

# 一种基于广义回归神经网络的裂纹扩展定量监测模型



安雨晴,杨宇,王莉

中国飞机强度研究所, 陕西 西安 710065

**摘要:**金属结构上裂纹的实时监测对飞行器损伤容限/疲劳试验、飞机定寿,以及保证服役过程中的安全性和可靠性、安排检修等任务具有重要意义。为实时监测金属结构疲劳裂纹的扩展过程,本文通过广义回归神经网络方法研究了提取自导波信号的多维损伤特征参量同裂纹长度之间的定量关系。结果表明,导波信号随着裂纹长度的变化存在规律性变化,损伤特征参量与裂纹长度存在一定的非线性相关性;多维损伤特征参量可实现较为准确的裂纹定量监测。可见广义回归神经网络可用于建立准确度较高的导波结构裂纹定量监测模型。

**关键词:**裂纹长度; 定量监测; 损伤特征参量; 导波; 广义回归神经网络

中图分类号: V219

文献标识码: A

DOI: 10.19452/j.issn1007-5453.2023.03.006

损伤容限已成为现代飞行器结构的主要设计方法<sup>[1]</sup>。准确把控损伤扩展历程、合理安排检查间隔,是成功应用损伤容限设计方法、兼顾结构减重与安全保障的关键。目前,主要依靠定期的无损检测技术来发现结构中孔、切口、台阶等应力集中区域的裂纹。但对于其中的不可达部位,仍需进行结构拆解检查,成本高昂且受人为因素影响大<sup>[2-3]</sup>,存在漏检的风险。例如,2019年全球50多架波音737NG翼身连接机身框叉臂被检查出裂纹。更重要的是,该裂纹不是在既有检查维护过程中发现的,而是在由波音737-MAX连续坠机事故连带的全面检查中意外发现的。健康监测技术能够对结构进行持续监测,评估结构是否安全,避免灾难性结构失效,因此其成为近年来研究的热点之一。

导波损伤监测技术作为一种常见的结构健康监测手段,有衰减小、传播距离远、可实现大面积监测的优点,因此被广泛应用于航空薄壁结构的健康监测<sup>[4-5]</sup>。Ihn等<sup>[6]</sup>通过建立导波信号的散射能量和基准信号能量比与裂纹长度的关系,初步实现了铆接头和修补补丁处的裂纹定量监测。Yang等<sup>[7]</sup>将互相关、相位和归一化幅值同时作为敏感参量,采用贝叶斯方法建立其与裂纹尺寸的关系,实现了对裂纹尺寸的定量监测。Masserey等<sup>[8]</sup>针对开孔紧固件建立了能

量指数与裂纹面积及裂纹长度的定量关系。邱雷等<sup>[9]</sup>建立了一种高斯混合模型结合的时变概率诊断模型,实现了对翼梁螺栓孔的孔边裂纹扩展监测。袁慎芳等<sup>[10]</sup>利用卷积神经网络(CNN)实现了对变幅载荷疲劳裂纹扩展的监测,该方法通过建立损伤敏参量同裂纹长度间的定量关系,实现了准确的裂纹定量监测。

利用导波技术对结构裂纹进行定量监测已经逐步从实验室验证走向工程应用,现阶段该技术主要面临的难点问题是如何解决因结构本身和“试验或服役”过程的不确定性引起的导波信号分散性问题。针对该技术难点,本文从两方面着手,试图得到一个更加准确的导波裂纹监测模型。首先,在损伤参数选择方面,提取多通路的多种损伤参量,挑选各通路同裂纹长度关系最紧密的参数来建模。其次,由于广义回归神经网络(GRNN)具有良好的非线性逼近能力和高度容错性、鲁棒性,本文采用此方法建立损伤指数与裂纹长度的关系,以期得到准确的监测模型。

## 1 试验介绍

### 1.1 试验件

试验件选材为2A12-T4铝合金,材料成分见表1,表面

收稿日期: 2022-12-16; 退修日期: 2023-01-11; 录用日期: 2023-02-21

引用格式: An Yuqing, Yang Yu, Wang Li. A quantitative monitoring model of structural crack propagation based on generalized regression neural network[J]. Aeronautical Science & Technology, 2023, 34(03): 40-48. 安雨晴, 杨宇, 王莉. 一种基于广义回归神经网络的裂纹扩展定量监测模型[J]. 航空科学技术, 2023, 34(03): 40-48.

粗糙度为 0.4。试件厚度为 3mm, 长度和宽度分别为 250mm 和 50mm。为了控制裂纹扩展的位置和方向, 在试件一侧加工 6mm 裂纹, 该预制裂纹尖端是长度为 1mm 的三角形区域, 试验件及预制裂纹具体尺寸如图 1 所示。本次试验件共 4 件, 编号为 B1~B4。

将 PZT 传感器网络均匀对称分布在裂纹扩展路径的两侧, 每侧各三个传感器。试验件几何尺寸、裂纹预制位置及传感器粘贴位置如图 1 所示。

表1 2A12主要化学元素成分含量

Table 1 2A12 content of main chemical elements

成分	Fe	Si	Mn	Ni	Cu	Ti	Zn	Mg
最小值	—	—	0.30	—	3.80	—	—	1.20
最大值	0.50	0.50	0.90	0.10	4.90	0.15	0.30	1.80

