

基于粒子群优化与宽度学习系统的地铁客流预测模型*

付建广¹ 尤斌^{2,3} 林毅⁴ 陈德旺^{2,3}

(1. 福州轨道交通设计院有限公司,350003,福州; 2. 福州大学数学与计算机科学学院,350116,福州;
 3. 福州大学智慧地铁福建省高校重点实验室,350116,福州;
 4. 福州地铁集团有限公司,350004,福州//第一作者 正高级工程师)

摘要 为了提高地铁客流量预测的准确性,基于传统的PSO(粒子群优化)算法与BLS(宽度学习系统),提出一种新的地铁客流预测模型,即PSO-BLS算法。首先,对地铁站点的繁华程度、前一时段进站量、前一时段出站量及前一时段断面客流量等参数进行分析,并根据分析结果提出需要根据工作日和双休日分别对地铁客流量进行预测。其次,利用PSO算法对BLS的特征层偏置进行优化。最后,以福州地铁1号线AFC(自动售检票)系统中记录的大量乘客出行数据为例,对所提PSO-BLS算法进行验证。验证结果表明:与传统的地铁客流量预测算法BP(反向传播)神经网络和ELM(极限学习机)相比,PSO-BLS算法获得的计算结果在多项性能指标中均取得了较优异的表现;对BLS的特征层偏置进行优化可以提高BLS的计算精度,为地铁客流量预测提供更精确的计算结果。

关键词 地铁; 粒子群优化; 宽度学习系统; 客流预测

中图分类号 U293.1¹⁺³

DOI:10.16037/j.1007-869x.2023.05.005

Metro Passenger Volume Prediction Model Based on Particle Swarm Optimization and Broad Learning System

FU Jianguang, YOU Bin, LIN Yi, CHEN Dewang

Abstract To improve the accuracy of metro passenger volume prediction, a new metro passenger volume prediction model based on the conventional PSO (particle swarm optimization) algorithm and BLS (broad learning system) is proposed, known as PSO-BLS algorithm. Firstly, parameters including the prosperity level of metro station, the inbound passenger volume, the outbound passenger volume and the sectional passenger volume in the previous time period are analyzed, the metro passenger volume of weekdays and weekends are predicted separately according to the analysis results. Secondly, PSO is applied to optimize the characteristic layer bias

of BLS. Finally, based on the large amount of passenger travel data recorded in AFC (automatic fare collection) system of Fuzhou Metro Line 1, the proposed PSO-BLS algorithm is verified. The verification results show that: compared with the conventional metro passenger volume prediction algorithm BP (backpropagation) neural network and ELM (extreme learning machine), the calculation results of PSO-BLS algorithm have achieved better performance in a number of performance indicators; optimizing the characteristic layer bias of BLS can improve the accuracy of BLS and provide more accurate calculation results for metro passenger volume prediction.

Key words metro; particle swarm optimization; broad learning system; passenger volume prediction

First-author's address Fuzhou Rail Transit Design Institute Co., Ltd., 350003, Fuzhou, China

目前,轨道交通系统的一项重要研究课题就是构建智慧轨道交通系统,即让轨道交通系统具备感知、预测及解决问题的能力,以满足当前客运和货运的运输需求。智慧轨道交通系统的功能之一就是监测地铁站点的客流量,并根据监测结果快速、准确地预测出未来时间段内该站点的客流量,进而达到优化城市轨道交通系统的部分参数并提高整体运行效率的目的。在相关的轨道交通短时间客流量预测研究^[1]中,常用的模型为BP(反向传播)神经网络及其改进模型,但是随着网络模型的不断扩大,通常需要耗费大量的时间和机器资源对庞大的神经网络参数进行优化。此外,若数据模型或网络结构发生了变化,则需要对整个网络模型进行重新训练。

