

# 基于公路通行数据的节假日山地景区 运力适配方法

闫晟煜<sup>1</sup>, 温福华<sup>1</sup>, 武瑾<sup>1</sup>, 郑毅<sup>2</sup>, 郝时杰<sup>1</sup>, 尤文博<sup>1</sup>

(1. 长安大学汽车学院, 西安 710018; 2. 云南省交通投资建设集团有限公司大数据资源开发中心, 昆明 650032)

**摘要:** 为确定节假日期间山地景区承运旅客所需的运力水平, 提出了基于短时客流预测的景区运力适配方法。基于公路通行数据, 将车流量换算为客流量, 建立用于短时客流预测的 CNN-LSTM 混合模型; 运用高斯函数拟合客流预测的离散数据, 采用广度搜索算法, 得到适配客流曲线的发车班次; 确定山地景区车辆运营的合理约束条件, 结合发车班次、客车核载人数、单程行驶时间等关键参数, 运用逆差函数构建运力适配模型; 选取金丝峡景区进行模型验证与实例分析。结果表明: CNN-LSTM 混合模型可有效预测山地景区短时客流量, 在 15 min 的时间粒度下, 模型的  $R^2$  可达到 0.92; 运力适配模型相较于传统“客满即走”的调度模式, 运力需求从 57 辆降至 28 辆, 有效降低了车队规模。研究可用于山地景区客流短时预测和节假日景区运力需求的精确测算。

**关键词:** 交通工程; 收费数据; 景区运力适配; 短时客流预测; 循环神经网络; 广度搜索算法  
**中图分类号:** U492.2 **文献标志码:** A **文章编号:** 1671-5497(2025)05-1576-12

**DOI:** 10.13229/j.cnki.jdxbgxb.20240692

## Algorithm for adapting transportation capacity of mountainous scenic areas in festival based on highway traffic data

YAN Sheng-yu<sup>1</sup>, WEN Fu-hua<sup>1</sup>, WU Jin<sup>1</sup>, ZHENG Yi<sup>2</sup>, HAO Shi-jie<sup>1</sup>, YOU Wen-bo<sup>1</sup>

(1. School of Automobile, Chang'an University, Xi'an 710018, China; 2. Development of Big Data Resource, Yunnan Communications Investment & Construction Group Co., Ltd., Kunming 650032, China)

**Abstract:** To determine the transport capacity by mountain scenic spots to carry tourists during holidays, an adaptation method of scenic spot transport capacity based on short-term passenger flow forecast was proposed. Based on highway traffic data, the traffic flow was converted into passenger flow, and a CNN-LSTM hybrid model for short-term passenger flow prediction was proposed; Gaussian function was used

收稿日期: 2024-06-21.

基金项目: 国家重点研发计划项目(2023YFB3209803); 长安大学中央高校基本科研业务费专项资金项目(300102224206); 陕西省教育厅科学研究计划项目(23JK0335); 陕西省重点研发计划项目(2025CY-YBXM-064).

作者简介: 闫晟煜(1987-), 男, 副教授, 博士. 研究方向: 公路运输规划, 智慧交通工程. E-mail: Leo9574@163.com

通信作者: 郑毅(1978-), 男, 高级工程师, 硕士. 研究方向: 交通大数据分析, 人工智能算法.

E-mail: 11403297@qq.com

to fit the discrete data of passenger flow forecast, and breadth-first search algorithm was used to obtain the departure frequency that fitted the passenger flow curve; The paper determined the reasonable constraint conditions of vehicle operation in mountain scenic spots, considering the key parameters such as departure frequency, the number of passengers carrying capacity and traveling time of the trip, a capacity adaptation model by deficit function was proposed. Taking Jinsixia scenic area as a case study, the models proposed were verified. The results show that the CNN-LSTM hybrid model can effectively predict the short-term passenger flow in mountain scenic spots, and the  $R^2$  of the model can reach 0.92 at the time granularity of 15 min. Compared with the traditional "full-passenger-ready-to-go" scheduling mode, the capacity adaptation model reduces the capacity demand from 57 to 28, effectively reducing the fleet supply. The research will be beneficial for short-term prediction of passenger flow in mountain scenic spots and accurate calculation of transportation capacity demand in holidays.

**Key words:** traffic engineering; toll collection data; adaptation of transportation capacity for scenic area; short-time passenger flow forecast; recurrent neural network; breadth-first search algorithm

## 0 引言

2012年8月国务院发布了《重大节假日免收小型客车通行费实施方案》,惠及了旅客在节假日的出行。受客流出行频次增加和政策驱动的影响,景区的客流大幅增加,远超出景区的服务能力<sup>[1]</sup>。景区短时客流量预测愈发受到重视,景区纷纷根据区位特点和数据优势作出预测,常用的数据源有历史票务数据、手机信令、断面交通量、网络搜索数据等,以作出相应的服务准备和客流错峰动态调整。

景区通过线上、线下售票等多种渠道获取客流,但仍以线下售票为主。线下售票是游客到达后购置的,先导性不强,重大节假日的客流量难以通过历史售票数据准确预测。公路通行数据包括高速公路联网收费数据(Toll collection data, TCD)、国道省道交通量观测数据,收费站和交通量观测站是进入景区前的关键数据载体,多设置在景区入口前5~20 km,可提前感知景区客流量,给予景区充裕的准备时间。高速公路TCD<sup>[2]</sup>记录了每辆车的通行信息,包括通行时间、起讫点、车型等信息,通行时间精确到秒级,可用于客流量短时预测。

梳理景区客流预测方法文献,研究关注点呈现数据源不断丰富、时间粒度不断细化的趋势,预测模型也由单一模型向复合模型转变<sup>[3]</sup>。数据源是决定时间粒度及模型精度的根本,研究人员<sup>[4,5]</sup>利用旅游局发布数据和百度搜索指数预测年度客流量。目前,景区对每日客流预测主要利用网络搜索、历史客流等数据<sup>[6]</sup>建立的时间序列数据进

