

doi: 10.7690/bgzdh.2014.09.008

基于 PCA-GA-BP 神经网络的状态评估算法

宁梓呈¹, 郑玉航¹, 王爱亮²

(1. 第二炮兵工程大学 301 教研室, 西安 710025; 2. 中国人民解放军 96421 部队, 陕西 宝鸡 721012)

摘要: 针对传统评估方法主观性强的缺点及 BP 神经网络自身缺陷, 提出基于数据知识的 PCA-GA-BP 状态评估组合算法。采用主成分分析对样本数据进行降维处理, 利用遗传算法对 BP 神经网络的初始权值阈值进行优化, 将历史数据作为学习样本训练神经网络, 处理实时信息得到评估结果, 并通过实例进行算法验证分析。结果表明, 该算法是可行的, 适用于复杂武器装备的状态评估。

关键词: 武器装备; 状态评估; 主成分分析; 遗传算法; BP 神经网络

中图分类号: TP183 **文献标志码:** A

Condition Estimating Algorithm Based on PCA-GA-BP Neural Network

Ning Zicheng¹, Zheng Yuhang¹, Wang Ailiang²

(1. No. 301 Staff Room, The Second Artillery Engineering University, Xi'an 710025, China;

2. No. 96421 Unit of PLA, Baoji 721012, China)

Abstract: Aiming at the traditional evaluation methods has disadvantage of strong subjectivity and defects of BP neural network, the combinational algorithm PCA-GA-BP based on data is established. Sample data dimensions are reduced by principal component analysis, the initial weights and threshold of BP neural network are optimized by genetic algorithm. The neural network is trained by historical data and can be used to evaluate real-time information, and algorithm is validated through the case analysis. The results show that, the algorithm is feasible, which is suitable to condition evaluation for complex weapon equipment.

Keywords: weapon equipment; condition estimating; principle components analysis; genetic algorithm; BP neural network

0 引言

21 世纪初, 以美国联合攻击战斗机(JSF)项目为代表的自主式后勤(AL)保障系统出现, 在一定程度上代表了 21 世纪美军武器装备后勤保障的发展方向^[1], 装备状态评估作为自主后勤保障系统的重要环节, 越来越被关注。科学、准确、快速地评估装备状态, 能为装备管理、维修与使用等工作的正确决策提供支持, 对部队的战备、作战具有非常重大的意义^[2]。以模糊综合评判法等为代表的传统评估方法依赖专家的定性评估, 主观性强, 同时不能有效利用长年累积的年检测数据^[3]。笔者采用基于数据知识的方法, 忽略指标体系的构建, 开发一种通用性的组合算法, 并定义其特点和适用范围。

1 理论基础

1.1 BP 神经网络

BP 神经网络是目前应用最为广泛和成功的神经网络之一。其基本思想是: 学习过程由信号的正向传播与误差的反向传播 2 个过程组成。基于神经

网络的评估方法具有自适应能力强、可容错性强的特点, 能够处理非线性、非局域性的大型复杂系统。适用于综合评估复杂、各个因素之间相互影响呈现出复杂的非线性关系系统^[4]。标准 BP 神经网络存在收敛速度慢、局部极值、权值和阈值及隐结点个数难以精确给定等缺点, 所以在实际应用中受到一定程度的限制^[5-6]。笔者将从训练样本及权值阈值考虑对 BP 神经网络进行优化, 提高训练速度及泛化能力。

1.2 主成分分析

主成分分析(principal component analysis, PCA)是统计学中的一个概念, 由 Pearson 于 1901 年提出, 并由 Hotelling 在 1933 年完善。它主要是把分散在一组变量上的信息集中到某几个综合指标(即主成分)上, 每个主成分都是原始变量的线性组合, 主成分之间互为正交关系, 继而可以缩减维数, 去除冗余信息, 减少部分噪声, 并且可以反映不同变量之间的相关性^[7]。当样本数据维数较多、结构复杂的时候, 采用主成分分析的方法在保证数据不失真的

