

文章编号:1671-6833(2007)01-0001-05

基于 RBF 神经网络的金属应力状态系数模型

孟令启,王海龙,马金亮,徐如松

(郑州大学 机械工程学院,河南 郑州 450001)

摘要:以 4 200 mm 热轧轧制 71 块钢板的实测数据为基础,利用 Matlab 人工神经网络工具箱,建立了轧制变形区的应力状态系数的 RBF 神经网络预测模型.通过分析应力状态系数的影响因素,结合传统的数学模型,确立了网络的输入层参数,并对函数 newrb() 中宽度系数 spread 的试验调整,确定了最佳的网络结构形式,提高了模型的预测精度以及网络的泛化能力.测试结果表明,RBF 网络模型具有很好的推广能力.与传统的 BP 神经网络模型相比较,结果表明,RBF 网络具有更高的精度和更好的泛化能力.

关键词:应力状态影响系数;RBF 神经网络;模型

中图分类号:TF 3

文献标识码:A

0 引言

轧制变形区的应力状态是影响轧制压力的一个重要因素,应力状态影响系数 Q_p 模型一直是轧制理论的核心问题^[1].传统的 Q_p 数学模型建立在分析大量数据的基础上,利用数值回归方法得到.由于 Q_p 的数值不能直接检测,所以数值回归需要的 Q_p 数值是间接测量值^[2],通过测得轧制压力 P 、轧辊转速 n 、轧件温度 T 、辊距 S 、轧件宽度 b 、钢中化学成分 $x\%$ 、轧制时间 t 等参数,利用适宜的轧制压力数学模型可得到应力状态系数 Q_p ,然后分析影响应力状态系数的因素,选取其中的主要因素作为参数进行数值回归运算.利用这种方法得出 Q_p 模型,由于轧制压力模型本身的误差,以及所选参数的简化,其精度和可靠性受到较大的影响.

人工神经网络(Artificial neural networks, ANN)具有适应性强和能够处理复杂非线性问题的特点,广泛应用于解决非线性系统以及模型未知系统的预测和控制^[3,4].运用神经网络建立有关的预测模型与传统的方法相比,不需要假设数学模型的类型,可以考虑更多的影响因素作为输入参数,直接实现输入参数与结果之间的非线性映射关系,因而避免了上述误差,方便计算机实现自动化控制.近些年来传统的 BP 反向传播网络

在各个领域的预测和控制中得到广泛应用,但是由于收敛速度慢,易陷入局部最小,会最终影响预测效果,而 RBF(径向基函数)神经网络具有全局逼近性质和最佳逼近性能,能较好地反映系统的实际情况,故作者尝试用 RBF 神经网络建立应力状态系数的预测模型.

1 RBF 神经网络的结构^[3]

RBF 神经网络的学习等价于在多维空间中寻找训练数据的最佳拟合平面.一个典型的径向基函数网络包括三个层:输入层、隐含层和输出层,其网络结构如图 1 所示.




图1 RBF神经网络

Fig.1 RBF neural network

输入层只是传递信号到隐含层,对输入信号不进行任何变换.隐含层神经元的作用函数可以是高斯函数、多二次函数、逆多二次函数等,通常

收稿日期:2006-09-28;修订日期:2006-11-13

基金项目:国家自然科学基金资助项目(10176010)

作者简介:孟令启(1962-),男,安徽蚌埠市人,郑州大学副教授,主要从事轧钢机械工程方面的研究工作.

情况下选用高斯函数

$$\varphi(r) = \exp\left(-\frac{(r-t)^2}{2\sigma^2}\right) \quad (\sigma > 0; r \in R) \quad (1)$$

式中: t 为高斯函数的中心; σ 为方差. 它具有形式简单、径向对称、光滑性好和存在任意阶导数的优点. 则网络隐含层的输出响应为

$$\begin{aligned} G(X_k, X_i) &= G(\|X_k - X_i\|) \\ &= \exp\left(-\frac{1}{2\sigma_i^2} \|X_k - X_i\|^2\right) \\ &= \exp\left(-\frac{1}{2\sigma_i^2} \sum_{j=1}^n (x_{kj} - x_{ij})^2\right) \quad (2) \end{aligned}$$

式中: $X_k (k = 1, 2, \dots, n)$ 为输入矢量; X_i 为高斯函数的中心; σ_i 为高斯函数的方差. 隐含层神经元对输入激励产生一个局部化的响应, 即每一个隐节点有一个参数矢量称为中心, 该中心用来与网络输入矢量相比较以产生径向对称响应, 仅当输入落在一个很小的指定区域中时, 隐节点才作出有意义的非零响应, 响应值在 0 ~ 1 之间, 输入与基函数中心的距离越近, 隐节点响应越大.