行预测。为提高预测精度<sup>[7]</sup>,一些学者还利用每日天气<sup>[8]</sup>、景区附近酒店预订情况<sup>[9]</sup>等数据来预测,受搜索引擎用户行为和天气不确定性的影响,预测结果精度有限。在预测模型运用方面,鉴于景区客流到达规律复杂,现阶段多使用组合模型以提高预测精度,采用ARIMA<sup>[10]</sup>、BP神经网络、GMDH算法、STL分解算法、注意力机制、双向长短期记忆模型<sup>[11]</sup>(Bi-LSTM)等技术构建组合模型预测客流量,研究表明:组合模型的预测精度优于单一模型。

景区车辆运行环境相对封闭与单一,适配客流量时应考虑调度发车间隔,短时预测客流是确定发车间隔的基础。已有研究多以优化车队规模为目标,而城市客车运行调度是以发车间隔、乘客拥挤度、乘客时间成本为多目标进行优化<sup>[12]</sup>。典型研究包括:Ceder等<sup>[13]</sup>最早采用逆差函数以确定车队调度规模;刘涛等<sup>[14]</sup>发现插入空驶车次能有效减少机场预约专线公交车队规模的规律;闫晟煜等<sup>[15]</sup>解决了封闭式景区在应对高峰客流的运力需求算法;还有文献<sup>[16,17]</sup>采用遗传算法、BP神经网络来调整发车间隔的方法,建立快速公交动态组合调度模型。

现有研究中,鲜见利用公路通行数据实现预测景区短时客流量的研究<sup>[18]</sup>,尚未有利用短时客流预测结果研究景区运力配置的文献。公路通行数据对景区客流量预测具有先导性,本文将挖掘高速公路TCD与景区客流的关联性,建立适用于景区短时客流预测的模型,根据预测得到的短时客流信息确定景区接驳车辆的车队规模及调度方

案,开展短时客流预测信息在旅游交通领域的运用分析。

## 1 景区客流短时预测

### 1.1 数据基础

客流淡季期间,景区利用自备运力,采用固定发车间隔滚动发车的调度模式可满足接驳客流的需求;重大节假日期间,景区会增加车队规模以应

对短时客流大幅提升的状况,为确定景区针对不同客流水平的最小车队规模,利用景区附近高速公路收费站的收费数据和国省道交通观测站的通行数据对客流到达的规模和趋势进行短时预测。客流预测时区分上行、下行,结合车型、线路长度、车辆核载人数等参数测算车队规模,满足实时预测和动态调度的要求。研究对象为封闭式景区,对旅客的接驳情景如图 1 所示。




图 1 封闭景区客流接驳场景

Fig. 1 Passenger flow connection scene of the closed scenic area

客车到达景区会到达距离景区最近的收费站驶下高速公路,即客车会采取全程高速公路或全程国省道 2 种方式,用于景区客流短时预测的公路通行数据主要字段说明如表 1 所示。多数山地景区远离城市,公路交通是旅客到达景区的首选方式。客流量由车流量乘以重大节假日的每车平均载客人数测算,各车型的每车平均载客人数可通过调查获得,可表示为:

$$p_r = \sum_{w=1}^W \sum_{k=1}^4 q_{wk}^e c_k^e + \sum_{b=1}^B \sum_{k=1}^4 q_{bk}^h c_k^h \quad (1)$$

式中: $r$ 为通行时段; $p_r$ 为 $r$ 时段的客流量; $W$ 为临近

景区的收费站数; $B$ 为临近景区的国省道观测站数; $k$ 为车型; $c_k^e, c_k^h$ 分别为高速公路、国省道 $k$ 型客车的重大节假日每车平均载客人数; $q_{rk}^e, q_{rk}^h$ 分别为高速公路、国省道 $r$ 时段 $k$ 车型的到达车流量。

### 1.2 客流短时预测模型

运用 CNN 提取时间序列数据局部特征<sup>[19]</sup>,运用 LSTM 模型<sup>[20]</sup>预测时间序列数据,搭建 CNN-LSTM<sup>[21]</sup>模型,模型结构如图 2 所示。此模型由输入层、卷积层、池化层、LSTM 层和输出层组成,以单一变量的时间序列作为输入值,进行单步预测并将客流量作为输出值。

表 1 公路通行数据主要字段说明

Table 1 Main field description of highway traffic data

数据类型	字段名称	字符类型	字段说明	字段用途
	入口站代码	Varchar	每个收费站对应的唯一数字 ID	精确定位客车驶入或驶出收费站位置及所属的高速公路编号
	出口站代码	Varchar		
高速公路收费数据	入口时间	Datetime	车辆驶入或驶出收费站的时间,精确到秒级	精准确定客车驶入或驶出收费站的时间,可计算全程平均速度
	出口时间	Datetime		
	车型	Varchar	核定载客人数范围划分为 I、II、III、IV 型	区分客车车型,可分车型计算高速公路客流量
	车牌号	Varchar	数据中识别车辆的唯一标识	追踪行驶轨迹,确定客流来源,标记 III、IV 客车
国省道交通量观测数据	观测时间段	Datetime	可将观测时间段缩小到短时预测级别	可按每分钟统计国省道分车型车流量
	车型	Varchar	分为小型客车(I、II型)、大型客车(III、IV型)	区分客车车型,可分车型计算国道、省道客流量
	车流量计数	Int	记录短时时段内各车型车流量	用于推算各车型客流量
	行驶方向	Varchar	标记车辆单向行驶方向	区分客车上行、下行方向

