

## An artificial intelligence model for energy-aware task scheduling based on learning automation for IoT applications

**Received: 04 January 2022**  
**Accepted: 16 February 2022**  
**Article type: Research Article**  
**PP: 13-23**

**DOI:**

[10.22034/pitc.2022.1266509.1113](https://doi.org/10.22034/pitc.2022.1266509.1113)

**reza ebrahim pourian**

Department of computer Islamic Azad  
university arak . arak. Iran

[Rezae7583@gmail.com](mailto:Rezae7583@gmail.com)

**Mehdi fartash**

Department of computer Islamic Azad  
university arak . arak. Iran

(Corresponding author)

[m-fartash@iau-arak.ac.ir](mailto:m-fartash@iau-arak.ac.ir)

**javad akbari torkestani**

Department of computer Islamic Azad university  
arak . arak. Iran

[j-akbari@iau-arak.ac.ir](mailto:j-akbari@iau-arak.ac.ir)

**Abstract**

In this paper, an artificial intelligence model for energy-aware task scheduling is based on learning automata in Fog Computing applications. fog computing is a distributed computing layer that acts as an intermediate layer between the cloud and the Internet of Things to improve the quality of services. One of the most important factors in energy consumption is related to task scheduling. This paper examines the timing of tasks in a fog environment to reduce energy consumption, makespan, and cost using learning automata. Then, for the first time, a neural network is introduced as a model of artificial intelligence based on learning automata in fog. The proposed neural network model has the ability to predict the relationship between the parameters of completion time, energy, and cost based on the number of virtual machines. The results of the proposed artificial intelligence model show that all the mentioned parameters are predicted with less than one percent accuracy.

**Keywords:** artificial intelligence, Cost, energy neural network  
Makespan, learning automata

## یک مدل هوش مصنوعی برای زمان بندی وظایف به صورت آگاه از انرژی بر پایه اتوماتای یادگیر تصادفی برای کاربردهای اینترنت اشیا

### چکیده

در این مقاله یک مدل هوشمند مصنوعی برای زمان بندی وظایف (Task scheduling) به صورت آگاه از انرژی (Energy-aware) بر پایه اتوماتای یادگیر (Learning automata) در کاربردهای رایانش مه (Fog Computing) ارائه شده است. رایانش مه یک لایه محاسباتی توزیع شده است که به عنوان یک لایه میانی بین ابر و اینترنت اشیا به منظور ارتقاء کیفیت خدمات عمل می کند. یکی از مهمترین فاکتورها در مصرف انرژی مربوط به زمان بندی وظایف است. در این مقاله موضوع زمان بندی وظایف در محیط مه به منظور کاهش مصرف انرژی، زمان اتمام کار (Makespan) و هزینه با استفاده از اتوماتای یادگیر بررسی شده است. سپس برای اولین بار یک شبکه عصبی به عنوان مدل هوش مصنوعی بر اساس اتوماتای یادگیر برنامه ریزی وظایف در محیط مه ارائه شده است. مدل شبکه عصبی ارائه شده توانایی پیش بینی ارتباط بین پارامترهای زمان اتمام کار، انرژی و هزینه را بر اساس تعداد ماشین های مجازی دارد. نتایج مدل هوش مصنوعی ارائه شده نشان می دهد که تمام پارامترهای مذکور با کمتر از یک درصد پیش بینی شده اند. همچنین در مدل ارائه شده خطای آموزش و آزمون برای پارامتر زمان اتمام کار به ترتیب ۰.۰۲ و ۰.۰۴ بدست آمد، برای پارامتر انرژی به ترتیب ۰.۱۶ و ۰.۸۴ بدست آمد و برای پارامتر هزینه به ترتیب ۰.۰۲ و ۰.۱۹ بدست آمد.

کلیدواژه ها: هوش مصنوعی، هزینه، انرژی، شبکه عصبی، زمان اتمام کار، اتوماتای یادگیر

دریافت: ۱۴۰۰/۱۰/۱۴

پذیرش: ۱۴۰۰/۱۱/۲۷

نوع مقاله: پژوهشی

صص: ۲۳-۱۳

شناسه دیجیتال (doi).

[10.22034/pitc.2022.1266509.1113](https://doi.org/10.22034/pitc.2022.1266509.1113)

رضا ابراهیم پوریان

گروه کامپیوتر، دانشگاه آزاد اسلامی،

واحد اراک، اراک، ایران

Rezae7583@gmail.com

مهدی فرتاش

گروه کامپیوتر، دانشگاه آزاد اسلامی،

واحد اراک، اراک، ایران

(نویسنده مسئول)

m-fartash@iau-arak.ac.ir

جواد اکبری ترکستانی

گروه کامپیوتر، دانشگاه آزاد اسلامی،

واحد اراک، اراک، ایران

j-akbari@iau-arak.ac.ir

## ۱- مقدمه

است. رایانش مه هزینه‌های خرید نرم‌افزار، سخت‌افزار، نصب و راه‌اندازی دیتاسنترها یا رک‌های سروری سایت (برق روزانه برای تأمین برق و خنک کردن آن‌ها) همچنین نیاز به کارشناسان فناوری اطلاعات برای مدیریت زیرساخت‌ها را به‌صورت چشمگیر کاهش می‌دهد که این موارد باعث سرعت بخشیدن به کارها می‌شود. بیشتر سرویس‌های رایانش مه بر اساس نیازهای موجود هستند، بنابراین مقادیر وسیعی از منابع رایانش را می‌توان در چند دقیقه فراهم کرد و تنها با چند کلیک ماوس، برنامه‌ای با انعطاف‌پذیری بسیار زیاد را ممکن ساخت و از فشار برنامه‌ریزی کاست.

مصرف انرژی در محیط مه، یک پارامتر مهم چالش‌برانگیز محسوب می‌گردد بنابراین روش‌هایی که برای کاهش انرژی در محیط‌های مه استفاده می‌شوند حائز اهمیت است. از جمله این روش‌ها می‌توان به دیجیتال‌سازی کردن، مراکز داده سبز و استفاده از انرژی‌های تجدید پذیر اشاره کرد. مراکز داده سبز از گرهای هوشمند، تهویه فضای باز و سرورهای کم‌توان، به‌منظور کاهش مصرف انرژی استفاده می‌کنند. زمان‌بندی وظایف، به‌عنوان یک مسئله NP-Hard یکی از مهم‌ترین پارامترهای حیاتی در رابطه با مصرف انرژی در محیط مه می‌باشد.

در محیط‌های توزیع شده، زمان‌بندی وظایف منابعی را با ترتیب مشخص به وظایف اختصاص می‌دهد. زمان‌بندی وظایف در سرورهای مه، از اهمیت بالایی برخوردار هستند، مخصوصاً در مواقعی که زمان‌بندی نامناسب باعث افزایش مصرف انرژی می‌شود [۶].

در مرجع [۶] یک الگوریتم ابتکاری ارائه گردیده است که این الگوریتم یک تعادل بین هزینه و زمان اتمام کار در منابع ابری و رایانش مه، ایجاد می‌کند. در مرجع [۷] یک روش به‌منظور بهبود هزینه، کاهش زمان پاسخ و مقیاس انرژی در سرویس‌های اینترنت اشیا ارائه شده است. مسئله زمان‌بندی در رایانش مه، در مرجع [۸] با آزمایش تقاضاهای محلی در محیط‌های مختلف مورد مطالعه قرار گرفته است. همچنین الگوریتم‌های فراابتکاری در مراجع [۹-۱۰] به‌منظور حل مسئله زمان‌بندی وظایف در محیط مه، ارائه شده‌اند.

در بسیاری از کارهای صورت گرفته، شبکه‌های عصبی مصنوعی (ANN) در بسیاری از روش‌های حل مهندسی مسئله به‌منظور پیش‌بینی، تخمین و مدل‌سازی بکار رفته است [۱۱-۱۸].

استفاده از شبکه‌های عصبی مصنوعی در زمینه اینترنت اشیا و رایانش مه، یک روش نسبتاً جدید محسوب می‌شود. سادگی و راحتی استفاده به‌منظور مدل‌سازی و پیش‌بینی از یک سو و دقت بالا از سوی دیگر از مهم‌ترین مزایای اصلی شبکه‌های عصبی مصنوعی هستند.

