

基于ResGNNet多模态融合的油气管道缺陷等级磁记忆定量识别

邢海燕¹ 武雪缘¹ 蔡智会² 赵力伟^{2*} 苏田¹ 韩晴¹

1. 东北石油大学机械科学与工程学院, 大庆, 163318

2. 温州市特种设备检测科学研究院, 温州, 325038

摘要: 针对油气管道磁记忆信号特征自动提取及缺陷等级定量识别难题, 提出一种结合残差神经网络和图神经网络的多模态融合模型即 ResGNNet 模型。采用金属磁记忆检测仪采集 L245N 管线钢不同深度缺陷的磁记忆原始信号。为实现特征的自动提取, 保留原始磁记忆信号的完整信息并考虑样本之间的相互关系, 利用 K 近邻-动态时间规整将原始信号转换成节点图, 并利用格拉姆角场将原始信号转换成二维图像。设计的图神经网络、残差神经网络可分别自动提取一维信号和二维图像的嵌入特征向量。融合多模态嵌入特征向量经多头自注意力机制加权筛选后, 输入 Softmax 分级模块, 完成缺陷等级识别。模型验证结果表明, 管道缺陷等级定量识别的准确率达到 93%。

关键词: 油气管道; 金属磁记忆技术; 缺陷等级; 图神经网络; 残差神经网络

中图分类号: TG115.284

DOI:10.3969/j.issn.1004-132X.2025.09.027

开放科学(资源服务)标识码(OSID):



Quantitative Identification of Oil and Gas Pipeline Defect Levels Based on Magnetic Memory Using ResGNNet Multi-modal Fusions

XING Haiyan¹ WU Xueyuan¹ CAI Zhihui² ZHAO Liwei^{2*} SU Tian¹ HAN Qing¹

1. School of Mechanical Science and Engineering, Northeast Petroleum University, Daqing, Heilongjiang, 163318

2. Wenzhou Special Equipment Inspection & Science Research Institute, Wenzhou, Zhejiang, 325038

Abstract: Aiming at the problems of automatic extraction of magnetic memory signal features and quantitative identification of defect levels in oil and gas pipelines, a multimodal fusion model was proposed combining residual neural network and graph neural network (ResGNNet). The original magnetic memory signals of defects of different depths on L245N pipeline steels were collected by metal magnetic memory detector. In order to realize automatic feature extraction, the complete information of the original magnetic memory signals was retained, and the relationship among samples was taken into account. The original signals were converted into a node graph by K nearest neighbor-dynamic time warping, and the original signals were converted into a 2D image by Gram angle field. The designed graph neural network and residual neural network may automatically extract the embedded feature vectors of 1D signals and 2D images respectively. The multimodal embedded feature vectors were fused, weighted and screened by multi-head self-attention mechanism, and then input into the Softmax classification module to complete the defect level identification. The model verification results show that the accuracy of quantitative identification of pipeline defect levels reaches 93%.

Key words: oil and gas pipeline; metal magnetic memory technology; defect level; graph neural network; residual neural network

0 引言

长输油气管道是解决当前油气产销区域矛盾的主要手段, 对资源调配有重要意义。油气管道损伤往往导致泄漏、爆炸事故, 造成巨大的经济损

失和人员伤亡, 因此, 高效、准确评估油气管道损伤程度是保障管道安全、降低运营风险的关键。

目前常用的油气管道检测方法有涡流、漏磁、超声, 它们分别存在趋肤效应、周向磁化困难、阻抗不匹配等检测障碍, 大都只能检测发展成形的宏观缺陷。金属磁记忆检测^[1]是一种新型无损检测技术, 不仅能检测宏观缺陷, 还能检测早期应力集中与隐性损伤^[2], 对管道早期损伤检测具有独

收稿日期: 2024-07-24

基金项目: 国家自然科学基金(11272084); 黑龙江省自然科学基金(LH2024E012); 温州市市场监督管理局科研计划(2024011)

特的优势。赵秉勋等^[3]基于腐蚀损伤机理,建立了腐蚀-力-磁耦合模型,通过实验测量和有限元分析研究了纯腐蚀及应力腐蚀下的漏磁信号特征与变化规律。湛立宁等^[4]对埋地燃气管道进行金属磁记忆检测,开挖验证及超声波测厚对比证明了金属磁记忆技术对埋地管道损伤检测的有效性。焦杨^[5]使用非接触磁记忆技术检测了2条埋地钢质管道,并进行开挖验证,发现磁记忆检测技术能准确查找管道存在的应力集中点和腐蚀缺陷点。石明江等^[6]基于磁记忆技术,利用优化的BP神经网络实现了金属管道的缺陷尺寸反演。万勇等^[7]基于金属磁记忆技术,建立了识别管道腐蚀缺陷和早期应力集中缺陷的多特征量统计识别方法。王贵生等^[8]采用支持向量机建立了管道缺陷的分类识别模型,并识别了穿孔腐蚀与未穿孔腐蚀。根据油气管道原始磁记忆信号可识别局部异常应力集中位置,但不同损伤程度的缺陷均表现为信号突变。现有信号特征提取方法主要依靠人工,存在表征能力有限且主观性强的问题,难以自动提取缺陷特征、识别缺陷等级。

