

Energy Management of Smart Buildings Using Graph Neural Network

Fariba Joorghanian, Omid Akbari*

Department of Electrical and Computer Engineering, Tarbiat Modares University, Tehran, Iran.

E-mails: f.joorghanian@modares.ac.ir; o.akbari@modares.ac.ir

Short Abstract

Buildings account for a significant portion of global energy consumption, with HVAC, lighting, water pumping, and other building-related energy requirements contributing to a considerable fraction of energy consumption. As the demand for energy continues to escalate and concerns about primary energy sources grow, effective energy management in buildings has become a crucial challenge. To tackle this issue, machine learning algorithms have been widely used for predicting building energy consumption. However, these algorithms often overlook the interdependence and impact of different building zones. In this article, we propose a graph convolutional network (GCN) approach for predicting energy consumption in smart buildings. The proposed method effectively models the energy consumption pattern in different zones of a building and considers the influence of neighboring zones. We evaluated the GCN model using the CU-BEMS dataset, which includes energy consumption data from various zones of a 7-story building. The experimental results demonstrate that the proposed GCN method can predict the energy consumption of a specific floor with 5 zones, for only 0.6 of mean squared error (MSE).

Keywords

Smart buildings, building energy management, energy consumption prediction, graph neural networks, energy efficiency.

1- Short Introduction

To achieve sustainable environments, efficient energy management in buildings is critical, as they account for a large share of energy use and CO₂ emissions. Accurate energy consumption prediction is key to reducing this impact. While machine learning (ML) models offer advantages over physics-based models by learning complex relationships with higher accuracy and fewer inputs, their design and interpretation can be complex, and current methods fall short for intricate building structures. To address this, a novel Graph Convolutional Network (GCN)-based model is introduced, utilizing a graph representation to consider interactions between multiple building zones, providing a promising solution for predicting energy consumption in complex buildings.

2- Proposed Work and Methodology

The present study proposes a novel method for accurately predicting the energy consumption of complex buildings through a two-stage process. The first stage involves dividing buildings into zones and constructing a graph to describe the internal features and relationships between zones. The second stage employs a Graph Convolutional Network (GCN) model to predict the energy consumption of each zone by learning hidden energy consumption patterns in the graph. This method is particularly effective in modeling subtle energy consumption patterns resulting from complex interactions between different areas in the building. To create a graph of complex buildings, a graphical approach is proposed. The building is divided into zones, each of which is described by features such as energy consumption, temperature, and humidity. A graph is used to represent the relationships between these zones, with nodes representing the zones and directed edges representing connections between them. The graph is obtained using node feature vectors, edge index vectors, and edge feature vectors. After obtaining the graphical representation of the building, a GCN model is created to predict the building's energy consumption. The model is trained by minimizing the Mean Squared Error (MSE) loss function between predicted and actual energy consumption values (labels). The proposed method's performance is evaluated on a public dataset, CU-BEMS, and the results demonstrate that the GCN model achieves lower MSE in both training and testing datasets.

3- Conclusion

This study proposes a graph convolutional network (GCN) model for predicting buildings energy consumption at the zone level, considering interactions and temperature gradient between zones. By transforming the zones into a graph representation, the model utilizes GCN to extract spatial representations and learn the temperature gradient between zones. The study highlights the importance of edge features in accurate energy consumption prediction. Results show that considering zone interactions and temperature gradient effects improves the model's performance in predicting energy consumption for multiple zones.

مدیریت انرژی ساختمان‌های هوشمند با استفاده از شبکه‌های عصبی گرافی

فریبا جورقانیان

دانشجوی کارشناسی ارشد معماری سیستم‌های کامپیوتری، دانشکده مهندسی برق و کامپیوتر، دانشگاه تربیت مدرس، تهران، ایران

امید اکبری

دانشیار، دانشکده مهندسی برق و کامپیوتر، دانشگاه تربیت مدرس، تهران، ایران

چکیده

ساختمان‌ها نقش مهمی در مصرف انرژی جهانی دارند و حدود یک سوم انرژی مصرفی آن‌ها از منابع انرژی اولیه تأمین می‌شود که شامل انرژی مصرفی برای گرمایش، تهویه و تبرید (HVAC)، روشنایی، پمپاژ آب و سایر نیازهای انرژی مرتبط با ساختمان است. با افزایش تقاضای انرژی و نگرانی‌های مربوط به منابع انرژی اولیه مانند نفت، گاز و زغال سنگ، و همچنین نیاز به حفظ آسایش ساکنین، مدیریت کارآمد انرژی در ساختمان‌ها به چالش بسیار مهمی تبدیل شده است. در همین راستا، الگوریتم‌های یادگیری ماشین به طور گسترده‌ای در پیش‌بینی مصرف انرژی ساختمان‌ها به کار می‌روند. این الگوریتم‌ها به طور عمومی توانایی پیش‌بینی مصرف انرژی کل ساختمان را دارند و قادر به پیش‌بینی مصرف انرژی هر ناحیه مستقل از یکدیگر نیستند، که منظور از ناحیه، هر بخشی از ساختمان است که سامانه مدیریت HVAC خود را داشته باشد. علاوه بر این، این الگوریتم‌ها اغلب ارتباط بین نواحی و تأثیر آن‌ها روی یکدیگر را نیز در نظر نمی‌گیرند. در این مقاله، یک رویکرد پیش‌بینی مصرف انرژی در ساختمان‌های هوشمند با استفاده از شبکه کانولوشن گرافی (GCN) ارائه شده است. در روش پیشنهادی، با مدل‌سازی یک ساختمان به صورت گراف، الگوی مصرف انرژی در نواحی مختلف آن ساختمان و همچنین تأثیر همسایگی این نواحی بر روی یکدیگر، به طور مؤثری در نظر گرفته می‌شوند. به منظور ارزیابی مدل GCN پیشنهادی، این روش با استفاده از مجموعه داده CUBEMS، که شامل مصرف انرژی نواحی مختلف یک ساختمان ۷ طبقه می‌باشد، آموزش داده شده است. نتایج آزمایش‌های انجام شده در این مقاله نشان می‌دهد که روش GCN پیشنهادی توانسته است در پیش‌بینی مصرف انرژی یک طبقه از ساختمان مورد نظر که دارای ۵ ناحیه است، تنها به میانگین مربع خطا (MSE) در حدود ۰.۶ منجر گردد.

کلمات کلیدی

ساختمان‌های هوشمند، مدیریت انرژی ساختمان، پیش‌بینی مصرف انرژی ساختمان، شبکه‌های عصبی گرافی، شبکه‌های کانولوشن گرافی، کارایی انرژی.

نام نویسنده مسئول: امید اکبری

ایمیل نویسنده مسئول: o.akbari@modares.ac.ir

تاریخ ارسال مقاله: ۱۴۰۲/۰۹/۰۱

تاریخ(های) اصلاح مقاله: ۱۴۰۲/۱۱/۱۵

تاریخ پذیرش مقاله: ۱۴۰۳/۰۲/۲۲

۱- مقدمه

مدیریت کارآمد انرژی ساختمان، یک جنبه حیاتی در راستای رسیدن به یک محیط ساختمان پایدار است. طبق آمار اخیر از سال ۲۰۲۳، ساختمان‌ها ۳۰٪ از مصرف انرژی و همچنین ۲۶٪ از تولید دی‌اکسید کربن جهانی را تشکیل می‌دهند [۱]. در نتیجه، کاهش مصرف انرژی در ساختمان‌ها به یک چالش مهم در کاهش مصرف انرژی جهانی تبدیل شده است.

از سوی دیگر، با توجه به تأثیرات قابل توجه محیط در میزان مصرف انرژی ساختمان‌ها، پیش‌بینی دقیق میزان مصرف انرژی نقشی حیاتی در فراهم نمودن امکان کاهش مصرف انرژی را ایفا می‌کند. از نظر دوره‌های زمانی مختلف، فرآیند پیش‌بینی مصرف انرژی به سه دسته تقسیم می‌شود [۲]: شامل پیش‌بینی کوتاه مدت (یک ساعت تا یک هفته) که به طور معمول برای بهینه‌سازی کنترل سامانه HVAC و پاسخ به تقاضا استفاده می‌شود؛ پیش‌بینی میان مدت (یک هفته تا یک سال) که برای مقایسه کارایی روش‌های مختلف کاهش انرژی مفید است؛ و پیش‌بینی بلندمدت (بیش از یک سال) که برای برنامه‌ریزی انرژی و تصمیم‌گیری‌های راهبردی به کار می‌رود. با این حال، به دلیل تعداد محدود مطالعات در زمینه پیش‌بینی بلندمدت، عمدتاً به دسته‌بندی پیش‌بینی مصرف انرژی بر اساس مقایسه زمانی ساعتی، روزانه و ماهانه اشاره شده است [۳].

علاوه بر جنبه زمانی، روش‌های استفاده شده برای پیش‌بینی‌های مصرف انرژی نیز جزو جنبه‌های قابل توجه در این فرآیند هستند. این روش‌ها به دو دسته کلی تقسیم می‌شوند: مدل‌های مبتنی بر ساختار فیزیکی ساختمان و مدل‌های مبتنی بر داده.

مدل‌های مبتنی بر ساختار فیزیکی ساختمان، به عنوان مدل‌های مهندسی یا مدل‌های جعبه سفید شناخته می‌شوند که از قوانین ترمودینامیک برای محاسبه انتقال حرارت در داخل و خارج ساختمان استفاده می‌کنند [۴، ۵]. ورودی‌های این مدل‌ها شامل عواملی مانند آب و هوا، موقعیت ساختمان، پوشش ساختمان، تعداد ساکنین، نور، تجهیزات، پارامترهای سامانه HVAC و برنامه‌های عملیاتی هستند. این مدل‌ها نیاز به دانش حرفه‌ای و تعداد زیادی پارامتر ورودی دارند که ممکن است منجر به طولانی شدن زمان محاسبه شود. همچنین در عمل، ذخیره‌سازی دقیق تمام پارامترهای ورودی چالش برانگیز است که باعث کاهش کاربرپذیری این مدل‌ها می‌شود [۶].

