

文章编号:1671-7449(2024)01-0079-06

基于递归定量分析与多核学习支持向量机的 玻璃纤维增强复合材料缺陷识别技术

郭伟, 王召巴*, 陈友兴, 吴其洲

(中北大学 信息与通信工程学院, 山西 太原 030051)

摘要: 为了提高玻璃纤维增强复合材料(Glass Fiber Reinforced Polymer, GFRP)超声检测中缺陷识别技术的准确性, 提出基于递归定量分析(Recurrence Quantitative Analysis, RQA)与多核学习支持向量机(MKLSVM)相结合的检测模型, 以提高检测GFRP中不同类型缺陷的能力。结果表明, 该模型能够准确识别GFRP中的分层缺陷与夹杂缺陷, 检测识别率达到92.92%, 并且与基于离散小波变换(Discrete Wavelet Transform, DWT)和经验模态分解(Empirical Mode Decomposition, EMD)的MKLSVM检测模型的识别率相比, 所提出的检测模型的识别率分别提高了7.5%和3.75%。

关键词: 玻璃纤维增强复合材料; 超声检测; 递归定量分析; 多核学习支持向量机

中图分类号: TB559

文献标识码: A

doi:10.3969/j.issn.1671-7449.2024.01.012

引用格式: 郭伟, 王召巴, 陈友兴, 等. 基于递归定量分析与多核学习支持向量机的玻璃纤维增强复合材料缺陷识别技术[J]. 测试技术学报, 2024, 38(1): 79-84.

GUO Wei, WANG Zhaoba, CHEN Youxing, et al. Defect identification of glass fiber reinforced polymer based on recurrence quantitative analysis and multiple kernel learning SVM[J]. Journal of Test and Measurement Technology, 2024, 38(1): 79-84.

Defect Identification of Glass Fiber Reinforced Polymer Based on Recurrence Quantitative Analysis and Multiple Kernel Learning SVM

GUO Wei, WANG Zhaoba*, CHEN Youxing, WU Qizhou

(School of Information and Communication Engineering, North University of China, Taiyuan 030051, China)

Abstract: In order to improve the accuracy of defect identification technology in ultrasonic testing of GFRP, a detected model based on the recurrence quantitative analysis (RQA) and multiple kernel learning support vector machine (MKLSVM) was proposed to improve the ability to detect different types of defects in glass fiber reinforced polymer (GFRP). The results show that the proposed detected model can accurately identify delamination defects and inclusion defects in GFRP, and the detection recognition rate reaches 92.92%. Compared with the recognition rate of the MKLSVM detection model based on discrete wavelet transform (DWT) and empirical mode decomposition (EMD), the recognition rate of the proposed detection model has increased by 7.5% and 3.75%, respectively.

Key words: glass fiber reinforced polymer (GFRP); ultrasonic testing; recurrence quantitative analysis; multiple kernel learning support vector machine (MKLSVM)

收稿日期: 2022-12-02

基金项目: 山西省自然科学基金资助项目(20210302124202); 山西省省筹资金资助回国留学人员科研资助项目(2022-145)

作者简介: 郭伟(1991-), 男, 博士生, 主要从事超声无损检测等研究。E-mail: b1705016@st.nuc.edu.cn。

*通信作者: 王召巴(1967-), 男, 教授, 博士生导师, 主要从事无损检测、信号与信息处理等研究。E-mail: wangzb@nuc.edu.cn。

0 引言

玻璃纤维增强复合材料(Glass Fiber Reinforced Polymer, GFRP)由于其优异的比强度和比模量、耐腐蚀性和耐高温性,已被广泛应用于民用飞机、车辆制造和航空航天^[1]。在GFRP的生产制作过程中,可能产生夹杂、裂纹和分层等缺陷,会严重降低复合材料的机械性能。因此,有必要检测隐藏在GFRP中的缺陷并对其进行分类,以确保健康的GFRP投入工程应用以及指导生产工艺及流程的改进,提高GFRP的生产质量。

