

王子涵, 韩院彬. 基于 DCGCN-BiGRU 的工业环境 LoRa 组网 RSSI 预测[J]. 智能计算机与应用, 2026, 16(2): 177-182.  
DOI: 10.20169/j.issn.2095-2163.24042501

# 基于 DCGCN-BiGRU 的工业环境 LoRa 组网 RSSI 预测

王子涵, 韩院彬

(河北工程大学 信息与电气工程学院, 河北 邯郸 056038)

**摘要:** 工业环境中的 LoRa 组网方式面临着复杂的环境变化, 因此准确预测设备信号接收强度对于确保可靠的通信至关重要。本文提出了一种融合双通道图卷积神经网络和双向门控循环单元的方法, 用于工业环境中 LoRa 组网的信号强度预测。该模型不仅能够有效地捕捉设备的空间和时间关系, 还能够适应工业环境中的动态信道条件, 实现对 LoRa 信号强度的精确预测, 为工业物联网应用提供了一种有效的通信管理和优化方法。经实验表明相比传统方法, 本文所提的方法具有更高的预测准确性。

**关键词:** 图卷积神经网络; 双向门控循环单元; LoRa 组网; 信号强度; 时空序列预测

**中图分类号:** TP389.1 **文献标志码:** A **文章编号:** 2095-2163(2026)02-0177-06

## LoRa networking RSSI prediction based on DCGCN-BiGRU industrial environment

WANG Zihan, HAN Yuanbin

(School of Information and Electrical Engineering, Hebei University of Engineering, Handan 056038, Hebei, China)

**Abstract:** In industrial environments, LoRa networks are subject to fluctuating conditions, necessitating the accurate prediction of device signal reception strength to ensure stable communication. This paper presents a novel approach that integrates a dual-channel Graph Convolutional Neural network with Bidirectional Gated Recurrent Units for the purpose of signal strength forecasting within LoRa networks. This integrated model is adept at capturing both spatial and temporal correlations of devices and is capable of adapting to the dynamic channel conditions characteristic of industrial settings, thereby facilitating precise prediction of LoRa signal strength. The proposed method offers a robust strategy for communication management and optimization within the context of industrial Internet of Things (IoT) applications. Empirical results indicate that the predictive accuracy of the proposed method surpasses that of traditional approaches.

**Key words:** GCN; BiGRU; LoRa networking; signal strength; spatiotemporal sequence prediction

## 0 引言

在工业生产和制作领域, 实时监测和控制设备状态对于提高生产效率、降低成本以及确保安全至关重要。远距离无线电(Long range Radio, LoRa)信号<sup>[1]</sup>作为一种低功耗广域网技术, 其在工业环境中潜力巨大, 尤其是在无线传感器网络的构建和数据传输方面展现出显著优势。然而, 工业环境的复杂性和多变性给 LoRa 组网带来了挑战, 其中信号接收强度(Received Signal Strength Indicator, RSSI)受到工厂内多种因素的影响, 如金属障碍物、温度<sup>[2]</sup>、磁场等, 这些都会导致信号衰减或干扰, 影响网络的覆盖和性能。

近年来, 国内外许多学者在 LoRa 技术及其应

用方面展开大量的研究工作。Liu 等学者<sup>[3]</sup>在室外利用双向长短期记忆网络来估计复杂环境中长距离链路的路径损失模型, 提高 LoRa 在复杂环境中的链路质量预测精度。Dakic 等学者<sup>[4]</sup>在面对加性高斯白噪声干扰和载波偏移的条件下, 提出 LoRa 信号解调方法, 该方法的性能较传统的解调方法更为出色。张子凡等学者<sup>[5]</sup>提出基于 LightGBM 的 LoRa 室外指纹定位算法, 相比传统定位方法提高了计算效率及准确度。文献[6]对 LoRa 在钢筋混凝土室内结构中电磁传播特性进行研究, 通过一个移动发射器向分别固定在屋顶和地下室的 2 个接收器发送信号进行测试, 结果显示屋顶位置信号覆盖良好。文献[7]对多墙体的室内环境中的 LoRa 传播特性