مدل‌های مبتنی بر داده که با نام مدل‌های جعبه سیاه نیز شناخته می‌شوند، از روش‌های محاسباتی متنوعی مانند تحلیل آماری و مدل‌های یادگیری ماشین استفاده می‌کنند تا الگوها را از داده‌های تاریخی استخراج کنند. در این حوزه، الگوریتم‌های ماشین بردار پشتیبان (SVM) [۷]، شبکه‌های عصبی مصنوعی

و نقش مهم آن در برنامه‌ریزی و عملکرد سامانه‌های برق پرداخته شده است. با این حال، پیش‌بینی میزان تولید برق در مدت زمان کوتاه در مورد انرژی‌های تجدیدپذیر، به دلیل نوسان و ناپیوستگی توان خروجی و تغییرات پویای آن با گذشت زمان که ناشی از شرایط آب و هوای محلی است، یک چالش مهم می‌باشد. برای درک ویژگی‌های مکانی-زمانی، این مقاله یک روش جدید مبتنی بر GCN و حافظه طولانی کوتاه مدت (LSTM) برای پیش‌بینی میزان تولید برق در مدت زمان کوتاه ارائه می‌دهد. به طور خاص، GCN برای یادگیری ارتباط مکانی پیچیده بین منابع انرژی تجدیدپذیر مجاور استفاده می‌شود و LSTM برای یادگیری تغییرات پویای منحنی تولید برق استفاده می‌شود. نتایج شبیه‌سازی‌ها نشان می‌دهد که روش ترکیبی پیشنهاد شده قادر است به خوبی ارتباط مکانی-زمانی انرژی‌های تجدیدپذیر را مدل کند.

در [۱۴]، یک شبکه عصبی بازگشتی کانولوشن گرافی (GCRNN) به عنوان یک مدل جدید برای مسئله پیش‌بینی بار کوتاه مدت (STLF) ارائه شده است که GCN و LSTM را ترکیب می‌کند تا به طور همزمان اطلاعات مکانی-زمانی را از کاربران با الگوهای مشابه مصرف استخراج کند. این مدل اطلاعات مکانی را از کاربران بدون اطلاع از موقعیت جغرافیایی آن‌ها و بدون وابستگی به متغیرهای محیطی اضافی به دست می‌آورد. نتایج تجربی نشان داده‌اند که در مقایسه با مدل‌های پایه، این مدل با بهبود ۹.۵٪ در میانگین درصد خطای مطلق، عملکرد بهتری را در پیش‌بینی بار دارد.

در [۱۵]، یک روش مبتنی بر GCN برای تخمین بار در مرحله طراحی اولیه ساختمان در سطح بلوک پیشنهاد شده است. بلوک یک بخش از ساختمان است که شامل چندین ناحیه می‌باشد. در این روش، ویژگی‌های ساختاری ساختمان‌ها استخراج شده و از آن‌ها برای برآورد دقیق بار در مرحله طراحی ساختمان استفاده شده است. سپس، الگوریتم CAM برای تعیین میزان تأثیرگذاری هر ویژگی ساختمان در خروجی مدل استفاده می‌شود. نتایج نشان می‌دهد که روش مبتنی بر GCN بالاترین دقت برآورد را در بین روش‌های معمول برای تخمین بار ساختمان دارد.

این مقالات که تمرکزشان بر مدیریت مصرف انرژی و شبکه کانولوشن گرافی است، در جدول ۱ مقایسه شده‌اند. در مقایسه با روش‌های پیشین، روش پیشنهادی قابلیت در نظر گرفتن تعاملات بین نواحی مختلف ساختمان، پیش‌بینی و بهینه‌سازی انرژی در سطح ناحیه و به کارگیری در انواع مختلف ساختمان‌ها را دارد.

بسیاری از روش‌های مبتنی بر داده، دو محدودیت قابل توجه را در استفاده از مدل‌های یادگیری ماشین برای پیش‌بینی مصرف انرژی ساختمان شناسایی کرده‌اند. نخست، مدل‌های کنونی تنها می‌توانند مصرف انرژی را در تنها یک ناحیه پیش‌بینی کنند. به عبارت دیگر، ساختمان را به عنوان یک تک ناحیه در نظر بگیرند که این محدودیت باعث محدود شدن قابلیت پیش‌بینی مصرف انرژی در چندین ناحیه به صورت همزمان می‌شود. دوم، این مدل‌ها فقط اثرات شرایط آب و هوایی و عوامل داخل یک ناحیه را در نظر می‌گیرند و نواحی مختلف روی یکدیگر را نادیده می‌گیرند.

برای حل این مشکلات، در این مقاله، برای نخستین بار یک مدل جدید یادگیری ماشین با استفاده از شبکه عصبی گراف (GNN) به نام شبکه کانولوشن گرافی (GCN) معرفی شده است. هدف از این مدل، پیش‌بینی مصرف انرژی ساختمان با در نظر گرفتن چندین ناحیه و تعاملات آن‌ها شامل اثرات پارامترهای داخلی هر ناحیه بر دیگر نواحی است. همچنین، استفاده از گراف به منظور توصیف ساختار ساختمان‌های پیچیده بسیار امیدوارکننده است.

الگوریتم GNN یک الگوریتم یادگیری قدرتمند است که می‌تواند دانش پنهان در داده‌های گراف پیچیده را یاد بگیرد. این الگوریتم قادر به استخراج اطلاعات ارزشمند از گراف است، که با یادگیری دانش پنهان در داده‌های گراف

(ANN) [۸] و شبکه‌های عصبی بازگشتی (RNN) [۹] نتایج قابل توجهی را به ارمغان آورده‌اند. در مقایسه با مدل‌های مبتنی بر ساختار فیزیکی، مدل‌های یادگیری ماشین با استفاده از تعداد کمتری پارامتر ورودی قادر به دست‌یابی به دقت بالاتری هستند. علاوه بر این، الگوی ورودی-خروجی داده‌ها باعث می‌شود این مدل‌ها کمتر به دانش کاربر درباره محیط ساختمان وابستگی داشته باشند. همچنین، این مدل‌ها قابلیت به‌روزرسانی مستمر با داده‌های آموزش جدید را دارند. با این حال، طراحی این مدل‌ها به دلیل مشکلات انتخاب ویژگی، طراحی مدل و تنظیم پارامترها، پیچیدگی بالایی دارد [۶]. همچنین، بسیاری از روش‌های موجود مبتنی بر داده برای پیش‌بینی مصرف انرژی ساختمان‌های با ساختار ساده هستند و برای ساختمان‌های با ساختار پیچیده مناسب نخواهند بود.

در [۱۰]، یک رویکرد جدید برای سیستم‌های مدیریت انرژی خانگی براساس طبقه‌بندی وظایف و تقاضای ساکنان مورد بررسی قرار گرفته است. چالش اصلی این بررسی به بهینه‌سازی برنامه‌های فعال‌سازی وظایف در محیط خانه، با در نظر گرفتن نیازهای ساکنان، محدودیت‌های دستگاه‌ها و زمان‌بندی استفاده از انرژی مرتبط می‌باشد. برنامه‌های فعال‌سازی وظایف در محیط خانه، به مجموعه‌ای از فعالیت‌ها یا برنامه‌هایی اشاره دارد که برای مدیریت بهینه مصرف انرژی و اجزای مختلف در یک خانه یا محیط خانگی طراحی می‌شوند. این بررسی با توسعه یک تابع کاربردی چندجمله‌ای مشتق شده از قانون کاهش کاربرد حاشیه‌ای که در تحلیل رفتار مصرف‌کنندگان و تولیدکنندگان در علم اقتصاد به کار می‌رود، به حل این چالش پرداخته است. این تابع امکان تنظیم کارایی هر وظیفه براساس ترجیحات شخصی ساکن را فراهم کرده و پیچیدگی مدیریت انرژی فردی در یک محیط خانگی را بررسی کرده است. همچنین، تبدیل مسئله به یک مسئله برنامه‌ریزی غیرخطی عدد صحیح مختلط و استفاده از نرم‌افزارهای تجاری، امکان مواجهه موفق با این نوع مسائل در یک زمان قابل قبول را فراهم کرده است. نرم‌افزارهای تجاری برای حل مسائل بهینه‌سازی و مسائل ریاضی پیچیده مورد استفاده قرار می‌گیرند.

در [۱۱]، یک الگوریتم ترکیبی هوشمند برای مدیریت مصرف برق خانگی با حضور خودروی برقی را معرفی می‌کند. در این الگوریتم، در گام اول، یک مدل برای مدیریت مصرف برق وسایل خانگی با هدف حداقل‌سازی هزینه خانوار و با در نظر گرفتن پارامتر رفاه ارائه شده است. سپس در گام دوم، برنامه پاسخگویی بار اضطراری (EDRP) و امکان تبادل انرژی بین خودروی برقی و شبکه برق مورد بررسی قرار گرفته است. در انتها و در گام سوم، مساله برنامه‌ریزی شارژ خودروی برقی به صورت تطبیقی و احتمالاتی بررسی شده است. نتایج نشان می‌دهد کاهش ۳۹٪ مصرف انرژی در مدیریت مصرف برق وسایل خانگی و زمان‌بندی بهینه شارژ خودروی الکتریکی امکان‌پذیر است.

