

DOI:10.16356/j.1005-2615.2017.04.003

基于 GRNN-ELM 的飞机复合材料结构损伤识别

崔建国^{1,3} 张善好² 于明月¹ 蒋丽英¹ 江秀红² 林泽力³

(1. 沈阳航空航天大学自动化学院,沈阳,110136;2. 沈阳航空航天大学电子信息工程学院,沈阳,110136;
3. 航空工业上海航空测控技术研究所故障诊断与健康管理工作航空科技重点实验室,上海,201601)

摘要:飞机结构的损伤严重影响着飞机的飞行安全,为了解决飞机复合材料结构损伤难以有效识别问题,本文提出一种基于广义回归神经网络(General regression neural network,GRNN)与极限学习机(Extreme learning machine,ELM)组合的飞机复合材料结构损伤识别新方法。首先对飞机复合材料层合板进行冲击,而后对其进行疲劳拉伸试验,通过优化布局在复合材料层合板上的光纤光栅传感器募集应变信息,并对其进行处理。采用变分模态分解(Variational mode decomposition,VMD)对募集的应变信息进行自适应分解,得到多个基本模式分量(Intrinsic mode function,IMF)。计算各阶 IMF 分量的奇异熵,通过核独立主元分析(Kernel independent component analysis,KICA)方法对奇异熵进行特征融合,构建融合特征向量。采用融合特征向量建立基于 GRNN-ELM 的复合材料结构损伤识别模型,通过试验对损伤识别模型的有效性进行了验证,并分别与所构建的 ELM 和 GRNN 损伤识别模型的识别结果进行比较。结果表明,该方法能有效对飞机复合材料结构损伤进行识别,具有很好的工程应用价值。

关键词:变分模态分解;奇异熵;核独立分量分析;GRNN-ELM 组合神经网络;损伤识别

中图分类号:V25 **文献标志码:**A **文章编号:**1005-2615(2017)04-0468-06

Damage Identification of Aircraft Composite Structure Based on GRNN-ELM

CUI Jianguo^{1,3}, ZHANG Shan hao², YU Mingyue¹, JIANG Liying¹, JIANG Xiuhong², LIN Zeli³

(1. School of Automation,Shenyang Aerospace University,Shenyang,110136,China;

2. School of Electronic and Information Engineering,Shenyang Aerospace University,Shenyang,110136,China;

3. Aviation Key Laboratory of Science and Technology on Fault Diagnosis and Health Management,
Shanghai Aero Measurement & Control Technology Research Institute, Shanghai,201601,China)

Abstract: Aircraft structure damage seriously affects the aircraft flight safety. In order to effectively identify aircraft composite structure damage, a new method combining general regression neural network (GRNN) and extreme learning machine (ELM) of composite structure damage diagnosis is proposed in this paper. Firstly, the data of fiber optic sensor on composite material laminated plates are gathered and pre-processed after striking and stretching on composite laminated plates. Secondly, strain information is decomposed by variational mode decomposition (VMD), and intrinsic mode functions (IMFs) are obtained. Meanwhile, the singular entropy feature of each IMF is derived. Then, a feature

基金项目:辽宁省自然科学基金(2014024003)资助项目;航空科学基金(20153354005)资助项目;航空科学基金(20163354004)资助项目;国家自然科学基金(51605309)资助项目。

收稿日期:2017-04-20;**修订日期:**2017-05-16

作者简介:崔建国,男,1963年生,博士后,教授,研究生导师,研究方向为飞行器健康诊断与预测及综合健康管理等,辽宁省与沈阳市科技专家,荣获省部级(含沈阳市)科技成果奖9项,承担纵、横向科研项目30余项,发表文章60余篇。

通信作者:崔建国,E-mail: gordon_cjg@163.com。

引用格式:崔建国,张善好,于明月,等.基于 GRNN-ELM 的飞机复合材料结构损伤识别[J].南京航空航天大学学报,2017,49(4):468-473. CUI Jianguo, ZHANG Shan hao, YU Mingyue, et al. Damage identification of aircraft composite structure based on GRNN-ELM[J]. Journal of Nanjing University of Aeronautics & Astronautics, 2017, 49(4): 468-473.

vector is built by kernel independent component analysis (KICA). Finally, the fusion feature vector is used to build GRNN-ELM identification model. Experimental data verify the effectiveness of the GRNN-ELM method, and the result shows that the GRNN-ELM model can realize aircraft composite structure damage identification more effectively compared with ELM and GRNN models, respectively, thus it has a good engineering application value.