در مرجع [۱۹] موارد استفاده از شبکه‌های عصبی مصنوعی در کاربردهای بارگذاری و بایاسینگ در محیط مه نمایش داده شده است.

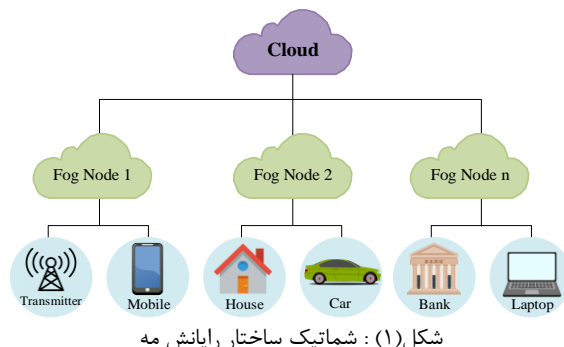
در مرجع [۲۰] شبکه عصبی مصنوعی و الگوریتم Q-learning به‌منظور استفاده در آدرس‌دهی اینترنت اشیا و زمان‌بندی وظایف

محاسبات مه به‌عنوان ابزاری برای پشتیبانی از کیفیت خدمات به کاربران از طریق رایانش ابری پدیدار شده است. رؤس مه غنی از منابع محاسباتی نیستند بنابراین از آن‌ها به همراه رایانش استفاده می‌شود. تا همین اواخر، رایانش ابری بهترین گزینه برای بسیاری از کاربران برای مدیریت، پردازش و بایگانی داده‌های حجیم خود در مرکز داده از راه دور از طریق اینترنت بوده است. از آنجایی که تقاضا برای خدمات رایانش ابری افزایش یافته است تا با بهره‌گیری از یک مدل قیمت‌گذاری آسان از منابع محاسباتی عظیم آن استفاده شود. فشار بیش‌ازحد بر خدمات رایانش ابری منجر به تأخیر زیاد و نیاز به پهنای باند شبکه است [۱-۳]. تأخیر زیاد ناشی از ارسال داده‌ها به ابر می‌تواند باعث ایجاد مشکلاتی گردد. به‌عنوان مثال، پردازش داده‌ها به‌صورت بلادرنگ برای ابزارهای پوشیدنی پزشکی بسیار مهم است زیرا با سلامت بیماران در ارتباط است. در نتیجه، ارائه‌دهندگان خدمات مجبور به گسترش مراکز داده با ایجاد مراکز جدید برای تحقق جاه‌طلبی‌های کاربران خود و اطمینان از خدمات ارائه‌شده هستند.

در برخی از کاربردها سرعت انتقال اطلاعات یک پارامتر حیاتی به حساب می‌آید. برای نمونه ممکن است تأخیر در زمینه‌های حمل‌ونقل و سیستم‌های کنترل سلامت موجب وجود آمدن یک تصادف یا مورد فوتی می‌گردد [۴].

در رایانش مه، مه بین ابر و کاربران نهایی قرار می‌گیرد و داده‌ها را به‌صورت محلی، پردازش، جمع‌آوری و نگهداری می‌کند. در این حالت فقط در صورت لزوم داده‌ها به ابر ارسال می‌شود که باعث پایین آمدن ترافیک شبکه و افزایش سرعت پردازش می‌شود.

شبکه‌های مه دارای معماری سلسله‌مراتبی از گرهای حسگر، ابزارهای لبه و ابر هستند. سنسورها داده‌های جمع‌آوری شده را به بالاترین سطح شبکه ارسال می‌کنند. همچنین گرهای راه‌انداز، به‌منظور کنترل و تغییر محیط بکار برده می‌شوند [۵]. شماتیک ساختار رایانش مه در شکل (۱) نمایش داده شده است.



رایانش ابری و رایانش مه دیدگاه سنتی ارتباطات و دسترسی به اطلاعات را در مورد منابع فناوری اطلاعات (IT) به‌کلی تغییر داده

که جهان بر اساس چندین انفجار بزرگ ساخته شده است. این تئوری از وجود چندین جهان موازی خبر می‌دهد که در موازات هم ادامه می‌یابند. الگوریتم چند نظمی بر اساس سه محتوا اصلی به نام سفید چاله، سیاه چاله و کرم چاله بنیان شده است و کاربرد فراوانی در بهینه‌سازی دارد.

الگوریتم گرده‌افشانی گل‌ها یا FPA<sup>۵</sup> یک الگوریتم فرا ابتکاری می‌باشد که از فرآیند گرده‌افشانی در طبیعت الهام گرفته است. ایده اصلی این الگوریتم برگرفته از گرده‌افشانی حیاتی (از گلی به گل دیگر توسط زنبورها...) و غیر حیاتی (خودگرده‌افشانی) گل‌ها در طبیعت است. این رفتار در این الگوریتم توسط پارامتر مشخصی کنترل می‌شود و کاربرد فراوانی در مدل‌سازی دارد.

الگوریتم شاهین هریس یا HHO<sup>۶</sup> یک الگوریتم فرا ابتکاری است که با تقلید از رفتار شکار نوعی شاهین، بنام شاهین هریس الهام گرفته شده است. ایده اصلی این الگوریتم، رفتار مشارکتی و سبک تعقیب شاهین هریس در طبیعت است که به نام یورش غافلگیرانه شناخته می‌شود. روش فوق برای بهینه‌سازی بکار می‌رود و معمولاً سریع به جواب می‌رسد.

الگوریتم خفاش یا BIA<sup>۷</sup> یک الگوریتم فرا ابتکاری می‌باشد که از رفتار جمعی خفاش‌ها در محیط طبیعی الهام گرفته است. این الگوریتم بر مبنای استفاده از خاصیت انعکاس صدا توسط خفاش‌ها است. خفاش‌ها مسیر و محل دقیق طعمه خود را بوسیله فرستادن امواج صوتی و دریافت بازتاب آن، پیدا می‌کنند. با بررسی و بهینه‌سازی این الگوریتم در سیستم‌ها و شبکه‌های مختلف می‌توان به تکنیک‌های نوین جهت بهینه‌سازی استفاده نمود.

در کار پیشنهادی یک مدل هوشمند مصنوعی برای زمان بندی وظایف به صورت آگاه از انرژی بر پایه اتوماتای یادگیر در کاربردهای رایانش مه ارائه شده است. رایانش مه که بین ابر و اینترنت اشیا قرار می‌گیرد باعث افزایش چشمگیر سرعت و کاهش هزینه‌ها می‌شود. در طرح پیشنهادی به کمک یک شبکه عصبی یک مدل هوش مصنوعی بر اساس اتوماتای یادگیر در محیط مه ارائه شد. مدل ارائه شده توانایی پیش‌بینی ارتباط بین پارامترهای زمان اتمام کار، انرژی و هزینه را بر اساس تعداد ماشین‌های مجازی دارد. نتایج مدل هوش مصنوعی ارائه شده نشان می‌دهد که تمام پارامترهای مذکور با کمتر از یک درصد پیش‌بینی شده‌اند. همچنین، در این مقاله یک مدل شبکه عصبی مصنوعی جدید به منظور پیش‌بینی ارتباط بین پارامترهای زمان اتمام کار، مصرف انرژی و هزینه بر اساس طول ماشین مجازی ارائه شده است. نتایج مدل پیشنهادی نشان داد که تمامی پارامترهای مطلوب با خطایی کمتر از یک درصد پیش‌بینی شده‌اند. همچنین از مدل شبکه عصبی پیشنهادی ارائه شده می‌توان

برای کاربردهای رایانش ابری ادغام شده‌اند. همچنین در مرجع [۲۱] روش شبکه عصبی به منظور استفاده از یک مکانیزم امن برای زمان بندی وظایف در کاربردهای رایانش مه استفاده شده است. در این مقاله مسئله زمان بندی وظایف با استفاده از اتوماتای یادگیر به جهت کاهش مصرف انرژی در گره‌های مه حل شده است. همچنین به منظور کمینه نمودن مصرف انرژی از اتوماتای یادگیر برای اختصاص وظایف به گره‌های مه استفاده شده است. نتایج بدست آمده از الگوریتم پیشنهادی با هفت الگوریتم مشابه مقایسه شده است که عبارتند از الگوریتم PSO [۲۲]، الگوریتم GWO [۲۳]، الگوریتم Flower [۲۴]، الگوریتم MVALS [۲۵]، الگوریتم WALS [۲۶]، الگوریتم HHOLS [۲۷] و الگوریتم BALS [۲۸]. نتایج این مقایسه کارآمدی الگوریتم پیشنهادی را از نظر مصرف انرژی، زمان اتمام کار و هزینه تأیید می‌کند.

