

一种集成多个机器学习模型的复合材料结构损伤识别方法

杨宇¹, 周雨熙², 王莉¹

(1. 中国飞机强度研究所, 西安, 710065; 2. 北京大学信息科学技术学院, 北京, 100871)

摘要: 针对基于导波的复合材料结构损伤监测手段在实际工程应用中遇到的问题, 结合目前已开展的利用机器学习模型辅助结构损伤识别的经验, 提出了一种基于最小边际系数的复合材料结构损伤识别方法。通过采用多个机器学习模型对监测数据进行预测, 利用不同机器学习模型之间的差异性和在不同数据分布上的预测置信度, 提高整体结构损伤识别的泛化能力。通过试验验证, 该方法能明显提高基于导波的复合材料结构损伤识别精度。

关键词: 机器学习; 导波; 复合材料; 结构健康监测; 最小边际

中图分类号: TP181 **文献标志码:** A

Integrated Method of Multiple Machine-Learning Models for Damage Recognition of Composite Structures

YANG Yu¹, ZHOU Yuxi², WANG Li¹

(1. Aircraft Strength Research Institute of China, Xi'an, 710065, China; 2. School of Electronics Engineering and Computer Science, Peking University, Beijing, 100871, China)

Abstract: In the topic of damage detection of composite structures based on lamb wave technology, damage index is commonly used for damage identification. However, its threshold is largely of expertise-dependence and poor performance at knowledge generalization. Therefore, a method based on the concept of least margin is proposed, which integrates even machine learning models and outputs the identification result by polling all models' decision. The proposed method avoids the shortage that damage recognition relies on a single but incomprehensive model, and puts the confidence on a number of most qualified models instead. Significantly higher accuracy of damage identification for composite structures is manifested through test verification.

Key words: machine learning; guided wave; composites; structural health monitoring; least margin

引言

碳纤维增强复合材料层压结构(Carbon fiber reinforced plastic laminates, CFRP laminates)已经广泛应用于飞机主承力部件,其应用量多少是反映飞机结构设计先进性的一个重要指标。但相比于传统的金属结构,CFRP laminates的主要缺点是对外来物冲击敏感(Foreign object impact, FOI),特别是当遭遇低速冲击时,如维护过程中的工具跌落、起降过程中的跑道碎片撞击等。这些冲击会造成层压结构

内部大面积分层,结构压缩强度下降40%以上,但是结构外观通常并不产生目视可见的损伤^[1],这会给飞行安全带来很大的隐患。针对这个问题,能够实时甚至在线地对结构状态进行监测的结构健康监测技术(Structural health monitoring, SHM)为上述问题提供了潜力巨大的解决途径^[2]。基于导波的损伤监测技术利用导波在结构中能传播较长距离且对裂纹、脱粘和分层等损伤敏感的特征^[3-12],是目前有效的、在航空结构损伤监测领域较有前景的一种结构损伤监测方法^[13-15]。经过半个世纪的发展^[16-17],基于导波的损伤监测技术已成功进入商业应用。然而,其面向航空复合材料结构的损伤监测能力,一直未能达到令人满意的程度,主要原因是基于导波信号的损伤判定阈值一直依赖专家经验。受结构构型、边界条件和环境温度等因素的影响,根据专家经验很难作出准确可靠的判断。例如,一种主要的损伤识别方法,是将原始监测信息的若干特征转换成损伤指数(Damage index, DI),通过损伤指数的高低来判断损伤是否发生。然而,由于DI缺乏明确的物理意义,需要通过大量的试验来确定经验阈值;但由于受多种因素影响,该经验阈值的泛化能力较差。机器学习技术作为一种数据驱动的建模技术,在上述缺乏物理模型或复杂非线性现象的不确定性建模中非常有用。

因此,本文收集了一定规模的基于导波的复合材料结构状态监测数据,并针对现有机器学习模型在解决此类问题中的不足,提出了一种基于交叉验证的递归特征消除与最小边际系数方法,开展更高效的结构损伤识别方法的探索研究。

1 基于导波的结构损伤监测原理

导波是横波和纵波在薄壁结构中经上下表面不断反射相互耦合后形成的一种弹性波^[18]。基于导波的结构损伤监测原理为:导波在结构中传播时,当其遇到结构边界或损伤(如内部分层、界面脱粘等)时,会产生边界反射信号或损伤散射信号。通过采用合适的信号分析方法^[19],提取出由疑似损伤引起的损伤散射信号,并对其进行时域、频域等^[20-21]分析处理,最终获得损伤有无、位置和程度等信息,从而达到对结构损伤进行监测的目的。