Key words: variational mode decomposition; singular entropy; kernel independent component analysis; GRNN-ELM combined neural network; damage identification

为提高飞机的结构性能、减轻结构重量,性能优越的复合材料在现代飞机上得到广泛应用。但由于飞机在服役过程中其结构会出现各种损伤,致使飞机结构承载能力骤降,从而影响飞机的飞行安全。因此,及时有效地识别出飞机复合材料结构损伤已成为目前亟待解决的影响飞机飞行安全的重要问题之一。

为了实现飞机复合材料结构损伤识别,许多学者对此开展了广泛研究。华生明采用小波分析和 BP 神经网络对复合材料的损伤进行检测^[1],但由于 BP 神经网络算法本身的结构问题,训练网络容易陷入局部极值,导致网络训练失败,不利于复合材料的损伤检测。王峰林等人采用 RBF 神经网络对复合材料脱粘缺陷进行识别^[2],但在训练样本过少时,RBF 神经网络的泛化能力弱,对实际应用带来不便。王明用经验模态分解和 BP 神经网络,较好地实现了对复合材料板的损伤识别和定位^[3]。但由于经验模态分解的模态混叠现象,改变了本征模函数的物理意义,对损伤的识别准确率有较大影响。为较好地解决飞机复合材料结构损伤识别问题,本文提出采用先进的变分模态分解(Variational mode decomposition, VMD)和核独立主元分析(Kernel independent component analysis, KICA)方法进行特征提取,避免了经验模态分解固有的模态混叠现象,并结合广义回归神经网络(General regression neural network, GRNN)和极限学习机(Extreme learning machine, ELM)组合的神经网络泛化能力强、网络训练可靠等特点,对飞机复合材料结构损伤识别方法展开了研究。

1 特征提取理论

1.1 变分模态分解

VMD 是一种自适应和准正交的分解方法^[4],通过搜寻约束变分模型的最优解以实现信号的自适应分解,可有效克服经验模态分解算法分解过程中的模态混叠,具有更强的噪声鲁棒性及较小的端点效应^[5],基本理论如下^[6]。

首先将每个模态重新定义为调频调幅 $u_k(t)$ 信号,表达式为

$$u_k(t) = A_k(t) \cos(\varphi_k(t)) \quad k = 1, \dots, K \quad (1)$$

$$\omega_k(t) = d\varphi_k(t)/dt \quad (2)$$

式中: $\varphi_k(t)$ 为时间 t 的相位函数; $A_k(t)$ 为 $u_k(t)$ 的瞬时幅值; k 为分解的模态数量; $\omega_k(t)$ 为 $u_k(t)$ 的瞬时频率。假设每个模态 $u_k(t)$ 具有中心频率和有限带宽,约束条件为各模态之和等于输入信号 f ,且每个模态的估计带宽之和为最小,其受约束的变分模型为

$$\min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|^2 \right\} \quad (3)$$

s. t. $\sum_k u_k = f$

式中: $\{u_k\}$ 为分解得到的 K 个有限带宽基本模式分量(Intrinsic mode function, IMF) $\{u_1, \dots, u_k\}$; $\{\omega_k\}$ 为各分量的频率中心 $\{\omega_1, \dots, \omega_k\}$; $\sum_k := \sum_{k=1}^K$; $\delta(t)$ 为 Dirac 分布。

引入扩展的 Lagrange 将约束性变分问题变为非约束性变分问题,求取式(3)的最优解为

$$L(\{u_k\}, \{\omega_k\}, \lambda) = \alpha \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|^2 + \left\| f(t) - \sum_k u_k(t) \right\|_2^2 + \langle \lambda(t), f(t) - \sum_k u_k(t) \rangle \quad (4)$$

