

doi: 10.7690/bgzdh.2015.10.020

基于概率神经网络的风洞设备故障预测诊断方法

张 鹏，杨兴锐，陈 龙

(中国空气动力研究与发展中心高速所，四川 绵阳 621000)

摘要：针对风洞设备故障征兆与故障原因之间的非线性关系，提出基于概率神经网络的风洞设备故障预测诊断方法。利用概率神经网络强大的自主学习能力和较强的模式识别能力，来预测诊断风洞设备的故障原因，通过故障样本对概率神经网络进行训练，并对待测样本进行故障预测诊断。结果表明：概率神经网络能满足故障诊断快速和准确的要求，故障预测诊断精度较高，适用于在线检测，具有实际应用价值。

关键词：PNN；风洞设备；故障预测诊断**中图分类号：**TJ06 **文献标志码：**A

Fault Forecast and Diagnosis of Wind Tunnel Equipment Based on Probabilistic Neural Network

Zhang Peng, Yang Xingrui, Chen Long

(High Speed Institute, China Aerodynamics Research & Development Center, Mianyang 621000, China)

Abstract: According to the nonlinear mapping relationship between fault symptom and wind tunnel equipment faults, fault forecast and diagnosis method was presented which is based on probabilistic neural network (PNN). By using the powerful self-learning ability and strong pattern recognition capability, the cause of the fault for the wind tunnel equipment is predicted. The sample of the fault is established and the PNN is trained based on the symptom diagnosis. The test sample is used to fault forecast and diagnosis. The result shows that PNN can meet the requirement for fast diagnosis rate and high diagnosis precision during fault diagnosis process, so PNN can be used in the real time diagnosis with application value.

Keywords: PNN; wind tunnel equipment; fault forecast and diagnosis

0 引言

风洞试验通过模拟飞行器在特定条件下的飞行状态，获取该状态下飞行器的性能参数，为飞行器的空气动力设计提供所需的重要原始参数。风洞试验时，风洞相关设备处于正常的工作状态是保证风洞试验安全、高质、有效进行的首要前提，同时也是确保试验数据真实、可靠、精确的重要基础。随着我国飞行器研制任务的不断深入，风洞试验任务日益加重，设备的使用频率逐渐增大，设备的连续运行时间也在递增，故障的出现已成为不可避免的问题，为此必然会给风洞试验的顺利开展带来一系列的困难。为有效确保设备可靠、高效地运行，充分发挥设备自身的运行效益、提高设备的使用寿命，同时也是为了更好地保障飞行器研制任务的顺利开展，有必要引入设备的故障预测诊断技术。

常规的故障诊断方法主要是通过人工经验对设备运行状态进行逐项分析判断来完成。该方法工作量大，且容易受人员分析能力、工作经验的限制，致使一些设备故障难以被及时发现，从而导致设备

带故障运行，容易引起试验数据报废，情况严重的话甚至可能会导致风洞试验失控，给国家财产和人身安全带来伤害。故障预测诊断技术就是利用测试、监控和计算机分析等方法搜集设备的异常现象和信息，根据现象或信息对设备的状态进行分析，从而判断设备故障的性质、原因和部位，并预测故障趋势的方法^[1-2]。由于风洞设备的各种故障征兆与故障类型之间是高度非线性关系，很难用具有线性关系的常规数学模型来进行故障诊断定位。而神经网络对于高维空间模式识别和非线性模式识别问题的分类精度较高，同时自身也具有非常强的自组织和自我学习能力；因此，可以通过已有的设备正常运行数据和故障样本数据对神经网络进行训练，从而达到使神经网络自身具备识别故障信息并分辨设备故障原因及类型的目的。

作为神经网络之一的概率神经网络 (probabilistic neural network, PNN)，其主要特点包括：1) 训练速度快，其对应的权值就是模式样本的分布，训练时间仅仅略大于读取数据的时间，因此

收稿日期：2015-05-15；修回日期：2015-06-30

作者简介：张 鹏(1985—)，男，四川人，硕士，工程师，从事风洞信号采集与处理研究。

能够满足训练上实时处理的要求; 2) 无论分类问题多么复杂, 只要有足够的训练数据, PNN 能够保证获得贝叶斯准则下的最优解, 确保其具有较高的分类准确率; 3) 允许增加或减少训练数据而不需要重新进行长时间的训练^[3-4]。因此, 笔者将应用 PNN 神经网络来对风洞设备进行故障预测诊断, 实现风洞设备故障预测诊断技术的智能化及自动化。

