. در نقطه مقابل، راهکار پیشنهادی به واسطه حلقه بهینه‌سازی مختلط کوانتومی-سنتی خود، وضعیت شبکه را به طور مداوم پایش کرده و به محض تشخیص افت عملکرد، مسئله بهینه‌سازی را با پارامترهای جدید شبکه مجدداً حل می‌کند. این فرآیند منجر به تخصیص مجدد و هوشمندانه وظایف به گره‌های

بر این اساس، راهکار پیشنهادی در تمامی نقاط، موقعیت برتری نسبت به سه رویکرد دیگر دارد و یک جبهه پارتوی بهینه‌تر را شکل داده است. این یعنی برای هر سطح مشخصی از مصرف انرژی، الگوریتم پیشنهادی تأخیر کمتری را به ثبت می‌رساند و متقابلاً برای هر سطح تأخیر دلخواه، انرژی کمتری مصرف می‌کند که نشان‌دهنده کارایی بالاتر و نوآوری موفقیت‌آمیز آن است. این برتری چشمگیر ناشی از رویکرد محاسباتی و مدل‌سازی ریاضی مسئله است. راهکار پیشنهادی با تبدیل مستقیم مسئله پیچیده تخصیص پویای وظایف چندهدفه به یک مدل QUBO، از قدرت محاسبات کوانتومی به شیوه‌ای بسیار کارآمد بهره می‌برد. این فرمول‌بندی دقیق ریاضی، به QAOA اجازه می‌دهد تا فضای جستجوی عظیم ناشی از انفجار ترکیبیاتی را به صورت موازی و مؤثر کاوش کند و در نتیجه قادر به یافتن راه‌حل‌هایی با توازن بسیار بهتری میان کاهش تأخیر و مصرف انرژی باشد. در مقایسه، سایر پژوهش‌ها با وجود به‌کارگیری مفاهیم مشابه، به دلیل تفاوت در رویکرد و دقت اجرا، در جایگاه‌های ضعیف‌تری قرار گرفته‌اند. الگوریتم ارائه شده توسط اختر و همکاران (جایگاه دوم)، چارچوب مفهومی جامع به نام QECC را معرفی می‌کند که با ادغام سه فناوری کلیدی، نتایج قابل قبولی ارائه می‌دهد، اما به دلیل فقدان یک مدل بهینه‌سازی ریاضی دقیق و متمرکز مانند QUBO، بیشتر جنبه مفهومی و آینده‌نگر داشته و در عمل به یافتن راه‌حل‌های اندکی نامطلوب‌تر در مقایسه با راهکار پیشنهادی منجر می‌شود. پژوهش حسین و همکاران (جایگاه سوم) نیز که از الگو مشابه QECC استفاده می‌کند، با ارائه داده‌های تجربی از مزیت عملی‌تری برخوردار است، اما اتکای زیاد آن به یک مطالعه موردی محدود، قابلیت تعمیم‌پذیری نتایج را کاهش می‌دهد. این محدودیت در دامنه کاربرد، مانع از یافتن بهینه‌ترین توازن‌های جهانی بین انرژی و تأخیر در سناریوهای گسترده‌تر شده و به همین دلیل منحنی آن در موقعیتی پایین‌تر از دو رویکرد قبلی قرار گرفته است. در نهایت، ضعیف‌ترین عملکرد متعلق به پژوهش ماهاپاترا و همکارانش است که از یک الگوریتم مبتنی بر QML به نام Q-FogSched بهره برده است. الگوریتم‌های یادگیری ماشین کوانتومی ذاتاً بسیار سنگین و پیچیده هستند و پیاده‌سازی آن‌ها در دستگاه‌های لبه با منابع محدود، یک چالش جدی محسوب می‌شود. این سنگینی محاسباتی خود می‌تواند منجر به مصرف انرژی و تأخیر بیشتر در فرآیند تصمیم‌گیری شود. علاوه بر این، عملکرد مدل‌های یادگیری ماشین به شدت به کیفیت داده‌های آموزشی وابسته است و ممکن است در شرایط پویای دنیای واقعی، تصمیمات غیربهینه اتخاذ کنند.

نمودار شکل ۷، عملکرد راهکارهای مختلف تخصیص وظیفه را در


همگرایی الگوریتم است. مقدار نمایش داده شده روی محور Y ، یعنی H_p ، یک واحد فیزیکی مستقیم نیست، بلکه خروجی هامیلتونین مسئله است که به عنوان یک تابع هزینه چندهدفه طراحی شده است. این تابع، ترکیبی وزنی از سه معیار اصلی عملکرد، شامل تأخیر، مصرف انرژی و کیفیت خدمات، به همراه جملات جریمه برای اطمینان از رعایت قیود سیستم است. بنابراین، H_p یک معیار انتزاعی و ترکیبی برای ارزیابی نامطلوب بودن یک راه حل به شمار می‌رود و هدف الگوریتم، کمینه کردن این امتیاز هزینه است. کاهش این مقدار به معنای یافتن راه حلی است که توازن بهتری بین اهداف متضاد برقرار کرده و تمام قیود مسئله را رعایت می‌کند. در تحلیل دقیق‌تر و مقایسه عملکرد رویکردها، منحنی مربوط به رویکرد پیشنهادی ما به وضوح برتری خود را با همگرا شدن به پایین‌ترین مقدار انرژی (۱۴،۷) نشان می‌دهد.



