

基于深度学习的电机故障诊断方法

马金凤

尼得科电机（大连）有限公司 辽宁大连

【摘要】随着电机在各领域广泛应用，其故障诊断至关重要。传统方法有局限，深度学习凭借强大特征学习能力崭露头角。通过构建合适神经网络模型，采集电机运行多源数据，如振动、电流等，经数据预处理、模型训练优化，能精准识别电机各类故障模式，有效提升诊断准确率与效率，为保障电机可靠运行提供有力技术支撑。

【关键词】深度学习；电机故障；数据采集；模型训练；故障诊断

【收稿日期】2025 年 3 月 5 日

【出刊日期】2025 年 4 月 6 日

【DOI】10.12208/j.jer.20250166

Motor fault diagnosis method based on deep learning

Jinfeng Ma

Nidec Motor (Dalian) Co., Ltd., Dalian, Liaoning

【Abstract】As motors are widely applied in various fields, fault diagnosis has become crucial. Traditional methods have limitations, while deep learning, with its powerful feature learning capabilities, is emerging as a promising approach. By constructing appropriate neural network models and collecting multi-source data from motor operation, such as vibration and current, through data preprocessing and model training optimization, it can accurately identify various fault modes of motors. This effectively enhances diagnostic accuracy and efficiency, providing strong technical support for ensuring the reliable operation of motors.

【Keywords】Deep learning; Motor fault; Data acquisition; Model training; Fault diagnosis

引言

在工业生产、交通运输等众多领域，电机是关键设备。一旦发生故障，不仅会造成生产停滞、设备损坏，还可能引发安全事故，带来巨大经济损失。传统电机故障诊断手段依赖人工经验与简单信号处理，难以应对复杂工况下的故障识别。深度学习技术的兴起，为电机故障诊断开辟新途径，有望突破现有瓶颈，实现智能化、高精度故障诊断，故开展相关研究意义重大。

1 电机数据采集分析

电机作为工业生产中的核心动力设备，其运行状态受到机械结构、电气参数、环境因素等多种复杂因素的综合影响。采集全面且准确的数据是实现精准故障诊断的基石。在数据采集环节，传感器的合理布局是首要关键。在电机的轴承部位，作为机械部件转动的枢纽，安置振动传感器能够敏锐地捕捉到因机械部件松动、磨损等问题引发的异常振动信号，哪怕是极其细微的振动变化，都可能成为早期故障的重要预警^[1]。在定子

绕组处安装温度传感器，可实时监测绕组因电流热效应产生的温度变化，过高的温度往往暗示着绕组短路、断路等电气故障的潜在风险。而电流传感器的部署，则能精准反映电机运行过程中的电流波动情况，为判断电气系统的健康状态提供关键依据。

实际采集到的数据常常面临诸多挑战。工业现场复杂的电磁环境、设备自身的运行噪声等因素，会导致采集的数据中混入大量噪声，严重干扰对真实信号的分析。由于传感器故障、数据传输中断等原因，数据缺失值问题也时有发生。针对这些问题，可采用先进的滤波算法，如卡尔曼滤波，它能够根据数据的历史信息和当前测量值，对噪声进行有效抑制，还原出真实的信号特征。对于缺失的数据，则利用插值法，如线性插值、样条插值等方法，依据相邻数据点的趋势，合理补齐缺失值^[2]。完成噪声去除和缺失值补齐后，为了使不同特征的数据具有可比性，需通过归一化操作，将数据缩放到统一的范围，如 $[0,1]$ 或 $[-1,1]$ ，为后续深度学习模

型的输入提供优质的数据基础。

值得注意的是,电机运行工况复杂多样,不同工况下的电机数据特征往往有着天壤之别。正常运行时,电机数据呈现出平稳且规律的特征;而一旦出现故障,无论是轴承磨损、绕组短路这类常见故障,数据都会产生明显波动与异常。负载的轻重、转速的快慢,同样会对电机数据造成显著影响。为训练出泛化能力卓越的模型,采集数据时,务必兼顾电机的正常运行状态、各类常见故障状态,以及不同负载(轻载、中载、重载)、不同转速(低速、中速、高速)等丰富多样的场景。只有如此,模型才能够充分学习到全面且细致的故障特征模式,在实际生产中,面对错综复杂、瞬息万变的工况,也能够实现精准无误的故障诊断。