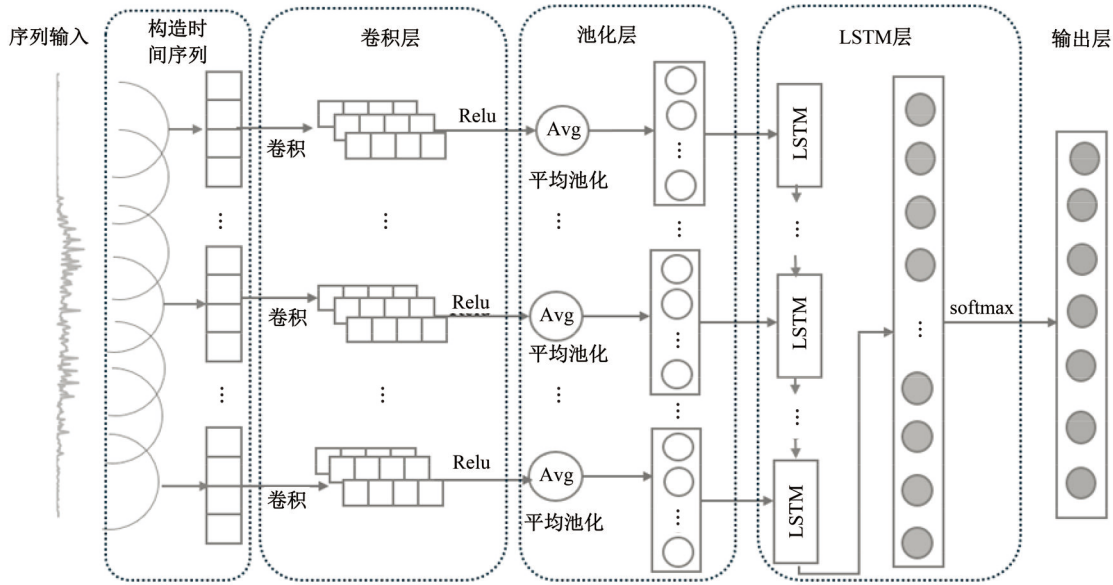


图 2 CNN-LSTM 混合模型结构

Fig. 2 Structure of CNN-LSTM hybrid model

1. 2. 1 构建客流序列

删除重复数据,剔除当地通勤车辆,根据景区历史客流量评估所需时间粒度,根据出口站编号、车型、出口时间 3 个关键字段,统计出各型客车在每个时段内的到达车流量;根据各车型的乘坐情况,将交通流换算为客流序列。通过实地调研五台山、金丝峡等 5A 级山地旅游景区 6 个,获得各车型节假日每车平均载客系数(见表 2)。

非节假日出行的 I 类客车每车平均载客系数为 2.39 人/辆次,而节假日出行的 I 类客车每车平均载客系数为 3.01 人/辆次,表明节假日出行时出现“集中乘车”的特征。

1. 2. 2 数据标准化

数据归一化可提高模型的收敛速度和鲁棒性,避免梯度陡然增加与消失,降低模型计算资源的需求。运用 Min-Max 方法<sup>[22]</sup>对客流序列数据  $x$  进行线性变换,将数据统一映射到  $[0, 1]$  上,方

表 2 节假日出行的座位数分布与每车平均载客数

Table 2 Distribution of seats capacity and average passenger in cube for holiday travel

客车 车型	核定载客数/人	平均座位 数/座	假期平均乘坐 人数/人	样本 量/个
I 类	9 座及以下	5.22	3.01	466
II 类	8~19 座	12.25	9.20	69
III 类	20~39 座	35.32	29.71	85
IV 类	40 座及以上	50.97	42.32	76

法为:

$$x' = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (2)$$

式中: $x$  为样本数据; $x'$  为标准化值; $\min(x)$  为样本最小值; $\max(x)$  为样本最大值。

1. 2. 3 构建时间窗口序列

为适配 LSTM 循环神经网络的训练,构建滑动窗口,将单一变量的时间序列划分成多个样本,使模型更好地学习数据的特征,提高模型泛化能力,其构造和模型输出  $X$  为:

$$X = \begin{pmatrix} x'_1 & x'_2 & \cdots & x'_l \\ x'_2 & x'_3 & \cdots & x'_{l+1} \\ \vdots & \vdots & \vdots & \vdots \\ x'_{n-l+1} & x'_{n-l+2} & \cdots & x'_n \end{pmatrix} \quad (3)$$

$$P = (p_{l+1}, p_{l+2}, \dots, p_{n+1}) \quad (4)$$

式中: $l$  为滑动窗口的长度; $n$  为输入样本总量; $P$  为预测客流量输出序列。

1. 2. 4 预测效果评价指标

为评价模型预测性能,运用均方根误差 RMSE 评价同一时间粒度重采样下不同模型的预测精度,运用  $R^2$  评价不同时间粒度重采样下同一模型的预测性能。RMSE 越小,则模型预测精度越高; $R^2$  越接近于 1,则模型精度越高<sup>[23]</sup>。计算方法为:

$$RMSE = \sqrt{\frac{1}{n-l} \sum_{i=l+1}^n (p_{ti} - p_{pi})^2} \quad (5)$$

$$R^2 = 1 - \frac{\sum_{i=l+1}^n (p_{ii} - p_{pi})^2}{\sum_{i=l+1}^n (p_{ii} - \bar{p})^2} \quad (6)$$

式中： $p_{ii}$  为客流量真实值； $p_{pi}$  为客流量预测值； $\bar{p}$  为客流量真实值的均值。

## 2 景区运力适配模型

### 2.1 模型建立

景区运力适配需提前计算发车时刻表和车次链,客流短时预测是发车时刻表和车次链的计算基础。节假日内景区应对大客流量时,常会面临 2 种选择:增加车数或加密发车频次,二者均会增加运营成本,通常是加密发车频次仍无法适配客流量时,才增加车数,应寻求最小车辆数测算方法,本文暂不考虑车辆维修养护成本的差异性。

逆差函数(Deficit function, DF)是一种阶跃函数,可直观地给出系统所需的最小车数<sup>[24]</sup>。将景区接驳车辆的调度简化为单场站系统,有 2 个假设:

(1)所有车辆均能正常运营,不存在景区内发生交通拥堵和交通事故等情况;

(2)车辆中途不停车,每辆车辆运行时间固定且核载人数一致。

考虑假设,提出基于车次链匹配的网络最大流规划模型为:

$$\min N = \sum \max DF(k, t) \quad t \in [T_1, T_2] \quad (7)$$

s. t.