در [۱۲]، به چالش استفاده بهینه از پنل‌های خورشیدی در ساختمان با اتصال به شبکه برق، به دلیل نوسانات برق و پراکندگی جغرافیایی، پرداخته شده است. پراکندگی جغرافیایی به معنای وجود تفاوت‌های منطقه‌ای در شرایط آب و هوا، شدت نور خورشید، ارتفاع، وضعیت زمین و سایر عوامل جغرافیایی است. این عوامل می‌توانند باعث تفاوت در تولید برق از پنل‌های خورشیدی در مناطق مختلف شوند. برای غلبه بر این مشکلات، یک سامانه مدیریت انرژی ساختمان مسکونی (REMS) با استفاده از شبکه عصبی کانولوشن (CNN)، رابطه غیرخطی بین توان پنل‌های خورشیدی و داده‌های هواشناسی را پیش‌بینی می‌کند. REMS شامل سه مرحله اصلی برای مدیریت انرژی است که شامل پیش‌بینی، برنامه‌ریزی و عملکرد واقعی است. نتایج نشان می‌دهد که مدل مبتنی بر CNN، توانایی مناسبی در کنترل و پیش‌بینی دارد. این روش با استفاده از داده‌های هواشناسی و برق مصرفی در زمان واقعی بررسی شده است. در [۱۳]، به پیش‌بینی دقیق انرژی خورشیدی و بادی در مدت زمان کوتاه

جدول ۱- مقایسه ویژگی‌های مقالات اخیر در حوزه مدیریت مصرف انرژی در ساختمان‌های هوشمند

مقاله مرجع	هدف اصلی	رویکرد مدیریت انرژی	در نظر گرفتن تعاملات بین نواحی مختلف ساختمان	قابلیت پیش‌بینی و بهینه‌سازی انرژی در سطح ناحیه
[۱۰]	بهینه‌سازی انرژی خانه هوشمند	استفاده از تابع چندجمله‌ای و برنامه‌ریزی غیرخطی عدد صحیح مختلط	خیر	خیر
[۱۱]	پیش‌بینی و بهینه‌سازی مصرف برق	استفاده از تابع مطلوبیت	خیر	خیر
[۱۲]	بهینه‌سازی انرژی ساختمان	استفاده از CNN	خیر	خیر
[۱۳]	پیش‌بینی کوتاه مدت انرژی تجدیدپذیر	مدل‌سازی با LSTM و GCN	خیر	خیر
[۱۴]	پیش‌بینی کوتاه مدت بار در خانه‌های مسکونی	مدل‌سازی با GCRNN	خیر	خیر
[۱۵]	تخمین بار در طراحی ساختمان	مدل‌سازی با GCN	بله	خیر
مدل پیشنهادی	پیش‌بینی انرژی ساختمان	مدل‌سازی با GCN	بله	بله

نواحی (ویژگی‌های گره)، GCN می‌تواند دانش پنهان در داده‌های گراف ساختمان‌های با ساختار پیچیده را یاد بگیرد و اطلاعات ارزشمند را از گراف استخراج کند.

روش ارائه شده مبتنی بر GCN برای پیش‌بینی مصرف انرژی ساختمان‌های هوشمند شامل دو مرحله اصلی می‌باشد:

• مرحله اول، شامل نمایش ساختمان‌های با ساختار پیچیده بر اساس گراف است که ممکن است ساختمان را به طبقاتی شامل چندین ناحیه تقسیم کند. در این بخش، گراف برای شرح و نمایش ویژگی‌های داخلی نواحی (مانند مصرف انرژی، دما، و رطوبت) و روابط آن‌ها با یکدیگر استفاده می‌شوند.

• در مرحله دوم، یک روش مبتنی بر GCN برای پیش‌بینی مصرف انرژی ساختمان‌های با ساختار پیچیده توسعه داده شده است. این روش می‌تواند دانش مخفی در داده‌های گراف ساختمان‌های با ساختار پیچیده را برای پیش‌بینی مصرف انرژی آن‌ها یاد بگیرد. به دلیل در نظر گرفتن ویژگی‌های هر ناحیه، عملکرد آن باید به طور قابل توجهی بالاتر از روش‌های متداول باشد.

نوآوری‌های این مقاله عبارتند از:


۱. ارائه یک روش جدید مبتنی بر گراف برای مدل‌سازی ساختمان‌های هوشمند که امکان تقسیم هر ساختمان پیچیده‌ای به چندین ناحیه را فراهم می‌کند و از گراف برای نمایش و تجزیه و تحلیل ویژگی‌های داخلی مانند مصرف انرژی، دما و رطوبت استفاده می‌کند.

۲. توسعه یک مدل GCN برای پیش‌بینی مصرف انرژی ساختمان‌های هوشمند با ساختار پیچیده که با در نظر گرفتن ویژگی‌های هر ناحیه، قادر به یادگیری الگوهای پنهان در داده‌های گراف ساختمان‌ها است.

۳. استفاده از وابستگی‌های پیچیده بین نواحی مختلف در ساختمان که روش پیشنهادی را قادر می‌سازد تا به طور جامع و دقیق وابستگی‌های پیچیده بین نواحی مختلف در ساختمان را درک کرده و از آن برای پیش‌بینی مصرف انرژی و بهبود عملکرد ساختمان‌های با ساختار پیچیده استفاده نماید. بر اساس نتایج آزمایش‌های انجام شده در این مقاله، روش پیشنهاد شده

با موفقیت استفاده شده است. با این حال، طبق بررسی انجام شده، هیچ تحقیقی وجود ندارد که چگونگی نمایش ساختمان‌های با ساختار پیچیده در سطح ناحیه را با استفاده از گراف نشان دهد. علاوه بر این، یک چارچوب کلی برای استفاده از GNN جهت پیش‌بینی مصرف انرژی ساختمان‌های با ساختار پیچیده در سطح ناحیه نیز وجود ندارد [۱۵].

در این مطالعه از GCN به عنوان یکی از معتبرترین انواع شبکه‌های عصبی گرافی استفاده شده است که دقت پیش‌بینی و تفسیرپذیری بسیار خوبی دارد. زیرا مسأله مدیریت انرژی ساختمان از طریق پیش‌بینی میزان مصرف انرژی اساساً یک مسأله رگرسیون است، به این معنی که هدف محاسبه و پیش‌بینی میزان مصرف انرژی بر اساس ورودی‌های مختلف است. به همین منظور، یک مدل برای پیش‌بینی یک متغیر پیوسته ایجاد شده است. در اینجا، مقادیر پیوسته به متغیرهایی اشاره دارد که مقادیر آن‌ها می‌تواند به صورت پیوسته و مداوم تغییر کند. این مقادیر از داده‌های سری زمانی مصرف انرژی ساختمان‌ها است که به عنوان ورودی‌های مدل شبکه عصبی گرافی استفاده می‌شوند. استفاده از گراف در این مسأله به دلیل وجود اتصالات و وابستگی‌های پیچیده بین داده‌ها بسیار نوید بخش است. زیرا ساختمان‌ها و سیستم‌های انرژی دارای ساختار گرافی هستند که شامل رابطه‌ها و وابستگی‌های پیچیده بین اجزاء مختلف است. بنابراین، از طریق نمایش داده‌ها به صورت گراف، می‌توانیم این وابستگی‌ها و ارتباطات را به خوبی درک کرده و از این اطلاعات برای پیش‌بینی دقیق‌تر و بهتر استفاده کنیم. به طور خاص، شبکه GCN مناسب برای استفاده در مسائل رگرسیون است زیرا قادر است اطلاعات مربوط به ساختار گراف را درک کرده و از آن برای پیش‌بینی مقادیر پیوسته استفاده کند. توانایی GCN در درک ساختار محلی و اتصالات گراف و نمایش اطلاعات مهم از محیط هر گره، که این ویژگی آن را برای وظایف طبقه‌بندی و رگرسیون گره مناسب می‌سازد. قابلیت تفسیرپذیری GCN امکان بررسی اهمیت گره‌ها و ویژگی‌ها را فراهم می‌کند و همچنین این شبکه قادر است پارامترهای یادگیری شده را بین گراف‌های مشابه منتقل کند. با استفاده از گراف برای نمایش ویژگی‌های داخلی



شکل ۱- یک مدل شبکه عصبی گرافی

۲-۲- کاربردهای شبکه‌های عصبی گرافی


GNN، در بسیاری از زمینه‌ها و وظایف مختلف مانند طبقه‌بندی گره‌ها، طبقه‌بندی گراف و پیش‌بینی گراف زمانی/مکانی کاربرد دارد. همچنین، در حوزه‌های بینایی ماشین، پردازش زبان طبیعی، سامانه‌های ترافیک، سامانه‌های پیشنهاددهنده و مسائل دیگر نیز به کار می‌رود. در سیستم‌های انرژی، GNN می‌تواند در تشخیص خرابی ترانسفورماتورها، پیش‌بینی سری زمانی بار و منابع انرژی تجدیدپذیر، و محاسبه جریان برق مورد استفاده قرار بگیرد. به عنوان مثال، با استفاده از GNN می‌توان روابط غیرخطی پیچیده بین داده‌های گاز حل شده و برچسب‌ها را در تشخیص خرابی ترانسفورماتورها استخراج کرد. همچنین، با استفاده از GNN و در نظر گرفتن عوامل خارجی مانند شرایط آب و هوایی، می‌توان پیش‌بینی دقیقی از تولید و مصرف برق در آینده ارائه داد. علاوه بر این، GNN می‌تواند در محاسبه جریان برق و توپولوژی شبکه برق نقش مؤثری داشته باشد [۱۹]. در کل، GNN در سیستم‌های انرژی به عنوان یک روش قدرتمند برای حل مسائل پیچیده و پیش‌بینی دقیق استفاده می‌شود.

۳-۲- شبکه‌های کانولوشن گرافی

GCN یک کلاس از شبکه‌های عصبی است که با داده‌های ساختار گرافی کار می‌کند. در شکل ۲، یک مدل از GCN نمایش داده شده است. در GCN، هدف یادگیری تابعی است که خروجی‌های سطح گره را تولید کند. این خروجی‌ها سپس می‌توانند برای وظایف مختلفی مانند طبقه‌بندی گره، پیش‌بینی یال و تحلیل سطح گراف استفاده شوند.

یک گراف $G = (V, E)$ ، که در آن V نشان دهنده مجموعه گره‌ها و E نشان دهنده مجموعه یال‌ها می‌باشد. برای هر گره $i \in V$ ، یک توصیف ویژگی x_i وجود دارد. این توصیف ویژگی‌ها می‌تواند به صورت ماتریس ویژگی $X \in R^{(N \times D)}$ نشان داده شوند، که در آن N تعداد گره‌ها و D بعد ورودی ویژگی‌ها است.

