

## 中厚板轧机应力状态系数神经网络模型

孟令启<sup>1</sup>, 王建勋<sup>1</sup>, 雷明杰<sup>1</sup>, 吴浩亮<sup>1</sup>, 聂孟辉<sup>2</sup>

(1. 郑州大学 机械工程学院, 河南 郑州 450001; 2. 洛阳铝业集团股份有限公司, 河南 洛阳 471500)

**摘 要:** 为寻求计算应力状态系数的新方法, 以 4200 轧机轧制的大量实测数据为基础, 利用 Matlab 神经网络工具箱, 以轧制前、后钢板厚度为输入神经元, 以实测轧制压力并依靠压力公式进行逆运算获得的  $Q_p$  为输出神经元, 建立了轧制变形区的应力状态系数与轧件轧制前后钢板厚度对应关系的 BP 神经网络模型和 GRNN 神经网络模型. 结果表明, 用人工神经网络算法预测应力状态系数是可行的; 且通过 GRNN 神经网络模型和 BP 模型的对比, 说明 GRNN 网络具有更高的精度和更强的泛化能力.

**关键词:** 应力状态系数; 人工神经网络; 中厚板轧机

**中图分类号:** TG 331

**文献标识码:** A

### 0 引言

在轧制压力计算过程中, 影响单位压力的因素很多, 如金属化学成分和组织、变形温度、变形速度、外摩擦、外区金属、张力因素等<sup>[1]</sup>. 这些因素对单位压力的影响, 称为应力状态影响系数<sup>[2]</sup>. 金属变形时的应力状态系数  $Q_p$  是轧制理论的重要参数之一, 受外区、摩擦系数、轧件与轧辊的接触面积和工具形状等一系列因素的制约, 这些因素之间又存在相互联系、相互制约的复杂关系, 因此  $Q_p$  不能直接检测, 通常采用实测轧制压力, 并通过压力公式进行逆运算获得间接测量值作为  $Q_p$  的实测值<sup>[3]</sup>.

人工神经网络在非线性系统建模和控制中的应用具有坚实的理论基础<sup>[4-7]</sup>. 近年来, 在各领域的预测和控制中, 最常使用的学习方法是误差反向传播法 (BP 算法). 广义回归神经网络 (GRNN 网络) 是利用径向基神经元和线性神经元建立起来的网络, 具有很强的非线性映射能力、柔性网络结构、高度的容错性和鲁棒性, 适用于非线性问题的研究. 笔者借助 Matlab 神经网络工具箱, 应用 BP 网络和 GRNN 网络分别建立了特定轧制工艺下的金属应力状态影响系数的神经网络模型, 并对该模型进行了仿真实验.

### 1 试验数据的确定

影响应力状态系数  $Q_p$  数值的因素很多: 主

要参数是变形区长度与轧制前后轧件平均厚度之比  $l/h_c$ 、变形程度  $\varepsilon$ 、摩擦系数  $f$  以及轧前厚度与轧辊直径之比  $H/D$  等. 在一定的试验条件下, 摩擦系数近似为常数. 传统的数学模型以  $l/h_c$  和  $H/D$  为变量的应力状态影响系数模型更能反映中厚板轧机应力状态的内在规律, 揭示了应力状态各影响因素的状况, 其数学模型<sup>[1]</sup>如下:

当  $l/h_c \leq 1$  时,

$$Q_p = 3.938 - 3.031l/h_c + 0.762H/D + 1.303(l/h_c)^2 - 11.783(l/h_c)(H/D) - 3.594(H/D)^2 \quad (1)$$

当  $l/h_c > 1$  时,

$$Q_p = 8.468 - 2.838l/h_c - 145.996H/D - 0.899(l/h_c)^2 - 69.075(l/h_c)(H/D) + 399.290(H/D)^2 \quad (2)$$

由传统的数学模型可知, 影响应力状态系数的主要参数是  $l/h_c$ 、 $H/D$  等. 因此, 应力状态的影响因素可以归结为钢板的轧前厚度  $H$ 、轧后厚度  $h$  及轧辊直径  $D$ . 而轧制生产中, 轧机的轧辊直径一般相对不变, 最终确定影响应力状态系数因素为钢板的轧前厚度  $H$  和轧后厚度  $h$ . 即确定网络模型的输入层参数为钢板的轧前厚度  $H$  和轧后厚度  $h$ ; 输出层参数为应力状态影响系数  $Q_p$ .