超声无损检测技术因具有成本低廉和方便易操作的优势被广泛应用于生产生活中,以确保相关材料部件的安全运行^[2]。受GFRP层合板的多层各向异性结构的影响,GFRP层合板的超声检测信号表现出明显的非线性与非平稳特性。传统基于线性与平稳模型的信号处理方法难以准确获得GFRP层合板的缺陷特征,限制了对GFRP层合板中缺陷的准确识别^[3]。而递归分析是一种研究复杂系统非线性动力学的有力工具,已被广泛应用于生物信号、经济金融、气象、监测设备等领域^[4-5]。与许多传统信号处理方法相比,递归分析对系统的非线性动态特性更加敏感,对噪声的敏感度更低,适合处理具有非线性非平稳特征的检测信号。

目前,机器学习等方法被广泛用于处理材料的超声检测信号,为缺陷检测信号特征的自动批量处理提供了强大的技术手段^[6]。其中,支持向量机(SVM)在处理工业生产过程中的高维和非线性特性检测信号方面具有显著优势。然而,当样本数据中包含异构数据时,样本数据在核空间中的投影就变得不稳定,基于单个核函数的SVM难以实现最佳分类效果。将多个核函数结合起来形成新的核函数,即多核学习,可获得更好的分类效果。Rakotomamonjy等^[7]提出了SimpleMKL算法,为基于混合范数正则化的多核学习算法提供了新的解决途径。Lanckriet等^[8]基于多个核函数构建多核学习框架,证明多核SVM方法具有稳定性高、分类准确的优点。Gönen等^[9]对不同多核学习算法进行了分类和回顾,指出在提供的信息方面,以多核函数的组合核比单个核函数更有优势。

本文基于前人的研究基础,将递归定量分析和多核学习SVM结合用于GFRP超声检测缺陷

识别中,提出基于递归定量分析和多核学习SVM的缺陷检测识别模型以提高GFRP层压板中不同类型缺陷的检测识别率。

1 GFRP层合板超声检测方法

使用如图1所示的DPR500超声检测设备与30 MHz超声换能器对GFRP层合板试件进行检测。GFRP层合板试件由环氧树脂和3层±45°方向编织的玻璃纤维布制成,每层的平均厚度为0.8 mm,试件模型如图2所示。分层缺陷与夹杂缺陷是GFRP层合板生产使用过程中常见的缺陷类型,分层缺陷是在生产使用过程中铺层之间形成空气或真空隙,夹杂缺陷是在GFRP生产过程中,非金属或金属介质等异物侵入。本文在GFRP试件的第2层和第3层之间嵌入双层特氟龙薄膜形成空气隙以模拟分层缺陷,并在相同深度位置处嵌入单层铝膜模拟夹杂缺陷。同时,选择图2中正方形阴影区域作为无缺陷区域。




图1 超声检测设备

Fig. 1 Ultrasonic testing equipment




图2 GFRP层合板试件样图

Fig. 2 Schematic diagram of GFRP laminates specimen

无缺陷、分层缺陷与夹杂缺陷不同区域的超声检测信号如图 3 所示。由于 30 MHz 的超声检测信号具有较高的分辨率, 无缺陷处的检测信号具有明显的内部界面结构噪声回波和底部回波。模拟分层缺陷处的超声检测信号, 在第 2, 3 层之间的界面回波幅值增强, 底部回波幅值消失, 缺陷回波相位与入射脉冲相反。铝箔夹杂缺陷处的超声检测信号在第 2, 3 层之间的界面回波幅值增强, 底部回波的幅值减弱, 缺陷回波相位与入射脉冲相同。




图 3 不同区域的超声检测信号
Fig. 3 Ultrasonic detection signals of different areas

2 递归定量分析特征提取

假设 $\{x(t_i), i=1, 2, \dots, n\}$ 是从系统测量得到的一维时间序列, 通过选择适当的延迟时间 τ 和嵌入维数 m , 原始一维时间序列可以扩展为 $m \times [n - (m - 1)\tau]$ 维相空间矩阵

$$\begin{bmatrix} X(t_1) \\ \vdots \\ X(t_i) \\ \vdots \\ X_{n-(m-1)\tau} \end{bmatrix}^T \Rightarrow \begin{bmatrix} x(t_1) & \dots & x(t_i) & \dots & x_{n-(m-1)\tau} \\ x(t_{1+\tau}) & \dots & x(t_{i+\tau}) & \dots & x_{n-(m-2)\tau} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ x(t_{1+(m-1)\tau}) & \dots & x(t_{i+(m-1)\tau}) & \dots & x(t_n) \end{bmatrix}, \quad (1)$$

