

中文引用格式:李福,吕伟,程文燕. 多源融合深度学习的电动汽车充电站负荷预测与风险预警[J]. 中国安全科学学报, 2026, 36(4):28-37.

英文引用格式:Li Fu, Lyu Wei, Cheng Wenyan. Multi-source fusion deep learning for electric vehicle charging station load forecasting and risk early warning [J]. China Safety Science Journal, 2026, 36(4):28-37

多源融合深度学习的电动汽车充电站负荷 预测与风险预警*

李福¹, 吕伟¹教授, 程文燕²

(1 武汉理工大学 安全科学与应急管理学院, 湖北 武汉 430070;

2 湖北中天亿信科技股份有限公司, 湖北 武汉 430073)

中图分类号:X924.2

文献标志码:A

DOI: 10.16265/j.cnki.issn1003-3033.2026.04.0114

【摘要】 为解决因电动汽车充电站规模持续扩大而导致电力过载、负荷波动及需求分布不均等风险,提出一种基于多源数据融合深度学习模型(混合深度融合(HDF)-长短期记忆(LSTM)网络)的负荷预测与分级预警方法,以实现高精度负荷预测与动态风险分级告警。该模型融合长短期记忆网络LSTM、循环神经网络(GRU)与自注意力机制Transformer结构,综合利用历史负荷、气象和交通流量等多源数据,并通过Pearson相关性分析与动态权重分配机制提升非线性特征的表达能力;在《电动汽车充电站设计标准》中变压器容量和同时率的约束条件下,设计三级风险预警机制,确保在运行接近临界水平时实现快速告警。结果表明:HDF-LSTM在预测精度上优于极端梯度提升(XGBoost)、GRU、LSTM和Transformer等模型,均方误差(MSE)与平均绝对误差(MAE)分别降至0.1852和0.2682,决定系数 R^2 达到0.9857,且具备较好的计算效率,适用于能耗预测与风险阈值动态计算等场景。

【关键词】 多源数据; 深度学习; 电动汽车充电站; 负荷预测; 风险预警

Multi-source fusion deep learning for electric vehicle charging station load forecasting and risk early warning

Li Fu¹, Lyu Wei¹, Cheng Wenyan²

(1 School of Safety Science and Emergency Management, Wuhan University of Technology,

Wuhan Hubei 430070, China; 2 Hubei ZTYS Technology Co., Ltd., Wuhan Hubei 430073, China)

Abstract: With the continuous expansion of electric vehicle charging stations, the power grid faces increasing risks such as power overload, load fluctuations, and uneven demand distribution. To address these issues, this paper proposes an Hybrid Deep Fusion(HDF)-Long Short-Term Memory(LSTM)-based method for load forecasting and graded early warning. The method integrates LSTM, Gated Recurrent Unit (GRU), and Transformer architectures with multi-source data, including historical load, meteorological conditions, and traffic flow. Pearson correlation analysis and a dynamic weight allocation mechanism are employed to improve nonlinear feature representation. Based on the transformer capacity and simultaneity factor specified in the Code for Design of Electric Vehicle Charging Stations, a three-level early warning

mechanism is developed for rapid alerting near critical thresholds. Results show that the proposed model outperforms eXtreme Gradient Boosting(XGBoost), GRU, LSTM, and Transformer models, with an Mean Squared Error(MSE) of 0.185 2, an Mean Absolute Error(MAE) of 0.2682, and an R^2 of 0.985 7. The model also shows good computational efficiency and application potential in charging station load forecasting and operational risk warning.

Keywords: multi-source data fusion; deep learning; electric vehicle charging station; load forecasting; risk early warning

0 引言

电动汽车(Electric Vehicle, EV)市场的快速发展带动了充电基础设施的持续扩张。2024 年,中国大陆电动汽车渗透率已接近 50%,公共充电桩数量占全球总量的 65%,同比增幅超过 30%^[1]。充电站规模的快速增长,使电力过载、负荷波动和需求分布不均等问题日益突出,对电网安全运行形成直接威胁^[2]。因此,开展高精度负荷预测与动态风险预警研究^[3],成为保障电网安全和支撑智慧城市能源管理的关键任务^[4]。