الگوریتم بهینه‌سازی گرگ خاکستری یا GWO<sup>۱</sup>، یک الگوریتم فرا ابتکاری است که از ساختار سلسله‌مراتبی و رفتار اجتماعی گرگ‌های خاکستری در هنگام شکار الهام گرفته است. این الگوریتم مبتنی بر جمعیت بوده، فرآیند ساده‌ای دارد و به سادگی قابلیت تعمیم به مسائل با ابعاد بزرگ را دارد. گرگ‌های خاکستری به عنوان شکارچیان رأس در نظر گرفته می‌شوند، که در بالای هرم زنجیره غذایی هستند. گرگ‌های خاکستری ترجیح می‌دهند در یک گروه (دسته) زندگی کنند، هر گروه چندین عضو دارد. همه اعضای این گروه دارای سلسله‌مراتب تسلط اجتماعی بسیار دقیق هستند و وظایف خاصی دارند. این الگوریتم برای بهینه‌سازی کاربرد فراوانی در علوم مهندسی دارد.

الگوریتم بهینه‌سازی ازدحام ذرات یا PSO<sup>۲</sup>، یک روش بهینه‌سازی است. این الگوریتم الهام گرفته از رفتار اجتماعی گونه‌های مختلف زیستی در زندگی گروهی آنان است؛ مانند پرندگان، ماهی‌ها یا کلونی‌های مورچه‌ها. این الگوریتم تعامل بین اعضا را برای به اشتراک‌گذاری اطلاعات تقلید می‌کند. الگوریتم ازدحام ذرات کاربرد وسیعی در حوزه‌های متعددی در بهینه‌سازی و در ترکیب با دیگر الگوریتم‌های بهینه‌سازی داشته است.

الگوریتم حداقل مربعات متناوب یا WALSS<sup>۳</sup>، الگوریتمی برای به حداقل رساندن تابع هدف هنگام فاکتورگیری ماتریس در سیستم‌های توصیه‌گر که می‌تواند وزنه‌ای سبک برای نمونه‌های از دست‌رفته باشد. WALSS خطای مربع وزنی بین ماتریس اصلی و بازسازی را با تناوبی بین تثبیت ردیف و ستون فاکتورگذاری به حداقل می‌رساند و کاربرد فراوانی در بهینه‌سازی دارد.

الگوریتم بهینه‌سازی چند نظمی یا MVO<sup>۴</sup> یک الگوریتم فرا ابتکاری و مبتنی بر جمعیت است. نظریه چند نظمی بر این باور استوار است

<sup>۵</sup> Flower Pollination Algorithm

<sup>۶</sup> Harris Hawks optimization

<sup>۷</sup> Bat-inspired algorithm

<sup>۱</sup> Grey Wolf Optimizer

<sup>۲</sup> Particle swarm optimization

<sup>۳</sup> Weighted Alternating Least Squares

<sup>۴</sup> Multi-Verse Optimizer

به منظور پیش بینی رفتار الگوریتم های دیگر که در مقدمه بیان شده اند استفاده کرد.

ساختار مقاله در ادامه به صورت زیر ارائه شده است: در بخش دوم توضیح مربوط به اتوماتای یادگیر ارائه شده است. معیارهای ارزیابی در بخش سوم بیان گردیده است. در بخش چهارم مسئله TSFC و مقدمه ای بر رایانش مه توضیح داده شده اند. الگوریتم پیشنهادی LaTSF در بخش پنجم ارائه شده است. نتایج عددی و مقایسه ای برای الگوریتم LaTSF در بخش ششم آورده شده است. ساختار مدل شبکه عصبی ارائه شده در بخش هفتم بیان شده است. نتیجه مدل شبکه عصبی ارائه شده و نتیجه گیری نهایی در بخش های هشتم و نهم بیان گردیده است.

مجموعه محدودی از ورودی ها،  $\beta = \{\beta_1, \beta_2, \dots, \beta_m\}$  مجموعه ای برای بیان سیگنال های تقویتی و  $C = \{c_1, c_2, \dots, c_r\}$  مجموعه ای برای بیان احتمال خطا است و  $c_i$  مرتبط با عملکرد داده شده  $\alpha_i$  است. بسته به ماهیت سیگنال تقویتی  $\beta$  مدل ها را می توان به سه دسته  $P, Q, S$  و تقسیم کرد. در مدل  $P$  سیگنال تقویتی مقادیر باینری صفر و یک دارد. در حالیکه در مدل  $Q$  این مقادیر به صورت محدود در بازه صفر و یک می باشند. همچنین در مدل  $S$  سیگنال تقویتی در بازه  $[a, b]$  قرار می گیرد. اگر یک محیط تصادفی به عملکرد پاداش بدهد، بردار احتمال عملکرد بوسیله الگوریتم یادگیری خطی که در رابطه (۱) توضیح داده شده است بروز رسانی می شود. در غیر این صورت اگر محیط به عمل انتخاب شده جریمه بدهد بردار احتمال بر اساس رابطه (۲) بروز رسانی می شود.

$$p_i(n+1) = p_i(n) + a[1 - p_i(n)] \quad (1)$$

$$\begin{aligned} p_j(n+1) &= (1-a)p_j(n) \quad \forall j, j \neq i \\ p_i(n+1) &= (1-a)p_i(n) \end{aligned} \quad (2)$$

لازم به ذکر است،  $r$  تعداد عمل های اتوماتا،  $a$  پارامتر پاداش و  $b$  پارامتر جریمه ای اتوماتا می باشند.

### ۳- ارزیابی

سه معیار عملکرد زمان اتمام کار، انرژی و هزینه برای بهینه سازی توسط اتوماتای یادگیری در نظر گرفته شده اند که در ادامه توضیح داده شده اند.

#### ۳-۱- زمان اتمام کار

ماشین مجازی وظایف دریافتی را یکی پس از دیگری پردازش می کند. زمان اجرا برای هر ماشین مجازی برابر با زمان پردازش آخرین وظیفه ارسالی می باشد. وقتی که وظیفه  $T_i$  به ماشین مجازی اختصاص داده می شود مقدار آن در ماتریس تخصیص برابر یک می باشد. در غیر این صورت مقدار آن برابر صفر می باشد. زمان اتمام کار برابر بزرگ ترین زمان اجرای کل یک ماشین مجازی  $V_{mj}$  در بین تمام ماشین های مجازی است. [۳۱]. زمان اجرای هر وظیفه در ماشین مجازی در رابطه (۳) تعریف شده است.


$$Et_j = \sum_{i=1}^m A_{ij} \times e_{ij} \quad (3)$$

که در رابطه (۳)  $A_{ij}$  ماتریس تخصیص است و  $e_{ij}$  در رابطه (۴) محاسبه شده است.

$$e_{ij} = \frac{w_i}{s_j} \quad (4)$$

### ۲- الگوریتم یادگیری اتوماتا

اتوماتای یادگیر مدلی انتزاعی است که قادر است تا تعداد محدودی عمل را انجام دهد. اتوماتا عمل های خود را به کمک یک بردار احتمال عمل انتخاب و آن را به یک محیط تصادفی اعمال می نماید. عمل انتخاب شده توسط اتوماتا، از سوی محیط احتمالی ارزیابی شده و پاسخ به اتوماتای یادگیر برگردانده می شود. اتوماتا بر اساس پاسخ دریافتی از محیط بردار احتمال عمل خود را به منظور انتخاب عمل در مرحله بعد بروز می نماید. اتوماتاهای یادگیر را از یک نقطه نظر می توان به دو دسته ای اتوماتاهای یادگیر با ساختار ثابت و اتوماتاهای یادگیر با ساختار متغیر تقسیم بندی کرد. که در دسته اول، توابع انتقال حالت خروجی اتوماتا با گذشت زمان ثابت بوده اما در دسته دوم این توابع تغییر پذیرند [۲۹-۳۰]. ساختار مدل اتوماتای یادگیر شامل اتوماتای یادگیر و محیط در شکل ۲ نمایش داده شده است.



