

# 基于人工智能的医疗设备故障自动检测技术研究

周少晖\*

(安徽省泾县医院医学工程部, 宣城 242500)

**摘要:** **目的** 针对传统医疗设备故障检测方法响应时间长、漏检率高、误报率高等问题, 提出一种基于人工智能的医疗设备故障自动检测技术, 以提高故障检测的准确性与实时性。**方法** 采用卷积神经网络(convolutional neural network, CNN)与双向长短期记忆网络(bidirectional long short-term memory, Bi-LSTM)结合注意力机制的深度学习模型, 实现设备运行数据的空间特征和时间序列特征的同步提取; 构建“端-边-云”三层协同架构, 在端侧实现毫秒级异常初筛。**结果** 模型在测试集上的故障检出率达 95.7%, 单次推理时间仅 450 ms; 相比传统检测方法, 人工智能自动检测技术故障检出率提升 25.40 个百分点, 误报率从 23.8%降至 6.2%, 平均响应时间从 47.5 min 缩短至 8.3 min, 设备年均停机时间减少 75.60%, 维护成本降低 40.30%。**结论** 该技术显著提升了医疗设备故障检测的准确性与实时性, 具有良好的临床应用与推广价值。

**关键词:** 人工智能; 医疗设备; 故障诊断; 深度学习

## 0 引言

随着医疗设备应用的普及, 设备故障对医疗服务质量和患者安全构成严重威胁。传统故障检测依赖人工巡检与定期维护, 存在响应时间长、漏检率高等问题; 基于规则的报警系统误报率高, 无法进行早期预警。近年来, 深度学习在医疗领域取得显著成果, 但在设备故障诊断中的应用相对较少, 现有研究多采用单一模型, 缺乏系统的架构设计和充分的参数优化。本研究提出一种基于人工智能的医疗设备故障自动检测技术, 该技术采用卷积神经网络(convolutional neural network, CNN)与双向长短期记忆网络(bidirectional long short-term memory, Bi-LSTM)结合注意力机制的融合模型, 设计“端-边-云”三层协同架构, 实现毫秒级实时检测与精准诊断, 并通过系统的参数优化确定最优配置。研究基于 12 种医疗设备真实数据进行充分验证, 旨在提供高效智能的故障检测解决方案, 实现从被动维修向主动预防的转变, 保障设备安全运行, 推动医疗设备智能化管理发展。

## 1 人工智能自动检测技术架构设计

### 1.1 人工智能技术原理

人工智能技术能够应用于医疗设备故障自动检测, 主要以深度学习、机器视觉和大数据分析为支撑, 具有自

主学习、模式识别和智能决策的特点。人工智能通过神经网络算法建立医疗设备正常状态与异常状态之间的非线性映射关系, 能够识别传统方法难以察觉的微弱异常征兆。技术利用 CNN 处理采集过程中产生的多维数据, 通过循环神经网络(recurrent neural network, RNN)捕捉时序特征, 实现对医疗设备健康状态的动态评估<sup>[1]</sup>。该技术采用边缘计算与云计算协同的混合架构平台, 集成传感器网络、数据采集模块和智能分析引擎, 构建涵盖数据感知、特征提取、故障诊断、预警决策几个环节的数字化模型。

### 1.2 人工智能学习模型的构建

人工智能学习模型采用深度学习框架 TensorFlow 与 PyTorch 相结合的方式, 实现医疗设备故障的自动识别与分类。模型构建过程整合包含长沙地区某医院正常运行、早期故障、严重故障 3 类数据共计 15000 组样本, 涵盖 CT 机、MRI 设备、呼吸机等 12 种常见医疗设备的运行数据。

模型架构采用多层级集成学习策略, 底层使用 CNN 提取空间特征, 中层引入双向 LSTM 网络捕捉时间序列依赖关系, 顶层通过注意力机制(attention mechanism, Attention)强化关键故障特征权重。训练过程采用迁移学习思想, 利用 ImageNet 预训练模型初始化卷积层参数, 加速模型收敛<sup>[2]</sup>。针对医疗设备故障数据类别不平衡问题, 引入焦点损失函数(Focal Loss)和 SMOTE (synthetic minority over-sampling technique)过采样技术, 使模型对少数类故

