

# 机器学习在金属磁记忆检测中的应用与展望

王慧鹏<sup>1</sup>, 李海航<sup>1</sup>, 石家龙<sup>1,2</sup>, 董丽虹<sup>2</sup>, 王海斗<sup>3</sup>

(1. 江西理工大学 机电工程学院, 赣州 341000; 2. 陆军装甲兵学院 再制造技术国家重点实验室, 北京 100072;  
3. 陆军装甲兵学院 机械产品再制造国家工程研究中心, 北京 100072)

**摘要:** 金属磁记忆检测技术(MMMT)能够检测以应力集中为代表的早期损伤, 在铁磁性构件损伤检测领域具有广阔的应用前景。由于金属磁记忆检测信号十分微弱并且具有较强的非线性, 在实际检测时容易出现漏检或误检。机器学习方法对信号数据集特征分析具有良好的自学习和自适应能力, 较适合金属磁记忆检测信号的分析与处理。对机器学习技术在金属磁记忆检测中的应用进行了综述, 讨论了金属磁记忆信号传统特征提取方法的特点, 分析了机器学习在金属磁记忆检测中的特征提取、定量识别及剩余寿命预测等方面的研究现状, 指出了机器学习在金属磁记忆检测领域的难点问题, 并对其发展方向进行了展望。

**关键词:** 金属磁记忆检测; 机器学习; 特征提取; 定量识别; 寿命预测

中图分类号: TG115.28

文献标志码: A

文章编号: 1000-6656(2024)08-0089-07

## Application and prospects of machine learning on metal magnetic memory testing

WANG Huipeng<sup>1</sup>, LI Haihang<sup>1</sup>, SHI Jialong<sup>1, 2</sup>, DONG Lihong<sup>2</sup>, WANG Haidou<sup>3</sup>

(1. School of Mechanical and Electrical Engineering, Jiangxi University of Science and Technology, Ganzhou 341000, China;  
2. National Key Laboratory for Remanufacturing, Army Academy of Armored Forces, Beijing 100072, China;  
3. National Engineering Research Center for Remanufacturing, Army Academy of Armored Forces, Beijing 100072, China)

**Abstract:** Metal magnetic memory testing (MMMT) can detect early damage represented by stress concentration, and has broad application prospects in the field of damage detection of ferromagnetic components. However, the MMMT signals are very weak and nonlinear, and it is prone to have no warning or false warning applied the MMMT is applied in engineering application. The machine learning method is suitable for data processing and analysis in MMMT for its good self-learning ability and adaptability for characteristic patterns finding. This paper focused on the application of machine learning methods in metal magnetic memory testing. The traditional feature extraction methods of MMMT signals were discussed, and the research status of machine learning methods in feature extraction, quantitative recognition and residual life prediction of metal magnetic memory testing was analyzed. The difficulties and future development direction of machine learning methods in the field of metal magnetic memory testing were discussed.

**Key words:** metal magnetic memory testing; machine learning; feature extraction; quantitative identification; life prediction

机械设备的大部分重要金属零部件均由铁磁性材料制造而成, 这些部件在运行过程中频繁地承受

收稿日期: 2023-11-22

基金项目: 国家自然科学基金(52065026)

作者简介: 王慧鹏(1983—), 男, 博士, 副教授, 硕士生导师, 主要从事无损检测技术、无损评价等方面的研究工作

通信作者: 董丽虹(1972—), 女, 博士, 副研究员, 博士生导师, 主要从事无损检测与再制造寿命预测工作 lihong.dong@126.com

交变荷载作用, 极易出现疲劳失效, 而导致机械设备发生不可逆损坏<sup>[1]</sup>。为确保人员安全与设备稳定运行, 非常有必要对铁磁性材料进行疲劳损伤检测。

疲劳损伤是指疲劳载荷作用下, 材料微观结构变化, 产生微观裂纹和孔洞等缺陷, 进而引发材料损伤累积和结构性能衰退的过程, 包含疲劳裂纹的萌生、扩展, 直到构件的破坏阶段。铁磁性构件的疲劳

损伤与其应力状态和微观缺陷密切相关, 传统无损检测技术(如磁粉检测、涡流检测、渗透检测和超声检测等)很难实现以应力集中为代表的早期损伤评估。俄国科学家DOBOV在20世纪90年代提出了金属磁记忆检测技术, 该技术不但能够检测损伤位置, 还具有评估铁磁性材料疲劳损伤的潜力。金属磁记忆检测的基本原理为: 在地磁场的激励下铁磁性材料受外加载荷作用后内部磁畴会发生定向转变而产生漏磁场。该方法具有无需附加外磁场、易操作、可提前进行损伤预测等优点, 得到了广泛关注并取得了良好的工程应用效果<sup>[2]</sup>。

