

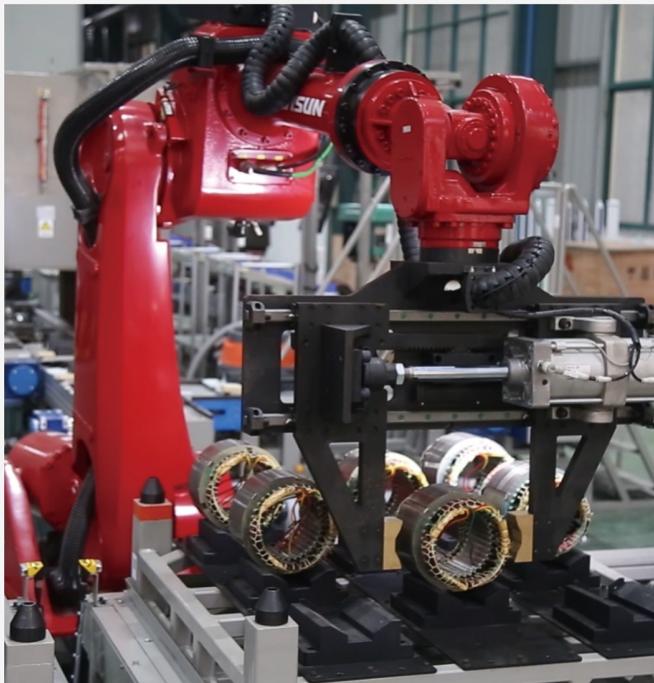
本文全文线上首发由
上海电器科学研究所
(集团)有限公司
支持

吴丹,甄昊涵,雷斑,陈津,钱勇生,
李樵,郑陆海.
基于CNN和LSTM混合网络的电动汽车
充电桩运行状态预测方法.
电机与控制应用,2022,49(2):83.



中国智能制造系统解决方案供应商联盟（成员）
上海智能制造系统解决方案供应商（首批）

电机·智能制造



咨询服务

规划设计

设计制造

信息化系统

项目实施



扫码联系我们

联系人: 黄先锋 手机: 13501892388
上海电器科学研究所(集团)有限公司
上海电机系统节能工程技术研究中心有限公司
上海市武宁路505号9号楼6层

基于 CNN 和 LSTM 混合网络的电动汽车充电桩运行状态预测方法^{*}

吴丹¹, 甄昊涵¹, 雷斑¹, 陈津¹, 钱勇生², 李樵², 郑陆海²

[1. 国网上海市电力公司, 上海 200122; 2. 上海电器科学研究所(集团)有限公司, 上海 200063]

摘要: 随着电动汽车的大规模发展, 公共充电桩运行数量和充电量逐年增长。然而, 充电桩运行始终存在故障频发、运维难度大和维修成本高等问题, 并且传统故障检测方法效率低下。因此提出了一种基于卷积神经网络(CNN)和长短期记忆(LSTM)网络的混合网络电动汽车充电桩运行状态预测方法, 可以实现对电动汽车充电桩运行状况的综合评估。在特征数据输入阶段, 对充电桩运行状态的关键指标进行分析, 通过CNN提取运行状态影响因素的特征量, 再利用LSTM判断和预测充电桩运行状态, 从而实现对充电桩潜在故障的预警。试验结果表明, 该方法预测准确率高、实用性强, 能较准确地反映和预测充电桩的运作状态, 可实际用于充电桩故障预测与运维检修。

关键词: 电动汽车充电桩; 故障预测; 卷积神经网络; 长短期记忆

中图分类号: TM93 文献标志码: B 文章编号: 1673-6540(2022)02-0083-07

doi: 10.12177/emca.2021.188

Prediction Method of Electric Vehicle Charging Pile Operating State Based on CNN and LSTM Hybrid Network^{*}

WU Dan¹, ZHEN Haohan¹, LEI Ting¹, CHEN Jin¹, QIAN Yongsheng², LI Qiao², ZHENG Luhai²

