



基于小波神经网络的组合故障模式识别¹⁾

胡寿松 周川 王源

(南京航空航天大学自动控制系 南京 210016)

摘要 提出了一种基于小波神经网络的组合故障模式识别方法. 针对以歼击机为代表的非线性系统中存在的多重并发故障, 构造了一个多层的小波神经网络, 在输入层对残差信号进行二进离散小波变换, 提取其在多尺度下的细节系数作为故障特征向量, 并将其输入到神经网络分类器进行相应的模式分类. 仿真结果表明, 本文方法为多重并发故障的诊断提供了有效的方法和途径.

关键词 故障诊断, 小波神经网络, 模式识别, 歼击机

中图分类号 TP277, O235

PATTERN RECOGNITION FOR COMPOSITE FAULT BASED ON WAVELET NEURAL NETWORKS

HU Shou-Song ZHOU Chuan WANG Yuan

(Department of Automatic Control, Nanjing University of Aeronautics and Astronautics, Nanjing 210016)

Abstract A pattern recognition method for composite fault diagnosis based on wavelet neural networks is presented. Considering the multiple faults in complex non-linear system such as a fighter, a multiple-layer wavelet neural network is constructed. Residual signal is processed by discrete binary wavelet transformation at the input layer, and the detail coefficients are obtained under multi-resolution as fault character vectors, finally these character vectors are sent to the neural network classifier to complete fault pattern recognition. Simulation results reveal that the presented method is effective for composite fault diagnosis.

Key words Fault diagnosis, wavelet neural networks, pattern recognition, fighter

1 引言

近年来, 故障诊断技术取得了很大的发展, 但故障诊断技术应用于复杂非线性系统仍存在一系列技术难点, 如故障诊断的实时性和多重并发故障的诊断等.

小波分析和小波神经网络的出现, 给故障诊断技术带来了新的方法和途径. 对于多重并

1) 国家自然科学基金(69974021)及航空科学重点基金(98Z51002)和高校博士点基金(2000028704)资助

发故障的情况,由于不同类型的故障具有各自的频域和时域特征,而小波变换中的小波函数相当于一带通滤波器,使得不同尺度、不同频率的信号能通过不同的频带通道分离出去,因而可将多个故障信号有效地识别出来^[1]. 本文着重探讨运用小波神经网络技术进行组合故障的模式识别. 首先对信号进行离散二进小波变换,求取其在多尺度下的细节系数作为故障特征向量,然后利用具有鲁棒学习算法的神经网络分类器对故障进行准确的模式分类.

2 小波神经网络的结构及学习算法

小波神经网络(Wavelet Neural Networks)是在小波分析的基础上提出的一种多层前馈型网络,可使网络训练从根本上避免局部最优且加快了收敛速度,具有很强的学习和泛化能力^[2].

小波神经网络与前馈网络的区别在于激活函数不是 Sigmoid 非线性函数,而是小波基函数. 对一个多输入多输出映射 $f:R^m \rightarrow R^q$,其网络方程的实现可表示为

$$\hat{y}_i(t) = \hat{f}_i(t) = \phi \left[\sum_{j=1}^p w_{ij} \left(\sum_{k=1}^m x_k(t) \psi \left(\frac{k-b_j}{a_j} \right) \right) \right], \quad i = 1, 2, \dots, q \quad (1)$$

式中 $x_k(t)$ ($k=1, 2, \dots, m$) 为第 k 个输入变量; $\hat{y}_i(t)$ ($i=1, 2, \dots, q$) 为第 i 个输出变量; p 为隐层的单元数; 由输入层第 k 个单元到隐层第 j 个单元的权函数为小波函数 $[\psi(k-b_j)/a_j]$, 其中 a_j, b_j 分别为小波函数的尺度和位移; w_{ij} 为隐层第 i 个单元到输出层第 j 个单元的连接权; $\phi(\cdot)$ 为非线性 Sigmoid 函数,整个网络待训练的参数有 w_{ij}, a_j, b_j . 设选择的训练样本为 $[x_k^l(t), y_i^l(t)]$, $l=1, 2, \dots, N$, 其中 N 为样本总数,则可以通过反复学习来获取以上参数. 为导出小波神经网络的学习算法,采用如下优化目标函数

$$J = \frac{1}{2} \sum_{l=1}^N \sum_{i=1}^q [y_i^l(t) - \hat{y}_i^l(t)]^2 \quad (2)$$

