

# 基于 AFC 的地铁车站楼扶梯客流参数预测与状态判定

孙建辉 胡 华 刘志钢

(上海工程技术大学城市轨道交通学院 上海 201620)

**摘要** 通过采集和计算得到地铁站楼扶梯等候区的客流密度和通过时间两个客流参数。对各闸机的进出站 AFC 数据和预测楼扶梯等候区的客流参数进行相关性分析,筛选出与预测楼扶梯相关联的闸机组。在此基础上,采用改进的 NARX 神经网络建立基于关联闸机组 AFC 数据的楼扶梯等候区客流参数预测模型,并提出基于客流参数预测值的楼扶梯等候区客流状态判定方法。通过 MATLAB 对 AFC 数据及客流参数进行仿真。结果表明,该预测方法能够通过地铁车站关联闸机组的进出站 AFC 数据对楼扶梯等候区的客流参数进行较高精度的预测。研究成果可为地铁站内楼扶梯等拥堵点的客流状态预判提供决策依据。

**关键词** 地铁站 楼扶梯等候区 AFC 数据 NARX 神经网络 客流参数

中图分类号 TP391.9 U231.92 文献标识码 A DOI:10.3969/j.issn.1000-386x.2019.01.049

## PREDICTION AND STATUS DETERMINATION OF PASSENGER FLOW PARAMETERS AT ESCALATOR OF SUBWAY STATION BASED ON AFC

Sun Jianhui Hu Hua Liu Zhigang

(College of Urban Rail Transportation, Shanghai University of Engineering Science, Shanghai 201620, China)

**Abstract** Two parameters: passenger flow density and passing time in the waiting area of escalator at subway station were obtained by acquisition and calculation. We analyzed the correlation between AFC data of in and out gates and passenger flow parameters in the waiting area of the escalator to select the gates related to the predicted the escalator. On this basis, we adopt the improved NARX neural network to establish the passenger flow parameter prediction model of waiting area of escalator based on the related gates' AFC data, and we proposed judging method of the passenger flow status in the escalator waiting area based on the predictive value of passenger flow parameters. The AFC data and passenger flow parameters were simulated by MATLAB. The results show that the proposed prediction method can predict the passenger flow parameters of the waiting area of escalator with high accuracy through AFC data of the subway station associated gates. The research results can provide decision-making basis for the prediction of passenger flow status at the congestion points such as escalators at subway stations.

**Keywords** Subway station Waiting area of escalator AFC data NARX neural network Passenger flow parameters

## 0 引言

近年来,地铁在我国各大城市快速发展,在居民出行方式中所占的比例越来越大。但是,地铁车站资源已不能满足当前的客流需求,造成车站拥堵现象,高密度客流大大增加了车站的安全隐患,车站楼扶梯更是行人跌倒、发生踩踏等突发事件的多发点。2016 年上

海轨道交通日均客流量<sup>[1]</sup>为 928 万人次,已达到公共交通日均客流量的 50%。因此,通过 AFC 数据预测地铁车站楼扶梯等候区的客流参数,对楼扶梯等候区客流状态进行预判对于保障地铁车站的运营安全具有重要意义。

针对地铁车站拥堵问题,文献[2]通过实验分析了车站瓶颈的客流特征,对瓶颈处的乘客特性进行了阐述,并对不同程度的瓶颈下的结果作出对比分析,研

究结果对于车站瓶颈的改善提供了参考价值。文献[3]通过对车站瓶颈点及客流交织点的现场调查,分析了站内设施对客流的影响机理,结果表明设施通行能力与其几何边界存在一定关系。蔡昌俊等<sup>[4]</sup>基于 AFC 数据构建了路网结构变化条件下的城轨站间客流量分布预测模型。李俊辉等<sup>[5]</sup>将楼扶梯的利用度作为评价车站客流状态的指标之一,建立了车站安全状态评价指标与安全评定等级之间的概率神经网络模型。

目前尚无专门针对楼扶梯等候区客流参数的研究。本文将楼扶梯等候区客流密度与客流通过时间作为客流状态表征参数,通过改进的 NARX 神经网络建立了关联闸机 AFC 数据与楼扶梯等候区客流参数预测模型,对楼扶梯等候区的客流状态进行了判定。楼扶梯等候区模型建立及预测过程如图 1 所示。以上海地铁 9 号线松江大学城站为例进行了验证分析。

