基于深度学习的调速器异常检测方法

齐宇翔

雅砻江流域水电开发有限公司，中国·四川　成都　610000

【摘　要】工业设备运行智能化程度不断提高，调速器作为关键调控元件，其状态异常往往成为系统故障的诱发因素。现有检测手段对复杂时变信号敏感度不足，无法满足对早期异常特征的精准识别需求。为此，本文面向调速器典型异常形态，构建深度网络结构，优化输入表达机制与输出识别策略，提出一套面向实际工况的异常检测方法，实现异常类型识别准确率与响应速度的双重提升，为关键设备故障预警提供智能支撑。

【关键词】调速器；深度学习；异常检测；状态识别；故障预警

引言

在工业系统运行复杂性持续增强的背景下，调速器作为控制执行链中的核心组件，其工作状态直接关系到设备运行的稳定性与精度。异常状态具有隐蔽性和突发性，若未能及时识别，将引发连锁性机械失效或生产中断。传统基于经验阈值或规则库的检测方法对非线性、非平稳特征的响应能力不足，难以满足智能化运维场景下对高精度、实时性的技术需求。

1　异常检测需求分析

1.1调速器常见异常类型与故障模式

调速器作为用于调节系统输出速度与负载响应的核心装置，其异常现象通常具有功能破坏隐蔽、动态特征复杂、干扰路径多源的综合表现，主要可划分为三类，即电气类异常、机械类异常和控制类异常。电气类异常表现为稳态运行电流异常波动、短时电压回路失衡或驱动信号中断，机械类异常多见于联轴器松动、转轴偏心与内部摩擦系数急剧增大，控制类异常则涉及控制信号失准、反馈延迟积累及调速指令执行失误等。上述异常类型在运行过程中常以高频噪声叠加、转速波形漂移、负载-输出响应失配等方式体现，并具备阶段性过渡与突发性冲击的双重特性，需结合多通道信号同步检测与结构力学建模加以识别。

1.2监测数据特征及采样约束

调速器在运行状态下产生的监测数据常由速度、电流、电压、振动与温度等多物理量构成，这些信号在时间尺度和频率分布上呈现非一致性特征，表现为高频信号响应快但噪声多，低频信号稳定但异常征兆隐蔽。高频信号如驱动电流和瞬时转速，需以每秒两千次以上的采样频率捕获其突变过程，低频信号如轴承温度和壳体振动则可在每秒几十次的采样下保留足够的变化趋势。在多信号融合建模场景下，需设计统一采样周期与时间对齐机制，同时使用信号增强技术对异常特征低频淹没的现象进行补偿。由于硬件资源限制，系统不可能无限提高采样频率，需在数据有效性与资源占用之间寻求平衡，引入差分判据函数，用于识别转速曲线在单位时间内的瞬时突变行为。

1.3异常检测场景对算法的功能要求

在实际工业应用场景中，调速器常部署于精密驱动控制环节、连续负载调整节点及复杂工况过渡阶段，其异常检测算法需同时满足高精度、多类型覆盖与实时响应等多重技术要求。在精度方面，模型需具备对非线性扰动、微小幅值突变及冗余信号干扰下的异常识别能力，保证在不同故障发展阶段均能实现稳定分类。在覆盖范围方面，算法需兼顾多种异常形态，在单一模型框架内完成从短时振动冲击到持续偏差漂移的统一判别，避免因模型结构割裂而降低泛化性。在响应方面，调速器运行状态变化快，部分关键异常需在毫秒级内完成识别与反馈，算法延迟直接决定保护系统是否能在异常前期做出响应。

2　基于深度学习的调速器异常检测方法

2.1异常检测任务驱动的模型结构选型依据

对于调速器异常检测过程中呈现的信号非平稳、异常模式多样与运行状态快速切换等技术特征，传统浅层模型在特征识别方面存在表达力有限与分类泛化能力弱的问题，而深度学习模型因其具备端到端的非线性映射能力、动态序列建模能力与结构组合灵活性，成为当前解决复杂异常识别任务的关键路径。调速器的核心运行变量如转速、电

