

doi: 10.7690/bgzdh.2019.03.012

基于小波神经网络的航天器故障诊断方法

闻新¹, 史超¹, 方紫帆²

(1. 南京航空航天大学航天学院, 南京 210016; 2. 宁夏大学教育学院, 银川 750021)

摘要: 针对微小航天器集群的故障诊断问题, 提出一种故障诊断 (fault diagnosis, FD) 的新方法。依据小波神经网络 (wavelet neural network, WNN) 理论, 结合航天器集群的领队航天器故障检测与系统重构问题, 构建一种故障诊断框架, 采用小波神经网络与神经网络相结合, 得出航天器姿态故障诊断策略及卫星姿态故障重构技术, 给出了领队航天器故障重构方案, 并进行了仿真实验与验证。仿真结果表明: 该故障诊断方法是有效的、故障重构也是可行的。

关键词: 航天器; 小波神经网络; 神经网络; 故障诊断; 故障重构

中图分类号: TP202 **文献标志码:** A

Fault Diagnosis Method of Spacecraft Based on Wavelet Neural Network

Wen Xin¹, Shi Chao¹, Fang Zifan²

(1. College of Astronautics, Nanjing University of Aeronautics & Astronautics, Nanjing 210016, China;

2. School of Education, Ningxia University, Yinchuan 750021, China)

Abstract: In this paper, a new fault diagnosis method is developed for the fault diagnosis of micro-spacecraft cluster. Based on the theory of wavelet neural network, in order to deal with the problem of failure detection of the leader spacecraft and reconfiguration of spacecraft cluster, a fault diagnosis framework is constructed. Combined with wavelet neural network and neural network, it is concluded the fault diagnosis strategy of spacecraft attitude and fault reconstruction technology of satellite attitude, gives the leader of the spacecraft fault reconstruction scheme, and carries out the simulation and verification. Simulation results show that the fault diagnosis method is effective and fault reconstruction is feasible.

Keywords: spacecraft; wavelet neural network; neural network; fault diagnosis; fault reconstruction

0 引言

目前, 多颗微小航天器协同工作已经成为航天领域发展的新兴方向, 也是国内外研究的最新热点^[1]。微小航天器群在遇到故障或者突发问题的时候, 一般都采用舍弃故障航天器的方式来减少风险, 对于整个群系统来说, 损失一颗航天器不会导致整个系统崩溃或者任务失败, 仅会引起执行任务的准确率和及时性下降。在发生故障时, 舍弃故障部分, 或者利用备份航天器代替故障航天器的位置与功能, 称为故障重构^[2]。

目前, 故障诊断的方法主要是基于模型的方法和基于人工智能的方法^[3-4]。前者需要被诊断对象的数学模型, 诊断效果很大程度依赖于模型的准确性。对于一些复杂的非线性系统, 很难建立精确的数学模型。专家们又提出了基于人工智能的故障诊断方法, 利用已有的历史数据进行训练分析, 模拟实际

系统, 从而完成故障诊断任务。如: 文献[5]利用 2 个递归神经网络用于识别卫星姿态控制系统的执行器和传感器故障; 文献[6]利用动态神经网络模拟了反作用飞轮的运行特性, 实现对卫星群姿态控制系统的故障检测与隔离; 文献[7]通过设计一种 Mahalanobis-like 距离计算神经元间距离的 HBF 神经网络, 引入新的矩阵表示神经元间的相似度, 用于航天器执行机构的故障重构。

小波神经网络 (WNN) 是在小波分析研究获得突破的基础上, 提出的一种前馈型网络, 其特点包括小波基元及整个网络结构的确定, 并且从根本上避免了网络训练过程中局部最优等问题^[8]。

笔者结合故障诊断最新研究成果^[9], 以及存在的问题, 采用小波函数与神经网络相结合, 设计一种故障诊断框架, 将其应用于航天器集群中领队航天器执行器的故障诊断, 同时给出了故障重构方法, 并仿真验证了算法的有效性与重构的可行性。

收稿日期: 2018-10-27; 修回日期: 2018-12-19

作者简介: 闻新 (1961—), 男, 辽宁人, 博士, 教授, 从事航天器编队控制、航天器故障诊断研究。

1 航天器故障诊断框架与问题描述

1.1 航天器故障诊断框架

笔者设计了一种新型自上而下的故障诊断系统框架。首先，在卫星群总体上评估是否能够完成任务，如果检测到任务完成准确性下降，说明整个系统出现了故障，需要进行故障诊断；然后，寻找出故障卫星，通过研究故障卫星，寻找出故障分系统，直至寻找到故障机构；最后，对故障机构进行故障隔离，通过故障类型判断是否进行故障重构。

