Journal of Applied And Basic Machine Intelligence Research (ABMIR)

پژوهش‌های نظری و کاربردی هوش ماشینی

سال دوم، شماره اول، بهار و تابستان ۱۴۰۳، صفحات ۱۳ - ۱

# ارائه مکانیسمی کارآمد برای تعیین تابعی برای توزیع بارکاری در محاسبات مه با استفاده از سیستم‌های دسته‌بند یادگیر

**مهدی عباسی، بهاره حمیدی محب ***

دانشکده فنی مهندسی، دانشگاه بوعلی سینا ، همدان، ایران

**مقاله پژوهشی**

## چکیده

**با توسعه سریع اینترنت اشیا، الگوی محاسبات مه به‌عنوان یک راه‌حل جذاب برای پردازش داده‌ها در برنامه‌های اینترنت اشیا ارائه‌شده است. در محیط مه، برنامه‌های اینترنت اشیا توسط گره‌های محاسباتی میانی در مه و همچنین کارگزارهای فیزیکی در مراکز داده ابری اجرا می‌شوند. ازاین‌رو، مسائل مربوط به مدیریت منابع و مدیریت انرژی به‌عنوان یکی از مشکلات چالش‌برانگیز در محاسبات مه باید موردتوجه قرار گیرد. اخیراً پژوهش‌هایی برای ایجاد تعادل بین انرژی و هزینه در محاسبات مه صورت گرفته است. در این پژوهش ضمن بررسی این رویکردها روشی کارآمد برای تقریب تابع توزیع بار با دو روش مبتنی بر سیستم‌های یادگیر دسته‌بند به نام XCSF و BCM-XCSF در گره‌های پردازشی مه به‌منظور بهینه‌سازی هرچه بیشتر رویکردهای قبلی و مدیریت منابع پردازشی مه ارائه‌شده است. این دو روش در داشتن یک حافظه برای نگهداری بهترین دسته‌بندها باهم متفاوت هستند. نتایج شبیه‌سازی نشان می‌دهد دو روش د XCS و BCM-XCS توزیع بار مناسبی دارند. این دو روش سربار محاسباتی را کم می‌کنند. روش BCM-XCSFافزون بر این‌که حدود ۶۰ درصد تأخیر را کاهش می‌دهد مصرف انرژی را نیز بهبود می‌بخشد.**

تاریخ دریافت:

۱۴۰۲ /۴/ ۸

تاریخ پذیرش:

۱۴۰۲ /۱۲/ ۲۲

کلیدواژه‌ها:

اینترنت اشیا، پردازش مه، پردازش لبه، تخمین تابع، سیستم‌های دسته‌بند یادگیر

نویسنده‌مسئول:

b.hamidimoheb@eng.basu.ac.ir

: 10.22034/ABMIR.2024.20271.1030

E-ISSN: 2821-2037 

## ۱– مقدمه

در اینترنت اشیاء میلیاردها موجودیت فیزیکی برای جمع‌آوری و مبادله داده‌ها به‌منظور ارائه برنامه‌های کاربردی، به یکدیگر متصل می‌شوند[۱]. محاسبات ابری راه‌حلی برای پردازش داده‌های بزرگ ارائه می‌دهد. با ظهور اینترنت اشیاء، محاسبات ابر با چالش‌های رو به رشدی مانند تأخیرها، محدودیت پهنای باند، منابع محدود دستگاه‌ها، اهمیت ارتباط امن و بدون وقفه مواجه است [۲, ۳]. بر اساس تحقیقات، برای کاهش این مشکلات، به‌جای استفاده از پردازش‌های ابری دور و متمرکز، از منابع غیرمتمرکز در لبه‌های شبکه برای پردازش داده‌های نزدیک به کاربر می‌توان استفاده کرد. این موضوع به‌عنوان محاسبات مه‌آلود یا محاسبات لبه نامیده می‌شود[٤, ٥]. در محاسبات مه‌آلود، پردازش‌ها با تأخیر کمی انجام می‌شوند. از طرفی تأمین انرژی برای انجام این محاسبات سنگین دشوار است. انرژی تجدید پذیر تا حدودی این دشواری را جبران می‌کند. همچنین، پیوستار محاسباتی در اینترنت اشیا شامل لایه‌های اشیا، لبه، مه و ابر است که هریک ظرفیت‌های محاسباتی متفاوتی دارند. بنابراین، لازم است تصمیم بگیریم به هر لایه چه میزان بارکاری تخصیص یابد یا به هر بخش چه تعداد وظیفه اختصاص یابد. تصمیم‌گیری‌ها باهدف بهبود معیارهای تأخیر، پهنای باند و هزینه صورت می‌گیرد [٦]. نکته مهم در این تخصیص‌ها آن است که از منابع موجود در لبه شبکه حداکثر بهره‌وری به عمل آید. تحقیقات اخیر نشان داده است که از روش‌های یادگیری تقویتی می‌توان برای به حداقل رساندن زمان بیکاری گره‌های لبه شبکه و استفاده بهینه از منابع و خدمات مه استفاده کرد[۷].

در زمینه‌های یادگیری تقویتی، می‌توان از سیستم‌های دسته‌بندی‌کننده یادگیر استفاده کرد. در این سیستم‌ها، تقریبی از تابع بازخورد ارائه می‌شود که به سیستم اجازه می‌دهد برای هر ورودی، بهترین کنش با بالاترین بازخورد مثبت را انتخاب کند [۸]. سیستم های دسته‌بندی کننده یادگیر، سیستم‌هایی مبتنی بر قانون هستند. در این سیستم‌ها قوانین عمدتاً به فرم "IF condition THEN action" هستند. اصطلاح LCS[1] نخست توسط هلند معرفی شد و در ابتدا توسعه‌ای برای الگوریتم‌های ژنتیکی بود[۹]. در دو دهه اخیر LCS استفاده زیادی در حل مسائل واقعی چون داده‌کاوی داشته است [۱۰, ۱۱].

افزایش توان محاسباتی تجهیزات ابری درکنار محدودیت منابع در لبه‌های شبکه، انگیزه‌ای برای جستجو راه‌حل‌های جدید جهت به حداکثر رساندن بهره‌وری منابع این محاسبات شده است. این پژوهش درصدد یافتن راه‌حلی کارآمد برای توزیع بارهای کاری به نحوی مطلوب بین منابع موجود در لبه شبکه است ضمن کاهش مصرف انرژی تأخیر را هم کاهش دهد. به این منظور، در محاسبات مه‌آلود از سیستم دسته‌بندی‌کننده یادگیر برای کمک به تصمیم‌گیری ایستگاه پایه جهت تعیین میزان بار پردازشی در لبه شبکه استفاده می‌شود. در مدل‌سازی بارها در محاسبات مه، ورودی این سیستم (شرایط) وضعیت شبکه و خروجی (کنش) آن میزان بار پردازشی در لبه شبکه است. با استفاده از یک الگوریتم XCSF میزان بار مناسب به شکل یک تابع برای پردازش در لبه شبکه پیش‌بینی می‌شود. پس از یادگیری ضرایب این تابع، می‌توان از آن برای محاسبه بار توزیع بار در زمان‌های آتی استفاده کرد. در این صورت، پس از یادگیری تابع توزیع بار، به ازاء ورود بارکاری جدید به لبه شبکه، نیازی به اجرای الگوریتم یادگیری مذکور نخواهد بود و باهمان تابع یادگیری شده، مقدار بار توزیعی در لبه مشخص خواهد شد.

