

A Hybrid Meta-Heuristic Clustering and Deep Transfer Learning Model for Cloud Energy Consumption Prediction

Habeeb Naji Atiyah¹, Behnam Barzegar^{2*}, Mohammadreza Soltanaghaei³, Hassan Falah Fakhroldeen⁴

1 - Department of Computer Engineering, Isf.C., Islamic Azad University, Isfahan, Iran

2* - Department of Computer Engineering, Bab.C., Islamic Azad University Babol, Iran

3- Department of Computer Engineering, Isf.C., Islamic Azad University, Isfahan, Iran

4- Computer Techniques Engineering Department, Faculty of Information Technology, Imam Ja'afar Al sadiq University, Baghdad, Iraq

Eng.habeebnaji@gmail.com¹, Behnam.barzegar@iaau.ac.ir^{2*}, Hassan.falah@ijsu.edu³, Soltan@iaau.ac.ir⁴

Corresponding author's address: Behnam Barzegar, Department of Computer Engineering, Islamic Azad University, Bab.C., Babol.

Abstract- Despite the popularity and availability of a wide range of cloud service providers, cloud computing faces challenges that need to be addressed. One of these challenges primarily includes the incredible energy consumption due to reasons such as the use of proper cooling systems, which is considered the biggest threat to the environment and its electricity consumption cost for cloud providers. Therefore, it is necessary to provide solutions to improve or predict energy consumption in cloud computing. Therefore, the aim of this paper is to present a hybrid approach based on optimized clustering and deep transfer learning for predicting energy load in cloud computing. The proposed method is tested on three Google Cluster datasets, European PV Load and IESO datasets and in total with five datasets, CPU usage from Google Cluster dataset; hourly load from the dataset and PV load (solar energy forecast) from the London dataset; Hourly load and consumption load price in Canadian dollars from the IESO dataset have been evaluated with MSE, RMSE, MAPE and MAE metrics. The results show that among the datasets, the Google Cluster dataset in the training data has performed very well and the errors have been at the lowest possible level (MSE = 0.0199, RMSE = 0.1411, MAPE = 0.4293 and MAE = 0.1195). In the test data, the error values also remain low and acceptable (MSE = 0.0356, RMSE = 0.1886, MAPE = 0.6460 and MAE = 0.1647), which indicates the high generalization ability of the model and increased prediction accuracy in complex and voluminous data.

Keywords- Clustering with Meta-Heuristic Algorithm, Deep Transfer Learning, Load Forecasting, Cloud Computing.

مدل خوشه‌بندی فرا ابتکاری و یادگیری انتقال عمیق ترکیبی برای پیش‌بینی مصرف انرژی در رایانش ابری

حبیب ناجی عطیه^۱، بهنام برزگر^{۲*}، محمدرضا سلطان آقایی^۳، حسن فلاح فخرالدین^۴

^۱ گروه علمی کامپیوتر، واحد خوراسگان، دانشگاه آزاد اسلامی، اصفهان، ایران

^{۲*} گروه علمی کامپیوتر، واحد بابل، دانشگاه آزاد اسلامی، بابل، ایران

^۳ گروه علمی کامپیوتر، واحد خوراسگان، دانشگاه آزاد اسلامی، اصفهان، ایران

^۴ گروه علمی کامپیوتر، واحد تکنولوژی، دانشگاه امام جعفر صادق، بغداد، عراق.

¹Eng.habeebnaji@gmail.com, ^{2*}Behnam.barzegar@iau.ac.ir, ³Soltan@iau.ac.ir, ⁴Hassan.falah@ijsu.edu

* نشانی نویسنده مسئول: بهنام برزگر، بابل، دانشگاه آزاد اسلامی واحد بابل، گروه مهندسی کامپیوتر.

چکیده- رایانش ابری علی‌رغم گسترش و محبوبیت روزافزون با چالش مصرف بالای انرژی در مراکز داده مواجه است که منجر به افزایش هزینه‌های عملیاتی و پیامدهای زیست محیطی می‌شود. از این رو، ارائه روش‌های دقیق برای پیش‌بینی بار مصرف انرژی در این محیط‌ها امری ضروری است. در این مقاله، یک رویکرد ترکیبی مبتنی بر خوشه‌بندی بهینه‌شده و یادگیری عمیق انتقالی برای پیش‌بینی بار مصرف انرژی در رایانش ابری ارائه می‌شود. روش پیشنهادی بر روی مجموعه داده‌های متنوع شامل مجموعه داده Google Cluster، داده‌های بار مصرفی و پیش‌بینی انرژی خورشیدی (PV) شهر لندن، و داده‌های بار ساعتی و قیمت برق مجموعه داده IESO ارزیابی شده است. در مجموع، پنج سناریوی داده‌ای شامل استفاده از CPU، بار ساعتی و انرژی خورشیدی مورد بررسی قرار گرفته‌اند. عملکرد مدل با استفاده از معیارهای MAE، RMSE، MAPE و نتایج نشان می‌دهد که مدل پیشنهادی در مجموعه داده Google Cluster به دقت بالایی دست یافته است، به گونه‌ای که در داده‌های آموزشی مقادیر خطا برابر با (MSE برابر ۰.۰۱۹۹، RMSE برابر ۰.۱۴۱۱، MAPE برابر ۰.۴۲۹۳ و MAE برابر ۰.۱۱۹۵) و در داده‌های آزمایشی برابر با (MSE برابر ۰.۰۳۵۶، RMSE برابر ۰.۱۸۸۶، MAPE برابر ۰.۶۴۶۰ و MAE برابر ۰.۱۶۴۷) به دست آمده است. این نتایج بیانگر توانایی تعمیم‌پذیری مناسب و کارایی بالای مدل در داده‌های حجیم و پیچیده می‌باشد.

واژه‌های کلیدی: خوشه‌بندی با الگوریتم فراابتکاری، یادگیری عمیق انتقالی، پیش‌بینی بار مصرفی، رایانش ابری

۱- مقدمه

ارائه می‌دهد [۳]. طبق تعریف رسمی NIST، رایانش ابری مدلی برای امکان دسترسی به شبکه در زمان و مکان، راحت و بر اساس تقاضا به یک مجموعه مشترک از منابع محاسباتی قابل تنظیم است که می‌تواند به سرعت با کمترین تلاش مدیریتی یا تعامل با ارائه دهنده خدمات مهیا شود [۴] و از چندین فناوری مانند ارائه خدمات، اینترنت، مجازی‌سازی، خدمات وب و غیره تشکیل شده است [۵]

رایانش ابری به سرعت در حال تبدیل شدن به یک سرویس مهم در محاسبات اینترنتی است [۱] که برای به دست آوردن خدمات میزبانی شده در اینترنت، به کار می‌رود [۲] و محصولات و خدمات را به هر کسی در هر نقطه از جهان که دارای اتصال به اینترنت است،

مصرف برق $1/2$ MV، می‌پردازد که برای مصرف برق حدود ۱۲۰۰ خانه استفاده می‌شود. اگر انرژی و مصرف برق مرکز داده کاهش یابد، نه تنها به نفع گرمایش جهانی بلکه از نظر اقتصادی نیز خواهد بود و این کمک بزرگی به پایداری محیط زیست خواهد بود. طبق برآورد Amazon.com و مراکز داده آنها، کل هزینه عملیات سرورها حدود ۵۳٪ از کل بودجه است و هزینه مربوط به انرژی ۴۲٪ از هزینه کل است. این هزینه مصرف انرژی شامل توان مورد نیاز برای کار سیستم‌ها و همچنین کل زیرساخت‌های خنک کننده می‌باشد [۱۲].

- با بیان مطالب فوق چالش اصلی در رایانش ابری و مودری که این پژوهش با آن روبه رو است، مصرفی انرژی می‌باشد زیرا:
۱. مرکز داده از صدها یا هزاران گره تشکیل شده است بنابراین مقدار زیادی برق مصرف می‌کند [۱۰].
 ۲. مراکز داده برای عملکرد صحیح به سیستم‌های خنک کننده مناسب نیاز دارند که منجر به افزایش هزینه‌ها و برق مصرفی می‌شود.
 ۳. مراکز داده ابری باید برای حفظ اطلاعات مشتریان خود انرژی زیادی را مصرف می‌کنند.
 ۴. برای افزایش کارایی ذخیره سازی و تجزیه و تحلیل داده‌های مشتری، ارائه دهندگان ابر نیاز به مصرف انرژی و برق دارند.
 ۵. مصرف انرژی و برق به عنوان بزرگترین تهدید برای محیط زیست محسوب می‌شود.
 ۶. هزینه مصرف انرژی برای ارائه دهندگان ابر چالش برانگیز شده است [۷].

بنابراین، بررسی عمیق مشکل و شناسایی علل احتمالی، فرصت‌ها و راه حل‌های مناسب برای صرفه جویی در انرژی و بهبود عملکرد مهم و ارائه راهکارهایی برای بهبود یا پیش‌بینی مصرف انرژی در رایانش ابری ضروری است، از راهکارهای در دنیای امروز مدل‌های یادگیری ماشین و یادگیری عمیق است که به طور گسترده برای بهینه‌سازی بهره‌وری انرژی، تبدیل، توزیع و کربن‌زدایی در شبکه‌های هوشمند مورد استفاده قرار گرفته‌اند که پتانسیل رویکردهای مبتنی بر داده را در این زمینه نشان می‌دهد [۱۳] و همچنین امکان پیش‌بینی دقیق تقاضای منابع انرژی را فراهم می‌کند و باید قادر به پیش‌بینی دقیق و قابل استفاده باشند [۱۴]. مدل‌های یادگیری ماشین، به‌ویژه یادگیری عمیق، پیشرفت‌های قابل‌توجهی در پیش‌بینی بار کوتاه‌مدت (STLF) نشان داده‌اند و تقاضا را از یک ساعت تا ۲۴ ساعت قبل با دقت بالا پیش‌بینی می‌کنند [۱۵].

در نهایت این پژوهش در جهت کاهش و پیش‌بینی مصرف انرژی

به عنوان روشی کم هزینه برای ذخیره سازی و توزیع نرم‌افزار اهمیت پیدا می‌کند که ابر ممکن است به عنوان شبکه‌ای از گره‌های سمت سرور تعریف شود [۶]. با وجود موفقیت اولیه، محبوبیت و در دسترس پذیر بودن گستره‌ای از فراهم‌کننده‌های سرویس‌های ابری، رایانش ابری با چالش‌هایی مواجه است که باید برطرف شود، که در درجه اول شامل مصرف انرژی که به عنوان بزرگترین تهدید برای محیط زیست و هزینه آن برای ارائه دهندگان ابر می‌باشد. انرژی مورد نیاز مراکز داده به طرح فیزیکی آن بستگی دارد و می‌تواند از چند کیلووات انرژی تا ده‌ها مگاوات یا بیشتر متغیر باشد. بهره‌وری انرژی مرکز داده را می‌توان به عنوان اثربخشی مصرف توان (PUE) اندازه گیری کرد، که نسبت کل توان ورودی تقسیم بر کل توان مصرف شده توسط منابع فیزیکی است. مشکل انرژی مصرف‌شده در الگوی ابری نه تنها چالش‌های افزایش هزینه‌ای را برای ارائه‌دهندگان خدمات ایجاد می‌کند، بلکه باعث ایجاد خطرات بهداشتی برای محیط‌زیست می‌شود که یکی از نگرانی‌های اصلی در عصر فناوری امروز است [۷]. مصرف انرژی یکی از موضوعات ضروری سیستم‌های مبتنی بر آن است. مصرف انرژی پس از بحران انرژی در دهه ۱۹۷۰ مورد توجه قرار گرفت. همچنین نشان داده شده است که مصرف انرژی در سراسر جهان به سرعت در حال افزایش است [۸]. در نتیجه مصرف باورنکردنی انرژی در رایانش ابری یکی از چالش بزرگ در این فناوری می‌باشد [۹]. پس به دلیل افزایش کاربران و خدمات و محاسبات در مقیاس، روند افزایشی در مصرف انرژی در مراکز داده ابر فعلی قابل مشاهده است. چنین افزایشی در مصرف انرژی و سطح مورد انتظار عملکرد خدمات مطمئناً بر پایداری محیطی (۳٪ گازهای گلخانه‌ای)، هزینه‌های پولی کاربر و اقتصاد ابر تأثیر می‌گذارد. چون مرکز داده از صدها یا هزاران گره تشکیل شده است بنابراین مقدار زیادی برق مصرف می‌کند [۱۰]. همچنین مراکز داده برای عملکرد صحیح به سیستم‌های خنک کننده مناسب نیاز دارند که منجر به افزایش هزینه‌ها و برق مصرفی می‌شود [۶]. همچنین مقدار زیادی از انتشار CO2 و گازهای گلخانه‌ای منتشر می‌کند که محیط زیست را آلوده می‌کند. افزایش تقاضای انرژی و متعاقباً هزینه‌ها هر چند وقت یکبار قطعاً بر اقتصاد و درآمد ارائه دهندگان خدمات تأثیر می‌گذارد [۱۰] و ویژگی‌های بار برق نیز با تغییرات فصلی، تغییرات آب و هوا، روزهای مشخص، مناطق مصرف برق و سایر عوامل تغییر می‌کند، برخی از بارها در مدت زمان کوتاهی به شدت نوسان می‌کنند [۱۱]. در نهایت مصرف انرژی مراکز داده واقع در سراسر جهان به عنوان ۱٫۴٪ از کل EEC (مصرف انرژی الکتریکی) محاسبه شده است و هر ساله با نرخ ۱۲٪ در حال رشد است. یک مرکز داده واقع در بارسلونا حدود ۱ میلیون پوند برای

پیش از اعمال مدل پیشنهادی، تمامی داده‌ها نرمال‌سازی شده و سپس با استفاده از روش تجزیه و تحلیل حالت تجربی و تبدیل موجک گسسته پیش‌پردازش شده‌اند. داده‌ها به دو بخش آموزش و آزمون تقسیم شده‌اند، به‌طوری‌که ۷۰٪ داده‌ها برای آموزش و ۳۰٪ برای آزمون در نظر گرفته شده است. تمامی شبیه‌سازی‌ها در محیط متلب انجام شده‌اند.

