

## بهبود انتقال وظایف با استفاده از منطق فازی نوع ۲ و الگوریتم یادگیری تقویتی با سیاست مجاور برای افزایش عملکرد برنامه های اینترنت اشیا

مصطفی عابدی<sup>۱</sup>، سید ابراهیم دشتی<sup>۲</sup>

<sup>۱</sup>دانشجوی کارشناسی ارشد، دانشکده برق و کامپیوتر، واحد شیراز، دانشگاه آزاد اسلامی

abediiii.mostafaaaa@gmail.com

<sup>۲</sup>دانشکده برق و کامپیوتر، واحد جهرم، دانشگاه آزاد اسلامی (نویسنده مسئول)

Sayed.Dashty@gmail.com

### چکیده

این مقاله روش نوین مهاجرت وظایف ارائه می دهد که برای بهبود کارایی برنامه های اینترنت اشیا در یک معماری سه لایه در محیط محاسبات مه و ابر طراحی شده است. لایه اینترنت اشیا شامل دستگاه های هوشمندی است که تعداد زیادی وظایف تولید می کنند؛ وظایفی که هر یک دارای مشخصات متنوعی مانند اندازه، نیازهای محاسباتی، نیازهای ارتباطی و محدودیت های زمانی هستند. به دلیل محدودیت ذخیره سازی و ظرفیت محاسباتی دستگاه های اینترنت اشیا، لازم است این وظایف به لایه های مختلف منتقل شوند تا پردازش مؤثری انجام شود و اهداف کیفیت خدمات (QoS) برآورده شوند. برای حل این چالش، از یک برنامه ریز وظایف مبتنی بر منطق فازی نوع ۲ استفاده شده است تا تصمیم گیری های هوشمندانه ای برای مهاجرت وظایف انجام دهد. این برنامه ریز بر اساس ویژگی های وظایف، مناسب ترین لایه پردازشی را انتخاب می کند. علاوه بر این، در این مقاله از یادگیری عمیق تقویتی بهینه سازی سیاست مجاور (PPO) استفاده شده است تا با مهاجرت مناسب وظایف سطح مه، تعادل بار میان گره های همکار حفظ گردد. نتایج تجربی نشان می دهند که طرح پیشنهادی در مقایسه با روش های پیشرفته موجود، از نظر کاهش تأخیر، مصرف انرژی، استفاده از شبکه، توان عملیاتی و نرخ مهاجرت وظایف عملکرد بهتری دارد.

**کلمات کلیدی:** انتقال وظایف، منطق فازی نوع دو، برنامه های اینترنت اشیا، رایانش مه، یادگیری تقویتی عمیق، بهینه سازی سیاست مجاور (PPO).

### تاریخچه مقاله:

تاریخ ارسال: ۱۴۰۳/۰۲/۰۲

تاریخ اصلاحات: ۱۴۰۳/۰۵/۲۷

تاریخ پذیرش: ۱۴۰۳/۰۶/۲۱

تاریخ انتشار: ۱۴۰۳/۰۶/۳۰

ایمیل نویسنده مسئول: sayed.dashty@gmail.com

### ۱- مقدمه

گسترش فناوری اینترنت اشیا (IoT) به عنوان یکی از مؤلفه های اصلی تحول دیجیتال، به ظهور برنامه های کاربردی نوینی منجر شده است که نیازمند پردازش سریع، دقیق و کم هزینه داده ها هستند. برنامه هایی مانند وسایل نقلیه خودران [۱]، واقعیت افزوده، و سامانه های پایش سلامت هوشمند [۲]، [۳]، از جمله نمونه هایی هستند که نه تنها حساس به زمان اند، بلکه حجم عظیمی از داده ها را برای پردازش تولید می کنند. این نیازها، دستگاه های IoT را که معمولاً از منابع محاسباتی و انرژی محدودی برخوردارند، با چالش های جدی مواجه می سازد. برای پاسخگویی به این چالش ها، فناوری رایانش مه به عنوان مکملی برای رایانش ابری معرفی شده است. رایانش مه با انتقال خدمات محاسباتی به لبه شبکه، امکان پردازش داده ها را نزدیک به منبع تولید آن ها فراهم می کند [۴]. این قابلیت نه تنها تأخیر ناشی از انتقال داده ها به ابر را کاهش می دهد، بلکه مصرف انرژی و بار شبکه را نیز بهبود می بخشد. با این حال، بهره گیری از این

ساختار مقاله به شرح زیر است: بخش دوم به بررسی مطالعات مرتبط و روش های موجود در انتقال وظایف می پردازد. در بخش سوم، استراتژی پیشنهادی به تفصیل تشریح می شود. الگوریتم های مورد استفاده در بخش چهارم توضیح داده می شوند. بخش پنجم به ارزیابی عملکرد روش پیشنهادی و مقایسه آن با روش های مبنا اختصاص دارد. در نهایت، بخش ششم به نتیجه گیری و معرفی مسیرهای تحقیقاتی آینده می پردازد.

## ۲ - کارهای مرتبط

انتقال وظایف یک مفهوم تثبیت شده است که به طور گسترده در رایانش ابری استفاده می شود. تخصیص وظایف شامل انتقال وظایف از دستگاه های IoT که دارای منابع محدود هستند به دستگاه های غنی از منابع، با هدف بهبود عملکرد برنامه های حساس به زمان است. دستگاه های کاربر در لبه شبکه قرار می گیرند تا وظایف محاسباتی سنگین به گره های مه و ابر از طریق شبکه های 4G/5G یا شبکه های محلی بی سیم (WLAN) منتقل شوند. در مواردی که یک گره مه قادر به مدیریت حجم کاری فزاینده نباشد، گره های اضافی مه یا ابر برای کمک در نظر گرفته می شوند. این راه حل عملی، از طریق ارسال وظایف محاسباتی به سرورهای قدرتمند در سیستم مه-ابر، به پشتیبانی برنامه های IoT کمک می کند. محققان [۱۰] به طور سیستماتیک چالش های مربوط به انتقال وظایف را با استفاده از الگوریتم های یادگیری تقویتی (RL) و یادگیری عمیق تقویتی (DRL) تحلیل کرده اند. این مطالعه به بررسی فرآیند انتقال وظایف از جنبه های مختلف مانند تصمیم گیری انتقال وظایف، معیارها، جهت ها و حالت های انتقال وظایف می پردازد.

این بخش به بررسی مطالعات مرتبط و روش هایی می پردازد که با تحقیق ما ارتباط نزدیکی دارند. به عنوان مثال، مطالعه [۹] یک چارچوب بهینه سازی انتقال وظایف میان لایه های محاسباتی مه، ابری برای مدیریت داده های حجیم تولید شده در اینترنت اشیا (IoT) ارائه می دهد. هدف اصلی این چارچوب کاهش مصرف انرژی و تأخیر سرویس در محیط های پویا و تأخیر حساس است. این تحقیق با استفاده از مدل سازی ریاضی و تکنیک های برنامه ریزی خطی عدد صحیح، روشی را پیشنهاد

فناوری مستلزم حل مسائل پیچیده ای مانند انتقال وظایف و توزیع بار کاری در میان گره های مه است [۵].

انتقال وظایف به عنوان یکی از مهم ترین چالش ها، مستلزم تصمیم گیری هوشمندانه درباره محل پردازش وظایف (محلی، گره های مه یا ابر) و همچنین توزیع بهینه بار کاری میان گره های ناهمگون شبکه مه است. با افزایش تعداد درخواست ها، خطر افزایش زمان انتظار و کاهش عملکرد سیستم وجود دارد. در همین راستا، استراتژی های مختلفی مانند انتقال وظایف عمودی به ابر یا انتقال وظایف افقی میان گره های مه پیشنهاد شده اند، اما این روش ها هنوز با محدودیت هایی مواجه اند. برای مقابله با این چالش ها، این مقاله استفاده از منطق فازی نوع ۲ و الگوریتم یادگیری تقویتی با سیاست مجاور (PPO) را به عنوان یک استراتژی ترکیبی معرفی می کند. منطق فازی نوع ۲ با توانایی مدیریت عدم قطعیت در تصمیم گیری، برای انتخاب بهینه لایه پردازشی (محلی، مه یا ابر) به کار گرفته می شود [۶]. در همین حال، الگوریتم PPO به عنوان یکی از تکنیک های پیشرفته یادگیری تقویتی، فرآیند تخصیص وظایف به گره های مه و توزیع متوازن بار کاری در میان گره های یک خوشه را بهینه می کند [۷]. هدف اصلی این پژوهش ارائه یک استراتژی نوآورانه برای بهبود عملکرد برنامه های IoT از طریق انتقال بهینه وظایف در معماری سه لایه مه-ابر است. مزایای کلیدی این استراتژی عبارتند از:

۱. کاهش تأخیر: پردازش وظایف حساس به زمان در نزدیکی منبع داده.
۲. بهینه سازی مصرف انرژی: کاهش بار ارسالی به ابر و استفاده بهینه از منابع مه.
۳. توزیع بار کاری متوازن: جلوگیری از بارگذاری بیش از حد گره های قدرتمند و استفاده از ظرفیت تمامی گره های مه.

برای ارزیابی کارایی این روش، شبیه سازی هایی با استفاده از ابزار iFogSim انجام شده است که نشان می دهد استراتژی پیشنهادی در مقایسه با روش های موجود، تأخیر، مصرف انرژی، استفاده از شبکه، توان عملیاتی و نرخ موفقیت انتقال وظایف را بهبود می بخشد [۸].

نتایج شبیه سازی نشان داد که این روش زمان تأخیر را کاهش داده و توزیع بار کاری را در مقایسه با روش های جایگزین بهبود می بخشد. با این حال، طرح انتقال وظایف آن ها فاقد مکانیزم زمان بندی کارآمد و از پیش تعیین شده برای اختصاص لایه مناسب به هر وظیفه بود.