**作者简介:** 王子涵(1999—), 女, 硕士研究生, 主要研究方向: 物联网技术。Email: 1969627104@qq.com; 韩院彬(1983—), 男, 博士, 副教授, 主要研究方向: 物联网技术。

收稿日期: 2024-04-25

哈尔滨工业大学主办 ◆ 科技创新与应用

进行研究,并设计整合 LoRa 室内传播的链路预算,以更好地了解和规划 LoRa 在复杂室内环境中的通信性能。Lu 等学者<sup>[8]</sup>提出基于 LoRa 的带离群滤波 BP 神经网络的室内定位算法,以其高精度和低成本而有望在医疗机构等领域得到推广应用。

本文提出一种基于双通道图卷积神经网络(Dual Channel Graph Convolution Network, DCGCN)和双向门控循环单元(Bidirectional Gated Recurrent Unit, BiGRU)技术,针对工业环境中 LoRa 组网的特点,综合考虑设备之间的拓扑结构和时间序列上的动态变化,提高对 LoRa 网络中信号强度准确预测能力,从而为工业物联网应用提供更可靠、高效的通信支持。

## 1 模型框架

### 1.1 构建邻接矩阵

Spearman 相关性系数<sup>[9]</sup>用来反映 2 个变量之间的相关程度,并且量化 2 个随机变量的变化趋势。本文中用来衡量各个设备之间信号强度的变化趋势,反映设备之间的相关程度。对此可以表示为:

$$d'_{a,b} = r_g(x'_a) - r_g(x'_b) \quad (1)$$

$$S_{a,b} = 1 - \frac{6 \sum (d'_{a,b})^2}{T(T^2 - 1)} \quad (2)$$

其中,  $x_a$  和  $x_b$  表示任意 2 个设备的信号强度值;  $r_g(x'_a)$  和  $r_g(x'_b)$  表示  $t$  时刻将信号强度值从小到大排序并分配等级号;  $d'_{a,b}$  表示在  $t$  时刻,设备  $a$  和设备  $b$  基于观测值相对大小计算出的序号差值。  $S_{a,b}$  计算出来相关系数的值为 -1 到 1 之间,其中 1 表示完全正相关, -1 表示完全负相关, 0 表示没有

相关性。根据计算出 Spearman 相关设置合适的阈值  $\gamma$  来确定 2 个 LoRa 设备之间是否存在关联性<sup>[10]</sup>。当相关系数大于阈值  $\gamma$  时,则表示 2 个设备之间存在较强的相关性,在邻接矩阵中对应元素设为 1,反之,则设为 0。构建邻接矩阵公式如下:

$$A_T = \left\{ \begin{array}{l} 1, S_{a,b} > \gamma, \forall a, b \in V \\ 0, S_{a,b} < \gamma, \forall a, b \in V \end{array} \right\} \quad (3)$$

由此得到 LoRa 组网的信号强度预测时空相关图  $G_T = (X_T, A_T)$ , 其中,  $X_T$  表示设备的特征数据,  $A_T$  表示 LoRa 设备时空相关图的结构。

### 1.2 DCGCN 提取空间特征

图卷积神经网络<sup>[11]</sup> (Graph Convolutional Network, GCN)是一种用于处理图结构数据的神经网络架构,核心功能是提取图中节点的空间特征,即捕捉节点的局部邻域结构信息。通过聚合图中节点的邻接信息,实现节点特征的更新和传递,卷积层的计算公式为:

$$\mathbf{H}^{(l+1)} = \sigma(\mathbf{D}^{-\frac{1}{2}} \mathbf{A} \mathbf{D}^{-\frac{1}{2}} \mathbf{H}^{(l)} \mathbf{W}^{(l)}) \quad (4)$$

