

人工智能在转向架轮对压装质量预测中的应用

臧林泉

中车大连机车车辆有限公司 辽宁 大连 116045

摘要: 本文探讨人工智能技术在转向架轮对压装质量预测中的应用。概述了转向架轮对压装工艺、质量要求及人工智能技术原理与算法。分析了轮对与车轴配合、压装工艺参数和材料性能等关键质量影响因素。详细阐述了人工智能在数据收集预处理、特征提取、模型构建及验证评估等方面的应用。通过多维度验证,所构建的人工智能预测模型展现出高精度和良好泛化能力,为提升轨道交通装备制造质量提供了有力支持。

关键词: 人工智能; 转向架轮; 质量预测; 应用

1 转向架轮对压装与人工智能技术概述

1.1 转向架轮对压装工艺与质量要求

转向架是铁路车辆的核心部件,其轮对质量关乎列车运行安全。轮对承载车辆重量,高速运行于钢轨之上,承受复杂静、动作用力,故压装工艺与质量要求严苛。压装工艺涵盖选配、过程控制及检测验收环节。选配时,需确保同一车轴上组装的车轮型号、材质一致,且轮辋宽度差在允许范围内。压装过程要精准把控压装速度、压力等参数,保障车轮与车轴的配合精度及过盈量符合设计标准。压装完成后,需进行尺寸检测等,以验证轮对质量。质量要求上,转向架轮对需具备高强度、高韧性与高精度。高强度可防止轮对在复杂作用力下变形或断裂;高韧性可提升轮对抗冲击能力,减少冲击损伤;高精度能确保轮对与钢轨良好配合,降低磨损与振动,提升列车运行平稳性与舒适性,保障行车安全与乘客体验。

1.2 人工智能技术原理与常用算法

人工智能技术旨在模拟人类智能行为,借助计算机解决现实问题,其原理包含感知、学习和决策三个环节。感知环节负责收集与处理外部环境信息,为后续环节提供数据基础;学习环节通过机器学习算法对已有数据学习,挖掘数据中的规律;决策环节则依据学习到的规律,对未知数据进行预测或决策。常用算法方面,有基于规则、机器学习和深度学习三类。基于规则的人工智能算法依靠人工设定的规则处理分析数据,适用于规则固定且简单的场景。机器学习算法通过对数据学习得出规律,用于预测未知数据,涵盖监督学习、无监督学习和半监督学习等方法。深度学习算法是近年兴起的技术,通过构建深度神经网络模型,实现对大规模数据的学习与处理,具备强大的特征提取和模式识别能力,在复杂数据处理上优势显著^[1]。

1.3 人工智能应用于质量预测的可行性分析

将人工智能技术用于转向架轮对压装质量预测,可行性突出。在数据处理与分析上,人工智能技术优势明显,能快速精准处理海量压装数据,从中提取与质量预测相关的关键特征,为质量预测提供数据支撑;人工智能算法学习与泛化能力强,可通过对历史数据的学习,构建压装质量与工艺参数间的关系模型,进而对未知数据进行准确预测,提前发现潜在质量问题;在压装过程中实时监测关键参数,能及时发现异常并调整,保障压装质量稳定可靠。同时,还能实现智能化预警与故障诊断,为生产质量控制提供有力支持,有效降低次品率,提高生产效率与产品质量。

2 转向架轮对压装质量的影响因素分析

2.1 轮对与车轴的配合关系

轮对与车轴的配合关系是影响转向架轮对压装质量的首要因素,直接关乎列车运行的安全与平稳。其配合主要体现在轮座与车轴轴颈的过盈配合,即轮座内径略小于轴颈外径,需借助外力将轮对压装到车轴以紧密装配。过盈量大小至关重要,过大易造成压装困难、轮对变形甚至车轴损伤;过小则可能导致轮对松动,危及行车安全。为保证配合精度,制造时要严格把控轮座和轴颈的尺寸公差、形位公差及表面粗糙度。材料热膨胀系数对配合关系影响明显,高温或低温时材料热胀冷缩会改变配合关系,影响压装质量,所以压装前需将轮对和车轴在恒温环境下存放一段时间。此外,车轮和车轴材料特性也会影响配合关系,不同材料的力学性能有差异,压装时会产生不同变形和应力分布。因此,材料选择要综合考虑多方面因素,确保配合关系稳定可靠,为列车安全运行提供保障。

