

中文引用格式:王文超,何健,汪磊,等. 融合 XGBoost 与 Transformer 的飞行员操纵风险预警方法[J]. 中国安全科学学报, 2025, 35(9): 121-128.

英文引用格式: WANG Wenchao, HE Jian, WANG Lei, et al. A pilot operation risk early warning method integrating XGBoost and Transformer [J]. China Safety Science Journal, 2025, 35(9): 121-128.

融合 XGBoost 与 Transformer 的飞行员操纵 风险预警方法*

王文超¹副教授, 何健^{**1}, 汪磊¹研究员, 张航宾²工程师

(1 中国民航大学 安全科学与工程学院, 天津 300300;

2 中国南方航空股份有限公司 信息中心, 广东 广州 510403)

中图分类号: X949

文献标志码: A

DOI: 10.16265/j.cnki.issn1003-3033.2025.09.0095

资助项目: 民航航空公司人工智能重点实验室项目(CZ202301118101)。

【摘要】 为强化飞行过程中的风险管理机制, 提出一种融合飞行大数据的飞行员操纵风险性预警方法。首先, 从快速存取记录仪(QAR)数据中筛选与不稳定进近相关的核心参数, 并利用梯度提升决策树(XGBoost)算法进行特征优化, 确定关键风险预警指标。然后, 融合 Transformer 网络的注意力机制, 构建有效捕捉时空依赖性的动态风险识别架构。最后, 以山东某航空公司 B737-800 型机的航班数据为例, 验证方法性能。结果表明: 该方法能够有效预测飞行中的风险事件, 尤其在降落前的关键时刻, 方法可提供高精度的风险预警。与传统预警方法相比, 该方法在识别精度、方法泛化性以及特征提取效能方面表现出显著优势。

【关键词】 飞行员; 风险预警; 极限梯度提升(XGBoost); Transformer; 快速存取记录仪(QAR)

A pilot operation risk early warning method integrating XGBoost and Transformer

WANG Wenchao¹, HE Jian¹, WANG Lei¹, ZHANG Hangbin²

(1 College of Safety Science and Engineering, Civil Aviation University of China, Tianjin 300300, China;

2 Information Center, China Southern Airlines, Guangzhou Guangdong 510403, China)

Abstract: To further enhance the risk management mechanism during flight operations, an early warning for pilot handling smoothness was developed by integrating flight big data. First, core parameters related to unstable approaches were filtered from QAR data. The XGBoost algorithm was then utilized for feature optimization to identify key risk early warning indicators. Subsequently, a dynamic risk identification architecture capable of effectively capturing spatio-temporal dependencies was constructed by incorporating the attention mechanism of Transformer networks. Finally, the method's performance was validated using flight data from B737-800 aircraft operated by an airline in Shandong. The results indicate that this method can effectively predict in-flight risk events, particularly in providing high-accuracy risk warnings

* 文章编号: 1003-3033(2025)09-0121-08; 收稿日期: 2025-04-17; 修稿日期: 2025-06-18

** 通信作者: 何健(1998—), 男, 山西太原人, 硕士研究生, 主要研究方向为航空人因安全分析。E-mail: hj0010202023 @ 163.com。

during critical phases before landing. Compared with traditional warning methods, the approach demonstrates significant advantages in identification accuracy, model generalization capability, and feature extraction efficiency.

Keywords: pilot; risk early warning; eXtreme Gradient Boosting (XGBoost); Transformer; quick access recorder (QAR)

0 引言

当前我国民航领域的安全管理仍以事后调查与快速存取记录仪 (Quick Access Recorder, QAR) 数据分析为主,其存在响应滞后、预警迟缓等不足,难以满足现代飞行运行对主动安全保障的迫切需求。因此,有必要开展研究并构建与之匹配的动态风险评估与预警机制。

目前,国内学者对于飞行安全风险评估的研究已经取得一定成果。如汪磊等^[1]利用 QAR 数据揭示了操纵特征对进近着陆结果的影响机制。张兆宁等^[2]提出一种基于多准则决策方法的飞行安全风险评估模型。陈光柔等^[3]构建了融合系统安全工程的飞行安全评估框架,整合故障树与事件树分析方法,实现了对飞行风险的递进式分解与系统化辨识,显著提升了风险评估的全面性与精细化水平。综合国内相关研究成果可知:尽管多维度飞行监控数据已在安全评估中展现出较高的分析价值,但当前方法普遍缺乏对飞行数据实时波动的响应能力,且对飞行员操控行为的动态建模与提前预警仍显不足。