در برخی از مطالعات مرتبط [۱۵]، از منطق فازی و الگوریتم های یادگیری عمیق تقویتی (DQN) برای حل چالش های انتقال وظایف در محیط رایانش مه-ابر استفاده شده است. در این روش ها، منطق فازی برای تصمیم گیری اولیه در خصوص انتخاب لایه مناسب (مانند لایه محلی، مه یا ابر) بر اساس ویژگی های وظایف از جمله اندازه، نیاز محاسباتی و حساسیت به تأخیر به کار گرفته شده است. سپس الگوریتم DQN با استفاده از فرآیند یادگیری عمیق تقویتی، گره بهینه مه را برای پردازش وظایف انتخاب کرده و توزیع بار متوازن را میان گره های همکار مه تضمین می کند. این روش ها بهبودهایی در کاهش تأخیر، مصرف انرژی و توزیع بار کاری نسبت به سایر روش های موجود نشان داده اند، اما همچنان در نظر گرفتن ناهمگنی گره ها و همکاری پیشرفته میان گره های مه نیازمند توسعه بیشتر است.

برای غلبه بر محدودیت های موجود در مطالعات پیشین، ما در این مطالعه از منطق فازی نوع ۲ برای تصمیم گیری انتقال وظایف و از الگوریتم PPO برای انتخاب گره مه بهینه و توزیع بار متوازن استفاده می کنیم. این رویکرد ضمن توجه به ناهمگنی وظایف و گره های محاسباتی، همکاری میان گره های مه و الزامات حساس به تأخیر، عملکرد بهتری در کاهش تأخیر، مصرف انرژی و افزایش نرخ انتقال وظایف ارائه می دهد.

### ۳ - معماری سیستم پیشنهادی

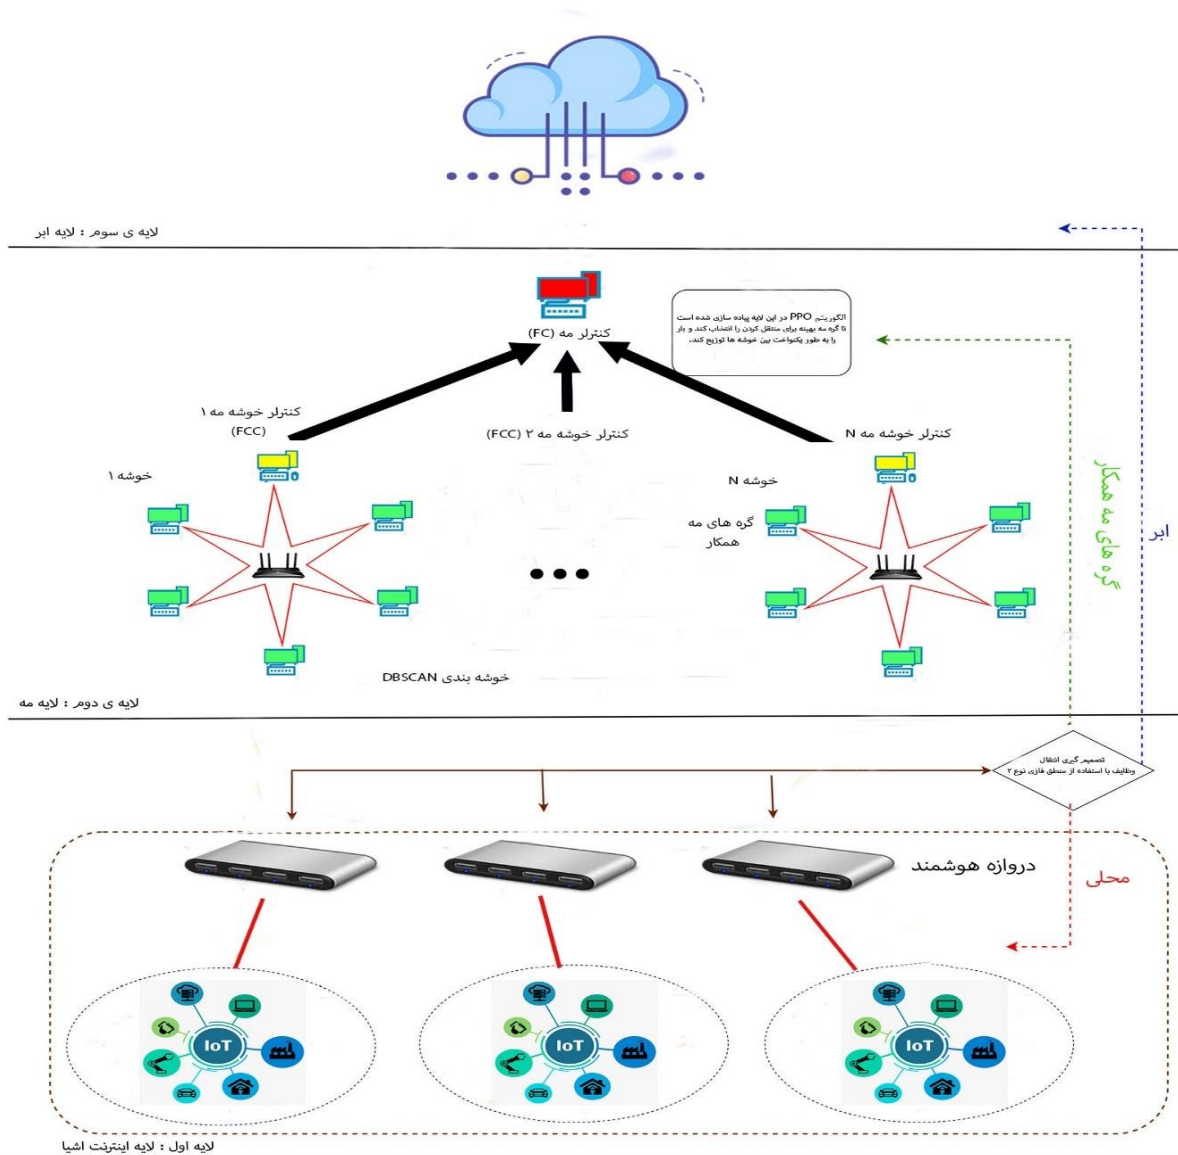
همان طور که پیش تر اشاره شد، چالش اصلی در رایانش مه این است که مشخص شود آیا وظایف باید به صورت محلی اجرا شوند یا به گره های مه و ابر منتقل شوند. چالش دیگر، توزیع مؤثر وظایف میان منابع موجود برای کاهش تأخیر و مصرف انرژی است. با وجود راه حل های ارائه شده برای این چالش ها در بخش

می کند که توزیع بهینه وظایف را بین دستگاه های مه و ابر فراهم می کند. نتایج نشان می دهد که این رویکرد در مقایسه با روش های موجود، تأخیر و مصرف انرژی کمتری دارد و عملکرد کلی سیستم را بهبود می بخشد.

مطالعه ای دیگر به منظور اولویت بندی وظایف و سیاست های انتقال وظایف با استفاده از منطق فازی [۱۱] انجام شد. هدف اصلی این روش، کاهش تأخیر و زمان انتظار متوسط بود. همچنین، اولویت وظایف در نظر گرفته شد و وظایف به صف های مناسب برای زمان بندی تخصیص داده شدند. این مطالعه از یک الگوریتم جایا چندجمعیتی با نخبگی باینری برای زمان بندی وظایف استفاده کرد. اگرچه نتایج نشان دهنده بهبود عملکرد این روش بود، اما این طراحی نتوانست گره بهینه مه را انتخاب کند و بار کاری را به طور یکنواخت توزیع کند.

مطالعه ی [۱۶]، به بررسی مسئله انتقال وظایف اینترنت اشیا (IoT) به لایه مه می پردازد تا زمان پاسخ دهی برنامه های IoT کاهش یابد. نویسندگان دو الگوریتم بهینه سازی الهام گرفته از طبیعت، شامل بهینه سازی کلونی مورچه ها (ACO) و بهینه سازی ازدحام ذرات (PSO)، را برای توزیع وظایف بر روی گره های مه معرفی می کنند. این الگوریتم ها هزینه ارتباطات، زمان محاسبه، و بار موجود روی گره های مه را در نظر می گیرند. نتایج تجربی نشان می دهد که الگوریتم ACO در کاهش زمان پاسخ دهی و توازن بار روی گره های مه عملکرد بهتری نسبت به PSO و الگوریتم Round Robin دارد. این تحقیق با هدف بهبود کیفیت سرویس در محیط های تأخیر حساس مانند شهرهای هوشمند ارائه شده است.

علاوه بر این، نویسندگان [۱۲] یک استراتژی نوآورانه برای انتقال وظایف ارائه کردند که هدف آن تصمیم گیری بهینه درباره زمان و مکان انتقال وظایف (گره های مه یا سرور ابری) بود. این مسئله به عنوان یک فرآیند تصمیم گیری مارکوف (MDP) فرموله شد. MDP معرفی شده شامل دو تصمیم گیرنده بود: کاربران IoT که مسئول انتخاب گره مه مناسب برای انتقال وظایف خود هستند و گره های مه که می توانند تصمیم بگیرند وظایف خاص را به سایر گره های مه یا به ابر منتقل کنند تا بار کاری به طور عادلانه توزیع شود. برای غلبه بر چالش های فضاهای بزرگ حالت و اقدام، یک روش مبتنی بر Q-Learning توسعه یافت تا یک سیاست ایده آل مشتق شود.