در ادامه این مقاله پژوهش‌های انجام‌شده در این حوزه، بررسی می‌شود. در بخش سوم روش پیشنهادی به‌صورت مفصل توضیح داده می‌شود. به این منظور، مدلی برای هزینه‌های سیستم بررسی می‌شود و مسئله توزیع بار در لبه شبکه مدل‌سازی و فرمول‌بندی می‌شود. در بخش چهارم، نحوه پیاده‌سازی و ارزیابی روش پیشنهادی توضیح داده می‌شود. درنهایت، بخش پایانی مقاله به نتیجه‌گیری و راهکارهای آتی می‌پردازد.

## ۲ – مروری بر پژوهش‌های انجام‌شده

در سال‌های اخیر، به‌ویژه پس از ۲۰۱٦ میلادی، پژوهش‌های متعددی درزمینه توزیع بهینه بار محاسباتی در لبه‌های شبکه صورت

[1] Learning Classifier System

گرفته است. در ادامه، تعدادی از کارهای انجام‌شده در حوزه بهبود مصرف انرژی و هزینه پردازش در محاسبات مه بررسی می‌شود.

اولین پژوهش‌ها در سال ۲۰۱۶ ارائه شد و امکان ترکیب انرژی‌های تجدید پذیر در محاسبات لبه‌های شبکه تلفن همراه را بررسی کردند. روش‌های ارائه‌شده عمدتاً برای بهبود مصرف انرژی بوده و عمدتاً کند بودند [۱۲].

در سال ۲۰۱۷ Jie Xu و همکارانش [۱۳] یک الگوریتم یادگیری تقویتی مبتنی بر تراکم طیفی انرژی ارائه دادند تا توزیع بار و تخصیص خودکار منابع در لبه شبکه به‌صورت بهینه انجام شود. الگوریتم فوق باوجوداینکه توانست مصرف انرژی را برای پردازش بارهای محاسباتی در لبه‌های شبکه بهبود بخشد، نمی‌توانست این بارهای کاری را به‌صورت متعادل در میان گره‌های پردازشی توزیع کند.

در سال ۲۰۱۸ Hang Wu و همکارانش [۱۴]، الگوریتمی را به نام GLOBE ارائه دادند. آن‌ها در این الگوریتم، دو مکانیسم تعادل بار جغرافیایی و کنترل ورودی بارها را برای بهینه‌سازی عملکرد ایستگاه‌های لبه شبکه، باهم ترکیب کردند. بااینکه این الگوریتم توزیع بارهای محاسباتی در میان گره‌های شبکه را بهبود بخشید، اما به حالت بهینه دست نمی‌یافت.

در سال ۲۰۱۸ Jiafu Wan و همکارانش [۱۵]، یک روش متعادل‌سازی توزیع بار محاسباتی برای بهبود مصرف انرژی رابت‌ها در محاسبات مه‌آلود را پیشنهاد کردند. نتایج کار ایشان نشان داد که در بستر ایجادشده، نسبت به سایر ربات‌ها کارایی بهتری نسبت به سایر روش‌های زمان‌بندی داشته و بارهای کاری به‌صورت متوازن‌تری در میان آن‌ها توزیع‌شده است.

در سال ۲۰۱۸ Deze Zeng و همکارانش [۱۶]، مسئله بهره‌وری انرژی را به‌صورت یک مساله برنامه‌ریزی خطی ارائه دادند و ثابت کردند که یک مسئله NP-hard است. نتایج حاصل از شبیه‌سازی نشان داد که بهره‌وری انرژی درروش آن‌ها، نزدیک به راه‌حل بهینه است.

در سال ۲۰۲۰، مهدی عباسی و همکارانش [۱۷]، روشی پیشنهاد دادند که از سیستم دسته‌بند یادگیری به نام XCS استفاده می‌کرد. در این پژوهش، با تطبیق پارامترهایی شامل کل بارکاری و مقدار انرژی تجدید پذیر به‌عنوان ورودی سیستم، میزان بهینه توزیع بارکاری در گره‌های لبه محاسبه می‌شد. همچنین از یک حافظه اضافی در سیستم XCS برای تسریع روند یادگیری استفاده شد. تأخیر در پردازش بارهای کاری و سطح باتری در XCS و XCS حافظه‌دار پیشنهادی در تحقیق مذکور، به‌طور قابل‌توجهی بهتر از هر روش اخیر بود. الگوریتم ارائه‌شده توانست تعادلی میان دو معیار انرژی موردنیاز برای محاسبات مه‌آلود و تأخیر ایجاد کند و همچنین یک مدل جامع برای توزیع بار محاسباتی، بین گره‌های پردازش مه ارائه دهد؛ بااین‌وجود، در هربار ورود بار محاسباتی جدید به لایه مه، الگوریتم باید اجرا گردد که این مورد سربار محاسباتی قابل‌توجهی را به سیستم وارد می‌کند.

## ۳ – روش پیشنهادی

فرض می‌کنیم که یک سیستم لبه از ایستگاه پایه و تعدادی از کارگزارهای لبه که ازلحاظ فیزیکی نزدیک به هم قرار دارند، تشکیل‌شده است. هرکدام از کارگزارهای مستقر در لبه شبکه دارای ظرفیت محدود باتری می‌باشند. یک منبع تغذیه پشتیبان نیز در لبه شبکه مستقرشده تا در صورت کمبود منابع در کارگزارهای لبه، بارهای کاری را به ابر منتقل کند. این بار محاسباتی از سمت کاربران وارد لبه شبکه شده و به ایستگاه پایه ارائه می‌شود. در این سناریو، وظیفه ایستگاه پایه تصمیم‌گیری میزان بار پردازشی در لبه شبکه و انتقال مابقی آن به کارگزارهای ابر است.

### ۳-۱ مدل‌سازی

پیوستار پردازش بار از لبه تا ابر از چهار منظر مدل می‌شود که شامل: مدل بارکاری، مدل تأخیر، مدل مصرف انرژی و مدل باتری است. برای هریک از این مدل‌ها فرمول‌هایی با توجه به مرجع [۱۲] ارائه می‌شود.