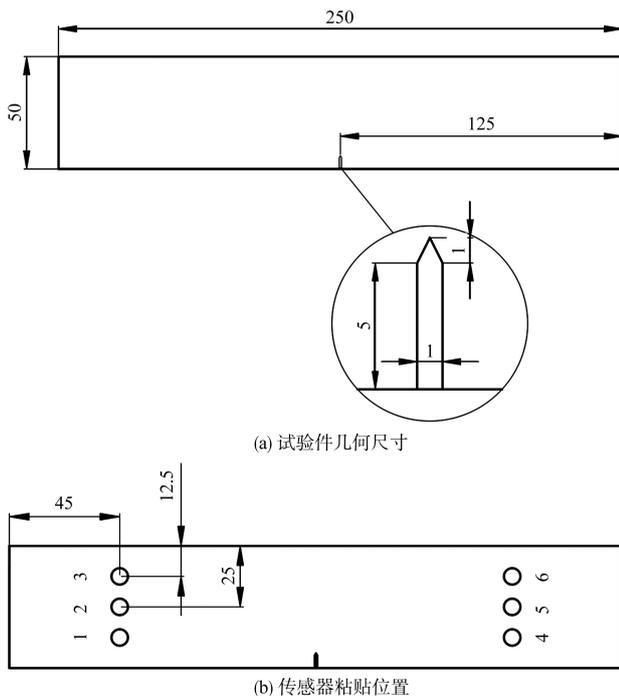


图1 试验件几何尺寸及传感器粘贴位置(单位:mm)

Fig.1 Geometry size of test specimen and location of PZT sensors(Unit: mm)

## 1.2 试验详情及数据

### 1.2.1 试验详情

本试验的加载设备为 MTS—10t 疲劳加载机。采用正弦恒幅加载载荷, 其中最大载荷为 9kN, 最小载荷为 0.9kN, 应力比  $R$  为 0.1, 加载频率为 10Hz。激励—采集导波信号时需试验暂停, 此时的保载载荷为 4.95kN。

试验数据采集和记录安排为: 自然裂纹萌生前, 每 5000

次载荷循环激发一次导波, 并采集相应的信号, 直到裂纹萌生。裂纹萌生以后, 长度每扩展 1mm 左右, 激发—采集一次导波信号, 并记录当下的载荷循环数和裂纹长度(裂纹长度采用渗透法进行观察和测量)。信号激励—采集设备为 ScanGenieIII—64 通道。

每条激励—采集通路选取的激励频率见表 2。不同通路的路径长度有差异, 导致直达波到达时间不同, 另外由于通路 with 试验件边界及裂纹扩展路径的相对位置不同, 可造成信号的反射、散射情况也不同, 综上, 要获得相对清晰的直达波波形便于后续的信号处理, 则需要首先对各通路进行扫频, 选取最佳频率, 在该频率下, 可获得该通路最为清晰的直达波波形。

表2 试验件各通路激发频率

Table 2 Excitation frequency of each pathway

通路	s1	s2	s3
频率/kHz	230	210	200
通路	s4	s5	s6
频率/kHz	220	240	270

### 1.2.2 试验数据

试验件本身材料的差异不可避免, 即使加载环境(温度和湿度)和加载设备可控制在一定的稳定状态, 4 个试验件的寿命和裂纹失稳前的可测长度并不相同, 具体的最大裂纹长度和对应寿命见表 3。整个试验过程中, 每个试验件均记录了 30 组以上的数据。对应  $a-N$  数据, 也采集到相应的导波信号, 每一组导波信号包含 6 个通路。

表3 试验件的最大裂纹长度和寿命

Table 3 Maximum crack length and life of the test piece

试验件编号	B1	B2	B3	B4
裂纹长度/mm	35	34	35.9	32.1
寿命/循环数	143541	133810	127854	136359

## 2 GRNN 裂纹长度监测模型

GRNN 是由 D. F. Specht 教授<sup>[11]</sup>于 1991 年提出来的, 它属于径向基神经网络的一种改进形式, 因此兼具径向神经网络良好的非线性逼近能力和高度容错性、鲁棒性, 同时拥有更快的学习速度。

### 2.1 广义回归神经网络理论依据

GRNN 理论基础是非线性回归分析, 即计算最大概率值的  $y^{[12]}$ 。假设  $x$  和  $y$  是两个随机变量, 则

$$Y(x) = \frac{\sum_{i=1}^n y_i \exp\left[-\frac{(x_0 - x_i)^T(x_0 - x_i)}{2\sigma^2}\right]}{\sum_{i=1}^n \exp\left[-\frac{(x_0 - x_i)^T(x_0 - x_i)}{2\sigma^2}\right]} \quad (1)$$

由式(1)可看出,预测值  $Y(x)$  是全部样本的测量值  $y_i$  的加权平均值,权重因子是相应的样本  $x_i$  与  $x$  之间欧氏距离平方的指数。由式(1)同样可以看出,  $\sigma$  的取值会较大程度影响  $Y(x)$  的值,在 GRNN 中,将其称作光滑因子。

GRNN 由 4 层神经元组成,分别是输入层、模式层、求和层和输出层。网络结构示意图如图 2 所示。对应网络输入  $X=[x_1, x_2, x_3, \dots, x_n]^T$ , 输出为  $Y=[y_1, y_2, y_3, \dots, y_k]^T$ 。