نوآوری اصلی این مقاله در ارائه یک چارچوب ترکیبی جدید برای پیش‌بینی بار کاری و مصرف انرژی در محیط‌های رایانش ابری نهفته است. برخلاف مطالعات پیشین، در این پژوهش برای نخستین بار ترکیب تجزیه و تحلیل حالت تجربی، تبدیل موجک گسسته، خوشه‌بندی مبتنی بر الگوریتم مگس میوه، انتخاب خوشه بهینه مبتنی بر آزمون آنوا و یادگیری عمیق انتقالی به‌صورت یکپارچه مورد استفاده قرار گرفته است. در روش پیشنهادی، سیگنال بار کاری CPU ابتدا به توابع حالت ذاتی (IMF) تجزیه شده و سپس هر IMF به زیرسیگنال‌های تقریبی و جزئی تفکیک می‌شود. به‌منظور استخراج بهتر الگوهای پنهان و کاهش پیچیدگی داده‌ها، یک مرحله خوشه‌بندی نوآورانه مبتنی بر الگوریتم مگس میوه برای گروه‌بندی IMF‌های مشابه معرفی شده است. شایان ذکر است که الگوریتم مگس میوه تاکنون برای خوشه‌بندی IMF‌ها در مسئله پیش‌بینی بار کاری و انرژی در رایانش ابری به کار گرفته نشده است. این چارچوب ترکیبی منجر به افزایش دقت پیش‌بینی، بهبود پایداری مدل و افزایش قابلیت تعمیم‌پذیری در داده‌های حجیم و پیچیده شده است.

این مقاله شامل پنج بخش می‌باشد. بخش اول، مقدمه‌ای بر چالش رایانش ابری و پیش‌بینی مصرف انرژی در رایانش ابری را دربرمی‌گیرد. بخش دوم مروری بر مطالعات در این حوزه پرداخته شده است. بخش سوم، مراحل و الگوریتم‌های مورد نیاز روش پیشنهادی که ارائه رویکردی ترکیبی مبتنی بر خوشه‌بندی بهینه شده و یادگیری عمیق انتقالی برای پیش‌بینی بار مصرفی انرژی در رایانش ابری می‌باشد، ارائه شده است. بخش چهارم به پیاده‌سازی روش پیشنهادی، ارزیابی عملکرد آن و نتایج حاصل از آزمایشات و مقایسه آن‌ها با روش‌های موجود تحلیل می‌شود. در نهایت، بخش پنجم شامل است.

۲- کارهای مرتبط

براساس موضوع پژوهش کارهای مشابه انجام شده، در مقاله [۴] به رویکردهای یادگیری ماشین برای استفاده کارآمد از انرژی در مراکز داده ابری پرداخته که به اهمیت رو به رشد و ماهیت انرژی بر مراکز داده می‌پردازد و بیان می‌کند رویکردهای یادگیری ماشین با در نظر

بار مصرفی در رایانش ابری است و هدف از آن ارائه رویکردی ترکیبی مبتنی بر خوشه‌بندی بهینه شده و یادگیری عمیق انتقالی برای پیش‌بینی بار مصرفی انرژی در رایانش ابری می‌باشد. بنابراین مشارکت‌های اصلی این مقاله به شرح زیر است:

۱- خوشه‌بندی بهینه با الگوریتم مگس میوه: در این پژوهش از الگوریتم فراابتکاری مگس میوه برای خوشه‌بندی داده‌ها استفاده می‌شود تا سیگنال‌های مشابه در خوشه‌های همگن قرار گیرند و ویژگی‌های مؤثر برای مدل یادگیری عمیق استخراج شوند.

۲- ارائه یادگیری عمیق انتقالی برای پیش‌بینی بار مصرفی انرژی: روش مبتنی بر یادگیری عمیق می‌تواند وابستگی‌های خطی و غیرخطی را با دقت مدل‌سازی کنند، اما محاسبات زیادی را شامل می‌شوند که زمان زیادی می‌برد. بنابراین هر چه میزان ویژگی‌ها بیشتر باشد مدل یادگیری عمیق می‌تواند بهتر اعمال نماید. بنابراین بدین منظور در این پژوهش برای ویژگی‌های بیشتر از تجزیه و تحلیل حالت تجربی و تبدیل موجک گسسته استفاده خواهد نمود.

۳- ارزیابی روش پیشنهادی: در این پژوهش، به‌منظور ارزیابی جامع عملکرد مدل پیشنهادی، از چندین مجموعه داده واقعی و متنوع مرتبط با بار کاری و انرژی استفاده شده است. این مجموعه داده‌ها شامل داده‌های خوشه‌ای گوگل، داده‌های مصرف و قیمت برق IESO و داده‌های پیش‌بینی انرژی خورشیدی و بار مصرفی شهر لندن می‌باشند.

مجموعه داده Google-۲۰۱۹-Cluster شامل اطلاعات استفاده از منابع در یک محیط رایانش ابری در مقیاس بزرگ است. در این پژوهش، سیگنال استفاده از پردازنده (CPU usage) به‌عنوان شاخص اصلی بار کاری انتخاب شده و به‌صورت یک سیگنال زمانی پیوسته مورد استفاده قرار گرفته است. این داده‌ها دارای ماهیت حجیم و نوسانات پیچیده بوده و برای ارزیابی توان تعمیم‌پذیری مدل مناسب هستند.

مجموعه داده IESO شامل داده‌های واقعی مربوط به بار مصرفی ساعتی و قیمت برق در استان انتاریو کانادا است. این مجموعه داده به دلیل نوسانات شدید و رفتار غیرایستا، چالش برانگیز بوده و برای بررسی پایداری مدل در شرایط واقعی مورد استفاده قرار گرفته است.

مجموعه داده‌های لندن شامل داده‌های پیش‌بینی انرژی خورشیدی (PV forecasting) و بار مصرفی (Load forecasting) با رزولوشن زمانی ساعتی می‌باشند. این داده‌ها دارای رفتار نسبتاً پیوسته‌تر بوده و برای ارزیابی دقت مدل در پیش‌بینی سیگنال‌های کم‌نوسان مناسب هستند.

را فراهم می‌کند. مقاله [۱۱] به روش پیش‌بینی بار مبتنی بر یادگیری عمیق بهبود یافته در محیط رایانش ابری پرداخته و نتایج تجربی نشان می‌دهد که میانگین خطای پیش‌بینی روش پیشنهادی اساساً اساساً در کوتاه مدت ۳ درصد و در بلندمدت ۰/۰۲۳ مگاوات، ۱۹/۷۵ درصد و ۲/۷۶ درصد کنترل می‌شود که بهتر از سایر روش‌های می‌باشد. مقاله [۲۴] به پیش‌بینی تقاضای انرژی با استفاده از یادگیری عمیق پرداخته و بیان می‌کند که نتایج می‌تواند به عنوان جایگزین‌های کارآمد برای مدل‌های پیش‌بینی انرژی در ابر مبتنی بر اینترنت اشیا در هر شهر هوشمند مورد استفاده قرار گیرد. مقاله [۲۵] به پیش‌بینی قیمت برق برای رایانش ابری با استفاده از یک مدل یادگیری ماشین پیشرفته پرداخته و نتایج نشان می‌دهد که مدل می‌تواند منجر به کاهش ۲۵/۳۲ درصدی در هزینه‌های برق شود. مقاله [۲۶] به پیش‌بینی مصرف انرژی در مرکز داده ابری با استفاده از یادگیری ماشین پرداخته و هدف این مقاله پیش‌بینی مصرف برق ماشین مجازی با کمک تحلیل پیش‌بینی رگرسیون، یکی از تکنیک‌های یادگیری ماشین است.

در نهایت می‌توان با توجه به مطالعات کارهای پیشین را به سه دسته ۱- بهینه‌سازی فراابتکاری در پیش‌بینی و تخصیص بار انرژی، ۲- رویکردهای مبتنی بر یادگیری عمیق در پیش‌بینی مصرف انرژی، ۳- رویکردهای مبتنی بر یادگیری ماشین در بهینه‌سازی انرژی تقسیم نمود. اما با وجود پیشرفت‌های قابل توجه در حوزه پیش‌بینی و بهینه‌سازی مصرف انرژی در رایانش ابری، هنوز شکاف‌هایی اساسی در پژوهش‌های موجود مشاهده می‌شود. نخست آنکه بیشتر مطالعات تنها بر یکی از جنبه‌های مسأله مانند پیش‌بینی بار انرژی یا تخصیص منابع تمرکز کرده‌اند و یکپارچگی خوشه‌بندی، پیش‌بینی و بهینه‌سازی فراابتکاری در قالب یک مدل جامع کمتر مورد توجه قرار گرفته است. دوم اینکه، اگرچه الگوریتم‌هایی نظیر فراابتکاری برای تنظیم پارامترهای شبکه‌ها به کار رفته‌اند، اما ترکیب هم‌زمان خوشه‌بندی داده‌ها با فراابتکاری، یادگیری عمیق انتقالی برای پیش‌بینی بار مصرفی انرژی در رایانش ابری تاکنون به صورت جامع بررسی نشده است. علاوه بر این، اغلب مدل‌های ارائه شده به داده‌های خاص یا شرایط محیطی محدود وابسته‌اند و از قابلیت تعمیم و پایداری پیش‌بینی در بارهای پویا و متغیر برخوردار نیستند. بنابراین، پژوهش حاضر با هدف پر کردن این خلأ علمی، رویکردی ترکیبی مبتنی بر خوشه‌بندی بهینه‌شده با الگوریتم فراابتکاری و یادگیری عمیق انتقالی ارائه می‌دهد تا از طریق تفکیک هوشمند داده‌ها، تنظیم بهینه پارامترها و انتقال دانش بین حوزه‌ها، پیش‌بینی دقیق‌تر و بهینه‌تر بار مصرفی انرژی در محیط رایانش ابری تحقق یابد.

