

基于深度学习的工业物联网 (IIoT) 设备故障预测方法

武秀龙

聊城大学物理科学与信息工程学院 山东聊城 252000

摘要: 随着工业5.0的推进,工业物联网(IIoT)已成为现代智能制造的核心基础设施,设备在长时间、高负荷运行下极易发生故障,导致高昂的停机成本与安全隐患,传统的设备维护策略和基于经验的故障诊断方法已难以应对海量、高维的工业传感数据。深度学习能够直接从海量传感数据中自动提取特征,克服了传统方法高度依赖人工的缺陷。本文主要探讨了明确了异常检测、故障诊断和剩余使用寿命的预测,数据处理中多模态数据融合,以及去噪扩散概率模型(DDPM)在解决样本不平衡与异常重构中的优势,重点介绍了时间序列基础模型(TSFM)的泛化能力,以及大语言模型(LLMs)与智能体在复杂诊断中的深度融合,分析了面向资源受限终端的模型压缩与部署策略,如树展平编译和激活感知权重分配(AWQ),并提出了未来白盒化的发展方向。

关键词: 工业物联网;深度学习;故障预测;预测性维护

引言

在工业生产中,关键设备的意外停机往往会导致严重的经济损失和生产线瘫痪,因此,工业维护策略应向预测性维护^[1],预测性维护的核心在于通过分析设备的运行状态数据,在故障发生前准确预测其健康趋势。

工业物联网(IIoT)的普及为预测性维护提供了硬件基础,海量的传感器被部署在工业设备上,实时采集振动、温度、电流、声学等多模态时间序列数据。然而,传统的数据驱动方法高度依赖人工^[2],在复杂的工业现场环境中,提取有效的特征需要丰富的领域专家经验,且模型泛化能力较差。深度学习技术的突破提供了新的思路,深度学习模型能够直接从原始传感数据中自动学习高阶的抽象特征,同时,其处理非线性复杂映射的能力,在处理IIoT海量多源异构数据时具有显著优势^[3]。因此将工业物联网应用于设备故障预测是不可避免地趋势。

一、工业物联网设备故障预测框架

在IIoT场景下,基于深度学习的故障预测主要涵盖三个渐进的任务,首先是异常检测,旨在从实时数据流中快速识别出偏离正常运行状态的异常模式,其次是故障诊断,在确认异常后,进一步识别故障的类型、发生部位及严重程度,最后就是剩余使用寿命预测,通过分析设备的退化轨迹,预测设备从当前时刻到彻底失效前还能正常运行的时间,这是预测性维护的最终目标^[4]。

一个完整的IIoT设备故障预测系统通常包含四个步

骤,分别是数据采集、数据预处理、模型训练与验证以及在线监测与预警。第一步是数据采集通过传感器获取多模态物理信号;第二步是数据预处理,对原始信号进行降噪、缺失值插补、归一化以及多源数据对齐,这是保证深度学习模型性能的前提;第三步是模型的训练与验证,选择合适的深度学习网络提取特征,利用历史数据集进行监督或无监督训练;最后一步就是在线监测与预警,将训练好的模型部署在IIoT边缘网关或云端,输入实时流数据,输出预测结果并触发维护指令。

二、工业数据的预处理与特征工程

深度学习具有强大的自动特征提取能力,但在现实的工业物联网环境中,工业现场采集的原始数据通常伴随着高噪声、多模态以及严重的类别不平衡,因此,高质量的数据预处理是提升模型预测准确率和鲁棒性的关键步骤。

现代工业设备通常配备多种类型的传感器,不同传感器的数据采样率、量纲和物理意义各不相同,数据融合技术旨在将这些异构数据在时间戳上进行对齐,并在数据级、特征级或决策级进行整合,有效的多模态数据融合能够提供设备健康状态的全局视角,显著降低单一传感器失效带来的误报率^[5]。还有工业现场的电磁干扰或传感器短暂故障会导致原始数据中出现异常尖峰(噪声)和缺失值,对于噪声常用的小波变换和经验模态分解(EMD)来进行平滑,它们能在保留关键故障特征的同时滤除高频环境噪声,对于缺失值,通常采用线性插