在故障诊断系统框架中借鉴文献[10]的分层结构，分为群层面故障(第 1 级故障)，航天器层面故障(第 2 级故障)，分系统层面故障(第 3 级故障)，器件层面故障(第 4 级故障)。

对于第 1 级、第 2 级故障，通过领队航天器与队员航天器之间的实际相对姿态角与预期相对姿态角的残差情况来诊断。例如，文献[11]提取并总结了气象部件的故障特征，验证了信号处理方法用于航天器故障诊断的有效性。

对于第 3 级故障，通过地面模拟实验很难总结出经验，需要借助人工智能技术来解决。例如，文献[12]通过基于 Elman 神经网络对卫星群中反作用飞轮发生故障进行诊断，同时可以通过相邻卫星监测到故障卫星的故障情况，具有很好的准确性与实时性。

对于第 4 级故障，其实质性内容是检测出故障的类型，因为进行故障重构任务要求明确故障问题是否属于永久性故障。对于间歇性、突发性故障，系统拥有自修复能力，经过一段时间，故障就不再出现了；如果是永久性故障，系统无法自我修复，所以对故障进行回复是十分必要的。

1.2 问题描述

多星系统的集群飞行普遍采用一定的构型组成分布式系统，完成空间监测、通信等任务，例如美国空军的 TechSat21 计划，美国国防高级研究计划局提出的 F6 计划等。文献[13]对轨道根数的变化对相对距离的影响进行了研究，并设计了控制逻辑，对三星集群系统的长时间轨道保持任务进行了仿真。在主从式控制策略中，领队航天器对队员有着决定性的控制作用，通过领队与队员之间的相对姿态角，控制队员的运行。但是，如果领队本身出现了故障，整个卫星群系统将不可能自我检测与修复，对卫星群系统造成毁灭性的打击。

笔者主要针对主从式多星集群系统的主从式卫星编队，控制策略如图 1 所示。在原有主从式卫星控制策略的基础上，添加基于小波神经网络的监察系统预测领队航天器与队员航天器间的相对姿态角，从而判断领队航天器状态的健康与否。




图 1 航天器编队主从式结构

2 小波神经网络与改进训练算法

2.1 小波神经网络

小波神经网络是在神经网络的基础上，将神经网络隐含层节点的 S 型函数由小波函数来代替，相应的输入层到隐含层的权值及隐含层的阈值，分别由小波函数的尺度伸缩因子和时间平移因子所代替。同时，考虑和分析了神经网络的激励函数特点以及神经网络的结构，并结合了小波变换的知识而构造^[14]。

由于小波神经网络是一种连续的非线性映射，使得小波神经网络存在多种形式和学习方法，包括松散型结合小波神经网络与紧密型小波神经网络。紧密型的结合方式具有多种优点，包括具有很好的自适应分辨性，良好的逼近能力和容错能力，并能够有效地避免局部最小值等优点。

笔者通过紧密型的结合方式将级联前馈神经网络与小波函数构造出一种新型智能算法，可使神经网络结构优化且具有自适应能力，从而更好地处理多目标跟踪与预测问题，其结构如图 2 所示。

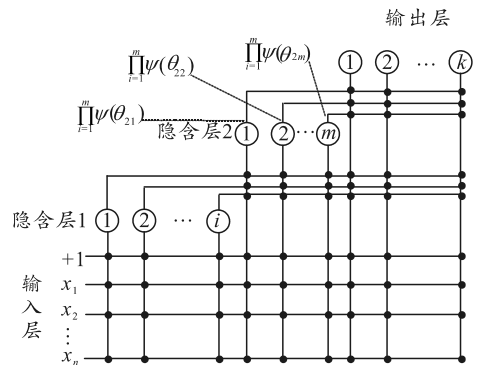


图 2 小波级联前馈神经网络结构

在图中，级联前馈神经网络与常见的前向神经网络结构类似，但是其输入量与每一层神经元均通

过权值连接，同时每一层神经元都与之前各层的神经元通过权值相连。级联前馈神经网络由输入层、隐含层和输出层构成。输入与输出层仅有一层，分别包括 n 、 m 个神经元。隐含层具有 g 层，每层包括 k 个隐含层神经元。该网络的第 i 层第 j 个神经元权值如下：

$$\varphi_{ij} = \begin{cases} 1 & j=1 \\ x_{ij} & 2 \leq j \leq n+1; \\ c_{ij} & j > n+1 \end{cases} \quad (1)$$

$$c_{ij} = f_j \left(\sum_{i=1}^{j-1} \varphi_{ii} w_{ij} \right) \quad (2)$$

笔者使用的级联前馈神经网络共有为 L 层，可以计算网络输出如下：

$$y = \sum_{i=1}^m \varphi_{ij} \theta_{iq} + \sum_{j=1}^k \varphi_{(m-1)j} \Psi_j \quad (3)$$