**مدل بارکاری**

بازه‌های زمانی در سناریوهای کاری سیستم با اعداد گسسته مانند $t = 0, 1, 2, 3, \dots$ نمایش داده می‌شود. در هر بازه زمانی باید تعداد کارگزارهای فعال در لبه شبکه تعیین شود. $L(t)$ نرخ رسیدن کل بارکاری در لحظه $t$ به لبه شبکه است به‌طوری‌که رابطه (۳) برقرار باشد. همچنین، $L_{max}$ حداکثر و $L_{min}$ حداقل بار ورودی

امکان‌پذیر به لبه شبکه است. مقدار بارکاری که تصمیم گرفته‌شده به‌صورت محلی پردازش شود، با پارامتر $L_f(t)$ نمایش داده می‌شود. بین این سطوح بارکاری رابطه (۳) همواره برقرار است. میزان بار قابل‌پردازش در ابر $L_c(t)$ از رابطه (۳) به دست می‌آید. در این مدل‌سازی، $S(t)$ تعداد کارگزارهای فعال در لبه شبکه در نظر گرفته می‌شود که در طول بازه زمانی ثابت است.

$$L(t) \in [L_{min}\ ,\ L_{max}] \quad (۱)$$

$$L(t) \geq L_f(t) \quad (۲)$$

$$L_c(t) = L(t) - L_f(t) \quad (۳)$$

## مصرف انرژی

در هر بازه زمانی، کل مصرف انرژی متشکل از دو نوع انرژی است:

- انرژی لازم برای عملیات پایه و انتقال بارها در لبه شبکه که با $E_{op}(t)$ نمایش داده می‌شود. میزان این انرژی فقط به میزان کل بار ورودی یعنی $L(t)$ وابسته است و از رابطه (٤) به دست می‌آید.

$$E_{op}(t) = E_{dyn}(t) + E_{sta}(t) \quad (٤)$$

مقدار $E_{dyn}(t)$ انرژی مصرفی متغیر در لبه شبکه است که به میزان بارکاری ورودی بستگی دارد و در این سناریو به دلیل نزدیکی مراکز پردازش، صفر در نظر گرفته می‌شود. مقدار $E_{sta}(t)$ نیز انرژی مصرفی ثابت در لبه شبکه است.

- انرژی موردنیاز برای پردازش بارهای کاری در لبه شبکه با $E_p(t)$نمایش داده می‌شود. این انرژی برحسب میزان بار قابل‌پردازش در لبه شبکه و تعداد کارگزارهای فعال محاسبه می‌شود.

طبق رابطه (۵) مصرف انرژی از جمع انرژی عملیاتی و انرژی لازم برای پردازش بارهای کاری به دست می‌آید.

$$E\,(\,L(t), L_f(t), S(t)) = E_{op}(t) + E_p(t) \quad (۵)$$

## باتری

مجموعه کل میزان باتری‌های موجود در لبه شبکه به شکل $b(t) \in [\,0, B]$ نمایش داده می‌شود. نماد $B$ نشان‌دهنده حداکثر میزان ظرفیت باتری است. باتری‌ها توسط انرژی تجدید پذیر مانند باد و خورشید شارژ می‌شوند که با $g(t)$ نمایش داده می‌شود. در ابتدا میزان انرژی باتری صفر فرض شده است. در لبه شبکه ممکن است در هر بازه زمانی دو حالت برای باتری رخ بدهد:

اگر $b(t) > Eop(t)$ باشد، مقداری از بارهای کاری $(Lf(t))$ در لبه شبکه پردازش و مابقی به ابر ارسال می‌شود. در این حالت میزان باتری برای بازه زمانی بعدی از رابطه (٦) محاسبه می‌شود.

$$b(\,t+1) = b(t) + g(t) - E((\,L(t), L_f(t), S(t)) \quad (٦)$$

در این حالت هزینه‌ای که به سیستم تحمیل می‌شود هزینه استهلاک باتری خواهد بود که از رابطه (۷) به دست می‌آید.

$$C_{bt}(t) = \beta.\max\{\,E((\,L(t), L_f(t), S(t)) - g(t), 0\} \quad (۷)$$

که $\beta<0$ هزینه استهلاک یک واحد باتری است. حالت اول در شکل (۱) این موضوع را به تصویر می‌کشد.

اگر $b(t) \leq E_{op}(t)$ باشد، کل بارکاری به ابر ارسال خواهد شد تا باتری توسط منبع تغذیه پشتیبان شارژ شود. هزینه این عملیات از رابطه (۹) حاصل می‌شود که درآن، $\varphi$ ضریب هزینه منبع تغذیه پشتیبان است. میزان انرژی باتری در بازه زمانی بعدی با فرمول (۹) محاسبه می‌شود. حالت دوم در شکل (۱) بیانگر این موضوع است.

$$C_{bak}(t) = \varphi.E_{op}(t) \quad (۸)$$

$$b(t+1) = b(t) + g(t) \quad (۹)$$

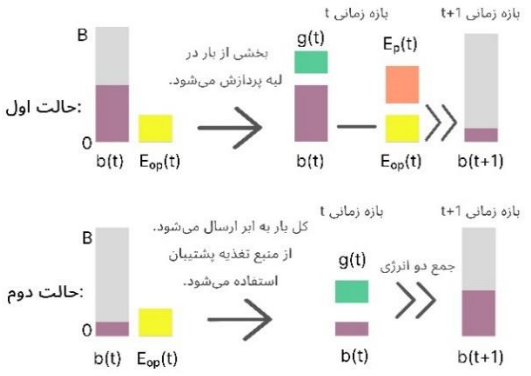

**شکل (۱): دو حالت موجود در عملکرد باتری**

## تأخیر

در این سناریو سه مدل تأخیر داریم. نخستین تأخیر، تأخیر انتقال بارهای کاری در شبکه بی‌سیم dtrans(t) است که برحسب مقدار بار قابل‌پردازش در لبه شبکه به دست می‌آید. مقدار این تأخیر در این سیستم به دلیل نزدیکی فیزیکی مراکز پردازش به مراکز تولید بارکاری صفر فرض می‌شود.

نوع دوم تأخیر، مربوطه به پردازش بارهای کاری به صوت محلی و در لبه شبکه است که با dlo(t) نمایان می‌شود. سبک محاسبه این تأخیر به مکانیسم مدیریت صف در لبه شبکه بستگی دارد. ازآنجایی‌که در مدل موردنظر ما، از مکانیسم مدیریت صف M/G/1 استفاده می‌شود، این مقدار توسطه رابطه (۱۰) به دست می‌آید. در رابطه مذکور α ظرفیت پردازش هر کارگزار است.

$$d_{lo}(t) = L_f(t) / (S(t).\alpha - L_f(t)) \qquad (۱۰)$$

تأخیر ارسال باقی‌مانده بارهای محاسباتی به ابر با dc(t) نمایش داده می‌شود و مقدار آن وابسته به ازدحام شبکه H(t) است. ازدحام شبکه مجموع تأخیر انتقال رفت‌وبرگشت و تأخیر پردازش در ابر است. درنتیجه این تأخیر طبق رابطه (۱۱) محاسبه می‌شود.

$$d_c(t) = (L(t) - L_f(t))\, H(t) \qquad (۱۱)$$

درنهایت هزینه تأخیر کل بارکاری که به سیستم وارد می‌شود بر اساس رابطه (۱۲)، از مجموع سه تأخیر فوق حاصل می‌شود.

$$\mathbf{d_{total}}\left(\mathbf{H(t), L(t), L_f(t), S(t)}\right) = \mathbf{d_{trans}(t) + d_{lo}(t) + d_c(t)} \qquad (۱۲)$$

## ۳-۲ سیستم دسته‌بند یادگیر

در این بخش، ابتدا به‌مرور الگوریتم XCS و سپس XCSF می‌پردازیم و برای بهبود عملکرد آن‌ها یک حافظه به آن اضافه می‌کنیم.