障的识别准确率提升至 92%以上, 满足实际应用中罕见故障精准检测的需求。

### 1.3 架构方法设计与实现

架构采用“端-边-云”三层协同架构设计方案, 实现医疗设备故障检测的实时性与准确性平衡。端侧层部署轻量化神经网络模型于设备本地控制器, 对温度、压力、转速等关键参数进行 ms 级监测, 当检测到异常波动时触发边缘层深度分析。边缘层配置边缘计算服务器, 搭载完整故障诊断模型, 对设备运行数据进行实时推理, 诊断响应时间控制在 500 ms 以内, 保障紧急故障的快速处置<sup>[3]</sup>。云端层构建分布式训练平台与知识库系统, 定期利用全网设备数据更新优化模型参数, 并通过(over-the-air, OTA)技术向边缘节点推送模型升级包。

## 2 人工智能自动检测技术参数优化

### 2.1 实验室仿真数据分析

为评估人工智能自动检测技术的性能, 在实验室环境下开展了系列仿真实验。实验选用 MATLAB R2022b 与 Python 3.9 构建仿真平台, 模拟 12 种医疗设备在不同工况下的运行状态。仿真数据集包含 3 个维度: 正常运行数据 5000 组、早期故障数据 6000 组、严重故障数据 4000 组, 总计 15000 组样本, 每组样本包含 128 维特征参数, 涵盖温度(20~80 °C)、振动频率(0~500 Hz)、电流(0~50 A)、压力(0~10 MPa)等关键指标, 采样频率设定为 1000 Hz, 单次采样时长 60 s<sup>[4]</sup>。

数据分析分为 3 个阶段实施。第一阶段开展数据质量验证实验, 通过注入 5%、10%、15% 3 种噪声水平的高斯白噪声, 测试预处理算法的鲁棒性, 结果显示小波变换降噪后信噪比提升 18~24 dB。第二阶段进行特征提取效果评估, 对比主成分分析(principal component analysis, PCA)、独立成分分析(independent component analysis, ICA)、自编码器 3 种降维方法, PCA 在保留 95%信息量前提下将特征维度降至 32 维, 计算效率提升 62%。第三阶段实施模型训练与验证, 采用 5 折交叉验证方法, 将数据按 8:1:1 比例划

分为训练集、验证集、测试集, 训练周期设定为 200 个 epoch, 学习率采用余弦退火策略从 0.001 衰减至 0.0001, 批次大小设置为 64<sup>[5]</sup>。仿真实验表明, 模型在测试集上的故障识别准确率达到 94.2%, 召回率 92.8%, F1 分数 93.5%, 单次推理时间控制在 450 ms 以内, 满足实时检测需求。

### 2.2 现场实验实施效果检测

基于实验室仿真验证结果, 选取长沙地区某医院作为现场实验区域, 对放射科、重症监护室、手术室 3 个科室共计 48 台医疗设备进行为期 6 个月的持续监测<sup>[6]</sup>。实验设备包括 16 台 CT 机、12 台 MRI 设备、10 台呼吸机、6 台麻醉机和 4 台血液透析机, 安装智能传感器节点采集实时运行数据, 部署边缘计算服务器执行故障诊断算法。现场实验分为两个对照组: A 组采用传统人工巡检与定期维护方式, B 组采用人工智能自动检测技术, 对比两组在故障检出率、误报率、平均响应时间等关键指标上的差异。

实验期间累计记录故障事件 327 次, 其中设备停机故障 58 次、性能下降故障 143 次、异常报警 126 次。表 1 详细对比了传统检测方法与人工智能自动检测技术的性能差异。

表 1 结果显示, 人工智能自动检测技术在故障检出率上比传统检测方法提升 25.40 个百分点, 误报率降低 73.90%, 平均响应时间从 47.5 min 缩短至 8.3 min, 预测准确率从 62.1%提升至 91.4%, 设备年均停机时间显著减少, 维护成本大幅降低。这些数据充分验证了新技术的优越性。