برای درک اطلاعات ساختاری گراف، ماتریس مجاورت $A \in R^{(N \times N)}$ استفاده می‌شود. ورودی‌های A حضور یا عدم حضور یال‌ها بین گره‌ها را کدگذاری می‌کنند که نشان دهنده اتصالات گراف هستند. به علاوه، در ماتریس مجاورت A ، برای هر گره‌ای که حداقل یک یال با آن وجود دارد، یک عنصر در قطر اصلی ماتریس قرار داده می‌شود. این عنصر، به عنوان ماتریس هویت شناخته می‌شود و مقدار آن برابر با ۱ است. ماتریس هویت یک ماتریس مربعی



شکل ۲- یک مدل شبکه کانولوشن گرافی

بر اساس GCN در پیش‌بینی مصرف انرژی ساختمان‌های با ساختار پیچیده عملکرد قابل قبولی دارد.

ادامه این مقاله به شرح زیر سازماندهی شده است: بخش ۲ پیش‌زمینه‌ای در مورد شبکه‌های عصبی گرافی و کاربردهای آن را ارائه می‌دهد. بخش ۳ به توضیح مدل پیشنهادی پرداخته است. بخش ۴ نتایج را ارائه کرده و بحثی درباره یافته‌ها ارائه می‌کند. در نهایت، در بخش ۵ مقاله به پایان می‌رسد.

۲- پیش‌زمینه و مدل‌سازی اجزا

در این بخش به بررسی پیش‌زمینه شبکه‌های عصبی گرافی، شبکه‌های کانولوشن گرافی و کاربردهای آنها پرداخته خواهد شد.


۱-۲- شبکه‌های عصبی گرافی

در یادگیری عمیق، روش‌های سنتی برای تجزیه و تحلیل داده‌های ساختار گراف کارآمد نیستند. به همین دلیل، شبکه‌های عصبی عمیق مبتنی بر گراف (GNN) برای تجزیه و تحلیل داده‌های ساختار گراف طراحی شده‌اند. در این مقاله، به توضیح گراف به عنوان یک مجموعه از گره‌ها و یال‌ها پرداخته شده است. مطابق شکل ۱، گره‌ها قسمتی از این مجموعه هستند که توسط یال‌ها به هم متصل شده‌اند. گراف می‌تواند جهت‌دار یا بدون جهت و وزن‌دار یا بدون وزن باشد. ماتریس لاپلاسیان گراف بدون جهت، به عنوان تفاضل بین یک ماتریس قطری از درجات گره‌ها و یک ماتریس مجاورت تعریف می‌شود. همچنین، ماتریس انتقال، احتمالات پویایی که بین گره‌های در حال انتشار در گراف وجود دارد را نمایش می‌دهد.

در یادگیری عمیق مبتنی بر گراف، وظایف را می‌توان به سه دسته آموزش تقسیم کرد: یادگیری نظارت شده بر گراف، یادگیری بدون نظارت بر گراف و یادگیری نیمه نظارت شده بر گراف [۱۶]. در یادگیری نظارت شده بر روی گراف، نمونه‌های دارای برچسب برای بهبود گرافی که برای وظایف یادگیری وظایف سطح پایین ایجاد شده است، استفاده می‌شوند. در یادگیری بدون نظارت مبتنی بر گراف، توابع خطا بر اساس اطلاعاتی استخراج شده از خود گراف، مانند ویژگی‌های گره‌ها و یال‌ها و توپولوژی گراف، تعریف می‌شوند. یادگیری نیمه نظارتی با سناریوهایی سروکار دارد که در آن تنها چند نمونه برچسب‌دار در اختیار قرار دارد و بقیه نمونه‌ها بدون برچسب هستند.

GNNها یک روش محبوب برای پیش‌بینی ویژگی‌های داده‌های ساختار گرافی هستند. انواع مختلفی از GNN وجود دارد که شامل GCN، GAT، GraphSAGE و MPNN می‌باشد. انتخاب نوع GNN مناسب برای هر مسئله، به نیازمندی‌های خاص آن مسئله بستگی دارد. GCN برای ساختارهای گراف همگن و تعریف شده به خوبی مناسب است، در حالی که GAT برای گراف‌های با درجات متفاوت اتصالات بهتر عمل می‌کند. GraphSAGE برای ساختارهای گراف با واریانس بالا کاربرد دارد و MPNN در گستره وسیعی از وظایف مبتنی بر گراف قابل استفاده است [۱۷، ۱۸].

در این مقاله، دلیل اصلی انتخاب شبکه‌های GCN برای وظایف پیش‌بینی، توانایی آن‌ها در درک ساختار محلی و اتصالات گراف است. با در نظر گرفتن گره‌های همسایه و روابط آن‌ها، شبکه‌های GCN می‌توانند به طور مؤثری نمایش‌هایی یاد بگیرند که اطلاعات مهم از محیط هر گره را در بر می‌گیرند، که این ویژگی آن‌ها را برای وظایف طبقه‌بندی و رگرسیون گره مناسب می‌سازد. علاوه بر این، با اضافه کردن لایه‌های متعدد، شبکه‌های GCN می‌توانند به تدریج ویژگی‌های پیچیده‌تری را یاد بگیرند که ارتباطات پیچیده بین گره‌ها را در نظر می‌گیرند. این ویژگی آن‌ها را به ابزار قدرتمندی برای وظایفی مانند پیش‌بینی ویژگی گره، که به درک تعامل بین گره‌ها در گراف نیاز دارند، تبدیل می‌کند.



شکل ۳- نمایش گرافیکی ساختار گراف نواحی یک ساختمان ۷ طبقه

دست‌یابی به پیش‌بینی دقیق و قابل اعتماد مصرف انرژی هستیم که می‌تواند در تصمیمات مهم مربوط به مدیریت و پایداری ساختمان مورد استفاده قرار گیرد. در ادامه به بررسی جزئیات ساختار گراف و شبکه عصبی پیشنهادی می‌پردازیم.

۳-۱- ساختار گراف ساختمان پیچیده

در این بخش، ما یک رویکرد نمایش گرافیکی برای پیش‌بینی دقیق مصرف انرژی ساختمان‌های پیچیده پیشنهاد می‌دهیم. گراف، که به عنوان $G = (V, E)$ نمایش داده می‌شود، یک ساختار داده ناقلیدسی است که توسط مجموعه‌ای از گره‌ها $v_i \in V = \{v_1, v_2, \dots, v_N\}$ و مجموعه‌ای از یال‌ها $e_{i,j} = (v_i, v_j) \in E$ نمایش داده می‌شود. ماتریس مجاورت $A \in R^{(N \times N)}$ ، اتصالات بین گره‌ها را نشان می‌دهد. ویژگی‌ها که اطلاعات عددی یا معنایی گراف را توصیف می‌کنند، معمولاً به گره‌ها، یال‌ها یا کل گراف اختصاص داده می‌شوند و به صورت ماتریس ویژگی‌ها ذخیره می‌شوند. شکل ۳ نمونه‌ای از نمایش گراف برای یک ساختمان پیچیده را نشان می‌دهد. رویکرد پیشنهادی بر اساس تقسیم ساختمان به چند ناحیه استوار است، که هر یک از این مناطق با مجموعه‌ای از عوامل ویژگی‌ها مانند انرژی، دما و رطوبت توصیف می‌شود. برای نمایش رابطه‌های پیچیده بین این نواحی، از گراف با گره‌هایی که نواحی را نمایش می‌دهند و یال‌های جهت‌دار که ارتباط بین دو ناحیه را نشان می‌دهند، استفاده می‌کنیم. برای به دست آوردن ویژگی‌های گراف، از سه نوع ماتریس استفاده می‌کنیم: ماتریس ویژگی‌ها، گره، ماتریس شاخص یال و ماتریس ویژگی‌ها. ماتریس ویژگی‌ها شامل عوامل ویژگی‌ها برای تمام گره‌های ناحیه است، در حالی که ماتریس شاخص یال یک ماتریس مجاورت است که اطلاعات رابطه بین نواحی را شرح می‌دهد. مطابق رابطه (۲)، مقدار عنصر در ماتریس شاخص یال برابر ۱۰۰ قرار می‌گیرد، اگر دو ناحیه متناظر دارای ارتباط باشند و در غیر این صورت برابر ۰۰۰ قرار می‌گیرد. ماتریس ویژگی‌ها یال (A) نیز ویژگی‌های یال‌ها را شامل می‌شود، مانند تفاوت دمای دو ناحیه.

است که در قطر اصلی آن، تنها یک عنصر با مقدار ۱ و در سایر جایگاه‌ها، عناصر با مقدار صفر قرار دارند. اضافه کردن حلقه به A ، تضمین می‌کند که در فرآیند گردآوری و تجمیع اطلاعات از همسایگان هر گره، ویژگی‌های آن گره نیز در نظر گرفته می‌شود. همچنین، اطلاعات همسایگان هر گره برای بهبود دقت پیش‌بینی‌ها نیز مورد استفاده قرار می‌گیرند. ایده اصلی در GCN این است که با استفاده از پارامترهای فیلتر به اشتراک گذاشته شده در تمام محل‌های گراف، عملیات کانولوشن بر روی ساختار گراف انجام شود که امکان را به GCN می‌دهد تا به طور موثر اطلاعات را از گره‌های همسایه جمع‌آوری و منتقل کند. قانون پخش برای هر لایه GCN در رابطه (۱) توصیف شده است [۲۰]:

$$H^{(l+1)} = \sigma(\hat{D}^{-\frac{1}{2}} \hat{A} \hat{D}^{-\frac{1}{2}} H^{(l)} W^{(l)}) \quad (1)$$

که در آن $H^{(l)} \in R^{(N \times F^{(l)})}$ خروجی لایه l ، تعداد ویژگی‌های لایه l ، $W^{(l)} \in R^{F^{(l-1)} \times F^{(l)}}$ ماتریس وزن خاص برای آن لایه، D ماتریس قطر عمق با $D_{ii} = \sum_j A_{ij}$ و $\sigma(\cdot)$ تابع فعال غیر خطی مانند ReLU است. با ترکیب چند لایه از قوانین پخش مشابه، GCN قادر به درک روابط وابستگی‌های پیچیده‌تر در ساختار گراف هستند. خروجی نهایی GCN یک ماتریس ویژگی‌ها سطح گره $Z \in R^{(N \times F)^R}$ است، که F تعداد ویژگی‌های خروجی مورد نظر برای هر گره را نشان می‌دهد. خروجی سطح گراف با تضمین عملکرد جمع‌شونده با استفاده از عملکردهای پولینگ قابل استخراج است.