式中: α 为惩罚参数; λ 为 Lagrange 乘子。

然后采用乘法算子交替法求取式(4)的变分约束模型,得到最优解,从而将信号分解成为 K 个窄带 IMF 分量。

1.2 奇异熵特征提取

由于在不同损伤下, VMD 分解得到的各阶 IMF 分量有所差异,计算得到的奇异熵有显著不同,为了有效地提取结构损伤信息,故以 VMD 分解的 IMF 分量为基础,将奇异熵引入到复合材料结构损伤特征提取中。奇异熵可以在整体上定量衡量原始振动信号的复杂性或不确定性程度,以表征复合材料结构的不同损伤。奇异熵计算步骤^[7]如下:

(1)构建特征向量矩阵

采用 VMD 算法对原始信号进行自适应分解,

得到 m 个 IMF 分量。提取各阶 IMF 分量作为初始特征向量矩阵 $\mathbf{D} = [\text{imf}_1, \text{imf}_2, \dots, \text{imf}_m]$ 。

(2) 奇异值分解

由矩阵分析理论知,必然存在矩阵 \mathbf{U} , 矩阵 \mathbf{V} 和矩阵 $\mathbf{\Lambda}$, 初始特征向量矩阵表示为

$$\mathbf{D} = \mathbf{U} \cdot \mathbf{\Lambda} \cdot \mathbf{V}^T \quad (5)$$

对角线矩阵 $\mathbf{\Lambda}$ 的主对角线 $\lambda_j (j=1, 2, \dots, m)$ 为初始特征向量矩阵的奇异值。

(3) 奇异值归一化处理

忽略残余分量,对初始特征矩阵的奇异值 $\lambda_j (j=1, 2, \dots, m)$ 进行归一化处理,则第 j 个奇异值归一化的计算公式为

$$\sigma_j = \lambda_j^2 / \sigma \quad (6)$$

式中 σ 为奇异值的总和, $\sigma = \sum_{j=1}^m \lambda_j^2$ 。

(4) 计算奇异熵

VMD 的奇异熵定义为

$$H_q(i) = - \sum_{i=1}^m p_i \log(p_i) \quad (7)$$

式中: $p_i = \sigma_i / \sigma, (i=1, 2, \dots, m)$ 表示第 i 个 IMF 分量的奇异值在奇异值和 σ 中的比重; 奇异值和为

$$\sigma = \sum_{j=1}^m \lambda_j^2。$$

1.3 基于核独立分量分析的特征融合

分散的单个传感器获取的特征信息难以准确表征整个复合材料结构件损伤状态,鉴于 KICA 方法具有能较完整保留原始数据特征信息的优点,采用 KICA 方法对 4 个光纤光栅传感器获取的特征信息进行融合,并将融合后的特征信息作为表征复合材料结构状态的特征量。

KICA 的基本思想是将原始输入数据经核函数 $\varphi(\cdot)$ 映射到高能特征空间 F 中进行 ICA 分析,从而获取非线性独立元。具体实现过程如下^[8]:

(1) 原始输入数据 x_1, x_2, \dots, x_n 在 F 空间中的映射为 $\varphi(x_1), \varphi(x_2), \dots, \varphi(x_n)$, 得到核矩阵 \mathbf{K} , 可表示为

$$K_{ij} = \langle \varphi(x_i), \varphi(x_j) \rangle = K(x_i, x_j) \quad (8)$$

(2) 按式(9)中心化,即

$$\tilde{\mathbf{K}} = \mathbf{K} - \mathbf{E}_n \cdot \mathbf{K} - \mathbf{K} \cdot \mathbf{E}_n + \mathbf{E}_n \cdot \mathbf{K} \cdot \mathbf{E}_n \quad (9)$$

式中 \mathbf{E}_n 为元素全为 $\frac{1}{n}$ 的 $n \times n$ 矩阵。

(3) 按式(10)归一化,即

$$\bar{\mathbf{K}} = \tilde{\mathbf{K}} / (f_{tr}(\tilde{\mathbf{K}}) / n) \quad (10)$$