金属磁记忆检测信号采集主要选用灵敏度高、分辨率高以及具备抗干扰能力的霍尔传感器, 并通过低通滤波器过滤掉高频信号干扰, 最后由放大电路及A/D(模/数)转换器将模拟电压信号转换为数字信号<sup>[3]</sup>。金属磁记忆信号具有离散性和非线性, 且信号微弱易受周围环境干扰, 检测出的疲劳损伤位置和大小往往存在误差, 因此, 如何从金属磁记忆信号中提取出合适的特征参量, 分析损伤对应的信号特征规律, 是实现金属磁记忆信号疲劳损伤评价的关键。近年来, 国内外许多学者针对这一问题尝试了多种形式的研究, 其中不少学者引入机器学习算法分析金属磁记忆检测信号特征规律, 从而构建损伤模型, 来对铁磁材料损伤进行有效定量评估。

## 1 金属磁记忆检测信号特征提取方法

金属磁记忆检测信号微弱且具有较强的非线性, 多采用时频分析方法对信号进行处理。此外, 金属磁记忆检测信号易受环境噪声干扰, 而噪声能量对信号能量谱特征提取会产生影响。因此, 在进行时频分析前要先进行去噪处理, 再对预处理信号进行特征提取和分析。金属磁记忆信号在进行常用特征提取和预处理时, 主要通过小波变换、小波包变换、平移不变小波去噪等方法提取出信号时频域特征; 对金属磁记忆信号的预处理, 除了运用不同层次的小波分解方法之外, 还可以使用时频联合分析、谱熵分析等。

### 1.1 基于时频分析的特征提取法

当信息只从一个域进行计算时, 在分析过程中可能丢弃具有高分辨力的重要特征, 这是时域或频域特征提取方法存在的局限性。对于这些限制, 可通过S变换、小波分解、经验模态分解、快速傅立叶变换、傅立叶变换等传统时频分析方法提取出所需

的磁记忆检测信号特征。

目前, 小波变换是金属磁记忆检测信号时频分析特征提取的常用方法。WANG等<sup>[4]</sup>通过小波变换进行信号分解, 并结合基于软阈值的小波熵表示信号能量分布, 根据信号在各分解尺度下的小波熵差异, 自适应确定高频分量的阈值, 从而有效确定损伤位置。王长龙等<sup>[5]</sup>提出了一种自适应阈值降噪算法, 该算法提取小波系数的总类内离散度和均值差平方, 通过综合多尺度分解小波系数特征确定最佳阈值, 能够克服全局阈值的缺陷, 提高了信号的可识别性。

基于小波分析的降噪方法能够准确地识别损伤特征, 其效果主要取决于小波基函数的选择。但实际工程应用时, 选择合适的小波基函数较为困难, 且不具备自适应性。为此, 蔡少川<sup>[6]</sup>针对管道缺陷金属磁记忆信号中噪声干扰严重的问题, 将经验模态分解法用于信号去噪及有效信号提取中, 其噪声抑制效果与小波变换处理效果相同, 该方法既克服了小波变换基函数选取困难以及不具备自适应性的缺点, 同时又具有小波变换高分辨率的优点。

除小波变换, 傅里叶变换在金属磁记忆信号特征识别领域也有诸多应用。梁志芳等<sup>[7]</sup>通过快速傅里叶变换方法发现傅里叶分析中的相位突变位置能够反映信号中深层包含的信息, 采用金属磁记忆信号多特征参数以及傅里叶相位突变位置信号特征参数归一化统计和可靠性分析, 确定焊接裂纹特征规律, 能够有效判断焊接裂纹的存在。XIAO等<sup>[8]</sup>建立了基于傅里叶变换和支持向量机的模型, 通过谱熵分布实现了铁磁材料内部裂纹扩展的监测。

基于小波变换理论, 利用小波包能量谱方法能够较好地处理铁磁性材料早期疲劳损伤定量识别问题。通过对金属磁记忆信号小波包降噪处理后, 任吉林等<sup>[9]</sup>用Hilbert变换提取信号包络, 极大地提高了信噪比和应力集中的可检测度。王继革等<sup>[10]</sup>提取去噪后的磁记忆信号小波包能量特征作为神经网络的输入, 该方法对钢绳芯胶带的早期损伤预测效果较好。LIU等<sup>[11]</sup>提出了一种基于小波包能量谱的磁记忆信号特征提取方法, 发现应力集中程度越高, 能量谱分布越集中并向低频方向发展。朱红运等<sup>[12]</sup>以小波变换为多尺度工具, 提取信号的能量、奇异性指数作为特征量构成评估疲劳损伤的多特征量, 实现了疲劳损伤的量化评估。

