

<http://bhxb.buaa.edu.cn> jbuaa@buaa.edu.cn

DOI: 10.13700/j.bh.1001-5965.2023.0443

基于 GBDT-GS 方法的民机重着陆风险预测

王向章^{1,*}, 牟瑞芳¹, 王赫², 许博浩²

(1. 西南交通大学 交通运输与物流学院, 成都 610031; 2. 四川航空股份有限公司 飞行部, 成都 610200)

摘 要: 重着陆可能造成机体结构损伤等征候事件, 甚至机毁人亡飞行事故。针对当前重着陆风险评估缺乏物理本质剖析, 为有效实施重着陆风险识别和等级判据, 以便提高飞行员着陆操作品质, 结合飞行状态分析, 基于梯度提升决策树 (GBDT) 算法和网格搜索 (GS) 法构建重着陆风险预测模型。通过飞机受力分析并构建着陆飞行运动学方程, 确定与重着陆关系密切的 5 项飞行状态参数; 从机载快速存取记录器 (QAR) 记录的数据中提取飞行状态数据构建数据集, 并根据 QAR 参数特征, 通过 GBDT 算法构建重着陆风险预测模型, 并利用 GS 优化模型参数; 以某航空公司“成都-沈阳”航线运行为例, 选取 530 个 QAR 数据对该模型进行训练和测试, 并与随机森林、Logistic 多元回归、循环神经网络 (RNN) 等算法结果比较。结果表明: GBDT-GS 方法在预测重着陆风险方面的性能较其他算法优异, 预测准确率达到 92%, 验证了所建模型的客观有效性。

关 键 词: 飞行状态; 重着陆; 风险预测; QAR 数据; 梯度提升决策树

中图分类号: V328.5

文献标志码: A

文章编号: 1001-5965(2025)09-3011-09

进近着陆阶段是飞行运行关键阶段。为保证飞机安全平稳着陆, 在进近着陆过程中, 飞行员需保持飞机航向、速度、姿态及发动机推力始终处于稳定状态^[1]。飞行状态的不稳定意味着飞机能量存在异常, 若不能及时控制则可能造成能量意外释放, 进而导致飞行事故发生。根据波音公司 2007—2016 年安全报告, 进近着陆飞行事故死亡人数占全球商用喷气式飞机事故总死亡人数的 48%, 其中, 飞行状态不稳定是导致飞行事故的关键因素^[2]。2019 年国际航空运输协会 (International Air Transport Association, IATA) 发布的安全报告则进一步指出, 重着陆、冲出跑道和飞行失控是进近着陆阶段发生频率较高的飞行事故, 这些事故几乎都与飞机飞行状态异常直接相关, 其中重着陆占到所有飞行事故的 14%^[3]。众所周知, 重着陆可能造成机体结构损伤等事故征候, 甚至机毁人亡飞行事故。重着

陆致因较为复杂, 包括环境因素、航空器性能、飞行员操作等, 但这些因素的影响结果最终都反应到飞机飞行状态变化上^[4]。

重着陆是指飞机接地时垂直加速度过大, 接地载荷超过了该机型给定的限制值^[5]。在实际运行过程中, 航空公司主要通过监控快速存取记录器 (quick access recorder, QAR) 数据中的接地时垂直加速度 (vertical acceleration during grounding, VRTG) 参数判断飞机是否发生接地载荷大事件。这种监控方式较为单一, 属于事后型分析, 缺乏及时性, 且常常存在误判漏判情况。对此, 围绕重着陆诊断和探测, 部分学者结合仿真技术或利用 QAR 数据, 采用贝叶斯灵敏性分析方法^[6]、支持向量机^[7-8]、人工神经网络^[9-10]等数据挖掘技术提高重着陆判断的精确度, 以便及时发现危害飞机结构的安全事件; 针对重着陆风险分析和预测, 有的学者主要通过软件、硬件、环境、人 (software, hardware, environment,

收稿日期: 2023-07-05; 录用日期: 2023-09-10; 网络出版时间: 2023-09-13 16:46

网络出版地址: link.cnki.net/urlid/11.2625.V.20230912.1820.001

基金项目: 民航安全能力建设基金项目 (ASSA202019)

* 通信作者. E-mail: 513432965@qq.com

引用格式: 王向章, 牟瑞芳, 王赫, 等. 基于 GBDT-GS 方法的民机重着陆风险预测 [J]. 北京航空航天大学学报, 2025, 51 (9): 3011-3019.

WANG X Z, MOU R F, WANG H, et al. Hard landing risk prediction of civil aircraft based on GBDT-GS method [J]. Journal of Beijing University of Aeronautics and Astronautics, 2025, 51 (9): 3011-3019 (in Chinese).

liveware, SHELL)模型来识别影响重着陆的风险因素^[11-12],有的则基于统计分析方法^[5]、正态云概念^[13]等构建了重着陆风险分析与评价模型,以评价飞行员着陆操作风险,或者结合实际飞行数据(主要为QAR数据),利用过程控制方法^[14]、动态事件规整方法^[15]、自适应变异粒子群法^[16]等实现了重着陆风险预测。但是,上述研究更多偏重于数学模型和算法的应用,并未从物体运动的角度深入分析重着陆发生的本质原因。