1 PNN 神经网络

PNN 网络实际上是一种常被用于模式分类的前馈型神经网络, 它由 RBF 网络发展而来, 其理论依据是贝叶斯最小风险准则。

1.1 贝叶斯决策理论

$\{w_i\} (i=1,2,\cdots,c)$ 代表有限 c 个类别集合, $P(w_j)$ 代表每个类别的先验概率, x 代表特征向量表示一个 d 维的随机变量。 $P(x|w_j)$ 代表在真实类别为 w_j 条件下 x 的概率密度函数, 每个类的实际后验条件概率为 $P(w_j|x)$, 通过贝叶斯公式^[3]计算得到

$$p(w_j|x) = \frac{p(x|w_j)p(w_j)}{p(x)}. \quad (1)$$

式中 $p(x)$ 为证据因子, 并有 $p(x) = \sum_{j=1}^c p(x|w_j)p(w_j)$,

则式(1)可表示成

$$p(w_j|x) = \frac{p(x|w_j)p(w_j)}{\sum_{j=1}^c p(x|w_j)p(w_j)}. \quad (2)$$

根据时间后验概率发生的大小, 可以对未知模式 x 做如下判决:

对于任意 $j \neq i = 1, 2, \dots, c$, 若 $p(w_i|x) > p(w_j|x)$, 则

$$x \in w_i. \quad (3)$$

这就是贝叶斯判决准则或者是最小误差率分类准则。

1.2 PNN 网络故障预测理论

PNN 网络主要由输入层、模式层、求和层及输出层 4 个部分构成, 如图 1 所示。

PNN 网络的工作原理: 通过神经网络的输入层接收训练样本数据, 然后再把特征向量传递给网络。模式层主要是计算输入特征向量与训练集中各个模式的匹配关系, 模式层神经元的个数等于各个类别训练样本数之和, 该层每个模式单元的输出^[3]为

$$f(X, W_i) = \exp \left[-\frac{(X-W_i)^T(X-W_i)}{2\delta^2} \right]. \quad (4)$$

式中: W_i 为输入层到模式层连接的权值; δ 为平滑因子, 对分类起着至关重要的作用。




图 1 概率神经网络结构

在求和层, 故障模式和神经元是一一对应的关系, 这些神经元将对应模式层的一组神经元输出求和, 从而得到故障模式的估计概率密度函数。输出层神经元是一种竞争神经元, 它接收从求和层输出的各类概率密度函数, 按照贝叶斯分类规则将输入向量分到具有最大后验概率密度的类别当中, 即概率密度函数最大的那个神经元输出为 1, 其他神经元的输出全为 0。当故障样本的数量增加时, 模式层神经元将随之增加; 而当故障模式多于 2 种时, 则求和层神经元将增加。随着故障先验知识的积累, 概率神经网络可以不断横向扩展, 故障诊断的能力将不断提高。

基于 PNN 的故障预测诊断方法能够被简单叙述如下: 假定现在存在已知故障模式 θ_A 和 θ_B , 对于待判定的故障特征样本 $X = (x_1, x_2, \dots, x_n)$:

如果 $h_A l_A f_A(X) > h_B l_B f_B(X)$, 则 $X \in \theta_A$;

如果 $h_B l_B f_B(X) > h_A l_A f_A(X)$, 则 $X \in \theta_B$ 。

其中: h_A, h_B 为故障模式 θ_A, θ_B 的先验概率; l_A 为将本属于 θ_A 的故障特征样本错误划分到模式的代价因子; l_B 为将本属于 θ_B 的故障特征样本错误划分到模式的代价因子; f_A, f_B 为故障模式的概率密度函数。根据 Parzen 方法概率密度函数的估计式为

$$f_A(X) = \frac{1}{2\pi^{P/2}} \frac{1}{m} \sum \exp \left[-\frac{(X-X_{ai})^T(X-X_{ai})}{2\delta^2} \right]. \quad (5)$$

