

基于深度学习的电气自动化设备故障预测与健康管理研究

杨玉心

长春水务投资发展集团有限公司 吉林 长春 130000

【摘要】：随着工业自动化水平的提高，电气设备在现代制造系统中日益关键。实现其运行状态的实时监测与故障预警，已成为保障生产连续性与安全性的核心问题。本文研究深度学习在电气自动化设备故障预测与健康管理（PHM）中的应用，旨在构建高效、准确的状态监测与寿命预测模型。通过分析多源传感器数据，结合 LSTM、CNN-LSTM 和 Transformer 等模型提取关键特征，建立故障预测体系，并设计健康指数（HI）与剩余使用寿命（RUL）评估机制，实现设备健康状态的动态评估与预警。实验结果表明，所构建模型在故障识别和状态预测方面具有较高精度与稳定性，显著提升了设备维护效率，降低了运维成本。研究成果为智能工厂建设和设备智能化运维提供了理论支持与实践参考。

【关键词】：电气自动化设备；故障预测；健康管理；深度学习；LSTM；健康指数；剩余使用寿命

DOI:10.12417/2811-0536.25.11.063

1 引言

随着工业 4.0 和智能制造技术的发展，电气自动化设备在现代制造业中扮演着关键角色，广泛应用于生产线控制、电力系统运行及各类自动化流程。其运行状态直接影响生产效率、产品质量和工厂安全运营。然而，长期运行中电气设备不可避免地出现老化、磨损或突发故障，导致维修成本上升、生产中断甚至安全事故。传统维护方式依赖定期检查和事后维修，存在响应滞后、资源浪费等问题。因此，发展提前预测潜在故障并进行健康状态评估的技术尤为重要。近年来，故障预测与健康管理（PHM）技术成为研究热点，通过数据分析和建模手段实现设备状态实时监测和剩余使用寿命估计，从“被动维修”转向“主动预防”。深度学习凭借强大的特征提取和非线性建模能力，在图像识别、自然语言处理等领域取得显著成果，也被引入 PHM 领域，为复杂设备的状态预测提供了新思路。本文探索深度学习在电气自动化设备故障预测与健康管理中的应用，构建高效预测模型，设计合理的健康评估体系，以提升设备维护智能化水平，降低运维成本，提高生产系统的可靠性和安全性，为智能工厂建设提供技术支持，并推动工业设备状态监测技术的发展。

2 相关研究概述

故障预测与健康管理作为提高设备可靠性和降低维护成本的重要手段，已经在航空航天、汽车制造、能源电力等多个行业中得到了广泛应用。PHM 的核心目标是对设备的运行状态进行实时监测，并基于历史数据和当前状态预测未来可能出现的故障，从而制定科学的维护策略。传统 PHM 方法主要包括基于物理模型的方法和基于统计模型的方法。其中，基于物理

模型的方法依赖于对设备内部结构和工作原理的深入理解，通常适用于具有明确物理机制的系统，但建模过程复杂且难以适应复杂的非线性系统；而基于统计模型的方法如支持向量机（SVM）、自回归积分滑动平均模型（ARIMA）等则能够在一定程度上处理不确定性数据，但往往需要大量先验知识和特征工程的支持，泛化能力有限。近年来，随着人工智能技术的发展，尤其是深度学习的兴起，越来越多的研究开始将卷积神经网络（CNN）、循环神经网络（RNN）、长短期记忆网络（LSTM）等模型应用于 PHM 任务中。深度学习模型能够自动提取高维数据中的有效特征，无需人工设计复杂特征，同时具备良好的非线性拟合能力，能够应对复杂多变的工业环境。