### ۳-۲-۱ الگوریتم XCS

موارد زیر که از مقاله [۱۸] برگرفته‌شده است، شرح مختصری از XCS است. در XCS یک ورودی ارائه می‌شود؛ سیستم تصمیم می‌گیرد و محیط، مقداری به‌عنوان بازده ارائه می‌کند. [P] شامل تمام قوانین تکامل‌یافته است. این جمعیت را می‌توان از مجموعه‌ای از قوانین شناخته‌شده برای هر کلاس یا یک قانون کاملاً عمومی واحد به‌طور تصادفی تولید کرد. مجموعه [M] شامل مجموعه‌ای از قوانین فعال‌شده به‌وسیله نمونه ورودی است. زمانی که یک کلاس پیش‌بینی‌شده از قوانین در [M] انتخاب شود، مجموعه عمل [A] شامل همه کنش‌های برگزیده کلاس قوانین [M] خواهد بود. ازنظر ساختاری، هر قانون دسته‌بند Cj در جمعیت [P] دارای یک شرط، یک عمل و مجموعه‌ای از پارامترهای مرتبط است. شرط، رشته‌ای از {۱،۰،#} است. هر عمل در یک قانون دسته‌بند به‌صورت یک عدد صحیح نمایش داده می‌شود. سه پارامتر اصلی در به‌روزرسانی و انتخاب دسته‌بندها وجود دارند. (۱) پیش‌بینی بازده pj، که در صورت مطابقت Cj و انتخاب آن توسط سیستم، بازده ای را که سیستم دریافت خواهد کرد را تخمین می‌زند، (۲) خطای پیش‌بینی εj، خطا را در pj با توجه به بازده‌های واقعی دریافتی تخمین می‌زند و (۳) قانون برازش Fj.

یک چرخه عملیاتی یا مرحله زمانی در این سیستم به این صورت است با دریافت اطلاعات اولیه از محیط در حافظه [P] جستجو می‌شود. آن دسته از دسته‌بندهایی که با ورودی مطابقت دارند در مجموعه مطابقت [M] ذخیره می‌شوند. طی محاسباتی آرایه پیش‌بینی که به تعداد اکشن‌ها خانه دارد، پر می‌شود. با استفاده از این آرایه بهترین عمل‌ها در مجموعه [A] قرار می‌گیرد و به سیستم اعمال می‌شود در قبال این عمل از محیط یک مقدار بازده دریافت می‌شود. در این بخش از طبق الگوریتم یادگیری تقویتی، پارامترهای دسته‌بندها به‌روزرسانی شده و در مراحل بعدی استفاده می‌شود.

در XCS درصورتی‌که ورودی با دسته‌بندی از مجموعه [P] منطبق شود، ولی مجموعه [A] کامل نباشد، سایر عمل‌ها به‌صورت تصادفی با عمل پوشش در قالب دسته‌بند جدید ایجادشده و به مجموعه [P] اضافه می‌شوند. این دسته‌بندهای جدید می‌تواند درنتیجه ورودی‌های بعدی تأثیرگذار باشد. بدین‌جهت باهدف عدم تولید دسته‌بندهای تصادفی در صورت تطبیق ورودی با یک دسته‌بند موجود در [p] در مقاله [۱۷] به سیستم XCS یک حافظه جانبی اضافه‌شده است. این حافظه در **Error! Reference source not found.**) به نام BCM نشان داده‌شده است. در این حافظه جدید، شرایط پیش‌آمده همراه با بهترین عمل مناسب برای آن و بهترین پاداشی که آن عمل از محیط دریافت کرده، نگهداری

می‌شود و الگوریتم یادگیری دارای چنین حافظه‌ای الگوریتم BCM-XCS نامیده می‌شود.

### ۳-۲-۲ الگوریتمXCSF

تقریب توابع یک تکنیک مهم است که در بسیاری از حوزه‌های مختلف ازجمله ریاضیات عددی، مهندسی و علوم اعصاب استفاده می‌شود. سیستم دسته‌بندی XCSF می‌تواند توابع چندبعدی پیچیده را، با استفاده از توابع ساده‌تر تقریب بزند. برای تقریب تابع، XCS از دو جنبه اصلاح شد. اولین مورد تطبیق الگوریتم برای ورودی عدد صحیح به‌جای بردارهای ورودی باینری بود. دومین تغییر پیش‌بینی‌های بازده الگوریتم را، مستقیماً در خروجی در دسترس قرار می‌دهد و سیستم را به یک عمل محدود می‌کند [۱۹]. در شکل (۳) این مورد کاملاً مشخص است. برنامه حاصل XCSF نام خواهد داشت. درواقع، شرط دسته‌بند از رشته‌ای مانند {#،۰،۱} به ترکیبی از بازه‌ها مانند ( li , ui) تغییر می‌کند. که در آن liحد پایین و ui حد بالای اعداد صحیح در بازه هستند. برای هر ورودی x مانند xi ، درصورتی‌که برای همه xiها عبارت li ≤ xi ≤ ui صدق کند دسته‌بند، آن را با بازه تطبیق می‌دهد.

خروجی الگوریتم XCSF یک تابع به شکل f(x) است که طبق رابطه (۱۳) به دست می‌آید. در این رابطه، w بردار وزنی شامل (w0 , w1 , … , wn)است. N تعداد ورودی‌های الگوریتم است. x´بردار ورودی‌ها شامل (x0 , x1 , … , xn) است. بردار وزن w دارای n + 1 جزء در فضای حالت n بعدی است و یک وزن wi برای هر بعد ورودی و وزن w0 برای ورودی ثابت x0 در نظر گرفته می‌شود.

$$f(x) = w \cdot x' \qquad (۱۳)$$

برای هر عمل ai در [M]، XCSF پیش‌بینی سیستم را محاسبه می‌کند. درواقع، بازدهی را که XCSF هنگام انجام عمل ai انتظار دارد، تخمین می‌زند. همانند XCS، در XCSF پیش‌بینی سیستم عمل a با میانگین وزنی برازش همه دسته‌بندهای منطبق که عمل a را مشخص می‌کنند، محاسبه می‌شود. بااین‌حال، برخلاف XCS، در XCSF پیش‌بینی دسته‌بند به‌عنوان تابعی از وضعیت فعلی st و وزن بردار دسته‌بند w محاسبه می‌شود. بر این اساس، در سیستم XCSF پیش‌بینی P تابعی از حالت فعلی s و عمل a است.

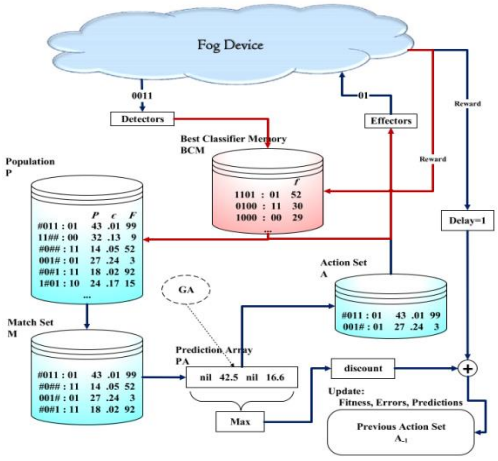


**شکل(۲): XCS و BCM-XCS** [۱۷]

درنتیجه، پیش‌بینی سیستم برای عمل a در حالت st به فرم P ( st , a) به‌صورت (۱۴) تعریف می‌شود:

$$P(s_t, a) = \frac{\sum_{cl \in [M]|a} cl, p(s_t) \cdot cl, F}{\sum_{cl \in [M]|a} cl, F} \qquad (۱۴)$$