具体的实现步骤如下:在结构上布置压电片网络,如图1(a)所示。由于其压电效应,压电片既可作为信号激发器,也可作为信号接收器。当作为激发器时,在电信号激励下,压电片振动激发导波在结构中传播;当作为接收器时,将接收到的导波信号转换为电信号以供存储分析。任意2个压电片构成一条监测路径(Monitoring path)。通过轮换每个压电片的信号激发和接收功能,使结构上所有压电片构成一个监测网络,如图1(b)所示。通过对比分析每条路径上的初始基准信号(Baseline signal)和过程监测信号(Monitoring signal)实现损伤识别功能。

图2(a),(b)分别为平板复合材料结构中在有分层损伤和无损伤路径上各自初始基线信号与过程监测信号对比图。从图2(a)可以看出,由于损伤的引入,前后监测信号有较大差别。但从图2(b)也可

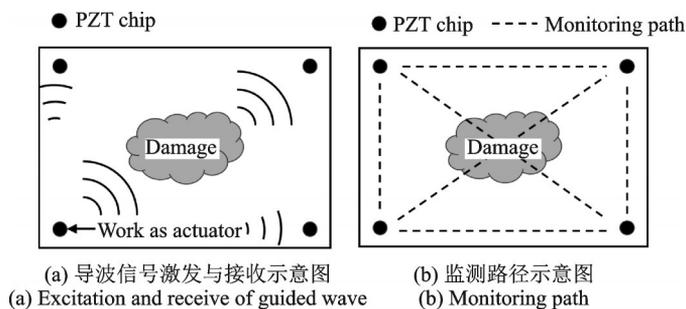


图1 压电传感器结构网络布置示意图

Fig.1 Schematic configuration of PZT sensor network

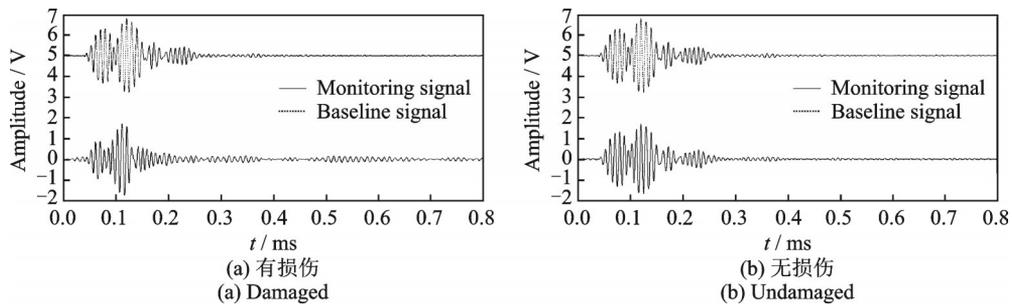


图2 复合材料平板结构中有损伤和无损伤情况下初始基线信号与过程监测信号对比图

Fig.2 Comparison of baseline and monitoring signals of guided waves in damage and undamaged cases of a composite laminate

发现,尽管未出现损伤,但前后监测信号仍有一定差别。表1列举了这4条信号在峰值时刻,幅值、能量等特征方面的差异。随着结构复杂程度的增加,以及各种环境因素的影响,这些差异会变得更加不明显或缺乏规律性。

表1 无损与有损伤情况下的典型导波信号特征对比

Table 1 Comparison of typical signal characteristics in undamaged and damaged cases of a composite laminate

状态	信号	典型信号特征		
		直达峰值时刻/ (10^{-7} s^{-1})	直达幅值/V	直达波能量/ (10^{-5} J^{-1})
无损	基线信号	1 212	1.791	5.169 6
	监测信号	1 210	1.797	5.072 5
	差值	2	-0.006	0.097 1
有损伤	基线信号	976	1.827	6.134 2
	监测信号	1 163	1.753	4.072 5
	差值	-187	0.074	2.061 7

2 结构状态监测数据

2.1 复合材料结构试验

本文所使用的试验数据来自2种不同结构的试验,分别是复合材料机身曲框4点弯曲试验和复合材料加筋板冲击试验。

2种试验采用了相同的损伤监测设备:压电多通道监测系统。监测设备的设置参数相同,其中激励信号的中心频率为90 kHz,信号采样频率为10 MHz,信号采样长度为5 000个数据点。试验中传感器都采用了P-51压电片,其直径为8 mm,厚度为0.45 mm。

在复合材料机身曲框4点弯曲试验中,加载方式如图3所示。根据经验,此类型试验的损伤类型为长桁与蒙皮之间的脱粘分层。因此,在易出现损伤的2个长桁两侧,各布置了一对压电传感器(图4)。在加载前,采集

