

基于大数据分析的建筑机械故障预测方法研究

文 / 施洋洋 亳州市建筑业管理服务中心

摘要: 为提升建筑机械故障预测准确性,文章采用大数据分析技术。通过实时监测与采集建筑机械运行数据,经清洗、处理后进行特征提取并建立模型,构建故障诊断与预警系统。分析了数据采集、预处理、特征选择及模型建立等方法,并给出故障预测评估指标。研究表明,优化策略如提升数据质量、增强模型泛化能力等,能有效提高故障预测效果,为建筑机械故障预测提供了新的思路与方法。

关键词: 大数据分析; 建筑机械; 故障预测; 数据处理; 预测模型

【DOI】10.12254/j.issn.2096-6539.2025.14.041

引言

建筑行业近年来发展迅猛,建筑机械在工程中扮演着关键角色。但因其工作环境复杂,高温、高湿、多尘且振动频繁,机械故障成为阻碍工程推进的一大难题。故障一旦发生,工期被迫延迟,维修费用大幅增加,甚至威胁人员安全。以往依靠人工经验或简单传感器数据分析的故障检测手段,既耗时又难以精准预测。大数据分析技术的兴起,为建筑机械故障预测开辟新径,能对海量运行数据深度剖析,有望精准预知故障,保障建筑工程顺利开展,这也促使该研究的展开。

一、大数据分析在建筑机械故障预测中的应用

(一) 实时数据监测与采集

施工机械在工作过程中,各部分相互协作,产生了海量的信息。为了实现对故障的预报,需要建立实时的数据采集和监控系统。该系统采用振动、温度、压力等多种传感器对设备的关键部位进行实时采集。这些感应器,就像是“神经末梢”,对最细微的变化,都有极强的感知能力。他可以精确地捕捉到机器的振动幅度,温度的波动,液压系统的压力波动。通过无线传输技术将采集到的数据实时汇集到数据中心^[1]。通过这种方式,技术人员可以随时掌握设备的运行状态,及时发现异常现象,为后续的数据分析提供第一手数据,从而为故障预报打下坚实的基础。

(二) 数据清洗与处理

刚采集到的原始数据,往往夹杂着噪声、错误数据及重复信息。所以,数据清洗与处理至关重要。专业的数据处理软件会先对数据进行筛查,识别并剔除那些明显错误或不合理的数据点。比如,当温度传感器反馈的数据超出机械正常运行温度范围数倍,大概率是传感器故障或传输错误,此类数据便会被清理。接着,对缺失数据进行填补,运用插值法、基于模型的推算等方法,让数据完整连贯。之后,将不同格式、不同来源的数据进行统一格式转换与整合。经过这般清洗与处理,原本混沌的数据变得条理清晰,为后续深入分析与挖掘奠定良好基础,使数据能更好地服务于故障预测。

(三) 特征提取与模型建立

从海量处理后的数据中提取关键特征,是迈向精准故障预测的关键一步。技术人员运用专业算法,深入挖掘数据背后隐藏的规律。例如,分析振动数据的频率特征,从中找出与特定故障相关的频率模式;研究机械部件的磨损速率变化趋势,作为判断部件健康状况的特征指标。提取出一系列有效特征后,便可着手建立预测模型^[2]。常见的模型有神经网络模型、支持向量机模型等。以神经网络模型为例,它模拟人脑神经元结构,将提取的特征数据作为输入,通过多层神经元的复杂运算,学习数据中的内在联系与模式,进而构建出能预测机械故障的有效模型,为故障预测提供有力工具。

(四) 故障诊断与预警系统

当预测模型搭建完成,就可将其融入故障诊断与预警系统。此系统实时接收经处理与特征提取后的数据,并输入到预测模型中进行运算。一旦模型判断机械运行状态偏离正常范围,存在潜在故障风险,系统便会迅速发出预警信号。预警形式多样,既可以是操作界面上醒目的红色警示弹窗,提醒操作人员及时关注;也能通过短信、邮件等方式,将预警信息发送给相关技术人员与管理人员。同时,系统会详细分析故障类型与可能的影响范围,为维修人员提供维修建议与参考方案。如此一来,在故障尚未真正发生或造成严重影响前,便能及时采取应对措施,降低损失,保障建筑机械的稳定运行与工程的顺利推进。

二、基于大数据分析的建筑机械故障预测方法

(一) 数据采集方法

在建筑机械故障预测中,数据采集方法极为关键。技术人员依据机械的结构与运行特性,精心挑选合适的采集手段。对于机械主体的关键部位,通常采用接触式传感器来收集数据,因其能紧密贴合部件,精准捕捉细微变化。例如,在发动机缸体上安装加速度传感器,可实时监测其振动状态。而对于一些难以布线、位置分散的部件,非接触式传感器便派上用场,像利用红外传感器测量机械部件表面温度,无需直接接触,避免对机械