针对油气管道磁记忆信号自动特征提取及缺陷等级定量识别难题,本文提出一种结合残差神经网络和图神经网络的多模态特征融合模型。为避免人工特征提取表征能力有限且主观性强的问题,同时保留原始信号的完整信息,并考虑样本之间的相互关系,采用K近邻-动态时间规整(K nearest neighbor-dynamic time warping, K-DTW)、格拉姆角场(Gramian angular field, GAF)将原始磁记忆信号分别转换成节点图和二维图像。将节点图、二维图像分别输入图神经网络(graph neural network, GNN)和残差神经网络(residual network, ResNet)自动提取样本的多模态嵌入特征向量,以补偿不同模态数据的异质性差异,增强算法的鲁棒性和泛化能力。在此基础上,融合提取的多模态嵌入特征向量经过多头自注意力机制加权筛选重要特征后,输入 Softmax 分级模块,实现缺陷等级的定量识别。

1 实验研究

1.1 实验方法

制作了5组材质为L245N管线钢的管道(长度1500 mm、直径350 mm、厚度10 mm)试件。为检测不同等级损伤的磁记忆信号,在管道试件上预制不同深度的缺陷。第1组试件如图1所示,沿管道轴向预制10个缺陷(直径均为4 mm,深度分

别为1、2、...、10 mm),其中,10号缺陷为穿孔。2~5组试件的缺陷直径分别为6、8、10、12 mm,其余参数与第1组试件相同。采用俄罗斯TSC-5M-32型金属磁记忆检测仪与Type 2M型探头,提离距离为2 mm,对每个缺陷进行8个方向的检测。相邻检测方向的夹角为45°,检测方向与检测仪器如图1所示,检测过程如图2所示。




图1 预制不同深度缺陷及检测方向示意图

Fig.1 Schematic diagram of prefabricated defects of different depths and detection directions




图2 缺陷检测示意图

Fig.2 Schematic diagram of defect detection

1.2 实验结果

磁记忆信号是由天然地磁场激励的漏磁信号,受地磁场方向影响。以直径10 mm、深度5 mm的缺陷为例详细说明检测方向的影响,如图3所示。检测方向1~4的磁场切向分量随检测方向不同而呈现衰减性与分散性。由图3、表1可看出,互为相反方向的1与5、2与6、3与7、4与8的磁场切向分量都呈近似中心对称分布且切向磁场强度峰峰值相近,磁场法向分量与切向分量变化规律近似一致,因此,后续数据集的构建应充分考虑检测方向,将各方向的磁记忆信号分别作为独立样本。

以检测方向1、直径8 mm的缺陷为例说明不同损伤程度缺陷的磁记忆信号差异。如图4所示,缺陷深度由1 mm增加至5 mm时,磁场信号切向与法向的峰峰值逐渐增大,缺陷深度与信号峰峰值近似正相关。缺陷深度由6 mm增加至10 mm时,磁场信号切向与法向的峰峰值减小。其他检测方向的磁记忆信号变化规律近似一致,不




图3 同一缺陷8个检测方向的磁场切向分量

Fig.3 Tangential component of the magnetic field for the same defect in 8 detection directions

表1 同一缺陷8个检测方向的磁场切向分量峰峰值

Tab.1 Peak-to-peak values of the tangential component of the magnetic field for the same defect in 8

detection directions

检测方向	1	2	3	4
峰峰值 $H_{pp}/(A \cdot mm^{-1})$	28.1	11.6	21.2	36.3
检测方向	5	6	7	8
峰峰值 $H_{pp}/(A \cdot mm^{-1})$	26.5	9.8	22.9	34.5




图4 同一检测方向下不同深度缺陷的磁场峰峰值

Fig.4 Magnetic field peak-to-peak values for defects of different depths in the same detection direction

再重复叙述。故直接利用磁记忆信号原始数据无法判别管道的缺陷损伤等级。

2 基于 ResGNNet 多模态融合的缺陷等级定量识别模型

本文提出的 ResGNNet 多模态融合模型架构主要包含一维信号和二维图像特征提取模块、多模态特征融合模块、Softmax 分级模块,如图 5 所示。首先,磁记忆样本数据通过 K-DTW 和 GAF 分别转换为一维信号节点图和二维图像。将转换后的数据分别输入图神经网络和残差神经网络,自动提取样本的多模态嵌入特征向量,以补偿不同模态数据的异质性差异。在此基础上,融合提

