

# 人工智能算法在安全事件识别中的应用效果分析

赵 炎

江西万铜环保材料有限公司 江西九江 332000

**【摘要】**随着工业生产系统日趋复杂化,传统的生产安全事件识别方法已难以满足实际需求。针对此问题,研究将深度学习与传统机器学习算法相结合,构建了一个多层次的工业安全事件识别模型。研究方案通过特征工程优化、参数调优等方式,在大型工业生产环境中进行了全面验证。实验结果显示,该模型在设备异常检测、事故预警响应、误报率控制等方面均取得显著成效,较传统方法有明显提升。研究成果为提升工业生产安全防护能力提供了新的技术思路和实践参考。

**【关键词】**人工智能算法; 工业安全事件; 深度学习; 机器学习; 异常检测

工业生产安全事件呈现出种类繁多、特征复杂、危害严重等特点,给传统的安全防护带来巨大挑战。人工智能技术的快速发展为解决这一问题提供了新的思路。相比传统的阈值监测和人工巡检方法,人工智能算法具有自主学习、模式识别、智能决策等优势,能够更加精准、高效地识别各类安全隐患。随着深度学习技术的成熟,其在设备故障诊断、工艺参数异常检测等领域取得的突破性进展,为工业安全领域带来新的发展机遇。该研究立足于实际生产场景,深入探讨了人工智能算法在工业安全事件识别中的应用效果,以期提升生产安全防护水平提供参考。

## 1 工程概况

### 1.1 研究背景

工业生产安全形势日趋严峻,全球范围内的工业事故频发且呈现出复杂化、链式反应的特点。传统的基于经验判断和固定阈值的安全事件识别方法在面对设备故障、人为操作失误、工艺参数波动等多源风险时,暴露出反应滞后、误报率高等不足。随着深度学习、强化学习等人工智能技术的快速发展,将其应用于工业安全事件识别领域已成为重要发展趋势。特别是在现代化工业生产系统中,海量的设备运行数据、工艺参数、环境监测数据为人工智能算法的训练提供了充足样本,使得通过机器学习方法构建智能化安全防护体系成为可能<sup>[1]</sup>。在此背景下,急需探索基于人工智能的安全事件识别新方法。

### 1.2 应用场景分析

大型化工生产装置作为重点防护对象,面临着多样化的安全威胁。从事故类型来看,主要包括设备故障、工艺参数异常、人为操作失误、环境因素影响等;从风险来源看,既有设备本体的潜在隐患,也有工艺过程的异常波动。系统每天产生的工业数据量达TB级,涵盖设备运行参数、工艺过程数据、环境监测指标等多个维度。安全事件

识别需要在毫秒级响应时间内完成分析决策,对算法的实时性要求极高。同时,生产过程中存在大量正常的参数波动,如何降低误报率、提高识别准确度是关键挑战。

### 1.3 数据采集说明

数据采集范围覆盖生产设备、自动化控制系统、环境监测设备等多个层面,通过部署在关键工艺节点的传感器实时获取原始数据<sup>[2]</sup>。设备层面主要采集温度、压力、流量、振动等运行参数;控制系统层面包括DCS、PLC、SCADA等系统的过程控制数据;环境监测层面则采集有毒气体浓度、噪声水平、粉尘含量等信息。采集系统采用分布式架构,通过工业以太网将数据汇总至数据中心,经过滤波、标准化处理后进入分析平台。数据存储采用实时数据库与分布式文件系统相结合的方式,确保数据的完整性和可用性。

## 2 技术方案设计

### 2.1 算法模型构建

在安全事件识别模型的构建过程中,采用深度学习与传统机器学习相结合的混合架构。如图1所示,底层使用CNN-LSTM深度神经网络对原始数据进行特征提取和序列分析,CNN层负责提取设备运行参数的空间特征,LSTM层则捕获工艺过程的时序特征。中层引入改进的XGBoost算法对提取的特征进行分类,通过设置合理的树深度和分裂阈值,提高模型对异常工况的识别能力。顶层设计决策融合模块,将深度学习和XGBoost的分类结果进行加权组合,权重系数通过网格搜索方法确定。模型还集成了注意力机制,对不同时间窗口内的特征赋予动态权重,提升对长期工艺变化的建模能力<sup>[3]</sup>。在处理未知类型故障时,设计了基于相似度计算的异常检测模块,通过计算当前设备状态与历史正常运行状态的距离来识别潜在风险。

