

文章编号:1673-9590(2024)01-0033-06

机场场面交通流量预测方法研究

廉冠^{1,2}, 于嘉欣³, 张晓玥³, 郭雪松³

(1. 桂林电子科技大学 广西智慧交通重点实验室, 广西 桂林 541010; 2. 桂林电子科技大学 南宁研究院, 广西 南宁 530000; 3. 桂林电子科技大学 建筑与交通工程学院, 广西 桂林 541010)

摘要:针对机场场面交通可获数据的局限性,为精准提取机场交通数据时空特征及预测场面交通流量。首先,基于推出控制理论,建立机场场面运行数值仿真模型,得到因数据局限无法获取的预测指标;其次,搭建卷积神经网络(CNN)与长短期记忆网络(LSTM)组合预测模型提取时空特征;最后,以河南郑州机场为例进行试验验证,比较模型在不同训练数据量下的预测性能与误差指标,结果表明基于仿真指标的预测模型预测结果精确度高且性能稳定。

关键词:交通流量预测;机场场面交通仿真;推出控制;卷积神经网络;长短期记忆网络

文献标识码:A **DOI:**10.13291/j.cnki.djdxac.2024.01.005

机场是由飞机、人和滑行环境等动态要素所构成的有机整体,是民航系统最重要的基础设施,同时也是国家综合交通基础设施的重要组成部分,因此机场场面交通流量的预测对精细化管制决策具有至关重要的意义。民航交通的研究应用最早集中在空中交通领域,随着我国国家综合机场体系的完善,交通拥堵由空域转移至机场,研究也开始聚焦于机场场面交通。

在机场场面交通运行状态研究方面,衡红军等^[1]首次提出一种适应机场交通特点的多一维元胞模型,模拟机场场面交通,达到预期效果。张亚平等^[2]针对繁忙机场,提出了推出控制理论,有效地将飞机在滑行等待时间转化为停机位停留时间,以此减少燃油消耗。Mori^[3]基于 Nagel-Schreckenberg 模型仿真机场地面的滑行情况,并对机场繁忙的状态进行验证。Kawagoe 等^[4]用蜂窝自动机仿真模拟东京国际机场的地面交通,仿真结果与实际数据对比发现,结果具有较好的精度。早期的交通流预测方法多数以统计分析方法为基础,如回归分析法^[5]等,近年来为了寻找更广泛、更适用的交通预测方法,不同学科相互交流

融合,神经网络^[6]、支持向量机^[7-8]及数据融合、数据挖掘^[9]和交通仿真等方法开始被广泛应用于交通预测。在民航交通领域,刘宁等^[10]通过 Elman 神经网络算法对道路交通流量进行预测,预测结果优于历史趋势法与多元回归模型。张波等^[11]基于 LSTM 模型预测机场辖区内路面交通拥堵状况,结果优于线性模型 ARMA 和 VAR。Lian 等^[12]对比 Softmax Regression 模型、神经网络方法和基于蜂群智能算法的改进支持向量回归方法,对机场拥堵态势进行预测。大部分交通预测方法多为基于时间序列的预测模型,忽略了交通数据空间关系影响。

为较好预测机场场面交通流量,本文从时间和空间的维度构建了卷积神经网络(CNN)和长短期记忆网络(LSTM)的组合预测模型,在预测指标的选择与处理上,结合既有的推出控制策略,建立机场场面交通仿真模型得到航班位置-时间信息与预测指标,预测机场场面流量。选用河南郑州机场历史数据进行试验,结果表明 CNN-LSTM 预测模型对机场场面交通流量的预测结果较好,具有较高的精度和鲁棒性。

收稿日期:2023-02-23

基金项目:广西科技基地和人才专项(桂科 AD19245021);广西自然科学基金项目(2020JJB170049);国家自然科学基金项目(61963011)

第一作者:廉冠(1989—),男,讲师。E-mail:lianguan@guet.edu.cn

1 基于机场运行仿真的预测指标

1.1 预测指标选取

为构建机场场面流量预测模型,首先选取场面流量影响因素作为预测指标。传统交通流预测方法通常采用单一指标或较少指标(如速度、流量)进行预测,但机场场面交通系统是由跑道、滑行道和停机位多个子系统组成的大型交通系统,

