

文章编号: 1007-7294(2026)05-0779-12

基于残差注意力布朗协方差网络的热塑性复合材料管脱层损伤识别

彭传远¹, 舒启明², 杜友威¹, 申 雯¹

(1. 青岛黄海学院 智能制造学院, 山东 青岛 266427; 2. 华中科技大学 船舶与海洋工程学院, 武汉 430074)

摘要: 热塑性复合材料管(Thermoplastic Composite Pipes, TCP)结构在海洋结构物中得到了广泛的应用, 本文建立残差注意力布朗协方差神经网络进行 TCP 复合材料层间脱层的损伤识别研究。首先, 通过有限元方法计算多组具有单损伤、多损伤和不同损伤程度的热塑性复合材料管的曲率模态; 然后, 讨论热塑性复合材料管脱层损伤识别方法; 最后, 将曲率模态作为输入参数, 构建残差注意力布朗协方差网络模型, 对热塑性复合材料管脱层损伤位置和损伤程度进行识别。结果表明, 本文提出的基于残差注意力布朗协方差网络的管道损伤识别模型能够识别损伤位置和大小。对损伤位置的识别准确率为 100%, 损伤程度识别误差低于 6%, 研究结果可为海洋工程结构物无损检测提供参考。

关键词: 热塑性复合材料管; 曲率模态; 损伤识别; 残差注意力网络

中图分类号: TB332 **文献标识码:** A **doi:** 10.3969/j.issn.1007-7294.2026.05.010

Delamination damage identification of thermoplastic composite pipe based on residual attention Brownian covariance network

PENG Chuan-yuan¹, SHU Qi-ming², DU You-wei¹, SHEN Wen¹

(1. Intelligent Manufacturing College, Qingdao Huanghai University, Qingdao 266427, China; 2. School of Shipbuilding and Ocean Engineering, Huazhong University of Science and Technology, Wuhan 430074, China)

Abstract: Thermoplastic composite pipes (TCP) have been widely used in marine structures. In this paper, a residual attention Brownian covariance neural network is established to study the damage identification of TCP composite delamination. Firstly, the curvature modes of multiple groups of thermoplastic composite tubes with single damage, multiple damages and different damage degrees were calculated using the finite element method. Then, the delamination damage identification method of thermoplastic composite tubes was discussed. Finally, the residual attention Brownian covariance network model was constructed using the curvature modes as input parameters to identify the delamination damage location and damage degree of TCP. The results show that the damage identification model based on residual attention Brownian covariance network can identify the location and degree of damage. The accuracy of damage location identification is 100%, and the error of damage degree identification is less than 6%. The research results provide a reference for non-destructive testing of marine engineering structures.

收稿日期: 2025-09-11

基金项目: 青岛黄海学院横向科研项目(KYH2024190); 青岛黄海学院科技计划项目(2023KJ12)

作者简介: 彭传远(1997-), 男, 硕士, 讲师, E-mail: pcy01131234@163.com;

舒启明(1997-), 男, 博士研究生, 通讯作者, E-mail: shuqm@hust.edu.cn。

Key words: thermoplastic composite pipe; curvature mode; damage identification; residual attention network

0 引言

热塑性复合材料管是由热塑性聚合物挤出管与多层玻纤增强复合材料带缠绕而成的新型管道,具有强度高、质量轻、设计性强等优点,已在海洋工程、土木工程等领域广泛应用。管道由内向外依次为内衬层、玻纤增强层和外保护层,典型TCP(Thermoplastic Composite Pipes)结构如图1所示。

热塑性复合材料管的内衬层和外保护层为高密度聚乙烯材料 HDPE(High Density Polyethylene),玻璃纤维增强层 GFRP(Glass Fiber Reinforced Composite)由玻璃纤维和热塑性树脂

基体复合而成。其中玻璃纤维为增强材料,为管道承载内压和环境载荷提供强度与刚度,HDPE 为基体材料,起到保护和固定纤维的作用^[1]。管道通过加热熔融形成一体式的管壁结构,具有较高的层间剪切强度,能够有效降低在位工况下管道的泄漏发生率。

热塑性复合材料管的复合材料层损伤包括基体开裂、纤维断裂和层间脱层等多种形式,复合管在生产、安装、服役过程中容易受到温度变化、应力集中、腐蚀等因素影响,进而发生脱层。据统计,脱层损伤占有所有损伤类型的 50% 以上^[2]。因此,如何有效地识别 TCP 的脱层损伤是一个具有挑战性的问题。