式中 $f_{tr}(\cdot)$ 为求迹运算。

(4) 求解 $\lambda \mathbf{v} = \bar{\mathbf{K}} \mathbf{v}$ 的特征值问题后,得到前 h 个特征值 $\lambda_1, \lambda_2, \dots, \lambda_h$ 和对应的特征向量 $[v_1, v_2, \dots, v_h]$ 。数据映射到高能特征空间,得

$$\mathbf{z} = \sqrt{n} \mathbf{\Lambda}^{-1} \mathbf{v}^T \tilde{\mathbf{K}} \quad (11)$$

式中: $\mathbf{v} = [v_1, v_2, \dots, v_h]$; $\mathbf{\Lambda} = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_h)$ 。

(5) 采用 FastICA 算法^[9]得到分离矩阵 \mathbf{W} 和特征空间中的独立主元 \mathbf{s} , 建立以下关系

$$\mathbf{s} = \mathbf{W} \cdot \mathbf{z} \quad (12)$$

至此,通过 KICA 方法可以将 4 个光纤光栅传感器获取的 4 维特征信息融合为 1 维特征信息,实现了特征数据的降维,完成了特征向量的构建。

2 GRNN-ELM 损伤识别模型

GRNN 网络是一种基于非线性回归理论的神经网络模型,它建立在数理统计的基础之上,具有学习速度快、网络模型稳定的特点^[10]。而 ELM 学习机是由单隐藏层反馈神经网络发展而来,该网络可以随机初始化输入权重和偏置并得到相应的隐含层节点输出,具有训练速度快、泛化能力强、模型简单等特点^[11]。本文将 GRNN 和 ELM 有效地结合,建立 GRNN-ELM 组合损伤识别模型。

GRNN-ELM 组合神经网络可看成是由 1 个输入层、4 个隐含层和 1 个输出层组成的前馈性神经网络,其网络结构如图 1 所示。

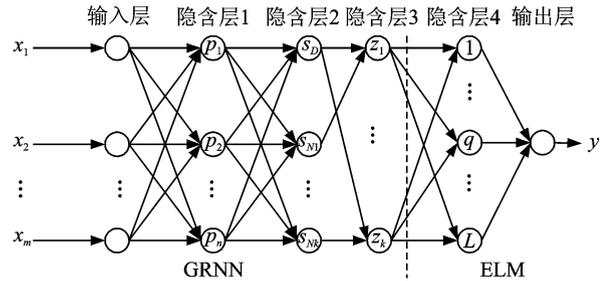


图 1 GRNN-ELM 组合神经网络结构

Fig. 1 Structure of GRNN-ELM neural networks

GRNN 子网模型构建方法如下^[12]:如图 1 所示, $\mathbf{X}_{n \times m} = [x_1, x_2, \dots, x_m]^T$ 为组合神经网络的输入,GRNN 子网输出为 $\mathbf{Z} = [z_1, \dots, z_k]^T$ 。GRNN 子网的输入节点个数为 m ;GRNN 子网的输出节点个数为 k 。

输入层的神经元数目等于输入样本的维数 m 。隐含层 1 的神经元数目等于输入样本的数目 n , 隐含层 1 的第 i 个神经元的传递函数为

$$P_i = \exp \left[- \frac{(\mathbf{X} - \mathbf{X}_i)^T (\mathbf{X} - \mathbf{X}_i)}{2e^2} \right]^T \quad i = 1, 2, \dots, n \quad (13)$$

隐含层 2 包含两类神经元,传递函数分别为

$$S_D = \sum_{i=1}^n P_i \quad (14)$$

$$S_{N_j} = \sum_{i=1}^n y_{ij} P_i \quad j = 1, 2, \dots, k \quad (15)$$

式中: P_i 为隐含层 2 第 i 个神经元的输入; j 为 GRNN 子网第 j 个输出节点。

隐含层 3 中的神经元数目等于 GRNN 子网输出节点的个数 k , 隐含层 3 的第 j 个神经元输出为

$$z_j = S_{N_j} / S_D \quad (16)$$

ELM 子网模型构建方法如下^[13]: 如图 1 所示, ELM 子网模型输出层的输出形式为

$$y_t = \sum_{q=1}^L \beta_q g(w_q \cdot z_t + b_q) \quad t=1, 2, \dots, n \quad (17)$$