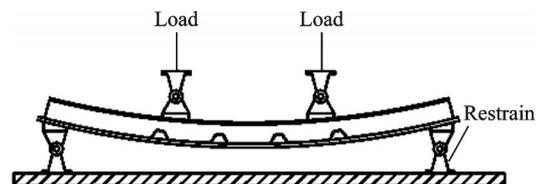


图3 试验件及其加载装置

Fig.3 Specimen for testing and its load device

了初始基准信号。在试验过程中,线性增加载荷直至结构破坏丧失承载能力。试验结束后,采集了服役监测信号。然后通过超声A扫描,确认了损伤形式为长桁与蒙皮之间的脱粘分层。分层位置如图4所示。

在复合材料加筋板冲击试验中,压电传感器网络布置如图5所示,共形成28条监测路径。在开始试验前,采集初始基准信号。试验中,采用落锤冲击装置对试验件进行冲击,从而在试验件中引入冲击分层损伤。冲头质量为3537g,冲头直径为16mm,冲头材质为钢,冲击能量范围为35~45J。试验结束后,采集了服役监测信号;然后用英国声纳公司生产的超声相控阵C扫描设备对冲击损伤进行了无损检测,以精确了解冲击分层损伤情况。

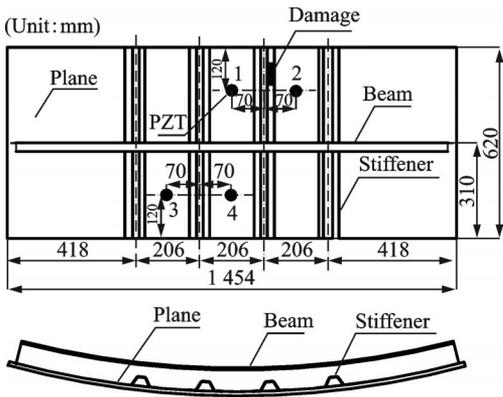


图4 压电传感器布置示意图
Fig.4 Layout of PZT sensors

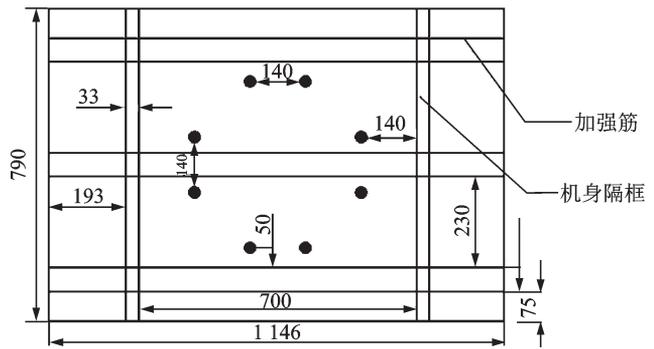


图5 加筋板尺寸和传感器位置的示意图
Fig.5 Schematic demonstration of stiffen panel and sensor network

2.2 监测数据预处理

通过复合材料机身曲框4点弯曲试验和复合材料加筋板冲击试验,得到808条有标签的导波监测数据集(见表2),其中无损伤数据有538条(占比66.58%),有损伤数据270条(占比33.42%)。这里“1条数据”指的是沿着1条监测路径上采集得到的基线信号和监测信号的集合。

按照文献[20,21]所提供的公式,对每一条数据计算得到12种损伤指数,如表3所示。

表3 损伤指数计算公式

Table 3 Mathematic expressions of DI

时域DI	表达式
Peak-to-peak amplitude ^[22]	$DI=A_1 - A_2$
Amplitude combined with ToF ^[23]	$DI=(A_1 - A_2) \times (T_{f_1} - T_{f_2})$
Root mean square ^[24]	$DI=\sqrt{(1/T) \int [f(t)]^2 dt}$
Root mean square deviation ^[25]	$DI=\sqrt{\int [f_2(t) - f_1(t)]^2 dt / \int f_1^2(t) dt}$
Variance	$DI=(1/T) \int (f(t) - \bar{f})^2 dt$
DI based on signal energy ^[26]	$DI=(\int f_1(t) ^2 dt) / (\int f_2(t) ^2 dt)$

表2 试验数据集

Table 2 Monitoring data status

试验类型	信号数量	损伤信号数量
机身框四点弯曲试验	58	17
加筋壁板冲击试验	750	253

续表

时域DI	表达式
DI based on signal energy ^[27]	$DI = \left(\int f_1(t) - f_2(t) ^2 dt \right) / \left(\int f_2(t) ^2 dt \right)$
DI based on signal energy ^[28]	$DI = \left(\int f_1(t) ^2 dt - \int f_2(t) ^2 dt \right) / \left(\int f_2(t) ^2 dt \right)$
DI based on Pearson correlation coefficient ^[29]	$DI = 1 - \left \frac{\sqrt{\int (f_1(t) - \bar{f}_1)(f_2(t) - \bar{f}_2) dt}}{\sqrt{\int (f_1(t) - \bar{f}_1)^2 dt} \sqrt{\int (f_2(t) - \bar{f}_2)^2 dt}} \right $
DI based on time-reversal	$DI = \frac{\int_0^T f_2^2(t) dt}{\int_0^T f_1^2(t) dt}$
DI's based on attenuation ^[30]	$DI = \ln(A_1/A_2)$
DI based on nonlinear time series analysis ^[31]	$DI = \frac{\int_0^T f_2^2(t) dt - \int_0^T f_1^2(t) dt}{\int_0^T f_1^2(t) dt}$

