

基于机器学习的大型机场离港滑行时间预测

李楠¹, 吴龙添^{1,2}, 郝锦彪³, 许瑞³

(1. 中国民航大学空中交通管理学院, 天津 300300; 2. 山西通用航空职业技术学院航空运输系, 山西 大同 037000;
3. 北京大兴国际机场运行管理部, 北京 102604)

摘要: 为了提高大型机场离港滑行时间预测的准确性, 首先, 本文通过皮尔逊相关系数分析确定大型机场离港滑行时间的共同特征变量; 然后, 使用经典机器学习和深度学习模型对北京大兴国际机场和香港赤鱘角国际机场的离港滑行时间进行预测比较。实验结果表明, 除随机森林(RF, random forest)模型以外, 每个模型的预测结果都较接近且效果较好, 预测精度平均为 88.485%, ± 3 min 预测精度平均为 78.605%, ± 5 min 预测精度平均为 93.867%; 梯度提升回归树(GBRT, gradient boosting regression tree)和支持向量回归(SVR, support vector regression)模型的预测性能优于其他模型, 为最佳预测模型, 且对于同一个最佳预测模型, 2个机场的预测结果差别不大。本文提出的离港滑行时间共同特征变量能够准确预测大型机场的离港滑行时间, 经典机器学习模型的预测效果优于深度学习模型, 且最佳预测模型具有可移植性。

关键词: 经典机器学习; 深度学习; 大型机场; 离港滑行时间预测

中图分类号: V352

文献标志码: A

文章编号: 1674-5590(2026)01-0017-08

Prediction of taxi-out time for large airports based on machine learning

LI Nan¹, WU Longtian^{1,2}, HAO Jinbiao³, XU Rui³

(1. College of Air Traffic Management, CAUC, Tianjin 300300, China; 2. Department of Air Transportation, Shanxi General Aviation Polytechnic, Datong 037000, Shanxi, China; 3. Operation Management Department, Beijing Daxing International Airport, Beijing 102604, China)

Abstract: To improve the accuracy of taxi-out time prediction for large airports, this paper first identifies common feature variables of taxi-out time at large airports through Pearson correlation coefficient analysis. Then, it compares predictions of taxi-out time at Beijing Daxing International Airport and Hong Kong Chek Lap Kok International Airport using classical machine learning and deep learning models. Experimental results show that, except for the random forest (RF) model, the prediction results of each model are relatively close and perform well, with an average prediction accuracy of 88.485%, an average prediction accuracy of 78.605% within ± 3 minutes, and an average prediction accuracy of 93.867% within ± 5 minutes. The gradient boosting regression tree (GBRT) and support vector regression (SVR) models outperform the others and are the best-performing models, and for the same best-performing model, the prediction results between the two airports show little difference. The common feature variables of taxi-out time proposed in this paper can accurately predict taxi-out time at large airports. Classical machine learning models achieve better prediction performance than deep learning models, and the best-performing model demonstrates transferability.

Key words: classical machine learning; deep learning; large airports; taxi-out time prediction

离港滑行时间是指飞机从停机位撤轮挡时刻开始到起飞离地时刻之间的时间段, 包括了机坪滑行时间、滑行道滑行时间及跑道上的起飞时间。大型机场跑滑系统结构复杂、机场场面交通流量大, 离港高峰时段不合理的推出率会导致飞机在机场场面上长时

间滑行及排队等待, 造成机场场面运行效率低下。离港滑行时间是飞机推出控制的基础和计算推出时刻的关键要素。准确预测离港滑行时间有利于减少飞机滑行等待时间, 提升机场运行效率。

国内外学者在离港滑行时间影响因素和预测模

型上的研究已经取得了相应的研究成果。Idris 等^[4]研究了机场场面飞机数量及滑行距离对飞机离港滑行时间的影响,并建立多元线性回归模型对波士顿洛根国际机场的离港滑行时间进行预测,但考虑的影响因素较少。文献[2-4]研究了机场场面进离港飞机数量、滑行距离、航空公司等影响离港滑行时间的因素。Lee 等^[5]研究了飞机等级、跑道运行方向等离港滑行时间的影响因素,并利用线性回归、支持向量机等机器学习模型对夏洛特道格拉斯国际机场的离港滑行时间进行预测,但预测准确度较低。Chatterji 等^[6]研究了航班推出前 15 min 的平均滑出延误时间、推出航班数量、气象条件等离港滑行时间影响因素,并基于神经网络模型对达拉斯沃思堡国际机场进行离港滑行时间预测,但未考虑跑道配置及运行时段的影响。文献[7-9]研究了跑道配置、运行时段、流量控制等离港滑行时间影响因素的差异,并应用机器学习和深度学习模型进行回归预测,但研究表明流量控制对预测精度无提升作用。刘家学等^[10]基于自回归积分滑动平均 (ARIMA, autoregressive integrated moving average) - 支持向量回归 (SVR, support vector regression) 组合模型对西安咸阳国际机场离港滑行时间进行预测且预测精度可达 90%, 但该组合模型的稳定性不佳。赵征等^[11]基于极端梯度提升 (XGBoost, extreme gradient boosting) 模型对广州白云国际机场进离港滑行时间进行了预测, 但该预测结果不具有一般性, 无法应用于其他大型机场。黄龙杨等^[12]基于遗传算法 (GA, genetic algorithm) 优化后的反向传播 (BP, back propagation) 算法对中南某枢纽机场可变离港滑行时间进行预测, GA 优化后的 BP 算法预测准确度得到了提升, 但该算法只考虑单个机场, 对于其他机场的应用效果未知。