传统负荷预测方法(如自回归积分滑动平均模型、功率平衡模型)在处理高维多源数据和复杂非线性关系时存在局限,预测精度有限^[5]。近年来,深度学习技术在充电负荷预测中展现出显著优势。长短期记忆(Long Short-Term Memory, LSTM)网络^[6]通过门控机制有效捕捉时间序列的长期依赖关系,预测精度优于传统方法^[7]。张洪财等^[8]提出了融合时空因素的预测方法,陆继翔等^[9]结合卷积神经网络(Convolutional Neural Network, CNN)与 LSTM 构建混合神经网络模型,提高了短期预测精度。在此基础上,多源数据融合逐渐成为研究热点,为解决充电负荷预测中的多维特征问题提供技术路径^[10]。吴思培等^[11]验证了交通流量与充电需求的相关性,Aduama 等^[12]利用 Transformer-LSTM 混合模型将预测均方误差(Mean Squared Error, MSE)降低约 20%。然而,现有研究仍存在不足:一是多源数据权重分配缺乏动态优化,非线性特征表达能力受限;二是现有模型鲁棒性不足,难以适应极端场景;三是风险预警机制未能充分结合《电动汽车充电站设计标准》^[3]的工程约束条件,如同时率范围 0.5~0.8。

在风险预警研究方面,李存斌等^[13]提出一种基于多重分形去趋势波动分析的方法,刘俊峰等^[14]利用深度强化学习技术,研究了微能源网的能量管理和优化策略。魏瑞增等^[10]提出结合多源预测与场

景分类的能源预警方法。高德新等^[15]基于深度信念网络(Deep Belief Network, DBN)提升了故障检测能力。唐敏安等^[16]利用加权无迹卡尔曼滤波(Weighted Unscented Kalman Filter, UKF)算法实现城市区域负荷预测。易强等^[17]提出了基于多智能体行程模拟的充电需求预测。Shen Yu 等^[18]进一步将 VMD-LSTM 与模糊模型结合用于稳态电能质量风险预警。这些方法未且尚未充分满足文献[3]要求。国际能源署预测,2030 年中国电动汽车渗透率将超过 80%,电网稳定性将面临更高挑战^[1]。

针对上述问题,本文拟提出一种多源数据驱动的深度学习模型(混合深度融合(Hybrid Deep Fusion, HDF)-LSTM),融合 LSTM、门控循环单元(Gated Recurrent Unit, GRU)^[7]与 Transformer^[19]等模型结构优势,并在负荷预测基础上提出分级预警方法,以提升电动汽车充电站复杂场景下的预测精度与风险识别能力;同时基于 EV Charging Station Usage 数据集^[20]和 Metro Interstate Traffic Volume 数据集^[21]开展试验,并与 CNN-LSTM^[22]、DBN 和极端梯度提升(eXtreme Gradient Boosting, XGBoost)等典型模型进行对比分析,以期可为充电站安全运行与电网调度提供依据。

1 充电站负荷预测数据构建

为提高电动汽车充电站负荷预测的准确性,并为风险预警模型提供可靠数据支撑,选取充电站公开数据集,并结合公路交通数据集,开展充电行为与交通状况的联合建模^[23-24]。2 类数据均为真实采集,但来源和维度存在差异,因此,在建模前需进行时间对齐、地理匹配和特征清洗等预处理。通过时间戳解析、位置映射及特征工程,完成多源数据的统一建模,为模型训练和验证奠定基础。

1.1 多源负荷特征构成

1) 电动汽车充电站数据。充电站公开数据集记录了公共充电站的运行信息,包括站点位置、充电接口类型、交易起止时间、充电时长及总能耗等

核心特征。该数据能够反映用户的充电行为模式和基础设施利用水平,为分析充电需求波动、识别高峰时段及评估运行效率提供可靠依据^[25]。

2) 交通和天气数据。州际交通数据集包含州际公路交通特征,如交通流量、交通密度和交通事件等。通过时间与空间的匹配,可耦合分析交通状况与充电行为,从而量化交通对充电负荷的影响^[26]。此外,该数据集还提供温度、降雨量、降雪量、云量和天气类别等气象信息,这些因素是负荷预测与风险预警的重要补充变量^[27]。

综上,电动汽车充电站数据、交通数据与气象数据相结合,可从用户行为、交通状况和环境条件3个维度刻画影响充电负荷的关键因素,从而提升预测模型在复杂场景下的准确性和稳定性。其主要特征关系见表1。

表1 电动汽车充电站使用数据与交通、天气的特征关系
Table 1 Correlation of charging station usage with traffic and weather features

类别	相关特征	特征作用分析
电量	交通流量, 交通密度	流量密度决定进出频率,影响负荷波动
充电时间	事件持续时间, 事件类型	事件属性影响停留时长与功率需求
位置	纬度,经度	地理位置反映区域差异,影响负荷分布
时区	时间,交通流量	时段与流量变化揭示负荷高低峰
天气	温度,降雨量, 降雪量,云量	天气条件影响出行充电,致负荷波动