شبکه‌های GCN چندین مزیت برای وظایف رگرسیون دارد. این شبکه از اطلاعات همسایگی محلی برای جمع‌آوری ویژگی‌های گره استفاده می‌کند و پارامترها را در تمام گره‌های گراف به اشتراک می‌گذارد که باعث بهبود کارایی محاسباتی آن می‌شود. GCN قابل توسعه است تا با ساختارهای گراف مختلف سازگار شود و قادر به دربرگیری ویژگی‌های یال، کنترل گراف‌های جهت‌دار و بدون جهت و سازگار شدن با انواع اندازه‌های گراف است. این شبکه قابلیت تفسیرپذیری را با امکان بررسی اهمیت گره‌ها و ویژگی‌ها فراهم می‌کند و قابلیت انتقال پارامترهای یادگیری شده بین گراف‌های مشابه را دارد.

۳-۲ مدل پیشنهادی

با توجه به چالش‌های مطرح شده در بخش پیشین، روش پیشنهادی ما به طور دقیق پیش‌بینی مصرف انرژی ساختمان‌های پیچیده را با استفاده از GCN هدف قرار داده است. این روش شامل دو مرحله اصلی است، مرحله اول شامل تقسیم ساختمان‌های پیچیده به چند ناحیه و استفاده از گراف برای توصیف ویژگی‌های داخلی این نواحی و روابط بین آن‌ها است. در مرحله دوم، یک مدل GCN آموزش داده شده است تا مصرف انرژی هر ناحیه در ساختمان را پیش‌بینی کند. این کار با یادگیری الگوهای پنهان انرژی در گراف‌ها انجام می‌شود که اجازه می‌دهد تا وابستگی‌های پیچیده بین نواحی مختلف در ساختمان درک شده و الگوهای مصرف انرژی ظریفی که از این تعاملات ناشی می‌شود مدل شود. با بهره‌گیری از قدرت شبکه‌های کانولوشن گرافی، ما قادر به

$$f(x) = \begin{cases} 0, & \text{zones } v_i \text{ and } v_j \text{ are not connected} \\ 1, & \text{zones } v_i \text{ and } v_j \text{ are connected} \end{cases} \quad (2)$$

ساختمان به هفت طبقه و هر طبقه به چند ناحیه تقسیم شده است که با ۳۳ گره در گراف متناظر هستند. ماتریس ویژگی‌ها گره X حاوی پارامترهای هر ناحیه است، مانند انرژی AC، که میزان انرژی الکتریکی که توسط سیستم تهویه مطبوع در هر ناحیه تولید شده است را نشان می‌دهد، انرژی Plugin، که میزان انرژی الکتریکی که توسط دستگاه‌های الکتریکی موجود در هر ناحیه مصرف شده است را نشان می‌دهد، دما و رطوبت. ماتریس شاخص یال A نشان می‌دهد که آیا دو منطقه مجاور هستند یا خیر، و ویژگی‌ها یال این گراف با استفاده از ماتریس ویژگی‌ها یال که شامل تفاضل دمای دو ناحیه است، شرح داده شده است.



شکل ۴- مدل شبکه کانولوشن گرافی به منظور پیش‌بینی مصرف انرژی ساختمان

شده‌اند و ارتباط بین گره‌ها بر اساس روابط مکانی آن‌ها تعیین می‌شود. اما هدف این است که در تعریف گره‌ها، از وزن یال‌ها نیز استفاده شود. در رابطه (۴)، گره‌ها بر اساس وزن‌های یال‌ها تعریف شده‌اند [۲۱]:

$$x_i' = W^T \sum_{j \in N(i) \cup \{i\}} \frac{e_{i,j}}{\sqrt{d_i d_j}} x_j \quad (4)$$

با توجه به ماتریس درجه $\hat{d}_i = 1 + \sum_{j \in N(i)} e_{i,j}$ که وزن گره‌ها را محاسبه می‌کند، $e_{i,j}$ وزن یال از گره مبدا i به گره هدف j را نشان می‌دهد. در این رابطه، وزن‌های یال‌ها برای تعیین ارتباط و تأثیر هر گره در همسایگان خود استفاده می‌شوند.

برای یادگیری نمایش کلی گراف، از GMP^2 به عنوان تابع pooling استفاده شده است. لایه‌ی pooling به منظور کاهش ابعاد و حجم داده‌های موجود و استخراج ویژگی‌های مهم‌تر از داده‌ها استفاده می‌شود. GMP برای هر بخش مشخصی از داده‌های ورودی، بزرگترین مقدار آن بخش را به عنوان خروجی انتخاب می‌کند. در مدل GCN، لایه pooling بیشترین مقدار هر ویژگی را در کل گراف به صورت رابطه (۵) محاسبه می‌کند [۲۲].

$$x_g = \max(x_{(R)_i}) \quad (5)$$

که در این رابطه، x_g نمایش کلی یک گراف و R تعداد لایه‌های Conv است. با اعمال عملیات جمع‌کننده‌ی بیشترین مقدار بر روی تمام نمایش‌های گره در گراف، بزرگترین ویژگی هر گره و همسایگان آن گره در نظر گرفته می‌شود. تابع pooling که در معادله (۴) توصیف شده است، به $x_{(R)_i}$ توجه دارد که نمایش i -امین گره در R -امین لایه Conv را نشان می‌دهد و بزرگترین ویژگی آن گره و همسایگانش را برای استفاده در لایه‌ی بعدی استخراج می‌کند. با اضافه کردن لایه FC پس از لایه pooling، مدل قادر است الگوها و وابستگی‌های پیچیده‌تری را در مصرف انرژی ساختمان شناسایی کند. این لایه با استفاده از نمایش کلی گراف و ویژگی‌های گره‌ها، قادر است برای هر گره و رابطه بین آن‌ها، روابط پیچیده‌تری را یاد بگیرد و برای پیش‌بینی مصرف انرژی دقیق‌تر عمل کند.

این مدل با کمینه کردن تابع هزینه MSE بین مصرف انرژی پیش‌بینی شده و واقعی، آموزش داده می‌شود. این تابع به صورت رابطه (۶) تعریف می‌شود [۱۵]:

۳-۲- مدل مبتنی بر GCN جهت پیش‌بینی انرژی ساختمان

پس از استخراج گراف ساختمان به عنوان داده ورودی، یک مدل GCN برای پیش‌بینی مصرف انرژی ساختمان ایجاد می‌شود. همان‌طور که در شکل ۴ نشان داده شده است، مدل GCN پیشنهادی شامل لایه‌های ورودی، ۲ لایه کانولوشن، هر کدام شامل دو لایه GCNConv، یک لایه pooling، یک لایه FC و لایه خروجی است.

برای پیش‌بینی مصرف انرژی ساختمان، با استفاده از GCN، به طور معمول از رابطه (۳) باید استفاده شود [۲۰]:

$$X' = \hat{D}^{-\frac{1}{2}} \hat{A} \hat{D}^{-\frac{1}{2}} X W \quad (3)$$

در این رابطه، X' حالت پنهان در لایه $\hat{A} = A + I$ ماتریس مجاورت با حلقه‌های خود^۱ است و به ما امکان می‌دهد تا در فرآیند پیش‌بینی، همسایگان هر گره را در نظر بگیریم و اطلاعات شباهت و ارتباط بین آن‌ها را بررسی کنیم. همچنین $\hat{D} = \sum_{j=0} \hat{A}_{ij}$ ماتریس درجه است که برای محاسبه وزن گره‌ها استفاده می‌شود و W ماتریس وزن است.

برای استفاده از GCN به منظور پیش‌بینی مصرف انرژی ساختمان، هر ساختمان به عنوان یک گره در گراف نشان داده می‌شود. ارتباطات بین گره‌ها بر اساس روابط مکانی آن‌ها بوده و با استفاده از ماتریس مجاورت A ، تعیین می‌شود. $A_{ij} = 1$ اگر نواحی i و j به صورت مکانی مجاور باشند و در غیر این صورت $A_{ij} = 0$ است. همچنین، با تعیین $A_{ij} = 1$ ، حلقه‌های آن به ماتریس مجاورت اضافه شده است، به این معنی که هر گره با خودش نیز ارتباط دارد.

در این مقاله از GCNConv برای پیاده‌سازی کانولوشن گراف بر روی ویژگی‌های هر ناحیه ساختمان به عنوان ورودی شبکه استفاده می‌شود که شامل ویژگی‌های مختلف ناحیه مانند مصرف انرژی، دما و رطوبت است. خروجی هر لایه از GCN، یک مجموعه جدید از ویژگی‌ها است که روابط بین نواحی همسایه را در بر دارد. تابع GCNConv وظیفه‌ی انتقال اطلاعات گره با اطلاعات گره‌ها و یال‌های مجاور را بر عهده دارد و با دریافت ورودی‌های گره، شاخص‌های یال و وزن‌های یال (ویژگی‌های یال)، بردار ویژگی به‌روزرسانی شده را به عنوان خروجی برمی‌گرداند.

در رابطه (۳) گره‌ها با استفاده از ماتریس مجاورت با حلقه‌های خود تعریف

² Global Max Pooling

¹ Adjacency Matrix with Self-Loops

۲. فرآیند آموزش: مدل با استفاده از بهینه‌ساز Adam آموزش داده شده است. Adam یک الگوریتم بهینه‌سازی برای بهبود عملکرد مدل و به روزرسانی پارامترها است.