式中: X_{ai} 是为故障模式 θ_A 的第 i 个训练向量; m 为故障模式 θ_A 的训练样本数目; δ 为平滑参数。

2 PNN 神经网络故障预测分析

PNN 网络预测大致流程如图 2 所示。PSI8400 扫描阀模块为风洞测压试验的关键设备，是获取模型表面压力分布参数的重要测试设备，该设备在运行时其自身具有 3 个带有重要表征意义的系数值。为验证概率神经网络对设备故障种类及原因的预测和分析，以 PSI8400 扫描阀模块作为故障预测分析对象，将其带有表征意义的系数值作为故障征兆参数，利用 PNN 网络对其故障现象及原因进行预测诊断。将 PSI8400 扫描阀模块的 C_0 、 C_1 、 C_2 这 3 个历史系数作为故障征兆参数，每个参数各有 30 组信号值，将收集的 30 组故障样本数据分成 2 部分，即将其中前 20 组故障数据作为 PNN 神经网络的训练样本，余下的 10 组故障数据作为待识别的故障样本（测试样本）。利用该设备常见的故障模式样本对 PNN 网络进行训练，由于故障征兆有 3 个，在 PNN 网络中输入层的节点数等于样本矢量的维数，所以 PNN 网络的输入层节点数为 3；故障训练样本有 20 种，模式层神经元个数等于各个类别训练样本之和，所以模式层的神经元节点数为 20；故障形式有 4 种，所以求和层与输出层的神经元节点数为 4。




图 2 PNN 网络预测流程

将前期收集的 30 组故障数据作为训练样本数据，并将故障样本集合和训练算法相结合，即可以开始进行神经网络的学习训练。笔者采用表 1 中的 PSI8400 扫描阀模块常见故障模式样本进行训练，在训练前根据不同的历史故障数据和经验可以将设备故障类型分为 4 类，如图 3 所示。通过 Matlab 中的 newpnn() 和 sim() 函数分别建立 PNN 网络模型和进行 PNN 测试仿真训练^[5]。训练后训练数据网络的学习结果见表 2，故障分类效果如图 3 所示。从图中可以看出：在训练后，将训练数据作为输入带入已经训练好的 PNN 网络中并无诊断错误的情况出现，证明该网络模型构造是可靠、可行的。

表 1 仪器常见故障模式样本

样本编号	状态	C_0	C_1	C_2
1	电缆信号错误	-0.051 00	0.710 82	0.135 73
2	电缆信号错误	-0.072 09	0.732 84	0.120 53
3	电缆信号错误	-0.128 83	0.403 31	0.124 10
4	电缆信号错误	-0.105 49	0.669 58	0.119 20
5	电缆信号错误	-0.033 08	0.414 77	0.123 44
6	阀体未到位	-33.036 84	45.420 52	0.130 68
7	阀体未到位	-30.032 57	33.297 65	0.144 33
8	阀体未到位	-29.021 17	30.923 34	0.137 96
9	阀体未到位	-28.136 38	37.601 84	0.119 30
10	阀体未到位	-23.113 52	47.619 75	0.115 76
11	气路堵塞	-20.055 50	17.057 42	0.123 97
12	气路堵塞	23.035 78	17.998 48	0.120 32
13	气路堵塞	22.105 63	19.322 94	0.138 32
14	气路堵塞	23.018 76	17.788 39	0.121 14
15	气路堵塞	30.226 80	17.579 23	0.122 53
16	气路连接错误	0.143 72	19.823 95	30.132 88
17	气路连接错误	-0.076 02	18.119 59	20.114 78
18	气路连接错误	0.285 87	17.204 63	20.124 88
19	气路连接错误	0.323 50	18.185 15	45.131 00
20	气路连接错误	-0.008 72	17.653 07	34.118 59
21	电缆信号错误	-0.153 96	0.523 09	0.117 28
22	气路连接错误	-0.027 46	17.572 43	23.118 27
23	阀体未到位	-24.089 16	37.461 59	0.114 69
24	气路堵塞	-20.112 90	17.242 79	0.116 43
25	气路堵塞	23.006 79	17.188 47	0.121 66
26	阀体未到位	-24.042 94	37.909 90	0.126 27
27	阀体未到位	-24.055 50	37.339 49	0.121 00
28	电缆信号错误	-0.045 28	0.652 11	0.118 57
29	电缆信号错误	-0.107 15	0.536 27	0.115 71
30	气路连接错误	0.032 74	17.412 71	20.121 25

表 2 PNN 网络学习结果

故障类型	PNN 诊断值
电缆信号错误	1
阀体未到位	2
气路堵塞	3
气路连接错误	4




图 3 训练后训练数据网络的故障分类效果

为验证该 PNN 网络对 PSI8400 扫描阀模块故障的预测诊断能力，将表 1 中的后 10 组测试样本的数据作为待测数据，对 PNN 故障诊断模型进行测试，网络测试结果如图 4 和表 3 所示，网络可见诊断结果与实际故障相符，可以用于实际诊断^[6]。




