

文章编号:1674-8190(2022)02-099-08

# 离港航空器滑出时间的BP神经网络预测模型

夏正洪, 贾鑫磊

(中国民用航空飞行学院 空中交通管理学院, 广汉 618307)

**摘要:** 准确地预测离港航空器滑出时间可有效提升机场场面运行效率,降低运行成本。构建基于BP神经网络的离港航空器滑出时间预测模型,分析影响离港航空器滑出时间的可量化因素,并对其相关性进行检验;通过我国中南某机场2周实际运行数据对模型进行验证,并以均方根误差、平均绝对误差和平均绝对误差百分比检验预测结果的准确性。结果表明:同时段推出航空器数量、同时段起飞航空器数量、同时段落地航空器数量、1小时内平均滑出时间与离港航空器滑出时间呈现强相关性,滑行距离、转弯个数、延误时间与滑出时间相关但不显著,航空器起飞时刻所在时段与滑出时间不相关;1小时内平均滑出时间对模型预测精度的提升起重要作用,具有相关性但不显著的影响因素的引入对预测结果精度的提升有一定的作用,引入不相关因素后模型的预测精度会显著下降。

**关键词:** 滑出时间预测;BP神经网络;1小时内平均滑出时间;离港航空器;滑出时间影响因素

**中图分类号:** V355; TP183

**文献标识码:** A

**DOI:** 10.16615/j.cnki.1674-8190.2022.02.15

**开放科学(资源服务)标识码(OSID):**



## Taxi-out Time Prediction Model of Departure Aircraft Based on BP Neural Network

XIA Zhenghong, JIA Xinlei

(College of Air Traffic Management, Civil Aviation Flight University of China, Guanghan 618307, China)

**Abstract:** Accurately predicting the departure aircraft slip out time can effectively improve the airport surface operation efficiency and reduce the operation cost. A prediction model of departure and departure time based on BP neural network is established. The key factors influencing the actual slip out time are analyzed, and the correlation is tested. The model is verified by two weeks' actual operation data of an airport in central and southern China, and the root mean square error (RMSE), mean absolute error (MAE) and MAE percentage are analyzed. The results show that there is a strong correlation between the number of aircraft launched in the same period, the number of aircraft taking off in the same period, the number of aircraft in the same period, the average taxiing time within one hour and the taxiing time of departing aircraft. The taxiing distance, the number of turns and the delay time are related to the taxiing time, but not significant. The time period at which the aircraft takes off is not related to the slip out time. The average slip out time within 1 hour plays an important role in improving the prediction accuracy of the model. The introduction of relevant but insignificant influencing factors plays a certain role in improving the accuracy of prediction results. After the introduction of irrelevant factors, the prediction accuracy of the model will decrease significantly.

**Key words:** taxi-out time prediction; BP neural network; one hour average taxi-out time; departure aircraft; influencing factors of taxi-out time

收稿日期: 2021-05-12; 修回日期: 2021-09-09

基金项目: 四川省科技计划项目(2020YFS0541); 四川省中央引导地方科技发展专项项目(2020ZYD094)  
中国民用航空飞行学院重点项目(ZJ2021-05)

通信作者: 贾鑫磊, 1142723218@qq.com

引用格式: 夏正洪, 贾鑫磊. 离港航空器滑出时间的BP神经网络预测模型[J]. 航空工程进展, 2022, 13(2): 99-106.

XIA Zhenghong, JIA Xinlei. Taxi-out time prediction model of departure aircraft based on BP neural network[J]. Advances in Aeronautical Science and Engineering, 2022, 13(2): 99-106. (in Chinese)

## 0 引言

滑出时间是指离港航空器从停机位推出到实际起飞的时间,准确预测滑出时间可有效地提升机场场面运行效率。目前,大型机场的场面滑行时间已经超过 25 min,且常出现滑行冲突,严重影响了机场场面运行效率。科学精准地预测离港航空器滑出时间,对于提升机场场面运行效率和协调决策能力,降低运行成本和污染排放有重要意义。

目前,国外关于离港航空器滑出时间的预测已有较为深入的研究。E. George 等<sup>[1]</sup>基于航空器历史数据对离港航空器的滑出时间进行了动态预测,提出了基于强化学习的 Q-learning 方法,且预测精度较高;H. B. Lee 等<sup>[2]</sup>利用机器学习算法来预测滑出时间,预测效果良好;F. Herrema 等<sup>[3]</sup>基于历史数据对单跑道场面滑行时间进行了预测;L. Simaiakis 等<sup>[4]</sup>利用自主研发的排队系统来预测场面交通拥堵情况,预测精度较高;P. Balakrishna 等<sup>[5]</sup>基于随机动态规划理论建立了多跑道非参数强化学习滑出时间预测模型,可得到精度较高的预测结果。

