

# 基于模式相关的改进 BP 神经网络算法<sup>①</sup>

谢永成<sup>1</sup>, 董今朝<sup>2</sup>, 李光升<sup>2</sup>, 魏 宁<sup>2</sup>

<sup>1</sup>(装甲兵工程学院 外训系, 北京 100072)

<sup>2</sup>(装甲兵工程学院 控制工程系, 北京 100072)

**摘 要:** 针对传统的 BP 神经网络模式分类算法在各个网络输出值较为接近或者模式类之间的网络输出值接近的情况下容易发生误判的问题, 提出一种基于模式相关的 BP 神经网络分类算法, 并结合具体电路, 运用该方法进行建模、仿真。实验结果表明, 采用模式相关的 BP 神经网络分类算法能够充分利用网络输出层各个节点的所有输出, 增强了网络的输出特性, 便于正确、方便的进行模式分类, 且分类效果良好, 具有一定的通用性。

**关键词:** BP 神经网络; 模式相关; 故障诊断

## Improved BP Neural Network Algorithm Based on Mode Correlation

XIE Yong-Cheng<sup>1</sup>, DONG Jin-Zhao<sup>2</sup>, LI Guang-Sheng<sup>2</sup>, WEI Ning<sup>2</sup>

<sup>1</sup>(The Foreign Training Department, Academy of Armored Forced Engineering, Beijing 100072, China)

<sup>2</sup>(Department of Control Engineering, Academy of Armored Forced Engineering, Beijing 100072, China)

**Abstract:** The traditional BP neural network classification algorithm has the inherent shortcomings such as miscarriage of justice when each network's output value or network output value between the mode classes is similar. So the fault diagnosis method of BP neural network based on mode correlation is proposed. Then the modeling and simulation are performed with a specific circuit. Experimental results show that the BP neural network which combining with mode correlation has made full use of all of the value which is outputted by every node of the network output layer and strengthened the network output performance. This method has made mode classification more convenient, better classification results and has certain universality.

**Key words:** BP neural network; mode correlation; fault diagnosis

目前, 随着控制系统结构的日趋复杂, 非线性系统的故障诊断已成为当今故障诊断领域的热点和难点问题。而人工智能故障诊断技术因不需要建立对象的精确数学模型, 部分解决了故障诊断的模糊性和不确定性等经典常规方法不能解决各类问题, 在故障诊断中得到了越来越广泛的重视<sup>[1]</sup>。人工神经网络着眼于模拟人脑, 是一个广泛连接的巨型系统, 它具有 I/O 非线性特性、信息的分布存储、并行处理和全局集体作用, 特别是其高度的自组织和自学习能力, 为故障诊断问题提供了一种崭新的途径<sup>[2]</sup>, 其中误差反向传播(Back-Propagation, BP)神经网络方法可以以任意精度逼近任意连续函数, 在复杂故障诊断中应用的最为

广泛<sup>[3,4]</sup>。由于传统的 BP 神经网络算法存在收敛速度慢、易陷入局部极小值等缺点, 很多学者对此提出了不同的改进方法, 如: 基于压缩映射遗传的 BP 神经网络优化方法<sup>[5]</sup>、用引入 Powell 算法的模拟退火算法优化 BP 神经网络的方法<sup>[6]</sup>、基于批处理的变速率 BP 求解方法<sup>[7]</sup>、采用附加动量项和自适应调整学习率的 BP 算法<sup>[8]</sup>等, 均取得了一定的效果。

本文提出了一种基于模式相关的 BP 神经网络分类算法: 利用数据相关分析原理, 将 BP 网络的实际输出与网络各个特征样本的期望输出进行相关分析, 选取其中相关系数最大的特征样本类作为分类结果, 进而代替传统的 BP 网络仅仅依靠输出层最大值进行模

① 收稿时间:2013-05-04;收到修改稿时间:2013-05-30

式分类的判别方法. 实验结果表明: 该算法与传统的 BP 神经网络模式分类的故障诊断算法相比, 提高了故障诊断的精度, 取得了更好的诊断效果.