شکل ۱: مدل سیستم پیشنهادی

این معماری شامل دستگاه های IoT در لایه اول و گره های میانی برای مسیریابی وظایف به گره های مه یا ابر می شود. در ادامه، ویژگی های عملیاتی هر لایه توضیح داده شده است:

### لایه IoT

این لایه شامل دستگاه های هوشمند ناهمگن است که حجم قابل توجهی از داده ها را از طریق عملگرها مانند (موتورها و شیرها)، حسگرها مانند (حسگرهای دما، رطوبت و حرکت) و دستگاه های IoT هوشمند مانند (دوربین های هوشمند، دستگاه های پوشیدنی و ابزارهای نظارت محیطی) تولید می کنند. علاوه بر این، این لایه گره های میانی مانند سوئیچ ها و

قبل، همچنان فضا برای بهبود تأخیر و مصرف انرژی در سیستم های مه-ابر وجود دارد. این بخش یک استراتژی نوآورانه انتقال وظایف را معرفی می کند که با بهره گیری از زمان بندی وظایف و توزیع بار کاری، عملکرد برنامه های IoT را در معماری سه لایه مه-ابر بهبود می بخشد. معماری سلسله مراتبی پیشنهادی شکل ۱ شامل سه لایه است:

- لایه IoT (لایه اول)
- لایه مه (لایه دوم)
- لایه ابر (لایه سوم)

جدول ۱: انگیزه های اصلی تحقیق

لایه ها	ویژگی های عملیاتی	الگوریتم استفاده شده
لایه ی ۱ (دستگاه های IOT)	۱. جمع آوری داده ها ۲. تصمیم گیری بهینه در مورد: الف) به صورت محلی ب) گره مه مشارکتی پ) ابر	الگوریتم منطق فازی نوع ۲
لایه ی ۲ (لایه مه)	۱. خوشه بندی گره های مه ۲. انتخاب بهینه گره های مه و توزیع بار	خوشه بندی خوشه DBSCAN الگوریتم PPO
لایه ی ۳ (لایه ابر)	مسئول پردازش وظایف فشرده ای که محدودیت های سخت تاخیر ندارند.	-----

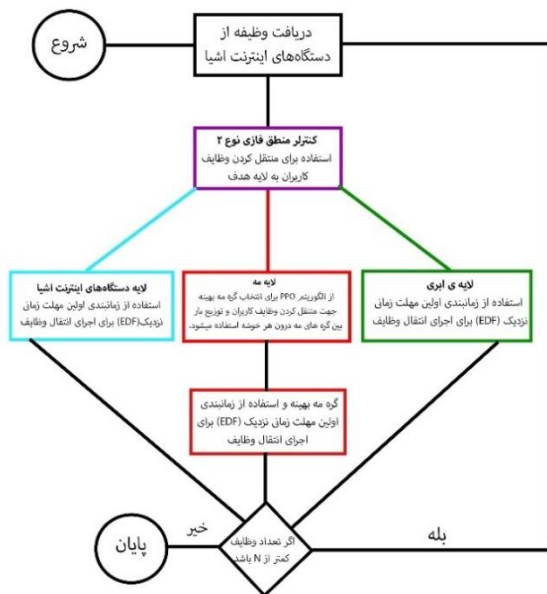
روترها را در بر می گیرد که به عنوان گیت وی های هوشمند عمل می کنند. به دلیل محدودیت در ظرفیت پردازشی و ذخیره سازی دستگاه های IOT، این گیت وی ها وظایف تولید شده را به گره های مه یا ابر منتقل می کنند. در این لایه، از منطق فازی نوع ۲ برای ارزیابی و دسته بندی وظایف بر اساس ویژگی های آن ها استفاده می شود تا لایه مناسب برای انتقال وظایف (محلی، گره مه همکار یا ابر) مشخص شود.

لایه مه

این لایه شامل گره های محاسباتی توزیع شده جغرافیایی است که به عنوان گره های مه شناخته می شوند. در این مرحله، از الگوریتم خوشه بندی DBSCAN برای خوشه بندی گره های مه بر اساس تراکم نقاط در فضای داده کار می کند. هر خوشه ترکیبی از منابع ناهمگن و همگن را برای برآورده کردن اهداف کیفیت خدمات در بر دارد. در هر خوشه، گره های مه با یک کنترل کننده خوشه مه (FCC) در ارتباط هستند و یک کنترل کننده مرکزی مه (FC) تمامی FCC ها را مدیریت می کند. در این لایه، از الگوریتم PPO برای انتخاب گره مه بهینه جهت منتقل کردن وظایف و توزیع متوازن بار کاری بین گره های همکار استفاده می شود.

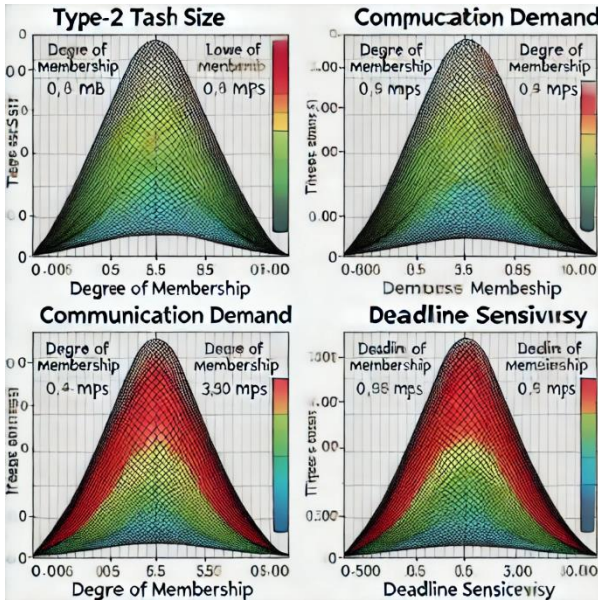
لایه ابر

این لایه وظیفه پردازش وظایف سنگین را که محدودیت تأخیر کمتری دارند بر عهده دارد و هدف آن به حداقل رساندن زمان خدمات و برآورده کردن مهلت های کلی وظایف است. این لایه شامل ماشین های مجازی قدرتمند و متمرکز است که به عنوان گره های محاسباتی عمل می کنند. بخش بعدی به تشریح جزئیات ویژگی های عملیاتی هر لایه در معماری پیشنهادی و الگوریتم های مورد استفاده برای زمان بندی وظایف و توزیع بار کاری جهت حل مسائل انتقال وظایف می پردازد. شکل ۲ جریان کلی مراحل استراتژی انتقال وظایف را نشان می دهد. همچنین، جدول ۱ انگیزه های اصلی تحقیق و الگوریتم های استفاده شده در این مطالعه را مشخص کرده.



شکل ۲: جریان کلی مراحل استراتژی انتقال وظایف

در این مرحله، رویکرد پیشنهادی اطلاعات مرتبط با وظایف منتقل شده را جمع آوری می کند تا مکان مناسب برای انتقال وظایف (محلی در لایه IoT، گره های مه همکار یا ابر) را تعیین کند. این فرآیند در شکل ۳ نشان داده شده است.



شکل ۳: تصمیم گیری انتقال وظایف با استفاده از منطق فازی نوع ۲

### فرآیند زمان بندی و تخصیص وظایف

در این فاز، از کنترل کننده منطق فازی نوع ۲ برای ارزیابی و دسته بندی وظایف بر اساس ویژگی های آن ها استفاده می شود. هدف از این فرآیند، انتخاب لایه پردازشی مناسب است. وظایف در سه کلاس به شرح زیر دسته بندی می شوند:

**کلاس محلی (Q1):** شامل وظایف دارای اولویت بالا که دارای تأخیر بسیار کم هستند و نیاز به منابع محاسباتی و ارتباطی زیادی ندارند. این وظایف در لایه IoT پردازش می شوند.

**کلاس گره های مه همکار (Q2):** شامل وظایفی با تأخیر متوسط که نیاز به سطوح متوسطی از منابع محاسباتی و ارتباطی دارند. این وظایف به گره های مه همکار با منابع نامگن و همگن انتقال داده می شوند.

## ۴ - الگوریتم های استفاده شده در معماری پیشنهادی

این بخش به تشریح جزئیات ویژگی های عملیاتی هر لایه در معماری پیشنهادی می پردازد. همچنین، الگوریتم های مورد استفاده برای زمان بندی وظایف و توزیع بار کاری جهت حل چالش های انتقال وظایف معرفی می شوند.

### الف) لایه IoT: جمع آوری داده ها

لایه IoT حجم عظیمی از داده ها را از دستگاه های هوشمند نامگن IoT تولید می کند. این داده ها دارای ویژگی های متفاوتی مانند اندازه، نیاز محاسباتی، نیاز ارتباطی و محدودیت تأخیر هستند. مراحل آماده سازی برنامه ها به صورت شبه کد به شرح زیر است: برای اجرای روش پیشنهادی، عناصر زیر ایجاد می شوند: دستگاه های IoT، گیت وی های هوشمند، گره های مه همگن، مراکز داده ابری، برنامه های IoT و توپولوژی شبکه. در ادامه، شبیه ساز اجرا می شود. در هر بازه زمانی، هر وظیفه، یک برنامه IoT با پارامترهای متفاوتی (مانند اندازه، نیاز محاسباتی، نیاز ارتباطی و محدودیت تأخیر) ایجاد می کند. در مرحله نهایی این الگوریتم، بهترین منابع محاسباتی برای انتقال وظایف کاربر انتخاب می شوند.

### الگوریتم ۱: مقداردهی اولیه برنامه اینترنت اشیا و مهاجرت وظایف

- 1: Initialize IoT system with devices, gateways, and computing layers
- 2: Deploy fog nodes and cloud data center
- 3: Define application structure and communication framework
- 4: while application is running do
- 5:     Generate task and identify attributes
- 6:     Evaluate uncertainties using Type-2 Fuzzy Logic
- 7:     Decide execution (local, fog, or cloud) using PPO
- 8: end while

متغیر ورودی	$x$
درجه عضویت فازی نوع ۱ (مقادیر بین ۰ و ۱)	$u$
مجموعه‌ای از مقادیر ممکن برای $\mu(x)$	$J_x$
تابع عضویت نوع ۲ که مقدار توزیع عضویت را بر $u$ مشخص می‌کند.	$\mu^{\sim}_A(x, u)$

**کلاس ابر (Q3):** شامل وظایفی که نیاز به منابع محاسباتی و ارتباطی بالا دارند و محدودیت تأخیر کمتری دارند. این وظایف در ابر پردازش می‌شوند. در این فرآیند، منطق فازی نوع ۲ برای دسته‌بندی درخواست‌های کاربر به صف‌های مناسب (Q1، Q2، Q3) استفاده می‌شود.