国内关于离港航空器滑出时间的预测研究尚处于起步阶段。Lian Guan 等<sup>[6]</sup>研究了双跑道机场的滑出时间,提出了考虑 6 个滑行时间影响因素的 BP 神经网络预测模型,预测精度达到 95%;Yin Jianan 等<sup>[7]</sup>构建了考虑 4 个影响因素的双跑道机场滑行时间预测模型;邢志伟等<sup>[8]</sup>利用贝叶斯网络的增量学习特点对预测模型进行动态调整,从而使模型能够动态地估计离港航空器滑行时间;刘继新等<sup>[9]</sup>提出了基于 SVR 和 BP 神经网络的离港滑行时间预测模型,并将预测结果用于 A-CDM 系统中,有效地提升了机场场面的运行效率;冯霞等<sup>[10]</sup>基于单跑道建立了无障碍滑出时间的计算模型与基于排队论的等待起飞时间预测模型;李楠等<sup>[11]</sup>根据分类结果建立多元回归模型,相较于传统多元线性回归,机器学习交叉训练集下的预测准确度更高;疏利生等<sup>[12]</sup>构建了航空器机场地面强化学习移动模型,能够实现停机位到跑道出口智能静态路径规划;陈祯等<sup>[13]</sup>从特征选择的角度对滑出时间预测模型进行改进,相比于单一特征,引入交互特征可以提高准确率;闫萍等<sup>[14]</sup>提出的滑行道与停机位联合调度模型可以有效避免滑行冲突

并兼顾服务质量和场面滑行效率;侯盼盼等<sup>[15]</sup>提出分段预测滑行冲突的计算方法,能够解决航空器路由规划的优化性和实时性之间的矛盾。

综上所述,现有研究成果主要从静态和动态两方面来预测离港航空器的滑行时间。目前对滑出时间预测的研究成果未全部使用可量化因素进行预测,缺乏根据相关性程度建立预测模型这一关键步骤。因此,本文分析影响离港航空器滑出时间的可量化因素,包括同时段内推出航空器数量、同时段内起飞航空器数量、同时段内进港航空器数量、1 小时内平均滑出时间、滑行距离、转弯转角数量、航空器延误时间和所在时段,根据相关性对影响因素进行重要性排序、分组,构建基于 BP 神经网络的离港航空器滑出时间预测模型;并以我国中南某枢纽机场 2 周实际运行数据对模型进行验证,讨论不同相关性的影响因素组合而成的模型对预测结果精度的影响,以期通过对滑出时间的预测,提升机场场面运行效率和安全性。

## 1 影响因素与相关性分析

### 1.1 影响因素

根据离港航空器滑出时间的定义,滑出时间等于离港航空器的实际起飞时间减去实际撤轮档时间。对于繁忙机场来说,离港航空器从停机位推出到起飞过程中的任何一个环节都有可能滑出时间的增加。因此,准确预测滑出时间,从而控制航空器的推出开车、滑行过程,以及优化航空器的滑行路径是在短期内提高场面运行效率、减少环境污染、降低滑行成本的重要途径。

$$T_A = T_1 - T_2 \quad (1)$$

式中: $T_A$ 为离港航空器的实际滑出时间; $T_1$ 为实际起飞时刻; $T_2$ 为实际撤轮档时刻。

根据离港航空器的管制指挥过程可知:离港航空器停机位远近,所在机场的高峰时段,近几个小时内的地面交通流量,滑行过程中航空器的速度,是否为直线滑行、经过多少个弯道等因素都会影响滑行时间。同时,机场地面交通流对滑出时间的影响也是非常显著的,如同时段进港航空器和离港航空器越多,则对后续离港航空器的滑出时间影响越大,且很容易造成滑行冲突,从而增加离港航空器的滑出时间。此外,天气、流量控制、跑道构型等对滑出时间也有一定的影响,但由于

很难量化这些因素,在本文中不做讨论。基于上述分析,本文提出8个可以量化的影响因素:同时段推出航空器数量 $x_1$ 、同时段起飞航空器数量 $x_2$ 、同时段进港航空器数量 $x_3$ 、1小时内平均滑出时间 $x_4$ 、滑行距离 $x_5$ 、转弯转角个数 $x_6$ 、延误 $x_7$ 、航空器起飞时刻所在时段 $x_8$ 。

(1) 同时段推出航空器数量 $x_1$

离港航空器 $i$ 可能与同时段推出的离港航空器争夺跑道和滑行道资源,在滑行过程中还可能产生对头或交叉冲突,从而造成某架航空器等待,增加滑出时间。因此,本文定义离港航空器 $i$ 同时段内推出航空器数量为

$$x_1(i) = \sum_{n=1}^j S_{j1} \quad (t_{\text{Block-out}(j)} < t_{\text{Take-off}(i)} \text{ 且 } t_{\text{Block-out}(j)} > t_{\text{Block-out}(i)}) \quad (2)$$