传统时频分析建立的特征提取方法(从短时傅里叶变换到Cohen类变换等各类分布)有数十种, 其中,

小波分解方法在使用时需要预先设定基函数, 当提取特征维数较高时, 易出现存储空间增加和分类识别计算过于复杂的问题。小波变换、小波包能量、傅里叶变换等方法适用于大部分信号, 对信号高频部分具有较高的时间分辨率, 对低频部分具有较高的频率分辨率, 非常适合用于检测正常信号中夹带的瞬变反常信号并分析其成分, 但是对于复杂工况下的微弱金属磁记忆信号问题, 还需要结合其他统计方法进行分析。

## 1.2 基于谱熵分析的特征提取方法

信息熵是系统状态不确定性的定量评价指标, 将信息论思想与不同信号分析方法相结合, 综合提取信息熵特征, 即能够得到系统整体的识别评价指标。相比于时频分析特征提取方法, 谱熵分析特征提取方法弥补了无法提取小部分信号特征的缺点。因而谱熵分析特征提取在金属磁记忆检测信号特征提取中具有显著的应用价值。

王太勇等<sup>[13]</sup>应用信息熵理论提取金属磁记忆检测信号特征, 并分析了一、二维谱熵方法的可行性和存在的局限性。邢海燕等<sup>[14]</sup>引入奇异谱熵、功率谱熵和小波空间能谱熵反映焊缝损伤程度, 建立了基于信息熵带和D-S证据理论联合的焊缝等级磁记忆评价模型, 其比单一信息熵能够更有效地降低识别结果的不确定度。刘涛等<sup>[15]</sup>通过对金属磁记忆信号特征和表面纹理特征建模, 对信号及其梯度的样本熵参数以及表面纹理的熵、能量及相关参数进行特征提取, 通过融合评估成功进行了再制造毛坯损伤预测。

谱熵分析既包含了相位信息, 又能够抑制高斯白噪声, 同时能够有效描述信号偏移过程的信息, 非常适用于非高斯信号及非线性信号的特征提取。而小波分解、经验模态分解及高阶谱分析等过程的信号识别率相对比较低, 计算复杂度也更高, 限制了这些方法的实际应用。普通情况下一维谱熵和二维谱熵可自动识别缺陷, 但是缺陷定量识别有时需要利用三维谱熵来提高准确率。因此, 基于金属磁记忆信号的谱熵分析特征提取方法, 可对融合信息谱熵、功率谱熵、奇异谱熵、包络谱熵等进行分析, 并融合其他时频变换方法, 最终找出适合于金属磁记忆检测信号特征提取的分析方法, 来进行铁磁性材料缺陷自动识别和缺陷损伤等级定量识别, 保证铁磁性材料产品的服役安全。

## 2 机器学习应用于金属磁记忆信号处理

随着检测系统的复杂性以及环境的不确定性

的增加, 传统数学模型计算得到的损伤结果的准确性显著降低。机器学习由统计学和人工智能发展而来, 能够克服传统数学模型的不足。该方法通过应用机器学习算法使计算机对大量数据进行自我学习分析, 从数据中找到规律, 利用所发现规律构建新的计算模型对数据进行自动分析处理。金属磁记忆检测信号微弱, 易受到环境噪声等因素影响, 致使直接采集到的信号数据存在离散性和非线性。机器学习方法处理金属磁记忆信号可以有效剔除外部因素对于磁记忆信号的影响, 能够有效提升检测效率与准确度<sup>[16]</sup>。

### 2.1 基于机器学习的金属磁记忆特征提取

传统特征提取方法虽然能够适用于大部分金属磁记忆检测信号特征提取, 但是对于复杂工况下的金属磁记忆检测信号, 则存在着函数选取困难或不具备自适应性等问题。机器学习方法可以通过数据融合将金属磁记忆信号内部多个特征进行融合再提取新的特征参量, 能够更加精准地识别铁磁材料损伤状态。