### موتور استنتاج فازی :

در موتور استنتاج، قوانین فازی مانند نوع ۱ بر اساس منطق "اگر-آنگاه" اعمال می‌شوند. اما در منطق فازی نوع ۲، به دلیل توابع عضویت فازی، خروجی هر قانون یک مجموعه فازی نوع ۲ است، نه یک مقدار دقیق. قوانین فازی معمولاً به صورت زیر تعریف می‌شوند:

اگر زیاد = Task Size و کم = Delay Tolerance آنگاه  
محلی = Offload

در نوع ۲، محاسبات قوانین فازی باید برای تمامی مقادیر احتمالی در بازه عضویت انجام شود. این باعث می‌شود خروجی هر قانون، یک تابع فازی دو بعدی باشد.

### دی فازی سازی :

در این مرحله، خروجی‌های فازی نوع ۲ که از موتور استنتاج تولید شده‌اند، به یک مقدار قطعی (Crisp) تبدیل می‌شوند. در منطق فازی نوع ۲، دی‌فازی‌سازی معمولاً به کمک کاهش نوع (Type Reduction) انجام می‌شود.

### روند کاهش نوع :

کاهش نوع فرایندی است که یک مجموعه فازی نوع ۲ را به یک مجموعه فازی نوع ۱ تبدیل می‌کند. روش‌های معروف کاهش نوع عبارت‌اند از:

- روش کرنر
- روش میانگین مرکز

### معماری منطق فازی نوع ۲

منطق فازی نوع ۲ از چهار بخش اصلی تشکیل شده است:

۱ - ورودی‌های فازی (Fuzzy Inputs)

۲ - فازی سازی (Fuzzification)

۳ - موتور استنتاج فازی (Inference Engine)

۴ - دی فازی سازی (Defuzzification)

### ورودی های فازی :

در این مرحله، داده‌های ورودی که ممکن است دارای ابهام و عدم قطعیت باشند، به سیستم وارد می‌شوند. ورودی‌ها شامل اندازه وظیفه، نیاز محاسباتی، نیاز ارتباطی و محدودیت تأخیر باشند.

### فازی‌سازی :

در منطق فازی نوع ۲، فازی‌سازی به جای استفاده از توابع عضویت قطعی مانند نوع ۱، از توابع عضویت فازی استفاده می‌کند. این توابع عضویت فازی مقادیر درجه عضویت را به صورت بازه‌ای و فازی نمایش می‌دهند. درجه عضویت برای هر مقدار ورودی، یک بازه از اعداد است که به آن تابع عضویت نوع ۲ یا Membership Function Type-2 می‌گویند. این بازه به صورت مجموعه فازی سطح بالاتر نمایش داده می‌شود. یک تابع عضویت نوع ۲ به صورت زیر تعریف می‌شود:

$$\{ [1,0] \subseteq J_x \in X, u \in \mu^{\sim}_A(x, u) \mid x, (x, u) \} = A^{\sim} \quad (1)$$

- **MinPts** : حداقل تعداد نقاط مورد نیاز در یک شعاع  $\epsilon$  برای تشکیل یک خوشه.

۲- طبقه بندی نقاط : نقاط داده به سه دسته تقسیم می شوند:

- **Core Points (نقاط اصلی)** : نقاطی که حداقل **MinPts** نقاط دیگر در شعاع  $\epsilon$  خود دارند.
- **Border Points (نقاط مرزی)** : نقاطی که خودشان **Core** نیستند اما در شعاع  $\epsilon$  یک نقطه **Core** قرار دارند.
- **Noise Points (نویز)** : نقاطی که نه **Core** هستند و نه در شعاع  $\epsilon$  یک **Core Point** قرار دارند.

۳- انتخاب نقطه شروع : الگوریتم از یک نقطه شروع می کند و همسایگان آن را در شعاع  $\epsilon$  جستجو می کند.

۴- تشکیل خوشه ها:

- اگر نقطه شروع یک **Core Point** باشد:
  ۱. خوشه ای جدید تشکیل می شود.
  ۲. تمامی نقاط در شعاع  $\epsilon$  که به این نقطه متصل هستند، به خوشه اضافه می شوند.
  ۳. این فرآیند به صورت بازگشتی ادامه می یابد تا زمانی که دیگر نقطه ای برای اضافه شدن وجود نداشته باشد.
- اگر نقطه شروع **Core** نباشد: نقطه بررسی شده به عنوان نویز علامت گذاری می شود یا به خوشه ای موجود اضافه می شود (اگر نقطه مرزی باشد).

۵- تکرار برای نقاط باقی مانده : این فرآیند برای تمام نقاط داده تکرار می شود تا زمانی که تمامی نقاط بررسی شوند. هر خوشه دارای یک کنترل کننده خوشه مه (نمایش داده شده با رنگ زرد) است که مسئول مدیریت منابع در سراسر خوشه و توزیع مؤثر بار کاری است. این کنترل کننده همچنین تعیین می کند که کدام گره مه می تواند درخواست های ورودی را پردازش کند. هر گره مه در یک خوشه با کنترل کننده خوشه مه (FCC) ارتباط برقرار می کند. کنترل کننده مه (FC) مسئول اتصال تمامی FCC های لایه مه است. در فرآیند انتقال

پس از کاهش نوع، خروجی به یک مقدار قطعی دی فازی سازی می شود. این مقدار خروجی نهایی برای تصمیم گیری در سیستم خواهد بود.

الگوریتم ۲: تصمیم گیری مهاجرت وظایف با استفاده از الگوریتم منطق فازی نوع ۲

---

Input: Application's Task  $T_i$  with parameters (Task Size, Computational Demand, Delay Constraint),  
number of computing nodes  $C_{ni}$   
Output: Optimal Offloading decision (Locally, Collaborative fog, Cloud)

- 1: For all Tasks in  $T_i$  do
- 2:  $F = \text{Type2FuzzyLogicSystem}(\text{TaskSize}, \text{ComputationalDemand}, \text{DelayConstraint})$
- 3: Compute uncertainty level  $U$  in  $F$
- 4: If  $F - U \leq \text{Flow}$  then
- 5: Allocate  $T_i$  on IoT layer
- 6: else
- 7: If  $F - U \leq F_{\text{medium}}$  then
- 8: Allocate  $T_i$  on collaborative fog
- 9: Start Algorithm 4
- 10: else
- 11: Allocate  $T_i$  on cloud
- 12: End if
- 13: End if
- 14: End for

---

(ب) لایه مه: انتخاب گره مه بهینه با الگوریتم PPO

این لایه وظایفی را پردازش می کند که دارای نیازهای محاسباتی و ارتباطی متوسط و تأخیر متعادل هستند. در این مرحله، رویکرد پیشنهادی از الگوریتم خوشه بندی DBSCAN برای خوشه بندی گره های مه به خوشه های مختلف استفاده می شود. بر اساس [۱۳] فرآیند خوشه بندی DBSCAN شامل مراحل زیر است:

۱- تعیین پارامترها:

- **Epsilon ( $\epsilon$ )** : شعاعی که برای جستجوی همسایگان هر نقطه استفاده می شود.

### ۳ - جمع آوری داده‌ها و تجربه‌ها:

عامل با محیط تعامل دارد و تجربیات را به شکل  $(a_t, r_t, S_t, S_{t+1})$  جمع آوری و در حافظه ذخیره می‌کند.

### ۴ - به‌روزرسانی سیاست:

با استفاده از داده‌های جمع‌آوری‌شده، پارامترهای سیاست  $\theta$  از طریق بیشینه‌سازی  $L^{CLIP}(\theta)$  به‌روزرسانی می‌شوند. روش‌ها مبتنی بر گرادینت برای بهینه‌سازی استفاده می‌شوند.

### مزایای استفاده از PPO در رایانش مه

الگوریتم PPO با جلوگیری از به‌روزرسانی‌های شدید، پایداری و قابلیت اطمینان در فرآیند یادگیری را فراهم می‌کند. این ویژگی در محیط‌های پویا مانند رایانش مه که در آن شرایط شبکه و منابع به‌طور مداوم تغییر می‌کنند، بسیار مفید است. استفاده از PPO باعث می‌شود وظایف به صورت کارآمد بین گره‌های مه توزیع شوند، تأخیر و مصرف انرژی کاهش یابد و بار کاری به طور متعادل تقسیم شود. این روش شامل دو مرحله آموزش و آزمایش است که هدف آن منتقل کردن مؤثر وظایف در محیط محاسبات مه-ابر می‌باشد. در ابتدا، وظایف و گره‌های مه بر اساس حداقل تأخیر مورد نیاز و ظرفیت محاسباتی مرتب‌سازی می‌شوند. سپس شبکه‌های سیاست و ارزش (Value Network) الگوریتم PPO مقداردهی اولیه می‌شوند. همچنین، یک حافظه تجربی برای ذخیره تجربیات شامل حالت، اقدام، پاداش و مزیت (Advantage) ایجاد می‌شود.

### مرحله آموزش

در مرحله آموزش، فرآیند زیر طی می‌شود:

۱. عامل PPO بر اساس شبکه سیاست اقدام به انتخاب گره مه برای انتقال وظایف می‌کند.
۲. پس از اجرای هر اقدام، پاداش به‌دست می‌آید و وضعیت جدید ثبت می‌شود.
۳. مزیت هر اقدام با استفاده از برآورد مزیت تعمیم یافته محاسبه می‌شود تا میزان عملکرد بهتر از سیاست مرجع را مشخص کند:

وظایف، اگر یک خوشه در لایه مه نتواند به دلیل نیازهای پردازشی یک وظیفه را مدیریت کند، کنترل‌کننده مه بررسی می‌کند که آیا وظیفه می‌تواند به خوشه دیگری ارسال شود یا خیر. اگر پاسخ مثبت باشد، وظیفه به خوشه جایگزین ارسال می‌شود؛ در غیر این صورت به لایه ابر منتقل خواهد شد.