流、电压与机械位移呈现典型的时序性与状态耦合关系，结构选型应先满足对多变量时域数据的同步建模需求。在调速器运行早期异常识别中，长短期记忆网络可有效处理反馈信号中的延迟响应模式与长期依赖信息，对于转速慢性偏移、电流冗余振荡等难以直接通过局部统计量识别的隐性异常类型具有较好拟合能力。而在系统突发异常场景，如负载突变引发的电压跌落或调节失败引起的振动冲击，可通过多尺度一维卷积神经网络捕捉时间窗口内的局部突变结构，尤其是采用3×1、5×1、7×1等可变卷积核组合方式可分别对应短时扰动、中程趋势与周期模式，使模型获得对不同时间尺度异常事件的感知能力[1]。

在复杂故障状态下，为保证对混合异常的判别精度，应构建双通路结构，一路针对电气通道信号进行局部卷积建模，一路针对机械变量构建循环序列编码，两路融合后经全连接层构建高阶联合特征空间，解决多源信号间干扰与弱相关问题。

2.2面向调速器信号特征的输入构建机制

调速器运行状态监测信号具有高维异构、多频耦合与变载扰动复杂的特点，其输入结构设计必须解决信号归一、同步对齐、物理变量间交互表达与模型兼容性四个核心问题。典型输入变量如驱动电流与转速构成高动态耦合对，若直接输入原始数据，易因幅值差异或时间偏移导致训练阶段梯度扰动加剧或特征权重错配。为此，需对输入变量进行标准化映射处理，并结合差分增强与能量归一策略进行复合构建[2]。在此基础上，所有信号需以固定采样间隔进行时序对齐。对于振动与温度类低频信号可采用数据插值法填补时间窗缺失，对于高频信号则需按滑动窗口分段提取微变特征并嵌入时间戳索引实现同步建模。以捕捉调速器状态突变为目标，构造输入特征序列中的关键点变化率指标D(t)，定义如下：

$$D(t) = \left|v(t) - v(t - \Delta t)\right| \div \Delta t$$

其中，D(t)表示t时刻调速器转速变化率，v(t)表示转速信号，Δt为固定时间间隔，该变化率作为异常指征特征之一用于增强模型对状态突变段的响应能力。构建多维输入张量时，应以通道为维度对信号变量进行分组编码，如电气变量（电压、电流）构成主输入通道，机械变量（位移、加速度）构成辅助通道，通过注意力机制模块建立主辅变量之间的权重矩阵，防止非关键变量对异常预测结果形成干扰。模型输入格式构建完成后，需采用Tensor维度扩展方式将所有信号嵌入统一时间序列张量，最终形成维度为N×T×C的输入结构，其中N为批处理样本数，T为时间序列长度，C为信号通道数，该结构满足当前主流深度学习框架下的批训练、迁移部署与快速响应需求，适用于工业控制系统中的边缘节点预测部署场景。

2.3异常判别精度优化的输出策略与损失设计

为提升调速器异常检测模型在实际工况下的输出精度与响应稳定性，输出层结构与损失函数设计需以多类状态判别、类别失衡处理与决策稳定性增强为核心目标展开。输出策略需先明确分类目标与标签编码结构，针对调速器运行状态中电气类异常、机械类异常、控制回路异常与正常状态共四类结果。输出层设置为四分类概率结构，输出维度为1×4向量，经Softmax归一后取最大概率对应类别作为最终判别标签[3]。在类别失衡条件下，如正常样本占比超过90%，应采用加权交叉熵函数进行训练损失控制，损失函数L定义如下：

$$L = -\sum(w_i \times y_i \times log(p_i))$$

其中，L表示损失值，w_i为第i类别的权重因子，y_i为样本真实标签，p_i为模型对该类别的预测概率，该结构可有效提升对低频异常样本的识别敏感度。在输出策略中还应嵌入置信控制机制对预测概率低于动态阈值的样本暂不输出决策，进而采用滑动窗口下的置信漂移函数构建动态报警门限，其中预测稳定性阈值T_a可表示为：

$$T_a = \text{平均值}\mu + \text{调节系数}\alpha \times \text{标准差}\sigma$$

其中，μ表示过去预测概率的均值，σ表示波动范围，α为人为设定的调节参数，该判别门限用于实现动态调整的报警机制，在避免误报同时实现突发故障快速识别。模型输出端还需设定异常敏感性增强机制，当模型多次预测值在阈值附近震荡但未达成明确分类决策时，系统应主动触发样本缓存重判流程，避免因偶发波动导致的误警或误放，进而提升检测系统在实际工业场景中的稳定输出能力与判别鲁棒性。

