

基于在线实测数据的地铁列车空调回风温度预测^{*}

杨 闯¹ 杨 宇² 陈 亮² 陈焕新¹ 程亨达¹

(1. 华中科技大学能源与动力工程学院, 430074, 武汉; 2. 广州鼎汉轨道交通车辆装备有限公司, 510260, 广州)

摘 要 [目的] 为了能够提前根据环境温度调控地铁列车空调系统的制冷能力, 有必要对地铁列车空调回风温度预测进行研究。[方法] 采用时序预测法预测地铁列车空调系统回风温度的变化趋势。利用空调系统传感器在线采集广州某地铁列车空调系统的实时运行数据, 通过箱形图清洗数据异常值, 采用滑动窗口处理输入及输出数据的时间跨度, 构建 LSTM(长短期记忆)神经网络模型对空调机组回风温度进行预测, 并对比分析不同样本个数对模型预测精度的影响。[结果及结论] LSTM 神经网络模型能够学习地铁列车空调系统的温度控制逻辑, 预测温度曲线与真实温度曲线有相似的变化趋势, 适用于预测地铁列车空调机组回风温度。通过参数优化将模型精度提高至 0.84, 实现了机组回风温度的精准预测。增大模型单次训练选取的样本数能够缩短模型的训练时间, 但同时其模型最终预测精度也会有所降低。

关键词 地铁; 空调系统; 长短期记忆神经网络

中图分类号 U270.38⁺³

DOI:10.16037/j.1007-869x.2024.12.018

Prediction of Metro Train Air-conditioning Return Air Temperature Based on Real-time Field-measured Data

YANG Chuang¹, YANG Yu², CHEN Liang², CHEN Huanxin¹, CHENG Hengda¹

(1. School of Energy and Power Engineering, Huazhong University of Science and Technology, 430074, Wuhan, China;

2. Guangzhou Dinghan Rail Transit Vehicle Equipment Co., Ltd., 510260, Guangzhou, China)

Abstract [Objective] To enable proactive adjustment of the cooling capacity for metro train AC (air-conditioning) system based on ambient temperature, it is essential to study the prediction of return air temperature in metro train AC systems.

[Method] A time series forecasting method is employed to predict the variation trend in return air temperature of metro train AC systems. Real-time operational data from the air-conditioning system of a Guangzhou Metro train are collected through AC sensors. Outliers are removed using a boxplot, and

a sliding window approach is applied to handle the time span of input and output data. An LSTM (long short-term memory) neural network model is then constructed to predict the return air temperature of the AC units, and the impact of different sample sizes on the model prediction accuracy is comparatively analyzed. [Result & Conclusion] The LSTM neural network model can learn the temperature control logic of metro train AC system, with the predicted temperature curve closely matching the actual temperature curve, therefore is suitable for predicting the return air temperature of metro AC units. Through parameter optimization, the model accuracy is improved to 0.84, enabling precise prediction of unit return air temperature. Increasing the sample size for a single training session can shorten model training time but may reduce the model final prediction accuracy to some extent correspondently.

Key words metro; air-conditioning system; long short-term memory

预测地铁列车空调温度控制效果的变化趋势, 能够有效改善列车空调的调控策略, 进而保障乘客的乘坐舒适度, 有利于列车的节能运行。目前, 针对列车车厢内温度的研究大多集中于数值模拟^[1-2], 通过求解列车数学模型的近似解, 获得列车车厢的温度场分布情况。但该方法构建的列车数学模型较为复杂, 模拟耗时较长。

时序预测方法具有建模简单、运算速度快等优点, 用于分析列车空调温度具有更大的优势。由于列车空调机组回风温度较为接近列车车厢内的实际温度, 因此采用时序预测方法对列车空调机组回风温度进行分析, 能够快速且准确地预测列车车厢内的温度。

文献[3]结合了深度学习时序预测方法和 CFD (计算流体力学) 数值模拟分析, 研究了地铁换乘车站的热环境。文献[4]采用 3 种时序预测模型对地铁车站温度进行了预测。文献[5]利用 3 种预测

^{*} 国家自然科学基金项目(51876070)


