

# 基于深度学习的机械设备故障诊断方法研究

胡小金

江西鑫昌畜牧设备有限公司 江西南昌 330200

**摘要:** 机械设备在工业生产中处于核心地位,其运行状态直接关系到生产效率、产品质量与安全保障。然而,随着设备复杂度和自动化水平的不断提高,传统基于经验或浅层机器学习的方法在故障诊断中的适用性逐渐受限。近年来,深度学习因其强大的特征自动提取与模式识别能力,被广泛应用于机械设备故障诊断研究与工程实践。研究表明,基于深度学习的故障诊断方法能够显著提升诊断的准确性与实时性,但仍面临数据质量、模型解释性与跨领域迁移等挑战。本文旨在为机械设备智能运维提供理论支持与实践参考。

**关键词:** 深度学习; 机械设备; 故障诊断; 智能运维; 模式识别

## 引言

机械设备的稳定运行是现代工业体系高效运转的关键环节。随着人工智能与大数据技术的发展,深度学习在图像识别、语音处理、自然语言理解等领域展现出卓越能力,为机械设备故障诊断提供了全新思路。深度学习通过多层神经网络实现特征的自动提取与深层次表达,能够有效处理振动信号、声学信号、红外热成像等多模态数据,并实现端到端的智能诊断。因此,探索基于深度学习的机械设备故障诊断方法,不仅具有重要的理论意义,也对提升工业设备运维的智能化水平与保障生产安全具有现实价值。

## 一、理论基础与研究现状

### 1. 机械设备故障诊断的基本理论与传统方法

机械设备故障诊断的根本目标在于通过多源信息的采集与分析,识别设备潜在异常并准确分类故障类型。传统理论体系主要由信号处理、特征提取和模式识别三部分构成。在信号处理层面,研究者通常借助傅里叶变换、小波变换、经验模态分解等方法,将复杂的时域信号转换为频域或时频域特征,以便揭示设备运行状态的周期性与突变特征。在特征提取环节,均方根、峭度、偏度、频谱熵等统计特征被广泛应用于区分不同健康状态,然而这些特征往往具有较强的工况依赖性,且人工选择过程易受主观经验影响,难以保证特征的全面性与普适性。在模式识别环节,支持向量机(SVM)、K近邻(KNN)、朴素贝叶斯等分类器长期作为主流算法,用于对提取的特征进行故障类型判别,但其建模能力有限,难以充分应对机械设备工况下普遍存在的非线性与多维

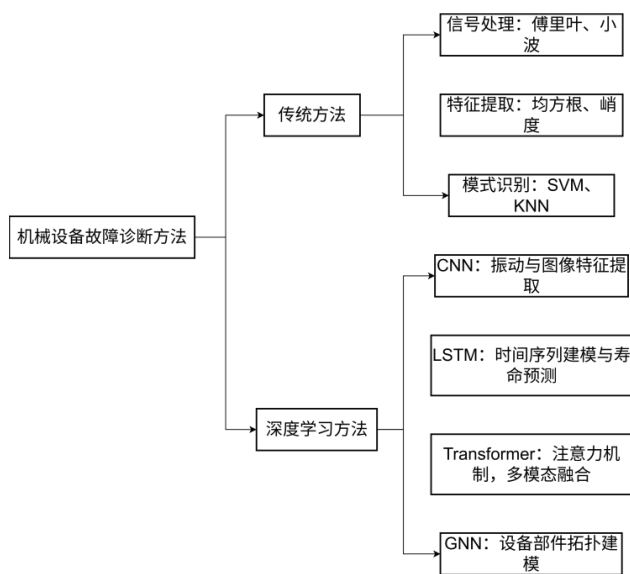
耦合特性。尽管传统方法在早期研究与实际工程中发挥了重要作用,但随着设备复杂度不断提升,其局限性逐渐凸显。一方面,人工特征提取对诊断结果的影响极大,不同研究者选择的特征集差异性较大,导致诊断结果难以保持一致性;另一方面,传统方法在面对高维、多模态数据时表现不足,难以有效刻画机械设备在长期运行过程中逐步演化的复杂失效机理。因此,探索能够自动提取高层次特征并具备强大建模能力的新型方法,成为机械设备故障诊断领域的重要方向。

### 2. 深度学习的兴起与国内外研究进展

深度学习作为人工智能的核心技术之一,在图像识别、语音识别和自然语言处理等领域取得突破性进展,其优势在于能够通过多层神经网络实现特征的自动学习与深层抽象,从而避免人工特征依赖。对于机械设备故障诊断而言,深度学习不仅能够处理振动、声学、温度等单一信号,还能实现多源异构数据的融合建模,从而显著提升诊断的准确率与鲁棒性。在具体应用层面,卷积神经网络(CNN)被广泛用于轴承与齿轮故障识别,通过对振动信号时频图像的卷积提取局部特征,实现了高精度的分类;循环神经网络(RNN)及其变种长短期记忆网络(LSTM)在处理时间序列数据方面优势显著,能够捕捉设备运行状态随时间演变的动态规律,被广泛用于剩余寿命预测与早期故障趋势分析;近年来,基于注意力机制和Transformer架构的模型逐渐应用于故障诊断,其在长序列依赖建模与多模态融合方面展现出潜力。