式中: $X(t_i)$ 为相空间矩阵中的相位点。相空间矩阵中的相位点数目为 $N = n - (m - 1)\tau$ 。

相空间中随着时间变化的相点序列反映了系统状态变化的演化轨迹。因此, 可以从低维空间中重构得到原始的高维非线性动态系统, 并且可

以恢复系统测量过程中丢失的系统信息。

递归图(RP)是对重构后的相空间中相点轨迹的递归行为的二维图像描述, 定义为

$$R_{i,j} = \Theta(\epsilon - \|X(t_i) - X(t_j)\|), \quad (2)$$

$$i, j = 1, 2, \dots, N,$$

式中: ϵ 为截止距离; $\| \cdot \|$ 为欧几里德范数; $\Theta(x)$ 为 Heaviside 函数:

$$\Theta(x) = \begin{cases} 1, & x > 0, \\ 0, & x \leq 0. \end{cases} \quad (3)$$

图 4 为分别利用平均互信息法与虚假邻点法确定相空间重构的最优延迟时间与嵌入维数^[10]。图 4(a) 中所示最佳延迟时间为 $\tau = 8 \mu\text{s}$, 图 4(b) 中所示最佳嵌入维数为 $m = 3$ 。此外, 本文通过计算将截止距离设置为一个固定值 $\epsilon = 1.5$, 使递归图中能清晰显示出递归结构。为了确保数据的可比性, 在后续检测信号的递归分析中选择相同的重建参数。

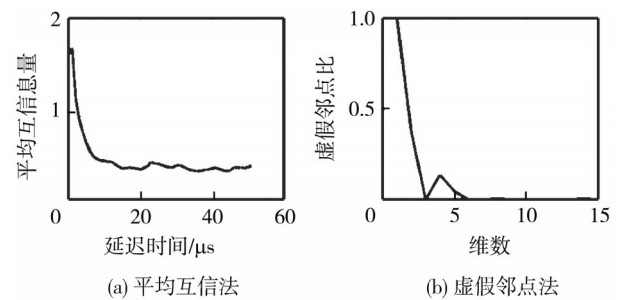


图 4 最优延迟时间与最优嵌入维数的计算

Fig. 4 Calculation of optimal delay time and optimal embedding dimension

使用上述重构参数计算绘制图 3 中各个检测信号的递归图, 结果如图 5 所示。在无缺陷处的检测信号递归图中, 垂直和水平 3 条白色交叉带将递归图中的递归点分成小块, 递归图中的黑块结构和白色交叉带分布更均匀, 表明无缺陷区的检测信号在传播过程中具有更稳定的波形。分层缺陷与夹杂缺陷的递归图右上角的白色交叉带消失, 对应于检测信号中底部回波的减弱或消失, 中间白色交叉带占据了较大的面积, 表明分层缺陷与夹杂缺陷的检测信号发生了显著变化, 而且分层缺陷与夹杂的递归图分布细节上也互不相同。

根据递归点密度和递归图中对角、垂直和水平线段的结构特征, 可以定义以下递归定量分析(RQA)变量:

1) 递归率(RR)

$$RR = \frac{1}{N^2} \sum_{i \neq j=1}^N R_{i,j}, \quad (4)$$

式中： $R_{i,j}$ 为递归图中除主对角线外的递归点数； N 为递归图的维数。




图5 不同区域检测信号的递归图

Fig. 5 The RP of detection signals in different areas

2) 平均对角线长度(D)

$$D = \frac{\sum_{l=l_{\min}}^N lH_D(l)}{\sum_{l=l_{\min}}^N H_D(l)}. \quad (5)$$