式中: z_t 为隐含层 3 的神经元输出, 同时也是 ELM 子网的输入; t 为隐含层 3 的神经元个数; $g(\cdot)$ 为激活函数; w_q 为隐含层 4 中第 q 个神经元的输入权重; b_q 为隐含层 4 中第 q 个神经元的输出权重。

将 GRNN 与 ELM 按图 1 形式进行组合, 从而可完成基于 GRNN-ELM 飞机复合材料结构损伤识别模型的构建。

3 试验数据获取与特征提取

试验件采用 BA9912-G0827 型号复合材料层合板, 尺寸为 100 mm × 150 mm, 多层对称层合板的一半铺层形式为 [45/-45/0/-45/0/45/0/90/0/45/-45/0]s, 单层铺层厚度为 0.18 mm, 整个层合板共 24 层。将 4 个光纤光栅传感器均布在板的表面。传感器布置见图 2, 圆圈处为放置传感器的位置。

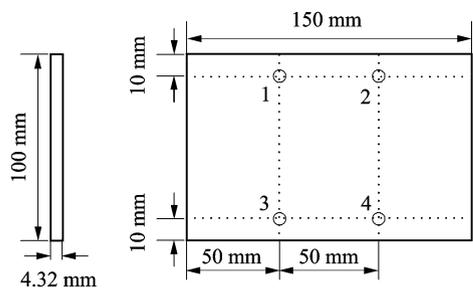


图 2 传感器布置示意图

Fig. 2 Sensor layout diagram

首先对试验件进行冲击, 而后采用疲劳拉伸机对其进行疲劳拉伸试验直至试件损坏, 如图 3 所示。复合材料疲劳损伤形式有多种^[14]。当试验件承受到较小的负载能量时, 其损伤主要表现为分



图 3 损坏的试验件

Fig. 3 Damaged test piece

层^[15]。重锤冲击后试验件出现直径为 5 mm、深度为 3 层的圆坑, 试验件处于初始损伤阶段; 随着疲劳加载次数的增加, 试验件上不断出现新的损伤。试验件的 11~13 层出现宽度 2 mm、长度为 6 mm 的条状分层损伤时, 试验件处于损伤扩展阶段; 试验件的 6~8 层处出现直径为 6.5 mm 的圆形分层损伤时, 试验件处于损伤失效阶段。本文将对完好、初始损伤、损伤扩展和损伤失效 4 种分层损伤进行研究。

首先, 对传感器网络募集到的分层损伤数据进行预处理, 剔除明显干扰波动数据后, 按照 1.1 节进行 VMD 分解, 得到各阶 IMF 分量, 按照 1.2 节特征提取步骤提取奇异熵特征, 最后按照 1.3 节对多个传感器的奇异熵特征进行融合。具体如下: 将传感器网络募集的 9 000 个应变值, 以每 10 个应变值进行 1 次 VMD 分解, 计算每个传感器的奇异熵后将所有传感器的奇异熵进行融合, 最终得到融合后的特征, 如表 1 所示。

表 1 各传感器信息的奇异熵和融合后的特征

Tab. 1 Singular entropy of each sensor and fusion feature

组数	传感器 1 的奇异熵	...	传感器 4 的奇异熵	融合后 的特征
1	1.673 6	...	1.674 1	1.547 2
⋮	⋮	⋮	⋮	⋮
225	1.631 8	...	1.643 7	1.404 1
226	1.573 1	...	1.518 4	0.495 0
⋮	⋮	⋮	⋮	⋮
450	1.488 5	...	1.488 7	0.528 3
451	1.298 9	...	1.339 0	-0.069 5
⋮	⋮	⋮	⋮	⋮
675	1.303 6	...	1.258 9	0.019 8
676	1.106 0	...	1.088 3	-1.184 6
⋮	⋮	⋮	⋮	⋮
900	1.006 0	...	1.081 2	-1.202 5