从物理本质上讲,重着陆是飞机受力改变引起飞行状态变化导致的结果,而飞行员操作、大气气流等都可能引起飞机受力发生变化,进而改变飞行状态。飞行状态是飞机在任一瞬时所处的空间位置、飞行速度及飞行姿态。因此,要认识重着陆发生的本质,需要理清飞行状态变化与重着陆之间的关系。目前,国内外专家学者在飞行状态研究方面已开展大量研究。这些研究的基本思路是通过传统的飞行动力学建模,运用卡尔曼滤波^[17-18]、约束粒子滤波模型^[19]及隐马尔可夫模型^[20]等方法识别或预测飞机飞行状态及轨迹变化,以帮助管制员指挥飞机及时调整飞行速度、高度和航向,进而避免发生空中冲突。而随着飞行数据质量和可用性的不断提高,越来越多学者开始利用递归神经网络^[21]、聚类分析技术^[22]、长短期记忆网络模型^[23]等大数据挖掘方法来识别飞行状态,分析飞机运动轨迹。然而,不管是传统机理建模分析,还是通过大数据技术预测,都只是从方法上提高飞行状态估计的准确程度,而对飞行状态变化与飞行事故之间的关联性并没有作进一步剖析。

尽管国内外学者已较为系统地分析了重着陆成因并开展了风险评价研究,但鲜有人剖析飞行状态变化对重着陆的影响。鉴于此,本文在已有研究的基础上,从飞机着陆运动过程入手,通过运动受力分析并构建着陆飞行运动学方程,确定与重着陆关系密切的飞行状态参数;然后,提出利用网格搜索(grid search, GS)法优化梯度提升决策树(gradient boosting decision tree, GBDT)来构建重着陆风险预测模型;最后,结合航班真实QAR数据,采用构建的GBDT-GS方法对重着陆风险进行预测,并验证本文方法的有效性。

1 飞行状态与重着陆风险

1.1 着陆飞行运动学方程

飞机从离跑道端口高15 m左右开始到飞机完全停止运动为着陆阶段。飞行员通常在决断高度前脱开自驾,改为人工操纵飞机进近着陆,并通过飞行显示器监控飞机速度、高度、姿态等飞行状态

信息,以便在状态发生偏离时及时恢复飞机稳定状态。根据标称着陆过程,可将着陆划分为3个阶段:下滑阶段、拉平飘落阶段、减速滑跑阶段,如图1所示。其中, γ 为下滑角, R 为拉平圆周运动半径, H_A 为下滑飞行高度, H_B 为飞机过跑道端口点高度, H_C 为飞行员拉平开始高度, X_1 为着陆下滑至拉平点的水平飞行距离, X_2 为拉平过程飞行距离, X_3 为着陆滑跑距离。




图1 标称进近着陆任务示意图

Fig. 1 Diagram of nominal approach and landing mission

飞机在着陆过程中主要受气动力(气动升力、气动阻力)、发动机推力和重力共同作用,并由气动力产生滚转力矩、俯仰力矩和偏航力矩。气动升力垂直于飞行速度,方向向上;气动阻力平行于飞行速度,方向向后;忽略发动机安装角,则推力平行于飞机纵轴,方向与速度方向一致,如图2所示,其中, L 为气动升力, D 为气动阻力, θ 为俯仰角, α 为飞机迎角, V 为飞行速度, T 为发动机推力, W 为重力。着陆过程中,飞机飞行状态变化的物理本质是受力的作用,且主要沿纵向做线性运动及绕机体纵轴和横轴的转动,而横轴的位置变化较小^[24]。因此,参考文献[24]建立各个阶段纵向运动学方程。




图2 飞机纵向受力示意图

Fig. 2 Diagram of longitudinal force on aircraft

1.1.1 下滑阶段

正常下降时,发动机处于慢车状态,飞机机头略微向下,并沿正常下滑角(3°)减速下滑。当飞

机在离跑道端口 15 m 左右高度时, 飞机速度达到进场速度 V_{app} 。通常情况下, 进场速度 V_{app} 与进场基准速度 V_{REF} 相同。下滑阶段飞机的飞行状态方程为

$$\begin{cases} \frac{W}{g} \cdot \frac{dV}{dt} = T \cos \alpha - D + W \sin \gamma \\ T \sin \alpha + L - W \cos \gamma = 0 \\ \frac{dH}{dt} = -V \sin \gamma \\ \frac{d\gamma}{dt} = 0 \\ \frac{dX_1}{dt} = V \cos \gamma - V_w \end{cases} \quad (1)$$

式中: W 为飞机重力; g 为重力加速度; H 为无线电高度; V_w 为风速。

1.1.2 拉平飘落阶段

由于前起落架能承受的撞击力远小于主起落架, 若以正常下滑角着陆, 飞机将直接俯冲向跑道, 造成严重结构损伤。因此, 在下滑到离地约 9 m 高度时, 飞行员通过拉杆和收油门配合操纵, 使飞机逐渐退出下滑状态转为平飘接地状态。在拉平过程中, 下滑角将由 3° 逐渐减小为 0° , 飞机俯仰姿态和迎角逐渐增大, 机头由低头状态逐渐转为抬头状态, 迎角保持一定, 形成两点姿势, 然后, 匀速下沉并在接地区域达到接地速度。拉平飘落阶段飞机的飞行状态方程为

$$\begin{cases} \frac{W}{g} \cdot \frac{dV}{dt} = T \cos \alpha - D + W \sin \gamma \\ \frac{W}{g} V \frac{d\gamma}{dt} = T \sin \alpha + L - W \cos \gamma \\ \frac{dH}{dt} = -V \sin \gamma \\ \frac{dX_2}{dt} = V \cos \gamma - V_w \end{cases} \quad (2)$$