[1. State Grid Shanghai Municipal Electric Power Company, Shanghai 200122, China;
2. Shanghai Electrical Apparatus Research Institute (Group) Co., Ltd., Shanghai 200063, China]

Abstract: With the large-scale development of electric vehicles, the number of public charging piles in operation and the charging capacity are increasing year by year. However, there are many problems in the operation of charging pile, such as frequent failures, difficult operation and high maintenance costs, and traditional fault detection methods are inefficient. Therefore, a hybrid network prediction method of electric vehicle charging pile operation state based on convolution neural network (CNN) and long short term memory (LSTM) network is proposed, which can realize the comprehensive evaluation of the operation state of electric vehicle charging piles. In the feature data input stage, the key indicators of the operation state of the charging pile are analyzed, and the characteristic quantities of the influencing factors of the operation state are extracted through CNN. Then, the operation state of the charging pile is judged and predicted by LSTM, so as to realize the early warning of potential failures of the charging pile. The experimental results show that the method has high prediction accuracy and strong practicability. It can accurately reflect and predict the operation state of charging piles, and can be used in actual charging pile fault prediction and operation and maintenance.

收稿日期: 2021-10-20; 收到修改稿日期: 2022-01-15

* 基金项目: 国网上海市电力公司科技项目(B30900200002)

作者简介: 吴丹(1981—), 男, 硕士, 高级工程师, 研究方向为智能用电技术、电动汽车充换电技术管理。

甄昊涵(1988—), 男, 硕士, 高级工程师, 研究方向为充电桩检验检测技术。

雷斑(1988—), 男, 硕士, 高级工程师, 研究方向为智能用电技术、充电桩检验检测技术。

Key words: electric vehicle charging pile; failure prediction; convolution neural network (CNN); long short term memory (LSTM)

0 引言

近年来,电动汽车以其清洁、环保、高效的优势,在许多国家逐渐得到发展和广泛应用。相关的配套充电设施也变得越来越重要,需要建设便捷的充电基础设施来提高用户充电体验^[1-2]。电动汽车充电设施作为国家发展的基础设施,其安全性、可靠性和兼容性等受到监管部门、车企、交通部门等相关单位的高度重视。目前,电动汽车充电设施的规划、建设和运维仍面临着众多问题,例如,充电站运维水平相对落后、充电桩状态评估技术滞后、充电桩故障率高、例行检验不合格项目多、部分充电桩存在安全隐患等^[3]。这些问题难以满足当前对充电设施的管理要求,会造成不良的社会影响,甚至导致事故的发生。

目前,充电桩故障检测方法大多基于人为经验判断,利用深度学习技术进行故障识别的方法不多^[4-5]。早期已经提出的充电桩运行状态或故障检测方法存在一定缺陷,都是通过人工检测和建立分析模型来预测故障^[6]。这些方法或模型在一定程度上可以判断充电桩故障,但对充电桩运行状态参数涉及不多,仅包含关键元器件的故障检测,其考察的故障检测范围也不够明确,判断准确率并不高^[7]。同样,随着充电桩数量的增加和充电设施系统的日益复杂,上述方法也难以批量化检测故障。因此,需要更有效的方法来进行故障检测与运行状态评估。

深度学习已经成为人工研究领域的研究热点,广泛应用于图像分类、视频识别和智能机器人等方面。采用神经网络学习特征提取和分类的方法,在模式识别^[8]、图像分类^[9]等许多领域取得了非常好的效果。其中,卷积神经网络(CNN)是前馈神经网络的一种可靠变体,由LeCun等最先提出^[10],具有特征提取的优势并成为解决分类问题的强大模型。在过去的二十年中,CNN已成功用于解决许多研究领域的分类问题,其优势在于其能够捕获输入数据特征的局部依赖性。长短期记忆网络(LSTM)是循环神经网络(RNN)的变体^[11],自提出以来,已广泛用于时间序列预测,解