目前,针对工程结构的损伤检测方法主要包括超声检测法、电容成像法、声发射检测法^[3]。刘雨等^[4]利用超声检测的方法开展纤维增强复合材料损伤识别的实验研究,实验结果表明,超声检测对复合材料修理区域的分层缺陷具有良好的识别效果。王克凡^[5]基于电容成像检测原理对蜂窝复合材料和复合材料抽油杆进行缺陷检测,研究发现电容成像可以实现复合材料完整性检测。Sofer 等^[6]研究了声发射信号在复合材料中的衰减、模态转换、散射等传播特性,发现该方法可识别基体裂纹、纤维断裂和脱粘等失效机制。然而,上述方法要求高精度的仪器设备,且依赖人工经验,面对复杂工程结构的损伤检测效果较差。

近年来,深度学习正逐渐成为一种解决上述问题的合适方案。典型的深度学习模型包括卷积神经网络和人工神经网络等,它们可以自动提取损伤相关的特征,大大减少了对专业知识的依赖。例如, Scholz 等^[7]应用全连接神经网络和卷积神经网络对复合材料转子的结构振动响应进行识别、定位和量化研究。Wu 等^[8-9]构建了 IPSO-BP 神经网络模型针对钢制管道的腐蚀进行损伤识别,预测效果良好。以此为基础,Mei 等^[10]应用多种神经网络模型对单损伤、多损伤及不同损伤位置的管道进行损伤预测,发现所提出的神经网络模型具有良好的检测精度。Zhao 等^[11]采用深度迁移学习实现损伤区域的实时定位,通过连续小波变换将声发射时域信号变换为输入图像,基于卷积神经网络的模型,通过从输入图像中提取特征来自动定位受损区域。

综上,研究复合材料在加工、装配、服役过程中的脱层损伤问题,并对损伤发生位置以及损伤程度进行识别至关重要。基于此背景,本文提出残差注意力布朗协方差网络进行 TCP 层间脱层损伤位置和损伤程度判定,为保障管道安全运行提供技术支撑。

1 位移模态与曲率模态

结构位移模态包含结构的振型信息,在实验过程中高阶位移模态往往难以获取,因此常用的位移




图1 典型 TCP 结构

Fig.1 Typical TCP structure

模态一般为 1~3 阶。一般情况下, 结构损伤会引起结构的动态参数变化, 当管道某个部位发生损伤时, 会对该部位的刚度产生影响, 导致结构位移模态发生变化, 进而影响结构曲率^[12-14]。

将热塑性复合材料管看成一维无阻尼梁式结构, 梁的截面抗弯刚度和曲率关系为

$$k(x) = \frac{1}{\rho(x)} = \frac{M}{EI(x)} \quad (1)$$

式中: $k(x)$ 为曲率; $\rho(x)$ 为曲率半径; M 为截面弯矩; $EI(x)$ 为截面抗弯刚度。

由式(1)可知, 曲率模态随着结构的抗弯刚度的变化而变化, 当 TCP 中存在损伤时, 损伤位置处的弯曲刚度会降低, 结构曲率模态会在该位置发生突变。因此, 结构曲率模态可以作为 TCP 结构的损伤识别的标准。利用中心差分法, TCP 结构上任意节点的曲率模态可以被表示为

$$C_r(i) = \frac{\varphi_{r(i+1)} + \varphi_{r(i-1)} - 2\varphi_{r(i)}}{l^2} \quad (2)$$

式中: r 为模态阶数; i 为节点编号; $C_r(i)$ 为 i 节点处的曲率模态; $\varphi_r(i)$ 为 i 节点在第 r 阶模态的横向位移; l 为相邻节点间距离。

复合材料脱层会导致脱层位置的弯曲刚度发生变化, 从而导致 TCP 的曲率发生改变, 本文将通过对比不同脱层损伤位置的结构曲率模态进行 TCP 损伤位置与损伤程度的判定^[15]。

2 任务描述

本文提出的残差注意力布朗协方差网络 RABCN(Residual Attention Brownian Covariance Network)模型通过学习模态数据来实现 TCP 损伤位置与损伤程度的预测。假设 TCP 的训练数据集中位移模态数据为 $D_d = (x_{i,j}, m, n)$ 。其中, m 代表损伤位置, n 代表损伤程度。TCP 损伤识别由损伤位置识别的分类任务 1 和损伤程度识别的回归任务 2 组成。两个任务的具体细节如下:

在损伤位置识别的分类过程中, 对数据进行预处理, 位移模态数据 $D_d = (x_{i,j}, i, j)$ 被转换为曲率模态数据 $D_c = (X_{i,j}, i, j)$ 。构建损伤位置识别数据集 $D_1 = (X_{i,j}, i)$ 被输入到 RABCN 模型中进行训练。将测试数据送到训练好的 RABCN 模型, 获得预测的损伤位置值。

