

孔洞缺陷的红外无损检测和 PNN 识别与定量评估

周建民,符正晴,李鹏,杨君

(华东交通大学机电工程学院,江西南昌 330013)

摘要:针对红外无损检测中因特征信息缺失,致使识别与评估效果不佳这一问题,研究以铝板为对象,基于红外无损检测技术,结合主成分分析和概率神经网络对铝板正常区及三类孔洞缺陷区进行了识别与面积定量评估。研究首先采集铝板降温过程的红外时序热图,提取了正常区和各类孔洞缺陷区的时序灰度值作为初始特征。其次,采用主成分分析对初始特征进行提取,并结合概率神经网络,以像素点为单位实现孔洞缺陷的识别及面积定量评估,并采用了支持向量机进行了对比研究。实验结果表明,对于正常区和三类孔洞缺陷区测试样本的面积评估正确率分别为 99.6%、97.0%、94.7% 和 93.0%,相比支持向量机的评估结果,所提出的研究方法具有更高的正确率。研究论证了采用主成分分析和概率神经网络,基于时序特征,以像素点为单位,实现孔洞缺陷识别和面积定量分析的有效性和准确性。

关键词: 红外无损检测; 缺陷识别; 定量评估; 概率神经网络; 主成分分析

中图分类号: TN219; TP29 **文献标志码:** A **文章编号:** 1007-2276(2015)04-1193-05

Infrared nondestructive testing of cavity defects and PNN recognition and quantitative evaluation

Zhou Jianmin, Fu Zhengqing, Li Peng, Yang Jun

(School of Mechatronics Engineering, East China Jiaotong University, Nanchang 330013, China)

Abstract: According to the less accessibility characteristics for the detection of defects will result in detection ineffective and quantitative inaccurate. The study focused on the subject of aluminum plate, based on infrared nondestructive testing technology, combined with principal component analysis and probabilistic neural network (PNN) on the normal area and three kinds of cavity defects area for the recognition and area of quantitative evaluation. Firstly, research during the cooling process of heating aluminum plate, the initial characteristics were obtained from the sequence grey value of normal and three kinds of cavity defects area on the basis of sequence infrared image. And the principal component analysis was used to extract initial characteristics. Finally, combined with the probabilistic neural network, the cavity defects were identified and quantitatively evaluated in pixels. And the support vector machine was used to carry on the comparative study. Experimental results show that the evaluation accuracy rates

收稿日期:2014-08-05; 修订日期:2014-09-15

基金项目:国家自然科学基金项目(51175175);江西省教育厅科技项目(GJJ13342)

作者简介:周建民(1975-),男,教授,博士,主要从事光电检测技术研究。Email:hotzjm@163.com

of the normal and the three kinds of cavity defects area were 99.6%, 97.0%, 94.7% and 93.0% respectively, compared with the evaluation results of support vector machine, the proposed research method has higher accuracy. Research demonstrates that using principal component analysis and PNN, based on the temporal characteristics, to achieve the effectiveness and accuracy of the cavity defects identification and quantitative analysis of the area in units of pixels.

Key words: infrared nondestructive testing; defect recognition; quantitative evaluation; PNN; principal component analysis

0 引言

随着板材及其构件在机械制造、汽车、航空航天和造船等工业领域的广泛应用,对板材表面质量的评估提出了更高的要求。孔洞缺陷作为一种板材的典型缺陷,不仅会导致结构的局部应力集中及材料的性能劣化,而且将严重影响其服役周期^[1]。目前,该类缺陷的有效识别和定量评估已成为无损检测的一个重要研究领域^[2]。

近年来,光学、电子学、精密机械和微型制冷技术等学科的飞速发展,为红外无损检测技术提供了研究基础,并使其成为无损检测技术中重要的研究方向之一。尤其是数字信号处理及模式识别技术的融入,使缺陷识别与定量评估成为红外无损检测的研究热点^[3-4]。目前,红外无损检测技术主要以分析某时刻被测件表面温度差异作为缺陷识别的主要手段和方法,由于受限于单一时刻被测件温差所表征的特征信息量,该方法的识别效率仍有待进一步提高。