### استفاده از الگوریتم PPO برای انتقال هوشمند وظایف

از الگوریتم PPO (Proximal Policy Optimization) برای تصمیم‌گیری هوشمندانه در انتقال وظایف و متعادل‌سازی بار کاری استفاده شده است. الگوریتم PPO با بهینه‌سازی یک سیاست  $\theta^\pi$  اطمینان می‌دهد که به‌روزرسانی‌های سیاست در یک محدوده قابل اعتماد باقی می‌مانند و از تغییرات شدید جلوگیری می‌کند. مراحل اجرای این الگوریتم به شرح زیر است:

#### ۱ - تعریف محیط:

- **حالات ( $S_t$ ):** شامل اطلاعات مربوط به وظایف فعلی و وضعیت گره‌های مه (مانند منابع موجود، بار کاری و تأخیر).
- **اقدامات ( $a_t$ ):** انتخاب بهترین گره مه یا خوشه برای انتقال یک وظیفه.
- **پاداش ( $r_t$ ):** معیارهایی مانند کاهش زمان پردازش، کاهش تأخیر و متعادل‌سازی بار کاری.

#### ۲- بهینه‌سازی سیاست:

الگوریتم PPO تابع هدف زیر را بیشینه می‌کند:

$$E_t [\min (r_t(\theta)A_t, \text{clip}(r_t(\theta), 1 - \epsilon, 1 + \epsilon)A_t)] = L^{CLIP}(\theta) \quad (2)$$

در این فرمول:

$r_t(\theta) = \frac{\pi_\theta(a_t|s_t)}{\pi_{old\theta}(a_t|s_t)}$  نسبت احتمال سیاست جدید به سیاست قدیمی است.

$A_t$  تابع مزیت است که نشان می‌دهد یک اقدام نسبت به میانگین عملکرد چقدر بهتر است.  $\epsilon$  یک مقدار کوچک است که محدوده تغییرات را کنترل می‌کند.

### انتقال وظایف به لایه ابر

در صورتی که وظیفه‌ای به دلیل محدودیت‌های منابع در گره‌های مه نتواند اجرا شود، به لایه سوم یعنی ابر منتقل می‌شود. در این لایه، وظایف با استفاده از الگوریتم زمان‌بندی اولین مهلت زمانی نزدیک (EDF) پردازش می‌شوند تا کارایی کلی سیستم با حداقل تأخیر تضمین شود.

### ۵- ارزیابی عملکرد

این بخش عملکرد طرح پیشنهادی انتقال وظایف را با مقایسه با روش‌های مرجع بررسی می‌کند. معیارهای ارزیابی شامل میانگین کاهش زمان تأخیر، مصرف انرژی متوسط، استفاده از شبکه، بازدهی، و نرخ انتقال وظایف می‌باشد.

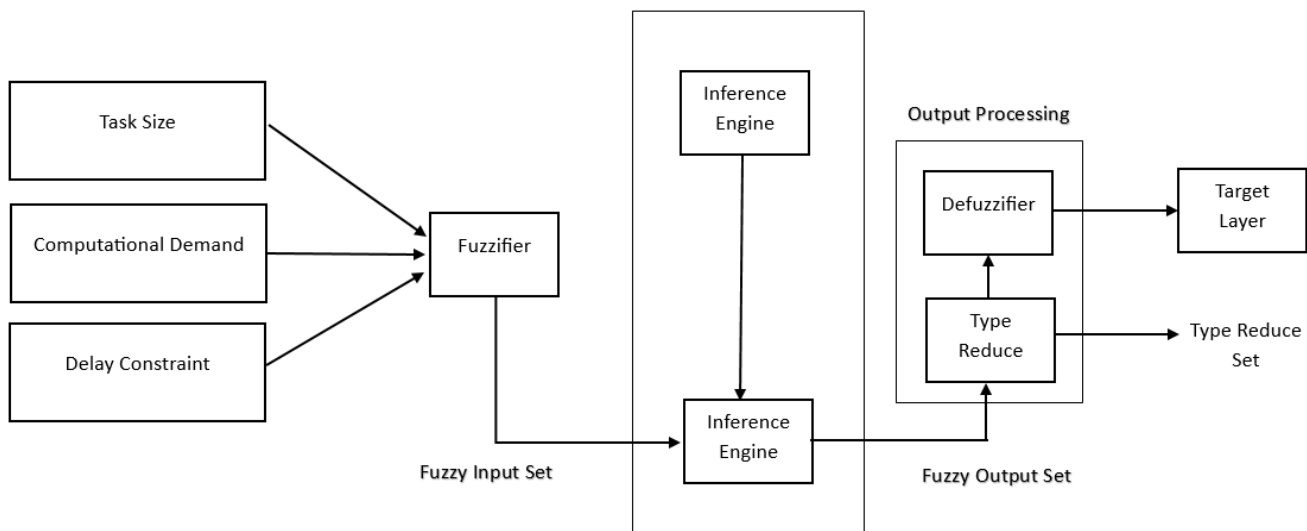
$$A_t^{\wedge} = \sum (\lambda \gamma^t) (V(S_t) - V(S_{t+1}) + R_t) \quad (3)$$

۴. داده های تجربی در حافظه بازپخش ذخیره می‌شوند.
۵. در فواصل زمانی مشخص، شبکه سیاست  $\pi$  با استفاده از هدف PPO-Clip بهینه سازی می‌شود
۶. شبکه ارزش  $V(S)$  نیز با مینیمم‌سازی خطای میانگین مربعات (MSE) به‌روزرسانی می‌شود :

$$L(V) = (V_{\gamma}(s') + R) - V(S))^2 \quad (4)$$

### مرحله آزمایش

در مرحله آزمایش، عامل آموزش‌دیده برای تخصیص وظایف به گره‌های مه از شبکه سیاست استفاده می‌کند:



شکل ۵: شماتیک منطق فازی نوع ۲

### الف. مطالعه موردی

سناریوی مورد بررسی شامل چندین دستگاه IoT از جمله سیستم‌های دوربین مداربسته هوشمند، خودروهای خودران و تلفن‌های هوشمند است. این دستگاه‌ها در حوزه‌هایی مانند حمل‌ونقل، تولید، بهداشت و امنیت کاربرد دارند. این برنامه‌ها

۱. برای هر وظیفه، وضعیت فعلی به شبکه سیاست داده شده و احتمال اقدام‌ها محاسبه می‌شود.
۲. اقدام (گره مه) با بیشترین احتمال به‌عنوان مقصد بهینه وظیفه انتخاب می‌شود.
۳. وضعیت جدید پس از تخصیص ثبت شده و این فرآیند برای تمام وظایف تکرار می‌شود.

سیستم عامل	Windows
------------	---------

توپولوژی شبکه iFogSim در شکل ۶ نشان داده شده است.

### پ. روش های مرجع برای مقایسه

برای نشان دادن اثربخشی استراتژی پیشنهادی، عملکرد آن با روش های زیر مقایسه شده است:

۱ - **NON-OFFLOAD**: در این روش، وظایف به صورت محلی اجرا می شوند و هیچ گونه انتقال وظایف به گره های مه یا ابر انجام نمی شود.

۲ - **FIRST FIT – FF**: در این روش، مقصد وظیفه بر اساس ترتیب گره های مه یا ابر در شبکه تعیین می شود [۱۴]. فرآیند انتخاب به این صورت است که گره مه اول برای انتقال وظایف بررسی می شود در صورت مناسب بودن، انتخاب می شود. در غیر این صورت، گره دوم ارزیابی می شود و این روند به ترتیب ادامه می یابد تا در نهایت به ابر ختم شود.

### ۳ - **GASDEO (Greedy Auto-Scaling Deep Reinforcement Learning-Based Offloading)**

: این روش از الگوریتم یادگیری تقویتی عمیق (DRL) برای انتخاب مقصد مناسب وظیفه استفاده می کند. در این استراتژی، تصمیم انتقال وظایف با هدف کاهش میانگین تأخیر انجام می شود. روش GASDEO شامل دو مرحله است، ابتدا، گره های مه به صورت محلی و با تکنیک حریصانه (Greedy) ارزیابی می شوند سپس، بهترین مقصد برای اجرای وظایف با استفاده از DRL مشخص می شود.

### ۴ - **NAFITO-FLA (A Novel Approach for IoT Tasks Offloading Based on Fuzzy Logic Algorithm)**

: این روش از منطق فازی برای شناسایی مکان مناسب انتقال وظایف استفاده می کند. جزئیات بیشتر در این مورد در [۱۵] توضیح داده شده است.

