

研究报告

基于正交实验的 BP 神经网络预测研究

蔡安辉，刘永刚，孙国雄

(东南大学机械系，南京 210096)

[摘要] 用不同的 $L_9(3^4)$ 正交实验方案结果作为训练学习样本集，对BP神经网络预测应用过程的策略进行了探讨，结果表明：完备的正交实验样本集是基本训练学习单元，在完备的正交实验样本集上添加或减少样本数量，所预测的结果是不可靠的；在同一类型、同一实验的条件下，完备的信息量大的正交实验样本集，能以很高的精度预测完备的信息量小的正交实验样本集；提出了一条新的实验设计思路——通过实验得出一个完备的正交实验样本集，通过计算机用BP神经网络就可以把与已知样本集有相同影响因素和水平的所有样本的值以相当高的精度预测出来，从而大大节省时间和劳力。

[关键词] BP 神经网络；正交实验；策略；实验设计思路；样本集

[中图分类号] TP183 **[文献标识码]** A **[文章编号]** 1009-1742 (2003) 07-0067-05

随着人工神经网络近半个多世纪的发展，尤其是对学习算法的不断研究，人工神经网络技术在许多领域的应用已发挥了巨大的潜能。由于人工神经具有自组织、自学习和对输入数据或规则的高容错能力，很适合处理趋势分析、预测和函数拟合等复杂问题^[1]。人工神经网络已在机械性能预测^[2]、铸件缺陷诊断与控制^[3,4]、非晶形成能力识别^[5]等方面得到应用。但是在这些研究中所取的样本数相当庞杂，并且带有许多随机性。在新材料的开发中，正交实验设计方法得到了广泛的应用。然而，人们通常要做许多正交实验才有可能开发出新的材料，这就给新材料的开发带来了很大的难度。能否结合人工神经网络和正交实验各自的优点为新材料的开发服务，至今尚未见报道。

笔者采用 $L_9(3^4)$ 正交实验，建立了3个不同的样本集，用BP神经网络对上述问题进行了探讨，结果表明：完备的正交实验样本集可以用做学习训练样本集，并且是学习训练样本集的基本单元，它对与正交实验有相同影响因素和水平的样本的预测精度很高，为科研人员提供了一条新的实验设计思

路。

1 BP 人工神经网络模型的建立

采用 $L_9(3^4)$ 型3组不同的正交实验：用湿砂铸造白口铸铁的正交实验，测出其硬度与冲击韧性作为1个样本集（见表1）；在相同制作

表1 样本集1

Table 1 Sample collection one

样本	C / %	Cr / %	Si / %	Mn / %	Cu / %	硬度 HRC	冲击韧性 / J·cm ⁻²
1	2.6	4.0	0.8	0.6	0.5	53.3	3.3
2	2.6	5.5	0.8	2.0	1.0	56.3	2.8
3	2.6	7.0	0.8	3.0	2.0	56.8	3.4
4	2.6	4.0	2.0	2.0	2.0	51.0	3.8
5	2.6	5.5	2.0	3.0	0.5	55.3	3.3
6	2.6	7.0	2.0	0.6	1.0	57.3	2.9
7	2.6	4.0	3.5	3.0	1.0	59.3	3.6
8	2.6	5.5	3.5	0.6	2.0	60.6	4.3
9	2.6	7.0	3.5	2.0	0.5	59.1	2.8

【收稿日期】 2003-03-15；修回日期 2003-05-12

【基金项目】 国家自然科学基金资助项目（59974011）

【作者简介】 蔡安辉（1970-），男，湖南新化县人，东南大学博士研究生

工艺和影响因素的条件下,用两组不同因素水平的关于磷酸盐石墨铸型的正交实验,分别测出其干抗拉强度和干抗压强度作为另2个样本集(见表2和表3)。用四输入、二输出且含有一个10节点隐含层的BP神经网络,输入和输出都为Sigmoid型函数的神经网络进行函数拟合,把各个影响因素作为网络的输入,对应条件下的性能值作为网络的输出,选取学习率为0.5。