شکل ۸. تأثیر عمق مدار کوانتومی (p) بر کیفیت راه حل (H_{obj})

این موفقیت بیانگر آن است که فرمول‌بندی مسئله به صورت بهینه‌سازی دودویی درجه دوم غیرمحدود QUBO و ادغام آن با QAOA در این روش، بهینه‌تر و کارآمدتر از سایر رقبا بوده است. این رویکرد توانسته است فضای راه حل را به طور مؤثرتری کاوش کرده و به یک پیکربندی با هزینه به مراتب کمتر دست یابد. در مقابل، دو رویکرد مبتنی بر الگو QECC که توسط حسین و اختر و همکارانشان ارائه شده‌اند، عملکرد قابل قبولی از خود به نمایش گذاشته و به ترتیب به مقادیر انرژی ۲۴،۳ و ۲۶،۱ همگرا شده‌اند. اگرچه این روش‌ها نیز به راه‌حل‌های مناسبی دست یافته‌اند، اما مقدار هزینه نهایی آن‌ها به طور قابل توجهی بالاتر از رویکرد پیشنهادی است. این تفاوت می‌تواند ناشی از دقت کمتر مدل ریاضی آن‌ها یا نداشتن غیر بهینه مسئله به چارچوب کوانتومی باشد که مانع از دستیابی به بهینگی مشابه شده است. در نهایت، رویکرد ماهایترا و همکارانش که از QML بهره می‌برد، در سطح انرژی بسیار

کارآمدتر شده و سیستم با سرعت بسیار بالایی خود را بازیابی می‌کند و تأخیر را به سطح نزدیک به حالت عادی در حدود ۳۵ میلی‌ثانیه بازمی‌گرداند. سایر پژوهش‌های مورد مقایسه نیز ماهیت پویا دارند اما سرعت و کیفیت بازیابی آن‌ها متفاوت است. راهکار ماهایترا و همکارانش به دلیل استفاده از QML به خوبی تطبیق می‌یابد، اما برای یادگیری وضعیت جدید شبکه به زمان بیشتری نیاز داشته باشد. رویکردهای اختر و حسین و همکارانشان نیز تطبیق‌پذیر هستند، اما چارچوب آن‌ها در یافتن راه‌حل بهینه جدید به اندازه راهکار پیشنهادی سریع یا کارآمد عمل نمی‌کند. در مجموع، این سناریوی واقع‌گرایانه نشان می‌دهد که ارزش اصلی یک سیستم تطبیق‌پذیر، نه در شرایط ایده‌آل، بلکه در توانایی آن برای مدیریت بحران و بازیابی سریع پس از یک رویداد غیرمنتظره مشخص می‌شود.



شکل ۷. نمودار همگرایی حلقه بهینه‌سازی مختلط کوانتومی -

سنتی

نمودار ارائه شده در شکل ۸، فرایند همگرایی چهار رویکرد مختلف بهینه‌سازی را بر اساس تعداد تکرارها به تصویر می‌کشد و عملکرد آن‌ها را در کمینه‌سازی یک تابع هزینه ترکیبی، که با مقدار مورد انتظار هامیلتونین (H_p) نمایش داده شده، مقایسه می‌کند. محور افقی نشان‌دهنده تعداد تکرارهای الگوریتم بهینه‌سازی و محور عمودی نمایانگر مقدار تابع هزینه یا انرژی راه حل است. روند کلی تمامی منحنی‌ها نزولی است که مشخصه اصلی یک فرآیند بهینه‌سازی موفق محسوب می‌شود. در تکرارهای اولیه، به دلیل فاصله زیاد از نقطه بهینه، شیب کاهش در تمام نمودارها بسیار تند است و الگوریتم‌ها به سرعت بهبودهای قابل توجهی را تجربه می‌کنند. با افزایش تعداد تکرارها و نزدیک شدن به نقاط بهینه محلی یا سراسری، این شیب کاهش یافته و منحنی‌ها به تدریج به یک حالت پایدار یا فلات (plateau) می‌رسند که نشان‌دهنده