值或基于K近邻(KNN)的方法进行填补,随后对数据进行归一化或标准化处理,以消除不同量纲对神经网络权重更新的负面影响。

样本不平衡问题是工业设备故障预测中最突出的难题之一,在实际运行中,设备绝大多数时间处于正常状态,故障数据极其稀缺,这种严重的数据不平衡会导致深度学习模型在训练时过度偏向正常类别,从而对少数的故障样本失去敏感度。目前主流的解决策略包括重采样技术、代价敏感学习与生成式方法,近年来,生成对抗网络(GAN)视为扩充少数类故障样本的主流解决方案,但是GAN在处理高度复杂的工业多频段振动信号或声学信号时,经常面临模式崩溃、训练极不稳定以及生成的样本缺乏语义连贯性等致命缺陷。当前的先进技术(SOTA)已全面转向去噪扩散概率模型(DDPM)和流模型(Flow-based Models)。DDPM的核心机制在于通过马尔可夫链的前向过程逐步向真实数据注入高斯噪声,直至数据完全转化为随机噪声,随后,通过训练一个深度神经网络来学习反向去噪过程,从而从纯噪声中逐步恢复出具有极高逼真度和多样性的合成故障样本。在具体的工业应用中,研究人员通常首先通过连续小波变换将一维原始振动信号转换为二维时频图,随后将其输入DDPM进行训练。实验结果表明,DDPM生成的样本在最大均值差异上,远优于传统的GAN,更重要的是,通过引入条件引导,DDPM能够在微弱信号和强环境噪声的恶劣环境下,精确合成特定严重程度故障特征,从而极大提升了多分类故障诊断模型的鲁棒性和泛化能力,除了作为数据增强工具,扩散模型本身正在重塑无监督异常检测的范式。

三、基于深度学习的故障预测核心方法

在完成数据预处理后,选择合适的深度学习架构是实现精准预测的核心,不同的神经网络模型在处理空间特征、时间依赖性和无监督学习方面各有优势,下面简单介绍两种在IIoT故障预测中应用最先进的几种核心方法。

首先是时间序列基础模型(TSFM_s),基于海量、多源、异构的时序数据集(包含交通、能源、工业物理传感等领域),研究人员训练出了如Lag-Llama、Chronos、Moirai、TimesNet、TTM和TimeGPT等数十种具有强大零样本和少样本泛化能力的时间序列基础模型。与传统的LSTM或针对特定数据集从头训练的CNN不同,TSFM_s的设计初衷是理解时间序列中通用的拓扑结构,以Lag-Llama为例,该模型采用了基于Llama的Transformer解码

器架构,并集成了RMSNorm归一化与旋转位置编码,它摒弃了传统的图像式分块处理,转而使用滞后特征构建序列,这种设计严格保证了时间序列的因果性,有效避免了信息泄露,使其在处理复杂的工业退化模式时表现出卓越的自回归预测能力。此外,TSFM_s在概率预测方面取得了突破,传统的决定性模型只能输出一个具体的RUL数值,而Lag-Llama的分布头采用学生t分布,能够为每一个预测时间步输出一个概率分布的参数,这种不确定性量化能力对于高风险的工业维护至关重要,宽分布意味着模型极度不确定,从而能够及时触发人工干预。实验结果表明,通过持续的预训练或轻量级的上下文学习,TSFM_s可以在极少目标域样本的情况下,快速适应特定数控机床或风机的物理退化特征,这样彻底解决了传统深度学习模型在数据孤岛和跨工况变载条件下的性能断崖问题。

大语言模型在IIoT中的应用已不仅限于代码编写或简单的文本分类,而是作为工业系统的核心认知引擎。在现有的IIoT架构中,LLM通常被部署在分析协议栈的最高层,底层的轻量化专业模型负责处理高频遥测原始信号并检测异常特征,随后,LLM利用其强大的上下文理解能力,接收这些高度浓缩的分析结论,通过结合检索增强生成(RAG)技术,LLM能够以毫秒级的速度扫描海量的设备设计文档、历史维修日志、工单记录以及专家知识库,最终,LLM不仅能够输出引发警报的根本原因分析,还能通过自然语言生成具有极高可解释性的维修建议。

四、深度学习模型在IIoT中的部署架构

在工业物联网高度异构的硬件生态中,最新的边缘智能(Edge AI)部署技术已经实现了更为精细和彻底的底层优化。

这里介绍一种面向微控制器与极端资源受限环境的压缩策略,随着边缘AI芯片算力的两极分化,一方面是高性能边缘网关承载LLM的微调部署,另一方面则是海量部署在电机侧的微控制器单元,对于后者,内存往往受限于数百KB之内。在这一微型化趋势中,树展平编译技术成为一种SOTA方案,通过将经过修剪的决策树集成模型直接编译为无动态内存分配的连续纯C语言确定性控制流语句,模型不仅能够大幅降低执行延迟并提高实时预测的时间确定性,还能将其体积压缩至约200KB以内,完美适配极低功耗和低内存容量的微控制器平台。对于包含上千万甚至数十亿参数的基础模型或视觉大模