1.2 负荷预测数据预处理

数据预处理是保障模型性能和结果可靠性的关键环节,主要包括以下步骤:

1) 数据合并与对齐。基于充电会话的起止时间与交通数据的时间戳,按小时粒度对齐。利用充电站经纬度与交通数据区域范围匹配,确保时间与空间一致性。通过地理距离和K-最近邻算法(K-Nearest Neighbors, KNN)匹配交通数据,并聚合同一区域内的充电站数据,计算交通量、能耗和充电时长的总量或均值,以全面刻画区域充电需求和交通状况。

2) 数据清洗与转换。首先统一时间信息至协调世界时,并按需调整至中央时区。缺失值采用不同策略处理:天气相关特征用均值或中位数填补,关键特征则使用历史均值补全。重复项予以删除,分类变量经独热编码或标签编码转换为数值形式;地

理数据格式统一,以保证一致性。

3) 特征工程。为增强模型的特征表达能力,提取以下关键特征:时间特征:小时、星期、节假日及高峰时段,用于反映周期性波动。天气特征:主要天气类别及极端天气(如暴雨、高温)标注,用于分析环境影响。地理特征:充电站至主干道或城市中心的距离,以及区域交通流量,用于衡量交通密度影响。用户行为特征:日均充电量、能耗与使用频率,用于揭示充电行为模式。

4) 时间序列划分。数据集分为训练集(70%~80%)、验证集(10%~15%)和测试集(10%~15%)。训练集用于模型构建,验证集用于参数优化,测试集用于性能评估,以确保模型具备良好的泛化能力。

1.3 负荷时空特征可视化分析

为揭示数据分布特征并验证预处理效果,采用可视化方法统计分析主要变量,重点考察时间序列趋势、空间分布规律及变量相关性,为模型构建提供参考。数据加载通过Python的pandas库实现,图形绘制借助于matplotlib与seaborn库完成。

图1为电力消耗的分布情况,结果呈右偏,主要集中在5~10 kWh区间。核密度曲线峰值明显,表明样本量充足,分布稳定。图2为24 h周期内的电力消耗特征,高峰时段集中在8:00—10:00和18:00—21:00,呈现典型的双峰结构。高峰时段离散度较大,但异常值分布合理,反映数据采集质量较好。图3为全年日用电量呈峰谷波动(0~50 kWh),高峰在3、9月末、11月中;6—8月低而稳,季节特征明显,整体趋势具有预测价值。图4为一周内用电负荷的差异,工作日的用电中位数略高于周末,符合日常活动规律。表明各天波动幅度接近,异常值多出现在高负荷时段,可能与天气或特定活动相关。四分位距适中,说明用电行为相对稳定,具备一定的预测性。




图1 总电力消耗分布直方图
Fig. 1 Total power consumption distribution histogram

图5为电力消耗与其他特征关系图,其散点矩




图 2 按时刻划分的电力消耗

Fig. 2 Hourly power consumption chart




图 3 按天划分的电力消耗

Fig. 3 Power consumption chart by day




图 4 按周划分的电力消耗

Fig. 4 Power consumption chart by day of week

阵反映了能源消耗、总功率消耗与时刻、周的关系。对角线密度图揭示了各变量的分布特征,非对角线散点则体现变量间相关性。能源消耗与总功率消耗呈显著正相关,近似线性分布;时间维度上表现出明显周期性特征,提示负荷受时段和星期规律性影响。结合图 1—图 5 可知:电力负荷在小时、日、周和年等尺度均呈现规律性;日内存在双峰,工作日与周末存在差异,年度表现出季节性波动。相关性分析进一步验证了主要变量间的显著关联,为预测模型提供了多维度支撑,也说明数据具备可靠性。

1.4 负荷影响因素相关性分析

为量化不同数据源与充电负荷的关系,并为特征加权提供依据,对充电负荷、充电时长、交通量及气象变量(温度、降雨量、降雪量、云量)进行 Pearson 相关系数分析,结果如图 6 所示。




