



ساوملی هفقه ٲرورش و فئاورمی



ءانشگاه بوعلی سینا  
ءانشكده مهندسی

ارائه ی مکانیسمی برای تعیین تابع توزیع بارکاری در پردازش های محاسبات مه  
بر پایه استفاده از سیستم های دسته بند یادگیر

گروه آموزشی کامپیوتر،  
ءانشكده مهندسی،  
ءانشگاه بوعلی سینا،  
همدان

استاد راهنما: جناب آقای ءکتر مهدی عباسی

ءانشجو: بهاره حمیدی محب

رشته: معماری سیستم های کامپیوتری

مقطع: کارشناسی ارشد

[b.hamidimoheb@eng.basu.ac.ir](mailto:b.hamidimoheb@eng.basu.ac.ir)

# چکیده

در سال های اخیر ، اینترنت اشیا (IoT) یکی از محبوب ترین فن آوری هایی است که تعاملات جدید میان افراد و انسان ها را برای ارتقا کیفیت زندگی تسهیل می کند. با توسعه سریع اینترنت اشیا ، الگوی محاسبات مه به عنوان یک راه حل جذاب برای پردازش داده های برنامه های اینترنت اشیا در حال ظهور است. در محیط مه ، برنامه های اینترنت اشیا توسط گره های محاسباتی میانی در مه و همچنین سرورهای فیزیکی در مراکز داده ابری اجرا می شوند. از طرف دیگر ، به دلیل محدودیت های منابع و انرژی ضروری است که مسائل مربوط به تصمیم گیری میزان بارکاری قابل پردازش به عنوان یکی از مشکلات چالش برانگیز در چشم انداز مه مورد توجه قرار گیرد. در این پژوهش قصد داریم راه حلی کارآمد و قابل پیاده سازی برای توزیع بارکاری مابین منابع پردازشی در لبه ی شبکه با در نظر گرفتن معیارهای انرژی و تأخیر و به شکلی بهینه ارائه دهیم. به طوری که از حداکثر توان منابع موجود در لبه ی شبکه بهره مند شویم. این مکانیزم بر پایه ی یادگیری تقویتی و سیستم های دسته بند یادگیر، با استفاده از الگوریتم XCSF تابعی را به عنوان میزان بارکاری پردازشی هر گره در لبه ی شبکه تقریب میزند.



## مقدمه

- اینترنت اشیا به ما اجازه می‌دهد، میلیاردها اشیاء فیزیکی را برای جمع‌آوری و مبادله داده‌ها به منظور ارائه برنامه‌های کاربردی، به یکدیگر متصل کنیم. نمونه‌ی این کاربردها، نظارت بر محیط‌زیست، مدیریت زیرساخت و دستگاه‌های خانگی به صورت خودکار است [۱]. اینترنت اشیا می‌تواند انسان و رایانه‌ها را برای یادگیری و تعامل با میلیاردها شیء که شامل حس‌گرها، ابزارها، سرویس‌ها و دیگر اشیاء متصل به اینترنت است در یک ارتباط شبکه‌ای فراهم کند. تحقق سیستم‌های اینترنت اشیا، سبب ادغام یکپارچه دنیای سایبری با دنیای فیزیکی می‌شود و اساساً تغییر و تقویت تعاملات انسانی با جهان را ایجاد می‌کند [۲].

اینترنت اشیا

محاسبات  
ابری

محاسبات  
مه

سیستم‌های  
دسته بندی  
کننده  
یادگیر

## مقدمه


- در حال حاضر، داده‌ها از شبکه‌های اینترنت اشیاء که شامل وسایل هوشمند هستند، جمع‌آوری و متراکم شده و سپس به کارزارهای ابری ارسال می‌شوند تا ذخیره‌سازی و مورد پردازش قرار گیرند. محاسبات ابری راه‌حلی را در سطح زیرساخت ارائه می‌دهد که پردازش داده‌های بزرگ را پشتیبانی می‌کند.
- در طول دهه گذشته، انجام محاسبات، کنترل و ذخیره‌سازی اطلاعات در شبکه‌های ابری، به مورد توجه قرار گرفته است. به‌طور خاص، محاسبات، ذخیره‌سازی و مدیریت شبکه به مراکز داده‌ی متمرکز، منتقل شده‌اند. با این حال، با ظهور اینترنت اشیاء، محاسبات ابر با چالش‌های رو به رشدی مواجه است. از چالش‌های به وجود آمده می‌توان به تأخیرها، محدودیت پهنای باند، منابع محدود دستگاه‌ها، اهمیت ارتباط امن و بدون وقفه اشاره کرد [۳، ۴].