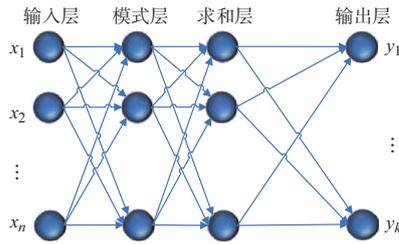


图2 GRNN 结构图  
Fig.2 Structure of GRNN

输入层负责接收输入样本,神经元的个数等于学习样本中输入矢量的维数。其传输函数为线性函数,直接将输入变量传递到模式层。

模式层即为径向基层,神经元为径向基神经元,其模型如图 3 所示,该层神经元的个数和学习样本的个数相等,每个神经元对应不同的样本,传递函数为

$$p_i = \exp\left[-\frac{(x - x_i)^T(x - x_i)}{2\sigma^2}\right], i = 1, 2, \dots, n \quad (2)$$

神经元  $i$  的输出为输入变量与其对应的样本  $x$  之间的欧氏距离平方的指数。式(2)中  $x$  为网络输入变量;  $j$  为第  $i$  个神经元所对应的学习样本。

求和层中有两种神经元进行求和:一种是连接权值为 1,即对所有模式层中的神经元进行直接求和,计算公式为

$$\sum_{i=1}^n \exp\left[-\frac{(x - x_i)^T(x - x_i)}{2\sigma^2}\right] \quad (3)$$

传递函数为

$$S_D = \sum_{i=1}^n P_i \quad (4)$$

另一种是连接权值各不相同,模式层第  $i$  个神经元与求和层第  $j$  个神经元之间的连接权值为第  $i$  个输出样本  $y_j$  中的

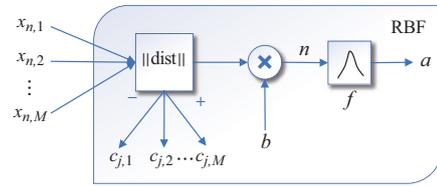


图3 模式层神经元原理图

Fig.3 Schematic of neurons in the pattern layer

第  $j$  个元素,计算公式为

$$\sum_{i=1}^n y_i \exp\left[-\frac{(x - x_i)^T(x - x_i)}{2\sigma^2}\right] \quad (5)$$

传递函数为

$$S_{Nj} = \sum_{i=1}^n y_{ij} P_i, j = 1, 2, \dots, k \quad (6)$$

它们的差异在于模式层与各神经元之间的连接权值不同。

输出层神经元数目等于输出矢量的维数  $k$ ,各神经元将求和层对应的输出相除,神经元  $j$  的输出对应估计结果  $y(x)$  的第  $j$  个元素

$$y_j = \frac{S_{Nj}}{S_D}, j = 1, 2, \dots, k \quad (7)$$

## 2.2 GRNN 裂纹定量监测模型

### 2.2.1 输入和输出提取

利用导波进行结构健康监测的原理是利用其对结构变化的敏感性,比较结构发生变化前后导波信号的差异,达到对变化的辨识。在结构裂纹定量监测方面,随着裂纹长度的不断增加,传感器接收到的导波信号峰值和相位等参量也存在一定的规律性变化,通过提取这些规律性变化的参量,建立其与裂纹长度的关系,可以实现裂纹长度的定量识别。图 4 为试验件 B4 通道 s6 的直达波信号随着裂纹长度增加的变化趋势。由图 4 可以看出,随着裂纹长度的改变,直达波信号波形发生规律性变化,在时域上主要表现为幅值衰减和相位延迟。

输入提取分两步进行,首先是损伤指数提取,其次是损伤指数选择。依据参考文献和工程经验,对每个通路,首先提取 13 种<sup>[13-18]</sup>常用的损伤指数分别是幅值变化比、能量比、能量变化比、散射能量变化比、均方根偏差损伤指数、均方根损伤指数、皮尔逊相关系数、散射信号归一化能量损伤因子、方差损伤指数、时域能量变化比、频域能量变化比、频域损伤能量变化比和互相关损伤指数。

通过计算、画图和分析可知部分损伤指数之间存在较高的线性相关性,如果将全部损伤指数直接作为输入将产

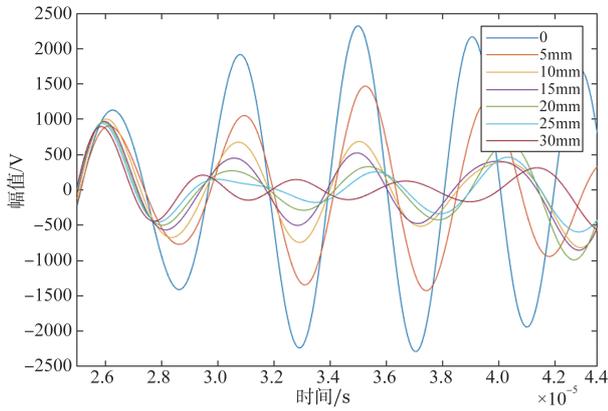


图4 Lamb波随裂纹扩展的变化趋势

Fig.4 Variation trend of Lamb wave along with crack propagation

生不必要的计算量。此外,一些损伤指数与裂纹长度的关系并不明朗,无法进行有效的关系建立。图5列举s1通路的部分损伤指数,可以看出互相关损伤指数与裂纹长度的关系较为明确且对小裂纹敏感,其余损伤指数与裂纹长度的关系则不明朗。