图 5 电力消耗与其他特征关系

Fig. 5 Relationship between power consumption and other features




图 6 多源特征的 Pearson 相关系数矩阵

Fig. 6 Pearson correlation matrix of multi-source features

特征加权采用相关性归一化方法^[28],其权重计算公式为:

$$w_x = \frac{r_x}{\sum r} \tag{1}$$

式中: r_x 为第 x 个特征变量与充电负荷的相关系数; W_x 为其对应的权重,其中, $x = 1, 2, \dots, n$ 。相关性较高的特征(如充电时长)被赋予更大权重,而相关性弱或冗余特征(如交通量、温度)权重相对较低。由图 6 可知:充电时长与负荷的相关系数最高 0.70,交通量与负荷呈弱负相关-0.15;温度与降雨量、云量与降雪量之间相关系数接近 1.00,说明存在强共线性。

2 负荷预测模型与预警机制

2.1 LSTM 基本原理

LSTM^[6] 是循环神经网络 (Recurrent Neural Network, RNN) 的改进模型,通过引入遗忘门、输入门与输出门这一核心门控机制(图 7),有效解决了 RNN 的梯度消失与爆炸问题。该机制能动态调控细胞状态中的信息更新与保留,从而擅长捕捉时间序列中的长期依赖关系及周期波动、随机扰动等非线性特征。




图 7 LSTM 门控机制与状态传递

Fig. 7 LSTM gating mechanism and state transition diagram

2.2 MSA-LSTM 预测模型构建

为处理多维时间序列数据,在原 LSTM 基础上构建多尺度注意力 (Multi-Scale Attention, MSA)-LSTM 基准深度学习模型。模型结构如图 8 所示。MSA-LSTM 模型主要包括以下部分:

1) 输入与特征处理。将原始输入划分为时间特征、历史负荷特征和辅助特征 3 类,经嵌入层映射为向量表示。

2) 多尺度 LSTM 层。设置小时、日和周 3 个并行 LSTM,用于捕捉短期波动、日常规律和长期趋势。

3) 特征融合与增强。通过自注意力机制整合多尺度输出,突出关键特征;采用 Dropout (20%) 与 L2 正则化提升泛化能力。

4) 输出层。经特征整合后,通过线性激活函数生成预测结果。

该分层架构结合多尺度特征提取与注意力机制,能够在复杂时序环境下提升预测精度与鲁棒性。

2.3 风险预警机制构建

为保障充电站在快速扩张背景下的电力供应安全,基于文献[3],构建分级预警机制。该机制结合




图 8 MSA-LSTM 模型结构

Fig. 8 MSA-LSTM model architecture diagram

历史负荷及外部数据(能耗、温度、降水量等),通过预测实时负荷,动态调整变压器容量与电网调度。其核心是合理核定最大功率 $P_{\max}$,并设置多级阈值,实现从正常运行到应急处置的分级响应。

1) 最大功率核定。根据文献[3],充电站变压器容量需考虑同时率(0.5~0.8),计算如下:

$$S = \sum P_i \times k \tag{2}$$

式中: P_i 为单桩功率, kW; k 为同时率(公共站 0.6~0.8,专用站 0.4~0.6)^[3]。在此基础上引入修正因子 m ,重新核定最大功率:

$$P_{\max} = S \times (1 + m) \tag{3}$$

其中, m 设定为 10%,用于覆盖储能备用和峰值波动。结合运行要求(如武汉地区规定峰时负荷不得超过额定容量的 80%),对 S 进行约束性优化。

同时,设计中考虑进线电缆载流能力(如 10 kV 电缆最大 400 A)及峰谷电价,峰时电价期间阈值上调 15%,以分散负荷压力;谷时适度下调,提高用电效率。储能备用容量统一设为 $P_{\max}$ 的 20%,用于削峰填谷,增强系统鲁棒性。

2) 阈值设定与响应机制。基于核定的 $P_{\max}$,构建三级预警机制(表 2),按负荷率区间划分等级,并对应不同调度策略。该机制实现了从常态运行、风险预警到应急处置的逐级管控。

表 2 预警响应机制

负荷比例	预警等级	区域	响应机制
< 60% $P_{\max}$	正常运行	绿色	正常运行, 储能保持备用
60% ~ 80% $P_{\max}$	二级预警	黄色	进入预备调度, 启用储能放电
$\geq 80\%$ $P_{\max}$	三级预警	红色	启动限流或停电保护, 并上报调度中心

3) 约束条件与优化。预警机制在运行过程中需满足以下约束条件:① 储能容量约束。储能备用不低于 $P_{\max}$ 的 20%, 确保峰值负荷下具备应急支撑能力。②峰谷电价约束。峰时将三级阈值上调至 92% $P_{\max}$, 谷时将一级解除阈值下调至 48% $P_{\max}$, 实现经济性与安全性平衡。③工程实践约束。依据文献[3], 公共充电站同时率取 0.7, 并结合充电站公开数据数据修正 S 值, 使机制更符合实际运行条件。