در رابطه فوق،cl یک دسته‌بند است، [M]|a نشان‌دهنده زیرمجموعه‌ای از دسته‌بندها در [M] با عمل a است، cl,F برازش دسته‌بند cl است. cl,p (st) پیش‌بینی cl است که در حالت st محاسبه می‌شود. به‌طور خاص، هنگامی‌که تقریب خطی تکه‌ای در نظر گرفته می‌شود، cl,p (st) به‌صورت (۱۵) محاسبه می‌شود:

$$cl, p(s_t) = cl, w_0 \cdot x_0 + \sum_{i>0} cl, w_i \cdot s_t(i) \qquad (۱۵)$$

در این رابطه، cl.wi وزن wi از دسته‌بند و x0 یک ورودی ثابت است. مقادیر P ( st , a ) آرایه پیش‌بینی را تشکیل می‌دهند . در مرحله بعد، XCSF یک عمل را برای انجام انتخاب می‌کند. دسته بندهای موجود در [M] که عمل انتخاب‌شده در آن موجود است، در مجموعه عملکرد فعلی [A] قرار می‌گیرند. عمل انتخاب‌شده به محیط ارسال می‌شود و یک پاداش P به سیستم برمی‌گردد [۲۰]. همان‌طور که در نسخه بهبودیافته XCS از یک حافظه برای نگه‌داری بهترین دسته‌بندها استفاده می‌شود، در XCSF هم می‌توان از این حافظه برای بهبود کارایی مدل یادگیر استفاده کرد که آن را BCM-XCSF می‌نامیم.

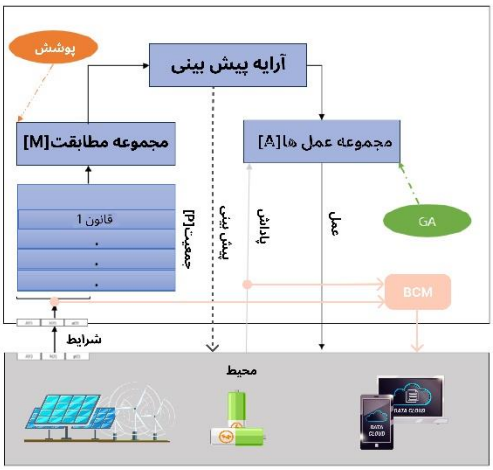


شکل (۳): ساختار XCSF و ارتباط آن با محیط

**تفاوت الگوریتم XCS و الگوریتم XCSF**

مهم‌ترین تفاوت XCS و XCSF تنها در خروجی است. بازخورد و ورودی‌های آن یکسان است. XCS مقدار ثابتی را به‌عنوان خروجی تولید می‌کند درحالی‌که در XCSF خروجی به شکل تابع $f(x)$ است. بخش وزنی این خروجی، w برداری است که در جریان الگوریتم یادگیری تقویتی به دست‌می‌آید. ورودی در محاسبات مه شامل میزان کل بار ورودی، ازدحام شبکه و میزان انرژی تجدید پذیر دریافت شده است. بنابراین بردار ورودی ما شامل این سه مورد است و در هر گره پردازشی مه مقدار بردار وزنی این تابع مشخص می‌شود.

## ۳-۳ فرموله سازی مسئله

در این قسمت، با استفاده از یادگیری تقویتی مسئله تخصیص بارها به ابر و لبه شبکه فرموله می‌شود. هدف این است که هزینه سیستم به حداقل برسد. در این یادگیری تقویتی یک عامل با استفاده از آزمون‌وخطا و تعامل با محیط و استفاده از بازخوردهای عمل‌ها مسئله را یاد می‌گیرد. درنتیجه از پاداش‌ها و تنبیه‌ها به‌عنوان معیاری برای شناسایی رفتار مثبت و منفی بهره برده می‌شود. عنصرهای اساسی یک مسئله یادگیری تقویتی از موردهای زیر تشکیل‌شده است:

۱-محیط: جهان فیزیکی عامل در آن عمل می‌کند.۲-حالت: موقعیت فعلی عامل ۳-پاداش: بازخورد از محیط ٤-سیاست: روشی برای نگاشت حالت عامل به عمل

از XCSF و BCM-XCSF برای کمک به تصمیم‌گیری ایستگاه پایه جهت تعیین میزان بار پردازشی در لبه شبکه استفاده می‌شود. در مدل‌سازی بارها در پردازش لبه ورودی این سیستم (شرایط) وضعیت شبکه و خروجی(عمل) آن میزان بار پردازشی در لبه شبکه است. شکل (٤) نمایی از شرایط دریافتی سیستم و عملی است که دسته‌بند تولید می‌کند .

| شرایط | | عمل |
|---|---|---|
| $L(t)$ | : | $L_f(t)$ |

شکل (٤): نمونه‌ای از یک سطر دسته‌بند

شکل (٤) گواه بر این است که وضعیت محیط با یک پارامتر $L(t)$ قابل دریافت است. همچنین، انرژی تجدیدپذیر $g(t)$ و ازدحام شبکه $H(t)$ در هر بازه زمانی به‌عنوان وضعیت محیط داده می‌شود. وضعیت باتری $b(t)$ هم در لبه در سیستم معلوم است. زیرا در بازه زمانی قبل محاسبه‌شده است. درنهایت بر اساس این شرایط و با استفاده از الگوریتم ذکرشده میزان بار مناسب برای پردازش در لبه شبکه پیش‌بینی و یاد گرفته می‌شود. این میزان بار $L_f(t)$ به‌عنوان یک عمل به محیط اعمال می‌شود. درنهایت نتیجه این عمل به‌عنوان پاداش از جانب محیط به ما بازخورد داده می‌شود. این بازخورد همان هزینه ایست که به سیستم تحمیل‌شده و الگوریتم به دنبال کاهش این هزینه‌ها عمل خواهد کرد. هزینه‌ها توسط مدل‌سازی ارائه‌شده در بخش ۳-۱ محاسبه می‌شود.

با تطبیق این شرایط با وضعیت سیستم و قرار دادن سیستم دسته‌بند یادگیر به‌عنوان عامل در الگوریتم یادگیر، عمل موردنظر تولید و به محیط اعمال می‌شود. پس از اعمال عمل، هزینه تحمیل‌شده به سیستم $c(t)$ تحت عنوان پاداش به عامل داده می‌شود. شکل (۳) این روند را به تصویر می‌کشد. همچنین در شکل (۳) حافظه BCMهم نمایش داده‌شده که برای استفاده از الگوریتم BCM-XCSFمورداستفاده قرار می‌گیرد.

در هر مرحله پس از پردازش بارها در ابر و لبه، هزینه تحمیل‌شده به سیستم را به‌عنوان بازده از محیط در نظر می‌گیریم که از فرمول (۱۶) محاسبه می‌شود:

$$\text{if } (b(t) \leq \text{dop } (L(t))) \quad (16)$$
$$c(t) = c_{delay}\,(H(t), L(t), 0, 0) + c_{bak}\,(L(t))$$
$$\text{else}$$
$$c(t) = c_{delay}(H(t), L(t), Lf(t), S(t)) + c_{battery}(t)$$

که در بخش اول اگر میزان باتری کمتر از انرژی موردنیاز باشد $Lf(t)=S(t)=0$ خواهد شد و برای ارسال بارها به ابر از منبع تغذیه پشتیبان استفاده خواهد شد. در بخش دوم که باتری به‌اندازه کافی داریم بجای هزینه منبع تغذیه پشتیبان، هزینه استهلاک باتری اضافه خواهد شد.