不同于参数量庞大的BP神经网络,BLS(宽度学习系统)能够在较短的训练时间内进行高效

* 国家自然科学基金面上项目(61976055);国家重点研究与发展计划项目(2018YFB0104403);智慧地铁福建省高校重点实验室建设经费项目(53001703)

学习。此外, BLS 还可以通过增量学习高效重建需要扩展的网络模型。但由于 BLS 中的大部分参数,如原始数据与特征层之间、特征层与增强层之间的权重与偏置均为随机生成的,且其初始化后往往不参与训练过程,其对 BLS 网络的计算精度有一定影响,所以需要进一步研究 BLS 中的参数优化方法,以提高网络计算精度。基于此,本文基于 PSO(粒子群优化)算法和 BLS,提出一种新的地铁客流预测模型——PSO-BLS 算法,利用 PSO 对特征层的偏置进行优化,并以福州地铁 1 号线(以下简称“1 号线”)的客流数据为例,测试所提模型的客流预测效果。最后,将 PSO-BLS 算法与传统的预测方法 BP 神经网络、ELM(极限学习机)及 BLS 进行分析对比,验证了 PSO-BLS 算法的有效性与精确性。本文研究可为地铁客流的精准预测提供一种新的解决思路,同时也可为地铁的运营优化提供借鉴与参考。

1 基于实测数据的客流量分析

1.1 统计数据

本文所使用的数据集来源于 2019 年 6 月—2019 年 12 月 1 号线 AFC(自动售检票)系统的乘客出行记录。在每条记录中包含了 86 项属性,其中仅有 28 项为非空间属性。出行记录包括记录序号、卡编号、进站编号、出站编号、进站时间、出站时间和刷卡设备编号等信息。

1.2 进出站客流量分析

地铁客流量的变化具有周期性^[2]。在工作日、双休日、节假日或突发状况等多种不同运营情况下,乘客的出行模式也会发生改变,进而影响客流量的大小与分布。基于此,将乘客出行模式细分为多种乘客出行模型,具体分为工作日和双休日进行讨论。

1.2.1 1 号线站点工作日客流量分析

1 号线站点工作日客流量如图 1 所示。在工作日,1 号线站点客流具有明显的方向性与时段性,1 号线福州火车站站与福州火车南站站的进出站客流量占 1 号线所有站点总客流量的 21.8%。1 号线其他部分站点在早高峰时段的客流表现为出多入少,而在晚高峰时段则表现为出少入多的情况。这种情况与站点周围地段的繁华程度具有正相关性,与上下班时段人群流动方向相吻合。

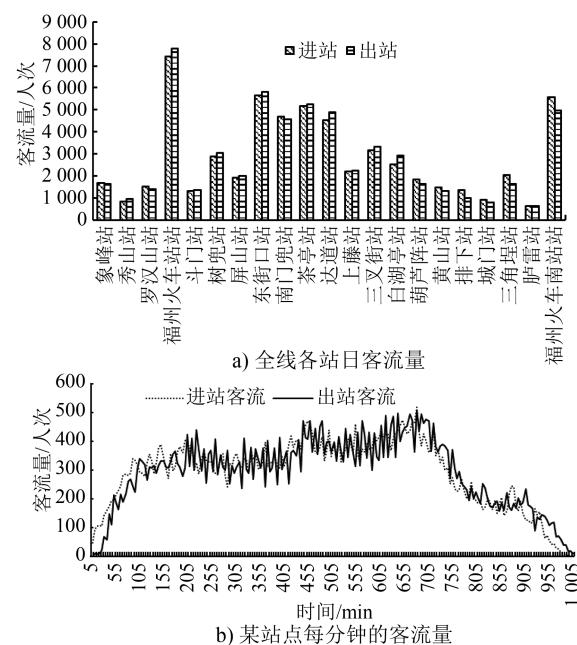


图 1 1 号线站点工作日客流量

Fig. 1 Passenger volume of Line 1 stations on weekdays

1.2.2 1 号线站点双休日客流量分析

在双休日,除 1 号线福州火车站站与福州火车南站站外,1 号线站点客流量表现为部分站点客流量极大,其余站点客流量较为平均的情况。乘客出行的目的地虽具有一定的随机性,但地铁站点客流量的大小主要受其周边百货商场和公园等大型公共场所对客流吸引力的影响。1 号线站点双休日客流量如图 2 所示。

