

基于深度学习的机电一体化系统故障诊断与预测维护

韩明政

1 金达科技股份有限公司, 河北省沧州市, 061001;

2 河北省塑料包装材料工程技术创新中心, 河北省沧州市, 061001;

摘要: 机电一体化系统作为工业制造、能源供应、交通运输等领域的核心装备, 其运行可靠性直接决定了生产效率与运维成本。传统故障诊断方法过于依赖专家经验, 对早期故障识别率不足, 难以实现前瞻性预测维护。深度学习技术凭借其自动特征提取、非线性拟合及长时序依赖捕捉能力, 为解决上述问题提供了有效路径。本文全面论述了深度学习模型在机电一体化系统故障诊断与预测维护中的应用机制, 为机电一体化系统智能化运维提供参考依据。

关键词: 深度学习; 机电一体化; 系统故障诊断; 预测维护

DOI: 10. 64216/3080-1508. 25. 11. 002

1 机电一体化系统故障诊断与预测维护现状

1.1 传统故障诊断与预测维护方法

当前工业场景中, 机电一体化系统的故障诊断与预测维护仍以传统方法为主, 主要可分为三类。

第一类是基于信号处理的故障诊断方法, 核心是通过传感器采集设备运行信号采用时域或频域分析提取故障特征。例如, 某数控机床主轴故障诊断中, 通过振动传感器采集 10kHz 采样频率的信号, 计算时域峭度值, 正常状态下峭度值约为 3, 当主轴轴承出现磨损时, 峭度值可升至 5-8, 据此判断故障程度。但该方法存在明显缺陷, 时域指标对早期故障敏感但抗干扰能力弱, 对多故障耦合场景的区分能力不足。

第二类是基于模型的故障诊断方法, 通过建立设备的物理模型, 对比模型预测值与实际测量值的偏差, 判断是否存在故障。例如, 风电齿轮箱的动力学模型可通过齿轮啮合刚度、轴承阻尼等参数计算理论振动频率, 若实际测量频率与理论值偏差超过 5%, 则判定为故障。该方法的局限性在于复杂机电一体化系统的物理模型构建难度大, 多自由度机械臂的动力学模型包含数百个参数, 模型参数受工况影响, 当负载变化超过 20% 时, 模型预测偏差可增至 10% 以上, 导致故障误判。

第三类是基于传统机器学习的预测维护方法, 通过支持向量机 (SVM)、随机森林 (RF)、人工神经网络 (ANN) 等模型, 利用历史故障数据训练预测模型, 实现设备健康状态评估与 RUL 预测。例如, 某轨道交通牵引变流器的维护中, 采用 RF 模型对电流、电压数据进行训练, 预测变流器电容的剩余寿命。但传统机器学习

模型存在两个关键问题。一是特征工程依赖人工经验, 当传感器数据维度超过 100 维时, 人工筛选特征的效率降低 50% 以上, 且易遗漏关键故障特征。二是模型处理长时序数据的能力弱, 当时间序列长度超过 1000 个采样点时, RF 模型的训练时间增加 300%, 且预测精度下降 25%-30%^[1]。

1.2 现有技术的局限性对比

从故障诊断与预测维护的技术性能维度出发, 传统信号处理、传统机器学习与深度学习三类方法的关键指标差异如下。

在识别准确率方面, 传统信号处理方法表现最弱, 准确率仅处于 65%-75% 区间, 传统机器学习方法性能有所提升, 平均准确率可达 80%-85%。而深度学习方法优势显著, 平均准确率能稳定维持在 95%-99%, 远高于前两类方法。

处理数据维度上, 传统信号处理方法受限于技术原理, 仅能处理 ≤ 10 维的数据。传统机器学习方法虽有改进, 但仍局限于 ≤ 50 维的数据规模, 深度学习方法则具备强大的数据处理能力, 可以有效处理 ≥ 1000 维的高维数据, 能更全面地挖掘多传感器采集的复杂信息。

训练时间针对 10 万样本维度, 传统信号处理方法无需进行模型训练, 可以实现实时分析。传统机器学习方法需 30-60 分钟完成训练, 深度学习方法因模型结构更复杂、数据处理量更大, 训练时间相对较长, 需 60-120 分钟。

泛化能力当工况变化 20% 时方面, 传统信号处理方法泛化能力差, 工况变化后准确率会下降 30% 以上, 传

统机器学习方法泛化能力一般, 准确率下降幅度为 15%-20%。深度学习方法泛化能力最优, 即便工况变化 20%, 准确率下降也能控制在 $\leq 5\%$ 的范围内, 能更好地适应工业场景中多变的运行工况。

早期故障识别率上, 传统信号处理方法对早期故障的捕捉能力较弱, 识别率仅为 40%-50%, 传统机器学习方法识别率提升至 60%-70%, 深度学习方法在早期故障识别上表现突出, 识别率高达 90%-95%, 可以提前发现设备潜在故障风险, 为预测维护争取充足时间^[2]。