采用梯度最速下降法,通过极小化式(2)来调整网络参数,其相应的迭代公式为

$$w_{ij}(n+1) = w_{ij}(n) - \eta_w \frac{\partial J}{\partial w_{ij}} + \alpha_w \Delta w_{ij}(n) \quad (3a)$$

$$a_j(n+1) = a_j(n) - \eta_a \frac{\partial J}{\partial a_j} + \alpha_a \Delta a_j(n) \quad (3b)$$

$$b_j(n+1) = b_j(n) - \eta_b \frac{\partial J}{\partial b_j} + \alpha_b \Delta b_j(n) \quad (3c)$$

其中 η_w, η_a, η_b 分别为参数 w, a, b 的学习速率, $\alpha_w, \alpha_a, \alpha_b$ 分别为相应的动量因子. 式(3)中相应的梯度项分别为

$$\frac{\partial J}{\partial w_{ij}} = \sum_{l=1}^N \sum_{i=1}^q \sum_{k=1}^m [y_i^l(t) - \hat{y}_i^l(t)] \phi' \left[\sum_{j=1}^p w_{ij} \left(\sum_{k=1}^m x_k^l(t) \psi \left(\frac{k-b_j}{a_j} \right) \right) \right] x_k^l(t) \psi \left(\frac{k-b_j}{a_j} \right) \quad (4a)$$

$$\frac{\partial J}{\partial a_j} = \sum_{l=1}^N \sum_{i=1}^q \sum_{k=1}^m [y_i^l(t) - \hat{y}_i^l(t)] \phi' \left[\sum_{j=1}^p w_{ij} \left(\sum_{k=1}^m x_k^l(t) \psi \left(\frac{k-b_j}{a_j} \right) \right) \right] \times w_{ij} x_k^l(t) \psi' \left(\frac{k-b_j}{a_j} \right) (k-b_j) \frac{1}{a_j^2} \quad (4b)$$

$$\frac{\partial J}{\partial b_j} = \sum_{l=1}^N \sum_{i=1}^q \sum_{k=1}^m [y_i^l(t) - \hat{y}_i^l(t)] \phi' \left[\sum_{j=1}^p w_{ij} \left(\sum_{k=1}^m x_k^l(t) \psi \left(\frac{k-b_j}{a_j} \right) \right) \right] \times w_{ij} x_k^l(t) \psi' \left(\frac{k-b_j}{a_j} \right) (k-b_j) \frac{1}{a_j} \quad (4c)$$

3 故障特征提取

小波神经网络的结构实质上由两部分组成,网络的第一部分选取小波基函数作为激活函数,完成对输入信号的变换以提取相应的模式特征;第二部分为一般的多层前馈神经网络,完成模式分类的功能.运用小波神经网络进行多故障的模式识别,其关键在于故障特征的选择,鉴于小波变换具有良好的时频局部化性质,可将原始信号分解到各个不同的频道内来刻画信号特性,这里将通过对信号进行小波变换,求取其在不同尺度下的小波细节系数作为故障的特征,为了快速而有效地对信号进行时频分析, Mallat 在 Burt 和 Adelson 图像分解和重构的金字塔算法启发下,提出了基于多分辨分析思想的离散二进小波变换,其快速算法为^[3]

$$A_{2^{j+1}}^d f = \sum_{k=-\infty}^{+\infty} h(k-2n) A_{2^j}^d f, \quad D_{2^{j+1}} f = \sum_{k=-\infty}^{+\infty} g(k-2n) A_{2^j}^d f \quad (5)$$

其中 $g(n) = (1-n)^{1-n} h(1-n)$, $h(n)$, $g(n)$ 是共轭镜像滤波器组.

由式(5)可得信号 $f(t)$ 的小波表示 $\{A_m^d f, (D_j f)_{1 \leq j \leq m}\}$, m 为整数. 其中 $D_j f$ 为尺度 2^j 下的细节系数.

当系统发生多重故障时,其相应的状态残差将发生变化,这种变化必然反应在残差信号在各个尺度下的局部化特性中,而小波变换的细节系数恰能将不同频带范围内的特征进行信息分离,并提供各个层次的丰富信息.