朱达荣等<sup>[17]</sup>以小波算法作为多尺度工具, 结合金属磁记忆信号小波包能量、奇异性指数以及梯度峰值, 融合多特征量来评估疲劳损伤, 弥补了单一特征量的不足, 实现了疲劳损伤的量化评估。ZHANG等<sup>[18]</sup>采集了不同温度应力下的无缝钢轨表面的磁记忆信号, 将钢轨应力温度曲线中包含的信息敏感范围和标准差作为时域特征, 同时提取磁记忆信号小波包能量信息作为频域特征, 结合时频和频域特征, 能够准确地检测不同应力分区的三个工况段温度应力。胥永刚等<sup>[19]</sup>选择采用二进递推法构造磁记忆信号矩阵, 通过多次重复奇异值分解获得不同分辨率的近似信号和细节信号, 实现了磁记忆信号的降噪。邢海燕<sup>[20]</sup>等结合切向梯度和法向梯度值提出了对磁损伤信号更为敏感的正交矢量合成梯度比 $K_r$ , 并基于模糊隶属度函数和无偏灰色预测理论建立模糊加权的马尔科夫链预测模型, 使最大相对误差从38.4925%降低到5.0464%, 能够有效地对焊缝隐形损伤进行识别。

目前针对金属磁记忆信号的微弱性和非线性, 多采用基于算法的多特征参量数据融合方法, 其能够把应力集中特征和缺陷信息相互融合以突出所需信号信息, 提升疲劳损伤检测识别的准确率。未来除了融合同源数据进行非线性信号过程的特征提取之外, 还可以在算法和多源数据融合方法上加以提

升与应用,如结合其他无损检测特征参数和磁记忆检测信号数据建立多源数据融合模型。这样提取的特征不仅具有更高的可压缩性和更高的分类准确性,而且更有利于构建高效的损伤评估模型。

## 2.2 基于机器学习的金属磁记忆定量识别

金属磁记忆检测的显著优势是能够对以应力集中为特点的损伤进行检测,但是难以通过其单一特征量准确判断损伤程度与损伤位置。应用机器学习方法对金属磁记忆信号进行特征分析并构建损伤分析模型,可以显著提升其准确度。目前磁记忆定量化检测中应用较为广泛的方法有支持向量机算法与神经网络方法。

### 2.2.1 支持向量机法的应用

朱红运等<sup>[21]</sup>采用类别可分性准则,基于金属磁记忆信号小波能量谱特征变换提取最优特征向量,可减少小波能量谱特征的冗余性和相关性,最优特征向量识别率为81.7%。采用类别可分性准则虽然能够直接进行特征参数提取,但支持向量选取精度过低或存在不稳定问题,通过参数寻优法可以避免上述问题,提升抗噪性、鲁棒性和分类识别率。邢海燕等<sup>[22]</sup>结合支持向量机和KNN(K-邻近算法)隶属度建立了金属磁记忆定量识别模型,并采用参数组合寻优法对模型核函数参数 $g$ 与惩罚因子 $c$ 进行寻优,分类识别准确率达91.67%。GONG等<sup>[23]</sup>将自适应遗传算法与支持向量机算法结合建立了新的定量识别模型,用于识别管道是否处于应力集中状态或是否存在裂纹,径向基函数核准确率达到95.52%。

传统金属磁记忆检测方法对一些较浅的显性损伤或隐形损伤进行检测时,得到的金属磁记忆信号切向分量和法向分量曲线表现出离散性和不确定性,直接用于评估损伤时的准确率较低。支持向量机法可以在计算过程中抓住关键样本、剔除大量冗余样本,其计算复杂度取决于支持向量数目,能够有效避免维数灾难,算法应用简单且具有较好的鲁棒性,非常适合用于金属磁记忆检测信号处理,但是支持向量机法对参数和核函数选择敏感,可在支持向量机法的基础上融合其他算法或者进行算法改进,以弥补单种方法的不足。

### 2.2.2 神经网络的应用

神经网络是近年发展起来的一种高效特征识别和分类方法,其通过对生物神经系统网络行为特征进行模仿,进行分布式并行监督数据处理,拥有较强的自适应能力以及学习能力,是金属磁记忆检测中

应用较多的机器学习方法之一。

BP神经网络是目前应用最广泛的多层感知神经网络,最常用的三层BP神经网络由输入层、隐含层和输出层构成,其核心是通过输入和输出层的传递与修正误差来调节参数逼近期望的输入输出映射关系。史小东等<sup>[24]</sup>将金属磁记忆多特征参数作为输入层建立3层BP神经网络模型进行学习,发现训练样本与测试样本重合度高,且不同损伤部位及不同信号的分布差异较大。LIU等<sup>[25]</sup>建立3层BP神经网络模型对管道裂纹的几何参数进行了量化识别,识别准确率达95%。

