

基于状态监测的桥式起重机关键部件 剩余寿命预测与维护策略

贾禄瑞, 武楠*, 杨红霞

(山东泰沃重工有限公司, 山东 泰安 271000)

摘要 本文以桥式起重机关键部件剩余寿命的预测和维护优化为研究对象, 提出融合物理模型和数据驱动两种方法进行预测。首先, 对关键部件的失效机理进行分析, 并设计多源异构状态监测系统; 其次, 在多源数据融合的基础上构造部件健康指标, 并对退化状态进行评价; 再次, 构建疲劳损伤累积物理模型和深度学习数据驱动模型组合的剩余寿命预测框架; 最后, 根据预测结果对动态维护策略进行优化, 并设置维护阈值和时间窗, 使状态监测向维护决策闭环管理转变, 以期为起重机的安全运行及维护成本控制等提供理论参考。

关键词 状态监测; 桥式起重机关键部件; 剩余寿命预测

中图分类号: TH21

文献标志码: A

DOI: 10.3969/j.issn.2097-3365.2026.06.042

0 引言

桥式起重机是现代工业体系中不可或缺的重型特种设备, 其作业安全性直接关联生产效率及作业人员安全。传统的定期维护有或多或少的缺点, 很难适应零件个体退化的不同。在状态监测技术不断发展的背景下, 以数据为基础的预测性维护已经成为人们关注的焦点^[1]。本文通过对多源监测数据的整合来构建部件的健康指标, 同时将物理模型和数据驱动方法整合在一起, 旨在达到对剩余寿命的准确预测, 继而对维护策略进行优化, 为起重机智能化和经济化运行维护提供新的思路。

1 桥式起重机关键部件失效机理与状态监测系统 设计

1.1 关键部件界定与失效机理分析

桥式起重机的结构较为复杂, 但其起升机构、运行机构、金属结构的某些零件由于受到交变载荷的作用, 动作频繁且容易磨损, 因此, 成为影响整机工作可靠性的薄弱环节。将关键部件界定为: 起升机构的钢丝绳、卷筒、减速器(特别是齿轮和轴承)以及制动器、大车、小车运行机构车轮、轨道、驱动减速器关键齿轮和轴承^[2]。这类零件失效的物理机制不同, 大致可以分为三大类: 疲劳失效、磨损失效、变形失效。以钢丝绳与齿轮为例, 起升循环过程中钢丝绳受到拉伸、弯曲、挤压等复合应力的作用, 破坏主要是通过内部钢丝之间的微动磨损来实现、外部腐蚀和过载造成疲劳

断丝以及断丝累积造成有效承载面积下降并最终断裂等。齿轮的失效则主要源于齿面接触疲劳(点蚀、剥落)和齿根弯曲疲劳(断裂), 其退化过程与载荷谱、润滑状态、材料缺陷密切相关。轴承失效的主要原因是滚动接触疲劳, 这通常表现为滚道或滚动体的脱落^[3]。

1.2 多源异构状态监测系统架构

为对以上关键部件的劣化过程进行综合感知, 需要设计多层次、多参数、多源异构状态监控系统。该系统架构应该由感知层、传输层、数据层、应用层组成。感知层作为系统前端负责布放各种传感器, 收集多维度物理信号来反映零件状态^[4]。根据不同零件及失效模式进行传感器选型要有针对性: 对齿轮及轴承、加装振动加速度传感器捕捉, 由于点蚀、剥落及其他缺陷诱发的冲击信号; 对钢丝绳可以使用基于漏磁或者视觉在线检测装置对断丝的数量和分布进行监控; 对制动器来说, 对制动衬片厚度(磨损量)、制动过程温度等进行监控; 对减速器而言, 集成油液在线监测传感器对油品黏度、水分、磨粒的组成和大小进行分析; 除此之外, 还需要收集载荷(通过称重传感器)、运行速度、起制动次数等工况参数。传输层负责将感知层采集的海量、异构数据(其中包括振动波形、图像、温度值、粒子计数)通过工业以太网或无线网络(5G、Wi-Fi 6等)可靠地传输至数据中心。数据层作为系统核心, 承担着接收原始监测数据的存储、管理、预处

作者简介: 贾禄瑞(1988-), 男, 专科, 研究方向: 计算机多媒体技术。

*通信作者: 武楠(1992-), 男, 本科, 助理工程师, 研究方向: 工业设计。E-mail: hyyjkbjb@163.com

理等任务,建设一个时标数据库或者数据湖作为上层分析的优质数据底座。应用层是将研究的核心算法模型,如健康指标构建、RUL 预测、维护决策优化整合在一起,提供可视化人机界面,将零件的健康状态、预测寿命、维护建议等信息呈现给运维人员^[5]。