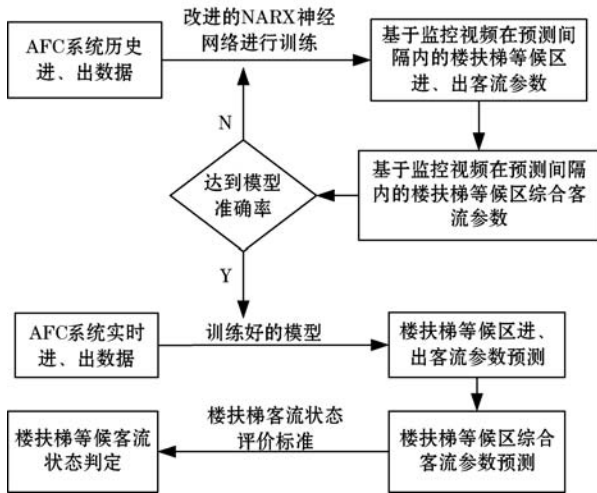


图 1 模型建立及预测过程

## 1 AFC 及楼扶梯客流参数分析

在工作日的早晚高峰以及非工作日的大部分时间,地铁站吸引大量的客流,高密度的客流给地铁站的运营管理带来了巨大的困难,同时也增加了地铁站发生突发事件的风险。地铁站内的拥堵点主要包括进出站口、通道、安检机、楼扶梯、站台等<sup>[6]</sup>部分,楼扶梯等候区是事故的多发区域,所以对地铁站楼扶梯等候区的客流分析对车站正常的运营管理具有重要意义。

### 1.1 AFC 数据分析

截至 2017 年底,我国已有 33 个城市开通了地铁,并且采用 AFC 智能票卡系统采集旅客信息,其基本数

据格式见表 1。

表 1 AFC 数据格式表

日期	进站 ID	进站时间	出站 ID	出站时间	票卡类型
日期 1	000104	07:06:14	000235	07:46:20	一卡通
日期 2	000308	07:10:15	000245	07:53:25	单程票
⋮	⋮	⋮	⋮	⋮	⋮

由表 1 可获得乘客的进出站时间、进出站日期及时间、票卡类型等信息。本文基于 AFC 数据推估楼扶梯口客流参数,将分别对进、出站 AFC 数据与楼扶梯口进、出站方向客流状态表征参数进行分析。

### 1.2 楼扶梯等候区客流参数分析

(1) 楼扶梯等候区域客流密度分析。对于等候区客流参数,要选取能够反映客流状态的具有代表性、相对独立的因素,客流密度是表征客流拥挤程度的重要特征参数,李颖宏等<sup>[7]</sup>提出了基于行人密度和单位宽度流率等反映客流状态的指标,建立了客流状态综合模糊评价模型。毕艳翔等<sup>[8]</sup>分析了站台客流密度对乘客安全性的影响,基于客流密度提出了轨道交通车站站台等候区服务水平的等级划分。因此,本文选取单位时间内楼扶梯处的平均客流密度作为参考,客流密度基于视频中等候区的乘客数求得;根据节点连接法<sup>[9]</sup>选取楼扶梯口区域  $S_i, S_j$  通过现场测量求得;选取每分钟为单位时段进行客流参数分析,单位时段内每 5 秒对视频内楼扶梯等候区域乘客数进行统计,计算每 5 秒内等候区的客流密度,最后计算单位时段的客流密度平均值。

楼扶梯等候区乘客对应进、出 AFC 的时间如图 2 所示。




图 2 目标区乘客进出 AFC 时间示意图

进站客流是连续不断的,出站客流具有间隔性的特点,预测间隔  $\Delta t$  可通过闸机与楼扶梯等候区之间的距离与乘客平均速度的比值求得。在每个发车间隔  $t_{发}$  内,包括客流的平均出站时间  $\bar{t}_{出}$  及空档时间  $t_{空}$ ,空档时间内是没有出站客流的,发车间隔构成如图 3 所示。




