

http://bhxb.buaa.edu.cn jbuua@buaa.edu.cn

DOI: 10.13700/j.bh.1001-5965.2023.0304

基于级联的航班地面保障动态预测

唐小卫^{1,*}, 丁叶¹, 吴政隆², 张生润¹, 吴佳琦¹, 叶梦凡¹

(1. 南京航空航天大学 民航学院, 南京 211106; 2. 新南威尔士大学 航空学院, 悉尼 NSW 2052)

摘

要: 对航班地面保障过程进行精准预测是实现航班精细化管理、提升机场协同决策

(A-CDM) 系统管理效能的关键。为此, 提出一种基于级联多输出梯度提升回归树模型的航班地面保障多节点动态预测方法。通过搭建级联框架实现了不同保障进度之间预测信息的传递和预测结果的更新, 基于可进行多节点预测的梯度提升回归树设计了地面保障过程动态预测算法, 以典型繁忙机场为对象构建了航班基础属性与层级信息传递两大类特征集。结果表明: 所提方法有效实现了地面保障各关键节点完成时间的动态预测, 初始预测各节点 ± 5 min 预测精度均达到 80% 以上, 随着保障过程推进模型预测性能逐步提升, 超过 60% 的节点 ± 5 min 最终预测精度超过 95%, 为提升航班运行的可预测性和机场多主体协同决策能力提供有效方法支撑。

关键词: 航空运输; 航班地面保障; 机场协同决策; 级联; 梯度提升回归树; 动态预测

中图分类号: V351.11

文献标志码: A

文章编号: 1001-5965(2025)05-1557-09

当前各机场对航班地面运行全流程管理主要依托机场协同决策 (airport collaborative decision making, A-CDM) 系统进行。A-CDM 系统的建设已打破空管、机场和航司等运行主体之间的信息壁垒, 但大多数机场只能对地面保障的终末节点“撤轮挡”进行结果监控, 属于事后管理的范畴; 少数机场虽已实现对“撤轮挡”的主动预测, 但单个节点的静态预测无法指导保障部门进行有效的事中干预, 其本质原因是地面保障延误萌发时期的特征相对模糊, 随着保障过程推进, 上游作业的波动会在下游产生累积, 继而影响后续离港流程。因此, 推动地面保障过程预测研究由静态向动态、由单一节点向全过程节点转变, 是实现航班精细化管理、提升 A-CDM 系统管理效能的关键所在。

航班地面保障作业流程管理研究领域经历了“单一流程单作业→单一流程多作业→多流程多作

业”的发展过程。在针对单一流程的研究中, 关于登机流程的研究最为丰富^[1-3], 近来的研究则更关注疫情防控对地面保障清洁和配餐作业的影响^[4]。随着协同决策思想在产业界的不断落地升级, 学术界更重视多流程多作业协同管理的相关问题^[5]。由于目标撤轮挡时间是 A-CDM 机制下各方衔接的核心^[6], 所以对撤轮挡时间的预测成为研究的重点, 研究方法包括分布拟合、仿真建模、网络作业、启发式算法等, 如 Sheibani 拟合保障作业的时间分布并通过关键路径法和蒙特卡罗模拟方法估计保障结束时间^[7], 邢志伟等基于人工鱼群算法改进的向量机模型^[8]与自适应多层遗传算法改进的 BP 神经网络模型^[9]估计了保障服务时间。上述研究直接对目标撤轮挡时间进行单一节点预测, 不利于在延误发生前即对地面保障进行干预。而王立文等提出一种结合高斯核概率密度估计的过站航班地面保障过程贝叶斯网络动态预测方法^[10], 初步实现了精

收稿日期: 2023-06-01; 录用日期: 2023-11-13; 网络出版时间: 2023-11-21 15:22

网络出版地址: link.cnki.net/urlid/11.2625.V.20231120.1526.002

基金项目: 国家自然科学基金 (U2333204, U2233208); 2023 年度民航安全能力建设项目 ((2023)155 号); 南京航空航天大学科研与实践创新计划资助项目 (xcxjh20220715)

* 通信作者. E-mail: tangxiaowei@nuaa.edu.cn

引用格式: 唐小卫, 丁叶, 吴政隆, 等. 基于级联的航班地面保障动态预测 [J]. 北京航空航天大学学报, 2025, 51 (5): 1557-1565.