决RNN学习过程中反向传播长时间滞后导致梯度爆炸或减小的问题,并被证明在长期和短期预测中表现良好。

本文提出了一种基于CNN和LSTM的混合网络,建立以数据驱动的设备状态预测模型,实现对充电桩运行状态的预测。试验结果表明,该方法显著提高了充电桩运行状态预测的效率和准确性。

1 充电桩运行状态指标体系

结合充电桩的故障程度、维修经验和专家分析,给出了状态分级策略。充电桩每个指标都根据操作状态阈值水平进行标准化,根据运行参数的优劣状况,可分为健康、正常、轻微故障和严重故障四种风险等级^[12-13]。对应的状态集为State={S1, S2, S3, S4}={健康, 正常, 轻微故障, 严重故障}。

健康S1,表示充电桩全部运行参数处于合理范围内,与设定值非常接近,稳定运行且无需检查,检查周期可能会延迟很长时间;正常S2,表示充电桩运行状态的个别参数超过设定值,但没有恶化的趋势,检查时间可以延迟或者可以计划维护保养;轻微故障S3,表示充电桩的运行参数达到设定值,发生多次故障并有恶化的趋势,处于待维修状态,需要进一步观察或安排一次维修;严重故障S4,表示充电桩运行参数达到设定值,部分功能已失效或严重故障,无法正常工作,应立即停机检查。充电桩运行状态与对应的检修策略如表1所示。

表1 充电桩状态与对应的检修策略

充电桩状态	S1	S2	S3	S4
检修策略	绝对正常	计划检修	安排检修	立即检修

充电桩的运行状况信息数据主要包括以下方面:通用选型配置、关键部件质量、运行环境和其他评价等,如表2所示。

基于图1所示的充电桩不同维度的多源状态信息模型,可挖掘出表征充电桩运行状态的特征信息。

表 2 充电桩的运行状况信息数据量化标准表

二级指标	三级指标	指标内容	量化标准
通用选型	结构形式	(a) 一体式充电桩	全部满足, 得分 $x=10$;
		(b) 分体式充电桩	不满足要求, 得分 $x=0$
		(c) 充电堆式充电桩	
	单枪功率	(a) 60 kW	全部满足, 得分 $x=10$;
		(b) 120 kW	不满足要求, 得分 $x=0$
		(c) 180 kW	
	接地	接地电阻应 $\leq 100 \text{ m}\Omega$	全部满足, 得分 $x=10$; 不满足要求, 得分 $x=0$
	充电模块	(a) 稳压精度 $\leq 0.5\%$	全部满足, 得分 $x=10$
		(b) 稳流精度 $\leq 1\%$	存在 1 项不满足要求, 得分 $x=6$
		(c) 电压纹波 $\leq 1\%$	存在 2 项不满足要求, 得分 $x=2$
设备关键器件质量评价指标	外壳	(a) 箱体开裂破损	存在 3 项不满足要求, 得分 $x=0$
		(b) 箱体外观褪色	全部满足, 得分 $x=10$
		(c) 箱体涂层磨损剥落	存在 1 项不满足要求, 得分 $x=8$
		(d) 箱体锈蚀腐烂	存在 2 项不满足要求, 得分 $x=6$
		(e) 铭牌缺失	存在 3 项不满足要求, 得分 $x=4$
	急停按钮	急停按钮损坏	存在 4 项不满足要求, 得分 $x=2$
	显示屏幕	无法显示	存在 5 项不满足要求, 得分 $x=0$
	盐雾	应满足 NB/T 33008—2018 的要求	全部满足, 得分 $x=10$
	湿度	相对湿度: +20 °C 时, 不高于 90%; +40 °C 时, 不应高于 50%	不满足要求, 得分 $x=0$
			全部满足, 得分 $x=8 \sim 10$
运行环境	雨水	户外充电桩(柜)应有防雨水浸入设施	不满足要求, 得分 $x=0$
	供应商	由各公司根据产品故障率程度、售后服务水平、响应及时率综合评判得出	全部满足, 得分 $x=10$
			不满足要求, 得分 $x=0$
			满足要求, 得分 $x=10$
	其他评价	基本的维护和保养	故障次数超出 ≤ 1 次/年, 得分 $x=7$
		安全措施	故障次数超出 ≤ 5 次/年, 得分 $x=5$
		管理服务	故障次数超出 ≤ 10 次/年, 得分 $x=3$