2 深度学习模型搭建

构建适配电机故障诊断的深度学习模型是整个诊断流程的核心任务。在众多深度学习模型中,卷积神经网络(CNN)以其卓越的二维数据特征提取能力脱颖而出,尤其适用于处理振动图像、电流频谱等二维形式的数据。CNN中的卷积层配备了一系列精心设计的卷积核,这些卷积核犹如精巧的过滤器,在数据中滑动扫描,能够自动提取出与电机故障相关的关键特征^[3]。在处理振动图像时,卷积核可以捕捉到图像中特定的纹理、形状等特征,这些特征往往与电机的机械故障模式密切相关。紧随卷积层之后的池化层,则通过降采样操作,降低数据维度,减少后续计算量的还能保留数据的关键特征,提升模型的计算效率。

循环神经网络(RNN)及其改进版本长短期记忆网络(LSTM),则在处理电机运行数据的时序性方面表现出色。电机的运行状态是一个随时间连续变化的过程,不同时刻的状态之间存在着紧密的关联。RNN和LSTM能够有效捕捉这种时间序列信息,其中LSTM的记忆单元具备独特的门控机制,可以选择性地长时间保存关键信息,遗忘无关信息,从而能够更好地应对电机故障在渐变过程中的特征变化。为了充分发挥CNN和LSTM的优势,将二者有机结合^[4]。首先利用CNN对电机数据进行空间特征提取,挖掘数据中的局部特征模式。将CNN提取的特征输入到LSTM中,进一步挖掘这些特征随时间变化的规律。通过搭建多层结构,在CNN和LSTM层之间以及模型的末端穿插全连接层,全连接层负责整合前面各层提取的特征,并根据这些特征对电机故障进行准确分类。

在模型初始化阶段,随机设定参数往往难以获得

理想的效果。为了克服这一问题,可采用预训练模型进行迁移学习。利用在大规模相似数据上预训练好的模型,结合电机领域少量的标注数据进行微调。这种方式能够借助预训练模型已经学习到的通用特征,加快模型在电机故障诊断任务上的收敛速度,显著提升模型性能,有效应对电机故障模式复杂多样的难题。

3 模型训练及评估

充足且高质量的标注数据是模型训练成功的关键因素。为此,需要组织具备深厚电机专业知识的人员,依据电机故障机理以及详细的维修记录,对采集到的数据进行精确标注。标注内容不仅要明确故障类别,如机械故障中的轴承磨损、转子不平衡,电气故障中的绕组短路、断路等,还要对故障程度进行量化评估,为模型提供准确的学习目标。

完成数据标注后,将数据集按照一定比例划分为训练集、验证集与测试集。训练集用于模型学习数据中的故障特征,通过不断调整模型权重,优化模型对故障模式的识别能力。验证集则在训练过程中发挥着重要的监控作用,通过观察模型在验证集上的表现,如准确率、损失值等指标,及时发现模型是否出现过拟合现象。测试集则用于在模型训练完成后,全面评估模型的最终性能,确保模型在未见过的数据上也能保持良好的泛化能力^[5]。在模型训练过程中,选择合适的损失函数是衡量模型预测结果与真实标签差异的关键。对于电机故障多分类问题,交叉熵损失函数因其能够有效度量两个概率分布之间的差异,成为常用的选择。优化算法的选择对模型的迭代优化起着决定性作用。随机梯度下降(SGD)及其变种Adagrad、Adadelta等算法,能够根据数据的特性动态调整学习率。在训练初期,较大的学习率可以加快模型的收敛速度;随着训练的推进,逐渐减小学习率,使模型能够更精确地收敛到最优解。

在训练过程中,需要进行多轮次的训练,密切观察验证集上准确率和损失值的变化情况。当发现验证集准确率不再提升,而损失值开始上升时,意味着模型可能出现了过拟合现象,此时应适时提前终止训练,保存当前最优模型。即使模型在训练完成后达到了较高的性能指标,但在复杂的工业现场实际运行时,由于工况的动态变化、新故障模式的出现等因素,模型仍可能出现诊断偏差^[6]。需要持续收集电机在实际运行中的新数据,反馈到模型中进行优化,确保模型始终保持较高的诊断精准性,适应电机长期运行过程中的各种工况变化。