گرفتن تنظیمات و پارامترهای مختلف، مصرف انرژی را از ۱،۶٪ به ۸۸،۵٪ کاهش می‌دهد. مقاله [۱۶] به کمیت عدم قطعیت بار خالص مبتنی بر داده برای مدیریت ذخیره انرژی ابری در ریزشبکه مسکونی و برای به حداقل رساندن هزینه‌های مصرف انرژی استفاده شده است. مقاله [۱۷] به حداقل رساندن هزینه انرژی HVAC در شبکه‌های هوشمند مبتنی بر ابر: رویکرد مدیریت تقاضا مبتنی بر ابر با بهینه سازی تئوری بازی و یادگیری عمیق پرداخته و نتایج نشان می‌دهد که هزینه انرژی HVAC را می‌توان تا ۳۶٪ کاهش داد در حالی که به طور غیرمستقیم نیز اوج به میانگین (PAR) و بار خالص کل را تا ۹/۹۷٪ کاهش می‌دهد. مقاله [۱۸] به مدیریت انرژی تجدیدپذیر در شبکه هوشمند با تحلیل امنیت ابری با استفاده از مدل یادگیری ماشین چند عاملی پرداخته و نتایج نشان می‌دهد که مصرف برق ۳۵ درصد و بهره وری انرژی ۹۶ درصد بهینه می‌شود. مقاله [۱۹] به پیش‌بینی بار بار از طریق شبکه عصبی بازگشتی با بهینه سازی ازدحام ذرات اصلاح شده پرداخته و نتایج نشان می‌دهد که مدل‌های بهینه‌سازی شده توسط فراابتکاری معرفی شده عملکرد بهتری از رویکردهای پژوهش‌های مشابه داشتند که با اعتبارسنجی آماری انجام شده تأیید شد. مقاله [۲۰] به یکپارچه‌سازی ماشین مجازی با پیش‌بینی چند مرحله‌ای و تکنیک Affinity-Aware برای مراکز داده ابری کارآمد انرژی پرداخته و نتایج تجربی نشان می‌دهد که روش پیشنهادی می‌تواند به بهبود قابل توجهی در کاهش مصرف انرژی، هزینه‌های مهاجرت ماشین مجازی و نقض توافق‌نامه سطح خدمات دست یابد. مقاله [۱۴] به پیش‌بینی بار میزبان در رایانش ابری با تبدیل موجک گسسته و شبکه عصبی واحد بازگشتی دروازه‌دار دوطرفه (BiGRU) پرداخته و نتایج تجربی نشان می‌دهد که این روش در مقایسه با انواع روش‌های پیشرفته، دقت پیش‌بینی را بین ۳ تا ۵۶ درصد بهبود می‌بخشد. مقاله [۲۱] به آموزش چند وظیفه‌ای برای پیش‌بینی قیمت برق و مدیریت منابع در سیستم‌های اینترنت اشیا صنعتی مبتنی بر ابر پرداخته و روش پیشنهادی در مقایسه با ۱۱ الگوریتم معیار، از جمله CNN، DenseNet و SVM که به ترتیب دارای دقت ۸۹، ۸۸، و ۸۲ درصد هستند، دقت ۹۷٪ دارد. در مقاله [۲۲] به پیش‌بینی قیمت برق برای محاسبات ابری با استفاده از مدل یادگیری ماشین پرداخته و نتایج نشان می‌دهد که روش پیشنهادی با معیار ارزیابی r_2_score ۹۱ درصد نسبت به رگرسیون تصادفی جنگل و رگرسیون بردار پشتیبان بهتر عمل نموده است. مقاله [۲۳] به آزمایش‌های یادگیری ماشینی و ابری برای مدیریت انرژی در یک خوشه ریزشبکه پرداخته که امکان پیش‌بینی تولید برق، پیش‌بینی مصرف انرژی، سیستم مدیریت انرژی بلادرنگ با استفاده از تکنیک‌های یادگیری ماشین

جدول ۱ خلاصه روش‌های پیشنهادی مقالات مشابه

نویسنده	الگوریتم	نتایج
پانوار و همکاران [۴]	روش یادگیری ماشین	کاهش مصرف انرژی بین ۱.۶٪ تا ۸۸.۵٪ در مقایسه با رویکردهای معیار.
ساینی و همکاران [۱۶]	یک مدل همجوشی فیوژن با استفاده از روش‌های SVR، CNN-GRU و LSTM	دقت بالا در پیش‌بینی بار روزانه و توان PV؛ MSE بین ۰.۲ تا ۱.۳ و MAPE حدود ۰.۴۵ تا ۱.۰.
حیدریکیانی و ابایی [۱۷]	روش تئوری بازی و یادگیری عمیق	کاهش ۳۶٪ در هزینه انرژی HVAC و بهبود ۹۷٪ در نسبت اوج به میانگین.
یانگ [۱۸]	روش یادگیری تقویتی چند عاملی مارکوف	دقت ۹۵٪، بهره‌وری انرژی ۹۶٪ و کاهش ۳۵٪ در مصرف برق.
پردیک و همکاران [۱۹]	روش مدل‌های یادگیری عمیق و فراابتکاری بهینه‌سازی ازدحام ذرات	عملکرد برتر با $R^2=0.858$ و $MSE=0.0095$.
لی و کائو [۲۰]	روش پیش‌بینی رگرسیون خطی	مقدار MAPE برای مصرف برق بین ۰.۰۱۹ تا ۰.۰۴۱.
دوگانی و همکاران [۱۴]	روش شبکه عصبی واحد بازگشتی دروازه‌دار دوطرفه، تبدیل موجک گسسته	بهبود دقت پیش‌بینی بین ۳٪ تا ۵۶٪ نسبت به روش‌های پیشرفته.
المازرو و عبوب [۲۱]	روش بهینه‌سازی مونگوس کوتوله	کاهش ۲۲٪ در هزینه برق و دقت بالای پیش‌بینی (MAE=2.22, MSE=6.33).
تیرونائو و ککاراسو و همکاران [۲۲]	روش افزایش گرادیان شدید	$R^2=91$ ٪، عملکرد بهتر از SVM و RF.
روزرو و همکاران [۲۳]	روش خوشه بندی	بهبود کارایی مدیریت انرژی از طریق خوشه‌بندی محلی و پردازش در نزدیکی منابع
ژانگ و همکاران [۱۱]	روش EMD و شبکه باور عمیق	$RMSE=19.75$ ، $MAPE=2.74$ ٪، عملکرد بهتر از مدل‌های مشابه.
هرنجیکا و دانسته مهر [۲۴]	روش مبتنی بر حافظه کوتاه مدت بلند مدت	$R^2=0.9427$ ، $SE=0.2789$ ، $RMSE=0.0255$
الباهل و همکاران [۲۵]	روش افزایش گرادیان شدید	کاهش ۲۵.۳۲٪ در هزینه برق و دقت ۹۱٪ در پیش‌بینی قیمت.
دیپیکا و پراکاش [۲۶]	روش پرسپترون چند لایه	قت پیش‌بینی ۹۱٪ در فرآیند مصرف انرژی.

۳- روش پیشنهادی

سیگنال‌های منفرد ممکن است منجر به از دست رفتن الگوهای پنهان شود، یک روش خوشه‌بندی مبتنی بر الگوریتم مگس میوه برای گروه‌بندی سیگنال‌های دارای رفتار مشابه ارائه شده است. این خوشه‌بندی علاوه بر کاهش ابعاد داده‌ها، موجب بهبود پایداری و کارایی مدل پیش‌بینی در مقایسه با روش‌های خوشه‌بندی مرسوم می‌شود.

مرحله پنجم: اعتبارسنجی و انتخاب خوشه بهینه. برای انتخاب مناسب‌ترین خوشه جهت آموزش مدل پیش‌بینی، از آزمون آماری آنوای یک‌طرفه استفاده می‌شود. این آزمون امکان ارزیابی تفاوت معنادار بین خوشه‌ها را فراهم کرده و خوشه‌ای با بیشترین اهمیت آماری به‌عنوان ورودی نهایی مدل انتخاب می‌شود.

مرحله ششم: پیش‌بینی مبتنی بر یادگیری انتقالی عمیق. در این مرحله، سیگنال‌های خوشه انتخاب‌شده به یک چارچوب یادگیری انتقالی مبتنی بر شبکه LSTM وارد می‌شوند. استفاده از یادگیری انتقالی موجب کاهش زمان آموزش و بهبود قابلیت تعمیم مدل در مجموعه داده‌های مختلف می‌شود. مدل پس از تنظیم دقیق، بر روی داده‌های آموزشی و آزمایشی ارزیابی می‌گردد.

در این مقاله، یک چارچوب چندمرحله‌ای ترکیبی برای پیش‌بینی بار کاری و مصرف انرژی در محیط‌های رایانش ابری ارائه شده است که شامل مراحل پیش‌پردازش سیگنال، تجزیه سیگنال، خوشه‌بندی، انتخاب خوشه بهینه و یادگیری انتقالی عمیق می‌باشد.


مرحله اول: ورودی داده‌ها و پیش‌پردازش. در این مرحله، سیگنال‌های خام بار کاری انتخاب شده و عملیات پیش‌پردازش شامل حذف مقادیر گمشده، نرمال‌سازی و تقسیم‌بندی زمانی بر روی آن‌ها انجام می‌شود تا داده‌ها برای مراحل بعدی آماده گردند.

مرحله دوم و سوم: تجزیه سیگنال. در ادامه، سیگنال‌های پیش‌پردازش‌شده با استفاده از تجزیه و تحلیل حالت تجربی به مجموعه‌ای از توابع حالت ذاتی (IMF) تفکیک می‌شوند. سپس، به‌منظور استخراج هم‌زمان ویژگی‌های حوزه زمان و فرکانس، تبدیل موجک گسسته بر روی هر IMF اعمال می‌شود. این فرآیند باعث افزایش قدرت نمایش ویژگی‌ها و کاهش اثر غیرایستایی سیگنال‌ها می‌گردد.

مرحله چهارم: خوشه‌بندی سیگنال‌ها. از آنجایی که کار با

۲. داده‌های ناقص، داده خالی و NaN: اگر رکوردی در مجموعه داده دارای داده ناقص باشد از مجموعه داده حذف خواهد شد. همچنین اگر رکوردی در مجموعه داده دارای مقادیر خالی و NaN باشد از مجموعه داده حذف خواهد شد.

۳. نمونه برداری و تقسیم‌بندی: جهت استفاده روش پیشنهادی از مجموعه داده‌های انتخاب شده برای پردازش منایب تعداد آنها به صورت تصادفی نمونه برداری شده و به دو دسته داده آموزش و آزمایش تقسیم می‌شود که ۷۰ درصد نمونه‌ها به داده آموزش و ۳۰ درصد برای داده‌های آزمایش استفاده شده است.



شکل ۲ مراحل پیش پردازش بر روی مجموعه داده‌ها

۲-۳- استخراج مولفه ذاتی سیگنال با استفاده از الگوریتم تجزیه و تحلیل حالت تجربی

تجزیه مولفه به سیگنال‌های ذاتی یک روش تحلیلی و کارآمد غیر خطی و غیر ثابت فرکانس داده‌های زمانی است که توسط هوانگ و همکاران معرفی شده است. این روش براساس این فرض ساده است که هر سیگنال از زیر مجموعه‌های مختلف تشکیل شده است. سری-های زمانی غیرخطی و غیرثابت می‌توانند به گروهی از سیگنال‌های میانگین متوسط و شبه تناوبی تقسیم شوند، جایی که هر یک از مؤلفه‌ها مولفه مد ذاتی نامیده می‌شوند. مراحل الگوریتم تجزیه سیگنال به مولفه ذاتی عبارتند از:

مرحله اول: تعیین نقاط ماکزیمم و مینیمم محلی سیگنال ورودی؛
مرحله دوم: ایجاد منحنی پوش بالا از طریق برازش منحنی درجه سه بر نقاط ماکزیمم محلی و ایجاد منحنی پوش پایین از طریق برازش منحنی درجه سه بر نقاط مینیمم محلی؛
مرحله سوم: میانگین‌گیری از منحنی‌های پوش بالا و پایین؛
مرحله چهارم: تفریق منحنی پوش بالا و پایین از سیگنال ورودی که در رابطه ۱ آورده شده است؛

مرحله هفتم: ارزیابی و مقایسه عملکرد. عملکرد نهایی با استفاده از معیارهایی مانند MSE، RMSE، MAE، MAPE ارزیابی و با روش‌های پیشرفته مقایسه می‌شود.

شکل ۱ روال روش پیشنهادی پژوهش را نشان می‌دهد.



شکل ۱ روال انجام روش پیشنهادی

۱-۳- پیش پردازش

برای استفاده از روش پیشنهادی لازم است بر روی مجموعه داده پیش پردازش صورت گیرد. برای پیش‌پردازش داده‌ها، مراحل زیر در نظر گرفته شده است که در شکل ۲ آورده شده است:

۱. انتخاب ویژگی و نرمال‌سازی: ویژگی از مجموعه داده که باید به عنوان سیگنال اصلی روی آن تجزیه و تحلیل انجام شود مانند CPU usage، بار ساعتی، بار PV و قیمت بار مصرفی انتخاب شده و برای استفاده از نرمال‌سازی و دقت مدل نرمال می‌شود.

