

中文引用格式:李怀谦,陈雨昊,付宇翔,等. 基于 WGAN-XGBoost 的 ADS-B 异常数据检测模型[J]. 中国安全科学学报, 2025, 35(8):188-195.

英文引用格式:LI Huaqian, CHEN Yuhao, FU Yuxiang, et al. ADS-B abnormal data detection model based on WGAN-XGBoost[J]. China Safety Science Journal, 2025, 35(8):188-195.

基于 WGAN-XGBoost 的 ADS-B 异常数据检测模型^{*}

李怀谦^{1,2}, 陈雨昊¹, 付宇翔¹, 沈嘉意³

(1 中国民航大学 空中交通管理学院, 天津 300300; 2 中国东方航空武汉有限责任公司, 湖北 武汉 430300; 3 中国民航大学 理学院, 天津 300300)

中图分类号:X924.2

文献标志码:A

DOI: 10.16265/j.cnki.issn1003-3033.2025.08.1566

资助项目:国家级大学生创新创业训练计划项目(202410059019)。

【摘要】 为保障航空运行安全、提升空域管理效率并增强系统对欺骗与干扰的防御能力,提出一种融合 Wasserstein 生成对抗网络(WGAN)和极限梯度提升(XGBoost)算法的异常数据检测模型。首先,通过 WGAN 学习预处理后 ADS-B 数据的内在分布特征,生成异常数据,将其与原始数据融合作为训练数据集;其次,基于 XGBoost 算法训练混合数据集,构建异常分类检测器;最后,通过试验与朴素贝叶斯、逻辑回归、感知机等基准模型开展性能对比。结果表明:与其他机器学习异常数据检测器相比,XGBoost 异常数据检测器在准确率、精确率、召回率、 F_1 分数等 6 项指标上均表现更优,其中准确率和精确率均超过 0.999;模型检测 243 792 条数据的总耗时为 2.070 2 s,平均每条数据检测耗时 0.008 5 ms,在检测性能与时间成本间实现最优平衡,且经真实异常事件验证,具备良好的实用性与适用性。

【关键词】 Wasserstein 生成对抗网络(WGAN); 极限梯度提升(XGBoost); 广播式自动相关监视(ADS-B); 异常数据检测; 朴素贝叶斯

ADS-B abnormal data detection model based on WGAN-XGBoost

LI Huaqian^{1,2}, CHEN Yuhao¹, FU Yuxiang¹, SHEN Jiayi³

(1 Air Traffic Management College, Civil Aviation University of China, Tianjin 300300, China;

2 China Eastern Airlines Wuhan Co., Ltd., Wuhan Hubei 430300, China;

3 College of Science, Civil Aviation University of China, Tianjin 300300, China)

Abstract: To enhance aviation operation safety, improve airspace management efficiency, and enhance the defense capabilities of system against spoofing and interference, an anomaly data detection model was proposed based on WGAN-XGBoost. Firstly, WGAN was utilized to learn the intrinsic distribution of the preprocessed ADS-B data, generating abnormal data for augmenting and balancing the training dataset. Then, XGBoost algorithm was employed to train the mixed dataset, building the final abnormal classification detector. Finally, the performance comparisons were conducted through experiments with benchmark models such as Naive Bayes, Logistic Regression, and Perceptron. The results show that the performance of XGBoost is superior to that of all comparison models including accuracy, precision, recall, and F_1 score, with accuracy and precision both exceeding 0.999. The total detection time for 243 792 data points is 2.070 2 s, with an average detection time of 0.008 5 ms per data point. It achieves the optimal

balance between detection performance and time cost and has been validated by real abnormal events, demonstrating good practicality and applicability.