1.1.3 减速滑跑阶段

飞机主轮接地后, 反推和地面扰流板打开, 飞机阻力增大, 滑跑速度减小。随着速度的减小, 升力也随之减小, 机头自然下俯, 直至前轮接地。待前轮接地后, 飞行人员使用脚踏板进行刹车减速, 并随滑跑速度减小, 再逐渐增大刹车量。减速滑跑阶段飞机的飞行状态方程为

$$\begin{cases} V_t = V - at \\ X_3 = Vt - \frac{1}{2}at^2 \\ a = \frac{g}{W} [T \cos \alpha - \mu W - (C_D - \mu C_L) \rho V^2 S / 2 - W \varphi] \end{cases} \quad (3)$$

式中: μ 为摩擦系数; ρ 为空气密度; S 为机翼参考面积; C_D 为阻力系数; C_L 为升力系数; V_t 为某时刻飞

机的滑跑速度; a 为飞机滑跑加速度; φ 为滚转角。

1.2 重着陆风险因子

飞行状态一般采用飞行速度、飞行高度、俯仰角、滚转角、迎角及侧滑角等来表征。由重着陆定义可知, 重着陆的发生必然伴随接地垂直加速大现象, 而垂直加速度与飞行高度、接地前垂直方向的飞行速度等飞行状态参数直接相关。结合式(1)和式(2)的飞行运动学方程, 从下滑、拉平、平飘、接地等过程, 对飞机着陆运动过程进行分析。

在下滑过程中, 若进跑道端口高度高, 为保证飞机在接地区域接地, 需增大下滑角快速下降, 从而导致下降率增加, 垂直加速度增大; 若拉平前飞行速度过大, 通过提前收油门减速, 可能使飞机升力快速减小, 垂直加速度增大。在拉平过程中, 若拉开始操作的高度较低, 飞机在接地前具有一定下滑角, 在重力 W 作用下将以较大的下降率快速下降, 飞行员带杆修正量不足, 则势必导致垂直加速度过大。在平飘至接地过程中, 接地飞行俯仰角小, 飞机迎角也将变小, 可能导致飞机升力骤减, 进而因 $W > L$ 造成飞机垂直加速度过大。在接地过程中, 受天气或飞行操作影响, 飞机可能存在一定滚转角, 使得接地瞬间存在主轮单点接地情况, 则单侧垂直方向上受力较大, 接地载荷可能瞬间超过机型限制值。

根据上述分析, 飞机在着陆过程中垂直加速度过大与过跑道端口高度、飞行速度、下降率、飞行俯仰角等密切相关。而飞行员对油门、操作杆的操作又直接影响飞行速度、俯仰姿态角, 同时接地前遇到风切变、顺风、乱流等恶劣天气, 也会影响飞行速度和姿态角。当这些因子出现异常时, 都可能直接或间接造成重着陆。但无论是飞行操作原因, 还是天气变化带来的影响, 最终都反应在飞行状态的变化上。因此, 本文以无线电高度 H 、飞行速度 V 、下降率 $I_{\downarrow}$ 、俯仰角 θ 、滚转角 φ 等飞行状态参数作为变量来分析状态变化导致的重着陆风险。

2 飞机重着陆风险预测模型

QAR 作为记录飞机飞行参数信息的重要设备, 储存了飞行员全部操作动作及飞机内外部状态参数数据, 常被用来监控飞行操作品质, 分析不安全事件原因。利用 QAR 数据分析飞机飞行状态和预测重着陆风险, 需要从原始 QAR 数据中提取有效信息。实际飞行运行中, 绝大部分 QAR 数据均为正常数据, 而涉及重着陆的飞行状态异常数据较少, 因此, 需要从大量已知数据中识别出异常数据, 即对异常数据进行分类处理以实现风险预测。

2.1 GBDT 算法

GBDT 是一种集成学习算法,其通过迭代训练多个决策树来提高模型性能。由于 GBDT 算法在回归预测和分类问题上具有良好的性能,因而受到各行业广泛关注。该算法由多棵决策树组成,主要采用前向分布式迭代方式,通过每次迭代学习基函数并更新权重系数来优化损失函数,从而使算法能够有效处理非线性关系和高维特征。假设 $t-1$ 次迭代得到的学习器为 $f_{t-1}(x)$, 损失函数为 $L(y, f_{t-1}(x))$, 则在第 t 次迭代后可找到一个能够使损失函数 $L(y, f_t(x))$ 最小的基函数 $g(x, \theta_t)$ ^[25]:

$$L(y, f_t(x)) = L(y, f_{t-1}(x)) + g(x, \theta_t) = (y - f_{t-1}(x) - g(x, \theta_t))^2 = r - g(x, \theta_t) \tag{4}$$