其中

$$\Psi_j = \prod_{i=1}^m \psi(\theta_{ij}) \quad (4)$$

式中： θ_{jq} 是连接第 j 个隐含神经元与第 q 个输出神经元间的权值； ψ_j 是多维小波函数。

神经网络的激活函数常使用 S 型函数，但小波神经网络使用最多的是小波母函数，经常使用的 3 种小波函数作为网络的激活函数，包括高斯小波、墨西哥草帽小波与 Morlet 小波函数，笔者采用墨西哥草帽小波函数。

2.2 改进训练算法

采用分段式训练算法对神经网络进行训练，第 1 阶段采用反向传播算法，利用误差校正学习算法调整网络的所有权值。

第 2 阶段采用新型训练算法对部分重要神经元权值进行优化。其中，连接输出神经元的权值与相应的小波伸缩系数与平移系数在网络中尤为关键，所以重点优化输出神经元权值，不仅能提高网络精度，同时也能提高网络训练速度。先将神经网络输出进行 QR 分解：

$$y = QR; \quad (5)$$

$$Q = (q_1 \quad q_2 \quad \dots \quad q_n),$$

$$R = \begin{pmatrix} 1 & r_{12} & \dots & r_{1n} \\ 0 & 1 & \dots & r_{2n} \\ \vdots & & & \vdots \\ 0 & \dots & 0 & 1 \end{pmatrix} q_i q_j = 0 (i \neq j) \quad (6)$$

在训练算法中，隐含层的初始权值在一定概率下的随机分配，不需要调整，而输出神经元的权值更新，不通过梯度或者广义逆的增量方式。下面推导出了与输出神经元相连的隐含层神经元权值优化方法。根据公式(5)和(6)，定义

$$\beta = (Q^T Q)^{-1} Q^T T \quad (7)$$

其中 T 为期望输出值。

$$\beta = ((Q_{n-1}, q_n)^T (Q_{n-1}, q_n))^{-1} (Q_{n-1}, q_n)^T =$$

$$\begin{pmatrix} (Q_{n-1}^T Q_{n-1})^{-1} & 0 \\ 0 & (q^T q)^{-1} \end{pmatrix} \begin{pmatrix} Q_{n-1}^T T \\ q^T T \end{pmatrix} =$$

$$\begin{pmatrix} (Q_{n-1}^T Q_{n-1})^{-1} Q_{n-1}^T T \\ (q^T q)^{-1} q^T T \end{pmatrix} \quad (8)$$

令

$$\beta = \begin{pmatrix} \beta_{n-1} \\ \phi \end{pmatrix}, \quad \phi = \frac{q^T T}{q^T q} \quad (9)$$

根据式(8)，令 $R = \begin{pmatrix} R_{n-1} & \eta \\ 0 & 1 \end{pmatrix}$ 根据分块矩阵理论：

$$\begin{pmatrix} R_{n-1} & \eta \\ 0 & 1 \end{pmatrix} \begin{pmatrix} R_{n-1}^{-1} & -R_{n-1}^{-1} \eta \\ 0 & 1 \end{pmatrix} = I_{n \times n}, \quad (10)$$

因此，有

$$R^{-1} = \begin{pmatrix} R_{n-1}^{-1} & -R_{n-1}^{-1} \eta \\ 0 & 1 \end{pmatrix} \quad (11)$$

通过 $\theta = R_n^{-1} \beta$ 可以得出优化后的与输出神经元相连的隐含层神经元权值，从而计算出小波伸缩系数与平移系数。

选用墨西哥草帽函数作为小波母函数^[15]，形式如下：

$$\phi(\theta_{ij}) = (1 - z_{ij}^2) \exp\left(-\frac{z_{ij}^2}{2}\right) \quad (12)$$