式中: $x_1(i)$ 为在航空器 $i$ 滑行过程中推出的所有航空器数量; $S_{j1}$ 为满足推出时刻处于航空器 $i$ 撤轮档时刻到起飞时刻之间的航空器数量。

(2) 同时段起飞航空器数量 $x_2$

离港航空器 $i$ 在滑行过程中,可能会与同时段起飞的航空器争夺滑行道资源和跑道资源,从而影响其滑出时间。因此,本文定义离港航空器 $i$ 同时段内起飞航空器数量为

$$x_2(i) = \sum_{n=1}^j S_{j2} \quad (t_{\text{Take-off}(j)} < t_{\text{Take-off}(i)} \text{ 且 } t_{\text{Take-off}(j)} > t_{\text{Block-out}(i)}) \quad (3)$$

式中: $x_2(i)$ 为在航空器 $i$ 滑行过程中所有起飞的航空器数量; $S_{j2}$ 为满足起飞时刻处于航空器 $i$ 撤轮档时刻到起飞时刻之间的航空器数量。

(3) 同时段进港航空器数量 $x_3$

离港航空器 $i$ 在滑出过程中,可能会与同时段落地的进港航空器争夺跑道和滑行道资源,且进港航空器的优先级通常高于离港航空器,因此可能出现等待的情况,从而影响滑出时间<sup>[11]</sup>。本文定义同时段进港航空器数量为航空器 $i$ 推出后已经落地但未进入停机位的所有航空器数量。

$$x_3(i) = \sum_{n=1}^j S_{j3} \quad (t_{\text{Arrive}(j)} > t_{\text{Block-out}(i)} > t_{\text{Take-off}(j)}) \quad (4)$$

式中: $x_3(i)$ 为在航空器 $i$ 滑行过程中进港的航空器

数量; $S_{j3}$ 为满足落地时刻处于航空器 $i$ 撤轮档时刻到起飞时刻之间的航空器数量。

(4) 1小时内平均滑出时间 $x_4$

1小时内平均滑出时间是衡量机场地面交通流状况的重要指标。该指标越大,说明场面交通流通常处于较为繁忙的时段,离港航空器在此时间段更可能出现滑行冲突,等待时间也可能越长。

$$x_4 = \frac{\sum_{i=1}^n T_i}{n} \quad (5)$$

式中: $x_4$ 为1小时内平均滑出时间; $T_i$ 为第 $i$ 架航空器的实际滑出时间。

(5) 滑行距离 $x_5$

滑出时间与航空器所在停机位的物理位置关系甚为紧密,滑行距离越长,则该停机位滑出的畅通滑行时间越长<sup>[10]</sup>。根据对交通流的分析及机场场面运行模式可知,选择机场图中最常用的滑出路径作为该机位的离港航空器滑出路径,通过测量及等比例缩放即可求得离港航空器的滑行距离。

$$x_5 = \frac{d_a}{d_b} \times 3600 \quad (6)$$

式中: $d_a$ 为滑行路径的总长度; $d_b$ 为跑道长度;3600为以米为单位的跑道长度。

(6) 转弯转角个数 $x_6$

航空器直线滑行速度与转弯滑行速度有较大的差异,离港航空器在滑出过程中经历的转弯个数越多,则其滑行时间越长<sup>[11]</sup>。根据停机位的位置和跑道滑行道运行模式,可知离港航空器的标准滑行路线和滑出过程中的转弯个数 $x_6$ 。

(7) 延误 $x_7$

根据交通流的传播特性,延误可能出现累积和传播现象,即上1小时的延误可能会对后续航空器的滑出时间造成影响<sup>[10]</sup>。根据《空中交通管理规则》可知:当实际起飞时间大于预计起飞时间15 min时,则开始计算延误,反之则延误为0。

$$\begin{cases} x_7(T_i) = T_{\text{Take-off}(j)} - T_{\text{Estimated}(j)} = T_i & (T_i \geq 900) \\ x_7(T_i) = T_{\text{Take-off}(j)} - T_{\text{Estimated}(j)} = 0 & (T_i < 900) \end{cases} \quad (7)$$

式中: $T_{\text{Estimated}(j)}$ 为上1小时离港航空器 $j$ 的预计起飞时间; $T_{\text{Take-off}(j)}$ 为上1小时离港航空器 $j$ 的实际起飞时间;900为以秒为单位的延误阈值。

(8) 航空器起飞时刻所在时段  $x_8$

大型机场的地面交通流通常呈现明显的日变化特征,即存在明显的早高峰、午间高峰和晚高峰,这些高峰时段的平均滑出时间通常较长。因此,引入航空器起飞时刻所在的时段这个可量化因素,用于区分高峰时段和正常时段。