جدول ۲ شبه کد الگوریتم تجزیه سیگنال به مولفه ذاتی

Input: Main signal
Start
1. $k=1:n$ (Finding all the eigenmode components)
2. Finding all signal extrema.
3. Calculate the Upper envelope curve.
4. Calculate the Lower envelope curve.
5. Averaging of upper and lower envelope curves.
6. Subtracting upper and lower envelope curves from input signal.
7. Calculating $D_k(t)$.
8. Checking stopping condition.
If Upper envelope curve & Lower envelope curve ≥ 0
$x = r$ (Substituting the signal obtained from step 2 in place of the original);
Else
Finding all the eigenmode components.
End
Stop.
Extracting all the intrinsic components of the Output:
signal(IMFS)

اطلاعاتی که در سری زمانی یا سیگنال نهفته است، استفاده می‌شود. موجک‌ها بر مبنای دو عمل اصلی قرار دارند: انتقال و پهن‌شدگی. تبدیل موجک به دو نوع پیوسته و گسسته تقسیم می‌شود. تبدیل پیوسته موجک یک سیگنال $x(t)$ به صورت رابطه ۵ تعریف می‌شود:

$$CWT_x^\Psi = \frac{1}{\sqrt{|s|}} \int_{-\infty}^{+\infty} x(t) \Psi^*\left(\frac{t-\tau}{s}\right) dt \quad (5)$$

که در آن Ψ تابع موجک، $(s > 1)$ پارامتر مقیاس یا اتساع، τ پارامتر انتقال زمان، t زمان و علامت نشان دهنده مزدوج مختلط می‌باشد. روش تبدیل موجک پیوسته، سیگنال را بوسیله تعداد بیشمار و نامحدودی از پارامترهای مقیاس و انتقال تجزیه می‌کند. در این روش پارامترهای مقیاس و انتقال بصورت پیوسته تغییر می‌کنند. از اینرو محاسبه ضرایب موجک برای همه مقیاس‌های ممکن، علاوه بر تولید حجم زیادی از اطلاعات، نیاز به کوششی قابل ملاحظه دارد. آشکارا مشخص است در روش تبدیل موجک پیوسته مقدار زیادی اطلاعات اضافی تولید می‌شود. اما می‌توان با استفاده از زیرنمونه‌هایی تبدیل موجک پیوسته ویژگی‌های کلیدی تبدیل را حفظ نمود این ایده منجر به ابداع تبدیل گسسته موجک (DWT) گردیده است. شکل گسسته تابع موجک به صورت رابطه ۶ می‌باشد.

$$\Psi_{j,k}(t) = \frac{1}{\sqrt{|s_0^j|}} \Psi\left(\frac{t - k\tau_0 s_0^j}{s_0^j}\right) \quad (6)$$

که در آن $\Psi_{j,k}$ تابع موجک به ازای مقادیر معین k و j (اعداد صحیح)، t زمان، $(s > 1)$ پارامتر ثابت اتساع، τ_0 پارامتر ثابت انتقال زمان بوده و وابسته به s_0 می‌باشد. در روش تبدیل موجک گسسته مقادیر پارامترهای مقیاس و انتقال توان‌هایی از ۲ در نظر گرفته

$$h_k(t) = x(t) - m_k(t) \quad (1)$$

مرحله پنجم: شرط توقف مربوط به IMF بوده است این شرط در رابطه ۲ آورده شده است:

$$D_k(t) = \frac{\sum_{t=0}^T |h_t^{k-1}(t) - h_t^k(t)|^2}{\sum_{t=0}^T |h_t^{k-1}(t)|^2} \quad (2)$$

مرحله ششم: در صورت عدم مرحله پنجم، جایگذاری سیگنال حاصل از مرحله چهار به جای سیگنال اصلی و ادامه فرایند از مرحله اول؛

مرحله هفتم: اگر شرط مرحله برقرار باشد فرآیند پایان یافته و $c_1 = h_1^k$ به عنوان اولین مولفه مد ذاتی در نظر گرفته می‌شود که در واقع مولفه فرکانس بالای سیگنال $x(t)$ است.

مرحله هشتم: باقیمانده به صورت $r_1 = x(t) - c_1^k$ تعریف شده و اگر خود، شرط مولفه مد ذاتی بودن را برآورده کند، یک مولفه مد ذاتی محسوب شده و در غیر اینصورت اگر شرط الف) تعداد ماکزیمم و مینیمم‌ها برابر یا بیشتر تعداد صفرها باشد را داشته باشد، به عنوان سیگنال اولیه، فرض شده و گام‌های یک الی چهار، تکرار می‌گردد تا مولفه مد ذاتی بعدی به دست آید و اگر این شرط را نداشته باشد به عنوان باقیمانده r در نظر گرفته می‌شود. باقیمانده را می‌توان به شکل رابطه ۳ تعریف نمود.

$$r_i = x(t) - c_i^k \quad (3)$$

بنابراین در واقع سیگنال اصلی ما مجموع مولفه مد ذاتی به علاوه باقیمانده است که در رابطه ۴ نشان داده شده است.

$$x(t) = \sum_{i=1}^n h_i(t) + r(t) \quad (4)$$

در معادله بالا $x(t)$ مقدار داده اصلی است، هر کدام از h_i^k ها مقدار λ امین مولفه مد ذاتی و $r(t)$ مولفه باقیمانده را نشان می‌دهد و n تعداد مولفه مد ذاتی می‌باشد [۱۴]. جدول ۲ شبه کد مراحل الگوریتم تجزیه سیگنال به مولفه ذاتی آورده شده است.

۳-۳ الگوریتم تبدیل موجک گسسته

تبدیل موجک دسته‌ای از توابع ریاضی هستند که برای تجزیه سیگنال پیوسته به مؤلفه‌های فرکانسی آن بکار می‌رود که رزولوشن هر مؤلفه برابر با مقیاس آن است. تبدیل موجک تجزیه یک تابع بر مبنای توابع موجک می‌باشد. بنابراین تبدیل موجک به عنوان یک تبدیل ریاضیاتی (مانند تبدیل فوریه) برای تشخیص

$$X(i) = X_{axis} + \text{RandomValue} \quad (7)$$

$$Y(i) = Y_{axis} + \text{RandomValue} \quad (8)$$

گام ۳: انتخاب سرخوشه و تخصیص مگس‌ها به نزدیکترین سرخوشه: محاسبه شدت بویایی مگس‌ها تا زمانی که محل غذا معلوم نشده باشد. در ابتدا نمی‌توان موقعیت منبع غذایی را به طور دقیق تعیین کرد.

بنابراین لازم است ابتدا $dist$ فاصله شروع بین فرد و نقطه تنظیم اولیه تخمین زده شود و سپس برای محاسبه غلظت آن را به مقدار S_i که از معادله ۱۱ بدست می‌آید، برسانیم که همان فاصله متقابل است. برای اختصاص یافتن نمونه‌ها به نزدیکترین مرکز خوشه طبق معادله ۹ از فاصله اقلیدسی تعیین می‌شود که رابطه ۱۰ محاسبه می‌شود؛

$$label_i = \|c_k - X_i\| \min(S_i) \quad (9)$$

$$dist = \sqrt{x(i)^2 + y(i)^2} \quad (10)$$

$$S_i = \frac{1}{dist_R} \quad (11)$$

در معادله ۹، X_i داده‌ها و c_k موقعیت سرخوشه k ام می‌باشد.

گام ۴: محاسبه میزان تابع برازندگی؛ با جایگزینی S_i به تابع ارزیابی غلظت طعم (که تابع هدف نیز نامیده می‌شود و هدف کمینه سازی آن می‌باشد)، مقدار غلظت بوی (i) بالای هر موقعیت مگس میوه را می‌توان از طریق کمینه سازی معادله ۱۲ محاسبه کرد:

$$Small(i) = fit(label_i) \quad (12)$$

گام ۵: یافتن میزان بهترین شدت بویایی؛ در این مرحله ارزش غلظت بهینه بهترین بو به خاطر سپرده می‌شود و در موقعیت مختصات X ذخیره می‌شود.

گام ۶: حرکت به سوی بهترین موقعیت؛

گام ۷: به روزرسانی موقعیت مگس‌ها؛ در این مرحله براساس موقعیت هترین مگس و میانگین جمعیت طبق معادله ۱۳ صورت می‌گیرد.

$$x_i^{new} = x_i + 0.1(x_{best} - x_i) + 0.05(x_{best} - \bar{X}) \quad (13)$$

گام ۸: معیار توقف؛ اگر تعداد تکرارها از حداکثر تعداد تکرارهای تعیین شده G_{max} کمتر باشد یا دقت هدف حاصل نشود، مراحل ۶-۸ دوباره تا برقراری معادله ۱۴ انجام می‌شود؛

می‌شود. در اصطلاح به این پارامترها، پارامترهای انتقال و اتساع دوتایی گفته می‌شود. اعمال این روش بر روی سیگنال باعث می‌شود اجزاء فرکانس بالا و پایین تجزیه شود که محتوای فرکانس پایین سیگنال تقریباً که آن را با A نشان می‌دهیم و محتوای فرکانس بالا جزئیات^۲ که آن را با D نشان می‌دهیم، نامگذاری می‌شود [۲]. جدول ۳ شبه کد مراحل الگوریتم تبدیل موجک گسسته آورده شده است.

جدول ۳ شبه کد الگوریتم تبدیل موجک گسسته

```

Input: signal
Start
1)  $i = 1 : \text{size(IMFS)}$  (Each IMFS is an intrinsic component of the signal)
2)  $X = \text{IMFS}(i)$ 
3)  $wname = 'haar'$ 
4)  $N = 5$ 
5)  $[C, L] = \text{wavedec}(X, N, wname)$ 
6) for  $i = 1 : N$ 
     $A\{i\} = \text{wcoef}('a', C, L, wname, i)$ 
     $D\{i\} = \text{wcoef}('d', C, L, wname, i)$ 
end
Stop
Output: Decomposition of approximation and detail frequency components
    
```

۳-۴- خوشه‌بندی بهینه شده با الگوریتم فراابتکاری

در این بخش یک خوشه بندی جدید براساس الگوریتم‌های فراابتکاری ارائه می‌گردد، تا بتوان خوشه های بهینه را براساس آن پیدا کرد.

از آنجایی که یافتن خوشه‌های بهینه یک مسئله بهینه‌سازی ترکیبی چند هدفه است، بنابراین با استفاده از الگوریتم‌های فراابتکاری الهام گرفته از طبیعت می‌توانیم مسئله چند هدفه را بهینه کنیم.

الگوریتم مورد استفاده الگوریتم مگس میوه می‌باشد که مشابه بسیاری از الگوریتم‌های دیگر فرا ابتکاری، بر اساس رفتار طبیعت (در اینجا مگس میوه)، طراحی شده است. مراحل الگوریتم بدین شرح می‌باشد:

گام ۱: تعیین پارامترها و موقعیت اولیه مگس؛ در این مرحله حداکثر تعداد تکرار که با G_{max} و اندازه جمعیت $Popsize$ تنظیم می‌شود. موقعیت جمعیت مگس میوه به طور تصادفی روی محور X_{axis} ، محور Y_{axis} توزیع می‌شود.

گام ۲: تعیین جهت و مسافت جست وجوی مگس به صورت تصادفی؛ در این مرحله اختصاص دادن هر مگس میوه برای یافتن غذا در هر جهت که عدد تصادفی در بازه $[0,1]$ و طبق روابط ۷ و ۸ که از طریق حس بویایی دست می‌آید.

جدول ۵ تحلیل واریانس آزمون آنوا

تغییرات	SS	Df	MS	F
بین گروهی	SS_{tr}	$a - 1$	$MS_{tr} = \frac{SS_{tr}}{a - 1}$	$\frac{MS_{tr}}{MS_E}$
درون گروهی (خطا)	SSE	$a(n - 1)$	$MS_E = \frac{SS_{tr}}{a(n - 1)}$	-
کل	SST	$a(n - 1)$	-	-

پیش‌بینی مصرف انرژی در رایانش ابری ارائه می‌شود. این رویکرد با انتقال دانش از داده‌ها یا وظایف منبع به حوزه هدف، هزینه آموزش را کاهش داده و دقت و توان تعمیم مدل را بهبود می‌بخشد. یادگیری‌های انتقال عمیق را می‌توان بر اساس همگنی داده‌های منبع به اختصار D_s و هدف به اختصار D_r گفته می‌شود به دو دسته همگن و ناهمگن تقسیم کرد. با این حال، این دسته بندی می‌تواند متفاوت انجام شود زیرا ذهنی و نسبی است. یادگیری انتقالی عمیق بر اساس وضعیت برچسب‌گذاری داده‌ها به سه دسته اصلی تقسیم می‌شود: انتقالی، استقرایی و بدون نظارت. در حالت انتقالی، تنها داده‌های منبع برچسب‌گذاری شده‌اند، در حالی‌که در یادگیری استقرایی، هر دو مجموعه داده منبع و هدف دارای برچسب هستند. در مقابل، در یادگیری انتقالی بدون نظارت، هیچ‌یک از داده‌ها برچسب‌گذاری نشده‌اند.

در رویکردهای مبتنی بر مدل در یادگیری انتقالی عمیق، معمولاً از ترکیبی از پیش‌آموزش، انجماد لایه‌ها، تنظیم دقیق و افزودن لایه‌های جدید استفاده می‌شود. مدلی که بر روی داده‌های منبع آموزش داده شده باشد، به‌عنوان مدل از پیش‌آموزش دیده شناخته می‌شود. در فرآیند انجماد، وزن‌های برخی لایه‌ها ثابت نگه داشته می‌شوند، در حالی‌که در تنظیم دقیق، پارامترها با مقادیر از پیش‌آموزش دیده مقداردهی اولیه شده و متناسب با داده‌های هدف به‌روزرسانی می‌شوند.

در شبکه‌های یادگیری عمیق، لایه‌های اولیه عمدتاً وظیفه استخراج ویژگی‌های سطح پایین را بر عهده دارند، در حالی‌که لایه‌های میانی و نهایی به استخراج ویژگی‌های سطح بالا و انجام پیش‌بینی یا طبقه‌بندی می‌پردازند.