因此,需要在众多损伤参量中进行选择,选取与裂纹长度相关性最高的损伤指数作为输入。由于损伤指数与裂纹长度的关系存在明显的非线性,因此相关性对比采用非线性相关系数——斯皮尔曼相关系数,计算所有损伤参量与裂纹长度的斯皮尔曼相关系数,然后选取计算结果绝对值最大的损伤指数。最终,s1通路将互相关损伤指数选择为最终的损伤参数,计算公式如式(8)所示。s2通路选择均方根偏差损伤指数,计算公式如式(9)所示。s3通路选择均方根偏差损伤指数,s4通路选择均方根偏差损伤指数,s5通路选择互相关损伤指数,s6通路选择互相关损伤指数,如图6~图10所示。

互相关损伤指数

$$DI = 1 - \frac{E(BD) - E(B)E(D)}{\sqrt{E(B^2) - E^2(B)} \cdot \sqrt{E(D^2) - E^2(D)}} \quad (8)$$

$$E(B) = \frac{\int_{t_1}^{t_2} b(t) dt}{t_2 - t_1}$$

式中,  $b(t)$  为基准信号,  $d(t)$  为监测信号, 其余同理。

均方根偏差损伤指数为

$$DI = \sqrt{\frac{\int_{t_1}^{t_2} H[d(t) - b(t)]^2 dt}{\int_{t_1}^{t_2} H[b(t)]^2 dt}} \quad (9)$$

其中,  $[t_1 t_2]$  为有效信号截取段;  $H[]$  为信号的希尔伯特

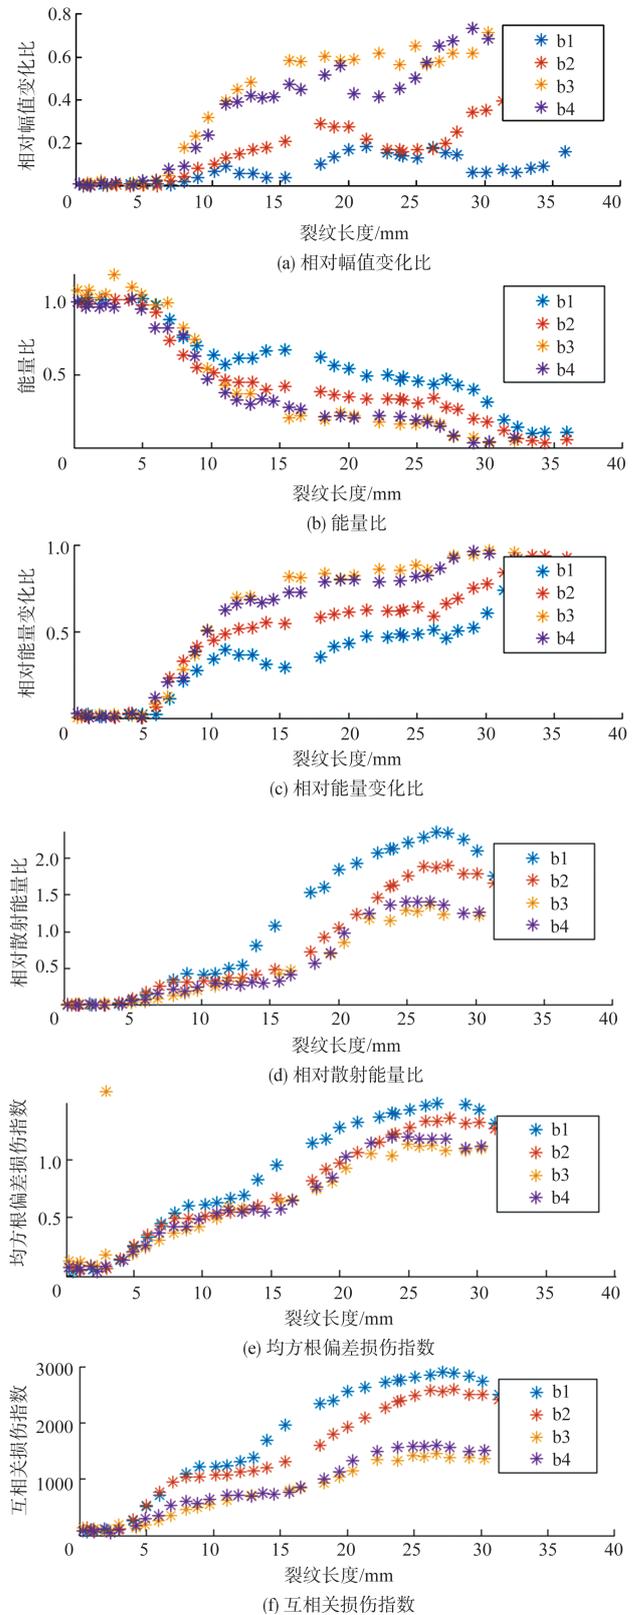


图5 s1通路损伤指数与裂纹长度关系

Fig.5 Relationship between damage index and crack length in s1 pathway

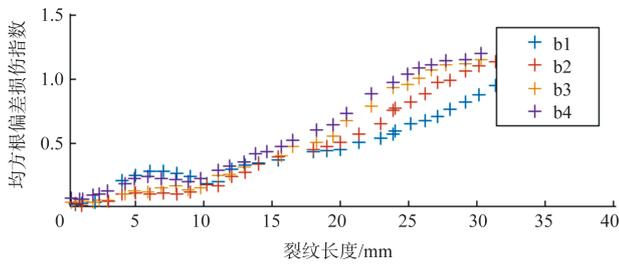


图6 s2通路均方根偏差损伤指数与裂纹长度关系

Fig.6 Relationship between Root mean square deviation damage index and crack length in s2 pathway