图 3 发车间隔构成

$$\rho_{ij}^{\text{进}} = \frac{\sum_{n=1}^N q_{ij(n)}^{\text{进}}}{NS_i} \quad (1)$$

$$\rho_{ij}^{\text{出}} = \frac{\sum_{n=1}^N q_{ij(n)}^{\text{出}}}{NS_i} \quad (2)$$

$$\rho_{ij} = \begin{cases} \rho_{ij}^{\text{进}} + \rho_{ij}^{\text{出}} & t \in \bar{t}_{\text{出}} \\ \rho_{ij}^{\text{进}} & t \in t_{\text{空}} \end{cases} \quad (3)$$

式中: $q_{ij(n)}^{\text{进}}$ 、 $q_{ij(n)}^{\text{出}}$ 为编号  $i$  楼扶梯等候区第  $j$  个单位时间内第  $n$  次进、出乘客数, $\rho_{ij}$ 为目标区域各单位时间内平均客流密度。

(2) 楼扶梯等候区域通过时间分析。贺杰<sup>[10]</sup>将排队长度和等待时间作为客流状态评价指标,对楼扶梯、站台等处客流状态加权建立了车站客流状态评价模型。通过时间包含了乘客在等候区的等待时间,可以进一步反映客流的拥挤程度及乘客速度,将每个单位时间分成三个等长时段,每个时段抽取相同数量乘客,进站方向共采集乘客数为  $M$ ,出站方向共采集乘客数为  $N$ ,分别计算进、出方向每个单位时间段内抽取乘客的平均通过时间。

进站方向的楼扶梯等候区客流平均通过时间为:

$$\bar{t}_{im} = \frac{\sum_{m=1}^M t_{im}}{M} \quad (4)$$

出站方向的楼扶梯等候区客流平均通过时间为:

$$\bar{t}_{in} = \begin{cases} \frac{\sum_{n=1}^N t_{in}}{N} & N \neq 0 \\ 0 & N = 0 \end{cases} \quad (5)$$

楼扶梯等候区客流的平均通过时间为:

$$\bar{t}_i = \begin{cases} \frac{M \cdot \bar{t}_{im} + N \cdot \bar{t}_{in}}{M + N} & N \neq 0 \\ \bar{t}_{im} & N = 0 \end{cases} \quad (6)$$

式中: $t_{im}$ 为单位时间段内编号为  $i$  楼扶梯等候区所选取的第  $m$  个进站乘客通过时间; $t_{in}$ 为单位时间段内编号为  $i$  楼扶梯等候区第  $n$  个出站乘客通过时间。

### 1.3 相关性分析

常用的相关性分析方法有 pearson 相关法、等级相关法、质量相关法,根据需要选取最常用的 pearson 相关系数对单位时间进、出站 AFC 数据与楼扶梯等候区单位时间进、出站客流参数分别作相关性分析。

$$r(X_p, X_q) = \frac{\sum_{l=1}^l (X_{pl} - \bar{X}_p)(X_{ql} - \bar{X}_q)}{\sqrt{\sum_{l=1}^l (X_{pl} - \bar{X}_p)^2} \sqrt{\sum_{l=1}^l (X_{ql} - \bar{X}_q)^2}} \quad (7)$$

式中: $X_{pl}$ 和  $\bar{X}_p$ 分别表示单位时间进、出 AFC 数据的第  $l$  个值及平均值, $X_{ql}$ 和  $\bar{X}_q$ 分别表示单位时间进、出目标区域的客流参数。Pearson 相关系数在 0.8 以上为高度相关、0.5~0.8 为中度相关、0.3~0.5 为低度相关、小于 0.3 为不相关。

### 1.4 楼扶梯等候区客流状态判定

通过客流密度及通过时间两个客流参数判断楼扶梯等候区的客流状态,楼扶梯等候区客流密度取值范围以文献[11]中安全阈值为基础并咨询相关地铁专家进行修正,楼扶梯等候区客流通过时间通过 K-均值聚类分析得到聚类中心并根据地铁专家经验进行修正。将楼扶梯等候区客流状态分为安全、较安全、一般、危险和很危险五种状态,客流状态评价标准如表 2 所示。

表 2 楼扶梯客流状态评价标准

安全等级	客流密度/(人·m <sup>-2</sup> )	楼扶梯等候区通过时间/s
安全	[0, 2.35]	[0, 14]
较安全	(2.35, 3.35]	(14, 27]
一般	(3.35, 4.20]	(27, 39]
危险	(4.20, 5.10]	(39, 52]
很危险	>5.10	>52