注: A_1 为基准信号的幅值, A_2 为损伤响应信号的幅值, T 为信号的采集长度, $f_1(t)$ 为基准信号, $f_2(t)$ 为损伤响应信号, $f(t) = f_1(t) - f_2(t)$ 为损伤散射信号, \bar{f}_1 为基准信号的平均值, \bar{f}_2 为损伤响应信号的平均值, T_{f_1} 为基准信号的峰值时刻, T_{f_2} 为损伤响应信号的峰值时刻, \bar{f} 为损伤散射信号的平均值。

3 基于最小边际系数的损伤识别方法

现有几种适合于处理导波数据的机器学习模型方法包括:最近邻 (k -nearest neighbor, KNN), 使用径向基函数的支撑向量机 (Radial basis function support vector machine, RBF-SVM), 高斯过程 (Gaussian process, GP), 决策树 (Decision tree, CvDTree), 神经网络 (Neural network, NN), 高斯朴素贝叶斯 (Gaussian naive Bayes, GNB) 和二次判别分析 (Quadratic discriminant analysis, QDA)。它们各具优缺点, 均不能在很广的范围内始终表现良好。因此, 本文提出一种基于最小边际系数 (Least margin) 的集成学习技术, 使用以上 7 种机器学习模型对同一组数据分别预测其不确定度 (即边际系数), 并选择在不同学习方法中具有最高置信度 (最小不确定性边际系数) 的预测结果作为最终预测结果, 相当于邀请多名专家 (机器学习模型) 组成决策委员会。对每项具体事件的决策结论, 是由对该事件认识最深刻、最权威 (即最小边际系数) 的几位专家的结论通过投票决定的。为了能够言简意赅的解释该方法, 图 6, 7 分别介绍了训练和测试的基本流程, 同时按照对数据的处理流程进行举例说明。

在模型训练阶段, 对每一条监测路径上的基线信号和监测信号, 按照表 3 公式所示, 分别计算出 12 种 DI 值。使用这 12 种 DI 值, 以及这条监测路径的状态结果 (有损伤或无损伤), 对 7 种机器学习模型逐一进行训练, 使其具备基于 12 种 DI 值能够进行结构状态判别得能力。

在模型测试阶段, 首先, 对一条数据记录 x_i , 通过第 2 节的预处理, 获得了 12 种损伤指数。然后使用每一种机器学习模型, 根据这 12 种损伤指数对其代表的结构状态进行预测。例如, 机器学习模型 ϕ_1 预测其为有损伤的概率为 0.95, 预测其为无损伤的概率为 0.05, 确定预测结果为“有损伤”; 机器学习模型 ϕ_2 预测其为有损伤的概率为 0.25, 预测其为无损伤的概率为 0.75, 确定预测结果为“无损伤” (如表 4 的前 4 行所示)。

因此, 一条数据记录 x_i 在一种机器学习模型 ϕ_n 下的不确定性边际系数定义为

$$\text{Margin}(x_i, \phi_n) = P(\hat{y}_n^{(2)} | x_i, \phi_n) - P(\hat{y}_n^{(1)} | x_i, \phi_n) \quad (1)$$