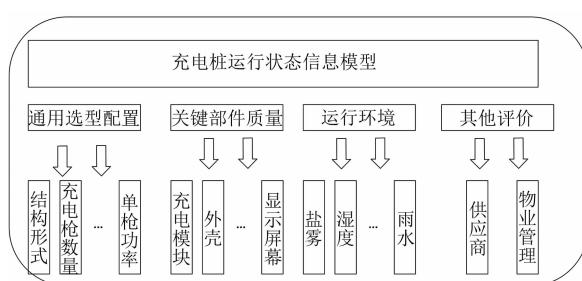


图 1 充电桩运行状态信息模型

针对复杂的设备状态综合评估问题, 本文将指标评估系统划分成三层结构: 第一层为最高层(目标层), 决策的目的、要解决的问题; 第二层为

中间层(子目标层), 考虑的因素、决策的准则; 第三层为最低层(指标层), 决策时的备选方案。在根据问题的性质与目标进行实际评估工作时, 首先将研究问题分解为不同的组成因素, 然后对分解的因素进行分析。

2 充电桩运行状态指标权重

层次分析法(AHP)是对各参量指标赋予相应权重的方法^[14]。层次分析过程是一种多标准决策方法, 其中因素按层次结构排列, 从总体目标到连续级别的标准、子标准和备选方案。AHP 理论为社会学、管理科学和经济学等领域提供一种方法论, 其框架为确定最佳选择、设置优先级、分

配资源等问题提供解决方案。

传统的层次分析法利用九标度法构造判断矩阵,但是必定存在较强的主观性,本文在此基础上进行改进。首先,通过采取三标度法来降低其主观因素,减少传统尺度的饱和;其次,为专家级判断提供了更方便的方法,在一致性检验不符且需要不断修正判断矩阵时,直接得到权重向量,从而提高计算效率,具体过程如下。

(1) 构造判断矩阵。对于 n 个状态指标量 a_n , 指标 a_i 与指标 a_j 两两相互之间进行比较, 构造各个指标的重要程度, 即形成判断矩阵 X :

$$X = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1n} \\ x_{21} & x_{22} & \cdots & x_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n1} & x_{n2} & \cdots & x_{nn} \end{bmatrix} \quad (1)$$

式中: x_{ij} 表示第 i 个状态指标与第 j 个状态指标的重要程度比较结果, $i, j = 1, 2, \dots, n$ 。

(2) 确定排序数。在得到判断矩阵后, 解答出来第 i 种指标和其他指标量的比较结果进行求和, 取得排序指数 b_i :

$$b_i = \sum_{j=1}^n x_{ij} \quad (2)$$

(3) 确定评判矩阵。利用排序数进行求解评判矩阵中的元素 y_{ij} :

$$y_{ij} = \begin{cases} \frac{b_i - b_j}{b_{\max} - b_{\min}}(k_m - 1) + 1, & b_i \geq b_j \\ \frac{1}{\frac{b_i - b_j}{b_{\max} - b_{\min}}(k_m - 1) + 1}, & b_i < b_j \end{cases} \quad (3)$$

式中: $k_m = \frac{b_{\max}}{b_{\min}}$, $b_{\max} = \max(b_i)$, $b_{\min} = \min(b_i)$ 。