## مقدمه

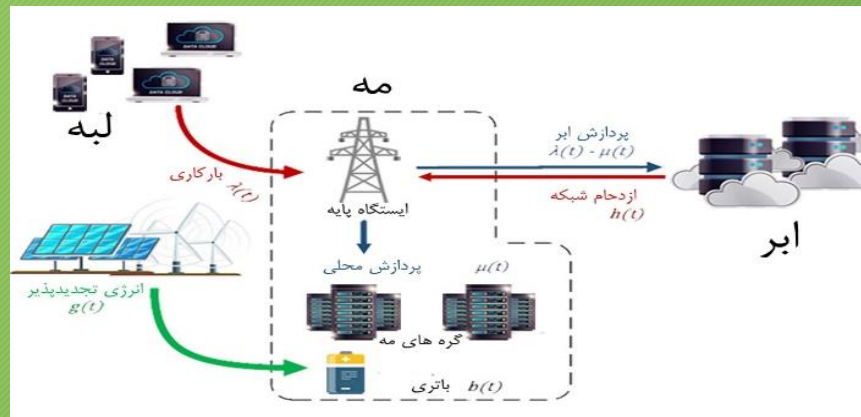
تحقیقات نشان داده است که برای کاهش این مشکلات، به جای استفاده از ابرهای دور و متمرکز، از منابع غیرمتمرکز در لبه‌های شبکه برای پردازش داده‌های نزدیک به کاربر می‌توان استفاده کرد. این موضوع به عنوان محاسبات مه‌آلود/ لبه نامیده می‌شود [۵، ۶]. در نتیجه فناوری اینترنت اشیا، نیاز به یک معماری جدید دارد تا محاسبات، کنترل، ذخیره‌سازی و توابع شبکه را به دستگاه‌های کاربر نهایی نزدیک کند. پردازش مه‌آلود به صورت توزیع شده است و کنترل و مدیریت سیستم‌های پردازش مه‌آلود نیاز به متخصص ندارد [۳].

همانطور که در شکل مشاهده میشود، معماری محاسبات مه‌آلود از سه لایه تشکیل میشود: الف) لایه پایین: شامل حس‌گرها، اشیاء و سایر ابزار متصل به اینترنت؛ ب) لایه میانی: شامل گره‌های مه/لبه و ج) لایه بالایی: که مراکز داده و ابرها را ساختار آن را تشکیل میدهد. لایه میانی (گره‌های لبه) شبکه از ارسال غیرضروری اطلاعات به سمت مراکز داده جلوگیری میکند و برخی از وظایف ابر را به عهده می‌گیرد [۵].



# مقدمه

- تخصیص بار، کار آسانی نیست زیرا معیارهای تخصیص منابع (که در بحث فوق ذکر شد) بسیار نزدیک و وابسته به یکدیگرند. به عنوان مثال، با توجه به محدودیت انرژی در لایه‌های پایین، بارکاری باید به مرکز داده‌ها فرستاده شود. از طرفی با ارسال این بارکاری به لایه‌های بالاتر، تأخیر به طور ناگهانی افزایش می‌یابد. پس باید معیارهایی برای بارهای کاری مختلف تعیین کرده، سپس آن‌ها را اولویت‌بندی کرد تا بتوان یک استراتژی تخصیص متناسب با معیارها، انتخاب کرد. بنابراین سه معیار تأخیر، انرژی و هزینه در استفاده از منابع توسط بارهای کاری هم‌زمان، باید مدنظر قرار گرفته شود [۷]. از طرفی تخصیص بار در گره‌های لبه‌ی شبکه باید به صورتی باشد که از منابع موجود در لبه‌ی شبکه حداکثر بهره‌وری را داشته باشیم. از روش‌های یادگیری تقویتی می‌توان برای به حداقل رساندن زمان بیکاری گره‌های لبه‌ی شبکه و استفاده بهینه از منابع و خدمات مه استفاده کرد [۸]. در شکل زیر پردازش بارکاری را در لایه‌ی مه نشان می‌دهد.

