

基于小波神经网络的滚动轴承故障诊断

吴松林, 张福明, 林晓东

(空军工程大学 工程学院, 陕西 西安 710038)

摘要:研究了基于BP神经网络、基于径向基神经网络等的故障诊断方法和原理,并利用小波包分解获得了滚动轴承振动信号的特征向量,进行了详细的故障诊断实验研究,通过实验,比较了基于松散型小波神经网络与紧致型小波神经网络的诊断结果。仿真结果表明,紧致型小波神经网络用于滚动轴承的故障诊断更为有效。

关键词:故障诊断;神经网络;小波分析

中图分类号: TN929.5 **文献标识码:**A **文章编号:**1009-3516(2008)01-0050-04

小波神经网络(Wavelet Neural Network, WNN)是利用小波基函数代替通常的 Sigmoid 函数作为网络的神经元函数,生成一个与径向基(RBF)网络在结构上相似的前向型神经网络。由于引入了伸缩因子和平移因子,所以小波神经网络具有比小波分解更多的自由度,更有效的函数逼近能力和更强的容错能力^[1-5]。

Zhang^[6]在1992年利用小波伸缩和平移得到的小波函数作为神经元函数,构造出了第一个被称为小波网络的前馈神经网络,并给出了用于网络训练的随机梯度算法。自从小波神经网络被提出后,在故障诊断领域有了许多成功的应用。如 Wang^[7]等将小波神经网络用于机器故障信号的预测,Chen 等应用小波神经网络进行瞬时故障信号的检测与诊断^[8]。江磊等将小波网络用于旋转机械的故障诊断^[9],郑海波等将小波网络用于齿轮的故障诊断^[10]等等。本文研究了小波神经网络在滚动轴承故障诊断中的应用。

1 实验原理与方法

滚动轴承实验装置采用加速度传感器监测轴承在载荷下运行时的径向和轴向振动信号。利用小波包分解获得振动信号的特征向量,实验分别研究了基于BP神经网络、基于径向基神经网络及基于紧致型小波神经网络的故障诊断,并进行了比较分析。

1.1 基于小波包分解的振动信号特征向量的提取

一般,功率谱能量集中在状态变化敏感的区域,故障引起功率谱的调制现象并在状态变化的敏感区域的边频带上产生能量的重新分布。小波变换是对被分解信号在满足特定条件下的滤波过程,因此恰当选择小波滤波器的参数,可以更为有效地获取状态变化敏感的区域信息。具体算法如下:

1) 将故障信号消噪处理后进行3层小波包分解,小波包分解采用函数 $t = \text{wpdec}(s_1, 3, 'db_1', 'shannon')$, 其中 s_1 为被分解信号,3为被分解层次, db_1 为分解所采用的小波类型, $shannon$ 为分解所选取的熵值。分别提取第3层从低频到高频8个频率成分的信号特征,分解结构如图1所示。

图1中, (i, j) 表示第 i 层的第 j 个结点,其中, $i=0, 1, 2, 3, j=0, 1, 2, \dots, 7$, 每个结点都代表一定的信号特征。其中, $(0, 0)$ 结点代表原始信号 S , $(1, 0)$ 代表小波包分解的第1层低频系数 X_{10} , $(1, 1)$ 小波包分解第1层的高频系数 X_{11} , 其他依次类推。

2) 对小波包分解系数重构,提取各频带范围的信号。重构系数可采用函数 $s = \text{wprcoef}(t, N)$ 得到, t 为被

收稿日期:2007-05-28

基金项目:捷克科学基金资助项目(101/04/1503)

作者简介:吴松林(1960-),男,江苏涟水人,副教授,主要从事设备管理、故障诊断、信息处理等研究。E-mail: slw60215@sina.com

重构的信号, N 为所重构的结点以 S_{30} 为 X_{30} 的重构信号, S_{31} 表示 X_{31} 的重构信号, 其他依此类推。本文只对第 3 层的所有结点进行分析, 则总信号可以表示为 $S = S_{30} + S_{31} + S_{32} + S_{33} + S_{34} + S_{35} + S_{36} + S_{37}$ 。

3) 求各频带信号总能量。设 S_{3j} ($j = 0, 1, \dots, 7$) 对应的能量为

E_{3j} ($j = 0, 1, \dots, 7$), 则 $E_{3j} = \int |S_{3j}(t)|^2 dt = \sum_{k=1}^n |x_{jk}|^2$, 式中: x_{jk} ($j = 0, 1, \dots, 7, k = 1, 2, \dots, n$) 为重构信号 S_{3j} 的离散点的幅值。