2 基于多源数据融合的健康指标构建与退化状态评估

2.1 多维度监测信号预处理

由监测系统得到的原始信号中往往含有很多噪声、干扰、冗余信息等,将其直接应用于分析将严重影响后续模型性能。所以,系统性预处理是很有必要的。预处理流程包括数据清洗、对齐、降噪、标准化等。数据清洗旨在处理因传感器故障、通信中断等原因产生的缺失值、异常值(超出量程的尖峰等)和无效数据段,可采用插值、滤波或直接剔除等方法。在数据对齐方面,由于多源传感器的采样频率和数据包的发送时间可能会有所不同,因此需要依赖统一的时间戳进行数据同步,以确保在同一时间点上,振动、温度、载荷等各种数据能够进行有效的关联性分析。在处理振动、声音等信号时,降噪是至关重要的一步,常用的技术包括小波阈值去噪、经验模态分解(EMD)及其变种、自适应滤波等,目标是在保持反映部件缺陷的冲击特性的同时,减少背景噪声和机械其他部分的干扰^[6]。

2.2 高维特征筛选与融合方法

经过预处理的信号需从其中提取能灵敏地反映部件退化状态并形成高维特征集的特征。对于振动信号,可从时域(均方根值 RMS、峰值、峭度、波形因子等)、频域(频谱重心、边频带的能量等)及时频域(小波包的能量熵、希尔伯特-黄变换的边际谱特征等)提取数百个特征。对油液数据可以在不同大小范围内提取磨粒浓度和铁谱指数。但是,在高维的特征集中有很多不相关或者冗余的特征,这些特征的直接利用造成“维度灾难”以及模型的过拟合等。所以,特征筛选和降维是很有必要的^[7]。特征筛选方法如基于相关性分析(和运行时间或者已知退化标签相关)、过滤法(方差选择、互信息)或封装法(根据具体分类器的性能来选择特征),旨在保留最具判别力的特征子集。特征融合的核心思想是将筛选出的来自各种传感器和模态的特征进行高效地融合,从而生成一个全面反映部件健康状况的低维向量。

2.3 部件级健康指标(HI)构建与性能评估

健康指标(HI)定义为一个单变量标量,它可以

从 0(全新/健康)逐渐退化到 1(完全失效)或呈现相反的趋势。该指标的构建目的是将复杂的多源融合特征空间转化为一个能够直观展示部件整体退化程度的量化指标。HI 的构建方法主要分为两大类:一是基于模型的,二是基于数据驱动的。本文提出一种基于马氏距离(Mahalanobis Distance, MD)的数据驱动方法。具体而言,在部件运行初期(视为健康基准状态),收集其多维融合特征数据,计算该状态下的特征均值向量和协方差矩阵。针对接下来的任何时间点的特征向量融合,计算它与健康基准状态之间的马氏距离。由于马氏距离充分考虑各特征之间的相关关系,所以,这个距离值可以有效地度量当前状态与健康状态之间的偏差大小,并且距离越大说明退化得越厉害。为使其取值范围固定在 $[0, 1]$,可对马氏距离序列进行最大最小归一化处理,并可能结合平滑滤波(指数加权的移动平均)以抑制波动。

3 融合物理模型与数据驱动的剩余寿命预测模型

3.1 预测模型总体框架设计

剩余寿命预测在状态监测和维护决策之间起到桥梁作用。单一的预测方法往往存在局限:纯物理模型(以断裂力学、疲劳累积损伤理论为基础)需要精确的载荷谱、材料参数、初始缺陷尺寸,而且实际工程中很难精确地得到这些参数,模型的简化还会引入误差;纯数据驱动模型(机器学习、深度学习等)虽然善于从历史数据中学习退化模式,但其预测的物理可解释性较弱,且在缺乏足够失效数据(尤其是接近失效的晚期数据)时,外推预测的可靠性下降。为此,提出一种“以物理模型为基准对数据驱动模型进行修改和强化”的融合预测框架。在此框架中,采用以物理为基础的模型将设计参数与典型载荷谱相结合,以平均工况为基准给出了理论寿命或者退化轨迹;利用实时监测数据驱动的 HI 序列,通过深度学习模型(有长短期记忆网络 LSTM、时序卷积网络 TCN 或 Transformer 等)学习实际退化轨迹与理论基准之间的偏差模式。

3.2 基于疲劳损伤累积的物理模型基准

对桥式起重机的齿轮、轴承及钢丝绳等关键部件而言,疲劳为主要失效模式。为此,基于疲劳损伤累积理论建立物理基准模型。以齿轮为例,Miner 线性累积损伤法则可以应用于其中。第一,通过对起重机的历史运行数据进行统计分析或基于起重任务规划的仿真,得到作用于目标部件的典型载荷谱(应力谱)。第二,根据材料的 S-N 曲线(应力-寿命曲线)或断裂力学 Paris 公式(针对裂纹扩展),计算在不同应力水平下单个循环所造成的损伤。第三,按照 Miner 法则对不同应力水平下的损伤进行了线性叠加,当累积损伤值

达到1时,从理论上讲,部件将会出现疲劳失效。通过此模型,可以计算出在基准载荷谱下部件的理论总寿命(循环次数或者运行时间等),推演出其理论损伤指数(或理论HI)随时间增长的曲线。