综上所述, 以上研究成果为本文研究离港滑行时间影响因素及预测方法提供了思路。然而, 已有的研究结果不能直接应用于其他大型机场, 缺少确定的共同特征变量, 无法对大型机场离港滑行时间进行准确预测。同时, 现有的研究针对的是单个机场, 提出的预测方法无法应用于其他大型机场。因此, 本文以北京大兴国际机场 (四字代码为 ZBAD) 和香港赤鱗角国际机场 (四字代码为 VHHH) 为研究对象, 首先, 采用文献分析法初步确定了一些影响大型机场离港滑行时间的特征变量, 保留与 2 个机场均具有相关性的特征变量, 并剔除不相关的特征变量, 从而确定大型机场离港滑行时间的共同特征变量; 其次, 采用经典机器学习和深度学习模型对 2 个大型机场的离港滑行时间进行预测; 最后, 比较分析各模型在 2 个机场的

预测结果。本文提出的离港滑行时间共同特征变量能够准确预测大型机场的离港滑行时间, 且最佳预测模型具有可移植性。

1 数据来源

本文以 ZBAD 和 VHHH 为研究对象, 2 个机场的机场场面布局如图 1 所示。多跑道运行是大型机场的重要特点之一, 不同的跑道运行规则对离港滑行效率存在一定影响。对于 ZBAD, 当机场向北运行时, 35R、11L 为主要离港跑道, 01L、35L 为主要进港跑道; 当机场向南运行时, 17L、11L 为主要离港跑道, 19R、17R 为主要进港跑道。对于 VHHH, 跑道运行采用独立分隔起降模式, 07L/25R 只作为进港跑道, 07R/25L 只作为离港跑道。




图1 ZBAD 和 VHHH 的场面布局图

Fig.1 Airfield layout of ZBAD and VHHH

在离港滑行时间预测任务上, 采用当月数据划分训练集和测试集进行模型训练与预测, 准确度会比含有跨月数据的更高。因此, 本文选取了 ZBAD 一个月内的原始运行数据 11 054 条, VHHH 一周的原始运行数据 4 406 条, 进行降噪处理后得到有效数据分别为 10 605 条和 4 183 条。数据信息包含日期、航班号、

机型、停机位、跑道、实际撤轮挡时刻、实际起飞时刻。

根据离港滑行时间的定义,离港滑行时间 $t_{\text{taxi-out}}$ 等于飞机实际起飞离地时刻 t_{atd} 减去飞机实际撤轮挡时刻 t_{pus} , 即

$$t_{\text{taxi-out}} = t_{\text{atd}} - t_{\text{pus}} \quad (1)$$

按照式(1)对 2 个机场的离港滑行时间进行计算,离港滑行时间分布和统计特征分别如图 2 和表 1 所示。




图 2 ZBAD 和 VHHH 的离港滑行时间分布

Fig.2 Taxi-out time distribution at ZBAD and VHHH

表 1 ZBAD 和 VHHH 的离港滑行时间统计特征

Tab.1 Statistical characteristics of taxi-out time at ZBAD and VHHH

机场	均值/ min	标准差/ min	最小值/ min	第一分 位数	中位数	第三分 位数	最大值/ min
ZBAD	18.5	7.0	5.0	14.0	17.0	21.0	73.0
VHHH	20.6	6.7	4.0	16.0	20.0	24.0	67.0

从图 2 可知,ZBAD 滑行时间呈现偏态分布,属于对数正态分布,而 VHHH 滑行时间呈现对称分布,也属于正态分布,均满足模型对数据样本服从正态分布的要求。从表 1 可知,ZBAD 平均滑行时间小于VHHH,但标准差大于 VHHH,说明 ZBAD 离港滑行时间波动性较大。表 1 中的第一分位数和第三分位数表明了 ZBAD 离港滑行时间集中在 14.0~21.0 min,VHHH 离港滑行时间集中在 16.0~24.0 min。

