

主成分分析结合神经网络技术在焊接 质量控制中的应用

杨海澜, 蔡 艳, 陈庚军, 吴毅雄

(上海交通大学 材料科学与工程学院 上海 200030)



杨海澜

摘 要: 介绍了主成分分析方法及人工神经网络技术在相关因素分析和质量控制的建模与估计中的应用。以大电流 MAG 焊熔宽控制为例, 通过对 6 个焊接过程参数进行主成分分析, 提取出影响熔宽的 4 个主要因素。讨论了提取的主成分与原始过程参数间的关系。以主成分得分作为新的训练样本集, 送入神经网络进行计算。结果表明, 基于主成分分析的神经网络无论在收敛速度, 还是在训练精度上, 都远远优于基本 BP 神经网络。

关键词: 主成分分析; 神经网络; BP 算法; 质量控制

中图分类号: TG409 **文献标识码:** A **文章编号:** 0253-360X(2003)04-55-05

0 序 言

主成分分析是将研究对象的多个相关变量(指标)化为少数几个不相关变量的一种多元统计方法, 它是在有一定相依关系的 n 个参数的 m 个样本值所构成的数据阵列的基础上, 通过建立较小数目的综合变量, 使其更集中地反映原来 n 个参数中所包含的变化信息, 从数学的角度来看, 就是降维的思想^[1,2]。

标准 BP 神经网络的收敛速度较慢, 提高收敛速度的方法主要有加入动量项、变步长法、采用新的激励函数或误差函数等^[3]。

作者采用改进的自适应变步长加动量项的学习算法。其带有动量项的加权调节公式为

$$\Delta w(t+1) = -\eta \frac{\partial E}{\partial w} + \theta \Delta w(t), \quad (1)$$

式中: η 为学习步长; θ 为动量系数; Δw 为网络权值的改变。引入动量项的效果使得学习过程中等效地改变 η 值而不再是恒定值, 调节向着底部的平均方向变化, 不致产生大的摆动, 即动量项起到了缓冲平滑的作用。若系统进入误差函数面的平坦区, 那么误差变化很小, $\Delta w(t+1)$ 近似于 $\Delta w(t)$, 平均 Δw 变为

$$\Delta w \approx \frac{-\eta}{1-\theta} \cdot \frac{\partial E}{\partial w} \quad (2)$$

式中系数 $-\eta/(1-\theta)$ 变得更有效, 使调节尽快脱离饱和区。

自适应变步长的基本原理是, 检验参数的选择是否有利于网络误差的下降^[4]。若此次迭代使误差减小, 则使学习步长增加一常量 a , 并为其设置一上限值, 以免步长过大引起网络震荡; 若检测到连续几次迭代使误差增大, 则使学习步长按比例 b 减小, 并设置一下限值, 防止收敛过慢。其中常量 a 和比例系数 b 经多次试验确定。

1 基于主成分分析的人工神经网络

传统的 BP 算法一般以误差函数最小为逼近目标, 利用梯度下降法进行网络参数的反复迭代而完成整个自学习过程。虽然该算法能够有效解决诸多问题, 但由于输入输出关系的复杂性导致当训练样本较多时其收敛速度和精度明显下降; 另一方面, 训练样本数的增加又是提高网络工作性能的重要前提^[5,6]。为解决这一矛盾, 许多改进算法被提出, 并取得一定的效果。然而常规的改进方法只是针对学习算法的局部改善。鉴于此, 作者提出基于主成分分析的神经网络。它的基本思想是针对复杂的系统问题, 首先利用主成分分析对多变量参数矩阵进行处理, 由于主成分分析的实质是 n 维空间的坐标旋转, 并不改变样本数据结构; 得到的主成分是原变量的线性组合且两两不相关, 能够最大程度地反映原变量所包含的信息^[7], 在以一定标准选取前 k 个较重要的主成分之后, 原来的多维问题就得以简化。以精简过的参数矩阵作为神经网络的输入量时, 在训练样本数并未减少的基础上消除了网络输入间的