راه‌حلی‌هایی با کمترین هزینه ترکیبی (شامل تأخیر، مصرف انرژی و جریمه کیفیت خدمات) می‌شود. در مقابل، پژوهش‌های رقیب هر یک به دلایل متفاوتی در سطوح بالاتری از تابع هزینه قرار می‌گیرند. رویکرد ارائه شده توسط ماهاپاترا و همکارانش که از QML استفاده می‌کند، عملکردی قوی اما ضعیف‌تر از رویکرد پیشنهادی ما دارد. اگرچه QML ابزاری قدرتمند است، اما کارایی آن به شدت به کیفیت داده‌های آموزشی وابسته است و برای مسائل بهینه‌سازی ترکیبیاتی خالص به اندازه QAOA بهینه عمل نکند، که همین امر منجر به مقدار تابع هدف بالاتر آن شده است. از سوی دیگر، پژوهش‌های حسین، اختر و همکارانشان یک چارچوب مفهومی تحت عنوان QECC را معرفی می‌کنند. این رویکردها بیشتر جنبه آینده‌نگرانه داشته و بر فناوری‌هایی تکیه دارند که هنوز در مراحل اولیه توسعه قرار دارند. این ماهیت مفهومی می‌تواند منجر به سربار محاسباتی بیشتر یا عدم بهینه‌سازی کامل مدل برای پیاده‌سازی‌های عملی شود. در نتیجه، مقادیر تابع هدف برای این دو پژوهش به طور قابل توجهی بالاتر از سایرین است و نشان‌دهنده راه‌حلی‌هایی است که در شرایط فعلی به اندازه رویکردهای متمرکز و تخصصی، بهینه نیستند.

در شکل ۱۰، رفتار سه رویکرد محاسباتی کوانتومی از منظر زمان همگرایی و کیفیت راه‌حل، براساس مقدار تابع هدف (H_{obj}) مورد بررسی قرار گرفته است. رویکرد پیشنهادی مبتنی بر QAOA با همگرایی بسیار سریع، بهترین عملکرد را نشان می‌دهد و تنها در حدود ۴۰ ثانیه، به یک راه‌حل با کیفیت بسیار بالا، یعنی مقدار تابع هدف ۱۱۵، می‌رسد. در نقطه مقابل، الگوریتم چارچوب Q-FogSched ماهاپاترا و همکارانش که مبتنی بر QML است، کندترین روند همگرایی را دارد و برای رسیدن به مقدار تابع هدف ۱۸۰، به زمانی در حدود ۱۳۰ ثانیه نیاز دارد که نشان‌دهنده پیچیدگی محاسباتی بالای آن است.

پژوهش‌های حسین، اختر و همکارانشان که هر دو بر چارچوب مفهومی QECC تکیه دارند، عملکردی میانی را به ثبت رسانده‌اند و تعادلی میان زمان و کیفیت راه‌حل برقرار می‌کنند. رویکرد پیشنهادی مبتنی بر QAOA با بهره‌گیری از توانایی ذاتی محاسبات کوانتومی در کاوش موازی فضاهای جستجوی بسیار بزرگ، به سرعت به راه‌حل‌های نزدیک بهینه همگرا می‌شود و نشان دهنده کارایی بالای این رویکرد برای کاربردهای حساس به زمان است. در مقابل، کندی الگوریتم Q-FogSched ماهاپاترا و همکارانش، ریشه در ماهیت محاسباتی سنگین آن دارد. ترکیب یادگیری ماشین کوانتومی با شبکه‌های عصبی عمیق، ذاتاً نیازمند زمان بیشتری برای

بالاتری (۴۲،۱) همگرا شده است. این عملکرد ضعیف‌تر می‌تواند به پیچیدگی محاسباتی بالای QML نسبت داده شود که منجر به گرفتار شدن الگوریتم در یک بهینه محلی (local minimum) شده است. در مجموع، این نمودار شبیه‌سازی، گواهی بر کارایی مدل پیشنهادی است که نشان می‌دهد حلقه بهینه‌سازی مختلط آن قادر است به راه‌حلی با هزینه کمتر و در نتیجه کیفیت بالاتر نسبت به روش‌های مورد مقایسه دست یابد.

با تحلیل نمودار ارائه شده در شکل ۹ که هزینه بهینه‌سازی تابع هدف (H_{obj}) را در محور عمودی بر اساس عمق مدار کوانتومی (p) در محور افقی نمایش می‌دهد، یک روند کلی مشخص قابل مشاهده است. در تمامی رویکردهای مورد بررسی، با افزایش مقدار p ، مقدار تابع هدف H_{obj} کاهش می‌یابد که نشان‌دهنده دستیابی به راه‌حل‌های بهینه‌تر است.