收稿日期: 2014-03-22; 修回日期: 2014-04-23

作者简介: 宁梓呈(1989—), 男, 四川人, 在读硕士, 从事武器系统健康管理研究。

前提下，可以简化输入样本，减少训练时间，提高训练的效率，达到提高神经网络泛化能力的目的，有较好的数据预处理能力。

1.3 遗传算法

遗传算法是 20 世纪 60 年代中期，美国密执根大学的 John Holland 在他人工作的基础上提出并建立起来的。它以自然选择和遗传理论为基础，将生物进化过程中适者生存原则与群体内部染色体的随机信息交换机制相结合，是一种全局寻优搜索算法。它将问题空间中的可能解看作是群体里的类似于染色体的个体，并将每一个个体编码成符号串的形式。按照适应度函数计算出函数值，然后依据函数值，模拟生物进化过程，进行选择、交叉、变异等操作，一代一代地不断进化，最终得到最优解^[8]。

2 流程分析

2.1 输入样本处理

主成分分析的目的就是对输入样本降维去冗余，主成分得分矩阵就是新样本，即为神经网络的输入，主成分个数为神经网络输入层节点数。

设有 k 项 n 维样本，得样本矩阵为 $\mathbf{X} = (x_{ij})_{k \times n}$ ， $i = 1, 2, \dots, k; j = 1, 2, \dots, n$ 。其中 x_{ij} 表示第 i 个样本的第 j 项数据^[9]。利用 PCA 处理样本矩阵的流程为：

步骤 1：对样本矩阵进行标准化，假定标准化后的矩阵用 \mathbf{X}^* 表示。

$$x_{ij}^* = \frac{x_{ij} - \bar{x}_j}{\sqrt{\text{var}(x_j)}} \quad (i = 1, 2, \dots, k; j = 1, 2, \dots, n) \quad (1)$$

其中 $\bar{x}_j = \frac{1}{k} \sum_{i=1}^k x_{ij}$ ， $\text{var}(x_j) = \frac{1}{k-1} \sum_{i=1}^k (x_{ij} - \bar{x}_j)^2$ 。

步骤 2：计算 n 个变量的相关系数矩阵。

$$\mathbf{R} = \begin{bmatrix} r_{11} & r_{12} & \cdots & r_{1n} \\ r_{21} & r_{22} & \cdots & r_{2n} \\ \vdots & \vdots & & \vdots \\ r_{n1} & r_{n2} & \cdots & r_{nn} \end{bmatrix} \quad (2)$$

其中 $r_{ij} = \frac{1}{k-1} \sum_{i=1}^k x_{ii} x_{ij}$ ($i, j = 1, 2, \dots, n$)。

步骤 3：计算相关系数矩阵 \mathbf{R} 的特征值 ($\lambda_1, \lambda_2, \dots, \lambda_n$)，并按从大到小将特征值排序，即 $\lambda_1 > \lambda_2 > \dots > \lambda_n$ ，对应相应的特征向量 $\mathbf{a}_i = (a_{i1}, a_{i2}, \dots, a_{in})$ ， $i = 1, 2, \dots, n$ 。

步骤 4：选择主成分。

$$\text{第 } k \text{ 个主成分的贡献率} = \lambda_k / \sum_{i=1}^n \lambda_i \quad (3)$$

$$\text{前 } k \text{ 个主成分的累积贡献} = \sum_{i=1}^k \lambda_i / \sum_{i=1}^n \lambda_i \quad (4)$$

一共可以得到 n 个主成分，每个主成分包含的信息量是递减的。当 $k = m$ 时，累积贡献率超过设定值，选取前 m 个主成分。

步骤 5：计算主成分得分 τ_i 。 τ_i 为新样本，即神经网络的输入。

选取前 m 个特征向量组成的矩阵 \mathbf{a}_i^* ($i = 1, 2, \dots, m$)，有

$$\tau_i = \mathbf{X}^* \mathbf{a}_i^* \quad (5)$$

2.2 权值阈值处理

步骤 1：种群初始化。个体编码方法为实数编码，每个个体均为一个实数串，由输入层与隐含层连接权值、隐含层阈值、隐含层与输出层连接权值及输出层阈值 4 部分组成。编码长度为：

$$L = L_1 \times R + R \times L_2 + R + L_2 \quad (6)$$

式中： L_1 、 L_2 为 BP 神经网络输入层、输出层节点数； R 为隐含层节点数。初始群体随机选取。

步骤 2：计算适应度。把 BP 神经网络的预测输出和期望输出之间的误差绝对值之和作为个体适应度值，计算公式为

$$F = k \left(\sum_{i=1}^{L_2} \text{abs}(y_i - o_i) \right) \quad (7)$$

式中： y_i 为神经网络第 i 个节点的期望输出； o_i 为第 i 个节点的预测输出， k 为系数， $0 < k \leq 1$ 。从适应度中选出最优个体。