2 影响离港滑行时间的特征变量

虽然不同机场场面布局、跑滑构型、运行规则及人为因素等会导致影响离港滑行时间的特征变量有所不同,但这些共同特征变量均与滑行时间具有相关性,而差异特征变量对离港滑行时间影响并不显著或不相关,剔除不相关特征变量以减少对离港滑行时间模型的影响。因此,本文通过文献分析法初步确定了同时段机场场面进港航班数量、同时段机场场面离港航班数量、同时段机场场面活动的航班数量、同时段起飞航班数量、同时段起降航班数量、推出前 15 min 平均滑行时间、滑行距离、机型类别、运行时段、离港跑道、航空公司等作为研究大型机场离港滑行时间的共同特征变量;然后进一步分析这些特征在 ZBAD 和 VHHH 的相关性;最后以共同特征变量在 ZBAD 和 VHHH 均存在相关性确定大型机场影响离港滑行时间的共同特征变量。

2.1 共同特征变量定义

1)同时段机场场面进港航班数量 F_1

若进港航班 j 的落地时刻 $t_{\text{ata},j}$ 在离港航班 i 的撤轮挡时刻 $t_{\text{pus},i}$ 之后,且在离港航班 i 起飞离地时刻 $t_{\text{atd},i}$ 之前的所有机场场面进港航班数量 $F_{1,i}$ 会对离港航班 i 有影响,即

$$F_{1,i} = \sum_{j=1}^{n_1} \text{count}(j) \quad t_{\text{pus},i} < t_{\text{ata},j} < t_{\text{atd},i} \quad (2)$$

式中, n_1 表示进港航班数量。

2)同时段机场场面离港航班数量 F_2

若离港航班 m 的撤轮挡时刻 $t_{\text{pus},m}$ 在离港航班 i 的撤轮挡时刻 $t_{\text{pus},i}$ 之后,且在离港航班 i 起飞离地时刻 $t_{\text{atd},i}$ 之前的所有离港航班数量 $F_{2,i}$ 会对离港航班 i 有影响,即

$$F_{2,i} = \sum_{m=1}^{n_2} \text{count}(m) \quad t_{\text{pus},i} < t_{\text{pus},m} < t_{\text{atd},i} \quad (3)$$

式中, n_2 表示离港航班数量。

3)同时段机场场面活动的航班数量 F_3

离港航班 i 滑行期间机场场面活动的航班数量 $F_{3,i}$ 等于同时段机场场面进港航班数量与同时段机场场面离港航班数量之和,即

$$F_{3,i} = \sum_{i=1}^{n_3} (F_{1,i} + F_{2,i}) \quad (4)$$

式中, n_3 表示进港与离港航班数量之和。

4)同时段起飞航班数量 F_4

若离港航班 p 的起飞离地时刻 $t_{\text{atd},p}$ 在离港航班 i

的撤轮挡时刻 $t_{pus,i}$ 之后,且在离港航班 i 起飞离地时刻 $t_{ald,i}$ 之前的所有起飞航班数量 $F_{4,i}$ 会对离港航班 i 有影响,即

$$F_{4,i} = \sum_{p=1}^{n_2} \text{count}(p) \quad t_{pus,i} < t_{ald,p} < t_{ald,i} \quad (5)$$

5) 同时段起降航班数量 F_5

离港航班 i 滑行期间起降航班数量 $F_{5,i}$ 等于同时段场面进港航班数量与同时段起飞航班数量之和,即

$$F_{5,i} = \sum_{i=1}^{n_3} (F_{1,i} + F_{4,i}) \quad (6)$$

6) 推出前 15 min 平均滑行时间 F_6

离港航班 i 撤轮挡时刻减去 15 min 之内的所有起飞航班 q 的平均滑行时间 $F_{6,i}$ 可表示为

$$F_{6,i} = \frac{\sum_{q=1}^{n_2} \text{sum}[t_{\text{taxi-out},q}]}{n_2} \quad t_{pus,i} - 15 \text{ min} < t_{pus,q} < t_{pus,i} \text{ 且 } t_{ald,q} < t_{ald,i} \quad (7)$$

7) 滑行距离 F_7

大型机场场面布局复杂,导致飞机滑行距离变长,离港滑行时间增加。航班滑行距离与停机位、滑行路径、起飞跑道、推出机头朝向等有关,计算滑行距离要首先根据机场运行规则,确定飞机推出机头朝向,再将停机位与起飞跑道之间使用频率最多的滑行路径作为该机位主流滑行路径,然后使用地图测量工具得到航班的滑行距离。

8) 机型类别 F_8

在大型机场既有国际航班也有国内航班,根据航班性质差异会使用不同机型执行航班,而不同机型的平均滑行速度会有所不同,导致滑行时间有所差异。本文根据中国民航《航班安全运行保障标准》^[13]将机型分为 5 类,具体为:60 座以下 A 类,61~150 座 B 类,151~250 座 C 类,251~500 座 D 类,500 座以上 E 类。