1.2 数据整理

本文所用数据来源于我国中南某机场 2 周的实际运行数据,主要包含航空器号、机型、实际起飞时间、撤轮挡时间、实际落地时间、跑道号和停机位等信息,如表 1 所示。

表 1 原始数据  
Table 1 Original data

航空器呼号	实际起飞时间	撤轮挡时间	上轮挡时间	实际落地时间	跑道号	停机位
CSZ9341	2019/05/26 16:50:00	—	2019/05/26 19:18:00	2019/05/26 19:18:00	15	380
CSN3459	2019/06/02 11:18:00	2019/06/02 11:09:44	—	2019/06/02 13:37:00	15	352
⋮	⋮	⋮	⋮	⋮	⋮	⋮
CSN3465	2019/06/02 00:33:00	2019/06/02 00:10:00	—	2019/06/02 02:19:00	15	387R

原始数据包含 12 647 条记录,其中离港航空器 5 987 架次,进港航空器 6 660 架次。按步骤(如

图 1 所示)进行数据处理,所得结果如表 2 所示。

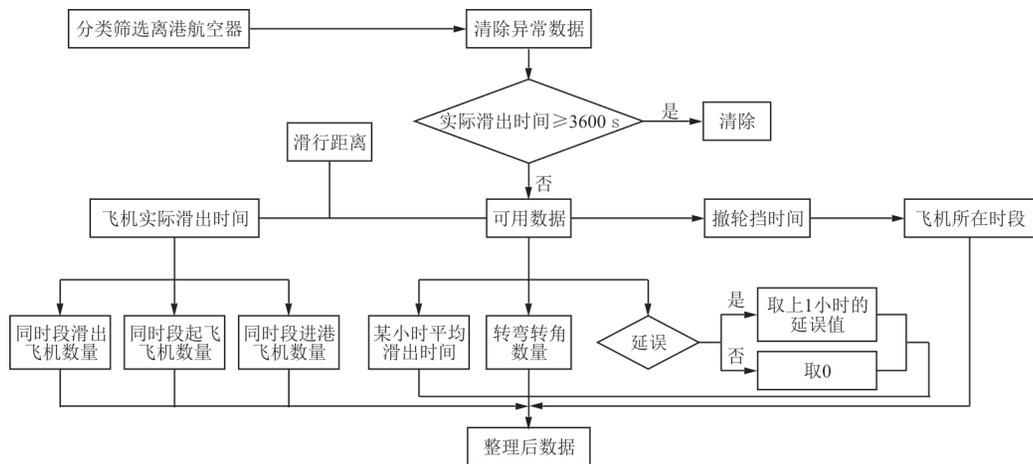


图 1 数据整理流程图

Fig. 1 Data consolidation flow chart

表 2 数据处理后的训练样本

Table 2 Training samples after data processing

航空器号	$x_1$ / 架次	$x_2$ / 架次	$x_3$ / 架次	$x_4$ /s	$x_5$ /m	$x_6$ /个	$x_7$ /s	$x_8$	滑出时 间/s
CSZ9341	7	6	8	1 003	121	5	103	1	1 124
CSN3459	6	7	11	1 003	339	2	103	1	1 200
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
CSN3465	8	9	12	1 003	320	2	103	1	1 380

注: $x_8$ 下方的“1”代表 00:00~01:00 时段。

数据整理的具体步骤为:

- Step 1:** 从原始数据中筛选出离港航空器;
- Step 2:** 清理异常数据(关键字段为空),并将实际滑出时间转换成秒(s);
- Step 3:** 计算同时段撤轮挡航空器数量、同时

段起飞航空器数量、同时段落地航空器数量;

- Step 4:** 计算 1 小时内平均滑出时间;
- Step 5:** 根据离港航空器的撤轮挡时间得到该航空器所在时段;
- Step 6:** 根据机场图及标准滑出路径得到离港航空器滑行过程中的滑行距离及转弯转角个数。
- Step 7:** 计算上一个时间段(1小时)的延误值。

1.3 相关性分析

基于 SPSS 软件对离港航空器实际滑出时间的影响因素进行相关性分析,分析流程如图 2 所示。基于皮尔逊相关系数、单尾检验结果和检验级别判定各影响因素的相关性。其中,相关性系数在 0~1 之间。

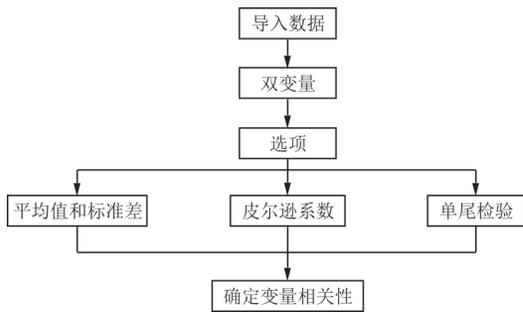


图 2 相关性分析流程图

Fig. 2 Flow chart of correlation analysis

首先将整理好的数据集导入 SPSS 软件, 然后对有相关性的双变量进行分析, 计算皮尔逊相关系数和单尾检验结果, 得到结果如表 3 所示。

表 3 相关性分析结果  
Table 3 Correlation analysis results

影响因素	皮尔逊相关性系数	单尾检验	检验级别
$x_1$	0.554	0.000	0.01
$x_2$	0.633	0.000	0.01
$x_3$	0.632	0.000	0.01
$x_4$	0.546	0.000	0.01
$x_5$	0.532	0.015	非 0.01
$x_6$	0.509	0.031	非 0.01
$x_7$	0.526	0.027	非 0.01
$x_8$	0.095	0.040	非 0.01

