

基于深度学习的电力拖动系统故障预测与健康管理 (PHM)

张光乐 李丽杰

杭州国电机械设计研究院有限公司 浙江 杭州 310012

摘要: 本文聚焦基于深度学习的电力拖动系统故障预测与健康管理 (PHM)。阐述深度学习理论基础, 分析电力拖动系统组成、故障机理与传播规律。构建基于深度学习的故障预测模型, 选择合适算法并设计架构、训练优化模型。研究健康评估方法, 构建指标体系、实现健康状态表示并构建评估模型。通过案例实验, 验证故障预测与健康管理方法的有效性, 结果表明其能准确预测故障、评估健康状态, 提升系统可靠性与运行效率。

关键词: 深度学习; 电力拖动系统; 故障预测; 健康管理 (PHM)

1 深度学习理论基础

深度学习作为机器学习的重要分支, 其理论根基植根于人工神经网络。它通过构建多层次的非线性神经网络结构, 模拟人脑的信息处理机制, 实现对复杂数据的高效学习与特征提取。从网络架构看, 深度学习模型由输入层、隐藏层与输出层组成。隐藏层可堆叠至数十甚至上百层, 这种深度结构赋予模型强大的表征学习能力, 能自动从原始数据中挖掘深层次、抽象化的特征模式, 摆脱传统方法依赖人工特征设计的局限。其核心学习机制基于反向传播算法与梯度下降优化方法, 反向传播通过链式法则, 将输出误差逆向传播至各层神经元, 计算参数梯度; 梯度下降则依据梯度方向调整网络权重, 逐步降低损失函数值, 使模型输出逼近真实数据分布^[1]。另外, 激活函数为神经网络引入非线性因素, 使其能拟合任意复杂函数。正则化技术 (如Dropout、L2正则化) 有效防止过拟合, 提升模型泛化能力。深度学习凭借这些理论支撑, 在图像识别、自然语言处理、语音合成等领域取得突破性进展, 推动人工智能技术迈向新高度。

2 电力拖动系统基础与故障机理分析

2.1 电力拖动系统组成与工作原理

电力拖动系统是将电能转换为机械能, 实现生产机械运动控制的系统, 在工业生产、交通运输等领域广泛应用。其主要由电动机、传动机构、工作机构、控制装置和电源五大部分组成。电动机作为系统的核心动力源, 常见类型有直流电动机、交流异步电动机、交流同步电动机等, 不同类型电动机依据电磁感应原理, 将电能转化为机械能。传动机构用于传递电动机的动力和运动, 包括皮带传动、齿轮传动、联轴器传动等, 可实现速度和扭矩的变换。工作机构是执行生产任务的部件,

如机床的主轴、起重机的吊钩等。控制装置负责对电动机的启动、调速、制动等运行状态进行控制, 包含各类控制电器和控制算法。电源为系统提供电能, 可分为直流电源和交流电源。系统的工作原理是控制装置根据生产工艺要求, 调节电动机的运行参数, 通过传动机构将电动机的旋转运动或直线运动传递给工作机构, 实现预定的生产动作。

2.2 常见故障类型

电力拖动系统在长期运行过程中, 受多种因素影响会出现各类故障。从故障发生的部位来看, 主要包括电动机故障、传动机构故障、控制装置故障和电源故障。电动机故障常见的有绕组故障 (如绕组短路、断路、接地)、轴承故障 (磨损、润滑不良、滚珠损坏)、转子故障 (断条、偏心) 等。传动机构故障表现为皮带打滑、齿轮磨损、联轴器松动等。控制装置故障涉及接触器触点烧蚀、继电器失灵、控制器参数设置错误等。电源故障则包括电压波动、缺相、谐波干扰等。从故障的性质分类, 可分为机械故障、电气故障和控制故障。机械故障多由部件磨损、安装不当等引起; 电气故障与电路、绝缘、电磁等因素相关; 控制故障主要是控制逻辑错误、信号传输异常导致。

2.3 故障机理与传播规律

电力拖动系统的故障并非瞬间形成, 而是有其特定的故障机理和传播规律。以电动机绕组短路故障为例, 通常是由于绝缘材料老化、受潮或机械损伤, 导致绕组之间的绝缘性能下降, 进而引发短路。短路故障发生后, 会使电动机电流增大, 产生大量热量, 加速绝缘材料的老化, 同时可能引起电动机振动加剧、转速下降, 进一步导致传动机构和工作机构负载不均, 引发其他部