相关性,同时减少了网络的输入数,简化了网络结构,可从整体上提高网络的性能^[8]。

2 试验数据分析处理及讨论

试验采用恒压外特性、最大输出电流 1 500 A 的逆变电源,送丝装置自制,送丝速度在 0.5 ~ 50 m/min 范围内可调,焊丝成分相当于 AWS ER70S-G,GB ER50-G,直径 ϕ 1.2 mm,试件为 12 mm 厚的 Q345 钢板,保护气以 Ar 为主,混合少量 CO₂ 及 O₂,经自行开发的高精度气体配比系统混合后送入焊枪。试验方式采用平板堆焊,直流反接,焊枪前倾 8°。所用钢板表面在焊接前均用角向磨光机进行仔细打磨,以除去表面的氧化物和铁锈。焊后对焊缝宽度进行了测量,得到 54 组试验数据,送入自行开发的主成分分析软件进行处理。

主成分分析的基本思想是根据数据变化的方差大小来确定变化方向的主次地位,按主次顺序得到各主成分^[9]。现有原始数据阵 $X_{n \times m}$,其中 $n = 54$ 为样本数, $m = 6$ 为变量(指标)数。

2.1 原始数据标准化

为消除因原变量的量纲不同、数值差异太大带来的影响,需要对原变量做标准化处理,即

$$x_{ki}^* = \frac{x_{ki} - \bar{x}_i}{\sqrt{S_{ii}^*}}, \tag{3}$$

$$k=1,2,\cdots,n; i=1,2,\cdots,m;$$

式中: x_{ki} 为原始样本数据; x_{ki}^* 为标准化标本数据; $\bar{x}_i$ 为各变量样本均值; S_{ii}^* 为各变量样本方差。其中

$$\bar{x}_i = \frac{1}{n} \sum_{k=1}^n x_{ki},$$

$$S_{ii}^* = \frac{1}{n-1} \sum_{k=1}^n (x_{ki} - \bar{x}_i)^2, \\ i=1,2,\cdots,m。$$

2.2 建立相关矩阵以便计算矩阵的特征值和特征向量

标准化后的样本相关矩阵为

$$R = \frac{1}{n-1} X^{*'} X^*, \tag{4}$$

式中: X^* 为标准化后的数据矩阵,见表 1。

由表 1 看出: (1) X_1 与 X_5, X_6 之间有着较大的正相关; (2) X_2 与 X_6 之间有着密切的负相关; (3) X_3, X_4 是两个相对独立的因子。

2.3 由 R 出发,运用 Jacobi 方法求出 R 的特征根 λ_i 及相应的特征向量 l_i

主成分对总方差的贡献率,即方差贡献率=

表 1 相关系数矩阵

Table 1 Matrix of related coefficients

Variables	X_1	X_2	X_3	X_4	X_5	X_6
X_1	1.00	—	—	—	—	—
X_2	0	1.00	—	—	—	—
X_3	0	0	1.00	—	—	—
X_4	0	0	0	1.00	—	—
X_5	0.617	0.006	0.017	0.087	1.00	—
X_6	0.371	-0.828	0.068	-0.076	0.302	1.00

Note: X_1 —wire feed rate, X_2 —wire extension, X_3 —welding speed, X_4 —gas flow, X_5 —welding voltage, X_6 —welding current.

$\lambda_i / \sum_{i=1}^m \lambda_i \times 100\%$ 。按贡献率由大到小的顺序对 m 个主成分进行排序,贡献率最大的主成分称为第一主成分,其次称为第二主成分,以此类推。选取主成分的个数取决于主成分的累计方差贡献率,通常使累计方差贡献率大于 85% 所需的主成分个数便可包含 m 个原始变量所能提供的绝大部分信息,见表 2。

表 2 特征值及累计方差贡献率

Table 2 Eigenvalues and variance proportion

Serial number	Eigenvalues	Variance proportion (%)	Accumulative variance proportion (%)
1	2.098	34.97	34.97
2	1.442	24.03	59.00
3	1.000	16.66	75.66
4	1.000	16.66	92.32
5	0.378	6.30	98.62
6	0.083	1.38	100.00

累计方差贡献率表明主成分包含全部因子提供的信息百分比。由表 2 可确定 4 个有重要意义的主成分,其主成分载荷值的计算结果见表 3。

表 3 主成分载荷值

Table 3 Loading values of principal components

Variables	PCs				
	I	II	III	IV	H_i^2
X_1	0.652	0.612	-0.029	-0.136	81.95
X_2	-0.682	0.686	0.069	-0.150	96.34
X_3	0.066	-0.030	0.997	0.005	99.97
X_4	-0.014	0.190	0.002	0.979	99.54
X_5	0.613	0.655	0	0	80.48
X_6	0.909	-0.361	0	0	95.67

