

文章编号: 1005-0523(2025)03-0057-10



基于 SMOTE 算法的航班正常率预测

张嘉懿^{1,2}, 胡明华¹, 黄梵根²

(1. 南京航空航天大学民航学院, 江苏 南京 211106; 2. 中国民用航空局空中交通管理局, 北京 100022)

摘要: 为实现对航班正常率的精准预测, 根据航班延误原因进行数据统计, 构建了包含起飞机场、目的地机场、流控信息、航线性质的航班正常预测指标体系, 提出了基于 SMOTE 算法的 XGBoost 分类预测模型 (SM-XGBoost 模型) 和基于 SMOTE 算法的 LightGBM 分类预测模型 (SM-LightGBM 模型), 并以华东地区主要机场实际数据为基础, 对所提模型的有效性和先进性进行了验证。结果表明: SM-XGBoost 模型和 SM-LightGBM 模型在预测准确度和误差上明显优于决策树和随机森林模型; 在训练集和测试集稳定性上, SM-LightGBM 模型优于 SM-XGBoost 模型, 对测试集的预测准确率最高达 88.2%。该方法为类似复杂系统事件预测提供了一种新的分析思路。

关键词: SMOTE 算法; 航班正常率; XGBoost 模型

中图分类号: [U8]; U111

文献标志码: A

本文引用格式: 张嘉懿, 胡明华, 黄梵根. 基于 SMOTE 算法的航班正常率预测[J]. 华东交通大学学报, 2025, 42(3): 57-66.

Flight Punctuality Rate Prediction Based on SMOTE Algorithm

Zhang Jiayi^{1,2}, Hu Minghua¹, Huang Fangen²

(1. College of Civil Aviation, Nanjing University of Aeronautics and Astronautics, Nanjing 211106, China;

2. Air Traffic Management Bureau of CAAC, Beijing 100022, China)

Abstract: To achieve accurate prediction of the flight punctuality rate, a flight regularity prediction index system was constructed based on data statistics of flight delay reasons, including departure airport, destination airport, flow control information, and route characteristics. It proposes a SMOTE algorithm-based XGBoost classification prediction model (SM-XGBoost model) and a SMOTE algorithm-based LightGBM classification prediction model (SM-LightGBM model). Based on the actual data of major airports in East China, the validity and progressiveness of the proposed model are verified. The results showed that the SM-XGBoost model and SM-LightGBM model were significantly better than the decision tree and random forest models in terms of prediction accuracy and error. In terms of stability of training set and test set, SM-LightGBM model is superior to the SM-XGBoost model, with a maximum prediction accuracy of 88.2% for test set. This method provides a new analytical approach for predicting events in similar complex systems.

Key words: SMOTE algorithm; flight punctuality rate; XGBoost model

收稿日期: 2024-09-09

基金项目: 国家自然科学基金项目 (52472345)

Citation format: ZHANG J Y, HU M H, HUANG F G. Flight punctuality rate prediction based on SMOTE algorithm[J]. Journal of East China Jiaotong University, 2025, 42(3): 57–66.

随着民航运输业的快速发展,航班延误、正常率较低等相关问题也备受瞩目,对正常率问题的研究既是满足航空运输业快速发展、缓解空域拥挤、提高运行效率的突破口,也是提升国家空域系统资源使用效率和空中交通管制服务品质的必然选择。同时,提高航班正常率的预测准确度,能够增强旅客的出行体验,减少因航班延误所带来的焦虑与不便,从而提升公众对于航空运输服务的整体满意度。

国内外对正常率预测研究各有侧重。Kim等^[1]建立了一个具有鲁棒性的长短期记忆和递归神经网络联合机场延误预测模型,该模型可预测单个航班最准确的延误状态。Rodriguez等^[2]分别从预测阶段和可靠性阶段揭示了影响机场性能因素之间的相互作用关系,提出用贝叶斯网络模型实现机场到达系统的运行状态的预测。Guleria等^[3]提出了一种基于多智能体的航班延误预测方法,延迟分类的阈值设定为15 min,预测准确率达到80%。Basturk等^[4]融合飞行、航线轨迹、天气信息,采用随机森林和深度神经网络模型实现对航班到达时间预测,并开发了一个应用程序,进一步提出动态预测模型。Zhang等^[5]利用PageRank算法获取空中交通延误动态空间依赖性,然后输入到长短期记忆网络和序列模型,联合挖掘时空依赖关系并实现机场延误的多步预测。Wang等^[6]采用了Beta分布、Erlang分布及正态分布来模拟飞行延误的情况,并运用LightGBM、多层感知机、随机森林模型对战略层面的飞行延误分布进行预测分析。罗杰等^[7]提出了一种基于XGBoost模型与Logistic模型集成的离港航班延误预测方法,可以显著提高单独预测模型在稀疏数据集上的预测效果。徐子玥等^[8]采用基于集合预报的集合轨迹预测方法获得预测轨迹的集合,建立航班过点时间极差的回归预测方程,计算结果验证了预测方法的有效性。郑玉帆等^[9]提出了一种基于SMOTE (synthetic minority oversampling technique) 算法的深度神经网络航班延误预测模型 (SMOTE-DNN), 该模型的预测精度可以达到88.79%, 且对航班延误各等级均有着较好的预测效果。曹卫东等^[10]提出了一种融合多机场时空相关性