表2 样本集2

Table 2 Sample collection two

样本	磷酸 /%	氧化铝粉 /%	温度 /℃	时间 /min	干抗压强度 /MPa	干抗拉强度 /MPa
1	18	16	400	40	0.905	0.08
2	21	16	500	100	0.571	0.128
3	24	16	600	150	1.269	0.242
4	18	18	500	150	0.897	0.193
5	21	18	600	40	0.482	0.296
6	24	18	400	100	1.081	0.234
7	18	30	600	100	0.646	0.175
8	21	30	400	150	1.293	0.213
9	24	30	500	40	2.221	0.467

采用下式对样本的输入与输出数值进行归一化:

$$x' = \frac{0.6}{x_{\max} - x_{\min}}(x - x_{\min}) + 0.2,$$

式中 x_{\max} , x_{\min} 是归一化前的输入和输出的最大值和最小值。

表3 样本集3

Table 3 Sample collection three

样本	磷酸 /%	氧化铝粉 /%	温度 /℃	时间 /min	干抗压强度 /MPa	干抗拉强度 /MPa
1	20	20	400	40	0.769	0.111
2	25	20	500	60	0.787	0.127
3	30	20	600	80	1.427	0.232
4	20	25	500	80	0.647	0.120
5	25	25	600	40	0.969	0.108
6	30	25	400	60	1.414	0.278
7	20	30	600	60	0.608	0.056
8	25	30	400	80	0.624	0.063
9	30	30	500	40	1.845	0.386

2 预测结果

2.1 以完备的样本集1为训练学习样本来预测

以完整的样本集1作为训练学习样本集,对与训练学习样本集有相同影响因素和水平的其他6个样本进行预测,期望误差设定为0.0001,总共训练学习了15 343次,预测结果与误差见表4中的样本1~6。

2.2 以不完备的样本集1为训练学习样本来预测

去掉样本集1中的第9个样本,把剩下的8个样本作为训练学习样本集,对被去掉的第9个样本进行预测,期望误差设定为0.0001,总共训练学习了16 650次,预测结果与误差见表4中的样本7。

表4 预测结果

Table 4 The forecasting results

样本	C/%	Cr/%	Si/%	Mn/%	Cu/%	硬 度			冲击韧性		
						实测值 HRC	预测值 HRC	误差/%	实测值/J·cm ⁻²	预测值/J·cm ⁻²	误差/%
1	2.6	4.0	2.0	2.0	1.0	54.6	54.233	-0.67	3.6	3.688	2.44
2	2.6	7.0	3.5	2.0	2.0	59.9	59.887	-0.02	3.6	3.828	6.33
3	2.6	7.0	2.0	2.0	1.0	57.0	56.312	-1.21	2.8	2.850	1.79
4	2.6	5.5	0.8	3.0	2.0	54.5	54.835	0.61	3.6	3.563	-1.03
5	2.6	5.5	2.0	2.0	1.0	56.1	56.038	-0.11	3.2	3.367	5.22
6	2.6	4.0	3.5	2.0	1.0	59.2	59.563	0.62	3.7	3.627	-1.97
7	2.6	7.0	3.5	2.0	0.5	59.1	55.537	-6.03	2.8	3.648	28.57

2.3 样本集2与样本集3独立互预测

样本集2与样本集3作为两个独立的样本集,用相同的初始化公式对样本集分别进行初始化。以样本集2作为训练学习样本集,对样本集3进行预

测,期望误差设定为0.0001,总共训练学习了23 788次;以样本集3作为训练学习样本集,对样本集2进行预测,期望误差设定为0.0001,总共训练学习了13 556次,两者的预测结果与误差见表5。