为此,研究以铝板为对象,基于红外无损检测技术,结合概率神经网络(PNN, Probabilistic Neural Network)和主成分分析(PCA, Principal Component Analysis),通过提取试件降温过程的时序灰度值作为特征,以像素点为单位进行识别,实现了试件正常和三类孔洞缺陷区的面积定量评估。研究表明,对于正常区和三类孔洞缺陷区,其训练样本的面积评估正确率分别为99.9%、100.0%、99.1%和97.5%,平均正确率为99.1%,其测试样本的正确率分别为99.6%、97.0%、94.7%和93.0%,平均正确率为96.1%。相同条件下,采用支持向量机的测试样本正确率分别为99.9%、97.3%、89.1%和76.4%,平均正确率为90.7%。相比于支持向量机的评估结果,本研

究可获得更高的评估正确率。

1 实验

1.1 实验仪器与试件制备

实验仪器包括热激励源(250 W 红外灯)和红外时序热图采集系统(红外热像仪 IR 970)。

实验试件选用90 mm×75 mm×15 mm的铝板(如图1所示),其表面制备有9个深度为9 mm,直径分别为8 mm、6 mm和4.2 mm的A、B、C三类孔洞缺陷,其中A₁、B₁和C₁作为不同类缺陷的训练样本,其余为测试样本。此外,选择部分正常区作为正常区的训练样本(图1方框区域),其余正常区作为测试样本。




图1 铝板试件

Fig.1 Aluminum plate specimen

1.2 红外时序热图采集

该系统采用IR970红外热像仪和图像采集卡实现时序热图的采集。首先,在距离试件5 cm处,采用热激励源对试件缺陷面进行加热,加热时间为20 min。其次,在加热结束时,利用红外热像仪自动采集试件加热面在降温过程中的红外时序热图,采集周期为30 s。图2为某降温初始时刻处理后的时序灰度图。图中某一像素点(i, j)处的灰度值 $f(i, j)$ 与温度值 $T(i, j)$ 存在如下关系^[5]:

$$f(i, j) = \frac{255(T(i, j) - T_{\min})}{(T_{\max} - T_{\min})} \quad (1)$$

式中: T_{\max} 为红外热图的最高温度; T_{\min} 为红外热图的最低温度。在试件降温过程中, 缺陷的存在将会影响温度场的分布, 时序热图的灰度值间接反应了试件的温度场分布特性。由图 2 可知, 虽然正常区与孔洞缺陷区的灰度值差异较大, 然而各类孔洞缺陷之间的灰度特征相似, 要实现各类孔洞缺陷的有效识别和定量评估, 必须获得缺陷的更多特征。




图 2 处理后的时序灰度图
Fig.2 Sequential image after gradation

2 初始特征获取及其主成分分析

2.1 初始特征获取

对于训练样本的初始特征, 以区域为单位构建, 以保证训练样本所代表模式类的有效性。首先, 在时序热图的基础上进行灰度化, 获取时序灰度图, 并依据试件和缺陷的大小及相对位置, 结合图像的像素确定图中各样本的区域。该灰度图像素大小为 180×150 , 以像素大小为 180×32 的区域作为正常区的训练样本(即, 图 1 中面积为 $90 \text{ mm} \times 16 \text{ mm}$ 的方框区域)。以 A_1 、 B_1 、和 C_1 为孔洞缺陷的训练样本区; 其次, 将正常区和各类孔洞缺陷区域细分为 5 个子区域, 其中以孔洞半径进行等分, 将孔洞区划分为 5 个圆形子区域(如, 第一子区域表示为 A_{11} 、 B_{11} 和 C_{11}), 正常区的 5 个子区域分别表示为 O_1 、 O_2 、 O_3 、 O_4 、 O_5 , 分别计算各子区的平均值; 最后, 为减小随机误差, 采用曲线拟合的方法对各子区的时序灰度平均值进行曲线拟合, 并在拟合曲线上每隔 30 s 选取一个灰度值, 构建训练样本的初始特征。图 3 为正常和各类缺陷的第一子区的灰度平均值拟合曲线。

对于测试样本的初始特征提取, 以像素点为单位构建, 以保证面积评估的正确率。




图 3 正常及孔洞缺陷区灰度值随时间变化的曲线
Fig.3 Curve of gray level values of normal and hole defect area change over time

2.2 初始特征的主成分分析

由于各类样品的初始特征值之间包含大量相关和冗余信息, 为保证缺陷识别效率, 研究采用主成分分析法^[6]对初始特征进行提取, 主成分分析的计算步骤如下^[7]:

(1) 建立初始特征矩阵 X 。分别以正常区和孔洞缺陷区(A_1 、 B_1 、 C_1)抽取训练集样品的灰度特征点, 经标准化后, 建立初始特征矩阵 X :

$$X = \begin{bmatrix} X_{11} & X_{12} & \cdots & X_{1p} \\ X_{21} & X_{22} & \cdots & X_{2p} \\ \cdots & \cdots & \cdots & \cdots \\ X_{n1} & X_{n2} & \cdots & X_{np} \end{bmatrix} \quad (2)$$

式中: n 为训练样本数; p 为初始特征维数, 依据每隔 30 s 取该点的灰度值, 共有 30 个灰度特征值, p 为 30。

(2) 计算初始特征矩阵 X 的标准化矩阵 S 。

(3) 计算标准化矩阵 S 的特征值 $\lambda_i (i=1, 2, \dots, p)$ (其中, 特征值 按由大到小顺序排列), 并计算出累积贡献率, 确定贡献率大于 85% 的主成分个数 m 。

(4) 计算主成分: 确定贡献率大于 85% 的主成分, 并作为样本特征用于概率神经网络的识别。

正常和各类缺陷样本的主成分散点图如图 4 所示。




图 4 正常和各类缺陷的主成分散点图($m=3$)
Fig.4 Main scattered points of normal and various defects($m=3$)

3 基于 PNN 的缺陷识别与定量评估

概率神经网络是基于贝叶斯分类规则与概率密度函数估计方法发展而来的一种并行分类算法。PNN 由输入层、模式层、求和层、输出层共 4 层组成。测试样品的特征矢量由输入层放入神经网络后,模式层与累加层将计算出该样品在每一模式类的概率密度,具有最大值的那一类将被认为是当前测试样品的模式类。其中,概率密度的计算公式如下^[8]:

$$f_A(X) = \frac{1}{(2\pi)^{p/2} \delta^p} \frac{1}{N_A} \sum \exp \left[-\frac{(X-X_{Ai})^T(X-X_{Ai})}{2\delta^2} \right] \quad (3)$$

式中: X 为测试样品的 p 维特征向量; $f_A(X)$ 为 X 属于 A 类的概率密度函数; X_{Ai} 为第 A 类缺陷类型的第 i 组训练样品的特征向量,其中 $i=5$; N_A 为 A 类中训练样品的个数; δ 为平滑系数。根据提取的时序灰度样本集进行主成分分析获得的前三个主成分得分,即可对 PNN 神经网络进行训练。当正常区和孔洞缺陷区 A_1 、 B_1 、 C_1 的训练集样品放入模式层之后,训练样本训练完成,然后对试件的所有像素点进行类型识别。并根据像素点所占有的面积进一步实现其孔洞缺陷面积的定量评估。

4 结果与分析

以像素点为单位,采用主成分分析和概率神经网络方法,以正常区、 A_1 、 B_1 和 C_1 三类孔洞缺陷区的时序灰度值作为训练集,然后对其他测试集进行识别,实验结果如图 5 所示,其中,识别为正常和缺陷的像素分别以黑点和白点表示。



图 5 像素识别结果

Fig.5 Results of pixel identification

并根据单位像素点面积(0.25 mm^2)计算正常区和三类缺陷区的评估面积,表 1、表 2 分别为训练样

本和测试样本面积定量评估的结果。

表 1 训练样本定量评估

Tab.1 Quantitative evaluation of training sample

	Normal	A	B	C
Number of test pixels	5 760	201	113	55
Test area /mm ²	1 440	50.24	28.26	13.85
Number of identifiable pixels	5 754	201	112	54
Identifiable area/mm ²	1 438.50	50.25	28.00	13.50
Correct rate of area/%	99.9	100.0	99.1	97.5

表 2 测试样本定量评估

Tab.2 Quantitative evaluation of test sample

	Normal	A	B	C
Number of test pixels	20 133	201×2	113×2	55×2
Test area /mm ²	5 032.96	50.24×2	28.26×2	13.85×2
Number of identifiable pixels	20 051	390	214	103
Identifiable area/mm ²	5 012.75	97.50	53.50	25.75
Correct rate of area/%	99.6	97.0	94.7	93.0

结果表明:

(1) 对于正常区,训练样本和测试样本的面积评估正确率分别为 99.9% 和 99.6%,根据拟合曲线(图 3)和主成分散点图(图 4)可以看出,获得较高正确率的原因在于正常区与三类缺陷区的灰度值和特征均有很好的区分度。