TANG X W, DING Y, WU Z L, et al. Dynamic prediction of flight ground service based on cascade [J]. Journal of Beijing University of Aeronautics and Astronautics, 2025, 51 (5): 1557-1565 (in Chinese).

细化的动态预测,但其预测需要进行大规模概率分布拟合计算,运算复杂度较高,较难在实际保障中应用。在特征构建方面,现有保障时间预测的特征库一般包括机型、机位、运行时段、航空公司、航线性质等因素,较少考虑由机场航班时刻表决定的内在因素。

为此,本文面向航班地面保障过程建立了可在层级间传递信息的级联框架,以此为基础采用多输出梯度提升回归树 (gradient boosting regression tree, GBRT) 作为不同保障进度下多节点预测的基本模型,并构建了适用于级联模型的特征集,最终结合机场实际保障数据验证了模型的有效性。

1 级联多输出梯度提升回归树模型构建

航班地面保障过程如图 1 所示,包含开关舱门、上下客货、配餐、清洁、加油等众多具有串并行关系、严格作业次序要求的作业,这些作业的开始与结束时间即为保障中需要关注的节点。航班地面保障多节点动态预测问题是指基于保障进程的实时推进,面向未完成的保障节点采用预测模型逐步更新其完成时间估计值,实现预测精度随任务推进持续提升的目的。本文将构建级联多输出梯度提升回归树 (cascaded multiple output-gradient boosting regression tree, CMO-GBRT) 模型对地面保障多节点进行动态预测。




图 1 航班地面保障作业流程
Fig. 1 Operation process of flight ground service

1.1 级联框架描述

级联框架是一个层级结构,每层级都需构建单独的学习器,通过学习器的组合来分解复杂问题^[11-12],组合方式可以是串联、并联和串并联结合。由于地面保障过程具有固定的作业次序,因此,本文采取串联组合方式,将多个多节点预测模型按照保障进程顺序进行组合。

级联框架的优点还在于能通过层级之间的信息传递提高系统整体性能。其原理是,构建每层结构时通过训练调优得到预测性能最好的学习器,将原特征、学习结果、学习结果与真实值的偏差作为下一层级的输入特征,下一层级学习器通过额外学习上层学习器的偏差得到改进,进一步提升预测性能。本文新引入了表征上一层级预测值与待修正值的层级信息传递特征,该特征将随着保障过程推进发生动态变化,不断传递修正信息,达到提升总体学习性能的目的。

针对地面保障多节点动态预测问题,若从上轮挡至撤轮挡的某条关键路线上共有 $n+1$ 个具备先后次序的关键节点。当保障进度依次推进到除终点节点撤轮挡以外的 n 个关键节点时,均需对当前进度下所有未完成节点的完成时间进行更新预测,因此,共需进行 n 次静态的多节点预测,其预测流程如图 2 右边框所示,对应 n 次预测构建 n 个层级的级联框架,其框架结构如图 2 左边框所示。

假设保障进度推进到第 i 个节点,需进行第 i 次更新预测,则 i 的取值范围为 $1 \leq i \leq n$,按次序第 1 至第 i 个节点为已完成节点(图 2 右边深色节点),第 $i+1$ 至第 $n+1$ 个节点为未完成节点(图 2 右边白色节点),亦为需更新预测的对象(图 2 右边虚线框)。令 n 次预测中节点真实值的集合记为 A ,节点预测值的集合记为 $\bar{A}$,表达式分别为

$$A = \{V_1, \{V_1, V_2\}, \dots, \{V_1, V_2, \dots, V_j, \dots, V_i\}, \dots, \{V_1, V_2, \dots, V_n\}\} \quad 1 \leq i \leq n, 1 \leq j \leq i \quad (1)$$




图 2 级联框架与地面保障多节点动态预测过程的映射关系

Fig. 2 Mapping relationship between cascaded framework and multi-node dynamic prediction of flight ground service

$$\bar{A} = \{ \{ U_2^1, U_3^1, \dots, U_{n+1}^1 \}, \{ U_3^2, U_4^2, \dots, U_{n+1}^2 \}, \dots, \\ \{ U_{i+1}^i, U_{i+2}^i, \dots, U_j^i, \dots, U_{n+1}^i \}, \dots, U_{n+1}^n \} \\ 1 \leq i \leq n, i+1 \leq j \leq n+1 \quad (2)$$