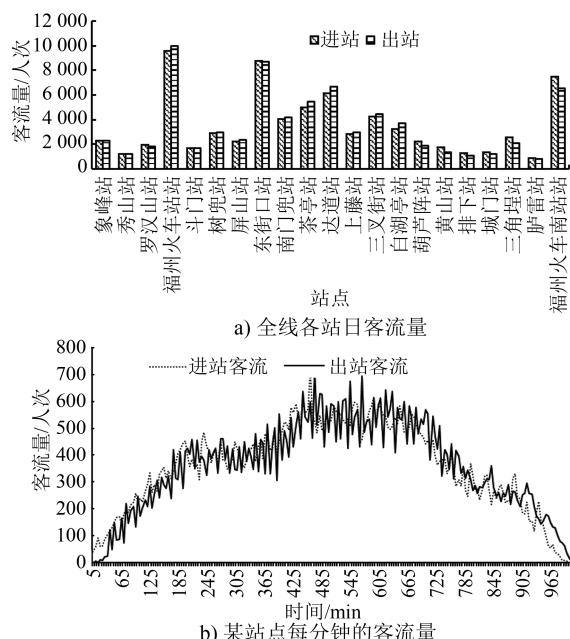


图 2 1 号线站点双休日客流量

Fig. 2 Passenger volume of Line 1 stations on weekends

1.3 客流量相关因素分析

地铁客流量具有一定的规律性,设 t 时刻某站点a的客流量估计值为 $F(t_a)$,则其可用若干个推导因子来表示:

$$F(t_a) = H \left[\sum_{j=0}^n \varphi_j(\omega_j, \chi_j, \beta_j) \right] \quad (1)$$

式中:

χ_j ——第 j 个推导因素;

ω_j ——第 j 个权重;

β_j ——第 j 个偏置;

$\varphi_j(\omega_j, \chi_j, \beta_j)$ ——第 j 个推导因素的客流量估计值的某种线性变换;

H ——网络输出函数。

通过对1号线工作日及双休日的客流特性进行分析发现,站点繁华程度类型,以往同时段站点进站、出站客流量平均值,前一时段站点进站、出站客流量及前一时段站点断面客流量6个指标与站点客流量显著相关,因此本文选取前6个维度的数据作为客流量估计的推导因子,如表1所示。

表1 客流量估计推导因子

Tab. 1 Derivation factors of passenger volume estimation

χ_j	参数含义
χ_1	站点a的繁华程度类型
χ_2	以往同时段站点a的进站客流量均值
χ_3	以往同时段站点a的出站客流量均值
χ_4	前一时段站点a的出站客流量
χ_5	前一时段站点a的进站客流量
χ_6	前一时段进入站点a的断面客流量

2 基于PSO的BLS

2.1 BLS

基于RVFLNN网络思想而设计的BLS采用了特征提取的方法。首先,由原始数据通过映射获得特征节点,再将特征节点经过映射获得其增强节点,所有的特征节点与增强节点都将连接到网络输出层。节点间连接的权重与偏置等参数均为随机生成。BLS在计算特征层、增强层与输出层之间的权值时,一般使用岭回归算法^[3]。

当网络需要扩展时,在不需要重新训练网络模型的情况下,增量学习算法能够快速重构网络,BLS可以利用增量学习高效地更新网络。当网络需要添加额外增强层节点或改变输入数据维度等涉及学习系统模型变化的操作时,运用该方法可以大幅减少训练网络模型所耗费的计算时间。相比于深