4) 构造特征向量。由于系统出现故障时, 会对各频带内信号的能量有较大的影响, 因此, 可以以能量为元素构造一个特征向量。特征向量 $T = [E_{30} + E_{31} + E_{32} + E_{33} + E_{34} + E_{35} + E_{36} + E_{37}]$ 。

当能量较大时, E_{3j} ($j = 0, 1, \dots, 7$) 通常是一个较大的数量, 在数据分析上会带来一些不方便的地方。因此, 可以对特征向量 T 进行归一化处理, 令 $E = (\sum_{j=0}^7 |E_{3j}|^2)^{1/2}$, 归一化后的向量 $T' = [E_{30}/E, E_{31}/E, E_{32}/E, E_{33}/E, E_{34}/E, E_{35}/E, E_{36}/E, E_{37}/E]$ 。

5) 仿真结果。按照所给出的算法, 分别对正常和故障状态时获取的信号进行小波包分析, 构造出各自的特征向量, 建立“特征向量 - 系统状态”的对应关系。以一组正常系统和故障系统的情况为例, 其小波包变换后, 得到表 1 中的 5 组测试数据。依据特征向量进行分类决策, 就可确定是否有故障。

表 1 无故障状态与故障状态结果表 (E_{3i} 表示无故障状态, (E_{3i}) 表示故障状态)

Tab. 1 The result of normal and fault state (E_{3i} – The normal state, (E_{3i}) – The fault state)

	E_{30}	(E_{30})	E_{31}	(E_{31})	E_{32}	(E_{32})	E_{33}	(E_{33})	E_{34}	(E_{34})	E_{35}	(E_{35})	E_{36}	(E_{36})	E_{37}	(E_{37})
1	4.41	17.46	1.44	12.96	1.05	23.67	1.30	15.13	2.30	5.62	2.87	12.08	1.47	18.77	2.69	15.74
2	4.60	17.83	1.83	15.37	0.96	22.24	1.12	15.84	2.97	5.47	2.75	10.31	1.39	18.96	2.22	16.50
3	4.01	16.10	1.60	15.01	1.34	24.14	1.32	14.37	3.14	6.04	3.71	11.57	1.30	24.97	1.93	14.35
4	4.45	13.23	1.29	15.37	1.25	24.02	1.30	16.22	2.98	5.10	3.16	10.65	1.80	22.11	1.77	11.74
5	4.49	10.98	1.63	17.09	1.23	22.80	1.45	12.81	2.58	6.10	2.78	9.61	1.35	21.84	2.02	14.25

1.2 基于松散型小波神经网络的滚动轴承故障诊断

松散型结合: 即小波分析作为神经网络的前置处理手段。用小波分析对信号进行预处理, 即以小波空间作为模式识别的特征空间, 通过将小波基与信号的内积进行加权和来实现信号的特征提取, 然后将提取的特征向量送入神经网络处理。

在对滚动轴承进行故障诊断时, 只分别对正常和故障两种状态进行诊断。在采集的数据中取了 20 组数据, 每组数据的小波分解分别提取的 8 个特征向量作为神经网络的输入向量。14 组数据用来训练网络, 6 组数据用来验证网络。

1) 基于 BP 神经网络的滚动轴承故障诊断。本文采用 3 层网络结构, 输入的特征向量维数为 8, 滚动轴承的状态为 2, 则 BP 网络输入层节点的个数为 8, 输出层节点数是 2 个。隐含层节点数后面根据训练误差的大小确定, 如图 2 所示。

接下来确定网络的输出模式, 采用如下的形式来表示输出: 正常: (0, 1), 故障: (1, 0)。

通过误差对比, 确定最佳的隐含层神经元个数, 并检验隐含层神经元个数对网络性能的影响。结果如表 2 所示。

表 2 网络训练误差

Tab. 2 The training error of the network

神经元个数	3	4	5	6	7	8	9
网络误差	0.016 871	0.029 566	0.019 371	0.021 819	0.021 208	0.017 416	0.018 1
神经元个数	10	11	12	13	14	15	16
网络误差	0.011 186	0.026 192	0.036 437	0.023 865	0.018 881	0.02 011	0.023 141

结果表明, 网络经训练后, 此样本条件下, 隐含层神经元个数为 10 的 BP 网络得到的误差最小。另外,

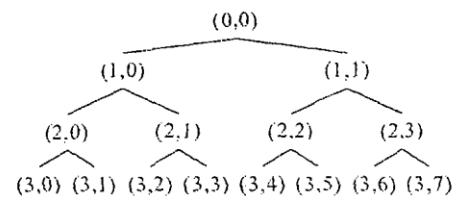


图 1 小波包 3 层分解树结构
Fig. 1 The three-layer structure of wavelet packet decomposition

