

基于SGNN-TCN融合模型的电动自行车换电需求预测研究

冉珂蔚, 曾传华*, 周 慧

西华大学汽车与交通学院, 四川 成都

收稿日期: 2026年7月14日; 录用日期: 2026年9月9日; 发布日期: 2026年9月20日

摘 要

外卖配送行业的快速增长使得电动自行车的使用量显著增加, 电动自行车在使用过程中需要频繁补充电能, 而传统的充电模式面临着充电时间长、安全隐患大等问题。电动自行车换电柜作为一种高效、便捷的电池更换方式, 逐渐成为解决充电难题的关键技术之一。而准确预测电动自行车的换电需求量, 不仅能为换电柜的选址提供可靠的数据支持, 也可以大大提高服务的效率和服务品质。因此, 针对换电需求量的预测, 本文提出了一种基于时空图神经网络(SGNN-TCN)的改进模型, 利用时间依赖性、空间依赖性和天气依赖性进行建模, 采用GNN对空间特征进行提取, 并将提取后的空间特征输入TCN层进一步挖掘时间变化规律, 该模型能够有效提取电动自行车使用数据中的空间和时间特征, 并准确预测未来的换电需求量。

关键词

电动自行车, 需求预测, SGNN-TCN

Research on Electric Bicycle Battery Swapping Demand Prediction Based on the SGNN-TCN Fusion Model

Kewei Ran, Chuanhua Zeng*, Hui Zhou

School of Automotive and Transportation, Xihua University, Chengdu Sichuan

Received: July 14, 2026; accepted: September 9, 2026; published: September 20, 2026

Abstract

The rapid growth of the food delivery industry has significantly increased the usage of electric

*通讯作者。

文章引用: 冉珂蔚, 曾传华, 周慧. 基于 SGNN-TCN 融合模型的电动自行车换电需求预测研究[J]. 交通技术, 2026, 15(5): 653-663. DOI: 10.12677/ojtt.2026.155056

bicycles. During operation, electric bicycles require frequent energy replenishment, while traditional charging methods face problems such as long charging times and high safety risks. As an efficient and convenient battery replacement method, electric bicycle battery swapping stations have gradually become one of the key technologies for addressing charging difficulties. Accurate prediction of electric bicycle battery swapping demand can not only provide reliable data support for the site selection of battery swapping stations but also greatly improve service efficiency and service quality. Therefore, this study proposes an improved prediction model based on a spatio-temporal graph neural network (SGNN-TCN) for electric bicycle battery swapping demand forecasting. The proposed model considers temporal dependency, spatial dependency, and weather dependency in the modeling process. The graph neural network (GNN) is employed to extract spatial features, and the extracted spatial features are then input into the temporal convolutional network (TCN) to further capture temporal variation patterns. The proposed model can effectively extract spatial and temporal features from electric bicycle usage data and accurately predict future battery swapping demand.

Keywords

Electric Bicycle, Demand Prediction, SGNN-TCN

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

自信息时代兴起以来, 网络经济采用了线上与线下相结合的运营模式, 利用互联网作为媒介, 构建了用户、第三方平台以及实体餐厅之间的联系, 为客户提供快捷、高效的服务, 网络经济的发展不但加快了物流业和快餐业的扩张, 还进一步推动了电动自行车行业的快速发展[1]。外卖行业的蓬勃发展带来外卖骑手数量急剧增长, “以换代充”模式在各大城市逐渐普及, 换电需求成为学术界研究热点之一。

但现有的换电需求预测方法主要依赖时间序列模型或传统机器学习方法[2][3], 难以同时考虑换电需求中的空间关联特征和时间动态变化规律[4]。近年来, 图神经网络通过构建节点之间的拓扑关系, 能够有效提取区域间空间依赖信息, 为需求预测提供了新的研究思路[5]。本文提出 SGNN-TCN 模型, 将 SGNN 与时间卷积网络相结合, 实现空间关联特征和时间变化特征的联合建模。为系统评估 SGNN-TCN 模型的性能优势, 采用 SGNN-TCN 混合模型对未来 60 分钟的站点需求进行预测分析, 并与 LSTM 模型、DCRNN 模型、STGNN 模型、SGNN-GRU 模型和其他无外部因素的 SGNN-TCN 模型进行对比, 通过这组系统性的对比实验, 全面评估各模型在短期需求预测任务中的表现差异。实验结果表明, SGNN-TCN 模型的有效性和预测精准度相较于其他基准模型有了提升。