(2) 对于孔洞类缺陷 A 类、 B 类和 C 类,训练样本的面积评估正确率分别为 100.0%、99.1% 和 97.5%,相应的测试样本面积评估正确率分别为 97.0%、94.7% 和 93.0%(表 1 和表 2)。结果表明孔洞缺陷面积越大的识别率越高,其原因在于缺陷边缘区域存在特征混淆的现象,增加了识别的难度,但结果表明该方法仍可保证较高的识别率。

(3) 对比训练和测试样本的评估结果可以发现, 虽然后者的评估结果略低于前者, 但仍可保持较高的水平。

(4) 在相同条件下, 采用支持向量机对测试样本中正常区和三类孔洞缺陷区进行识别, 其面积评估正确率分别为 99.9%、97.3%、89.1% 和 76.4%, 平均正确率: 90.7%, 识别时间为 1.465s。而 PNN 方法的正确率分别为 99.6%、97.0%、94.7% 和 93.0%, 平均正确率 96.1%, 识别时间为 0.954s。结果表明, 在识别正确率和识别时间方面, 概率神经网络明显优于支持向量机。

5 结论

针对红外检测中因特征信息缺失, 致使识别效率不佳和定量评估不准确这一问题, 研究在采集铝板降温过程的红外时序热图的基础上, 提取时正常区和孔洞缺陷区的时序灰度值作为初始特征, 通过主成分分析成功地提取了样品的特征向量; 并结合概率神经网络, 以像素为单位, 对孔洞缺陷进行识别并进一步实现了面积定量评估。结果表明, 正常区和孔洞缺陷 A 类、B 类和 C 类的测试样本的面积评估正确率分别为 99.6%、97.0%、94.7% 和 93.0%。克服了仅依靠单一时刻红外热图进行缺陷识别的局限性, 提高了识别及定量评估的有效性和精确性, 具有重要的意义和价值。

参考文献:

- [1] Lv Xinmin, Luo Zhiyong. The real-time detection of the moving steel strip surface hole with plane array charge coupled devices [J]. *Opto-Electronic Engineering*, 1997, 24(1): 42-45. (in Chinese)
吕新民, 罗志勇. 用面阵 CCD 实时检测运动带钢表面孔洞 [J]. *光电工程*, 1997, 24(1): 42-45.
- [2] Yang Shuishan, He Yonghui, Zhao Wansheng. Strip steel surface defect recognition based on Boosting optimized decision tree [J]. *Infrared and Laser Engineering*, 2010, 39(5): 954-958. (in Chinese)
杨水山, 何永辉, 赵万生. Boosting 优化决策树的带钢表面缺陷识别技术 [J]. *红外与激光工程*, 2010, 39(5): 954-958.
- [3] Liu Yongchang, Wu Peng, Zhang Li. Intelligent IR imaging homing guidance technique toward new century [J]. *Infrared Technique*, 2002, 24(2): 1-5. (in Chinese)
刘永昌, 吴鹏, 张黎. 迈向新世纪的智能化红外成像的制导技术 [J]. *红外技术*, 2002, 24(2): 1-5.
- [4] Feng Lichun, Tao Ning, Xu Chuan. Lock in thermography and its application in nondestructive evaluation [J]. *Infrared and Laser Engineering*, 2011, 40(6): 1121-1123. (in Chinese)
冯立春, 陶宁, 徐川. 锁相热像技术及其在无损检测中的应用 [J]. *红外与激光工程*, 2011, 40(6): 1121-1123.
- [5] Bulanon D M, Burks T F, Alchanatis V. Image fusion of visible and thermal images for fruit detection [J]. *Bio Systems Engineering*, 2009, 103(1): 12-22.
- [6] Lee J J, Kim D, Chang S K. An improved application technique of the adaptive probabilistic neural network for predicting concrete strength [J]. *Computational Materials Science*, 2009, 44(3): 988-998.
- [7] Li Junmei, Hu Yihua, Tao Xiaohong. Recognition method based on principal component analysis and back-propagation neural network [J]. *Infrared and Laser Engineering*, 2006, 34(6): 719-723. (in Chinese)
李军梅, 胡以华, 陶小红. 基于主成分分析与 BP 神经网络的识别方法研究 [J]. *红外与激光工程*, 2006, 34(6): 719-723.
- [8] Lee J J, Lee J W, Yi J H, et al. Neural networks-based damage detection for bridges considering errors in baseline finite element models [J]. *Journal of Sound and Vibration*, 2005, 280(3): 555-578.