$$\int_{i-1}^i f_u(t) dt = C \quad (8)$$

$$\int_{j-1}^j f_d(t) dt = C \quad (9)$$

$$a_{vij} \in \{0, 1\} \quad (10)$$

$$\sum_{v=1}^N \sum_{i=1}^n \sum_{j=1}^m a_{vij} = m + n \quad (11)$$

$$a_i + T < a_j < a_{i+1} \quad (12)$$

$$a_j + T < a_i < a_{j+1} \quad (13)$$

式中： $N$  为所需车辆数； $DF(k, t)$  为执行  $k$  场站所有车次链计划的最小客车数； $T_1$  为运营起始时间； $T_2$  为运营结束时间； $i$  为上行时段； $j$  为下行时段； $f_u(t)$  为上行客流拟合函数； $f_d(t)$  为下行客流拟合函数； $C$  为车辆核载乘客数； $a_i$  为起点站时刻为  $i$  的车次； $a_j$  为终点站时刻为  $j$  的车次； $v$  为车次链编号； $T$  为车辆完成 1 个车次链所需的时间； $a_{vij}$  为车辆  $v$  执行车次  $i$  和车次  $j$  的布尔值； $m, n$  分别

为起点站、终点站的车次总数。

景区内各个景点的上下车人数未知,本文研究单场站调度优化,仅包括起点站和终点站的调度优化。式(11)约束了所有车次都应被执行。式(12)与(13)为插入空驶车次的逻辑条件:当车辆在本场站执行下一个车次的发车时刻晚于另一场站的下一个待发车次,且车辆返回时能执行该待发车次,则车辆空驶返回且执行该待发车次。

### 2.2 模型求解

模型最优解求解过程分为 2 个阶段。

第 1 阶段为短时客流预测阶段。为确定发车班次,拟合短时预测客流数据,根据拟合函数分配发车班次。对解析式的求解为单层查找过程,运用广度优先算法(Breadth-first search, BFS)求解发车间隔与发车时刻,创建可行的解集  $Q$ ,将式(12)(13)作为判断可行解的逻辑条件,对满足条件的有效解加入发车时刻表集合  $M$ ,求解算法如图 3 所示。

第 2 阶段为基于  $M$  寻优车次链以确定最小车队规模。采用插入空驶车次以减小车队规模的方法,使  $M$  成为非固定解集数量的集合。对于此类集合,类似于遗传算法<sup>[25]</sup>、粒子群算法<sup>[26]</sup>等用于求解固定解集数量的寻优算法对该问题不适用,故而本文运用 BFS 算法求解。为保证车次链衔接的逻辑性,车次信息应加入起点和终点的信息,从时间和空间 2 个维度判断每个车次的可衔接

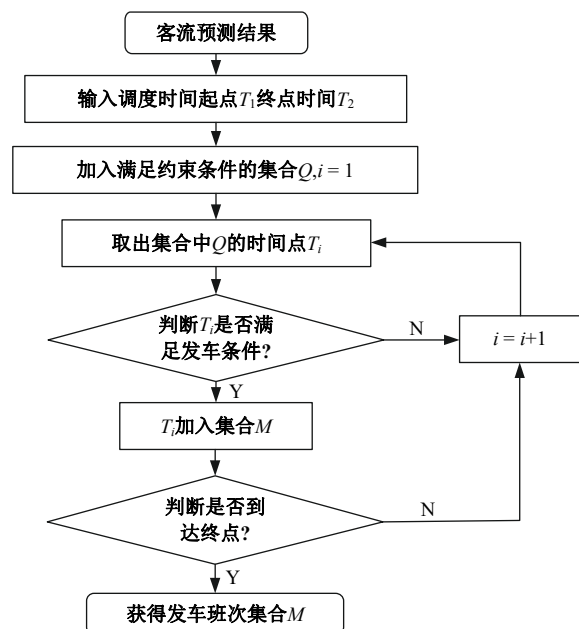


图 3 发车时刻表求解算法

Fig. 3 Algorithm for solving the departure schedule

性,为每辆车创建空集  $C_N$  来储存搜索到的车次链,求解流程如图 4 所示。

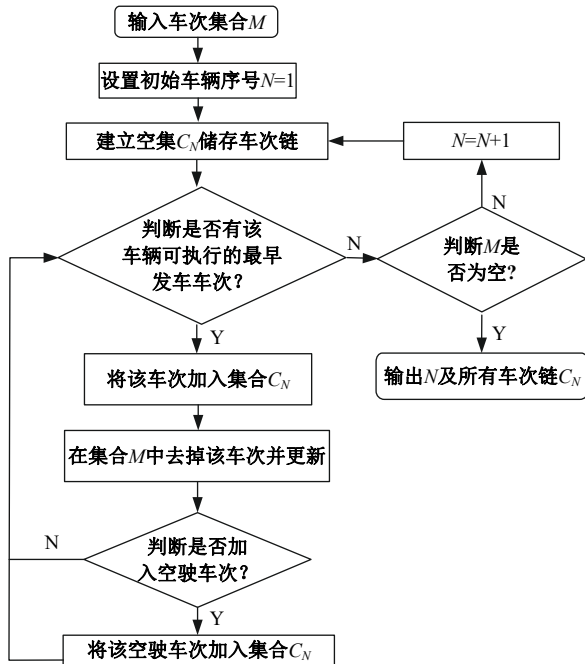


图 4 车次链求解算法

Fig. 4 Train chain for solving algorithm

### 3 模型验证与实例分析

陕西商洛金丝峡景区为 5A 级景区,毗邻陕高速 G40,主要承担西安、商洛、安康以及河南省、湖北省的客流。省道郭山路为东西走向,与沪陕高速 G40 并行。景区有 2 条旅客接驳专线:北游客中心停车场↔陆督门专线;陆督门↔栗园门停车场专线。本文以北游客中心停车场↔陆督门专线的运力适配为实例开展研究论证。景区周边的高速公路与国省道分布如图 5 所示。