شکل (۲): ساختار مدل یادگیری اتوماتا

همان طور که گفته شد، در اتوماتای یادگیر بردار احتمال عمل بر اساس سیگنال دریافتی از محیط، به روز رسانی می شود. هدف اصلی اتوماتای یادگیر پیدا کردن عمل بهینه به منظور کمینه کردن خطای دریافتی از محیط است. استفاده از اتوماتای یادگیری در سیستم هایی بیشتر اهمیت پیدا می کند که اطلاعات کاملی در مورد محیط وجود ندارد. همچنین اتوماتا کارکرد بهینه ای در محیط های پیچیده، تصادفی و پویا دارد. در مدل اتوماتای یادگیری، محیط به صورت  $E = \{\alpha, \beta, c\}$  تعریف می گردد که در آن  $\alpha = \{\alpha_1, \alpha_2, \dots, \alpha_r\}$  بیان کننده ی

$\langle F, VM, C \rangle$  تعریف شود به نحوی که  $F = \{F_i | 1 \leq i \leq n\}$  مجموعه‌ای از  $n$  گره ناهمگن است،  $VM = \{vm_i | \forall F_i \in F\}$  مجموعه‌ای از ماشین‌های مجازی است و  $C = \{c_{ij} | vm_{ij} \in VM\}$  ظرفیت‌های پردازشی در یک ماشین مجازی است. با توجه به مرجع [۳۳] مسئله زمان‌بندی وظایف در محیط مه بوسیله سه پارامتر  $\langle f, T, \Lambda \rangle$  تعریف می‌شود، به نحوی که  $f(F, VM, C)$  محیط مه را تعریف می‌کند،  $T = \{\langle t_i, R_i, W_i \rangle | i = 1, 2, 3, \dots, m\}$  وظایف را تعریف می‌کند. همچنین تابع  $\Lambda: T \rightarrow F \times \sigma$  برای نگاشت وظیفه بر روی رأس مه با استفاده از زمان‌بند  $\sigma: T_i \times F \rightarrow VM \times \tau$  است.

### ۵- الگوریتم پیشنهادی

مجموعه  $T = \{T_1, T_2, \dots, T_m\}$  وظایفی هستند که باید به رئوس مه  $F = \{F_1, F_2, \dots, F_n\}$  اختصاص داده شوند. مسئله این است که تخصیص رئوس مه  $F$  به وظایف  $T$  باید با آگاهی از مصرف انرژی و  $MK$  باشد. به طور مشخص هدف، کاهش  $MK$  برای وظایف و انرژی مصرفی توسط رئوس مه است. برای انجام این کار ما با استفاده از اتوماتای یادگیر و مبتنی بر زمان پیشنهادی اجرا و میزان نیازمندی منابع برای هر وظیفه  $T_i$  اقدام به ارائه یک الگوریتم کردیم. یک اتوماتای یادگیر بر اساس زمان پیش‌بینی شده و منابع مورد نیاز برای هر وظیفه ارائه شده است. در الگوریتم پیشنهادی یک استراتژی زمان‌بندی به منظور اختصاص وظایف به منابع محاسباتی توسط اتوماتای یادگیری ارائه شده است.

برای انتخاب وظایف اتوماتای  $A_{TF}$  تعریف شده است. مجموعه‌ی وظایف آن  $A_{TF} = \{A_{TF}^i | \forall i \in \{T_1, T_2, \dots, T_m\}\}$  است. انتخاب عمل  $\alpha$  به این معنی است که زمان‌بند اجازه می‌دهد کار برای پردازش به سیستم وارد شود.  $P_{TF}$  بردار احتمال عمل اتوماتای یادگیری  $A_{TF}$  باشد. واضح است که عمل  $\alpha$  با احتمال  $P$  انتخاب می‌شود. همه اقدامات در ابتدا با احتمال یکسان انتخاب می‌شوند ( $1/N_m$ ). این بدان معناست که در ابتدا تمام وظایف از شانس یکسانی برای انتخاب برخوردار هستند.

الگوریتم پیشنهادی دارای مراحل زیر است:

مرحله ۱: تخصیص احتمال به مجموعه اقدامات  $A_{TF}$ .

مرحله ۲: یک وظیفه توسط اتوماتا با توجه به بردار احتمال  $A_{TF}$  انتخاب می‌شود.

مرحله ۳: اختصاص ماشین مجازی به وظیفه و اجرای آن و به‌روزرسانی بردار احتمال.

مرحله ۴: منابع مورد استفاده برای اجرای وظیفه انتخاب شده به منابع سیستم مه بازگردانده می‌شود.

بردار احتمال عملکرد (APV) اتوماتون  $A_{TF}$  با استفاده از رابطه (۱۱) تعریف می‌شود.

همان‌طور که گفته شده زمان اتمام کار (MK) به‌عنوان بیشترین زمان اجرای نهایی تعریف می‌شود که در رابطه (۵) نمایش داده شده است. همچنین پارامترهای  $w_i$  برابر بار کاری وظیفه و  $s_j$  برای توان پردازش ماشین مجازی است.

$$\text{Makespan}(MK) = \max Et_j, \quad j=1,2,\dots,n \quad (5)$$

### ۲-۳- انرژی

هر ماشین مجازی در یکی از وضعیت‌های فعال یا غیرفعال قرار می‌گیرد. حدود ۶۰ درصد انرژی مصرف شده در سرورها وقتی است که آن‌ها در حالت غیرفعال قرار دارند. بنابراین انرژی مصرف شده توسط ماشین مجازی  $VM_j$  برابر حاصل جمع مصرف انرژی در حالت فعال و غیرفعال است.

زمان بیکاری ماشین مجازی  $VM_j$  برابر حاصل تفریق زمان اجرا  $Et_j$  از  $MK$  است. انرژی مصرف شده توسط هر ماشین مجازی با استفاده از رابطه (۶) محاسبه می‌گردد [۲۷].

$$\text{Energy}(VM_j) = (Et_j \times \beta_j + (MK - Et_j) \times \alpha_j) \times s_j \quad (6)$$

که در رابطه (۶)،  $\beta_j$  انرژی مصرف شده توسط ماشین مجازی در حالت فعال برای پردازش هر میلیون دستورالعمل (MI) که با واحد ژول است. انرژی مصرف شده در سیستم محاسبات مه برابر حاصل جمع انرژی مصرف شده توسط ماشین‌های مجازی است.  $\beta_j$  و  $\alpha_j$  به ترتیب در رابطه‌های (۷) و (۸) تعریف می‌شوند.

$$\beta_j = 10^{-8} \times (S_j^2) \quad (7)$$

$$\alpha_j = 0.6 \times \beta_j \quad (8)$$

در رایانش مه، انرژی مصرف شده نهایی برابر با مجموع انرژی مصرف شده تمام ماشین‌های مجازی می‌باشد که در رابطه (۹) تعریف می‌شود.

$$\text{Total\_energy} = \sum_{j=1}^n \text{Energy}(VM_j) \quad (9)$$

### ۳-۳- هزینه

هزینه، یک پارامتر بسیار مهم در رایانش مه می‌باشد. با توجه به ساختار ناهمگن ماشین‌های مجازی، هزینه وابسته به ظرفیت آن‌ها می‌باشد. هزینه وظایف پردازش شده بر روی ماشین‌های مجازی در رابطه (۱۰) تعریف شده است.

$$\text{Total\_cost} = \sum_{j=1}^n \text{cost}_j \times Et_j \quad (10)$$

### ۴- زمان‌بندی وظایف در رایانش مه

همان‌طور که قبلاً توضیح داده شد ساختار رایانش مه مابین ابر و کاربرهای انتهایی قرار می‌گیرد، درحالی‌که اطلاعات فقط در صورت لزوم به ابر ارسال می‌شود [۳۲]. یک محیط رایانش مه، می‌تواند با سه پارامتر