式中: $r = y - f_{t-1}(x)$ 为残差。在每次迭代过程中,沿负梯度方向,通过与每棵回归树拟合以减小残差。Friedman 提出利用梯度提升法减小残差,其主要通过泰勒公式一阶展开来近似处理损失函数^[26],如式(5)所示。该方法得到的损失函数值与实际更接近,且具有较高的预测准确率。图 3 为 GBDT 算法原理图。

$$r \approx -\left(\frac{\partial L(y_i, f(x_i))}{\partial f(x_i)}\right)_{f(x_i)=f_{t-1}(x)} \tag{5}$$




图 3 GBDT 算法原理图
Fig. 3 Schematic diagram of GBDT algorithm

2.2 基于 GBDT-GS 方法的重着陆风险预测模型

根据 GBDT 算法原理,以回归树为基学习器,平方误差为损失函数构建基于 GBDT 算法的重着陆风险预测模型。该模型通过累加所有基学习器的计算结果得到预测值,再利用下一个基学习器拟合损失函数对预测值的残差得到预测精度。为验证 GBDT 模型预测结果是否符合精度要求,再采用 GS 进一步优化模型参数。因此,重着陆风险预测模型包括基于 GBDT 算法的预测值计算及基于 GS 的模型参数优化。

2.2.1 基于 GBDT 算法的预测值计算

GBDT 算法的训练过程包括特征选择、分裂点选择和模型更新 3 个阶段。特征选择阶段,通过计算各飞行状态参数特征的平方差损失,并选择具有

最小损失的特征作为分裂特征;分裂点选择阶段,根据选定的分裂特征,计算不同分裂点的分裂增益 (Gain), 并选择具有最大增益的分裂点作为最佳分裂点;模型更新阶段,利用贪心算法遍历所有分裂特征的所有分裂点,并通过循环迭代分裂过程,生成多个基学习器。在每次迭代中,GBDT 根据学习器的误差率来更新模型的权值分布。Gain 计算公式为

$$G_{\text{ain}} = \frac{1}{2} \left[\frac{G_L^2}{H_L + \lambda} + \frac{G_R^2}{H_R + \lambda} - \frac{(G_L + G_R)^2}{H_L + H_R + \lambda} \right] - \hat{\gamma} \tag{6}$$

式中: G_L 为左子树梯度值; G_R 为右子树梯度值; H_L 为左子树的设置分数; H_R 为右子树的设置分数; λ 表示正则项系数; $\hat{\gamma}$ 为叶子个数。

无线电高度 H 、飞行速度 V 、下降率 I_{VV} 、俯仰角 θ 、滚转角 φ 等飞行状态参数的平方误差损失分别为: h_{loss} 、 V_{loss} 、 I_{VVloss} 、 θ_{loss} 、 φ_{loss} , 其权值更新过程如图 4 所示。




图 4 参数特征损失的权值更新过程
Fig. 4 Parameter feature loss weight updating process

2.2.2 基于 GS 的模型参数优化

模型训练时,模型的学习率 l 和决策树最大深度 d 对重着陆风险预测结果影响较大。为找到最佳的参数组合,本文采用 GS 法对模型参数进行调优^[27]。通过将待搜索参数的取值空间划分成一个网格,再对每个参数组合进行模型训练,选择出最佳预测结果的参数组合。根据经验,将 l 、 d 的取值空间分别设置为 $[0.05, 0.15]$ 、 $[1, 5]$, 空间步长设置为 0.01 、 1 。根据取值范围和空间步长,通过遍历每个待搜索参数组合对模型进行迭代训练和评估。经过多轮优化后,可得到具有通用性的超参数组

合,即将均方根误差(root mean square error, RMSE)最小的参数组合作为最终模型参数。利用 GS 法优化模型参数的过程如图 5 所示。




图 5 GS 优化模型参数

Fig. 5 Optimization of model parameters by GS

2.3 评估指标

本文实验主要采用准确率(accuracy, ACC)、RMSE、平均绝对误差(mean absolute error, MAE)和均方误差(mean square error, MSE)对 GBTD-GS 方法的预测性能进行评估。4 个评估指标的计算式分别为

ACC = (Tp + TN) / (Tp + TN + Fp + FN) (7)

MAE = 1/m * sum(|yi - y_i|) (8)

MSE = 1/m * sum((yi - y_i)^2) (9)

RMSE = sqrt(1/m * sum((yi - y_i)^2)) (10)

式中: yi 为真实值; y_i 为模型预测值; m 为实验样本数。若 MAE、MSE、RMSE 的值越小,则说明本文模型的预测性能越好。

3 实例分析与验证

3.1 实例分析流程

首先,本文根据着陆飞行运动方程分析,选取与重着陆相关的风险因子作为监测指标,并从 QAR 数据中提取重着陆相关飞行参数进行预处理;然后,建立基于 GBDT 的预测模型进行训练与测试,得到重着陆风险预测结果;最后,将预测结果与循环神经网络(recurrent neural networks, RNN)、Logi-

stic 多元回归、随机森林等算法进行比较,验证本文方法的有效性。本文方法流程如图 6 所示。




图 6 本文方法流程

Fig. 6 Flow of the proposed method

3.2 指标确定及数据预处理

根据飞行运动学分析,无线电高度 H、飞行速度 V、下降率 L_{VV}、俯仰角 θ、滚转角 φ 等飞行状态参数出现异常,将可能导致重着陆发生。飞行员在人工操作飞机着陆过程中,极易因操作技术、天气原因等导致飞行状态异常。因此,参考民航咨询通告《飞行品质监控(FOQA)实施与管理》(AC-121/135-FS-2012-45R1)^[28]及航空公司飞行品质监控中的监测标准,采用 Delphi 法,在广泛征集一线飞行人员意见后,以 A320 机型着陆过程中进跑道端口高度 x₁、拉平时(9 m 左右)飞行速度 x₂及接地前 1 s 的下降率 x₃、俯仰角 x₄、滚转角 x₅ 共 5 项飞行状态参数作为重着陆风险监测指标,并根据 A320 机型着陆载荷监控标准,以接地期间的 VRTG 值作为样本等级判据,并设置标签。飞行数据样本的数据化处理方式如表 1 所示。