的ST-LightGBM模型预测机场离港航班延误。

为做好航班正常率预测,应选取能充分反映航班各方面情况的指标^[11],综合评估建立航班正常性预测指标体系。本文使用SMOTE算法对传统的决策树、随机森林模型等预测模型进行优化,提出了基于SMOTE算法的XGBoost分类预测模型 (SM-XGBoost模型) 和LightGBM分类预测模型 (SM-LightGBM模型),并应用于航班正常率预测方面。构建了包含起飞机场、目的地机场、流控信息、航路航线性质的航班正常性预测指标体系,提升训练速度的同时,降低了内存消耗,并提高了预测准确率。

1 航班正常性预测框架

1.1 航班正常性预测流程图

航班正常性预测流程如图1所示,具体步骤如下。

1) 确定预测对象并收集数据。选定具有代表性的航空网络区域,采集航空网络中天气预报数据、航路点数据、航班计划数据和流量控制数据。对采集数据集进行数据融合、数据清洗、剔除异常值,从而形成航班正常性预测的原始数据集。

2) 根据航班运行特点和航空网络结构,综合考虑航空公司、机场、空管部门的影响,提出航班正常性预测指标,并将这些指标进行区别归类,分别属于起飞机场、目的地机场、常态化流量控制信息、航路航线性质的4大类。形成航班正常性预测最终数据集。

3) 根据航班正常性预测最终数据集的构建情况,联合数据平衡算法、参数优化算法和预测模型,提出航班正常性预测模型。首先,使用SMOTE算法对航班正常性预测问题存在的类别不平衡情况进行处理,从而达到平衡数据集的目的;然后,将平衡化的预测数据集输入到XGBoost模型和LightGBM模型中;最后,使用网格搜索算法对预测模型进行超参数调优,选择预测效果最优的参数组合。

4) 根据预测模型评价指标对比,输出预测效果最优的航班正常性预测结果。根据航班正常性预测结果计算航班正常率,并对选定航空网范围内的




图1 航班正常性预测流程图

Fig. 1 Flight punctuality prediction flow chart

航班正常率的时空分布结构进行分析。

5) 分别输出XGBoost模型和LightGBM模型中预测特征重要度排名,并进行对比,定量分析影响航班正常性的因素,挖掘航班正常性的关键影响因素。

1.2 航班正常性预测指标体系

本文从航空网络中的要素入手,结合数据获取情况,分别从起飞机场、目的地机场、常态化流量控制、航路航线性质4个角度出发提出航班正常性预测指标体系。

2 航班正常性预测指标体系

2.1 基于机场运行的航班正常性预测指标体系构建

2.1.1 机场预计流量与容量

机场流量反映了机场的运行情况和繁忙程度,当机场流量超过机场本身的保障容量时,机场可能

会出现航班排队等待、停机位不足、旅客登机延误等问题,导致航班无法按时起飞,影响航班的正常性。机场流量越大,航班出现不正常运行的概率越大。因此,机场流量是确保航班正常性和机场运行效率的关键因素,本文提出起飞机场预计流量和目的地机场预计流量作为航班正常性预测的指标,指标的相关定义如下。

1) 起飞机场预计流量: $\left[t - \frac{w}{2}, t + \frac{w}{2}\right]$ 时段内起飞机场预计起飞的架次。 t 为预测对象计划到港时刻, w 为时间窗口, 本文 w 为 30 min。