场面交通流量受多种因素影响,单一的预测指标无法反映机场场面交通的时空相关性。因此,需要综合多方面选择影响因素,构建基于多因素机场场面交通特征指标的流量预测方法。为更好地体现机场场面交通特征,本文从进场、离场两个角度选取机场场面流量影响因子作为预测指标,见表1。

表1 机场场面交通流量预测指标

类型指标	指标名称	说明
进场类	进场航班流量 I_1	统计周期内降落但未进入机位的进场航班架次
	进场时间偏差 I_2	进场航班实际到达时间与预计到达时间的偏差,体现进场航班延误情况对场面流量影响
	进场航班滑行时间 I_3	飞机进场时进入机场跑道的着陆时刻与通过滑行道进入停机坪处在飞机滑轮前面安置挡板时刻的差值
离场类	离场时间偏差 I_4	离场航班的实际起飞时间与预计起飞时间偏差
	离场航班排队长度 I_5	统计周期跑道端排队的飞机数量,离场航班在起飞前需要按照一定的顺序进行排队等待
	离场航班滑行时间 I_6	飞机离场过程在滑行道总滑行时间,其中包括滑行时间与排队等待时间

1.2 机场场面运行数值仿真

1.1节选取了对机场场面交通流量影响显著的指标,由于机场可获数据局限于撤轮挡时刻、挡轮挡时刻等里程碑节点时刻数据(表2),排队长度和排队等待时间无法直接统计,且指标计算复

杂。为使机场场面交通流量预测模型更准确,利用 Matlab 软件对机场场面运行过程进行数值仿真,获得机场场面离场航班滑行过程中的位置-时间信息与预测指标,为后续机场运行分析提供依据。

表2 进场和离场航班原始数据

	进场航班	航线	预到	实到	机位	挡轮挡
进场	MU2322	西安—郑州	01:10	01:14	907	01:22
	MU2759	南京—郑州	08:40	08:32	242	08:39
	⋮	⋮	⋮	⋮	⋮	⋮
	ZH9150	沈阳—郑州	23:15	23:14	237	23:30
	MU2544	上海—郑州	23:20	23:26	906	23:38
	离场航班	航线	预飞	实飞	登机口	撤轮挡
离场	MU2322	郑州—合肥	01:50	03:08	230	02:55
	MU2759	郑州—西宁	09:30	09:29	242	09:13
	⋮	⋮	⋮	⋮	⋮	⋮
	HU7396	郑州—兰州	22:15	23:52	253	23:19
	HU7694	郑州—厦门	21:40	23:56	257	21:57

首先将机场场面结构建模为网络结构图,定义起点为停机位节点,终点为跑道端节点,赋予边距离权值;离场航班滑行至跑道的过程建模为排队系统,航班滑行至跑道端的过程视为 M/M/1 排队系统的输入过程。已有的经验数据表明,飞机滑行至跑道端的分布服从一定参数的泊松分

布,到达方式为单个到达,跑道服务时间服从负指数分布,排队规则为先到先服务原则(FCFS)。每个统计周期的到达航班频率不同,参数也不相同,使用 Little 公式直接计算排队参数误差较大,因此选择对统计周期内每一架航班的排队情况进行数值仿真。参考推出控制策略,假定最优的推出

控制数量,参考《中华人民共和国飞行基本规则》,对模型做出以下假设:

(1)飞机在跑道排队起飞过程服从负指数分布,互相独立。

(2)不考虑机场内中转航班运行的影响以及各航班机型的影响,假设飞机机型相同。

(3)模型中的滑行速度默认为平均滑行速度 10 节/h,即 5.14 m/s。

(4)设置滑行道路上的排队阈值 N 为 15 架次。

首先,用 Floyd 算法将推出航班分配最短路径作为离场滑行路径。其次,对从停机位推出的航班应用推出控制策略,若滑行道路系统中的航班超过 15 架次便不再推出。赋值第一架离场飞机进入跑道端时刻为 t_1 ,此时系统的排队等待时间和排队长都为 0(第一架离场飞机无须等待和排队),计算每个统计周期离场航班的排队长度与滑行时间。最后,定义位置变量,获取航班节点时刻信息,应用时间插值公式进行航班位置时序扫描,得到离场航班实时滑行位置节点-时间信息与预测指标数值仿真结果。仿真流程示意图见图 1。