在损伤程度识别的回归过程中, 对数据进行预处理, 位移模态数据 $D_d = (x_{i,j}, i, j)$ 被转换为曲率模态数据 $D_c = (X_{i,j}, i, j)$ 。获取的曲率模态数据 $D_2 = (X_{i,j}, j)$ 被输入到 RABCN 模型中进行训练。测试数据被送到训练好的 RABCN 模型, 获得预测的损伤程度值。值得注意的是, 在分类任务中, 全连接层的输出为位置类别, 回归任务中全连接层的输出为 1。

3 残差注意力布朗协方差网络模型

针对热塑性复合材料管的损伤精准识别这一难点问题, 残差注意力网络凭借通道与空间注意力机制, 能够显著增强对局部故障特征的提取能力^[16]; 同时, 布朗协方差模型以其对高阶统计关联的敏感性, 能够有效捕捉变量间的复杂相关性^[17]。本文融合二者优势, 提出了一种结合残差注意力与布朗协方差匹配的网络模型(RABCN), 以揭示热塑性复合材料管损伤特征与结构状态之间的深层非线性关联, 实现复杂工况下的高精度损伤识别, 其结构如图 2 所示。

在残差注意力模块中, 首先对监测信号进行初步的特征提取。采用卷积层和残差连接机制, 将监测信号转化为高维特征。在这个过程中, 空间注意力与通道注意力被加入到残差连接路径中, 以增强对故障特征的全局关注。接着, 高维特征被输入到布朗协方差模块, 通过随机观测和矩阵转换, 生成布朗协方差 BDC(Brownian Distance Covariance)矩阵。最后, 将 BDC 矩阵输入到全连接层进行诊断。

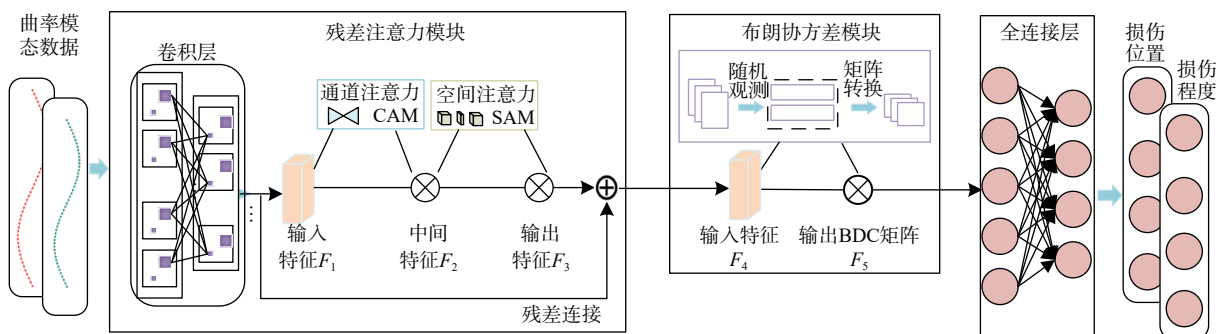


图2 残差注意力布朗协方差网络总体结构图

Fig.2 The overall architecture of Residual Attention Brownian Covariance Network (RABCN)

3.1 残差注意力模块

残差注意力模块的作用是提取监测信号中与故障相关的高维特征。作为残差网络 ResNet (Residual Network) 的一种变体, 残差注意力模块在残差连接中加入通道注意力机制 CAM (Channel Attention Mechanism) 和空间注意力机制 SAM (Spatial Attention Mechanism), 提升模块对监测信号中隐藏特征的全局注意力, 进而提取具有故障信息的全局特征。

CAM 采用 3D 排列来保留跨三维的特征信息。随后, 利用一个双层感知机 MLP (Multilayer Perceptron), 模拟通道之间的非线性关系。其中, MLP 是一个编码器-解码器结构, 具有缩减比 r , sigmoid 为激活函数。通过 CAM, 卷积层提取的特征 F_1 被转化为特征 F_2 , 该过程可公式化为

$$F_2 = \text{CAM}(F_1) \otimes F_1 \quad (3)$$

式中: $\text{CAM}(\cdot)$ 是通道注意力函数, 表达式为: $\text{CAM}(F_1) = \text{sigmoid}(\text{MLP}(\text{Permute}(F_1)))$, Permute 将维度从 (C, H, W) 置换为 (H, W, C) , $\otimes$ 是逐个元素相乘运算。通道注意力模块具体结构如图 3 所示。




图3 通道注意力结构图

Fig.3 The architecture of Channel Attention

SAM 使用两个卷积层进行空间信息融合, 从而捕捉空间信息。值得注意的是, 由于 SAM 不包含传统注意力机制中的池化层, 不改变特征张量的空间尺寸。因此, 输出张量包含了三个维度的相互作用。通过 SAM, 提取的特征 F_2 被转化为特征 F_3 , 该过程可公式化为

$$F_3 = \text{SAM}(F_2) \otimes F_2 \quad (4)$$

式中: $\text{SAM}(\cdot)$ 是空间注意力函数, 表达式为: $\text{SAM}(F_2) = \text{sigmoid}(\text{Conv2}(\text{Conv1}(F_2)))$, Conv2 和 Conv1 是两个卷积层, $\otimes$ 是逐个元素相乘运算。空间注意力模块如图 4 所示。