شکل ۹. نمودار کیفیت راه‌حل در برابر زمان محاسبات

این پدیده با مبانی نظری QAOA کاملاً سازگار است، زیرا افزایش عمق مدار به الگوریتم اجازه می‌دهد تا فضای مسئله را با دقت بیشتری کاوش کند. با این حال، شیب این کاهش با افزایش p کمتر می‌شود؛ پدیده که به عنوان کاهش بازده شناخته می‌شود، نشان می‌دهد که پس از یک نقطه مشخص، افزایش منابع محاسباتی تأثیر کمتری بر بهبود راه‌حل دارد، زیرا الگوریتم به تدریج به نقطه بهینه نزدیک می‌شود. در مقایسه عملکرد رویکردهای مختلف، چارچوب پیشنهادی به وضوح در تمامی مقادیر p ، کمترین مقدار تابع هدف را به خود اختصاص داده و برتری خود را به اثبات رسانده است. دلیل اصلی این عملکرد برجسته، طراحی یک چارچوب بهینه‌سازی مختلط است که مسئله را به صورت مستقیم به فرمت QUBO تبدیل کرده و سپس از QAOA برای حل آن بهره می‌برد. این رویکرد یکپارچه و تطابق کامل ساختار مسئله با الگوریتم حل‌کننده، کارایی فرآیند بهینه‌سازی را به حداکثر می‌رساند و منجر به یافتن

شود که وظایف محاسباتی را در هنگام مواجهه با شبکه ضعیف، از ابر به گره‌های پردازشی نزدیک‌تر مانند مه یا لبه منتقل می‌کند تا از سربار ناشی از ارسال داده در یک کانال ارتباطی پرازدحام و کند جلوگیری نماید.

در مقابل، روش‌های حسین، اختر و همکارانشان که مبتنی بر مدل QECC هستند، عملکردی بسیار نزدیک به یکدیگر و به مراتب بهتر از الگوریتم ماهاپاترا و همکارانش عمل می‌کنند، اما تأخیر آن‌ها به طور قابل توجهی بیشتر از راهکار پیشنهادی است. این برتری نشان می‌دهد که الگوریتم بهینه‌سازی پیشنهادی، در تخصیص پویای منابع و واکنش سریع به تغییرات لحظه‌ای شبکه، کارآمدتر عمل می‌کند. برتری جزئی عملکرد حسین نسبت به اختر نیز می‌تواند به دلیل پشتیبانی از ادعاها با داده‌های تجربی در پژوهش او باشد.



شکل ۱۱. تأثیر پویایی شبکه بر عملکرد الگوریتم‌های تخصیص وظایف

در سوی دیگر این طیف، الگوریتم Q-FogSched ماهاپاترا و همکارانش، با بالاترین تأخیر را در تمام سناریوها عملکردی ضعیف دارد که ناشی از پیچیدگی محاسباتی و سنگین بودن ذاتی الگوریتم QML-محور آن است که فرآیند تصمیم‌گیری تخصیص مجدد وظایف را زمان‌بر می‌سازد که در شبکه‌های ضعیف شدت می‌یابد و با ممانعت از تطبیق سریع سیستم با وضعیت جدید، منجر به افزایش تأخیر کل تا ۵۸۰ میلی‌ثانیه می‌شود. بنابراین، نتایج نمودار فراتر از سنجش تأخیر بوده و ضمن تأکید بر اهمیت سازگاری و هوشمندی الگوریتم در مدیریت منابع تحت شرایط بحرانی شبکه، برتری راهکار پیشنهادی در این زمینه را اثبات می‌کند.

نمودار شکل ۱۲ به مقایسه عملکرد رویکرد پیشنهادی با سه پژوهش دیگر در زمینه بهینه‌سازی همزمان تأخیر و مصرف انرژی در سه سناریوی عملیاتی متمایز می‌پردازد و به وضوح اصل بنیادین توازن

آموزش و جستجو در فضای راه‌حل است و همین امر پیچیدگی محاسباتی را به نقطه ضعف اصلی این روش تبدیل کرده است. پژوهش‌های حسین، اختر و همکارانشان با معرفی چارچوب مفهومی و جامع QECC، یک رویکرد مختلط را برای ادغام فناوری‌های کوانتوم، لبه و ابر ارائه می‌دهند که هدف اصلی طراحی آنها لزوماً بهینه‌سازی برای سرعت نبوده است. این دو رویکرد با عملکردی میانی، سریع‌تر از روش مبتنی بر QML اما کندتر از الگوریتم QAOA است. یکی از چالش‌های دیگر این چارچوب‌ها، اتکای شدید به فناوری محاسبات کوانتومی است که هنوز در مراحل اولیه توسعه قرار دارد و پیاده‌سازی عملی و بهینه این چارچوب‌ها را با محدودیت‌های سخت‌افزاری و نرم‌افزاری فعلی مواجه می‌کند. این مقایسه نشان می‌دهد که انتخاب الگوریتم مناسب، وابستگی مستقیمی به اولویت‌های مسئله، از جمله سرعت همگرایی، کیفیت نهایی راه‌حل و بلوغ فناوری زیرساختی دارد.