## 2 预测模型

BP 神经网络属于静态神经网络,是目前使用最成熟的一种神经网络,但是 BP 神经网络不能进行长时预测,且易陷入局部最优解,静态神经网络对于动态系统预测效果不佳。NARX 神经网络属于一种动态神经网络,对于非线性动态系统具有较好的预测结果。NARX 神经网络包括输入层、隐含层、输出层、输入延时和输出延时五部分,在使用 NARX 神经网络时要确定输入、输出延时及隐含层神经元个数,其不确定因素较多,所以本文选取一种只需要确定隐层神经元个数的改进 NARX 神经网络<sup>[12]</sup>,相较传统 NARX 神经网络其神经元的激励函数具有动态的映射功能,使用更为简单。图 4 为改进 NARX 神经网络结构模型,其中隐层 D 为动态神经元,其结构如图 5 所示。




图 4 改进 NARX 神经网络结构




图5 动态激励函数的神经元模型

图5 网络结构内设参数  $\Delta$  为输出一阶时延。

进站方向客流参数预测模型输入和输出分别为：

$$x^{进} = (x_{p1}^{进}, x_{p2}^{进}, \dots, x_{pl}^{进})$$

$$y^{进} = \begin{bmatrix} \rho_{i1}^{进}, \rho_{i2}^{进}, \dots, \rho_{il}^{进} \\ \bar{t}_{i1}^{进}, \bar{t}_{i2}^{进}, \dots, \bar{t}_{il}^{进} \end{bmatrix}^T \quad (8)$$

出站方向客流参数预测模型输入和输出分别为：

$$x^{出} = (x_{p1}^{出}, x_{p2}^{出}, \dots, x_{pl}^{出})$$

$$y^{出} = \begin{bmatrix} \rho_{i1}^{出}, \rho_{i2}^{出}, \dots, \rho_{il}^{出} \\ \bar{t}_{i1}^{出}, \bar{t}_{i2}^{出}, \dots, \bar{t}_{il}^{出} \end{bmatrix}^T \quad (9)$$

输入  $x^{进}$ 、 $x^{出}$  为相关进、出站闸机 AFC 数据, 输出  $y^{进}$ 、 $y^{出}$  为楼扶梯等候区进、出站方向的客流参数;  $\rho_{il}^{进}$ 、 $\rho_{il}^{出}$  为编号  $i$  的楼扶梯第  $l$  个进、出方向客流密度,  $\bar{t}_{il}^{进}$ 、 $\bar{t}_{il}^{出}$  为编号  $i$  的楼扶梯第  $l$  个进、出方向通过时间。隐含层动态神经元的传递函数如下：

$$v(k) = x(k) \cdot \omega^1 \quad (10)$$

$$net(k) = k_1 \cdot v(k) + k_2 \cdot net(k-1) + k_3 \cdot v(k-1) \quad (11)$$

$$z(k) = f(net(k)) \quad (12)$$

式中:  $x(k)$  为输入层神经元第  $k$  次输入单位时间进、出 AFC 向量;  $v(k)$  为隐层神经元第  $k$  次的加权单位时间进、出 AFC 输入向量;  $\omega^1$  为输入层与隐层的权向量;  $v(k-1)$  为隐层神经元第  $k-1$  次的加权输入值;  $net(k)$  为隐层神经元第  $k$  次的净输入;  $net(k-1)$  为隐层神经元第  $k-1$  次的净输入;  $f$  为动态神经元的激活函数;  $k_1$ 、 $k_2$ 、 $k_3$  为隐含层动态神经元的自适应参数;  $z(k)$  为隐层神经元第  $k$  次的输出。

改进的 NARX 神经网络输出层输出向量  $y(k)$ ：

$$y(k) = \sum \omega^2 \cdot z(k) + \beta \quad (13)$$

式中:  $\omega^2$  隐层神经元与输出神经元的权向量;  $\beta$  为输出神经元的阈值。

NARX 神经网络采用较多的 BPTT (Backpropagation Through Time) 等典型算法, 存在不能在线运算、计算复杂和效率低等不足<sup>[13-16]</sup>。因此本文的 NARX 神经网络权值调整采用 RTRL (Real-Time Recurrent Learning) 算法<sup>[17]</sup>, 如下所示：