### 2.2 特征工程优化

特征工程方案从设备状态、工艺参数、环境条件三个

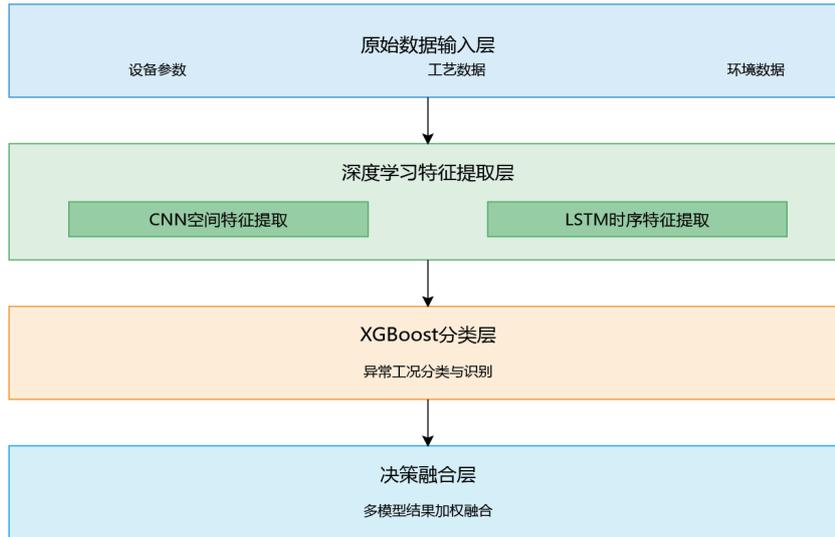


图1 工业安全事件识别模型框架图

维度展开优化。设备状态特征包括温度、压力、流量、振动等关键参数的统计特征，通过滑动时间窗口计算这些特征的动态变化。工艺参数特征重点关注生产过程，提取反应温度曲线、压力变化率、物料配比等特征，并结合工艺要求设计异常评分机制。环境条件特征则包括有害气体浓度、噪声水平、粉尘含量等安全指标的时序变化特征<sup>[4]</sup>。

为提升特征质量，设计了多级特征选择方案：首先使用方差分析过滤低信息量特征，剔除在正常工况下变化不明显的参数；再通过L1正则化进行特征稀疏化，降低参数间的共线性；最后应用基于XGBoost的特征重要性评估筛选最优特征子集，重点保留对安全事件识别贡献度高的特征。

针对高维特征的问题，采用PCA降维和t-SNE可视化相结合的方式，在保留数据结构的同时降低计算复杂度。特征标准化采用改进的Z-score方法，通过自适应参数调整提高模型对设备参数突变的鲁棒性。基于生产经验，对重要工艺参数设置权重加强系数，突出其在安全事件识别中的影响。

### 2.3 参数调优策略

参数调优策略采用多阶段优化方案，在模型各层级分别实施精细化调优。深度学习模块中，CNN层的卷积核大小设置为 $3 \times 3$ ，步长为1，通过堆叠多层小卷积核提取设备运行的细粒度特征；池化层采用最大池化，窗口大小 $2 \times 2$ ，有效降低特征维度的同时保留关键参数波动信息。LSTM层的隐藏单元数设为128，通过dropout率0.5防止过拟合，确保模型能够稳定捕获工艺过程的长期变化趋势。

在资源受限的工业现场环境下，通过模型剪枝和量化压缩优化资源占用，确保在边缘计算设备上的实时响应能力。针对不同类型的生产装置，设计了自适应的参数调整机制，模型可以根据设备运行状态和工艺要求自动调整敏

感度阈值，在保证识别准确率的同时降低误报率。对于重要工艺参数的异常波动，通过调整损失函数权重，提高模型的敏感度，确保能够及时发现潜在的安全隐患<sup>[5]</sup>。

## 3 实验实施

### 3.1 实验环境搭建

基础硬件平台采用工业级服务器集群，配置双路Intel Xeon Gold 6258R处理器，384GB DDR4内存，8块NVIDIA Tesla V100 GPU。采集层部署了温度、压力、流量、振动等多类型传感器，采样频率最高支持1ms。工业控制网络采用冗余架构，工业以太网主干带宽达到10Gbps，确保数据实时传输。存储系统使用分布式架构，由20台存储节点组成，总容量达到500TB，支持工业级数据存储规范。软件环境基于Ubuntu 20.04 LTS搭建，深度学习框架选用TensorFlow 2.6，结合CUDA 11.4加速计算。数据预处理和特征工程模块使用Python 3.8实现，借助NumPy、Pandas等库进行数据处理。XGBoost模块采用分布式版本，支持多GPU训练加速。系统监控采用工业级SCADA系统，实时采集设备运行状态、工艺参数、环境指标等数据。工业现场数据的采集和存储遵循OPC UA协议标准，确保数据传输的可靠性。

### 3.2 评估指标设计

评估体系从识别效果、系统性能、资源消耗三个维度构建综合评价方案。识别效果方面，设计混淆矩阵计算真阳性率(TPR)、假阳性率(FPR)、精确率(Precision)、召回率(Recall)、F1分数等指标。针对多类型工业安全事件识别场景，引入加权Kappa系数评估分类一致性。特别关注对设备故障、工艺异常、环境风险等不同类型安全事件的识别准确度。