运行造成干扰。同时，随着物联网技术的普及，通过无线传输模块将传感器采集到的数据，快速且稳定地传输至中央数据采集平台。这种多样化的数据采集方法，全面覆盖建筑机械的各个关键环节，为后续的故障预测分析积累了丰富且可靠的数据资源。

（二）数据预处理技术

采集到的数据需借助数据预处理技术进行打磨。数据预处理的首要任务是去除噪声数据，专业的数据处理软件运用滤波算法，将那些因电磁干扰、传感器故障等因素产生的异常波动数据过滤掉，还原数据的真实面貌。紧接着，面对数据缺失的情况，工作人员会运用统计学方法进行填补。比如，参考同类机械在相似工况下的数据分布，采用均值、中位数等方法估算缺失值^[3]。随后，为了让不同格式的数据能够协同分析，需进行格式转换，把文本型、数值型等各类数据统一成适合分析的格式。经过这一系列烦琐且细致的数据预处理操作，原本杂乱无章的数据变得整齐有序，为后续的特征提取与模型构建创造了有利条件。

（三）特征提取与选择方法

从海量预处理后的数据中挖掘关键特征，技术人员运用多元统计分析、机器学习算法等多种手段来实现这一目标。在振动数据分析方面，通过傅里叶变换将时域信号转换为频域信号，进而分析不同频率段的能量分布，从中筛选出与故障紧密相关的频率特征。针对机械部件的运行参数，运用主成分分析方法，将众多相关性较强的参数简化为少数几个相互独立的主成分，这些主成分浓缩了数据的核心信息，能有效反映机械的运行状态。在特征选择过程中，技术人员还会综合考量特征的稳定性、可解释性等因素，去除那些冗余、对故障预测贡献不大的特征，确保所选特征既能准确表征机械故障，又能提高后续模型的运算效率与预测精度。

（四）预测模型的建立方法

构建预测模型是实现建筑机械故障精准预测的核心环节。研究人员基于不同的理论基础，开发出多种模型构建方法。以神经网络模型为例，它通过模拟人脑神经元之间的信息传递方式，构建复杂的网络结构。将经过特征提取与选择后的数据作为输入，在网络内部经过层层神经元的加权运算与非线性变换，不断学习数据中的复杂模式与内在联系。经过大量样本数据的训练，模型逐渐优化参数，使其能准确预测机械故障的发生概率与类型。而支持向量机模型则从另一个角度出发，通过寻找一个最优分类超平面，将不同类别的数据点尽可能分开，以此实现对机械运行状态的分类预测，有效识别正常状态与潜在故障状态，为建筑机械故障预测提供了有力的技术支撑。

（五）故障预测的评估指标

为了检验故障预测方法的有效性，一套科学合理的评估指标不可或缺。在实际应用中，常用准确率来衡量预测结果与真实情况的吻合程度，即准确预测出故障的样本数占总样本数的比例。召回率也是重要指标之一，它反映了模型对实际存在故障样本的捕捉能力，若召回率低，意味着可能会遗漏许多潜在故障^[4]。此外，F1值综合考虑了准确率与召回率，能更全面地评价模型性能。同时，研究人员还会关注预测的及时性，也就是在故障发生前多久能够准确发出预警，这对于提前采取维修措施、避免损失至关重要。通过对这些评估指标的综合分析，不断优化故障预测方法，提高建筑机械故障预测的可靠性与实用性。

三、基于大数据分析的建筑机械故障预测方法优化策略

（一）数据质量提升与标准化

数据质量是建筑机械故障预测精准度的基石。为提升数据质量，技术人员首先强化传感器的维护与校准工作。定期对传感器进行检查，及时更换老化或损坏的部件，确保其测量精度与稳定性。因为只有传感器精准采集数据，后续分析才有价值。在数据采集环节，制定严格的操作规范，要求工作人员按照标准流程执行，减少人为因素导致的数据偏差。针对采集到的数据，运用先进的数据清洗算法，不仅去除噪声数据，还深入挖掘数据中的潜在错误与异常值。例如，通过数据挖掘技术识别那些不符合机械运行逻辑的数据点，并进行修正或删除。在标准化方面，建立统一的数据标准体系至关重要。对于不同类型、不同品牌建筑机械的数据，明确规定数据格式、单位及编码规则等。如此一来，各类数据在进入分析流程前，都能依据标准进行转换与适配，消除数据之间的“隔阂”。当所有数据遵循相同标准时，数据的可比性与兼容性大幅提升，为后续跨机械、跨项目的综合分析提供有力支撑，进而提升故障预测的准确性与可靠性（如图一所示）。