式中： i 表示预测次数； j 表示节点在所有关键节点中的次序； V_j 表示第 j 个节点的真实值，一旦获知则固定不变； U_j^i 表示第 i 次预测时第 j 个节点的预测值，同一节点的预测值随保障进程推进不断更新； A 与 $\bar{A}$ 互为补集。

因此，根据图 2 中预测次数等于级联框架层数的映射关系， n 层级联框架定义如下：

定义 n 层级联框架 n -cascaded。进行第 i 次预测的学习器位于级联框架的第 i 层级，其目标标签集合为 $\{U_{i+1}^i, U_{i+2}^i, \dots, U_j^i, \dots, U_{n+1}^i\}$ ，用 Z_i 表示，第 i 层级的学习器记为 f_i ，学习器的超参数记为 θ_i ，原始输入特征记为 X ，由第 $i-1$ 层级的学习结果计算得到的层级信息传递特征，记为 I_{i-1} ，则第 i 层级的表达式为 $Z_i = f_i((X, I_{i-1}); \theta_i)$ 。

1.2 级联多输出梯度提升回归树模型

级联框架搭建完成后需要进一步构建每层级的学习器，本文选择多输出梯度提升回归树模型进行每层的多节点预测。

输入多个表征预测对象特点的特征值后可以输出多个预测对象的预测值，即为多输入多输出^[13]，借助 python 中 MultiOutputRegressor 函数，整合封装多个独立单输出模型，可以构成一个多输出模型，仅需训练一次即可输出所有对象预测值，极大减少了模型训练的复杂度与时间成本，使得预测更加高效；而梯度提升回归树是以决策树为基本学习器的基于 boosting 框架的集成学习算法^[14]，可以

灵活地处理连续或离散类型的数据且充分利用数据的全部特征信息^[15]，并且对异常值有较好的鲁棒性^[14]，在相对较少的运算时间下能获得较高的预测精度^[16]。因此，构建多输出梯度提升回归树进行单层多节点预测，结合级联框架形成 CMO-GBRT 模型，并设计航班地面保障多节点动态预测算法如图 3 所示，具体步骤如下：

步骤 1 获取机场地面保障实际运行数据，分




图 3 级联多输出梯度提升回归树算法框架

Fig. 3 Algorithm framework for cascaded multi-output gradient boosting regression tree

析并构建具有 m 个原始输入特征的原始特征集 $X = \{x_1, x_2, \cdots, x_m\}$, 判断地面保障关键节点, 构建 n 个层级的 CMO-GBRT 模型, 其中, 第 i 层的子模型记为 CMO-GBRT _{i} 。

步骤 2 当保障进度推进到起始节点上轮挡时进行第 1 层级预测。此时无前序层级, 取紧前节点完成时间为初始层级传递特征, 记为 I_0 , 与 X 形成第 1 层级的特征集 input₁。

步骤 3 通过多次训练调参得到预测性能最优的 CMO-GBRT₁ 模型, 输入特征集 input₁, 得到当前保障进度下所有未完成节点的完成时间预测值 output₁。

步骤 4 当保障进度推进到第 2 个关键节点时进行第 2 层级预测。结合当前进度节点的真实值与上一层级的预测值计算得到层级传递信息特征 I_1 , 与 X 形成 input₂。

步骤 5 重复步骤 3 和步骤 4 直至完成所有层级预测, 其中, CMO-GBRT _{i} 模型输入为 input _{i} , 输出为 output _{i} , 输入下一层级的层级传递信息特征为 I_i 。最终获得所有动态预测结果 result。

2 数据准备及特征构建

2.1 实验数据及预处理

本文实验数据来源于浦东机场 2022 年的部分过站客运航班地面保障运行数据, 数据字段包括航班基本信息与主要保障节点时刻数据, 如表 1 所示。机位一栏出现 2 个机位号表示该航班进离港使用了不同机位, 存在拖曳的情况。经数据清洗后得到有效数据样本 50 770 条。

表 1 航班地面保障运行数据			
Table 1 Data of flight ground service operations			
字段	样例	字段	样例
日期	2021-3-1	上轮挡	14:32
航班号	9C6136 9C8569	开客门	14:36
航班属性	正班	下客开始/结束	14:38 14:43
STA	14:35	保洁开始/结束	14:51 15:02
STD	15:50	供油开始/结束	15:24 15:37
机型	A320	配餐开始/结束	15:28 15:29
机位	55 61	登机口开启	15:34
航线性质	国内 国际	登机口关闭	15:50
地面代理	CQH	关客门	15:57
旅客总数	175 165	撤轮挡	16:07