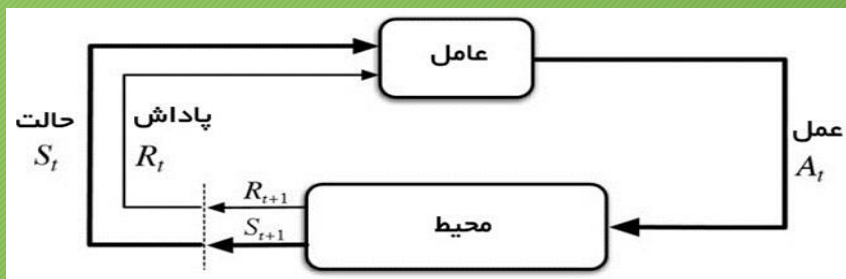




## مقدمه

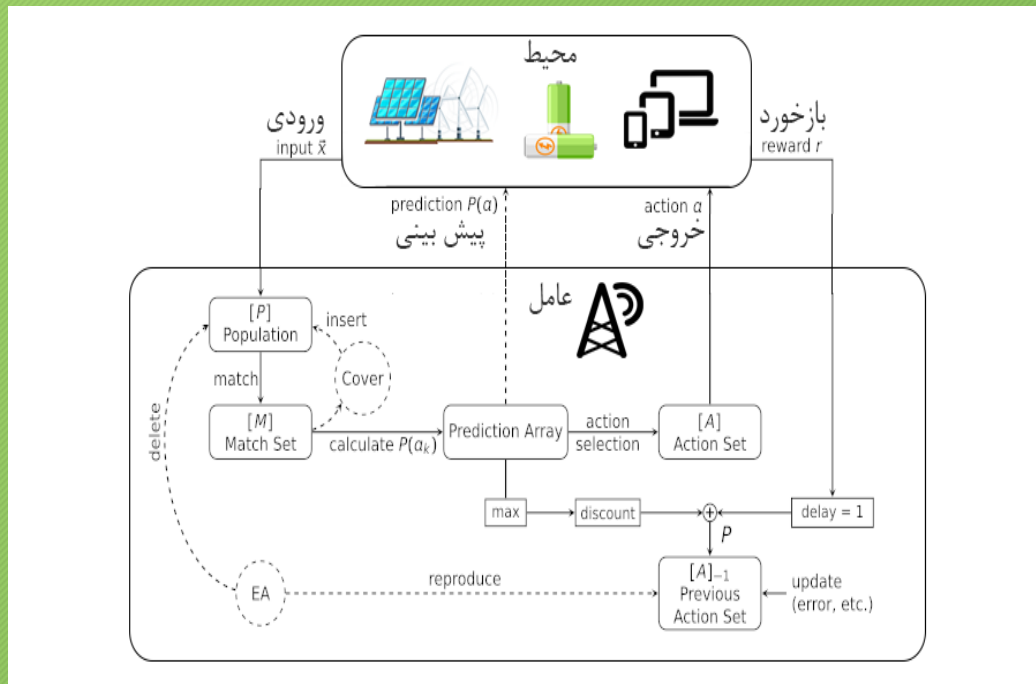
- در زمینه های یادگیری تقویتی ، به طور معمول از سیستم های دسته بند استفاده می شود. بنابراین تقریبی از تابع بازخورد خواهیم داشت که به سیستم اجازه میدهد برای هر ورودی که شامل میزان کل بار ورودی، وضعیت ازدحام شبکه و میزان انرژی تجدیدپذیر دریافت شده است، بهترین و بالاترین بازخورد را انتخاب کند [۹].

- سیستم های دسته بندی کننده یادگیر ، سیستم هایی مبتنی بر قانون هستند. در این سیستم ها قوانین عمدتاً به فرم “ IF **condition THEN action** هستند. از یک الگوریتم تکاملی یا روش های شهودی میتوان برای جستجو در فضای قوانین موجود و در همان زمان از فرآیند یادگیری دیگر برای انتساب نحوه استفاده به قوانین موجود میتوان استفاده نمود که در واقع باعث هدایت جستجو به سمت قوانین بهتر میشود [۱۰]. در محاسبات مه آلود، از سیستم دسته بندی کننده یادگیر برای کمک به تصمیم گیری ایستگاه پایه جهت تعیین میزان بار پردازشی در لبه شبکه استفاده میشود. شکل زیر نمایی از یک سیستم یادگیری تقویتی را که حوزه محاسبات مه آلود استفاده شده است نمایش می دهد. در واقع، ورودی این سیستم شامل میزان کل بار ورودی، وضعیت ازدحام شبکه و میزان انرژی تجدیدپذیر دریافت شده است و بازخورد همان هزینه ایست که به سیستم تحمیل شده است. الگوریتم مبتنی بر یادگیری نیز با هدف کاهش این هزینه ها عمل خواهد کرد [۱۱].