输出层神经元的作用函数是对隐含层神经元输出的信号进行线性加权后输出, 作为网络的输出结果. 网络第 i 个输出神经元的实际输出为

$$y_i = \sum_{j=1}^r G_j \omega_{ij} \quad (3)$$

式中: ω_{ij} 是隐含层与输出层之间的连接权; r 为隐节点的数目.

RBF 网络要学习的参数有 3 个: 基函数的中心、方差及权值. 其学习过程分为两个阶段: 第一阶段为预处理阶段, 可以采用模式识别中无教师学习方法, 根据各聚类中样本数据的位置分布情况求出高斯基函数的中心矢量 X_i 和方差 σ_i , 也可从样本中随机选取这些值; 第二阶段为权值的学习阶段, 在隐层参数确定好后, 可以采用 LMS 算法求出网络输出层的权矩阵 W .

作者采用 Matlab 神经网络工具箱设计 RBF 网络. RBF 神经网络的 Matlab 实现函数为

$$\text{net} = \text{newrb}(P, T, \text{goal}, \text{spread}, \text{MN}, \text{DF})$$

式中: P 为输入矢量; T 为目标输出矢量; goal 为设定误差的平方和, 默认值为 0; spread 为径向基函数的宽度系数, 默认值为 1; MN 为隐层最大神经元个数, 默认为输入样本的组数; DF 为增加神经元的显示频率, 默认为 25. 用此函数设计 RBF 网络, spread 的取值直接影响到网络的拟合和泛化, 可通过试验选取, 通过比较网络的预报误差得到最优值^[5].

万方数据

2 应力状态影响系数神经网络模型的构建

2.1 传统的应力状态影响系数模型^[5,6]

应力状态系数反映外摩擦、轧件与轧辊接触面积、工具形状、轧件尺寸等对轧制力的影响, 因而影响其数值的因素很多, 根据现场实测和实验室研究认为影响应力状态的主要参数是 l/h_c , ε , f , H_0/D 等. 在一定的试验条件下, 摩擦系数近似为常数. 大多数数学模型理论公式形式各异, 但根本区别就在于选用的变量不同. 例如 Bland-Ford 理论的 δ 函数, 以及 Hill 理论的 Q_p 简化式以 H_0/D 和 ε 为自变量, 俄国一些学者提出的以 l/h_c 和 ε 作为自变量. 作者分别以 H_0/D 和 ε , l/h_c 和 ε , l/h_c 和 H_0/D 为变量, 通过多元回归分析, 代入 71 块钢板, 697 个轧制道次的实测工艺参数, 建立相应的应力状态影响系数的数学模型. 通过方差以及反算结果分析, 以 l/h_0 和 H_0/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:

$$Q_p = 3.938 - 3.031l/h_c + 0.762H_0/D + 1.303(l/h_c)^2 - 11.783(l/h_c)(H_0/D) - 3.594(H_0/D)^2 \quad (l/h_c \leq 1) \quad (4)$$

$$Q_p = 8.468 - 2.838l/h_c - 145.996H_0/D - 0.899(l/h_c)^2 + 69.075(l/h_c)(H_0/D) + 399.290(H_0/D)^2 \quad (l/h_c > 1) \quad (5)$$

这说明传统的数学模型变量的选择对模型的适用性有着较大的影响.