图一：故障处理

（二）增强模型的泛化能力

模型的泛化能力关乎其能否在不同场景下准确预测建筑机械故障。为增强泛化能力，研究人员采用多样化的训练数据。收集来自不同地区、不同施工环境、不同使用年限建筑机械的运行数据，涵盖各类工况与故障类型。丰富的数据样本能让模型学习到更广泛的机械运行模式与故障特征，而非局限于特定场景的数据规律。在模型训练过程中，运用正则化技术来约束模型复杂度。例如，添加 L1 或 L2 正则项，防止模型过度拟合训练数据中的噪声与细节，使其更关注数据的整体特征与普遍规律。同时，采用交叉验证方法，将训练数据划分为多个子集，轮流作为训练集与验证集，全面评估模型性能，调整模型参数，使模型在不同数据子集上都能保持较好的预测能力。此外，持续更新与扩充训练数据也是关键。随着建筑机械技术的发展与新故障类型的出现，及时将新数据纳入训练集，让模型不断学习新知识，适应新变化，从而在复杂多变的实际应用场景中，依旧能够准确预测建筑机械故障，展现出强大的泛化能力。

（三）高效特征选择算法

高效的特征选择算法是提升建筑机械故障预测效率与精度的关键。技术人员摒弃传统单一的特征选择方法，采用多种算法融合的策略。例如，将基于统计分析的卡方检验与基于机器学习的递归特征消除法相结合。卡方检验先从统计学角度筛选出与故障相关性较强的特征，初步缩小特征范围；递归特征消除法则通过构建模型，逐步剔除对模型性能影响较小的特征，进一步优化特征子集。在特征选择过程中，充分考虑特征之间的相关性与冗余性。运用相关性分析方法，识别那些高度相关的特征，保留其中最具代表性的特征，去除冗余部分，避免模型因输入过多重复信息而增加运算负担，同时防止冗余特征干扰模型对关键信息的学习。此外，开发动态特征选择算法也是趋势。建筑机械在不同运行阶段，其故障特征可能发生变化。动态特征选择算法能够根据机械的运行状态、时间等因素，实时调整特征选择策略，选取最能反映当前机械故障状态的特征，为故障预测提供精准且高效的特征输入，提升预测模型的性能与适应性。

（四）模型优化与调参技术

模型优化与调参是挖掘模型潜力、提升建筑机械故障预测性能的重要手段。研究人员针对不同的预测模型，采用相应的优化算法。对于神经网络模型，运用随机梯度下降法及其变种，如 Adagrad、Adadelta 等算法，在训练过程中动态调整模型参数的更新步长，加快模型收敛速度，避免陷入局部最优解。对于支持向量机模型，优化核函数参数，选择合适的核函数类型，如线性核、高斯核等，以更好地适应数据分布，提高模型的分类与

预测能力。在调参方面，运用自动化调参工具，如网格搜索、随机搜索等方法。这些工具能够在预设的参数空间内，按照一定规则遍历不同的参数组合，通过交叉验证评估每个参数组合下模型的性能，自动寻找最优参数配置。同时，结合经验与领域知识，对参数进行合理的初始设置与范围限定，减少调参的盲目性，提高调参效率。此外，定期对模型进行性能评估与更新。随着建筑机械运行数据的不断积累与环境变化，模型性能可能逐渐下降。

（五）基于深度学习的预测方法创新

深度学习在建筑机械故障预测领域展现出巨大潜力，推动着预测方法的创新发展。研究人员构建新型深度学习模型，如深度卷积神经网络（DCNN）与长短时记忆网络（LSTM）相结合的混合模型。DCNN 擅长提取数据的空间特征，能够有效处理图像、振动信号等数据中的局部特征；LSTM 则对时间序列数据具有出色的处理能力，能够捕捉机械运行状态随时间的变化趋势。二者结合，可全面挖掘建筑机械运行数据中的时空特征，提升故障预测的准确性。在模型训练过程中，采用迁移学习技术。利用在大规模通用数据集上预训练好的模型，迁移其学习到的通用特征与知识，在此基础上针对建筑机械故障预测任务进行微调。这样既能减少模型训练所需的大量数据与计算资源，又能借助预训练模型的强大特征提取能力，快速提升模型在建筑机械故障预测领域的性能。

结语

综上所述，利用大数据分析，搭建起建筑机械故障预测体系。通过实时监测采集数据、清洗处理及特征提取建模，实现故障诊断与预警。同时，提出优化策略，提升数据质量、增强模型泛化等。研究表明，大数据分析在建筑机械故障预测中效果显著。未来，随着技术进步，有望进一步完善预测模型，挖掘更多潜在故障特征，拓展应用场景，为建筑行业安全生产与高效运营提供有力保障，持续推动该领域的创新发展。

参考文献

- [1] 张聪. 建筑机械设备和物资材料的集约化管理研析 [J]. 建设机械技术与管理, 2024, 37 (06): 27-29.
- [2] 杜学胜, 魏丁一, 李梦真, 等. 高层建筑机械加压送风系统压力分析 [J]. 河南工程学院学报 (自然科学版), 2024, 36 (04): 20-25.
- [3] 全永强. 建筑机械节能现状及对策 [J]. 建材发展导向, 2024, 22 (17): 120-122.
- [4] 曾祥荣, 刘秋娟. 建筑机械远程监控与管理平台的设计实现 [J]. 网络安全和信息化, 2024, (08): 111-113.

作者简介：施洋洋（1992.02-），男，汉族，安徽人，工程师，本科学历，研究方向：建筑机械。