根据计算的评判矩阵 Y_{ij} 结果构造拟优一致矩阵 Y'_{ij} :

$$Y'_{ij} = 10^{\frac{1}{n} \sum_{k=1}^n (d_{ik} - d_{jk})} \quad (4)$$

$$d_{ij} = \ln Y_{ij} \quad (5)$$

3 基于 CNN 和 LSTM 混合网络

3.1 CNN

一般来讲,CNN 包括两个主要部分: 特征提取部分和分类部分。特征提取部分由一层或多层卷积层和池化层组成, 提取的输出(特征图)成为

分类部分的输入。分类部分由全连接层组成。

假设给定训练数据集 $\{x_n\}$, $n = 1, 2, \dots, N$ 和相应的标签集 $\{t_n\}$ 作为目标。利用神经网络通过最小化均方误差或制定的 E 函数进行训练, 如下所示:

$$E(w) = \frac{1}{2} \sum_{n=1}^N \| y(x_n, w) - t_n \|^2 \quad (6)$$

式中: $y(x_n, w)$ 是给定向量输入 x_n 和训练算法产生的向量权重 w 和 t_n , 对应的实际标签(类)作为 CNN 输出的预测标签(类)。

3.2 LSTM 网络

LSTM 网络可以看作是由多个 LSTM 单元连接组成, 每个 LSTM 单元都具有三个控制信息流的门: 输入门 i_t 、遗忘门 f_t 和输出门 o_t , 其结构如图 2 所示。

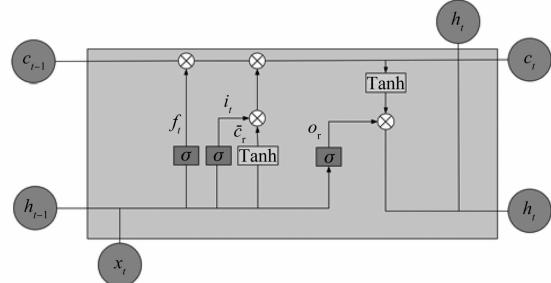


图 2 LSTM 基本结构

输入门的作用是选择下一个状态要存储的数据, 忘记门从状态数据中选择不会被存储的数据。例如, 如果计算结果为 0, 则意味着完全保留该信息。如果计算结果为 1, 则意味着完全丢弃该信息。输出门确定要路由到输出的状态信息。 c 代表单元状态, 在任意时刻 t , 用下列方程来计算 i_t 、 f_t 、 o_t 和 \tilde{c}_t :

$$f_t = \sigma(w_f \times [h_{t-1}, x_t] + b_f) \quad (7)$$

$$i_t = \sigma(w_i \times [h_{t-1}, x_t] + b_i) \quad (8)$$

$$o_t = \sigma(w_o \times [h_{t-1}, x_t] + b_o) \quad (9)$$

$$\tilde{c}_t = \tanh(w_c \times [h_{t-1}, x_t] + b_c) \quad (10)$$

式中: w 表示权重矩阵; b_f, b_i, b_o 和 b_c 表示偏置向量; x_t 为时间步的输入; h_{t-1} 表示前一个周期计算的 LSTM 输出; \tilde{c}_t 表示 \tanh 层创建的中间候选值; σ 表示符号 Sigmoid 的激活函数。

然后, 忘记门规则计算要从单元状态中删除的先前内存值, 输入门确定单元状态的新输入。

单元状态的计算如下:

$$c_t = f_t \cdot c_{t-1} + i_t \cdot \tilde{c}_t \quad (11)$$

然后,LSTM 输出为 \bar{y}_t 如下:

$$\bar{y}_t = w_y h_t \quad (12)$$

给定 w_y 是 h_t 降维的投影矩阵。

3.3 CNN 和 LSTM 混合网络

CNN 和 LSTM 混合网络的预测模型有两个组成部分,分别为 CNN 和 LSTM,在充电桩运行状态预测模型中扮演着不同的角色。其中,CNN 能够高效挖掘输入序列的潜在信息,LSTM 网络可以更好地预测输入序列的特征信息,其结构如图 3 所示。三个卷积层都设为 16 组卷积核,卷积核大小分别设为 8×8 、 5×5 和 3×3 ,其后紧跟一个 Batch Normalization 函数^[15]和一个 ReLU 激活函数^[16],每个卷积层后面接着最大池化层,3 个 LSTM 网络的隐层神经元个数为 128,以及全连接层。