提取景区 2019 年客车月度 TCD 和国省道交通量观测数据进行分析,景区车流每逢重大节假日均出现客流高峰,劳动节期间车流强度达到 5 000 辆/日,是日均车流量的 10 倍。景区的自备运力难以满足客流运输需求,需要合理预测短时客流量并对适配的车队规模做出调整。选取景区 2019 年劳动节期间 5 月 1~4 日客车 TCD,将通行时间粒度分割为 30 min,每日各时段车流量趋势相近,如图 6 所示。


#### 3.1 客流短时预测

将景区 5 月 1~3 日的客流序列作为训练集数据,5 月 4 日的客流序列作为测试集数据,全程采用单步预测方式。为比较单一模型预测的效果和

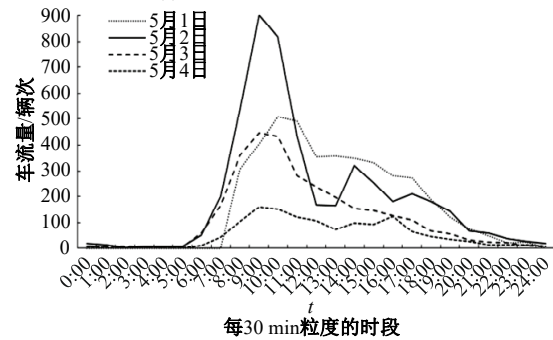


图 5 金丝峡景区路网布局

Fig. 5 Highway layout of Jinsixia Scenic Area



(a) 2019 年景区全年车流量变化



(b) 2019 年劳动节期间车流量变化

图 6 2019 年金丝峡景区车流量变化特征

Fig. 6 Characteristics of traffic flow changes in Jinsixia Scenic Area in 2019

组合模型对预测的有效性,对时间粒度为 5 min 的 1 152 条数据进行训练和测试,对模型结构和超参数进行调优,获得各模型的最佳预测效果,如图 7 所示。

CNN 模型表现出对客流波动性和非线性特征出色的捕捉能力,可预测客流大幅波动的部分,但由于预测结果与真实值在时间轴上错位,使模型预测结果偏差较大;LSTM 模型可出色地捕捉

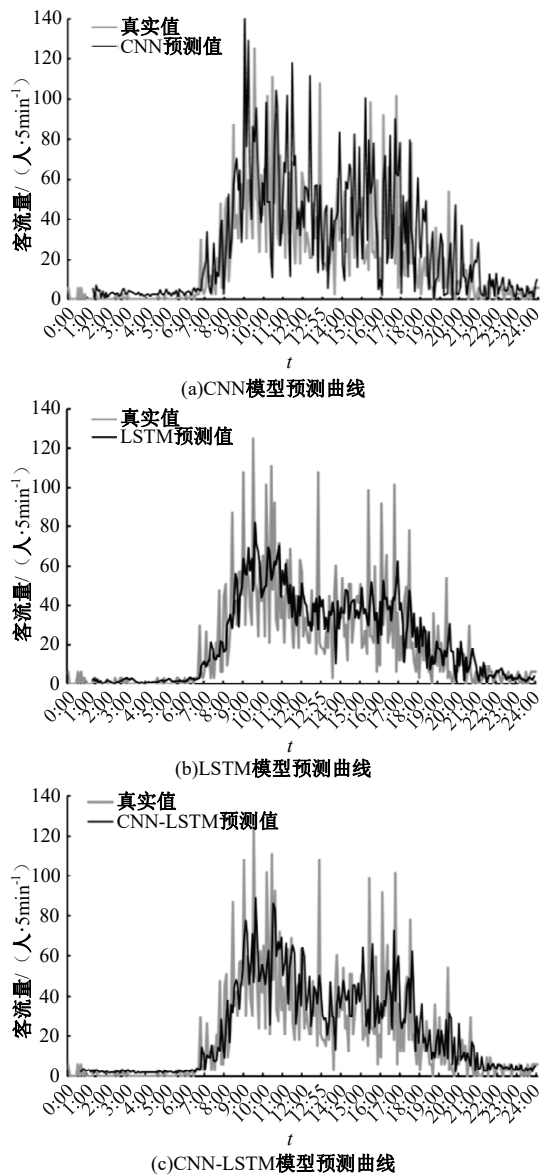


图 7 3 种模型预测效果对比图

Fig. 7 Comparison of prediction effects of the three models  
到客流序列在时序上的波动趋势,但对客流大幅波动的部分预测效果一般;CNN-LSTM 组合模型可有效发挥 2 种模型的优点,可有效预测客流序列的波动性和时序性。3 种模型预测精度和拟合效果如表 3 所示。

表 3 3 种模型预测效果对比

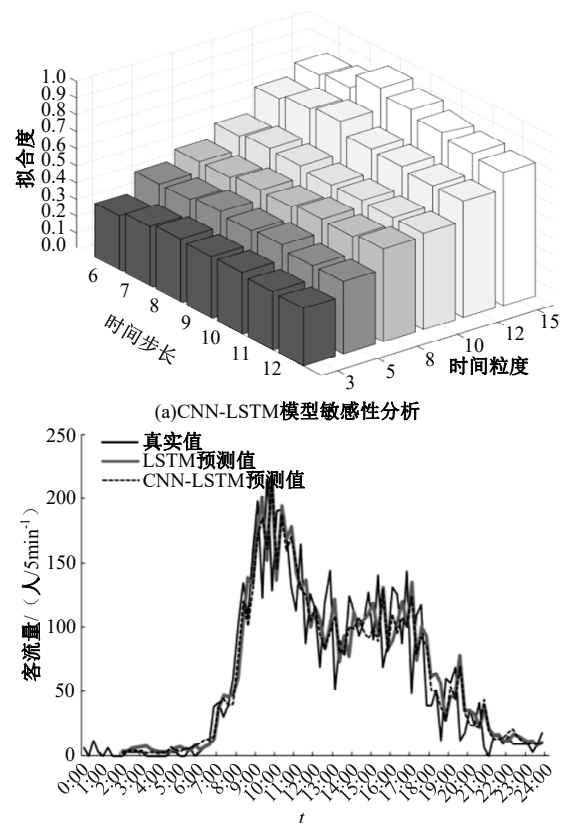
Table 3 Comparison of prediction effects of the three models

