

doi: 10.7690/bgzd.2015.06.004

概率神经网络在武器装备故障诊断中的应用

郭涛, 于海涛, 肖鲁, 刘敬明

(北京宇航系统工程研究所, 北京 100076)

摘要: 针对当前复杂武器系统在装备部队后出现的故障定位难题, 采用概率神经网络进行装备的故障诊断。给出概率神经网络算法及故障诊断步骤, 建立基于概率神经网络的故障诊断模型, 以某新型武器装备为对象, 将该模型应用于装备故障诊断, 并使用 Matlab 进行仿真验证。仿真结果表明: 概率神经网络能够有效识别出装备的各种典型故障, 降低部队使用过程中故障排查难度, 提高装备的维修保障能力。

关键词: 故障诊断; 概率神经网络; 模式分类; 武器装备

中图分类号: TJ06 **文献标志码:** A

Application of Probabilistic Neural Network in Fault Diagnosis of Weapon Equipment

Guo Tao, Yu Haitao, Xiao Lu, Liu Jingming

(Beijing Institute of Aerospace Systems Engineering, Beijing 100076, China)

Abstract: To solve the problem of fault localization in complicated weapon equipment after delivering to army, the paper proposes to diagnose fault by probabilistic neural network. The training algorithm and fault diagnosis steps are put forward, and the fault diagnosis model based on probabilistic neural network is established. Taking a new type of weapon equipment as the research object, the model is applied to fault diagnosis, and use Matlab for simulation validation. The simulation results show that the probabilistic neural network can distinguish all kinds of classical fault effectively, decrease the difficulty of troubleshooting, and increase the repairing and supporting ability of the equipment.

Keywords: fault diagnosis; probabilistic neural network; pattern classification; weapon equipment

0 引言

近年来, 多种新型武器系统陆续装备部队, 新型装备的性能有了显著提高, 但同时呈现技术密集、结构复杂和系统性强的特点, 要求维修保障人员具有广博的装备知识和维修技能。传统的测试设备和故障诊断方式已难以满足装备的检修要求, 部队在使用过程中面临故障定位的问题。某新型武器装备由于组成及其原理的复杂性, 在使用过程中一旦发现故障, 基层部队通常难以快速完成故障的定位及维修, 直接导致装备无法完成预定作战任务。因此, 能否及时、准确地诊断出故障点将决定着装备的维修保障能力与作战效能。

BP 神经网络具有很强的非线性映射能力、自适应能力和模式识别能力, 在故障诊断中得到了广泛应用, 但同时也存在网络结构难以确定、易陷入局部最优和收敛速度慢等缺点, 在一定程度上影响了诊断效果。相对于 BP 神经网络, 概率神经网络 (probabilistic neural network, PNN) 具有收敛速度快、需调节参数少和使用简单的特点, 为研究复杂武器装备故障诊断提供了一条新的思路^[1]。笔者利用 PNN 实现对某新型复杂武器装备的故障诊断, 并

通过 Matlab 进行仿真, 取得了较好的应用效果。

1 故障诊断概念及其描述

1.1 故障诊断概念

故障诊断概念可以表述为被诊断系统正常和故障的所有状态, 组成的状态集合为 Y , 其所有可测量的征兆构成的集合为 X 。在系统处于某一状态 y 时, 该系统就具有确定的征兆 x , 即存在映射 $g: Y \rightarrow X$ 。反之, 一定的征兆也对应确定的状态, 即存在映射 $f: X \rightarrow Y$ 。

故障诊断就是根据所测量的征兆判断被诊断系统所处的状态, 即找出映射 f 。

1.2 故障诊断数学描述

故障诊断就是找出故障征兆到故障自身的映射^[2], 该问题可以用如下四元式来表述:

$$DP = (X, Y, E, X^+)$$

其中: $X = (x_1, x_2, \dots, x_n)^T$ 是一个非空的被诊断系统的征兆集合; $Y = (y_1, y_2, \dots, y_n)^T$ 为一个非空的被诊断系统的故障集合; $X^+ \subseteq X$ 是 X 的一个子集, 表示目前已经测量到的征兆集合, $E \subseteq X \times Y$ 是定义在