卷积操作流程为:首先,将第  $l$  层的节点特征矩阵  $\mathbf{H}^{(l)}$  与权重矩阵  $\mathbf{W}^{(l)}$  相乘,实现对节点特征的线性变换。然后,通过归一化后的邻接矩阵  $\tilde{\mathbf{A}}$  对节点特征进行聚合。聚合的方式是通过邻接矩阵中的边权重进行加权求和,考虑了节点间的连接关系。最后,激活函数  $\sigma$  对聚合后的特征进行非线性变换,得到  $(l+1)$  层的节点特征矩阵  $\mathbf{H}^{(l+1)}$ 。在整个过程中节点的特征表示不仅包含自身的信息,还融合了其邻居节点的特征,从而捕捉到节点间的复杂关系。双通道图卷积网络<sup>[12]</sup>结构如图 1 所示。




图 1 双通道图卷积网络结构

Fig. 1 Dual-channel graph convolutional network structure

该结构包括输入层、2 个通道(Channel 1 和 Channel 2),这 2 个通道分别通过图卷积层 GCN Conv1 和 GCN Conv2 后进行特征拼接,最后进行输出。这个模型的设计旨在通过图卷积层提取和转换图结构数据的特征,并通过特征的拼接来增强模型的表示能力,最终通过输出层得到预测结果。

### 1.3 BiGRU 提取时间特征

门控循环单元(Gated Recurrent Unit, GRU)<sup>[13]</sup>是一种用于处理序列数据的循环神经网络(RNN)架构。其通过引入更新门(Update Gate)和重置门(Reset Gate)这 2 种门控单元从而改善传统 RNN 的梯度消失或爆炸的问题。图 2 为 GRU 的结构图<sup>[13]</sup>。




图 2 门控循环单元结构

Fig. 2 Gated Recurrent Unit structure

更新门控制保留先前的记忆并加入到当前状态中,确定前一个时间步的隐藏状态融合到当前时间步的候选隐藏状态。研究推得的公式如下:

$$z_t = \sigma(w_z \cdot [h_{t-1}, x_t]) \quad (5)$$

其中,  $z_t$  表示在时间  $t$  的更新门的输出;  $w_z$  表示更新门的权重矩阵;  $h_{t-1}$  表示前一个时间步的隐藏状态;  $x_t$  表示当前时间步的输入;  $\sigma$  为 Sigmoid 激活函数, 表征信息的通过程度。

重置门决定对先前记忆丢弃或保留, 控制前一个时间步的隐藏状态对当前时间步的候选隐藏状态, 研究推得的公式如下:

$$r_t = \sigma(w_r \cdot [h_{t-1}, x_t]) \quad (6)$$

其中,  $r_t$  表示在时间步  $t$  的重置门的输出。

计算更新门和重置门后, GRU 会计算一个候选隐藏状态  $\tilde{h}_t$ , 计算公式如下<sup>[14]</sup>:

$$\tilde{h}_t = \tanh(w \cdot [r_t \cdot h_{t-1}, x_t]) \quad (7)$$

结合当前输入  $x_t$  和调整重置门前一个隐藏状态  $r_t$  和  $h_{t-1}$  来得到最终的隐藏状态  $h_t$ , 即可写为:

$$h_t = (1 - z_t) \cdot h_{t-1} + z_t \cdot \tilde{h}_t \quad (8)$$

由式(8)可知, 这是前一个隐藏状态  $h_{t-1}$  和候选隐藏状态  $\tilde{h}_t$  的加权和, 其权重由更新门  $z_t$  控制<sup>[15]</sup>。