3) 捕获时间(TT)

$$TT = \frac{\sum_{v=v_{\min}}^N vH_V(v)}{\sum_{v=v_{\min}}^N H_V(v)}, \quad (6)$$

式中： v_{\min} 为递归图中垂直结构的最小分析长度。

4) 递归熵($ENTR$)

$$ENTR = - \sum_{l=l_{\min}}^N p(l) \ln_p(l), \quad (7)$$

式中： $p(l)$ 为对角线长度分布的概率密度。

对图2中试件中的分层缺陷、夹杂缺陷和无缺陷区域分别随机采集200组数据，根据式(4)~式(7)分别计算每个区域检测信号的RQA参数，箱形图分布如图6所示。不同区域检测信号的RQA变量参数的数据分布存在差异，这就使得利用RQA特征数据对GFRP层合板中的分层缺陷与夹杂缺陷进行检测识别成为可能。




图6 不同区域的RQA变量箱线图分布

Fig. 6 Boxplot of RQA variables in different areas

3 多核学习SVM缺陷识别

支持向量机(SVM)分类的核心是通过核函数 $K(x_i, x)$ 将数据样本映射到高维核空间，使得数据可以线性可分，并生成用于划分数据的超平面。核函数的选择决定了分类效果，为了充分利用核函数各自的优点，将核函数组合起来构造新的核函数，可以实现多核学习SVM(MKLSVM)。多项式核函数与高斯核函数分别具有良好的学习与较强的泛化能力。本文将这两种核函数结合起来以获得更好的分类效果。

多核函数的线性组合形式为

$$K(x_i, x) = \gamma K_1(x_i, x) + (1 - \gamma) K_2(x_i, x), \quad (8)$$

$$0 \leq \gamma \leq 1,$$

式中： $K_1(x_i, x) = (x^T \cdot y + 1)^d$ ， $K_2(x_i, x) = \exp\left(-\frac{\|x - y\|^2}{2\sigma^2}\right)$ ； γ 为权重系数。

结合拉格朗日对偶，将超平面求取问题转化为求解对偶问题，基于核函数的目标函数为

$$\max_{\alpha} \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j K(x_i, x), \quad (9)$$

$$\text{s.t. } \sum_{i=1}^n \alpha_i y_i = 0, \quad 0 \leq \alpha_i \leq c.$$

相应的决策函数为

$$f(x) = \text{sign}\left(\sum_{i=1}^n \alpha_i^* y_i K(x_i \cdot x) + b^*\right). \quad (10)$$