表5 预测结果

Table 5 The forecasting results

样本	以样本集2为训练样本集的预测结果				以样本集3为训练样本集的预测结果			
	干抗压强度/MPa	误差/%	干抗拉强度/MPa	误差/%	干抗压强度/MPa	误差/%	干抗拉强度/MPa	误差/%
1	0.767 6	-0.186	0.111 2	0.198	0.701 4	-22.50	0.145 5	81.915
2	0.797 9	1.38	0.125 0	-1.56	0.746 0	30.65	0.162 4	26.85
3	1.426 1	-0.065	0.232 2	0.071	1.628 9	28.36	0.287 0	18.61
4	0.646 6	-0.069	0.131 7	9.73	0.579 4	-35.41	0.206 2	6.82
5	0.961 8	-0.745	0.109 7	1.61	0.928 9	92.72	0.126 0	-57.44
6	1.409 8	-0.298	0.279 0	0.349	1.467 0	35.72	0.308 0	31.63
7	0.613 4	0.882	0.055 0	-1.866	0.485 0	-24.94	0.082 6	-52.77
8	0.625 9	0.31	0.063 0	-0.015	0.506 3	-60.84	0.117 1	-45.02
9	1.850 6	0.302	0.384 9	-0.285	2.225 3	0.196	0.466 2	-0.18

2.4 样本集2与样本集3作为一个样本集来预测

样本集2与样本集3进行统一初始化, 以样本集2作为训练学习样本集, 对样本集3进行预测, 期望误差设定为0.000 1, 总共训练学习了22 573次, 预测结果见表6; 样本集2中添加样本集3中第1个样本作为训练学习样本集, 对样本集3的其余样本进行预测, 期望误差设定为0.000 1, 总共训练学习了15 294次, 预测结果见表7; 样本集2中添加样本集3中前3个样本作为训练学习样本集, 对样本集3的其余样本进行预测, 期望误差设定为0.000 1, 总共训练学习了37 488次, 预测结果见表8中的样本1—6, 误差曲线见图1; 样本集2中添加样本集3中前8个样本作为训练学习样本集, 对样本集3中剩余的1个样本进行预测, 期望误差设定为0.000 1, 总共训练学习了130 428次, 预测结果见表8中的样本7, 误差曲线见图2。

表6 预测结果

Table 6 The forecasting results

样本	干抗压强度/MPa	误差/%	干抗拉强度/MPa	误差/%
1	1.661 9	116.11	0.245 7	121.35
2	1.509 5	91.80	0.425 1	242.95
3	1.823 1	27.76	0.495 2	113.45
4	0.955 9	47.74	0.216 2	80.17
5	1.622 8	67.47	0.510 0	372.22
6	2.374 0	67.89	0.520 1	87.09
7	1.198 8	97.17	0.340 1	507.3
8	2.452 3	293.00	0.455 1	616.03
9	2.290 8	24.16	0.530 0	37.31

表7 预测结果

Table 7 The forecasting results

样本	干抗压强度/MPa	误差/%	干抗拉强度/MPa	误差/%
1	1.291 8	64.14	0.300 5	136.61
2	2.580 1	80.81	0.546 4	135.52
3	0.437 7	32.35	0.089 2	25.67
4	2.127 4	119.55	0.518 6	380.19
5	2.552 9	80.54	0.537 5	92.37
6	1.266 0	108.22	0.374 7	569.11
7	1.568 6	151.38	0.293 2	365.40
8	2.694 9	46.07	0.566 7	46.81

表8 预测结果

Table 8 The forecasting results

样本	干抗压强度/MPa	误差/%	干抗拉强度/MPa	误差/%
1	0.420 3	35.04	0.077 9	35.08
2	2.094 1	116.11	0.501 7	364.54
3	2.296 4	62.40	0.457 2	64.46
4	1.662 5	173.44	0.468 5	736.61
5	1.916 1	207.07	0.398 6	532.70
6	2.625 0	42.28	0.526 5	36.40
7	1.537 6	152.89	0.343 6	513.57