客流预测模型	预测效果评价指标	
	RMSE/%	$R^2$
CNN	34.64	0.14
LSTM	20.14	0.34
CNN-LSTM	18.86	0.46

CNN 模型对客流时序数据的预测效果最差, RMSE 最大,  $R^2$  最小; CNN-LSTM 模型较 LSTM 模型的 RMSE 降低了 6%,  $R^2$  提高了 35%, 有效提升了预测精度。

对于较小的时间粒度, 客流序列的波动性大且复杂度高, CNN-LSTM 模型的预测效果不佳, 对时间步长的变化也不敏感; 对于较大的时间粒度, 样本数据量会减少, 使深度学习模型增加过拟合的风险且降低了泛化能力, 还不利于景区做出精细化管理, 本文的时间粒度最大值为 15 min。将时间粒度划分为 3、5、8、10、12、15 min 的客流序列数据输入 CNN-LSTM 模型, 在不同滑动窗口长度  $l$  下, 对比分析 CNN-LSTM 模型预测效果, 结果如图 8 所示。

由图 8 可见, 随着时间采样粒度的增大, 客流到达数据波动性减小, 客流序列的线性特征逐渐清晰, CNN-LSTM 模型的  $R^2$  不断增大。在时间粒度为 15 min 且  $l=8$  时, CNN-LSTM 模型的  $R^2$  达到最大值的 92%, 预测效果对  $l$  的变化最为敏感,  $l=8$  时更能表现输入数据的局部特征, 预测



(a) CNN-LSTM 模型敏感性分析

(b) LSTM 与 CNN-LSTM 模型预测效果对比

图 8 CNN-LSTM 模型预测效果对比

Fig. 8 Comparison of prediction effect of CNN-LSTM model

曲线更贴近真实值,预测效果最好。模型的 RMSE、 $R^2$ 、程序运行时间如表 4 所示。

表 4 LSTM 与 CNN-LSTM 预测情况对比

Table 4 Comparison between LSTM and CNN-LSTM predictions

模型	RMSE/%	$R^2$	程序运行时间/s
LSTM	32.01	0.86	120
CNN-LSTM	29.12	0.92	146

### 3.2 运力适配测算

#### 3.2.1 客流曲线拟合与发车车次确定

选择预测效果最佳的 15 min 时间粒度,根据入口站、入口时间、车型 3 个字段,聚合数据得到 I~IV 型客车在各时段内的发送车流量,处理并输入模型后得到 5 月 4 日上下行客流的预测数据,如图 9 所示。

假设每 15 min 内的客流到达服从均匀分布,绘制每分钟的客流量散点图,运用二次高斯分布拟合游客到达和离开的规律,得到上行、下行旅客拟合曲线  $f_u(t)$ 、 $f_d(t)$ ,拟合优度分别达到 95.35% 和 93.08%,拟合函数经积分求解后分别与预测的上行、下行客流量相差 24 人、38 人。

#### 3.2.2 发车车次确定

根据上行、下行客流量拟合曲线,得到上下行发车时刻和间隔曲线(见图 10),其中上行客流共需要 129 个班次,下行客流共需要 124 个班次,最大发车间隔为 16 min,最小发车间隔为 2.7 min。在景区的 98 份专项调查问卷中,超过 93.4% 的旅客对 30 min 以内的候车时间表示可以接受,所有人都接受 20 min 以内的候车时间,可见所求发车班次能满足旅客所能接受的最大等待时间。


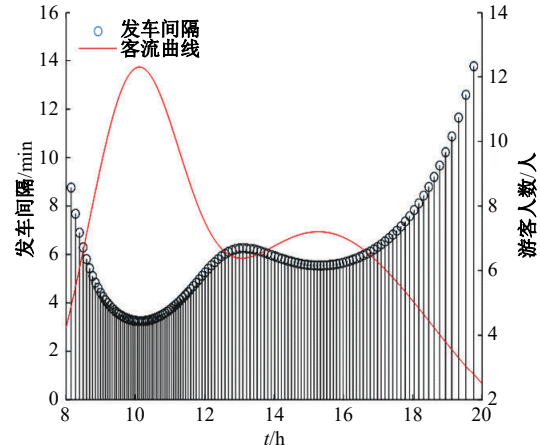
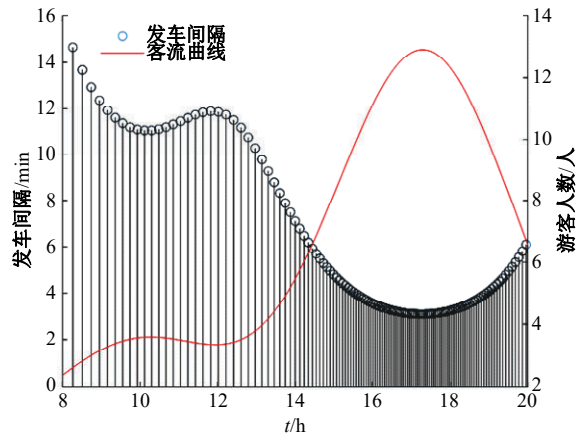


图 9 上下行客流量预测

Fig. 9 Forecast of the number of upstream and downstream passengers



(a)上行发车时刻与间隔



(b)下行发车时刻与间隔

图 10 上行与下行发车信息图

Fig. 10 Information diagram for bus departure of upstream and downstream

#### 3.2.3 车队规模求解与分析

由于上行客流集中在 10 时前后,下行客流集中在 18 时前后,这 2 个时段的高峰客流是决定车辆规模增加的关键因素。在未插入空驶车次时,共需要 57 辆车才能满足到达景区客流的运输需求;在本文调度模型下,共插入 55 个空驶车次,将车辆规模降低到 28 辆。