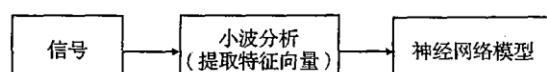


图 2 基于 BP 网络的滚动轴承故障诊断模型

Fig. 2 The model of fault diagnosis based on BP neural network

并非隐含层神经元的个数越多,网络的性能就越好。

网络训练过程是一个不断修正权值和阈值的过程,通过调整,使网络的输出误差达到最小,满足实际应用的要求。经过训练后,网络的性能就达到了要求,误差目标设为 0.000 1。

2) 基于径向基网络的滚动轴承故障诊断。径向基(RBF)网络主要包括隐含层和输出层,其中隐含层的传递函数为 radbas,输出层的传递函数为纯线性函数 purelin,如图 3 所示。

MATLAB 神经网络工具箱中用于创建 RBF 网络的函数为 newrbe,在利用函数创建网络的过程中,可以自动增加隐含层的神经元个数,直到均方误差满足要求为止。在轴承故障诊断中,将小波包分解得到的特征向量作为输入层,输入层节点数为 8,输出层节点数为 2,参考 BP 神经网络训练的结果,选择隐含层节点数为 10,即采用 8-10-2 三层网络结构。误差目标设为 0.000 1。

3) BP 网络和 RBF 网络在滚动轴承故障诊断中的比较两种算法在相同结构下,通过训练对比可知,RBF 在学习速度上优于 BP,且 RBF 的分类能力也优于 BP 网络。

1.3 基于紧致型小波神经网络的滚动轴承故障诊断

紧致型小波神经网络基本思想即用小波函数来代替常规神经网络的隐层函数,同时相应的输入层到隐含层的权值及隐含层阈值分别由小波基函数的尺度函数和平移函数来代替,如图 4 所示。

1) 小波函数的选择。本文分别采用 Morlet 小波和 Mexican hat 小波作为小波神经网络隐含层节点的传递函数,输出层传递函数采用对数 S 型函数。

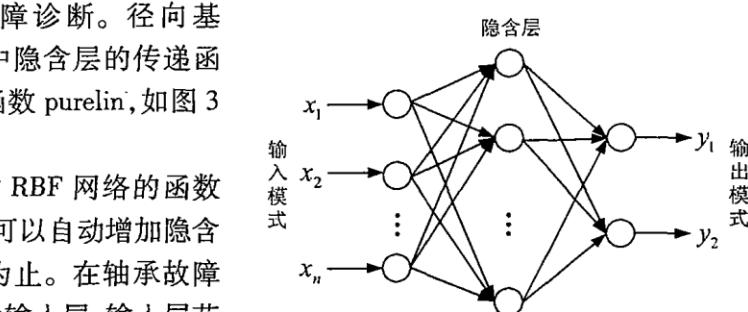


图 3 径向基网络结构

Fig. 3 The structure of RBF neural network

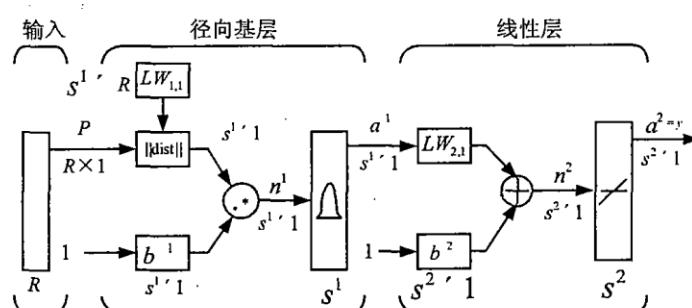


图 4 紧致型小波神经网络结构

Fig. 4 The structure of the close - type wavelet neural network

2) 隐含层节点数的确定。网络输入与输出层节点数的确定与 BP 网络一样,为了与前述网络比较,隐含层节点的个数也采用 10 个。即网络结构为 8-10-2。

3) 网络训练及校验。根据小波神经网络的学习算法,对轴承进行故障诊断,误差目标设为 0.000 1。

表 3 为采用不同算法、不同小波得到的实际输出与目标输出之间的对比。

表 3 采用不同算法、不同小波的目标输出与实际输出对比

Tab. 3 The actual output got from different algorithms and different wavelet compared with the target output