所用的训练数据是以 4200 轧机采用 71 块钢板 (其中 SS41 11 块, Q235-A 10 块, Q235-B 30 块, SM50B-1 20 块), 697 个轧制道次, 实测轧制

收稿日期: 2008-11-08; 修订日期: 2008-12-22

基金项目: 国家自然科学基金资助项目 (10176010)

作者简介: 孟令启 (1963-), 男, 安徽蚌埠人, 郑州大学教授, 博士, 主要从事金属材料的加工与控制研究.

前、后钢板厚度以及通过测轧制压力并依靠压力公式进行逆运算获得  $Q_p$  的间接测量值作为数据. 选取以轧辊直径  $D=980\text{ mm}$  时轧制的 280 组实验数据作为训练数据,另取 280 组以外的 20 组数据作为测试数据,以检测网络的性能.

由于参加训练的数据较多且分散,为保证网络在训练过程中收敛,在进行网络训练之前将实验数据进行标准化处理,使它们处于区间  $[0,1]$

之间,以便于网络的快速拟合<sup>[6]</sup>. 笔者采用的输入参数标准化方法为:

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \tag{3}$$

式中: $x'$ 为归一化的值; $x$ 为原始值; $x_{\max}$ 为该组变量的最大值; $x_{\min}$ 为该组变量的最小值.

归一化后部分样本数据如表 1 所示.

表 1 部分样本数据  
Tab.1 Part of sample data

样本号	输入向量		输出向量	样本号	输入向量		输出向量
1	0.949 69	0.940 3	0.198 86	296	0.823 90	0.791 04	0.107 43
2	0.226 42	0.231 34	0.605 33	297	0.672 96	0.686 57	0.454 55
3	0.603 77	0.604 48	0.391 05	298	1.000 00	1.000 00	0.232 53
4	0.484 28	0.462 69	0.279 28	299	0.962 26	0.955 22	0.207 44
⋮	⋮	⋮	⋮	300	0.050 314	0.059 701	0.999 01

2 神经网络模型的建立

2.1 BP 网络模型的训练及确定<sup>[5-6]</sup>

BP 网络模型是一种多层感知器结构的反向传播模型,结合本试验数据,确定神经网络输入层神经元为 2 个,输出层神经元为 1 个,神经网络层数设为 3 层.训练函数采用 trainlm 算法函数,通过调整网络的权值和阈值使网络误差的平方和最小.

对于笔者所建立的网络模型,隐含层神经元的个数会影响网络的性能,因此设置合理的隐含

层神经元个数会大大提高网络的预测精度,提高网络的性能.首先根据经验公式进行神经元数的计算,然后针对具体应用通过实验选择使网络具有足够泛化能力和足够输出精度的隐层神经元.因此需要对不同的隐含层神经元个数分别进行实验,以确定最佳的网络结构.通过 Matlab 神经网络工具箱编程,隐含层单元的传递函数取正切 S 形函数,输出单元取 Logsig 函数,得到隐含层神经元个数  $A$  取不同值时网络的训练结果,如表 2 所示.

表 2 网络参数/训练参数/训练结果  
Tab.2 Parameters of network/training parameters/training results

网络参数		训练参数		训练结果		
				隐层神经元个数 A	训练次数	训练精度
					实际/目标	实际/目标
训练函数	trainlm	训练次数	500	4	132/500	0.000 996 905/0.001
		训练目标	0.001	5	98/500	0.000 999 691/0.001
学习函数	learnlm	学习速率	0.1	6	136/500	0.000 990 462/0.001
				7	94/500	0.000 976 390/0.001

由表 2 可知,当隐含层神经元数为 5 时,网络实际训练次数较少,为 98 次,效率较高;网络实际输出均方差与目标值 0.001 最为接近,拟合程度最好,训练精度最高.因此最终确定 BP 模型的隐含层神经元个数为 5,此时模型的训练过程如图 1 所示.