Learning Automata Task Scheduling Fog Computing (LaTSF)

Algorithm LaTSF

```

{
  IF There is no tasks or capacity for processing Then Terminate the LaTSF
  Else
  {
    For all Tasks
    {
      Ti = Random select one of the tasks based in APV
      IF (Requirements for Ti < Resources in Fog)
      And
      (The predicted time for Ti is the shortest of all tasks)
      Then
      {
        Reward the chose Task Ti in APV
        Penalize the other Tasks in APV
        A1f ← A1f - {The action corresponding to the task Ti}
        Minus Resources of tasks Ti from Fog system
        Assignment Resource to task Ti
        Resources required to run the task are deducted from the fog system
        Exec task Ti
        Remove Resources of task Ti and add to fog system
        APV ← APV - {Probability of action related to the task Ti}
        Update APV
      }
    }
  }
  Else
  {
    Penalize the chosen Task Ti in APV
    Reward the other tasks in APV
  }
}

```

شکل (۴): الگوریتم پیشنهادی مبتنی بر اتوماتای یادگیر برای زمان بندی وظایف در رایانش مه (LaTSF).

## ۶- شبیه سازی و نتایج الگوریتم پیشنهادی


در این بخش نتایج به دست آمده از شبیه سازی و مقایسه الگوریتم پیشنهادی با چندین الگوریتم شناخته شده ارائه می شود. الگوریتم پیشنهادی با استفاده از کتابخانه cloudsim مبتنی بر جاوا پیاده سازی شده است. سیستم کامپیوتری که برای شبیه سازی استفاده شده دارای مشخصات مقابل است.

Intel® Core™ i5 CPU@2.67GHZ,3GB of RAM, in Windows 7 Ultimate.

در این مرحله ۱۰ ماشین مجازی با ظرفیت پردازش در محدوده [۱۰۰۰، ۱۰۰۰۰] به طور تصادفی ایجاد کردیم، طول کلیه وظایف نیز ۵۰۰ می باشد. ماشین های مجازی به دو گروه تقسیم شده است: در گروه اول، ماشین هایی که دارای سرعت پردازش ۱۰۰۰ MIPS با هزینه ۱۰۰ واحد در زمان و گروه دوم دارای سرعت پردازش MIPS ۲۰۰۰ با هزینه ۱۵۰ واحد در زمان هستند. ما الگوریتم پیشنهادی را برای تست عملکرد با هفت الگوریتم دیگر مقایسه کردیم. میانگین زمان اتمام کار برای ۵۰۰ وظیفه برای اجرا بر روی ماشین های مجازی با طول (ظرفیت پردازشی) متفاوت در شکل (۵) نمایش داده شده است. همان طور که در شکل (۵) دیده می شود با افزایش طول ماشین مجازی مقدار زمان اتمام کار کاهش می یابد. این نتایج نشان می دهد که LaTSF در مقایسه با الگوریتم های دیگر موفق به کسب مقدار MK پایین تری شده است.

$$P_{Tf} = \{ p_{sf}^i \mid \forall i \in \{1, 2, \dots, N_m\} \} \quad (11)$$

نحوه ارتباط بین زمان بند و اتوماتا در شکل (۳) نمایش داده شده است.



شکل (۳) ارتباط بین زمان بند و اتوماتای یادگیر

در ابتدا تمامی عملکردها با یک احتمال یکسان انتخاب می شوند که به این معنی می باشد که تمامی وظایف شانس یکسانی برای دسترسی به سیستم دارند. با توجه به بردار احتمال مربوط به اتوماتون  $A_{Tf}$  در هر مرحله یکی از اعمال  $\alpha_{su}^i$  انتخاب می شود. در ابتدا بررسی می شود که اگر وظیفه ای برای اجرا وجود ندارد الگوریتم خاتمه پیدا می کند. در غیر این صورت بررسی می شود که منابع مورد نیاز برای اجرای وظیفه  $T_i$  از منابع موجود سیستم کوچک تر بوده و همچنین زمان پیشنهادی برای اجرای وظیفه  $T_i$  در بین همه وظایف موجود نیز کوچک ترین باشد. در صورتی که این دو شرط برقرار باشد به وظیفه  $T_i$  پاداش داده می شود و سایر وظایف را جریمه می کنیم و پس از آن بردار احتمال را به روزرسانی می کنیم که در رابطه (۱۲) نشان داده شده است.

$$\text{If } ((\text{Resource requirement for } T_i < \text{Resources in Fog}) \ \&\& \ (\text{Predicted time for } T_i \text{ is the shortest of all tasks})) \quad (12)$$

همچنین اگر شروط فوق برقرار نباشد یعنی منابع کافی برای اجرای وظیفه  $T_i$  وجود نداشته باشد و همچنین زمان پیشنهادی برای  $T_i$  از بقیه وظایف کوچک تر نباشد آنگاه وظیفه  $T_i$  را جریمه کرده و سایر وظایف را پاداش می دهیم و دوباره بردار احتمال را به روزرسانی می کنیم. لازم به ذکر است هر وظیفه  $T_i$  که در نهایت برای اختصاص یافتن روی رئوس مه انتخاب شود از مجموعه اعمال اتوماتا حذف می گردد که در رابطه (۱۳) نشان داده شده است.


$$A_{Tf} \leftarrow A_{Tf} - \{ \text{The action corresponding to the task } T_i \} \quad (13)$$

به همین ترتیب، اتوماتا  $A_{Tf}$  به طور تصادفی یکی از اعمال را پس از به روزرسانی بردار احتمال انتخاب می کند و این الگوریتم دوباره تکرار می شود. لازم به ذکر است پیچیدگی الگوریتم پیشنهادی  $O(M \times \text{Max\_iteration})$  است. بیشترین تکرار الگوریتم می باشد. الگوریتم پیشنهادی یادگیری اتوماتا جهت زمان بندی وظایف در رایانش مه (LaTSF<sup>1</sup>) در شکل (۴) نمایش داده شده است.

<sup>1</sup> Learning Automata Task Scheduling Fog Computing


## ۷- ساختار مدل پیشنهادی شبکه عصبی

همان طور که در فصل های قبلی توضیح داده شده، در این مقاله با استفاده از اتوماتای یادگیر زمان بندی وظایف در محیط مه با رویکرد کاهش مصرف انرژی، زمان اتمام کار، انرژی و هزینه بررسی شده است. سپس یک شبکه عصبی به عنوان مدل هوش مصنوعی بر اساس اتوماتای یادگیر در محیط مه ارائه شده است. مدل شبکه عصبی ارائه شده توانایی پیش بینی ارتباط بین پارامترهای زمان اتمام کار، انرژی و هزینه را بر اساس تعداد ماشین های مجازی دارد. شبکه عصبی مصنوعی پیشرو یک ابزار مناسب برای مدل سازی، پیش بینی و تخمین در کاربردهای مختلف می باشد. یک شبکه عصبی چندلایه پرسپترون (MLP) به منظور مدل سازی پارامترهای الگوریتم یادگیری اتوماتای آگاه از انرژی در کاربردهای اینترنت اشیا و رایانش مه بکار رفته است. در این مدل ماشین های مجازی به عنوان پارامتر ورودی و سه پارامتر انرژی، زمان اتمام کار و هزینه به عنوان پارامترهای خروجی شبکه در نظر گرفته شده اند. مدل شبکه عصبی پیشنهادی در شکل (۸) نشان داده شده است.




شکل (۸): ساختار مدل شبکه عصبی پیشنهادی.

شکل (۹) ساختار شبکه MLP پیشنهادی را بر اساس شبکه عصبی تعریف شده نمایش می دهد. همان طور که در شکل مشخص شده است، پارامترهای ورودی به وسیله یک لایه مخفی مشتمل بر ۵ نرون به گره های خروجی متصل شده است. چندین ساختار مختلف از شبکه های عصبی با تعداد نرون های متفاوت آزمایش گردیدند که در این بین ساختار پیشنهادی بهترین ساختار را داشت.