从某航空公司 AirFASE 译码系统抽取 2022 年上半年“成都-沈阳”航段 QAR 数据,共计 580 份。经分析数据结构,所有 QAR 数据参数的采集频率均为 1 Hz(每秒采样 1 次)。由于飞机传感器敏感

表 1 飞行数据样本的数据化处理

Table 1 Data processing of flight data samples		
接地载荷	样本状态	标签
VRTG > 1.75G	高风险	3
1.6G < VRTG < 1.75G	中风险	2
1.5G < VRTG < 1.6G	低风险	1
VRTG < 1.5G	无风险	0

注: G 表示飞机“过载”。

度原因,导致部分 QAR 数据存在缺失。为使样本数据的质量满足预测分析要求,通过剔除缺失严重的数据,最终得到 530 份 QAR 数据,然后,从数据样本中选取前文确定的与重着陆相关的飞行状态参数建立数据集,数据集样本如表 2 所示。由于篇幅原因,本文仅列出其中部分原始数据,并按照 7:3 的比例建立训练集与测试集,即 371 个样本作为训练集,159 个样本作为测试集。训练集和测试集的数据样本均按照航班运行时间排列,使样本保持时间序列特征。

表 2 数据集样本 (部分)

Table 2 Data set sample (partial)

样本	x_1/m	$x_2/(\text{m}\cdot\text{s}^{-1})$	$x_3/(\text{m}\cdot\text{s}^{-1})$	$x_4/(\text{°})$	$x_5/(\text{°})$	标签
1	14.32	67.39	-1.204	2.81	0	0
2	14.63	69.45	-1.219	3.52	-1.32	0
3	15.24	69.45	-1.300	6.33	-2.46	0
4	13.72	72.02	-1.382	2.98	-2.46	1
5	19.51	70.48	-2.753	1.41	0	3
6	14.93	70.48	-1.529	4.20	0.40	0
⋮	⋮	⋮	⋮	⋮	⋮	⋮
529	18.29	68.42	-1.544	2.30	0.40	2
530	15.85	69.45	-1.199	3.46	1.05	0

由于飞行参数数据单位不统一,数值范围差异较大,为加强预测模型的泛化能力,加快收敛速度,保证模型的训练和预测效果,采用式(11)对训练集和测试集原始数据进行归一化处理,实现一致性分析:

$$x' = \frac{x - (x_{\max} - x_{\min})}{x_{\max} - x_{\min}} \tag{11}$$

式中: x 为样本当前值; $x_{\max}$ 和 $x_{\min}$ 分别为样本数据的最大值和最小值。

3.3 实验结果讨论与分析

3.3.1 实验结果

本次实验运行环境及参数配置:电脑 CPU 为 2.70 GHz,内存 32.0 GB,操作系统为 Windows11,编程语言为 Python3.11。在实验过程中,设置梯度提升决策树模型训练最大迭代次数为 200 次,利用 GS 法对 GBDT 模型进行优化,通过调整学习率和树的深度,得到不同参数条件下模型的预测性能,如表 3 所示。使用 ACC、MSE、MAE 和 RMSE 作为评估指标,经过反复迭代实验,当最大迭代次数为 200 次,学习率为 0.10,最大深度为 4 时, RMSE 的值最小。

利用测试集数据对模型进行验证,由 GBDT-GS 模型预测测试集数据,预测准确度为 92%,结果如图 7 所示。图中,0 级风险、1 级风险、2 级风险、3 级风险分别为无风险、低风险、中风险、高风险。

表 3 不同参数下的预测性能 (部分)

Table 3 Prediction performance under different parameters (partial)

参数	ACC	RMSE	MAE	MSE
[200, 0.05, 1]	0.868 1	0.125 8	0.419 6	0.176 1
⋮	⋮	⋮	⋮	⋮
[200, 0.05, 5]	0.869 8	0.159 2	0.469 2	0.221 3
⋮	⋮	⋮	⋮	⋮
[200, 0.10, 3]	0.886 4	0.169 8	0.520 0	0.270 4
[200, 0.10, 4]	0.918 5	0.119 5	0.412 1	0.163 5
[200, 0.10, 5]	0.875 4	0.207 6	0.555 1	0.308 2
⋮	⋮	⋮	⋮	⋮
[200, 0.15, 1]	0.865 8	0.251 6	0.537 9	0.289 3
⋮	⋮	⋮	⋮	⋮
[200, 0.15, 5]	0.875 0	0.213 8	0.560 78	0.314 5