4 鲁棒故障模式分类

为了保证在有噪声和扰动的前提下仍能对系统故障进行准确的分类和隔离,可引入一个新的优化性能指标,即在神经网络输入端加入噪声来进行训练,以提高神经网络故障分类器对噪声和扰动的鲁棒性.

定理 1. 对于给定的神经网络输入残差样本 $\mathbf{r} = [r_1, \dots, r_p]^T$ 以及输出故障模式样本 $\mathbf{e} = [e_1, \dots, e_q]^T$, 若网络权值的调整规则为 $\Delta w_{ij} = -\eta \partial \bar{J}(W) / \partial w_{ij}$, 且 $\bar{J}(W)$ 定义为

$$\bar{J}(W) = E \left\{ \sum_k |e^{(k)} - f(\mathbf{r}^{(k)} + \boldsymbol{\xi})|^2 \right\} \quad (6)$$

其中 $\boldsymbol{\xi}$ 为分布已知且独立于 $\mathbf{r}^{(k)}$ 的随机噪声向量, 则该算法可保证神经网络故障模式分类的鲁棒性.

证明. 略.

对定理 1 中的性能指标(6)进行极小化, 等价于在残差样本输入端加入噪声后, 仍采用式(4)的梯度算法进行训练, 可保证网络输出对残差信号中的噪声扰动具有鲁棒性, 从而保证了该神经网络故障模式分类的鲁棒性.

5 歼击机组合故障识别的仿真研究

设某歼击机同时发生平尾卡死故障和副翼损伤故障: 飞机在 2 秒时左平尾卡死在 -2

度且右副翼损伤 50%，选取最能反映故障特征的滚转角速度和俯仰角速度的残差信号作为特征量。

对滚转角速度和俯仰角速度的残差信号在 4 个尺度 $2^0, 2^1, 2^2, 2^3$ 上进行分解, 并对各个频带上的信号提取其细节系数, 其结果如图 1 和图 2 所示, 由图可见, 滚转角速度残差的小波细节系数表征了副翼损伤故障, 而俯仰角速度残差的小波细节系数表征了平尾卡死故障, 因此可以作为故障的特征送入神经网络分类器以进行故障的分类. 考虑 B 样条小波具有自适应数据变化的能力, 故选择小波基函数为四阶 B 样条小波. 选定小波神经网络的结构为 4—8—4, 输入对应两个信号在 4 个尺度上的系数, 输出则为相应的故障模式, 其中 e_1 代表平尾卡死, e_2 代表平尾损伤, e_3 代表副翼卡死, e_4 代表副翼损伤。




图 1 俯仰角速度残差在多尺度下的细节系数




图 2 滚转角速度残差在多尺度下的细节系数

在理想情况下, 当发生第 i 种故障时, 第 i 个模式输出 $e_i=1$; 否则为 0. 考虑到噪声和参数摄动的影响, 选取门限为 0.5 进行分类, 即当 $e_i < 0.5$, 则无第 i 种故障发生; 当 $e_i > 0.5$, 则发生第 i 种故障. 根据相应的样本数据, 采用定理 1 的鲁棒学习算法对小波神经网络进行训练, 训练完成后再采用仿真数据进行测试, 则可得网络的模式输出为 $e = [e_1, e_2, e_3, e_4] = [1.0, 0.02, 0.01, 0.95]$, 由此判定飞机同时发生了平尾卡死和副翼损伤故障, 从而实现了对多重组合故障的模式识别。

参 考 文 献

- 1 Kumar A, Fuhrmann D R *et al.* A new transform for time-frequency analysis. *IEEE Trans. Signal Processing*, 1992, **40**(7):1697~1707
- 2 Delyon B, Juditsky A, Benveniste A. Accuracy analysis for wavelet networks. *IEEE Trans. Neural Networks*, 1995, **6**:332~348
- 3 Mallat S, Hwang W L. Singularity detection and processing with wavelet. *IEEE Trans. Information Theory*, 1992, **38**(2):617~643

胡寿松 现为南京航空航天大学教授、博士生导师、中国自动化学会理事. 近期主要研究方向为神经网络故障模式识别及非线性系统的自修复控制。

周 川 工学博士, 现为南京理工大学博士后. 研究方向为智能故障检测与自修复控制。