شکل (۹): ساختار شبکه MLP پیشنهادی.

در مدل شبکه عصبی پیشنهادی ۸۰٪ از داده ها برای آموزش و ۲۰٪ مابقی برای فرایند تست بکار رفته است. در مدل شبکه عصبی




شکل (۵): مقایسه میانگین زمان اتمام کار برای ۵۰۰ وظیفه با طول ماشین های مجازی متفاوت.

در شکل (۶) مقایسه انرژی نهایی برای ۵۰۰ وظیفه با طول ماشین های مجازی متفاوت نشان داده شده است. فعالیت ماشین های مجازی مصرف انرژی را افزایش می دهد. همچنین همان طور که در شکل (۶) دیده می شود الگوریتم پیشنهادی LaTSF کمترین مصرف انرژی را در بین الگوریتم های پیشنهادی دیگر دارد.



شکل (۶): مقایسه انرژی نهایی برای ۵۰۰ وظیفه با طول ماشین های مجازی متفاوت.

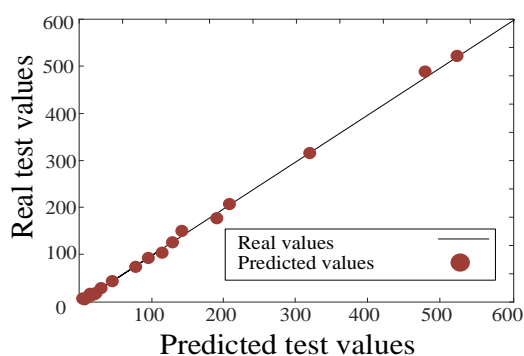
در شکل (۷) مقایسه میانگین هزینه برای ۵۰۰ وظیفه با طول ماشین های مجازی متفاوت نشان داده شده است. همان طور که شکل (۷) دیده می شود هزینه ماشین های مجازی برای اجرای الگوریتم پیشنهادی در مقایسه با الگوریتم های دیگر بسیار کاهش یافته است.




شکل (۷): مقایسه میانگین هزینه برای ۵۰۰ وظیفه با طول ماشین های مجازی متفاوت.

در فصل بعدی یک مدل شبکه عصبی برای پیش بینی پارامترهای انرژی، زمان بندی وظایف و هزینه ارائه شده است. این مدل بر اساس الگوریتم پیشنهادی یادگیری اتوماتا جهت زمان بندی وظایف در رایانش مه (LaTSF) بیان شده است.

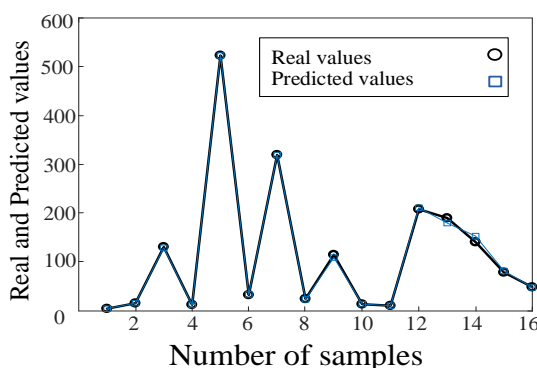




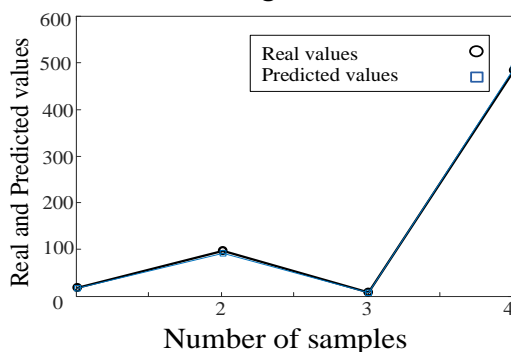
(الف)



(ب)



(ج)



(د)

شکل (۱۱) مقایسه مقادیر حقیقی و پیش‌بینی شده زمان اتمام کار با استفاده از مدل پیشنهادی برای (الف) فرایند آموزش و (ب) فرایند تست. مقادیر حقیقی و پیش‌بینی شده زمان اتمام کار با استفاده از مدل پیشنهادی برای (ج) فرایند آموزش و (د) فرایند تست بر حسب شماره نمونه‌ها

پیشنهادی خطای MRE به صورت رابطه (۱۴) نشان داده است جهت ارزیابی نتایج مدل در نظر گرفته شده است.

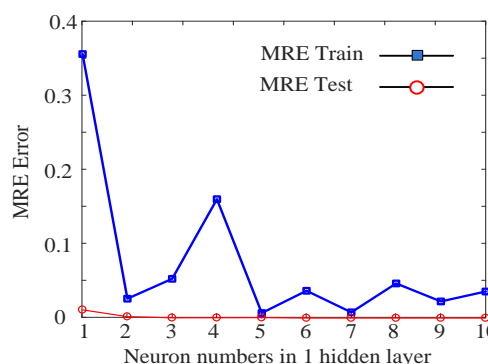
$$MRE = \frac{1}{N} \sum_{i=1}^N \left| \frac{Y_{Ri} - Y_{Pi}}{Y_{Ri}} \right| \quad (14)$$

که در رابطه (۱۴)، N نشان دهنده تعداد کل داده‌ها و  $Y_{Pi}$  و  $Y_{Ri}$  به ترتیب نشان دهنده مقادیر واقعی و مقادیر پیش‌بینی شده مدل شبکه عصبی می‌باشند.

### ۷-۱ یافتن بهترین ساختار برای مدل شبکه عصبی

#### پیشنهادی


همان‌طور که توضیح داده شد چندین ساختار با تعداد نرون‌های مختلف برای مدل پیشنهادی آزمایش گردید شکل (۱۰) خطای نرمالیزه شده MRE را برای مقادیر پیش‌بینی شده در فرایندهای تست و آموزش بر حسب تعداد نرون‌های مختلف در یک لایه پنهان را نمایش می‌دهد. با توجه به مقادیر خطای بدست آمده در شکل (۱۰) شبکه‌ی پیشنهادی با مشخصات تعداد پنج نرون با یک لایه‌ی پنهان دارای پایین‌ترین خطای بدست آمده است. همچنین با توجه به خطای پایین بدست آمده در نظر گرفتن تعداد لایه‌های بیشتر برای شبکه که موجب پیچیدگی بیش‌ازحد آن نیز می‌شود لزومی ندارد.



شکل (۱۰) خطای نرمالیزه شده MRE را برای مقادیر پیش‌بینی شده در فرایندهای تست و آموزش بر حسب تعداد نرون‌های مختلف.

### ۸- نتایج مدل شبکه عصبی پیشنهادی


همان‌طور که در فصل قبل توضیح داده شد ساختار مدل پیشنهادی با یک لایه پنهان و پنج نرون در لایه پنهان به‌عنوان دقیق‌ترین مدل انتخاب شد. مقادیر حقیقی و پیش‌بینی شده زمان اتمام کار با استفاده از مدل پیشنهادی در شکل (۱۱) مقایسه شده است. در شکل (۱۱) قسمت (ج) و (د) محورهای افقی نشان دهنده‌ی شماره‌ی نمونه‌ای است که به‌صورت تصادفی از داده‌های آموزش و تست در نظر گرفته شده و همچنین محور عمودی بیانگر مقدار آن نمونه است که مقادیر واقعی و پیش‌بینی شده در این شکل نمایش داده شده است.



(د)


شکل (۱۲) مقایسه مقادیر حقیقی و پیش‌بینی شده پارامتر انرژی با استفاده از مدل پیشنهادی برای (الف) فرایند آموزش و (ب) فرایند تست. مقایسه مقادیر حقیقی و پیش‌بینی شده پارامتر هزینه با استفاده از مدل پیشنهادی برای (ج) فرایند آموزش و (د) فرایند تست. در این شکل مقادیر انرژی باید در ۱۰۰۰ ضرب شوند.

مقادیر حقیقی و پیش‌بینی شده فرایند آموزش و تست مدل پیشنهادی برای پارامترهای انرژی و هزینه در شکل (۱۲) نمایش داده شده‌اند. همان‌طور که مشاهده می‌شود پارامترهای انرژی و هزینه با دقت بالایی پیش‌بینی شده‌اند.