收稿日期: 2015-02-04; 修回日期: 2015-03-15

作者简介: 郭涛(1983—), 男, 陕西人, 硕士研究生, 工程师, 从事装备电气系统集成设计与优化、综合保障研究。

$X \times Y$ 上的关系子集, 表示故障与征兆之间的因果关系。在神经网络故障诊断系统中, E 表现为网络输入层与输出层之间的连接权值和阈值^[3]。

2 概率神经网络

2.1 PNN 结构

PNN 是 D. F. Specht 在 1989 年提出的一种前馈网络, 属于径向基网络的一个分支, 具有结构简单、训练简洁的特点。作为一种基于 Bayes 最小风险准则发展而来的并行算法, PNN 由 Bayes 分类规则构成, 使用 Parzen 窗概率密度函数估计方法来估算条件概率, 以实现模式分类与识别。在实际应用中, 利用 PNN 的非线性分类能力, 将故障征兆集映射到故障模式集中, 形成一个具有较强自适应能力和容错能力的诊断网络系统^[4]。

PNN 结构通常由输入层、模式层、求和层和输出层构成, 网络结构如图 1 所示。




图 1 PNN 结构示意图

图 1 中, 第 1 层是输入层, 该层将输入信号用分布的方式表示, 将特征向量输入网络。这一层的神经元数量与输入样本矢量维数相同; 第 2 层是模式层, 该层计算输入的特征向量与训练所用样本集中各个模式的相互匹配关系, 以其距离送入高斯型激活函数, 进而得到该层的输出。这一层神经元数量与输入样本矢量的数量相同; 第 3 层是求和层, 该层对对应于训练所用样本集中同一类模式层传来的输入进行求和, 进而得出输入样本属于该类的最大可能性。网络中每一类对应一个求和层单元, 并且只与属于自己类的模式层单元相连, 与模式层其他单元不连接。这一层的神经元数量与想要划分的模式数量相同; 第 4 层是输出层, 该层执行判断功能, 输出为 1 或 0, 表示输入模式的类别。这一层

神经元数量与训练所用样本集中数据的种类数量相同, 该层神经元接收求和层输出的概率密度函数, 概率密度函数最大的神经元输出为 1, 表示所对应的一类为待识别的样本模式类别, 其他神经元输出为 0^[5]。PNN 中, 实现 Bayes 决策方法的是模式层和求和层, 输出层只进行简单的阈值辨别, 目的是在不同故障模式估计概率密度中选择一个具有最大后验概率密度的神经元作为系统的输出。

在实际应用中, 模式层神经元数量随着故障样本数量增加而不断增加, 同时求和层神经元数量随着故障模式数量的增加而不断增加。因此, 随着被诊断系统故障先验知识的逐渐积累, 故障诊断网络可以不断扩展, 故障诊断能力也将随之不断提高。

2.2 PNN 算法

PNN 实质是一个分类器, 它根据概率密度函数的无参估计来进行 Bayes 决策, 从而得到分类结果。这是一种统计学中被广泛应用的决策方法, 算法描述如下: 假设有 a 和 b 2 种已知的故障模式, 设待诊断的征兆向量为 X , 按照 Bayes 理论^[6], 有如下诊断规则

$$\begin{cases} \text{若 } H_a L_a f_a(X) > H_b L_b f_b(X), \text{ 则 } X \in a \\ \text{若 } H_a L_a f_a(X) < H_b L_b f_b(X), \text{ 则 } X \in b \end{cases} \quad (1)$$

其中: H_a 、 H_b 表示 X 属于 a 、 b 的先验概率; L_a 、 L_b 表示对 a 、 b 故障诊断错误时的代价因子; f_a 、 f_b 表示 X 属于 a 、 b 的概率密度函数, 通常通过已有的故障样本集求得统计值, 公式如下:

$$f_a(X) = \frac{1}{(2\pi)^{p/2} \sigma^p N_a} \times \sum_{i=1}^{N_a} \left[-\frac{(X - X_{ai})^T (X - X_{ai})}{2\sigma^2} \right] \quad (2)$$

其中: p 表示待分类向量及训练维数; N_a 表示故障模式 a 对应的训练样本数量; X_{ai} 表示故障模式 a 的第 i 个训练样本向量; σ 表示平滑参数。

实际应用中, 通常对训练向量和待诊断向量进行归一化处理, 则有

$$(X - X_{ai})^T (X - X_{ai}) = -2(X^T X_{ai} - 1) \quad (3)$$

考虑到式 (1) 中

$$H_a = N_a / N \quad (4)$$

其中 N 表示训练样本总数。

将式 (2)~式 (4) 代入式 (1), 可以得到对故障模式 a 的诊断规则:

$$L_a \sum_{i=1}^{N_a} \exp\left(\frac{X^T X_{ai} - 1}{\sigma^2}\right) \geq L_b \sum_{i=1}^{N_b} \exp\left(\frac{X^T X_{bi} - 1}{\sigma^2}\right) \quad (5)$$