# روش انجام تحقیق

در این پژوهش، به منظور بهینه‌تر کردن این روش توزیع بار را به عنوان تابع در هر گره در نظر می‌گیریم و بنابراین میزان بارکاری قابل پردازش در هر گره، با توجه به ورودی سیستم، مقدار پویایی دارد به شکلی متعادل تر در هر گره توزیع خواهد شد و همچنین منجر به مدیریت منابع بهتر و کارایی بالاتر محاسبات مه‌آلود خواهد شد. بنابراین از یک سیستم دسته‌بند یادگیر به نام XCSF به منظور تعیین تابعی از میزان بارکاری پردازشی هر گره بهره‌مند خواهیم شد.



توزیع بار را به عنوان تابع در هر گره در نظر می‌گیریم و بنابراین از یک سیستم دسته‌بند یادگیر به نام XCSF به منظور تعیین تابعی از میزان بارکاری پردازشی هر گره بهره‌مند خواهیم شد. برای این منظور از کتابخانه‌ی XCSF [۱۲] به زبان ++C برای شبیه‌سازی استفاده خواهد شد. در شکل روبرو نمای کلی از XCSF مشاهده میشود. در این الگوریتم یک ورودی  $X$  را از محیط دریافت میکند و یک خروجی را محیط میدهد و متناسب با آن یک بازخورد دریافت میکند که به بهبود عملیات یادگیری دسته‌بندها کمک میکند.



# روش انجام تحقیق

تفاوت XCS و XCSF تنها در خروجی است. بازخورد و ورودی های آن یکسان است. XCS مقدار ثابتی را به عنوان خروجی میدهد درحالی که در XCSF خروجی به شکل تابع  $f(x)$  است. در این تابع  $w$  بردار وزنی است که در الگوریتم یادگیری تقویتی یادگرفته میشود. همانطور که قبلا هم ذکر شده بود، ورودی در محاسبات مه شامل میزان کل بار ورودی ، ازدحام شبکه و میزان انرژی تجدیدپذیر دریافت شده می باشد. بنابراین بردار ورودی ما شامل این سه مورد است و در هر گره پردازشی مه این تابع مشخص می شود. در واقع باید ضریب هر یک از این ورودی ها توسط سیستم های دسته-بند یادگیر تعیین شود.

XCSF در محاسبات مه	XCS در محاسبات مه	
$\lambda(t)$ : میزان کل بار ورودی $h(t)$ : وضعیت ازدحام شبکه $g(t)$ : میزان انرژی تجدیدپذیر دریافت شده	$\lambda(t)$ : میزان کل بار ورودی $h(t)$ : وضعیت ازدحام شبکه $g(t)$ : میزان انرژی تجدیدپذیر دریافت شده	ورودی (condition)
توان تاخیر مصرف باتری	توان تاخیر مصرف باتری	بازخورد (reward)
$f(x) = w \cdot x'$	$\mu(t)$ : میزان بار قابل پردازش در لبه ی شبکه	خروجی (action)

$$w = (w_0, w_1, \dots, w_n)$$

$$x' = (x_0, x_1, \dots, x_n)$$

## فرضیه‌ها

- در تامین انرژی به دلیل افزایش حجم پردازش‌ها در لبه‌ی شبکه و نبود منبع تولید انرژی در گره‌ها ، با چالش مواجه هستیم.
- قرار دادن منابع تولید انرژی در لبه‌های شبکه، بسیار پرهزینه است.
- با برخورداری از حداکثر توان منابع پردازشی موجود در شبکه میتوان تا حدی این کمبود انرژی را جبران کرد.
- امکان ارائه مدل جامعی از تخصیص بار بین گره‌های پردازش مه‌آلود با در نظر گرفتن معیارهای ارزیابی کارایی توزیع وجود دارد.
- الگوریتم‌های موجود در حوزه بهینه‌سازی امکان بهینه‌سازی مدل ارائه‌شده را با در نظر گرفتن معیارهای هزینه و انرژی فراهم می‌کنند.
- بکارگیری الگوریتم‌های یادگیری تقویتی و دسته‌بند یادگیر در تخصیص بارها به شکلی پویا و متناسب با منابع موجود در لبه‌ی شبکه
- برای هر گره تابعی به فرم  $f(x) = w \cdot x'$  ارائه خواهد شد. وزن‌ها ( $w$ ) با کمک الگوریتم XCSF یادگیری خواهند شد تا بهترین تابع برای هر گره در نظر گرفته شود.



## بحث و نتیجه گیری

از آنجاکه برخی از جریان‌های کاری حساسیت زیادی به تأخیر در زمان پاسخ دارند، نمیتوان آن‌ها را به سمت ابرها فرستاد و به‌ناچار باید این محاسبات در گره‌های لبه شبکه صورت پذیرد. پس با افزایش حجم پردازش‌ها در لبه‌ی شبکه و نبود منبع تولید انرژی در این گره‌ها، محاسبات مه‌آلود برای تأمین انرژی، دچار چالش جدی میشود. از طرفی برای قرار دادن منابع تولید انرژی در لبه‌های شبکه، هزینه‌های زیادی باید متحمل شد تا انرژی موردنیاز برای این محاسبات تأمین گردد.