- 1) 通过 NARX 过滤器计算输出  $y(k)$ ；
- 2) 建立输出  $y(k)$ 、 $y(k-1)$  与权值的微分方程适应误差平方和函数；
- 3) 通过  $d_{y(k)}$  各项的变化判断权重的最大影响项, 即网络延时输入向量；
- 4) 当系统开放时, 计算对权重影响最大的项, 其余项为零, 进行权值更新。

$$\frac{\partial y(k)}{\partial \omega^2} = z(k) \quad (14)$$

$$\frac{\partial y(k)}{\partial k_1} = dz(k) \cdot v(k) \quad (15)$$

$$\frac{\partial y(k)}{\partial k_2} = dz(k) \cdot net(k-1) \quad (16)$$

$$\frac{\partial y(k)}{\partial k_3} = dz(k) \cdot v(k-1) \quad (17)$$

$$\frac{\partial y(k)}{\partial \omega^1} = \omega^2 \cdot dz(k) \cdot \frac{dnet(k)}{dv(k)} \cdot x(k) \quad (18)$$

$$\text{式中: } \frac{dnet(k)}{dv(k)} = k_1(k) + k_2(k) \cdot \frac{dnet(k-1)}{dv(k-1)} \quad (19)$$


学习速率的调整方法表示为：

$$\eta(n) = \begin{cases} \gamma\eta(n-1) & e(n) < e(n-1) \\ \alpha\eta(n-1) & e(n) > e(n-1) \end{cases} \quad (20)$$

式中:  $\eta$  为学习速率,  $e$  为学习误差;  $\gamma > 1$ ,  $\alpha < 1$ 。

### 3 实例分析

本文基于上海地铁九号线松江大学城车站 2017-11-06 至 2017-11-12 历史数据, 对车站工作日每五分钟的平均进、出站客流量及非工作日每五分钟的平均进、出站客流量分别进行了分析。6:30:00-18:30:00 时段每五分钟进站 AFC 数据及 6:30:30-18:30:30 时段每五分钟出站 AFC 数据曲线图如图 6 所示。






图 6 客流量曲线图

从图 6 中可看出工作日与非工作日的平均进、出站客流量变化趋势无明显差别,非工作日平峰时间段内的平均进站客流略高于工作日平峰时间段内的平均进站客流。

松江大学城地铁站布局图如图 7 所示,闸机 1、2 为进站闸机,闸机 3、4 为出站闸机。选楼扶梯 1 等候区进行进出客流参数分析,通过皮尔逊相关分析得到如表 3 所示。由表 3 可知闸机 1、2 进站 AFC 数据与楼扶梯 1 等候区客流密度相关系数为 0.93、0.9,通过时间相关系数为 0.89、0.86,呈显著相关,选取闸机 1、2 为楼扶梯 1 的相关进站闸机;闸机 4 出站 AFC 数据与楼扶梯 1 等候区客流密度、通过时间的相关系数为 0.85、0.81,选取闸机 4 为楼扶梯 1 的相关出站闸机。

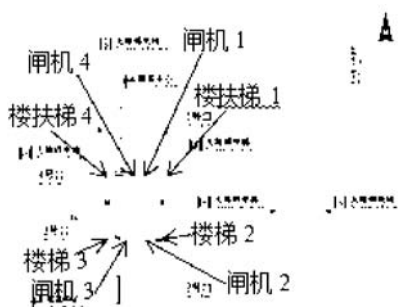


图 7 上海地铁九号线松江大学城地铁站布局

表 3 皮尔逊相关性分析

客流参数		闸机编号			
		闸机 1	闸机 2	闸机 3	闸机 4
Pearson 系数(进)	客流密度	0.93	0.90	0.0	0.0
	通过时间	0.89	0.86	0.0	0.0
Pearson 系数(出)	客流密度	0.0	0.0	0.26	0.85
	通过时间	0.0	0.0	0.18	0.81