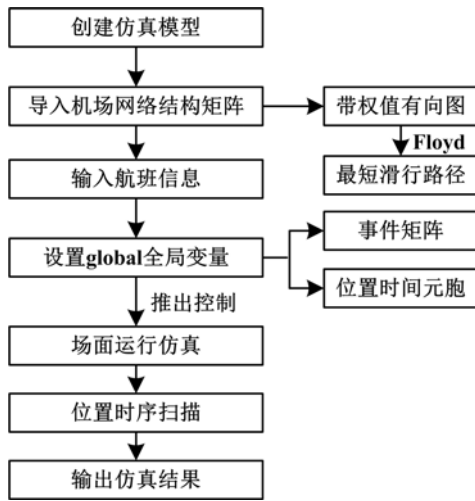


图 1 仿真流程示意图

2 基于 CNN-LSTM 的机场场面交通流量预测模型

通过搭建机场运行数值仿真得到机场场面交通流量影响因子的数据矩阵。场面流量预测重点在于交通数据时空特征的提取,现有的交通流量预测方法集中于时间序列预测,对复杂交通系统的空间相关性分析不足,导致预测性能不佳。结合卷积神经网络与长短期记忆网络进行交通流量预测,其网络结构见图 2。




图 2 CNN-LSTM 网络结构

组合预测模型中的卷积神经网络是一种深度前馈神经网络,其主要特征包含局部感知野、权重共享和多层结构等。经典的卷积神经网络一般由卷积层、池化层和全连接层等构成,输入的预测指标通过卷积层和池化层中的特征转换和提取进行处理,机场交通数据之间的时空相关性可以被卷积层提取出来,弥补 LSTM 时序预测的不足。机场的特征输入是一维数据,因此为提取机场场面航班数据的空间特征,模型选取 32 个 10×1 大小的卷积核,在卷积层之后加了平均池化层用来降维,可以减少卷积核的尺寸,同时又可以保留相应的特征。模型的卷积层与平均池化层的计算公式分别为:

$$C_j^l = \varphi(C_i^{l-1} * k_{ij}^l + b_j^l) \quad (1)$$

$$y_{m,n}^d = \frac{1}{|R_{m,n}^d|} \sum_{i \in R_{m,n}^d} x_i \quad (2)$$

式中: $*$ 表示卷积操作; C_j^l 是第 l 层的第 j 个输出; C_i^{l-1} 是第 $l-1$ 层的第 i 个特征; k_{ij}^l 表示第 l 层的卷积核; b_j^l 是第 l 层的第 j 个偏置值; φ 是激活函数; x_i 为区域 R_k^d 内每个神经元的活性值。

模型中的长短期记忆网络层是基于循环神经网络(RNN)的创新,在 RNN 隐藏层各神经元中增加 LSTM 记忆模块,处理了简单 RNN 的梯度消失或爆炸的问题,其结构见图 3。




图 3 LSTM 记忆单元结构

LSTM 记忆单元结构主要包括输入门、遗忘门和输出门。各层的方程如下:

$$i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i) \quad (3)$$

$$o_t = \sigma(W_o x_t + U_o h_{t-1} + b_o) \quad (4)$$

$$f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f) \quad (5)$$

$$\tilde{c}_t = \sigma(W_c x_t + U_c h_{t-1} + b_c) \quad (6)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot \tilde{c}_t \quad (7)$$

$$h_t = o_t \odot \tanh(c_t) \quad (8)$$

式中: $\sigma(\cdot)$ 为 Logistic 函数,其输出区间为 $(0, 1)$; \tanh 为激活函数; \odot 为向量元素乘积。

LSTM 的记忆功能可以获取数据的时序变化信息,因此模型中的 LSTM 层用来提取机场航班数据的时间特征。设置模型中 CNN 层神经元数为 32, LSTM 网络层神经元数为 50,同时设置 Dropout 层为 0.25,避免过拟合现象。模型的参数设置见表 3,训练流程见图 4。