9) 运行时段 F_9

在一天的不同运行时段下,机场场面交通流呈现高峰和平稳 2 个时段,这是每一个大型机场共同存在的特点。高峰时段下机场场面航班数量增多且机场资源有限,导致高峰时段平均滑行时间大于平稳时段。本文根据每小时平均滑行时间对一天的运行时段进行分类。

10) 离港跑道 F_{10}

离港跑道分配与机场跑道运行规则有关,不同离港跑道会间接影响滑行距离,从而导致滑行时间差异。对于多跑道的大型机场,在运行高峰时段,由于机场场面进离港飞机数量叠加,飞机穿越跑道次数增多,

也会影响当前跑道的使用,从而导致滑行时间不同。

11) 航空公司 F_{11}

离港航班的推出速度和滑行速度会因不同航空公司而存在区别,导致不同航空公司的平均滑行时间存在差异。除此之外,航空公司原因造成航班延误也会导致离港滑行时间过长。

2.2 皮尔逊相关系数分析

皮尔逊相关系数 ρ 是统计学中用于量化 2 个变量之间线性相关程度的指数。本文对所提出的特征变量与离港滑行时间进行皮尔逊相关系数分析。当 $0.8 < \rho \leq 1.0$ 时,表示极强相关;当 $0.6 < \rho \leq 0.8$ 时,表示强相关;当 $0.4 < \rho \leq 0.6$ 时,表示中等程度相关;当 $0.2 < \rho \leq 0.4$ 时,表示弱相关;当 $0 \leq \rho \leq 0.2$ 时,表示极弱相关或不相关;当 $\rho < 0$ 时,表示负相关。文献[14]研究表明,引入具有相关性但不具备显著性的特征变量对模型预测精度有提升作用,而引入不相关的特征变量会导致预测精度显著下降。因此,本文剔除不相关的特征变量,将其余特征变量作为影响大型机场滑行时间的共同特征变量。

ZBAD 和 VHHH 的皮尔逊相关系数 ρ 和显著性水平 p 如表 2 所示,其中,显著性水平检验标准为 $p = 0$ 。

表 2 各特征变量与离港滑行时间的皮尔逊相关系数分析结果

Tab.2 Results of Pearson correlation coefficient analysis between the characteristic variables and taxi-out time

特征变量	皮尔逊相关系数 ρ		显著性水平 p	
	ZBAD	VHHH	ZBAD	VHHH
F_1	0.632**	0.729**	0	0
F_2	0.622**	0.683**	0	0
F_3	0.834**	0.790**	0	0
F_4	0.677**	0.711**	0	0
F_5	0.861**	0.800**	0	0
F_6	0.525**	0.586**	0	0
F_7	0.406**	0.233**	0	0
F_8	0.132	-0.002	0.141	0.920
F_9	0.133**	0.247**	0	0
F_{10}	0.163**	-0.179**	0	0
F_{11}	-0.140**	-0.073**	0	0

注:** 表示在 0.01 级别(双尾),相关性显著。

从表 2 可知,对于 ZBAD 和 VHHH, $F_1 \sim F_6$ 与离港滑行时间的皮尔逊相关系数均在 0.5 以上,说明离港滑行时间主要受交通流影响。对于 ZBAD, F_7 与离港滑行时间呈现中等程度相关,而 VHHH 表现为弱相关,说明滑行距离并不是大型机场离港滑行时间的主要影响因素,但可以作为大型机场影响离港滑行时间的共同特征变量。对于 2 个机场,由于 F_8 均不具有显著性 ($p > 0$),因此,与离港滑行时间没有相关性, F_9 对 ZBAD

的离港滑行时间表现为极弱相关,对 VHHH 表现为弱相关, F_{10} 对 ZBAD 的离港滑行时间表现为极弱相关,对 VHHH 则表现为负相关, F_{11} 对 ZBAD 和 VHHH 的离港滑行时间均表现为负相关。因此,在选取影响大型机场离港滑行时间的共同特征变量时,考虑剔除不相关和负相关的特征变量,保留具有相关性的特征变量,将 $F_1 \sim F_7$ 及 F_9 作为共同特征变量。同时,这些共同特征变量在 ZBAD 和 VHHH 全部通过显著性检验 ($p=0$)。

3 离港滑行时间预测模型

近年来,机器学习在各领域已被广泛应用。本文依据是否借鉴人类神经元组成将机器学习分为经典机器学习和深度学习,使用二者来预测离港滑行时间,对比各模型预测性能,从而获得最佳的预测模型。