模型对地铁车站的能耗进行了预测,基于预测结果确定了预测模型的最佳滞后时间。本文选用时序预测方法中的 LSTM(长短期记忆)神经网络模型,其能有效避免梯度消失问题,还能更精准地分析时间序列数据不同参数间的相互作用及影响。

本文采集了地铁列车空调的运行数据进行分析,选择接近车厢温度的机组回风温度作为预测目标,将空调机组中的其他参数作为输入,构建 LSTM 神经网络模型。本文研究可为列车温度调节提供指导与借鉴。

1 地铁空调数据在线采集与处理

1.1 数据在线采集装置与数据介绍

从地铁列车上采集空调系统的运行数据,以完成对地铁空调机组回风湿度的预测建模。本文对广州某地铁列车 2021 年 9 月 1 日—2021 年 9 月 26 日的运行维护数据进行实时追踪,利用其空调系统上布置的传感器等设备,对列车空调的实时运行数据进行在线采集。该列车空调系统传感器布置示意图如图 1 所示。其中,包含 1 个回风湿度传感器、1 个新风温度传感器、1 个 CO₂ 体积分数传感器、2 个低压压力传感器、2 个高压压力传感器、6 个不同设备的电流传感器、2 组水浸传感器及 1 个空气压差传感器。



注:1—回风湿度传感器;2—新风温度传感器;3—CO₂ 体积分数传感器;4—低压压力传感器;5—高压压力传感器;6—压缩机电流传感器;7—送风机电流传感器;8—冷凝风机电流传感器;9—水浸传感器;10—空气压差传感器。

图 1 列车空调系统传感器布置示意图

Fig. 1 Layout diagram of train air-conditioning system sensors

在传感器采集到的数据中,送风机与冷凝风机的电流数据基本为定值或 0,对时序预测模型无意义,因此仅计算其余参数与回风湿度的 Pearson 系数,并经过专家知识选择,最终保留了机组回风温

度、新风温度、回风湿度、系统 1 高压、系统 1 低压、系统 2 高压、系统 2 低压、新风压差 8 个参数,共 20 732 组数据,采样时间间隔约为 1 min。

1.2 地铁空调系统数据预处理

本文采用箱形图分析法对异常数据进行清洗。通过只取连续时间段的数据解决数据的缺失值问题。由于预测模型对输入数据有一定的要求,因此还需对原始数据进行预处理。

1.2.1 基于箱形图分析的异常值清洗

由于数据的四分位数不受异常值的影响,因此利用箱形图能够比较客观地分析数据分布,找出其中的异常值^[6]。该方法的基本原理为,将数据从小到大排列,然后找出数据中心的下四分位数点 Q_1 和上四分位数点 Q_3 ;根据所需精确度选择合适的调整因子 k ,用于确定数据点 X 是否偏离了数据集的常规分布。当 k 取为 1.5 时,表示筛选的是数据集的中度异常范围;当 k 取为 3.0 时,表示筛选的是数据集的极度异常范围。整个数据集的合理范围可以表示为:

$$Q_1 - k(Q_3 - Q_1) \leq X \leq Q_3 + k(Q_3 - Q_1) \quad (1)$$


处于式(1)范围外的数据即为异常值。原始数据集箱形图如图 2 a)所示,其中包含 8 个不同的空调机组参数,共 20 732 组数据。根据找出的四分位数点,确定数据集的最终合理分布范围,将范围之外的数据作为异常值清洗后,共留下 19 821 组数据,则清洗的数据占原始数据集约 4%,四分位数处理后的数据集箱形图如图 2 b)所示。

由图 2 可知:在原始数据集中,有 3 个参数存在离散的异常值;当进行四分位数处理后,这 3 个参数中仍存在部分游离于合理数值范围之外的数据,但其连续性相较于处理前更好。由此可知,这些箱形图判断出的异常点是在某些工况下的正常值。


1.2.2 模型输入数据预处理

对异常值进行清洗后,为了消除数据中奇异数据的不良影响,加快神经网络的学习速度,需要对数据集进行量纲一化处理。本文选择普遍使用的最大最小量纲一化法,将数据线性转化至 $[0, 1]$ 范围,为 LSTM 神经网络模型训练提供更优质的数据集。