درنهایت الگوریتم XCSF طی یک‌بار اجرا وزن‌ها را مقداردهی می‌کند و یک تابع به فرم (۱۷) در اختیار ما قرار می‌دهد. پس‌ازآن در زمان‌های بعدی که مقداری بار ورودی داریم، الگوریتم اجرا نخواهد شد و از تابع به‌دست‌آمده از الگوریتم XCSF برای تعیین میزان بار قابل‌پردازش در گره‌های مه استفاده خواهد شد. تا زمانی که درصد خطای کمی داشته باشیم، ازاین‌روند بهره‌وری می‌شود. این درصد خطا توسط میزان مصرف انرژی و تأخیر تعریف می‌شود. در هر مرحله که از این تابع به‌دست‌آمده استفاده می‌کنیم، میزان مصرف انرژی و تأخیر را باید زیر نظر بگیریم. درصورتی‌که الگوی مصرف انرژی تغییرات قابل‌توجهی را داشته باشد یا میزان تأخیر از مقدار متعارف بیشتر شود، مجدد الگوریتم اجرا می‌شود و تابع جدیدی برای میزان بار ورودی ارائه خواهد شد.

$$f(L(t)) = w_0 \cdot x_0 + w_1 \cdot L(t) \quad (17)$$

## ٤ -پیاده‌سازی و ارزیابی

در این پژوهش هر دو الگوریتم پیشنهادی XCSF و BCM-XCSFرا پیاده‌سازی می‌کنیم تا عملکرد آن را در لبه شبکه ارزیابی کنیم. حتی اگر خروجی‌های تابع‌های حاصل از این الگوریتم که همان مقدار بار قابل‌پردازش در لبه شبکه هستند، تا حدودی مشابه با خروجی‌های الگوریتم XCS و BCM-XCSF باشد ما نتایج مطلوب را گرفته‌ایم، زیرا سربار محاسباتی اجرای الگوریتم پس از مشخص شدن وزن‌های تابع با XCSF کاهش می‌یابد. پس از مشخص شدن ضرایب وزنی تابع توزیع بار در XCSF، از این تابع برای محاسبه میزان باری که درباید در لبه باید پردازش شود می‌توان استفاده نمود.

### ٤-١ جزییات پیاده‌سازی

روش پیشنهادی روی سیستمی با پردازنده ۵ هسته‌ای و فرکانس ۳۰/۲ GHz و حافظه ۸ گیگابایت با کتابخانه‌ای زبان C++ پیاده‌سازی شده است [۲۱]. در این شبیه‌سازی قسمت بازده الگوریتم XCSF فرمول‌های ارائه‌شده در بخش ۳-۱ محاسبه می‌شود و داده‌های مقاله مرجع که کل بار ورودی در هرلحظه هستند را به الگوریتم می‌دهیم. خروجی الگوریتم با توجه به بازده در هرلحظه، میزان بار قابل‌پردازش در لبه شبکه خواهد بود. در این بخش ابتدا مقادیر تنظیم‌شده برای متغیرهای سناریو پیشنهادی بیان‌شده و سپس نتایج حاصله ارزیابی می‌شود. این سناریو شامل ده هزار بازه زمانی بوده که هر بازه زمانی ۱۵ ثانیه است. تعداد بار ورودی در هر بازه زمانی $L(t)$ بین ۱۰ درخواست بر ثانیه تا ۱۳۰درخواست بر ثانیه، به‌صورت تصادفی با تابع توزیع پواسون به ایستگاه پایه وارد می‌شود. $H(t)$ بین ۱۰ میلی‌ثانیه تا ۲۰ میلی‌ثانیه تغییر می‌کند. مقدار انرژی تجدید پذیر طبق[۱۲] از توزیع نرمال با پارامتر $N(520,150)$ به سیستم وارد می‌شود. حداکثر ظرفیت باتری $B=2kWh$ در نظر گرفته‌شده که در $b(0)=0$ است. مصرف انرژی ثابت ایستگاه پایه $E_{sta}=300W$ است. حداکثر تعداد کارگزارها در لبه شبکه $S=10$ است که هرکدام از این کارگزارها در صورت فعال بودن 150Wمصرف می‌کند. حداکثر نرخ پردازشی هر کارگزار ۲۰ درخواست بر ثانیه است. هزینه استهلاک هر واحد از باتری $\beta=0.01$ خواهد بود و ضریب هزینه هر واحد از منبع تغذیه پشتیبان $\varphi=0.15$ است. مقادیر پارامترها در الگوریتم XCSF به این صورت است که مقدار x0 در این مسئله ۱ در نظر گرفته‌شده است. مقدار نرخ یادگیری ۰,۵ است.

### ٤-٢ مقایسه خروجی XCSF و XCS

همان‌طور که ذکر شد، الگوریتم XCSF تقریبی از وزن‌های تابع خطی توزیع بار به لبه شبکه به ما می‌دهد و ما می‌توانیم از این تابع برای تصمیم‌گیری در مورد ورودی‌ها در زمان‌های بعدی

استفاده کنیم. بنابراین نیازی به اجرای الگوریتم برای تصمیم‌گیری برای بارهای کاری در اسلات‌های زمانی بعدی نخواهد بود. برای هر بار اجرای الگوریتم سرباری به هر گره در محیط مه اضافه می‌شود. درنتیجه در اسلات‌های زمانی پس از همگرایی سیستم به تابع توزیع بار، درصورتی‌که خروجی یعنی میزان بار قابل‌پردازش در گره‌های مه در الگوریتم XCSF با خروجی الگوریتم XCS مطابقت تقریبی داشته باشد، این سربار محاسباتی از سیستم حذف‌شده وXCSF بهتر از XCSعمل می‌کند. پس در این پژوهش، معیار بهبود XCSF به XCF، تطابق تقریبی خروجی‌های این دو الگوریتم است .

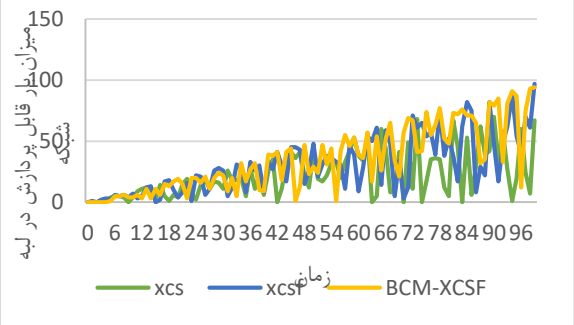


**شکل (۵): میزان توزیع بار به ازای بار ورودی در ۱۰۰ بازه زمانی**

در شکل (۵) می‌بینیم که نمودار خروجی‌های الگوریتم XCSF و خروجی‌های الگوریتم XCS باهم تطابق تقریبی دارند.به عبارت دیگر، می‌توان نتیجه گرفت که میانگین بار پردازشی در مه، در هر دو الگوریتم باهم تطابق دارد.

حتی پس از افزودن حافظه برای نگه‌داری بهترین دسته‌بندها در XCF نیز این تطابق تقریبی خروجی‌ها حفظ می‌شود. حال باید ببینیم که مقدار مصرف انرژی، تأخیر و مصرف باتری در هر الگوریتم چطور تغییر می‌کند. چراکه هدف ما ایجاد مصالحه بین سطح انرژی و تأخیر بوده است.