由以上可知, 深度学习方法在处理高维数据、泛化能力及早期故障识别率上具有显著优势, 但其训练时间较长, 需离线完成, 这一局限性可通过模型轻量化技术缓解, 因此更适用于现代机电一体化系统的智能化运维需求。

2 深度学习关键技术在机电一体化系统故障诊断与预测维护中的应用

2.1 卷积神经网络 (CNN) 在故障特征自动提取中的应用

CNN 的核心优势是通过卷积层与池化层的交替作用, 自动提取数据的局部空间特征, 无需人工设计特征工程, 尤其适用于振动信号、红外热成像图等具有空间结构的多维度数据。在机电一体化系统故障诊断中, CNN 常被用于处理振动信号转换后的二维特征图或直接处理设备部件的红外热成像图像, 实现故障类型的分类识别。

2.1.1 应用场景

数控机床主轴轴承是保证加工精度的核心部件, 其早期磨损故障会导致加工误差增大, 圆度误差从 0.005mm 增至 0.02mm, 当未及时诊断, 可能引发主轴卡死等严重故障。某型号立式加工中心的主轴轴承故障诊断中, 采用以下方案。

(1) 数据采集。在主轴电机端安装 PCB 356A15 振动传感器, 测量范围 0-5000Hz, 灵敏度 100mV/g, 采样频率设为 10kHz, 每 5 秒采集一段数据, 含 50000 个采样点, 共采集正常状态、内圈磨损、外圈磨损、滚动体磨损 4 类数据, 每类 1000 个样本。

(2) 数据预处理。对振动信号进行去趋势, 消除直流分量, 50Hz 陷波滤波抑制电网干扰, 然后通过短时傅里叶变换将一维时域信号转换为 224x224 像素的梅尔频谱图, 使故障特征在频域-时域平面上可视化。

2.1.2 实验结果

在该数控机床主轴轴承数据集上, CNN 模型的平均故障识别率达 98.2%, 其中内圈磨损、外圈磨损、滚动体磨损的识别率分别为 97.5%、98.8%、99.1%, 正常状态识别率为 97.4%, 对比传统 FFT 频域分析, 平均识别率 72.3%, CNN 模型的识别率提升 25.9 个百分点, 尤其对早期磨损故障的识别率从 58.6% 提升至 96.3%, 有效解决了传统方法对早期故障敏感度过低的问题^[3]。

2.2 长短期记忆网络 (LSTM) 在时序故障预测中的应用

机电一体化系统的运行数据具有显著的时序特性, 故障的发展是一个渐进过程, 风电齿轮箱油温从正常 25℃ 逐步升至故障 40℃, LSTM 通过门控机制能够有效捕捉长时序数据中的依赖关系, 避免传统循环神经网络的梯度消失问题, 因此被广泛应用于设备健康状态趋势预测与剩余使用寿命估算。

2.2.1 应用场景

风电齿轮箱是风电机组的核心传动部件, 其运维成本占风电场总运维成本的 30% 以上, 精准预测其 RUL 可减少非计划停机时间。某 1.5MW 风电机组的齿轮箱 RUL 预测中, 采用以下方案。

(1) 数据采集。通过传感器采集齿轮箱油温采样间隔 1min、输入轴转速采样间隔 10s、输出扭矩采样间隔 10s、振动有效值采样间隔 1min 4 类时序数据, 共采集 6 台故障齿轮箱的全生命周期数据, 从正常运行至故障停机, 每台设备的数据长度约为 262800 个时间步, 对应 6 个月运行时间。

(2) 数据预处理。对时序数据进行归一化, 处理缺失值采用线性插值法, 然后构建时序样本, 以过去 60 个时间步的数据作为输入特征, 以未来剩余运行时间作为标签, 共生成 15000 个训练样本、3000 个测试样本。

(3) LSTM 模型结构。输入层时间步长 $T=60$, 特征数 $F=4$, 即 4 类时序参数 $\rightarrow$ LSTM 层 1 (64 个神经元, 返回序列, 用于捕捉短期时序依赖) $\rightarrow$ LSTM 层 2 (32 个神经元, 不返回序列, 用于捕捉长期时序依赖) $\rightarrow$ 全连接层 1 (16 个神经元, ReLU 激活) $\rightarrow$ 输出层 (1 个神经元, 线性激活, 输出 RUL 预测值)。

2.2.2 核心公式与实验结果

LSTM 的遗忘门计算公式为:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (1)$$

式(1)中, f_t 为遗忘门输出, $0 \leq f_t \leq 1$, 值越接近 1 表示保留更多历史信息, W_f 为遗忘门权重矩阵, h_{t-1} 为 $t-1$ 时刻的隐藏层输出, x_t 为 t 时刻的输入样本, b_f 为遗忘门偏置项, $\sigma(\cdot)$ 为 Sigmoid 激活函数。