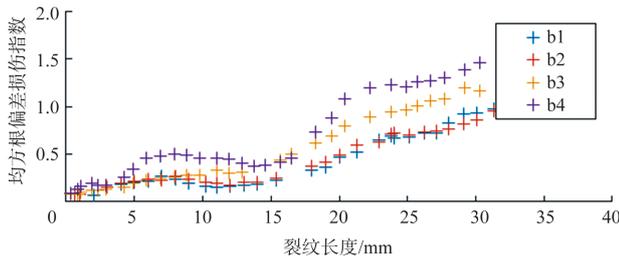


图7 s3通路均方根偏差损伤指数与裂纹长度关系

Fig.7 Relationship between Root mean square deviation damage index and crack length in s3 pathway

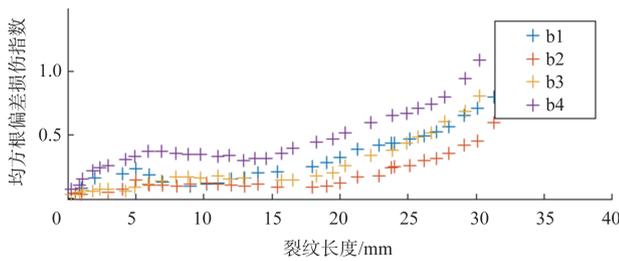


图8 s4通路均方根偏差损伤指数与裂纹长度关系

Fig.8 Relationship between Root mean square deviation damage index and crack length in s4 pathway

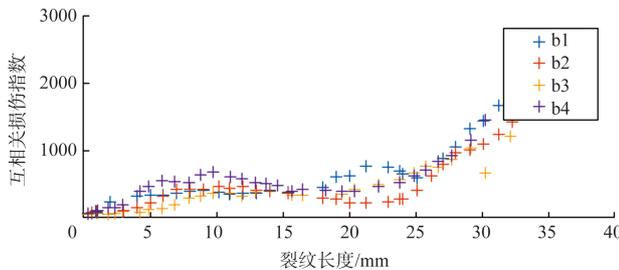


图9 s5通路互相关损伤指数与裂纹长度之间的关系

Fig.9 Relationship between Cross-correlation damage index and crack length in s5 pathway

(Hilbert)变换; $b(t)$ 为基准信号; $dt$ 为监测信号。

最后将所有选择的损伤指数进行整合和重新编号,形成输入信号矩阵,即损伤特征矩阵  $X = [x_1, x_2, x_3, x_4, x_5, x_6]$ ,

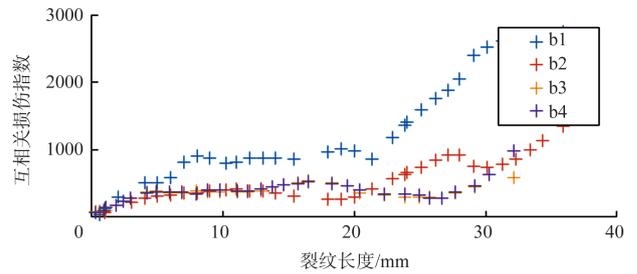


图10 s6通路互相关损伤指数与裂纹长度之间的关系

Fig.10 Relationship between cross-correlation damage index and crack length in s6 pathway

具体流程如图11所示。

输出变量为裂纹长度,将裂纹长度按照和损伤参量对应的顺序,进行整合,生成一维矩阵  $A$ ,将此矩阵定义为  $Y$ ,即本模型的输出变量。

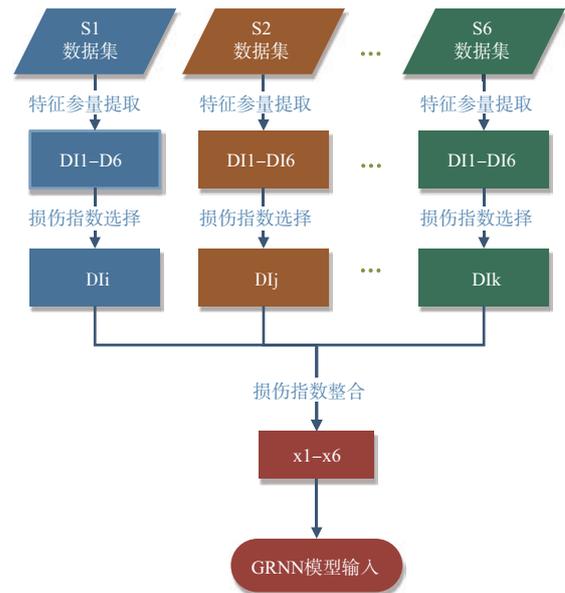


图11 模型输入变量的建立流程

Fig.11 Flowchart of the model input variable setting up

### 2.2.2 建模过程

#### (1) 输入数据集和输出数据集划分

本文选取4个试验件(B1、B2、B3、B4)的损伤特征集和对应的裂纹扩展数据组成输入和输出数据集进行GRNN裂纹定量监测模型的建模。这4个试验件共包括128组数据,随机选取其中32组数据作为验证集,剩余96组数据作为训练集。