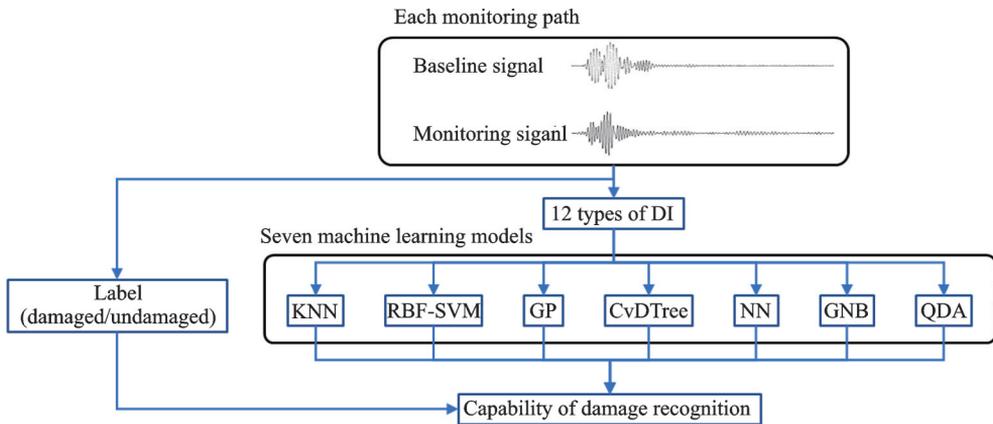


图6 模型训练基本流程

Fig.6 General procedure of model training

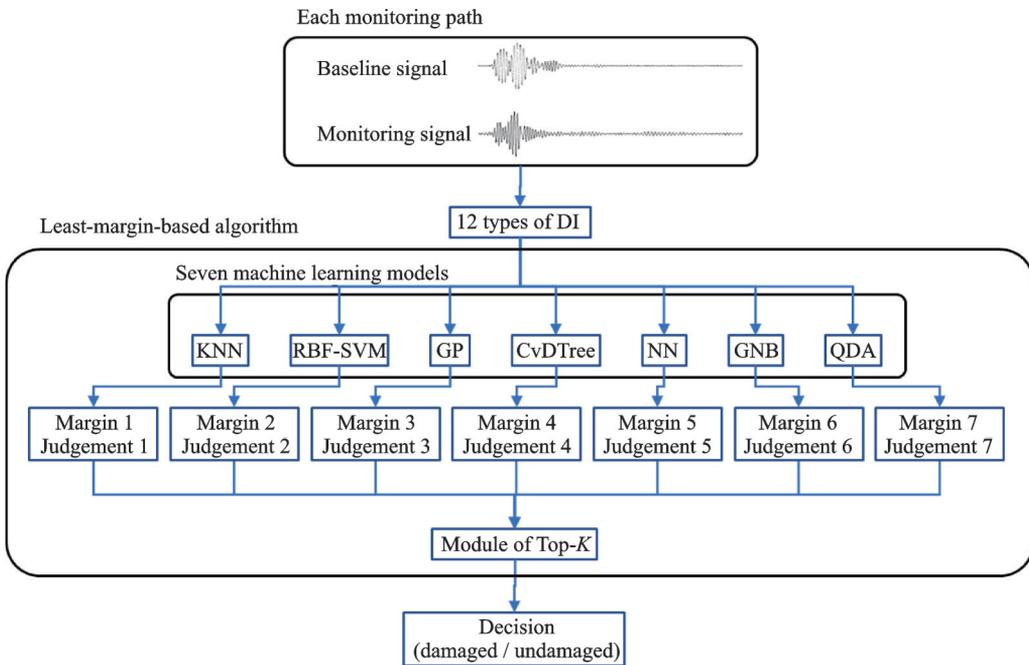


图7 模型测试基本流程

Fig.7 General procedure of model testing

表4 针对数据 x_i 的结构状态识别流程示例

Table 4 Example of structural state identification from data x_i

机器学习模型	ϕ_1	ϕ_2	ϕ_3	ϕ_4	ϕ_5	ϕ_6	ϕ_7
概率最大状态-有损伤	0.95		0.85		0.775	0.675	
概率第2大状态-无损伤	0.05		0.15		0.225	0.325	
概率最大状态-无损伤		0.75		0.65			0.55
概率第2大状态-有损伤		0.25		0.35			0.45
边际系数(式(1))	-0.90	-0.50	-0.70	-0.30	-0.55	-0.35	-0.10
座次排名	1	4	2	6	3	5	7
最高置信度的方法(式(2))	ϕ_1						
最高置信度方法预测的结构状态(式(3))	有损伤(概率为0.9)						

式中： $\hat{y}_{in}^{(1)}$ 和 $\hat{y}_{in}^{(2)}$ 分别为数据记录 x_i 在机器学习模型 ϕ_n 下概率最大和第二大的结构状态类型， P 为预测为该结构状态的概率。则机器学习模型集合 $\phi=[\phi_1, \phi_2, \dots, \phi_N](N=7)$ 中使这一条数据 x_i 置信度最高的机器学习模型定义为

$$\phi_i^* = \arg \min_{\phi_n, n \in \{1, 2, \dots, N\}} \text{Margin}(x_i, \phi_n) = \arg \max_{\phi_n, n \in \{1, 2, \dots, N\}} (P(\hat{y}_{in}^{(1)}|x_i, \phi_n) - P(\hat{y}_{in}^{(2)}|x_i, \phi_n)) \quad (2)$$

类似地，定义数据 x_i 在机器学习模型集合 $\phi=[\phi_1, \phi_2, \dots, \phi_N]$ 中置信度最高的损伤状态类型为

$$y_i^* = \arg \max_{\hat{y}_{in}^{(1)}, n \in \{1, 2, \dots, N\}} (P(\hat{y}_{in}^{(1)}|x_i, \phi_n) - P(\hat{y}_{in}^{(2)}|x_i, \phi_n)) \quad (3)$$