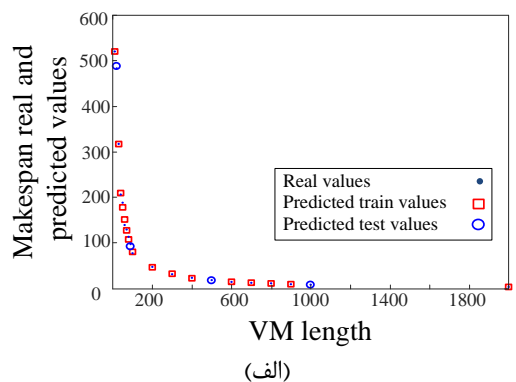


(الف)

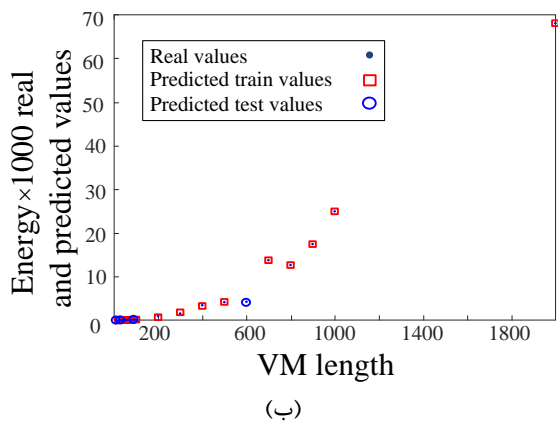
مقادیر واقعی و پیش‌بینی شده خروجی مدل پیشنهادی برای پارامترهای زمان اتمام کار، انرژی و هزینه بر حسب تعداد ماشین‌های مجازی در شکل (۱۳) نمایش داده شده است.



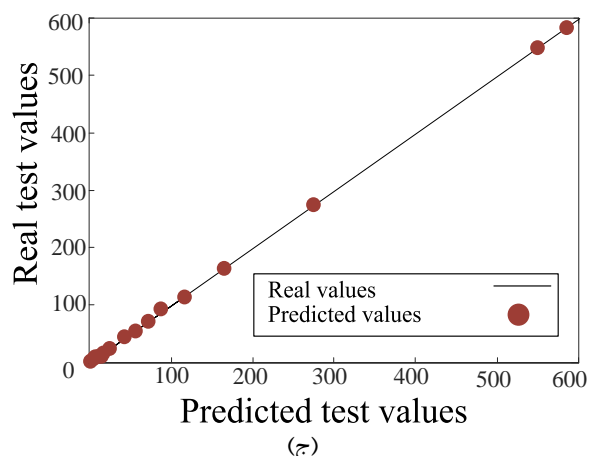
(ب)



(الف)



(ب)



(ج)

جدول (۲) نتایج نهایی مدل شبکه عصبی پیشنهادی

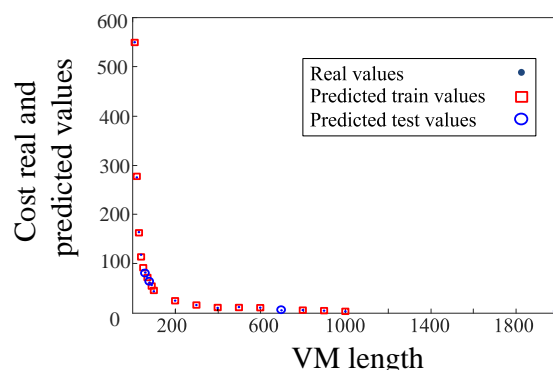
مقدار خطای هزینه	مقادیر خطای انرژی		مقادیر خطای زمان اتمام کار	
	Test	Train	Test	Train
MRE	0.04	0.02	0.84	0.16
	0.19	0.02		

## ۹- نتیجه گیری

در این مقاله، مسئله ی زمان بندی در محیط مه به جهت کاهش مصرف انرژی، بهبود زمان اتمام کار و کاهش هزینه با استفاده از اتوماتای یادگیر بررسی شد. همچنین یک شبکه عصبی چندلایه به منظور پیش بینی پارامترهای اتوماتای یادگیر به صورت آگاه از انرژی ارائه شده که توانایی تخمین و پیش بینی پارامترهای مطلوب را با دقت بالایی دارا می باشد. برای انتخاب بهترین ساختار شبکه عصبی تعداد نرون های متفاوتی برای شبکه بررسی شد و هر شبکه به ازای هر نرون مختلف ۲۰۰ بار اجرا گردید. بهترین مقادیر خطا از بهترین ساختار برای شبکه عصبی در نظر گرفته شد. نتایج نشان داد که تمامی پارامترهای مورد نظر با دقت بسیار بالایی توسط شبکه عصبی پیشنهادی پیش بینی گردیدند. در مدل ارائه شده خطای آموزش و آزمون برای پارامتر زمان اتمام کار به ترتیب ۰.۰۲ و ۰.۰۴ بدست آمد، برای پارامتر انرژی به ترتیب ۰.۱۶ و ۰.۸۴ بدست آمد و برای پارامتر هزینه به ترتیب ۰.۰۲ و ۰.۱۹ بدست آمد.

## مراجع

- [1] Nguyen, B.M., Thi Thanh Binh, H., Do Son, B. "Evolutionary algorithms to optimize task scheduling problem for the IoT based bag-of-tasks application in cloud-fog computing environment", Applied Sciences, Vol. 9, No. 9, pp. 1730. Jan. 2019.
- [2] Ghasempour, A. "Internet of things in smart grid: Architecture, applications, services, key technologies, and challenges", Inventions, Vol.4, No. 1, pp. 22, Mar 2019.
- [3] Gupta, H., Dastjerdi, S., Ghosh, K., Buyya, R., "iFogSim: a toolkit for modeling and simulation of resource management techniques in internet of things, edge and fog computing environments", Software: Practice and Experience, Vol. 47, No. 7, pp. 1275-1296. 2017.
- [4] Multag, A.A., et al., "Enabling technologies for fog computing in healthcare IoT systems", Future Generation Computer Systems, Vol. 90, pp. 62-78. 2019.
- [5] Rahmani, A.M., et al., "Exploiting smart e-health gateway at the edge of healthcare internet-of-things a fog computing approach", Future Generation Computer System, Vol. 78, No. 3, pp. 641-658, Feb. 2017.
- [6] Pham X.Q., and Huh, E.N., "Towards task scheduling in a cloud- fog computing system", in 18th IEEE Asia-Pacific network operations and management symposium (APNOMS), 2016.
- [7] Tran, M.Q., et al., "Task placement on fog computing made efficient for IoT application provision", Wireless Communications and Mode Computing. Vol. 2019., 2019.



(ج)

شکل (۱۳) مقادیر واقعی و پیش بینی شده خروجی مدل پیشنهادی برای پارامترهای (اف) زمان اتمام کار، (ب) انرژی و (ج) هزینه بر حسب تعداد ماشین های مجازی.

مقادیر پیش بینی شده و واقعی در فرایندهای تست و آموزش خروجی مدل پیشنهادی در جدول (۱) لیست شده اند. همان طور که در جدول مشخص شده است مقادیر پیش بینی شده از دقت بالایی برخوردار هستند، همچنین نتایج نهایی مدل شبکه عصبی پیشنهادی در جدول (۲) آورده شده است. لازم به ذکر است که به منظور آموزش بهتر شبکه ی عصبی ارائه شده، در ابتدا برای آموزش شبکه، داده ها نرمالیزه شدند و سپس بعد از آموزش شبکه به منظور مقایسه ساده تر مقادیر پیش بینی شده با مقادیر واقعی، داده ها دی نرمالیزه شدند. مقادیر خطای نمایش داده شده در جدول (۲) بر اساس داده های دی نرمالیزه شده محاسبه شده است. داده های تست و آموزش به صورت تصادفی از میان داده های اصلی انتخاب شده اند. بر اساس نتایج حاصله در جدول (۲) مدل پیشنهادی به صورت ایده آلی بر اساس داده های استفاده شده آموزش دیده شده است.