همانطور که قبلاً هم گفته شد، محاسبات مه یک پلت فرم محاسباتی توزیع شده است که به جای انتقال از راه دور به ابر، قابلیت پردازش و ذخیره اطلاعات را برای انجام خدمات اینترنت اشیا به صورت محلی فراهم می‌کند. مشابه رایانش ابری، منابع ذخیره سازی، محاسبات و شبکه را فراهم می‌کند. با توجه به پویایی، ناهمگنی و عدم اطمینان محیط مه، یک مکانیسم مدیریت منابع برای واقعیت بخشیدن محاسبات مه بسیار ضروری است [۱۳].

با این روش پیشنهادی ضمن بهینه سازی تعادل بین تأخیر و مصرف انرژی، از حداکثر توان منابع پردازشی موجود در لبه‌ی شبکه بهره‌وری میشود. از آنجایی که میزان بار در گره‌های لبه به صورت تابعی از ورودی‌های گره‌های لبه‌ی شبکه در نظر گرفته میشود؛ لذا هر گره در لبه‌ی شبکه میتواند مقدار بارکاری متفاوتی با توجه به منابع پردازشی موجود در گره، پردازش کند و همین امر موجب کارایی بالاتر در محاسبات مه‌آلود میشود. لذا با استفاده از حداکثر توان منابع پردازشی موجود در لبه‌ی شبکه این تعادل بین تأخیر و مصرف انرژی را بهینه‌تر می‌شود.

# تقدیر و تشکر



از جناب آقای دکتر مهدی عباسی که راهنمایی این پایان نامه را به عهده دارند، کمال تشکر را دارم.



- [1] J. Ni, K. Zhang, . X. Lin and . X. . S. Shen, "Securing fog computing for internet of things applications: Challenges and solutions," IEEE Communications Surveys & Tutorials, vol. 20, pp. 601-628, 2017.
- [2] A. H. Ngu, M. Gutierrez, . V. Metsi, . S. Nepal and Q. . Z. Sheng, "IoT middleware: A survey on issues and enabling technologies," IEEE Internet of Things Journal, vol. 4, pp. 1-20, 2017.
- [3] M. Chiang and . T. Zhang, "Fog and IoT: An overview of research opportunities," IEEE Internet of Things Journal, vol. 3, pp. 854-864, 2016.
- [4] A. Al-Fuqaha, M. Guizani, M. Mohammadi, . M. Aledhari and . M. Ayyash, "Internet of things: A survey on enabling technologies, protocols, and applications," IEEE Communications Surveys & Tutorials, vol. 17, pp. 2347-2376, 2015.
- [5] C. -H. Hong and . B. Varghese, "Resource Management in Fog/Edge Computing: A Survey," arXiv preprint arXiv:1810.00305, 2018.
- [6] P. Zhang, . M. Zhou and . G. Fortino, "Security and trust issues in Fog computing: A survey," Future Generation Computer Systems, vol. 88, pp. 16-27, 2018.
- [7] W. Shi, J. Cao, Q. Zhang, Y. Li and . L. Xu, "Edge computing: Vision and challenges," IEEE Internet of Things Journal, vol. 3, pp. 637-646, 2016.

- [8] F. M. Talaat, . M. S. Saraya, . A. I. Saleh, H. A. Ali and S. H. Ali , "A load balancing and optimization strategy (LBOS) using reinforcement learning in fog computing environment," Ambient Intell Human Comput, vol. 11, p. 4951-4966, 2020.
- [9] S. W. Wilson, "Classifiers that approximate functions," Natural Computing, vol. 1, p. 211-234, 2002.
- [10] M. . V. Butz, "Learning Classifier Systems".
- [11] . M. Abbasi, M. Yaghoobikia, M. Rafiee, A. Jolfaei and M. R. Khosravi, "Efficient resource management and workload allocation in fog-cloud computing paradigm in IoT using learning classifier systems," Computer Communications, vol. 153, pp. 217-228, 2020.
- [12] fchauvel, "XCSF," [Online]. Available: <https://github.com/fchauvel/XSCF>.
- [13] M. Ghobaei-Arani, A. Souri and A. A. Rahmanian, "Resource Management Approaches in Fog Computing: a Comprehensive Review," Journal of Grid Computing, vol. 18, p. 1-42, 2020.