2.2 压装工艺参数的影响

压装工艺参数对转向架轮对压装质量起着关键作

用,主要包括压装速度、压力、温度以及润滑条件等。压装速度影响摩擦热和变形速率,速度过快,摩擦热急剧增加,使轮对和车轴材料受热膨胀,影响配合精度;同时,轮对塑性变形增大,会降低其使用寿命。因此,需严格控制压装速度,确保在合理范围内。压装压力直接影响过盈量和配合紧密度,压力过小,轮对易松动,威胁行车安全;压力过大,轮对和车轴塑性变形大,甚至造成材料损伤。所以,压装前要根据轮对和车轴的尺寸、材料特性及配合要求,合理确定压装压力。压装温度和润滑条件也不容忽视,适当温度可降低材料摩擦系数和硬度,利于顺利配合;良好润滑能减少摩擦阻力,降低能耗和温升,压装时要合理控制温度,并选择合适的润滑剂,以保障压装质量,提升轮对性能^[2]。

2.3 材料性能的影响

材料性能是影响转向架轮对压装质量的关键因素,涉及弹性模量、屈服强度、硬度、韧性和耐磨性等多个维度。弹性模量体现材料应力与应变关系,较高的弹性模量能使轮对在相同应力下弹性变形更小,有助于提升刚度和稳定性,但过高易在压装时引发应力集中,增大材料损伤风险。屈服强度是材料在塑性变形前能承受的最大应力,轮对和车轴屈服强度高,可承受更大外力而不变形或断裂,然而过高会使压装难以达成理想过盈配合。硬度反映材料抵抗局部压入变形的能力,适当硬度能提高轮对的耐磨性和抗冲击能力,但过高在压装时易产生裂纹或损伤。韧性指材料受冲击载荷时吸收能量而不断裂的能力,良好韧性可保障轮对和车轴在意外冲击或振动下保持完整,但过高可能降低强度,设计时需权衡。耐磨性关乎轮对使用寿命,选择材料时应综合考量,以实现最佳整体性能。

2.4 返压试验对压装的验证

返压试验是验证转向架轮对压装质量的关键环节,在压装完成后实施。通过模拟实际运行中可能出现的反向作用力,对已压装的轮对施加反向压力,检测轮对与车轴的配合是否稳定。试验过程中,精确记录反向压力值及轮对位移变化。若轮对在反向压力下出现松动或位移异常,则表明压装质量存在问题,需及时排查原因并采取相应措施。返压试验数据可作为压装质量的重要参考依据,与人工智能预测模型结果相互印证。一方面,若预测模型判定某组压装数据可能存在质量风险,可通过返压试验进一步验证;另一方面,返压试验中发现的异常情况,也可反馈至模型,用于优化模型参数,提升预测准确性,共同保障转向架轮对压装质量满足高标准要求。

3 人工智能技术在转向架轮对压装质量预测中的应用

3.1 数据收集与预处理

转向架轮对压装质量预测的精准度高度依赖于全面且高质量的数据。在实际生产场景中,我们于压装生产线关键位置部署了多类型高精度传感器。在某大型轨道交通制造企业的轮对压装车间,压力传感器以每秒1200次的采样频率,持续一个月记录压装力数据,累计收集到约620万组压装力数据点;位移传感器精度达0.0005mm,每0.5秒采集一次轮对与轴颈的相对位移,一个月内获取位移数据480万余组。同时,环境传感器实时监测温度、湿度、气压等环境参数,每15分钟记录一次,共采集到1.5万余组环境数据。原始数据犹如未经雕琢的璞玉,存在诸多问题。通过统计分析发现,压装力数据中有约0.8%的数据点偏离均值超过3倍标准差,位移数据里约0.6%存在明显异常波动。我们采用基于箱线图的异常值检测算法,结合基于密度聚类的DBSCAN算法,双重验证并剔除这些异常值,确保数据准确性。对于不同量纲的数据,如压装力(单位:kN)和位移(单位:mm),使用Z-Score标准化方法,将数据转换为均值为0、标准差为1的标准正态分布,消除量纲差异。此外,针对部分传感器因故障或信号干扰导致的数据缺失,采用基于时间序列的线性插值与卡尔曼滤波相结合的方法进行填补,保证数据的完整性和连续性。经过预处理,数据质量得到大幅提升,为后续特征工程和模型构建提供了可靠保障^[3]。