图4 空间注意力模块

Fig.4 Spatial attention module

最后, 残差注意力模块通过残差连接机制生成特征 F_4 , 该过程可公式化为

$$F_4 = \text{RC}(F_1, F_3) \quad (5)$$

式中: $\text{RC}(\cdot)$ 为残差连接函数, 表达式为: $y = F(x, \{W_i\}) + x$; x 是输入向量, y 为输出向量, $\{W_i\}$ 指的是网络

层的权重集合。

3.2 布朗协方差模块

残差注意力模块的输出特征 F_4 进一步输入布朗协方差模块以消除干扰信息, 获得 BDC 矩阵 F_5 。基于 BDC 度量理论, BDC 矩阵可以根据边际与联合特征函数的乘积来度量两个随机向量之间的距离。两个随机向量之间的 BDC 度量表示为

$$\rho(X, Y) = \int_{R^p} \int_{R^q} \frac{|\phi_{XY}(\mathbf{t}, \mathbf{s}) - \phi_X(\mathbf{t})\phi_Y(\mathbf{s})|^2}{c_p c_q \|\mathbf{t}\|^{1+p} \|\mathbf{s}\|^{1+q}} d\mathbf{t} d\mathbf{s} \quad (6)$$

其中, $X \in R^p$ 和 $Y \in R^q$ 分别表示 p 维和 q 维欧几里得空间的随机向量。 $\rho(\cdot)$ 表示度量函数, $\|\cdot\|$ 表示欧几里德范数, $c_p = \pi^{\frac{1+p}{2}} / \Gamma\left(\frac{1+p}{2}\right)$, $c_q = \pi^{\frac{1+q}{2}} / \Gamma\left(\frac{1+q}{2}\right)$ 。 $\phi_{XY}(\mathbf{t}, \mathbf{s})$ 为 X 和 Y 的联合特征函数, $\phi_X(\mathbf{t})$ 和 $\phi_Y(\mathbf{s})$ 分别是 X 和 Y 的边缘特征函数。

假设得到一个 $X \in R^{hw \times d}$ 特征张量, 两个随机观测 $x_i \in R^{hw}$ 和 $x_j \in R^d$ 从 X 中获得。其中, x_i 代表 X 的每一列, x_j 代表 X 的每一行。BDC 矩阵 A 可以被获取

$$\tilde{A} = 2 \left(1 \left(X^T X \circ I \right) \right)_{sym} - 2 X^T X \quad (7)$$

$$A = \hat{A} - \frac{2}{d} (1 \hat{A})_{sym} + \frac{1}{d^2} 1 \hat{A} 1 \quad (8)$$

其中, $1 \in R^{d \times d}$ 代表每个元素为 1 的矩阵, I 代表单位矩阵, $\circ$ 代表 Hadamard 乘积, $\hat{A} = \sqrt{\tilde{A}}$ 。因此, 由于能够使用欧几里得距离捕获通道之间的非线性关系, BDC 矩阵可以消除干扰信息, 并提取深层的代表性特征。

3.3 全连接层

全连接层 FCL(Fully Connected Layer)的作用是将学习到的代表性特征进行显式表示。通过空间映射将代表性特征空间与样本空间进行关联, 代表性特征被展开为一维向量, 并与当前层的权重进行线性组合, 再通过激活函数进行非线性变换, 最终被映射为预测值。值得注意的是, 在分类任务中, 全连接层的机制可以被表达为

$$FCL(x) = \text{GELU}(Wx + b) \quad (9)$$

其中, W 是权重矩阵, b 是偏差向量。GELU 是激活函数, $\text{GELU}(y) = \frac{y}{2} \left(1 + \text{erf} \left(\frac{y}{\sqrt{2}} \right) \right)$, 其中 erf 为误差函数, 它被用来对特征进行非线性变换, 增强模型的表征能力。

3.4 训练策略

RABCN 网络的损失函数是通过计算真实值和预测值之间的差值构成的。由于损伤识别包括损伤位置识别任务 1 和损伤程度识别任务 2, 因此有两个损伤函数。

$$L_1 = \frac{1}{N} \sum_{i=1}^N (m_i - \hat{m}_i)^2 \quad (10)$$

$$L_2 = \frac{1}{N} \sum_{i=1}^N (n_i - \hat{n}_i)^2 \quad (11)$$

其中, N 是样本数量, m_i 是第 i 个样本的损伤位置真实值, $\hat{m}_i$ 是第 i 个样本的损伤位置预测值, n_i 是第 i 个样本的损伤程度真实值, $\hat{n}_i$ 是第 i 个样本的损伤程度预测值。