بر این اساس، کارآمدترین راهبرد در یادگیری انتقالی عمیق، انجماد لایه‌های اولیه و میانی یک مدل مرتبط از پیش‌آموزش دیده و تنظیم دقیق لایه‌های نهایی برای وظیفه یا مجموعه داده جدید است. همچنین، در یادگیری انتقالی پیش‌رونده، لایه‌های جدید به انتهای مدل از پیش‌آموزش دیده افزوده می‌شوند تا فرآیند یادگیری

$$\begin{cases} Smellbest = Smellbest \\ X(i) = X(bestindex) \\ Y(i) = y(bestindex) \end{cases} \quad (14)$$

جدول ۴ شبه کد مراحل الگوریتم مگس میوه آورده شده است.

جدول ۴ شبه کد الگوریتم بهینه سازی مگس میوه برای خوشه‌بندی

Input: Data
Start
1. Defining parameters.
a. Compute dataMin, dataMax for each feature;
b. Randomly initialize flies of size (popSize, K, numFeatures) within [dataMin, dataMax];
c. bestCenters ← flies(1);
bestFitness ← ∞;
2. Main loop.
For iter = 1 to maxIter
For i = 1 to popSize
a. tempCenters = flies(i);
b. labels = assign each sample in data to nearest center in tempCenters;
c. fitness(i) = sum of squared distances of samples to their assigned centers;
End
End
3. Update global best
If min(fitness) < bestFitness:
bestFitness = min(fitness);
bestCenters = corresponding fly ;
End
4. Update flies
meanFly = mean of all flies;
For i = 1 to popSize:
flies(i) ← flies(i) + 0.1*(bestCenters - flies(i)) + 0.05*(meanFly - flies(i));
Stop.
Output: Clustering

۳-۵- آزمون آنوا

آزمون آنوا یا تحلیل واریانس یک طرفه برای آزمون مقایسه میانگین یک متغیر کمی در بین بیش از دو گروه مستقل استفاده می‌شود. شرایط آزمون تحلیل واریانس این است که داده‌ها توزیع نرمال داشته باشند.

واریانس در گروه‌ها برابر باشد. مشاهدات در گروه‌ها مستقل از هم باشند. روش تجزیه و تحلیل داده‌های مربوط به یک آزمایش آنالیز واریانس یک طرفه در جدول ۵ آورده است.

فیلدهای آن عبارتند از: منبع تغییرات که شامل بین گروه‌ها^۳، میان گروه‌ها یا خطا^۴ و مجموع کل می‌باشد. مجموع مربعات را با SS و درجه آزادی را با Df و میانگین مربعات را با MS نشان می‌دهند. مجموع همه داده‌ها با y_{00} مشخص می‌شود. تعداد سطر در ستون برابر است $N = n * a$. C_F عامل تصحیح کننده است [۲۷].

۳-۶- مدل یادگیری عمیق انتقالی

در این مرحله، با استفاده از یادگیری انتقالی عمیق، مدلی برای

به صورت تدریجی تکمیل گردد [۲۸].

در این پژوهش برای استفاده از یادگیری عمیق و یک مدل از پیش آموزش دیده از مدل LSTM استفاده شده است. LSTM از چندین واحد ذخیره سازی تشکیل شده است که اطلاعات را ذخیره می کنند.

هر واحد ذخیره سازی حفاظت و کنترل اطلاعات را از طریق سه گیت ویژه (دریچه ورودی، دروازه فراموشی و گیت خروجی) محقق می کند. دروازه فراموشی f_t تعیین می کند که چه مقدار از اطلاعات سلول قبلی توسط سلول فعلی حفظ می شود و مقدار آن در رابطه ۱۵ نشان داده شده است:

$$f_t = \sigma(w_f \cdot [h_{t-1}, x_t] + b_f) \quad (15)$$

در رابطه ۱۵ w_f ماتریس وزن، b_f انحراف و σ تابع سیگموئید می باشد. دروازه ورودی به روز رسانی داده های ورودی فعلی را به مقدار وضعیت واحد ذخیره سازی کنترل می کند که در رابطه ۱۶ نشان داده شده است.

$$i_t = \sigma(w_i \cdot [h_{t-1}, x_t] + b_i) \quad (16)$$

در رابطه ۱۶ در آن w_i ماتریس وزن و b_i انحراف است. اطلاعات وضعیت جدید $\tilde{c}_t$ را می توان از رابطه ۱۷ بدست آورد:

$$\tilde{c}_t = \tanh(w_c \cdot [h_{t-1}, x_t] + b_c) \quad (17)$$

بنابراین، وضعیت فعلی $\tilde{c}_t$ را می توان به صورت رابطه ۱۸ بدست آورد:

$$c_t = f_t \cdot c_{t-1} + i_t \cdot \tilde{c}_t \quad (18)$$

دروازه خروجی o_t مقدار خروجی مقدار حالت سلول حافظه را کنترل می کند، و مقدار آن طبق رابطه ۱۹ و ۲۰ تعریف می شود که در آن w_o ماتریس وزن و b_o انحراف است.

$$o_t = \sigma(w_o \cdot [h_{t-1}, x_t] + b_o) \quad (19)$$

$$h_t = o_t \cdot \tanh(c_t) \quad (20)$$

با کمک سه گیت کنترل و واحد ذخیره سازی، LSTM می تواند اطلاعات طولانی مدت را بخواند، تنظیم مجدد و به روز کند. با توجه به مکانیسم اشتراک گذاری پارامترهای داخلی LSTM، می توان آن را با تنظیم ماتریس وزن کنترل کرد.

در ادامه استفاده از مدل LSTM برای یادگیری عمیق انتقالی با توجه به یک منبع $D_s = \{X_s, f_s(X)\}$ و وظایف یادگیری T_s و با

توجه به یک دامنه هدف $D_r = \{X_r, f_r(X)\}$ و اهداف آموزشی مربوطه T_r ، وقتی $D_s \neq D_r$ یا $T_s \neq T_r$ ، از دامنه منبع و یادگیری در دامنه منبع برای به دست آوردن تابع پیش بینی $f_t(\cdot)$ در دامنه هدف استفاده می شود.

در این تعریف، توزیع ویژگی و فضای ویژگی با هم یک حوزه را در یادگیری انتقال تشکیل می دهند. یعنی $D = \{X, P(X)\}$ زمانیکه $D_s \neq D_r$ دو حالت وجود دارد: $X_s \neq X_r$ یا $P(X_s) \neq P(X_r)$ جایی که $X_s \in X_s, X_r \in X_r$ توزیع شرطی و فضای برچسب با هم وظیفه انتقال یادگیری $T = \{Y, P(Y|X)\}$ را تشکیل می دهند، وقتی $T_s \neq T_r$ ، دو حالت نیز وجود دارد: $Y_s \neq Y_r$ یا $P(Y_s) \neq P(Y_r)$ جایی که $Y_s \in Y_s, Y_r \in Y_r$ هنگامی که دامنه منبع و دامنه هدف یکسان هستند، هدف وظیفه نیز یکسان است، یعنی $D_s = D_r$ و $T_s = T_r$ سپس، این مشکل به یک کار معمولی یادگیری ماشینی تبدیل می شود [۲۹]. مراحل استفاده از یادگیری عمیق انتقالی با استفاده از مدل LSTM بدین شرح می باشد:

بارگذاری و آماده سازی داده ها: داده ها پس از آماده سازی مراحل پیشین، نرمال سازی شده و به مجموعه های آموزش و آزمون تقسیم می شوند.

تعریف معماری اولیه LSTM: معماری اولیه شبکه شامل لایه ورودی و لایه های LSTM طراحی می شود.

تنظیم پارامترهای آموزش: پارامترهایی نظیر الگوریتم بهینه سازی، نرخ یادگیری و حداکثر تعداد epoch تعیین می گردد.

آموزش اولیه شبکه: شبکه LSTM با استفاده از داده های آموزش، آموزش داده می شود.

آماده سازی برای یادگیری انتقالی: لایه های آموزش دیده LSTM استخراج شده، در معماری جدید جایگزین می شوند و وزن لایه های منتخب منجمد می گردند.

آموزش مجدد شبکه: معماری انتقال یافته با داده های آموزش، مجدداً آموزش داده می شود.

پیش بینی و ارزیابی عملکرد: پیش بینی برای داده های آموزش و آزمون انجام شده، خروجی ها از حالت نرمال خارج می شوند و معیارهای RMSE، MSE، MAE و MAPE محاسبه می گردند. همچنین نمودار مقایسه ای مقادیر واقعی و پیش بینی شده برای هر دو مجموعه ترسیم می شود.

جدول ۶، شبه کد مراحل اجرای مدل یادگیری عمیق انتقالی ارائه شده است.

جدول ۶ شبه کد مدل یادگیری عمیق انتقالی مبتنی بر LSTM

Input: Data
 Start
 1-ata normalization and Split into training, validation and test data.
 2-Prepare input format for LSTM (Convert data to cell (a column for each sample)).
 3-Define initial LSTM architecture.
 a. Sequence input layer;
 b. First LSTM layer with OutputMode='sequence';
 c. Dropout layer to prevent overfitting;
 d. Second LSTM layer with OutputMode='last';
 e. Fully Connected layer;
 f. Regression layer for numerical output;
 4-Set training options (trainingOptions)
 a. Select the adam optimization algorithm ;
 b. Set the maximum number of iterations (epoch) ;
 c. Set the mini-batch size ;
 d. Set the initial learning rate ;
 e. Enable randomization (shuffle);
 f. Gradient threshold (optional);
 g. Show the training progress;
 h. Disable additional messages;
 5-Initial network training(trainNetwork with training data and defined layers).
 6- Extract weights from Trained network
 a. Extract and Copy trained layers ← transfer_layers;
 b. Freeze LSTM layer weights;
 7- .Re-training (fine-tuning)
 a. Use transferred architecture;
 b. Re-train with training data;
Stop.
Output: Prediction of training and test data with Deep Transfer Learning

چندجمله‌ای بوده و با توجه به ماهیت آفلاین فرآیند آموزش، برای کاربردهای پیش‌بینی بار کاری و انرژی در محیط‌های ابری قابل قبول و مقیاس‌پذیر است.

۴- نتایج و ارزیابی

۴-۱- محیط شبیه سازی

در این مقاله محیط شبیه سازی با نرم افزار MATLAB R2020a برای مدل سازی استفاده شده است و کامپیوتر برای شبیه سازی دارای پردازنده مرکزی اینتل سری i3-2350 و دارای حافظه ۴ گیگ و ۵۰۰ گیگا بایت هارد می‌باشد.

۴-۲- مجموعه داده

در این پژوهش برای ارزیابی روش پیشنهادی از سه مجموعه داده استفاده خواهد شد.

مجموعه داده اول: مجموعه داده خوشه‌ای گوگل^۵ که در پژوهش‌های [۲۰] و [۱۴] استفاده شده است. این مجموعه داده بارهای کاری CPU است که در هشت خوشه محاسباتی Google Borg برای ماه مه ۲۰۱۹ اجرا می‌شود. این مجموعه بر اساس ردیابی یک خوشه در ماه مه ۲۰۱۱ است که طیف وسیعی از تحقیقات را در زمینه پیشرفت زمان‌بندی خوشه‌ها و محاسبات ابری ممکن کرده است و برای تولید صدها تحلیل و مطالعه استفاده شده است. این مجموعه داده در مجموعه‌داده kaggle^۶ قابل دسترسی می‌باشد.

مجموعه داده دوم: مجموعه داده دوم بار مصرفی PV اروپا است که در پژوهش [۱۶] استفاده شده است. این مجموعه داده ساعتی تا روزانه همه کشورهای عضو اتحادیه اروپا به اضافه نروژ و سوئیس در طول بیش از ۳۰ سال از سال ۱۹۸۵ تا ۲۰۱۶ می‌باشد. این مجموعه داده شامل دو فایل است که فایل اول آن دارای داده‌های گمشده می‌باشد. اما فایل دوم که به نام ninja_europe_wind_v1.1 از سایت renewables.ninja^۷ قابل دانلود است.

مجموعه داده سوم: مجموعه داده به نام IESO مخفف Independent Electricity System Operator است که سازمانی است که مسئول مدیریت سیستم برق و اطمینان از عملکرد قابل اعتماد شبکه برق در انتاریو، کانادا که در پژوهش‌های [۲۱، ۲۲] و [۲۵] استفاده شده است. این مجموعه داده شامل اطلاعات ساعتی در مورد تقاضا و قیمت از سال ۲۰۰۳ تا ۲۰۲۳ است که شامل سه رکورد: ساعت(ساعت ۱ از ساعت ۱۲ صبح است. تا ۱ بامداد، ساعت ۲ از ۱ بامداد است. تا ساعت ۲ بامداد ساعت ۱ تا ۲۴ ساعت از نیمه شب یک روز تا نیمه شب روز بعد است. زمان استاندارد شرقی در

۳-۷- پیچیدگی زمانی

به‌منظور بررسی کارایی محاسباتی چارچوب پیشنهادی، پیچیدگی زمانی هر یک از مراحل اصلی به‌صورت جداگانه تحلیل می‌شود. فرض می‌شود n تعداد نمونه‌های داده، k تعداد خوشه‌ها، m تعداد توابع حالت ذاتی (IMFs) و T تعداد تکرارهای الگوریتم بهینه‌سازی باشد.