2.4 MSA-LSTM 训练结果

为评估 MSA-LSTM 模型的预测性能, 采用 MSE、均方根误差 (Root Mean Squared Error, RMSE)、平均绝对误差 (Mean Absolute Error, MAE) 和决定系数 R^2 这 4 项指标, 从不同维度反映预测精度与拟合能力。




图 9 真实值与预测值对比

Fig. 9 Comparison chart of actual values and predicted values

图 9 显示, 预测曲线与实际负荷走势高度一致, 尤其在峰值点 (约 16 kWh) 表现出较高精度, 说明模型能够有效捕捉负荷的动态变化及极值特征。

图 10 为残差分布。由图 10 可知: 残差主要集中在 ± 1 kWh 范围内, 分布近似正态, 说明预测性能稳定, 无明显系统性偏差。图 11 为模型训练与验证损失曲线。从图 11 可以看出, 模型在前 10 个轮次 (epoch) 内损失快速下降, 随后趋于平稳收敛; 训练与验证损失曲线间隔适度, 说明模型具备良好泛化能力。

量化结果显示, $MSE = 0.719\ 9$, $RMSE = 0.848\ 5$, $MAE = 0.674\ 8$, $R^2 = 0.943\ 8$, 说明预测误




图 10 残差分布

Fig. 10 Residual distribution




图 11 模型训练与验证损失曲线

Fig. 11 Model training and validation loss curve

差较小, 模型能解释 90% 以上的负荷变化, 验证了其在实际应用中的可靠性。

2.5 HDF-LSTM 模型优化

MSA-LSTM 在负荷预测中表现较好, 但在负荷大幅波动场景下仍存在精度不足, RMSE 为 0.848 5, 残差分布略呈偏态, 训练后期收敛减缓。为进一步提升模型性能, 提出多源融合深度学习模型 HDF-LSTM, 其结构如图 12 所示。

1) 模型架构优化。HDF-LSTM 模型接收多源数据 (负荷、气象、交通), 通过 CNN、Transformer 和双向 LSTM (Bidirectional LSTM, BiLSTM) 网络分支分别提取局部模式、全局依赖和长期序列特征, 同时辅以辅助特征分支增强表达能力。各分支输出经特征融合层整合, 并通过全局平均池化降维, 最终由线性激活输出预测值。

2) 训练过程优化。为提升训练效率与稳定性, 采用以下策略: ①数据预处理。包括最小-最大 (min-max) 归一化以缩放特征, 以及线性插值法填补缺失值。数据集按 70%、15%、15% 的比例划分为训练集、验证集和测试集。②优化器与超参数。优化器采用自适应矩估计 (Adaptive Moment Estimation, Adam) (初始学习率为 0.001, 每 10 个 epoch 衰减 0.1); 批量大小设为 32; 最大训练轮数为 100, 并启用早停策略 (耐心值为 10); 损失函数为 MSE, L2 正则化系数 0.01。③稳定性增强。在 Transformer 与 BiLSTM 层应用层归一化, Dropout 比率 0.2, 防止过拟合。




图 12 HDF-LSTM 模型结构

Fig. 12 HDF-LSTM model architecture diagram

3) 性能验证与分析。优化后的 HDF-LSTM 在预测精度上显著优于 MSA-LSTM: ①指标对比: MSE 从 0.719 9 降至 0.185 2, RMSE 从 0.848 5 降至 0.427 2, MAE 从 0.674 8 降至 0.268 2, R^2 从 0.943 8 提升至 0.985 7。②验证方法: 采用 5 折交叉验证, 确保稳定性; 在极端天气(降雨量 > 50 mm)和交通高峰(流量 > 1 000 veh/h)下, RMSE 仍低于

0.5。③性能提升原因: CNN 提取局部特征, Transformer 建模全局依赖, BiLSTM 捕捉双向时序, 融合层实现协同优化; 层归一化与 Dropout 抑制过拟合, 全局平均池化降低参数量并提升计算效率。