件的损坏。轴承故障初期表现为润滑不良、轻微磨损,随着运行时间增加,磨损加剧,产生振动和噪声,振动通过轴传递到电动机和传动机构,影响系统的稳定运行,最终可能导致轴承卡死,电动机停转。控制装置的故障可能是由于元件老化、电磁干扰等原因,导致控制信号异常,使电动机无法正常启动、调速或制动,进而影响整个系统的工作性能。电源故障会导致电动机电压不稳定,引起电流波动,增加电动机的损耗,长期运行会加速电动机和其他部件的损坏。

3 基于深度学习的故障预测模型构建

3.1 深度学习算法选择

在构建电力拖动系统故障预测模型时,深度学习算法的选择至关重要。考虑到电力拖动系统运行数据具有时序性和非线性特点,循环神经网络(RNN)及其变体LSTM、GRU成为合适的候选算法。RNN能够处理序列数据,通过隐藏层的循环连接,保留序列中的历史信息,适合对具有时间依赖关系的数据进行建模。传统RNN存在梯度消失和梯度爆炸问题,难以学习长序列数据。LSTM通过引入记忆单元和门控机制,有效解决了RNN的长期依赖问题,能够更好地捕捉长时序数据中的特征。GRU作为LSTM的轻量级变体,结构相对简单,计算效率更高,在处理电力拖动系统数据时也能取得较好的效果^[2]。另外,卷积神经网络(CNN)具有强大的特征提取能力,可通过卷积层和池化层自动提取数据的局部特征,在结合时序数据的处理方法后,也可应用于电力拖动系统的故障预测,尤其是对于具有空间特征的数据处理有独特优势。因此根据具体的数据特点和故障预测需求,合理选择深度学习算法是构建有效模型的基础。

3.2 故障预测模型架构设计

基于选定的深度学习算法,设计故障预测模型架构。以LSTM为例,模型通常包含输入层、多个LSTM隐藏层、全连接层和输出层。输入层接收经过预处理的电力拖动系统运行数据,如电动机的电流、电压、转速、温度等监测数据,将其转换为适合模型处理的格式。隐藏层由多个LSTM单元组成,通过堆叠多层LSTM层,能够更深入地提取数据中的时序特征和复杂模式。全连接层将LSTM隐藏层输出的特征向量进行整合,映射到输出层。输出层根据故障预测的任务需求,若为故障分类任务,则输出各类故障的概率;若为故障剩余寿命预测任务,则输出剩余寿命的估计值。在架构设计过程中,还需考虑模型的参数设置,如LSTM单元数量、隐藏层层数、学习率等,通过实验和调参优化模型结构,以提高模型的预测精度和泛化能力。

3.3 模型训练与优化

模型训练是将准备好的训练数据输入到设计好的模型中,通过优化算法调整模型参数,使模型能够准确地预测故障。在训练过程中,首先需要确定损失函数,对于故障分类任务,通常采用交叉熵损失函数;对于故障剩余寿命预测任务,常用均方误差损失函数。优化算法选择Adam算法,该算法结合了Adagrad和RMSProp算法的优点,能够自适应地调整学习率,在保证训练速度的同时,避免陷入局部最优解。训练过程中,将数据集划分为训练集、验证集和测试集,通过训练集训练模型,验证集用于调整模型参数和防止过拟合,测试集则用于评估模型的泛化性能。在训练过程中,监控损失函数和评估指标的变化,若出现过拟合现象,可采用正则化方法(如L1、L2正则化)或增加数据增强等方式进行优化。

4 基于深度学习的健康评估方法研究

4.1 健康评估指标体系构建

构建科学合理的电力拖动系统健康评估指标体系是实现准确健康评估的基础。在电气性能方面,选取电动机的电压偏差率、电流谐波含量、绕组绝缘电阻等指标,反映电源质量和电动机电气系统的健康状况。机械性能指标包括轴承振动幅值、传动机构的磨损程度、工作机构的运行平稳性等,用于评估系统机械部件的运行状态。控制性能指标涵盖控制信号的准确性、控制响应时间、调速精度等,体现控制装置的工作性能。还可考虑环境因素指标,如工作环境温度、湿度对系统运行的影响。通过综合分析这些指标,建立层次分明、相互关联的健康评估指标体系,全面反映电力拖动系统的健康状况^[3]。

4.2 基于深度学习的健康状态表示

基于深度学习强大的特征提取能力,对健康评估指标数据进行处理,实现电力拖动系统健康状态的有效表示。首先将构建的健康评估指标数据进行归一化等预处理,然后输入到深度学习模型中。采用自编码器(Autoencoder)或变分自编码器(VAE)等无监督学习模型,对高维的健康评估指标数据进行降维和特征提取,将原始数据映射到低维的健康状态特征空间。在这个特征空间中,不同的特征向量代表系统不同的健康状态,能够更直观地反映系统健康状况的变化。自编码器通过编码和解码过程,学习数据的压缩表示,保留数据的关键特征;VAE在自编码器的基础上引入概率分布,使学习到的特征具有更好的泛化性和可解释性。