## 1 传统的BP神经网络模式分类算法

BP(Back-Propagation)网络即误差反向传播训练的神经网络, 由信息的正向传播和误差的反向传播两个过程组成. 它是由 RUMELHART 等在 1986 年提出的, 是一种多层前馈神经网络, 网络一般由三层或者三层以上的神经元组成, 包括输入层、隐含层(至少包含一个隐含层)、输出层. BP 网络隐层神经元具有非线性传输函数, 而输出层为线性传输函数. 只要隐层节点数目够多, 单隐层前馈网络可以逼近任何闭区间内的一个连续函数<sup>[5]</sup>. 在基于 BP 算法的多层前馈网络的应用中, 图 1 所示的单隐层神经网络的应用最为普遍<sup>[9]</sup>.

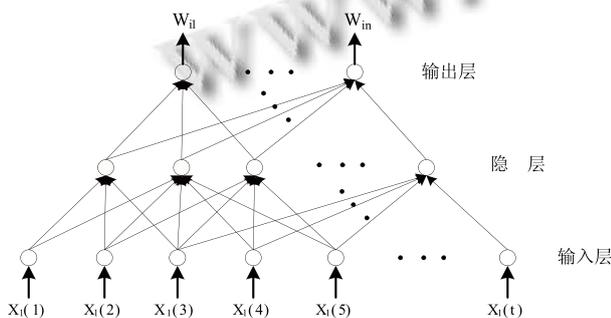


图 1 BP 神经网络模型结构

将此模型结构用作分类器时, 其工作过程主要分为: 网络训练, 通过各种训练样本让 BP 神经网络进行学习, 并随时利用网络输出值与期望值之间的差值来修改各个神经元的连接权值和阈值, 最终使网络的输出满足要求; 然后训练好的网络根据输出层神经元的最大值来判断具体属于哪种故障的类别两个阶段.

设 BP 网络共需判别  $n$  个模式类,  $W_j (j=1, 2, \dots, n)$  为  $n$  个模式类的类别空间, 通常设置网络结构时, 网络输出层的节点数等于分类数  $n$ ; 又设:

$$W = \{ \{w_{11}, w_{12}, \dots, w_{1n}\}, \{w_{21}, w_{22}, \dots, w_{2n}\}, \dots, \{w_{n1}, w_{n2}, \dots, w_{nn}\} \} \quad (1)$$

是  $n$  个已知模式类样本的期望网络输出, 对于第  $i$  个已知模式类的标准输出, 选取为:

$$w_{ij} = \begin{cases} 1, & j=i \\ 0, & j \neq i \end{cases} \quad i=1, 2, \dots, n; j=1, 2, \dots, n \quad (2)$$

若输入样本  $X$  经过网络计算后得到网络输出序列为:  $Y = \{y_1, y_2, \dots, y_n\}$ , 则传统 BP 神经网络分类算法的判决方法为:

$$\text{if } y_{j^*} = \max_{1 \leq i \leq n} \{y_i\} \text{ then } Y \in W_{j^*}; j^* \in [1, n] \quad (3)$$

该方法简单、实用并且易于判断, 但是由于没有充分考虑到网络输出层其他节点的信息以及其他网络的信息:

$$\{y_j : j \in [1, n]; j \neq j^*\} \quad (4)$$

这就造成在网络分类模式各个节点输出值比较接近以及网络间距离较近时容易发生误判.

## 2 改进的BP神经网络模式分类算法

为了克服上述传统方法的局限性, 同时也为了提高网络分类的正确性, 提出一种采用待分模式  $X = \{x_1, x_2, \dots, x_n\}$  的实际网络输出  $Y = \{y_1, y_2, \dots, y_n\}$  与各个已知模式类的期望输出  $W_j = \{w_{j1}, w_{j2}, \dots, w_{jn}\}$ , ( $j=1, 2, \dots, n$ ) 进行相关分析来增强该网络分类能力的方法. 此方法运用线性相关原理, 将 BP 网络的输出与期望输出进行相关分析, 取其线性相关最强的模式类为最终分类结果. 即: 将 BP 网络输出矢量与期望输出矢量当成两个变量, 简单运用线性相关的有关理论, 求取两者之间的相关系数, 取相关系数最大的模式类为最终分类结果.

相关系数的值介于 -1 与 +1 之间, 即  $-1 \leq r \leq +1$ . 其性质如下:

当  $r > 0$  时, 表示两变量正相关,  $r < 0$  时, 两变量为负相关.