2.6 负荷预测与预警效果评估

为验证 HDF-LSTM 模型的有效性, 从预测精度、鲁棒性和预警功能 3 个方面展开评估, 并结合图 13、图 14 及表 3、表 4 对比说明。

1) 预测精度评估。为比较 HDF-LSTM 与其他主流模型的性能, 在同一物理环境(双核 Intel Core i5 2.7 GHz, 内存 8 GB, 未使用 GPU 加速)及同一经过预处理的数据集(Cleaned_Merged_Data)上进行对比测试, 确保公平性。图 13 为模型在测试集上的预测表现。实际值与预测值高度吻合, 仅在个别峰值点存在轻微偏差, 残差分布集中于 0 附近且近似正态, 说明模型无明显系统性误差。散点图中大部分点落在对角线附近, 表明拟合效果理想。表 3 列出了多种模型的量化指标对比结果。HDF-LSTM 在 MSE、RMSE 和 MAE 指标上均取得最优表现(MSE = 0.185 2, MAE = 0.268 2, R^2 = 0.985 7), 优于 XGBoost、CNN-LSTM、GRU、LSTM 和 Transformer。相较传统 LSTM, 其预测误差降低幅度超过 70%, 验证了所提模型在预测精度上的优势。




图 13 HDF-LSTM 模型性能特征

Fig. 13 Performance characteristics diagram of HDF-LSTM model

表 3 多种模型的量化指标训练结果对比

Table 3 Comparison of quantitative metrics for multiple models

模型	MSE	RMSE	MAE	R^2	训练时间/s	预测时间/s
HDF-LSTM	0.185 2	0.427 2	0.268 2	0.985 7	94.72	0.31
XGBoost	0.265 1	0.514 8	0.384 9	0.979 3	0.169 0	0.003 6
CNN-LSTM	0.384 2	0.619 8	0.442 6	0.970 0	14.511 8	0.591 3

续表 3

模型	MSE	RMSE	MAE	R^2	训练时间/s	预测时间/s
GRU	1.163 8	1.078 8	0.640 9	0.909 1	16.065 3	1.431 2
LSTM	4.223 7	2.055 2	1.455 3	0.670 2	17.913 4	2.262 8
Transformer	1.275 9	1.129 6	0.856 8	0.900 4	11.994 3	0.450 8

表 4 为综合得分(满分 3.0)。HDF-LSTM 在精度维度表现突出,总体得分最高(1.38),体现了模型在精度与效率之间的均衡性。

表 4 综合得分(满分 3.0)

Table 4 Composite score (maximum: 3.0)

模型	精度得分	效率得分	总体得分
HDF-LSTM	1.75	0.50	1.38
XGBoost	1.40	1.00	1.28
CNN-LSTM	1.05	0.75	0.96
GRU	0.70	0.55	0.66
LSTM	0.35	0.45	0.38
Transformer	0.70	0.75	0.72

2) 鲁棒性与泛化能力。为验证模型在复杂工况下的适应性,选取数据集中异常值极端天气(降雨量> 50 mm)和交通高峰(流量> 1 000 辆/h)等场景进行测试。结果显示,HDF-LSTM 的 RMSE 始终保持在 0.5 以下,预测曲线依旧紧密贴合实际曲线。结合残差图 13 可知:误差分布稳定,无显著偏移,说明模型在异常条件下仍能保持较高预测精度,具备良好的鲁棒性和泛化能力。

3) 预警功能评估。基于核定的 $P_{\max}$,采用三级分级预警机制(表 2)验证模型,效果如图 14 所示。数据来自多源融合后的 Cleaned_Merged_Data 数据集,包含充电站运行、交通流量与气象特征,保证了评估的真实性与复杂性,运行结果表明:当前状态:负载率预测值为 21.92%,实际值为 20.52%,均处于正常区间($<60\%P_{\max}$),无需触发预警。

统计特征。在整个测试周期内,最大负载率仅为 41.26%,平均负载率为 16.30%,始终低于二级预警阈值;超载情况($\geq 80\%P_{\max}$)未出现,超载频率为 0.00%。

分级一致性。图 14 的时序对比表明:预测负载率整体趋势与实际高度一致,在“正常运行区”时间占比接近,差异极小;在接近临界阈值的区间,预测值略有偏差,但未影响整体分级判断。

整体来看,模型能够准确跟踪负载波动,正确划分预警等级,特别是在正常运行区保持了与实际接近的一致性,说明其在风险识别和分级预警中的可靠性较高。




图 14 HDF-LSTM 模型预测结果及动态预警

Fig. 14 Prediction results and dynamic early warning diagram of HDF-LSTM model

3 结 论

1) HDF-LSTM 在主要量化指标上优于对比模型。与传统 LSTM 相比,其 MSE、RMSE、MAE 分别下降约 70%, R^2 提升至 0.985 7,能够准确刻画负荷动态变化。鲁棒性测试显示,该模型在极端天气和交通高峰场景下依旧保持较低预测误差($RMSE < 0.5$),残差分布稳定,无明显系统性偏差,体现了较强的泛化能力。基于文献[3]设计的分级预警机制,验证了模型在实际运行环境中的适用性,能够准确识别不同负荷区间的运行状态,确保风险响应及时可靠。