设 ϑ 和 θ 分别为残差注意力模块和全连接层的参数。公式(9)和(10)可以改写为

$$\delta_\vartheta^*, \delta_\theta^* \leftarrow \underset{\delta_\vartheta, \delta_\theta}{\text{argmin}} L_{\text{MSE}}(\delta_\vartheta, \delta_\theta) \quad (12)$$

其中, δ_ϑ^* 和 δ_θ^* 表示网络的优化参数。

4 基于残差注意力布朗协方差网络的 TCP 损伤识别过程

采用提出的 RABCN 网络进行 TCP 损伤识别过程如图 5 所示, 包含以下步骤:

(1) 数据采集与划分: 通过 TCP 仿真模型, 获取位移模态数据, 通过预处理, 将位移模态数据转化为曲率模态数据。构建损伤位置识别任务和损伤程度识别任务, 选取任一任务, 按照一定比例, 将处理后的数据分成训练集、验证集和测试集, 用于模型训练和评估。

(2) RABCN 模型构建与训练: 使用划分好的训练集数据对 RABCN 模型进行训练, 验证集数据对模型进行评估, 并根据评估结果对模型进行调优, 以提高预测准确率和稳定性。

(3) 损伤识别与定位: 使用测试集对训练好的 RABCN 模型进行评估, 实现 TCP 损伤位置和损伤程度预测。




图 5 损伤识别过程

Fig.5 Process of damage identification

5 损伤模拟分析

5.1 含损伤的 TCP 模型构建

应用数值仿真软件 Abaqus 建立 TCP 模型进行模态分析, 其结构参数和材料参数如表 1~2 所示。

表 1 结构参数

Tab.1 Structure parameters

名称/单位	数值	名称/单位	数值
总长 L /mm	1000	外保护层厚度 t_3 /mm	2.5
内径 R /mm	50	玻纤增强层层数/层	10
内衬层厚度 t_1 /mm	3	铺层方向 (交叉铺层) /°	±55
玻纤增强层厚度 t_2 /mm	3		

表 2 材料参数
Tab.2 Material parameters

部件	属性/单位	参数
GFRP	弹性模量 E_{ij} /MPa	$E_{11} = 28\,000, E_{22} = E_{33} = 3200$
	剪切模量 E_{ij} /GPa	$G_{12} = G_{13} = 2750, G_{23} = 1230$
	泊松比 ν_{ij}	$\nu_{12} = \nu_{13} = 0.32, \nu_{23} = 0.33$
HDPE	弹性模量 E /MPa	1423
	泊松比 ν	0.38

管道两端分别创建参考点 RP-1 和 RP-1 与两端面建立 6 个自由度方向的耦合约束,管道两端简支。采用 C3D8R 单元对 TCP 进行网格划分,沿管道轴向布置 51 个等分节点,划分 50 个单元,离散后的网格和沿管道轴向的节点编号如图 6 所示。

采用共用节点的方法模拟复合材料层间粘接,脱层单元处不共用节点,脱层位置分别设置为第 2 个节点至第 50 个节点。通过有限元模态分析可以提取含脱层损伤 TCP 结构的固有频率和模态振型。为解释数据提取流程和处理方法,选择具有不同脱层位置和脱层层数的 8 种典型预设损伤工况进行对比分析,如表 3 所示。




图 6 TCP 网格划分
Fig.6 TCP meshing

表 3 典型 TCP 损伤工况
Tab.3 Typical TCP damage condition

工况编号	损伤节点编号	损伤程度（层数）	工况编号	损伤节点编号	损伤程度（层数）
1	15	1	5	10	3
2	15	3	6	20	3
3	15	5	7	30	3
4	15	7	8	40	3

通过有限元模态分析可以得到 TCP 的固有频率和振型参数,由于在工程分析中高阶模态的频率测量和提取较为困难,仅提取前 3 阶位移模态并进行归一化处理,以工况 1 为例,不同节点的前 3 阶位移模态数据如图 7 所示。




图 7 前 3 阶位移模态
Fig.7 The first 3 displacement modes

由图7可知,发生脱层损伤和未发生脱层损伤节点的各阶位移模态曲线光滑,也就是说刚度变化对位移模态影响较小,脱层损伤对结构振型参数不敏感。

5.2 曲率模态计算

为提高损伤识别的稳定性,将位移模态数据处理成结构曲率模态数据,作为结构的损伤识别数据。将不同工况下的2阶模态位移参数代入公式(2),利用中心差分法将位移模态转换为曲率模态,得到管道各节点的曲率模态数据,为探讨曲率模态对TCP损伤程度识别的敏感性,计算工况1~4不同损伤程度的管道曲率模态进行对比,如图8所示。