鉴于此,笔者拟聚焦于空间分布、时间演化及其交互作用 3 个维度,系统性地探索不稳定进近事件的时空特征与动态演变特征,并进行可视化呈现。基于极限梯度提升 (eXtreme Gradient Boosting, XGBoost) 算法进行特征筛选,并结合 Transformer 的注意力分配机制,构建不稳定进近触发因子预警框架。通过对多元 QAR 参数的时空关联建模,系统辨识不稳定进近事件的触发因子及演化模式,深入解析其内在规律性与典型特征。以期实现对飞机不稳定进近状态的精准预警。

1 着陆风险预警体系构建

建立一套科学且具备可操作性的风险评估指标体系,是实现进近与着陆阶段有效风险识别与预警的核心基础。基于飞机复杂状态预防与改出训练 (Upset Prevention and Recovery Training, UPRT) 理论^[4],从人-机-环境系统要素出发,构建层次化指

标体系。各指标均满足数据可获得性要求,并依据解释结构方法计算结果确定其层级关系,依据结果构建层级,并完全遵照事故因果关系进行指标连接,指标结构如图 1 所示。

在系统梳理着陆流程各环节的基础上,归纳提炼出包含 3 大类共计 56 项与着陆密切相关的 QAR 数据参数。在飞行员进近过程中,UPRT 划分了明确的标准,见表 1。

依据标准规范要求,选取俯仰角、横滚角、航向变化率及坡度变化率 4 项关键指标作为核心预警变量,其余参数作为训练特征输入算法,借以实现对不稳定进近事件的前瞻性识别。

2 进近着陆操纵风险预警方法

2.1 XGBoost 特征提取

采用 XGBoost 算法评估 QAR 特征变量与不稳定进近事件之间的相关性强度,以提升特征选择的科学性与算法输入的精度。

XGBoost 算法应用列抽样策略增强方法泛化性能,其核心特征增益度的计算彼此独立,可以并行计算,从而大幅提高效率^[5]:

1) 风险预警参数集初始化。建立候选风险预警参数集 $W^{(0)} = \{x_1, x_2, \dots, x_n\}$ 。

2) 风险预警参数特征重要度计算。依据交叉验证原则,结合 XGBoost 优化过程中的拉格朗日对偶方法,对各特征的贡献度进行权重 ω 的分配与评估。

$$\omega = \sum_{i=1}^n \alpha_i y_i x_i, i = 1, 2, \dots, n \quad (1)$$

第 k 个风险预警参数的特征重要度为 ω_k , 表示为:

$$\omega_k = (\omega_k)^2 = \left(\sum_{i=1}^n \alpha_i y_i x_{ik} \right)^2 \quad (2)$$

式中: ω_k 为第 k 个参数的权重系数; α_i 为拉格朗日乘子; y_i 为第 i 个数据样本的类别; x_{ik} 为第 i 个数据第 k 个参数的数值; n 为数据样本容量。

3) 候选参数集更新。依据特征重要度评估结果,迭代剔除当前候选参数集中权重最低的风险指




图 1 进近着陆风险体系指标

Fig. 1 Approach and landing risk system indicators

标,从而生成更新后的候选集 $\mathbf{W}^{(i+1)}$ 及其关联数据集 $\mathbf{V}^{(i+1)}(\mathbf{W}^{(i+1)}, y)$ 。将各参数被剔除的次序进行逆向排列并整合,最终形成一组按特征重要性降序排列的参数序列 $\mathbf{T} = \{x_{r_1}, x_{r_2}, \cdots, x_{r_m}\}$, r 表示特征的重要性排名顺序, r_1 为最重要, r_m 为最不重要,该序列将作为后续风险建模的关键参考依据。

4) 风险预警参数提取。风险预警参数子集的构建采用递进式策略:初始子集 $\mathbf{T}_{(1)}$ 仅包含序列 $\mathbf{T}$ 中重要性排名首位的参数 x_{r_1} ;再逐级将序列 $\mathbf{T}$ 形成包含所有 n 个参数的第 n 级子集 $\mathbf{T}_{(n)}$ 。