度学习的反复训练及时常陷入局部最优解的情况,BLS的优势非常明显。

2.2 PSO

PSO是一种模仿生物种群行为的群体智能算法,该算法把种群中的每一个个体都称为粒子,每一个粒子都表示一个潜在的可行解,该算法的最终目的就是找到全局最优解。

种群中 t 时刻第 i 个粒子的位置和速度的更新方式可以表示为:

$$\begin{aligned} v_i(t+1) &= v_i(t) + a_1 r_1 [p_i(t) - x_i(t)] + \\ &\quad a_2 r_2 [p_g(t) - x_i(t)] \end{aligned} \quad (2)$$

$$x_i(t+1) = x_i(t) + v_i(t+1) \quad (3)$$

式中:

$v_i(t)$ —— t 时刻第 i 个粒子的速度;

$x_i(t)$ —— t 时刻第 i 个粒子的位置;

$p_i(t)$ ——直到 t 时刻第 i 个粒子所经历过的最优位置;

$p_g(t)$ ——直到 t 时刻当前所有粒子所经历过的最优位置,即当前的全局最优位置;

a_1, a_2 ——粒子加速度;

r_1, r_2 ——服从均匀分布的随机数,其取值范围为 $[0, 1]$ 。

当搜索空间移动时,为了避免在不断更新中的粒子速度过大或过小,需要设定粒子速度的取值范围,可以表示为:

$$\left. \begin{array}{l} v_i = v_{\max}, v_i > v_{\max} \\ v_i = -v_{\max}, v_i < -v_{\max} \end{array} \right\} \quad (4)$$

式中:

v_i ——第 i 个粒子的速度;

v_{\max} ——粒子速度的最大值。

2.3 PSO-BLS 算法流程

为解决BLS中原始数据至特征层的连接参数的初始值随机赋值会影响预测准确性的问题,PSO-BLS算法采用特征层偏置的方法提高预测的准确性。因此本文使用PSO算法对特征层偏置进行优化,以进一步提高BLS的性能,即PSO-BLS算法。PSO-BLS算法的输入为训练集,记为:

$$\Phi = \{ [(y_{1j}, y_{2j}, y_{3j}, y_{4j}, y_{5j}, y_{6j}), T_z] | \\ y_{mj} \in \mathbf{R}, T_z \in \mathbf{R}, z = 1, 2, \dots, N \} \quad (5)$$

式中:

x_{mj} ——第 j 个推导因子;

T_z ——第 z 条数据集流量;

N ——训练集大小。

PSO-BLS 算法的输出为优化后的 PSO-BLS 网络。由式(1)可知,PSO-BLS 算法流程为:

步骤 1: 网络初始化, 随机生成第 d 个特征层权重 ω_{ed} 。

步骤 2: 随机生成第 k 个增强层权重 ω_{hk} 与第 k 个增强层偏置 β_{hk} 。

步骤 3: 计算每个粒子对应的特征层偏置 β_{ed} , 计算特征层输出 Z 与增强层输出 V , 通过 $A = [Z | V]$ 获得矩阵 A 后, 再计算其广义逆矩阵。

步骤 4: 利用最小二乘法根据公式计算输出层权重, 并计算其输出。

步骤 5: 根据损失函数计算每一个粒子所对应的网络误差, 并将该误差作为每一个粒子的评价值。

步骤 6: 利用粒子群算法对特征层节点的偏置进行更新, 如果 $L < K$ (L 为当前的循环次数; K 为最大迭代次数) 且未满足精度要求, 则 $L = L + 1$, 跳转至步骤 3, 否则结束算法, 输出训练后的 PSO-BLS 网络。

3 实际客流量数据与 PSO-BLS 算法模型预测结果对比与分析

3.1 性能评价指标

本文选取均方差、平均绝对值误差及均方根误差作为预测模型准确度的评价指标。MSE(均方差)可以反映一个数据集的离散程度。MAE(平均绝对值误差)是所有单个观测值与算术平均值偏差的绝对值的平均。RMSE(均方根误差)是预测值与真实值偏差的平方与观测次数比值的平方根, 用于衡量观测值与真值之间的偏差。