۳. الگوریتم آموزش: در این الگوریتم، ابتدا داده‌ها به دسته‌های تصادفی تقسیم شده و سپس برای هر دسته، ماتریس‌های مجاورت گراف محاسبه می‌شود و با استفاده از عملکردهای کانولوشن و pooling، ویژگی‌های مورد نیاز استخراج می‌شود. سپس با استفاده از لایه FC، پیش‌بینی انجام شده و خطا محاسبه می‌شود. در نهایت، با استفاده از گرادیان خطا، پارامترهای مدل به روزرسانی می‌شود. این فرآیند برای هر دسته تکرار می‌شود تا به پایان دسته‌ها برسد. در نهایت، میانگین خطاهای گره‌ها و کل گراف محاسبه شده و به عنوان خروجی الگوریتم بازگردانده می‌شود.

۴. تقسیم داده: نمونه‌های داده به نسبت ۸۰ درصد برای آموزش و ۲۰ درصد برای تست تقسیم شده‌اند.

۵. داده ورودی: در این مدل، داده ورودی شامل یک دنباله از نمونه‌های داده است که در طول ۲۴ ساعت ثبت شده است. این نمونه داده‌ها در فواصل زمانی یک دقیقه‌ای قرار دارند. هر نمونه داده از مجموعه‌ای از ویژگی‌ها، مانند دما، رطوبت و کیفیت هوا تشکیل شده است. مدل سعی می‌کند بر اساس ویژگی‌های هر نمونه داده و نمونه‌های قبلی، وضعیت بعدی داده را پیش‌بینی کند.

۶. پارامترهای مدل: تعداد دوره‌های مورد نیاز و نرخ یادگیری^۵ در مدل به طور معمول بر اساس آزمایش‌ها و تجربیات قبلی تنظیم می‌شود. با توجه به آزمایش‌ها و تجربیات انجام شده در بخش ۴-۴، تعداد دوره را ۲۰۰ و نرخ یادگیری را ۰.۰۰۱ تنظیم کردیم. این مقادیر با توجه به اینکه در آزمایش‌های قبلی با استفاده از این مقادیر بهترین عملکرد را داشتیم و با توجه به منابع محاسباتی و پیچیدگی مدل، انتخاب شده‌اند.

۷. نرم‌افزار: توسعه برنامه با استفاده از زبان برنامه‌نویسی پایتون ۳.۱۱ و چارچوب PyTorch 2.1.0 انجام شده است.

۸. محیط شبیه‌سازی: شبیه‌سازی‌ها بر روی سیستم کامپیوتری دارای پردازنده مرکزی AMD Ryzen 5 4600G دارای ۱۲ هسته با فرکانس ۳.۷۰ گیگاهرتز، حافظه رم ۱۶ گیگابایت، و پردازنده گرافیکی AMD Radeon انجام شده است.

۳-۴- معیارهای ارزیابی

به منظور ارزیابی جامع عملکرد مدل پیشنهادی چندین معیار مختلف شامل RMSE، RMSE، MAE و امتیاز R^2 ارزیابی شده است، زیرا هر یک از این معیارها جنبه‌های مختلفی از دقت پیش‌بینی مدل را در بر می‌گیرند. MSE، خطای میانگین مربعات بین پیش‌بینی و مقدار واقعی را اندازه‌گیری می‌کند. این معیار به صورت رابطه (۷) محاسبه می‌شود [۱۵]:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y - \hat{y})^2 \quad (7)$$

RMSE ریشه میانگین خطا مربعی است که یک اندازه قابل تفسیرتر برای خطای متوسط است. این معیار به صورت رابطه (۸) محاسبه می‌شود [۱۵]:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (\hat{y} - y)^2}{n}} \quad (8)$$

MAE خطای مطلق متوسط بین پیش‌بینی و مقدار واقعی را اندازه‌گیری می‌کند. این معیار به صورت رابطه (۹) محاسبه می‌شود [۱۵]:

$$loss(y, \hat{y}) = \frac{1}{n} \sum_{i=1}^n (y - \hat{y})^2 \quad (6)$$

که y انرژی مصرف شده و $\hat{y}$ انرژی پیش‌بینی شده است. در ادامه، عملکرد مدل بر روی یک مجموعه داده عمومی از مصرف انرژی ساختمان ارزیابی می‌شود.

۴- شبیه‌سازی و مطالعه عددی

در این بخش به ارائه و تحلیل نتایج حاصل از آزمایش‌های انجام شده بر روی روش پیشنهادی می‌پردازیم. این روش با چندین معیار برای تحلیل دقت و قدرت پیش‌بینی مدل ارزیابی شده و تأثیر ابرپارامترها و ویژگی یال بر روی شبکه مورد بررسی قرار می‌گیرد.

۴-۱- مجموعه داده

داده‌های استفاده شده در این مطالعه مربوط به مجموعه داده‌های یک ساختمان هفت طبقه می‌باشد که در سال ۲۰۲۰ منتشر شده است [۲۳]. این مجموعه داده در فواصل زمانی یک دقیقه‌ای برای دوره ۱۸ ماهه از ۱ ژوئیه ۲۰۱۸ تا ۳۱ دسامبر ۲۰۱۹، جزئیاتی شامل مصرف برق و اندازه‌گیری‌های محیط داخلی یک ساختمان هفت طبقه در بانکوک، تایلند را در بر می‌گیرد.

این مجموعه داده به دلیل تجزیه و تحلیل مصرف برق سطح ساختمان به هر ناحیه و هر طبقه از ساختمان، منحصر به فرد است و برای کاربردهای مختلفی مانند پیش‌بینی بار، توسعه مدل حرارتی، اعتبارسنجی مدل شبیه‌سازی ساختمان و توسعه الگوریتم‌های پاسخ به تقاضا قابل استفاده است. ویژگی‌های هر ناحیه از یکی از طبقات ساختمان در جدول ۲ آمده است. آزمایشات ما به دلیل محدودیت‌های سخت افزاری تنها بر روی داده‌های یک طبقه از این ساختمان انجام شده است.

۴-۲- تنظیمات آزمایش

مشخصات مدل و تنظیمات آزمایش‌های انجام شده برای ارزیابی روش پیشنهادی عبارت است از:

۱. معماری مدل: مدل پیشنهادی شامل لایه‌های ورودی، دو لایه GCN با پولینگ سراسری، لایه‌های FC و لایه‌های dropout است. هر مجموعه از لایه‌های GCN ویژگی‌های مکانی را از داده ورودی استخراج می‌کند، سپس با پولینگ سراسری، بیشترین ویژگی‌ها را استخراج می‌کند. پس از آن، ویژگی‌های استخراج شده از طریق لایه‌های FC برای استخراج اطلاعات زمانی عبور می‌کنند، و سپس با لایه‌های dropout جلوگیری از بیش‌برازش^۳ صورت می‌گیرد.

جدول ۲- نمونه‌ای از ویژگی‌های یکی از طبقات ساختمان مورد

بررسی شامل ۴ ناحیه

ناحیه	مصرف برق (کیلو وات)	دما (درجه سلسیوس)	رطوبت نسبی (%)	نور محیط (lux)
۱	۵.۴	۲۳.۵	۷۲.۱	۲۷
۲	۵.۲	۲۳.۳	۷۱.۹	۲۹
۳	۵.۳	۲۳.۴	۷۲.۰	۲۸
۴	۵.۱	۲۳.۲	۷۱.۸	۳۰

^۵ Learning Rate

^۳ Overfitting

^۴ Epoch

دقیقه‌ای و به مدت ۲۴ ساعت نشان داده شده است. اما شبیه‌سازی‌های روش پیشنهادی به ازای داده‌های واقعی مصرف انرژی ساختمان طی ۷ ماه انجام شده است. لازم به ذکر است که تعداد داده‌ها در ۲۴ ساعت برابر با ۱۴۴۰ داده (شامل مصرف برق (کیلو وات)، دما (درجه سلسیوس)، رطوبت نسبی و نور محیط)، و در حدود ۷ ماه برابر ۲۹۴ هزار داده است. همان‌طور که در این نمودارها مشاهده می‌گردد، روش پیشنهادی کارایی مناسبی داشته است که برای طبقه‌ی شبیه‌سازی شده MSE در حدود ۰.۶ می‌باشد. برای تعداد دوره‌های مختلف، می‌توان این نتایج را به صورت دقیق تحلیل و عملکرد مدل را ارزیابی کرد:

۱. MSE نشان می‌دهد که میزان خطا وارده در پیش‌بینی‌های مدل چقدر است. مقادیر کمتر این معیار به معنی دقت بالاتر در پیش‌بینی است. بر اساس نتایج، مدل GCN در تعداد دوره ۲۰۰ با MSE برابر با ۰.۵۹ عملکرد خوبی داشته است.

۲. RMSE نشان می‌دهد که میانگین خطای مطلق پیش‌بینی‌های مدل چقدر است. همانند MSE، مقادیر کمتر این معیار به معنی دقت بالاتر در پیش‌بینی است. مدل GCN در تعداد دوره ۲۰۰ با RMSE برابر با ۰.۷۷ نشان داده است که پیش‌بینی‌های آن نزدیک به مقادیر واقعی هستند.

۳. MAE نشان‌دهنده میانگین خطای مطلق پیش‌بینی‌های مدل است، به این معنی که میانگین فاصله بین پیش‌بینی‌های مدل و مقادیر واقعی چقدر است. با توجه به نتایج، مدل GCN با MAE برابر با ۰.۴۳ در تعداد دوره ۲۰۰، عملکرد قابل قبولی داشته است. این به این معنی است که پیش‌بینی‌های مدل نسبتاً نزدیک به مقادیر واقعی بوده‌اند و دقت پیش‌بینی‌های آن بالاست.