上述公式中包含了惩罚参数 c 、多项式核函数参数 d 、高斯核函数参数 σ 和权重系数 γ ，这使得

MKLSVM 参数的选择特别复杂。为了选择合适的参数,使用粒子群优化(PSO)算法来优化参数^[11]。

基于 RQA 特征提取与 MKLSVM 模型的 GFRP 缺陷识别算法流程如图 7 所示。

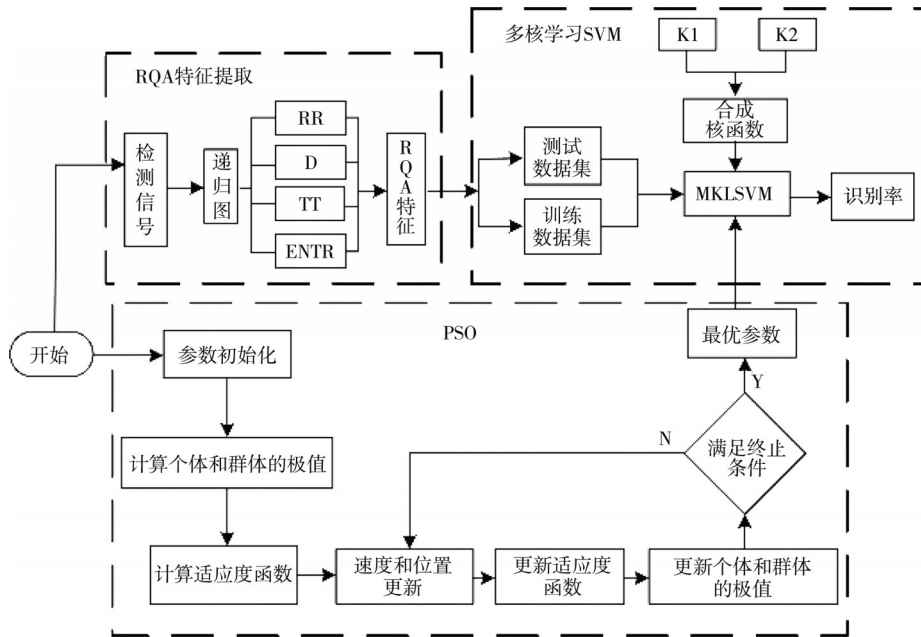


图 7 基于 RQA 与 MKLSVM 的 GFRP 缺陷识别算法流程

Fig. 7 Algorithm flow of GFRP defect identification based on RQA and MKLSVM

对图 3 中检测试件样本中的分层缺陷、夹杂缺陷和无缺陷区域分别采集的 200 组数据计算 RQA 参数,将每个检测区域的 120 组 RQA 参数划分为训练样本,其余 80 组用作测试样本。分层缺陷、夹杂缺陷和无缺陷区域的 RQA 数据集的分类标签分别定义为 1, 2 和 3。按照图 7 算法流程建立多核学习 SVM 训练模型,并对测试样本进行了预测和分析。将本文方法与基于离散小波变换(DWT)和经验模态分解(EMD)的传统特征提取方法的检测模型进行比较,以验证 RQA 特征提取的有效性^[3]。

分别利用所得的优化参数建立基于 RQA、DWT 与 EMD 的 MKLSVM 分类模型,并对测试样本进行分类识别,识别结果如图 9 所示。

基于 PSO 优化算法计算 MKLSVM 参数的优化过程,如图 8 所示。

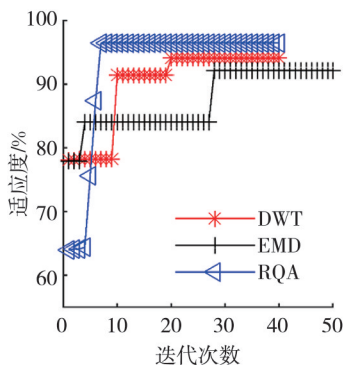


图 8 粒子群优化适应度曲线

Fig. 8 Fitness curve of particle swarm optimization

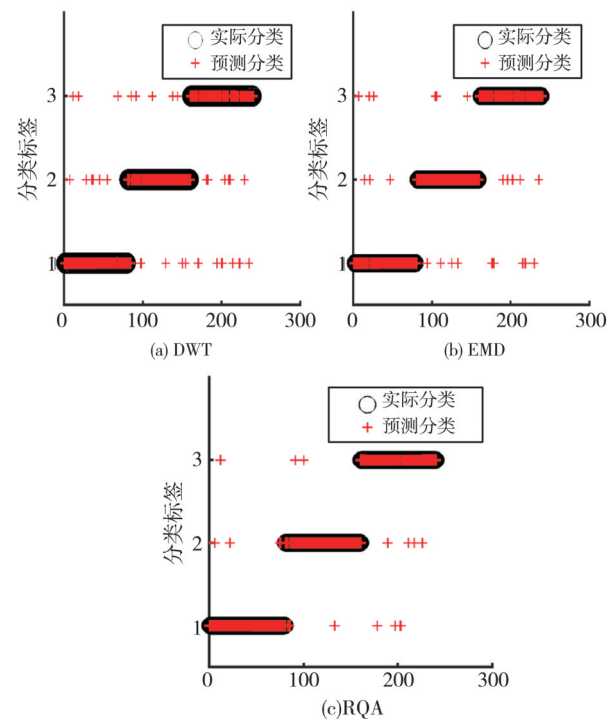


图 9 基于不同特征提取方法的 MKLSVM 检测模型识别结果

Fig. 9 Recognition results of MKLSVM detected model based on different feature extraction methods