3.1 经典机器学习

经典机器学习是指基于统计学习理论的算法,通过从大量数据中学习模型来自动化处理数据,从而实现预测或分类等任务。经典机器学习算法包括线性回归、逻辑回归、决策树、支持向量机等。这些算法通常不涉及神经网络技术,因此,被称为经典机器学习。本文采用梯度提升回归树(GBRT, gradient boosting regression tree)、随机森林(RF, random forest)、SVR、LASSO(least absolute shrinkage and selection operator)、k 最近邻(k-NN, k-nearest neighbor)进行离港滑行时间预测。

3.2 深度学习

深度学习是一种基于多层神经网络结构的机器学习技术,是人工智能领域最具代表性的技术之一。深度学习通过多层神经网络来学习数据中的特征和规律,从而实现自动数据分类、预测和生成等任务。本文采用长短期记忆(LSTM, long short-term memory)网络、深度神经网络(DNN, deep neural networks)、卷积神经网络(CNN, convolutional neural network)进行离港滑行时间预测。

3.3 模型评价指标

1) 准确度 P_{accuracy}

预测模型的准确度是衡量预测值与真实值的符合程度,当预测值越符合真实值,则准确度越大,计算方法为

$$P_{\text{accuracy}} = \left(1 - \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \right) \times 100\% \quad (8)$$

式中: y_i 表示航班 i 离港滑行时间真实值; \hat{y}_i 表示航班 i 离港滑行时间预测值; n 表示预测的离港航班总数。

2) 决定系数 R^2

R^2 反映因变量的全部变动能通过回归关系被自变量解释的比例, R^2 介于 0~1 之间,当 R^2 越趋近于 1 时,表明回归关系越能解释因变量的变异,即模型的拟合优度越好。计算方法为

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n \left(y_i - \frac{1}{n} \sum_{i=1}^n y_i \right)^2} \quad (9)$$

3) 平均绝对误差 E_{MAE}

E_{MAE} 用于测量预测值和实际值之间的平均绝对偏差, E_{MAE} 越小,表明模型预测误差越小,计算方法为

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

4) 均方根误差 E_{RMSE}

均方根误差 E_{RMSE} 也是衡量模型预测性能的重要指标, E_{RMSE} 越小,表明模型预测误差越小,计算方法为

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

5) $\pm 3 \text{ min}$ 、 $\pm 5 \text{ min}$ 的预测精度

计算预测值与真实值之间的残差在 $\pm 3 \text{ min}$ 、 $\pm 5 \text{ min}$ 的预测精度。

4 模型参数确定与比较分析

4.1 模型参数确定

在机器学习中,需要对算法中的超参数进行调整,使模型能更好地学习到数据中规律,从而提高模型预测性能。首先,将数据集划分为训练集(80%)和测试集(20%);其次,使用 MinMax Scaler 函数对数据集进行标准化,并对模型进行初始训练和测试;然后,基于网格搜索调整超参数,以均方根误差 E_{RMSE} 作为评价标准并使用 5 折交叉验证。在深度学习中,通过不断训练迭代并根据损失值、平均绝对误差 E_{MAE} 下降情况调整学习率和迭代次数,对模型设置早期停止,防止过拟合。最终,各种模型的最佳超参数配置如表 3 所示,未列出的参数为默认值。其中,RF 模型表现出过拟合情况,列出的超参数没有意义,故舍去。

4.2 比较分析

不同模型下 ZBAD 和 VHHH 的离港滑行时间预测评价结果如表 4 和表 5 所示。对于预测性能,除

表3 各种模型的最佳超参数

Tab.3 Optimal hyperparameters for various models

模型	超参数	
	ZBAD	VHHH
GBRT	子采样为 0.9; 内部节点再划分所需最小样本数为 9; 叶子节点最少样本数为 3; 树的最大深度为 4; 划分时考虑的最大特征数为 4	子采样为 0.8; 内部节点再划分所需最小样本数为 5; 叶子节点最少样本数为 1; 树的最大深度为 4; 划分时考虑的最大特征数为 4
SVR	错误项的惩罚系数为 1; 容忍偏差为 0.1	错误项的惩罚系数为 1; 容忍偏差为 0.1
LASSO	正则化强度为 0.000 1	正则化强度为 0.000 1
k-NN	最近邻居数量为 28	最近邻居数量为 7
LSTM	特征维数为(1, 8) 隐藏层大小为 100	特征维数为(1, 8) 隐藏层大小为 100
DNN	特征维数为(8, none) 隐藏层大小为 64 学习率为 0.001	特征维数为(8, none) 隐藏层大小为 64 学习率为 0.001
CNN	特征维数为(4, 4, 1) 隐藏层大小为 256 学习率为 0.01	特征维数为(4, 4, 1) 隐藏层大小为 256 学习率为 0.01

了 RF 模型表现过拟合数据不能采用外, 其他模型的预测精度和误差都比较接近且较好。根据所提出的共同特征变量进行预测, 2 个机场的预测准确度平均为 88.485%, 最高可达 89.883%, ±3 min 的预测精度平均为