Keywords: Wasserstein generative adversarial network (WGAN); extreme gradient boosting (XGBoost); automatic dependent surveillance-broadcast (ADS-B); abnormal data detection; naive Bayesian

0 引言

广播式自动相关监视 (Automatic Dependent Surveillance-Broadcast, ADS-B) 技术是当前空中交通监视的主流手段。由于 ADS-B 信号缺乏强加密保护,易遭受欺骗 (如发送伪造 ADS-B 信号),导致地面控制和其他飞行器接收虚假信息,严重干扰空中交通管理决策,已引发航空业界对 ADS-B 数据安全性的广泛关注^[1]。2014 年欧洲航空安全局及 2015 年美国联邦航空管理局均有报告或记录显示,飞行员在飞行中接收到伪造 ADS-B 信号,致使机载导航系统显示错误飞行数据^[2]。因此,开展 ADS-B 数据异常检测技术的系统性研究具有重要的现实意义。

目前,针对 ADS-B 数据异常检测的研究已形成基于统计与航迹基准的传统方法和基于机器学习与深度学习的智能检测方法 2 大类主流技术路径。MUELLER^[3]通过统计分析衡量 ADS-B 位置信息准确性,对位置导航精度类别开展质量评估。沈笑云等^[4]则利用位置导航不确定类别 (Navigation Uncertain Category for Position, NUCp),以航迹点与航路中心线的水平偏差为位置实际误差,结合分位数-分位数图法进行正态分布检验,得出不同 NUCp 值下的误差置信区间。LI Nisi 等^[5]提出一种基于变分自编码器 (Variational Auto-Encoder, VAE) 和支持向量数据描述 (Support Vector Data Description, SVDD) 的 ADS-B 异常数据检测模型,通过增加 VAE 潜在变量的维度并选择适当的重建值,可有效降低异常检测的误报率和漏报率。王振昊等^[6]提出一种利用双向门控循环单元和 SVDD 的模型,显著提升了 ADS-B 对抗网络攻击时的检测准确率和适应性。LUO Peng 等^[7]结合时间卷积网络、Transformer 和 SVDD,利用时序特征增强异常检测效率。丁建立等^[8]采用深度学习 seq2seq 模型实现高效异常检测。刘浪等^[9]提出一种结合卷积神经网络和长短期记忆网络的模型,显著提升了检测效率与性能。ÇEVİK 等^[10]分析发现,机器学习和深度学习技术在 ADS-B 系统异常检测中的应用有效性已得到显著

提升。SABUHI^[11]系统性论述了生成式对抗网络 (Generative Adversarial Network, GAN) 在异常数据检测中的应用,强调 GAN 在学习异常数据相关特性方面具有显著优势。YUE Meng^[12]、郑圣彬^[13]、李佳晟^[14]、官成功^[15]等通过训练 GAN 学习少量无时间相关性的数据分布,在测试阶段基于特定阈值,通过预定义的评分函数识别异常数据。但现有研究存在高质量异常样本稀缺、生成模型合成真实复杂时空分布的 ADS-B 异常数据受限、复杂高维 ADS-B 数据特征捕捉不足的问题。

鉴于此,笔者拟基于 ADS-B 数据特征,提出一种融合 Wasserstein 生成对抗网络 (Wasserstein Generative Adversarial Network, WGAN) 和极限梯度提升 (Extreme Gradient Boosting, XGBoost) 的异常数据检测模型,通过 WGAN 生成 ADS-B 异常数据,将其与原始数据融合后输入下游 XGBoost 模型进行分类,从而得到 ADS-B 异常数据检测结果,旨在为 ADS-B 异常数据检测工作提供新思路,以便更有效地保障航空运行安全、提升空域管理效率,并增强系统对欺骗与干扰的防御能力。

1 ADS-B 异常数据检测模型构建

1.1 异常数据生成器构建

WGAN 是一种深度神经网络,由生成器和判别器组成,其设计框架如图 1 所示。生成器通常需要采用更深且结构更复杂的网络,以更好地学习并表现数据的内在多尺度特征。文中的生成器包含 4 层隐藏层;判别器则包含 3 层隐藏层。




