

基于 LSTM(长短期记忆)网络的城市轨道交通 列车停站精度预测*

谢嘉琦¹ 邹喜华¹ 汪小勇² 毕文峰² 华志辰²

(1. 西南交通大学信息科学与技术学院, 610031, 成都;
2. 卡斯柯信号有限公司, 200072, 上海 // 第一作者, 硕士研究生)

摘要 城市轨道交通列车进站自动停车过程中常会出现冲标和欠标问题, 结合行车日志大数据分析和 LSTM(长短期记忆)网络算法, 提出了有效的解决方案。首先针对行车日志中大量的列车停车精度历史信息进行大数据分析, 按 1 d 为一个统计周期对数据进行分期, 并对数据进行预处理和多类拟合, 对比后获得最佳拟合参数的时间序列。然后通过 LSTM 网络算法构建深度学习模型, 对列车进站自动停车精度的分布进行预测。最后基于成都某地铁线列车停车精度的历史数据, 对该 LSTM 预测模型进行训练与验证。结果表明: 该预测模型可满足统计学上对相似度大于 0.9 的要求, 从而验证了该模型的有效性和准确性。

关键词 城市轨道交通; 长短期记忆网络; Weibull 分布; 停车精度预测

中图分类号 U284.48

DOI:10.16037/j.1007-869x.2022.11.014

Prediction of Urban Rail Transit Train Stop Accuracy Based on LSTM Network

XIE Jiaqi, ZOU Xihua, WANG Xiaoyong, BI Wenfeng, HUA Zhichen

Abstract In order to solve the problems of standard deviation and non-standard deviation in the process of automatic rail transit train parking, an effective solution is proposed based on the analysis of running log big data and the LSTM (long and short term memory) network algorithm. Firstly, the big data analysis is conducted for a large amount of historical information on train parking accuracy in the running log. In which the data is divided into stages with 1 d as a statistical cycle, then, the data is preprocessed and multi-type fitted. After comparison, the time series of the best fitting parameters is obtained. On this basis, a deep learning model is built by LSTM network algorithm to predict the distribution of automatic train parking accuracy. Finally, based on the historical data of train parking

accuracy of a subway line in Chengdu, the LSTM prediction model is trained and verified. Results show that the prediction model can meet the statistical requirements for the similarity greater than 0.9. Thus, the effectiveness and accuracy of the model are verified.

Key words urban rail transit; LSTM network; Weibull distribution; stop accuracy prediction

First-author's address School of Information Science and Technology, Southwest Jiaotong University, 610031, Chengdu, China

0 引言

许多城市轨道交通线路采用了全自动运行系统。全自动运行系统不仅可以保障列车的运行安全, 有效提升线路的折返效率, 还可以减轻运维作业的工作量^[1]。与传统有人驾驶城市轨道交通线路相比, 列车进站自动停车功能是全自动运行线路的优势之一。在列车进站自动停车的过程中, 停车精度是衡量列车是否停准的一个重要指标。

影响列车停车精度的因素主要有以下几点: 首先是列车自身因素, ATO(列车自动运行)系统会给空气制动系统设定一个预压力, 以提高空气制动的响应速度, 从而导致列车实际的制动力偏高^[2]; 其次, 考虑到故障-安全原则, ATO 会对制动系统设定一个空气制动余量, 这个余量会导致列车实际制动力略大于所需值; 再次, 在线路方面, 某些车站的线路曲线半径过小, 以及露天线路天气的影响、各站点应答器的安装差异、站台门的对位差异等因素, 都会在一定程度上影响列车的停车精度^[3]。

国内外关于 ATO 模式下列车停车控制的研究

* 上海市自然科学基金资助项目(22ZR1422200)

主要集中在两大方面:优化控制算法和机器学习方法。由于城市轨道交通线路投入运营后基本不会更改列车运行的控制算法,且停车过程的建模较为困难,因此,优化控制算法在城市轨道交通中的适用性不强。在机器学习方法的相关研究中,文献[4]对停车过程中列车的速度、位置等信息进行建模,对比了CNN(卷积神经网络)和DNN(全连接神经网络)两种算法的优劣。文献[5]利用多种数据挖掘算法(如Ridge回归、RBF(径向基函数)神经网络等)构建了列车停车精度的预测程序。文献[6]采用了机器学习中的Boosting回归算法对列车停车精度进行了回归预测。