表 3 CNN-LSTM 预测模型参数设置

参数	说明	设置
conv	卷积核大小	10×1
pool	池化方式	平均池化
activation	激活函数	ReLU
dropout	防止过拟合	0.25

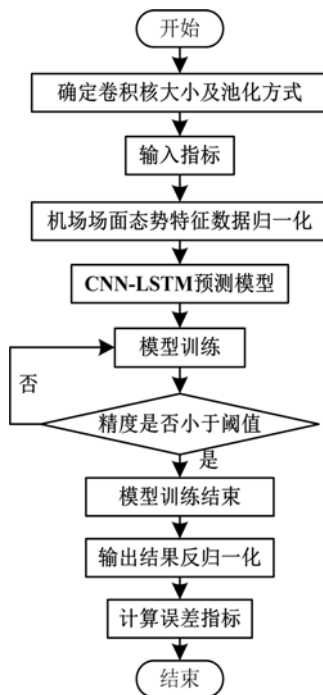


图 4 CNN-LSTM 模型训练流程

3 试验分析

3.1 数据来源及处理

为评估 CNN-LSTM 预测模型的性能,选用表 2 所示河南郑州机场的进离场航班数据进行试验

分析,选取 2016 年 4 月 1 日—7 月 1 日的航班数据作为训练集,以 8 月 1 日的数据作为测试样本。依据机场实际运行数据仿真模拟,得到预测模型输入指标,使用 max-min 归一化方法对数据进行预处理操作,将数据变化范围限制在 $[0, 1]$ 区间内,预测之后进行反归一化,有效地减少迭代时间,提高结果精度:

$$X' = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (9)$$

式中: X' 为归一化后的值; X 为原始值; X_{\max} 、 X_{\min} 为训练样本的最大值、最小值。

3.2 误差评价指标

为了体现 CNN-LSTM 预测模型的预测性能,选取平均绝对误差 (Mean Absolute Error, MAE)、均方根误差 (Root Mean Square Error, RMSE) 作为模型的评估指标,定量分析模型预测效果:

$$E_{\text{MAE}} = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (10)$$

$$E_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (11)$$

式中: n 为样本数量; \hat{y}_i 为预测值; y_i 为真实值; \bar{y} 为样本均值。

3.3 试验结果与分析

本文搭建的 CNN-LSTM 组合网络机场态势预测模型,使用 CNN 网络层提取机场场面流量预测指标的空间相关性,搭建 LSTM 网络层提取指标间的时间特征。以 24 h 的航班流量数据作为测试样本,设定时间间隔为 1 h,得到最终预测结果。用典型交通流时序预测模型 LSTM 神经网络与 Elman 神经网络进行比较,结果见表 4。

表 4 模型评估参数对比

模型结构	E_{MAE}	E_{RMSE}
Elman	1.136 0	1.360 1
LSTM	1.062 3	1.310 6
CNN-LSTM	0.683 4	0.936 8

评估参数的对比结果表明, CNN-LSTM 模型的预测性能要优于其他预测模型。与 LSTM 模型相比, CNN-LSTM 模型的 MAE 和 RMSE 值分别降低了 0.378 9 和 0.373 8,证明通过卷积层提取机场航班数据时空特征后的 LSTM 模型,预测精度变高,有效提升了模型的学习能力和学习效率。与 Elman 模型相比, CNN-LSTM 模型的 MAE 值降低了 0.452 6, RMSE 值降低了 0.423 3,说明加

入空间特征提取后的长短期记忆网络预测模型精度优于局部记忆单元和反馈链接的递归神经网络 Elman 模型。预测模型结果对比见图 5。预测模型的预测结果同实际值的曲线趋势走向基本一致,说明机场场面流量预测指标的选取对预测结果是有效可行的。CNN-LSTM 神经网络机场流量预测模型对比评估指标 MAE、RMSE 有很好的预测精准度,与现有预测模型对比,预测模型性能明显提升,可以准确地预测机场场面交通流量。