2) 目的地机场预计流量: $\left[t - \frac{w}{2}, t + \frac{w}{2}\right]$ 时段内目的地机场预计到达的架次。

此外,机场容量作为机场流量的对比性指标,同样也是影响航班正常性的关键指标。由于本文

对起飞机场群所属的航空网络范围进行了界定,起飞机场的容量参考意义不大,故仅将目的地机场到港小时容量作为航班正常性预测指标,该容量由各机场的申报容量进行确定。

2.1.2 天气状况

不同的天气类型会对航班运行产生不同的影响。恶劣的天气条件,如雷雨、降雪、大雾等,可能导致能见度降低、跑道积水、冰雪覆盖等情况,这些情况会对航班飞行安全产生影响。当恶劣天气发生时,机场有关部门会采取相应的措施,如限制起降数量、调整航班计划或者暂停运营,以确保航班的安全。其次,风向风速也是影响航班正常率的重要因素之一。当阵风超过飞机的安全限制范围时,飞机的起降操作可能会受到限制。当风速过大时,飞机可能无法安全地起飞或降落,需要延迟或取消航班。当风向变化较大时,航班起降跑道发生变化,也会进一步影响航班的正常性。此外,温度对航班正常率也有一定影响。在极端高温条件下,机场的空气密度会降低,飞机性能受到影响,导致起飞距离延长、爬升速度减慢等。相反,在极端低温条件下,机场跑道和设备可能会受到冰冻或结冰的影响,需要进行除冰和防冰处理,这可能会导致航班无法正常起飞。

综上所述,机场天气类型、风向风速和温度是保障航班安全运行的重要天气指标。本文根据天气预报信息,分别统计起飞机场和目的地机场的天气类型、风向风速、温度作为航班正常性预测的指标。

2.1.3 时段

在高峰或繁忙的时间段,机场通常会有更多的航班起飞和到达,机场的跑道、停机位和登机口资源可能出现紧缺的现象。当机场管理部门无法有效地处理这些航班时,会增加航班延误或取消的概率。此外,目的地机场预计到达时段还与后续航班连接有关。如果航班延误导致旅客无法及时到达下一班次的航班,这会对航班的正常性产生连锁反应,影响整个航班网络的运行。因此,起飞机场的预计起飞时段和目的地机场的预计到达时段对航班正常性有着重要的影响。

2.2 基于常态化流量控制挖掘的航班正常性预测指标体系构建

2.2.1 常态化受控内容

为确保航班正常运行,空管的流量管理部门预

判可能会发生的延误影响,对进入特定空域的航班要求在特定时间段进行起降。同时,航空公司可能需要调整航班的起飞时间、中转时间等,以适应流量控制措施的要求,从而导致航班的正常性受到影响。航空网络具有复杂性和多变性,天气情况、空中交通拥堵、机场设备故障等因素都可能导致流控信息的调整或更新,流量控制信息处于不断变化中。因此,为有效捕捉流量控制信息对航班正常性的影响,本文梳理历史流量控制的发生模式和趋势,挖掘一些常态化的流量控制信息(半年中频次出现超过100次的流控措施),将其作为航班正常性预测的类别指标。将不受常态化流量控制措施限制的航班归为一类,否则按常态化流量控制措施的内容归类,并结合该措施出现的频次,进行赋值处理。

2.2.2 预计通过的常态化受控航路点

通常情况下,空管的流量管理部门发布的流量控制措施都是针对容流不平衡节点(机场或航路点),将这些受到管控的点称之为受控航路点。这些受控航路点是造成空中交通管理延误的重要组成部分,进而影响航班正常运行。若航班预计通过的受控航路点越多,该航班出现不正常运行的概率越大。出现受控航路点的原因是多样的,受控航路点具有不确定性。为捕捉受控航路点对航班正常性的影响,本文梳理历史受控航路点出现规律,确定一些常态化的受控航路点(半年中频次出现超过100次的受控航路点),将其作为航班正常性预测的类别指标。将不通过常态化受控航路点的航班归为一类,否则按常态化受控航路点类别归类,并结合受控航路点出现的频次,进行赋值处理。

2.2.3 空中交通流量控制

为应对机场或航路点出现容需不平衡现象,避免飞机在空中拥堵和碰撞,空中流量管理部门实施流量控制措施,用以维持空中交通系统的运行效率。空管流量管理部门为每个可能经过拥堵节点(机场或航路点)的航班分配一个计算起飞时间(calculated take off time, CTOT)。当航班的CTOT晚于航空公司计划的目标起飞时间(target take off time, TTOT),该航班出现空中交通管理/流量延误,航班正常率受到影响。因此,本文将航班是否受到空中流量管控作为航班正常性预测的指标,该指标的相关定义如下:依据航班是否分配CTOT判断航班是否受到流量控制,1表示航班受到流量控制,0