如满足式 (5) 的要求, 则 $X \in a$ 。同理可得到对

故障模式 b 的诊断规则，此处不再赘述。

PNN 网络相比 BP 网络，主要具有如下优点^[7]：

1) 收敛速度快，PNN 网络的训练过程一次完成，比 BP 网络快约 5 个数量级，其训练时间仅略大于数据读取时间；

2) 总收敛于 Bayes 最优解，在训练样本足够多的情况下，即使分类问题非常复杂，PNN 网络也能够获得 Bayes 准则下的最优解，而 BP 网络可能会陷入局部最优解，无法得到全局最优解；

3) 样本追加能力强，可以增加或减少训练样本而不需要重新进行网络训练；

4) 抗干扰能力强，有较强的鲁棒性，可减少漏报率和误报率。特别是当测量参数存在较大噪声时，PNN 网络的故障诊断率远优于 BP 网络。

3 故障诊断实例

3.1 基于 PNN 的故障诊断步骤

基于 PNN 的模式分类与识别能力，进行故障诊断主要包括 2 个步骤：

1) 对被诊断系统所积累的历史数据进行整理，得到神经网络训练所需的故障样本集(即征兆-故障集)，使用预处理后的故障样本集对网络进行训练，得到故障诊断网络；

2) 获取被诊断系统当前的征兆值并进行预处理，输入已经创建的故障诊断网络，对系统状态进行诊断。

基于 PNN 的故障诊断系统结构如图 2 所示。




图 2 基于 PNN 的故障诊断系统结构

3.2 故障诊断模型构建

在某新型武器装备使用过程中，由于装备的复

杂性，传统方法很难及时辨别故障发生的原因，笔者尝试使用 PNN 实现对该型装备的故障诊断。根据该型装备研制及使用过程中出现的各种故障现象，总结归纳出 9 种典型的故障类型以及与之对应的 10 个征兆参数，征兆参数和故障类型间的对应关系如图 3 所示。




图 3 某型武器装备征兆参数与故障类型间的关系

其中： M_1 为母线电压异常； M_2 为计算机电源电压异常； M_3 为惯组电源电压异常； M_4 为惯组频标异常； M_5 为压力传感器零位异常； M_6 为电爆管压降异常； M_7 为电池电压异常； M_8 为转电电压异常； M_9 为数据上传及下载异常； M_{10} 为发动机解锁异常； D_1 为无故障； D_2 为 VXI 故障； D_3 为通信故障； D_4 为计算机故障； D_5 为惯组故障； D_6 为电爆管故障； D_7 为电池故障； D_8 为转电故障； D_9 为保险机构故障。上述 10 种征兆参数中， $M_1 \sim M_8$ 为连续型参数， M_9 、 M_{10} 为成败型参数(其中 0 为正常，1 为异常)。

使用 Matlab 中的 newpnn 命令创建一个 PNN，即 $net=newpnn(P, T, SPREAD)$ 。其中， net 表示创建的 PNN； P 表示输入的训练样本矢量； T 表示所对应的故障模式矢量； $SPREAD$ 表示径向基函数分布密度，用于调节高斯函数的灵敏度，默认为 0.1(文中网络对 SPREAD 不敏感)。

3.3 训练与测试

为了对故障诊断网络进行训练，笔者收集到该型装备 9 种典型故障发生时 10 个征兆参数数据，作为输入的典型故障样本数据，如表 1 所示(归一化后征兆参数)。同时使用表 2 的形式表示所对应的故障模式(即期望输出)。

表 1 典型故障样本集

故障类型	故障征兆									
	M_1	M_2	M_3	M_4	M_5	M_6	M_7	M_8	M_9	M_{10}
D_1	0.811	0.831	0.706	0.621	0.578	0.714	0.718	0.860	0	0
D_2	0.331	0.396	0.467	0.653	0.218	0.763	0.097	0.308	0	1
D_3	0.812	0.786	0.691	0.874	0.710	0.705	0.732	0.799	1	0
D_4	0.801	0.136	0.679	0.953	0.222	0.680	0.750	0.868	1	0
D_5	0.824	0.848	0.258	0.339	0.583	0.698	0.709	0.812	0	0
D_6	0.828	0.817	0.673	0.673	0.591	0.994	0.736	0.834	0	0
D_7	0.108	0.818	0.790	0.587	0.580	0.731	0.406	0.132	0	0
D_8	0.118	0.818	0.675	0.599	0.572	0.685	0.703	0.127	0	0
D_9	0.796	0.804	0.675	0.642	0.560	0.733	0.708	0.881	0	1