BP神经网络虽然收敛过程稳定,但数据量大时,其计算过程中收敛速度过慢,以及存在易陷入局部最优而无法求解的问题。小波神经网络在BP神经网络的基础上,引入小波函数作为中间隐含层的神经元激励函数,收敛速度、逼近精度以及泛化能力等方面均得到了显著提升。王连华等<sup>[26]</sup>建立了基于小波神经网络的缺陷量化方法,效果较传统BP神经网络的更加理想。为实现磁记忆检测中对缺陷承受的拉伸载荷、缺陷宽度及深度的识别,王帅等<sup>[27]</sup>将主成分分析与遗传算法优化神经网络法进行有机结合,同时利用遗传算法改进神经网络对其求解优化,实现了对磁记忆信号的定量识别。考虑到神经网络机器学习模型总是在实验室中(通过高性能计算机硬件系统)实施,以MENG等<sup>[28]</sup>基于智能图像识别和磁记忆技术,开发了一种嵌入轻量级深度学习模型并配备微磁传感器的电缆检测方法,利用SqueezeNet卷积神经网络模型,结合图像去噪算法和迁移学习方法,识别出5种斜拉索表面缺陷及其特征,识别准确率达97.18%。

神经网络方法能有效地识别处理金属磁记忆检测数据,但要求较多的学习样本才能够保证其准确性,而金属磁记忆检测方法在检测环境准备和数据采集方面工作量较大,当神经元的数目较多时,神经网络模型训练时间也会较长。因此在训练过程中往往需要进行一些人为的参数调整。利用神经网络机器学习方法首先要解决金属磁记忆信号特征超参数问题、优化调参和减少模型训练时间,从而提高铁磁性材料疲劳损伤状态定量识别率。

### 2.2.3 其他机器学习算法的应用

近年来除了支持向量机、神经网络这些经典算法,还有许多学者将其他机器学习算法应用于金属磁记忆检测定量识别中,并且取得了良好的效果。

刑海燕等近年来将以下机器学习算法应用于金属磁记忆信号定量识别中<sup>[29-34]</sup>: ① 基于免疫算法结合动态模糊聚类算法相似准则提出损伤识别模型, 该模型很好地避免了单一聚类算法易陷入局部最优值的问题, 能够有效地识别焊缝疲劳损伤各阶段, 模型预测准确率达90%; ② 基于模糊C均值聚类算法的焊缝等级定量识别模型, 焊缝损伤识别准确率达90%; ③ 基于粒子群优化模糊C均值聚类算法(FCM)焊缝等级定量识别模型, 模型分类识别率达97.93%; ④ 改进的最大似然估计(MLE)定量识别模型, 其平均不确定度为3.66%。

各类机器学习算法在金属磁记忆检测应用中的优缺点比较如表1所示, 可见, 除常用的支持向量机法、神经网络算法, 其他机器学习方法也能够很好地应用于信号处理分析, 例如梯度算法、主成分分析、聚类分析算法等。这些方法能够根据金属磁记忆信号特点和缺陷特征参数建立针对性的识别方案, 不但能很好地定位铁磁性材料缺陷位置, 还能提高缺陷识别准确率及缺陷尺寸的检测精度。所以在进行信号处理时, 应综合考虑环境、设备、人为干扰等情况, 提出有针对性的缺陷评估方法。