步骤 3：迭代操作。选择算子是遗传算法的关键，它体现了自然界适者生存的思想，即向最优解逼近。笔者选择轮盘赌法计算，即基于适应度比例的选择策略，每个个体 i 的选择概率 p_i 为：

$$f_i = k / F_i \quad (8)$$

$$p_i = f_i / \sum_{j=1}^N f_j \quad (9)$$

式中： f_i 为个体适应度值，由于适应度越小越好，所以在个体选择前对适应度值求倒数； k 为系数，一般取 1； N 为种群个体数目。

因个体采用实数编码，所以交叉操作方法采用实数交叉法，它体现了最优解的产生。第 k 个染色体 a_k 和第 l 个染色体 a_l 在 j 位的交叉操作方法为：

$$\begin{cases} a_{kj} = a_{lj}(1-b) + a_{kj}b \\ a_{lj} = a_{kj}(1-b) + a_{lj}b \end{cases} \quad (10)$$

其中 b 是 $[0,1]$ 间的随机数。交叉概率决定是否进行交叉，交叉染色体和交叉位置都是随机选择的。

变异体现了全局最优解的覆盖。变异概率决定是否进行变异。随机选取第 i 个个体的第 i 个基因进行变异，操作方法为

$$a_{ij} = \begin{cases} a_{ij} + (a_{ij} - a_{\max})f(g) & r \geq 0.5 \\ a_{ij} + (a_{\min} - a_{ij})f(g) & r < 0.5 \end{cases} \quad (11)$$

式中： a_{\max} 为基因 a_{ij} 的上界； a_{\min} 为基因 a_{ij} 的下界；

$f(g) = r_2(1 - g/G_{\max})$ ， r_2 为一个随机数； g 为当前迭代次数； G_{\max} 为最大进化次数； r 为 $[0,1]$ 间的随机数。

步骤 4：计算神经网络误差是否满足要求，从而判断进化是否结束，若否，则返回步骤 2^[10]。

2.3 网络训练与状态评估

将优化的权值阈值代入神经网络结构中，由主成分样本对神经网络进行训练，确定 BP 神经网络输入输出关系。笔者采用 Matlab 工具箱默认的学习训练函数。图 1 为网络训练流程。

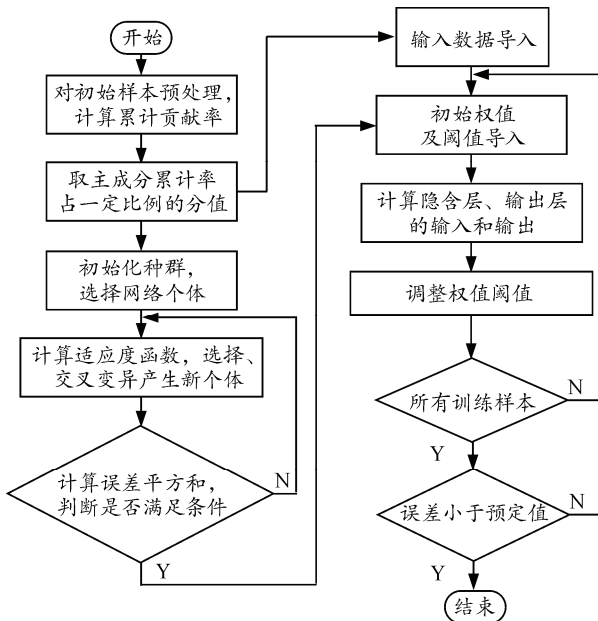


图 1 基于 PCA-GA-BP 的网络训练流程

将装备的实时检测数据代入训练好的网络，依据输出评估其状态。

3 算法验证

笔者引用某转子 5 种状态运行的 100 组特征数据作为样本数据，每种状态 20 组样本，5 种状态依次是：不对中、碰磨、松动、正常、不平衡，对输出进行编码，对应依次为 $(0, 0, 1)$ 、 $(0, 1, 0)$ 、 $(0, 1, 1)$ 、 $(1, 0, 0)$ 、 $(1, 0, 1)$ 。特征数据是由转子振动数据提取，经过了去直流滤波处理，特征分别为均值、均方根、方差、峰峰值、方根幅值、平均幅值和峰值。将样本每种状态后 2 组共 10 组作为测试样本，依次编号为 19、20、39、40、59、60、79、80、99、100。其余 90 组作为训练样本。