## ٤- ۳ مقایسه مصرف انرژی

در شکل (٦) مصرف انرژی برای ۱۰۰۰ بازه زمانی نمودار رسم شده است. در ابتدا صعود هر سه الگوریتمXCS ، BCM XCS و XCSF یکسان است. پس از بازه زمانی ۱٤۰ مصرف انرژی الگوریتم XCSF به‌صورت ناگهانی بسیار افزایش می‌یابد. اما همان‌طور که مشخص است مقدار میانگین مصرف انرژی در الگوریتم BCM XCSF در طول این بازه زمانی از ۲۰۰۰ کمتر است و رشد صعودی نخواهد داشت. پس می‌توان نتیجه گرفت که ازنظر مصرف انرژی الگوریتم BCM XCSF عملکرد بهتری دارد.

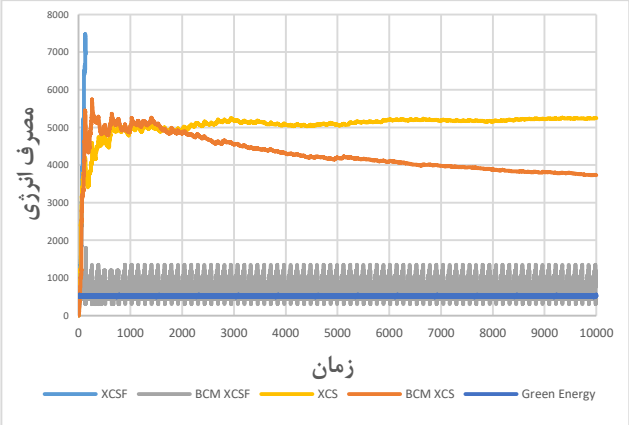


شکل (٦): میزان مصرف انرژی در ۱۰۰۰۰ بازه زمانی

نکته‌ای که در شکل (٦) به چشم می‌خورد، این است که مصرف انرژی مدل حافظه‌دار نسبت به مدل بدون حافظه در XCSF کاهش داشته و تقریباً انرژی تجدید پذیر مقداری انرژی موردنیاز را در لبه شبکه تأمین می‌کند. از این موضوع می‌توان نتیجه گرفت که روش BCM-XCSF با ادامه یادگیری و جمع‌آوری بهترین دسته‌بندها در تلاش است، بارها به‌گونه‌ای توزیع شوند که انرژی موردنیاز آن‌ها بیشتر از طریق انرژی تجدید پذیر تأمین شود تا مصرف باتری به حداقل برسد.

در ۱۰۰۰ بازه زمانی دو روش XCS و BCM-XCS روند تقریباً مشابهی را طی می‌کنند اما اگر در بازه زمانی ۱۰۰۰۰ آن‌ها را مقایسه کنیم، در بازه زمانی ۲۰۰۰ به بعد مصرف انرژی روش BCM-XCS نسبت به XCS پایه رو به کاهش می‌رود و به عدد ٤۰۰۰ در مصرف انرژی همگرا می‌شود، درحالی‌که در بازه ۱۰۰۰۰ روش XCSپایه به عدد ۵۰۰۰ در مصرف انرژی همگرا می‌شود.

روشBCM-XCSF حتی در ۱۰۰۰۰ بازه زمانی نیز عملکرد خود را حفظ می‌کند و مصرف انرژی آن از ۱۵۰۰ افزایش نمی‌یابد. لازم به ذکر است که در بازه زمانی ۱۰۰۰۰، مصرف انرژی روش XCSFمقدار مصرف انرژی به‌اندازه‌ای زیاد می‌شود که با نمودارهای دیگر قابل‌مقایسه نیست.

## ٤-٤ مقایسه میزان باتری مصرف‌شده

طبق نمودار به‌دست‌آمده در شکل (٦) در ابتدای بازه زمانی، باتری در هر دو الگوریتم در حال شارژ شدن است. در ابتدای بازه زمانی الگوریتم XCS مقدار شارژ بیشتری را در باتری نتیجه می‌دهد. پس از بازه زمانی ۲۵۰ مقدار شارژ در دو الگوریتم در حال همگرا شدن هستند. در الگوریتم XCSF بافاصله کمی از الگوریتم XCS شارژ بیشتری در باتری‌ها باقی می‌ماند. با درنظر گرفتن نمودار روش BCM-XCS، این بار سه روش XCS ، XCSFو BCM-XCS را در ۱۰۰۰۰ بازه زمانی می‌بینیم. نتایج نشان می‌دهند که مقدار باتری BCM-XCS بیشتر از دو روش دیگر است. بنابراین، عملکرد روش XCSF در شارژ باتری از روش XCS پایه بهتر است.

در شکل (۷) می‌توان دید که BCM-XCSF به دلیل اینکه مصرف انرژی کمتری دارد و مقداری از این انرژی مصرفی توسط انرژی تجدید پذیر تأمین‌شده است در بیشتر اوقات میزان شارژ باتری بیشتری را نتیجه می‌دهد. درواقع، در این روش استفاده کمتری از باتری شده است و در بسیاری از بازه‌هایی زمانی باتری شارژ کامل یعنی ۲۰۰۰ را دارد.

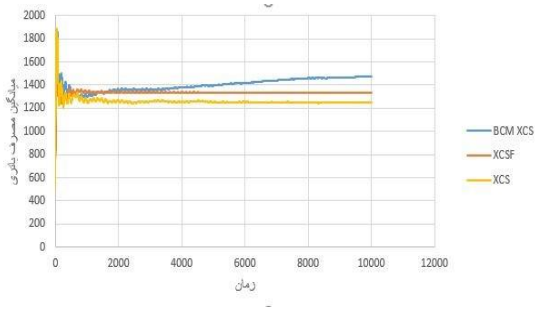


**شکل (۷): میانگین مصرف باتری در ۱۰۰۰۰ بازه زمانی**

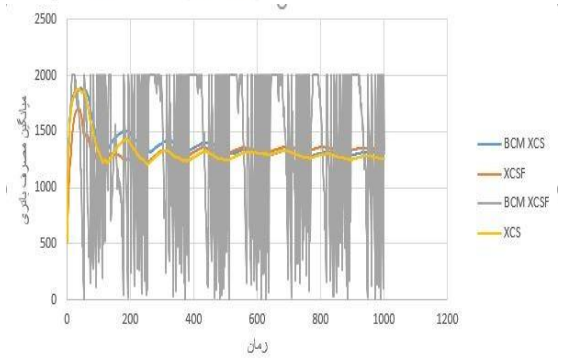


**شکل (۸): میانگین مصرف باتری هر ٤ روش در ۱۰۰۰ بازه زمانی**

## ٤-٥ مقایسه تأخیر

در شکل (۹) نمودار میزان تأخیر هر الگوریتم تا بازه‌ی زمانی ۲۰۰ نمایش داده‌شده است. برای ملموس بودن و قابل‌مقایسه بودن نمودار هرکدام از روش‌ها، تسریع آن‌ها نسبت به الگوریتم XCS نرمال شده است. طبق تصویر می‌بینیم که تأخیر الگوریتم XCSF رو به کاهش است. تأخیر الگوریتم BCM-XCSF تا حدودی مشابه به تأخیر الگوریتم BCM-XCS است اما کمتر از آن است . در بازه‌های زمانی که مقدار بار ورودی برای پردازش کمتر است، عملکرد روش BCM-XCSF به عملکرد روش XCSF نزدیک تر است. هرچقدر این میزان بار ورودی یعنی L(t) افزایش یابد، عملکرد BCM-XCSF به عملکرد BCM-XCS ازلحاظ تأخیر نزدیک‌تر می‌شود. برای مثال، در ۱۰ بازه زمانی ابتدایی و همین‌طور بازه زمانی ۱۲۵ تا ۱٤۰ مقدار L(t) زیر ۱۰ است. در این بازه زمانی، تأخیر XCSF و BCM-XCSF تا حدودی مشابه است و در برخی نقاط این دو نمودار به هم متصل می‌شوند و حدوداً تاخیرشان به ترتیب، ٤۰٪ و ٦۰٪ تأخیر XCS است.