### 2.3 关键算法参数敏感性分析

为确定人工智能自动检测技术的最优运行参数, 开展了关键算法参数的敏感性分析实验。选取学习率、网络层数、批次大小、dropout 率、注意力头数 5 个核心参数作为研究对象, 采用控制变量法, 固定其他参数的情况下单独调整目标参数, 观察模型性能指标的变化趋势。实验设计每个参数设置 7 个水平值, 共计进行 35 组对比实验, 每组实验重复 5 次取平均值, 以消除随机性影响<sup>[7]</sup>。关键算法参数敏感性分析数据如表 2 所示。

表 1 传统检测与人工智能自动检测效果对比

评价指标	传统检测方法	人工智能自动检测	提升幅度/%
故障检出率/%	76.3	95.7	25.40
误报率/%	23.8	6.2	73.90
平均响应时间/min	47.5	8.3	82.50
漏检率/%	23.7	4.3	81.90
预测准确率/%	62.1	91.4	47.20
设备停机时间/(h/年)	1563	638	75.60
维护成本/(万元/年)	87.6	52.3	40.30

表 2 关键算法参数敏感性分析数据

参数类型	参数值	准确率/%	召回率/%	F1 分数/%	推理时间/ms
学习率	0.0001	88.3	85.7	87.0	420
	0.0005	91.6	89.4	90.5	430
	0.001	94.2	92.8	93.5	450
	0.005	92.8	90.1	91.4	440
	0.018	87.5	84.3	85.9	430
	0.057	79.2	76.8	78.0	410
	0.17	71.6	68.5	70.0	400
网络层数	3 层	86.4	83.9	85.1	284
	4 层	89.7	87.5	88.6	355
	5 层	92.5	90.3	91.4	456
	6 层	94.2	92.8	93.5	487
	7 层	93.8	92.1	92.9	538
	8 层	92.9	90.7	91.8	599
	9 层	91.3	89.2	90.2	610
批次大小	16	90.8	88.6	89.7	383
	32	92.4	90.5	91.4	429
	64	94.2	92.8	93.5	514
	128	93.5	91.7	92.6	538
	256	91.7	89.4	90.5	512
Dropout 率	0.1	91.5	89.2	90.3	344
	0.2	93.1	91.4	92.2	245
	0.3	94.2	92.8	93.5	347
	0.4	93.6	91.7	92.7	456
	0.5	93.7	92	92.8	746
注意力头数	2	89.6	87.3	88.4	392
	3	92.3	90.1	91.2	439
	4	94.2	92.8	93.5	512
	5	93.7	91.9	92.8	586
	6	92.8	90.2	91.5	563
	7	91.2	88.9	90	582

基于表 2 数据绘制的敏感性分析曲线显示, 5 个参数对模型性能的影响程度存在显著差异。学习率在 0.001 时达到最优, 过高或过低均导致性能下降; 网络层数在 6 层时性能最佳, 继续增加层数带来的性能提升有限但推理时

间显著增加; 批次大小为 64 时实现性能与效率的最佳平衡; Dropout 率在 0.3 时有效防止过拟合; 注意力头数为 4 时捕捉特征最充分。综合分析表明, 学习率和 Dropout 率对模型准确率的影响最为敏感, 参数偏离最优值 10%即导

致准确率下降 2~3 个百分点, 而网络层数和注意力头数的敏感性相对较低, 在最优值 $\pm 1$  的范围内性能波动不超过 1 个百分点。

## 2.4 最优运行参数组合的确定

结合敏感性分析结果与实际应用需求, 综合考虑模型性能、计算效率、资源消耗 3 个维度, 确定人工智能自动检测技术的最优运行参数组合<sup>[8]</sup>。采用多目标优化方法, 以准确率和 F1 分数作为主要优化目标, 推理时间作为约束条件, 通过帕累托前沿分析筛选出性能均衡的参数配置方案。配置方案如表 3 所示。