الگوریتم ۳: انتخاب بهینه گره مه Fog با استفاده از روش PPO

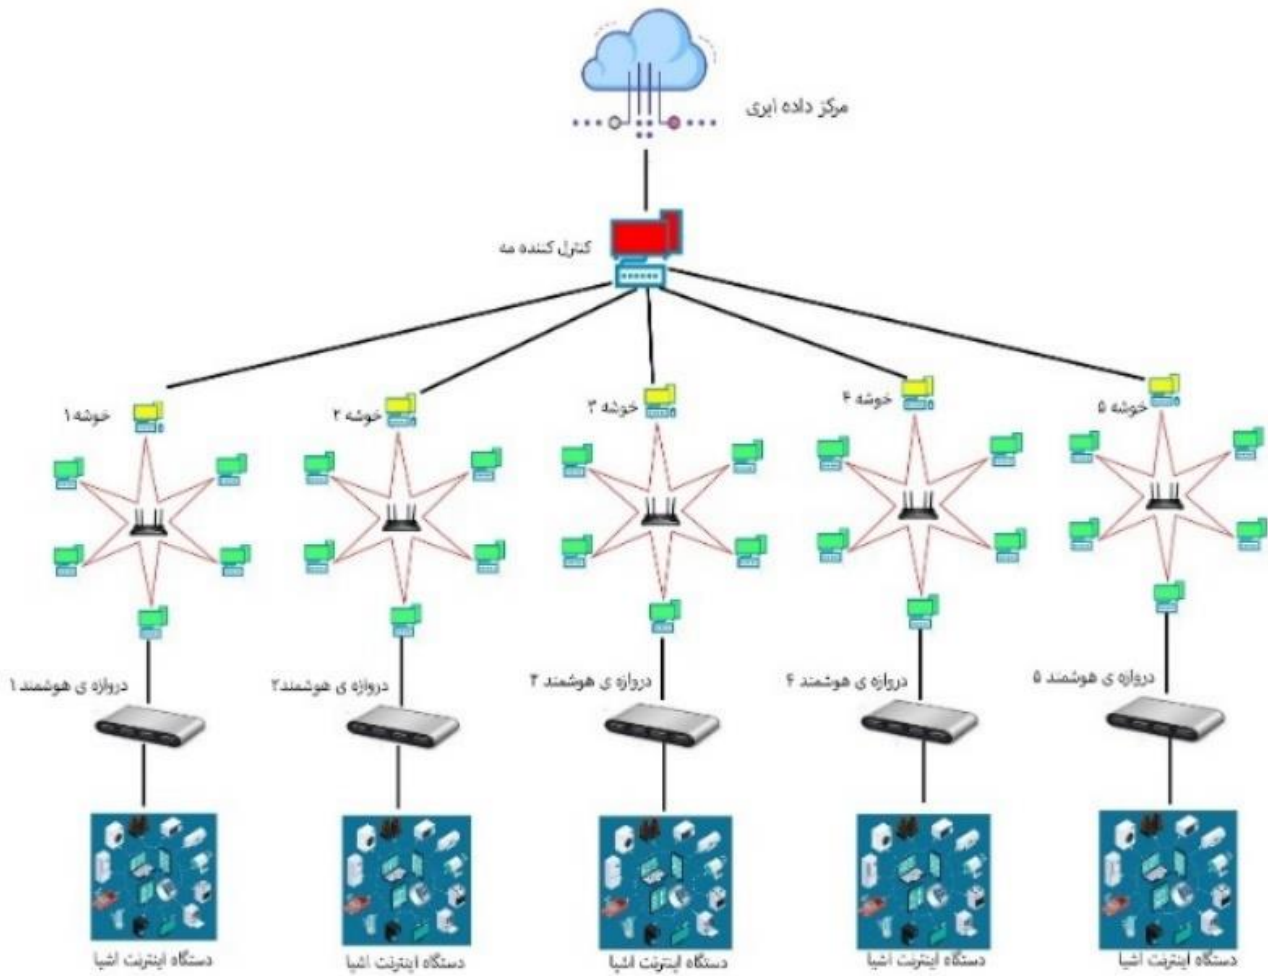
Input: Tasks (Ti), Fog Nodes (Fi)  
 Output: Task assignments to optimal fog nodes  
 1: Sort tasks by minimum required delay  
 2: Sort fog nodes by computational capacity  
 3: Initialize PPO parameters and networks (Policy  $\pi$ , Value V)  
 4: Train PPO:  
 5: For each episode and task, select action A using  $\pi$   
 6: Execute A, observe reward R, update state S'  
 7: Compute advantage  $\hat{A}$  using GAE  
 8: Optimize  $\pi$  with PPO-Clip and update V network  
 9: Periodically clear experience buffer  
 10: Assign tasks:  
 11: For each task, use  $\pi$  to select the best fog node  
 12: Store (Task, Optimal Fog Node) in TaskAssignments  
 13: Return TaskAssignments

نیازمند پردازش داده های حجیم و تأخیر پایین هستند. هر برنامه شامل وظایف مختلفی است؛ برای مثال، برنامه های CCTV هوشمند شامل وظایفی مانند تشخیص حرکت و شناسایی چهره می باشند. این وظایف از نظر مشخصاتی مانند اندازه، نیازهای محاسباتی، نیازهای ارتباطی و تأخیر تفاوت دارند. با توجه به این ویژگی ها و منابع موجود، وظایف می توانند در منابع محاسباتی محلی، گره های مه مشارکتی، یا ابر مستقر و اجرا شوند. جزئیات بیشتر درباره مدل های معماری پیشنهادی در بخش ۳ توضیح داده شده است.

### ب. تنظیمات شبیه سازی

کارایی استراتژی پیشنهادی با استفاده از شبیه ساز iFogSim ارزیابی شد. آزمایش ها روی سیستمی با مشخصات زیر انجام شدند:

پردازنده	Intel i7 2.4 GHz
رم	16 GB



شکل ۶: توپولوژی شبکه ی iFogSim

میلی ثانیه تخمین زده می شود، یکی از معیارهای مهم برای ارزیابی عملکرد سیستم های محاسبات مه است، به ویژه برای برنامه هایی که به حساسیت زمانی بالا نیاز دارند. تأخیر مربوط به یک وظیفه که توسط یک دستگاه IoT منتقل می شود، تحت تأثیر چهار عامل است:

### ت. معیارهای عملکرد

در این بخش، پارامترهای عملکردی به همراه فرمول های ریاضی مربوطه تعریف می شوند.

### ۱ - تأخیر (Delay)

تأخیر صف بندی ( $Q_d$ ) ، تأخیر انتقال ( $T_d$ ) ، تأخیر انتشار ( $Pro_d$ ) ، تأخیر پردازش ( $P_d$ )

مجموع تأخیر از رابطه زیر محاسبه می شود:

$$Delay = Q_d + T_d + Pro_d + P_d \quad (1-5)$$

### ۲ - مصرف انرژی (Energy Consumption)

مصرف انرژی برای کل توپولوژی شبکه با استفاده از معادله زیر محاسبه می شود:

$$E = E_c + (T_n - T_{lu}) * P_h \quad (2-5)$$

تأخیر یا زمان تأخیر هنگامی رخ می دهد که یک وظیفه برای پردازش به یک لایه مشخص ارسال می شود. نرخ تأخیر برای هر


نوع وظیفه با توجه به ویژگی های خاص آن متفاوت است. به عنوان مثال، زمان مورد نیاز برای پردازش و انتقال یک وظیفه در محلی با زمانی که برای پردازش و اجرای وظایف در گره های مه یا ابر نیاز است، متفاوت خواهد بود. تأخیر که معمولاً بر حسب

$$OFR = \frac{T_f}{N} * 100 \quad (5-5)$$

تعداد کل وظایفی که با موفقیت منتقل شده‌اند	$T_f$
تعداد کل وظایف، شامل وظایف محلی و منتقل شده	$N$

### ث. نتایج و بحث

در این بخش، نتایج به دست آمده از ارزیابی طرح پیشنهادی و بحث پیرامون عملکرد آن بررسی می‌شود.



شکل ۷: نمودار تاخیر در برابر وظایف

### ۱ - تأخیر (Delay)

در ابتدا میانگین تأخیر هر وظیفه به دلیل فرآیند انتقال وظایف مورد بررسی قرار می‌گیرد. شکل ۷ عملکرد روش پیشنهادی را در مقایسه با روش‌های مرجع نشان می‌دهد. مطابق این شکل، با افزایش تعداد وظایف، میانگین تأخیر نیز افزایش می‌یابد. این امر به دلیل ایجاد بار بیشتر روی گره‌های مه، افزایش تأخیر صف‌بندی و نیاز بیشتر به پهنای باند شبکه رخ می‌دهد. روش پیشنهادی در مقایسه با روش‌های مرجع در تمامی موارد عملکرد بهتری دارد. در روش‌های پایه، گره مه بهینه برای پردازش وظایف در نظر گرفته نمی‌شود که منجر به افزایش تأخیر خدمات می‌شود. روش Non-Offload بیشترین تأخیر را تجربه می‌کند، زیرا تمام وظایف به صورت محلی پردازش می‌شوند.

انرژی مصرفی فعلی	$EC$
زمان فعلی	$T_n$
زمان آخرین به روزرسانی استفاده	$T_{lu}$
توان میزبان در آخرین به روزرسانی	$P_h$

مدل‌های مختلفی برای کاهش مصرف انرژی در شبکه‌های مه و IoT توسعه یافته‌اند. این مدل‌ها تلاش می‌کنند چالش‌های مربوط به مصرف انرژی و تأخیر را در محیط‌های محاسبات مه برطرف کنند.

### ۳ - استفاده از شبکه (Network Usage)

میزان استفاده از شبکه به اندازه وظیفه منتقل شده در یک زمان مشخص و تأخیر وابسته است. استفاده از شبکه با رابطه زیر محاسبه می‌شود:

$$\text{Network usage} = \text{Latency} * \text{tupleSize} \quad (5-3)$$

### ۴- بازدهی (Throughput)

بازدهی به مقدار داده یا اطلاعاتی اشاره دارد که می‌تواند در یک بازه زمانی پردازش شود. این مقدار بر حسب بیت در ثانیه (bps) اندازه‌گیری می‌شود و با رابطه زیر بیان می‌گردد:

$$TH = \frac{Nspt}{Ti} \quad (4-5)$$


تعداد کل وظایفی که با موفقیت منتقل شده‌اند.	$Nspt$
زمان انتقال وظایف	$Ti$

### ۵ - نرخ انتقال وظایف (Offloading Rate)

نرخ انتقال وظایف به میزان انتقال وظایف یا بارهای کاری از یک دستگاه محلی به گره مه، ابر یا گره‌های مه مشارکتی دیگر گفته می‌شود. هدف اصلی نرخ انتقال وظایف، بهینه‌سازی استفاده از منابع و کاهش بار محاسباتی دستگاه‌های محلی از طریق انتقال وظایف به منابع قوی‌تر یا در دسترس در شبکه است. این نرخ به صورت ریاضی با رابطه زیر بیان می‌شود:

### ۳ - استفاده از شبکه (Network Usage)

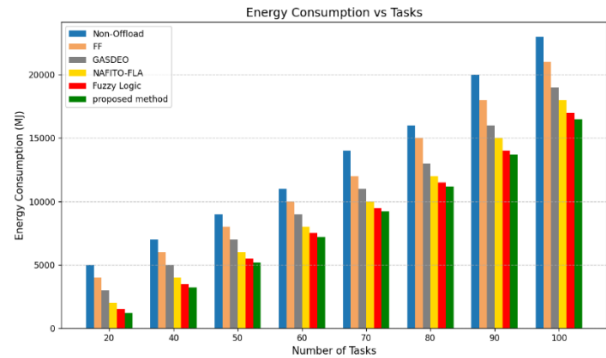
زمانی که ترافیک روی سرورهای ابری افزایش یابد، تنها از منابع ابری استفاده می‌شود. این موضوع باعث بهبود استفاده از شبکه در سرورهای ابری می‌شود. در سیستم‌های توزیع شده جغرافیایی، هر گره مه به منطقه‌ای خاص اختصاص دارد که درخواست‌ها از آن منطقه را مدیریت می‌کند. این موضوع باعث کاهش استفاده از شبکه در این نوع سناریوها می‌شود. شکل ۹ نتایج مقایسه استفاده از شبکه را نشان می‌دهد. روش Non-Offload از منابع شبکه استفاده نمی‌کند. با این حال، روش‌های FF، GASDEO، NAFITO-FLA و Fuzzy Logic نتایج تقریباً مشابه دارند. روش پیشنهادی توانسته در این معیار بهتر عمل کند و حتی با افزایش اندازه شبکه نیز کارایی خود را حفظ کند. استراتژی‌های هوشمند آفلودینگ در روش پیشنهادی می‌توانند با تعیین مکان پردازش مناسب، استفاده از شبکه را بهینه کنند.