3 理论基础与关键技术

电气自动化设备常见故障包括机械类（如轴承磨损、齿轮断裂）、电气类（如绝缘老化、电路短路）及热效应引起的故障，表现为温度升高、电流波动、振动加剧等。理解这些故障的机理及其在信号中的表现形式是准确预测的基础。例如，轴承故障会在振动信号中表现出特定频率变化，电机绕组老化则导致电流谐波异常增加。有效的信号采集与分析机制是 PHM 的前提。深度学习模型通过非线性映射和模式识别实现高精度预测。LSTM 网络擅长捕捉时序数据的长期依赖关系，CNN-LSTM 结合了局部特征提取和时间维度建模的优势，适用于多传感器数据融合；Transformer 利用自注意力机制处理长序列数据，在时间序列预测中展现潜力。VAE 和 GAN 用于异常检测和数据增强，提升小样本情况下的泛化能力。数据预处理和特征工程至关重要，原始数据需经过缺失值填补、归一化等步骤清洗，并通过时域统计和频域变换提取关键特征，

为模型训练提供高质量输入。

4 系统设计与方法实现

针对电气自动化设备的 PHM 需求,构建了一个系统架构,包括数据采集、预处理、模型训练、健康评估及可视化展示五大模块。数据采集层从传感器获取电压、电流、温度和振动等数据,并通过 Modbus 或 OPC UA 传输至中央处理单元。预处理层对数据进行去噪、插值、归一化,提取时域、频域及复合特征形成结构化数据集。模型训练层使用 TensorFlow 或 PyTorch 框架,训练 LSTM、CNN-LSTM 和 Transformer 模型,选取最优者用于预测。健康评估层基于模型输出构建健康指数(HI),结合历史状态估算剩余使用寿命(RUL),设定预警阈值并触发报警机制。可视化展示层通过 Web 界面实时显示设备状态、预测结果及健康趋势,便于运维人员监控。实验数据来自某制造企业的生产线设备记录,涵盖多传感器通道数据,按时间顺序分为训练集、验证集和测试集以确保泛化能力。模型训练采用交叉熵损失函数与 Adam 优化器,设置合适的学习率和批量大小,并通过早停机制防止过拟合。评估指标包括准确率、召回率、F1 分数及 AUC-ROC 曲线,全面衡量模型性能。该健康评估体系实现了设备状态的精准判断,为动态维护策略提供了科学依据。

5 电气设备健康状态评估方法

在现代工业环境中,电气自动化设备的高效稳定运行是确保生产过程顺利进行的关键。随着设备复杂性的增加以及对生产效率和安全性要求日益提高,传统的基于经验的维护方式已无法满足需求。因此,构建一套科学、系统的电气设备健康状态评估方法显得尤为重要。该方法不仅能够准确预测设备故障,还能实时监测设备健康状况,从而为制定合理的维护策略提供依据。

首先,电气设备健康状态评估体系的构建需要明确健康指标的选择标准。这些指标通常来源于设备运行过程中产生的各种参数,如电压、电流、温度、振动等。其中,电压和电流的变化可以反映设备内部电路的工作状态;温度则与设备的散热性能及负载情况密切相关;而振动数据则是检测机械部件磨损的重要依据。此外,还包括一些间接指标,比如设备的工作时长、启动次数等。为了全面、准确地描述设备的健康状态,需要综合考虑多种类型的指标,并通过数据分析确定各指标的权重。

其次,在构建基于深度学习的健康状态评估模型

方面,自编码器(Autoencoder,AE)是一种广泛应用的技术。自编码器是一种无监督学习算法,它通过训练一个神经网络来重构输入数据,中间层作为特征提取器,可用于异常检测。具体来说,当输入数据经过自编码器后,如果输出与原始输入之间的误差较大,则表明该数据点可能存在异常,即设备处于非正常工作状态。此外,还可以利用变分自编码器(Variational Autoencoder,VAE),它不仅能重构输入数据,还能生成新的数据样本,对于处理复杂的电气设备数据具有更好的适应性。