为清晰展现客车的车次链与执行时段,绘制车辆调度甘特图,如图 11 所示。

由图 11(a)可见,在客满即走调度方式下,上行和下行的高峰时段与平峰时段运力调度差异明显。当插入空驶车次后,图 11(b)中高峰时段车次链分布更为集中,起到了“削峰填谷”的效果,应对客流高峰时段的调度更合理。第 17~25 号车辆所需执行的车次链较短,且无须执行车次链的时段较为集中,产生了图 11(b)中方框内的空闲时段;而 1~16 号车辆执行的车次链时间较长且






图 11 不同调度模式下的车辆运行甘特图


Fig. 11 Gantt chart of vehicle operation under different scheduling modes

紧凑,休息时间呈碎片化分布,则可使 17~25 号车辆在 12~15 时的时段内,执行 1~16 号车辆对应时段的车次链,使被替代的车辆满足燃料补充、司机满足休息和进餐的需求。26~28 号 3 辆车仅执行了高峰时段的 1~2 个车次,可将这少部分的车辆作为应急车辆,应对客流预测失稳时段和应急事件的调度需求。

为展现调度优化后的运力适配效果,对比传统“客满即走”模式下的车队规模,绘制 2 种模式下的场站逆差函数,如图 12 和图 13 所示,可见,从起点、终点场站的逆差函数图来看,插入空驶车次使车辆规模变化浮动范围变小,车辆调度频次变高,有效避免了车辆在场站逗留,也使北游客中心停车场的最大车队规模(逆差函数最大值)由 54 辆降至 23 辆,使陆督门停车场的最大停驶车辆由 40 辆降至 9 辆,充分节约了参与调度的车辆数量。在景区开始运营时,北游客中心停车场应布




(a)北游客中心停车场




(b)陆督门停车场

图 12 客满即走模式下的场站逆差函数图

Fig. 12 Deficit function diagram of the station under full buses departing



(a)北游客中心停车场



(b)陆督门停车场

图 13 插入空驶车次模式下的场站逆差函数图

Fig. 13 Deficit function diagram of the station with empty trains inserted

设 24 辆车,陆督门停车场应布设 3 辆车即能满足上下行客流的调度需求。

### 4 结 论

(1) 基于公路通行数据和景区节假日各客车车型乘坐率调查,构建了用于景区客流短时预测的 CNN-LSTM 模型,其中 CNN 模型用于捕捉客流序列波动的局部特征,而 LSTM 模型用于把握客流序列的时序特征。经实例验证, CNN-LSTM 模型能够实现对节假日复杂非线性短时客流的有效预测。

(2) 本文提出的运力适配模型是对短时客流预测结果的综合运用,给出了基于公路通行数据的最佳时间粒度确定方法。研究发现,通过插入空驶车次能够有效降低景区的运力配置,且调度计划可根据 15 min 的短时客流预测结果做出动

态调整,可弥补以运营日为单位制订的行车计划表无法满足景区高峰时段的实时调度需求。

(3)本文基于公路通行数据开展免费节假日的客流短时预测,而对于收费公路,有免费节假日和不免费节假日之分,二者数据特征不同,客流短时预测的时间粒度与结果精度会有所不同。为减少数据滞后性带来的误差,本文运用同期的数据进行训练,导致模型输入样本数量不多,限制了模型预测精度。在下一步研究中,将重点探索景区的离线短时预测改进为在线的增量学习预测方式,提高景区调度决策水平。

#### 参考文献:

- [1] 孙九霞. 国内旅游业更新升级的新动向与新挑战[J]. 人民论坛, 2024(7): 94-98.  
Sun Jiu-xia. New trends and challenges in the renewal and upgrading of the domestic tourism industry[J]. People's Tribune, 2024(7): 94-98.
- [2] 闫晟煜, 王钊龙, 武瑾, 等. 省域高速公路网车辆碳排放量测算方法[J]. 中国环境科学, 2024, 44(12): 7095-7104.  
Yan Sheng-yu, Wang Zhao-long, Wu Jin, et al. Estimation model of vehicle carbon emission for provincial expressway networks[J]. China Environmental Science, 2024, 44(12): 7095-7104.
- [3] Song H Y, Richard T Q, Jinah P. Review of research on tourism demand forecasting: launching the annals of tourism research curated collection on tourism demand forecasting[J]. Journals of Tourism Research, 2019, 75: 338-362.
- [4] Hu Y C. Predicting foreign tourists for the tourism industry using soft computing-based Grey-Markov models[J]. Sustainability, 2017, 9(7): 1-12.
- [5] Li S W, Chen T, Wang L, et al. Effective tourist volume forecasting supported by PCA and improved BPNN using Baidu index[J]. Tourism Management, 2018, 68(10): 116-126.
- [6] Sun S L, Wei Y J, Tsui K L, et al. Forecasting tourist arrivals with machine learning and internet search index[J]. Tourism Management, 2019, 70(2): 1-10.
- [7] Bi J W, Liu Y, Li H, et al. Daily tourism volume forecasting for tourist attractions[J]. Annals of Tourism Research, 2020, 83(3): No. 102923.
- [8] Bi J W, Li C X, Xu H, et al. Forecasting daily tourism demand for tourist attractions with big data: an ensemble deep learning method[J]. Journal of Travel Research, 2022, 61(8): 1719-1737.
- [9] Han W, Li Y, Li Y, et al. A deep learning model based on multi-source data for daily tourist volume forecasting[J]. Current Issues in Tourism, 2024, 27(5): 768-786.
- [10] 廖治学, 戈鹏, 任佩瑜, 等. 基于AB@G集成模型的九寨沟景区游客量预测研究[J]. 旅游学刊, 2013, 28(4): 88-93.  
Liao Zhi-xue, Ge Peng, Ren Pei-yu, et al. Research on prediction of tourists quantity in Jiuzhai Valley based on AB@G integration model[J]. Tourism Science, 2013, 28(4): 88-93.
- [11] Mohd A, Wu J Z, Chakraborty R K, et al. Attention-based STL-BiLSTM network to forecast tourist arrival[J]. Processes, 2021, 9(10): No. 09101759.
- [12] 《中国公路学报》编辑部. 中国公路交通学术研究综述2012[J]. 中国公路学报, 2012, 25(3): 2-50.  
Editorial Department of China Journal of Highway and Transport. An academic research summary on china highway and transport: 2012[J]. China Journal of Highway and Transport, 2012, 25(3): 2-50.
- [13] Ceder A, Helman I S. Deficit function bus scheduling with deadheading trip insertions for fleet size reduction[J]. Transportation Science, 1981, 11: 338-363.
- [14] 刘涛, 尤海林. 基于人机协同决策的运输调度优化研究[J]. 交通运输系统工程与信息, 2024, 24(2): 136-148.  
Liu Tao, You Hai-lin. Human-machine collaborative decision-making for transportation scheduling optimization [J]. Journal of Transportation Systems Engineering and Information Technology, 2024, 24(2): 136-148.
- [15] 闫晟煜, 赵佳琪, 尤文博, 等. 高速公路货车差异化通行费折扣的双层规划模型[J/OL]. 清华大学学报: 自然科学版, 2025, <https://link.cnki.net/urlid/11.2223.N.20250411.1525.003>  
Yan Sheng-yu, Zhao Jia-qi, You Wen-bo, et al. Bi-level programming model for differential toll discounts for expressway trucks[J]. Journal of Tsinghua University (Science and Technology), 2025, <https://link.cnki.net/urlid/11.2223.N.20250411.1525.003>
- [16] 董强. 基于遗传算法的风景区电瓶摆渡车发车管理[J]. 佳木斯大学学报: 自然科学版, 2017, 35(3): 488-491.