实验采用 NASA 的 FD001 涡扇发动机数据集, 包含 4 台发动机的全生命周期数据进行对比验证, 结果显示, LSTM 模型对风电齿轮箱 RUL 的预测 MAE 为 8.2 个循环, 1 个循环对应 1 小时运行时间, 均方根误差为 10.5 个循环。对比传统 ARIMA 模型 (MAE=23.5, RMSE=28.7), LSTM 的 MAE 降低 65.1%, RMSE 降低 63.4%; 即使训练数据减少 30%, 模拟数据缺失场景, LSTM 的 MAE 仅增至 9.5 个循环, 鲁棒性显著优于传统模型。

2.3 自编码器 (AE) 在无监督故障诊断中的应用

工业场景中, 机电一体化系统的故障样本往往稀缺, 故障发生率通常低于 5%, 而正常运行数据充足, 传统有监督学习模型因样本不平衡易出现过拟合。自编码器是一种无监督深度学习模型, 通过编码器将输入数据压缩为低维特征向量, 再通过解码器重构输入数据, 以重构误差作为健康状态评估指标, 正常数据的重构误差小, 故障数据的重构误差大, 从而实现无监督故障诊断。

2.3.1 应用场景

牵引变流器是轨道交通列车的核心电力电子设备, 负责将电网直流电压转换为电机所需的交流电压, 其 IGBT 开路、电容老化等故障会导致列车牵引力下降, 甚至引发停运^[4]。某地铁线路的牵引变流器故障诊断中, 采用以下方案。

(1) 数据采集。采集牵引变流器的三相输入电压 (DC 1500V, 采样频率 5kHz)、三相输出电流 (AC 0-1000A, 采样频率 5kHz)、IGBT 模块温度 (采样频率 1Hz) 3 类数据, 仅采集正常运行数据, 10000 个样本, 每个样本含 100 个采样点用于训练 AE 模型, 采集 IGBT 开路、电容老化、正常状态 3 类数据用于测试。

(2) AE 模型结构。输入层 $3 \times 100 = 300$ 个神经元, 对应 3 类参数的 100 个采样) → 编码器层 1200 个神经元, ReLU 激活 → 编码器层 2100 个神经元, ReLU 激活 → 瓶颈层 50 个神经元, 低维特征向量 → 解码器层 1100 个神经元, ReLU 激活 → 解码器层 2200 个神经元, ReLU 激活 → 输出层 300 个神经元, Sigmoid 激活, 重构输入数

据。

(3) 故障判定逻辑。通过正常数据训练 AE 模型, 计算正常样本的重构误差, 取 99% 分位数作为阈值; 测试样本的重构误差若超过 0.05, 则判定为故障, 否则为正常。

2.3.2 核心公式与实验结果

AE 的重构损失函数 (均方误差 MSE) 为:

$$L = \frac{1}{N} \sum_{i=1}^N \|x_i - \hat{x}_i\|_2^2 \quad (2)$$

式(2)中, N 为样本数量, x_i 为第 i 个输入样本, $\|\cdot\|_2$ 为 L2 范数, 衡量输入与重构样本的差异^[5]。

实验结果显示, AE 模型对正常状态样本的重构误差均小于 0.03, IGBT 开路故障样本的重构误差均值为 0.12, 电容老化故障样本的重构误差均值为 0.09, 对 IGBT 开路、电容老化故障的识别率分别为 96.5%、97.8%, 误报率仅 2.1%, 对比传统 K-means 聚类方法, AE 的故障判定精度提升 74.7%, 有效解决了故障样本稀缺场景下的诊断难题。

3 结语

综上, 本文全面研究了深度学习技术在机电一体化系统故障诊断与预测维护中的应用, 不同深度学习模型的应用场景具有针对性。未来, 随着深度学习技术与工业物联网、数字孪生、边缘计算的深度融合, 机电一体化系统的故障诊断与预测维护将向“实时化、精准化、自主化”方向发展, 为构建智能工厂提供核心技术支撑。

参考文献

- [1] 刘原源. 关于智能控制在矿山机电一体化系统中的应用研究[J]. 能源与节能, 2025(2): 288-290.
- [2] 汪涛. 智能控制在矿山机电一体化系统中的应用[J]. 中国高新科技, 2024(5): 71-73.
- [3] 王晓辉, 杨氟. 机电一体化系统中的传感器与执行器技术研究[J]. 葡萄酒, 2024(21): 0085-0087.
- [4] 郝中波, 李晓南, 刘姣. 人工智能背景下机电一体化设备的故障诊断技术优化[J]. 信息与电脑, 2024, 36(7): 146-148.
- [5] 范梅林. 机电一体化设备故障智能诊断技术探讨[J]. 模具制造, 2024, 24(12): 230-232.