شکل ۱۰. تحلیل مقایسه‌ای عملکرد بهینه‌سازی در سناریوهای مختلف

شکل ۱۱ به مقایسه میانگین تأخیر کل در الگوریتم‌ها تحت شرایط متغیر شبکه می‌پردازد. در تمام راهکارهای مورد بررسی، با افت کیفیت شبکه از پهنای باند بالا/تأخیر کم به سمت پهنای باند کم/تأخیر بالا، تأخیر کل افزایش می‌یابد که وابستگی زمان پردازش شبکه به کیفیت ارتباطات امری طبیعی در سیستم‌های توزیع‌شده است و تفاوت اصلی میان الگوریتم‌ها در شیب این افزایش و میزان سازگاری آن‌ها با تخریب شرایط شبکه است. راهکار پیشنهادی، در تمامی سناریوهای شبکه، عملکردی برتری دارد و همواره کمترین میزان تأخیر را ثبت می‌کند. در شرایط ایده‌آل شبکه، تأخیر آن تنها ۵۵ میلی‌ثانیه است و در بدترین حالت شبکه نیز تأخیر آن تنها به ۲۶۰ میلی‌ثانیه می‌رسد، در حالی که سایر الگوریتم‌ها تأخیری بین ۳۸۰ تا ۵۸۰ میلی‌ثانیه را دارند. این برتری از معماری هوشمند مبتنی بر بهینه‌سازی کوانتومی پویا برای تخصیص وظایف ناشی می

عمومی‌تر و کمتر بهینه است. به همین دلیل، مقادیر تأخیر و انرژی آن‌ها در سناریوهای متمرکز، بهبود چشمگیری نشان نمی‌دهد و در مجموع بالاتر از دو رویکرد دیگر قرار می‌گیرد. البته در سناریوی کاهش تأخیر روش حسین و همکاران برپا میزان تأخیر ۰,۴۰ عملکردی اندکی بهتر از اختر و همکاران با تأخیر ۰,۴۵ دارد. مزیت کلیدی رویکرد پیشنهادی، قابلیت کنترل پویای رفتار سیستم از طریق تنظیم ضرایب وزنی است؛ به گونه‌ای که افزایش ضریب μ_L باعث تخصیص وظایف به گره‌های سریع‌تر، حتی پرمصرف‌تر، و افزایش ضریب μ_E ، موجب اولویت با گره‌های کم‌مصرف و لو با تأخیر بیشتر می‌شود. این ویژگی آن را از الگوریتم‌های متمرکز بر یک هدف متمایز کرده و و نمودار فعلی این برتری را به صورت کمی و بصری اثبات می‌کند. نتایج شبیه‌سازی نیز بر اساس پارامترهای واقع‌گرایانه، از جمله گره‌هایی با توان پردازشی مشابه Raspberry Pi، شبکه مبتنی بر استانداردهای 5G/Wi-Fi و بار کاری واقعی اینترنت اشیاء مانند پردازش ویدئو، به دست آمده است.

۴-۳- تحلیل پویایی سیستم و مزیت راهبردی بهینه‌سازی کوانتومی


این قسمت به طور دقیق نتایج مقایسه‌ای عملکرد الگوریتم‌ها را در شرایط عملیاتی و پویای شبکه، فراتر از معیارهای ایستا، تحلیل می‌کند.

- چارچوب ریاضی پیشنهادی به صورت عام و انتزاعی طراحی شده است تا به یک فناوری یا معماری خاص محدود نباشد. هدف، ارائه یک مدل پایه است که بتواند با پارامترهای مختلف از سناریوهای گوناگون تطبیق یابد. با این حال، برای ارزیابی عملکرد و اعتبارسنجی مدل، در بخش شبیه‌سازی (که جزئیات آن در جدول ۳ آمده است)، این پارامترهای انتزاعی با مقادیر واقع‌گرایانه و مشخص مقداردهی شده‌اند. به عنوان مثال:

- ظرفیت پردازشی گره‌ها: با الهام از دستگاه‌های لبه رایج مانند Raspberry Pi مدل‌سازی شده است.
- پهنای باند شبکه: بر اساس استانداردهای مدرن ارتباطی مانند Wi-Fi و 5G در نظر گرفته شده است.
- حجم کاری وظایف: مبتنی بر کاربردهای واقعی اینترنت اشیاء، مانند پردازش جریان‌های ویدئویی، تعریف شده است.

بنابراین، اگرچه مدل ریاضی عام است، نتایج عملکردی ارائه شده در مقاله مبتنی بر یک سناریوی شبیه‌سازی مشخص و واقع‌گرایانه است تا بتواند ارتباط مدل نظری را با کاربرد عملی آن به خوبی نشان

(Trade-off) را در سیستم‌های بهینه‌سازی بیان می‌کند، که بر اساس آن، بهبود یک شاخص عملکردی معمولاً به قیمت افت شاخص دیگر تمام می‌شود. به عنوان مثال، در سناریوی تمرکز بر تأخیر، رویکرد پیشنهادی با دستیابی به کمترین تأخیر نرمال شده (۰,۱۵)، ناگزیر مصرف انرژی بالاتری (۰,۵۵) را دارد؛ زیرا برای کاهش زمان پاسخ، وظایف به گره‌های پردازشی قوی‌تر و سریع‌تر و پرمصرف‌تر تخصیص می‌یابند. این رفتار در سناریوی تمرکز بر انرژی به صورت معکوس دیده می‌شود و نشان‌دهنده رفتار قابل پیش‌بینی سیستم در شرایط مرزی است.