双向门控循环单元<sup>[16]</sup>是建立在 GRU 基础上的一种改进型, 结构如图 3 所示。

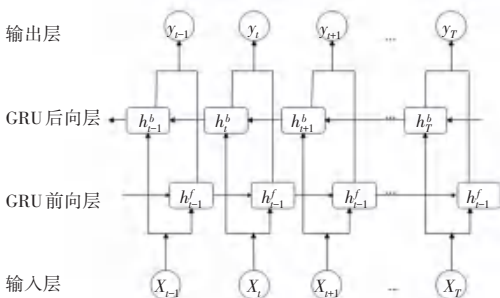


图 3 双向门控循环单元结构

Fig. 3 Bidirectional Gated Recurrent unit structure

与普通 GRU 相比, BiGRU 能够更好地捕捉序

列数据中的双向依赖关系。在处理序列数据时不仅考虑了当前时刻之前的信息, 还考虑了该时刻之后的信息。通过引入 2 个独立的 GRU 结构, 分别处理输入序列的正向和反向。在每个时间步, 正向 GRU 接收当前时刻及之前时刻的输入, 并产生一个正向隐藏状态序列; 而反向 GRU 是接收当前时刻及之后的输入, 并产生一个反向隐藏状态序列。其优势为能够更好地捕捉序列数据中的双向依赖关系, 通过整合正向和反向的信息就可以提供更加全面的序列表示, 从而改善了模型的性能。

### 1.4 评价指标

本文选取的评价指标有: 均方误差 (Mean Square Error, MSE)、均方根误差 (Root Mean Square Error, RMSE)、平均值绝对误差 (Mean Absolute Error, MAE) 和平均绝对误差 (Mean Absolute Percentage Error, MAPE)<sup>[17]</sup>。各项指标的值越小, 其精度越高。各指标计算公式如下:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (9)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (10)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (11)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{|y_i|} \times 100\% \quad (12)$$

其中,  $n$  表示数量;  $y_i$  表示预测值;  $\hat{y}_i$  表示真实值。

## 2 基于 DCGCN-BiGRU 的 LoRa 组网信号

本文工业环境 LoRa 组网 RSSI 预测流程为:

**步骤 1** 设备信号强度值进行数据标准化和归一化处理, 并按照比例划分训练集、验证集和测试集。

**步骤 2** 通过计算 Spearman 值, 设置合适的阈值确定图结构, 并输入邻近矩阵。

**步骤 3** 通过最小化损失函数, 反复更新模型的权重和偏置, 从而确定 DCGCN-BiGRU 的最佳参数。

**步骤 4** 在验证集上选择最佳参数, 用最优模型在测试集上进行预测, 经反归一化后得到结果<sup>[18]</sup>。

**步骤 5** 利用特定的评估指标来衡量模型的准确性, 并据此来优化 DCGCN-BiGRU 模型。

本文使用一种融合空间和时间特征的深度学习模型, 用于预测各个 LoRa 的信号强度值, 整体模型结构如图 4 所示。

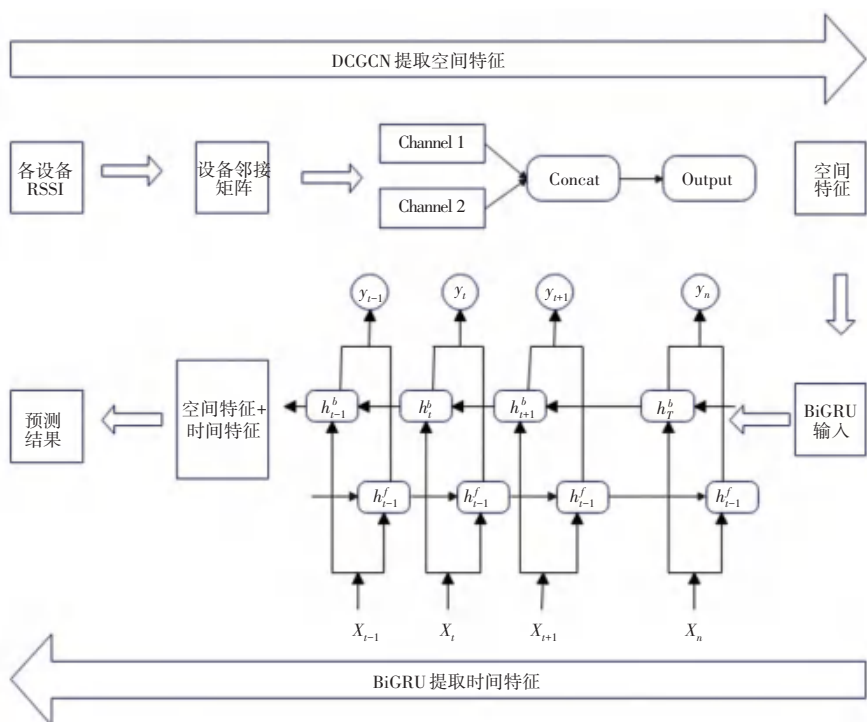


图4 DCGCN-BiGRU 结构

Fig. 4 DCGCN-BiGRU structure

首先,通过相关系数计算确定邻接矩阵并输入到模型中,DCGCN 负责从设备邻接矩阵中提取关键的空间特征,能够捕捉到设备间的拓扑结构信息,从而提取出反映设备空间分布特征的数据。然后,空间特征与时间特征相结合<sup>[19]</sup>,时间特征通常由历史状态信息构成,通过 BiGRU 进行处理,在 2 个方向上处理序列数据来捕获时间上的长期依赖关系,即正向和反向传播路径,这使得模型能够更全面地理解时间序列的动态特性。最终,模型生成的输出是下一个时间步的空间特征预测。意味着模型不仅考虑了当前的状态,还能够根据学习到的时间动态信息,对将来的状态做出预测。综上所述,该模型是一个结合了空间拓扑结构和时间序列分析的先进预测模型,融合 DCGCN 和 BiGRU 的结构,能够对设备网络中的空间和时间特征进行深度学习,从而实现了对设备信号强度的未来变化趋势的准确预测。

### 3 实验与结果对比分析

#### 3.1 数据集及预处理

本实验采取 2024 年 3 月 10 日到 2024 年 3 月 28 日邯郸某工厂内不同位置部署的 13 个 LoRa 设备,每个设备每 5 min 更新当前信号强度值,并记录各个设备的信号强度随时间的变化,共计 5 000 条。通过接口获取数据并进行解析,存入数据库,以保证

数据的完整性与真实性。将数据按照 8 : 1 : 1 的比例划分训练集、验证集和测试集<sup>[20]</sup>。为保证数据质量,对数据进行缺失值、异常值处理,然后经过归一化,最后利用长度为 10 的滑动窗口进行处理。

#### 3.2 模型参数

模型通过调整超参数来提高其在数据上的准确性和泛化能力,有助于防止过拟合,提升模型训练的资源效率,减少所需的时间和计算成本。本实验的主要超参数见表 1。

表1 DCGCN-BiGRU 模型参数设置


Table 1 DCGCN-BiGRU model parameter settings

参数	值
epochs	50
优化器	Adam
学习率	0.008
batch size	512
dropout	0.1
激活函数	ReLU

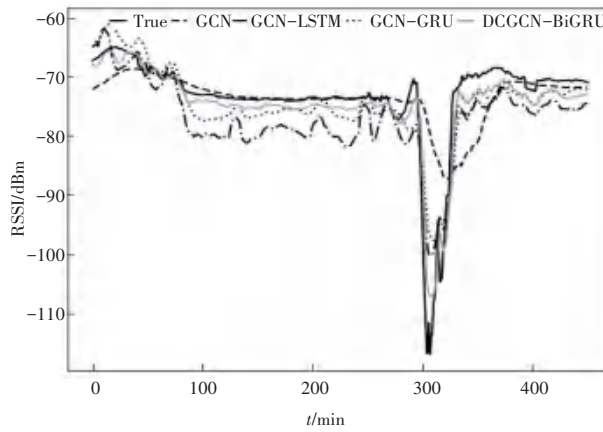
#### 3.3 模型性能分析

为验证模型的预测效果,将 DCGCN-BiGRU 模型与 GCN、GCN-LSTM 和 GCN-GRU 三种模型进行对比。由于模型预测结果包含 13 个设备,考虑到篇幅所限,故选其中 3 个设备进行展示,效果对比如图