2. 模型选择

2.1. 时间卷积网络 TCN

时间卷积网络(TCN)是一种基于一维卷积架构的时序建模方法, 通过因果卷积和扩张卷积扩大时间感受野, 能够有效提取序列数据中的长期依赖关系。相比传统循环神经网络, TCN 采用卷积结构进行并行计算, 在处理长时间序列数据时具有更高的计算效率和更稳定的训练性能。TCN 通过设置不同扩张因子, 可以同时捕获短期需求波动和长期周期变化, 为换电需求预测提供有效的特征提取能力。图 1 展

示了时间卷积网络(TCN)的工作流程。




Figure 1. Schematic diagram of TCN working process
图 1. TCN 工作流程示意图

时间卷积网络在基础架构之外,还集成了两项重要的训练优化技术,实施权重归一化处理对网络参数进行标准化约束和在网络各层级间引入随机失活 dropout 正则化策略,以一定概率暂时丢弃部分神经元连接,有效抑制了模型对训练数据的过度拟合倾向。

2.2. 图卷积网络

图神经网络(Graph Neural Network, GNN)是一类针对图结构数据设计的深度学习模型,其通过构建节点与节点之间的连接关系,并利用邻域信息传播机制实现空间特征提取。根据图卷积方式的不同, GNN 主要包括谱域图卷积和空间域图卷积两类方法。刘杰等人[6]在深度学习框架下提出了多图卷积神经网络(GNN)模型,目的是对交通流进行精确预测。为了搜捕时间和空间的相关性, GNN 模型采用以下方法提取特征:假设输入到神经网络的是 $X_{in} \in R^{N \times din}$, 那么其输出结果 $X_{out} \in R^{N \times din}$ 可以通过式(1)计算:

$$X_{out} = \sigma(D'^{-1/2} A D'^{-1/2} X_{in} W) \quad (1)$$

在这个方程中,引入了激活函数(Rectified Linear Unit, ReLU),它具有非线性特性。 $A' = A + I_N$ 表示改进后的邻接矩阵,其中 I_N 为 N 维单位矩阵,而 D' 则是经过优化处理后的矩阵,其形式为: $D'_{ij} = \sum_j A'_{ij}$, W 是需要通过学习来掌握的变量。基于此,方程可以进一步简化为:

$$X_{out} = f_g(A, X_{in}) \quad (2)$$

图神经网络(GNN)的运算机制完全由其输入的拓扑数据决定,这些数据通常来源于交通监测传感器网络的空间分布特征。在实际应用中,传感器节点间的连接关系主要依据其地理位置信息建立,其中两点间的直线距离即欧式距离是最常用的空间关系度量指标,基于以上考虑本文进一步加入了站点之间的全局特征,从而有效避免了上述问题的影响[7]。

2.3. 模型框架

基于对循环神经网络和图卷积网络的对比分析,本文提出了 SGNN-TCN 模型,用于预测电动自行车的需求量。模型输入端接收构建的路网拓扑图,通过图卷积层 GNN 学习节点间的空间依赖模式,生成具有空间编码特性的特征表示,这些空间特征随后作为时间卷积网络 TCN 的输入,由于电动自行车的需求量受邻近性因素、每日和每周变化的影响,模型引入了三种不同的膨胀因子:1、24、24 * 7,分别用于

捕捉每日、每周的变化特性以及邻近性特征，这些特征通过加权融合得到预测结果。

时间序列：本文将历史数据按预定时间间隔划分为若干部分，每个部分称为时间序列。

网络结构图：节点代表外卖订单的起始点或配送区域，连接节点的边则表示这些地点之间的关联程度，边的权重反映了两个站点之间的联系强度，通常边的权重越大，表示两个地点之间的关联度越强。

电动自行车需求量：电动自行车的需求量包括两个方面，一是外卖订单的取货量 I ，二是外卖订单的送达量 O 。假设存在 N 个电动自行车站点或配送区域，某一位置的订单配送起点和终点分别用 αI_i 和 αO_i 来表示，那么，在某一时刻，订单的送达总数可以表示为 $I' = [\alpha I'_1, \alpha I'_2, \dots, \alpha I'_N]$ ，而时间步 t 的借出量则为 $O' = [\alpha O'_1, \alpha O'_2, \dots, \alpha O'_N]$ 。