در مرحله تجزیه و تحلیل حالت تجربی، پیچیدگی زمانی به‌طور تقریبی از مرتبه $m \times O(n)$ است، زیرا فرآیند استخراج IMF ها نیازمند چندین عبور از سیگنال ورودی می‌باشد. در مرحله تبدیل موجک گسسته که روی هر IMF اعمال می‌شود، پیچیدگی زمانی از مرتبه $O(n)$ می‌باشد. مرحله خوشه‌بندی مبتنی بر الگوریتم مگس میوه با توجه به اندازه جمعیت و تعداد تکرارها دارای پیچیدگی تقریبی $m \times k \times O(T)$ است. آزمون آنوا برای انتخاب بهترین خوشه پیچیدگی زمانی خطی $O(n)$ می‌باشد. در نهایت، مرحله یادگیری عمیق انتقالی بیشترین بار محاسباتی را دارد که پیچیدگی آن به تعداد لایه‌ها، تعداد نوروها و تعداد تکرارها وابسته بوده و به‌صورت کلی می‌توان آن را $p \times n \times O(E)$ در نظر گرفت، که در آن E تعداد تکرارها و p تعداد پارامترهای مدل است.

در مجموع، پیچیدگی زمانی چارچوب پیشنهادی به‌صورت

$$MAE = \frac{1}{n} \sum_{i=1}^n |P_i - A_i| \quad (24)$$

در روابط بالا A_i مقدار واقعی، P_i مقدار پیشگویی شده، n تعداد نمونه‌ها است.

۴-۴- پیاده‌سازی روش پیشنهادی

سیگنال‌های سه مجموعه داده مورد استفاده در شکل ۳ آورده شده است.

همانطور که در شکل ۳ نشان می‌دهد، از سه مجموعه داده که به تعداد متفاوت نمونه انتخاب شده است، روش پیشنهادی بر روی پنج سیگنال ۱- CPU usage از مجموعه داده خوشه‌ای گوگل؛ ۲- بار ساعتی مجموعه داده لندن؛

۳- بار (پیش‌بینی انرژی خورشیدی) PV مجموعه داده لندن؛

۴- بار ساعتی مجموعه داده IESO؛

۵- قیمت بار مصرفی به دلار کانادا از مجموعه داده IESO اعمال می‌شود. مراحل روش پیشنهادی که به صورت مستند آورده می‌شود بر روی مجموعه داده اول صورت گرفته است و در نهایت نتایج برای ۵ سیگنال بیان می‌گردد.

تمام طول سال استفاده می‌شود، تقاضا- ساعتی (کل تقاضای ساعتی انتاریو بر حسب کیلووات ساعت) و متوسط قیمت- ساعتی (میانگین وزنی قیمت ساعتی به سنت کانادا/کیلووات ساعت. همچنین به عنوان قیمت انرژی ساعتی انتاریو (HOEP) شناخته می‌شود، میانگین دوازده قیمت تسویه بازار (MCP) تعیین شده در هر ساعت است. هر پنج دقیقه یک MCP جدید تنظیم می‌شود. میانگین‌ها با مقدار برق مصرفی در سراسر استان در هر ساعت وزن می‌شوند). این مجموعه داده در مجموعه داده kaggle^۸ قابل دسترسی می‌باشد.


۴-۳- معیار ارزیابی

مقایسه نتایج حاصل با استفاده معیار MSE ، $RMSE$ ، $MAPE$ و MAE صورت می‌گیرد و نحوه محاسبه این معیارها در رابطه ۲۱، ۲۲، ۲۳ و ۲۴ نشان داده شده است. MSE انحراف پیش‌بینی از داده‌های واقعی را اندازه‌گیری می‌کند.


$$MSE = \frac{1}{n} \sum_{i=1}^n (P_i - A_i)^2 \quad (21)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (P_i - A_i)^2} \quad (22)$$

$$MAPE = \frac{100}{n} \sum_{i=1}^n \frac{|P_i - A_i|}{P_i} \quad (23)$$



شکل ۳ سیگنال‌های مورد استفاده از مجموعه داده‌ها



شکل ۴ استخراج مولفه‌های ذاتی CPU usage

داده بار ساعتی مجموعه داده لندن برابر ۷ مولفه، بار (پیش‌بینی انرژی خورشیدی) PV مجموعه داده لندن برابر ۶ مولفه، بار ساعتی مجموعه داده IESO برابر ۷ مولفه و قیمت بار مصرفی به دلار کانادا از مجموعه داده IESO برابر ۸ مولفه استخراج شده است. مرحله سوم استفاده از الگوریتم تبدیل موجک گسسته برای تولید سیگنال‌های بیشتر و استخراج اجزاء فرکانس بالا و پایین تجزیه شود که محتوای فرکانس پایین سیگنال تقریب که آن را با A نشان می‌دهیم و محتوای فرکانس بالا جزئیات که آن را با D نشان داده شده است. برای مولفه مد ۸ استخراج شده مرحله قبلی الگوریتم تبدیل موجک اعمال می‌شود. در تبدیل موجک گسسته از موجک هار و تعداد لایه ۵ در نظر گرفته شده است. شکل ۵ و ۶ سیگنال‌های تقریب و جزئیات مولفه ذاتی ۱ و ۵ را نشان می‌دهد که برای نمونه آورده شده است

همانطور که شکل ۶ در مورد مولفه مود ذاتی پنجم نشان می‌دهد، در سطح‌های بالاتر سیگنال اصلی بیش‌تر صاف و هموار می‌شود، زیرا بخش تقریب بیشتر روی مؤلفه‌های کم‌فرکانس متمرکز می‌شود و روند کلی سیگنال را نمایش می‌دهد. در مقابل، بخش جزئیات در

مرحله دوم استخراج مولفه ذاتی سیگنال با استفاده از الگوریتم تجزیه و تحلیل حالت تجربی می‌باشد. سیگنال‌های استخراج شده از این الگوریتم در شکل ۴ آورده شده است.

همانطور که شکل ۴ نشان می‌دهد، ۹ مولفه ذاتی از سیگنال CPU usage استخراج شده است. جدول ۷ استخراج مولفه ذاتی سیگنال با استفاده از الگوریتم تجزیه و تحلیل حالت تجربی برای سایر سیگنال‌ها نشان می‌دهد.

همانطور که جدول ۷ نشان می‌دهد، تعداد مولفه مود ذاتی مجموعه


جدول ۷ استخراج مولفه ذاتی سیگنال با استفاده از الگوریتم تجزیه و تحلیل حالت تجربی

تعداد مولفه‌های مود ذاتی	مجموعه داده
۷	بار ساعتی مجموعه داده لندن
۶	بار (پیش‌بینی انرژی خورشیدی) PV مجموعه داده لندن
۷	بار ساعتی مجموعه داده IESO
۸	قیمت بار مصرفی به دلار کانادا از مجموعه داده IESO


برای هر مجموعه داده را نشان می‌دهد.

مرحله چهارم خوشه‌بندی بهینه شده با الگوریتم فراابتکاری که از الگوریتم بهینه سازی مگس میوه استفاده شده است. جدول ۹ پارامترهای مربوط به الگوریتم فراابتکاری مگس میوه با فاصله اقلیدسی بین نمونه‌ها آورده شده است. همانطور که شکل ۷ نشان می‌دهد، براساس خوشه‌بندی الگوریتم بهینه سازی مگس میوه


این سطح تقریباً فقط شامل مؤلفه‌های پرفرکانس و نویز سیگنال است. بنابراین با افزایش سطح تجزیه، سیگنال تقریب اطلاعات کلی و بلندمدت سیگنال را نگه می‌دارد، در حالی که سیگنال جزئیات تغییرات سریع و گذرای سیگنال را برجسته می‌سازد. با توجه به تعداد لایه‌ها و استخراج سیگنال‌های تقریب و جزئیات مؤلفه‌های مود ذاتی تعداد سیگنال‌ها برابر ۹۰ سیگنال ۲۵۰۰ نمونه می‌باشد. جدول ۸ تعداد کل سیگنال‌های تقریب و جزئیات مؤلفه‌های مود ذاتی



شکل ۵ سیگنال‌های تقریب و جزئیات مؤلفه مد ذاتی ۱



شکل ۶ سیگنال‌های تقریب و جزئیات مؤلفه مد ذاتی



شکل ۷ خوشه‌بندی بهینه شده با الگوریتم فرا ابتکاری با الگوریتم بهینه سازی مگس میوه بین نمونه‌ها

جدول ۱۱ تحلیل واریانس آزمون آنوا برای هر خوشه دوم

تغییرات	SS	Df	MS	F	Prob>F
بین گروهی	۸۲۷۰۴٫۹	۹۹۹	۸۲٫۷۸۷۷	۷٫۱	5.928e-300
درون گروهی (خطا)	۲۳۳۱۱٫۲	۲۰۰۰	۱۱٫۶۵۵۶	-	-
کل	۱۰۶۰۱۶	۲۹۹۹	-	-	-

خوشه اول و دوم را نشان می‌دهد.

شکل ۷ خوشه‌بندی با الگوریتم مگس میوه برای نمونه‌ها برای همگراشدن تابع هدف و مراکز و تعداد خوشه‌ها را نشان می‌دهد.

جدول ۱۱ نتایج آزمون آنوا مربوط به خوشه دوم را ارائه می‌دهد. مقدار بسیار کوچک $\text{Prob} > F$ ($5.92e-300$) بیانگر معناداری بالای آزمون است. همچنین مقدار $F = ۷٫۱$ نشان می‌دهد که تفاوت میانگین سیگنال‌ها در بین گروه‌ها در مقایسه با درون گروه‌ها قابل توجه است. بنابراین، خوشه دوم نیز به طور آماری معنادار تشخیص داده شده و انتخاب آن در فرایند پیش‌بینی توجیه‌پذیر است. بعد از تحلیل آماری کمترین مقدار F مربوط به خوشه اول است. بنابراین این خوشه برای پیش‌بینی بار با آزمون آنوا انتخاب می‌شود. همچنین این خوشه دارای همبستگی معناداری با مقدار $2.84124e-30$ است ($P < ۰٫۰۱$). مرحله ششم استفاده از الگوریتم یادگیری عمیق انتقالی برای پیش‌بینی می‌باشد. جدول ۱۲ پارامترهای مورد نظر برای layers و options مدل یادگیری عمیق انتقالی را نشان می‌دهد.

شکل ۸ خروجی مدل پیش‌بینی کننده یادگیری عمیق یادگیری با توجه به سیگنال اصلی و سیگنال پیش‌بینی شده برای داده‌های آموزش و آزمایش را نشان می‌دهد.

نمونه‌ها به دو خوشه تقسیم شده که در خوشه ۱ تعداد ۸۵ سیگنال ۲۵۰۰ نمونه و خوشه ۲ تعداد ۵ سیگنال ۲۵۰۰ نمونه قرار گرفته است. مرحله پنجم انتخاب بهترین خوشه می‌باشد، بنابراین بر روی هر خوشه آزمون آنوا انجام می‌گیرد. جدول ۱۰ و ۱۱ تحلیل واریانس

جدول ۸ تعداد کل سیگنال‌های تقریب و جزئیات مولفه‌های مود ذاتی برای هر مجموعه داده

مجموعه داده	تعداد مولفه‌های مود ذاتی
بار ساعتی مجموعه داده لندن	۷۰
بار (پیش‌بینی انرژی خورشیدی) PV مجموعه داده لندن	۶۰
بار ساعتی مجموعه داده IESO	۷۰
قیمت بار مصرفی به دلار کانادا از مجموعه داده IESO	۸۰


جدول ۹ پارامترهای الگوریتم مگس میوه برای خوشه‌بندی بهینه شده با الگوریتم فرا ابتکاری نمونه‌ها

مقدار	نام پارامتر
۲۰	تعداد مگس‌ها
۱۰۰	تعداد تکرار
$\max(\text{data})$ بردار کمینه برای هر ویژگی	dataMax
$\min(\text{data})$ بردار بیشینه برای هر ویژگی	dataMin
به صورت تصادفی به مقدار مگس‌ها در هر خوشه	Flies (مقداردهی اولیه مگس‌ها)
حذف ابعاد Flies	مقداردهی اولیه بهترین راه‌حل

کمینه سازی جمع مربعات فاصله نقاط از مراکز خوشه‌ها

$$\min_n \sum_{i=1}^{n(\text{popSize})} (\text{data} - \text{squeeze}(\text{flies}(i)))^2$$

تابع هدف



شکل ۸ خروجی مدل یادگیری عمیق یادگیری با توجه به سیگنال اصلی و سیگنال پیش‌بینی شده برای داده‌های آموزش و آزمایش

جدول ۱۳ نتایج مدل یادگیری عمیق انتقالی با معیارهای ارزیابی

مجموعه داده	داده‌های آموزش			
	MSE	RMSE	MAPE	MAE
Google Cluster 2019				
مدل پیشنهادی	۰,۰۱۹۹۲۰	۰,۱۴۱۱۳۷	۰,۴۲۹۲۸۴	۰,۱۱۹۴۵۹
بدون خوشه‌بندی	۰,۰۵۱۳۲۵	۰,۲۲۶۵۵۱	۰,۶۱۷۷۰۰	۰,۱۷۹۷۷۷
داده‌های آزمون				
-	MSE	RMSE	MAPE	MAE
مدل پیشنهادی	۰,۰۳۵۵۷۰	۰,۱۸۸۶۰۰	۰,۶۴۶۰۱۲	۰,۱۶۴۷۲۲
بدون خوشه‌بندی	۰,۰۸۲۷۹۷	۰,۲۸۷۷۴۵	۰,۸۸۶۹۰۲	۰,۲۲۶۲۵۱

شکل ۹ تفاوت خوشه‌بندی با فرابتنکاری و بدون خوشه‌بندی را نشان می‌دهد.