图12为128组参与建模的数据,不同通路的损伤指数用不同的颜色画出。由于互相关损伤指数的量级大于其余

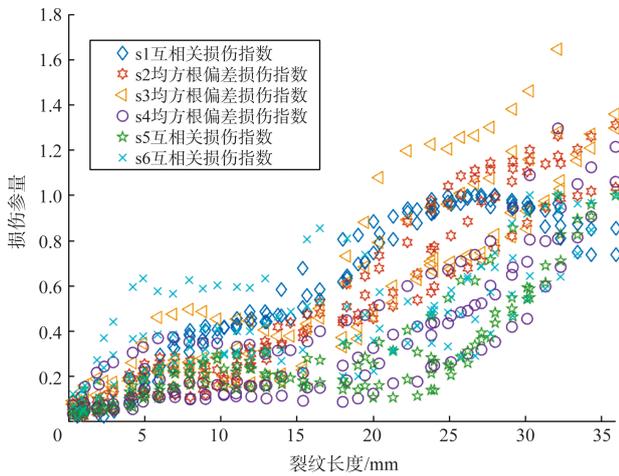


图12 128组输入—输出数据

Fig.12 128 groups of input-output data

损伤指数,因此将其进行归一化,参与计算。

采用最大误差eM和均方根误差RMSE对模型计算结果进行评估。其计算公式如式(10)和式(11)所示

最大误差为

$$eM = \max |a_{\text{real}} - a_{\text{pre}}| \quad (10)$$

均方根误差为

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (a_{\text{real}} - a_{\text{pre}})^2} \quad (11)$$

式中, $a_{\text{real}}$ 为试验中测量的裂纹长度, $a_{\text{pre}}$ 为GRNN模型计算的结果, $N$ 为验证集的数据个数。

### (2) 光滑因子的选择

光滑因子 $\sigma$ 的取值对网络的性能影响很大,需要优化取值。网络的训练过程是光滑因子的一维寻优。若光滑因子取值非常大, $d(x_0, x_i)$ 趋近于0, $y(x_0)$ 近似于所有样本因变量的平均值。若光滑因子趋近于0,则 $y(x_0)$ 与训练样本的值非常接近,会造成过拟合,预测效果变差,网络失去推广能力。

GRNN通过调整spread参数的值来调整网络的光滑因子,推荐的选择范围区间为[0.1, 2],本文也选择此范围进行寻优,寻优过程的步长选择0.1。

在一次建模过程中,网络会循环建立spread所有取值范围内的对应模型,然后对比多个模型的预测结果误差,将对应于误差最小的模型作为最终的建模结果。此处的误差最小取均方误差最小。多次计算结果表明,当spread为0.1时,预测的结果与真实数据误差最小。因此在本文所建的关于GRNN裂纹扩展定量监测模型中选取0.1作为spread的值。

### (3) 建模

由图1(b)传感器布置图可以看出6个传感器可构成9路激发—传感通道,遗憾的是其中两个试验件的4号传感器在试验过程中发生故障,使得由其组成的激励—传感通道信号丢失,故这三个通道无法用于建模。因此,本文共通过6路激励—传感通道信号来进行GRNN建模。这6个激励—传感通道如图13所示。

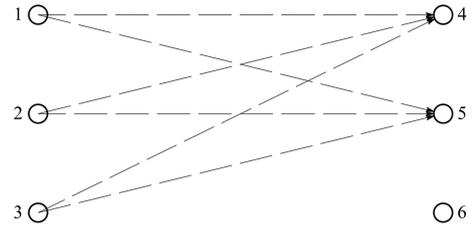


图13 激励—传感通路

Fig.13 Excitation-sensing pathway

由2.2.1节可知,输入变量和输出变量已建立,将其按照对应的顺序输入GRNN网络,可实现裂纹监测模型的建立,同时得到该模型预测结果的最大误差和均方根误差。

## 3 建模结果与对比分析

图14所示为GRNN的建模结果。预测最大误差为1.7198mm,均方误差为0.60476mm<sup>2</sup>;可以看出本模型对裂纹长度有良好的监测结果。

为了对该方法的计算结果进行对比,本文还采取多元多项式拟合的方法建立损伤指数与裂纹长度的关系,进行损伤监测。

首先通过SPSS软件的曲线估算功能选取合适的拟合次数,估算结果见表4。其中,R方为拟合优度,表示拟合的方程能解释因变量变化的百分数;F为方差检验量,是整个模型的整体检验。由表4可知,s1互相关损伤参数的拟合次数选择三次为最佳(比较R方),s2均方根偏差损伤指数选择二次拟合最佳(三次和二次拟合的拟合优度相同,取项数少的二次进行拟合),其余损伤指数的拟合次数选择同理。

利用自编Matlab程序进行损伤指数和裂纹长度之间关系的多元多次多项式拟合,将s1~s6通路的损伤指数分别记作 $X_1, X_2, X_3, X_4, X_5, X_6$ ,裂纹长度记作 $Y$ ,可得拟合的方程如式(12)所示

$$Y = -21.7391X_1^3 + 30.5109X_1^2 + 7.03425X_1 + 13.719X_2 - 6.67768X_3^2 + 9.33015X_4^2 + 2.63459X_5^2 + 2.61599X_6^2 + 0.0676413 \quad (12)$$