شکل ۱۲. تحلیل مقایسه‌ای عملکرد بهینه‌سازی در سناریوهای مختلف

رویکرد پیشنهادی، یک چارچوب بهینه‌سازی چندهدفه پویا است که از طریق ضرایب وزنی (μ_Q , μ_E و μ_L) قابلیت تنظیم دقیق را فراهم می‌آورد. برتری اصلی این مدل در انعطاف‌پذیری بالای آن نهفته است، به طوری که در هر سه سناریو، عملکردی رقابتی و در اکثر موارد برتر از خود نشان می‌دهد. این قابلیت تنظیم‌پذیری، آن را از یک الگوریتم تک‌بعدی به یک ابزار کنترلی هوشمند تبدیل می‌کند. به طور خاص، در سناریوی رویکرد متوازن، مجموع مقادیر نرمال‌شده برای رویکرد پیشنهادی (۰,۴۷) به شکل قابل توجهی کمتر از سایر رقبا است که نشان می‌دهد الگوریتم QAOA در شناسایی نقطه بهینه حقیقی در فضای چندبعدی راه‌حل‌ها بسیار مؤثر عمل کرده است. در مقایسه، پژوهش ماهاپاترا و همکارانش به دلیل بهره‌گیری از QML برای بهینه‌سازی چندین پارامتر QoS، نزدیک‌ترین رقیب محسوب می‌شود. با این حال، الگوریتم Q-FogSched آنها به دلیل پیچیدگی محاسباتی بالا، تأخیر و مصرف انرژی کمی بیشتر از روش پیشنهادی دارد. از سوی دیگر، دو پژوهش حسین، اختر و همکارانشان، با چارچوب مشترک QECC بر ادغام فناوری‌های کوانتوم، لبه و ابر متمرکز دارند و فاقد یک الگوریتم بهینه‌سازی دقیق و قابل تنظیم هستند و در نتیجه، عملکرد آن‌ها

"دیوار پیچیدگی" مواجه خواهند شد، در حالی که رویکرد پیشنهادی ما مقیاس‌پذیری بسیار بهتری خواهد داشت (همان‌طور که در تحلیل زمانی شکل ۴ نشان داده شد). این پژوهش، مدل‌سازی و نرم‌افزار لازم را برای بهره‌برداری از نسل آینده پردازنده‌های کوانتومی را فراهم می‌آورد و بدین ترتیب، شکاف نرم‌افزاری آینده را پر می‌کند تا با فراهم‌شدن سخت‌افزار کافی، بتوان از پتانسیل آن استفاده کرد.

مزیت رقابتی اصلی این رویکرد در مقیاس‌پذیری برتر و کیفیت بالاتر راه‌حل در مسائل بزرگ مقیاس نهفته است. همان‌طور که در نتایج شبیه‌سازی (به‌ویژه شکل‌های ۴ و ۱۰) نشان داده شده است، رویکرد پیشنهادی با رشد تقریباً خطی زمان محاسباتی، بر پدیده انفجار ترکیباتی غلبه می‌کند، در حالی که الگوریتم‌های سنتی و حتی رویکردهای مبتنی بر یادگیری ماشین کوانتومی با رشد نمایی یا چندجمله‌ای مواجه هستند. این مزیت، رویکرد ما را به یک راه‌حل راهبردی برای مدیریت بهینه سیستم‌های اینترنت اشیا نسل آینده تبدیل می‌کند.