由于缺失值会导致时间序列的中断,影响预测精度,因此本文从数据集中选择连续时间段的数据进行分析,以保障输入模型数据的连续性。本文从



a) 原始数据集



b) 四分位数处理后的数据集

注: IQR 为四分位距, 数值等于 Q_3 与 Q_1 的差值。

图2 原始数据集及四分位数处理后的数据集箱形图

Fig. 2 Data box plot after original dataset and quartile processing

处理后的数据集中挑选出每一天连续时间的数据集, 并选择列车处于运行时间段的数据用于预测机组回风温度。

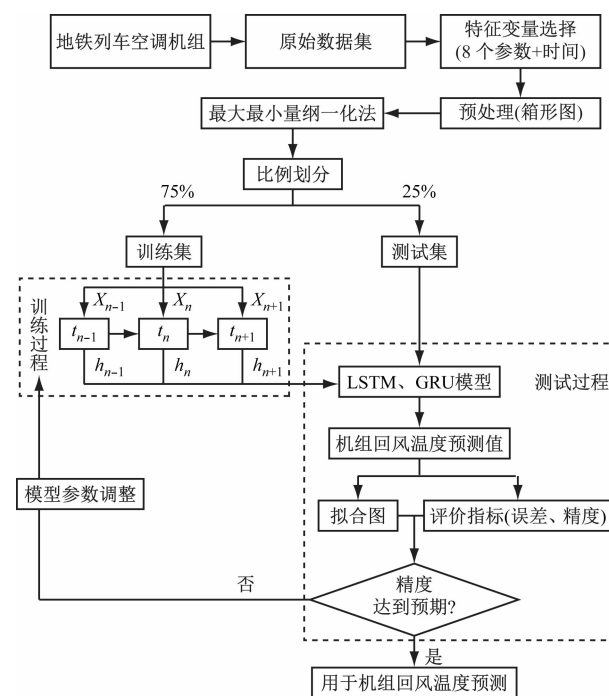
本文采用滑窗处理法处理输入模型数据, 利用过去 200 个时间点的 8 个空调机组参数预测未来 50 个时间点的机组回风温度。本文选择其中 3 d 中的 1 250 组列车空调数据作为训练集, 经过滑窗处理后共有 14 组列车空调数据; 选择其中 1 d 中的 300 组数据作为测试集来测试模型精度, 经过滑窗处理后共有 2 组列车空调数据。

2 空调机组回风温度预测模型

2.1 时序模型预测流程

时序模型预测流程示意图如图 3 所示。利用划分好的训练集和测试集对模型进行训练和测试。根据 LSTM 神经网络模型测试得到的结果, 对 LSTM 神经网络模型的参数进行修正和优化, 逐渐

提高预测结果的精度, 最终获得满足需求的高精度 LSTM 神经网络模型。



注: t 为时间点; h 为输出数据; n 为数据点序号; GRU 为门控循环单元。

图3 时序模型预测流程示意图

Fig. 3 Diagram of time series model prediction flowchart

2.2 LSTM 神经网络模型参数设置

LSTM 神经网络模型是一种特殊的循环神经网络。本文中的 LSTM 神经网络模型设置为: 层数为 2; 每一层的神经元个数为 30; 包含 Dropout 层以防止过拟合; 将 Dense 层作为输出层。通过不断修正训练过程中的损失值, 最终确定学习速率为 0.01, 训练次数取为 300 次。通过改变模型单次训练所选取的样本个数 (取为 1、2、3、4), 比较不同样本个数下的模型精度, 研究其对模型训练过程及预测精度的影响。

