

# 基于深度学习的电子设备故障智能检测方法研究

周明凡<sup>1</sup> IDER LOZVOI<sup>2</sup>

1 山东工程职业技术大学, 山东省济南市, 250200;

2 蒙古民族大学, 蒙古乌兰巴托, 028043;

**摘要:** 随着电子设备向高度集成化、复杂化发展, 传统故障检测在响应速度、精度与适应性上显局限。本文聚焦深度学习在电子设备故障智能检测的应用, 剖析核心逻辑与技术路径, 先阐述故障信号特征与深度学习建模的适配性, 再分析 CNN、RNN、Transformer 在故障特征提取与模式识别的原理及优势, 探讨小样本、多模态数据融合、实时性检测问题, 提出迁移学习、注意力机制优化方案。研究表明, 深度学习凭端到端特征学习突破传统方法对人工特征工程的依赖, 为复杂设备故障检测提供高效精准支撑, 也为后续优化指明方向。

**关键词:** 深度学习; 电子设备; 故障智能检测; 特征提取; 模式识别

**DOI:** 10.64216/3080-1516.25.12.095

## 引言

电子设备作为工业生产、日常生活及科技研发的核心载体, 其运行稳定性直接影响生产效率与生活质量。随着芯片制程升级、多模块协同架构普及, 电子设备内部电路、信号传输路径愈发复杂, 故障类型也呈现出多样性、隐蔽性特征——从元件老化引发的渐进式故障, 到电磁干扰导致的突发性异常, 传统基于规则推理、人工巡检的检测方式, 不仅需依赖专业人员的经验积累, 还难以应对动态变化的运行环境, 导致故障漏检、误检率较高, 且检测滞后性显著。深度学习技术凭借其对高维、非线性数据的强大拟合与学习能力, 为电子设备故障检测提供了新的技术路径<sup>[1]</sup>。与传统方法需人工设计故障特征不同, 深度学习可直接从设备运行数据(如电压、电流、温度信号)中自动挖掘故障关联信息, 实现从“数据输入”到“故障判断”的端到端检测, 大幅提升检测的智能化水平。

## 1 电子设备故障检测的核心需求与数据特征

### 1.1 故障检测的核心需求

电子设备故障检测的核心目标是在设备出现功能异常前或异常初期, 精准识别故障类型、定位故障位置, 并给出预警或维修建议, 以避免故障扩大导致的设备损坏或生产中断。从实际应用需求来看, 故障检测需满足三项关键要求: 一是高精度, 需区分“正常波动”与“故障信号”, 避免因误检导致的不必要停机, 或因漏检引发的安全风险; 二是强适应性, 电子设备在不同工况下运行数据特征存在差异, 检测方法需能适应工况变化, 保持稳定的检测性能; 三是低依赖度, 减少对人工经验的依赖, 尤其针对复杂设备, 传统人工检测需专业人员

掌握设备内部结构与信号逻辑, 而智能检测方法须具备自主学习与适应能力<sup>[2]</sup>。

### 1.2 故障检测的数据源与特征

电子设备故障检测的数据来源主要为设备运行过程中所产生的物理信号与状态数据, 按信号类型可以分为三类: 一类是电信号, 如电路中的电压、电流、电阻信号, 元件故障会直接导致电信号的幅值、频率或波形发生异常; 另一类是非电信号, 如温度、振动、噪声信号, 例如芯片过热会预示散热模块故障, 电机振动异常会反映轴承磨损; 再一种是系统日志数据, 对于带有软件控制的电子设备如智能家电、工业 PLC, 这些数据在故障监测场合下具有明显的特征: 一是高维性, 单台复杂电子设备的监测点有数十个甚至上百个, 每一个监测点产生的时序数据或波形数据维数较大, 用常规方法难以直接处理; 二是非线性, 故障与数据特征之间的关联不是线性关系, 如电流信号的微小变化就可能对应很多故障类型, 必须通过非线性模型挖掘其深层关联; 三是时序相关性, 大多数故障的发生是一个渐进过程, 如元件老化引起的故障, 其对应的电信号

## 2 电子设备故障检测中深度学习的关键技术与模型

### 2.1 CNN 在故障特征提取中的应用

卷积神经网络 CNN 具有局部感受野, 权值共享的结构特点, 在空间特征提取方面有天然的优势, 特别适用于处理电子设备故障中的“波形类数据”与“图像化数据”<sup>[3]</sup>。在故障检测中, CNN 的应用逻辑可以分为三个阶段: 第一阶段为数据预处理, 通过短时傅里叶变换,