由图8可知,工况1~4在节点15附近出现显著的曲率模态突变峰,其突变极值位置与表3预设损伤坐标完全吻合。同时,管道曲率模态会在损伤区域与未损伤区域表现出显著差异:在完好区域呈现连续平滑特征,而损伤位置则出现明显的模态突变现象,且随着损伤层数的增加,损伤位置处的弯曲刚度减小,模态突变幅值显著增大。这一特征表明曲率模态对损伤程度识别具有良好的敏感性。

为对比曲率模态对TCP损伤位置识别的敏感性,对计算工况5~8不同损伤位置的管道曲率模态进行对比,如图9所示。




图8 不同损伤程度 TCP 曲率模态




图9 不同损伤位置 TCP 曲率模态

Fig.8 TCP curvature mode with different damage degrees

Fig.9 TCP curvature mode with different damage locations

由图9可知,在工况5~8中,预设损伤节点位置均呈现出显著的曲率模态突变峰特征,而未损伤区域则保持平滑的模态分布特性。值得注意的是,损伤位置与曲率模态突变峰在空间分布上具有一一对应关系。该现象充分验证了曲率模态参数对复合材料脱层损伤位置的表征灵敏度,表明曲率模态对损伤位置的识别同样具有良好的敏感性,为脱层损伤的定位检测提供了有效依据。

综上所述,使用管道曲率模态参数作为管道的损伤识别参数是可行的。曲率模态数据不仅能通过特征峰突变准确定位TCP的脱层损伤位置,还能有效区分损伤程度,实现TCP结构损伤位置和损伤程度的有效评估。

以此为基础,本文共构建261组TCP损伤工况作为网络的输入参数展开研究。为提高前后处理效率,基于Python语言编写参数化脚本进行有限元模型创建和结果数据提取。其中,训练样本245组,分别对应不同损伤位置和损伤程度下的管道参数;测试样本16组,损伤位置和损伤程度随机生成。部分TCP曲率模态数据如表4所示。

6 基于残差注意力布朗协方差网络的损伤识别结果

为了定量评估模型的性能,本文采用4个评价指标,分别是平均绝对误差MAE(Mean Absolute Error)、平均绝对百分比误差MAPE(Mean Absolute Percentage Error)、均方误差MSE(Mean Squared

表4 部分 TCP 曲率模态数据
Tab.4 Data of partial TCP curvature mode

	样本 编号	脱层节点 编号	脱层 层数	损伤 程度	节点曲率模态						
					2	3	4	...	48	49	50
训练样本	1	2	1	0.1	528.53	1066.62	1590.94	...	-1576.91	-1059.54	-555.01
	2	2	3	0.3	552.69	1284.99	1634.05	...	-1574.89	-1058.18	-554.28
	3	2	5	0.5	573.17	1531.05	1688.45	...	-1572.61	-1056.67	-553.46
	...	...			...	...	...	...	...	...	...
	245	50	2	0.2	551.21	1052.71	1566.47	...	-1805.04	-2180.50	-726.42
测试样本	246	5	2	0.2	556.35	1055.83	1574.22		-1576.34	-1059.14	-554.80
	247	5	8	0.8	554.70	1058.99	1576.09		1574.92	-1058.19	-554.30
	...	...	...		...	...	...	...	...	...	...
	261	40	8	0.8	554.95	1059.42	1576.73	...	-1576.59	-1059.45	-554.69

Error)和决定系数 R^2 来评价预测值与真实值之间的误差。其中, MAE 是预测值与真实值之差的绝对值, 然后取平均值, 反映了误差平均值的大小。计算公式如下

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (13)$$

其中, y_i 和 $\hat{y}_i$ 分别代表预测值和真实值, N 表示样本的数量。

MAPE 是相对误差的平均值, 它按比例反映了误差的大小。计算公式如下

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{\hat{y}_i - y_i}{y_i} \right| \quad (14)$$

MSE 是每个误差平方和的平均值, 用来衡量真实值与预测值之间的差值。计算公式如下

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (15)$$

决定系数 R^2 用于评估回归模型与数据的拟合程度。它测量的是因变量中可从自变量中预测的方差的比例。 R^2 越高表示拟合越好。计算公式如下

$$R^2 = 1 - \frac{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2}{\frac{1}{N} \sum_{i=1}^N (y_i - \bar{y})^2} \quad (16)$$