表示航班不受到流量控制。

2.3 基于航路航线性质的航班正常性预测指标体系构建

2.3.1 航路点流量

当航路点流量过大时,航路点容易发生拥堵,航空器可能需要采取绕过航路点的飞行路径或在地面进行排队等待起飞,进而延长航班到达时间,影响航班正常性。根据航班计划通过的航路和预计通过航路点的时间,计算航路点预计通过流量,并将其作为航班正常性预测的指标。当航班预计通过的航路点流量越大,航班发生绕行、延误等不正常的可能性越大。

2.3.2 飞行计划时长

飞行计划时长为计划挡轮档时刻(scheduled in-block time, SIBT)与计划撤轮档时刻(scheduled off-block time, SOBT)的差值。

长时间的飞行计划通常面临更多的不确定性,如天气变化、航路拥堵、机场超容等。此外,较长时间的飞行通常需要携带更多的燃油以满足飞行需求,在某些情况下,飞机需要在途中进行加油,导致额外的停留时间和延误的可能性。因此,飞行计划时长是航班正常性的一个重要影响因素。

2.3.3 缓冲时长

缓冲时长为飞行计划时长与历史实际飞行时长之差,根据一个航班的历史实际飞行时长的平均值得到该航班的历史实际飞行时长。若航班的缓冲时长为正数,则当航班突发延误时,航班有多余的缓冲时长完成航班计划,缓冲时长可以在一定程度上缓解延误对航班正常运行的影响。航班的缓冲时长越长,航班受到延误影响越小,航班正常性越高。

2.3.4 城市对

航线资源通常集中分布在经济发达、运输需求旺盛的地区。此外,如果某些城市之间存在密切的商业联系、旅游需求等,航空公司会将时刻资源倾斜于这些热门城市对之间的航线,从而导致这些热门航线的航班计划密集。当这些城市对航线发生航班延误时,延误波及范围广,航班系统运行受到影响。因此,城市对是影响航班正常性的影响因素。

综上,如表1所示,构建航班正常性预测影响因素体系,并根据影响因素的起源进行归类,分为起飞机场、目的地机场、流控信息、航路航线性质4大类。

3 航班正常性预测模型

根据航班正常性预测指标体系的构建,形成航

表1 航班正常性预测影响因素

Tab.1 Influencing factors of flight punctuality prediction

类别	航班正常性影响因素	参数
起飞机场	预计流量	X1
	天气类型	X2
	天气温度	X3
	能见度	X4
	预计起飞时段	X5
目的地机场	预计流量	X6
	天气类型	X7
	天气温度	X8
	能见度	X9
	预计到达时段	X10
	到港小时容量	X11
流控信息	常态化受控内容	X12
	预计通过的常态化航路点	X13
	是否受到空中交通流量控制	X14
航路航线性质	航路点流量	X15
	飞行计划时长	X16
	缓冲时长	X17
	城市对	X18

班正常性预测数据集。航班正常性预测数据中,正常航班和不正常航班的数据量相差较大,为了解决不平衡样本导致分类模型预测准确度低的问题,引入SMOTE算法对航班正常性预测数据集进行预处理。本文分别提出基于SMOTE算法的XGBoost分类预测模型(SM-XGBoost模型)和基于SMOTE算法的LightGBM分类预测模型(SM-LightGBM模型),并使用网格搜索算法寻找预测模型中最佳的参数组合,提高模型的性能和泛化能力,实现对特定航空网络中的航班正常性进行预测。

3.1 SMOTE算法

2002年,Chawla等^[12]首次提出了SMOTE算法,旨在应对类别不平衡难题。作为一种广受认可的数据增强策略,SMOTE专注于缓解机器学习及数据挖掘领域中显著的样本类别不平衡现象,即部分类别样本数量远逊于其他类别的挑战。该算法核心机制围绕着增加少数类样本量展开,具体通过选取少数类样本的邻近样本,利用线性插值技术在其间虚构新的样本点,以此促进各类样本数量的均衡,其算法原理图见图2所示。

以下是SMOTE算法的关键实施步骤概述:

- 1) 针对少数类群体中的每一份样本,执行欧式距离度量,以识别并获取该样本的 K 个最近邻居;
- 2) 考虑数据集中存在的不平衡比率,设定抽样放大系数 N ,并基于此为每份少数类样本独立抽取