جدول (۱) مقادیر پیش بینی شده و واقعی در فرایندهای تست و آموزش

خروجی مدل پیشنهادی

مقدار پیش بینی شده هزینه	مقدار واقعی هزینه	مقدار پیش بینی شده انرژی	مقدار واقعی انرژی	مقدار پیش بینی شده زمان اتمام کار	مقدار واقعی زمان اتمام کار
<b>مقادیر آموزش زمان اتمام کار، انرژی و هزینه</b>					
1	4	3.9975	1.6000	1.8758	11.3000
2	15	15.3173	68.1000	68.1001	5.7000
3	130	128.2649	0.0830	0.0878	73.0000
4	12	11.6531	0.0260	0.0391	119.0000
5	521	521.0230	0.1800	0.1550	276.0000
6	32	33.0170	4.2000	4.2554	165.0000
7	318	317.7680	1.0300	0.7497	25.7897
8	24	23.0958	13.8000	13.7996	6.8000
9	114	108.3104	12.7000	12.6990	4.3000
10	13	13.3721	0.1620	0.2130	550.0000
11	10	9.9870	0.0450	0.0698	88.1000
12	207	210.1366	3.5000	3.3302	13.0000
13	189	178.7513	17.5000	17.4988	45.0000
14	140	152.1584	25.0000	24.9994	17.1000
15	78	80.9593	0.0930	0.1079	11.8000
16	48	47.1377	0.0950	0.1302	57.8000
<b>مقادیر تست زمان اتمام کار، انرژی و هزینه</b>					
1	19	18.0451	0.0070	0.0261	83.0000
2	98	92.6705	4.3000	4.0788	62.8000
3	9	8.3225	0.1630	0.1825	6.4000
4	484	488.5159	0.0360	0.0536	2.5000

- [20] Tong, Z., Chen, H., Deng, X., Li, K., Li, K., "A scheduling scheme in the cloud computing environment using deep Q-learning", *Information Sciences*, 1; Vol. 512, pp. 1170-91, Feb 2020.
- [21] Wang, Y., Guo, C., Yu, J., "Immune scheduling network based method for task scheduling in decentralized fog computing", *Wireless Communications and Mobile Computing*. Vol. 2018. Jan 2018.
- [22] Kennedy, J., "Practice Swarm Optimization", *Encyclopedia of machine learning Springer*, Vol. 10: pp. 760-766, 2010.
- [23] Mirjalili, S., Mirjalili, S.M., and Lewis, A., "Grey Wolf Optimizer", *Advances in engineering software*, Vol. 69, pp. 46-61, 2014.
- [24] Yang, X.S. "Flower Pollination algorithm for global optimization", In *Springer International Conference on unconventional computing and natural computation*. 2012.
- [25] Mirjalili, S., Mirjalili, S.M., and Hamilton, A., "Multi-verse Optimizer: A Natural-inspired algorithm for global optimization", *Neural Computing and Applications*, Vol. 27. No. 2, pp. 495-513, 2016.
- [26] Mirjalili, S., and Lewis, A., "The Whale Optimization Algorithm", *Advances in engineering software*, Vol. 95, pp. 51-67, 2016.
- [27] Abdel-Basset, M., El-Shahat, D., Elhoseny, M., and Song, H., "Energy-Aware Metaheuristic algorithm for Industrial Internet of Things task scheduling problems in fog computing applications", *IEEE Internet of Things*, 2020.
- [28] Yang, X.S., "A new metaheuristic bat-inspired algorithm, in *Nature inspired cooperative strategies for optimization*", NISCO, Springer. pp. 65-74. 2010.
- [29] Narendra, K.S., Thathachar, K.S., *Learning Automata: An Introduction*. Prentice-Hall, New York, 1989.
- [30] Thathachar, M.A.L., Harita, B.R., "Learning automata with changing number of actions", *IEEE Trans. Syst. Man Cybern. SMG17*, Vol. 7, No. 6, pp. 1095-1100, 1987.
- [31] Wang, Y., Wang, K., Huang, H., Miyazaki, T., Guo, S., "Traffic and Computation co-offloading with reinforcement learning in fog computing for industrial applications", *IEEE Transactions on Industrial Informatics*, Vol. 15, No. 2, pp. 976-986, 2018.
- [32] Sopin, E., Samouylov, K., Shorgin, S., "The Analysis of the Computation Offloading Scheme with Two-Parameter Offloading Criterion in fog computing", *Internet and Distributed Computing System (IDCS2019) Springer, Lecture Notes in computer Science*, Vol. 11874, 2019.
- [33] Yeh, W.C., C.M. Lai and K.C., "Tseng. Fog computing task scheduling optimization based on multi-objective simplified swarm optimization", In *Journal of physics: Conference Series*, IOP Publishing, Vol. 1411, No. 1, 2019.
- [8] Rahbari, D., and Nikrahy, M., "Low latency and energy-efficient scheduling in fog-based IoT applications", *Turkish Journal and Electrical Engineering & Computer Sciences*, Vol. 27, No. 2, pp. 1406-1427, 2019.
- [9] Yang, X. and N. Rahmani, Task scheduling mechanisms in fog computing: review, trends, and perspectives. *Kybernetes*, Vol. 50, No. 1, pp. 22-38, 2020.
- [10] Teylo, L., de Paula, U., Frota, Y., de Oliveira, D. and Drummond, L.M., "A hybrid evolutionary algorithm for task scheduling and data assignment of data-intensive scientific workflows on clouds", *Future Generation Computer Systems*, 76, pp.1-17. 2017.
- [11] Roshani, S., Jamshidi, M.B., Mohebi, F., Roshani, S., "Design and Modeling of a Compact Power Divider with Squared Resonators Using Artificial Intelligence", *Wireless Personal Communications*, Vol. 117, No. 3, pp. 2085-2096, Apr 2021.
- [12] Jamshidi, M., et al. "Artificial intelligence and COVID-19: deep learning approaches for diagnosis and treatment", *IEEE Access*. Vol. 12, No. 8, pp. 109581-109595, Jun 2020.
- [13] Roshani, S., Roshani, S., "Two-Section Impedance Transformer Design and Modeling for Power Amplifier Applications", *Applied Computational Electromagnetics Society Journal*, Vol. 32, No. 11, pp. 1042-1047, Nov 2017.
- [14] Roshani, M., Phan, G.T., Ali, P.J.M., Roshani, G.H., Hanus, R., Duong, T., Corniani, E., Nazemi, E., Kalmoun, E.M., "Evaluation of flow pattern recognition and void fraction measurement in two phase flow independent of oil pipeline's scale layer thickness", *Alex. Eng. J. Vol. 60*, pp. 1955-1966, 2021.
- [15] Roshani, M., Phan, G., Roshani, G.H., Hanus, R., Nazemi, B., Corniani, E., Nazemi, E. Combination of X-ray tube and GMDH neural network as a nondestructive and potential technique for measuring characteristics of gas-oil-water three phase flows", *Measurement*, 168, pp. 108427, 2021.
- [16] Roshani, M., Phan, G., Faraj, R.H., Phan, N.H., Roshani, G.H., Nazemi, B., Corniani, E., Nazemi, E., "Proposing a gamma ra-diation based intelligent system for simultaneous analyzing and detecting type and amount of petroleum by-products", *Nucl. Eng. Technol. Vol. 53*, No. 4, pp.1277-1283 2020.
- [17] Roshani, M., Sattari, M.A., Ali, P.J.M., Roshani, G.H., Nazemi, B., Corniani, E., Nazemi, E., "Application of GMDH neural network technique to improve measuring precision of a simplified photon attenuation based two-phase flowmeter", *Flow Meas. Instrum*, Vol. 75, pp. 101804, 2020.
- [18] Sattari, M.A., Roshani, G.H., Hanus, R., Nazemi, E., "Applicability of time-domain feature extraction methods and artificial intelligence in two-phase flow meters based on gamma-ray absorption technique", *Measurement*, Vol. 168, pp. 108474, 2021.
- [19] Sharma, S., Saini, H., "A novel four-tier architecture for delay aware scheduling and load balancing in fog environment," *Sustainable Computing: Informatics and Systems*. Vo. 24, Dec 2019 .

