

人工智能在电子信息设备故障诊断中的应用

覃玉观

南宁轨道交通运营有限公司 广西 南宁 530029

摘要：随着科技的飞速发展，电子信息设备在现代社会中的应用日益广泛，其复杂性和集成度不断提高，对故障诊断的准确性和效率提出了更高要求。人工智能技术的引入，为电子信息设备的故障诊断提供了全新的解决方案。本文旨在探讨人工智能在电子信息设备故障诊断中的应用实现、优势与挑战，以及未来发展趋势，以期为相关领域的研究与应用提供参考。

关键词：人工智能；电子信息设备；故障诊断；应用

引言

电子信息设备作为现代科技的重要载体，其稳定运行直接关系到生产生活的顺利进行。然而，随着设备复杂性的增加，传统基于经验和规则的故障诊断方法已难以满足实际需求。人工智能技术的兴起，为电子信息设备的故障诊断带来了革命性的变化。通过机器学习、深度学习等先进算法，人工智能能够实现对设备故障的自动识别、诊断与预测，显著提高诊断效率和准确性。

1 人工智能在电子信息设备故障诊断中的应用路径

1.1 数据采集与预处理

数据采集是故障诊断技术的首要 and 关键步骤，它涉及通过传感器、摄像头等硬件设备实时或定期地获取设备的运行状态数据。这一环节的目标是全面、准确地捕捉设备在运行过程中的各种状态信息，为后续的故障诊断提供坚实的基础。采集到的原始数据往往包含大量的噪声、冗余信息和异常值，这些数据可能会对后续的分析 and 诊断造成干扰，甚至导致误诊。因此，数据预处理成为了一个不可或缺的环节。在数据预处理阶段，主要进行以下操作：（1）数据清洗：去除数据中的异常值和缺失值^[1]。异常值可能是由于传感器故障、数据传输错误或环境因素等造成的，它们会严重影响数据的准确性和可靠性。对于缺失值，我们可以通过插值、拟合或基于算法的方法来进行填补，以确保数据的完整性。（2）数据去噪：采用滤波、平滑等技术减少数据中的随机误差和干扰。这一步骤对于提高后续分析的准确性至关重要，因为它能够消除数据中的高频噪声和不必要的波动。（3）数据归一化：将数据缩放到一个统一的数值范围内。归一化处理可以消除不同数据之间的量纲差异，使得后续的分析 and 比较更加公平、准确。同时，它还可以加快后续算法的收敛速度，提高诊断效率。

1.2 特征提取与选择

1.2.1 特征提取

特征提取是指从预处理后的数据中提取出能够反映设备运行状态和故障信息的特征。这些特征应该具有明确的物理意义，能够直接或间接地指示设备的健康状态。

1.2.1.1 常见特征类型

一是时域特征：如均值、方差、峰值、偏度、峭度等，这些特征直接反映了信号在时间域上的统计特性。二是频域特征：通过对信号进行傅里叶变换等频谱分析方法，提取出信号的频谱特性，如主频、带宽、能量分布等。这些特征能够揭示信号在频率域上的特性，对于旋转机械等设备的故障诊断尤为重要。三是时频特征：结合时域和频域的特性，如短时傅里叶变换、小波变换等，能够同时反映信号在时间和频率上的变化特性。

1.2.1.2 特征提取方法

一是基于统计的方法：直接计算信号的统计量作为特征。二是基于模型的方法：根据设备的物理模型或运行规律，推导出与故障相关的特征参数。三是基于信号处理的方法：利用信号处理技术（如滤波、去噪、平滑等）对信号进行预处理，然后提取特征。四是基于机器学习的方法：利用机器学习算法（如主成分分析、自编码器等）自动学习数据的低维表示，作为特征。

1.2.2 特征选择

特征选择是在提取出的特征中进一步筛选出对故障诊断最有价值的特征^[2]。特征选择的目的在于去除冗余特征和无关特征，降低模型的复杂度，提高计算效率和诊断准确性。

1.2.2.1 特征选择方法

（1）过滤法（Filter Methods）：根据特征的离散性（如方差）或与目标的相关性（如皮尔逊相关系数）进行评分，选择得分较高的特征。这种方法简单高效，但可能忽略特征之间的组合效应。（2）包裹法（Wrapper

Methods)：通过不断排除或选择特征，并对训练得到的模型效果进行打分，根据预测效果评分来决定特征的去留。这种方法能够较好地保留有价值的特征，但计算成本较高。(3) 嵌入法 (Embedded Methods)：在模型训练过程中自动进行特征选择。例如，在决策树或随机森林模型中，通过特征的重要性评分来选择特征；在Lasso回归中，通过正则化项将部分特征属性的权重调整到0，从而实现特征选择。