78.605%, 最高可达 82.445%, ±5 min 的预测精度平均为 93.867%, 最高可达 95.374%, 表明这些共同特征变量能够准确预测大型机场离港滑行时间。

在经典机器学习模型上, GBRT、SVR 模型在 2 个机场的预测性能优于其他模型, 为最佳预测模型。最佳性能指标主要分布于经典机器学习模型中, 表明在离港滑行时间预测上, 经典机器学习模型优于深度学习模型。RF 模型在 2 个机场均表现过拟合, 其训练时表现很好, 而测试时表现很差, 是典型的模型过拟合特征。如图 3 和图 4 所示, RF 模型的学习曲线中训练集与测试集间隔拉大, 说明模型存在过拟合, 而其他模型的学习曲线和损失曲线呈现收敛状态。对于深度学习模型, CNN 模型在 2 个机场的预测性能最差, DNN 模型其次, LSTM 模型预测性能最好。

对于同一个最佳预测模型, 在不同机场的预测效果差别不大。GBRT 模型在 2 个机场的预测精度差别为 1.424%, ±3 min 预测精度差别为 2.649%, ±5 min 预测精度差别为 0.163%。SVR 模型在 2 个机场的预测精度差别为 0.894%, ±3 min 预测精度差别为 2.032%, ±5 min 预测精度差别为 1.007%。数据表明在相同特征变量下, 最佳预测模型在移植到另一个机场时能够保持良

表4 不同模型下针对 ZBAD 的预测评价结果

Tab.4 Evaluation results of prediction for ZBAD using different models

模型	$P_{accuracy}/\%$		R^2/min		E_{MAE}/min		E_{RMSE}/min		±3 min 预测精度/%		±5 min 预测精度/%	
	训练集	测试集	训练集	测试集	训练集	测试集	训练集	测试集	训练集	测试集	训练集	测试集
GBRT	89.497	88.459	0.789	0.751	1.752	1.918	2.263	2.457	83.288	79.675	96.689	95.078
RF	95.643	88.257	0.962	0.732	0.731	1.966	0.955	2.529	99.323	78.444	99.963	94.734
SVR	89.767	88.901	0.777	0.747	1.728	1.885	2.299	2.462	83.386	80.413	96.037	94.832
LASSO	87.831	87.612	0.723	0.706	2.031	2.054	2.592	2.647	77.355	76.345	94.711	94.783
k-NN	89.024	88.258	0.761	0.737	1.856	1.972	2.410	2.527	81.540	78.641	95.668	94.537
LSTM	89.015	88.472	0.753	0.738	1.880	1.930	2.456	2.497	80.630	79.232	95.323	95.029
DNN	88.793	87.866	0.771	0.736	1.852	1.983	2.363	2.507	80.999	77.805	96.320	95.374
CNN	88.099	87.770	0.718	0.708	2.030	2.031	2.630	2.636	78.230	76.378	93.942	94.045

注: 加粗表示该性能指标最佳。

表5 不同模型下针对 VHHH 的预测评价结果

Tab.5 Evaluation results of prediction for VHHH using different models

模型	$P_{accuracy}/\%$		R^2/min		E_{MAE}/min		E_{RMSE}/min		±3 min 预测精度/%		±5 min 预测精度/%	
	训练集	测试集	训练集	测试集	训练集	测试集	训练集	测试集	训练集	测试集	训练集	测试集
GBRT	91.491	89.883	0.853	0.812	1.567	1.860	2.052	2.500	86.886	82.324	97.698	94.915
RF	96.391	90.057	0.975	0.811	0.671	1.810	0.919	2.544	99.030	82.203	1.000	95.278
SVR	90.848	89.795	0.846	0.805	1.678	1.836	2.316	2.588	84.464	82.445	95.729	93.825
LASSO	87.809	87.232	0.739	0.734	2.276	2.254	3.013	3.025	72.562	72.518	89.521	89.588
k-NN	91.159	89.293	0.860	0.792	1.639	1.950	2.205	2.671	86.190	80.750	96.517	93.825
LSTM	90.416	89.709	0.829	0.809	1.777	1.912	2.428	2.625	83.282	80.508	94.609	94.188
DNN	90.163	88.836	0.850	0.800	1.727	1.960	2.275	2.690	84.161	79.540	96.365	94.067
CNN	87.674	85.362	0.761	0.726	2.270	2.408	2.892	3.149	64.688	70.460	81.980	87.772