3.3 基于深度学习的数据驱动 RUL 预测模型

数据驱动模型的核心任务是学习从部件监测历史(特别是HI序列)到其RUL的映射关系。鉴于部件退化的过程具有显著的时序依赖性和非线性特点、深度学习中的循环神经网络(RNN)以及其相关的变体LSTM、GRU,再加上近些年兴起的TCN、Transformer架构,都非常适合执行这一任务。文中以所构造的组件HI时间序列为主要输入,对模型进行研究。模型结构一般由输入层、多个隐藏层、输出层组成。以LSTM模型为例,输入层接收按时间步排列的HI序列片段(最近N时刻HI)。LSTM单元通过其门控机制(输入门、遗忘门、输出门等)能够有效捕获时间序列中的长期依赖关系,记忆重要的退化趋势信息,并遗忘无关的细节波动。若干LSTM层堆叠能够抽取更深的时序特征。最终,通过全连接层将最后一个时间步的输出映射为预测的RUL值(余数或起升循环的余数等)。在模型训练阶段,需要准备足够多的部件从开始运行到失效的完整HI序列作为训练样本(它可以由历史数据得到,也可以由加速寿命试验得到)。将样本分为观测窗口(输入)和相应的真实RUL标签(输出),并采用均方误差(MSE)作为损失函数,通过反向传播算法来优化模型的参数。

4 基于 RUL 预测的动态智能维护策略优化

4.1 维护决策问题建模

在得到精确的RUL预测结果之后,如何转化成最优维护决策,这是预测性维护闭环形成过程中最后一个环节。维护决策优化的目标是,在满足安全运行约束(故障风险低于可接受的水平)的前提下,最小化长期运行下的总期望维护成本,或最大化设备的长期可用度。这个问题是一个标准的随机动态优化挑战。本文把它建模成决策模型,把预测RUL作为决策模型的输入。决策变量通常包括:是否执行预防性维护(PM)、何时执行(维护时间点)、执行何种类型的维护(小修、更换等)。维护成本通常包括:预防性维护成本(计划更换零件或修理费用、计划停机损失等)、故障维修成本(较高紧急修理费用、非计划停机所带来的产量损失、潜在安全事故损失)、日常监测系统的运行成本。约束条件则包括:维护资源的可用性(备件库存、维修人员等)、维护活动的时间窗口(利用生产间隙等),以及故障风险阈值。

4.2 动态维护阈值与时间窗确定

在传统的CBM策略中,人们通常会设定一个固定的健康指标阈值,一旦HI超过这个阈值,系统就会启动相应的维护程序。这个方法没有充分地考虑到RUL预测的不稳定性和执行过程中的灵活性。本文提出基于预测RUL确定动态维护阈值和时间窗。其核心思想为:维护决策将不再仅仅以当前HI超限与否为依据,而将以未来退化路径及故障发生时间为概率进行预测。具体而言,利用预测模型输出的RUL分布(均值与方差等),可以计算出在未来任意时间点设备发生故障的概率,即故障风险函数。维护策略可被设置成动态风险阈值。例如:当预测的故障风险在未来一周内超过某个预设的临界值(5%)时,则建议在本周内安排维护。这样就界定“维护时间窗”而不是准确的“维护时间点”,给运维调度带来灵活性。

5 结束语

本文对桥式起重机关键零部件在状态监测基础上的剩余寿命预测及维护策略进行研究。采用多源数据融合的方法构造健康指标,并将物理模型和深度学习模型相结合增强寿命预测的准确性。以此为基础提出一种动态维护策略优化方法以实现维护阈值和时间窗等参数的智能设定。研究成果为起重机预测性维护工作提供可行性方案,有利于减少突发故障的风险和运维成本。未来的研究可以将多部件耦合失效和维护资源约束等因素进一步纳入考虑范围,促进运维决策朝着更加综合的智能化方向发展。

参考文献:

- [1] 韦鸿鼎. 桥式起重机常见起升机构故障诊断与维修方法研究[C]//《中国招标》期刊有限公司. 新质生产力驱动第二产业发展与招标采购创新论坛:绿色智造·采购革新专题(第二册). 广西来宾广投银海铝业有限责任公司,2025.
- [2] 胡松明. 多工况下桥式起重机防摆控制方法研究[D]. 沈阳:沈阳建筑大学,2025.
- [3] 王磊,郭鹏伟,廖志明,等. 桥式起重机智能安全监测系统研究与应用[J]. 起重运输机械,2024(20):89-93.
- [4] 王义军,陈旭,张志斌,等. 基于数字孪生的桥式起重机智能健康管理系统设计[J]. 机械设计,2024,41(S2):61-65.
- [5] 范侠. 吊钩可视化监控系统在冶金桥式起重机中的应用[J]. 冶金与材料,2024,44(03):52-54.
- [6] 邓磊. 桥式起重机的智能化与数字化技术[J]. 冶金管理,2023(23):24-25.
- [7] 吴宇震,殷东升,王琇峰,等. 一种门座式起重机转盘轴承健康状态监测指标设计[J]. 港口科技,2023(02):29-33.