3 预测结果与分析

3.1 误差评价指标

本文采用的误差评价指标为均方误差 S_{MSE} 、均方根误差 S_{RMSE} 、平均绝对误差 S_{MAE} 、平均绝对百分比误差 S_{MAPE} 和相关系数 R^2 [7], 相关计算公式为:

$$S_{MSE} = \frac{1}{m} \sum_{t=1}^m (y_{true,t} - y_{pred,t})^2 \quad (2)$$

$$S_{RMSE} = \sqrt{\frac{1}{m} \sum_{t=1}^m (y_{true,t} - y_{pred,t})^2} \quad (3)$$

$$S_{MAE} = \frac{1}{m} \sum_{t=1}^m |y_{true,t} - y_{pred,t}| \quad (4)$$

$$S_{MAPE} = \frac{1}{m} \sum_{t=1}^m \frac{|y_{true,t} - y_{pred,t}|}{y_{true,t}} \times 100\% \quad (5)$$

$$R^2 = 1 - \frac{\sum_{t=1}^m (y_{true,t} - y_{pred,t})^2}{\sum_{t=1}^m (y_{true,t} - \bar{y})^2} \quad (6)$$

式中:

m ——时间序列数据长度;

y_{true} ——参数真实值;

y_{pred} ——参数预测值;

\bar{y} ——参数平均值。

计算各评价指标,对比分析不同样本个数对模型预测精度的影响,定量给出 LSTM 神经网络模型预测结果的精确度。

3.2 回风温度预测结果分析

3.2.1 最佳机组回风温度预测结果

基于 2.2 节的参数设置,能够获得最佳的机组回风温度预测模型。机组回风温度预测模型的预测值和真实值对比如图 4 所示。由图 4 可知:所提模型能够较好地学习到数据中的特征,较为准确地预测出机组回风温度在一段时间内的变化趋势。




图 4 机组回风温度预测模型的预测值和真实值对比

Fig.4 Comparison of predicted and actual values of unit return air temperature prediction model

此外,图 4 中真实值的数据曲线在一定范围内处于波动状态,据此可以推断该地铁列车空调机组的控制逻辑为刻意振荡,即根据制冷目标温度和机组回风温度之间的差值实现控制。当检测到机组回风温度过低时,控制装置会调制冷系统压缩机的工作频率,机组制冷能力降低,使车厢内的温度持续上升。此时,回风温湿度传感器不断采集并反馈机组回风温度,判断其与制冷目标温度之间的差

值。当温度逐渐升高,到达过高的状态时,地铁列车空调控制系统会检测到温差过大,进而加强空调机组的制冷能力,使机组回风温度逐渐下降,达到调节车厢内温度的目的。利用这种控制方式能够调节空调机组找到合适的工作频率,进而达到节约能耗的目的。而 LSTM 神经网络模型的预测结果说明了其能够学习到数据集中隐藏的这种控制逻辑,适用于预测空调机组的回风温度。

根据模型预测值可以得到各评价指标计算结果,预测模型的 MSE、RMSE、MAE、MAPE 分别为 0.080 6、0.283 9、0.215 9、0.008 8,均小于 0.300 0,预测值与真实值的相关系数 R^2 为 0.843 7,接近于 1,因此可以认为该预测模型的预测结果精度符合要求。综上所述,LSTM 神经网络预测模型能够较为精确地预测地铁空调机组回风温度的变化情况。

3.2.2 不同样本个数对模型预测结果影响

保持其他参数取值不变,改变模型单次训练提取的样本个数,分析模型单次训练时,不同样本个数对模型预测结果的影响。由于模型每次训练的结果有偏差,故对每个模型进行 5 次训练,并取 5 次训练的平均值作为计算结果进行对比分析。

不同样本个数下的预测模型训练过程用时如表 1 所示。不同样本个数下的预测模型误差评价指标如表 2 所示。当样本个数增大时,训练时间逐渐减少;但当样本个数为 3 时,相较于样本个数为 2 时的情况,训练时间反而增加了。这是由于当样本参数为 2 时,14 组训练数据能够被均匀划分,使得预测模型能够快速学习数据集;而当样本参数为 3 时,数据集不能被均匀划分,训练时的数据组数并未有较多减少,但单次训练的训练时间却有所增加,从而导致预测模型的训练速度有小幅降低。当样本个数为 1 时,预测模型的训练时间均有所降低。综上所述,随着样本参数个数的增加,预测模型的训练时间大致呈降低趋势。