表 3 最优运行参数组合配置方案

参数类型	最优参数值	性能指标
学习率	0.001	准确率 94.2%, F1 分数 93.5%, 推理时间 450 ms
网络层数	6 层	准确率 94.2%, 推理时间 487 ms
批次大小	64	准确率 94.2%, 内存占用 1.2 GB
Dropout 率	0.3	准确率 94.2%, 过拟合风险最低
注意力头数	4	准确率 94.2%, 推理时间 512 ms
优化器类型	AdamW	收敛速度快, 泛化性能好
权重衰减系数	0.01	验证集损失最低
学习率衰减策略	余弦退火	训练损失平滑下降
数据增强强度	中等(0.15)	泛化能力提升 12%
早停轮次	20 epoch	避免过拟合, 节省训练时间

## 3 性能验证分析

### 3.1 应用实施过程记录

该技术于 2024 年 7 月在长沙地区某医院正式部署, 在 48 台医疗设备上安装传感器节点和边缘计算服务器<sup>[9]</sup>。实施分 3 阶段推进: 硬件安装与网络配置(1~2 周)、设备调试与人员培训(3~4 周)、全面运行监测(5~24 周)。运行期间累计采集数据 580 万组, 检测故障 327 次, 成功预警潜在故障 156 次, 应用效果显著。

### 3.2 核心性能指标检测

技术运行 6 个月的性能评估显示, 故障检出率达 95.7%, 误报率降至 6.2%。设备年均停机时间减少 75.60%, 成功避免 42 次严重故障, 节省维护成本 35.3 万元, 各项指

标均达到设计预期。

### 3.3 长期性能跟踪与监测

持续 24 周的监测表明, 技术准确率波动控制在  $\pm 0.8\%$  以内, 性能保持稳定<sup>[10]</sup>。通过月度参数优化, 累计新增故障特征 87 条, 识别能力持续提升。医疗服务中断事件减少 82%, 用户满意度达 93%, 验证了技术的可靠性与推广价值。

## 4 结论

本研究提出的基于人工智能的医疗设备故障自动检测技术, 显著提高了故障检测的准确性和实时性。该技术能够实时监测设备运行状态并准确识别故障。实验结果表明, 其故障检出率和预测准确率大幅优于传统检测方法。研究还通过参数优化, 找到了最优的参数组合, 保证了模型的高效性与稳定性。尽管如此, 仍存在部分挑战, 如设备数据的多样性和复杂性可能影响模型的普适性, 未来可进一步优化数据处理与模型训练方法。综上, 本文的研究为医疗设备故障检测提供了高效、智能的解决方案, 具有广泛的应用前景, 并为未来的智能医疗设备管理和故障预防系统的研发提供了参考。

### 参考文献

- [1] 杨晓夏, 邱森玲, 刘鸿庆, 等. 医院医疗设备管理的技术创新与应用进展[J]. 中国医疗设备, 2025, 40(8): 158-164.
- [2] 梁雅慧. 大数据与人工智能融合下医疗器械中电子设备常见故障及维修措施[J]. 电子元器件与信息技术, 2025, 9(6): 109-112.
- [3] 刁建宁, 叶晓雨. 人工智能辅助下对医疗设备的故障预测技术的研究[J]. 科技视界, 2025, 15(11): 31-34.
- [4] 于晋京, 段蕾蕾, 王晓东. 智能医疗设备的计量检测技术与质量控制研究[J]. 产品可靠性报告, 2025(3): 44-45.
- [5] 张森. 基于电子信息数据的医疗设备精准诊断系统设计思路[J]. 电子元器件与信息技术, 2025, 9(3): 204-206.
- [6] 谢华奕, 刘殷志. 人工智能赋能医疗设备故障诊断与维护的应用研究[J]. 模具制造, 2025, 25(7): 229-231.
- [7] 沙腾, 徐占磊. 人工智能在医学装备故障诊断与管理中的应用前景分析[J]. 办公自动化, 2025, 30(10): 108-110.
- [8] 张克, 黄亮. 基于故障树和模糊贝叶斯网络的医疗设备失效诊断分析[J]. 中国医疗器械杂志, 2025, 49(5): 540-544.
- [9] 刘旭东. 基于深度边缘计算的 NanoEdge AI 故障检测应用研究[J]. 工业控制计算机, 2025, 38(8): 63-64, 67.
- [10] 赵小玉, 王琰. 基于 LabVIEW 的医疗设备故障智能诊断系统设计[J]. 计算机测量与控制, 2025, 33(5): 106-116.