取到的多模态嵌入特征向量经多头自注意力机制加权筛选重要特征后,输入 Softmax 分级模块,识别缺陷损伤等级。

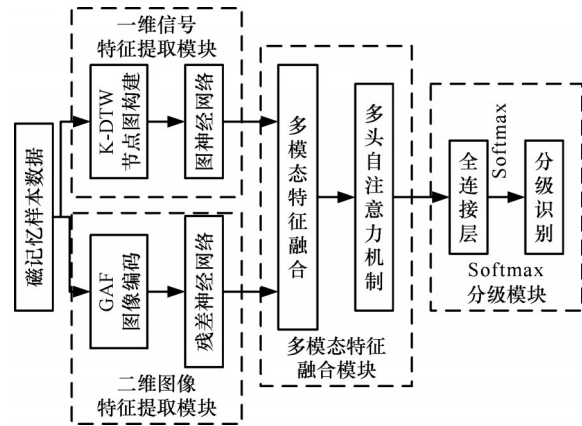


图5 ResGNNet 模型架构

Fig.5 ResGNNet model architecture

2.1 一维信号特征提取模块

2.1.1 K-DTW 节点图构建

磁记忆一维信号无法直接输入图神经网络进行特征提取,需将其构造为图结构。K-近邻构图法常以欧氏距离衡量信号之间的相似性,但该方法对局部时间偏移较为敏感,同一信号在不同时间对齐状态下获得的相似度也存在较大差异。动态时间规整(dynamic time warping, DTW)通过局部缩放对齐解决局部时间偏移问题,并计算时间序列数据的最优匹配路径,以规整距离衡量数据样本之间相似性^[9]。本文综合考虑 K-近邻和 DTW 的优势,构建 K-DTW 节点图,具体过程如下。

对于给定的 2 个一维磁记忆信号样本,综合考虑切向磁场分量 $H(x)$ 、切向梯度 K_x 、法向磁场分量 $H(y)$ 、法向梯度 K_y ,按照 $H(x) \rightarrow K_x \rightarrow H(y) \rightarrow K_y$ 的顺序依次拼接,拼接后的样本分别为 $X = \{x_1, x_2, \dots, x_N\}$ 、 $Y = \{y_1, y_2, \dots, y_M\}$,其中, N 、 M 分别为时间序列 X 和 Y 的长度。 X 和 Y 的相似度计算步骤如下:

1) 构建距离矩阵 $D_{N \times M} = [d_{n,m}]_{N \times M}$,其中,矩阵元素为

$$d_{n,m} = |x_n - y_m| \quad (1)$$

$$n=1,2,\dots,N \quad m=1,2,\dots,M$$

2) 通过动态规划算法在 $D_{N \times M}$ 中寻找从 $d_{1,1}$ 到 $d_{n,m}$ 的最短累积距离路径,其递推公式为

$$\tilde{D}_{n,m} = d_{n,m} + \min(\tilde{D}_{n-1,m-1}, \tilde{D}_{n-1,m}, \tilde{D}_{n,m-1}) \quad (2)$$

式中: $\tilde{D}_{n,m}$ 为从起点到矩阵位置 (n,m) 的最短累积距离。

3) 将搜索得到的最短累积距离作为信号 X 和 Y 之间的相似性度量指标。最短累积距离越小,

信号间相似性越高。

每个样本视为一个节点,将样本间的动态时间规整(DTW)距离按升序排序,根据K近邻准则,将与所求样本相似度最高的 k 个样本作为其邻居:

$$Ne(v_i) = K-DTW(k, v_i, \phi) \quad (3)$$

$$\phi = \{v_{i+1}, v_{i+2}, \dots, v_{i+m}\}$$

其中, $K-DTW(*)$ 返回子集 ϕ 中与节点 v_i 相似度最高的 k 个样本。节点 v_i 与节点 v_j 的边权重 l_{ij} 可用高斯核权函数估计:

$$l_{ij} = \exp\left(-\frac{[DTW(v_i, v_j)]^2}{2\xi^2}\right) \quad v_j \in Ne(v_i) \quad (4)$$