## 4 模型应用的仿真分析

基于相关闸机 AFC 数据预测楼扶梯等候区的客流密度及客流通过时间,选取每分钟内相关闸机的 AFC 数据作为输入,以视频采集的楼扶梯等候区的客流密度与客流通过时间为输出,建立改进的 NARX 神经网络,改进的 NARX 神经网络只需要确定隐含层神经元数目。输出采用一阶延时,本文通过专家经验及试凑法确定了隐含层神经元个数为 8,采用权值自适应调整算法进行训练。为验证改进的 NARX 神经网络在运算速度及准确率等方面的效果,随机选取 500、250、50、25 个样本模型进行训练<sup>[18]</sup>,通过 BP 神经网络做对比实验。本文通过 Matlab8.4 进行了模型的创建、训练及仿真测试,在多次实验后,模型准确率变化如图 8 所示,表明模型已符合要求。

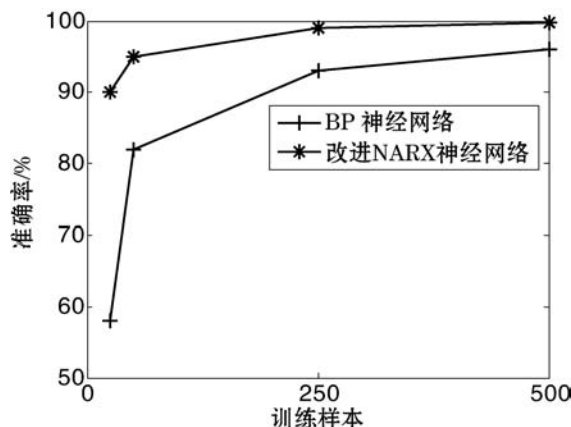



图 8 改进的 NARX 神经网络与 BP 神经网络的比较

### 4.1 楼扶梯等候区进站客流参数预测

选取周五 7:00 - 9:00 时段采集楼扶梯 1 等候区进站客流每分钟的客流参数并分析对应时段的相关进站闸机的每分钟 AFC 数据,用于神经网络测试。进站测试样本的实际值与改进 NARX 神经网络的预测值如图 9 所示。






图9 进站测试数据实际值与预测值

由图9可知楼扶梯1等候区进站客流密度、通过时间在7:00-9:00早高峰期间较大,高峰期间进站客流密度最大值接近4人/m<sup>2</sup>,通过时间最大为30s,根据表2判断客流处于一般状态。

### 4.2 楼扶梯等候区出站客流参数预测

选取周五7:00-9:00时段采集楼扶梯1等候区出站客流每分钟的客流参数的采集并分析对应时段相关出站闸机的每分钟AFC数据,用于神经网络测试。出站测试样本的实际输出与改进NARX神经网络的预测输出如图10所示。

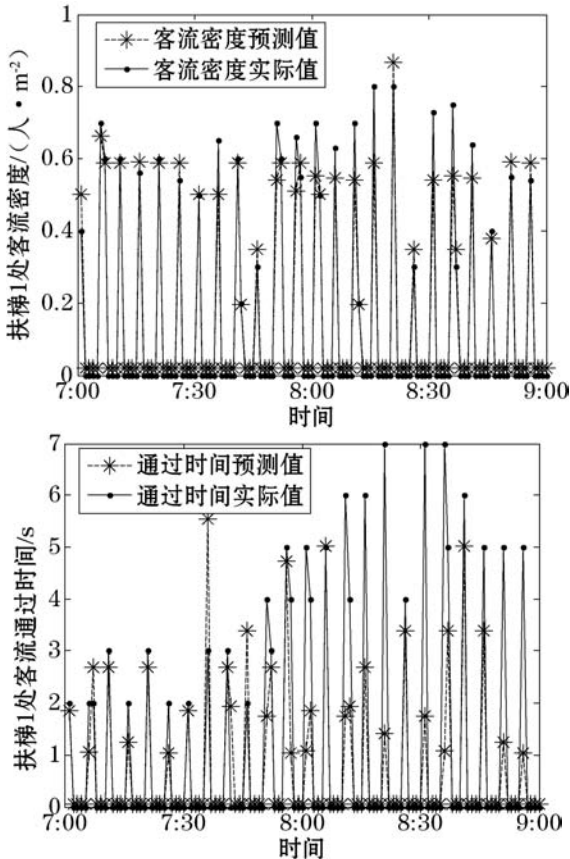


图10 出站测试数据实际值与预测值

由图10可知,楼扶梯1等候区出站客流密度、通

过时间在7:00-9:00时段较小,出站客流密度峰值不超过1人/m<sup>2</sup>,通过时间最大值不超过8s,由表2判断客流状态为安全状态。

### 4.3 楼扶梯等候区客流参数预测

对进出站方向的客流参数进行综合预测,将进出站方向的楼扶梯等候区预测客流密度按式(3)进行计算,进出站方向的楼扶梯等候区预测客流通过时间按式(6)进行计算,并与实际的楼扶梯等候区客流密度、通过时间进行对比,如图11所示。