小波变换等,将原始时序信号转化为二维频谱图——这种转化的核心优势在于,将时域上难以区分的故障信号,在频域上转化为具有明显视觉差异的特征图谱,例如电容故障可能导致频谱图中特定频率段的幅值异常升高,电阻故障可能表现为频谱的杂波增多;第二与传统人工设计特征相比,CNN能够自动挖掘数据中的深层空间特征——人工特征往往只能反映信号的表层规律,而CNN能捕捉到频谱图中细微的纹理差异,这些差异可能对应着人工难以察觉的早期故障。譬如,对于电源模块的故障检测,传统的方法可能仅仅是看电压幅值是否超过阈值,而CNN可以从电压频谱图中识别出“幅值波动频率的细微变化”,这种变化虽然在故障初期对电压幅值没有影响,但却是元件老化的早期信号,从而实现更早的故障预警。

## 2.2 RNN 和其变种在时序故障检测中的应用

电子设备故障的发生往往具有时序关联性,如电机驱动模块的故障,会先表现为电流信号的间歇性波动,然后逐渐发展为持续性异常,这样的时序特征需要模型具备对“历史数据”的记忆能力。RNN通过“隐藏状态”使前一时刻的输入传递到当前时刻,可以获取数据的时序依赖关系,可用于电子设备的时序运行数据的处理<sup>[4]</sup>。然而,传统的RNN存在“梯度消失”问题——当使用长时序数据时,模型无法对长时序数据进行远距离依赖信息的传递,无法识别长时间跨度下的故障演化规律。为解决这一问题,LSTM与GRU通过“门控机制”对重要信息的保留和无关信息的遗忘实现,极大地提高了对长时序数据的处理能力。LSTM/GRU在电子设备故障检测中的应用场景主要集中在“渐进式故障”与“间歇性故障”检测。以工业控制器故障检测为例,控制器在运行过程中会持续产生输入输出信号的时序数据,间歇性故障会导致某一时刻的信号异常,但随后恢复正常,传统方法容易将这种异常判定为“干扰信号”而忽略。此外,双向LSTM(Bi-LSTM)在故障检测中也有广泛应用——它通过正向与反向两个方向的LSTM处理时序数据,不仅能利用历史数据的信息,还能结合未来数据的特征,进一步提升故障判断的准确性。例如在通信设备信号故障检测中,Bi-LSTM可同时分析当前信号之前的“历史波动规律”与之后的“信号恢复情况”,区分“暂时性干扰”与“永久性故障”,减少误检率。

## 2.3 Transformer 模型在多模态故障数据融合中的潜力

随着电子设备监测技术的发展,故障检测逐渐从

“单一数据源”向“多模态数据融合”方向发展。例如同时利用电信号、温度信号与系统日志数据进行故障判断,多模态数据的融合可弥补单一数据的局限性。然而,多模态数据存在“模态差异”,传统融合方法难以有效挖掘不同模态间的关联信息。在电子设备多模态故障检测中,Transformer的应用可分为两个层面:一是跨模态注意力,用于挖掘不同模态数据间的关联,例如计算“电流信号异常”与“温度升高”之间的注意力权重,若两者权重较高,说明这两种异常可能由同一故障(如元件短路)引起;二是时序注意力,用于处理多模态数据中的时序特征。与CNN、RNN相比,Transformer在多模态融合中的优势在于:CNN擅长空间特征提取,但难以处理多模态的异构性;RNN可处理时序数据,但对长时序的依赖关系捕捉能力仍弱于Transformer的自注意力机制;而Transformer通过自注意力机制,可同时处理空间特征、时序特征与跨模态关联,尤其适用于复杂电子设备的多维度故障检测<sup>[5]</sup>。例如在新能源汽车电池管理系统(BMS)故障检测中,Transformer可融合电池电压、温度、充放电次数等电信号数据,以及BMS系统日志中的通信状态、指令执行结果等文本数据,通过注意力机制识别“电压骤降”与“日志中‘充电中断’代码”的关联,从而精准判断故障类型为“电池接口接触不良”,而单一数据则可能导致故障误判。

## 3 深度学习在电子设备故障检测中的关键问题与优化方向

### 3.1 小样本故障检测问题与迁移学习优化

电子设备故障检测中面临的核心问题之一是“小样本问题”——多数电子设备在生命周期内以正常运行为主,故障样本数量极少,而深度学习模型的性能依赖于大量标注样本的训练,小样本场景下模型易出现过拟合,导致检测精度大幅下降。例如工业生产中的专用控制器,其设计寿命可达10年以上,但可能仅在运行3~5年后出现一次“芯片逻辑错误”故障,此类故障样本难以收集,传统深度学习模型无法有效学习故障特征。针对小样本问题,迁移学习是当前最有效的优化方向之一。迁移学习的核心逻辑是将“源领域”(样本丰富的领域)的知识迁移到“目标领域”(小样本的电子设备故障检测领域),通过共享源领域与目标领域的共性特征,减少目标领域对样本数量的依赖。此外,基于元学习(Meta-Learning)的迁移学习方法在小样本故障检测中也展现出潜力。元学习通过在“多个源任务”上训练模型,使模型具备“快速学习新任务”的能力。