城市轨道交通的运维人员通过收集长期的列车停车精度数据,根据数据每日的变化趋势,手动对列车停车的追踪目标点进行调整。这种做法工作量大、效率低下,严重影响了生产效率。因此,迫切需要找到一种有效的方法,通过对历史大数据进行分析,找出隐藏其中的数据规律,为列车进站自动停车精度提供辅助预测,用以指导车辆运维人员进行参数配置。

本文提出一种列车进站自动停车精度的预测方法。该方法采用Weibull分布参数拟合每期的停车精度分布,得到分布拟合结果后,构建LSTM(长短期记忆)网络算法模型。在此基础上,采用成都某地铁线路列车的历史数据对模型进行训练和验证,对预测模型的分布参数进行回归预测。在工程应用上,城市轨道交通车辆运维人员将列车实时的停车精度数据序列输入到模型后,模型将自动预测列车在下一个车站的停车精度,运维人员从而可以通过手动移动列车的追踪目标点来确保列车精确停车。

1 列车进站自动停车精度预测分析与拟合

1.1 列车进站自动停车精度预测分析的算法框架

图1为列车进站自动停车精度预测分析的主要流程。该流程主要包括以下5个步骤。

步骤1:数据清洗。运维人员获得现场停车日志后,提取出列车停车精度的记录信息,并对其中无效的数据予以去除。

步骤2:对列车停车精度数据进行预处理。根据城市轨道交通一线员工的工作经验,将列车停车精度的历史数据以1d为1个统计周期进行预处理(如数据清洗、数据转换等)。

步骤3:采用Weibull最小极值分布法和Weibull最大极值分布法对每个统计周期的数据进行拟合,得到对应的分布参数;对比分析这两种分布的拟合度,得到对应参数的时间序列。

步骤4:构建LSTM预测模型。在已获得的时间序列基础上,采用LSTM网络算法构建列车进站自动停车精度的LSTM预测模型;对模型进行验证评估,并对下一个统计周期的分布参数进行预测。

步骤5:预测模型的应用。通过预测获得的下一个统计周期的分布参数,综合评估下一个统计周期列车停车精度调整的偏差值。

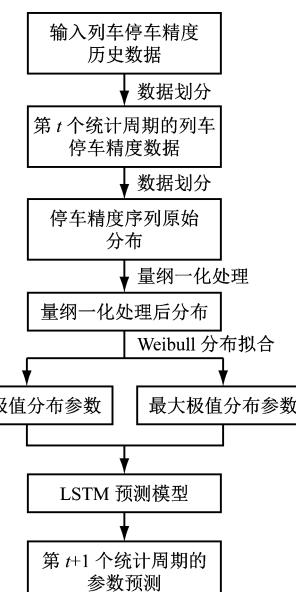


图1 列车进站自动停车精度预测分析算法框架

Fig. 1 Prediction and analysis algorithm framework of automatic train parking accuracy

1.2 列车停车精度分布拟合

目前,主要采用两种方法对Weibull分布进行参数拟合:最大似然估计法和矩估计法。本文经过大量的实践验证后,采用简单有效的最大似然估计法对Weibull分布进行参数估计。Weibull分布的最大似然函数为:

$$L(x_1, x_2, x_3, \dots, x_i, \alpha, \beta) = \prod_{i=1}^n \frac{\beta}{\alpha} \left(\frac{x_i}{\alpha} \right)^{\beta} - \frac{1}{\alpha^\beta} \sum_{i=1}^n x_i^\beta \quad (1)$$

式中:

L —Weibull分布的最大似然函数;

$x_1, x_2, x_3, \dots, x_i$ —各维度的数据值, i 为停车精度的维度;

α, β —Weibull 分布拟合参数;

n —自然数序列。

式(1)两边取对数,可得:

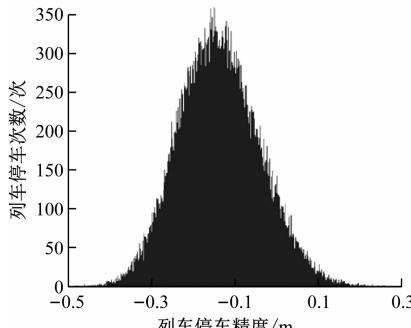
$$\ln L(x_1, x_2, x_3, \dots, x_n; \alpha, \beta) =$$

$$n \ln \frac{\beta}{\alpha} + (\beta - 1) \sum_{i=1}^n \ln \left(\frac{x_i}{\alpha} \right) - \frac{1}{\alpha^\beta} \sum_{i=1}^n x_i^\beta \quad (2)$$