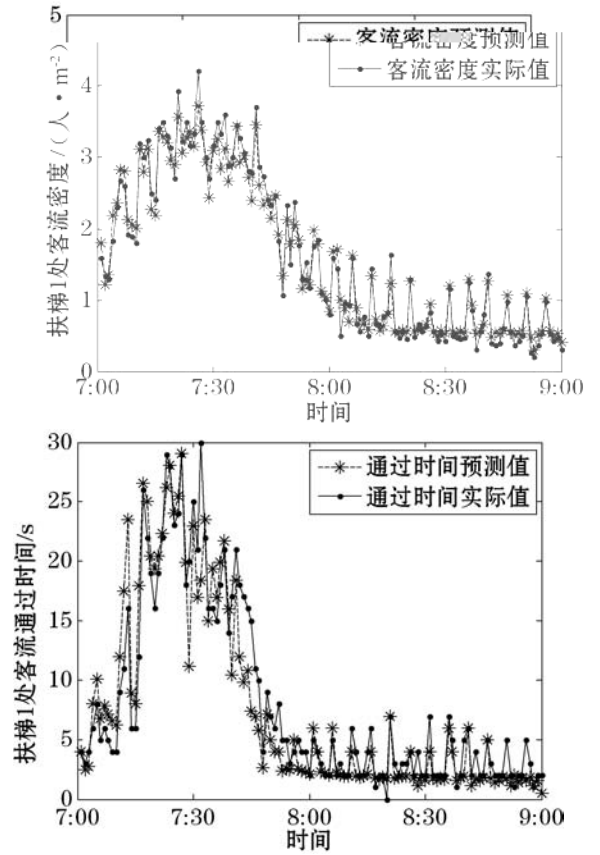


图11 测试数据实际值与预测值

由图11可知楼扶梯1等候区的客流密度及通过时间在7:00-9:00时段较大,7:10左右楼扶梯等候区密度达到3人/m<sup>2</sup>,此时地铁站运营管理人员可预先采取措施应对客流高峰,7:30左右客流密度超过4人/m<sup>2</sup>,峰值达到4.5人/m<sup>2</sup>,通过时间最大值为30s,由表2判断客流处于危险状态。

### 4.4 误差分析

本文采用均方误差MSE与平均绝对百分误差MAPE来评价神经网络的预测效果:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y}_i)^2 \quad (21)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \bar{y}_i}{y_i} \right| \times 100\% \quad (22)$$

式中: $y_i$ 为客流参数期望值, $\bar{y}_i$ 为客流参数预测值, $n$ 预测样本数。

为进一步说明改进的 NARX 神经网络的预测效果,本文采用 BP 神经网络进行对比预测分析。楼扶梯 1 等候区客流参数的性能评价结果如表 4、表 5 所示。

表 4 不同模型下客流密度的误差分析

模型	指标			
	训练 MSE	测试 MSE	训练 MAPE	测试 MAPE
改进 NARX	0.09	0.14	6.63%	13.58%
BP	0.16	0.49	14.85%	20.45%

表 5 不同模型下通过时间的误差分析

模型	指标			
	训练 MSE	测试 MSE	训练 MAPE	测试 MAPE
改进 NARX	8.56	12.34	5.26%	10.12%
BP	18.44	36.83	12.54%	19.71%

由表 4 可知,改进后 NARX 神经网络的客流密度训练 MSE、测试 MSE 为 0.09、0.14,小于 BP 神经网络的 MSE;改进后 NARX 神经网络的客流密度训练 MAPE、测试 MAPE 分别为 6.63%、13.58%,小于 BP 神经网络的 MAPE。改进后 NARX 神经网络的客流通过时间训练 MSE、测试 MSE 分别为 8.56、12.34,训练 MAPE、测试 MAPE 分别为 5.26%、10.12%,均小于 BP 神经网络的 MSE 和 MAPE。综合客流密度及通过时间两个客流参数来看,改进后 NARX 精度高于 BP 神经网络,对地铁站楼扶梯等候区的客流参数预测更为准确。