问题定义：利用给定 S 个站点在历史 T 个时间步的观测数据，预测未来 M 时间内各个站点的位置及其电动自行车数量需求，采用了 SGNN-TCN 混合模型，并结合全局层的函数 $f(\cdot)$ 来提取数据的时空特征，最终通过预测层输出所需的预测结果。

$$[Y_{t+1}, \dots, Y_{t+m}] = f([Y_{t+1}, \dots, Y_{t+m}]) \quad (3)$$

在外部特性抽取方面，通过外部信息导入模块进行研究，获得其他特性的向量表示，将这些特性向量与时序相关卷积层的输出向量进行连接处理，合成的向量作为输入，模型通过多层卷积运算得到预测输出后，利用损失函数计算模块衡量预测值与真实值的误差，并据此调整网络参数。从图 2 可以看出，SGNN-TCN 模型的框架结构包括空间特征提取层(GNN)、时间特征提取层(TCN)、天气因素特征提取层及全连接层。



Figure 2. Schematic diagram of SGNN-TCN structure
图 2. SGNN-TCN 结构示意图

3. 空间特征层

3.1. 配送起止点与空间特征提取

本文的研究数据采集自某外卖平台，涵盖大连市的 101,564 条外卖订单记录。同时，通过高德地图应用程序编程接口(API)获取了大连市的兴趣点(POI)数据，以支持空间特征提取。空间特征的精确提取是模型构建的关键步骤。本研究基于外卖订单的配送地址与 POI 数据，采用最近邻匹配法来识别配送点所在区域的主要功能属性。对于每个外卖订单的起始点或终点 P ，首先计算其与周边所有 POI 之间的欧氏距离(公式(4))，进而选取距离最近的 POI 点(公式(5))，并将该 POI 的功能类别赋予相应的配送点。该方法能够将抽象的地理位置转化为具有具体功能意义的标签，为后续模型提供关键的空间语义输入。

$$d(P, s_i) = \sqrt{(x_p - x_{s_i})^2 + (y_p - y_{s_i})^2} \quad (4)$$

$$POI_n = \arg \min_{s_i \in S} d(P, s_i) \quad (5)$$

3.2. 图结构构建与边权重构建

图结构的构建是空间特征提取中的核心环节，目的就是利用节点和边来描绘不同区域之间配送需求的空间关系，在这张图里的每个区域是一个节点，区域之间的配送流量通过边来体现，节点特征反映了区域本身的静态属性，边权重表示区域之间的动态联系。

(1) 节点特征提取

每个区域被表示为一个节点，其特征用于描述该区域的空间属性以及配送需求的分布。

订单密度用于衡量每个区域的配送需求强度。订单密度越大，表示该区域的配送需求越为集中，是配送活动的关键热点。

1) 订单密度：

$$D = \frac{Q}{\text{Area}} \quad (6)$$

其中， Q 表示该区域内的订单总数，而 Area 则代表该区域的面积。

2) 区域面积：采用最小凸包法计算区域的实际地理轮廓面积。计算公式为：

$$\text{Area} = \frac{1}{2} \left| \sum_{i=1}^{n-1} (x_i y_{i+1} - x_{i+1} y_i) + (x_n y_1 - x_1 y_n) \right| \quad (7)$$

3) POI 多样性(H):

$$H = - \sum_{i=1}^N P_i \log P_i \quad (8)$$

在此： P_i 代表第 i 类 POI 在该区域中的比例； N 则是 POI 类别的总数。

4) 区域的几何中心：

$$\text{Center}(s_i) = \left(\frac{\sum_{j=1}^n x_{s_j}}{n}, \frac{\sum_{j=1}^n y_{s_j}}{n} \right) \quad (9)$$