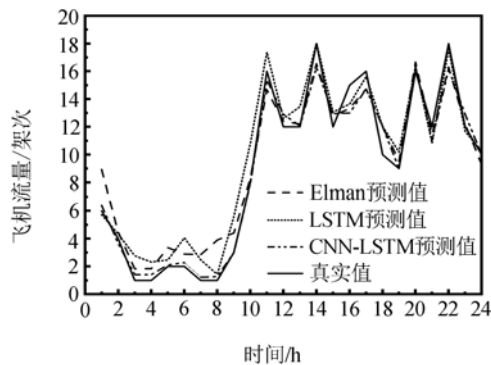


图 5 预测模型结果对比

此外,将模型训练数据集分别设定为 20%、40%、60%、80%和 100%,表示不同的可用数据量,即 20%和 40%表示缺少航班大部分数据,60%表示良好的航班数据集,80%或更多表示适当的航班运行数据集,由图 6 可知,不同的数据可用量下,CNN-LSTM 预测模型的鲁棒性优于对比模型。




图 6 不同可用数据下预测模型的鲁棒性

4 结论

本文对机场场面交通的数值仿真,解决了机场场面交通可获数据类型的局限性,从时间和空间维度构建了 CNN 和 LSTM 的组合交通流量预测模型,预测机场场面流量。机场场面运行中飞

机的流量可以较为准确的评估机场在某个时刻的交通状况,减少离场飞机在滑行过程中产生的等待,降低航班延误所造成的时间和成本损失。试验验证结果表明,本文提出的预测方法有效地预测了机场场面流量,为机场场面交通态势研究奠定了基础。

参考文献:

- [1] 衡红军, 孙晟, 武娟. 基于元胞自动机的机场场面交通仿真模型[J]. 微计算机信息, 2009, 25(25): 36-38.
- [2] 张亚平, 廉冠, 邢志伟, 等. 飞机推出控制停机位等待惩罚策略[J]. 哈尔滨工业大学学报, 2018, 50(3): 39-45.
- [3] MORI R. Aircraft ground-taxiing model for congested airport using cellular automata[J]. IEEE Transactions on Intelligent Transportation Systems, 2013, 14(1): 180-188.
- [4] KAWAGOE Y, CHINO R, TSUZUKI S, et al. Analyzing stochastic features in airport surface traffic flow using cellular automaton: Tokyo International Airport[J]. IEEE Access, 2022(10): 95344-95355.
- [5] 杨凯茜, 刘玮蔚. 基于数据挖掘的交通流预测研究[J]. 汽车实用技术, 2020(11): 87-89.
- [6] 王德广, 黄浩洋. 基于 MHP SO 优化 GRU 神经网络的短时交通流预测[J]. 大连交通大学学报, 2020, 41(1): 12-17.
- [7] 何祖杰, 吴新焯, 刘中华. 基于改进灰狼算法优化支持向量机的短期交通流预测[J]. 厦门大学学报(自然科学版), 2022, 61(2): 288-297.
- [8] 赵亚斌, 白磷, 武奇生, 等. 基于 MPSO-RVM 的短期交通流预测方法研究[J]. 计算机应用研究, 2020, 37(增刊 1): 69-71.
- [9] 闫伟, 刘云岗, 王桂华, 等. 基于数据挖掘的交通流预测模型[J]. 系统工程理论与实践, 2010, 30(7): 1320-1325.
- [10] 刘宁, 陈昱颀, 虞慧群, 等. 基于 Elman 神经网络的交通流量预测方法[J]. 华东理工大学学报(自然科学版), 2011, 37(2): 204-209.
- [11] 张波, 周芳, 李强. 基于 LSTM 模型的北京首都国际机场路面交通拥堵预测[J]. 数理统计与管理, 2020, 39(5): 761-770.
- [12] LIAN G, ZHANG Y P, DESAI J, et al. Predicting taxi-out time at congested airports with optimization-based support vector regression methods[J]. Mathematical Problems in Engineering, 2018(1): 1-11.