式中: $DTW(v_i, v_j)$ 为节点 v_i 与节点 v_j 之间的动态时间规整距离; ξ 为高斯核的带宽。

形成的邻接矩阵用坐标格式(Coordinate, COO)表示以节省存储空间。节点图构建过程如图6所示。

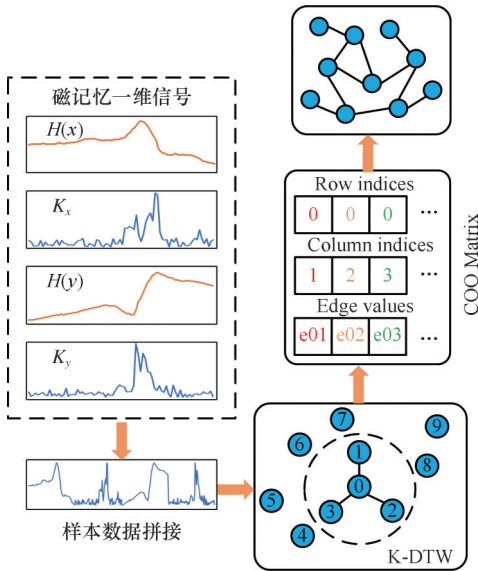


图6 基于K-DTW的节点图构建

Fig.6 Constructed based on K-DTW node graphs

2.1.2 图神经网络

缺陷损伤等级识别任务中,磁记忆信号存在不同等级样本间相似、相同等级样本离散性较高问题。图神经网络(GNN)基于节点消息传递机制,通过邻接节点更新节点特征向量,使相同等级缺陷样本间的特征相似度增大、不同等级缺陷样本间的特征相似度减小。因此,将基于K-DTW构建的节点图输入GNN,得到样本嵌入特征向量,使同等级样本间的特征距离减小、不同等级样本间的特征距离增大,从而提高模型的分级识别性能。

本文采用图卷积神经网络(graph convolutional network, GCN)^[10]提取一维信号特征。设计的GCN模型堆叠了2个图卷积层,如图7所示,

以节点特征矩阵 Z 和邻接矩阵 A 为输入。GCN的层与层之间的传播方式为

$$H_{l+1} = \sigma(\hat{D}^{-1/2} \hat{A} \hat{D}^{-1/2} H_l W_l) \quad (5)$$

$$\hat{A} = A + I$$

式中: I 为单位矩阵; \hat{D} 为 \hat{A} 的度矩阵; $\sigma(*)$ 为非线性激活函数; W_l 为第 l 层的权重矩阵; H_l 表示第 l 层节点的特征,对于输入层, $H=Z$ 。




图7 图神经网络结构图

Fig.7 Structure of graph neural network structure

2.2 二维图像特征提取模块

2.2.1 GAF图像编码

二维图像数据包含更丰富的缺陷信息,为最大程度保留原始信号的完整信息和特征,采用格拉姆角场GAF^[11]将磁记忆数据转换为二维图像进行自动特征提取,如图8所示。

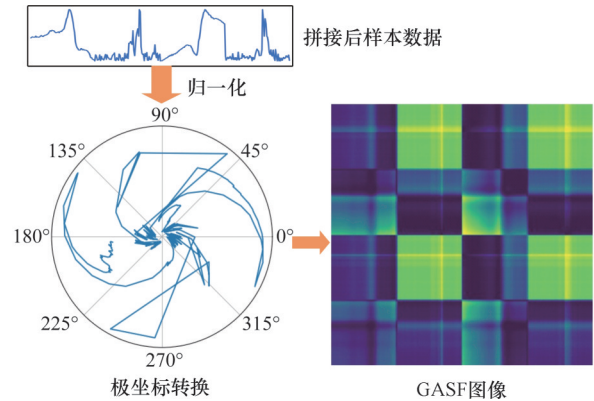


图8 GAF图像编码示意图

Fig.8 Schematic diagram of GAF image coding

具体转换过程如下:对于给定的一维磁记忆信号样本,依次拼接切向磁场分量、切向梯度、法向磁场分量、法向梯度,得到样本 X 。通过归一化得到磁记忆数据的第 i 个元素值

$$\tilde{x}_i = \frac{2x_i - \max X - \min X}{\max X - \min X} \quad (6)$$

式中: x_i 为磁记忆信号样本数据的第 i 个实测值。

然后通过下式:

$$\left. \begin{aligned} \varphi_i &= \arccos \tilde{x}_i, \tilde{x}_i \in \tilde{X} \\ r_i &= t_i/B \end{aligned} \right\} \quad (7)$$

式中： φ_i, r_i 分别为第*i*个元素在极坐标系中的极角和极径； \tilde{X} 为归一化后的磁记忆信号样本； t_i 为时间戳； B 为时间戳的总长度，即信号序列的长度。