令 $\frac{\partial \ln L}{\partial \alpha} = 0, \frac{\partial \ln L}{\partial \beta} = 0$, 代入式(2)则有:

$$\begin{cases} \frac{\partial \ln L}{\partial \alpha} = -\frac{n\beta}{\alpha} + \frac{\beta}{\alpha^{\beta+1}} \sum_{i=1}^n x_i^\beta = 0 \\ \frac{\partial \ln L}{\partial \beta} = -\frac{n}{\beta} + \sum_{i=1}^n \ln \left(\frac{x_i}{\alpha} \right) - \sum_{i=1}^n \ln \left(\frac{x_i}{\alpha} \right)^\beta \ln \left(\frac{x_i}{\alpha} \right) = 0 \end{cases} \quad (3)$$

求解上式(3),即求得 α 和 β 。



a) 整体停车精度分布

2 LSTM 预测模型的实例验证与结果分析

2.1 数据的处理及拟合

本文以成都地铁某线路列车为例进行实例验证。该线列车停车精度的历史数据共 137 973 条。对数据进行清洗、去除偏差值较大数据后,得到有效数据 136 704 条。

从图 2 a) 可以看出,这些数据在整体分布上具有正态分布的特点。采用 Alpha 分布、Weibull 分布(包括 Weibull 最大极值分布、Weibull 最小极值分布)及 Laplace 分布对数据进行拟合,得到的拟合结果如图 2 b) 所示。其中,Weibull 分布拟合效果最好。因此,本文采用 Weibull 分布对该线列车后续每一个统计周期的数据进行拟合并分析。

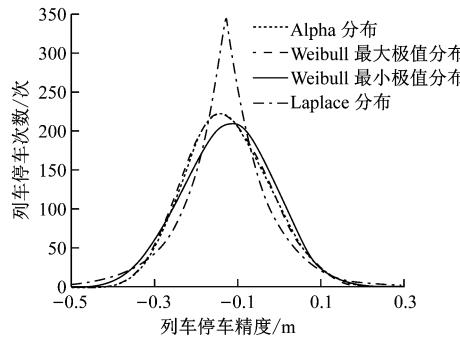


图 2 列车停车精度的整体分布及 4 种分布拟合

Fig. 2 Overall distribution of train parking accuracy and 4 kinds of distribution fitting

根据列车运行计划,该列车在 1 d 内停靠站台的次数为 534 次。该列车的历史数据统计了 256 d,以 1 d 为 1 个统计周期,则将历史数据划分为 256 期,即有 256 个数据样本。对每 1 期数据采用 Weibull 分布进行拟合,可得到 Weibull 分布拟合尺度参数和形状参数的时间序列。由于数据过多,为便于展示,本文仅列出第 1 期、第 50 期、第 100 期、第 150 期、第 200 期及第 250 期的数据样本,以及这些样本对应的分布参数,如表 1 所示。

2.2 构建 LSTM 预测模型

利用多层网络搜索法,寻找 LSTM 网络最佳拟合参数的三维图,3 个维度分别是窗口长度 l 、学习率 η 、状态大小 S_{state} 。对这 3 个维度进行量纲一化处理,可以得到最佳的拟合参数分别为: $l = 3, \eta = 0.01284, S_{\text{state}} = 4.5735$ 。

表 1 列车停车精度的 Weibull 分布参数

Tab. 1 Weibull distribution parameters of train parking accuracy

样本序列	尺度参数	形状参数
第 1 期	2.7863	1.9256
第 50 期	3.3120	1.9142
第 100 期	4.2250	2.3369
第 150 期	3.5618	2.0496
第 200 期	1.2449	1.6246
第 250 期	1.2098	1.6863

图 3 是测试集上对 Weibull 最小极值分布和 Weibull 最大极值分布的形状参数和尺度参数的预测结果。这两个参数均具有周期化波动的趋势,传统的机器学习方法不适用于处理这类预测问题。并且,本文所研究的数据是一维的时间序列,而在

时间序列的预测方面,基于RNN(循环神经网络)的LSTM网络有较好的效果,因此,构建基于RNN的LSTM预测模型。由图3可看出,量纲一化后得到的列车停车精度分布预测效果与各统计周期下的