- Dong Qiang. The bus scheduling based on genetic algorithm[J]. Journal of Jiamusi University (Natural Science Edition), 2017, 35(3): 488-491.
- [17] 张建华. 基于实时客流信息的快速公交车辆组合调度优化研究[D]. 成都: 西南交通大学交通运输与物流学院, 2013.
- Zhang Jian-hua. Research on the optimization of combinational scheduling bat based on real-time passenger flow[D]. Chengdu: School of Transportation and Logistics, Southwest Jiaotong University, 2013.
- [18] 杨凤满. 基于人工神经网络的交通流预测方法综述[J]. 公路交通科技, 2020, 37(增刊1):130-135.
- Yang Feng-man. Review of traffic flow prediction methods based on artificial neural network[J]. Journal of Highway and Transportation Research and Development, 2020, 37(Sup. 1): 130-135.
- [19] 陈晓雷, 孙永峰, 李策, 等. 基于卷积神经网络和双向长短期记忆的稳定抗噪声滚动轴承故障诊断[J]. 吉林大学学报: 工学版, 2022, 52(2): 296-309.
- Chen Xiao-lei, Sun Yong-feng, Li Ce, et al. Stable anti-noise fault diagnosis of rolling bearing based on CNN-BiLSTM[J]. Journal of Jilin University(Engineering and Technology Edition), 2022, 52(2): 296-309.
- [20] Yang D, Chen K R, Yang M N, et al. Urban rail transit passenger flow forecast based on LSTM with enhanced long-term features[J]. IET Intelligent Transport Systems, 2019, 13(10): 1475-1482.
- [21] 苏恩杰, 叶飞, 何乔, 等. 基于卷积神经网络-长短期记忆的施工期盾构管片上浮过程预测模型[J]. 同济大学学报: 自然科学版, 2023, 51(9): 1352-1361.
- Su En-jie, Ye Fei, He Qiao, et al. Prediction model of shield segment floating process during construction based on convolutional neural networks and long short-term memory[J]. Journal of Tongji University (Natural Science), 2023, 51(9): 1352-1361.
- [22] 戢晓峰, 孔晓丽, 陈方, 等. 基于ETC数据和A-BiLSTM神经网络的高速公路节假日短时交通流预测模型[J]. 交通信息与安全, 2023, 41(3): 166-174.
- Ji Xiao-feng, Kong Xiao-li, Chen Fang, et al. A forecasting model of short-term traffic flow on expressways during holidays based on ETC data and A-BiLSTM neural network models[J]. Journal of Transport Information and Safety, 2023, 41(3): 166-174.
- [23] 赵阳阳, 夏亮, 江欣国. 基于经验模态分解与长短期记忆神经网络的短时地铁客流预测模型[J]. 交通运输工程学报, 2020, 20(4): 194-204.
- Zhao Yang-yang, Xia Liang, Jiang Xin-guo. Short-term metro passenger flow prediction based on EMD-LSTM[J]. Journal of Traffic and Transportation Engineering, 2020, 20(4): 194-204.
- [24] Cao Z C, Ceder A A. Autonomous shuttle bus service timetabling and vehicle scheduling using skip-stop tactic[J]. Transportation Research Part C: Emerging Technologies, 2019, 102(5): 370-395.
- [25] 范厚明, 田攀俊, 吕迎春, 等. 越库配送下考虑时空距离的库门分配与车辆调度优化[J]. 中国管理科学, 2022, 30(2):137-149.
- Fan Hou-ming, Tian Pan-jun, Lyu Ying-chun, et al. Cross-dock door assignment and vehicle routing problem of considering temporal-spatial distance[J]. Chinese Journal of Management Science, 2022, 30(2): 137-149.
- [26] 李翠玉, 胡雅梦, 康亚伟, 等. 应用自适应遗传算法的电动汽车充放电协同调度[J]. 吉林大学学报: 工学版, 2022, 52(11): 2508-2513.
- Li Cui-yu, Hu Ya-meng, Kang Ya-wei, et al. Coordination scheduling of electric vehicle charge and discharge using adaptive genetic algorithm[J]. Journal of Jilin University (Engineering and Technology Edition), 2022, 52(11): 2508-2513.