以选取的 4 项预警指标为参考,通过 XGBoost 相关性分析 56 项输入指标,去除指标之间的相互干扰,以俯仰角为例,作出其相关性如图 2 所示。

各特征变量的重要性由 QAR 训练样本的系统计算与比较排序得出,从而确保输入特征集具有更强的判别效能。

经特征相关性分析,筛选出重要性排名前 21 位的指标作为方法输入,剔除贡献度低的指标以降低噪声干扰,从而优化方法训练精度,保留 21 项指标,见表 2。

表 1 稳定进近标准
Table 1 Stable approach criteria

进近类型	进近阶段	具体标准
仪表进近	五边进近 305~457 m(机场标高以上,Above Field Elevation,(AFE))	飞机飞行航径正确
		只需要很小的航向/俯仰变化就能保持正确的飞行航径
		推力调至适合于飞机形态
		着陆襟翼放出;起落架放下,完成着陆形态
		完成着陆检查单;完成着陆准备(风挡、雨刷、夜航灯光)
		按进近图规定的标准稳定下降率(如果进近下降时)
		调整速度到目标速度(+10/-5 kn)
	五边进近 152 m(AFE)	航道和下滑道偏离指示在+/-1个点范围内
		按进近图规定的标准保持稳定的下降率并不超过 305 m/min
		保持速度稳定在目标着陆速度(+5/-0 kn)
目视进近	五边进近 305 m(AFE)	航道和下滑道偏离指示小于+/- (1/4)点范围并保持在航道/下滑道上
		飞机飞行航径正确
		只需要很小的航向/俯仰变化就能保持正确的飞行航径
		推力调至适合于飞机形态
		着陆襟翼放出;起落架放下,完成着陆形态
		完成着陆检查单;完成着陆准备(风挡、雨刷、夜航灯光)
	五边进近 152m(AFE)	调整速度到目标速度(+10/-5 kn)
		保持稳定的着陆航向对正跑道,在转弯后对正跑道或反向进近对正跑道时,机翼应是水平的
		保持稳定的下降率,不超过 305 m/min(如果进近需要降率大于 305 m/min,下降前应做特别简令)
		保持速度稳定在目标着陆速度(+5/-0 kn)
着陆	进近着陆过程中	目视着陆在高于接地点 30 m 时,飞机的位置应该是驾驶舱在跑道水平延长线范围之内,并持续保持在此范围
	飞机过跑道时	稳定在目标速度到目标速度+5 kn 以内,或是机型要求的进近着陆速度的目标值
		稳定地保持飞行的航径
		可以在接地区做正常着陆(跑道的前 914 m 或前 1/3,以较短的为准)

表 2 特征提取后的输入指标

Table 2 Input indicators after feature extraction			
参数序号	参数名称	参数序号	参数名称
1	踏板输入量	12	风速
2	修正油门频率	13	风向
3	下滑道偏差	14	大气压力
4	垂直载荷	15	湿度
5	仰角	16	襟翼位置
6	推力杆位置	17	空速
7	下降率	18	空气温度
8	航向角	19	坡度角
9	磁航向	20	右发转速
10	迎角	21	左发转速
11	垂直偏差		

2.2 注意力机制

通过分析进近着陆问题,鉴于所采集的多航班

着陆阶段 QAR 数据蕴含显著的时空复杂性及不确定性特征^[6],设计并实现融合 XGBoost 特征筛选与 Transformer 时序建模的进近着陆风险预警方法。该方法由输入层、特征提取卷积模块、注意力分配单元以及输出预测层构成,层间结构协同实现高维序列数据的有效建模^[7]。在飞行员获取目视参考后启动决策过程,该过程综合考虑多样化的着陆场景条件和飞行员个体操作特性。方法初始化关键参数,包括决策时限 T 、反馈矩阵 S 、偏好阈值 γ 以及初始偏好向量 $P(0)$,这些参数作为决策域方法的核心输入,支撑后续的动态推理^[8]。根据每类操作模式的统计数量,设定关键参数:

1) 属性矩阵 M 。 M 的元素 m_{ij} 表示飞行员对于备选方案 i 的属性 j 的评价值^[9]。基于 B737-800 机型,选取 4 项关键操控变量作为方法的风险输出指标。理想情况下,操作参数应趋近其标准设定值。基于 QAR 数据,利用正态分布拟合确定各预警参数




图 2 风险指标皮尔逊相关系数

Fig.2 Pearson correlation coefficient plots for risk indicators

的特征分布,并将变量的均值设定为参考基准,以坡度变化率为例展示,如图 3 所示。属性矩阵的归一化处理通过线性插值方法完成^[10],具体结果见表 3、表 4。




图 3 进近着陆正态拟合

Fig.3 Approach and landing normal fit diagram

从表 3 和表 4 可以看出,俯仰角预警效果最优,不同属性表现有所差异,体现了飞行员对各属性关

表 3 预警指标矩阵与指标参考值

Table 3 Early warning indicator matrix and reference values of indicators (°)