3 结果分析

由表4可知, 以完备样本集训练学习, 能够对与训练样本集相同因素和水平的其余样本进行很好的预测, 精度较高, 能满足工程需要; 但是以不完备样本集训练学习, 即使只对与其构成完备样本集

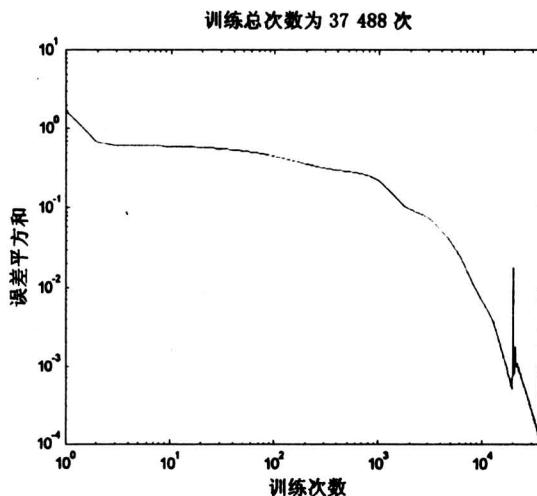


图 1 误差曲线

Fig. 1 The error curve

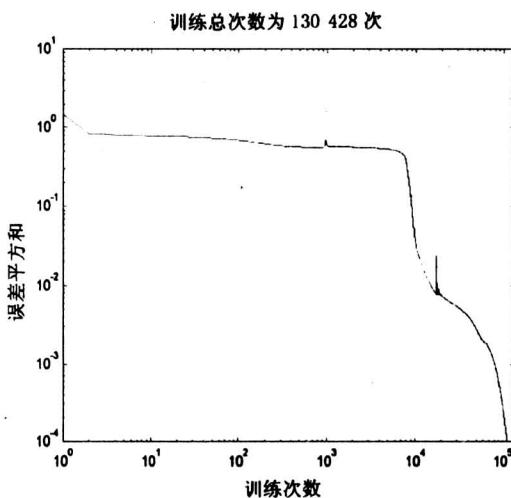


图 2 误差曲线

Fig. 2 The error curve

的其中 1 个样本进行预测，精度也很差。这与正交实验所得完备样本集空间和信息的高度对称性和代表性有关。

由表 5 可知，样本集 2 能对样本集 3 以极高的精度进行预测，但是样本集 3 不能对样本集 2 进行预测。因为，通过方差分析可知，影响铸型抗拉强度和抗压强度的因素是磷酸与氧化铝粉用量的比值以及烘干温度与烘干时间的乘积，正交实验所得的样本集信息量的大小即由这两个因素决定。从表 3 和表 2 来看，样本集 2 中的磷酸与氧化铝粉用量的比值以及烘干温度与烘干时间的乘积两个量分别为 $0.6 \sim 1.5$ 和 $16\ 000 \sim 90\ 000$ ；样本集 3 中的磷酸与氧化铝粉用量的比值以及烘干温度与烘干时

间的乘积两个量分别为 $0.67 \sim 1.5$ 和 $16\ 000 \sim 48\ 000$ 。因此，样本集 2 包含的重要信息量空间大于样本集 3 所包含的。BP 神经网络只能在所包含的空间中有很强的非线性映射能力，超出映射空间却无能为力，所以，以信息量大的样本集作为训练学习样本集去预测信息量小的样本集，精度很高；反之，则不行。

如果把样本集 2 与样本集 3 组合为 1 个样本集进行初始化，由表 6 可知，样本集 2 不能对样本集 3 进行预测，因为把两个样本集组合为一进行初始化，相当于把完备的正交空间中的信息分割给每个样本集，因而两个样本集中的信息都不完备，所以两者之间是不能进行互预测的。同样地，由表 7 和表 8 可知，其预测精度很差是可以理解的；由图 1 和图 2 的误差曲线可知，两个独立的正交实验样本集之间是不能进行统一初始化的。