皮尔逊相关性系数指的是影响因素与滑出时间的比值, 比值大于 0.5 则表示二者相关, 若同时单尾检验处于 0.01 级别, 则二者显著相关; 且单尾检验的值越小, 则说明两者之间偏差越小。若单尾检验大于 0.01, 则两变量的相关性不显著。若皮尔逊相关性系数小于 0.5, 则说明二者不相关。根据上述规则可依次判断这 8 个可量化因素与滑出时间之间的相关性。

从表 3 可以看出: 同时段推出航空器数量、同时段起飞航空器数量、同时段进港航空器数量、1 小时内平均滑出时间与离港航空器的滑出时间显著相关, 滑行距离、转弯个数、延误与滑出时间相关但不显著, 航空器起飞时刻所在时段与滑出时间不相关。

## 2 模型建立与仿真分析

### 2.1 模型构建

经过数据处理可获得该机场离港航空器数据记录 5 919 条, 结合整理后的可量化影响因素及其

离港滑出时间, 选取 5 500 组数据作为训练集, 419 组数据作为测试集, 选用 Matlab 的 BP 神经网络工具箱编程, 对离港航空器的滑出时间进行训练和预测。

(1) 将离港航空器滑出时间影响因素作为网络的输入数据, 实际滑出时间作为输出导入到 Matlab 中, 建立相应的数据集。

(2) 将样本数据顺序打乱, 筛选出 5 500 组数据作为训练集, 419 组数据作为测试集。

(3) 为加快神经网络收敛速度, 将样本数据进行归一化处理。

$$y = (x - x_{i\min}) / (x_{i\max} - x_{i\min}) \quad (x=1, \dots, 8) \quad (8)$$

(4) 构建 BP 神经网络, 设置神经网络训练参数, 学习率 0.001, 最大迭代次数 10 000 次, 而后对样本数据进行训练。

(5) 待神经网络稳定后, 将测试集数据导入神经网络, 网络输出结果反归一化即可得到离港航空器滑出时间预测结果。

### 2.2 结果分析

考虑可量化的 8 种离港航空器滑出时间影响因素后, 构建基于 BP 神经网络的滑出时间预测模型, 得到预测值与真实值之间的关系, 如图 3 所示。

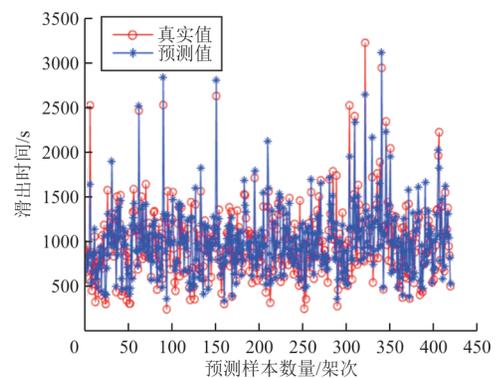


图 3 基于 BP 神经网络的滑出时间预测结果  
Fig. 3 Taxi-out time prediction results based on BP neural network

从图 3 可以看出: 离港航空器滑出时间预测结果与真实值的拟合程度较高,  $R^2=0.8488$ 。

为了进一步验证预测模型的合理性, 基于平均绝对误差百分比 (MAPE)、平均绝对误差 (MAE)、均方根误差 (RMSE) 对模型进行验证, 公式如下<sup>[8]</sup>:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{(X'_i - X_i)}{X_i} \right| \times 100\% \quad (9)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |X'_i - X_i| \quad (10)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (X'_i - X_i)^2} \quad (11)$$

考虑 8 种可量化影响因素的滑出时间 BP 神经网络预测模型所得结果的平均绝对误差百分比为 0.137 0、平均绝对误差为 125.369 2 s、均方根误差为 171.652 1 s。在  $\pm 3$  min 内的误差准确率占 82.8%， $\pm 5$  min 内的误差准确率占 94.9%。为了进一步验证 BP 神经网络应用于离港航空器滑出时间预测的合理性，将其与多元线性回归方法的预测结果进行对比，如表 4 所示。

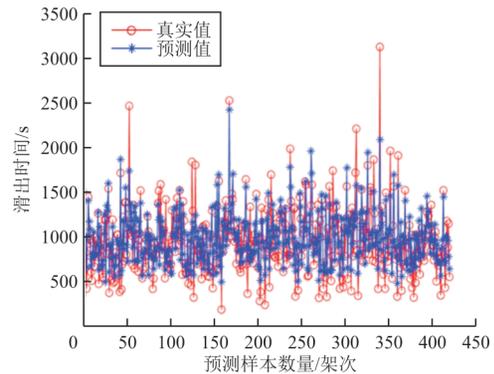
表 4 BP 神经网络与多元线性回归预测结果对比  
Table 4 Comparison of prediction results between BP neural network and multiple linear regression