2.2 RBF 网络结构分析

由传统的应力状态系数数学模型的建立可知, 影响应力状态系数的主要参数是 l/h_c , ε , f , H_0/D 等. 因此, 要掌握这样一个非常复杂的过程参数的基本内在规律, 关键在于如何选取作为自变量的参数, 以便能更确切地反映外区、外摩擦以及轧件与轧辊的接触面积和工具形状等因素的综合规律. 应力状态的影响因素最终可以归结为钢板的轧前厚度 H_0 、轧后厚度 H_1 、轧辊直径 D 对应力状态影响系数的影响, 根据实际情况, 以 $D = 980, 950, 910$ mm 这 3 种情况分别对应建立应力状态系数的 3 个网络模型: net1 、 net2 、 net3 , 再分别用这 3 种情况下的试验数据进行训练. 网络模型的输入层参数为: 钢板的轧前厚度 H_0 、轧后厚度 H_1 、轧辊直径 D ; 输出层参数为: 应力状态影响系数 Q_p .

隐含层神经元的个数是影响网络性能的重要

因素. 由于 Matlab 实现的 RBF 网络隐层的默认值为样本数目. 取默认值可能会造成过拟合现象, 影响泛化能力. 正确的做法是通过试验选取泛化性能最优的隐含层数目, 提前结束网络的训练.

2.2 网络模型的训练及确定^[7]

RBF 神经网络的 Matlab 实现函数为:

$$\text{net} = \text{newrb}(\boldsymbol{P}, \boldsymbol{T}, \text{goal}, \text{spread}, \text{MN}, \text{DF})$$

式中: \boldsymbol{P} 为输入矢量; \boldsymbol{T} 为目标输出矢量; goal 为设定误差的平方和, 默认值为 0; spread 为径向基函数的宽度系数, 默认值为 1; MN 为隐层最大神经元个数, 默认为输入样本的组数; DF 为增加的神经元的显示频率, 默认为 25 个. 用此函数设计 RBF 网络, 宽度系数 spread 的取值直接影响到网络的拟合和泛化, 可通过实验选取, 通过比较网络的均方差 (MSE) 得到最优值.

通过对网络模型的训练, 确定最佳的隐含层神经元的个数, 以最终确定网络的结构. 训练过程所用的样本数据是以 4 200 mm 轧机实测 71 块钢板, 697 个轧制道次的实测数据, 其中 SS41 11 块, Q235 - A 10 块, Q235 - B 30 块, SM50b - 1 20 块, 选取以 $D = 980, 950, 910$ mm 这 3 种情况下轧制的 450 组实验数据训练网络, 每个网络用 150 组数据训练, 测试样本对应选取 450 组以外的 48 组数据.

对 3 个网络分别进行训练, 逼近误差统一设定为 0.001, 隐含层神经元个数最大值暂设为 150. 对于每个网络选取不同的宽度系数 spread 进行实验以确定最佳的网络结构. 以网络 “net1” 为例, 其在不同的 spread 时的网络训练结果见表 1.

表 1 RBF 网络训练结果

Tab. 1 Training results of RBF neural network

宽度系数	训练次数 (隐含神经元数)	拟合 均方差	泛化 均方差	训练用时 /s
1	143	0.067 2	1.075 3	37.8
5	118	0.002 9	0.045 8	15.2
7	132	0.324 2	5.187 0	15.8
10	81	0.001 0	0.016 0	8.5
13	113	0.067 1	1.072 9	12.1
15	119	0.041 4	0.663 0	13.5

由表 1 知, 在 $\text{spread} = 10$ 时, 测试样本的均方差最小, 泛化性能最好. 因此 RBF 网络模型的最大隐含层神经元定为 81. 此时, 网络的设定参数为

$$\text{goal} = 0.001; \text{spread} = 10; \text{MN} = 90; \text{DF} = 1; \text{net} = \text{newrb}(\boldsymbol{P}, \boldsymbol{T}, \text{goal}, \text{spread}, \text{MN}, \text{DF}).$$

网络的训练过程如图 2 所示.