当  $|r|=1$  时, 表示两变量为完全线性相关.

当  $r=0$  时, 表示两变量间无线性相关关系.

当  $0 < |r| < 1$  时, 表示两变量存在一定程度的线性相关. 一般可按三级划分:  $|r| < 0.4$  为低度线性相关;  $0.4 \leq |r| < 0.7$  为显著性相关;  $0.7 \leq |r| < 1$  为高度线性相关.

具体步骤为: 分别计算待分模式  $X = \{x_1, x_2, \dots, x_n\}$  的网络实际输出  $Y = \{y_1, y_2, \dots, y_n\}$  与期望输出  $W_j = \{w_{j1}, w_{j2}, \dots, w_{jn}\}$ , ( $j=1, 2, \dots, n$ ) 的相关系数, 选取相关性最强的模式类作为最终分类结果. 待分模式输出序列  $Y = \{y_1, y_2, \dots, y_n\}$  与第  $j$  个已知模式类期望输出  $W_j$  的相关系数序列为:

$$\rho_{ij} = \frac{c_{ij}}{\sqrt{c_{ii}c_{jj}}}; i=1, 2, \dots, n; j=1, 2, \dots, n \quad (5)$$

其中,  $\rho_{ij} = \{\rho_{1j}, \rho_{2j}, \dots, \rho_{nj}\}$  是两个序列  $W_j$ 、 $Y$  的相关系数序列中的系数矩阵,  $-1 \leq \rho_{ij} \leq 1$ ,  $C_{ij}$  是这两个序列的协方差, 当  $i=j$  时, 即  $C_{ii}$  表示两个序列的方差. 该值的计算表达式为:

$$C_{ij} = E[(y - u_y)(w_j - u_{w_j})] \\ = \frac{1}{n} \sum_{k=1}^n (y - u_y)(w_j - u_{w_j}); i, j = 1, 2, \dots, n \quad (6)$$

此时, 网络模式分类的输出判据为:

$$\text{if } \rho_{i^*j} = \max_{1 \leq j \leq n} \{\rho_{ij}\} \text{ then } Y \in W_{i^*}; \\ i = 1, 2, \dots, n; i^* = 1, 2, \dots, n \quad (7)$$

这种改进的 BP 网络分类算法可以克服传统 BP 网络简单求取最大值作为网络分类结果的不足, 其分类精度更高, 判断相似模拟类更为容易.

### 3 故障诊断实例

为了验证方法的有效性, 以装甲车辆电源系统调压器的电压调节电路(图 2)为研究对象, 从该电路中选取 5 个测试点<sup>[10]</sup>(out1~out5)的电压作为 BP 神经网络的输入信号, 为简便起见, 只考虑电路中电阻和电容的硬故障, 当 VCC 端输入 28.5V 时, 选择 4 种故障类型和正常状态共 5 种类型进行分析诊断. 测试样本数据如表 1 所示.

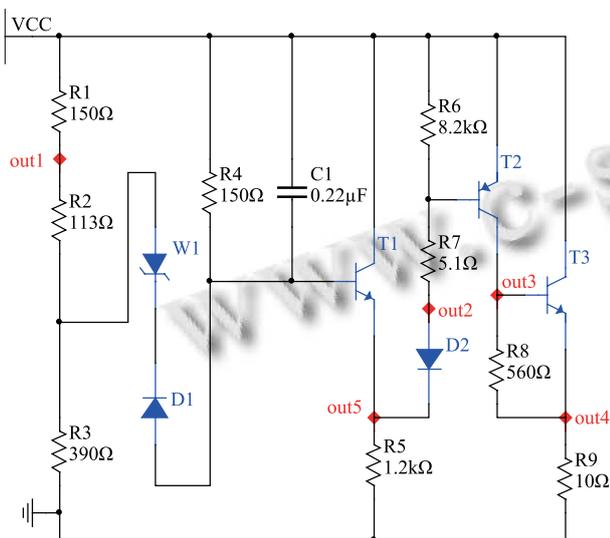


图 2 调压器调节电路

电路共有 5 种故障类型, 故神经网络输出层的输出节点选取为 5 个, 又由于网络输入层输入节点也为 5 个, 则网络隐层节点数可参照美国科学家 Hebb 提出的