表中 $H_i^2 = \sum_{j=1}^4 a_{ij}^2 \times 100\%$ 。由于 a_{ij} 为变量 X_i

在第 j 个主成分上的载荷, 那么在 4 个主成分上载荷的平方和就表示 4 个主成分能包含变量 X_i 的信息率。由表 3 可以看出均超过 80%。

主成分载荷是主成分与变量因子间的相关系数。由表 3 可见: (1) X_6 与主成分 I 有着密切的正相关关系, 与主成分 II 有着一定的负相关关系, 而 X_2 的情况正好与之相反; (2) X_1 和 X_5 与 I, II 主成分都有着较大的正相关关系, 表明因子 X_1, X_5 对熔宽而言是非常重要的两个影响因素; (3) X_3 与主成分 III 有着非常密切的正相关关系, 表明主成分 III 主要体现了因子 X_3 对熔宽的影响; (4) 同理, 主成分 IV 主要体现了因子 X_4 对熔宽的影响。

2.4 建立主成分方程, 计算主成分载荷 α 及主成分得分 τ

主成分载荷值方程为

$$\alpha_i = \sum_{i=1}^m \sqrt{\lambda_i} l_i, \tag{5}$$

式中: $l_i (i=1, 2, \dots, m)$ 为对应于特征值 λ_i 的特征向量。

主成分得分值方程为

$$\tau_i = x_i^* \alpha_i, \tag{6}$$

式中: x_i^* 为各变量的标准化数值。计算出的各主成分得分值, 经标准化处理后, 即为神经网络新的训练样本输入。

3 主成分的图示结果分析

图 1 为第一、二主成分的分值图, 它可以看作是 54 个样本点在新的坐标轴(第一、二坐标)下的坐标值。图 2 为质量参数的分布图, 可以看到, 和第一、二主成分的分布大体相似, 也就是说, 第一、二主成分在趋势上已基本反映质量参数的变化情况。这也说明, 质量波动是一段时间内生产过程运行参数变化的集中反映, 借助一定条件下一段时间内运行参数的变化, 可以估计出产品的质量指标^[10]。

由图 3 可以看出, 第三、四主成分的分值呈明显的规律性分布, 基本没有反映质量参数的变化情况。这一方面是由于第三、四主成分对质量参数的影响贡献较小(分别只有 16% 左右), 更重要的原因在于前面提到的, 它们是两个相对独立的因子, 分别只体现了变量 X_3 和变量 X_4 对熔宽的影响, 而不像第一、二主成分是几个重要变量的综合表现。此外, 变量 X_3 和 X_4 的原始试验数据呈规律性分布也是一个重要因素。




图 1 第一、二主成分分值分布图
Fig. 1 Distribution of I & II PC values




图 2 质量参数分布图
Fig. 2 Distribution of quality parameter

4 神经网络计算及输出结果比较

将原始数据(6 变量)与经过主成分分析并经过标准化处理的主成分得分值数据(4 变量)分别送入神经网络(循环次数: 20 000, 误差限: 0.001)进行计算, 并与实测值(熔宽)进行比较(为便于图示, 已将数值从小到大顺序排列), 结果如下。

对第一种情况, 网络一般在运行 3 000 次左右后产生震荡, 此时误差陷入局部最小, 约 0.043 左右。最后输出结果与实测值比较见图 4。




图 3 第三、四主成分分值分布图

Fig.3 Distribution of III & IV PC values




图 4 实测值与基本 BP 神经网络输出结果比较

Fig.4 Comparison between measured values and outputs of basic BP NN

对第二种情况,网络在运行 10 000 次左右收敛到误差下限值。最后输出结果与实测值比较见图 5。




图 5 实测值与 PCA-based 神经网络输出结果比较


Fig.5 Comparison between measured values and outputs of PCA-based NN

由两个对比图可以看出,基本 BP 网络当网络规模过大时,归纳能力大为下降,甚至无法进行有效的学习;基于主成分分析的神经网络在不改变样本数据结构的基础上,消除了网络输入因子间的相关性,减少了输入变量,简化了网络结构,从整体上提高了网络的学习速率及工作性能。