注: STA 为计划到港时间, STD 为计划离港时间, CQH 为国际民用航空组织规定的春秋航空三字代码。

因为时间格式数据不适用于回归预测模型, 所以需要进行数据转化, 定义某个节点完成时间为地面保障开始至该节点完成的时长:

$$T_{\text{task}} = t_{\text{task}}^{\text{end}} - t_0 \tag{3}$$

式中: T_{task} 为节点完成时间, task 为节点名; $t_{\text{task}}^{\text{end}}$ 为该节点实际完成时间; t_0 为保障实际开始时间, 本文以上轮挡时间代替。转化后表 1 样例节点完成时间如表 2 所示。

表 2 航班地面保障节点完成时间转化结果
Table 2 Conversion result of node completion time in flight ground service

节点	转化后节点完成时间/min	节点	转化后节点完成时间/min
上轮挡	0	配餐结束	57
开客门	4	登机口开启	62
下客结束	11	登机口关闭	78
保洁结束	30	关客门	85
供油结束	65	撤轮挡	95

2.2 特征集构建

2.2.1 基础属性特征

本文构建基础属性特征, 对应定义中的原始输入特征 X 。关于地面保障时间预测的已有研究主要考虑机型、机位、航线性质、地面代理、运行时段等外部特征^[10], 而由机场航班时刻表决定的内部特征较少得到关注, 包括航班的计划过站时间、最小过站时间及航班密度等, 本文在特征集的构建中拟引入这些因素, 具体如下。

1) 过站时间因素

计划过站时间是航班计划离港时间与计划到港时间的差值, 机场保障部门需根据计划过站时间合理调配人力与设备资源。如图 4(a) 所示, 由于每个航班入位后均需立即进行开客门与下客作业, 所以计划过站时间长短对开客门与下客结束节点完成时间无显著影响, 而其余节点均与计划过站时间密切相关。计划过站时间计算如下:

$$T_s = t_{\text{STD}} - t_{\text{STA}} \tag{4}$$

式中: T_s 为计划过站时间; t_{STD} 为计划离港时间; t_{STA} 为计划到港时间。

最小过站时间是指地面服务人员为保证飞机完成后续飞行任务提供所需服务的必要服务时间。浦东机场常见机型的座位数可分为 250 座以下和 250 座以上 2 类, 民航局规定的最小过站时间标准分别为 65 min 和 75 min。2022 年浦东机场无 A380 机型执飞的客运航班, 其标准为 120 min, 在本文暂不考虑。如图 4(b) 所示, 本文最小过站时间设




图 4 过站时间对地面保障节点完成时间的影响

Fig. 4 Effect of turn-round time on node completion time in flight ground service

置为分类变量, 基于机型确定 65 min 和 75 min 两类最小过站时间, 分别用 0 和 1 表示。不同的最小过站时间标准也显著影响了节点完成时间(开客门和下客结束除外)。

2) 航班密度因素

航班密度表示在过站航班邻近时间窗内需要竞争地面保障资源的航班数量, 其数值直观反映了机场地面保障的繁忙情况。如图 5 所示, 航班密度越大, 则保障任务越密集, 保障资源使用越紧凑, 促使提高保障作业效率, 进而对除开客门和下客结束外的各节点完成时间产生影响。本文定义航班密度为在当前保障航班实际落地的前后相邻时间窗内落地的航班数量:

$$N_d = (N_b t + N_a t) / 2t \tag{5}$$

式中: N_d 为到达航班密度; N_b 、 N_a 分别为当前保障航班实际落地前、后相邻时间窗内落地的航班数量; t 为时间窗, 本文取 15 min。




图 5 航班密度对地面保障节点完成时间的影响

Fig. 5 Effect of flight density on node completion time in flight ground service

2.2.2 层级信息传递特征

本文具体构建前序保障预测时间与前序保障

预测偏差这 2 个层级信息传递特征, 如图 6 所示, 通过 CMO-GBRT 进行预测时, 保障进度依次推进到每个节点时, 都将对未完成节点的完成时间进行新一层级的预测值更新, 当前进度中刚完成的节点既拥有一个上一层级的预测时间, 还拥有一个新获得的实际时间, 将上一层级的预测值作为前序保障预测时间特征, 将预测值与实际值的偏差作为前序保障预测偏差特征:

$$L_{pre} = U_i^{i-1} \tag{6}$$

$$L_{bias} = V_i - U_i^{i-1} \tag{7}$$

式中: L_{pre} 为前序保障预测时间特征; U_i^{i-1} 为第 $i-1$ 层级中第 i 个节点完成时间的预测值; L_{bias} 为前序保障预测偏差特征; V_i 为第 i 层级开始时获得的第 i 个节点完成时间的实际值。