二次成本函数^[16]对权值 θ 的偏导数为：

$$\frac{\partial L_n}{\partial \theta} = \frac{1}{2n} \sum_{p=1}^n \frac{\partial E_p}{\partial \theta} = \frac{1}{2n} \sum_{p=1}^n \frac{\partial E_p}{\partial y_p} \frac{\partial y_p}{\partial \theta} =$$

$$\frac{1}{n} \sum_{p=1}^n (-(\bar{y}_p - y_p) \frac{\partial y_p}{\partial \theta}) = -\frac{1}{n} \sum_{p=1}^n e_p \frac{\partial y_p}{\partial \theta} \quad (13)$$

式中网络输出对各个权值及输入向量的偏导数为：

$$\frac{\partial y_p}{\partial \varphi_i} = x_i; \quad (14)$$

$$\frac{\partial y_p}{\partial \varphi_j} = \Psi_j(x) = \prod_{i=1}^m (1 - \theta_{ij}^2) e^{-\frac{1}{2} z_{ij}^2}; \quad (15)$$

$$\frac{\partial y_p}{\partial \varphi_{(b)ij}} = \frac{\partial y_p}{\partial \Psi_j} \frac{\partial \Psi_j}{\partial \psi(\theta_{ij})} \frac{\partial \psi(\theta_{ij})}{\partial \theta_{ij}} \frac{\partial \theta_{ij}}{\partial \varphi_{(b)ij}} = -\frac{\omega_j}{\varphi_{(a)ij}} \psi(\theta_{1j}) \cdots \psi'(\theta_{ij}) \cdots \psi(\theta_{mj}); \quad (16)$$

$$\frac{\partial y_p}{\partial \varphi_{(a)ij}} = \frac{\partial y_p}{\partial \Psi_j} \frac{\partial \Psi_j}{\partial \psi(\theta_{ij})} \frac{\partial \psi(\theta_{ij})}{\partial \theta_{ij}} \frac{\partial \theta_{ij}}{\partial \varphi_{(a)ij}} = -\varphi_j \psi(\theta_{1j}) \cdots \psi'(\theta_{ij}) \cdots \psi(\theta_{mj}) = -\frac{\omega_j}{\varphi_{(b)ij}} \theta_{ij} \psi(\theta_{1j}) \cdots \psi'(\theta_{ij}) \cdots \psi(\theta_{mj}) = \theta_{ij} \frac{\partial y_p}{\partial \varphi_{(b)ij}}; \quad (17)$$

$$\frac{\partial y_p}{\partial x_i} = \varphi_i + \frac{\sum_{j=1}^k \omega_j (\partial \Psi_j)}{\partial \psi(\theta_{ij})} \frac{\partial \psi(\theta_{ij})}{\partial \theta_{ij}} \frac{\partial \theta_{ij}}{\partial x_i} = \varphi_i + \sum_{j=1}^k \varphi_j \psi(\theta_{1j}) \cdots \psi'(\theta_{ij}) \cdots \psi(\theta_{mj}) \frac{1}{\varphi_{(b)ij}} = \varphi_i - \sum_{j=1}^k \frac{\partial y_p}{\partial \theta_{(a)ij}}. \quad (18)$$

通过分段训练算法，在不涉及小波函数的神经元时，采用普通的梯度下降算法进行神经网络分段训练，提高了网络的训练速度；在涉及到小波函数的神经元时，采用新型优化算法对已经用梯度下降算法训练好的重要权值进行优化，从而得到精确的小波伸缩系数与平移系数，综合提升了网络的准确度。

3 航天器姿态控制系统故障诊断

3.1 航天器姿态故障诊断策略

运用小波神经网络算法对单颗航天器的俯仰、偏航和滚转的姿态角进行监测，通过卫星的三轴姿态角与三轴推力数据训练神经网络，可以预报三轴推力。如果实际推力与预报推力间的残差超出阈值，诊断推理机就可以判断出是相应轴的问题，从而隔离出故障执行器。小波神经网络诊断推理机如图 3 所示。




图 3 小波神经网络诊断推理机

3.2 卫星姿态故障重构技术

针对领队式构型的航天器群系统故障重构问题，讨论 2 种故障情况领队航天器发生了永久性故

障。通常，领队具有决策作用，通过与队员之间的相对姿态角，带领队员飞行。在发生了故障情况后，还肩负着处理故障，保证集群稳定的任务。

在领队故障情况下，基于小波神经网络的领队故障监察系统便起了作用，因为领队本身出现了故障，整个航天器群将不可能自我检测与修复。通过诊断推理机对航天器群进行判断，可以否决掉领队的决策作用。让故障领队飞离群的中心，以免故障领队影响和干扰整个航天器群。