图 1 WGAN 的设计框架

Fig. 1 Design framework of WGAN

在 WGAN 中, Wasserstein 距离被用于衡量真实样本分布和生成样本分布之间的差异^[16]。通过优化一个满足 M-Lipschitz 连续性的函数计算距离, 确保函数的变化不会超过输入变化的 M 倍, 即函数 f 满足 M-Lipschitz 连续的约束^[17]:

$$\frac{|f(x_1) - f(x_2)|}{|x_1 - x_2|} \leq M \tag{1}$$

式中 x_1 与 x_2 为数据集中的特征变量。

判别器和生成器通过对抗过程完成训练, 其中, 判别器用于区分真实数据和生成数据, 生成器则用于生成可欺骗判别器的数据。判别器与生成器的损失函数分别如下:

$$L_D = -\frac{1}{m} \sum_{i=1}^m [\ln D(x^{(i)}) + \lambda \ln(1 - D(G(z^{(i)})))] \tag{2}$$

式中: L_D 为判别器的损失函数; m 为样本数量; $D(x^{(i)})$ 为判别器对真实样本 $x^{(i)}$ 的输出; λ 为超参数, 用于平衡真实数据和生成数据的分类错误; $D(G(z^{(i)}))$ 为判别器对生成样本 $G(z^{(i)})$ 的输出。

$$L_G = -\frac{1}{m} \sum_{i=1}^m D(G(z^{(i)})) + \beta \text{KL}(G(z^{(i)}) \parallel p_d) \tag{3}$$

式中: L_G 为生成器损失函数; β 为超参数, 用于控制多样性损失的权重; $\text{KL}(G(z^{(i)}) \parallel p_d)$ 为生成样本 $G(z^{(i)})$ 和真实数据分布 p_d 之间的 Kullback-Leibler

散度。

判别器的损失函数用于最大化其对真实数据和生成数据的区分能力, 生成器的损失函数则用于最小化判别器对其生成数据的识别能力。为避免函数梯度过大并满足 Wasserstein 距离的 Lipschitz 连续性约束, 采用权重剪裁限制判别器网络的权重大小, 使损失函数通过梯度更新驱动判别器和生成器的持续对抗学习。

权重剪裁:

$$W_{ij}^p = \min(\max(W_{ij}, -c), c) \tag{4}$$

式中: W_{ij}^p 为裁剪后的权重值; W_{ij} 为判别器网络层的原始权重值; c 为裁剪参数。

1.2 异常数据检测器构建

利用 WGAN 模型生成占比为 20% 的合成数据, 与原始数据合并, 作为 ADS-B 异常数据检测的训练数据集。将该数据集用于训练基于机器学习梯度推进机 (Gradient Boosting Machine, GBM) 改进的 XGBoost 模型, 以提高模型识别异常数据的能力^[18]。

XGBoost 模型通过计算二阶梯度下降方向, 并训练子样本数据, 提升模型的效率和泛化能力。该模型在保持模型精确度的同时, 能够显著提升模型的训练效率^[19]。XGBoost 模型的分类流程如图 2 所示, 其中, 分类回归树 (Classification and Regression Tree, CART) 表示分类与回归树。




图 2 XGBoost 的分类流程

Fig. 2 Classification process of XGBoost

1.3 WGAN-XGBoost 异常数据检测模型构建

首先, 利用预处理后的数据训练 WGAN 模型, 生成 ADS-B 异常数据。然后, 将合成数据与原始数据合并, 形成分类模型的训练数据集。最后, 采用 XGBoost 分类数据集判断样本的真实性, 实现对 ADS-B 异常数据的检测。WGAN-XGBoost 模型的原理如图 3 所示。




图 3 WGAN-XGBoost 模型的原理

Fig. 3 Principle of WGAN-XGBoost model

2 异常数据检测模型试验与结果

2.1 试验网络架构与数据处理

WGAN 的网络架构如图 4 所示,生成器的第 1—第 4 层隐藏层分别包含 256、512、1 024、2 048 个神经元,激活函数均为 ReLU;输出层包含 5 个神经元,