图2 SMOTE算法原理图

Fig. 2 SMOTE algorithm schematic diagram

N 个最近邻样本;

3) 对于每一名选定的邻近样本 x' , 首先计算它与源样本 x_i 之间的差异向量, 随后运用随机线性插值策略在这两个点之间生成一个新的合成样本, 具体的插值计算公式为

$$x_{\text{new}} = x_i + \text{rand}(0, 1) \times (x' - x_i) \quad (1)$$

式中: x_{new} 为新的合成样本; $\text{rand}(0, 1)$ 为区间 $(0, 1)$ 内的随机数。

重复步骤 1)~步骤 3), 直到生成足够数量的合成样本。将生成的新样本与原样本合并在一起, 形成平衡后的航班正常性预测数据集。

通过上述操作流程, SMOTE 算法能够有效应对数据中的类别不平衡问题, 促使机器学习模型对各类别样本实现更均衡的处理, 在解决航班正常性预测等涉及类别分布不均的场景中具有显著作用。

3.2 航班正常性分类预测模型

XGBoost 和 LightGBM 都是基于梯度提升树算法的改进版本, 能够有效处理类似航班正常性预测这样的二分类问题。这些模型通过并行化处理、特征选择以及优化算法等技术手段, 克服了传统 GBDT 模型的局限性, 并展现出更好的性能和效果。因此, 本文选用 XGBoost 和 LightGBM 分类模型并与随机森林和决策树经典算法进行对比研究。

3.2.1 XGBoost 模型

为解决传统树模型计算效率低、难以处理大规模高维数据的问题, 在传统的 GBDT 模型的代价函数中加入正则项, 提出一种极限梯度提升模型 XGBoost²⁷ (extreme gradient boosting)。XGBoost 模型的代价函数如式 (2) 所示, 正则项如式 (3) 所示

$$\text{obj}(\varphi) = \sum w(y_i, f(x_i)) + \Omega(f_i) \quad (2)$$

$$\Omega(f_i) = \gamma T + \frac{1}{2} \lambda \|a\|^2 \quad (3)$$

式中: φ 为模型参数; $\Omega(f_i)$ 为正则项, 用于度量模型的复杂度; γ 和 λ 为正则化参数; T 为树的叶子节点数; a 为叶子节点的权重。

3.2.2 LightGBM 模型

微软在 GBDT 模型的基础上改进了损失函数计算残差方式, 推出了一种迭代提升树系统称为 LightGBM, 它专注于解决大规模数据集上的训练效率问题。LightGBM 模型的目标函数与 XGBoost 模型形式相同, 都由损失函数和正则项组成, 但二者在实现形式上有所区别。LightGBM 模型在解决大规模数据集上的训练效率问题时有两个关键点。

1) 离散化特征值: LightGBM 利用了离散化处理技术, 将连续特征值转换成离散的桶或分箱数据。这种做法不仅显著减少了内存占用, 还提高了训练速度。通过这种方式, 算法能够更高效地处理大规模数据的特征, 同时也降低了计算成本。

2) 基于直方图的决策树算法: LightGBM 使用了基于直方图的算法进行决策树生长, 这与传统的基于树节点的决策树相比具有明显优势。该方法通过构建直方图来近似寻找最佳分裂点, 减少了遍历所有数据的复杂度, 加速了训练过程, 特别适用于处理大规模数据。这使得 LightGBM 能够更有效地处理大规模数据, 从而提高了训练效率。

XGBoost 和 LightGBM 在原理上都是对传统的梯度提升决策树 (gradient boosting decision tree, GBDT) 进行改进和优化。它们通过并行化处理、特征选择和优化算法等技术手段, 有效地解决了传统 GBDT 模型存在的一些问题, 展现了更好的性能和效果。

3.3 航班正常性分类预测模型关键参数

不同的参数设置将直接影响模型的预测性能, 通过多轮实验, 本文筛选出针对航班正常性预测问题中 XGBoost 模型和 LightGBM 模型的重要参数, 并进行解释说明。 $n_estimators$ 、 max_depth 、 $learning_rate$ 对 XGBoost 和 LightGBM 模型的预测性能影响都较大, 这 3 个参数在不同程度上影响着模型的复杂度和拟合能力。模型的复杂度和拟合能力随 $n_estimators$ 的数量增加而增加, 计算成本和过拟合的风险也随之升高; max_depth 数值越大, 模型学习复杂特征和关系的能力越强, 过拟合风险越大; 较大的 $learning_rate$ 会使每个基学习器的贡献较大, 模型训练过程更加激进, 可能导致过拟合。