3.2 预测结果对比分析

以 1 号线 2018 年 1 月 2 日—2018 年 1 月 5 日作为工作日客流量数据, 1 月 6 日、1 月 7 日、1 月 13 日与 1 月 14 日作为双休日客流量数据, 总计 30 000 条客流量数据。通过这些客流量数据对 PSO-BLS 算法的准确性进行测试。其中, 25 000 条客流量数据作为训练集, 5 000 条客流量数据作为测试集。不同算法下的训练集训练结果对比如表 2 所示, 不同算法下的测试集训练结果对比如表 3 所示。

由表 2 和表 3 可知, 所提 PSO-BLS 算法在地铁客流预测中有更优的表现, 其预测结果与实际情况的均方差值较小, 说明所提算法的准确度更高, 预测结果更接近于实际情况。综上所述, 经过 PSO 算

表 2 不同算法下的训练集训练结果对比

Tab. 2 Comparison of training set training results with different algorithms

算法	MSE	MAE	RMSE
BP 神经网络	239.814	10.514	15.485
ELM	222.882	10.412	14.929
BLS	240.009	10.802	15.492
PSO-BLS	229.526	10.641	15.150

表 3 不同算法下的测试集训练结果对比

Tab. 3 Comparison of test set training results with different algorithms

算法	MSE	MAE	RMSE
BP 神经网络	261.403	11.427	16.167
ELM	289.395	10.923	17.011
BLS	246.306	11.178	15.694
PSO-BLS	238.420	11.030	15.440

法优化后的 BLS 网络在预测精确度上有着一定的提高, 能在地铁客流预测模型中发挥出更好的效果。

4 结语

快速、精准地预测某一时段某站点的客流对于智慧轨道交通系统的实时优化是至关重要的。对地铁客流而言, 传统的 BP 神经网络、ELM 和 BLS 的预测效果均不佳。深度神经网络虽然计算精度较高, 但由于其参数较多, 导致其计算效率较低。本文结合 PSO 算法与 BLS, 提出一种新的地铁客流预测模型——PSO-BLS 算法。以 1 号线 AFC 系统中记录的大量乘客出行数据为例, 验证所提算法模型的有效性。验证结果表明, PSO-BLS 算法精度更高、预测效果更优。本文研究可为福州地铁运营优化提供数据基础。

未来还需要进一步研究 PSO-BLS 算法, 以进一步提高其预测精度和计算效率, 为地铁客流大数据预测系统提供更高效的解决方案, 进一步提升地铁系统的运营效率。

参考文献

- [1] 王雪梅, 张宁, 张云龙. 城市轨道交通短时客流预测体系框架及关键技术 [J]. 交通运输工程与信息学报, 2013, 11(2): 107.
WANG Xuemei, ZHANG Ning, ZHANG Yunlong. Framework and key technologies of short term passenger flow forecast of urban rail transit [J]. Journal of Transportation Engineering and Information, 2013, 11(2): 107.

示。由图11可知,随着溶洞尺寸的增大,支护桩的最大水平位移、基坑坑底土体最大隆起量、支护桩后最大地面沉降近似抛物线形迅速增大。通过抛物线形拟合可获得三者与溶洞尺寸之间的关系,将拟合结果与无溶洞时的情况进行对比发现,相较于无溶洞的情况,5种变动参数工况下,增大溶洞尺寸导致支护桩最大水平位移分别增大了5.4%、9.9%、16.6%、20.4%、30.9%。当溶洞尺寸在2.5 m×2.5 m及以上时,溶洞会导致支护桩的最大水平位移大于30 mm,超过规范设计限值,对围护结构的稳定性产生了较大影响;当溶洞尺寸大于2.0 m×2.0 m时,基坑坑底土体隆起量明显增大;当溶洞尺寸为4.0 m×4.0 m时,相较于无溶洞的情况,基坑坑底土体隆起量增大了33.41 mm。溶洞尺寸对支护桩后地面沉降的影响相对不大,当溶洞尺寸为4.0 m×4.0 m时,相较于无溶洞的情况,支护桩后最大地面沉降增大了1.27 mm。