图 6 层级信息传递特征示意图

Fig. 6 Level information transmission feature

2.2.3 最终特征集

结合浦东机场实际运行数据, 考虑基础属性特征与层级信息传递特征的最终特征集。其中, 基础属性特征: 机型 C , 是否拖曳 X_{pull} , 进港机位 S_{arr} , 离

港机位 S_{dep} , 进港机位类型 N_{arr} , 离港机位类型 N_{dep} , 进港航站楼 T_{arr} , 离港航站楼 T_{dep} , 进港旅客数 P_{arr} , 离港旅客数 P_{dep} , 地面代理 G , 进港保障时段 F_{arr} , 离港保障时段 F_{dep} , 进港航线性质 Q_{arr} , 离港航线性质 Q_{dep} , 最小过站时间 T_{MTTT} , 计划过站时间 T_S , 到达航班密度 N_d 。层级信息传递特征: 前序保障预测时间 L_{pre} , 前序保障预测偏差 L_{bias} 。

3 实验验证与结果分析

进行地面保障多节点动态预测前, 需要预先判断保障关键节点以设计预测层级。结合浦东机场实际保障数据计算保障关键路线, 得到的关键路线主要由旅客流程及部分其他流程的节点组成, 现有研究也表明地面保障能否按时完成与旅客保障流程密切相关^[4]。但此时关键路线上的节点数量仍较多, 不利于对保障过程进行有效监控, 因此, 再利用多元线性回归模型进一步分析不同节点的延迟完成时间对最终保障完成时间的影响程度, 初步确定上轮挡、开客门、下客结束、供油结束、登机口开启、登机口关闭、关客门与撤轮挡这 8 个影响最大的节点为初始关键节点。因此, 初步构建具有 7 个层级的 CMO-GBRT 模型。

由 2.2.3 节可知每层级特征集各需构建 20 个特征, 包括 18 个固定的基础属性特征和 2 个动态变化的层级信息传递特征, 将处理好的数据集以 7:3 的比例划分为训练集与测试集, 设置平均绝对误差 (mean absolute error, MAE)、 R 平方值 (R -squared, R^2) 和预测精度等预测性能为模型评价指标, 其中, 预测精度指标为预测结果与实际时间差值在 $\pm 3 \text{ min}$ 和 $\pm 5 \text{ min}$ 内的样本数量占比。

在保障进行到上轮挡节点时进行初次预测, 对应第 1 层级模型, 用紧前节点完成时间进港滑入时长作为初始层级信息传递特征, 初始预测结果如表 3 所示。第 1 层级预测对象为开客门、下客结束、供油结束、登机口开启、登机口关闭、关客门和撤轮挡共 7 个节点, 除供油结束节点外, 其余节点预测结果的 MAE 均低于 3.2 min, 表明这些节点的初始预测结果与真实时间的误差较小, 符合机场协同决策系统技术规范^[17]对关键节点预测准确性的要求; 同时 R^2 较高, 包括供油结束节点在内均大于 0.7, 表明模型对样本数据的拟合度较好, 验证了本文构建的特征集的有效性; 在预测精度方面, 除供油结束节点外, 其余节点 $\pm 5 \text{ min}$ 的预测精度均达到 80% 以上, $\pm 3 \text{ min}$ 的预测精度均达到 50% 以上, 其中, 开客门与下客结束节点的 $\pm 3 \text{ min}$ 预测精度更达到了 85.20% 与 67.32%, 表明在第 1 层级获得的