4 诊断系统集成应用

将训练好的深度学习模型成功集成到实际的电机故障诊断系统中,是实现其工业应用价值的关键一步。在系统设计方面,首先要打造一个用户友好的交互界面。操作人员通过这个界面,能够便捷地输入电机实时采集的数据,或者上传历史数据段^[7]。系统在接收到数据后,能够快速调用训练好的模型进行分析,并及时给出详细的故障诊断结果,同时根据故障类型和严重程度,提供针对性的处理建议,为操作人员的决策提供有力支持。

在工业生产线环境中,电机故障可能会对整个生产流程造成严重影响。将诊断系统与 PLC(可编程逻辑控制器)、DCS(集散控制系统)等工业控制系统紧密相连至关重要。一旦诊断系统检测到电机出现故障,能够立即触发报警信号,同时联动控制系统采取一系列应急措施^[8]。对于关键生产环节的电机,可自动控制其停机,避免故障进一步扩大;对于具备备用电机的系统,可迅速切换到备用电机,维持生产的连续性,最大限度降低因电机故障导致的生产损失。

借助云平台技术,电机故障诊断系统能够达成多电机的远程集中诊断。在现代工业场景下,电机往往分布在不同区域,通过高效的数据传输链路,这些电机的数据能实时上传至云平台。在大型制造业园区中,位于生产车间 A、仓库 B 以及物流转运区 C 的电机,其运行时产生的电流、电压、温度、振动等关键数据,能以毫秒级的速度汇聚到云平台。专家凭借便捷的网络接入,无论身处办公室、出差途中还是家中,都可远程登录云平台,详细查看电机的实时运行数据,利用专业知识和工具深入分析故障情况。每一个案例都是对系统的一次严苛考验,案例来源涵盖不同品牌、型号的电机,以及多样的运行环境,如高温车间、潮湿地下室等。在验证过程中,不断优化系统的响应速度,采用先进的算法和硬件加速技术,确保能够在最短时间内检测到电机故障。利用边缘计算技术在电机端初步处理数据,减少数据传输量,使云平台能更快聚焦关键故障信息;通过优化数据处理流程,将故障检测时间从原本的数秒缩短至毫秒级。

5 结语

深度学习为电机故障诊断带来变革,经数据采集分析、模型搭建、训练评估及系统集成应用等流程,已能在多场景有效诊断电机故障。展望未来,随着硬件算力提升、算法持续创新,深度学习模型将更精准高效。一方面,新模型架构融合多领域知识,能处理极端工况、微弱故障信号;另一方面,与物联网、边缘计算结合,实现电机实时在线诊断,故障预警更及时,保障设备长周期稳定运行,助力工业智能化大步迈进。

参考文献

- [1] 魏勇召,马龙.基于定子电流信号分析的机车牵引电机轴承故障诊断方法[J].电力机车与城轨车辆,2025, 48(02): 116-119.
- [2] 高彩霞,冯凌云,党建军.基于双级 PNN 的直驱永磁同步电机匝间短路故障诊断方法[J].河南理工大学学报(自然科学版),2025,44(02):116-127.
- [3] 刘金浦,张培航.全自动纺织络筒机槽筒电机驱动故障诊断方法[J].毛纺科技,2025,53(03):118-123.
- [4] 潘景宜,张旭,晏佳胜,等.基于 GA-SVM 的 DR-PMSM 匝间短路故障诊断方法研究[J].微电机,2025,58(02):14-20+32.
- [5] 马杰,都业林,金涛,等.动车组牵引电机匝间短路故障诊断方法研究[J].铁道机车车辆,2025,45(01):144-151.
- [6] 汪东玉.基于二次分解的水泵电机轴承异常振动故障诊断方法[J].水利技术监督,2025,(02):282-286.
- [7] 闫国华,胡以怀.以信号图像表示的基于 CNN 的永磁同步电机故障诊断方法[J].船舶工程,2025,47(01):114-123.
- [8] 陈立秋,马越.基于振动信号分析的电机故障诊断方法研究[J].防爆电机,2025,60(01):79-81+92.

版权声明: ©2025 作者与开放获取期刊研究中心(OAJRC)所有。本文章按照知识共享署名许可条款发表。

<https://creativecommons.org/licenses/by/4.0/>