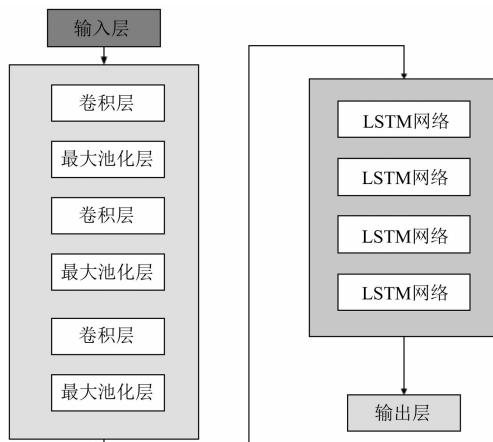


图 3 CNN 和 LSTM 混合网络的基本结构

4 基于 CNN 和 LSTM 混合网络的充电桩运行状态预测实现

4.1 模型建立

本文状态预测的输入输出量规定如下:输入量包括状态中通用选型配置、充电桩的关键部件质量、充电桩的运行环境和其他评价,以及与充电桩时间序列的关联性,输出量则为预测下一时间段的充电桩运行状态。预测充电桩运行状态的时候,只需要明确关键性指标对充电桩综合评价的影响,无需关注指标之间的潜在关系。利用 CNN 提取输入信息的特征量,再选择适合处理时序预测问题且结构相对简单的 LSTM 作为状态预测的

深度学习网络。

可以利用非线性变换的各指标属性,以及结合具有时间序列的 LSTM 网络,通过 Softmax 分类器映射到充电桩状态集的概率值,以最大概率准则确定充电桩的状态信息^[17]。图 4 展示了基于 CNN 和 LSTM 混合网络的充电桩运行状态预测架构,该架构具体实施步骤如下。

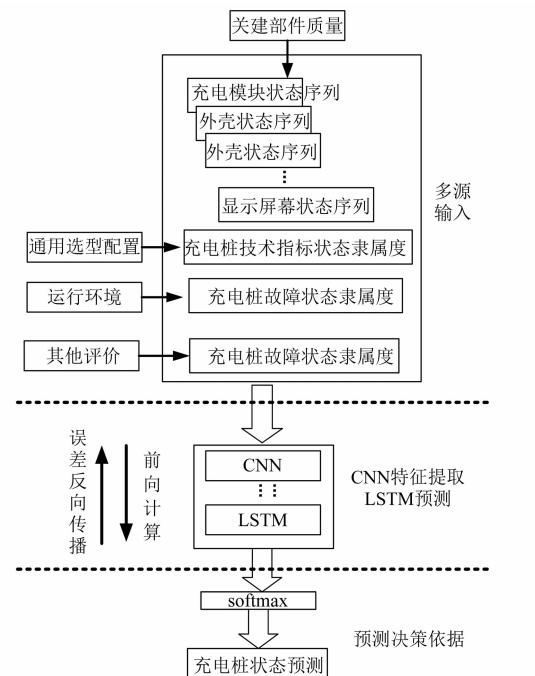


图 4 基于 CNN 和 LSTM 混合网络的充电桩运行状态预测架构

(1) 收集并选取充电桩历史运行状态数据作为样本,将样本划分为训练集和测试集。

(2) 将训练样本中通用选型配置信息及关键部件质量、运行环境、其他评价作为输入参数量,通过构建时间序列对充电桩运行状态做预处理。为了降低通用选型配置信息数据分散性对模型的影响,采用离差标准化方法进行归一化处理,如下式所示:

$$\bar{x} = (x - x_{\min}) / (x_{\max} - x_{\min}) \quad (13)$$

式中: x_{\min} 为样本集合数据的最小值; x_{\max} 为样本集合数据的最大值; \bar{x} 为进行归一化数据处理后的数据。

(3) 对关键部件质量指标进行统计数据,通过支持向量机拟合得到充电桩不同状态分布函数。

(4) 对运行环境和其他评价采用模糊统计方法进行评估。

(5) 利用改进的 AHP 法确定通用选型配置、关键部件质量、运行环境和其他评价指标参数中的各指标权重系数。

(6) 得到步骤(3)、步骤(4)中的结果数据后,再根据步骤(5)不同的权重系数分配全权求得充电桩 S1~S4 的运行状态的模糊评判结果作为数据标签。

(7) 利用 CNN 和 LSTM 混合网络对历史数据训练集进行训练操作,提取关键指标量与充电桩状态的非线性且抽象表示的特征信息,得到预测模型的参数。

(8) 通过 CNN 和 LSTM 混合网络预测模型,来预测测试集中的充电桩运行状态,并验证预测模型准确度。

4.2 算例分析

本文运用平均绝对误差(MAE)和均方根误差(RMSE)来研究与验证预测模型的准确性^[18]。其定义如下:

$$E_{MAE} = \frac{1}{N} \sum_{i=1}^N |Y_i - \hat{Y}_i| \quad (14)$$

$$E_{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (Y_i - \hat{Y}_i)^2} \quad (15)$$

式中:N 为预测的数量; Y_i 为当时的标准化实际观察值; \hat{Y}_i 为同一时期的预测标准化值;i 为预测点序列编号。

本文以实际充电站现场收集得到的 626 例确认存在严重故障的数据和 174 例在线运营平台出现预警、报警后跟踪观察到的数据组成 800 例样本数据库。

针对样本数据库中的 800 例充电桩数据进行随机划分处理,选取 640 例充电桩运行状态数据构成训练集,剩下的 160 例充电桩数据构成测试集。利用 CNN 对充电桩的通用选型配置、关键部件质量、运行环境和其他评价的关键指标进行特征信息的提取。另外,为了加快 CNN 和 LSTM 混合网络的学习速率,避免网络在学习过程中出现过拟合情况,加入 dropout 层,信号损失率设为 0.2。输出层规模为 4,迭代次数为 100。

表 3 所示为 BP、ARIMA 和 CNN-LSTM 方法对充电桩运行状态进行一个月预测的 MAE 和

RMSE 的结果。在相同的测试集中,与 BP 神经网络和 ARIMA 模型相比,CNN-LSTM 预测模型得到的 MAE 和 RMSE 的结果最低,最接近实际充电桩故障情况。

表 3 不同预测方法的误差结果

方法	MAE	RMSE
CNN-LSTM	0.875	1.186
ARIMA	0.968	1.347
BP	1.069	1.464

由图 5 可知,当预测时间尺度为一周时,其预测准确率按 BP、ARIMA、CNN-LSTM 模型依次提高,其中,CNN-LSTM 模型与 BP 模型和 ARIMA 模型进行比较,在训练集上状态预测准确率分别提高了 10.7% 和 6.2%,在相同的测试集上预测准确率分别提升了 10.6% 和 6.3%。

随着预测尺度增加,BP、ARIMA 和 CNN-LSTM 模型在测试集上的准确率见图 6 所示。由图 6 可知,当预测时间周期增加时,三种模型预测准确率均有所下降,其中,CNN-LSTM 模型的准确率均高于其他预测模型。

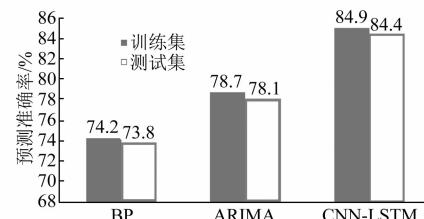


图 5 充电桩状态预测准确率(预测尺度:一周)