۴. R^2 نشان می‌دهد که چه مقدار از واریانس متغیر هدف توسط مدل

$$MAE = \frac{1}{n} \sum_{i=1}^n |y - \hat{y}| \quad (9)$$


R^2 نشان دهنده درصد واریانس در متغیر هدف است. این معیار در بازه ۰ تا ۱ قرار دارد و با افزایش آن، دقت پیش‌بینی بالاتر است و به صورت رابطه (۱۰) محاسبه می‌شود [۱۵]:

$$R^2 = 1 - \frac{\sum_{i=1}^n (\hat{y} - y)^2}{\sum_{i=1}^n (y - \bar{y})^2} \quad (10)$$


به عبارت دیگر، MSE به دلیل رابطه توان دو MSE با اندازه خطا، به خطاهای بزرگ‌تر و داده‌های پرت حساس است و اهمیت کاهش این خطاها را در پیش‌بینی‌های مدل تأکید می‌کند. RMSE میانگین بزرگی خطاها را نشان می‌دهد تا بتوان درک بهتری از اندازه و انحراف خطاهای پیش‌بینی شده توسط مدل پیدا کرد. MAE نسبت به MSE و RMSE کمتر به داده‌های پرت حساس است و در حضور داده‌های پرت، قوی‌تر عمل می‌کند. امتیاز R^2 نیز یک معیار اندازه‌گیری خطاست که نشان می‌دهد چقدر متغیرهای مستقل توانایی توضیح تغییرات متغیر وابسته را دارند.

۴-۴- نتایج


نتایج مدل GCN نشان می‌دهد که این مدل در پیش‌بینی متغیر هدف عملکرد خوبی دارد. در شکل ۵، برای نمایش بهتر اختلاف مقادیر واقعی مصرف انرژی و پیش‌بینی شده، نمودار مصرف انرژی یک طبقه از ساختمان (شکل ۵-الف) شامل پنج ناحیه (شکل ۵-ب تا شکل ۵-و) به ازای فاصله‌ی زمانی ۱۰




(الف)




(ب)




(ج)



(د)



(ه)



(و)

شکل ۵- مقادیر واقعی و پیش‌بینی شده مصرف انرژی در (الف) یک طبقه از ساختمان، شامل پنج ناحیه (نمودارهای (ب) تا (و))

جدول ۳- مقایسه زمان شبیه‌سازی و نتایج مدل GCN پیشنهادی با تغییر تعداد طبقات

تعداد طبقات	MSE	RMSE	MAE	$R^2 score$	تعداد دسته	کانال‌های مخفی	تعداد نوروها	زمان شبیه‌سازی (دقیقه)
۱	۰.۵۹	۰.۷۷	۰.۴۳	۰.۹۸۹۰	۶۴	۳۲	۱۲۸	۱۵۷
۲	۰.۷۲	۰.۸۴	۰.۵۲	۰.۹۸۹۱	۱۲۸	۶۴	۱۰۲۴	۴۳۳
۳	۰.۴۱	۰.۶۴	۰.۳۸	۰.۹۹۳۱	۲۵۶	۱۲۸	۲۰۴۸	۱۴۱۵
۴	۰.۵۶	۰.۷۴	۰.۴۵	۰.۹۹۰۱	۲۵۶	۱۲۸	۲۰۴۸	۱۸۸۵
۵	۰.۴۶	۰.۶۷	۰.۳۹	۰.۹۹۱۸	۵۱۲	۲۵۶	۴۰۹۶	۶۶۷۸

و MAE با افزایش تعداد دوره‌ها کاهش می‌یابند، تا زمانی که در حدود ۲۰۰ دوره به حداقل خود برسند. برای دستیابی به عملکرد بهتر مدل، نیاز است تعداد دوره‌های لازم با استفاده از روش‌های بهینه‌سازی و جستجوی پارامترها تعیین شود. شکل ۶ نمایش‌دهنده نمودار مقادیر معیارهای MSE و MAE برای تعداد دوره‌های مختلف است.

جدول ۵- مقایسه معیارهای دقت بر اساس نرخ یادگیری

نرخ یادگیری	MSE	RMSE	MAE	$R^2 Score$
۰.۰۰۰۱	۰.۹۳	۰.۹۶۶	۰.۵۷	۰.۹۸۲۹
۰.۰۰۱	۰.۵۹	۰.۷۷	۰.۴۳	۰.۹۸۹۰
۰.۰۱	۵۴.۹۷۶	۷.۴۱	۵.۰۳	-۱.۷۱۷۹

شکل ۷ نمایش‌دهنده نتایج آزمایش برای نرخ یادگیری‌های مختلف است. در شکل ۷-الف) و (ب) مشاهده می‌شود که زمانی که نرخ یادگیری برابر با ۰.۰۰۱ تنظیم می‌گردد، هر دو معیار MSE و MAE به مقادیر حداقل خود نزدیک می‌شوند. بنابراین، طبق مقادیر معیارهای خطا در جدول ۵، نرخ یادگیری برابر با ۰.۰۰۱ تعیین شده است.

• تأثیر ویژگی یال

عملکرد مدل GCN در هر ناحیه با حذف ویژگی یال متفاوت است. برخی نواحی نشان‌دهنده کاهش قابل توجه عملکرد هستند، درحالی‌که برخی دیگر کاهش کمتری نشان دادند. نتایج به دست آمده که در نمودار شکل ۸ آمده است، نشان می‌دهند که وجود تفاوت‌های دما در بین نواحی، که از طریق یال با هم مرتبط هستند، باعث بروز تأثیرات گوناگون در رفتار یا ویژگی‌های مرتبط با مصرف انرژی در هر ناحیه می‌شود. به عبارت دیگر، تفاوت‌های دما باعث می‌شود که نواحی با یکدیگر تفاوت داشته باشند و نحوه پیش‌بینی مصرف انرژی در هر ناحیه به دلیل این تفاوت‌ها ممکن است متفاوت باشد.

عملکرد مدل GCN به طرز قابل توجهی هنگام حذف ویژگی یال تحت تأثیر قرار گرفته است. میانگین خطای تست در سطح گره برای هر ناحیه بدون ویژگی یال بیشتر بوده است که نشان می‌دهد ویژگی یال نقش بسیار حیاتی در پیش‌بینی مصرف انرژی دارد. همچنین، میانگین خطای تست در سطح گراف بدون ویژگی یال نیز بالاتر بوده است که اهمیت استفاده از این ویژگی را در مدل مورد تأکید قرار می‌دهد.

این نتایج اهمیت استفاده از ویژگی یال در مدل GCN برای پیش‌بینی مصرف انرژی ساختمان‌ها را نشان می‌دهند. علاوه بر این، اهمیت انتخاب و

پوشش داده شده است. این معیار بین ۰ و ۱ قرار می‌گیرد، و هرچه به ۱ نزدیک‌تر باشد، نشان‌دهنده عملکرد بهتر مدل است. بر اساس نتایج، مدل GCN در تعداد دوره ۲۰۰ با R^2 برابر با ۰/۹۸۹۱ عملکرد بسیار خوبی داشته است و حدود ۹۸.۹ درصد از واریانس متغیر هدف را توضیح داده است.

بر اساس نتایج جدول ۳، ابعاد ساختمان‌ها می‌تواند تأثیر قابل توجهی بر زمان شبیه‌سازی داشته باشد. بدیهی است که مدل‌های با تعداد دسته‌ها و نوروهای بیشتر زمان بیش‌تری برای شبیه‌سازی نیاز داشته‌اند. بهترین دقت پیش‌بینی (کمترین مقادیر MSE، RMSE و MAE، و بیشترین امتیاز R^2) به ازای تعداد طبقات برابر با ۳ و زمان شبیه‌سازی ۱۴۱۵ دقیقه رخ داده است. از این رو، افزایش طبقات یا ابعاد ساختمان‌ها می‌تواند منجر به افزایش تعداد گره‌ها و یال‌ها در گراف مربوط به ساختمان شود که این موضوع می‌تواند زمان شبیه‌سازی مدل شبکه عصبی گرافی را افزایش دهد. بنابراین، در صورت پیاده‌سازی بر روی یک ساختمان بزرگ‌تر، ممکن است نیاز به بهینه‌سازی الگوریتم‌ها و استفاده از روش‌های مقیاس‌پذیری برای مدیریت حجم بزرگ داده‌ها و گراف‌ها و همچنین بهینه‌سازی زمان اجرا باشد. در نتیجه مدل GCN با دقت بالا و خطای کم، الگوها و روابط زیربنایی داده‌های مربوط به مصرف انرژی ساختمان‌ها را به خوبی فراگرفته است.


• تأثیر ابرپارامترها

در این بخش، تأثیر ابرپارامترها بر عملکرد مدل پیشنهادی را بررسی می‌کنیم. به طور خاص، تعداد دوره‌های مرحله آموزش و نرخ یادگیری را در محدوده ۱۰۰ تا ۲۰۰ دوره با فاصله ۱۰ دقیقه و به ازای سه نرخ یادگیری مختلف (۰.۰۰۱، ۰.۰۰۱ و ۰.۰۰۰۱) تغییر داده و تأثیر آن‌ها بررسی می‌شود.

جدول ۴- مقایسه معیارهای دقت بر اساس تعداد دوره در آموزش

تعداد دوره	MSE	RMSE	MAE	$R^2 Score$	زمان آموزش (دقیقه)
۱۰۰	۰.۷۳	۰.۸۵	۰.۴۷	۰.۹۸۶۶	۸۶
۱۲۵	۱.۰۲	۱.۰۱	۰.۵۲	۰.۹۸۱۲	۱۰۱
۱۵۰	۰.۶۹	۰.۸۳	۰.۴۷	۰.۹۸۷۳	۱۳۰
۱۷۵	۰.۹۴	۰.۹۷	۰.۵۵	۰.۹۸۲۷	۱۴۳
۲۰۰	۰.۵۹	۰.۷۷	۰.۴۳	۰.۹۸۹۰	۱۵۷

نتایج به دست آمده برای مقادیر مختلف دوره و خطاهای مربع متوسط (MSE) و خطاهای مطلق میانگین (MAE) مربوط به آن‌ها در شکل ۶-الف) ارائه شده است. مطابق جدول ۴ نتایج نشان می‌دهد که مقادیر معیارهای MSE



شکل ۸- مقایسه تاثیر وجود/عدم وجود ویژگی یال بر روی مدل

نواحی، به ویژه ناحیه‌هایی که اهمیت ویژگی‌های یال در آن‌ها بیشتر است، نقش حیاتی در پیش‌بینی دقیق مصرف انرژی دارند و حذف آن‌ها باعث کاهش قابل توجه عملکرد مدل می‌شود.