除了自编码器之外,健康退化趋势预测模型也是健康状态评估的重要组成部分。这类模型旨在根据历史数据预测未来一段时间内设备健康状态的变化趋势。例如,长短时记忆网络(LSTM)和门控循环单元(GRU)等递归神经网络(RNN)特别适用于处理时间序列数据,它们能够捕捉到数据中的长期依赖关系,非常适合用于分析电气设备随时间变化的健康状况。通过将不同时间段的数据输入到 LSTM 或 GRU 中,可以得到设备健康状态随时间演化的曲线图,进而预测出何时可能达到临界健康阈值。

动态阈值设定与自适应评估机制是提升健康状态评估准确性的重要手段。传统固定阈值的方法往往难以适应设备在不同工况下的变化。采用基于数据驱动的方法,可以根据实时采集的数据动态调整阈值。例如,使用滑动窗口技术计算当前时段内的统计特征(如均值、方差),并据此更新阈值。这种方法使得健康状态评估更加灵活,能够更好地应对实际应用中的不确定性。

6 系统集成与工程应用

在电气自动化设备故障预测与健康管理的(Prognostics and Health Management, PHM)研究不断深入的基础上,将理论模型与工程实践相结合,构建一个高效、稳定、可扩展的系统集成平台,成为推动该技术落地应用的关键环节。系统集成不仅涉及算法模型的部署与优化,还包括硬件平台的搭建、数据采集与处理、软件系统开发以及与现有工业控制系统的无缝对接。通过系统集成,能够将基于深度学习的故障预测与健康评估方法转化为实际可用的工程解决方案,提升设备运行的安全性、可靠性和维护效率。

系统集成的整体架构通常包括数据采集层、边缘计算层、云端处理层以及用户交互层。数据采集层负责通过各类传感器(如电压传感器、电流传感器、温度传感器、振动传感器等)实时获取设备运行状态数

据,并通过工业总线(如 Modbus、CAN、PROFIBUS 等)或无线通信协议(如 Wi-Fi、5G、LoRa 等)传输至边缘计算设备。边缘计算层承担数据预处理、特征提取和初步故障识别的任务,能够在本地快速响应关键事件,减少对云端的依赖,提高系统的实时性和稳定性。云端处理层则集中部署深度学习模型,进行大规模数据分析、模型训练与优化,并实现跨设备、跨平台的健康状态评估与故障预测。用户交互层提供可视化界面,支持设备状态监控、报警提示、维护建议等功能,便于管理人员进行决策和调度。

在系统开发与实现过程中,前后端架构的设计至关重要。前端通常采用 Web 或移动端界面,利用 HTML5、CSS3、JavaScript 及主流框架(如 Vue.js、React 等)实现友好的用户交互体验;后端则采用

Python、Java 或 C#等语言开发,结合 Flask、Django、Spring Boot 等框架实现数据接口、模型调用与业务逻辑处理。数据库系统(如 MySQL、MongoDB、InfluxDB 等)用于存储历史数据、模型参数及健康评估结果,确保数据的可追溯性与安全性。

7 结论

通过构建 LSTM 及其改进模型对设备运行数据进行分析,实现了较高的故障识别准确率与健康状态评估能力,为实现预测性维护提供了有效路径。研究表明,深度学习在 PHM 领域具有广阔的应用前景,不仅能提升设备维护的智能化水平,还能有效降低运维成本,提高生产系统的安全性和稳定性。未来将继续完善模型架构,拓展应用场景,推动 PHM 技术在更多工业领域的落地实施。

参考文献:

- [1] 陶书弘,吕瑞.故障预测与健康管理技术的应用与发展[J].中国设备工程,2020,(07):147-148.
- [2] 陈刚.电气自动化设备故障诊断与预测维护技术进展探究[J].仪器仪表用户,2024,31(11):93-95.
- [3] 史传博,胡玉山.电气自动化系统中的故障检测与诊断技术应用[J].灯与照明,2025,49(01):186-189.
- [4] 陈方逸.基于深度学习的电气自动化系统运行故障状态快速预警方法[J].电气技术与经济,2025,(01):335-337.