激活函数为 Tanh。判别器的第 1—第 3 层隐藏层分别包含 1 024、512、256 个神经元,激活函数均为 ReLU;输出层包含 1 个神经元,不设置激活函数,输出 1 个实数值。WGAN 模型使用 128 维的潜在空间,每次迭代处理 128 个训练样本,共进行 50 次迭代。为防止梯度爆炸,判别器的权重取值范围为 $[-0.01, 0.01]$ 。





图 4 WGAN 的网络结构

Fig. 4 Network structure of WGAN

数据集包含 1 015 799 个样本,每个样本均记录了经度、纬度、高度、航向和速度等 5 个特征信息。为避免数据质量问题^[20],确保数据分析的准确性和可靠性,需要预处理 ADS-B 数据。首先,清理空值和重复数据;其次,采用 Min-Max 归一化方法将不同维度、不同量纲的特征变量调整至统一尺度范围,从而提高模型训练的效率和性能。同时,为提高分类模型的性能和泛化能力,标准化处理训练数据集。

2.2 评估指标

异常数据检测属于二分类问题,数据的真实类别和预测类别分为 4 种情况:真阳性(True Positive, TP)、假阳性(False Positive, FP)、真阴性(True Negative, TN)和假阴性(False Negative, FN),如图 5 所示。



注:T 和 F 分别为真实类别的真和假;P 和 N 分别为预测类别的阳性和阴性。

图 5 二分类问题分类结果

Fig. 5 Classification results of binary classification problems

- 常且被正确识别为异常。
- 2) TN 表示检测结果的负判定,数据实际为正常且被正确识别为正常。
- 3) FP 表示检测结果的误判定,数据实际正常

却被错误标记成异常,该误判可能引起不必要的警报,进而造成资源浪费。

4) FN 表示检测结果的缺判定,数据实际为异常但被错误标记为正常,严重时将会导致安全隐患。

采用以下 6 个评价指标评估模型的分类效果:

1) 准确率。准确率指在整个数据集中,样本被正确分类的比例。

$$A = \frac{TP + TN}{TP + FP + TN + FN} \quad (7)$$

2) 精确率。精确率指预测类别和真实类别均为阳性的样本比例。

$$P = \frac{TP}{TP + FP} \quad (8)$$

3) 召回率。召回率指在所有真实类别为阳性的样本中,预测类别也为阳性的比例。

$$R = \frac{TP}{TP + FN} \quad (9)$$




图 6 WGAN 损失曲线

Fig. 6 Loss curve of WGAN

由图 6 可知:WGAN 模型在学习过程中展现出良好的收敛性。模型的判别器和生成器的损失值在最初的 10 次迭代中快速下降,表明模型迅速学习了训练数据分布。随后,损失值稳定,模型达到收敛状态。这种快速收敛表明:生成器能够迅速生成高质量数据,判别器能够有效区分真实数据和生成数据。

2.3.2 对比试验算法

选取以下具有代表性的分类算法与 XGBoost 对比:

1) 朴素贝叶斯。基于贝叶斯定理和特征条件独立假设的分类方法,假设每个特征都服从高斯分布,通过计算每个类别的概率密度函数来预测新实例的类别^[21]。

2) 逻辑回归。通过计算样本属于正类的概率,并将其映射到 0 和 1 之间,从而实现分类^[22]。

4) F_1 分数。 F_1 分数指精确率和召回率的调和平均数,值越大,说明模型的分类效果越好。

$$F_1 = \frac{2 \times P \times R}{P + R} \quad (10)$$

5) 受试者工作特征曲线下面积 (Receiver Operating Characteristic-Area Under Curve, ROC-AUC)。该指标用于描述真阳率和伪阳率之间的变化关系,值越大,说明分类效果越好。