4 仿真分析与验证

4.1 故障检测仿真分析

如果领队航天器发生了故障，运用新型训练算法的神经网络，采集到故障航天器与中心航天之间的相对姿态角与故障航天器本身的姿态角，可以预测出正常状态相对姿态角，从而进行故障诊断。

在 2.5 s 向领航航天器 X 轴执行器注入故障，运用小波神经网络，采集到故障航天器与队员航天之间的相对姿态角与故障航天器本身的姿态角，可以预测出正常状态下脉冲等离子体推进器的推力大小，有效检测出故障的发生，从而进行故障诊断，如图 4、图 5 所示。





图 4 航天器 X 轴姿态角神经网络预测效果



(a) 航天器 Y 轴




图 5 航天器姿态角神经网络预测效果

图 6 为小波神经网络对于领航航天器的故障诊断结果，当 2.5 s 发生了故障以后，航天器的实际角速度突破了阈值范围，表明系统发生了故障。




图 6 航天器检测结果

4.2 故障重构仿真分析

笔者设计的新型主从式航天器集群，选取 4 颗队员航天器与 1 颗领航航天器进行仿真分析。领航航天器的初始轨道根数为 $a_0 = 7\ 000\ \text{km}$ ， $e_0 = 0$ ， $i_0 = 0$ ， $\omega_0 = 0$ ， $\Omega_0 = 0$ ， $t_{f0} = 0$ ^[17]。其中 $a_0, e_0, i_0, \omega_0, \Omega_0, t_{f0}$ 分别为中心航天器的 6 个轨道参数。设定微小航天器群的初始编队轨道面与领航航天器的轨道夹角为 45° ，以中心航天器为参考原点，长半轴为 2 km 的椭圆队形，建立队员航天器与领航航天器的相对运动状态和轨道六根数。

在基于小波神经网络的航天器集群监察系统，检测出领航航天器发生了不可修复的永久性故障，

需要让故障领队飞离集群中心，以免故障领航航天器影响和干扰航天器群，故障重构任务如图 7 所示。




图 7 航天器故障重构

可以通过监察系统选择出新的领队，替代故障领队的位置和功能，与剩余队员构成统一的整体，保证航天器集群正常执行飞行任务。

5 结论

笔者提出一种新的故障诊断方法。该方法针对航天器群中领队航天器故障情况，使用小波神经网络理论，并将其用于航天器相对姿态控制系统执行器的故障诊断中，具备故障检测与估计的能力。小波神经网络具有较少的神经元，应用该网络预测能力减少了传统方法时的复杂性，并且对非线性动态系统故障具有较高的敏感性。笔者通过仿真证明了该故障诊断方法的有效性与准确率，有助于实际应用；同时针对领队航天器故障情况给出了相应的故障重构方案，保证了航天器集群正常执行飞行任务。

参考文献：

- [1] 闻新. 太空探索正在进入航天器集群时代[J]. 人民论坛学术前沿, 2017(5): 19-26.
- [2] 牛禄, 王宏伟, 杨威. 用于微小卫星推进装置的脉冲等离子体推力器[J]. 上海航天, 2004, 21(5): 39-43.
- [3] VENKATASUBRAMANIAN V, RENGASWAMY R, YIN K, et al. A review of process fault detection and diagnosis: Part I: Quantitative model-based methods[J]. Computers & Chemical Engineering, 2003, 27(3): 293-311.
- [4] VENKATASUBRAMANIAN V, RENGASWAMY R, KAVURI S N. A review of process fault detection and diagnosis. Part II: Quantitative models and search strategies. Comput[J]. Computers & Chemical Engineering, 2003, 27(3): 313-326.
- [5] TALEBI H A, KHORASANI K, TAFAZOLI S. A recurrent neural-network-based sensor and actuator fault detection and isolation for nonlinear systems with application to the satellite's attitude control subsystem[J]. IEEE Transactions on Neural Networks, 2009, 20(1):

45-60.

[6] MOUSAVI S, KHORASANI K. Fault detection of reaction wheels in attitude control subsystem of formation flying satellites: A dynamic neural network-based approach[J]. International Journal of Intelligent Unmanned Systems, 2014, 2(1): 2-26.

[7] WEN X, ZHANG X W, ZHU Y P. Design of Fault Detection Observer Based on Hyper Basis Function[J]. Tsinghua Science and Technology, 2015, 20(2): 200-2005.