以表4的数据处理为例，针对数据 x_i 找到具有最高置信度的机器学习模型 ϕ_1 后，将其从机器学习模型集合 ϕ 中去掉，然后针对余下的机器学习模型重复以上流程。通过 K 次循环迭代，可以利用式(2)，(3)得到机器学习模型集合 $\phi=[\phi_1, \phi_2, \dots, \phi_N]$ 下数据记录 x_i 的 K 个置信度最高的损伤状态类别，即不确定度边际最小的 K 个状态类别集合 $\hat{Y}_{1:K}^{(i)}$ ，其算法流程如算法1所示。

算法1 Selecting top- K labels

输入：监测数据 x_i ，整数 K ，机器学习模型集合 $\phi=[\phi_1, \phi_2, \dots, \phi_n]$

输出：针对监测数据 x_i ，机器学习模型集合 ϕ 中 K 个置信度最高的损伤状态类别

function $K\text{-LABELS}(x_i, K, \phi)$

$\hat{Y}_{1:K}^{(i)} \leftarrow \phi$

$k \leftarrow K$

while $k > 0$ do

$\phi_i^* \leftarrow$ 针对监测数据 x_i ，根据式(2)得到在模型集合 $\phi(x_i)=[\phi_1(x_i), \phi_2(x_i), \dots, \phi_n(x_i)]$ 中置信度最高的机器学习模型

$y_i^* \leftarrow$ 根据式(3)得到该机器学习模型给出的预测结果

$\phi \leftarrow \phi \setminus \phi_i^*$

$\hat{Y}_{1:K}^{(i)} \leftarrow \hat{Y}_{1:K}^{(i)} \cup \{y_i^*\}$

$k \leftarrow k - 1$

end while

return $\hat{Y}_{1:K}^{(i)}$

end function

按照该算法，通过 K 次迭代(这里假设 $K=5$)，得到对数据记录 x_i 的 $K=5$ 个状态类别集合：[有损伤，有损伤，有损伤，无损伤，有损伤]。根据式(4)

$$\hat{Y}_{k,j}^{(i)} = \begin{cases} 1 & \hat{y}_k^{(i)} = c_j \\ 0 & \text{其他} \end{cases} \quad (4)$$

将其扩充成矩阵形式，如表5所示。

表5 状态类别的矩阵形式

Table 5 State categories in matrix form

K	C_1 (有损伤)	C_2 (无损伤)
1	1	0
2	1	0
3	1	0
4	0	1
5	1	0
总票数	4	1

最后对不确定度边际系数最小的 K 个损伤状态类别进行投票

$$\hat{y}^{(i)} = \arg \max_j \left(\sum_{j=1}^K \hat{Y}_{k,j}^{(i)} \right) \quad (5)$$

将得票率最高的损伤状态类别称之为 K -边际系数最小的损伤状态类别,亦即在多个机器学习模型下置信度最高的损伤状态类别,并将其作为学习模型集合 ϕ 下识别出的数据记录 x_i 的最终损伤状态。在本例中,针对数据 x_i ,有损伤状态获得的票数是 4 票,无损伤 1 票。因此,最终该方法判定数据 x_i 代表的结构状态为“有损伤”。

4 试验验证

4.1 验证指标

试验验证过程中,将试验数据集随机分割成 70% 的训练集和 30% 的测试集。在训练 10 次后,进行 10 次测试,取预测结果的平均值来进行考核。模型效果的评估方面采用机器学习领域常用的 3 个模型性能评价指标(准确率、召回率和 F_1 值)进行评估,如图 8 所示。

A 表示模型将实际标签为无损伤的数据识别为无损伤的实例, B 表示模型将实际标签为无损伤的数据识别为有损伤的实例, C 表示模型将实际标签为有损伤的数据识别为无损伤的实例, D 表示模型将实际标签为有损伤的数据识别为有损伤的实例,所以对实际标签为无损伤的数据实例来说准确率(查准率)为 $A/(A+B)$,召回率(查全率)为 $A/(A+C)$, F_1 值为准确率和召回率的加权平均值。准确率和召回率是相互影响的,一般情况下模型准确率高了召回率就会变低,召回率高准确率就低,但希望模型不仅能识别准确,还应该每类的所有实例都不要有识别遗漏(也就是需要查全率高),所以一般希望两者都高的情况下就用 F_1 值来衡量模型的性能。