初始预测时间与真实时间的 5 min 偏离值较小, 初始预测能较好地确定节点实际完成时间的范围, 在上轮挡开始时即能对资源投入与保障进度安排提供指导。

表 3 第 1 层级关键节点完成时间预测结果

Table 3 Prediction results of key node completion time at Level 1

关键节点	MAE/min	R^2	$\pm 3 \text{ min}$ 预测精度/%	$\pm 5 \text{ min}$ 预测精度/%
开客门	1.60	0.85	85.20	95.39
下客结束	2.46	0.80	67.32	87.98
供油结束	7.66	0.72	26.40	41.61
登机口开启	2.93	0.96	56.36	82.47
登机口关闭	2.96	0.97	54.79	82.37
关客门	2.94	0.97	55.44	83.23
撤轮挡	3.11	0.97	52.97	80.04

注: 预测精度是指模型输出的时间与实际滑入时间的差值在某一设定范围内的数量与总预测样本数之比。

在第 1 层级初始预测的 7 个节点中, 供油结束节点的拟合度较好但预测误差大、预测精度低, 表明本文模型在全面学习供油结束节点数据信息的情况下仍不能对其进行准确预测。与其余关键节点不同, 实际保障中供油结束后并不一定紧邻后序登机口开启节点, 因此, 其非延误情况下完成时间范围大、不确定性高, 仅在延误时对保障过程产生影响, 且可以通过登机口开启节点是否延误进行侧面印证, 其预测值对实际保障指导性不高。因此, 不再将供油结束节点作为关键节点, 最终建立 6 层级 CMO-GBRT 模型, 层级序号与进行该层级预测时的保障进程对应关系如表 4 所示。

表 4 层级序号与进行该层级时的对应保障进程

Table 4 Level number and service process at corresponding levels

层级序号	对应保障进程	层级序号	对应保障进程
1	上轮挡	4	登机口开启
2	开客门	5	登机口关闭
3	下客结束	6	关客门

为验证 GBRT 模型的优越性, 选择目前常用于地面保障预测的深度学习模型中的卷积神经网络 (convolutional neural network, CNN)、经典机器学习算法中的决策树 (decision tree, DT)、支持向量机回归 (support vector regression, SVR) 及同为集成学习模型的随机森林 (random forest, RF) 进行对比分析, 以第 1 层级撤轮挡节点的预测结果为比较对象, 对比如表 5 所示。预测误差方面, 树模型类的 DT、RF 与 GBRT 相对较低, 其中, GBRT 最优; 模型拟合方面 GBRT 的表现也较好; 预测精度方面, SVR 在 $\pm 3 \text{ min}$ 预测精度最高, GBRT 处于中间水平, 但

表 5 不同模型在第 1 层级时的撤轮挡时间预测结果对比

Table 5 Comparison of off-block time prediction results of different models at Level 1


预测模型	MAE/min	R^2	± 3 min预测精度/%	± 5 min预测精度/%
CNN	5.77	0.87	34.83	53.64
DT	3.62	0.85	59.58	73.00
SVR	5.31	0.53	63.60	70.23
RF	3.83	0.77	55.03	78.42
GBRT	3.11	0.97	52.97	80.04

是在 ± 5 min 预测精度上, GBRT 具有最高的精度, 远高于 SVR 模型。综上所述, 本文模型误差更小、拟合度更高、预测精度更好, 因此, 本文选择 GBRT 模型作为基准模型是有效的。

表 6 所有节点在不同层级的动态预测结果

Table 6 Dynamic prediction results for all nodes at different levels

保障进程	层级	MAE/min	R^2	± 3 min预测精度/%	± 5 min预测精度/%
开客门	1	1.60	0.85	85.20	95.39
	2	1.92	0.87	79.65	95.27
登机口开启	1	2.93	0.96	56.36	82.47
	2	2.93	0.96	57.41	83.06
	3	2.92	0.96	58.37	83.14
登机口关闭	1	2.96	0.97	54.79	82.37
	2	3.02	0.96	55.91	81.11
	3	2.99	0.97	55.69	82.19
	4	2.56	0.97	64.05	88.61
关客门	1	2.94	0.97	55.44	83.23
	2	3.01	0.97	55.89	81.91
	3	2.97	0.97	56.88	82.21
	4	2.5	0.98	66.06	88.93
	5	0.96	0.98	97.04	99.00
撤轮挡	1	3.11	0.97	52.97	80.04
	2	3.11	0.97	54.59	79.96
	3	3.11	0.97	54.02	79.89
	4	2.62	0.98	64.46	86.60
	5	2.11	0.98	75.22	94.54
	6	2.01	0.98	77.34	95.29