在极坐标系中用 φ_i 和 r_i 表示 \tilde{x}_i 。最后根据编码过程中采用的不同三角函数，得到格拉姆角和场(Gramian angular summation fields, GASF)和格拉姆角差场(Gramian angular difference fields, GADF)。本文采用GASF，其矩阵为

$$T = \begin{bmatrix} \cos(\varphi_1 + \varphi_1) & \cos(\varphi_1 + \varphi_2) & \cdots & \cos(\varphi_1 + \varphi_n) \\ \cos(\varphi_2 + \varphi_1) & \cos(\varphi_2 + \varphi_2) & \cdots & \cos(\varphi_2 + \varphi_n) \\ \vdots & \vdots & \ddots & \vdots \\ \cos(\varphi_n + \varphi_1) & \cos(\varphi_n + \varphi_2) & \cdots & \cos(\varphi_n + \varphi_n) \end{bmatrix} \quad (8)$$

2.2.2 残差神经网络

传统的卷积神经网络在训练过程中会出现信息丢失、梯度消失或爆炸的问题。为解决上述问题，HE等^[12]借助提出的残差神经网络，通过引入残差连接来有效缓解梯度消失问题，增强信息的传递能力，从而提高深层网络结构的训练稳定性与收敛速度。

Resnet18复杂度较高，故对其进行改进以避免过拟合。如图9所示，笔者设计的Resnet模型由多个残差块(Resblocks)和平均池化层(Avgpool)组成，用于提取二维图像的特征。每个Resblock包括3个二维卷积(Conv2D)层、3个批处理归一化(BN)层、3个激活函数ReLU，其中， 1×1 的卷积层(1×1 Conv2D)用于调整输入特征的通道数和空间尺寸。每个Resblock中，BN层抑制内部协变量移位并平滑损失面^[13]。BN的原理如下式所示：

$$\hat{z}_i = \gamma_i \frac{z_i - \mu_B}{\sqrt{\sigma_B^2 + \epsilon}} + \beta_i \quad (9)$$

$$\mu_B = \frac{1}{n_B} \sum_{i=1}^{n_B} z_i \quad (10)$$

$$\sigma_B = \sqrt{\frac{1}{n_B} \sum_{i=1}^{n_B} (z_i - \mu_B)^2} \quad (11)$$

式中： z_i 为第*i*个样本的数值； \hat{z}_i 为标准化后的数值； γ_i, β_i 为可学习的参数，初始值分别为1和0； ϵ 为超参数， $\epsilon = 10^{-5}$ ； n_B 为批量处理的大小。

2.3 多模态特征融合模块

2.3.1 多模态特征融合

为充分表征原始磁记忆信号的特征，将提取到的一维信号和二维图像特征进行融合：

$$F_{\text{join}} = \text{Concat}(F_{1D}, F_{2D}) \quad (12)$$

式中： F_{join} 为拼接融合的特征； $\text{Concat}(\ast)$ 为拼接函数； F_{1D}

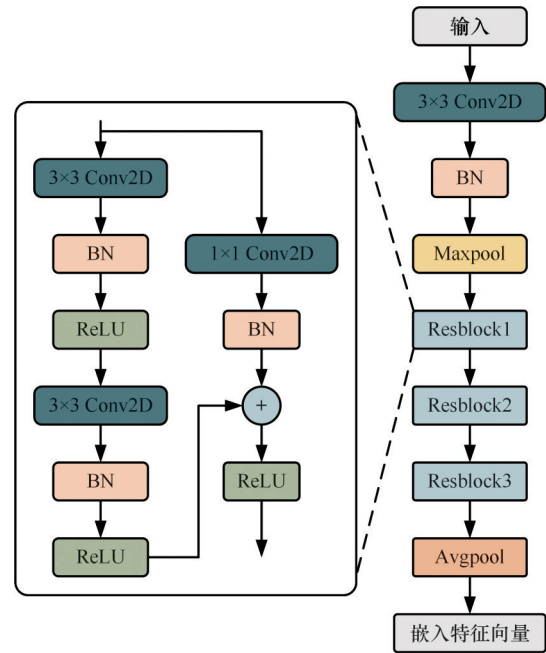


图9 残差神经网络结构图

Fig.9 Structure of residual neural network

为一维信号特征； F_{2D} 为二维图像特征。

2.3.2 多头自注意力机制

融合特征 F_{join} 的数量增加一倍，但各特征对分级识别任务的贡献度并不相同，故引入多头自注意力机制加权筛选重要的融合特征。如图10所示，每个注意力头(数量为*h*)关注融合特征的不同部分，并行计算各自的加权特征输出。最后拼接所有注意力头的输出，综合不同注意力头提取的关键特征信息，有助于提高模型分级识别性能。自注意力机制是注意力机制的变体，更关注输入内部间的关系^[14]。自注意力机制的查询向量Query、键向量Key和值向量Value属于相同的序列，可简写为 Q, K 和 V 。