其中： x_{s_j} 、 y_{s_j} 分别表示节点内 POI 的经纬度坐标， n 则是该节点中 POI 的数量。

在第 i 行第 j 列网格中某种 POI 类型的数量为 A_{ij} ，而该网格中所有 POI 的总数为 A_k ，则定义该网格中此类 POI 类型占总 POI 数量的比例为 P_{ij} 。

$$P_{ij} = \frac{A_{ij}}{A_k} \quad (10)$$

显然，存在 $\sum_i \sum_j P_{ij} = 1$ ，而 POI 信息熵的定义如下所示：

$$H_S = - \sum_i \sum_j P_{ij} \times \log P_{ij} \quad (11)$$

通过应用甘井子区 POI 信息熵计算模型，分析基于 POI 的熵的分布特性，图 3 展示了不同 POI 信息熵值区间的频率分布情况，结果显示大多数观测值集中在 2.0 至 3.0 的熵值区间，说明甘井子区的功能多样性较为显著，而熵值位于 0 至 0.7 区间的频次较低，数据整体呈现右偏正态分布趋势，反映出大部分区域的土地利用类型具有较高的多样化，体现了功能混合程度较高。




Figure 3. Histogram of POI information entropy distribution
图 3. POI 信息熵分布直方图

(2) 边的构建与权重计算

$$W_{ij} = \frac{Q_{ij}}{\max(Q)} \quad (12)$$

其中, Q_{ij} 表示从区域起点 i 到区域终点 j 的配送订单总数, 而 $\max(Q)$ 则是所有区域节点对中的最大配送订单总量。

(3) 边稀疏化处理

设置一个权重阈值 T , 仅保留 $W_{ij} \geq T$ 的边; 与此同时, 删除低权重的边, 仅保留区域间最为显著的关联。

通过匹配配送起止点和进行 POI 聚类, 构建了图的节点特征; 接着结合配送流量来构建边和其权重, 将最后生成的图结构将作为图卷积网络的输入, 用于捕捉空间关联特性并进行换电需求量的预测。

4. 时间特征层

空间特征提取模块的输出将作为时序建模环节的输入数据, 该模块专门用于捕获时间维度上的变化规律。系统采用时序卷积网络(TCN)架构, 通过分析历史需求数据的演变趋势, 实现对电动自行车未来需求量的准确预估[8] [9]。为了避免过拟合, 结合 TCN 的特点, 决定用一层时序卷积网络来捕捉电动自行车外卖配送订单的时间属性。在实际操作中不仅相邻时段的数据会影响预测结果, 前一天和上周的外卖订单量也可能对电动自行车的需求产生影响[10]。为了更全面地提取时间特征, 在时间依赖性建模过程中, 设置了三种具有不同时间跨度的膨胀系数, 对应的膨胀因子分别是 1、24 和 $24 * 7$, 所以具有三个不同膨胀因子的时间卷积模块分别表示为 X_h^t 、 X_d^t 和 X_w^t , 其表达式如下:

$$R_h^t = (H_S^{t-S_h}, \dots, H_S^{t-2}, H_S^{t-1}) \in R^{S_h \times N \times F} \quad (13)$$

$$R_d^t = (H_S^{t-24*S_d}, \dots, H_S^{t-24*2}, H_S^{t-24*1}) \in R^{S_d \times N \times F} \quad (14)$$

$$R_w^t = (H_S^{t-24*7*S_d}, \dots, H_S^{t-24*7*2}, H_S^{t-24*7*1}) \in R^{S_w \times N \times F} \quad (15)$$

在此, H_S^t 表示在时间步长 t 下, 输出的空间依赖性建模特征。为了检测不同时间尺度上的卷积核长

度, 使用了 S_h 、 S_d 和 S_w 检测对应的时间卷积核长度, 其中 S_h 表示小时尺度的卷积核长度, S_d 表示天尺度的卷积核长度, S_w 表示周尺度的卷积核长度; N 代表经过聚类后的区域总数, F 则是提取的空间依赖性特征的维度。