表1 各类机器学习算法在金属磁记忆检测应用中的优缺点比较

机器学习算法	优点	缺点
支持向量机法 <sup>[21-23]</sup>	可以解决高维问题、小样本下机器学习问题; 能够处理非线性特征的相互作用; 无局部极小值问题; 相对于神经网络等算法无需依赖整体数据; 泛化能力比较强。	处理大数据样本效率不高; 对非线性问题缺乏通用解决方案, 寻找合适的核函数比较困难; 对核函数的高维映射解释力不强, 尤其是径向基函数; 只支持二分类; 对缺失数据敏感。
神经网络算法 <sup>[24-28]</sup>	分类的准确度高; 良好的并行分布处理能力、分布式存储和学习能力, 对含噪声的神经数据具有强大的鲁棒性和容错性, 能有效逼近复杂的非线性关系, 同时还具备联想记忆能力。	需要输入大量样本进行学习, 学习时间过长; 无法观察中间的学习过程, 难以解释所得到的输出结果, 从而影响结果的可信度和可接受度。
主成分分析 <sup>[27]</sup>	降维效果明显, 使得数据集更易使用; 降低算法的计算开销; 能够有效去除噪声; 使得结果容易理解; 完全无参数限制。	对异常值敏感, 可能会导致主成分偏离; 特征值分解存在限制, 变换矩阵须是方阵; 数据集在不满足高斯分布的情况下, 所求得主元在非高斯分布可能并非最优。
模糊C均值聚类算法 <sup>[30-31]</sup>	节省了多重迭代的重复计算过程, 效率明显提高; 可提取数据库中的数据形成模糊相似矩阵, 无需反复扫描数据库; 适用于高维度数据的处理, 具有较好的伸缩性, 便于找出异常点。	$m$ 值(确定数据点隶属权值的指数)具有不确定性, 人为设置 $m$ 值可能影响试验结果; 初始聚类中心存在敏感性, 易陷入局部最优。
最大似然估计法 <sup>[32-33]</sup>	原理简单应用范围广, 样本数据越大, 对参数的估计值越接近真实值, 并且估计值的极限分布也越接近正态分布。	对数据分布的假设要求较高, 训练数据较少时会发生过拟合, 估计的参数可能不准确。
梯度下降算法 <sup>[34]</sup>	低泛化误差; 容易实现, 分类准确率较高, 没有太多参数可以调整。	易陷入局部极小值; 对异常值比较敏感; 训练时间过长, 执行效果依赖于弱分类器的选择。

### 2.3 机器学习应用于金属磁记忆剩余寿命预测

剩余寿命预测是设备服役过程中的重要工序, 通过了解设备状况、预测其失效机制和剩余寿命能够有效地预防疲劳损伤破坏所带来的损失。目前大多数研究仍然依靠较为系统和全面的疲劳试验, 并基于试验数据使用传统疲劳寿命预测方法进行剩余寿命预测, 不仅耗费巨大的时间成本与人力成本, 而且难以作为技术基准来对在役机械设备、构件疲劳损伤状况进行检测评估。通过提取金属磁记忆信号特征参数进行机器学习, 总结发现损伤规律, 可精准有效地对剩余寿命进行预测, 为金属构件疲劳损伤状态评估提供更高效的技术支撑。

为了评估油井套管的危险程度, LIU等<sup>[25]</sup>对12组油井套管的金属磁记忆信号降噪处理后进行特征值提取, 建立了磁特征参数和危险程度间的支持向量机识别模型, 准确率达100%。黄海鸿等<sup>[35]</sup>使用ABAQUS软件建模进行汽车车桥桥壳有限元疲劳

寿命仿真分析, 提取零件疲劳危险区中表征疲劳损伤程度的金属磁记忆信号法向分量梯度最大值、裂纹长度、应力强度因子、应力集中度等作为参数, 建立了基于支持向量机法的寿命预测模型。吴家风<sup>[36]</sup>开展了基于GM(1, 1)模型的灰色疲劳寿命预测模型, 有效地预估了疲劳寿命。SU等<sup>[37]</sup>基于朴素贝叶斯分类算法建立模型, 实现了腐蚀桥梁钢归一化疲劳寿命统计评估。GAO等<sup>[38]</sup>提出了一种基于金属磁记忆检测的优化支持向量机新模型, 建立了基于支持向量机模型的再制造抽油杆剩余寿命预测模型, 并采用遗传算法、粒子群算法和网格搜索算法依次对径向基函数核参数和惩罚因子进行优化, 预测值与实测值的平均偏差在5%以内。

通过支持向量机法、贝叶斯分类法以及多种算法融合的金属磁记忆信号机器学习方法建立寿命预测模型, 能够有效、准确地预测铁磁性材料的剩余寿命。但在工程实践中, 寿命预测准确率和金属磁记

忆信号特征指标具有强关联性, 需要更大的测试数据集来验证最优方法的实用性和可靠性, 以此优化和改进当前的预测模型。

### 3 结论和展望

对机器学习方法在金属磁记忆检测中的应用进行了综述, 其中在金属磁记忆信号数据模型构建中应用最为广泛的机器学习方法包含支持向量机、神经网络以及其他融合优化学习算法, 主要应用于铁磁构件损伤的信号特征提取、定量识别和剩余寿命预测中。未来, 机器学习方法在金属磁记忆检测中的应用将主要集中于以下几个方面。