1.2.2.2 特征选择步骤

一是候选特征子集的生成：根据特征提取的结果，生成一个包含所有候选特征子集。二是子集评价：采用适当的评价准则（如准确率、召回率、F1值等）对候选特征子集进行评估。三是停止准则：设定停止条件（如达到预设的特征数量、模型性能不再显著提升等），以避免过度拟合和计算资源浪费。四是结果验证：在独立的测试集上验证所选特征子集的有效性和稳定性。

1.2.3 特征降维与融合

1.2.3.1 特征降维

特征降维是指通过一定的数学变换，将高维特征空间映射到低维空间中，同时尽可能保留原始数据中的重要信息。特征降维技术有助于提高计算效率和减少噪声干扰。常见的特征降维方法包括主成分分析 (PCA)、线性判别分析 (LDA)、多维尺度分析 (MDS) 等。

1.2.3.2 特征融合

特征融合是指将多个单一特征进行组合，形成新的特征向量，以更好地反映设备的运行状态和故障信息。特征融合技术可以充分利用不同特征之间的互补性，提高故障诊断的准确性和鲁棒性。特征融合的方法多种多样，可以根据实际情况选择适当的融合策略。

1.3 模型构建与训练

1.3.1 模型选择

在选择模型时，需要考虑数据的特性、故障的类型以及诊断的需求。常见的模型包括神经网络、支持向量机 (SVM)、决策树、随机森林等。每种模型都有其独特的优势和适用场景。神经网络具有强大的非线性拟合能力，适用于处理复杂的数据关系和模式。神经网络的层数、节点数、激活函数等参数可以根据具体任务进行调整。支持向量机 (SVM) 在小样本情况下表现优异，能够找到数据中的最优分类边界。SVM的核函数、惩罚系数等参数对模型性能有较大影响。决策树易于理解和实现，能够生成直观的故障分类规则^[3]。决策树的深度、剪枝策略等参数需要仔细调整。随机森林由多个决策树

组成，通过集成学习提高模型的稳定性和准确性。随机森林的树的数量、树的深度等参数对性能有影响。

1.3.2 数据准备

模型训练需要标注好的故障数据，这些数据应该涵盖设备的各种运行状态和故障类型。数据准备包括以下几个步骤：(1) 数据标注：由专业的技术人员对采集到的数据进行标注，指示出故障的类型和位置。(2) 数据划分：将标注好的数据划分为训练集、验证集和测试集。训练集用于模型训练，验证集用于模型选择，测试集用于评估模型的泛化能力。(3) 数据预处理：对划分好的数据进行预处理，包括归一化、标准化、去噪等，以确保数据的质量和一致性。

1.3.3 模型训练

模型训练是使用标注好的故障数据对选择的模型进行学习的过程。训练过程中需要不断调整模型的参数和结构，以优化模型的性能。一是参数初始化：对模型的参数进行初始化，如神经网络的权重和偏置。二是损失函数定义：根据任务需求定义合适的损失函数，如交叉熵损失、均方误差损失等。三是优化算法选择：选择合适的优化算法对模型进行训练，如梯度下降法、Adam优化器等。四是迭代训练：通过多次迭代训练，不断调整模型的参数，以最小化损失函数。五是模型评估：在每次迭代后，使用验证集对模型进行评估，监控模型的性能变化。

1.4 模型评估与优化

1.4.1 模型评估

1.4.1.1 评估方法

常用的模型评估方法包括留出法、交叉验证法和自助法。(1) 留出法：直接将数据集划分为训练集和测试集，用训练集训练模型，然后用测试集评估模型性能。这种方法简单直观，但需要注意训练集和测试集的划分要尽可能保持数据分布的一致性。(2) 交叉验证法：将数据集划分为多个大小相似的子集，然后多次进行训练和测试，每次选择不同的子集作为测试集，其余子集作为训练集。这种方法可以充分利用有限的的数据，得到更为可靠的评估结果。常见的交叉验证方法包括K折交叉验证和留一法。(3) 自助法：通过自助采样法生成多个训练集和测试集，然后分别在这些数据集上进行训练和测试。这种方法适用于数据量较小的情况，但需要注意自助采样可能会引入一些偏差。

1.4.1.2 评估指标

评估模型性能的指标有很多，常用的包括准确率、召回率、F1值、AUC-ROC等。(1) 准确率

(Accuracy): 衡量模型正确预测的样本数占总样本数的比例。但对于不平衡数据集, 准确率可能不是很好的评估指标。(2) 召回率 (Recall): 衡量模型正确预测为正例的样本数占实际正例样本数的比例。在故障诊断中, 召回率高意味着模型能够更多地识别出故障样本。(3) F1值 (F1 Score): 是精确率和召回率的调和平均数, 用于平衡精确率和召回率的影响。F1值高表示模型在精确率和召回率上都有较好的表现。(4) AUC-ROC: 衡量模型在不同阈值下的泛化错误率。AUC-ROC值越高, 表示模型的性能越好。