主成分分析能够有效地简化数据变量,但必须明确主成分的意义,对获得的数据分析结果做出合理解释,才能真正用于实际生产过程。将主成分分析结合人工神经网络用于焊接质量控制,是一种新的尝试。文中以大电流 MAG 焊为例,简要介绍了这种方法的处理过程及分析结果,不足之处需进一步研究和实践才能得以完善。

5 结 论

- (1) 对大电流MAG焊6个焊接过程参数进行
- [下转第 64 页]



(a) PWM signal with 25% duty ratio



(b) PWM signal with 50% duty ratio

图 8 PWM 控制信号

Fig. 8 PWM control signal

(3) 一个焊机,特别是高数字化、智能化程度的焊机的控制是多方位的,即是多任务控制系统,要保证对各任务控制之间在时间上的合理分配、延时、同步性。单CPU 系统由于其分时的指令执行系统,很难解决多任务系统的时间分配问题,因此,双CPU 甚至多CPU 控制系统可很好地解决这一问题。

参考文献:

[1] 张雄伟, 曹铁勇. DSP 芯片的原理与开发应用[M]. 北京: 电子工业出版社, 2000. 5~60.

[2] Glauser H P. A new digital controlled inverter system with static switch[A]. International telecommunications energy conference [C]. Twenty-Third International, 2001. 520~524.

[3] Hua Chihchiang. Two lever switching patented deadbeat DSP controlled PWM inverter[J]. IEEE Trans. Power Electron, 1995, 10 (3): 310~317.

作者简介: 何建萍, 女, 1964 年 3 月出生, 副教授, 博士研究生。主要研究方向为数字化焊接电源、自动控制系统、信息处理和通信。发表论文 7 篇。

Email: jnejphe@etang.com

[上接第 58 页]

主成分分析, 提取出影响熔宽的 4 个主要因素。分析结果表明, 占有重要地位的主成分 I 与主成分 II 是各原始焊接过程参数的综合变量, 其中送丝速度与焊接电压对熔宽的影响较大, 而处于次要地位的主成分 III 与主成分 IV 是两个相对独立的因子, 分别代表了焊接速度与保护气流量对熔宽的影响。

(2) 两组输出结果对比显示, 利用主成分分析方法对样本集进行处理, 形成新的训练样本集, 减少了神经网络建模时网络的输入数, 同时消除输入因子的相关性并简化网络结构, 能大大提高网络的学习速率。得到的神经网络模型能达到较高的精度, 为影响因素多且机理尚不清的焊接过程神经网络建模提供了一个有效的方法。

参考文献:

[1] 曾黄麟, 虞厥邦, 曾 谦. 基于主成分分析的特征简化[J]. 四

川轻化工学院学报, 1999, 12(1): 1~4.

[2] 黄 宁. 关于主成分分析应用的思考[J]. 数理统计与管理, 1999, 18(5): 44~52.

[3] 袁曾任. 人工神经网络及其应用[M]. 北京: 清华大学出版社, 1999. 78~103.

[4] 李宇峰, 裴旭东, 黄聪明. BP 神经网络实际应用中的若干问题[J]. 兵工自动化, 1998, (1): 1~4.

[5] 贾 磊, 万百五, 冯祖仁. 以高维输入神经网络作为生产线产品质量模型[J]. 控制与决策, 2000, 15(5): 569~572.

[6] 彭 松, 方祖祥. BP 神经网络学习算法的联合优化[J]. 电路与系统学报, 2000, 5(3): 26~30.

[7] 叶双峰. 关于主成分分析做综合评价的改进[J]. 数理统计与管理, 2001, 20(2): 52~61.

[8] 吴新生, 谢益明, 刘焕彬. 主成分分析法用于化工过程人工神经网络建模[J]. 计算机与应用化学, 1999, 16(3): 220~230.

[9] 李艳双, 曾珍香, 张 闯, 等. 主成分分析法在多指标综合评价方法中的应用[J]. 河北工业大学学报, 1999, 28(1): 94~97.

[10] 冯 炜, 阳究惠. 质量控制中的统计相关分析与建模[J]. 清华大学学报(自然科学版), 1998, 38(9): 63~66.

作者简介: 杨海澜, 男 1975 年 12 月出生, 博士研究生。主要从事焊接设备及焊接过程质量控制方面的研究, 发表论文 8 篇。

Email: tombraiderhyl.student@sina.com