2.2 GRNN 网络模型的训练及确定<sup>[7]</sup>

广义回归神经网络 (GRNN) 是径向基网络的一种,具有训练时间短、仿真精度高等特点. GRNN 的网络结构如图 2 示,由一个径向基网络

层和一个线性网络层组成,  $a_{1i}$  表示第 1 层输出  $a_1$  的第  $i$  个元素,  $W_i$  表示第 1 层权值矩阵  $W_1$  的第  $i$  个元素.  $P$  表示输入向量,  $R$  表示网络输入的维数,  $S$  表示每层网络的神经元个数,同时还表示训练样本的个数,  $b_1$  为隐含层阈值. 符号“ $\otimes$ ”表示  $\| \text{dist} \|$  的输出与阈值  $b_1$  的元素与元素之间的乘积关系. 隐含层采用径向基函数 (一般为高斯函数) 作为激励函数. 网络的第 2 层为线性输出层, 其权函数为规范化点积权函数, 传递函数为  $a_2 = \text{purelin}(n_2)$ , 从而计算网络输出.




图 1 BP 网络的训练过程

Fig. 1 Training process of BP network

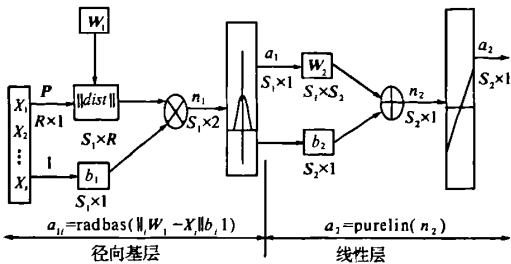


图 2 广义回归神经网络结构

Fig. 2 Structure of generalized regression neural network

GRNN 网络具有自动确定网络结构,输出与初始权值无关等优良特性.用 MATLAB 语言建立 GRNN 网络:Net = newgrnn(P,T,spread).

其中,P 为输入向量,T 为输出目标向量,spread 为光滑因子,其值的大小对网络的最终逼近精度有着较大的影响.光滑因子值越大,函数越平滑,但是,无穷大的光滑因子意味着需要非常多的神经元来适应函数的快速变化,导致计算困难,而过小的光滑因子可能会导致所设计的网络性能不好.因此,在网络设计中,需要调整光滑因子的

值,直到达到比较理想的精度.网络模型建立后,已完成对网络的训练,无需对网络再进行训练,只需合理选择光滑因子.笔者分别取光滑因子为 0.01、0.02、0.03、0.04 和 0.05,采用相同的样本进行不同光滑因子值下的网络建模,网络的输入和输出设置一样,记录实际仿真时的测试误差,以比较网络性能.

3 模型预测及结果分析

采用表 1 中的后 20 组输入向量样本数据进行 BP 网络仿真和 GRNN 网络仿真,将仿真值与表 1 中输出向量实测值进行比较,得到 BP、GRNN 网络的仿真结果如图 3、表 3 所示.可以看出,所建立的 BP 网络和 GRNN 网络均建立了金属应力状态系数输入和输出关系.表 3 所建立的 BP 网络拟合性能较好,应力状态系数仿真值与实测值之间的相对误差在 -2.557 4% ~ 4.205 7% 之间,精度很高,远远满足神经网络预测精度 15% ~ 20% 的要求.但在实验仿真中发现,BP 网络数据不稳定,这是因为 BP 网络的输出与初始权值的随机性有关.相比之下,GRNN 网络数据较为稳定.图 3 显示的是网络模型的光滑因子取 0.01、0.02、0.03、0.04 和 0.05 时的 GRNN 预测结果.从图中可以看出:当 spread 取 0.01 时,预测性能最优,仿真值与实测值之间的相对误差在 -0.268 9% ~ 0.789 6% 之间,说明所建立的网络模型已有很好的泛化能力;并且可以看出光滑因子是影响 GRNN 网络模型性能的重要因素,光滑因子越小,网络对样本的逼近性能就越强,随着光滑因子的增加,误差也在不断地增大.因此确定选用光滑因子为 0.01 的 GRNN 网络模型做为金属应力状态系数预测模型,并与 BP 网络建立的模型作比较.