6) 精确率-召回率曲线下面积 (Precision-Recall Area Under Curve, PR-AUC)。该指标用于描述精确率和召回率之间的变化关系,值越大,说明分类效果越好。

2.3 试验结果分析

2.3.1 WGAN 训练结果

WGAN 损失曲线如图 6 所示,通过可视化损失函数的变化趋势评估 WGAN 模型的收敛性。

3) 感知机。由带权重的前馈神经元构成^[23],通常包含感知层、连接层和反应层^[24]。

2.3.3 对比试验结果

对比 4 种异常数据检测模型在测试集上的 6 个评估指标,各个模型的评估结果见表 1。由表 1 可知:XGBoost 的准确率、精确率、召回率、 F_1 分数、ROC-AUC 和 PR-AUC 的值均大于 0.99,表明该模型在 ADS-B 数据的异常检测中表现出色,泛化性更强。从整体来看,XGBoost 的 6 个评估指标结果均高于其他模型,具有最佳的检测效果,表明该模型具备针对大型 ADS-B 数据集开展异常检测的能力,且检测效果比传统模型更好。

各模型的 ROC 曲线和 PR 曲线如图 7 和图 8 所示。由图 7 可知:XGBoost 在低假阳性率下保持着较高真阳性率,表明该模型识别正类样本时更为准

表 1 各模型的评估结果

评价指标	XGBoost	朴素贝叶斯	逻辑回归	感知机
准确率	0.999 4	0.947 2	0.824 8	0.814 2
精确率	1.000 0	0.824 5	0.451 5	0.214 2
召回率	0.996 2	0.868 9	0.229 1	0.042 4
F_1 分数	0.998 1	0.846 1	0.303 9	0.070 8
ROC-AUC	1.000 0	0.986 4	0.865 9	0.781 1
PR-AUC	0.999 9	0.942 9	0.439 6	0.325 4

确和可靠,也能较好地控制误报率。由图 8 可知:XGBoost 的 PR 曲线呈直角与水平线形态,分类精准且稳定。相比之下,其他模型曲线平缓下降,表明 XGBoost 能够精准地提取出最具区分度的判别性特征。同时,XGBoost 在高召回率下依然保持极高精确率,表明该模型已成功捕捉到用以区分稀有样本的复杂非线性特征组合,能有效地建模 ADS-B 高维大数据并提取相关特征。




图 7 各模型的 ROC 曲线
Fig. 7 ROC curves of each model




图 8 各模型的 PR 曲线
Fig. 8 PR curves of each model

2.3.4 模型的时间复杂度

各模型异常检测时间见表 2。尽管 XGBoost 在

处理速度上并非最优,但考虑到其在准确率、精确率等关键性能指标上的显著优势,可判定 XGBoost 在检测效果与时间成本间取得了最佳平衡,证明模型具有一定实用性。

表 2 异常检测时间

模型	总检测时间/s	平均每次检测时间/ms	异常检测次数
XGBoost	2.070 2	0.008 5	2437 92
朴素贝叶斯	0.157 7	0.000 6	2437 92
逻辑回归	0.757 7	0.003 1	2437 92
感知机	0.547 8	0.002 2	2437 92

2.3.5 模型适用性验证

基于 2024 年 1 月 21 日四川航空 3U8424 航班从 12:14 起飞到 14:40 因故障返航的原始 ADS-B 数据,采用模型判别器 XGBoost 开展飞行异常行为判断。由于缺失部分数据,经插值处理后,绘制 3U8424 航班的三维轨迹如图 9 所示。

该航班在爬升过程中,右侧发动机突然喷出火焰,导致飞机的升力下降,影响飞机爬升^[25]。由图 9 可知:该模型成功检测出因发动机喷火导致的非正常飞行行为,即数据点异常,证明模型具有一定的适用性。