在研究现状方面,国外学者较早探索深度学习在设备故障诊断中的应用。例如,美国麻省理工学院研究团队利用CNN实现了对滚动轴承早期故障的自动识别,准

准确率超过98%；德国弗劳恩霍夫研究所提出结合深度自编码器的无监督方法，用于复杂系统早期异常检测。国内学者也开展了大量研究工作，如清华大学团队将LSTM用于旋转机械的预测性维护，实现了设备健康状态的实时跟踪；华中科技大学研究者则结合卷积与注意力机制提出混合模型，在齿轮箱故障诊断中取得良好效果。与此同时，随着工业物联网、大数据与数字孪生技术的发展，深度学习模型逐渐从实验室走向实际工程应用，形成了从数据采集、特征学习到智能诊断的全流程体系。总体来看，深度学习为机械设备故障诊断提供了革命性工具，但仍需解决小样本学习、跨工况迁移与模型可解释性等关键问题。



为了更清晰地展示机械设备故障诊断方法的发展脉络，本文将传统方法与深度学习方法的结构特点进行了对比与归纳，如图1所示。

## 二、深度学习方法在机械设备故障诊断中的应用

### 1. 卷积神经网络与循环神经网络的应用

深度学习在机械设备故障诊断中的应用最早集中在卷积神经网络（CNN）与循环神经网络（RNN）两个方向。CNN因其独特的卷积运算结构，能够自动从原始信号中提取局部特征并进行多层次组合，被广泛用于处理机械振动信号与时频图像。例如，在轴承故障诊断中，研究者通过将振动信号转化为短时傅里叶变换（STFT）或连续小波变换（CWT）得到的时频图输入CNN，模型能够捕捉不同故障模式下频谱能量分布的差异，从而实现高精度分类。相较于传统特征工程，CNN摆脱了人工挑选特征的依赖，诊断准确率往往可提升5%—10%。

另一方面，循环神经网络（RNN）及其改进型长期记忆网络（LSTM）更适合处理时间序列数据，能够捕捉机械设备运行状态随时间演化的动态规律。例如，在齿轮箱与风机轴承的故障预测中，LSTM能够通过长期依赖建模，实现对设备剩余寿命的估计与故障趋势的提前预警。与仅关注静态特征的传统分类器相比，LSTM能够揭示故障发展过程中的潜在模式，为预测性维护提供依据。在工程实践中，某风电场通过LSTM模型对齿轮箱故障进行提前两周预测，显著降低了突发停机风险与运维成本。

CNN与LSTM在应用中也存在一定互补关系。CNN侧重于空间或频谱特征的捕捉，而LSTM擅长时序依赖的建模。近年来，学者们提出将两者结合形成混合网络结构，如通过CNN提取局部时频特征，再交由LSTM进行序列建模，从而兼顾空间特征与时间依赖，显著提升了诊断精度与泛化能力。这类混合模型尤其适用于复杂工况下的旋转机械与大型装备，为深度学习在工业场景的落地提供了实践路径。

### 2. 新兴模型与多模态融合应用

随着深度学习理论与算力的进步，传统的CNN与LSTM逐渐向更复杂、更高效的模型架构演进。其中，基于自注意力机制的Transformer模型因其能够捕捉长距离依赖关系而备受关注。在机械设备故障诊断中，Transformer能够在长时间序列中挖掘全局特征，避免了RNN在长序列建模中的梯度消失问题。例如，研究者在液压泵故障预测中引入Transformer结构，不仅提高了预测精度，还在多工况切换时表现出更好的适应性。此外，自注意力机制的引入使模型具备一定的特征解释能力，有助于分析不同时间片段对故障诊断的贡献，为工程应用提供参考。

另一类重要的发展方向是图神经网络（GNN）的应用。机械设备往往由多个部件构成，其内部关系具有复杂的拓扑结构。传统模型仅将信号视为独立序列，难以有效反映部件间的交互作用。GNN则能够通过图结构对设备部件关系进行建模，在复杂系统故障诊断中展现出优势。例如，在机床主轴系统诊断中，研究者将传感器信号映射为节点，将部件之间的耦合关系映射为边，利用GNN实现了对多部件协同故障的准确识别。除了单一模型的创新，多模态数据融合成为深度学习在机械设备故障诊断中的新趋势。现代工业现场通常配备多类传感器，如振动、声学、温度、压力与红外热成像等，这些信号从不同角度反映设备的运行状态。多模态融合方法