图10 多头自注意力机制原理图

Fig.10 Schematic diagram of the multiple self-attention mechanism

多头自注意力机制首先采用不同的线性投影矩阵将 Q, K 和 V 投影*h*次。投影结果作为输入并行送到尺度化点积注意力中汇聚，按照下式：

$$head_i = Attention(Q_i, K_i, V_i) = softmax(\frac{Q_i K_i^T}{\sqrt{d_k}}) V_i \quad (13)$$

式中: $Attention(*)$ 为自注意力机制的输出; $softmax(*)$ 为权重归一化函数; d_k 为键向量 K 的维度; 下标 i 表示第 i 个注意力头。

进行自注意力计算。最后将这 h 个自注意力输出拼接在一起, 通过线性投影产生最终输出:

$$MultiHead(Q, K, V) = Concat(head_1, head_2, \dots, head_h) W_o \quad (14)$$

式中: $MultiHead(\cdot)$ 为多头自注意力机制的输出; $Concat(\cdot)$ 为拼接函数; W_o 为可学习的变换矩阵; $Head$ 表示注意力头。

2.4 Softmax 分级模块

将多模态特征融合模块的输出向量输入全连接层, 通过 Softmax 函数得到样本属于某个缺陷等级的概率, 然后根据概率最大原则确定等级。训练阶段使用了交叉熵损失函数:

$$L = - \sum_{i=1}^N y_i \ln(\exp(z_i) / \sum_{j=1}^N \exp(z_j)) + (1 - y_i) \ln(1 - \exp(z_i) / \sum_{j=1}^N \exp(z_j)) \quad (15)$$

式中: L 为损失值; y_i 为 i 级缺陷的真实标签; N 为样本的个数; z_i 为模型的输出的原始数值。

基于该损失函数, 模型通过反向传播机制不断优化网络中的参数, 以最小化预测结果与真实标签之间的误差。式(15)的 $\exp(z_i)$ 确保所有概率为正数, $\sum_{j=1}^N \exp(z_j)$ 使所有类别概率总和为 1。

3 模型实现与验证

3.1 模型参数设置

根据 GB 50251—2015《输气管道工程设计规范》和 GB/T 35090—2018《无损检测管道弱磁检测方法》, 参考文献[4, 15], 将管道按壁厚损失 t 划分为 3 个等级: I 级为高风险 ($t > 40\%$), II 级为中风险 ($20\% < t \leq 40\%$), III 级为低风险 ($t \leq 20\%$)。

实验采用 Windows10 操作系统, 深度学习框架为 PyTorch2.0.1, 硬件包括 13700K 处理器、RTX 4060 显卡和 16G 内存。使用的 400 组数据源于测试, 并按照上述壁厚损失将缺陷划分为 3 个等级。从实验数据中随机抽取 70% 作为训练集, 30% 作为测试集。训练过程中设置批量大小为 32, 最大迭代次数为 100, 学习率设为 0.0001, 损失函数为交叉熵损失函数, 优化器为 Adam 优化器。ResGNet 模型的主要参数如表 2 所示。

3.2 验证结果

将训练集输入到 ResGNet 模型中训练, 并

表 2 ResGNet 模型的主要参数

Tab.2 Main parameters of ResGNet model

网络层	输入通道	输出通道	输出特征图尺寸
Conv2d	3	16	75×75×16
Maxpool			38×38×16
Resblock1	16	32	19×19×32
Resblock2	32	64	10×10×64
Resblock3	64	128	5×5×128
Avgpool			128
GConv1	320	320	320
GConv2	320	128	128
Concat			256
MultiHead			256
FC Layer			3
Softmax			3

在每轮训练完成后, 使用测试集进行评估。得到的训练集和测试集准确率曲线如图 11 所示, 训练集损失曲线如图 12 所示, 可以看出, 模型迭代 100 次后达到收敛状态, 训练集和测试集的最终准确率分别为 99% 和 93%。




图 11 ResGNet 训练和测试准确率

Fig.11 ResGNet training and testing accuracies




图 12 ResGNet 训练损失曲线

Fig.12 ResGNet training loss curve

由表 3 可知, 不同检测方向的缺陷识别准确率存在差异, 相反检测方向的缺陷分级识别准确率较为接近, 如方向 1 和 5。地磁场的方位性造成同一缺陷在不同方位的磁记忆检测信号存在差异, 导致识别准确率相差较大, 如检测方向 1~4。

为直观观察到模型分级识别效果, 采用 T-SNE 算法将训练过程进行可视化降维投影, 并

表3 不同检测方向缺陷等级识别准确率对比
Tab.3 Comparison of defect level identification accuracy in different detection directions

检测方向	1	2	3	4
准确率/%	92.85	86.66	94.66	100.00
检测方向	5	6	7	8
准确率/%	92.31	87.50	93.75	96.44