由表 2 可知:随着样本个数的增加,各模型的评价指标 MSE、RMSE、MAE、RMAE 均逐渐增大,表明各模型预测结果的误差逐渐增大,且 R^2 从 0.842 降低至 0.800 以下;当样本个数从 1 增加为 2 时, R^2 减小了约 6%。由此可知,样本个数的增加会导致预测模型的预测精度有所降低。

不同样本个数下,机组回风温度预测模型的预测值和真实值对比,如图 5 所示。当样本个数为 1 时,机组回风温度预测模型的预测值与真实值拟合

表 1 不同样本个数下的预测模型训练过程用时


Tab.1 Prediction model training session time with different sample sizes

样本个数/个	时间/s
1	428.4
2	195.3
3	243.0
4	165.6
5	128.7


表 2 不同样本个数下的预测模型误差评价指标

Tab.2 Error evaluation index of prediction model with different sample sizes


样本个数/个	S_{MSE}	S_{RMSE}	S_{MAE}	S_{MAPE}	R^2
1	0.081 4	0.285 4	0.211 2	0.008 6	0.842 0
2	0.106 5	0.326 3	0.259 1	0.010 6	0.793 4
3	0.143 4	0.378 7	0.296 7	0.012 2	0.721 9
4	0.153 9	0.392 3	0.309 2	0.012 7	0.701 4




a) 样本个数为 1



b) 样本个数为 2



c) 样本个数为 3



d) 样本个数为 4

图 5 不同样本个数下机组回风温度预测模型的预测值和真实值对比

Fig. 5 Comparison of predicted and actual values of unit return air temperature prediction model with different sample sizes

程度较好。而当样本个数增大至 2、3、4 时,在机组回风温度较低的部分,真实值与预测值均出现了较大的偏差,在机组回风温度较高处,二者的偏差相对较小。总体来看,随着样本个数的增加,机组回风温度预测模型的预测值与真实值之间的拟合程度有所降低。该现象是由于当单次训练选取的样本个数增多时,LSTM 神经网络模型不能在较短时间的训练中学习数据中的全部信息,而总的训练次数不变导致了训练迭代次数的减少,最终预测模型并不能完全学习地铁空调数据集的特征,导致预测效果有所降低。因此在模型的实际训练过程中,

需要综合考虑训练时间与模型精度,选择合适的参数取值,以保证获得训练时间较短的高精度预测模型。

4 结语

本文以某地铁列车的空调系统为例,采集列车运行时的空调系统实时参数,并对空调系统的温度、湿度及压力等参数进行处理,利用 LSTM 神经网络模型对空调机组的回风温度进行预测,获得以下几个结论:

1) 地铁车厢温度控制逻辑为根据目标温度与

回风温度的差值,对空调系统的制冷能力进行调节,本文构建的机组回风温度预测模型的预测值也表现出相同的变化趋势,表明了 LSTM 神经网络模型能够学习地铁空调系统的数据特征,适用于预测地铁空调机组的回风温度。

2) 通过优化模型结构和训练参数,获得了预测精度较高的机组回风温度预测模型,将机组回风温度预测模型的预测精度提高至 0.843 7,表明了 LSTM 时序预测方法能够较为精准地预测一段时间内的地铁列车空调数据。

3) 增大样本个数在一定程度上能够缩短模型训练的时间,但最终的模型预测精度会有所降低。当样本个数从 1 增加至 2 时,其训练时间减少了约 54.4%,但其相关系数减小了约 6%。

参考文献

- [1] 李福韩,张登春. 地铁车厢内不同客流量的热环境特性及变化规律[J]. 铁道科学与工程学报, 2021, 18(6): 1546.
LI Fuhuan, ZHANG Dengchun. Thermal environment characteristics and changing laws of different passenger flows in subway cars [J]. Journal of Railway Science and Engineering, 2021, 18(6): 1546.
- [2] 张建平,李桐. 地铁列车车厢内不同气流形式下的舒适性[J]. 大连交通大学学报, 2020, 40(1): 39.
ZHANG Jianping, LI Tong. Thermal comfort of subway train compartment with different airflow forms [J]. Journal of Dalian Jiaotong University, 2020, 40(1): 39.
- [3] 方杰. 地铁热环境状态的神经网络预测与数值模拟分析[D]. 北京: 北京交通大学, 2020.
FANG Jie. Neural network prediction and numerical simulation a-

nalys of subway thermal environment [D]. Beijing: Beijing Jiaotong University, 2020.