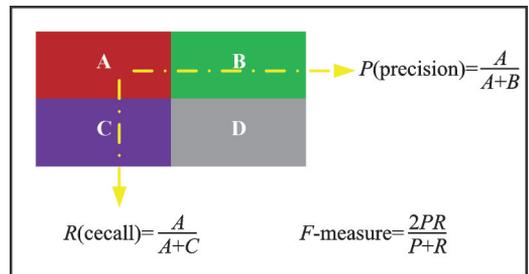


图 8 模型性能评价指标示意图

Fig.8 Schematic of model performance evaluation index

4.2 准确度比较

表 6 列举了基于多种机器学习模型的损伤识别准确度比较,从结果可以看出,基于最小边际系数的损伤识别方法在各项指标中优势明显。

表 6 基于特征工程的机器学习模型准确度比较

Table 6 Accuracy comparison of least margin with other machine learning methods

方法	准确率 / %	召回率 / %	F_1 / %
KNN	64.29	57.69	63.11
RBF-SVM	65.97	50.00	52.44
GP	39.50	54.14	28.11
CvDTree	74.50	78.30	73.89
NN	34.03	50.00	17.28
GNB	68.07	53.09	57.07
QDA	67.65	52.47	56.18
最小边际	91.31	89.83	90.54

5 结束语

当前,利用导波对复合材料结构进行状态监测是结构健康监测的一个重要研究方向,其中损伤指数法是最常用的一种方法。但是,该方法存在严重依赖专家经验、损伤指数阈值受试验环境影响大的问题。鉴于此,本文提出了一种基于最小边际系数的结构状态识别方法。该方法集成了7种机器学习模型,能够自动选择对不同模型最有效的监测信号特征集合,并充分利用不同模型之间的差异性和在不同数据分布上的预测置信度对多种机器学习模型进行集成学习,从而从整体上提高本方法对结构损伤的识别精度。经过验证,该方法的识别精度达到91%。

参考文献:

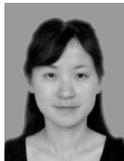
- [1] CRAVEN R, IANNUCCI L, OLSSON R. Delamination buckling: A finite element study with realistic delamination shapes, multiple delaminations and fibre fracture cracks[J]. *Composites Part A: Applied Science and Manufacturing*, 2010, 41(5): 684-692.
- [2] 卿新林, 王奕首, 赵琳. 结构健康监测技术及其在航空航天领域中的应用[J]. *实验力学*, 2012, 27(5): 517-526.
QING Xinlin, WANG Yishou, ZHAO Lin. Structural health monitoring technology and its application in aeronautics and astronautics[J]. *Journal of Experimental Mechanics*, 2012, 27(5): 517-526.
- [3] IHN J B, CHANG F K. Detection and monitoring of hidden fatigue crack growth using a built-in piezoelectric sensor/actuator network: I. Diagnostics[J]. *Smart Materials and Structures*, 2004, 13(3): 609.
- [4] IHN J B, CHANG F K. Pitch-catch active sensing methods in structural health monitoring for aircraft structures[J]. *Structural Health Monitoring*, 2008, 7(1): 5-19.
- [5] PUREKAR A S, PINES D J. Damage detection in thin composite laminates using piezoelectric phased sensor arrays and guided lamb wave interrogation[J]. *Journal of Intelligent Material Systems and Structures*, 2010, 21(10): 995-1010.
- [6] QIU Lei, YUAN Shenfang, ZHANG Xiaoyue, et al. A time reversal focusing based impact imaging method and its evaluation on complex composite structures[J]. *Smart Materials and Structures*, 2011, 20(10): 105014.
- [7] RAMADAS C, BALASUBRAMANIAM K, JOSHI M, et al. Sizing of interface delamination in a composite T-joint using time-of-flight of Lamb waves[J]. *Journal of Intelligent Material Systems and Structures*, 2011, 22(8): 757-768.
- [8] YU Lingyu, GIURGIUTIU V, WANG Jingjiang, et al. Corrosion detection with piezoelectric wafer active sensors using pitch-catch waves and cross-time-frequency analysis[J]. *Structural Health Monitoring*, 2012, 11(1): 83-93.
- [9] NG C T, VEIDT M. Scattering characteristics of Lamb waves from debondings at structural features in composite laminates[J]. *The Journal of the Acoustical Society of America*, 2012, 132(1): 115-123.
- [10] QIU Lei, LIU Menglong, QING Xinlin, et al. A quantitative multidamage monitoring method for large-scale complex composite[J]. *Structural Health Monitoring*, 2013, 12(3): 183-196.
- [11] CLOUGH A R, EDWARDS R S. Characterisation of hidden defects using the near-field ultrasonic enhancement of lamb waves [J]. *Ultrasonics*, 2015, 59: 64-71.
- [12] HE Jingjing, RAN Yunmeng, LIU Bin, et al. A fatigue crack size evaluation method based on Lamb wave simulation and limited experimental data[J]. *Sensors*, 2017, 17(9): 2097.
- [13] NG C T, VEIDT M. A Lamb-wave-based technique for damage detection in composite laminates[J]. *Smart Materials and Structures*, 2009, 18(7): 074006.
- [14] ONG W H, CHIU W K. Redirection of Lamb waves for structural health monitoring[J]. *Smart Materials Research*, 2012, 2012: 1-9.
- [15] MEMMOLO V, MONACO E, BOFFA N D, et al. Guided wave propagation and scattering for structural health monitoring of stiffened composites[J]. *Composite Structures*, 2018, 184: 568-580.
- [16] WORLTON D C. Experimental confirmation of Lamb waves at megacycle frequencies[J]. *Journal of Applied Physics*, 1961, 32(6): 967-971.
- [17] DEMER L J, FENTNOR L H. Lamb wave techniques in nondestructive testing: Lamb waves behavior applied to defect