۵- نتیجه‌گیری

در این پژوهش، چارچوبی نوآورانه برای حل مسئله پیچیده و چندوجهی تخصیص وظایف در شبکه‌های اینترنت اشیا با استفاده از یک رویکرد ترکیبی کوانتومی-سنتی ارائه شد. هدف اصلی ما غلبه بر چالش‌های مقیاس‌پذیری و ناکارآمدی الگوریتم‌های سنتی در مواجهه با انفجار ترکیباتی بود. با تبدیل مسئله به فرمت QUBO و حل آن توسط الگوریتم QAOA، نشان دادیم که می‌توان به طور همزمان چندین معیار حیاتی مانند تأخیر، مصرف انرژی و QoS را بهینه کرد. یافته‌های کلیدی این پژوهش، برتری قاطع رویکرد پیشنهادی را در مقایسه با پژوهش‌های پیشین، از جمله مدل‌های Q-FogSched، QECC و سایر روش‌های مشابه، اثبات می‌کند. نتایج شبیه‌سازی نشان داد که روش ما نه تنها به راه‌حل‌های با کیفیت‌تری دست می‌یابد، بلکه مقیاس‌پذیری بسیار بهتری نیز از خود نشان می‌دهد، به گونه‌ای که با افزایش ابعاد مسئله، عملکرد آن به شکل محسوسی از رقبا پیشی می‌گیرد. این تفاوت عملکرد ریشه در توانایی ذاتی الگوریتم‌های کوانتومی در کاوش موازی فضای جستجوی عظیم دارد که آن‌ها را قادر می‌سازد سریع‌تر به راه‌حل بهینه همگرا شوند. این پژوهش یک اثبات مفهوم قدرتمند برای امکان بهینه‌سازی کوانتومی در حل مسائل دنیای واقعی است که فراتر از توانایی‌های محاسبات سنتی هستند. برای پژوهش‌های آینده، می‌توان به ادغام سایر اهداف بهینه‌سازی مانند امنیت و قیمت‌گذاری منابع در مدل ریاضی پرداخت تا چارچوب جامع‌تری حاصل شود.

دهد. قطعاً تغییر این پارامترها مثلاً استفاده از پروتکل‌های کم‌مصرف مانند LoRaWAN یا گره‌های محاسباتی قدرتمندتر نتایج را تغییر خواهد داد، اما برتری اصلی رویکرد پیشنهادی در بهینه‌سازی تخصیص منابع، فارغ از مقادیر دقیق، همچنان پابرجا خواهد بود.

- در رویکرد پیشنهادی، ویژگی‌های کلیدی که مورد بهره‌برداری قرار گرفته‌اند عبارتند از:

۱. فرمول‌بندی مسئله به صورت بهینه‌سازی دودویی نامقید درجه دوم (QUBO): این ویژگی معماری محاسباتی، چالش اصلی تخصیص وظایف چندهدفه در اینترنت اشیا را مستقیماً به زبانی ترجمه می‌کند که برای الگوریتم‌های کوانتومی بهینه‌سازی، به‌ویژه الگوریتم بهینه‌سازی تقریبی کوانتومی (QAOA)، قابل فهم و حل است. این تبدیل، ساختار ترکیباتی مسئله را حفظ کرده و امکان بهره‌گیری از قدرت محاسبات کوانتومی را فراهم می‌آورد.
۲. بهره‌گیری از اصول کوانتومی در الگوریتم QAOA:

- برهم‌نهی: این الگوریتم با قرار دادن کیوبیت‌ها در حالت برهم‌نهی، قادر است فضای جستجوی بسیار بزرگ مسئله (شامل تمام ترکیبات ممکن برای تخصیص وظایف) را به صورت موازی و همزمان کاوش کند.

- درهم‌تنیدگی و تداخل: از طریق اعمال متناوب عملگرهای برگرفته از هامیلتونی مسئله و هامیلتونی ترکیب‌کننده، الگوریتم به صورت هدفمند، احتمال یافتن راه‌حل‌های بهینه را افزایش داده و راه‌حل‌های نامناسب را حذف می‌کند.

شبیه‌سازی انجام‌شده در این پژوهش، صرفاً یک بازنمایی سطحی از عملکرد الگوریتم نیست، بلکه پیاده‌سازی عددی دقیق الگوریتم کوانتومی QAOA بر پایه مدل ریاضی (QUBO) است. برتری نشان‌داده‌شده در نتایج، تصادفی یا ناشی از خطای شبیه‌سازی نیست، بلکه ریشه در برتری بنیادین و ریاضیاتی الگوریتم در کاوش فضاهای جستجوی ترکیباتی دارد. در واقع، شبیه‌سازی نشان می‌دهد در صورت وجود سخت‌افزار کوانتومی ایده‌آل، این مدل بهینه‌سازی به دلیل ساختار ذاتی خود، عملکردی برتر از روش‌های سنتی ارائه می‌کند. بنابراین، نتایج این پژوهش یک اثبات مفهوم (Proof-of-Concept) معتبر برتری الگوریتمی و نظری رویکرد پیشنهادی است. هدف اصلی این مقاله ارائه یک چارچوب راهبردی برای نسل آینده اینترنت اشیا است. ما ادعا نمی‌کنیم که این روش در شرایط کنونی فوراً قابلیت پیاده‌سازی تجاری دارد، بلکه نشان می‌دهیم که با بلوغ سخت‌افزارهای کوانتومی، رویکردهای سنتی با