2) 与以往研究相比,HDF-LSTM 的优势主要体现在 3 方面:①通过多源数据融合与动态权重分配,提高了模型对非线性特征的表达能力;②集成卷积、双向序列建模与注意力机制,实现了局部与全局特征的协同提取;③结合国家标准阈值设计的分级预警机制,为电动汽车充电站运行优化与电网调度提供了可操作的技术路径。

3) 未来将基于大规模真实电动汽车充电站数据进一步开展模型验证,并探索其在联邦学习与边缘计算场景下的实时部署潜力,以增强方法的工程应用能力与推广价值。

参考文献

- [1] International Energy Agency. Global electric vehicle outlook 2025[R/OL]. [2025-09-15]. <https://www.iea.org/reports/global-ev-outlook-2025>.
- [2] 黄匀飞, 魏志文, 余江盛, 等. 基于配置协调优化的多站融合供电调峰运行方法研究[J]. 电力系统自动化, 2024, 48(23): 46-53.
Huang Yunfei, Wei Zhiwen, Yu Jiangsheng, et al. Research on the peak shaving operation method of multi-station Integrated power supply based on configuration coordination optimization[J]. Automation of Electric Power Systems, 2024, 48(23): 46-53.
- [3] GB/T 50966—2024 电动汽车充电站设计标准[S].
GB/T 50966-2024 Design code for electric vehicle charging stations[S].
- [4] 何淑波, 项薇, 石钟淼. 基于机器学习的电动汽车电池系统的风险预警[J]. 中国安全科学学报, 2023, 33(2): 159-165.
He Shubo, Xiang Wei, Shi Zhongmiao. Risk early warning of electric vehicle battery system based on machine learning[J]. China Safety Science Journal, 2023, 33(2): 159-165.
- [5] Xie Tuo, Su Yang, Zhang Gang, et al. Optimizing peak-shaving cooperation among electric vehicle charging stations: a two-tier optimal dispatch strategy considering load demand response potential[J]. International Journal of Electrical Power & Energy Systems, 2024, 162: DOI: 10.1016/j.ijepes.2024.110228.
- [6] Hochreiter S, Schmidhuber J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.
- [7] He Xin, Zhao Wenlu, Gao Zhijun, et al. Short-term load forecasting by GRU neural network and DDPG algorithm for adaptive optimization of hyperparameters[J]. Electric Power Systems Research, 2025, 238: DOI: 10.1016/j.epsr.2024.111119.
- [8] 张洪财, 胡泽春, 宋永华, 等. 考虑时空分布的电动汽车充电负荷预测方法[J]. 电力系统自动化, 2014, 38(1): 13-20.
Zhang Hongcai, Hu Zechun, Song Yonghua, et al. A prediction method for electric vehicle charging load considering spatial and temporal distribution[J]. Automation of Electric Power Systems, 2014, 38(1): 13-20.
- [9] 陆继翔, 张琪培, 杨志宏, 等. 基于 CNN-LSTM 混合神经网络模型的短期负荷预测方法[J]. 电力系统自动化, 2019, 43(13): 131-137.
Lu Jixiang, Zhang Qipei, Yang Zhihong, et al. Short-term load forecasting method based on cnn-lstm hybrid neural network model[J]. Automation of Electric Power Systems, 2019, 43(13): 131-137.
- [10] Wei Ruizeng, Hu Siyu, Fan Yang, et al. New energy power prediction and warning based on multi-source prediction and scene classification recognition[J]. Procedia Computer Science, 2023, 224: 401-406.
- [11] Wu Sipei, Xiao Yao, Fu Shengxiang, et al. A hybrid deep learning model for load forecasting of electric vehicle charging stations using time series decomposition[J]. Journal of Power Sources, 2025, 655: DOI: 10.1016/j.jpowsour.2025.237882.
- [12] Aduama P, Zhang Zhibo, Al-sumaiti A S. Multi-feature data fusion-based load forecasting of electric vehicle charging stations using a deep learning model[J]. Energies, 2023, 16(3): DOI:10.3390/en16031309.
- [13] 李存斌, 李庆良, 王庆林, 等. 基于多重分形去趋势波动分析的电力负荷风险预警阈值[J]. 电力系统自动化, 2016, 40(5): 1437-1441.
Li Cunbin, Li Qingliang, Wang Qinglin, et al. Research on electric power load risk warning threshold based on multi-fractal detrended fluctuation analysis[J]. Automation of Electric Power Systems, 2016, 40(5): 1437-1441.
- [14] 刘俊峰, 陈剑龙, 王晓生, 等. 基于深度强化学习的微能源网能量管理与优化策略研究[J]. 电力系统自动化, 2020, 44(14): 3794-3803.
Liu Junfeng, Chen Jianlong, Wang Xiaosheng, et al. Energy management and optimization of micro-energy grid based on deep reinforcement learning[J]. Automation of Electric Power Systems, 2020, 44(14): 3794-3803.