通过引入多通道CNN、联合注意力机制或跨模态对齐算法，实现了不同信号特征的协同建模，显著提升了复杂场景下的诊断性能。如在航空发动机故障检测中，融合振动与红外图像的深度模型能够同时捕捉机械振动异常与热分布变化，其诊断准确率高于单一模态模型10%以上。这类方法为应对复杂、多变工况下的设备健康管理提供了可行路径。

### 三、关键技术与实现路径

#### 1. 数据获取与预处理

深度学习模型在机械设备故障诊断中的有效性高度依赖于数据的质量与多样性。高质量数据不仅能够保证模型的训练效果，还直接决定了诊断系统在实际应用中的可靠性。因此，数据获取与预处理是构建智能故障诊断系统的首要环节。

在数据采集方面，常用的方式包括振动传感器、加速度计、麦克风、温度传感器、油液监测装置以及红外热成像仪等。不同传感器能够捕捉设备运行状态的不同特征维度：振动信号可揭示轴承、齿轮等旋转部件的微小缺陷；声学信号能够反映机械部件在摩擦、冲击过程中的异常；油液监测数据则可检测磨粒浓度和润滑状态，从而推断部件磨损情况。在工程应用中，往往需要布设多类传感器，形成一个多维度、多模态的数据获取系统，以全面反映设备健康状态。

而工业现场采集到的数据通常包含噪声、丢包、非平稳性与工况波动等问题，直接输入深度学习模型会显著影响其性能。因此，预处理环节显得尤为关键。常见方法包括：信号去噪（如小波阈值法、经验模态分解）、归一化与标准化处理（消除量纲差异）、特征变换（如短时傅里叶变换、希尔伯特-黄变换）等。特别是在时频分析中，将振动信号转化为时频谱或小波散射图后再输入卷积神经网络，能够有效提升特征表达能力。此外，为了应对故障样本不足的问题，研究者常采用数据增强技术，如随机切片、加噪声扰动、信号混合等，以扩展训练样本集，从而缓解深度学习模型的过拟合风险。

#### 2. 模型设计、训练与部署

深度学习模型的设计与优化是实现高效故障诊断的核心环节。针对不同机械设备与应用场景，研究者需结合工况特点与数据类型选择合适的网络结构。例如，对于轴承和齿轮故障识别，卷积神经网络因其善于捕捉局部模式而成为首选；而对于需要分析设备寿命演化的任务，则更适合采用LSTM或Transformer等时序建模方法。

在实际设计中，常见的思路是通过多层卷积提取信号局部特征，再引入循环结构或注意力机制进行全局信息整合，从而实现端到端的诊断与预测。

在模型训练阶段，需重点关注样本不平衡与过拟合问题。由于故障状态相较于正常状态往往发生频率较低，样本类别极易失衡，导致模型训练偏向正常数据。解决方案包括对少数类样本进行过采样、利用生成对抗网络（GAN）生成虚拟故障数据、或通过代价敏感学习提升模型对少数类的关注度。同时，正则化、Dropout与早停等策略也被广泛用于防止过拟合。随着计算硬件的发展，模型训练可通过GPU集群或分布式框架进行加速，以支持大规模数据与复杂网络的高效训练。

在模型部署环节，工业场景对实时性和稳定性有严格要求。将模型直接部署在云端虽然能够保证算力，但会带来通信延迟和数据安全隐患。近年来，边缘计算成为重要趋势，即将训练好的模型轻量化后部署至本地设备或边缘服务器，结合量化、剪枝与知识蒸馏等方法降低模型复杂度，从而实现低功耗与低延迟的在线诊断。在某些关键设备场景中，还可以采用“云一边一端”协同架构：云端负责模型更新与迭代，边缘节点负责推理与异常检测，终端设备则用于简单的状态监控，从而在保证实时性的同时维持模型的持续优化。

### 结论

本文系统研究了基于深度学习的机械设备故障诊断方法，梳理了相关理论、典型模型与应用案例。研究表明，深度学习能够有效提升诊断的准确性与实时性，是推动设备智能运维与工业4.0发展的关键技术。未来随着多源数据融合、模型可解释性与跨领域迁移能力的进一步提升，基于深度学习的故障诊断将在更多复杂工业场景中得到广泛应用，为构建安全、高效与绿色的智能制造体系提供有力支撑。

### 参考文献

- [1] 郑凡帆. 基于深度学习的机械设备故障预警与诊断技术研究[D]. 北京: 北京化工大学, 2020.
- [2] 陶加云, 尹志鹏. 基于深度学习的机械电气设备变频器故障诊断方法[J]. 电气技术与经济, 2025(1): 296-298.
- [3] 徐坚栋, 王丽辰. 基于深度学习的建筑机械设备故障诊断方法研究[J]. 大众科学, 2025, 46(12): 4-6.