随后, 将 R_h^t 、 R_d^t 和 R_w^t 作为输入传递给 TCN 层, 对应的 TCN 层卷积操作为:

$$s_h = \sigma(W_h R_h^t) \quad (16)$$

$$s_d = \sigma(W_d R_d^t) \quad (17)$$

$$s_w = \sigma(W_w R_w^t) \quad (18)$$

时间卷积网络采用多参数架构设计, 包含了三个可调节的参数: W_h 、 W_d 和 W_w , 分别表示不同时间尺度下输入与输出的映射关系, 为有效处理数据的非线性特征, 模型集成 ReLU 非线性变换单元, 考虑到近似趋势、周趋势和每日趋势在影响力上的差异, 本文构建了三个卷积结构, 单独提取特定时间维度的特征, 最终通过自适应权重融合机制实现特征整合。具体的操作方式如下所示。

$$y_{fusion} = \sigma(\mu_h \odot y_h + \mu_d \odot y_d + \mu_w \odot y_w) \quad (19)$$

在该模型中, μ_h 、 μ_d 和 μ_w 分别表示近似趋势、日趋势和周趋势的可训练参数, 而 $\odot$ 代表矩阵中对应元素的逐项乘积, 也就是哈达玛积运算。

5. 外部因素特征层和损失函数计算

除了时间和空间因素会影响电动自行车的需求量, 天气因素也会对骑手配送状态以及换电需求产生影响, 所以为了提高预测的准确性, 需要把天气因素也考虑进去。本文的研究数据采集自某外卖平台的外卖订单数据, 数据主要包括订单所属骑手序号、订单分配时间、订单轨迹序号、当天的天气情况、取货点和送货点的经纬度、订单创建时间、分配时间以及期望送达时间等信息。为了避免模型过拟合, 本文对天气数据进行了归一化处理, 1 代表天气状况良好, 0 则代表天气状况差, 处理之后用一个完整的连通层把外部数据即天气数据嵌入进去, 得到各因子的特征矢量, 再将各因子的特征矢量连接起来, 把合并后的特征向量作为输入, 传递到全卷积层里进行预测。

在训练过程中, 历史数据集被划分为测试集 Y_{test} 、训练集 Y_{train} 和验证集 Y_{valid} , 针对电动自行车换电需求的预测场景, 设置滑动时间窗口机制: 以前 21 天历史数据构建特征矩阵作为模型输入, 对应未来 60 分钟的换电需求量构成预测目标。原始数据集按时间顺序分割为训练集(80%)、验证集(10%)和测试集(10%)三个独立子集, 该比例设置既能保证模型充分学习时序模式, 又可有效评估泛化能力。如图 4 所示, 展示了训练集划分的示意图。



Figure 4. Schematic diagram of the dataset division
图 4. 数据集划分示意图

在计算损失函数 S 时, 将预测结果与真实数据进行对比, 并以均方误差(Mean Squared Error, MSE)为训练参数。损失函数 $S(\partial)$ 用于评估模型的预测精度, 具体表达式如下:

$$S(\vartheta)=\left\|\hat{X}_t-X_t\right\|_2^2$$

(20)

其中， ϑ 为模型中所有的可训练参数。

6. 算法分析

6.1. 实验环境

本文提出的 SGNN-TCN 混合模型采用 Pytorch 深度学习框架实现，通过系统的参数调优实验并综合相关领域研究成果，最终确定了 SGNN-TCN 模型在电动自行车需求预测任务中的最优超参数组合，具体数值详见表 1，图 5 展示了模型在配送订单数据集训练过程中损失函数的收敛曲线，反映了模型参数优化的动态过程。当处理数据时，模型会在第 90 次迭代中终止，整个训练时间约为 23 分钟。




Figure 5. Loss value variation curve of the SGNN-TCN model
图 5. SGNN-TCN 模型的损失值变化曲线

Table 1. Experimental parameter

表 1. 实验参数

超参数	电动自行车
图卷积模块 GNN 层数	2
时间序列相似性模块 GNN 层数	2
TCN 临近趋势输入长度	1
TCN 日趋势输入长度	24
TCN 周趋势输入长度	168
TCN 输出特征维数	32
外部因素 FCN 输出特征维度	4
每轮输入数据量	64
优化器	Adam
初始学习率	0.0001
权重衰减	0.0005
损失函数	均方误差(MSE)
早停策略	20 个 epoch 没有下降，模型训练将终止

6.2. 基准方法与评价指标

为系统评估 SGNN-TCN 模型的性能优势, 本文进行了多维度对比实验方案, 选取了 LSTM 模型、DCRNN 模型、STGNN 模型、SGNN-GRU 模型和无其他外部因素的 SGNN-TCN 模型五个模型进行对比。