注: 加粗表示该性能指标最佳。

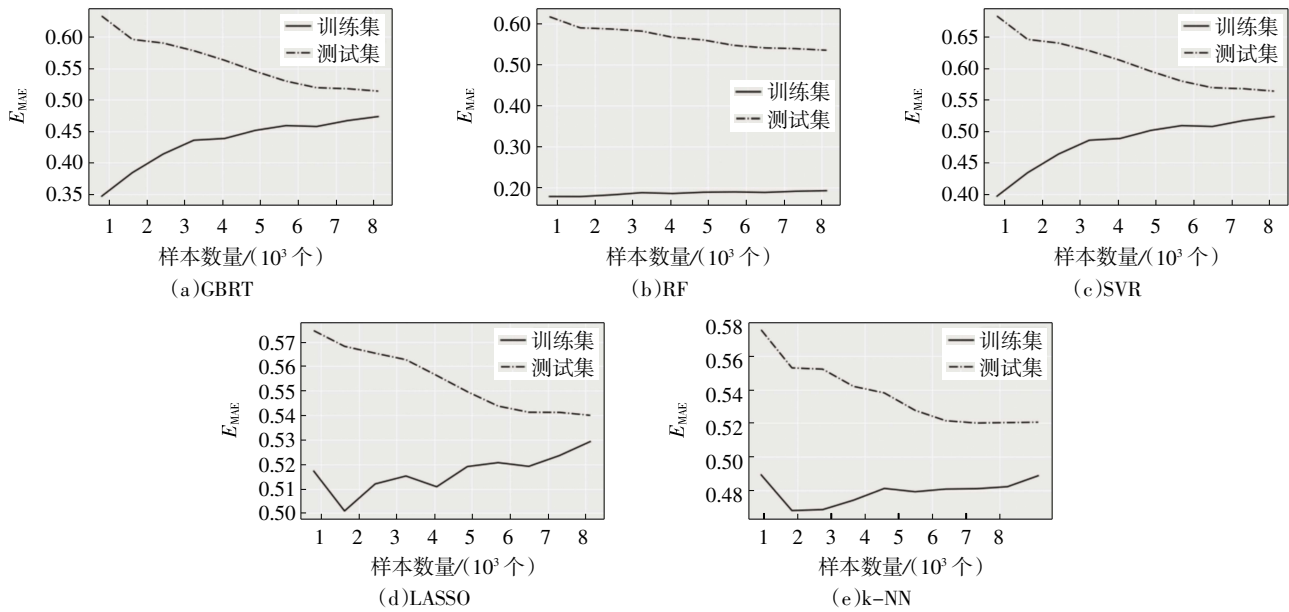


图 3 ZBAD 经典机器学习模型学习曲线

Fig.3 Learning curves of classical machine learning models on ZBAD




图 4 ZBAD 深度学习模型损失曲线

Fig.4 Loss curves of deep learning models on ZBAD

好的预测性能,即模型具有可移植性。

4.3 样本数据量对实验结论的影响

由于 ZBAD 和 VHHH 的数据规模存在较大差异,为了验证即使存在数据规模差异,也不影响得到的实验结论,因此,本文设计了一组对比实验,将 VHHH 数

据量进行减半,然后重新进行实验,通过比较同一机场的 2 组不同数据规模的实验结果,判断是否能得到相同的实验结论。如果对比实验结果相同,则说明可以得到相同的实验结论,从而验证了数据规模差异不影响实验结论。对比实验结果如表 6 所示。

表 6 数据量减半下不同模型针对 VHHH 的预测结果

Tab.6 Prediction results of different models for VHHH with half of the data

模型	$P_{accuracy}/\%$		R^2/min		E_{MAE}/min		E_{RMSE}/min		$\pm 3\text{min}$ 预测精度/ $\%$		$\pm 5\text{min}$ 预测精度/ $\%$	
	训练集	测试集	训练集	测试集	训练集	测试集	训练集	测试集	训练集	测试集	训练集	测试集
GBRT	90.911	89.821	0.859	0.788	1.608	1.879	2.083	2.510	87.238	78.934	97.523	95.939
RF	96.132	90.580	0.971	0.807	0.693	1.765	0.940	2.397	99.111	81.218	99.809	96.192
SVR	90.759	89.934	0.835	0.789	1.658	1.829	2.247	2.510	85.333	79.695	96.127	94.670
LASSO	87.495	87.403	0.712	0.696	2.247	2.277	2.974	3.014	73.460	73.604	91.682	89.593
k-NN	90.809	89.081	0.839	0.745	1.673	2.039	2.225	2.754	86.603	78.426	96.698	93.908
LSTM	89.365	88.430	0.790	0.740	1.902	2.038	2.554	2.765	79.682	75.380	94.730	92.385
DNN	89.708	87.640	0.834	0.751	1.748	2.101	2.265	2.704	82.666	73.096	96.761	93.908
CNN	86.343	85.971	0.625	0.594	2.610	2.619	3.401	3.453	65.702	65.228	86.591	87.817