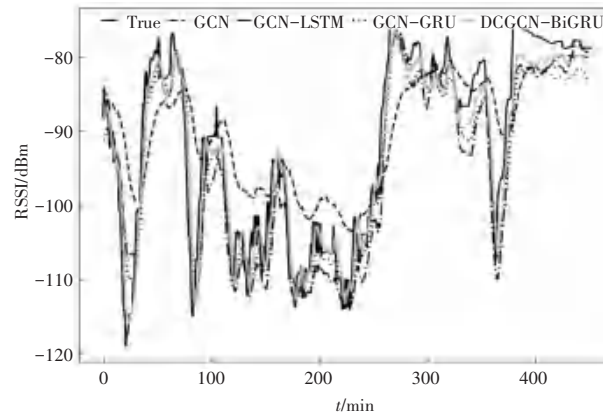
5 所示。图 5 中,纵坐标表示信号强度值,横坐标表示时间。



(a) 设备 1#RSSI 预测图



(b) 设备 2#RSSI 预测图



(c) 设备 3#RSSI 预测图

图 5 设备 1~3 在各模型 RSSI 预测值和真实值对比

Fig. 5 Comparison of RSSI predicted values and actual values for devices 1~3 in various models

从图 5 可以看出相比于单一的 GCN 对真实值的拟合程度较差,GCN-LSTM、GCN-GRU 组合模型的预测曲线更接近真实值,也展示出空间与时间相结合的模型取得了较为理想的效果。本实验所提 DCGCN-BiGRU 模型的效果达到了最优。

为量化这 4 种模型的预测结果,将 13 个 LoRa

设备 MSE、RMSE、MAE 和 MAPE 四种评价指标均取其平均值。其评价指标见表 2。

表 2 不同模型评价指标表现

Table 2 Performance of evaluation indicators for different models

模型	MSE/dBm	RMSE/dBm	MAE/dBm	MAPE/%
GCN	10.80	2.37	1.66	2.33
GCN-LSTM	7.88	2.39	2.01	2.97
GCN-GRU	6.76	2.19	1.76	2.27
DCGCN-BiGRU	2.81	1.45	1.18	1.75

由表 2 可知,GCN 模型在所有模型中表现最差,具有最高的误差值。GCN-LSTM 的误差对比表明在某些极端情况下的误差较大。GCN-GRU 模型表明该模型在预测的准确性和稳定性方面表现良好。DCGCN-BiGRU 模型在所有评价指标上都表现最佳,这表明该模型在预测任务上最准确,误差最小。从这些评价指标来看,DCGCN-BiGRU 模型的性能最佳,而 GCN 模型的性能最差。这意味着 DCGCN-BiGRU 模型在处理相关任务时,能够更好地捕捉数据的特征和模式,从而提供更准确的预测。

### 4 结束语

本文融合双通道神经网络和双向门控循环单元提取空间和时间特征的模型。首先,利用 Spearman 相关系数分析各个设备随时间信号强度变化的特征,构建邻接矩阵。然后,使用双通道卷积神经网络对设备的空间特征进行提取,最后用双向门控循环单元对时间特征进行提取。通过实验与传统模型进行对比,结果证明本文所提出 DCGCN-BiGRU 模型,比现有的模型接近真实值,在各项指标上均有所提升。为确保实时自适应信号强度的预测算法具备高效的计算能力和实时性,未来可采用轻量级模型设计、快速响应机制和增量学习等技术,能使算法在短时间内对环境变化进行适应性调整,从而确保系统在工业环境中的实时性和稳定性。

### 参考文献

[1] SUN Zehua, YANG Huanqi, LIU Kai, et al. Recent advances in LoRa: A comprehensive survey[J]. ACM Transactions on Sensor Networks, 2022, 18(4): 3543856.

[2] PEI Tian, FENG Xuyang, MA Xiaoyuan, et al. Environmental impact on the long-term connectivity and link quality of an outdoor LoRa network [C]//Proceedings of the 19<sup>th</sup> ACM Conference on Embedded Networked Sensor Systems. New York: ACM, 2021: 565-568.