4 结论

1) BP 神经网络有很强的非线性映射能力，能对它所训练过的样本集中的信息进行很好的学习，有很强的预测能力。

2) 由于正交实验所得的样本集在空间的高度代表性和信息全面性，因而用完备的正交实验样本集可以对与其影响因素和水平相同的样本以很高的精度进行预测；用信息量大的样本集能很好地对信息量小的样本集进行预测，精度也很高，而信息量小的样本集不能对信息量大的样本集进行预测。

3) 完备的正交实验样本集是实验设计的基本单元，通过人工神经网络完全可以在计算机上进行实验设计，这给科研人员提供了新的实验设计思路，从而大大节省时间和劳力。

参考文献

- [1] 从爽. 基于 METLAB 的神经网络原理及应用 [M]. 合肥: 中国科技大学出版社, 1998. 1~10
- [2] 王昌龙, 黄惟一. 用神经网络法预测集装箱角铸钢件的力学性能 [J]. 铸造, 2002, 51(4): 232~235
- [3] 徐建林, 陈超, 王智平, 等. 基于 MATLAB 的铸件缺陷分析与控制 [J]. 铸造, 2002, 51(6): 362~365
- [4] 路阳, 王智平, 刘在德, 等. 混合遗传算法在灰铸铁件缺陷诊断神经网络模型中的应用 [J]. 铸造, 2002, 51(3): 177~179
- [5] 蔡熠东, 许伟杰, 陈念贻. 自组织人工神经网络在氟化物非晶态形成的判别条件中的应用 [J]. 无机化学学报, 1994, 10(2): 151~154

Research on the Forecast of the BP Neural Network Based on the Orthogonal Test

Cai Anhui, Liu Yonggang, Sun Guoxiong

(Department of Technical Engineering, Southeast University, Nanjing 210096, China)

[Abstract] The strategy for forecasting the BP neural network was researched on the basis of the training-studying samples that were obtained in the orthogonal test of $L_9(3^4)$. The self-contained orthogonal sample was the basic training and studying cell. When others samples were added into the self-contained orthogonal samples or the self-contained orthogonal samples were cut down, the forecasting results were completely irresponsible. On the same test condition and orthogonal test type, the self-contained orthogonal sample with large information content could forecast that with small information content at high precision. A new test-design approach was put forward. Namely, the self-contained orthogonal sample was obtained through the orthogonal test, and then, the values of all other samples whose factors were the same as that of the self-contained orthogonal sample could be forecast in the BP neural network and its precision was considerable high. Therefore, the time and labors were enormously saved.

[Key words] BP neural network; orthogonal test; strategy; design-test approach; sample collection

(上接第46页)

参考文献

- [1] He Ping. Non-optimum system theory and methods [A]. Fuzzy Sets and System [C]. First Joint IFSA-EC Workshop Press, 1986. 58~62
- [2] 何平. 系统非优理论的现实源泉与应用展望 [J]. 系统工程, 1989, 2 (7): 1~5
- [3] 何平. 系统非优判别指导系统 [J]. 控制与决策, 1989, 3 (4): 18~21
- [4] 苗东升. 系统科学精要 [M]. 北京: 中国人民大学出版社, 1998
- [5] 何平. 探讨经济系统的新方法 [M]. 大连: 大连理工大学出版社, 1989
- [6] 何平. 系统非优理论的进一步研究与探讨 [A]. 物元与系统理论 [C]. 大连: 大连理工大学出版社, 1991

System Non-optimum Analysis Theory and Method

He Ping

(Liaoning Policeman Collage, Dalian, Liaoning 116033, China)

[Abstract] This paper discusses non-optimum analysis theory of system and points out main problem of exploring indefinite system optimization. The key is short of the non-optimum analysis to the system. The article establishes symptom covey and empirical analysis based on non-optimum category of the system, and puts forward that system is degree measured along with non-optimum traced up to systematic self-organization and so on.

[Key words] the non-optimum category of system; non-optimum symptom covey; non-optimum magnanimity; systematic self-organization