预警参数	均值	标准参考值
俯仰角	1.88	0.92
横滚角	1.76	0.82
航向变化率	1.93	0.96
坡度变化率	1.87	0.85

表 4 预警指标归一值

Table 4 Normalization of early warning indicators (°)

预警参数	归一值
俯仰角	0.98
横滚角	0.84
航向变化率	0.63
坡度变化率	0.77

注程度不同。整体来看,飞行员在着陆过程中更倾

向于关注俯仰角变化,而对如接地姿态、操作幅度等控制因素重视不够,这可能导致重着陆或偏离跑道等不平稳事件,从而增加接地环节的风险水平。

2) 注意力权重向量 $\mathbf{W}(t)$ 。 $\mathbf{W}(t)$ 表示飞行员在时刻 t 分配给每个风险指标的关注程度^[11]。着陆阶段要求飞行员持续监控各项关键属性的参数动态。假设飞行员在决策过程中对不同风险指标的关注度遵循一个平稳随机过程进行演化。方法初始化时,为 4 项核心预警指标赋予均等的注意力权重^[12]。

2.3 风险预警方法运行

归一化后的 QAR 数据被按时间步组织成二维矩阵格式,以适应方法对时序数据的学习需求^[13]。同时,采用滑动窗口机制构建训练样本,目标预测值为未来 25 s 时刻的目标变量 y 。同时,在保障方法运行效率的情况下,滑动窗口大小也设为 25 s。

为验证方法效能,采用 Transformer 层、Dropout 层和 Dense 层的网络架构提出预警方法^[14]。针对不同类型的风险诱因,所采用的 Transformer 架构在细节设计上略有差异,并需结合试验反馈进行逐步调优。

3 风险预警结果与分析

在完成数据预处理后,选取来自山东某航空公司的 B737-800 型航班共 200 架次,其中,用于方法训练、验证和测试的数据分别为 200、60 和 140 条记录。每架航班均构建 150 个样本,最终形成 4 个独立试验组。为保留各航班序列数据的时间依赖特征,并避免样本间的信息泄露,采用滑动窗口策略分段构建输入数据。方法输入部分引入前期特征选择得到的 21 项 QAR 参数,输出层则聚焦于 4 个关键飞行操控指标:俯仰角、横滚角、航向变化率和坡度

变化率。

3.1 风险预警参数计算

归一化处理数据集的进近着陆风险预警参数数据,经处理后的进近着陆风险预警数据集示例见表 5。借助 XGBoost 算法对所有风险变量进行排序,形成按重要性递减排列的候选参数序列 $U=\{\text{下降率,迎角,下滑道偏差},\cdots,\text{左发转速}\}$,用于后续多级参数组合测试。按照参数权重等级,逐步构建包含不同数量变量的 21 个风险预警子集,并分别在验证集中评估其分类性能,见表 6。

表 5 进近着陆风险预警数据集

Table 5 Approach and landing risk early warning data sets

组别	下降率	迎角变化率	下滑道偏差	...	襟翼位置
1	0.933 8	0.881 4	0.860 4	...	0.294 8
2	0.713 9	0.851 6	0.751 5	...	0.361 9
3	0.635 4	0.773 6	0.780 8	...	0.453 3
4	0.454 6	0.910 2	0.760 2	...	0.501 5

表 6 风险预警参数集预警准确率

Table 6 Early warning accuracy of risk early warning parameter sets

风险指标数	风险指标	预警准确率/%
1	下降率	58.91
2	下降率,迎角	79.32
3	下降率,迎角,下滑道偏差	86.76
⋮	⋮	⋮
21	下降率,迎角,下滑道偏差⋯,左发转速	94.93

3.2 风险预警结果

将筛选出的 21 项关键指标输入预设的着陆风险评估规则库中,方法计算结果输出各指标对应的风险值,见表 7。

表 7 进近着陆时刻风险预警值

Table 7 Risk early warning values during approach and landing

指标	下降率	仰角	修正油门频率	空速	迎角	垂直偏差
风险预警值	3.39	3.32	3.28	3.21	3.19	3.12
指标	下滑道偏差	风速	磁航向	襟翼位置	航向角	坡度角
风险预警值	3.03	2.98	2.88	2.76	2.51	2.33
指标	右发转速	左发转速	踏板输入量	垂直载荷	推力杆位置	风向
风险预警值	2.06	2.06	1.98	1.77	1.43	1.02
指标	空气温度	大气压力	湿度	—	—	—
风险预警值	0.53	0.32	0.11	—	—	—