预测方法	MAPE	MAE/s	RMSE/s	准确率	
				$\pm 3$ min/ %	$\pm 5$ min/ %
BP 神经网络	0.137 0	125.369 2	171.652 1	82.8	94.9
多元线性回归	0.203 5	200.986 4	201.122 3	55.3	78.5

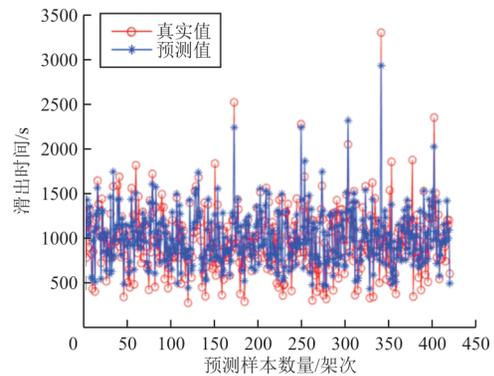
从表 4 可以看出：多元线性回归模型的平均绝对误差百分比为 0.203 5、平均绝对误差为 200.986 4 s、均方根误差为 201.122 3 s。在  $\pm 3$  min 内的误差准确率占 55.3%， $\pm 5$  min 内的误差准确率占 78.5%。各项指标显示，基于 BP 神经网络的离港航空器滑出时间预测精度要明显高于多元线性回归预测结果。

### 2.3 仿真分析

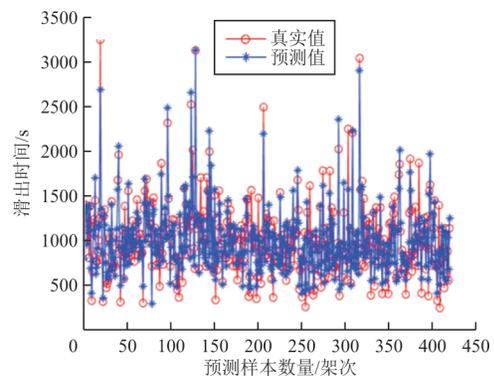
根据相关性分析结果可知，同时段推出航空器数量  $x_1$ 、同时段起飞航空器数量  $x_2$ 、同时段落地航空器数量  $x_3$ 、1 小时内平均滑出时间  $x_4$  与离港航空器滑出时间呈现强相关性；滑行距离  $x_5$ 、转弯个数  $x_6$ 、延误  $x_7$  与滑出时间相关但不显著；航空器起飞时刻所在时段  $x_8$  与滑出时间不相关。其中，前三个因素 ( $x_1, x_2, x_3$ ) 是现有滑出时间预测成果中普遍采用的影响因素，而 1 小时内平均滑出时间  $x_4$  是本文提出的可量化影响因素。为讨论影响因素相关性强弱与模型构建、模型预测结果精度之间的关系，本文将可量化的影响因素进行组合，构建不同维数的滑出时间 BP 神经网络预测模型，得到预测结果对比图如图 4 所示，不同组合预测模型的预测精度及评价结果如表 5 所示。



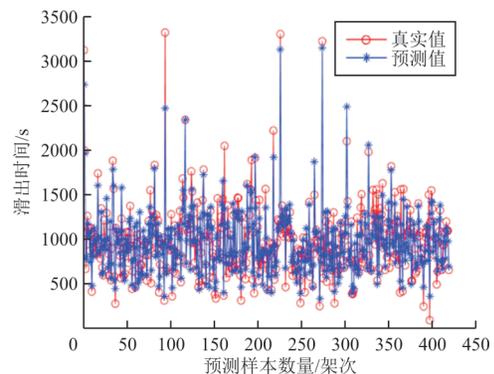
(a) 三组输入预测结果对比 ( $R^2=0.661\ 05$ )



(b) 四组输入预测结果对比 ( $R^2=0.755\ 77$ )



(c) 六组输入预测结果对比 ( $R^2=0.829\ 15$ )



(d) 七组输入预测结果对比 ( $R^2=0.878\ 68$ )

图 4 考虑不同影响因素的预测结果对比

Fig. 4 Comparison of prediction results considering different influencing factors

表5 不同组合预测结果对比分析  
Table 5 Comparative analysis of the different combination predicted results