图 2 网络 “net1” 的训练过程

Fig. 2 Training process of network “net1”

仿照网络 “net1” 的方法, 可以分别确定网络 “net2” 和网络 “net3” 的最佳参数. 对于网络 “net2”: 在 $\text{spread} = 4$ 时, 最小拟合均方差为 0.005 1, 最大隐含层神经元个数为 131, 网络训练过程如图 3. 对于网络 “net3”: 当 $\text{spread} = 6$ 时, 最小拟合均方差为 0.002 5, 最大隐含层个数为 115, 网络训练过程如图 4. 从图 2、3、4 中可以看到在 3 个网络训练过程中的误差变化情况, RBF 网络从隐含层神经元为 0 时开始训练, 训练样本循环计算一次, 网络的输出误差若大于设定误差, 则产生一个新的隐含层神经元, 如此 3 个网络分别经过 81 次、131 次、115 次迭代运算后, 曲线的拟合误差均降到了 0.001 以下, 达到设定误差, 网络停止训练. 虽然 3 个网络经过训练后, 其逼近误差均达到了要求, 但是, 网络 “net1” 的拟合均方差为 0.001, 三者之中为最小值, 预测精度最好, 并且其逼近速度快, 说明其性能要好于其它两个网络.




图 3 网络 “net2” 的训练过程

Fig. 3 Training process of network “net2”

3 模型的测试及结果分析

另取 450 组训练数据以外的 48 组数据分别

对 3 个网络进行测试,测试数据的网络输出应力状态系数和实测应力状态系数的对比如表 2 所示.




图 4 网络“net3”的训练过程

Fig. 4 Training process of network “net3”

表 2 网络输出值与实测值的对照

Tab. 2 Comparison of predicted using neural network and measured

网络	网络预测值	实测值	相对误差/%	网络预测值	实测值	相对误差/%
net1	0.899 9	0.895 2	0.522	1.137 5	1.177 3	-3.499
	0.866 2	0.860 2	0.693	1.519 1	1.539 0	-1.310
	0.781 6	0.781 2	0.051	1.325 0	1.345 5	-1.547
	0.917 5	0.917 6	-0.011	1.371 3	1.368 3	0.219
	0.822 6	0.821 7	0.109	1.343 9	1.344 4	-0.037
	0.677 7	0.690 5	-1.889	1.287 8	1.286 0	0.140
	1.182 8	1.178 1	0.397	1.779 0	1.800 4	-1.203
net2	1.041 2	1.039 3	0.182	1.180 0	1.112 8	5.695
	0.870 3	0.873 9	-0.414	1.053 1	1.076 8	-3.808
	0.839 8	0.839 7	0.012	1.014 3	1.268 0	-6.162
	0.759 0	0.762 0	-0.395	1.286 9	1.295 3	-0.653
	0.890 0	0.902 0	-1.348	1.170 1	1.175 7	-0.479
	0.806 1	0.800 9	0.645	1.347 8	1.344 0	0.282
	0.670 9	0.673 4	-0.373	1.223 6	1.275 0	-4.201
net3	1.106 9	1.110 3	-0.307	1.675 1	1.651 6	1.403
	0.974 6	0.975 6	-0.103	1.390 9	1.385 0	0.424
	0.831 5	0.839 4	-0.950	0.952 9	0.952 6	0.031
	0.766 6	0.777 2	-1.383	0.951 4	0.888 9	6.569
	0.749 5	0.750 1	-0.08	1.025 0	1.089 1	-6.254
	0.842 0	0.897 4	-6.58	1.295 0	1.295 2	-0.015
	0.778 4	0.778 5	-0.013	1.301 5	1.297 0	0.346
	0.730 5	0.701 0	4.038	1.243 3	1.242 7	0.048
	0.497 6	0.516 6	-3.818	1.736 5	1.731 6	0.282
	1.071 3	1.070 0	0.121	1.434 6	1.433 0	0.112

由上述知,作者所建模型的预测精度很高. 经计算分析,传统的数学模型得到的预测值和实测值之间的误差达到 10%,与之相比,RBF 网络的预测精度远大于传统的数学模型的精度,充分体现了神经网络预测模型在精度方面的优势^[8-10]. 同时,神经网络模型的建立仅用较少的实验数据(150 组),模型就达到了 0.001 的设定精度. 作者针对不同的轧辊直径 D 建立了不同的网络模型,减少了输入参数的变化,不同直径的轧

由表 2 中 3 个网络的预测结果和实测应力状态系数对比,可以看出相对误差绝大多数在 3% 范围以内,较大的预测误差是由所选轧制力数学模型本身的误差以及实验的偶然性因素造成的,其中网络“net1”的预测误差几乎都在 3% 以内,明显好于其它两个网络,说明随着轧辊磨损,模型的预测精度逐渐降低. 工作辊直径与网络模型的精度成正向关系. 因此,在编制轧制规程时,应尽量把辊径定在 980 ~ 960 mm 范围内.