表 1 故障样本数据

测试点电压 \ 故障类型	故障类型				
	无故障	R <sub>5</sub> 短路	R <sub>8</sub> 短路	D <sub>2</sub> 短路	T <sub>1</sub> 开路
V <sub>out1</sub> /V	22.583	22.586	22.584	22.586	22.508
V <sub>out2</sub> /V	28.495	0.880	28.493	28.398	27.498
V <sub>out3</sub> /V	0.001	28.512	0.001	0.000	28.504
V <sub>out4</sub> /V	0.001	27.496	0.000	0.000	27.513
V <sub>out5</sub> /V	28.401	0.000	28.403	28.397	26.789

以下经验公式选取:

$$h = \sqrt{n + m} + a \quad (8)$$

其中,  $n$  为输入层输入节点个数;  $m$  为输出层输出节点个数;  $a$  为 [1,10] 之间的常数. 则隐层节点数:

$$h = \sqrt{5 + 5} + a \quad a \in (1, 10) \quad (9)$$

即  $h$  的取值范围为: [5,14]. 一般来说, 隐层节点数越多, 网络的可存储信息量越大, 其学习能力也就越强, 但同时故障诊断所需的时间也越长. 故而隐层节点数的确定需要根据学习样本的复杂性以及所希望神经网络达到的学习能力和泛化能力, 通过神经网络的学习与检验调整确定<sup>[11]</sup>. 经过多次实验测定, 选取  $h=11$ .

按照第二节所述的方法设计网络的理想输出序列如下表 2 所示(其中  $S_1 \sim S_5$  分别表示 5 个网络输出节点的输出值,  $W_1 \sim W_5$  分别表示 5 种故障类型, 下同). 输出状态: 0 为正常, 1 为故障.

表 2 网络的理想输出序列

故障类型 \ 输出节点	故障类型				
	W <sub>1</sub>	W <sub>2</sub>	W <sub>3</sub>	W <sub>4</sub>	W <sub>5</sub>
S <sub>1</sub>	1	0	0	0	0
S <sub>2</sub>	0	1	0	0	0
S <sub>3</sub>	0	0	1	0	0
S <sub>4</sub>	0	0	0	1	0
S <sub>5</sub>	0	0	0	0	1

注: W<sub>1</sub>(无故障), W<sub>2</sub>(R<sub>5</sub> 短路), W<sub>3</sub>(R<sub>8</sub> 短路), W<sub>4</sub>(D<sub>2</sub> 短路), W<sub>5</sub>(T<sub>1</sub> 开路).

通过 Matlab 创建一个 BP 神经网络, 编写网络训练程序, 输入层  $X$  为  $5 \times 5$  矩阵, 输出层  $Y$  即为网络的理想输出序列, 隐层神经元选择  $\text{tansig}$  函数<sup>[12]</sup>(S 型正切函数)为激活函数, 输出层神经元选择  $\text{purelin}$  函数<sup>[12]</sup>(线性传递函数)为激活函数, 选择 Levenberg-Marquardt BP 训练函数, 设定训练次数为 1000, 训练目标  $\text{net.trainParam.goal}=0.01$ .

网络训练的误差曲线如图 3 所示.