此外, $subsample$ 、 $colsample_bytree$ 参数对 XGBoost 模型的预测性能影响也较大。 $subsample$ 参数控制了每个基础学习器使用的训练样本比例, 较小的 $subsample$ 值意味着用于训练每棵树的样本较少, 从

而增加模型的多样性,但容易存在欠拟合的问题。`colsample_bytree`指定了每棵树在训练时使用的特征比例,较大的`colsample_bytree`值意味着每棵树使用的特征数量较多,模型过拟合的风险增加。`feature_fraction`和`num_leaves`对LightGBM模型的预测性能影响也较大。`feature_fraction`为LightGBM模型中每棵树在训练时使用的特征的比例,与XGBoost模型`colsample_bytree`参数含义相似;`num_leaves`为每棵树的叶子节点数量,`num_leaves`数值越大,模型每棵树的结构越复杂,模型过拟合风险增加。

3.4 模型性能评价指标

本文选用 R^2 、平均绝对误差MAE(mean absolute error)、均方根误差RMSE(root mean square error)

、准确度Accuracy指标对航班正常性预测模型进行模型评估。 R^2 表示模型解释数据方差的比例,越接近1,表示模型对目标变量的解释能力越强;Accuracy表示模型预测正确的样本数占总样本数的比例,Accuracy越高,模型的分类能力越强。MAE、RMSE的计算公式为

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (4)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (5)$$

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

综上,构建航班正常性预测模型,具体流程如图3所示。




图3 基于SMOTE算法的航班正常性预测模型

Fig. 3 Flight punctuality prediction model based on SMOTE algorithm

4 实例验证

根据学者对空中交通网络拥挤判别与预测的研究,筛选出中国空域拥挤等级较高的华东地区作为实例验证对象。选择华东地区4个具有代表性的机场作为起飞机场构建航班正常性预测网络,用ICAO代码进行表示,ZSSS(上海虹桥机场)、ZSPD(上海浦东机场)、ZSHC(杭州机场)、ZSNJ(南京机场)。

2023年5月1日到5月31日,收集从华东地区4个机场起飞的航班正常性预测数据,共51 373条。由于数据采集和不正常航班比例问题,本文仅选择国内航班进行实验,剔除国际航班和异常数据后,获得航班正常性预测有效数据共44 261条。其中,正常航班数据为36 612条,不正常航班数据7 649条。将5月1日—5月22日的航班正常性预测数据作为训练集,5月23日—5月31日的航班正常性预

测数据作为测试集,从流量管理的战术层面,对华东四场离港的航班正常性进行短时预测。

4.1 预测模型性能对比

本研究运用SMOTE算法与网格搜索算法,分别结合XGBoost模型和LightGBM模型,对航班正常性预测数据的测试集开展实验。通过对比参数调优操作与数据平衡处理对原始模型预测性能的影响,得出模型评估结果,具体如表2所示。使用网格搜索算法进行调参的操作,应用SMOTE算法平衡预测数据集的操作处理后模型预测拟合度和准确度均有提升。经过数据平衡操作处理后的模型在预测准确度方面的优化幅度高于调参操作处理后的模型。对比原始模型,SM-XGBoost模型和SM-LightGBM模型的预测准确度分别提升了17个百分点和18.5个百分点。对SM-XGBoost模型和SM-LightGBM模型进行调参处理后,模型预测拟

表2 调参和数据平衡操作对模型预测性能影响的评估结果

Tab.2 Evaluation results of the impact of parameter adjustment and data balance operation on the prediction performance of the model

模型	R^2	Accuracy
XGBoost	0.52	66.3%
调参后 XGBoost	0.60	71.2%
SM-XGBoost	0.78	83.3%
调参后 SM-XGBoost	0.82	86.1%
LightGBM	0.55	68.9%
调参后 LightGBM	0.66	74.5%
SM-LightGBM	0.80	84.8%
调参后 SM-LightGBM	0.85	88.2%

合度均达到 0.82 以上,预测准确度分别提升了 2.8 个百分点和 3.4 个百分点。经过多轮实验,确定 SM-XGBoost 和 SM-LightGBM 模型关键参数最佳组合如表 3 所示。

表3 SM-XGBoost 模型与 SM-LightGBM 模型
关键参数最佳组合

Tab.3 Optimal combination of key parameters of SM-XGBoost model and SM-LightGBM model