با در نظر گرفتن تعاملات نواحی و تاثیر دما بر روی آن‌ها، روش پیشنهادی ما نتایج قابل اعتمادی در پیش‌بینی مصرف انرژی برای چندین ناحیه به دست آورده است. مدل پیشنهاد شده قابلیت بهینه‌سازی عملکرد HVAC بر اساس هر ناحیه را فراهم کرده است.

اختصارات انگلیسی


AC	Air Conditioning
ANN	Artificial Neural Networks
CAM	Class Activation Mapping Algorithm
CNN	Convolutional Neural Network
DA	Day-Ahead
FC	Fully connected
GAT	Graph Attention Networks
GCN	Graph Convolutional Network
GCRNN	Graph Convolutional Recurrent Neural Network
GMP	Global Max Pooling
GNN	Graph Neural Network
GraphSAGE	Graph Sampling and Aggregation
HVAC	Heating, Ventilation, and Air Conditioning
LSTM	Long Short-Term Memory
MAE	Mean Absolute Error
MSE	Mean Squared Error
MPNN	Message Passing Neural Networks
RNN	Recurrent Neural Network
RMSE	Root Mean Square Error
ROA	Robust Optimization Approach
RS	Robust-Stochastic
RT	Real-Time
REMS	Residential Energy Management System
SVM	Support Vector Machines
SP	Stochastic Programming
STLF	Short-Term Load Forecasting

علائم


گراف	G
گره	v
مجموعه گره‌ها	v_i
یال	E



شکل ۶- مقایسه تاثیر تعداد دوره بر روی معیارهای دقت



(الف)



(ب)

شکل ۷- مقایسه تاثیر نرخ یادگیری بر روی معیارهای دقت

(الف) معیار MSE (ب) معیار MAE

استفاده از ویژگی‌های مرتبط با یال‌ها در بهبود عملکرد مدل GCN را مورد تأکید قرار داده و برای تحقیقات آینده در این حوزه بینش‌های ارزشمندی ارائه می‌دهد.

۵- نتیجه‌گیری

در این مطالعه، یک مدل شبکه کانولوشن گرافی (GCN) برای پیش‌بینی مصرف انرژی ساختمان در سطح ناحیه با در نظر گرفتن تعاملات و تاثیر دمای بین این نواحی پیشنهاد شد. مدل پیشنهادی از شبکه‌های عصبی گرافی برای درک اثرات انتقال دما بین نواحی استفاده می‌کند، که امکان پیش‌بینی همزمان مصرف انرژی برای چندین ناحیه را فراهم می‌کند.

برای نمایش ساختار توپولوژیکی و ویژگی‌های مناطق، ما آن‌ها را به یک نمایش گراف تبدیل کردیم. گراف توسط یک ماتریس مجاورت، یک تنسور دوبعدی ویژگی گره، یک تنسور ویژگی یال و یک تنسور برجسب تعریف می‌شود. ماتریس مجاورت ارتباطات بین نواحی (گره‌ها) را نشان می‌دهد، درحالی‌که ماتریس ویژگی گره، شامل ویژگی‌های مختلفی از جمله انرژی AC، انرژی Plugin، دما، رطوبت، و نور می‌باشد. ماتریس ویژگی یال براساس تفاوت‌های دما بین گره‌های متصل به وسیله یال‌ها ساخته می‌شود و ماتریس برجسب مصرف انرژی کل در دقیقه برای هر ناحیه را نمایش می‌دهد. علاوه بر این، بررسی‌ها نقش حیاتی ویژگی‌های یال در پیش‌بینی دقیق مصرف انرژی را نشان می‌دهد. علاوه بر این، نتایج نشان می‌دهند که ویژگی‌های یال در برخی

- [8] M. Peplinski, B. Dilkina, M. Chen, S. J. Silva, G. A. Ban-Weiss, and K. T. Sanders, "A machine learning framework to estimate residential electricity demand based on smart meter electricity, climate, building characteristics, and socioeconomic datasets," *Applied Energy*, vol. 357, p. 122413, 2024.
- [9] A. Li, F. Xiao, C. Zhang, and C. Fan, "Attention-based interpretable neural network for building cooling load prediction," *Applied Energy*, vol. 299, p. 117238, 2021.
- [۱۰] مرتضی رجبی‌مندی، محمدابراهیم حاجی‌آبادی، مجید بقائی‌نژاد، «الگوریتمی ترکیبی بر پایه روشهای هوش محاسباتی جهت مدیریت مصرف برق خانگی با حضور خودروی برقی»، *مجله مهندسی برق دانشگاه تبریز*، دوره ۴۸، شماره ۲، صفحه ۶۱۷-۶۲۹، تابستان ۱۳۹۷
- [۱۱] امیر صمدی، حسین سعیدی، محمد امین لطیفی، مهدی مهدوی، «مدیریت مصرف در خانه با رعایت تاثیر تقاضاهای کنترل محیطی در تقاضاهای زمان محدود»، *مجله مهندسی برق دانشگاه تبریز*، دوره ۵۰، شماره ۲، صفحه ۷۶۵-۷۷۶، تابستان ۱۳۹۹
- [12] C. Chellawamy, R. Ganesh Babu, and A. Vanathi, "A framework for building energy management system with residence mounted photovoltaic," in *Building Simulation*, vol. 14, no. 4: Springer, pp. 1031-1046, 2021.
- [13] W. Liao, B. Bak-Jensen, J. R. Pillai, Z. Yang, and K. Liu, "Short-term power prediction for renewable energy using hybrid graph convolutional network and long short-term memory approach," *Electric Power Systems Research*, vol. 211, p. 108614, 2022.
- [14] S. Arastehfar, M. Matinkia, and M. R. Jabbarpour, "Short-term residential load forecasting using graph convolutional recurrent neural networks," *Engineering Applications of Artificial Intelligence*, vol. 116, p. 105358, 2022.
- [15] J. Lu et al., "Graph convolutional networks-based method for estimating design loads of complex buildings in the preliminary design stage," *Applied Energy*, vol. 322, p. 119478, 2022.
- [16] P. Veličković, "Everything is connected: Graph neural networks," *Current Opinion in Structural Biology*, vol. 79, p. 102538, 2023.
- [17] N. A. Asif et al., "Graph neural network: A comprehensive review on non-euclidean space," *IEEE Access*, vol. 9, pp. 60588-60606, 2021.
- [18] Y. Wu, H.-N. Dai, and H. Tang, "Graph neural networks for anomaly detection in industrial internet of things," *IEEE Internet of Things Journal*, vol. 9, no. 12, pp. 9214-9231, 2021.
- [19] W. Liao, B. Bak-Jensen, J. R. Pillai, Y. Wang, and Y. Wang, "A review of graph neural networks and their applications in power systems," *Journal of Modern Power Systems and Clean Energy*, vol. 10, no. 2, pp. 345-360, 2021.
- [20] T. N. Kipf and M. Welling, "Semi-supervised classification with graph convolutional networks," *arXiv preprint arXiv:1609.02907*, 2016.
- [21] Available online at: https://pytorch-geometric.readthedocs.io/en/latest/generated/torch_geometric.nn.conv.GCNConv.html#torch_geometric.nn.conv.GCNConv
- [22] Available online at: https://pytorch-geometric.readthedocs.io/en/latest/generated/torch_geometric.nn.pool.global_max_pool.html#torch_geometric.nn.pool.global_max_pool
- [23] M. Pipattanasomporn et al., "CU-BEMS, smart building electricity consumption and indoor environmental sensor datasets," *Scientific Data*, vol. 7, no. 1, p. 241, 2020.

$e_{i,j}$	مجموعه یال‌ها
i	گره مبدأ
j	گره مقصد
x_i	توصیف ویژگی برای هر گره
X	ماتریس ویژگی‌ها
A	ماتریس مجاورت گراف
l	لایه کانولوشن
$H^{(l)}$	خروجی لایه l
$\sigma(\cdot)$	تابع فعال غیر خطی
$W^{(l)}$	ماتریس وزن
D	ماتریس درجه
x_g	نمایش کلی گراف
R	تعداد لایه‌های کانولوشن
γ	انرژی مصرف شده
$\hat{\gamma}$	انرژی پیش‌بینی شده

سیاس‌گذاری

بدین‌وسیله از پژوهشگاه ارتباطات و فناوری اطلاعات که طبق قرارداد شماره ۵۰۰/۹۹۱۲/پ مورخ ۱۴۰۲/۰۶/۱۱ از این پایان نامه حمایت کرده است و همچنین از راهبر پژوهش سرکار خانم سلیمی سیاس‌گذاری می‌شود.

مراجع

- [1] Available online at: <https://www.iea.org/energy-system/buildings>
- [2] M. Khalil, A. S. McGough, Z. Pourmirza, M. Pazhoohesh, and S. Walker, "Machine Learning, Deep Learning and Statistical Analysis for forecasting building energy consumption—A systematic review," *Engineering Applications of Artificial Intelligence*, vol. 115, p. 105287, 2022.
- [3] L. Zhang et al., "A review of machine learning in building load prediction," *Applied Energy*, vol. 285, p. 116452, 2021.
- [4] Y. Hu et al., "A data-driven approach for the disaggregation of building-sector heating and cooling loads from hourly utility load data," *Energy Strategy Reviews*, vol. 49, p. 101175, 2023.
- [5] S. Afzal, A. Shokri, B. M. Ziapour, H. Shakibi, and B. Sobhani, "Building energy consumption prediction and optimization using different neural network-assisted models; comparison of different networks and optimization algorithms," *Engineering Applications of Artificial Intelligence*, vol. 127, p. 107356, 2024.
- [6] Y. Li, Z. O'Neill, L. Zhang, J. Chen, P. Im, and J. DeGraw, "Grey-box modeling and application for building energy simulations-A critical review," *Renewable and Sustainable Energy Reviews*, vol. 146, p. 111174, 2021.
- [7] W. Cai, X. Wen, C. Li, J. Shao, and J. Xu, "Predicting the energy consumption in buildings using the optimized support vector regression model," *Energy*, vol. 273, p. 127188, 2023.