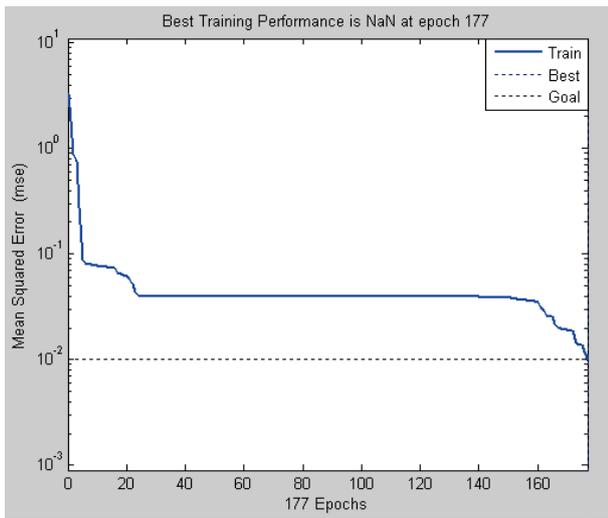


图 3 传统 BP 神经网络算法的误差曲线

训练结果如表 3 所示。

表 3 传统的 BP 神经网络训练结果

故障类型 输出节点	无故障	R <sub>5</sub> 短路	R <sub>8</sub> 短路	D <sub>2</sub> 短路	T <sub>1</sub> 开路
S <sub>1</sub>	0.7929	-0.0016	0.2436	0.0082	-0.0033
S <sub>2</sub>	0.0049	1.0000	-0.0050	0.0006	0.0000
S <sub>3</sub>	0.2630	-0.0018	0.7311	0.0092	-0.0002
S <sub>4</sub>	-0.0545	0.0034	0.0238	0.9828	0.0035
S <sub>5</sub>	-0.0066	-0.0000	0.0068	-0.0008	1.0000

应用改进的 BP 神经网络算法即：编程分别求取表 3 中的网络实际输出与表 2 中期望输出的相关系数，得到的训练结果，即相关系数矩阵  $\rho_{ij}$  如表 4 所示。

表 4 改进后的 BP 神经网络训练结果

故障类型 输出节点	无故障	R <sub>5</sub> 短路	R <sub>8</sub> 短路	D <sub>2</sub> 短路	T <sub>1</sub> 开路
S <sub>1</sub>	0.9366	-0.2520	0.0775	-0.2450	-0.2541
S <sub>2</sub>	-0.3081	1.0000	-0.3651	-0.2547	-0.2500
S <sub>3</sub>	0.0996	-0.2522	0.9454	-0.2437	-0.2502
S <sub>4</sub>	-0.4019	-0.2457	-0.3138	0.9999	-0.2456
S <sub>5</sub>	-0.3262	-0.2500	-0.3441	-0.2565	1.0000

对比表 3 和表 4，经过模式相关的计算后，各个待分模式类输出序列的特征相对于原来的网络输出序列得到增强，若去掉该输出矩阵中的负相关系数单元，得到更为清晰的输出矩阵，如表 5 所示。

可以看出，改进后的 BP 网络训练结果优于传统的 BP 网络的训练结果。

表 5 去除负相关的网络输出

故障类型 输出节点	无故障	R <sub>5</sub> 短路	R <sub>8</sub> 短路	D <sub>2</sub> 短路	T <sub>1</sub> 开路
S <sub>1</sub>	0.9366	0	0.0775	0	0
S <sub>2</sub>	0	1.0000	0	0	0
S <sub>3</sub>	0.0996	0	0.9454	0	0
S <sub>4</sub>	0	0	0	0.9999	0
S <sub>5</sub>	0	0	0	0	1.0000

#### 4 结语

BP 神经网络因其具有良好的模式分类能力，尤其适用于故障诊断领域，但是，传统的 BP 神经网络故障分类方法由于仅考虑输出层输出节点的最大值，没有充分考虑网络输出层其他节点的输出，以及其他的网络信息，对于模式类各个网络输出值较为接近或者模式类之间的网络输出值接近的情况下容易发生误判。运用模式相关的 BP 神经网络分类方法，结合装甲车辆电源系统调压器电压调节电路进行建模、仿真，并对仿真结果进行模式相关分析后，取得了良好的分类效果。该方法与传统的 BP 网络分类方法相比，增强了网络的输出特性，便于正确、方便的进行模式分类，具有一定的通用性。

#### 参考文献

- 1 李春华,张生,杨智慧.基于 BP 神经网络电路故障诊断系统研究.煤矿机械,2009,30(3):196-198.
- 2 周世官,张云.基于进化神经网络的模拟电路故障诊断.计算机测量与控制,2007,15(8):991-993.
- 3 王玲,杜庆东,杨雨迎,杨军.基于神经网络的装备智能故障诊断技术研究.科学技术与工程,2011,11(6):1344-1347.
- 4 刘小丽,王申涛,代睿,魏石峰.基于改进的粒子群优化的神经网络故障诊断方法研究.计算机应用与软件,2011,28(1):207-209.
- 5 冯立颖.改进的 BP 神经网络算法及其应用.计算机仿真,2010,27(12):172-175.
- 6 陈金辉,赵雷震,杨宗宵,郭伟.改进的 BP 神经网络在故障诊断中的应用.河北科技大学学报,2011,32(5):455-459.
- 7 于胜男,郑永前.基于改进 BP 神经网络的机器故障诊断技术研究.精密制造与自动化,2011,1:36-39.
- 8 顾秀江,姚竹亭.基于改进 BP 神经网络的模拟电路故障诊断.电子测试,2011,6:8-11.