[15] Gao Dexin,Wang Yi,Zheng Xiaoyu, et al. A fault warning method for electric vehicle charging process based on adaptive deep belief network[J]. World Electric Vehicle Journal, 2021, 12(4): DOI:10.3390/wevj12040265.

[16] Tang Minan, Guo Xi, Qiu Jiandong, et al. Electric vehicle charging load demand forecasting in different functional areas of cities with weighted measurement fusion UKF algorithm[J]. Energies, 2024, 17(17): DOI:10.3390/en17174505.

[17] Yi Qiang, Zhou Yifei, Gebreyesus G D, et al. Multi-agent trips simulation-based charging demand forecasting[J]. IEEE Transactions on Electrical and Electronic Engineering, 2025, 20(8): 1 219–1 228.

[18] Shen Yu, Hu Wei, Dong Mingqi, et al. A risk warning method for steady-state power quality based on VMD-LSTM and fuzzy model[J]. Heliyon, 2024, 10(9): DOI:10.1016/j.heliyon.2024.e30597.

[19] Zhou Haoyi, Zhang Shanghang, Peng Jieqi, et al. Informer: beyond efficient transformer for long sequence time-series forecasting[C]. Proceedings of the AAAI Conference on Artificial Intelligence, 2021: 11 106–11 115.

[20] Hogue J. EV charging station usage of California city[DB/OL]. [2025-09-15]. <https://www.kaggle.com/datasets/venkatsairo4899/ev-charging-station-usage-of-california-city>.

[21] UCI. Metro interstate traffic volume[DB/OL]. [2025-09-15]. <https://archive.ics.uci.edu/dataset/492/metro+interstate+traffic+volume>.

[22] Cui Xuyang,Zhu Junda,Jia Lifu, et al. A novel heat load prediction model of district heating system based on hybrid whale optimization algorithm (WOA) and CNN-LSTM with attention mechanism[J]. Energy, 2024, 312: DOI: 10.1016/j.energy.2024.133536.

[23] Madaram V G, Biswas P K, Sain C, et al. Advancement of electric vehicle technologies, classification of charging methodologies, and optimization strategies for sustainable development: a comprehensive review[J]. Heliyon, 2024, 10(20): DOI:10.1016/j.heliyon.2024.e39299.

[24] 熊智, 钟少波, 宋敦江, 等. 城市轨道交通客流量时间序列分段拟合方法[J]. 中国安全科学学报, 2018, 28(11): 35–41.

Xiong Zhi, Zhong Shaobo, Song Dunjiang, et al. A method of fitting urban rail transit passenger flow time series[J]. China Safety Science Journal, 2018, 28(11): 35–41.

[25] Xu Xianfeng, Wu Jiahao, Lu Yong, et al. A spatio-temporal prediction approach for charging load of clustered electric vehicles in dynamic traffic flow environment of highway[J]. Sustainable Energy, Grids and Networks, 2024: DOI: 10.1016/j.segan.2024.101593.

[26] Li Benxin, Chang Xuanming. EV Charging station load prediction in coupled urban transportation and distribution networks[J]. Energy Engineering, 2024, 121(10): 3 001–3 018.

[27] Li Xinli, Zhang Kui, Luo Zhenglong, et al. Two-stage dual-attention spatiotemporal joint network model for multi-energy load prediction of integrated energy system[J]. Sustainable Energy Technologies and Assessments, 2024, 72: DOI: 10.1016/j.seta.2024.104085.

[28] Ba J L, Kiros J R, Hinton G E. Layer normalization[C]. Advances in Neural Information Processing Systems, 2016: 1–9.

作者简介： 李 福 （1981—）,男,湖北恩施人,博士研究生,研究方向为基于人工智能的安全科学与工程、应急管理 与风险智能预测控制。E-mail:492566@qq.com。