همانطور که شکل ۹ و جدول ۱۳ نشان می‌دهد، استفاده از خوشه‌بندی و انتخاب ویژگی با الگوریتم فرابتنکاری (FFOA) (در حالت اول با ۸۵ سیگنال) منجر به کاهش قابل توجه خطاها و افزایش دقت مدل پیش‌بینی شده است.

در این حالت، مقادیر MSE، RMSE، MAPE و MAE همگی نسبت به حالت دوم کمتر هستند، که نشان‌دهنده اثربخشی خوشه‌بندی در حذف ویژگی‌های نامرتب و نویزی است. در مقابل، در حالت دوم که بدون خوشه‌بندی و انتخاب ویژگی انجام شده و از ۹۰ سیگنال مشتق شده به صورت مستقیم استفاده شده است، خطاها به طور محسوسی بیشتر هستند. این موضوع تأیید می‌کند که صرفاً داشتن تعداد بیشتر ویژگی (سیگنال)، بدون تحلیل و انتخاب بهینه، لزوماً منجر به دقت بالاتر نخواهد شد. جدول ۱۴ نتایج مدل یادگیری عمیق انتقالی با معیارهای ارزیابی برای سایر مجموعه داده‌ها را نشان می‌دهد.

همانطور که شکل ۸ نشان می‌دهد مدل یادگیری عمیق انتقالی با خطای کم توانسته مدل را پیش‌بینی نماید. جدول ۱۳ نتایج مدل یادگیری عمیق انتقالی با معیارهای ارزیابی را نشان می‌دهد.

جدول ۱۲ پارامترهای مدل یادگیری عمیق انتقالی مبتنی بر LSTM

پارامترهای مدل	مقدار
LSTM	
numHiddenUnits1	۱۲۸
numHiddenUnits2	۶۴
sequenceInputLayer	inputSize
lstmLayer	numHiddenUnits1
dropoutLayer	۰,۵
lstmLayer	sequenceInputLayer
trainingOptions	adam
MaxEpochs	۲۵۰
MiniBatchSize	۱۶
InitialLearnRate	۱e-۳
LearnRateDropPeriod	۵۰
LearnRateDropFactor	۰,۵
GradientThreshold	۱
Shuffle	every-epoch
Verbose	۰
Transfer_layers	
transfer_layers	lstmLayer1 & lstmLayer ۲
Transfer_options	
MaxEpochs	۲۵۰
MiniBatchSize	۱۶
InitialLearnRate	۱e-۳




شکل ۹ تفاوت خوشه بندی با فرا ابتکاری و بدون خوشه بندی

جدول ۱۴ نتایج مدل یادگیری عمیق انتقالی با معیارهای ارزیابی برای سایر مجموعه داده‌ها


مجموعه داده	مجموعه داده	مجموعه داده کل	مجموعه داده	مجموعه داده
معیار ارزیابی	پیش بینی بار لندن	پیش بینی توان (PV) لندن	تقاضای ساعتی انتاریو IESO	قیمت ساعتی برق IESO
MSE	۰,۰۹۱۹۶۲	۰,۰۳۳۶۳۲	۰,۰۸۱۴۸۷	۰,۲۵۵۱۱۰
RMSE	۰,۳۰۳۲۵۳	۰,۱۸۳۳۹۱	۰,۲۸۵۴۵۹	۰,۵۰۵۰۸۴
MAPE	۰,۶۴۴۰۲۸	۰,۳۵۴۱۰۴	۰,۹۹۰۵۵۹	۲,۹۲۸۷۹۸
MAE	۰,۲۱۵۳۴۱	۰,۱۴۳۷۱۶	۰,۲۲۴۲۱۰	۰,۳۸۲۸۱۸
MSE	۰,۱۰۱۱۵۶	۰,۱۶۷۹۹۶	۰,۱۷۴۷۴۹	۰,۱۷۳۰۷۷
RMSE	۰,۳۱۸۰۵۱	۰,۴۰۹۸۱۳	۰,۴۱۹۰۲۲۹	۰,۴۱۶۰۲۵
MAPE	۰,۶۸۷۶۰۳	۰,۷۹۵۰۸۸	۰,۹۰۰۲۳۹	۲,۷۷۷۹۶۷
MAE	۰,۲۹۸۸۲۳	۰,۳۰۲۴۰۷	۰,۳۳۴۵۹۶	۰,۳۲۸۹۳۹

همان‌طور که جدول ۱۴ نشان می‌دهد، عملکرد مدل پیشنهادی با استفاده از معیارهای MSE, RMSE, MAPE و MAE بر روی چندین مجموعه داده متنوع ارزیابی شده است. نتایج بیانگر آن است که مدل در داده‌های با رفتار پیوسته‌تر، به‌ویژه مجموعه داده پیش‌بینی انرژی خورشیدی لندن، کمترین میزان خطا را ثبت کرده و دقت بالایی از خود نشان داده است. در مقابل، بیشترین خطا مربوط به مجموعه داده قیمت ساعتی برق انتاریو بوده که به نوسانات شدید این داده‌ها نسبت داده می‌شود.


مقایسه نتایج با مجموعه داده Google-2019-Cluster نشان داد که مدل پیشنهادی در داده‌های آموزشی و آزمون عملکردی پایدار و با خطای پایین دارد که بیانگر توانایی تعمیم‌پذیری مناسب آن است. به‌طور کلی، تحلیل‌ها نشان می‌دهند که مدل در مواجهه با داده‌های دارای نوسانات محدود دقت بالاتری دارد، در حالی که در داده‌های نامنظم‌تر با کاهش نسبی دقت مواجه می‌شود. شکل ۱۰ تا ۱۳ نتایج پیش‌بینی مدل پیشنهادی را برای سایر مجموعه داده‌ها نمایش می‌دهد.




شکل ۱۰ نتیجه پیش‌بینی روش پیشنهادی با مدل یادگیری عمیق انتقالی برای مجموعه داده بار ساعتی مجموعه داده لندن



شکل ۱۱ نتیجه پیش‌بینی روش پیشنهادی با مدل یادگیری عمیق انتقالی برای مجموعه داده بار (پیش‌بینی انرژی خورشیدی) PV مجموعه داده لندن



شکل ۱۲ نتیجه پیش‌بینی روش پیشنهادی با مدل یادگیری عمیق انتقالی برای مجموعه داده بار ساعتی مجموعه داده IESO



شکل ۱۳ نتیجه پیش‌بینی روش پیشنهادی با مدل یادگیری عمیق انتقالی برای مجموعه داده قیمت بار مصرفی به دلار کانادا از مجموعه داده IESO

۴-۵- مقایسه و ارزیابی با سایر پژوهش‌ها

با توجه به مدل پیشنهادی و ارزیابی آن با همان روش با سایر مدل‌ها نشان داده است که عملکرد روش و مدل پیشنهادی بهتر عمل میکند و مقایسه با سایر مطالعات می‌تواند بر این امر گواه باشد. البته لازم به ذکر است که استفاده از تعداد نمونه‌ها از مجموعه داده‌ها در مقالات ممکن است با هم متفاوت باشد چون تعداد آن به صورت واضح بیان نشده است و ممکن است مقایسه نتایج را تحت تاثیر قرار دهد اما آنچه از نتایج بدست آمده از مقالات دریافت شده است مورد مقایسه قرار گرفته است. جدول ۱۵ روش پیشنهادی مجموعه داده google-2019-cluster با مقاله مشابه مورد بررسی قرار گرفته است.

همانطور که جدول ۱۵ نشان می‌دهد، مدل پیشنهادی و مدل BiGRU ارائه‌شده توسط دوگانی و همکاران [۱۴] را در دو مجموعه داده‌ی Google Cluster و Alibaba نشان می‌دهد. نتایج حاصل از سه معیار ارزیابی اصلی (MAE، MAPE و RMSE) بیانگر برتری معنادار مدل پیشنهادی نسبت به مدل مرجع هستند. برای نمونه، مقدار MAE مدل پیشنهادی در مجموعه داده Google برابر با ۰٫۱۶۴۷ شده، در حالی که همین معیار در مدل BiGRU

جدول ۱۵ بررسی روش پیشنهادی مجموعه داده google-2019-cluster با مقاله مشابه

مدل	مجموعه داده	RMSE	MAPE	MAE
Gated-Recurrent Unit (BiGRU)	Google cluster	۳٫۱	۱۵٫۴	۲٫۸
	Alibaba	۳٫۹	۱۰٫۴	۳٫۱
مدل پیشنهادی (EMD-DWT-FFOA Clustering- Deep Transfer Learning with LSTM)				
	Google cluster	۰٫۱۸۸۶۰	۰٫۶۴۶۰۱	۰٫۱۶۴۷۲
		۰	۲	۲

به ۲٫۸ می‌رسد. به‌طور مشابه، در سایر معیارها نیز کاهش چشمگیر خطاها مشاهده می‌شود. این نتایج مؤید آن است که بهره‌گیری از خوشه‌بندی بهینه مبتنی بر الگوریتم مگس میوه، تجزیه سیگنال (EMD-DWT)، و مدل یادگیری عمیق انتقالی مبتنی بر LSTM می‌تواند به‌صورت چشمگیری دقت پیش‌بینی را در داده‌های پیچیده و حجیم افزایش دهد. جدول ۱۶ روش پیشنهادی پیش‌بینی انرژی خورشیدی در لندن و پیش‌بینی بار مصرفی لندن با مقاله مشابه مورد بررسی قرار گرفته است.

جدول ۱۶ بررسی روش پیشنهادی پیش‌بینی انرژی خورشیدی در لندن و پیش‌بینی بار مصرفی لندن با مقاله مشابه

مدل	مجموعه داده	MSE	RMSE	MAPE	MAE
(SVR, LSTM, and CNN-GRU) چارچوب تلفیقی پیش‌بینی	منطقه لندن (پیش‌بینی بار)	۱٫۰۳۴۲	۱٫۰۱۶۹	۰٫۱۷۷۲	۰٫۷۴۶۸
	منطقه لندن (پیش‌بینی توان فتوولتائیک)	۰٫۲۰۳۲	۰٫۴۵۰۷	۰٫۳۱۱۴	۰٫۲۴۱۶
	منطقه لندن (پیش‌بینی بار)	۰٫۱۰۱۱۵۶	۰٫۳۱۸۰۵۱	۰٫۶۸۷۶۰۳	۰٫۲۹۸۸۲۳
مدل پیشنهادی (EMD-DWT-FFOA Clustering- Deep Transfer Learning with LSTM)					
	منطقه لندن (پیش‌بینی توان فتوولتائیک)	۰٫۱۶۷۹۹۶	۰٫۴۰۹۸۷۱۳	۰٫۷۹۵۰۸۸	۰٫۳۰۲۴۰۷

جدول ۱۷ بررسی روش پیشنهادی قیمت ساعتی برق در انتاریو با مقالات مشابه

مدل	مجموعه داده	MSE	RMSE	MAPE	MAE
Dwarf Mongoose Optimization Algorithm (DMOA)	قیمت برق (IESO)	۶,۲۳	۵,۲۳	۳,۸۵	۵,۴۶
XGBoost	قیمت برق (IESO)	۱۵,۶۶	۹,۲۵	۴۰,۹۰	۳,۷۴
EMD-DWT- FFOA Clustering- Deep Transfer Learning with LSTM)	قیمت برق (IESO)	۰,۱۷۳۰۷۷	۰,۴۱۶,۲۵	۲,۷۷۷۹۶۷	۰,۳۲۸۹۳۹

مقایسه با دو روش دیگر به دست آورده است. به طور مشخص، کاهش قابل توجه RMSE و MSE نسبت به مدل DMOA (به ترتیب ۲۳,۵ و ۶,۲۳) و مدل XGBoost (به ترتیب ۲۵,۹ و ۱۵,۶۶) بیانگر دقت بالای روش پیشنهادی در مدل سازی نوسانات پیچیده قیمت برق است. این نتایج نشان می دهد که استفاده از رویکرد ترکیبی مبتنی بر تجزیه سیگنال و یادگیری عمیق انتقالی، نقش مؤثری در استخراج ویژگی های پنهان داده های زمانی و بهبود دقت پیش بینی ایفا می کند.