参数	SM-XGBoost	SM-LightGBM
n_estimators	100	120
max_depth	9	8
learning_rate	0.1	0.2
subsample	0.8	
colsample_bytree	0.9	
feature_fraction		0.8
num_leaves		64

为准确评估两个模型的预测性能,引入传统机器学习算法决策树(decision tree, DT)和随机森林(random forest, RF)进行对比实验。首先,利用 SMOTE 算法对航班正常性预测数据进行平衡处理,再分别输入到 DT、RF 模型中进行训练。本文将基于 SMOTE 算法的 DT、RF 预测模型分别记作 SMOTE-DT、SMOTE-RF 模型。4 个模型在 R^2 、MAE、RMSE、Accuracy 指标的对比结果如表 4 所示。SMOTE-DT 模型中训练集和测试集预测准确

度存在较大差异,训练集预测准确度高达 97.2%,测试集预测准确度仅为 79.8%,且训练集 R^2 为 0.96,可能存在过度拟合的问题。SM-XGBoost 模型和 SM-LightGBM 模型在预测准确度和误差上明显优于 SMOTE-DT 模型和 SMOTE-RF 模型。在训练集和测试集稳定性上,SM-LightGBM 模型优于 SM-XGBoost 模型,且 SM-LightGBM 模型对测试集的预测准确度最高为 88.2%。

为进一步对比不同类别预测性能,分别输出 SM-XGBoost、SM-LightGBM 模型的混淆矩阵。SM-XGBoost、SM-LightGBM 模型对正常航班的预测精准度均高于不正常航班的预测,预测精准度分别为 86.1%、88.2%。SM-XGBoost 模型对不正常航班 R^2 仅为 0.82。相比之下,SM-LightGBM 模型对两种类别的预测精准度稳定性更高,对不正常航班 R^2 达到 0.85。

综上,SM-XGBoost 模型和 SM-LightGBM 模型预测性能均优于传统机器学习模型。在对不同数据集和不同类别预测效果上,SM-LightGBM 模型的预测稳定性高于 SM-XGBoost 模型。

4.2 特征重要性分析

根据 SM-XGBoost、SM-LightGBM 模型得出特征重要度排名,探究从华东四场离港的航班正常性指标对预测结果的重要性。基于 SM-XGBoost 模型和 SM-LightGBM 模型的航班正常性特征重要度排名如图 4 所示。在 SM-XGBoost 模型中,特征重要度排在前 3 的指标分别为是否受到空中交通流量控制、缓冲时间、起飞机场预测起飞时段。其中,是否受到空中交通流量控制是最关键的特征,重要度超过 0.2。在 SM-LightGBM 模型中,特征重要度排在前 3 的指标分别为缓冲时间、是否受到空中交通流量控制、常态化受控内容。其中,缓冲时间是最关键的特征,重要度为 0.16。此外,起飞机场天气类型也是两个模型值得重点关注的特征,特征重要度排名均排第 4。从特征所属类别来看,流控信息在航班正常性的预测中发挥重要作用。

4.3 航班正常性预测结果分析

如图 5 所示,分别输出 SM-XGBoost、SM-Light-

表4 航班正常性预测模型评估结果对比

Tab.4 Comparison of flight punctuality prediction model evaluation results

模型	R^2		MAE		RMSE		Accuracy	
	训练集	测试集	训练集	测试集	训练集	测试集	训练集	测试集
SMOTE-DT	0.96	0.78	0.04	0.25	0.06	0.40	97.2%	79.8%
SMOTE-RF	0.95	0.80	0.10	0.16	0.12	0.38	95.4%	81.3%
SM-XGBoost	0.95	0.82	0.09	0.14	0.09	0.22	94.2%	86.1%
SM-LightGBM	0.92	0.85	0.07	0.18	0.14	0.24	92.8%	88.2%




图4 航班正常性特征重要度排名

Fig. 4 Ranking of flight punctuality feature importance




图5 航班正常率预测结果

Fig. 5 Prediction results of flight punctuality rate

GBM模型对华东4个机场的航班正常率预测结果,根据航班正常率的计算公式进行计算得到各机场的航班正常率预测结果。从预测值和真实值曲线对比结果来看,预测的航班正常率较真实航班正常率偏低。不同机场的航班正常率预测结果稳定性有所区别。其中,南京机场航班正常率预测结果较真实值波动最大,其次是虹桥机场。浦东机场和杭州机场的航班正常率预测稳定性最好,杭州机场的航班正常率预测趋势与真实航班正常率趋势较为一致。从航班正常率来看,南京机场航班正常率最低,航班不正常运行数量最多,存在的不确定因素较多,可能导致航班正常率预测准确度降低。其余3个机场的航班正常率较稳定。从模型的预测结果对比来看,SM-LightGBM模型对华东四场航班正常率的预测准确度和稳定性高于SM-XGBoost模型。