表 3 BP 网络仿真结果

Tab. 3 Simulation result of BP network

样本 序号	网络输 出值	实测值	相对误 差/%	样本 序号	网络输 出值	实测值	相对误 差/%
1	0.716 76	0.706 98	-1.382 90	11	1.624 30	1.681 80	3.416 10
2	0.985 98	1.019 50	3.292 30	12	1.179 30	1.178 10	-0.105 56
3	0.752 76	0.756 73	0.524 44	13	1.544 30	1.548 20	0.253 12
4	0.974 68	0.993 67	1.911 00	14	1.389 30	1.355 30	-2.507 00
5	1.288 70	1.291 40	0.214 63	15	1.065 70	1.079 40	1.267 70
6	0.708 12	0.690 47	-2.557 40	16	0.795 10	0.800 36	0.657 92
7	0.928 76	0.927 12	-0.177 25	17	1.179 20	1.190 80	0.975 60
8	0.778 41	0.784 12	0.727 29	18	0.941 07	0.941 08	0.000 98
9	0.710 82	0.695 96	-2.134 70	19	0.915 42	0.912 86	-0.279 64
10	0.974 68	0.993 67	1.911 00	20	1.727 40	1.803 20	4.205 70




图3 GRNN网络仿真结果

Fig.3 Simulation result of GRNN

将BP网络模型和GRNN网络模型的仿真误差相比较,如图4所示。由图4可以明显看出GRNN网络模型的仿真精度远远高于BP模型的精度。同BP网络相比,在建模和预测过程中GRNN模型表现出了数据稳定、操作简单、预测精度高的特点,其网络性能更优,实现了与实测结果的高度拟合。




图4 两种模型仿真分析结果的比较

Fig.4 Comparison of simulation results between two models

## Artificial Neural Network of the Stress State Modulus Model of Medium Plate Mill

MENG Ling - qi<sup>1</sup>, WANG Jian - xun<sup>1</sup>, LEI Ming - jie<sup>1</sup>, WU Hao - liang<sup>1</sup>, NIE Meng - hui<sup>2</sup>

(1. School of Mechanical Engineering, Zhengzhou University, Zhengzhou 450001, China; 2. China Molybdenum Co. Ltd., Luoyang 471500, China)

**Abstract:** To find a new method of calculating the stress state modulus, according to a large number of experimental data in 4200 rolling mill, BP and GRNN prediction models are established for the relationship between stress state modulus which is the output element and thickness which is the input element before and after rolling by Matlab neural network toolbox. The results indicate that using the algorithm of artificial neural network is feasible, and compared with the model of BP neural network GRNN model has better accuracy and adaptability.

**Key words:** stress state modulus; artificial neural network; medium plate mill

## 4 结论

(1) 人工神经网络能很好地预测应力状态系数  $Q$ , 随轧制前后轧件厚度变化的情况, 实现了与试验结果的高度拟合, 表明该方法具有取代部分实验的能力, 与传统数学回归模型相比, 该方法具有计算时间短、精度高的特点。

(2) 通过建立金属应力状态系数 BP 神经网络模型和 GRNN 神经网络模型, 比较发现 GRNN 神经网络模型能更好地预测金属的应力状态系数, 性能更优, 具有更高的精度和更强的泛化能力, 实现了与实测结果的高度拟合。

## 参考文献:

- [1] 孟令启. 中厚板轧机测量测试与力学行为建模 [M]. 郑州: 黄河水利出版社, 2006: 219 - 263.
- [2] 邹家祥. 轧钢机械 [M]. 北京: 冶金工业出版社, 1989. 32 - 43.
- [3] 葛懋琦, 程晓茹, 陈贻宏, 等. 高韧性热轧管线用钢轧制压力模型 [J]. 钢铁研究学报, 1997, 9(4): 18 - 23.
- [4] 孟令启, 王海龙, 马金亮, 等. 基于 RBF 神经网络的金属应力状态系数模型 [J]. 郑州大学学报: 工学版, 2007, 28(1): 1 - 5.
- [5] 韩丽琦, 臧勇, 邹家祥, 等. 基于人工神经网络的热轧碳钢变形抗力预报 [J]. 北京科技大学学报, 2001, 23(2): 131 - 133.
- [6] 魏立群. 基于 MATLAB 的 BP 网络预报 2350 中板轧制力能参数 [J]. 上海金属, 2005, (4): 43 - 49.
- [7] 孟令启. 基于 GRNN 神经网络的 4200 轧机宽展模型 [J]. 钢铁研究学报, 2008, 20(3): 23 - 26.