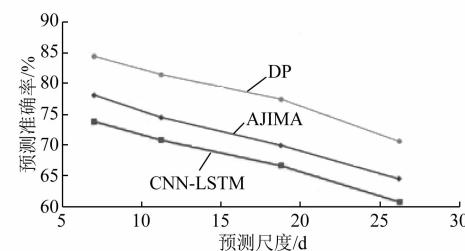


图 6 各种模型在测试集上预测准确率

5 结语

本文提出的一种基于 CNN 和 LSTM 混合网络的电动汽车充电桩运行状态预测方法,解决了

充电桩故障检测效率低、精度差的问题。首先,通过获取充电桩的相关历史典型故障数据、信息参数和运行环境等运行状态数据,分析充电桩故障发生的影响因素并确定充电桩运行状态的关键指标量,再对关键指标量进行量化量级处理,利用改进的层次分析法来确定充电桩关键指标量的权重;其次,搭建一种结合 CNN 和 LSTM 的混合网络架构,CNN 主要对充电桩运行状态的关键指标进行特征挖掘和提取,LSTM 网络将关键特征量与时间维度相关联,利用 CNN 和 LSTM 混合网络对训练样本进行训练,并与其它模型的训练效果进行比较。试验结果表明,该模型效率高,实用性强,能较准确地反映充电桩的运行状态,可用于电动汽车充电桩的故障预测与运维检修。然而充电桩的运行参数数据资源有限,无法根据实际场站运行场景进行进一步的补充和完善,得到更全面更稳定的状态评价或预测。

【参考文献】

- [1] 胡泽春,宋永华,徐智威,等.电动汽车接入电网的影响与利用[J].中国电机工程学报,2012,32(4): 1.
- [2] MANOHARAN S. An improved safety algorithm for artificial intelligence enabled processors in self driving cars[J]. Journal of Artificial Intelligence and Capsule Networks,2019(2): 95.
- [3] 陈辉.电动汽车充电设施检测及故障诊断[J].电力设备管理,2020(11): 196.
- [4] 赵翔,陈良亮,李明贞,等.一种基于深度神经网络的直流充电桩故障诊断方法[J].电测与仪表,2021,58(6): 148.
- [5] GAO D, HOU J, LIANG K, et al. Fault diagnosis system for electric vehicle charging devices based on fault tree analysis [C] // 37th Chinese Control Conference (CCC),2018.
- [6] ISERMANN R. Model-based fault detection and diagnosis-status and applications [J]. IFAC Proceedings Volumes,2004,37(6): 49.
- [7] 侯俊杰.电动汽车充电设备状态监测与远程故障诊断系统设计与实现[D].青岛:青岛科技大学,2019.
- [8] YEUNG J A, WEI Z, CHAN K Y, et al. Jump detection in financial time series using machine learning algorithms [J]. Soft Computing, 2020, 24 (3): 1789.
- [9] HUANG F, LU J, TAO J, et al. Research on optimization methods of ELM classification algorithm for hyperspectral remote sensing images [J]. IEEE Access,2019,7: 108070.
- [10] RANZATO M, LECUN Y. A sparse and locally shift invariant feature extractor applied to document images [C] // International Conference on Document Analysis and Recognition,2007.
- [11] GERS F A, SCHMIDHUBER J, CUMMINS F. Learning to forget: continual prediction with LSTM [J]. Neural Computation,2000,12(10): 2451.
- [12] 张朝龙,何怡刚,杜博伦,等.基于深度学习的电力变压器智能故障诊断方法[J].电子测量与仪器学报,2020,34(1): 81.
- [13] 范建磊,刘君.电动汽车充电桩综合评价方法研究[J].电气应用,2014,33(11): 31.
- [14] 陆牧君,王佳乐,杨嘉贤,等.基于层次分析法的电动汽车调度方法研究[J].电工技术,2020(20): 37.
- [15] 吴晓富,常圆圆,张索非,等.基于 SReLU 函数的神经网络图像分类方法:CN108596235A [P]. 2018-09-28.
- [16] 蒋昂波,王维维. ReLU 激活函数优化研究[J]. 传感器与微系统,2018,37(2): 50.
- [17] 李东东,王浩,杨帆,等.基于一维卷积神经网络和 Soft-Max 分类器的风电机组行星齿轮箱故障检测[J].电机与控制应用,2018,45(6): 80.
- [18] SU C, LI L, WEN Z. Remaining useful life prediction via a variational autoencoder and a time-window-based sequence neural network [J]. Quality and Reliability Engineering International, 2020, 36 (5): 1639.