状态	目标 输出	BP 网络实际输出				紧致型 WNN 网络实际输出			
		Morlet 小波		Mexican 小波		Morlet 小波		Mexican 小波	
正常	0	0.343 0	0.932 6	0.343 0	0.932 6	0.000 1	0.973 8	0.009 5	1.034 6
	0	0.003 6	0.967 7	0.003 6	0.967 7	0.004 7	1.034 0	0.017 1	0.997 2
故障	1	0.999 4	0.001 2	0.999 4	0.001 2	0.970 4	0.002 5	0.962 8	0.010 3
	1	0.512 5	0.403 5	0.512 5	0.403 5	0.965 4	0.002 9	0.991 3	0.016 9

2 结论

本文研究了小波神经网络在滚动轴承故障诊断中的应用。对测得的滚动轴承的原始振动信号进行了基于小波包分解的特征向量提取,分别研究了不同类型的小波神经网络的滚动轴承故障诊断,仿真结果验证了该方法的有效性。结果表明,在隐含层节点传递函数分别采用 Morlet 小波和 Mexican hat 小波,输出层传递函数采用 S 型函数的小波神经网络中,两种小波神经网络的效果差不多,但都比 BP 网络的精度高。因此,紧致型小波神经网络用于滚动轴承的故障诊断更为有效。

参考文献:

- [1] Kugarajah T, Zhang Q H. Multidimensional Wavelet Frames [J]. IEEE Transactions on NN, 1995, 6(6) : 1552 - 1556.
- [2] Roemer M J, Kacprzynski G J. Advanced Diagnostics and Prognostics for Gas Turbine Engine Risk Assessment: IGTE/ASME Turbo Expo[C]. Munich, Germany : [s. n.], 2000.
- [3] Wesley G, Zanardelli, Elias G. Strangas and Selin Aviyente. Failure Prognosis for Permanent Magnet AC Drives Based on Wavelet Analysis[J]. International Electric Machines and Drives Conference, 2005, (5) : 64 - 70.
- [4] Greitzer F L, Ferryman T A. Predicting Remaining Life of Mechanical Systems[J]. Intelligent Ship Symposium, 2001, (4) : 2 - 3.
- [5] Tom Brotherton, Paul Grabill. A Testbed for Data Fusion for Helicopter Diagnostics and Prognostics: Proceedings of the 2003 IEEE Aerospace Conference[C]. [S. l.] : Big Sky MT IEEE, 2003.
- [6] Zhang Q H, Beveniste A. A Wavelet Networks[J]. IEEE Transactions on Neural Networks, 1992, 3(6) : 889 - 892.
- [7] Wang P, Vachtsevanos G. Fault Prognostics Using Dynamic Wavelet Neural Networks [J]. Artificial Intelligence for Engineering Design Analysis and Manufacturing, 2001, 15 : 349 - 365.
- [8] Chen W R, Qian Q Q, Wan X R. Wavelet Neural Network Based Transient Fault Signal Detection and Identification: Proceedings of IsInt Conf On Information, Communications & Signal Processing (ICICS 97) [C]. Singapore : [s. n.], 1997 : 1377 - 1381.
- [9] 江 磊,江 凡. 基于小波神经网络的旋转机械故障诊断[J]. 汽轮机技术, 2004, 46(3) : 204 - 206.
JIANG Lei, JIANG Fan. Fault diagnosis of Rotation Machine Based on Wavelet Neural Network [J]. Turbing Technology, 2004, 46 (3) : 204 - 206. (in Chinese)
- [10] 郑海波,陈心昭,李志远,等. 小波神经网络故障诊断系统的设计与应用[J]. 农业机械学报, 2002, 33(1) : 73 - 77.
ZHENG Haibo, CHEN Xinzhaoy, LI Zhiyuan, et al. Implementation and Application of a Neural Network Fault Diagnosis System Based on Wavelet Transform [J]. Transactions of the Chinese Society of Agricultural Machinery. 2002, 33 (1) : 73 - 77. (in Chinese)

(编辑:田新华,徐楠楠)

Wavelet Neural Network Based Diagnosis of the Rolling Bearing

WU Song - lin, ZHANG Fu - ming, LIN Xiao - dong

(The Engineering Institute, Air Force Engineering University, Xi'an 710038, China)

Abstract: In this paper, the feature vectors of the roller bearing signals are extracted on the basis of wavelet analysis and a fault diagnosis experiment is carried through wavelet neural network in detail. The method and the theory of fault diagnosis based on BP neural network and the radial basis function neural network are studied and the results of diagnosis based on relax - type neural - networks and close - type neural - networks are compared. Simulation results indicate that diagnosis based on close - type networks more effective.

Key words: fault diagnosis; neural network; wavelet analysis