[3] LIU Li, YAO Yuguang, CAO Zhichao, et al. DeepLoRa: Learning accurate path loss model for long distance links in LPWAN[C]//

- Proceedings of IEEE INFOCOM. Piscataway, NJ: IEEE, 2021: 1-10.
- [4] DAKIC K, AI-HOMSSI B, AI-HOURANI A, et al. LoRa signal demodulation using deep learning, a time-domain approach[C]// Proceedings of 2021 IEEE 93<sup>rd</sup> Vehicular Technology Conference. Piscataway, NJ: IEEE, 2021: 1-6.
- [5] 张子凡, 庞成鑫, 冉浦东, 等. 基于 LightGBM 的 LoRa 室外指纹定位算法[J]. 计算机应用与软件, 2023, 40(10): 174-178.
- [6] GREGORA L, VOJTECH L, NERUDA M. Indoor signal propagation of LoRa technology [C]// Proceedings of the 17<sup>th</sup> International Conference on Mechatronics. Piscataway, NJ: IEEE, 2017: 215-217.
- [7] HOSSEINZADEH S, LARIJANI H, CURTIS K, et al. Empirical propagation performance evaluation of LoRa for indoor environment [C]// Proceedings of the 15<sup>th</sup> IEEE International Conference on Industrial Informatics. Piscataway, NJ: IEEE, 2017: 26-31.
- [8] LU Kaiyu, YUE Yong, MA Jieming. Enhanced LoRaWAN RSSI indoor localization based on BP neural network. [C]// Proceedings of 2021 IEEE 4<sup>th</sup> International Conference on Information Systems and Computer Aided Education (ICISCAE). Piscataway, NJ: IEEE, 2021: 190-195.
- [9] SPEARMAN C. The proof and measurement of association between two things[J]. Journal of Epidemiology, 2010, 39(5): 1137-1150.
- [10] 吴军英, 路欣, 刘宏, 等. 基于 Spearman-GCN-GRU 模型的超短期多区域电力负荷预测[J]. 中国电力, 2024, 57(6): 131-140.
- [11] WU F, SOUZA A, ZHANG Tianyi, et al. Simplifying graph convolutional networks [J]. arXiv preprint arXiv, 1902. 07153, 2019.
- [12] 李平, 戴月明, 吴定会. 双通道卷积神经网络在文本情感分析中的应用[J]. 计算机应用, 2018, 38(6): 1542-1546.
- [13] DEY R, SALEM F. Gate-variants of gated recurrent unit neural networks [C]// Proceedings of 2017 IEEE 60<sup>th</sup> International Midwest Symposium on Circuits and Systems. Piscataway, NJ: IEEE, 2017: 1597-1600.
- [14] 贺小伟, 徐靖杰, 王宾, 等. 基于 GRU-LSTM 组合模型的云计算资源负载预测研究[J]. 计算机工程, 2022, 48(5): 11-17.
- [15] 李洁琼, 刘振. 基于 CNN 和 GRU 的农产品价格预测模型研究[J]. 湖北农业科学, 2023, 62(1): 177-181.
- [16] 杜琰, 孙弋. 融合 GRU 和注意力机制的图卷积关系抽取[J]. 计算机与数字工程, 2023, 51(11): 2568-2572.
- [17] 刘智玉, 陈南梁, 汪军. 基于随机森林算法的小样本纱线质量预测[J]. 东华大学学报(自然科学版), 2023, 49(6): 80-86.
- [18] 李丹, 黄烽云, 杨帆, 等. 计及动态时空相关性的多风电场短期功率预测[J]. 电力系统及其自动化学报, 2025, 37(2): 1-9.
- [19] 代丽伟. 基于 GCN-BiLSTM 的动态网络异常行为检测[J]. 信息技术与信息化, 2023(4): 67-70.
- [20] 杨超, 冉启武, 罗德虎, 等. 基于注意力机制的 CNN-BIGRU 短期电价预测[J]. 电力系统及其自动化学报, 2024, 36(3): 22-29.