表 1 中 1~225 组、226~450 组、451~675 组和 676~900 组数据分别对应完好、初始损伤、损伤扩展和损伤失效下得到的奇异熵和融合后的特征。1~200 组、226~425 组、451~650 组和 676~875 组融合后的特征作为识别模型的训练数据。200~225 组、426~450 组、651~675 组和 876~900 组融合后的特征作为识别模型的测试数据。

4 损伤识别模型及试验验证

4.1 损伤识别模型及模型的构建

根据第 2 节理论, 用第 3 节中的训练数据构建损伤识别模型。该损伤识别模型的输入层为 1 个节点, 输出层为 1 个节点。结构损伤模式与对应的输出形式见表 2。

表2 结构损伤模式与对应的输出形式

Tab. 2 Structure damage model and output form

损伤模式	输出形式
完好	1
初始损伤	2
损伤扩展	3
损伤失效	4

4.2 损伤识别试验验证

为验证所构建的 GRNN-ELM 损伤识别模型的准确性,本文分别设计了 GRNN 损伤识别模型和 ELM 损伤识别模型作为对比。并用第3节中未参与建模的测试数据分别对以上3个损伤识别模型的有效性进行验证,结果见表3和图4。

表3 3种损伤识别模型验证结果

Tab. 3 Verification results of three models

模型	测试数目/组	错误个数	准确率/%
GRNN-ELM	100	5	95
ELM	100	8	92
GRNN	100	10	90

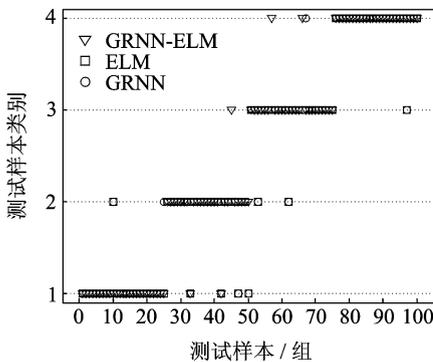


图4 3种损伤识别模型验证结果

Fig. 4 Verification results of three models

由试验结果可知,飞机复合材料分层结构损伤信息经过 VMD-KICA 方法特征提取后,采用 GRNN-ELM 方法进行损伤识别,损伤识别准确率达到 95%,与 ELM 和 GRNN 单一损伤识别模型相比,准确率更高,同时验证了 GRNN-ELM 损伤识别模型的有效性。

5 结束语

本文提出了一种基于变分模式分解和 GRNN-ELM 组合神经网络的飞机复合材料结构损伤识别方法。以飞机复合材料层合板为具体研究对象,将光纤传感器网络募集到的应变信息通过 VMD 分解,得到 IMF 分量,提取其奇异熵特征并采用 KICA 方法对奇异熵特征进行融合,构建融合特征向量,分别建立基于 GRNN-ELM、ELM 和 GRNN

的飞机复合材料结构损伤识别模型,并对飞机复合材料结构损伤进行识别。试验结果表明,所提出的基于 GRNN-ELM 的复合材料结构损伤识别方法明显优于其他两种损伤识别方法,验证了 GRNN-ELM 损伤识别模型的有效性,有很好的应用前景。

参考文献:

- [1] 华生明. 结合小波分析和 BP 神经网络的复合材料损伤检测技术研究[D]. 南京:南京航空航天大学, 2015.
HUA Shengming. Composite material damage detection research combining wavelet analysis and BP neural network [D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2015.
- [2] 王峰林,王长龙,胡永江. 基于改进 LMS 算法的复合材料超声检测缺陷识别[J]. 军械工程学院学报, 2013,119(5):66-69.
WANG Fenglin, WANG Changlong, HU Yongjiang. Recognition of composite materials flaws within ultrasonic testing based on improved LMS algorithm[J]. Journal of Ordnance Engineering College, 2013,119(5):66-69.
- [3] 王明. 基于光纤传感和 EMD 分解的复合材料损伤监测研究[D]. 武汉:武汉理工大学,2012.
WANG Ming. Study on damage monitoring of composite materials based on fiber optic sensor and EMD [D]. Wuhan: Wuhan University of Technology, 2012.
- [4] 岳应娟,孙钢,蔡艳平,等. 变分模态分解在轴承故障诊断中的应用[J]. 轴承, 2016, 441(8):50-54,65.
YUE Yingjuan, SUN Gang, CAI Yanping, et al. Application of variational mode decomposition in fault diagnosis for bearings[J]. Bearing, 2016, 441(8): 50-54,65.
- [5] JIANG Wanlu, WANG Zhenwei, ZHU Yong, et al. Fault recognition method for rolling bearing integrating VMD denoising and FCM clustering[J]. Journal of Information and Computational Science, 2015, 12(16):5967-5975.
- [6] 谢平,杨芳梅,李欣欣,等. 基于变分模态分解-传递熵的脑电信号耦合分析[J]. 物理学报, 2016, 65(11):285-293.
XIE Ping, YANG Fangmei, LI Xinxin, et al. Functional coupling analyses of electroencephalogram and electromyogram based on variational mode decomposition-transfer entropy [J]. Acta Physica Sinica, 2016, 65(11): 285-293.
- [7] 王玉静,宋立新,康守强. 基于 EMD 和奇异值分解的心律失常分类方法[J]. 信号处理, 2010, 26(9):1423-1427.
WANG Yujing, SONG Lixin, KANG Shouqiang.

- Arrhythmia classification based on empirical mode decomposition and singular value decomposition[J]. *Signal Processing*, 2010, 26(9):1423-1427.
- [8] 唐勇波,桂卫华,彭涛,等. PCA 和 KICA 特征提取的变压器故障诊断模型[J]. *高电压技术*, 2014, 255(2):557-563.
- TANG Yongbo, GUI Weihua, PENG Tao, et al. Transformer fault diagnosis model based on PCA and KICA feature extraction[J]. *High Voltage Engineering*, 2014, 255(2):557-563.
- [9] 张宵,马洁. 数据驱动 PCA、ICA 和 KICA 故障检测仿真比较[J]. *北京信息科技大学学报*, 2014, 101(5):56-61,66.
- ZHANG Xiao, MA Jie. Simulation comparisons among PCA, ICA and KICA fault detection based on data-driven[J]. *Journal of Beijing Information Science and Technology University*, 2014, 101(5):56-61,66.
- [10] ZHANG J, TAN Z, LI C, et al. A novel hybrid forecasting method using GRNN combined with wavelet transform and a GARCH model[J]. *Energy Sources, Part B: Economics, Planning, and Policy*, 2015, 10(1/2/3/4):418-426.
- [11] 甘露. 极限学习机的研究与应用[D]. 西安:西安电子科技大学, 2014.
- GAN Lu. Research and application of extreme learning machine[D]. Xi'an: Xidian University, 2014.
- [12] 李聪. 基于 GRNN 网络的短期与超短期负荷预测[D]. 吉林:东北电力大学, 2010.
- LI Cong. Short-term and ultra-short-term load forecasting based on GRNN network[D]. Jilin: Northeast Electric Power University, 2010.
- [13] 刘静雅. 基于极限学习机的航空发动机传感器故障诊断研究[D]. 天津:中国民航大学, 2015.
- LIU Jingya. Research of aero-engine sensor fault diagnosis based on extreme learning machine [D]. Tianjin: Civil Aviation University of China, 2015.
- [14] FRUEHMANN R K, DULIEU-BARTON J M, QUINN S. Assessment of fatigue damage evolution in woven composite materials using infra-red techniques [J]. *Composites Science and Technology*, 2010, 70(6):937.
- [15] 罗武. 基于神经网络的复合材料结构的损伤监测[D]. 西安:西北工业大学, 2004.
- LUO Wu. The method based on neural network of composite structure damage monitoring[D]. Xi'an: Northwestern Polytechnical University, 2004.