影响因素组合	变量	MAPE	MAE/s	RMSE/s	准确率 ±3 min/%	准确率 ±5 min/%
三元组	$x_1, x_2, x_3$	0.188 9	148.603 9	215.653 5	68.5	88.5
四元组	$x_1, x_2, x_3, x_4$	0.177 3	152.511 3	215.833 0	71.8	92.6
六元组	$x_1, x_2, x_3, x_5, x_6, x_7$	0.151 1	121.543 6	165.603 6	78.5	94.0
七元组	$x_1, x_2, x_3, x_4, x_5, x_6, x_7$	0.131 7	109.653 5	151.245 4	84.2	96.4
八元组	$x_1, x_2, x_3, x_4, x_5, x_6, x_7, x_8$	0.137 0	125.369 2	171.652 1	82.8	94.9

从图4和表5可以看出:(1)对比三元组和四元组预测结果可知,加入1小时内平均滑出时间后,预测准确率有明显提升;(2)对比七元组和四元组的预测结果可知,在加入有相关性但不显著的因素后,预测准确性也有一定的提高;(3)由于加入了相关但不显著的因素,相比于三元组±5 min内的准确率88.5%,六元组的±5 min内的准确率达到94.0%。在引入1小时内平均滑出时间后,七元组预测结果的准确率相比于六元组的预测结果仍有明显提高,达到96.4%。由此可见,1小时内平均滑出时间对模型精度的提升起到了关键作用;(4)对比七元组和八元组预测结果可知,加入不相关的可量化因素后,预测准确率明显下降。综上所述,考虑强相关性、中度相关性的七元组合预测模型的性能最佳:平均绝对误差百分比仅为0.131 7,平均绝对误差为109.653 5 s,均方根误差为151.245 4 s,预测结果±3 min内的准确率为84.2%,±5 min内的准确率为96.4%。

### 3 结 论

(1) 同时段推出航空器数量、同时段起飞航空器数量、同时段落地航空器数量、1小时内平均滑出时间与离港航空器滑出时间呈现强相关性,滑行距离、转弯个数、延误时间与滑出时间相关但不显著,航空器起飞时刻所在时段与滑出时间不相关。

(2) 基于BP神经网络的离港航空器滑出时间预测结果精度要明显高于基于线性回归模型的预测精度。

(3) 1小时内平均滑出时间对模型精度的提升起到了重要作用,相关性不显著的影响因素引入对预测结果精度的提升有一定的作用,引入不相关因素后模型的预测精度会显著下降。

### 参考文献

- [1] GEORGE E, KHAN S S. Reinforcement learning for taxi-out time prediction: an improved Q-learning approach[C]// 2015 International Conference on Computing and Network Communications (CoCoNet). Trivandrum, India: IEEE, 2015: 1-11.
- [2] LEE H B, MALIK W, JUNG Y C. Taxi-out time prediction for departures at Charlotte airport using machine learning techniques[C]// AIAA Aviation Technology, Integration, and Operations Conference. Washington, USA: AIAA, 2016: 1-17.
- [3] HERREMA F, CURRAN R, VISSER H. Taxi-out time prediction model at Charles de Gaulle Airport[J]. Journal of Aerospace Information Systems, 2018, 15(3): 120-130.
- [4] SIMAIAKIS L, PYRGIOTIS N. An analytical queuing model of airport departure processes for taxi out time prediction[C]// 10th AIAA Aviation Technology, Integration, and Operations (ATIO). Washington, USA: AIAA, 2010: 1-9.
- [5] BALAKRISHNA P, JANESAN R, SHERRY L. Accuracy of reinforcement learning algorithms for predicting aircraft taxi-out times: a case-study of Tampa Bay departures[J]. Transportation Research Part C: Emerging Technologies, 2010, 18(3): 950-962.
- [6] LIAN Guan, ZHANG Yaping, DESAI J, et al. Predicting taxi-out time at congested airports with optimization-based support vector regression method[J]. Mathematical Problems in Engineering: Theory, Methods and Applications, 2018(4): 1-11.
- [7] YIN Jianan, HU Yuxin, MA Yuanyuan, et al. Machine learning techniques for taxi-out time prediction with a macroscopic network topology[C]// AIAA/IEEE 37th Digital Avionics Systems Conference. Los Alamitos, CA, USA: IEEE, 2018: 23-27.
- [8] 邢志伟, 蒋骏贤, 罗晓, 等. 基于贝叶斯网的离港航班滑行时间动态估计[J]. 计算机工程与应用, 2018, 54(24): 66-71, 203.
- [9] XING Zhiwei, JIANG Junxian, LUO Xiao, et al. Dynamic estimation of taxiing time of aircraft departing port based on Bayesian network[J]. Computer Engineering and Applications, 2018, 54(24): 66-71, 203. (in Chinese)
- [9] 刘继新, 尹旻嘉, 朱学华, 等. 基于航班滑出时间的离场影