(1) 金属磁记忆检测信号具有较强的非线性, 可以通过融合神经网络模型或是支持向量机、主成分分析法等先进的处理方法提取信号特征。由于金属磁记忆信号的峰值、功率谱和频带能量等特征易受到高斯噪声的影响, 随着计算机计算速度的进一步提高和人工智能的发展, 对各类现有算法进行机器学习并将新算法应用到金属磁记忆检测中将成为未来发展的趋势。

(2) 当前机器学习在金属磁记忆检测中的应用多聚焦于缺陷的定量分类识别, 即通过提取金属磁记忆信号特征参数, 引入算法提取特征信号数据, 建立起磁特征参数与缺陷间的定量关系模型, 实现缺陷的定量化识别, 并能够将其进一步拓展至剩余寿命预测中。

(3) 近年来机器学习算法在无损检测领域已经取得了一定的发展, 但实际工程应用场景往往比实验室更加复杂, 机器学习算法种类繁多, 每种算法都存在自身的优劣和适用范围, 没有哪一种算法能够解决全部的问题。通过融合多种机器学习算法的自身优势, 能够更加有效地提升模型的适应性和金属磁记忆检测的缺陷识别能力。

### 参考文献:

[1] 张栋, 钟培道, 陶春虎, 等. 失效分析[M]. 北京: 国防工业出版社, 2004.

[2] 卢兵兵, 王海斗, 董丽虹, 等. 金属磁记忆疲劳损伤检测的应用现状及发展前景[J]. 材料导报, 2021, 35 (7):7139-7144.

[3] 任吉林. 金属磁记忆检测技术[M]. 北京: 中国电力出版社, 2000.

[4] WANG Y Q, XU J P, SHI Y, et al. Research on the application of wavelet entropy theory in detecting metal magnetic memory[J]. Applied Mechanics and Materials, 2013, 401: 1212-1217.

[5] 王长龙, 朱红运, 徐超, 等. 自适应小波阈值在磁记忆信号降噪处理中的应用[J]. 系统工程与电子技术, 2012, 34(8): 1555-1559.

[6] 蔡少川. 经验模态分解在管道缺陷漏磁检测信号处理中的应用研究[J]. 中国机械工程, 2006, 17(21): 2201-2203.

[7] 梁志芳, 李午申, 王迎娜, 等. 焊接裂纹的金属磁记忆信号特征[J]. 天津大学学报, 2006, 39(6): 181-184.

[8] XIAO M L, HONG S D, SHI W B. Research on the stress-magnetism effect of ferromagnetic materials based on three-dimensional magnetic flux leakage testing[J]. NDT & E International, 2014, 62: 50-54.

[9] 任吉林, 范振中, 陈曦, 等. 基于小波包变换的磁记忆信号特征值的提取[J]. 无损检测, 2008, 30(9): 184-186.

[10] 王继革, 王文江, 郭爽. 金属磁记忆信号特征量提取中的Lipschitz指数法[J]. 无损检测, 2008, 30(8): 494-497.

[11] LIU S, YONG Q, HE D, et al. A new feature of magnetic memory signal for quantitative identification of stress concentration[J]. Vibroengineering Procedia, 2021, 38: 107-112.

[12] 朱红运, 王长龙, 徐超. 基于Wigner-Ville分布及局部奇异值分解的磁记忆信号特征提取与识别[J]. 军械工程学院学报, 2012, 24(2): 40-43.

[13] 王太勇, 刘兴荣, 秦旭达, 等. 谱熵分析方法在漏磁信号特征提取中的应用[J]. 天津大学学报, 2004, 37(3): 216-220.

[14] 邢海燕, 葛桦, 韩亚潼, 等. 基于熵带与DS理论的焊缝等级磁记忆量化评价[J]. 仪器仪表学报, 2016, 37 (3): 610-616.

[15] 刘涛, 鲍宏, 朱达荣, 等. 基于磁记忆和表面纹理特征融合的再制造毛坯疲劳损伤评估[J]. 中国机械工程, 2018, 29(13): 1615.

[16] 杨茂, 张洪, 周建庭, 等. 机器学习在磁记忆无损检测领域的应用及展望[J]. 重庆交通大学学报(自然科学版), 2022, 41(8): 58.

[17] 朱达荣, 潘志远, 刘涛, 等. 金属疲劳过程磁记忆信号多特征量提取研究[J]. 现代制造工程, 2018 (10): 123-129.

[18] ZHANG Y, HU D, CHEN J, et al. Research on non-destructive testing of stress in ferromagnetic components based on metal magnetic memory and the Barkhausen effect[J]. NDT & E International, 2023, 138: 102881.