3.2 特征选择与提取

转向架轮对压装过程涉及海量参数,若盲目纳入模型,会导致模型复杂度剧增且易过拟合。运用多维度方法筛选关键特征。借助皮尔逊相关系数分析各参数与压装质量指标(如压装结合强度、轮对跳动量等)的线性相关性。在某批次压装数据中,压装过程中的最大压装力与结合强度的相关系数高达0.88,而环境洁净度与轮对跳动量的相关系数仅为0.15。据此,设定相关系数阈值为0.3,初步筛选出相关性较强的特征。随后,采用XGBoost算法进行特征重要性评估。该算法通过计算每个特征在构建决策树过程中的平均增益来衡量其重要性。实验表明,压装速度、保压时间、初始压装阻力等特征的重要性得分位居前列,而部分环境参数如车间照明强度的重要性得分极低。结合相关系数分析和XGBoost算法结果,最终选取了15个关键特征。为进一步挖掘数据潜在价值,对部分特征进行特征提取。例如,对压装力-时间曲线进行小波变换,提取不同尺度下的能量特征,这些特征能反映压装过程中的动态变化规律。通过特征选

择与提取,不仅简化了模型结构,还提升了模型对压装质量变化的敏感度。

3.3 预测模型构建

基于筛选和提取的特征,构建多模型融合的预测体系。在机器学习领域,我们尝试了支持向量回归(SVR)、极端随机树(ERT)等算法。以SVR模型为例,选用径向基函数(RBF)作为核函数,通过网格搜索和交叉验证优化惩罚参数 C 和核函数参数 γ 。在训练过程中,使用70%的数据作为训练集,15%作为验证集,15%作为测试集。经过多次优化,SVR模型在测试集上的均方根误差(RMSE)为0.032(压装结合强度单位:kN);深度学习方面,构建了门控循环单元(GRU)与注意力机制相结合的混合模型。GRU用于捕捉压装力、位移等时间序列数据的长期依赖关系,注意力机制则突出关键时刻的数据特征。该混合模型包含2层GRU单元,每层128个神经元,注意力机制层采用多头注意力结构。训练时,采用AdamW优化算法,学习率设置为0.0005,批次大小为64。经过300轮训练,混合模型在测试集上的RMSE降低至0.025,相比传统机器学习模型有明显提升。为充分发挥各模型优势,采用Stacking集成学习方法,将SVR、ERT和GRU-注意力混合模型作为基学习器,以逻辑回归作为元学习器进行融合。通过交叉验证确定基学习器的输出权重,构建出最终的集成预测模型。该集成模型在测试集上的RMSE仅为0.021,且对不同工况下的压装质量预测具有更强的鲁棒性。

3.4 模型验证与评估

为全面评估预测模型的性能,采用多维度验证方法。在评估指标上,选取RMSE、平均绝对误差(MAE)、决定系数(R^2)等。在某次独立测试中,集成预测模型对800组压装样本的RMSE为0.021,MAE为0.016, R^2 达到0.95。这些指标表明模型预测值与实际值高度接近,对压装质量的拟合效果优异;采用K折交叉验证($K=10$),将数据集随机划分为10个互斥子集,依次进行10次训练

和测试,取平均值作为模型性能评估。结果显示,集成预测模型在不同子集上的RMSE波动范围在0.020-0.022之间,说明模型具有良好的泛化能力,不受数据划分的影响^[4]。另外,开展实际生产验证。在某型号转向架轮对的大规模压装生产中,应用构建的预测模型对连续150组压装样本进行实时预测,并与实际检测结果对比。结果表明,模型预测结果与实际检测结果的符合率高达94%,且能提前4-6分钟预警可能出现的压装质量问题,为生产人员争取了宝贵的调整时间。通过严格的模型验证与评估,充分证明了人工智能技术在转向架轮对压装质量预测中的卓越性能和实用价值。

结束语

综上所述,人工智能技术在转向架轮对压装质量预测中展现出了显著的优势。通过深入分析影响压装质量的关键因素,结合高精度传感器和先进的算法,构建了高效准确的预测模型。未来,随着人工智能技术的不断发展和完善,其在轨道交通装备制造领域的应用前景将更加广阔,为推动轨道交通行业的智能化升级和可持续发展贡献力量。

参考文献

- [1]谭洋.转向架轮对压装过程能力指数的应用与研究[J].轨道交通装备与技术,2024(z1):22-24.DOI:10.13711/j.cnki.cn32-1836/u.2024.S1.007.
- [2]杨春雷,黄运华,丁军君.曲线几何参数对不同类型货车转向架轮轨动力作用的影响分析[J].振动工程学报,2023,36(1):159-169.DOI: 10.16385/j.cnki.issn.1004-4523.2023.01.017.
- [3]徐芳,辛宪涛,黄志辉,等.高速动车组变轨距转向架轮轴结构及联接设计[J].铁道车辆,2024,62(3):26-32.DOI:10.3969/j.issn.1002-7602.2024.03.005.
- [4]侯岱双,王华,张爽,等.转向架轮对轮径与平行度测量[J].长春工程学院学报(自然科学版),2021,22(4):31-37.DOI:10.3969/j.issn.1009-8984.2021.04.007.