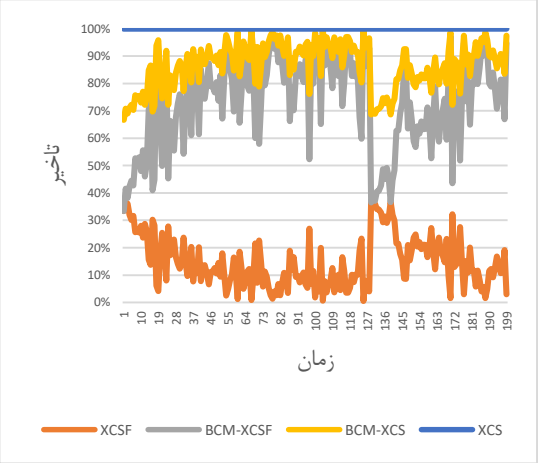


**شکل (۹): مقایسه درصد تأخیر الگوریتم‌ها در هر بازه زمانی**

## ۵-نتیجه‌گیری

در این مقاله ، از سیستم دسته‌بند یادگیر مبتنی برXCS به نام XCSF برای تقریب تابع توزیع بار در محاسبات مه‌آلود استفاده شد. نتایج نشان داد که بار محاسباتی به‌صورت بهینه توسط این مدل یادگیری تقویتی بین مه و ابر توزیع می‌شود. مقایسه‌ها نشان می‌دهد که روش ارائه‌شده ازنظر کاهش انرژی مصرفی و کاهش زمان پردازش از XCS پایه بهتر عمل می‌کند. درروش ارائه‌شده، در اکثر زمان‌ها بیشینه انرژی تجدید پذیر موجود برای محاسبات استفاده‌شده و انرژی باتری در بیشترین سطح شارژ ممکن باقی می‌ماند.

پیاده‌سازی مدل‌های کوچک از دسته‌بند ارائه‌شده در این تحقیق قدم بعدی تحقیق خواهد بود. چنین مدل‌های کوچکی قابلیت اجرا در سیستم‌های لبه با منابع محدود را دارند.

## References

[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] M. Chiang and . T. Zhang, "Fog and IoT: An oveBrview of research opportunities," IEEE Internet of Things Journal, vol. 3, pp. 854-864, 2016.

[3] 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.

[4] C. -H. Hong and . B. Varghese, "Resource Management in Fog/Edge Computing: A Survey," arXiv preprint arXiv:1810.00305, 2018.

[5] P. Zhang, . M. Zhou and . G. Fortino, "Security and truäst issues in Fog computing: A survey," Future Generation Computer Systems, vol. 88, pp. 16-27, 2018.

[6] 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.

[7] 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.

[8] S. W. Wilson, "Classifiers that approximate functions," Natural Computing, vol. 1, p. 211–234, 2002.

[9] J. Holland et al., "What Is a Learning Classifier System?," in Learning Classifier Systems, 2000.

[10] B. Bartin, "Use of learning classifier systems in microscopic toll plaza simulation models," IET Intelligent Transport Systems, vol. 13, pp. 860-869, 2019.

[11] M. R. Karlsen and S. Moschoyiannis, "Evolution of control with learning classifier systems," Applied network science, vol. 3, p. 30, 2018.

[12] J. Xu, . L. Chen and S. Ren, "Online learning for offloading and autoscaling in energy harvesting mobile edge computing," IEEE Transactions on Cognitive Communications and Networking, vol. 3, pp. 361-373, 2017.

[13] D. Kanapram, . G. Lamanna and . M. Repetto, "Exploring the trade-off between performance and energy consumption in cloud infrastructures," in Second International Conference on Fog and Mobile Edge Computing (FMEC), 2017.

[14] H. Wu, L. Chen, C. Shen, . W. Wen and . J. Xu, "Online geographical load balancing for energy-harvesting mobile edge computing," in 2018 IEEE International Conference on Communications (ICC), 2018.

[15] J. Wan, B. Chen, S. Wang, M. Xia, D. Li and C. Li, "Fog Computing for Energy-aware Load Balancing and Scheduling in Smart Factory," IEEE Transactions on Industrial Informatics, 2018.

[16] D. Zeng, L. Gu and H. Yao, "Towards energy efficient service composition in green energy powered Cyber–Physical Fog Systems," Future Generation Computer Systems, 2018.

[17] 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.
[18] S. W. Wilson, "Get Real! XCS with Continuous-Valued Inputs," in International Workshop on Learning Classifier Systems, 2000.
[19] S. W. Wilson, "Classifiers that approximate functions," Natural Computing, vol. 1, p. 211–234, 2002.
[20] P. Lanzi, "XCS with Computed Prediction for the Learning of Boolean Functions," in IEEE Congress on Evolutionary Computation, 2005.
[21] fchauvel, "XCSF," [Online]. Available: https://github.com/fchauvel/XSCF.Optimization of Electrical and Electronic Equipment (pp. 167–173).

Journal of Applied And Basic Machine Intelligence Research (ABMIR)

Applied and Basic Machine Intelligence Research

Vol. 2, No. 1, Spring & Summer 2024, pp. 1-13

# An efficient mechanism to determine a function for load distribution in fog computing based on the use of learning classification systems

Mahdi Abbasi, Bahareh HamidiMoheb*

Computer Engineering Department, Boali Sina University, Hamedan

## Article Information

**Original Research Paper**

**Received:**
2023 June 29

**Accepted:**
2024 March 12

**Keywords:**
Internet of things, fog computing processing, function estimation , learning classification systems

**Corresponding Author*:**
b.hamidimoheb@eng.basu.ac.ir

## Abstract

With the rapid development of the Internet of Things, the fog computing model has been introduced as an attractive solution for processing data in IoT applications. In the fog environment, IoT applications are executed by intermediate computational nodes in the fog, as well as physical servers in cloud data centers. Therefore, issues related to resource management and energy management as challenging problems in fog computing need to be addressed. Recently, research has been conducted to create a balance between energy and cost in fog computing. In this study, while examining these approaches, an efficient method for approximating the load distribution function using two learning classification systems called XCSF and BCM-XCSF in fog processing nodes has been presented to optimize previous approaches and manage fog processing resources as much as possible. These two methods differ in having memory to store the best classifiers. Simulation results indicate that both XCS and BCM-XCS have appropriate load distribution. These two methods reduce computational overhead. Particularly, the BCM-XCSF method not only reduces delays by about 60%, but also improves energy consumption.

: 10.22034/ABMIR.2024.20271.1030

E-ISSN: 2821-2037 