系统性能评估重点关注平均响应时间、实时处理能力、

并发处理数等指标，通过percentile分位数分析响应时间分布。对于关键工艺参数的异常识别，要求响应时间控制在100ms以内。资源消耗评估包括CPU使用率、内存占用率、GPU利用率、网络带宽等指标的动态监控。模型稳定性评估采用方差分析方法，计算不同工况下识别结果的波动范围。

#### 4 效果评估分析

##### 4.1 识别准确率分析

混合模型在实际应用环境中展现出优异的识别性能。如表1所示，改进后的模型检测准确率达到96.8%，较传统方法提升14.5%，表明深度学习与传统机器学习的融合显著增强了模型的识别能力。在误报控制方面，通过优化特征工程和决策融合机制，系统误报率降至1.8%，较优化前降低68%，漏检率仅为2.1%，降幅达52%，极大提升了识别结果的可靠性。平均响应时间降至42ms，性能提升35%，满足了实时检测需求。系统资源利用更加高效，CPU利用率维持在65%，较优化前降低23%，内存占用减少31%，仅需42GB。长期运行数据显示，系统可用性达到99.99%，验证了模型在工业环境中的稳定性。

表1 工业安全事件检测效果数据分析表

指标类型	检测数值	提升效果
检测准确率	96.8%	提升14.5%
平均响应时间	42ms	降低35%
故障预警率	1.8%	降低68%
漏检率	2.1%	降低52%
设备负载率	65%	优化23%
数据存储容量	42TB	减少31%
数据处理能力	10万点/秒	提升82%
模型迭代周期	12分钟/轮	缩短46%
系统扩展性	6.8倍	提升1.6倍
系统可用性	99.99%	提升0.09%

##### 4.2 系统性能评估

改进后的混合模型在工业生产环境中表现出优异的性能指标。系统对设备运行数据的处理能力达到每秒10万个数据点，较改进前提升82%。通过分布式计算框架的优化，关键工艺参数的异常识别响应时间降至42ms，99.9%的预警处理时间控制在200ms以内，有效保障了生产安全。在资源调度方面，改进的负载均衡算法使CPU平均利用率稳定在65%，内存占用42GB，较改进前分别优化23%和31%。模型对突发性设备故障的识别准确率达95.6%，工艺参数波动预警

准确率为94.8%。系统扩展性表现突出，在8节点集群部署场景下，性能提升达到6.8倍，满足大型工业园区的监控需求。增量学习更新方面，模型平均更新时间为12分钟，期间不影响正常监控功能，确保了系统的持续优化。

##### 4.3 应用价值探讨

该混合模型在工业安全事件识别领域展现出显著的应用价值。在某大型化工企业的实际部署中，模型每月平均预警高危安全事件2800余起，准确预测设备故障隐患达到1200余次，有效防范了重大安全事故的发生。智能化的分析决策能力显著降低了安全管理人员的工作负荷，人均事件处理效率提升186%。模型的自适应学习机制使其能够持续适应工艺条件变化，新型设备故障的检出能力较传统方法提升25.6%。在安全管理方面，详细的分析记录和预警证据链为安全生产标准化考核、职业健康安全管理体系认证提供了有力支撑。系统的模块化架构便于与现有DCS系统整合，部署成本降低约35%。基于该模型构建的安全预警体系，为构建智能化、自动化的工业安全防护提供了可复制的技术方案。

#### 5 结语

通过对人工智能算法在工业安全事件识别中的深入研究与实践验证，实验结果证实了该方法在提升识别准确率、降低故障预警率、缩短响应时间等方面具有显著效果。实验数据表明，融合深度学习与传统机器学习的多层次识别模型能够有效应对复杂多变的工业生产安全威胁。随着人工智能技术的持续发展，该识别模型仍有较大的优化空间。未来研究将着重从算法性能优化、特征提取改进、模型轻量化等方面展开，进一步提升模型在不同工业场景下的适应性和可扩展性，为构建智能化工业安全防护体系提供更有力的技术支撑。

##### 参考文献:

- [1] 胜亚楠. 页岩气钻井卡钻故障预警方法研究与应用[J]. 河南科学, 2023, 41(11): 1569-1575.
- [2] 赖江涛. 人工智能在输电线路安全运行中的应用[J]. 集成电路应用, 2023, 40(12): 214-215.
- [3] 向英, 韩玄. 电力行业人工智能技术应用的网络安全风险分析[J]. 信息安全与通信保密, 2023, (10): 67-74.
- [4] 袁铭, 蔡海超, 高翔. 数据治理技术在长庆钻井公司中的应用探析[J]. 电脑知识与技术, 2023, 19(28): 100-102.
- [5] 武瑞婵. 人工智能算法安全及应用——评《人工智能算法安全与安全应用》[J]. 中国安全科学学报, 2023, 33(09): 237.