شکل ۹: عملکرد بازردهی در برابر وظایف

### ۴ - بازردهی (Throughput)

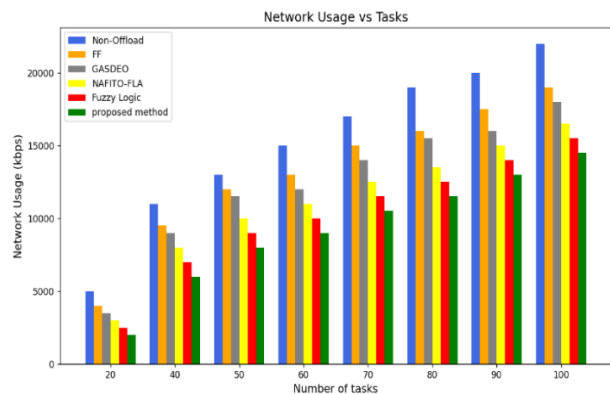
شکل ۱۰ عملکرد بازردهی میانگین را در برابر تعداد وظایف نشان می‌دهد. روش پیشنهادی در مقایسه با سایر روش‌ها بهترین عملکرد را در این معیار داشته است. این به دلیل توزیع بهتر وظایف بین چندین گره و سرور است. روش پیشنهادی اجازه می‌دهد وظایف متعددی به صورت همزمان بر روی منابع مختلف اجرا شوند، که منجر به پردازش سریع‌تر وظایف و بهبود بازردهی می‌شود. همچنین، تکنیک‌های تعادل بار مؤثر می‌توانند وظایف و پردازش داده‌ها را به طور یکنواخت بین گره‌های مه توزیع کرده و از تراکم شبکه جلوگیری کنند.



شکل ۸: مصرف انرژی در برابر وظایف

### ۲ - مصرف انرژی (Energy Consumption)

شکل ۸ کارایی روش پیشنهادی را از نظر مصرف انرژی در مقایسه با روش‌های موجود نشان می‌دهد. مطابق این شکل، مصرف انرژی تقریباً به صورت خطی با افزایش تعداد وظایف افزایش می‌یابد. این کاهش مصرف انرژی به دلیل استفاده از معماری پیشنهادی با روش بهینه برای زمان‌بندی وظایف و اجرای آن‌ها است. وظایف به گره‌های مه قدرتمندتر منتقل می‌شوند، که مصرف انرژی در گره‌های ضعیف‌تر را کاهش داده و بازردهی کلی را بهبود می‌بخشد. برنامه‌ریزی مؤثر وظایف و استراتژی‌های انتقال وظایف نیز می‌توانند با تعیین مکان پردازش بهینه، مصرف انرژی را به حداقل برسانند. روش‌های Non-Offload و FF به دلیل پردازش محلی و انتخاب غیر بهینه گره‌ها، مصرف انرژی بالاتری دارند.



شکل ۹: میزان استفاده از شبکه در برابر وظایف

## ۲- امنیت و حریم خصوصی (Security and Privacy)

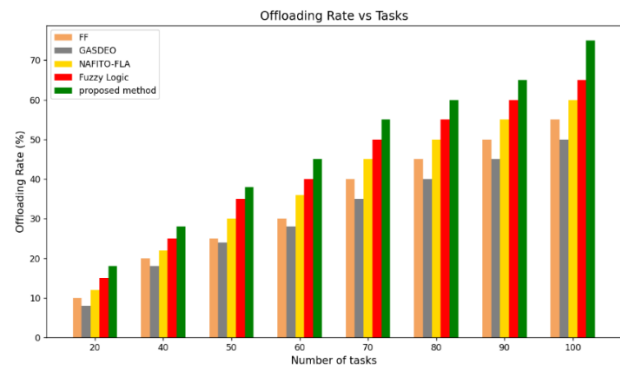
سیستم‌های مه-ابر شامل انتقال و پردازش داده‌های حساس هستند که نگرانی‌هایی در مورد امنیت و حفظ حریم خصوصی اطلاعات ایجاد می‌کنند [۱۹]. برای کاهش این خطرات:

- پروتکل‌های رمزنگاری قوی باید برای انتقال داده استفاده شوند، مانند پروتکل‌های SSL/TLS و رمزنگاری انتها به انتها [۲۰] (E2EE).
- مکانیزم‌های کنترل دسترسی مناسب باید اطمینان حاصل کنند که تنها موجودیت‌های مجاز به سیستم دسترسی دارند. این مکانیزم‌ها می‌توانند شامل احراز هویت مبتنی بر توکن یا بلاک‌چین باشند [۲۱].
- استفاده از تکنیک‌های حفظ حریم خصوصی مانند داده‌های دیفرانسیلی (Differential Privacy) می‌تواند خطرات افشای اطلاعات حساس را کاهش دهد [۲۲].

ادغام اقدامات امنیتی در کل معماری، انجام بازرسی‌های امنیتی دوره‌ای، و همکاری میان ذینفعان از مؤلفه‌های حیاتی این استراتژی هستند [۲۳].

## ۶- نتیجه گیری

در این مطالعه، ما یک استراتژی جدید برای برون‌سپاری وظایف ارائه دادیم که عملکرد برنامه‌های اینترنت اشیا (IoT) را در محیط‌های مه محاسباتی بهبود می‌بخشد. ایده اصلی طرح پیشنهادی شامل پردازش داده‌های حس شده تولید شده توسط دستگاه‌های اینترنت اشیا در لایه‌های مختلف معماری مه محاسباتی است. الگوریتم‌های منطق فازی نوع ۲ برای تصمیم‌گیری بهینه در مورد برون‌سپاری وظایف به لایه پردازشی هدف، چه در گره‌های مه محلی، چه گره‌های مه تعاملی یا ابر، با در نظر گرفتن چهار نیازمندی مختلف وظایف استفاده شدند. سپس، از روش یادگیری تقویتی عمیق مبتنی بر الگوریتم PPO برای انتخاب گره مه بهینه در میان گره‌های مه تعاملی جهت برون‌سپاری وظایف استفاده شد. در ادامه، یک روش زمان‌بندی وظایف با اولویت اولین مهلت زمانی نزدیک (Earliest Deadline First) برای زمان‌بندی وظایف بر روی تمام منابع محاسباتی پیشنهاد شد. در نهایت، نتایج



شکل ۱۱: نرخ انتقال وظایف در برابر وظایف

## ۵- نرخ انتقال وظایف (Offloading Rate)

نرخ انتقال وظایف به میزان وظایفی اشاره دارد که از دستگاه محلی به گره مه، ابر یا گره‌های مه دیگر منتقل می‌شوند. شکل ۱۱ عملکرد نرخ انتقال وظایف میانگین را در برابر تعداد وظایف نشان می‌دهد. این معیار نشان می‌دهد که روش پیشنهادی کارایی بهتری نسبت به سایر روش‌ها دارد. روش پیشنهادی منابع را به‌طور مؤثر استفاده می‌کند و وظایف را به منابع قدرتمندتر انتقال می‌دهد. این فرآیند باعث بهبود عملکرد، کاهش مصرف انرژی و استفاده بهینه از منابع می‌شود. همچنین، زمان‌بندی مؤثر و اولویت‌بندی سریع وظایف به افزایش نرخ انتقال وظایف کمک می‌کند.

## ج. محدودیت‌ها

این بخش محدودیت‌های روش پیشنهادی را در زمینه‌های توپولوژی ایستا، امنیت و حفظ حریم خصوصی روشن می‌کند:

### ۱- توپولوژی ایستا (Static Topology)

یکی از محدودیت‌های این روش وابستگی به توپولوژی ایستا است، به طوری که موقعیت دستگاه‌های IoT و گره‌های مه ثابت فرض شده‌اند. این در حالی است که در سناریوهای واقعی IoT، معمولاً نودهای متحرک حضور دارند که پویایی بیشتری را به سیستم اضافه می‌کنند و در این مطالعه به‌صراحت به آن پرداخته نشده است [۱۷]. پژوهش‌های اخیر نشان داده‌اند که استفاده از توپولوژی‌های پویا و طراحی مکانیزم‌های انتقال وظایف مبتنی بر حرکت، می‌تواند عملکرد سیستم را در چنین سناریوهایی بهبود بخشد [۱۸].

[8] A. K. M. A. Hossain, M. A. Chowdhury, A. Gani, and R. Ranjan, "iFogSim: A toolkit for modeling and simulation of resource management in the Internet of Things," *Proceedings of the 2017 IEEE/ACM International Conference on Utility and Cloud Computing (UCC)*, 2017.

[9] S. Beborita, S. S. Tripathy, U. M. Modibbo, and I. Ali, "An optimal fogcloud offloading framework for big data optimization in heterogeneous IoT networks," *Decis. Anal. J.*, vol. 8, Sep. 2023, Art. No. 100295, doi: [10.1016/j.dajour.2023.100295](https://doi.org/10.1016/j.dajour.2023.100295).

[10] D. H. Abdulazeez and S. K. Askar, "Offloading mechanisms based on reinforcement learning and deep learning algorithms in the fog computing environment," *IEEE Access*, vol. 11, pp. 12555–12586, 2023, doi: [10.1109/ACCESS.2023.3241881](https://doi.org/10.1109/ACCESS.2023.3241881).