5 结论

1) 通过构建一个多维度的航班正常性预测指标体系,为航班正常率预测提供了更为全面和细致的视角。

2) 不仅继承了SMOTE算法在处理数据集不平衡问题上的优势,更在此基础上创新性地构建了两种新的预测模型,无论是结构上,还是预测准确度和误差控制方面均优于传统的决策树和随机森林模型,为航班正常性预测领域的研究和实践提供了新思路。

3) 在训练集和测试集稳定性上,SM-LightGBM模型优于SM-XGBoost模型,对测试集的预测准确度最高为88.2%。

参考文献:

- [1] KIM Y J, CHOI S, BRICENO S, et al. A deep learning approach to flight delay prediction[C]//Sacramento: 2016 IEEE/AIAA 35th Digital Avionics Systems Conference (DASC), 2016.
- [2] RODRÍGUEZ-SANZ A, COMENDADOR F G, VALDÉS R A, et al. Assessment of airport arrival congestion and delay prediction and reliability[J]. Transportation Research Part C: Emerging Technologies, 2019, 98: 255-283.
- [3] GULERIA Y, CAI Q, ALAM S, et al. A multi-agent approach for reactionary delay prediction of flights[J]. IEEE Access, 2019, 7: 181565-181579.
- [4] BASTURK O, CETEK C. Prediction of aircraft estimated time of arrival using machine learning methods[J]. The Aeronautical Journal, 2021, 125(1289): 1245-1259.
- [5] ZHANG H, SONG C Y, ZHANG J, et al. A multi-step airport delay prediction model based on spatial-temporal correlation and auxiliary features[J]. IET Intelligent Transport Systems, 2021, 15(7): 916-928.
- [6] WANG Z M, LIAO C H, HANG X, et al. Distribution prediction of strategic flight delays via machine learning methods[J]. Sustainability, 2022, 14(22): 15180.
- [7] 罗杰, 侯霞, 杨鸿波, 等. 基于集成学习的离港航班延误预测方法[J]. 计算机工程与设计, 2022, 43(4): 1145-1151.
- [8] LUO J, HOU X, YANG H B, et al. Prediction of departure flight delay based on ensemble learning[J]. Computer Engineering and Design, 2022, 43(4): 1145-1151.
- [8] 徐子玥, 胡明华, 张颖, 等. 基于风集合预报的扇区概率拥堵预测[J]. 华东交通大学学报, 2022, 39(4): 48-57.
- [9] XU Z Y, HU M H, ZHANG Y, et al. Probabilistic sector congestion prediction based on ensemble wind forecasts[J]. Journal of East China Jiaotong University, 2022, 39(4): 48-57.
- [9] 郑玉帆, 徐海文. 基于SMOTE算法的深度学习航班延误预测模型[J]. 价值工程, 2023, 42(4): 118-120.
- [10] ZHENG Y F, XU H W. Flight delay prediction model of deep neural network based on SMOTE algorithm[J]. Value Engineering, 2023, 42(4): 118-120.
- [10] 曹卫东, 张金迪, 刘晨宇. 基于ST-LightGBM的机场离港航班延误预测[J]. 陕西科技大学学报, 2023, 41(4): 166-172.
- [11] CAO W D, ZHANG J D, LIU C Y. Airport departure flight delay prediction based on ST-LightGBM[J]. Journal of Shaanxi University of Science & Technology, 2023, 41(4): 166-172.
- [11] 晋百川, 杨鸿波, 侯霞, 等. 面向集成学习的航班离港延误状态预测[J]. 传感器与微系统, 2023, 42(9): 141-144.
- [12] JIN B C, YANG H B, HOU X, et al. Prediction of flight departure delay state based on ensemble learning[J]. Transducer and Microsystem Technologies, 2023, 42(9): 141-144.
- [12] CHAWLA N V, BOWYER K W, HALL L O, et al. SMOTE: synthetic minority over-sampling technique[J]. Journal of Artificial Intelligence Research, 2002, 16(1): 321-357.



通信作者: 张嘉懿(1988—), 女, 工程师, 硕士, 研究方向为交通运输规划与管理。E-mail: fuji415@sina.com。

(责任编辑: 吴海燕)