(下转第 99 页)

次迭代后空间中还是存在很多孤立点, 而 IA<sup>4</sup>C 算法在聚类效果上就好很多, 孤立点也相对较少. 虽然 IA<sup>4</sup>C 在此数据集中正确率上有所不足, 但是聚类的正确率也仅仅是衡量聚类质量的一个标准. 簇的个数过多有时候会使得聚类的正确率有所提高, 极端情况下一个簇一条数据正确率将会达到 100%, 但这显然不是聚类所要的结果, 所以在考虑聚类正确率的同时也要兼顾聚类簇的个数.

## 5 结语

本文在 A<sup>4</sup>C 算法框架的基础上, 提出了一种特征带权的蚁群聚类算法 IA<sup>4</sup>C. IA<sup>4</sup>C 将主成分分析方法引入到蚁群聚类当中, 借以消除数据间的冗余, 并针对不同的特征赋予不同的权重, 有效的提高聚类的质量. 此外本文还通过 PCA 计算出贡献率最高的二维属性对应二维网格进行投影用以取代原算法当中的随机投点方式, 有效提高算法运行的效率. 实验结果表明, 本文改进的 IA<sup>4</sup>C 算法能够有效的改善聚类的质量和效率.

## 参考文献

- Han JW, Kamber M. 范明, 孟小峰译. 数据挖掘: 概念与技术. 北京: 机械工业出版社, 2007: 196–216.
- 孙吉贵, 刘杰, 赵连宇. 聚类算法研究. 软件学报, 2008, 19(1): 48–61.
- Deneubourg JL, Goss S, Franks N, Sendova-Franks A, Detrain C, Chrétien L. The dynamics of collective sorting robot-like  
Conference on Simulation of Adaptive Behavior on: from ants and ant-like robots. Proc. of the First International Animals to Animats. Cambridge. MIT Press. 1990. 356–363.
- Lumer ED, Faieta B. Diversity and adaptation in populations of clustering ants. Proc. of the Third International Conference on Simulation of Adaptive Behavior: from Animals to Animats 3. Cambridge. MIT Press. 1994. 501–508.
- Handl J, Meyer B. Improved ant-based clustering and sorting in a document retrieval interface. In Goos G, Hartmanis J, Leeuwen J, eds. Lecture Notes in Computer Science. Proc. of the 7th International Conference on Parallel Problem Solving from Nature PPSN VII. Berlin. Springer. 2002, 2439. 913–923.
- Handl J, Knowles J, Dorigo M. Ant-based clustering and topographic mapping. Artificial Life, 2006, 12(1): 35–61.
- Xu X, Chen L, He P. A novel ant clustering algorithm based on cellular automata. Web Intelligence and Agent Systems, 2007, 5(1): 1–14.
- Xu XH, Chen L. An adaptive ant clustering algorithm. Journal of Software, 2006, 9(17): 1884–1889.
- 王丽娟, 关守义, 王晓龙, 王熙照. 基于属性权重的 Fuzzy C Mean 算法. 计算机学报, 2006, 29(10): 1797–1802.
- 陆虎. 基于 PCA 与属性权重模糊聚类的入侵检测方法. 江苏科技大学学报(自然科学版), 2008, (2).
- 张蕾, 曹其新, 李杰. 一种基于群体智能聚类的设备性能横向比较算法. 上海交通大学学报, 2006, 40(3): 439–443.
- <http://archive.ics.uci.edu/ml/>.
- 郑连清. 基于神经网络的三相全控桥整流电路故障诊断. 重庆大学学报, 2004, 27(9): 72–74.
- 张德丰. Matlab/Simulink 建模与仿真实例讲解. 北京: 机械工业出版社, 2010: 275–288.
- Fu JY, Liang SG, Li QS. Prediction of wind-induced pressures on a large gymnasium roof using artificial neural networks. Computers & Structures, 2007, 85 (3-4): 179–192.
- 康洪铭. 装甲车辆电源系统测试性设计与故障诊断方法研究. 北京: 装甲兵工程学院, 2012.

(上接第 103 页)