根据预警原则,当风险值达到某一阈值时,预警系统应立刻对飞行员给予相应提示,并明确指出风险来源。依据第 1 节所定义的进近着陆规范标准,

将风险水平细化为 3 类区间: $[0,1.5]$ 为安全, $[1.5,3]$ 为较安全, $[3,+\infty]$ 标示为需及时调整。由表 7 可知:在进近着陆阶段,下降率、仰角、修正油门

频率、空速、迎角、垂直偏差和下滑道偏差为风险值较高的指标,需要飞行员重点关注,对于下降率偏高及下降轨迹异常等高风险因子,预警系统应在关键阶段及时发出预警提示,引导飞行员快速作出修正决策。

表 8 下降率接地过程风险预警值

接地前时刻/s	25	20	15	10	5	4	3	2	1
风险预警值	3.39	3.40	4.59	6.60	6.91	5.23	4.88	4.01	3.26

预警结果如图 4 所示,由图 4a 和图 4b 可知:该方法在训练集和验证集上对俯仰角的预测趋势与实际值大体吻合,但在俯仰角突变点及横滚角幅度较小时预测精度有待提升。由图 4c 和图 4d 可知:坡度变化率和航向变化率的预测曲线与真实值走势高度吻合,进一步表明方法在这 2 类指标上的预测精度较高,具备良好的预警效果。方法输出的预测曲线与实际观测数据吻合度较高,有效捕捉了各预警

选择风险等级最高的“下降率”这一指标进行计算,表 8 显示了飞机从接地前 25 s 至触地瞬间的风险预警值演化过程,风险值在初期持续上升,随后逐步回落,该趋势验证了方法在 25 s 预测窗口下的有效性,为飞行员提供充裕的操控调整时间。

变量在进近着陆过程中的动态演化特征。通过实时监测关键预警指标是否突破预设的进近着陆安全阈值,可辅助判定发生操纵不平稳事件的风险等级。需指出,该方法涉及的参数配置及预警阈值具备灵活性,可依据不同航空公司的运行标准和规章进行定制化调整。展望未来研究,整合更丰富的 QAR 数据流,构建多模态输入特征,有望显著增强该方法对复杂风险态势的预测精度与鲁棒性。




图 4 预警结果展示
Fig. 4 Display of early warning results

4 结 论

1) 充分利用民航历史飞行数据,提出一种系

统化的数据处理方案以实现进近着陆阶段的风险识别。通过“人-机-环境”多维视角提取关键预警因子,并引入 XGBoost 算法对其重要性进行

量化排序,构建结构合理、特征显著的风险预警数据集。所采用的特征工程技术显著降低了方法训练的复杂性,并同步提升了预警结果的准确性。

2) 为增强该方法应对多样化风险场景的适应能力和预测精度,针对不同的风险触发机制,设计了具有结构差异性的算法。但是实际运行中仍需开发

兼容性更强的统一预警方法,以实现多种触发类型的实时预测与响应,从而全面降低进近阶段的安全风险,确保飞行落地过程的平稳性。同时,在建模的过程中,也需要考虑更多的精度评定方法。此外,未来方法设计应进一步引入长时序依赖建模机制,以增强对持续性不稳定趋势的识别能力,从源头保障飞行任务的运行安全。