表1为基于不同方法的MKLSVM检测模型识别率比较。基于RQA特征提取方法的MKLSVM分类模型的平均识别率为92.92%，而基于DWT与EMD特征提取方法的MKLSVM分类模型平均识别率为85.42%与89.17%。基于RQA特征提取方法的MKLSVM检测模型识别率分别比基于DWT和EMD的MKLSVM检测模型识别率高7.5%和3.75%。结果表明，本文所提出的检测模型可以准确识别出GFRP层合板中的分层缺陷与夹杂缺陷，并且与两种基于传统特征提取方法的分类模型相比，基于RQA特征方法的MKLSVM分类模型更适合处理具有非线性变化特征的GFRP超声检测信号。

表1 基于不同特征提取方法的MKLSVM检测模型识别率
Tab. 1 Recognition rates of MKLSVM detection models based on different feature extraction methods

方法	分层缺陷/%	夹杂缺陷/%	无缺陷处/%	平均/%
DWT	88.75	87.50	80.00	85.42
EMD	92.50	91.25	83.75	89.17
RQA	95.00	93.75	90.00	92.92

4 结束语

本文提出了一种基于递归定量分析和多核学习SVM的GFRP缺陷检测识别模型，并且通过实验研究验证了该模型的有效性。结论表明本文所提出的检测模型可以准确检测识别出GFRP层合板中的分层缺陷与夹杂缺陷，并且与基于传统特征提取方法EMD和DWT的MKLSVM检测模型相比，基于递归定量分析的MKLSVM检测模型在处理具有非线性特征的检测信号方面具有明显优势，更适合处理GFRP复合材料的超声检测信号。

参考文献:

[1] KARATAS M A, GOKKAYA H. A review on machinability of carbon fiber reinforced polymer (CFRP) and glass fiber reinforced polymer (GFRP)

composite materials[J]. Defence Technology, 2018, 14(4): 318-326.

- [2] KORKH Y V, PEROV D V, RINKEVICH A B. Detection of subsurface microflaws using the high-frequency acoustic microscopy method[J]. Russian Journal of Nondestructive Testing, 2015, 51(4): 198-209.
- [3] BARILE C, CASAVOLA C, PAPPALETTERA G, et al. Detection of damage in cfrp by wavelet packet transform and empirical mode decomposition: an hybrid approach[J]. Applied Composite Materials, 2020, 27(5): 641-655.
- [4] DENG T, GONG Y Z, WANG X K, et al. Use of genome-scale integrated analysis to identify key genes and potential molecular mechanisms in recurrence of lower-grade brain glioma[J]. Medical Science Monitor, 2019, 25: 3716-3727.
- [5] WANG P, WANG H, YAN R Q. Bearing degradation evaluation using improved cross recurrence quantification analysis and nonlinear auto-regressive neural network[J]. IEEE Access, 2019, 7: 38937-38946.
- [6] VIRKKUNEN I, KOSKINEN T, JESSEN-JUHLER O, et al. Augmented ultrasonic data for machine learning[J]. Journal of Nondestructive Evaluation, 2021, 40(1): 1-11.
- [7] RAKOTOMAMONJY A, BACH F R, CANUET S, et al. SimpleMKL[J]. Journal of Machine Learning Research, 2008, 9: 2491-2521.
- [8] LANCKRIET G R, CRISTIANINI N, BARTLETT P, et al. Learning the kernel matrix with semidefinite programming[J]. Journal of Machine Learning Research, 2004, 5(1): 27-72.
- [9] GÖNEN M, ALPAYDIN E. Multiple kernel learning algorithms[J]. The Journal of Machine Learning Research, 2011, 12: 2211-2268.
- [10] KENNEL M B, BROWN R, ABARBANEL H D. Determining embedding dimension for phase-space reconstruction using a geometrical construction[J]. Physical Review A, 1992, 45(6): 3403.
- [11] EBERHART R, KENNEDY J. Particle swarm optimization[C]//Proceedings of the IEEE International Conference on Neural Networks, 1995: 1942-1948.