### 3.2 多模态数据异构性问题与注意力机制优化

多模态数据融合是提升电子设备故障检测精度的重要手段,但多模态数据存在“异构性”问题——不同模态数据的类型、维度、分布差异显著,例如电信号数据为连续数值型,系统日志数据为离散文本型,温度数据为低维度时序数据,而频谱图数据为高维度图像数据,这些差异导致传统数据融合方法(如特征拼接、加权求和)难以有效挖掘模态间的关联信息,甚至可能因数据异构性引入噪声,降低模型检测性能。对于多模态数据异构性问题,基于注意力机制的优化方法可以有效提升融合效果。注意力机制通过计算不同模态数据的“贡献权重”,使模型聚焦于对故障判断更为重要的模态,同时弱化异构数据带来的噪声干扰。具体优化思路有:一是模态注意力权重分配,在模型训练过程中,自动学习不同模态数据在故障检测中的权重——例如在电源模块故障检测中,当“电压信号异常”与“温度信号正常”时,模型会对电压信号分配更高的注意力权重,而当“电压信号正常但温度信号骤升”时,模型会提高温度信号的权重,从而根据实际数据情况动态调整模态贡献;二是模态内特征注意力,针对单一模态数据中的关键特征进行强化,在电信号数据中。

### 3.3 轻量化模型优化与实时性检测问题

在实际的电子设备故障检测应用场景中,实时性是其重要的要求之一。比如工业生产线的电子控制器,如果故障检测存在较大延迟,那么可能导致生产线的停机时间长,并造成极大的经济损失;再比如航空电子设备,在毫秒级的时间内必须对故障进行检测,以确保飞行的安全。然而,深度学习模型计算量大,需要大量的算力支持,在嵌入式电子设备中很难满足实时性要求。轻量化模型优化是针对实时性问题的核心解决方向,是在保证检测精度的前提下,通过模型结构简化,参数压缩,减少模型计算量与推理时间。模型轻量化优化的方法主要有三类:一是模型结构轻量化设计,比如使用深度可分离卷积来代替传统卷积——传统卷积同时完成“空间特征提取”与“通道特征融合”,而深度可分离卷积将二者分离,先用深度卷积提取空间特征,再用逐点卷积融合通道特征,可以减少8~9倍的计算量,同时保持较高的特征提取能力。例如,在电子设备故障检测中,基于MobileNet的故障检测模型,其推理时间可以由传统CNN的500ms缩短至80ms,满足工业控制器的实时性要

求;二是模型参数量化与剪枝,参数量化将模型中的32位浮点数参数转换为8位整数或者16位浮点数,减少参数存储空间与计算资源消耗。三是模型蒸馏,通过“教师—学生”模型架构将复杂深度学习模型的知识迁移到简单模型中。例如,在电子设备故障检测中,教师模型通过大量数据学习到复杂的故障特征映射关系,学生模型通过模仿教师模型输出进行训练,最终达到“简单模型具备复杂模型检测精度”的效果。

## 4 结论

本研究以深度学习在电子设备故障智能检测领域的应用为研究对象,对故障检测的核心需求及数据特征进行深入分析,对CNN、RNN及其派生模型、Transformer模型在电子设备故障检测中的应用技术原理及其实际应用场景进行了细致梳理,应对小样本数据、多模态数据异构以及实时性这三个技术难点,提出采用迁移学习、注意力机制和轻量化模型相结合的故障检测改进路径。深度学习凭借端到端的特征学习能力,深度学习技术对电子设备故障数据的复杂多维特征、非线性特性及时间序列相关性有很好的契合度,削弱了传统故障检测手段对人工经验的重度依赖,有效提升故障检测的准确率及智能化水平,CNN在故障空间特征提取(如波形、频谱图分析)中表现突出,RNN/LSTM适用于时序关联故障(如渐进式、间歇性故障)检测,Transformer在处理多模态数据融合问题上展现出高效率,而采用迁移学习、引入注意力机制、优化轻量化模型,围绕样本依赖、数据融合、实时性能三个关键考量,为深度学习在电子设备故障检测中的应用铺平了道路。

## 参考文献

- [1] 朱宏禹. 基于深度学习的变电站设备故障智能检测算法研究[D]. 中北大学, 2024.
- [2] 刘虎林, 韩俊, 苏柏松. 基于动态状态估计法的智能变电站隐性故障检测方法研究[J]. 机械与电子, 2022, 40(07): 38~42+47.
- [3] 汪韦怡. 基于深度学习点过程的航空电子设备故障预测[D]. 电子科技大学, 2021.
- [4] 梁天辰. 基于多深度置信网络融合的航空电子设备故障预测[J]. 电讯技术, 2021, 61(02): 248~253.
- [5] 王素芳, 谢芳. 拖拉机电气故障诊断方法研究——基于深度学习理论和大数据[J]. 农机化研究, 2021, 43(06): 264~268.