升,可以不断指导各保障单位加大或减少资源投入、加快或放慢保障进度等,提高资源的调配效率。值得关注的是,登机口关闭、关客门与撤轮挡节点的预测性能在第4层级得到显著提升,因此,登机口开启是协同决策机制介入地面保障进程、避免航班延误的最佳切入点。

综上所述,本文构建的CMO-GBRT模型在模型误差、拟合度和预测精度上都获得了较好的预测结果,并可与A-CDM系统的相关模块结合以提供航班地面保障关键节点预计完成时间与整体进度,实现A-CDM系统对地面保障进程的实时监控功能,为保障异常情况处置、保障过程干预和保障作业协调提供有力的指导。

4 结 论

本文提出通过级联框架构建多层级模型,实现不同保障进度间的预测信息传递,并结合多输出梯度提升回归树进行保障过程动态预测,研究表明:

1) 包含前序保障预测时间与预测偏差的层级信息传递特征是级联结构中连接各层级的核心要素与影响预测结果的关键因素,计划过站时间、最小过站时间和航班密度等由航班时刻表决定的内部特征同样限制了保障进程,因此,引入这些特征构造模型特征集,初始预测 $\pm 5\text{ min}$ 预测精度均可达到80%以上。

2) 随着保障过程推进,原层级模型预测结果的指导性降低,层级信息传递特征可为新一层级模型提供修正信息,达成修正预测偏差、提高预测性能的目的,使得60%以上节点的最终预测 $\pm 5\text{ min}$ 精度超过95%,为机场和航司实施干预保障进度提供准确参考依据。

航班地面保障过程是多主体协同、多作业串并行的复杂过程。本文方法仅为串联关系的保障关键节点提供了动态预测,层级信息传递方式未考虑实际保障中可能存在的并行节点情况,尚有不足,未来将在相关数据可得的情况下进一步开展覆盖保障全流程节点的动态预测研究。

参考文献 (References)

[1] MILLER T, LU B, STERLING L, et al. Requirements elicitation and specification using the agent paradigm: the case study of an aircraft turnaround simulator[J]. IEEE Transactions on Software Engineering, 2014, 40(10): 1007-1024.

[2] GARCÍA ANSOLA P, GARCÍA HIGUERA A, OTAMENDI F J, et al. Agent-based distributed control for improving complex resource scheduling: application to airport ground handling operations[J]. IEEE Systems Journal, 2014, 8(4): 1145-1157.

[3] 冯霞,张鑫,陈锋. 飞机过站上客过程持续时间分布[J]. 交通运输工程学报, 2017, 17(2): 98-105.

FENG X, ZHANG X, CHEN F. Boarding duration distribution of aircraft turnaround[J]. Journal of Traffic and Transportation Engineering, 2017, 17(2): 98-105(in Chinese).

[4] SCHULTZ M, EVLER J, ASADI E, et al. Future aircraft turnaround operations considering post-pandemic requirements[J]. Journal of Air Transport Management, 2020, 89: 101886.

[5] POHLING O, SCHIER-MORGENTHAL S, LORENZ S. Looking into the crystal ball: how automated fast-time simulation can support probabilistic airport management decisions[J]. Aerospace, 2022, 9(7): 389.

[6] EVLER J, ASADI E, PREIS H, et al. Airline ground operations: schedule recovery optimization approach with constrained resources[J]. Transportation Research Part C: Emerging Technologies, 2021, 128: 103129.

[7] SHEIBANI K. Scheduling aircraft ground handling operations under uncertainty using critical path analysis and Monte Carlo simulation[J]. International Journal of Business Strategy and Automation, 2020, 1(1): 37-45.

[8] 邢志伟,吴兵,罗晓,等. 基于AFSA-RVM的航班保障服务时间状态估计[J]. 计算机仿真, 2020, 37(8): 35-39.

XING Z W, WU B, LUO X, et al. State estimation about service time of flight support based on AFSA-RVM[J]. Computer Simulation, 2020, 37(8): 35-39(in Chinese).

[9] 邢志伟,韩大浩,罗谦. 基于改进GA的神经网络航班保障时间估计[J]. 计算机工程与设计, 2020, 41(1): 107-114.

XING Z W, HAN D H, LUO Q. Estimation of flight support time based on improved GA neural network[J]. Computer Engineering and Design, 2020, 41(1): 107-114(in Chinese).