4 结语

本文以南京一句容城际轨道交通工程白水桥东站为例,基于三维有限元数值计算模型研究了溶洞对岩溶区段轨道交通车站基坑开挖稳定性的影响,分析了开挖过程中溶洞位置和溶洞尺寸等因素对基坑及围护结构稳定性的影响规律,现场实测结果验证了数值模拟的准确性。主要得到以下结论:

1) 基坑被动区溶洞的存在对基坑开挖及围护结构的稳定性影响较大,溶洞的存在会使支护桩水平位移、基坑坑底土体隆起变形、支护桩后地面沉降均有所增大。

2) 随着溶洞与支护桩水平距离、溶洞在基坑底部埋深的增加,支护桩最大水平位移、基坑坑底土体最大隆起量和支护桩后最大地面沉降均有所减小,并在一定范围内与溶洞与支护桩水平距离及溶

洞在基坑底部埋深大小呈较好的抛物线形关系。

3) 随着溶洞尺寸的增加,支护桩最大水平位移、基坑坑底土体最大隆起量和支护桩后最大地面沉降呈现抛物线形增大。溶洞尺寸对基坑坑底土体隆起量的影响较大,而对支护桩后地面沉降的影响较小。

参考文献

- [1] 崔庆龙,沈水龙,吴怀娜,等.广州岩溶地区深基坑开挖对周围环境影响的研究[J].岩土力学,2015,36(增刊1): 553.
CUI Qinglong, SHEN Shuiliang, WU Huaina, et al. Field investigation of deep excavation of metro station on surrounding ground in karst region of Guangzhou [J]. Rock and Soil Mechanics, 2015, 36 (S1) : 553.
- [2] 李慎奎,陶嵒.武汉地区岩溶发育特征及地铁工程中岩溶处理[J].隧道建设,2015,35(5): 449.
LI Shenkui, TAO Lan. Features of karst development in Wuhan area and treatment of karsts encountered in construction of Wuhan Metro [J]. Tunnel Construction ,2015,35(5) : 449.
- [3] 江杰,王彰庆,彭远胜,等.岩溶区溶洞对基坑稳定性影响及处治技术研究[J].地下空间与工程学报,2018,14(增刊1): 471.
JIANG Jie, WANG Zhangqing, PENG Yuansheng, et al. Effect study of karst cave on the stability of foundation pit and treatment technology in karst region [J]. Chinese Journal of Underground Space and Engineering, 2018, 14 (S1) : 471.
- [4] 王倩.溶洞对支护桩稳定性影响研究[D].南宁:广西大学,2014.
WANG Qian. The research on the effect of karst cave on the stability of retaining pile [D]. Nanning: Guangxi University, 2014.
- [5] 梅博轩.岩溶区基坑支护桩的稳定性分析[D].广州:广东工业大学,2018.
MEI Boxuan. Stability analysis of foundation pit supporting pile in karst area [D]. Guangzhou: Guangdong University of Technology, 2018.

(收稿日期:2020-12-12)

(上接第26页)

- [2] 周云娣.地铁客流特征分析与运营措施的优化[J].中国水运(下半月),2018,18(7): 40.
ZHOU Yundi. Analysis of subway passenger flow characteristics and optimization of operation measures [J]. China Water Trans-

port, 2018, 18(7) : 40.

- [3] MCDONALD G C. Ridge regression[J]. WIREs Computational Statistics, 2009, 1(1) : 93.

(收稿日期:2020-11-30)