图 9 三维轨迹
Fig. 9 Three-dimensional trajectory

3 结 论

1) 相较于感知机、逻辑回归和朴素贝叶斯这 3 种机器学习异常数据检测器,XGBoost 异常数据检测器的准确率、精确率、召回率、 F_1 分数、ROC-AUC 和 PR-AUC 这 6 个指标结果均表现优异,其中,ROC-AUC 和 PR-AUC 均超过 0.999。

2) XGBoost 模型检测 243 792 条数据的总耗时为 2.070 2 s,平均每次异常检测耗时为 0.008 5 ms,表明模型在检测效果与时间成本间取得了最佳平衡,且经真实异常事件检测,验证了模型具有一定的实用性和适用性。

3) 未来研究将进一步探索缩短模型检测异常数据时间的方法,通过优化模型结构和参数,并采用更高效的训练策略,结合新的算法和技术,在保障 ADS-B 数据实时性的基础上,实现更快、更准确的异常数据检测。

参 考 文 献

[1] 暴佳伟,田小平,刘宇娜,等. ADS-B 安全问题研究综述[J]. 现代防御技术, 2022,50(5):28-35.
BAO Jiawei, TIAN Xiaoping, LIU Yuna, et al. Summary of research on security issues of ADS-B protocol[J]. Modern Defence Technology, 2022, 50(5): 28-35.

[2] COSTIN A, FRANCILLON A. Ghost in the air (traffic): on the security of ADS-B[C]. Proceeding in 21st USENIX Security Symposium (USENIX Security 12), 2012: 1-16.

[3] MUELLER R K. Quality of reported NACP in surveillance and broadcast services systems[C]. Proceeding in 28th IEEE/AIAA Digital Avionics Systems Conference, 2009; DOI:10.1109/DASC.2009.5347431.

[4] 沈笑云,唐鹏,张思远,等. ADS-B 统计数据的位置导航不确定类别质量分析[J]. 航空学报, 2015, 36(9): 3 128-3 136.
SHEN Xiaoyun, TANG Peng, ZHANG Siyuan, et al. Quality analysis of navigation uncertain category for position based on ADS-B statistical data[J]. Acta Aeronautica et Astronautica Sinica, 2015, 36(9):3 128-3 136.

[5] LI Nisi, LIN Lin, LI Fan. ADS-B anomaly data detection using SVDD-based LSTM encoder-decoder algorithm[C]. Proceeding in 3rd IEEE International Conference on Civil Aviation Safety and Information Technology,2021:1 295-1 300.

[6] 王振昊,王布宏. 基于 SVDD 的 ADS-B 异常数据检测[J]. 河北大学学报:自然科学版, 2019,39(3):323-329.
WANG Zhenhao, WANG Buhong. ADS-B anomaly data detection based on SVDD[J]. Journal of Hebei University: Natural Science Edition, 2019, 39(3):323-329.

[7] LUO Peng, WANG Buhong, LI Tengyao, et al. ADS-B anomaly data detection model based on VAE-SVDD[J]. Computers & Security, 2021, 104; DOI: 10.1016/j.cose.2021.102213.

[8] 丁建立,邹云开,王静,等. 基于深度学习的 ADS-B 异常数据检测模型[J]. 航空学报, 2019,40(12):167-177.
DING Jianli, ZHOU Yunkai, WANG Jing, et al. ADS-B anomaly data detection model based on deep learning[J]. Acta Aeronautica et Astronautica Sinica, 2019, 40(12):167-177.

[9] 刘浪,时宏伟. 基于注意力机制的 CNN-LSTM 的 ADS-B 异常数据检测[J]. 计算机系统应用, 2023, 32 (4): 94-103.
LIU Lang, SHI Hongwei. ADS-B anomaly detection based on attention mechanism for CNN-LSTM[J]. Computer Systems & Applications, 2023, 32(4):94-103.

[10] ÇEVİK N, AKLEYLEK S. SoK of machine learning and deep learning based anomaly detection methods for automatic dependent surveillance-broadcast[J]. IEEE Access, 2024, 12:643-662.