在评估预测模型的指标时, 本文使用了均方根误差(RMSE)、平均绝对值误差(MAE)以及加权平均绝对百分比误差(WMAPE), 计算过程为:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - y_i)^2} \quad (21)$$

$$\text{WMAPE} = \frac{\sum_{i=1}^n |y_i - \hat{y}_i|}{\sum_{i=1}^n y_i} \quad (22)$$

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |x_i - y_i| \quad (23)$$

其中, x_i 是输出的实数值, y_i 是输出的预测值, N 是样本大小。

6.3. 算法性能分析

采用 SGNN-TCN 混合模型对未来 60 分钟的站点需求进行预测分析, 并与其他 5 个模型进行对比, 通过系统性的对比实验, 全面评估各模型在短期需求预测任务中的表现差异。

为确保对比实验结果的可靠性, 本文对包含随机初始化过程的模型进行了 10 次重复实验, 每次实验采用不同的随机初始化参数, 最终性能指标取多次实验的平均值。表 2 展示了对电动自行车需求量的预测误差值, 选用加权平均绝对百分比误差(WMAPE)作为主要评估指标。

表 2 对比了 SGNN-TCN 模型与五种基准模型, 可以看出 SGNN-TCN 模型相较于其他五种预测模型来说有更加精准的预测性能, 对电动自行车需求量这类具有显著波动特性的时间序列数据, 而 HA 模型通过计算历史数据的平均值进行预测, 适用于数据波动较小且无明显趋势或季节性的情况, ARIMA 模型适用于平稳或可通过差分转化为平稳的时间序列, 然而电动自行车需求量可能受多种因素影响, 如天气因素, 导致数据波动较大, 所以本文没有采用 HA 模型和 ARIMA 模型进行对比实验。

Table 2. Evaluation metrics values of the SGNN-TCN

表 2. SGNN-TCN 模型与其他模型的评价指标值

	RMSE	MAE	WMAPE	训练时长(min)
LSTM	17.3	8.1	35.4	45
DCRNN	15.7	7.3	35.2	39
STGNN	16.1	7.9	35.9	34
SGNN-GRU	16.9	7.8	36.1	42
无外部因素的 SGNN-TCN	18.1	8.6	36.5	39
SGNN-TCN	15.5	6.7	33.5	21

由表 2 可知, SGNN-TCN 的 WMAPE 比 STGNN 低 2.4%, 时空特征捕捉更优, 原因或是 TCN 擅长长序列建模且并行计算能力强。与 SGNN-GRU 相比, 其 WMAPE 低 2.6%, 表明 TCN 通过卷积操作对数据的建模能力更稳健, 适应性也更强, 尤其在短时间和长时间序列建模中表现更出色。

通过对比带有外部因素和不带外部因素的 SGNN-TCN 模型可以看出,加入外部因素之后 SGNN-TCN 模型的 WMAPE 值下降了 3.0%, 精度有了明显提升, 这说明天气因素对模型的预测能力有一定的辅助作用, 能让它更精准地捕捉需求变化的影响。

最后, SGNN-TCN 模型与 DCRNN 模型对比显示, WMAPE 值降低了 1.7%, 这也进一步验证了 TCN 模型在捕捉复杂时空依赖方面的显著优势。不同模型的预测情况如图 6 所示。




Figure 6. Prediction performance of different models

图 6. 不同模型的预测情况

从图 6 可以看出 SGNN-TCN 模型和其他几种模型: 对未来一小时内电动自行车换电需求量的预测结果, 以及预测误差的分布情况, 大部分时间里, SGNN-TCN 模型的预测曲线都更接近真实值, 尤其是在早晚高峰的高需求时段更精准地捕捉到需求的峰值, 预测误差也更小, 这说明 SGNN-TCN 模型的卷积模块在提取时空特征方面能力很强, 特别适合电动自行车这种短时高频的需求场景。和 STGNN 模型相比, SGNN-TCN 模型在不同时间段的预测波动更小, 尤其在需求变化大的时段, SGNN-TCN 模型的稳定性和精度都更高。SGNN-TCN 模型的预测精度也比 SGNN-GRU 模型好, 后者在高需求时段的预测略显不足, 未能很好地捕捉真实需求的变化, 总体对比下来, SGNN-TCN 模型在预测能力上比其他模型好。从预测结果来看, 不含外部因素的 SGNN-TCN 模型和含外部因素的 SGNN-TCN 模型在部分时间段的预测曲线较接近, 但在高需求波动的时段, 加入外部因素后预测精度明显提升, 表明天气等外部因素在电动自行车需求预测中很重要, 尤其是在需求受外部条件显著影响的情况下, 其特征学习效果更突出。这也再次证明了 SGNN-TCN 模型在电动自行车需求量预测中的优势, 为电动自行车换电柜的选址提供了更可靠的需求预测依据。