[19] 胥永刚, 谢志聪, 孟志鹏, 等. 基于奇异值分解的磁记忆信号特征提取方法[J]. 振动. 测试与诊断, 2014, 34 (6): 1105-1109.

[20] 邢海燕, 孙晓军, 王犇, 等. 基于模糊加权马尔科夫链的焊缝隐性损伤磁记忆特征参数定量预测[J]. 机械工程学报, 2017, 53(12): 70-77.

[21] 朱红运, 王长龙, 于卫刚, 等. 基于类别可分性准则的金属磁记忆信号小波能量谱特征提取研究[J]. 军械工程学院学报, 2011, 23(6): 25-28.

[22] 邢海燕, 党永斌, 王犇, 等. 基于K-近邻隶属度模糊支持向量机的再造抽油杆损伤等级磁记忆定量识别[J]. 石油学报, 2015(11): 1427-1432.

[23] GONG L, LI Z, ZHANG Z. Diagnosis model of pipeline cracks according to metal magnetic memory signals based on adaptive genetic algorithm and support vector machine[J]. The Open Mechanical Engineering Journal, 2015, 9(1): 55-58.

[24] 史小东, 樊建春, 周威, 等. 基于BP神经网络管道磁记忆检测模式识别[J]. 石油机械, 2020, 48(6): 111-117.

[25] LIU Z L, LIU L T, ZHANG J. Signal feature extraction and quantitative evaluation of metal magnetic memory testing for oil well casing based on data preprocessing technique[J]. Abstract and Applied Analysis, 2014, 2014: 902304.

[26] 王连华, 吴静, 刘新萌, 等. 小波神经网络在三维漏磁检测缺陷量化中的应用[C]//全国无损检测学会超声检测学术交流会暨钢结构检测技术交流会. 上海: 中国机械工程学会无损检测分会, 2016.

[27] 王帅, 黄海鸿, 韩刚, 等. 基于PCA与GA-BP神经网络的磁记忆信号定量评价[J]. 电子测量与仪器学报, 2018, 32(10): 190.

[28] MENG Q, ZHANG Y, WANG H, et al. A detection method for bridge cables based on intelligent image recognition and magnetic-memory technology[J]. Journal of Performance of Constructed Facilities, 2022, 36(6): 04022059.

[29] 邢海燕, 陈玉环, 李雪峰, 等. 基于动态免疫模糊聚类的金属焊缝缺陷等级磁记忆识别模型[J]. 仪器仪表学报, 2022, 40(11): 225-232.

[30] 邢海燕, 刘超, 徐成, 等. 基于粒子群优化模糊C焊缝等级磁记忆定量识别模型[J]. 吉林大学学报(工学版), 2022, 52(3): 525-532.

[31] 邢海燕, 喻正帅, 李雪峰, 等. 基于模糊C均值聚类算法的焊缝缺陷等级磁记忆定量识别[J]. 压力容器, 2018, 35(6): 57-63.

[32] XING H Y, GE H, DAI G G, et al. Maximum likelihood estimation modeling of welded joints based on metal magnetic memory parameters[J]. Applied Mechanics and Materials, 2017, 853: 458-462.

[33] XING H, XU C, YI M, et al. Modified maximum likelihood estimation metal magnetic memory quantitative identifying model of weld defect levels based on dempster-shafer theory[J]. Applied Sciences, 2023, 13(13): 7959.

[34] 邢海燕, 戈鸣, 段成凯, 等. 基于改进梯度下降算法优化的磁梯度张量组合不变量算法的管道缺陷边缘识别模型[J]. 中国机械工程, 2023, 34(16): 1915.

[35] 黄海鸿, 孙霄, 汪燕, 等. 基于磁记忆检测的服役铁磁零件剩余寿命预测[J]. 机械设计与研究, 2014, 30(4): 66-70.

[36] 吴家风. 连续油管疲劳损伤磁记忆检测试验及剩余寿命预测方法研究[D]. 北京: 中国石油大学, 2018.

[37] SU S, YANG Y, WANG W, et al. Crack propagation characterization and statistical evaluation of fatigue life for locally corroded bridge steel based on metal magnetic memory method[J]. Journal of Magnetism and Magnetic Materials, 2021, 536: 168136.

[38] GAO Y T, LENG J C, LI S Q. Residual life prediction method for remanufacturing sucker rods based on magnetic memory testing and a support vector machine model[J]. Insight-Non-Destructive Testing and Condition Monitoring, 2019, 61(1): 44-50.