## 5 结语

基于 AFC 数据与楼扶梯等候区客流参数之间的关系,通过改进的 NARX 神经网络预测楼扶梯等候区的客流密度及客流通过时间,相比 BP 静态神经网络具有更高准确性。仿真结果表明,该神经网络对于楼扶梯等候区客流参数具有较好的预测结果,并可通过客流状态评价标准对楼扶梯等候区的客流状态进行判定,相比人工判断具有更高的准确性及超前性,精度高,运行速度快,能适用于大样本判别及计算机实时处理的要求,为车站运营管理人员实时判断楼扶梯等候区客流状态提供决策依据。本文仅针对楼扶梯等候区客流参数及客流状态进行了研究分析,对于站台候车区等其他拥堵点的客流参数预测及客流状态判定有待进一步研究论证。

## 参 考 文 献

- [1] 中国城市轨道交通协会. 城市轨道交通 2016 年度统计和分析报告[J]. 城市轨道交通, 2017(2).
- [2] Hoogendoorn S P, Daamen W. Pedestrian behavior at bottlenecks[J]. Transportation Science, 2005, 39(2):147-159.
- [3] Helbing D, Buzna L, Johansson A, et al. Self-organized pedestrian crowd dynamics: experiments, simulations, and design solutions[J]. Transportation Science, 2005, 39(1):1-24.
- [4] 蔡昌俊, 姚恩建, 张永生, 等. 基于 AFC 数据的城轨站间客流量分布预测[J]. 中国铁道科学. 2015, 36(1):126-132.
- [5] 李俊辉, 黎新华, 谢小星. 基于概率神经网络的轨道交通车站客流安全状态评价[J]. 都市快轨交通, 2015, 28(4):65-69.
- [6] 付婷. 城市轨道交通车站集散能力瓶颈识别[D]. 北京:北京交通大学, 2014.
- [7] 李颖宏, 郝晓青. 综合交通枢纽客流状态智能分析[J]. 智能系统学报, 2014, 9(6):677-684.
- [8] 毕艳翔, 蒋顺章. 城市轨道交通车站站台空间服务水平指标体系探讨[J]. 城市轨道交通研究, 2013, 16(10):7-10.
- [9] 刘虎. 基于特征约束的四边形网格划分算法研究与实现[D]. 南京:南京航空航天大学, 2007.
- [10] 贺杰. 城市轨道交通车站客流拥堵等级评价模型研究[D]. 北京:北京交通大学, 2014.
- [11] 田健, 蒲琪, 陈小丽. 基于层次分析法模糊综合评价大客流安全状态[J]. 城市轨道交通研究, 2014, 17(1):47-50.
- [12] 李明, 杨汉生. 一利改进的 NARX 回归神经网络[J]. 电气自动化, 2006, 8(4):6-11.
- [13] 刘亚秋, 马广富, 石忠. NARX 网络在自适应逆控制动态系统辨识中的应用[J]. 哈尔滨工业大学学报, 2005, 37(2):173-176.
- [14] Kumar P, Merchant S N, Desai U B. Improving performance in pulse radar detection using Bayesian regularization for neural network training [J]. Digital Signal Processing, 2004, 14(5):438-448.
- [15] Hirschen K, Schäfer M. Bayesian regularization neural networks for optimizing fluid flow processes [J]. Computer Methods in Applied Mechanics & Engineering, 2006, 195(7):481-500.
- [16] 王晓晔, 王正欧. 正则化训练的神经网络与粗集理论相结合的股票时间序列数据挖掘技术[J]. 电子与信息学报, 2004, 26(4):625-631.
- [17] Plett G L. Adaptive inverse control of linear and nonlinear systems using dynamic neural networks. [J]. IEEE Transactions on Neural Networks, 2003, 14(2):360-376.
- [18] 温惠英, 罗钧, 李俊辉. 基于 PNN 的山区高速公路路段安全状态评价[J]. 华南理工大学学报(自然科学版), 2011, 39(8):113-117.