1.4.2 模型优化

1.4.2.1 优化方法

常用的模型优化方法包括正则化、剪枝、集成学习等。一是正则化 (Regularization): 通过在损失函数中加入正则化项来约束模型的复杂度, 防止模型过拟合。常见的正则化方法包括L1正则化和L2正则化。二是剪枝 (Pruning): 对于决策树、随机森林等模型, 可以通过剪枝去除一些不必要的分支或特征, 从而简化模型结构, 提高模型的泛化能力。三是集成学习 (Ensemble Learning): 通过将多个单一模型进行组合来形成一个更强的模型。常见的集成学习方法包括Bagging、Boosting和Stacking等。这些方法可以通过提高模型的多样性和减少方差来提高整体性能。

1.4.2.2 优化步骤

模型优化的步骤通常包括: (1) 分析评估结果: 首先分析模型在测试集上的表现, 找出性能瓶颈所在。(2) 调整模型参数: 根据评估结果调整模型的超参数, 如学习率、正则化系数等。(3) 改进模型结构: 如果调整参数无法显著提升性能, 可能需要考虑改进模型结构, 如增加或减少层数、改变激活函数等。(4) 重新训练和评估: 使用调整后的模型参数和结构重新训练模型, 并在新的测试集上进行评估以验证优化效果。

2 人工智能在电子信息设备故障诊断中的应用优势与挑战分析

2.1 优势

人工智能在电子信息设备故障诊断中的应用带来了显著的优势。其强大的数据处理能力使得故障诊断更加高效和准确, 大大缩短了诊断时间, 提高了维护效率。同时, 自动化故障诊断减少了对人工的依赖, 显著降低了人工成本, 使得企业能够更加灵活地应对设备故障问题。此外, 通过实时监控设备状态, 人工智能还能够提前预测潜在故障, 实现预防性维护, 从而避免设备突发

故障带来的生产中断和损失。

2.2 挑战

尽管人工智能在故障诊断中展现出巨大潜力, 但其应用也面临着一些挑战。首先, 需要大量高质量的数据来训练模型, 而数据的获取和标注成本往往较高。其次, 模型需要具备良好的泛化能力, 以处理各种复杂多变的故障情况, 这对模型的训练和优化提出了更高要求。最后, 故障诊断需要实时响应, 同时模型还需保证安全性, 防止恶意攻击和信息泄露, 这对系统的设计和实施带来了不小的挑战。

3 未来发展趋势

未来, 随着技术的不断创新与突破, 深度学习、自然语言处理、知识图谱等先进技术将持续发展, 并将进一步提升故障诊断的准确性和效率, 为电子信息设备的维护带来更高水平的技术支持。同时, 多模态数据融合将成为重要趋势, 通过融合来自不同传感器的多种数据, 实现更加全面和准确的故障诊断, 提高维护的精准度和效率^[4]。此外, 个性化优化与学习也将成为关键发展方向, 针对不同设备和故障特征进行个性化优化和学习, 使故障诊断更加具有针对性和可靠性。最后, 加强人工智能模型的可解释性研究, 提高诊断结果的透明度和可信度, 将是未来发展的重要方向, 有助于提升人工智能在故障诊断领域的应用价值和社会认可度。

结语

人工智能在电子信息设备故障诊断中的应用已经取得显著成效, 未来随着技术的不断发展和完善, 其应用前景将更加广阔。通过深入研究人工智能技术在故障诊断中的应用现状、技术实现、优势与挑战以及未来发展趋势, 可以为相关领域的研究与应用提供有力支持。相信在不久的将来, 人工智能将在电子信息设备故障诊断中发挥更加重要的作用, 推动相关行业的持续健康发展。

参考文献

- [1] 谢辰子. 电子设备智能故障诊断技术研究[J]. 中国设备工程, 2021, (03): 154-155.
- [2] 白辰. 基于大数据技术的电子信息工程故障诊断与维护[J]. 电子元器件与信息技术, 2023, 7(12): 115-118.
- [3] 冯元, 李超, 梁博, 等. 基于虚拟化技术的电子信息设备故障诊断与虚拟仿真实验室设计[J]. 集成电路应用, 2024, 41(01): 226-227.
- [4] 杨晓娜, 刘志远, 王蔚, 等. 报修信息生命周期化采集下的电子设备故障快速诊断方法[J]. 测试技术学报, 2022, 36(05): 455-460.