4.3 健康评估模型构建与评估

基于提取的健康状态特征,构建健康评估模型。可

采用支持向量机 (SVM)、随机森林 (RandomForest) 等传统机器学习算法, 也可利用深度学习模型如多层感知机 (MLP) 进行健康状态分类或回归预测。若采用 MLP 构建健康评估模型, 模型结构包含输入层、多个隐藏层和输出层。输入层接收经过深度学习处理后的健康状态特征向量, 隐藏层通过非线性变换学习特征之间的复杂关系, 输出层根据评估任务输出系统的健康状态等级或健康评分。在模型构建完成后, 使用训练集对模型进行训练, 通过验证集调整模型参数, 最后利用测试集对模型的评估性能进行客观评价。常用的评估指标包括准确率、召回率、F1值、均方误差等, 通过这些指标评估模型的准确性、可靠性和泛化能力, 确保健康评估模型能够准确反映电力拖动系统的实际健康状态, 为系统的健康管理提供决策依据。

5 案例研究与实验分析

5.1 实验平台搭建与数据采集

为验证基于深度学习的故障预测和健康评估方法的有效性, 搭建电力拖动系统实验平台。实验平台主要由电动机、传动机构、工作机构、控制装置和数据采集系统组成。电动机选用三相交流异步电动机, 传动机构采用齿轮传动, 工作机构模拟实际生产中的负载设备。控制装置包括变频器、接触器、继电器等, 实现对电动机的启动、调速和制动控制。数据采集系统采用传感器 (如电流传感器、电压传感器、振动传感器、温度传感器等) 实时采集电动机和系统关键部位的运行数据, 采样频率根据实验需求设定。在实验过程中, 设置不同的运行工况和故障模拟场景, 如正常运行、电动机绕组短路、轴承故障、传动机构磨损等, 采集对应工况下的运行数据。为保证数据的可靠性和完整性, 对采集到的数据进行去噪、滤波等预处理, 并按照一定的规则划分训练集、验证集和测试集, 为后续的实验分析提供数据支持。

5.2 故障预测实验与结果分析

利用搭建的实验平台采集的数据, 基于选定的深度学习算法构建故障预测模型并进行实验。以 LSTM 故障预测模型为例, 将训练集输入模型进行训练, 调整模型参数, 使损失函数达到最小。在测试集上对训练好的模型进行测试, 通过对比模型预测结果与实际故障情况,

评估模型的预测性能。实验结果表明, 基于 LSTM 的故障预测模型在不同故障类型的预测中均能取得较高的准确率, 能够提前识别出电力拖动系统的潜在故障, 为故障预警和维修决策提供了有力支持。

5.3 健康管理实验与效果验证

基于构建的健康评估指标体系和健康评估模型, 开展电力拖动系统的健康管理实验。将采集到的系统运行数据输入健康评估模型, 得到系统的健康状态评估结果^[4]。根据评估结果制定相应的健康管理策略, 如对于健康状态良好的系统, 制定定期维护计划; 对于接近故障状态的系统, 及时进行维修或更换部件。通过对实验平台系统的长期监测和健康管理, 验证健康评估方法和管理策略的有效性。实验结果显示, 基于深度学习的健康评估方法能够准确反映电力拖动系统的健康状态, 通过合理的健康管理策略, 有效降低系统的故障率, 提高系统的可靠性和运行效率, 证明该研究在实际工程应用中的可行性和价值。

结束语

本文将深度学习技术应用于电力拖动系统的故障预测与健康管理, 从理论到实践展开全面研究。通过构建故障预测模型与健康评估体系, 并经实验验证其有效性, 为电力拖动系统的稳定运行提供有力保障。未来, 可进一步优化模型算法、拓展数据来源, 并探索与物联网、大数据等技术的融合, 推动电力拖动系统 PHM 技术向智能化、高效化方向发展, 提升工业生产的安全性与经济效益。

参考文献

- [1] 汪可友, 徐晋, 李国杰. 电力系统参数空间暂态稳定边界构建及在线快速更新方法[J]. 电力系统自动化, 2021, 45(9): 1-15.
- [2] 李刚, 张华, 王建民. 基于机器学习的工业设备故障诊断与预测综述[J]. 自动化学报, 2020, 46(1): 43-59.
- [3] 吕坐君. 基于事故链模型的电力系统故障风险评估分析[J]. 自动化技术与应用, 2024, 43(4): 18-21, 176. DOI: 10.20033/j.1003-7241.(2024)04-0018-05.
- [4] 范召典, 孟庆超, 张军, 等. 基于故障录波图的电力系统故障特征分析[J]. 光源与照明, 2023(1): 234-236.