其计算结果的最大误差为 3.0005mm,均方根误差为 1.0926mm<sup>2</sup>,如图 15 所示。由误差对比结果可以看出,本文所提的 GRNN 方法对于裂纹长度的监测计算优于多项式拟合方法,能够较为准确地建立导波信号损伤参量与裂纹尺寸之间的关系,实现结构裂纹长度的有效识别。此外,对于损伤参量较多的模型,相比于多元多项式拟合过程的繁琐,本模型具有较高的效率。

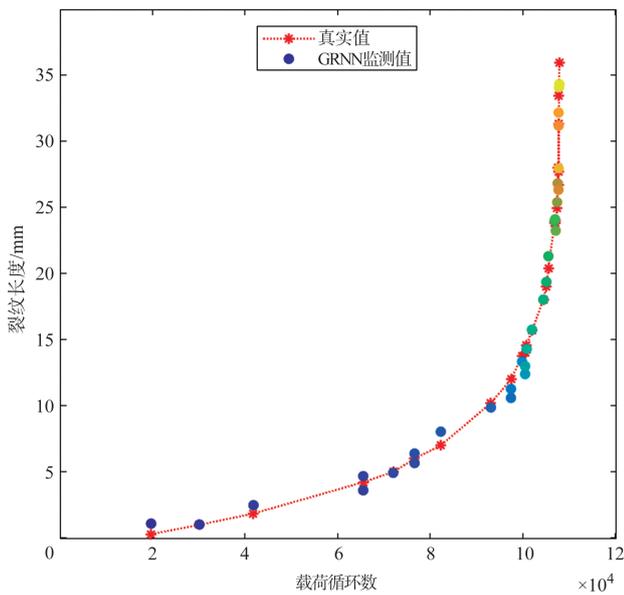


图 14 GRNN 建模结果与真实测量结果对比

Fig.14 Comparison between GRNN modeling results with real measurement results

表 4 模型估算结果

Table 4 Model estimation result

损伤指数 估算参量		s1	s2	s3	s4	s5	s6
		损伤 指数	损伤 指数	损伤 指数	损伤 指数	损伤 指数	损伤 指数
线性	R方	0.884	0.912	0.807	0.654	0.655	0.523
	F	960	1300	525	237	239	138
二次	R方	0.884	0.942	0.856	0.701	0.735	0.530
	F	476	1008	370	146	173	70
三次	R方	0.899	0.942	0.856	0.701	0.738	0.541
	F	366	677	245	96	116	48

### 4 结论

本文依据裂纹疲劳扩展试验数据进行裂纹长度定量监测模型的建立和验证,得到以下结论:

(1)本文所采用的 GRNN 方法,可实现较为准确的试验室裂纹定量监测,本文为该方法的进一步工程应用提供了

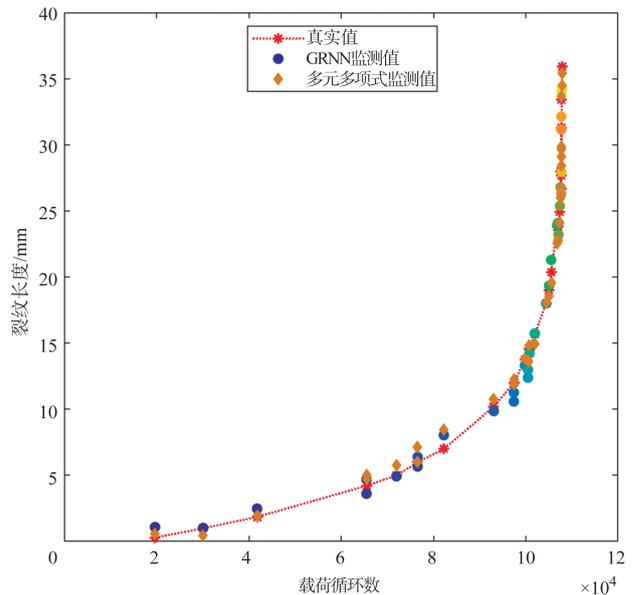


图 15 GRNN 方法和多项式拟合方法结果对比

Fig.15 Comparison between GRNN and polynomial fitting method

理论和试验基础。

(2)采取综合 6 路激励—传感通路中最为敏感的损伤指数作为模型输入进行建模,可以实现较为准确的裂纹定量监测,本文所布置路径和对应路径的损伤指数类型对于同类型结构、同种材料的裂纹定量监测具有参考意义。



### 参考文献

[1] 林建鸿,王彬文.飞机疲劳失效适航规章演变历程回顾[J].航空科学技术,2022,33(3):39-51.  
Lin Jianhong, Wang Binwen. Evolution history of airworthiness regulations for aircraft structural fatigue designs[J].Aeronautical Science & Technology, 2022, 33(3):39-51.(in Chinese)

[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. (in Chinese)

[3] 杨宇,周雨熙,王莉.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[J].数据采集与处理,2020,35(2):278-287.  
Yang Yu, Zhou Yuxi, Wang Li. Integrated method of multiple