- evaluation in nondestructive tests of solid elongated cylindrical objects[J]. *International Journal of Nondestructive Testing*, 1969, 1: 251-283.
- [18] 袁慎芳. 结构健康监测[M]. 北京:国防工业出版社, 2007: 206.
YUAN Shenfang. Structural health monitoring and damage control[M]. Beijing: National Defense Industry Press, 2007: 206.
- [19] 王强. Lamb波时间反转方法及其在结构健康监测中的应用研究[D]. 南京:南京航空航天大学, 2009.
WANG Qiang. Research on Lamb wave time reversal technique and its applications in structural health monitoring[D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2009.
- [20] TORKAMANI S, ROY S, BARKEY M E, et al. A novel damage index for damage identification using guided waves with application in laminated composites[J]. *Smart Materials and Structures*, 2014, 23(9): 095015.
- [21] WU Zhanjun, LIU Kehai, WANG Yishou, et al. Validation and evaluation of damage identification using probability-based diagnostic imaging on a stiffened composite panel[J]. *Journal of Intelligent Material Systems and Structures*, 2015, 26(16): 2181-2195.
- [22] BETZ D C, STASZEWSKI W J, THURSBY G, et al. Structural damage identification using multifunctional Bragg grating sensors: II. Damage detection results and analysis[J]. *Smart Materials and Structures*, 2006, 15(5): 1313.
- [23] YUAN Shenfang, LIANG Dakai, SHI Lihua, et al. Recent progress on distributed structural health monitoring research at NUAA[J]. *Journal of Intelligent Material Systems and Structures*, 2008, 19(3): 373-386.
- [24] RIZZO P, DI SCALEA F L. Feature extraction for defect detection in strands by guided ultrasonic waves[J]. *Structural Health Monitoring*, 2006, 5(3): 297-308.
- [25] PARK S, YUN C B, ROH Y, et al. PZT-based active damage detection techniques for steel bridge components[J]. *Smart Materials and Structures*, 2006, 15(4): 957.
- [26] MICHAELS J E, MICHAELS T E. An integrated strategy for detection and imaging of damage using a spatially distributed array of piezoelectric sensors[C]//*Proceedings of Health Monitoring of Structural and Biological Systems 2007*. [S.l.]: International Society for Optics and Photonics, 2007.
- [27] QING Xinlin, CHAN Hianleng, BEARD S J, et al. An active diagnostic system for structural health monitoring of rocket engines[J]. *Journal of Intelligent Material Systems and Structures*, 2006, 17(7): 619-628.
- [28] WU Zhanjun, QING Xinlin, GHOSH K, et al. Health monitoring of bonded composite repair in bridge rehabilitation[J]. *Smart Materials and Structures*, 2008, 17(4): 045014.
- [29] GAO Huidong, SHI Yuan, ROSE J L. Guided wave tomography on an aircraft wing with leave in place sensors[C]//*Proceedings of AIP Conference*. [S.l.]: AIP, 2005, 760(1): 1788-1794.
- [30] PIERCE S G, CULSHAW B, MANSON G, et al. Application of ultrasonic Lamb wave techniques to the evaluation of advanced composite structures[C]//*Proceedings of Smart Structures and Materials 2000: Sensory Phenomena and Measurement Instrumentation for Smart Structures and Materials*. [S.l.]: International Society for Optics and Photonics, 2000, 3986: 93-103.
- [31] TRENDAFILOVA I, MANOACH E. Vibration-based damage detection in plates by using time series analysis[J]. *Mechanical Systems and Signal Processing*, 2008, 22(5): 1092-1106.

作者简介:



杨宇(1980-),男,博士,高级工程师,研究方向:复合材料结构损伤容限、智能结构、结构健康监测, E-mail: yangyu@cae.ac.cn。



周雨熙(1986-),女,博士研究生,研究方向:人工智能。



王莉(1992-),女,硕士研究生,研究方向:压电损伤监测技术。

(编辑:张彤)