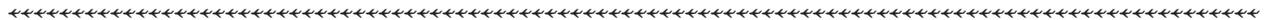
- 响因素研究[J]. 武汉理工大学学报(交通科学与工程版), 2018, 42(2): 195-200.
- LIU Jixin, YIN Minjia, ZHU Xuehua, et al. Research on influencing factors of departure based on aircraft sliding out time [J]. Journal of Wuhan University of Technology (Transportation Science & Engineering), 2018, 42(2): 195-200. (in Chinese)
- [10] 冯霞, 孟金双. 基于排队论的航班滑出时间预测[J]. 南京航空航天大学学报, 2016, 48(5): 772-780.
- FENG Xia, MENG Jinshuang. Prediction of aircraft sliding out time based on queuing theory [J]. Journal of Nanjing University of Aeronautics and Astronautics, 2016, 48(5): 772-780. (in Chinese)
- [11] 李楠, 焦庆宇, 张连东, 等. 离场航空器滑行时间预测研究[J]. 重庆交通大学学报(自然科学版), 2021, 40(3): 1-6.
- LI Nan, JIAO Qingyu, ZHANG Liandong, et al. Study on prediction of taxiing time of departure aircraft [J]. Journal of Chongqing Jiaotong University (Natural Science Edition), 2021, 40(3): 1-6. (in Chinese)
- [12] 疏利生, 李桂芳, 嵇胜. 基于强化学习的航空器机场智能静态路径规划[J]. 航空工程进展, 2021, 12(3): 65-70.
- SHU Lisheng, LI Guifang, JI Sheng. Aircraft AI static path planning on airport ground based on reinforcement learning [J]. Advances in Aeronautical Science and Engineering, 2021, 12(3): 65-70. (in Chinese)
- [13] 陈祯, 唐小卫, 林有超, 等. 基于决策树的航空器离港滑出时间预测方法和模型[J]. 武汉理工大学学报(交通科学与工程版), 2021, 45(3): 448-453.
- CHEN Zhen, TANG Xiaowei, LIN Youchao, et al. Prediction method and model of aircraft taxi-out time based on decision tree [J]. Journal of Wuhan University of Technology (Transportation Science & Engineering), 2021, 45(3): 448-453. (in Chinese)
- [14] 闫萍, 袁媛. 航班滑行路径规划和停机位分配联合优化[J]. 控制工程, 2021, 28(3): 464-470.
- YAN Ping, YUAN Yuan. Joint optimization of airline taxiing path planning and parking assignment [J]. Control Engineering of China, 2021, 28(3): 464-470. (in Chinese)
- [15] 侯盼盼, 王梓旭. 基于分时段与概率分布的滑行冲突预测研究[J]. 航空工程进展, 2020, 11(6): 803-810.
- HOU Panpan, WANG Zixu. Taxi conflict prediction algorithm based on time bucket and probability distribution [J]. Advances in Aeronautical Science and Engineering, 2020, 11(6): 803-810. (in Chinese)

#### 作者简介:

夏正洪(1985—),男,硕士,副教授。主要研究方向:空管自动化应用,机场场面运行效率。

贾鑫磊(1995—),男,硕士研究生。主要研究方向:机场场面运行效率。

(编辑:马文静)



(上接第84页)

- [16] NASIR I M, KHAN M A, YASMIN M, et al. Pearson correlation-based feature selection for document classification using balanced training [J]. Sensors, 2020, 20: 6793.
- [17] CHEN Pengtian, LI Fei, WU Chunwang. Research on intrusion detection method based on Pearson correlation coefficient feature selection algorithm [J]. Journal of Physics: Conference Series, 2021, 1757: 012054.
- [18] PAN Han, YOU Xiaoming, LIU Sheng, et al. Pearson correlation coefficient-based pheromone refactoring mechanism for multi-colony ant colony optimization [J]. Applied Intelligence, 2021, 51(2): 752-774.
- [19] 张勇军. 我国航空航天制造业竞争力研究[D]. 哈尔滨: 哈尔滨工程大学, 2017.
- ZHANG Yongjun. Research on the competitiveness of China's aerospace manufacturing industry [D]. Harbin: Harbin Engineering University, 2017. (in Chinese)
- [20] 郑金华. 基于超声的热障涂层厚度检测方法研究[D]. 南昌: 南昌航空大学, 2014.
- ZHENG Jinhua. Research on detection method of thermal barrier coating thickness based on ultrasonic [D]. Nanchang: Nanchang Hangkong University, 2014. (in Chinese)
- [21] 余映红. 基于深度学习的航空发动机气路参数基线建模和趋势预测研究[D]. 厦门: 厦门大学, 2019.
- YU Yinghong. Deep learning-based baseline model and trend prediction of aeroengine gas path parameter [D]. Xiamen: Xiamen University, 2019. (in Chinese)

#### 作者简介:

黄世杰(1998—),男,硕士研究生。主要研究方向:飞行器适航技术,持续适航技术。

蔡景(1976—),男,博士,副教授。主要研究方向:飞行器适航技术,持续适航技术。

何盛(1991—),男,学士,助理工程师。主要研究方向:交通运输飞机维修。

(编辑:马文静)