[11] SABUHI M, ZHOU Ming, BEZEMER C P, et al. Applications of generative adversarial networks in anomaly detection: a systematic literature review[J]. IEEE Access, 2021, 9:3-29.

[12] YUE Meng, ZHENG Han, CUI Haoran, et al. GAN-LSTM-based ADS-B attack detection in the context of air traffic control[J]. IEEE Internet of Things Journal, 2023, 10(14): DOI: 10.1109/jiot.2023.3252809.

[13] 郑圣彬,谢加良,张东晓. 基于 LSTM-WGAN 的时间序列数据异常检测[J]. 福建师范大学学报:自然科学版, 2024, 40 (2): 36-45.
ZHENG Shengbin, XIE Jialiang, ZHANG Dongxiao. Time series data anomaly detection based on LSTM-WGAN[J].

Journal of Fujian Normal University: Natural Science Edition, 2024, 40(2): 36–45.

- [14] 李佳晟. 基于多元特征的 ADS-B 异常检测关键技术研究[D]. 成都: 电子科技大学, 2023.
LI Jiasheng. Research on key technologies of multivariate feature based ADS-B anomaly detection[D]. Chengdu: University of Electronic Science and Technology of China, 2023.
- [15] 官成功, 高勇. 基于生成对抗网络的 ADS-B 信号降噪[J]. 通信技术, 2021, 54(3): 568–574.
GUAN Chenggong, GAO Yong. Generative adversarial nets for ADS-B signal denoising[J]. Communications Technology, 2021, 54(3): 568–574.
- [16] KIM C, PARK S, HWANG H J. Local stability of Wasserstein GANs with abstract gradient penalty[J]. Neural Networks and Learning Systems, 2022, 33(9): 4 527–4 537.
- [17] CHEN Shichuan, ZHENG Shilian, YANG Lifeng, et al. Deep learning for large-scale real-world ACARS and ADS-B radio signal classification[J]. IEEE Access, 2019, 7: 256–264.
- [18] CHEN Tianqi, GUESTRIN C. XGBoost: a scalable tree boosting system[C]. Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 2016: 785–794.
- [19] MANESH M R, KAABOUC N. Analysis of vulnerabilities, attacks, countermeasures and overall risk of the automatic dependent surveillance-broadcast (ADS-B) system[J]. International Journal of Critical Infrastructure Protection, 2017, 19: 16–31.
- [20] ALI B S, TAIB N A. A study on geometric and barometric altitude data in automatic dependent surveillance broadcast (ADS-B) Messages[J]. The Journal of Navigation, 2019, 72(5): 40–58.
- [21] 周志华. 机器学习[M]. 北京: 清华大学出版社, 2016: 44–56.
- [22] SHERWIN J S, CHARTIER J. Parameter optimization of logistic regression classifiers[J]. BMC Neuroscience, 2013, 14(S1): DOI: 10.1186/1471-2202-14-S1-P62.
- [23] 周长春, 陈勇刚. 基于人工神经网络的城市火灾事故的预测方法[J]. 中国安全科学学报, 2005, 15(5): 21–23.
ZHOU Changchun, CHEN Yonggang. Prediction method of city fire accidents based on artificial neural network[J]. China Safety Science Journal, 2005, 15(5): 21–23.
- [24] 王旭. 人工神经网络原理与应用[M]. 沈阳: 东北大学出版社, 2000: 20–45.
- [25] 徐翔, 陈龙, 李松阳, 等. 航空发动机燃烧室机匣烧穿火焰特性试验研究[J]. 清华大学学报: 自然科学版, 2024, 64(6): 984–991.
XU Xiang, CHEN Long, LI Songyang, et al. Experimental study on flame characteristics of combustor casing burn-through in aero-engine[J]. Journal of Tsinghua University: Science and Technology, 2024, 64(6): 984–991.

作者简介: 李怀谦 (2003—), 男, 湖北随州人, 本科, 主要从事航空器动态监控体系方面的工作。E-mail: 13886889946@163.com。