对 100 组 8 维数据进行主成分分析，利用 Matlab 编程，得各特征项的贡献率及累计贡献率，如表 1。

表 1 主成分分析结果

特征项	方差贡献率/%	累计方差贡献率/%
方差	31.023	31.023
均方根	20.389	51.412
峰峰值	18.561	69.973
峰值	11.823	81.796
方根幅值	7.637	89.433
均值	5.945	95.378
平均幅值	4.622	100

选取累计方差贡献率大于 85% 的前 m 个主成分。由表 1 知前五项方差贡献率之和为 89.433%，则选取的主成分为方差、均方根、峰峰值、峰值和方根幅值。计算主成分得分即为神经网络输入样本。

对神经网络的初始权值阈值进行训练。具有足够多隐单元的三层前向网络能以任意准确度逼近任何连续的映射^[5]。神经网络输出层节点数为 3，经试凑法确定隐含层节点数为 11 时误差最小。随机初始种群，确定遗传算法的基本参数：种群规模，10；最大进化代数，30；交叉概率，0.2；变异概率，0.1。利用 Matlab 遗传算法工具箱完成此操作。图 2 为适应度曲线，得到最优个体适应度值。




图 2 最优个体适应度值

在 23 次迭代之后,染色体的适应度基本趋于稳定,得到最优的初始权值和阈值,如表 2。

表 2 最优初始权值阈值

编号	1	2	3	4	5	6	7	8	9	10	11
W_{1j}	2.631 3	0.542 9	-0.356 2	2.651 5	0.935 5	-0.288 3	2.038 2	0.195 7	0.323 3	1.080 4	-0.796 9
W_{2j}	-1.564 3	0.473 5	2.201 3	-0.559 3	-2.324 3	-0.336 9	-1.198 9	-0.591 7	2.000 2	-0.578 2	-0.658 9
W_{3j}	-0.837 3	-2.158 5	-1.439 2	-2.479 1	-0.423 6	-1.456 3	-1.214 7	-0.450 8	-2.284 8	-0.029 6	1.238 4
W_{4j}	-1.538 6	1.710 4	-2.555 5	-0.636 7	-2.979 6	-1.675 9	-2.992 2	-1.864 9	-2.145 1	-1.391 5	-1.950 6
W_{5j}	-2.168 1	0.593 3	2.406 3	2.636 3	-1.672 9	-0.104 0	-0.743 9	0.142 7	-1.410 8	-2.589 9	-0.382 0
B_{1j}	-1.956 9	-2.843 4	2.728 1	-0.416 4	2.769 4	1.574 5	-2.955 9	1.080 2	1.235 7	0.870 8	0.313 9
W_{2j}	-1.691 3	1.634 2	-1.631 8	-0.774 8	2.345 6	2.138 3	-0.585 4	-1.091 9	0.651 8	2.461 2	2.454 6
B_{2j}	0.549 6	—	—	—	—	—	—	—	—	—	—

其中: W_{ij} ($i = 1, 2, \dots, 5; j = 1, 2, \dots, 11$) 为输入层与隐含层权值; B_{1j} 为隐含层阈值; W_{2j} 为隐含层与输出层权值; B_{2j} 为输出层阈值。将最优初始权值阈值代

入到 BP 神经网络,开始训练 90 组样本,达到期望误差值时代入测试样本获得测试结果。BP 神经网络训练参数设置为 goal: 0.000 01; lr: 0.1。表 3 为 PCA-GA-BA 网络与标准 BP 神经网络的测试结果。