型, 激活感知权重分配, 展现出了比传统全局INT8量化更为优异的性能保障。AWQ技术基于对校准数据集的统计分析, 识别出网络中对最终特征表达最为关键的约1%的显著参数。在实施模型压缩时, 这些关键参数被保留为高精度, 而其余99%的冗余参数则被激进地量化为4-bit甚至更低精度的数值, 这种混合精度压缩策略在极大缩小模型体积和边缘设备端之间传输时延的同时, 近乎无损地保留了深度学习模型在复杂工业非线性动态系统中的特征提取精度, 彻底打通了重型基础模型向IIoT终端下沉的物理屏障。

五、当前挑战与未来研究方向

尽管基于深度学习的IIoT设备故障预测取得了很大的进展, 但距离在全行业的全面落地仍面临诸多挑战。在化工、核电、航空制造等安全关键型工业中, 黑盒AI由于缺乏逻辑透明度和不确定性量化, 很容易被拒绝。

基于知识图谱与图神经网络(GNN)的白盒化推理, 单纯的数据驱动深度学习模型无法理解复杂的物理拓扑和因果传播路径。前沿研究正在大力推动领域专家经验的符号化表示——知识图谱(Knowledge Graphs, KGs)与图神经网络(GNN)的深度融合。例如, 风险级知识图谱(Risk Level Knowledge Graph, RLKG)能够将工业设备的层级结构、故障传播机理以及历史风险等级进行本体建模。

将RLKG与GNN结合, 利用结构化的先验知识来初始化GNN的节点特征并稀疏化网络连接权重, 能有效过滤无关变量造成的噪声干扰。这种混合框架不仅能够将模型的收敛速度提升35%, 更重要的是, 它极大地增强了模型的可解释性: 超过89%的GNN注意力权重可以直接映射到具体的物理系统组件上, 从而清晰地展示出故障是如何沿着拓扑网络传播的。结合大规模预训练模型(PTMs), 该框架在处理高压直流系统(HVDC)等复杂非线性系统时, 展现出了卓越的抗噪鲁棒性和少样本泛化能力。

置信度校准与数字孪生闭环, 建立工业信任的另一个核心支柱是模型置信度的校准, 一个高可信的系统必须能在面对超出其训练分布的数据时, 准确表达出“不确定性”。近期的研究在诊断架构中引入了温度缩放置

信度校准模块以及风险评估模块, 通过期望校准误差等指标客观量化系统输出的可靠性。当复杂特征模式或传统模型存在知识盲区导致冲突时, 基于人类-AI治理(HAIG)框架的系统会动态调整其信任指标, 必要时将决策权移交给人类, 这样可以有效避免一些事故。

结论

随着工业5.0浪潮的推进, 基于深度学习的IIoT设备故障预测已彻底超越了早期的“模式识别”与“异常报警”阶段。未来的预测性维护系统将是一个融合计算、通信与控制(Computing, Communication, and Control)的三位一体复杂认知生态。在这个生态中, 时间序列基础模型(TSFM)的零样本能力和大语言模型(LLMs)的常识推理共同赋予系统超越人类专家的认知广度; 去噪扩散概率模型(DDPM)与数字孪生解决了极端罕见故障的数据合成瓶颈; 而6G时代的动态任务导向语义通信则打通了云边协同中高维智能表征的物理传输动脉。通过引入高可信度的置信度校准机制和基于知识图谱的因果推理, 人工智能将彻底摆脱“黑盒”标签, 重塑人类与工业基础设施的互信交互模式, 最终构筑起具有极高弹性和自愈能力的下一代智能制造底座。

参考文献

- [1] 郭宇. 基于故障预测的设备预防性维护策略研究及应用[D]. 重庆大学, 2017.
- [2] 吴斌, 徐杨. 基于物联网技术的电气自动化设备远程故障诊断系统应用[J]. 造纸装备及材料, 2025, 54(11): 10-12.
- [3] 阿布, 胥嘉幸. 机器学习之路[M]. 电子工业出版社: 201708: 328.
- [4] 王栋, 李伟, 霍鑫睿, 等. 基于深度学习的机电系统故障智能诊断与预测方法研究[J]. 现代制造技术与装备, 2026, 62(01): 117-119. DOI: 10.16107/j.cnki.mmte.2026.0035.
- [5] 李彦龙, 张天民, 冯志强, 等. 多模态融合的大型LNG接收站智能化管控平台设计[J/OL]. 控制工程, 1-7[2026-03-11].