注:加粗表示该性能指标最佳。

从表6可以看出,模型仍表现出较好的预测性能,其中RF模型表现出过拟合。最佳性能指标分布特点集中在经典机器学习模型上。GBRT和SVR为最佳预测模型。实验结果与表5呈现出相同特点,说明在数据规模减半的情况下仍可以得到相同结论,因此,证明了2个机场数据规模的差异不影响实验结论。

5 结语

本文通过皮尔逊相关系数确定了影响大型机场离港滑行时间的共同特征变量,并基于这些共同特征变量得出ZBAD和VHHH 2个大型机场离港滑行时间的预测准确度平均为88.485%, ± 3 min预测精度平均为78.605%, ± 5 min预测精度平均为93.867%,表明这些共同特征变量能够准确预测大型机场离港滑行时间。

(1)在最佳性能指标上,主要分布在经典机器学习模型中,经典机器学习模型相比深度学习模型在离港滑行时间预测上有更好的预测性能。同时说明了在模型选择上,应根据任务选择模型,复杂模型不一定适用简单任务。

(2)与其他离港滑行时间预测研究相比,本文采用多模型、多机场进行预测对比,在特征相同的情况下,同一最佳模型应用于不同机场仍可保持良好预测性能,表明了共同特征变量和最佳模型具有可移植性。

(3)若各影响因素之间存在高度的相关性,可能导致多重共线性问题。多重共线性是指在线性回归模型中,由于解释变量之间存在高度相关关系而使模型预测不准确。本文使用的模型均为非线性回归,且机器学习模型具有抗多重共线性功能,对预测结果不会产生影响。

本文仅研究了11个影响大型机场离港滑行时间的特征变量,最后确定了8个共同特征变量,未来将进一步研究更多因素对离港滑行时间的影响,如转弯角数量、天气等,以挖掘更多共同特征变量,提高模型预测精度。同时,本文模型在调整超参数时使用网格搜索方法,未来将采用智能算法优化超参数。

参考文献:

- [1] IDRIS H, CLARKE J P, BHUVA R, et al. Queuing model for taxi-out time estimation[J]. Air Traffic Control Quarterly, 2002, 10(1): 1-22.
- [2] CLEWLOW R, SIMAIAKIS I, BALAKRISHNAN H. Impact of arrivals on departure taxi operations at airports[C]//AIAA Guidance, Navigation, and Control Conference, August 2-5, 2010, Toronto, Ontario, Canada. Reston, Virginia: AIAA, 2010: 7698.
- [3] KISTLER M, GUPTA G. Relationship between airport efficiency and surface traffic[C]//9th AIAA Aviation Technology, Integration, and Operations Conference (ATIO), September 21-23, 2009, Hilton Head, South Carolina. Reston, Virginia: AIAA, 2009: 7078.
- [4] JORDAN R, ISHUTKINA M A, REYNOLDS T G. A statistical learning approach to the modeling of aircraft taxi time[C]//29th Digital Avionics Systems Conference, October 3-7, 2010, Salt Lake City, UT, USA. IEEE, 2010: 1. B. 1-1-1. B. 1-10.
- [5] LEE H, MALIK W, JUNG Y C. Taxi-out time prediction for departures at charlotte airport using machine learning techniques[C]//16th AIAA Aviation Technology, Integration, and Operations Conference, June 13-17, 2016, Washington DC. Reston, Virginia: AIAA, 2016: 3910.
- [6] CHATTERJI G, ZHENG Y. Wheels-off time prediction using surface traffic metrics[C]//12th AIAA Aviation Technology, Integration, and Operations (ATIO) Conference and 14th AIAA/ISSMO Multidisciplinary Analysis and Optimization Conference, September 17-19, 2012, Indianapolis, Indiana. Reston, Virginia: AIAA, 2012: 5699.
- [7] JIAO Q Y, LI N, ZHU X H, et al. Prediction of departure aircraft taxi time based on deep learning[J]. Transactions of Nanjing University of Aeronautics and Astronautics, 2020, 37(2): 232-241.
- [8] 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.
- [9] 李楠, 焦庆宇, 樊瑞, 等. 基于逐步回归法航空器滑行时间影响因素研究[J]. 计算机仿真, 2021, 38(9): 57-63.
- [10] 刘家学, 白明皓, 郝磊. 基于ARIMA-SVR组合方法的航班滑出时间预测[J]. 中国科技论文, 2021, 16(6): 661-667.
- [11] 赵征, 冯事成, 宋梅雯, 等. 基于XGBoost的航空器动态滑行时间预测方法研究[J]. 航空工程进展, 2022, 13(1): 76-85.
- [12] 黄龙杨, 夏正洪. 离港航班可变滑出时间预测方法及应用[J]. 科学技术与工程, 2021, 21(33): 14434-14439.
- [13] 中国民用航空局. 关于印发《航班安全运行保障标准》的通知: 民航发[2020]4号[S]. 北京: 中国民用航空局, 2020.
- [14] 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.

(责任编辑:刘雅婷)