[8] HAN S J, CHO S B. Evolutionary neural networks for anomaly detection based on the behavior of a program[J]. IEEE Transactions on Systems Man & Cybernetics Part B Cybernetics A Publication of the IEEE Systems Man & Cybernetics Society, 2006, 36(3): 559-70.

[9] 张威, 魏炳翌, 闻新. 国内航天器故障诊断技术应用状况分析与展望[J]. 航空兵器, 2017(4): 66-74.

[10] ISLAM M M, SATTAR M A, AMIN M F, et al. A New Adaptive Merging and Growing Algorithm for Designing Artificial Neural Networks[J]. IEEE Transactions on Systems Man & Cybernetics Part B Cybernetics, 2009, 39(3): 705-722.

[11] HORNIK K, STINCHCOMBE M, WHITE H. Multilayer

feedforward networks are universal approximators[J]. Neural Networks, 1989, 2(5):359-366.

[12] SATTAR M A, ISLAM M M, MURASE K. A New Constructive Algorithm for Designing and Training Artificial Neural Networks[C]//Neural Information Processing. Springer-Verlag, 2007: 317-327.

[13] LAROCHELLE H, ERHAN D, Courville A, et al. An empirical evaluation of deep architectures on problems with many factors of variation[C]//International Conference on Machine Learning. ACM, 2007: 473-480.

[14] BOONSERM C, SURESH C S, DHADBANJAN T. A neural network based power system stabilizer suitable for on-line trainin-A practical case study for EGAT system[J]. IEEE Transactions on energy conversion, 2000, 15(1): 103-109.

[15] 张威, 王嘉轶. 一种微纳航天器编队的故障构型重构方法[J]. 航空兵器, 2017(5): 75-82.

[16] 李新, 闻新, 罗立生, 等. 基于小波神经网络的一类非线性系统的故障检测[J]. 盐城工学院学报(自然科学版), 2016, 29(1): 10-16.

[17] 王嘉轶, 闻新. 航天器故障诊断技术的研究现状与进展[J]. 航空兵器, 2016(5): 71-76.

(上接第 41 页)

3.2 实验结果

图 6 是 tensorboard 中的标量图表示的训练集的准确率图像。随着训练次数的增加, 4 种方案的准确率不断提高, 到达 10 000 次趋于平稳状态, 因此训练次数定为 10 000 次。方案 1 最终准确率均值是 90.62%, 方案 2 的最终准确率均值是 92.58%, 方案 3 的准确率均值达到了 93.58%, 方案 4 为 87.99%。笔者再将测试样本输入到模型中, 得到对测试样本的识别率, 方案 1 是 90.62%, 方案 2 是 92.16%, 方案 3 是 93.04%, 方案 4 是 85.41%。从测试集和训练集的精确率来看, 方案 3 取得的效果最好, 对故障类别的分类更加精确。




图 6 训练集准确率趋势

4 结束语

笔者提出了一种基于卷积神经网络的滚动轴承

故障诊断方法, 通过将 1 维的振动信号转化成 2 维的灰度图像, 采用 5 层的卷积神经网络来对其有的特征进行充分的学习。实验结果表明: 相比人为的故障识别, 该方法提高了特征提取效率与识别准确性。由于采用 RMSPropOptimizer 优化器, 增强了模型的稳定性, 提高了处理样本数据的效率, 实现了轴承故障的智能诊断。

参考文献:

[1] 包红燕. 基于 MEMD 和条件熵相空间重构的滚动轴承故障诊断[D]. 秦皇岛: 燕山大学, 2014: 43-47.

[2] 林京, 屈梁生. 基于连续小波变换的信号检测技术与故障诊断[J]. 机械工程学报, 2000, 36(12): 95-100.

[3] 陈果. 滚动轴承早期故障的特征提取与智能诊断[J]. 航空学报, 2009, 30(2): 362-367.

[4] 王皓, 衣同胜. 基于神经网络 CA/OS-CFAR 检测方法[J]. 兵工自动化, 2018, 37(2): 15-18.

[5] 柳小桐. BP 神经网络输入层数据归一化研究[J]. 机械工程与自动化, 2010(3): 122-123, 126.

[6] 李红利, 张晓彤, 兰立柱, 等. 基于遗传算法的 RBF 神经网络的优化设计方法[J]. 计算机仿真, 2003, 20(11): 67-69.

[7] 贾小权, 曲林伟, 王强, 等. 滚动轴承内圈局部故障碰撞的 NeimarkSacker 分岔研究[J]. 兵器装备工程学报, 2017(2): 122-126.