表 2 故障样本集的期望输出

故障类型	1	2	3	4	5	6	7	8	9
D ₁	1	0	0	0	0	0	0	0	0
D ₂	0	1	0	0	0	0	0	0	0
D ₃	0	0	1	0	0	0	0	0	0
D ₄	0	0	0	1	0	0	0	0	0
D ₅	0	0	0	0	1	0	0	0	0
D ₆	0	0	0	0	0	1	0	0	0
D ₇	0	0	0	0	0	0	1	0	0
D ₈	0	0	0	0	0	0	0	1	0
D ₉	0	0	0	0	0	0	0	0	1

为了检验诊断网络对训练样本的分类能力，将表 1 中的数据作为输入矢量，得到网络对故障样本模式的分类识别结果，如图 4 所示，可知网络成功地将故障模式分为了 9 类。

网络训练完成后，选取装备的另外 6 个故障样本进行测试，如表 3 所示(归一化后征兆参数，其中

故障类型表述形式与表 2 一致)。网络的诊断结果如图 5 所示。从图 5 可以看出：网络成功地诊断出了这 6 类故障，表明 PNN 用于该型装备故障分类与诊断是可行的。





图 4 训练后 PNN 对训练样本的分类效果

表 3 测试样本集

样本	M ₁	M ₂	M ₃	M ₄	M ₅	M ₆	M ₇	M ₈	M ₉	M ₁₀	故障类型
1	0.319	0.436	0.397	0.675	0.212	0.712	0.079	0.327	0	1	D ₂
2	0.850	0.822	0.725	0.896	0.723	0.691	0.744	0.798	1	0	D ₃
3	0.878	0.160	0.733	0.932	0.215	0.681	0.708	0.903	1	0	D ₄
4	0.802	0.844	0.190	0.397	0.590	0.718	0.732	0.854	0	0	D ₅
5	0.138	0.789	0.746	0.614	0.610	0.682	0.363	0.093	0	0	D ₇
6	0.088	0.760	0.727	0.636	0.542	0.698	0.697	0.122	0	0	D ₈



(a) PNN网络的故障诊断效果 (b) PNN网络的故障诊断误差

图 5 PNN 故障诊断效果

需要注意的是，神经网络故障诊断是建立在大量的故障样本训练基础上的，其诊断效果在一定程度上取决于所选训练样本的数量及其分布情况。如果样本选择不当，特别是在训练样本少、样本分布不均匀的情况下，很难拥有良好的诊断能力^[8-9]；所以，在研制诊断系统时应尽可能多地收集具有代表性的、分布均匀的故障数据，同时应考虑数据库维护和网络训练功能，以便于持续提高系统的故障诊断能力。

4 结束语

笔者针对某新型武器系统在装备部队后突显出的故障排查难题，采用概率神经网络进行装备的故障诊断。经过对诊断网络的训练与测试，取得了良好的诊断效果，有效识别出了装备的多种典型故障，

可以极大地降低部队使用过程中装备故障排查的难度，提高装备维修保障能力。同时，该方法在其他复杂武器装备故障诊断方面拥有较高的推广价值。

参考文献：

- [1] 张金玉, 张炜. 装备智能故障诊断与预测[M]. 北京: 国防工业出版社, 2013: 123-154.
- [2] 胡霄楠, 史忠科. BP神经网络在雷达故障诊断中的应用研究[J]. 计算机测量与控制, 2006, 14(12): 1660-1661.
- [3] 李明亮, 姜秋喜, 韩晓玲. 基于网络雷达的一种数据关联算法[J]. 四川兵工学报, 2010, 31(2): 5.
- [4] 张德丰. Matlab神经网络应用设计[M]. 北京: 机械工业出版社, 2009: 270-276.
- [5] 张洪波, 何怡刚, 周炎涛, 等. 主成分分析法与概率神经网络在模拟电路故障诊断中的应用[J]. 计算机测量与控制, 2008, 16(12): 1789-1791.
- [6] Qu S W. Bandwidth Enhancement of Wide-Slot Antenna Fed by CPW and Microstrip Line[J]. IEEE Antennas and Wireless Propagation Letters, 2006, 5(4): 15-17.
- [7] 石磊, 王兴成. 概率神经网络在发动机故障诊断中的应用[J]. 自动化仪表, 2011, 32(3): 33-34.
- [8] Burke L I. Neural methods for the traveling salesman problem: insights from operations research[J]. Neural Networks, 1994, 7(4): 681-690.
- [9] Kowalski C T, Orłowska-Kowalska T. Neural networks application for induction motor faults diagnosis[J]. Mathematics and Computers in Simulation, 2003, 63(3-5): 435-448.