- [4] 赵明珠,王丹,方杰,等. 基于 LSTM 神经网络的地铁车站温度预测[J]. 北京交通大学学报, 2020, 44(4): 94.
ZHAO Mingzhu, WANG Dan, FANG Jie, et al. Prediction of subway station temperature based on LSTM neural network [J]. Journal of Beijing Jiaotong University, 2020, 44(4): 94.
- [5] 罗启崑,龙静,陈焕新,等. 基于数据挖掘算法的地铁站能耗时序预测方法[J]. 城市轨道交通研究, 2020, 23(6): 23.
LUO Qiyin, LONG Jing, CHEN Huanxin, et al. Time series prediction of subway station energy consumption based on data mining algorithm [J]. Urban Mass Transit, 2020, 23(6): 23.
- [6] 朱恩文,朱安麒,王洁丹,等. 基于 EEMD-GA-BP 模型的风电功率短期预测研究[J]. 广西师范大学学报(自然科学版), 2022, 40(1): 166.
ZHU Enwen, ZHU Anqi, WANG Jiedan, et al. Research on wind power short-term prediction based on EEMD-GA-BP model [J]. Journal of Guangxi Normal University (Natural Science Edition), 2022, 40(1): 166.
- [7] 刘茜阳,宋燕,张亚萌. 基于模糊 K 线的 FCLSTM-vSVR 模型的股票价格预测[J]. 智能计算机与应用, 2022, 12(4): 54.
LIU Qianyang, SONG Yan, ZHANG Yameng. Stock price forecasting using FCLSTM-vSVR based on fuzzy Candlestick [J]. Intelligent Computer and Applications, 2022, 12(4): 54.

· 收稿日期:2022-07-15 修回日期:2022-08-19 出版日期:2024-12-10
Received:2022-07-15 Revised:2022-08-19 Published:2024-12-10
· 第一作者:杨阔,硕士研究生,2662569619@qq.com
通信作者:陈焕新,教授,chenhuanxin@tsinghua.org.cn
· ©《城市轨道交通研究》杂志社,开放获取 CC BY-NC-ND 协议
© Urban Mass Transit Magazine Press. This is an open access article under the CC BY-NC-ND license

(上接第 106 页)

- [5] 聂文成. 无缝线路应力放散及调整分析[J]. 中小企业管理与科技(上旬刊), 2014(6): 130.
NIE Wencheng. Analysis of stress dissipation and adjustment of jointless track [J]. Management & Technology of SME, 2014(6): 130.
- [6] 余田,廖凯,李立君,等. 薄壁件表面应力松弛均化的时效分析与实验[J]. 振动测试与诊断, 2020, 40(2): 242.
YU Tian, LIAO Kai, LI Lijun, et al. Aging analysis and experiment of stress relaxation and homogenization on the surface of thin-walled components [J]. Journal of Vibration, Measurement & Diagnosis, 2020, 40(2): 242.
- [7] 郭磊. 无缝线路应力及稳定性检测评估方法方案的研究[D].

北京: 北京化工大学, 2016.

GUO Lei. Research on stress and stability detection and evaluation method and scheme for jointless track [D]. Beijing: Beijing University of Chemical Technology, 2016.

· 收稿日期:2024-01-14 修回日期:2024-01-19 出版日期:2024-12-10
Received:2024-01-14 Revised:2024-01-19 Published:2024-12-10
· 第一作者:贺相林,高级工程师,hexianglin65021@126.com
通信作者:路宏遥,实验师,luhongyao1@163.com
· ©《城市轨道交通研究》杂志社,开放获取 CC BY-NC-ND 协议
© Urban Mass Transit Magazine Press. This is an open access article under the CC BY-NC-ND license