7. 结论

本文创新性地提出了 SGNN-TCN 模型用于电动自行车换电需求预测。该模型有效融合了时空图神经网络对空间依赖关系的捕捉能力, 以及时间卷积网络对长期时间依赖的建模优势。TCN 通过其因果卷积和膨胀卷积结构, 确保了模型在预测时不会使用未来信息, 同时能够以并行计算方式高效处理序列数据, 显著提高了训练效率并避免了循环神经网络中常见的梯度消失问题。为了系统评估模型性能, 我们设计了对比实验, 将 SGNN-TCN 模型与 LSTM、DCRNN、STGNN、SGNN-GRU 等基准模型在未来 60 分钟站点需求预测任务上进行了全面比较。结果表明, 相较于其他基础模型, 此算法对电动自行车换电需求量预测方面展现出更高的精准度。

基金项目

本课题为四川省大件运输实验室(西华大学, 四川省大件运输有限公司)资助课题(课题编号: XHDJ-202504)部分研究成果。

参考文献

- [1] 孙彪, 常庆男. 基于外卖 O2O 模式的电动自行车设计思考[J]. 设计, 2017(9): 118-119.
- [2] Xing, Q., Chen, Z., Zhang, Z.Q., Huang, X., Leng, Z., Sun, K., *et al.* (2019) Charging Demand Forecasting Model for Electric Vehicles Based on Online Ride-Hailing Trip Data. *IEEE Access*, **7**, 137390-137409.
<https://doi.org/10.1109/access.2019.2940597>
- [3] 何鸿杰. 基于聚类 and 指数平滑法的共享自行车需求预测方法[J]. 交通与运输, 2023, 39(3): 85-89.
- [4] 乔健, 陈少博, 何梦莹. 考虑可变环境因素的公共自行车短期需求预测模型[J]. 计算机应用研究, 2022, 39(8): 2427-2431.
- [5] Kuang, H.X., Deng, K.X., You, L.L. and Li, J. (2025) Citywide Electric Vehicle Charging Demand Prediction Approach Considering Urban Region and Dynamic Influences. *Energy*, **320**, Article ID: 135170.
<https://doi.org/10.1016/j.energy.2025.135170>
- [6] 刘杰, 尚学群, 宋凌云, 等. 图神经网络在复杂图挖掘上的研究进展[J]. 软件学报, 2022, 33(10): 3582-3618.
- [7] Ko, S.M. and Shin, J.W. (2023) Projection of Fuel Cell Electric Vehicle Demand Reflecting the Feedback Effects between Market Conditions and Market Share Affected by Spatial Factors. *Energy Policy*, **173**, Article ID: 113385.
<https://doi.org/10.1016/j.enpol.2022.113385>
- [8] Wang, S.Y., Zhuge, C.X., Shao, C.F., Wang, P.X., Yang, X. and Wang, S.Q. (2023) Short-Term Electric Vehicle Charging Demand Prediction: A Deep Learning Approach. *Applied Energy*, **340**, Article ID: 121032.
<https://doi.org/10.1016/j.apenergy.2023.121032>
- [9] 赵明伟, 张文胜, 王克文, 等. 基于 EMD-PSO-LSTM 组合模型的城市轨道交通短时客流预测[J]. 铁道运输与经济, 2022, 44(7): 110-118.
- [10] Zhang, J.B., Zheng, Y. and Qi, D.K. (2017) Deep Spatio-Temporal Residual Networks for Citywide Crowd Flows Prediction. *Proceedings of the AAAI Conference on Artificial Intelligence*, **31**, 1655-1661.
<https://doi.org/10.1609/aaai.v31i1.10735>