现场原始数据分布基本吻合。由此可以得出结论:LSTM预测模型能够较好地捕捉尺度参数和形状参数的变化趋势,并可准确地预测后续统计周期的参数值。

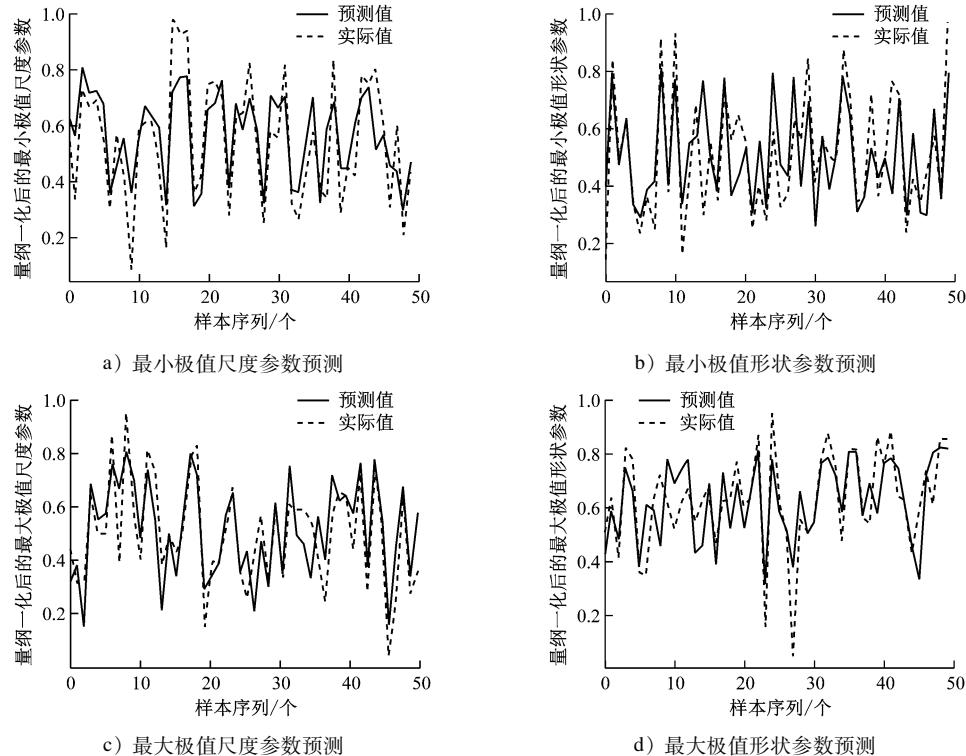


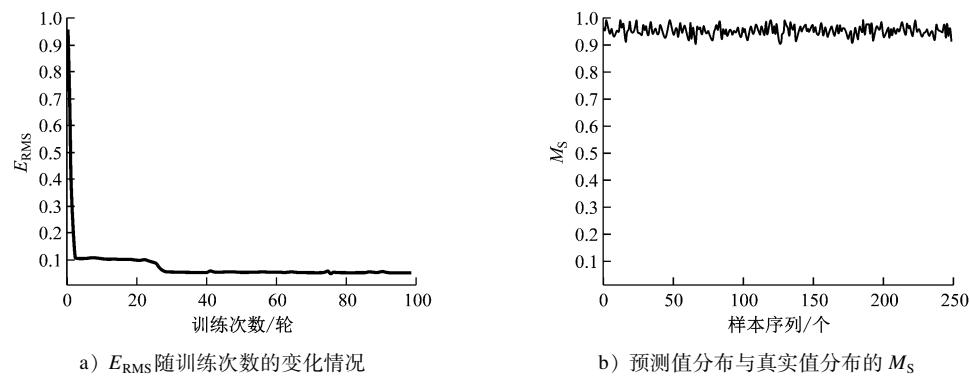
图3 采用Weibull分布得到的形状参数和尺度参数预测结果

Fig. 3 Prediction results of shape parameters and scale parameters obtained by Weibull distribution

图4为LSTM预测模型最小极值尺度参数的均方误差值 E_{RMS} ,以及预测值分布和实际值分布的相似度 M_s 的计算结果。由图4可知,随着训练轮数的增加, E_{RMS} 大为降低,在100轮左右 E_{RMS} 下降到0.0437并趋于稳定。这说明模型训练比较充分,可满足统计学角度对 E_{RMS} 的要求。形状参数和尺度

参数时间序列的预测效果较好,从而验证了LSTM预测模型的有效性。

从分布相似性的角度看,预测值分布和实际值分布的相似性均值 E_{AR} 为0.9426,且每一个统计周期的 M_s 均大于0.9。这说明LSTM预测模型具有较好的普遍适用性和有效性。



a) E_{RMS} 随训练次数的变化情况

b) 预测值分布与真实值分布的 M_s

图4 LSTM预测模型最小极值尺度参数和形状参数的 E_{RMS} 和 M_s 计算结果

Fig. 4 E_{RMS} and M_s calculation results of scale parameters and shape parameters of LSTM prediction model's minimum extreme value

(下转第71页)