图 4 预测诊断数据网络的故障分类效果

表 3 PNN 预测诊断测试结果

样本编号	状态	PNN 诊断值	与实际故障吻合与否
1	电缆信号错误	1	正确
2	气路连接错误	4	正确
3	阀体未到位	2	正确
4	气路堵塞	3	正确
5	气路堵塞	3	正确
6	阀体未到位	2	正确
7	阀体未到位	2	正确
8	电缆信号错误	1	正确
9	电缆信号错误	1	正确
10	气路连接错误	4	正确

3 结束语

笔者针对风洞设备故障征兆与故障原因之间复杂的非线性关系, 利用 PNN 神经网络强大的自主学习能力及其较强的模式识别能力, 通过监测设备的

(上接第 55 页)

参考文献:

- [1] Lakshmi J, Nandy S K. I/O device virtualization in the multi-core era, a QOS perspective[C]. in 2009 Workshops at the Grid and Pervasive Computing Conference, GPC 2009, May 4, 2009-May 8, 2009, Geneva, Switzerland: IEEE Computer Society, 2009: 128–135.
- [2] Chen Y, Byna S, Sun X, et al. Hiding I/O latency with pre-execution prefetching for parallel applications[C]. in Proceedings of the 2008 ACM/IEEE conference on Supercomputing, Austin, Texas: IEEE Press, 2008: 1–10.
- [3] Hildebrand D, Ward L, Honeyman P. Large files, small writes, and PNFS[C]. in 20th Annual International Conference on Supercomputing, ICS 2006, June 28, 2006–July 1, 2006, Cairns, Queensland, Australia: Association for Computing Machinery, 2006: 116–124.
- [4] Hildebrand D, Honeyman P. Exporting storage systems in a scalable manner with PNFS[C]. in Twenty-second IEEE/Thirteenth NASA Goddard Conference on Mass Storage Systems and Technologies, IEEE/NASA MSST2005, April 11, 2005–April 14, 2005, Montere, CA, United states: IEEE Computer Society, 2005: 18–27.
- [5] 童薇. 高效光纤存储通道技术研究[D]. 武汉: 华中科技大学, 2011.
- [6] 李云龙. 网络存储技术的应用研究[J]. 计算机光盘软件与应用, 2013, 4(2): 33–34.
- [7] 冬瓜头. 大话存储: II 存储系统架构与底层原理极限剖析[M]. 北京: 清华大学, 2011: 10–14.

重要参数指标作为设备故障征兆, 预测分析参数的变化趋势, 从而预测诊断风洞设备的故障原因, 提出了基于概率神经网络的风洞设备故障预测诊断方法, 给出了诊断原理和学习算法。测试结果表明: 基于 PNN 的状态诊断方法可以最大程度地利用状态先验知识, 在贝叶斯最小风险准则下对设备的状态进行很好的定性诊断, 能够有效识别出系统各种典型故障, 对于非线性的系统故障识别能力达到预期目标, 适用于实时在线诊断要求, 是一种有效可行的智能状态诊断方法。

参考文献:

- [1] 李铁军, 朱成实, 吕营, 等. 基于概率神经网络的水泵故障诊断研究[J]. 农机化研究, 2008, 3(3): 53–55.
- [2] 黄贡献, 刘刚. 基于概率神经网络的自行火炮发动机状态监控系统[J]. 兵工自动化, 2014, 33(2): 24–26.
- [3] 王小川, 史峰, 郁磊, 等. Matlab 神经网络 43 个案例分析 [M]. 北京: 北京航空航天大学出版社, 2013: 213–228.
- [4] 张鹏, 谢艳, 孙宁. 基于 Matlab 的风洞信号延迟时间计算方法[J]. 兵工自动化, 2014, 33(6): 74–77.
- [5] 张鹏, 金志伟, 孙宁, 等. 风洞连续信号小波分析处理平台的设计与实现[J]. 测控技术, 2014, 33(4): 120–123.
- [6] 何汉林, 孟爱华, 祝甲明, 等. 基于优化的 GRNN 和 BP 神经网络的磁滞曲线拟合对比分析[J]. 机电工程, 2013, 30(1): 116–120.