通过混淆矩阵展示管道缺陷等级的分级识别效果。由图13(坐标轴数值为归一化特征投影维度)可以看出,未经训练的样本无规律散落于全局范围内,训练后的样本呈现同类聚拢、异类分散的状态。由图14可知,ResGNNet模型对I级、II级、III级缺陷的分级识别准确率分别为0.94、0.92、0.92,达到了分级识别的预期效果。

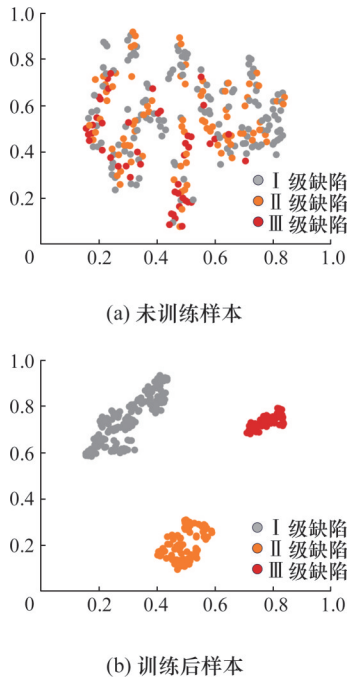


图13 训练前后样本的分布可视化

Fig.13 Visualization of sample distribution before and after training




图14 混淆矩阵

Fig.14 Mixing matrix

进一步分析模型对不同缺陷等级的识别效果,引入评价指标精确率 η_{Pre} 、召回率 η_{Rec} 、F1分数 η_{F1} :

$$\eta_{Pre} = \frac{P_T}{P_T + P_F} \quad (16)$$

$$\eta_{Rec} = \frac{P_T}{P_T + N_F} \quad (17)$$

$$\eta_{F1} = \frac{2P_T}{2P_T + N_F + P_F} \quad (18)$$

式中: P_T 为将正样本预测为正样本的个数; P_F 为将负样本预测为正样本的个数; N_F 为将正样本预测为负样本的个数。

采用每个类别的 η_{Pre} 、 η_{Rec} 、 η_{F1} 宏平均评价模型的综合性能。由表4可以看出,精确率、召回率、F1分数的宏平均均超过90%,表明模型综合性能良好。

表4 模型分级识别性能评估

Tab.4 Model hierarchical recognition performance evaluation %

	精确率	召回率	F1分数
I级缺陷	95.74	93.75	94.74
II级缺陷	91.67	91.67	91.67
III级缺陷	84.62	91.67	88.00
宏平均	90.68	92.36	91.47

3.3 对比分析

为进一步验证 ResGNNet 模型的有效性,将其与单独使用 ResNet 和 GNN 模型进行对比。对比模型的网络层参数与 ResGNNet 模型参数相同,为避免实验结果的偶然性,所有方法均进行5次独立实验并取数据均值为最后结果。对比结果如表5所示。

表5 不同模型分级识别准确率

Tab.5 Different model classification recognition accuracy %

准确率	ResNet	GNN	ResGNNet
训练集	90.12	93.26	99.99
测试集	72.85	78.96	93.33

由表5可以看出,ResGNNet模型在测试集的准确率最高,达到93.33%;单独使用 ResNet 和 GNN 模型的准确率均低于80%。ResGNNet模型对油气管道缺陷分级识别效果明显优于其他两种方法。分析其原因可知,ResGNNet模型能同时提取一维信号和二维图像的多模态特征,补偿了不同模态数据的异质性差异,增强算法的鲁棒性和泛化能力。此外,引入的多头自注意力机制能为有助于缺陷分级识别的特征分配更大权重,进一步提高分级识别的准确率。

4 结论

针对自动提取缺陷特征并识别缺陷等级的难题,提出一种结合残差神经网络和图神经网络的多模态特征融合模型即 ResGNNet 模型。该模型同时自动提取一维信号和二维图像的多模态特征

来补偿不同模态数据的异质性差异,增强算法的鲁棒性和泛化能力。引入的多头自注意力机制从多个角度筛选重要多模态融合特征,提高模型分级识别性能。模型验证结果表明,所提模型在管道缺陷等级量化识别中的准确率达 93%。

参考文献:

[1] DUBOV A A. A Study of Metal Properties Using the Method of Magnetic Memory[J]. Metal Science and Heat Treatment, 1997, 39(9):401-405.

[2] 苏三庆,高志刚,王威. 受拉钢丝应力状态的磁记忆信号峰峰值判别技术[J]. 西安建筑科技大学学报(自然科学版), 2018, 50(2):155-161.

SU Sanqing, GAO Zhigang, WANG Wei. Discrimination of Stress Stage about Steel Wire under Tension Based on Peak-peak Difference Value of Magnetic Memory Signals[J]. Journal of Xi'an University of Architecture and Technology, 2018, 50(2): 155-161.