表 3 测试结果对比

测试样本		标准 BP 神经网络		PCA-GA-BA 网络	
样本编号	期望输出	测试结果	相对误差/%	测试结果	相对误差/%
19	(0,0,1)	(0.111 7, 0.012 8, 0.963 1)	3.69	(0.011 7, 0.014 8, 0.983 7)	1.63
20	(0,0,1)	(0.021 1, 0.016 3, 0.913 8)	8.62	(0.013 5, 0.015 9, 0.962 1)	3.79
39	(0,1,0)	(0.163 3, 0.910 2, 0.099 3)	8.98	(0.102 3, 0.928 6, 0.091 6)	7.14
40	(0,1,0)	(0.084 1, 0.912 7, 0.064 9)	8.73	(0.063 7, 0.946 1, 0.056 2)	5.39
59	(0,1,1)	(0.024 7, 0.901 9, 0.914 8)	9.81	(0.019 5, 0.921 3, 0.964 7)	7.87
60	(0,1,1)	(0.035 2, 0.921 4, 0.918 9)	8.11	(0.026 8, 0.961 5, 0.962 4)	3.85
79	(1,0,0)	(0.923 1, 0.076 9, 0.035 7)	7.69	(0.971 3, 0.081 2, 0.021 6)	2.69
80	(1,0,0)	(0.901 8, 0.062 2, 0.067 2)	9.82	(0.931 6, 0.053 7, 0.061 8)	6.84
99	(1,0,1)	(0.882 1, 0.091 3, 0.912 5)	11.79	(0.886 9, 0.071 8, 0.935 6)	11.31
100	(1,0,1)	(0.913 8, 0.028 7, 0.941 3)	8.62	(0.954 8, 0.013 7, 0.962 9)	4.52

由 PCA-GA-BP 网络测试结果评估转子状态,知 19、20 组属于不对中状态(0, 0, 1), 39、40 组属于碰磨状态(0, 1, 0), 59、60 组属于松动状态(0, 1, 1), 79、80 组属于正常状态(1, 0, 0), 99、100 组属于不平衡状态(1, 0, 1), 各组测试结果都与实际情况相符合。将其精度与标准 BP 神经网络对比分析,令期望输出与测试结果编码非零位相对误差绝对值的最大值作为最终相对误差,知 PCA-GA-BP 网络的精度明显优于标准 BP 神经网络。此外,标准 BP 神经网络的收敛速度慢,PCA-GA-BP 网络训练步数仅为 28 步,速度优于标准 BP 网络。验证了组合算法的可行性与精确度。

4 结束语

主成分分析对样本进行降维降噪处理,选出新的训练和测试样本,从而消除了输入因素的相关性影响,并简化网络结构,降低了神经网络的复杂度,大大提高了网络的学习速率和泛化能力。用遗传算法的全局搜索能力来优化 BP 网络的初始权值阈值,有效地克服了 BP 算法易陷入局部收敛等问题,同时提高了学习速率。笔者所研究的基于 PCA-GA-BP 神经网络的组合算法基于数据知识,具有一定的通用性,适用于复杂武器装备的状态评

估,其表征数据项多、维数大,且需要的样本较丰富,否则 BP 的训练将达不到良好的泛化能力,遗传算法的优化不会有实质性的效果,样本的预处理会适得其反。

参考文献:

- [1] 张宝珍. 21 世纪的保障方案: JSF 的自主式后勤[J]. 航空维修与工程, 2003 (1): 27-30.
- [2] 杜恩祥, 王玮, 常雷. 基于 FMECA 的装备健康状态评估方法[J]. 装甲兵工程学院学报, 2013, 27(2): 25-28.
- [3] 张鹏, 薛江平, 金志伟, 等. 模糊综合评估技术在装备管理工作中的应用[J]. 兵工自动化, 2013, 32(7): 55-58.
- [4] 马亚龙, 邵秋峰, 孙明, 等. 评估理论和方法及其军事应用[M]. 北京: 国防工业出版社, 2013: 141-143.
- [5] 夏玫. BP 神经网络泛化能力改进研究[D]. 太原: 太原科技大学, 2009: 7-9.
- [6] 覃光华. 人工神经网络技术及其应用[D]. 成都: 四川大学, 2003: 10-12.
- [7] 代雪静, 田卫. 水质模糊评价模型中赋权方法的选择[J]. 中国科学院研究生院学报, 2011, 28(2): 169-176.
- [8] 王小平, 曹立明. 遗传算法—理论、应用于软件实现[M]. 西安: 西安交通大学出版社, 2002: 39-46.
- [9] 黄舟. 基于 PCA 的 GA-BP 网络对股票预测研究[D]. 上海: 华东理工大学, 2013: 14-15.
- [10] 黄庆斌. BP 算法的改进及其应用研究[D]. 成都: 西南交通大学, 2010: 28-30.