图 7 重着陆风险识别结果

Fig. 7 Identification results of hard landing risk

3.3.2 模型对比分析

为验证本文模型的优越性,将 GBDT-GS 模型与随机森林、Logistic 多元回归和 RNN 构建的模型进行比较。将 GBDT-GS 的模型参数设定为:最大迭代次数为 200,学习率为 0.1,最大深度为 4;将随机森林的模型参数设定为:树的个数为 100,分裂准则为“gini”;将 Logistic 多元回归的模型参数设定为:L2 正则化;将 RNN 的模型参数设定为:隐含层神经元数目为 10,迭代训练次数为 10 次,核函数采用 Adam 函数。经过反复实验,以上 4 种算法训练得到的模型准确率变化对比如图 8 所示。

由图 8 可知,GBDT 算法结合 GS 建立的预测模型对重着陆风险预测的准确率比随机森林、Logistic 多元回归和 RNN 模型的准确率高。使用最优参数构建的模型和其进行预测的性能如表 4 所示。

由表 4 可知,GBDT-GS 模型的 RMSE、MAE 及 MSE 值均小于其他 3 种算法,说明使用 GBDT-GS 模型预测重着陆风险时,实际值与预测值之间的误差较小,模型的精度和预测效果优于其他算法。从而证




图 8 准确率变化对比

Fig. 8 Accuracy change comparison

表 4 4 种算法预测性能对比

Table 4 Comparison of prediction performance among four algorithms				
算法	ACC	RMSE	MAE	MSE
GBDT-GS	0.918 5	0.119 5	0.412 1	0.163 5
随机森林	0.886 8	0.123 2	0.440 4	0.182 4
Logistic多元回归	0.838 9	0.138 4	0.488 9	0.239 0
RNN	0.838 9	0.132 1	0.469 2	0.220 3

明了本文方法的优越性,可以为重着陆风险预测提供有力的方法支持。

提取“成都-沈阳”航段 A320 机型的 QAR 数据,运用 GBTD-GS 模型对最近 2 周 50 个航班重着陆风险进行评估预测,结果如表 5 所示。由表 5 可知,近 2 周 A320 机型运行沈阳机场,有 2 个航班存在重着陆风险,其中,第 25 个航班的重着陆风险等级为“3 级,高风险”,第 49 个样本的风险等级为“1 级,低风险”。针对第 25 个航班,结合具体飞行数据分析,飞机进跑道端口高度偏高($H>18\text{ m}$),拉平时飞行速度大,将导致飞机能量过大,为在接地区域接地,避免冲出跑道事故,飞行员通过推杆使飞机快速下沉,在后续修正过程中带杆不足,进一步造成飞机下降率大及接地俯仰角小,进而导致飞

表 5 “成都-沈阳”航段近期 QAR 数据

Table 5 Recent QAR data of Chengdu-Shenyang segment						
样本	x_1/m	$x_2/(\text{m}\cdot\text{s}^{-1})$	$x_3/(\text{m}\cdot\text{s}^{-1})$	x_4	x_5	风险等级
1	15.85	70.28	-0.518	4.60	-0.35	0
2	17.68	70.93	-1.463	4.22	-1.05	0
3	16.76	69.19	-0.833	4.92	0	0
⋮	⋮	⋮	⋮	⋮	⋮	⋮
25	23.16	73.89	-2.946	-1.10	-0.35	3
26	14.93	69.79	-1.488	4.04	0	0
⋮	⋮	⋮	⋮	⋮	⋮	⋮
49	16.76	70.74	-1.951	3.03	4.22	1
50	16.46	69.98	-0.523	4.13	0	0

机垂直加速度大,造成重着陆风险事件。后调取航班航后报告,着陆载荷达到 2.24G,评估结果与实际相符,因此,验证了 GBDT-GS 方法的客观有效性。

根据调研,绝大多数重着陆事件的发生都与进近着陆飞行操作密切相关,而飞行操作直接影响飞机飞行状态的变化,造成飞机能量异常。因此,在进近着陆过程中,对飞机能量进行控制是降低重着陆风险的有效手段。飞机能量管理主要包括动能管理和势能管理,其中,动能管理主要是对着陆飞行速度及飞行姿态的控制;势能管理主要是对飞机高度及下降率的控制,需要飞行员通过控制操作面(侧杆、方向舵等)和油门杆协调配合完成。在进近阶段,飞行员应在 300 m 左右使飞机处于稳定状态,并在飞行状态参数出现偏差后及时修正;下滑过程中,宜以固定的下滑点、合适的下滑曲线、稳定的下滑速度和均匀的下降率下滑,避免过跑道端口时高度过高、下降率过大;在拉平飘落过程中,应综合判断飞机下沉趋势,逐步带杆,柔和增加俯仰;若飞机过早拉平或拉飘后,不应为追求接地地点而前推驾驶杆。

4 结 论

1) 本文从重着陆事件发生的物理本质出发,针对飞机进近着陆过程,通过飞机受力分析并构建着陆飞行运动学方程,确定过跑道端口高度、飞行速度、下降率、俯仰角、滚转角等 5 项飞行状态参数与重着陆事件密切相关。

2) 通过 GBDT 算法构建了重着陆风险预测模型,并利用 GS 优化了模型参数;利用大量真实数据对模型进行训练和测试,并与随机森林、Logistic 多元回归和 RNN 模型对比。结果表明,GBDT-GS 方法在重着陆风险预测中的准确率和预测性能都高于其他模型,验证了本文模型的可用性。

3) 通过 QAR 数据,利用 GBDT-GS 模型评估 A320 机型运行沈阳机场的重着陆风险,得出准确率为 92%,进一步验证了本文模型识别和预测重着陆风险的客观有效性。

本文分析了各飞行状态参数对重着陆风险的影响关系,而飞行操作输入、气象环境等数据对重着陆的影响均反映在飞行状态变化上,因此,下一步需要分别建模分析飞行操作风险、气象环境风险对飞机着陆飞行状态的影响,以便深入识别重着陆间接风险因素,为重着陆风险控制提供指导。

参考文献 (References)

[1] International Civil Aviation Organization. Aircraft operations[M].