مراجع

- Framework,” *Comput. Intell. Neurosci.*, vol. 2022, no. 1, p. 6138434, 2022.
- [10] T. A. Ahanger, F. Dahan, U. Tariq, and I. Ullah, “Quantum inspired task optimization for IoT edge fog computing environment,” *Mathematics*, vol. 11, no. 1, p. 156, 2022.
- [11] M. Bhatia, S. K. Sood, and S. Kaur, “Quantum-based predictive fog scheduler for IoT applications,” *Comput. Ind.*, vol. 111, pp. 51–67, 2019.
- [12] S. N. Ghorpade, M. Zennaro, B. S. Chaudhari, R. A. Saeed, H. Alhumyani, and S. Abdel-Khalek, “Enhanced differential crossover and quantum particle swarm optimization for IoT applications,” *IEEE Access*, vol. 9, pp. 93831–93846, 2021.
- [13] S. Khan, N. Younas, M. Alhussein, W. J. Khan, M. S. Anwar, and K. Aurangzeb, “Quantum Inspired Adaptive Resource Management Algorithm for Scalable and Energy Efficient Fog Computing in Internet of Things (IoT).,” *Comput. Model. Eng. Sci.*, vol. 142, no. 3, 2025.
- [14] M. Hayeri Khyavi, “Emerging technologies in future generations of high performance computing: introduction, taxonomy and future research directions,” *Journal of Information and Communication Technology*, vol. 55, no. 55, p. 26, 2023.
- [15] M. Esnaashari, F. Ehsani Boshla, M. Dehyadegari, and B. Samadi, “High Performance Computing: Next Generation Requirements and Research Axes,” *Journal of Information and Communication Technology*, vol. 51, no. 51, p. 209, 2022.
- [16] M. Azimzadeh, A. Rezaee, S. Jafarali Jassbi, and M. Esnaashari, “Community-Based Multi-Criteria Placement of Applications in the Fog Environment,” *Journal of Information and Communication Technology*, vol. 59, no. 59, p. 17, 2024.
- [17] A. G. Delavar, R. Akraminejad, and S. Mozafari, “WSTMOS: A Method For Optimizing Throughput, Energy, And Latency In Cloud Workflow Scheduling,” *Journal of Information and Communication Technology*, vol. 57, no. 57, p. 62, 2023.
- [18] Z. Abbasi, S. Fatahi, and M. J. Ershadi, “An approach to prioritize quality dimensions of based on cloud computing using Multiple Criteria Decision Making method,” *Journal of Information and Communication Technology*, vol. 53, no. 53, p. 224, 2023.
- [1] H.-Z. Xu et al., “Quafu-Qcover: Explore combinatorial optimization problems on cloud-based quantum computers,” *Chinese Phys. B*, vol. 33, no. 5, p. 50302, 2024.
- [2] A. Mahapatra, R. Pradhan, S. K. Majhi, and K. Mishra, “Quantum ML-Based Cooperative Task Orchestration in Dew-Assisted IoT Framework,” *Arab. J. Sci. Eng.*, vol. 50, no. 15, pp. 11975–12002, 2025, doi: 10.1007/s13369-024-09661-8.
- [3] M. I. Hossain, S. A. Sumon, H. M. Hasan, F. Akter, M. B. Badhon, and M. N. U. Islam, “Quantum-edge cloud computing: A future paradigm for iot applications,” *arXiv Prepr. arXiv2405.04824*, 2024.
- [4] S. Akter, M. B. Badhon, M. K. I. Bhuiyan, H. M. Hasan, F. Akter, and M. N. U. Islam, “Quantum-edge cloud computing for iot: Bridging the gap between cloud, edge, and quantum technologies,” *Edge, Quantum Technol. (September 29, 2024)*, 2024.
- [5] B. Narang, H. Virwani, and N. Jain, “Comprehensive Review on the Synergies and Challenges of Quantum Computing, Cloud Computing, and Fog Computing in New Era,” in *Proceedings of the 5th International Conference on Information Management \& Machine Intelligence*, in *ICIMMI '23*. New York, NY, USA: Association for Computing Machinery, 2024. doi: 10.1145/3647444.3652433.
- [6] Y. Mahmoudi, N. Zioui, and H. Belbachir, “A new quantum-inspired clustering method for reducing energy consumption in IOT networks,” *Internet of Things*, vol. 20, p. 100622, 2022, doi: <https://doi.org/10.1016/j.iot.2022.100622>.
- [7] S. Jannu et al., “Energy Efficient Quantum-Informed Ant Colony Optimization Algorithms for Industrial Internet of Things,” *IEEE Trans. Artif. Intell.*, vol. 5, no. 3, pp. 1077–1086, 2024, doi: 10.1109/TAI.2022.3220186.
- [8] K. Zانبوري, H. M. R. Al-Khafaji, N. J. Navimipour, and Ş. Yalçın, “A New Fog-Based Transmission Scheduler on the Internet of Multimedia Things Using a Fuzzy-Based Quantum Genetic Algorithm,” *IEEE Multimed.*, vol. 30, no. 3, pp. 74–86, 2023, doi: 10.1109/MMUL.2023.3247522.
- [9] T. Hasan et al., “Edge Caching in Fog-Based Sensor Networks through Deep Learning-Associated Quantum Computing