参考文献

- [1] WANG Lei, SUN Ruishan, WU Changxu. An analysis of flight quick access recorder (QAR) data and its applications in preventing landing incidents[J]. Reliability Engineering and System Safety, 2014, 23(11): 89-91.
- [2] 张兆宁,陈子辰,卢飞. 配对进近侧向位置误差 QAR 参数关联性分析[J]. 中国安全科学学报, 2021, 31(8): 47-52.
- [3] ZHANG Zhaoning, CHEN Zichen, LU Fei. Correlation analysis of QAR parameters for lateral position error in paired approach[J]. China Safety Science Journal, 2021, 31(8): 47-52.
- [4] CHEN Kuangjiu, SHIN Jiaping, CHU Hsuanlin, et al. Training and dashboard design: Impact on operator performance and mental workload for flight safety[J]. Safety Science, 2025, 181: 525-535.
- [5] BECKER T, AYTON P. Effects of flight crew role assignment on aviation accidents and incidents: evidence of a systemic safety issue[J]. Safety Science, 2024, 17(10): 52-63.
- [6] 朱彤,秦丹,魏雯,等. 基于机器学习的公交驾驶员事故风险识别及影响因素研究[J]. 中国安全科学学报, 2023, 33(2): 23-30.
- [7] ZHU Tong, QIN Dan, WEI Wen, et al. Research on accident risk identification and influencing factors of bus drivers based on machine learning[J]. China Safety Science Journal, 2023, 33(2): 23-30.
- [8] 戴义博,赵晓华,边扬,等. 雾天桥梁运行风险主动预警防控策略的改善效用[J]. 华南理工大学学报:自然科学版, 2024, 52(11): 118-133.
- [9] DAI Yibo, ZHAO Xiaohua, BIAN Yang, et al. Improvement effectiveness of active warning prevention and control strategy for operation risk on foggy bridges[J]. Journal of South China University of Technology: Natural Science Edition, 2024, 52(11): 118-133.
- [10] TANG Ziyang, LI Zuo Tian, HOU Tieying. SiGra: single-cell spatial elucidation through an image-augmented graph transformer[J]. Nature Communication, 2023, 14(1): DOI: 10. 1038/s41467-023-41437-w.
- [11] 武强,张帅,杜沅泽,等. 基于 MRAU 视频分割模型的矿井涌(突)水风险识别方法[J]. 煤炭科学技术, 2024, 52(11): 17-28.
- [12] WU Qiang, ZHANG Shuai, DU Yuanze, et al. Mine water inrush risk identification method based on MRAU video segmentation model[J]. Coal Science and Technology, 2024, 52(11): 17-28.
- [13] 李博文,丁牧恒,方美华,等. 基于注意力机制优化的神经网络模型对行驶疲劳度的研究[J]. 计算机工程, 2023, 11(3): 1-15.
- [14] LI Bowen, DING Muheng, FANG Meihua, et al. Study on fatigue detection based on neural network models optimized by attention during driving[J]. Computer Engineering, 2023, 11(3): 1-15.
- [15] 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, 2023, 49(9): 1-12.
- [16] WANG Xiangzhang, MOU Ruifang, WANG He, et al. Hard landing risk prediction of civil aircraft based on GBDT-GS method[J]. Journal of Beijing University of Aeronautics and Astronautics, 2023, 49(9): 1-12.
- [17] 祝琴,韩沈阳,曾明如,等. SFW-YOLOv8 复杂场景视频车辆检测模型[J]. 汽车工程, 2024, 46(12): 2 290-2 302.
- [18] ZHU Qin, HAN Shenyang, ZENG Mingru, et al. SFW-YOLOv8 complex scene video vehicle detection model[J]. Automotive Engineering, 2024, 46(12): 2 290-2 302.
- [19] 曹鹏飞,王秀英,孟庆斌. 融合测距修正和哈里斯鹰优化的 DV-Hop 定位算法[J]. 电子测量技术, 2023, 46(11): 166-172.
- [20] CAO Pengfei, WANG Xiuying, MENG Qingbin. DV-Hop localization algorithm combining ranging correction and Harris hawks optimization[J]. Electronic Measurement Technology, 2023, 46(11): 166-172.
- [21] 王均,黄钊然,许潇,等. 基于阶梯碳价和自适应分时电价的电动汽车有序充电[J]. 电力自动化设备, 2024, 44(2): 64-71.
- [22] WANG Jun, HUANG Keran, XU Xiao, et al. Ordered charging of electric vehicles based on ladder-type carbon price and adaptive time-of-use electricity price[J]. Electric Power Automation Equipment, 2024, 44(2): 64-71.
- [23] 刘旒菲,李小帅,杨俊安,等. 基于 SANER-PPO 算法的无人机集群干扰资源分配方法[J]. 控制与决策, 2024, 39(12): 3 937-3 945.
- [24] LIU Yifei, LI Xiaoshuai, YANG Jun'an, et al. SANER-PPO algorithm-based jamming resource allocation for UAV swarm[J]. Control and Decision, 2024, 39(12): 3 937-3 945.

作者简介: 王文超 (1982—),男,河北承德人,博士,副教授,主要从事民航安全风险管理和人因工程等方面的研究。E-mail:wenchao wang@163.com。