5th ed. Montreal: International Civil Aviation Organization, 2006.

[2] The Boeing Company. Statistical summary of commercial jet airplane accidents: worldwide operations | 1959-2024[R]. Chicago: The Boeing Company, 2025.

[3] International Air Transport Association. IATA safety report 2018[R]. Montreal: International Air Transport Association, 2019.

[4] 王冉. 基于飞行数据的颠簸飞行状态估计初步研究[D]. 南京: 南京航空航天大学, 2020.

WANG R. Preliminary study on bumpy flight state estimation based on flight data[D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2020(in Chinese).

[5] 汪磊, 孙瑞山, 吴昌旭, 等. 基于飞行 QAR 数据的重着陆风险定量评价模型[J]. 中国安全科学学报, 2014, 24(2): 88-92.

WANG L, SUN R S, WU C X, et al. A flight QAR data based model for hard landing risk quantitative evaluation[J]. China Safety Science Journal, 2014, 24(2): 88-92(in Chinese).

[6] SARTOR P, BECKER W, WORDEN K, et al. Bayesian sensitivity analysis of flight parameters in a hard-landing analysis process[J]. *Journal of Aircraft*, 2016, 53(5): 1317-1331.

[7] 聂磊, 黄圣国, 舒平, 等. 基于支持向量机 (SVM) 的民用飞机重着陆智能诊断研究[J]. 中国安全科学学报, 2009, 19(7): 149-153.

NIE L, HUANG S G, SHU P, et al. Intelligent diagnosis for hard landing of aircraft based on SVM[J]. China Safety Science Journal, 2009, 19(7): 149-153(in Chinese).

[8] 许桂梅, 黄圣国. 应用 LS-SVM 的飞机重着陆诊断[J]. 系统工程理论与实践, 2010, 30(4): 763-768.

XU G M, HUANG S G. Airplane's hard landing diagnosis using LS-SVM[J]. Systems Engineering-Theory & Practice, 2010, 30(4): 763-768(in Chinese).

[9] 曹海鹏, 舒平, 黄圣国. 基于神经网络的民用飞机重着陆诊断技术研究[J]. 计算机测量与控制, 2008, 16(7): 906-908.

CAO H P, SHU P, HUANG S G. Study of aircraft hard landing diagnosis based on neural network[J]. Computer Measurement & Control, 2008, 16(7): 906-908(in Chinese).

[10] 于健, 董健康, 李佳. 基于神经网络的飞机着陆垂直载荷大诊断技术研究[J]. 中国民航飞行学院学报, 2010, 21(4): 16-18.

YU J, DONG J K, LI J. Research on large diagnosis technology of aircraft landing vertical load based on neural network[J]. Journal of Civil Aviation Flight University of China, 2010, 21(4): 16-18(in Chinese).

[11] 郑薇. 基于 QAR 数据的重着陆风险评估及预测研究[D]. 天津: 中国民航大学, 2014.

ZHENG W. Research on risk assessment and prediction of heavy landing based on QAR data[D]. Tianjin: Civil Aviation University of China, 2014(in Chinese).

[12] 周进. 基于熵权 TOPSIS 的飞机重着陆风险因素排序[J]. 河南科技, 2019, 38(19): 106-110.

ZHOU J. Risk factors sequencing of aircraft hard landing based on entropy weight and topsis method[J]. Henan Science and Technology, 2019, 38(19): 106-110(in Chinese).

[13] 汪磊, 郭世广, 任勇. 基于飞行数据正态云的着陆操作风险评价方法[J]. 安全与环境学报, 2019, 19(5): 1555-1561.

WANG L, GUO S G, REN Y. Landing operation risk evaluation based on the normal cloud of the flight data[J]. Journal of Safety and Environment, 2019, 19(5): 1555-1561(in Chinese).

[14] 孙瑞山, 张思远, 汪磊. 基于统计过程控制的 QAR 数据风险预测方法[J]. 统计与决策, 2015, 31(21): 33-36.

SUN R S, ZHANG S Y, WANG L. QAR data risk prediction method based on statistical process control[J]. Statistics & Decision, 2015, 31(21): 33-36(in Chinese).

[15] 郑磊, 池宏, 许保光, 等. 飞机重着陆预警分析方法[J]. 数学的实践与认识, 2019, 49(3): 56-72.

ZHENG L, CHI H, XU B G, et al. Method of early warning analysis for aircraft hard landing[J]. Mathematics in Practice and Theory, 2019, 49(3): 56-72(in Chinese).

[16] 陈思, 孙有朝, 郑敏. 基于支持向量机的飞机重着陆风险预警模型[J]. 兵器装备工程学报, 2019, 40(9): 154-158.