其中, $\bar{y}$ 表示所有样本的平均值。

RABCN 模型由 Adam 优化器训练, 学习率为 0.001, 批大小为 64。图 10 显示了 RABCN 模型的训练迭代过程。由于损伤识别包括损伤程度识别任务和损伤位置识别任务, 因此 RABCN 模型有两个损失函数。在损伤位置识别的训练迭代过程中, RABCN 模型在 90 次迭代时收敛。在损伤程度识别的训练迭代过程中, 当迭代次数在 30 次左右时, RABCN 模型趋于稳定, 这意味着模型收敛速度较快, 能够快速识别 TCP 脱层损伤的损伤位置和损伤程度。

表 5 显示了 RABCN 模型和 ResNet 模型的识别性能结果对比, 可以发现, 在损伤位置识别




图 10 迭代次数与损失函数关系

Fig.10 Relation between the number of iterations and the loss function

任务中,本文提出的 RABCN 模型在 4 项指标中均达到最优。在损伤程度识别任务中,RABCN 模型的预测效果较好,MAE、MAPE、MSE 和 R^2 分别达到 0.017 19、0.037 32、0.0004 和 0.9924。明显地,在 TCP 的脱层损伤识别中,本文提出的 RABCN 模型识别性能优于 ResNet 模型^[18],这是因为提出的 RABCN 模型中的布朗协方差模块利用欧几里得度量函数捕获曲率模态与损伤位置、曲率模态与损伤程度之间的非线性关系,从而有效提取隐藏的损伤特征,进而实现良好的识别效果。

表 5 模型性能对比

Tab.5 Comparison of model performance

任务	模型	MAE	MAPE/%	MSE	R^2
位置识别	ResNet	1.2105	8.07	27.84	0.8605
	RABCN	0	0	0	1
程度识别	ResNet	0.0836	17.09	0.0189	0.6223
	RABCN	0.0172	3.73	0.0004	0.9924

表 6 和图 11 显示了布朗协方差网络损伤识别结果,其中 m_t 、 n_t 分别为实际损伤的位置和程度, m_p 、 n_p 分别为预测损伤的位置和程度。无脱层损伤管道显示损伤程度为 0,所有层均脱层显示损伤程度为 1。根据误差率 ER(Error Rate)对预测结果进行统计,计算公式为

$$ER = \frac{y_i - \hat{y}_i}{y_i} \quad (17)$$

表 6 损伤识别结果对比

Tab.6 Comparison of damage identification results

样本	实际损伤状态 (m_t, n_t)	预测损伤状态 (m_p, n_p)	样本	实际损伤状态 (m_t, n_t)	预测损伤状态 (m_p, n_p)
1	5, 0.2	5, 0.188	9	21, 0.6	21, 0.629
2	5, 0.8	5, 0.845	10	24, 0.2	24, 0.19
3	7, 0.2	7, 0.195	11	27, 0.8	27, 0.828
4	8, 0.6	8, 0.608	12	33, 0.4	33, 0.381
5	10, 0.2	10, 0.189	13	34, 0.8	34, 0.808
6	14, 0.4	14, 0.416	14	37, 0.6	37, 0.614
7	14, 0.6	14, 0.635	15	40, 0.4	40, 0.405
8	19, 0.4	19, 0.420	16	40, 0.8	40, 0.790




图 11 损伤程度识别误差率

Fig.11 Error rate of damage degree identification

16 组检测样本中,损伤位置预测准确率达 100%,损伤程度误差率均低于 6%(最大值为 6%,最小

值为1%),其中6个检测样本的损伤程度误差率低于3%。本文提出的RABCN模型在结构损伤检测中展现出显著优势,不仅能准确识别损伤位置,还能对不同脱层损伤程度实现定量化判别,验证了该方法在复杂损伤场景下的鲁棒性与可靠性。

7 结 论

本文针对热塑性复合材料管道的脱层损伤检测展开研究,研究形成的“特征参数-深度学习”诊断体系,提升了复合材料管道损伤检测的工程适用性,获得结论如下:

(1)基于曲率模态的损伤识别方法发现,在损伤单元节点处曲率模态存在显著突变。该参数不仅可实现脱层损伤的精准定位,还能通过突变幅值与损伤面积的正相关特性实现损伤程度的量化,为TCP损伤识别提供了高灵敏度指标。

(2)构建基于残差注意力布朗协方差网络的智能识别模型,其在损伤位置识别中实现全样本准确判别,准确率达到100%,损伤程度的识别误差率低于6%,其优异的非线性特征提取能力可为海洋工程结构健康监测提供参考。

参 考 文 献:

- [1] 彭传远,付新钰,师梦科,等. 大口径热塑性复合材料管及接头内压失效分析[J]. 工程塑料应用, 2022, 50(7): 104–109.
Peng C Y, Fu X Y, Shi M K, et al. Failure analysis of internal pressure of large-diameter thermoplastic composite pipes and joints[J]. Application of Engineering Plastics, 2022, 50(7): 104–109. (in Chinese)
- [2] 潘静雯,袁浩凡,张芝芳. 基于频率识别纤维增强复合材料弧形板分层损伤[J]. 噪声与振动控制, 2017, 37(6): 180–185.
Pan J W, Yuan H F, Zhang Z F. Hierarchical damage identification of fiber-reinforced composite arc-shaped plates based on frequency[J]. Noise and Vibration Control, 2017, 37(6): 180–185. (in Chinese)
- [3] 梁智洪,詹超,张芝芳. 基于频率识别纤维增强树脂复合材料加筋板的分层损伤[J]. 复合材料学报, 2019, 36(11): 2614–2627.
Liang Z L, Zhan C, Zhang Z F. Delamination damage of fiber-reinforced resin composite reinforced plates based on frequency identification[J]. Journal of Composite Materials, 2019, 36(11): 2614–2627. (in Chinese)
- [4] 刘雨,夏张松,宫兆斌,等. 复合材料修理区域的超声检测[J]. 无损检测, 2024, 46(10): 81–87.
Liu Y, Xia Z S, Gong Z B, et al. Ultrasonic testing of the composite material repair area[J]. Nondestructive Testing, 2024, 46(10): 81–87. (in Chinese)
- [5] 王克凡. 基于电容成像的复合材料无损检测技术研究[D]. 青岛: 中国石油大学(华东), 2020.
Wang K F. Research on non-destructive testing technology of composite materials based on capacitance imaging technique[D]. Qingdao: China University of Petroleum, 2020. (in Chinese)
- [6] Sofer M, Jakub C, Martin F, et al. Damage analysis of composite CFRP tubes using acoustic emission monitoring and pattern recognition approach[J]. Materials, 2021, 14(4): 786.
- [7] Scholz V, Winkler P, Andreas H, et al. Structural damage identification of composite rotors based on fully connected neural networks and convolutional neural networks[J]. Sensors, 2021, 21(6): 2005.
- [8] 吴磊,梅江涛,赵硕. 基于IPSO-BP神经网络的管道损伤检测方法[J]. 实验室研究与探索, 2022, 41(7): 44–49.
Wu L, Mei J T, Zhao S. Pipeline damage detection method based on IPSO-BP neural network[J]. Laboratory Research and Exploration, 2022, 41(7): 44–49. (in Chinese)
- [9] Wu L, Mei J T, Zhao S, et al. Pipeline damage identification based on an optimized back-propagation neural network improved by whale optimization algorithm[J]. Applied Intelligence, 2023, 53(10): 12937–12954.
- [10] Mei J T, Wu L, Chen E Q, et al. A novel structural damage detection method using a hybrid IDE-BP model[J]. Knowledge-

- based Systems, 2023, 273: 110606.
- [11] Zhao J Y, Xie W H, Yu D, et al. Deep transfer learning approach for localization of damage area in composite laminates using acoustic emission signal[J]. Polymers, 2023, 15(6): 1520.
- [12] Liu K, Yan R J, Guedes S, et al. Damage identification in offshore jacket structures based on modal flexibility[J]. Ocean Engineering, 2018, 170: 171–185.
- [13] 杜宇, 杨涛, 何梅洪. 基于运行模态的复合材料梁脱层损伤识别[J]. 宇航材料工艺, 2021, 51(2): 81–86.
Du Y, Yang T, He M H. Delaminate damage identification of composite beam based on operational modal[J]. Aerospace Materials & Technology, 2021, 51(2): 81–86. (in Chinese)
- [14] 杜宇, 何梅洪, 李菊峰. 基于曲率模态变化率的复合材料梁脱层损伤识别[J]. 固体火箭技术, 2021, 44(3): 385–389.
Du Y, He M L, Li J F. Delamination damage diagnosis of composite beams based on curvature mode change rate[J]. Solid Rocket Technology, 2021, 44(3): 385–389. (in Chinese)
- [15] Zhang Y, Guo J, Xie Y G, et al. Warship damage identification using mode curvature shapes method[J]. Applied Ocean Research, 2022, 129: 103396.
- [16] Zhou F, Cicone A, Zhou H M, et al. An enhanced Iterative Residual Convolutional Neural Network for non-stationary signal decomposition[J]. Pattern Recognition Letters, 2025: 328–336.
- [17] 苟光磊, 朱东华, 李小菲, 等. 深度掩膜布朗距离协方差小样本分类方法[J]. 计算机应用研究, 2024, 41(7): 2229–2234.
Gou G L, Zhu D H, Li X F, et al. Deep mask Brownian distance covariance for few-shot classification[J]. Application Research of Computers, 2024, 41(7): 2229–2234. (in Chinese)
- [18] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[J]. Conference on Computer Vision and Pattern Recognition, 2016: 770–778.