۵- نتیجه گیری

مصرف بالای انرژی در رایانش ابری، علاوه بر افزایش هزینه های عملیاتی، پیامدهای زیست محیطی قابل توجهی به همراه دارد و به یکی از چالش های اصلی این حوزه تبدیل شده است. از این رو، در این مقاله یک رویکرد ترکیبی مبتنی بر خوشه بندی بهینه شده و یادگیری عمیق انتقالی برای پیش بینی بار مصرفی انرژی در رایانش ابری ارائه شده است. نتایج ارزیابی نشان می دهد که به کارگیری خوشه بندی مبتنی بر الگوریتم فراابتکاری پیش از مرحله یادگیری، موجب کاهش معنادار خطا در معیارهای MSE، RMSE، MAPE و MAE شده و دقت پیش بینی را به طور چشمگیری افزایش داده است. روش پیشنهادی در مواجهه با داده های پیچیده و متغیر، پایداری و قدرت تعمیم بالاتری از خود نشان داده است. بررسی پنج مجموعه داده واقعی نشان می دهد که مدل در داده های دارای ساختار خوشه ای و الگوهای پایدار عملکرد بهتری دارد؛ به طوری که بهترین نتایج مربوط به مجموعه داده های PV و Google بوده است. در مقابل، داده های قیمت برق به دلیل نوسانات شدید، خطای پیش بینی بیشتری ایجاد کرده اند. در نهایت، ترکیب خوشه بندی بهینه، تجزیه سیگنال EMD-DWT و یادگیری انتقالی عمیق مبتنی بر LSTM، کمترین میزان خطا را در تمامی معیارها به دست آورده و برتری روش پیشنهادی را نسبت به پژوهش های پیشین در پیش بینی داده های پیچیده و حجیم رایانش ابری تأیید می کند.

همانطور که جدول ۱۶ نشان می دهد، عملکرد مدل پیشنهادی را در برابر مدل ترکیبی ارائه شده توسط ساینی و همکاران [۱۶] که از یک چارچوب تلفیقی شامل SVR، LSTM و CNN-GRU بهره می برد، در پیش بینی بار و توان خورشیدی منطقه لندن ارزیابی می کند. در پیش بینی بار، مدل پیشنهادی با کاهش قابل توجه در معیارهای خطا از جمله MAE (0.2988 در مقابل ۰,۷۴۶۸) و MSE (۰,۳۴۴۲ در مقابل ۱,۰۱۱) عملکرد دقیق تری را نسبت به مدل ساینی و همکاران [۱۶] ارائه داده است. همچنین در پیش بینی توان خورشیدی، مدل پیشنهادی نیز توانسته مقادیر پایین تری از خطا مانند RMSE (۰,۴۰۹۸ در مقابل ۰,۴۵۰۷) و MAPE (۰,۷۹۵۰ در مقابل ۰,۳۱۱۴) را ثبت کند، که نشان دهنده بهبود چشمگیر در دقت پیش بینی، به ویژه در داده های ناپایدار خورشیدی است. این نتایج مؤید آن است که ترکیب خوشه بندی بهینه شده با الگوریتم مگس میوه، تجزیه سیگنال (EMD-DWT)، و مدل یادگیری عمیق انتقالی مبتنی بر LSTM قادر است عملکرد مدل های کلاسیک و تلفیقی را در هر دو حوزه پیش بینی بار و توان خورشیدی به طور معناداری بهبود بخشد.

جدول ۱۷ روش پیشنهادی قیمت ساعتی برق در انتاریو با مقالات مشابه مورد بررسی قرار گرفته است.

همان طور که در جدول ۱۶ مشاهده می شود، عملکرد مدل پیشنهادی در پیش بینی قیمت برق (مجموعه داده IESO) (با دو روش مرجع شامل الگوریتم DMOA ارائه شده توسط آلمزروی و همکاران [۲۱] و الگوریتم XGBoost به کاررفته توسط الباهلی و همکاران [۲۵] مقایسه شده است. نتایج نشان می دهد که مدل پیشنهادی مبتنی بر ترکیب خوشه بندی بهینه با الگوریتم مگس میوه، تجزیه سیگنال EMD-DWT و یادگیری انتقالی عمیق مبتنی بر LSTM، در تمامی معیارهای خطا عملکرد برتری دارد. این مدل با ثبت مقادیر $MAE = ۰,۳۲۸۹$ ، $MAPE = ۲,۷۷۷۹$ ، $RMSE = ۰,۴۱۶۰$ و $MSE = ۰,۱۷۳۱$ ، کمترین میزان خطا را در

مراجع

- Eng. Sci. Technol. J., vol. 4, no. 6, pp. 341–356, 2023, doi: 10.51594/estj.v4i6.636.
- [16] V. K. Saini, A. S. Al-Sumaiti, and R. Kumar, “Data-driven net load uncertainty quantification for cloud energy storage management in residential microgrid,” *Electr. Power Syst. Res.*, vol. 226, Art. no. 109920, 2024, doi: 10.1016/j.epsr.2023.109920.
- [17] R. Heidarykian and C. Ababei, “HVAC energy cost minimization in smart grids: A cloud-based demand side management approach with game theory optimization and deep learning,” *Energy AI*, vol. 16, Art. no. 100362, 2024, doi: 10.1016/j.egyai.2024.100362.
- [18] Z. Yang, “Renewable energy management in smart grid with cloud security analysis using multi-agent machine learning model,” *Comput. Electr. Eng.*, vol. 116, Art. no. 109177, 2024, doi: 10.1016/j.compeleceng.2024.109177.
- [19] B. Predic et al., “Cloud-load forecasting via decomposition-aided attention recurrent neural network tuned by modified particle swarm optimization,” *Complex Intell. Syst.*, vol. 10, pp. 2249–2269, 2024, doi: 10.1007/s40747-023-01265-3.
- [20] P. Li and J. Cao, “Virtual machine consolidation with multi-step prediction and affinity-aware technique for energy-efficient cloud data centers,” *Comput. Mater. Continua*, vol. 76, no. 1, pp. 81–105, 2023, doi: 10.32604/cmc.2023.039076.
- [21] A. A. Almazro and N. Ayub, “Multi-task learning for electricity price forecasting and resource management in cloud-based industrial IoT systems,” *IEEE Access*, vol. 11, pp. 54280–54295, 2023, doi: 10.1109/ACCESS.2023.3280857.
- [22] M. Thirunavukkarasu, D. S. G. Phanish Chandra, and G. Sai Rahul, “Electricity price forecasting for cloud computing using machine learning model,” *Int. J. Sci. Res. Eng. Manag.*, vol. 7, no. 5, pp. 1–5, 2023, doi: 10.55041/IJSREM21372.
- [23] D. G. Rosero, N. L. Díaz, and C. L. Trujillo, “Cloud and machine learning experiments applied to the energy management in a microgrid cluster,” *Appl. Energy*, vol. 304, Art. no. 117770, 2021, doi: 10.1016/j.apenergy.2021.117770.
- [24] B. Hrnjica and A. Danandeh Mehr, “Energy demand forecasting using deep learning,” in *Smart Cities Performability, Cognition, & Security*, 2020, pp. 71–104, doi: 10.1007/978-3-030-14718-1_4.
- [25] S. Albahli, M. Shiraz, and N. Ayub, “Electricity price forecasting for cloud computing using an enhanced machine learning model,” *IEEE Access*, vol. 8, pp. 1–12, 2020, doi: 10.1109/ACCESS.2020.3035328.
- [26] T. Deepika and P. Prakash, “Power consumption prediction in cloud data center using machine learning,” *Int. J. Electr. Comput. Eng.*, vol. 10, no. 2, pp. 1524–1532, 2020, doi: 10.11591/ijece.v10i2.pp1524-1532.
- [27] C. F. J. Wu and M. Hamada, *Experiments: Planning, Analysis, and Optimization*. Hoboken, NJ, USA: Wiley, 2021, doi: 10.1002/9781119470007.
- [28] M. Iman, H. R. Arabnia, and K. Rasheed, “A review of deep transfer learning and recent advancements,” *Technologies*, vol. 11, no. 2, Art. no. 40, 2023, doi: 10.3390/technologies11020040.
- [29] Q. Zhu, C. Wang, W. Jin, J. Ren, and X. Yu, “Deep transfer learning based on LSTM model for reservoir flood forecasting,” *Int. J. Data Warehous. Min.*, vol. 20, no. 1, pp. 1–17, 2023, doi: 10.4018/IJDWM.338912.
- [1] M. Chiregi and N. J. Navimipour, “Cloud computing and trust evaluation: A systematic literature review of the state-of-the-art mechanisms,” *J. Electr. Syst. Inf. Technol.*, vol. 3, no. 3, pp. 608–622, 2018, doi: 10.1016/j.jesit.2017.09.001.
- [2] V. K. Damera, A. Nagesh, and M. Nagaratna, “Trust evaluation models for cloud computing,” *Int. J. Sci. Technol. Res.*, vol. 9, no. 2, pp. 1964–1971, 2020.
- [3] A. Agashe, S. Pande, and R. C. Jaiswal, “A survey paper on cloud computing and migration to the cloud,” *J. Emerg. Technol. Innov. Res.*, vol. 9, no. 10, pp. 258–265, 2022.
- [4] S. S. Panwar, M. M. S. Rauthan, V. Barthwal, N. Mehra, and A. Semwal, “Machine learning approaches for efficient energy utilization in cloud data centers,” *Procedia Comput. Sci.*, vol. 235, pp. 1782–1792, 2024, doi: 10.1016/j.procs.2024.04.169.
- [5] A. Singh and K. Chatterjee, “UStTrust: A user and service trust evaluation model for cloud computing environment,” *Int. J. Comput. Intell. IoT*, vol. 2, no. 4, pp. 771–776, 2019.
- [6] A. Katal, S. Dahiya, and T. Choudhury, “Energy efficiency in cloud computing data centers: A survey on software technologies,” *Cluster Comput.*, vol. 26, pp. 1845–1875, 2023, doi: 10.1007/s10586-022-03713-0.
- [7] N. Gupta, K. Gupta, A. Singh, A. Kaur, and D. Gupta, “Cloud computing: A walk through in models, challenges, and energy solutions,” *IOP Conf. Ser.: Mater. Sci. Eng.*, vol. 1022, pp. 1–10, 2021, doi: 10.1088/1757-899X/1022/1/012070.
- [8] A. Mosavi and A. Bahmani, “Energy consumption prediction using machine learning: A review,” *Preprints*, vol. 11, pp. 1–61, 2019, doi: 10.20944/preprints201903.0131.v1.
- [9] S. Saxena, K. M. Zubair, R. Singh, A. Agarwal, and P. Pramanik, “Clustering-based prediction for VM workload in green computation,” *Educ. Adm.: Theory Pract.*, vol. 30, no. 5, pp. 9657–9666, 2024, doi: 10.53555/kuey.v30i5.2585.
- [10] A. A. Khan and M. Zakarya, “Energy, performance and cost efficient cloud datacentres: A survey,” *Comput. Sci. Rev.*, vol. 40, Art. no. 100390, pp. 1–31, 2021, doi: 10.1016/j.cosrev.2021.100390.
- [11] K. Zhang, W. Guo, J. Feng, and M. Liu, “Load forecasting method based on improved deep learning in cloud computing environment,” *Sci. Program.*, pp. 1–11, 2021, doi: 10.1155/2021/3250732.
- [12] A. K. Yadav and M. L. Garg, “The issues of energy efficiency in cloud computing based data centers,” *Biosci. Biotechnol. Res. Commun.*, vol. 12, no. 2, pp. 1–10, 2019, doi: 10.21786/bbrc/12.2/35.
- [13] X. Wang, H. Wang, B. Bhandari, and L. Cheng, “AI-empowered methods for smart energy consumption: A review of load forecasting, anomaly detection and demand response,” *Int. J. Precis. Eng. Manuf.-Green Technol.*, vol. 11, pp. 963–993, 2024, doi: 10.1007/s40684-023-00537-0.
- [14] J. Dogani, F. Khunjush, and M. Seydali, “Host load prediction in cloud computing with discrete wavelet transformation and bidirectional gated recurrent unit network,” *Comput. Commun.*, vol. 198, pp. 157–174, 2023, doi: 10.1016/j.comcom.2022.11.018.
- [15] A. O. Aderibigbe et al., “Enhancing energy efficiency with AI: A review of machine learning models in electricity demand forecasting,”

پاورقی‌ها:

⁵ cluster data sets from Google

⁶ <https://www.kaggle.com/datasets/derrickmwiti/google-2019-cluster-sample>

⁷ <https://www.renewables.ninja/downloads>

⁸ <https://www.kaggle.com/datasets/jacobsharples/ontario-electricity-demand>

¹ Approximation

² Details

³ within

⁴ Between(Error)