CHEN S, SUN Y C, ZHENG M. Heavy landing risk pre-warning model based on support vector machine[J]. Journal of Ordnance Equipment Engineering, 2019, 40(9): 154-158(in Chinese).

[17] 阙向东. 飞机飞行状态估计与飞行品质评估研究[D]. 西安: 西北工业大学, 2004.

QUE X D. Research on aircraft flight state estimation and flight quality evaluation[D]. Xi'an: Northwestern Polytechnical University, 2004(in Chinese).

[18] 耿建中, 姚海林. 基于 UKF 的飞机飞行状态估计[C]//2008 系统仿真技术及其应用学术会议论文集. 合肥: 中国科学技术大学出版社, 2008: 68-71.

GENG J Z, YAO H L. Aircraft flight state estimation based on unscented Kalman filter[C]//Proceedings of the 2008 Academic Conference on System Simulation Technology and Applications. Hefei: Press of University of Science and Technology of China, 2008: 68-71(in Chinese).

[19] COOMBES M, LIU C J, CHEN W H. Situation awareness for UAV operating in terminal areas using bearing-only observations and circuit flight rules[C]//Proceedings of the American Control Conference. Piscataway: IEEE Press, 2016: 479-485.

[20] 孙禾. 航空器飞行状态预测方法研究[D]. 天津: 中国民航大学, 2014.

SUN H. Research on prediction method of aircraft flight state[D]. Tianjin: Civil Aviation University of China, 2014(in Chinese).

[21] RAOL J, JATEGAONKAR R. Aircraft parameter estimation using recurrent neural networks——A critical appraisal[C]//Proceedings of the 20th Atmospheric Flight Mechanics Conference. Reston: AIAA, 1995.

[22] LI L S, GARIEL M, HANSMAN R J, et al. Anomaly detection in onboard-recorded flight data using cluster analysis[C]//Proceedings of the IEEE/AIAA 30th Digital Avionics Systems Conference. Piscataway: IEEE Press, 2011: 1-31.

[23] LEE H, PURANIK T G, FISCHER O P, et al. Flight data driven system identification using neural networks for landing safety assessment[C]//Proceedings of the IEEE/AIAA 40th Digital Avionics Systems Conference. Piscataway: IEEE Press, 2021: 1-9.

[24] 王晴昊, 胡剑波, 姚登凯. STPA 在进近着陆飞行安全分析中的研究及应用[J]. 系统工程理论与实践, 2018, 38(10): 2703-2712.

WANG Q H, HU J B, YAO D K. Research and application of STPA to flight safety analysis in approach and landing[J]. Systems Engineering-Theory & Practice, 2018, 38(10): 2703-2712(in Chinese).

[25] 刘琼, 张豹. 基于 GBDT 算法的锂电池剩余使用寿命预测[J]. 电

子测量与仪器学报, 2022, 36(10): 166-172.

LIU Q, ZHANG B. Remaining useful lifetime prediction for lithium-battery based on GBDT algorithm[J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(10): 166-172(in Chinese).

[26] FRIEDMAN J H. Greedy function approximation: a gradient boosting machine[J]. The Annals of Statistics, 2001, 29(5): 1189-1232.

[27] 奉国和. SVM 分类核函数及参数选择比较[J]. 计算机工程与应用, 2011, 47(3): 123-124.

FENG G H. Parameter optimizing for support vector machines classification[J]. Computer Engineering and Applications, 2011, 47(3): 123-124(in Chinese).

[28] 中国民用航空局. 飞行品质监控 (FOQA) 实施与管理: AC-121/135-FS-2012-45R1[S]. 北京: 中国民用航空局飞行标准司, 2015-06-30.

Civil Aviation Administration of China. Implementation and management of flight quality control (FOQA): AC-121/135-FS-2012-45R1[S]. Beijing: Flight Standards Department of Civil Aviation Administration of China, 2015-06-30.

Hard landing risk prediction of civil aircraft based on GBDT-GS method

WANG Xiangzhang^{1,*}, MOU Ruifang¹, WANG He², XU Bohao²

- (1. School of Transportation and Logistics, Southwest Jiaotong University, Chengdu 610031, China;
2. Flight Department, Sichuan Airlines Co., Ltd., Chengdu 610200, China)

Abstract: Hard landing may cause structural damage of aircraft or other potential accident causes and even crash and fatal flight accidents. In view of the lack of physical nature analysis in current hard landing risk assessment, combined with flight status analysis, a hard landing risk prediction model based on gradient boosting decision tree (GBDT) and grid search (GS) was proposed to effectively implement hard landing risk identification and grade criteria and improve pilots' landing operation quality. Firstly, the flight kinematics equation of landing was established through the force analysis of aircraft, and five flight status parameters closely related to hard landing were determined. Then, flight status data was extracted from onboard quick access recorder (QAR) data to construct a data set. According to QAR parameter characteristics, the hard landing risk prediction model was constructed by the GBDT algorithm, and model parameters were optimized by GS. Finally, taking the Chengdu-Shenyang route operation of an airline as an example, the study selected 530 pieces of QAR data to train and test the model and compared the result of the model with those of random forest, recurrent neural networks (RNN), and Logistic multiple regression. The results show that the GBDT-GS method is better than other algorithms in predicting hard landing risk, and its prediction accuracy reaches 92%, which verifies the objective validity of the constructed model.

Keywords: flight status; hard landing; risk prediction; QAR data; gradient boosting decision tree