辊在轧制时采用不同的网络模型,客观上也提高了所建网络模型的预测精度.

为了将作者提出的 RBF 网络预测模型与传统的 BP 网络相比较,笔者用 Matlab 神经网络工具箱又设计了应力状态系数的 BP 网络模型,输入层参数和 RBF 网络一样为 3 个,隐含层确定为 9 个,输出节点 1 个,网络误差也设定为 0.001,经过网络 589 次误差反传调整权值和阈值后,其输出结果与 RBF 网络的比较见表 3.

表 3 RBF 网络和 BP 网络的预测结果的比较

Tab. 3 Comparison of predicted using RBF and

项目	BP neural network			
	最大相对 误差/%	拟和 均方差	泛化 均方差	训练用时 /s
RBF 神经网络	5.695	0.001	0.016	8.5
BP 神经网络	8.47	0.005 9	0.093 9	16.1

由表 3 可以看出 RBF 网络的预测精度要高于 BP 网络,训练的速度更快,并且其泛化性能好于 BP 网络。

4 结论

(1)作者利用 Matlab 神经网络工具箱,以钢板的轧前厚度 H_0 、轧后厚度 H_1 、轧辊直径 D 作为输入参数,以不同的轧辊直径分别建立中厚板轧机的应力状态系数的 3 个 RBF 神经网络模型,测试结果显示,相对误差基本限制在 $\pm 3\%$ 以内,实现了与实测结果的高度拟合。

(2)通过分析预测结果,得出不同辊径对模型精度的影响规律,并对轧制工艺规程的制定提出了合理建议。

(3)为了与 RBF 网络相对比,最后建立了应力状态影响系数的 BP 网络模型,对比结果表明,通过选择合适的参数,RBF 神经网络在预测精度以及泛化性能方面均优于 BP 神经网络。

参考文献:

- [1] 邹家祥. 轧钢机械 [M]. 北京: 冶金工业出版社, 1989. 32 - 43.
- [2] 葛懋琦, 程晓茹, 陈貽宏, 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.
- [3] 高 隼. 人工神经网络原理及仿真实例 [M]. 北京: 机械工业出版社, 2003. 55 - 73.
- [4] 王冬丽, 吕智林, 何小阳, 等. 基于 Matlab 的高速公路交通流 RBF 神经网络建模 [J]. 交通与计算机, 2005, 23(5): 26 - 30.
- [5] 许江勤. 钢材轧制应力状态系数与变形区形状参数分析 [J]. 南昌水专学报, 2003, 22(3): 59 - 62.
- [6] 孟令启, 李 成. 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. 242 - 261.
- [7] 张 铮, 杨文平. MATLAB 程序设计 with 实例应用 [M]. 北京: 中国铁道出版社, 2003. 234 - 258.
- [8] 王秀梅, 王国栋, 刘相华. 人工神经网络和数学模型在热连轧机组轧制力预报中的综合应用 [J]. 钢铁, 1999, 34(3): 37 - 43.
- [9] 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.
- [10] 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.

The Model of Influential Coefficient in Stressed State of Medium and Heavy Plate Rolling Mill Based on RBF Neural Network

MENG Ling - qi, WANG Hai - long, MA Jin - liang, XU Ru - song

(School of Mechanical Engineering, Zhengzhou University, Zhengzhou 450001, China)

Abstract: Based on the experimental data obtained from 71 steel plates rolled in 4200 rolling mill, this paper established a RBF neural network prediction model of influential coefficient in stressed state by Matlab neural network toolbox. By analyzing influential factors of coefficient of stressed state and taking into account the traditional mathematical model, this paper affirmed the parameters of input layer, and by selecting suitable spread in function-newrb(), this paper affirmed the best form of the network, and as a result, it improved the prediction accuracy and the adaptability of the network. The results of testing the model indicated that the model based on RBF neural network has a good generalizing capability. Compared with traditional BP network, the result indicated that RBF has better accuracy and adaptability of the network.

Key words: influential coefficient in stressed state; RBF neural network; model