[10] 王立文,李彪,邢志伟,等. 过站航班地面保障过程动态预测[J]. 北京航空航天大学学报, 2021, 47(6): 1095-1104.

WANG L W, LI B, XING Z W, et al. Dynamic prediction of ground support process for transit flight[J]. Journal of Beijing University of Aeronautics and Astronautics, 2021, 47(6): 1095-1104(in Chinese).

[11] MA Y L, JAMES HOUSDEN R, FAZILI A, et al. Real-time registration of 3D echo to X-ray fluoroscopy based on cascading classifiers and image registration[J]. Physics in Medicine and Biology, 2021, 66(5): 055019.

[12] TIAN M Z, LIU L, LU J Y, et al. Vehicle recognition based on haar features and adaboost cascade classifier[J]. Journal of Physics: Conference Series, 2022, 2303(1): 012052.

[13] 王宁,曹萃文. 基于XGBoost模型的炼油厂氢气网络动态多输出预测模型[J]. 华东理工大学学报(自然科学版), 2020, 46(1): 77-83.

WANG N, CAO C W. A dynamic multi-output prediction model of the hydrogen network in a real-world refinery based on XGBoost model[J]. Journal of East China University of Science and Technology, 2020, 46(1): 77-83(in Chinese).

[14] ALHAKEEM Z M, JEBUR Y M, IMRAN H, et al. Prediction of ecofriendly concrete compressive strength using gradient boosting regression tree combined with gridsearchCV hyperparameter-optimization techniques[J]. Materials, 2022, 15(21): 7432.

[15] HUANG Y F, LIU Y H, LI C H, et al. GBRTVis: online analysis of gradient boosting regression tree[J]. Journal of Visualization, 2019, 22(1): 125-140.

[16] WANG T, HU S H, JIANG Y. Predicting shared-car use and examining nonlinear effects using gradient boosting regression trees[J]. International Journal of Sustainable Transportation, 2021, 15(12): 893-907.

[17] 中国民用航空局. 机场协同决策系统技术规范: MH/T 6125—2022

[S]. 北京: 中国民用航空局, 2022.

Civil Aviation Administration of China. Technical specifications for airport collaborative decision-making system: MH/T 6125—2022

[S]. Beijing: Civil Aviation Administration of China, 2022(in Chinese).

Dynamic prediction of flight ground service based on cascade

TANG Xiaowei^{1,*}, DING Ye¹, WU Zhenglong², ZHANG Shengrun¹, WU Jiaqi¹, YE Mengfan¹

(1. College of Civil Aviation, Nanjing University of Aeronautics and Astronautics, Nanjing 211106, China;
2. School of Aviation, University of New South Wales, Sydney NSW 2052, Australia)

Abstract: Accurate prediction of flight ground service is the key to achieving fine flight management and improving management efficiency of the airport collaborative decision making (A-CDM) system. Therefore, a multi-node dynamic prediction method for flight ground service based on a cascaded multi-output gradient boosting regression tree model was proposed. The cascaded framework was built to realize the prediction information transmission and result updates between different service schedules. The dynamic prediction algorithm of flight ground service was designed based on gradient boosting regression tree which could be used for multi-node prediction. By taking a typical busy airport as an object, a feature set was constructed, covering flight basic attributes and level information transmission. The results show that the proposed method can effectively realize the dynamic prediction of key node completion time in flight ground service. The initial prediction accuracy of each node within ± 5 min reaches more than 80%, and the prediction performance gradually improves as the flight ground service continues. The final prediction accuracy of over 60% of nodes within ± 5 min exceeds 95%. It provides effective method support for improving the flight operation predictability and the collaborative decision making ability of multi-agents in airports.

Keywords: air transportation; flight ground service; airport collaborative decision making; cascade; gradient boosting regression tree; dynamic prediction

Received: 2023-06-01; Accepted: 2023-11-13; Published Online: 2023-11-21 15:22

URL: link.cnki.net/urlid/11.2625.V.20231120.1526.002

Foundation items: National Natural Science Foundation of China (U2333204,U2233208); 2023 Civil Aviation Safety Capacity Building Project ((2023)No.155); Postgraduate Research & Practice Innovation Program of NUAA (xcxjh20220715)

* Corresponding author. E-mail: tangxiaowei@nuaa.edu.cn