[11] C. Chakraborty, K. Mishra, S. K. Majhi, and H. K. Bhuyan, "Intelligent latency-aware tasks prioritization and offloading strategy in distributed fog-cloud of things," *IEEE Trans. Ind. Informat.*, vol. 19, no. 2, pp. 2099–2106, Feb. 2023, doi: [10.1109/TII.2022.3173899](https://doi.org/10.1109/TII.2022.3173899).

[12] S. Aljanabi and A. Chalechale, "Improving IoT services using a hybrid fog-cloud offloading," *IEEE Access*, vol. 9, pp. 13775–13788, 2021, doi: [10.1109/ACCESS.2021.3052458](https://doi.org/10.1109/ACCESS.2021.3052458).

[13] M. Ester, H.-P. Kriegel, J. Sander, and X. Xu, "A density-based algorithm for discovering clusters in large spatial databases with noise," in *Proc. 2<sup>nd</sup> Int. Conf. Knowledge Discovery and Data Mining (KDD)\**, Portland, OR, USA, 1996, pp. 226–231.

[14] Q.-H. Nguyen and T.-A. Truong Pham, "Studying and developing a resource allocation algorithm in fog computing," in *Proc. Int. Conf. Adv. Comput. Appl. (ACOMP)*, Nov. 2018, pp. 76–82, doi: [10.1109/ACOMP.2018.00020](https://doi.org/10.1109/ACOMP.2018.00020).

[15] Dezeen H. Abdulazeez and Shavan K. Askar, "A Novel Offloading Mechanism Leveraging Fuzzy Logic and Deep Reinforcement Learning to Improve IoT Application Performance in a Three-Layer Architecture Within the Fog-Cloud Environment", date of current version 20 March 2024, ACCESS.2024.3376670

[16] M. K. Hussein and M. H. Mousa, "Efficient task offloading for IoT-based applications in fog computing using ant colony optimization," *IEEE Access*, vol. 8, pp. 37191–37201, 2020, doi: [10.1109/ACCESS.2020.2975741](https://doi.org/10.1109/ACCESS.2020.2975741).

[17] A. Leon-Garcia et al., "Dynamic Topology in IoT: Challenges and Solutions," *IEEE Internet of Things Journal*, vol. 7, no. 3, pp. 2152–2165, 2020.

[18] X. Wang et al., "Mobility-Aware Offloading in IoT," *Proceedings of IEEE ICC*, 2019.

[19] F. Bonomi et al., "Fog Computing and Its Role in IoT Security," *Proceedings of ACM MCC Workshop*, 2012.

[20] M. Abomhara et al., "Cyber Security and the Internet of Things," *Future Generation Computer Systems*, vol. 89, pp. 421–432, 2018.

شبیه سازی در چندین معیار عملکردی مقایسه شده و نشان داده شد که استراتژی برون سپاری پیشنهادی در معماری مه، از سایر روش های موجود بهتر عمل می کند.

در کارهای آینده، ما بر روی برون سپاری وظایف بدون در نظر گرفتن پارامترهای امنیتی تمرکز خواهیم کرد. به عنوان مثال، چه اتفاقی می افتد اگر یک وظیفه به یک گره مه در معرض خطر برون سپاری شود؟ ما در حال حاضر در نظر داریم این ویژگی را برای پیاده سازی های آینده بررسی کنیم. علاوه بر این، این مطالعه از یک توپولوژی ثابت استفاده کرده است و فرض کرده که دستگاه های اینترنت اشیا و گره های مه در موقعیت های ثابت قرار دارند. در حالی که در سناریوهای واقعی اینترنت اشیا ممکن است گره های متحرک در حال کار باشند. در نتیجه، ما قصد داریم در مرحله بعدی این تحقیق، تأثیر توپولوژی دینامیک بر کارایی طرح برون سپاری را بررسی کنیم.

## ۷ - منابع

[1] A. Ahmed, S. Abdullah, S. Iftikhar, I. Ahmad, S. Ajmal, and Q. Hussain, "A novel blockchain based secured and QoS aware IoT vehicular network in edge cloud computing," *IEEE Access*, vol. 10, pp. 77707–77722, 2022, doi: [10.1109/ACCESS.2022.3192111](https://doi.org/10.1109/ACCESS.2022.3192111).

[2] Y.-L. Jiang, Y.-S. Chen, S.-W. Yang, and C.-H. Wu, "Energy efficient task offloading for time-sensitive applications in fog computing," *IEEE Syst. J.*, vol. 13, no. 3, pp. 2930–2941, Sep. 2019, doi: [10.1109/JSYST.2018.2877850](https://doi.org/10.1109/JSYST.2018.2877850).

[3] M. Izhar, S. A. A. Naqvi, A. Ahmed, S. Abdullah, N. Alturki, and L. Jamel, "Enhancing healthcare efficacy through IoT-edge fusion: A novel approach for smart health monitoring and diagnosis," *IEEE Access*, vol. 11, pp. 136456–136467, 2023, doi: [10.1109/ACCESS.2023.3337092](https://doi.org/10.1109/ACCESS.2023.3337092).

[4] F. Bonomi, R. Milito, P. Natarajan, and J. Zhang, "Fog Computing and Its Role in the Internet of Things," *Proceedings of the First Edition of the MCC Workshop on Mobile Cloud Computing*, pp. 13–16, Aug. 2012

[5] M. Zorzi, L. G. Giordano, and A. F. M. D. M. P. D. T. M. W. G. B. F. S. M. M. R. S. C., "Task Offloading for IoT Applications: A Survey," *IEEE Communications Surveys & Tutorials*, vol. 18, no. 4, pp. 2641–2675, 2016.

[6] L. A. Zadeh, "Type-2 Fuzzy Logic: Theory and Applications," *Proceedings of the IEEE*, vol. 90, no. 5, pp. 1032–1052, May 2002.

[7] J. Schulman, F. Wolski, and R. H. D. S. McCool, "Proximal Policy Optimization Algorithms," *arXiv:1707.06347*, 2017.

سامانه های توزیع شده، سال هفتم، شماره ۱، شماره پیاپی ۱۳، صفحه ۳۳ تا ۵۰، سال ۱۴۰۳

**How to cite:** M. Abedi, S. E. Dashti, **Improving Task Offloading Using Type-2 Fuzzy Logic and Proximal Policy Reinforcement Learning to Enhance IoT Application Performance**, Journal of Distributed Computing and Systems (JDCS), Vol 7, Issue 1, Pages 33 - 50, 2024.

## Improving Task Offloading Using Type-2 Fuzzy Logic and Proximal Policy Reinforcement Learning to Enhance IoT Application Performance

Mostafa Abedi<sup>1</sup>, Seyed Ebrahim Dashti<sup>2</sup>

<sup>1</sup>M.Sc. Student, Faculty of Electrical and Computer Engineering, Shiraz Branch, Islamic Azad University  
[abediiii.mostafaaaa@gmail.com](mailto:abediiii.mostafaaaa@gmail.com)

<sup>2</sup>Faculty of Electrical and Computer Engineering, Jahrom Branch, Islamic Azad University (Corresponding Author)  
[Sayed.Dashty@gmail.com](mailto:Sayed.Dashty@gmail.com)

### Abstract

This paper presents a novel task offloading approach designed to improve the efficiency of IoT applications within a three-layer architecture in fog and cloud computing environments. The IoT layer consists of smart devices that generate numerous tasks, each with diverse characteristics such as size, computational requirements, communication needs, and time constraints. Due to the storage and computational limitations of IoT devices, it is necessary to offload these tasks to different layers to ensure efficient processing and meet Quality of Service (QoS) objectives. To address this challenge, a Type-2 Fuzzy Logic-based task scheduler is employed to make intelligent task migration decisions. This scheduler selects the most suitable processing layer based on the task

[21] K. Zhao et al., "Blockchain-Based Access Control for IoT," *IEEE Transactions on Industrial Informatics*, vol. 15, no. 6, pp. 3632-3641, 2019.

[22] C. Dwork, "Differential Privacy: A Survey of Results," *Lecture Notes in Computer Science*, 2008.

[23] S. Pearson and Y. Shen, "Privacy Management in IoT Architectures," *IEEE Cloud Computing*, vol. 3, no. 3, pp. 34-42, 2016.



مصطفی عابدی دانشجوی کارشناسی ارشد نرم افزار در دانشکده برق و کامپیوتر، دانشگاه آزاد اسلامی، واحد شیراز، ایران است. وی مدرک کارشناسی خود را در رشته مهندسی

کامپیوتر از دانشگاه آزاد اسلامی واحد شیراز دریافت کرده است. علاقه مندی های پژوهشی وی شامل الگوریتم های یادگیری ماشین، اینترنت اشیا، داده کاوی، هوش مصنوعی، مدل سازی و راستی آزمایی رسمی، و تحلیل قابلیت اطمینان می باشد. نشانه رایانامه ایشان عبارتند از :

[abediiii.mostafaaaa@gmail.com](mailto:abediiii.mostafaaaa@gmail.com)



سیدابراهیم دشتی، دانشیار دانشگاه آزاد اسلامی استان فارس، ایران است. وی مدرک دکتری خود را در رشته مهندسی کامپیوتر از دانشگاه علوم و تحقیقات تهران دریافت کرده است. و دارای چندین

جلد کتاب و دهها مقاله می باشند. علاقه مندی های پژوهشی وی شامل رایانش ابری، اینترنت اشیا، رایانش فراگیر و محاسبات نرم می باشد. نشانه رایانامه ایشان عبارتند از :

[Sayed.Dashty@gmail.com](mailto:Sayed.Dashty@gmail.com)

**روش ارجاع:** م.عابدی، س.ا.دشتی، بهبود انتقال وظایف با استفاده از منطق فازی نوع ۲ و الگوریتم یادگیری تقویتی با سیاست مجاور برای افزایش عملکرد برنامه های اینترنت اشیا، دوفصلنامه محاسبات و

characteristics. Additionally, this paper leverages Proximal Policy Optimization (PPO) deep reinforcement learning to maintain load balancing among cooperative nodes in the fog layer through optimal task migration. Experimental results demonstrate that the proposed scheme outperforms existing advanced methods in terms of reducing latency, energy consumption, network utilization, throughput, and task migration rate.