- machine-learning models for damage recognition of composite structures[J]. *Journal of Data Acquisition and Processing*, 2020, 35(2): 278-287. (in Chinese)
- [4] 鲍峤, 邱雷, 袁慎芳. 飞行器结构健康监测中压电-导波成像技术的发展与挑战[J]. *航空科学技术*, 2020, 31(3):15-33.  
Bao Qiao, Qiu Lei, Yuan Shenfang. Development and challenges of PZT-guided wave based imaging technique in aircraft structural health monitoring[J]. *Aeronautical Science & Technology*, 2020, 31(3):15-33.(in Chinese)
- [5] 杨宇, 王彬文, 吕帅帅, 等. 一种基于深度学习的复合材料结构损伤导波监测方法[J]. *航空科学技术*, 2020, 31(7):102-108.  
Yang Yu, Wang Binwen, Lyu Shuaishuai, et al. A deep-learning-based method for damage identification of composite laminates [J]. *Aeronautical Science & Technology*, 2020, 31(7): 102-108. (in Chinese)
- [6] Ihn J B, Chang F K. Detection and monitoring of hidden fatigue crack growth using a built-in piezoelectric sensor/actuator network: II. Validation using riveted joints and repair patches[J]. *Smart Materials & Structures*, 2004, 13(3): 621-630.
- [7] Yang Jinsong, He Jingjing, Guan Xuefei. A probabilistic crack size quantification method using in-situ Lamb wave test and bayesian updating[J]. *Mechanical Systems and Signal Processing*, 2015,14:S0888327015003052.
- [8] Masserey B, Fromme P. In-situ monitoring of fatigue crack growth using high frequency guided waves[J]. *Nondes Tructive Testing and Evaluation International*, 2015, 71: 1-7.
- [9] Qiu Lei, Yuan Shenfang, Chang F K, et al. On-line updating Gaussian mixture model for aircraft wing spar damage evaluation under time-varying boundary condition[J]. *Smart Materials and Structures*, 2014, 23(12):125001.
- [10] 袁慎芳, 李晓泉, 陈健. 疲劳裂纹扩展的卷积神经网络辨识[J]. *航空科学技术*, 2020, 31(7):64-71.  
Yuan Shenfang, Li Xiaoquan, Chen Jian. Convolutional neural network based fatigue crack growth identification[J]. *Aeronautical Science & Technology*, 2020, 31(7): 64-71. (in Chinese)
- [11] Specht D F. A general regression neural network[J]. *IEEE Transactions on Neural Networks*, 1991, 2(6): 568-576.
- [12] 李孟杰. 基于GRNN神经网络的船舶柴油机排放预测的研究[D]. 厦门:集美大学, 2016.  
Li Mengjie. The Study of the emissions prognostication on marine diesel engine based on GRNN[D]. Xiamen: Jimei University, 2016. (in Chinese)
- [13] Su Zhongqing, Lin Ye, Ye Lu. Guided Lamb waves for identification of damage in composite structures: A review[J]. *Journal of Sound and Vibration*, 2006, 295(3-5): 753-780.
- [14] 李晓泉. 变幅载荷下疲劳裂纹扩展分析及监测研究[D]. 南京:南京航空航天大学, 2020.  
Li Xiaoquan. Analysis and monitoring research on fatigue crack growth under variable amplitude loading[D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2020. (in Chinese)
- [15] 杨伟博, 袁慎芳, 邱雷. 基于Lamb波的平尾大轴裂纹扩展监测[J]. *振动、测试与诊断*, 2018, 38(1):143-147.  
Yang Weibo, Yuan Shenfang, Qiu Lei. Flat tail large axis crack propagation monitoring based on Lamb wave[J]. *Journal of Vibration, Measurement & Diagnosis*, 2018, 38(1): 143-147. (in Chinese)
- [16] He J, Guan X, Peng T, et al. A multi-feature integration method for fatigue crack detection and crack length estimation in riveted lap joints using Lamb waves[J]. *Smart Materials and Structures*, 2013, 22(10): 105007.
- [17] Fuqiang S, Ning W, Jingjing H, et al. Lamb wave damage quantification using GA-based LS-SVM[J]. *Materials*, 2017, 10 (6):648.
- [18] Lim H J, Sohn H, Kim Y. Data-driven fatigue crack quantification and prognosis using nonlinear ultrasonic modulation[J]. *Mechanical Systems and Signal Processing*, 2018, 109: 185-195.

## A Quantitative Monitoring Model of Structural Crack Propagation Based on Generalized Regression Neural Network

An Yuqing, Yang Yu, Wang Li

*Aircraft Strength Research Institute of China, Xi'an 710065, China*

**Abstract:** The real-time monitoring of cracks on metal structures is of great significance to the damage tolerance and fatigue test of aircraft, as well as the life determination of aircraft, the safety and reliability assurance and the maintenance arrangement during aircraft service. In order to monitor the fatigue crack propagation process of metal structures in real time, the generalized regression neural network method is used to investigate the quantitative relationship between the multi-dimensional damage parameters extracted from the guided wave signal and the crack length. The results show that the guided wave signal changes regularly with the crack length, and there is a certain non-linear correlation between the damage parameters and the crack length. What's more, It also shows that the multi-dimensional damage parameters can achieve a relatively accurate crack quantitative monitoring. It is concluded that the generalized regression neural network can be used to establish a high accuracy model of the guided wave-crack quantitative monitoring.

**Key Words:** crack length; quantitative monitoring; damage parameter; guided wave; generalized regression neural network