3 检测方法实现与性能验证

3.1异常检测模型训练流程与实验集构建

为验证所构建模型在调速器多类异常状态识别中的工程适应性，本文构建了以结构选型、输入机制、输出策略三项核心改进为支撑的训练实验框架，数据来源为实际工业

现场四台变频调速器的多通道运行记录系统，涵盖运行状态下的电流、电压、转速、振动及控制反馈五类通道。其中，高频采样类数据以1kHz采样，低频信号以10Hz同步采集，形成统一数据矩阵，经滑动窗口处理构造定长序列输入张量，窗口长度设为128，步长为32，样本总量为84672条。为验证模型结构设计在捕捉时间依赖性方面的有效性，分别对比单卷积结构、单LSTM结构与本文所设定的双通道融合结构，采用相同训练轮数200轮、早停机制与加权交叉熵损失函数，模型训练流程中保持输入构建规则一致，保证实验变量控制唯一。

训练阶段重点考察模型对微弱扰动段的学习能力与不同类型异常标签收敛精度的变化趋势，在每轮验证集上引入异常区间置信波动评估，结合输出策略中提出的动态阈值机制，以置信窗口漂移幅度标准差σ小于0.02为收敛标志，最终模型在第136轮达到验证损失最小，并保持稳定输出。为检测标签处理过程的一致性，将异常标签生成方式限定为物理判据与操作日志联合标注，控制类异常由调速反馈延迟超过0.3s作为触发阈值，电气异常由瞬态电流超过稳态3倍以上波动幅度定义，机械异常依赖轴端振动信号频谱出现非周期跳变作为标志，建立统一标注模板后转化为4类独立编码标签，与输出策略设计完全一致，保证后续评价指标与结构方法的一一对应。

3.2检测精度、误报率与响应时间测试

模型性能验证聚焦于所提出的结构优化策略在准确性与响应效率方面的实效，采用三种结构对比：单CNN、单LSTM与双分支融合模型，所有模型保持相同输入构建机制与输出标签设置。评价指标包括：精度（Accuracy），定义为异常样本正确识别占比。误报率（False Alarm Rate），定义为正常样本被误判为异常的比例。响应时间为单条序列在边缘设备（ARM Cortex-A72，1.5GHz）上推理所需时间。表1展示三种结构模型在验证集上的量化性能指标，

表1 不同结构模型在异常检测任务中的对比评估结果

模型结构	检测精度（%）	误报率（%）	平均响应时间（ms）
单CNN结构	89.4	6.8	5.6
单LSTM结构	91.2	5.3	8.9
双分支融合结构	95.7	3.2	6.1

表中数据显示，在相同数据集与输入机制下，双分支融合结构在检测精度、误报率及响应时间三项指标上均优于单一结构模型，具体表现为检测精度达到95.7%，相较单CNN结构提升6.3个百分点，较单LSTM结构提升4.5个百分点，说明融合卷积的局部特征提取能力与循环网络的时序建模能力可协同增强模型对调速器异常状态的全域判别能力。在误报率方面，融合结构控制在3.2%，明显低于CNN的6.8%与LSTM的5.3%，证明多通道输入与动态输出策略有效抑制了非故障状态的错误触发。在响应时间方面，融合结构虽略高于CNN但优于LSTM，表明其在保证识别性能的同时兼顾了部署实时性，具备工业应用中的实效性与实用性。

4 结语

本文围绕调速器异常状态检测中的非线性、多耦合与响应时效性难题，构建了集深度融合结构、特征驱动输入机制与动态判别输出策略于一体的识别模型，并在多类异常数据集下完成系统性验证，证实所提方法在识别准确性、误报控制与响应效率等方面具备工程实用性与可部署性。后续研究可面向复合故障场景引入模态协同感知与因果结构建模，拓展模型在复杂工业系统中的泛化能力与预测深度。

参考文献：

[1]曹哲骁,傅瑶,王丽,等.基于深度学习网络的遥感图像异常检测方法研究[J].空间控制技术与应用,2023,49(6):77-85.

[2]王旭.基于深度学习的自适应概念漂移与不平衡数据的异常流量检测方法研究[D].天津理工大学,2024.

[3]刘晶.基于深度学习的配电网线损异常检测方法[J].今日自动化,2024(7):129-131.