[3] 赵秉勋. 腐蚀-力-磁耦合模型及金属应力腐蚀的磁记忆方法研究[D]. 北京:北京交通大学, 2022.

ZHAO Bingxun. Research on corrosion-stress-magnetic coupling model and stress corrosion of metal based on magnetic memory method[D]. Beijing: Beijing Jiaotong University, 2022.

[4] 湛立宁,卢俊文,王肖逸,等. 非接触式磁应力检测技术在埋地管道腐蚀评价中的应用[J]. 管道技术与设备, 2023(1):46-50.

ZHAN Lining, LU Junwen, WANG Xiaoyi, et al. Application of Non-contact Magnetic Stress Detection Technology in Corrosion Evaluation of Buried Pipelines[J]. Pipeline Technique and Equipment, 2023(1):46-50.

[5] 焦杨. 非接触式磁记忆检测技术在埋地管道上的应用[J]. 全面腐蚀控制, 2017, 31(11):23-25.

JIAO Yang. Application of Non Contact Magnetic Memory Testing Technology in Buried Pipeline[J]. Total Corrosion Control, 2017, 31(11):23-25.

[6] 石明江,陈瑞,冯林. 基于磁记忆的金属管道缺陷检测方法[J]. 电子测量与仪器学报, 2022, 36(1): 44-53.

SHI Mingjiang, CHEN Rui, FENG Lin. Metal Pipeline Defect Detection Method Based on Magnetic Memory[J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(1):44-53.

[7] 万勇,王宇,杨勇,等. 管道缺陷类型多特征量阈值识别方法[J]. 油气储运, 2020, 39(3):268-276.

WAN Yong, WANG Yu, YANG Yong, et al. Multi-characteristic Threshold Identification Method for Pipeline Defect Types[J]. Oil & Gas Storage and Transportation, 2020, 39(3):268-276.

[8] 王贵生,李炜,杨勇,等. 基于磁记忆信号特征的管道缺陷分类识别和分级识别方法[J]. 腐蚀与防护, 2022, 43(11):68-73.

WANG Guisheng, LI Wei, YANG Yong, et al. Identification Methods for Pipeline Defect Classification and Grading Based on Magnetic Memory Signal Characteristics[J]. Corrosion & Protection, 2022, 43(11):68-73.

[9] WAN Yuan, CHEN Xiaoli, SHI Ying. Adaptive Cost Dynamic Time Warping Distance in Time Series Analysis for Classification[J]. Journal of Computational and Applied Mathematics, 2017, 319: 514-520.

[10] KIPF T N, WELLING M. Semi-supervised Classification with Graph Convolutional Networks [J]. ArXiv e-Prints, 2016;arXiv:1609.02907.

[11] WANG Zhiguang, YAN Weizhong, OATES T. Time Series Classification from Scratch with Deep Neural Networks: a Strong Baseline[C]//2017 International Joint Conference on Neural Networks. Anchorage, 2017:1578-1585.

[12] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Deep Residual Learning for Image Recognition [C]//2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, 2016:770-778.

[13] SANTURKAR S, TSIPRAS D, ILYAS A, et al. How Does Batch Normalization Help Optimization? [J]. arXiv, 2018:1805.11604.

[14] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is All You Need [J]. arXiv, 2017: 1706.03762.

[15] 廖柯熹,冷吉辉,何腾蛟,等. 一种埋地管道腐蚀缺陷检测方法[J]. 腐蚀与防护, 2021, 42(2):52-55.

LIAO Kexi, LENG Jihui, HE Tengjiao, et al. A Method for Detecting Corrosion Defects in Buried Pipelines[J]. Corrosion & Protection, 2021, 42(2): 52-55.

(编辑 张洋)

作者简介:邢海燕,女,1971年生,教授、博士研究生导师。研究方向为电磁无损检测与可靠性评价、设备健康监测与故障诊断。发表论文 50 余篇。E-mail: xxhhyhit@163.com。赵力伟(通信作者),男,1986年生,硕士,工程师。研究方向为特种设备检验检测。发表论文 10 余篇。Email:13780183961@163.com。

本文引用格式:

邢海燕,武雪缘,蔡智会,等. 基于 ResGNNet 多模态融合的油气管道缺陷等级磁记忆定量识别[J]. 中国机械工程, 2025, 36(9): 2150-2157.

XING Haiyan, WU Xueyuan, CAI Zhihui, et al. Quantitative Identification of Oil and Gas Pipeline Defect Levels Based on Magnetic Memory Using ResGNNet Multi-modal Fusions[J]. China Mechanical Engineering, 2025, 36(9):2150-2157.