

[文章编号] 1004- 0609(2001)05- 0862- 05

神经网络在预测斜轧穿孔毛管偏差中的应用^①

双远华¹, 赖明道²

(1. 太原重型机械学院 机械工程系, 太原 030024; 2. 燕山大学 机械工程学院, 秦皇岛 066004)

[摘要] 斜轧穿孔中毛管质量与许多工艺参数, 如辊型、送进角、顶头前伸量及温度, 以及设备性能参数如穿孔机刚度、加工精度和顶杆振动等有关。传统的轧制理论难以解决其质量问题, 应用神经网络则能较好地解决毛管质量的预测问题。应用实测的工艺参数与其对应的毛管精度参数, 训练和学习网络的权值和阈值, 建立起模拟穿孔机生产的数学模型, 即网络模型。预测了毛管偏差及合理的工艺参数。

[关键词] 斜轧穿孔; 神经网络; 数学模型

[中图分类号] 335.71

[文献标识码] A

长期以来, 工艺参数对毛管质量的影响主要靠调整试凑的方式进行修正。已经发展的斜轧理论有: 1) 借助纵轧板材的单位压力计算公式^[1]; 2) 根据斜轧变形特点, 用塑性力学推导的工程计算公式^[2]; 3) 用滑移线导出的计算公式^[3]; 4) 能量法^[4]; 5) 有限元理论^[5]; 6) 各种经验计算公式。利用有限元方法对不同的工艺参数可以计算出其对应的毛管形状与变形, 以及一系列有关质量方面的信息, 如扭转角度、内外裂纹与螺纹、多余应变等, 但很难利用有限元法对其工艺参数与质量参数建立一一对应的映射关系。随着神经网络算法的发展, 已将其逐步应用于冶炼^[6]、轧制^[7]、材料成形^[8]中。本文作者利用神经网络^[9, 10]的特点, 建立金属无缝管材加工模拟数学模型, 对生产中亟待解决的管材壁厚偏差和工艺参数优化问题做了预测。

1 基本原理

应用现场测试的大量数据, 对神经网络的 BP 算法的权值和阈值进行训练学习, 从而得出其已知工艺与毛管精度的映射关系。通过该映射关系, 在确定毛管的质量精度要求下, 反向模拟(映射)其对应的工艺参数, 从而对工艺参数进行优化。

1.1 网络结构与数学模型

设输入矢量: $x \in R^n$, $x = (x_0, x_1, \dots, x_{n-1})^T$, 输出矢量, $y \in R^m$, $y = [y_0, y_1, \dots, y_{m-1}]^T$ 。本文采用 BP 四层网络结构, 如图 1 所示,

隐层神经元的激励函数取 Sigmoid 函数:

$$f(u_j) = \frac{1}{1 + \exp(-u_j)} \quad (1)$$

$$u_j = \sum w x_i - \theta \quad (2)$$

式中 u_j 为该隐层的输出函数, x_i 为该隐层的输入函数。

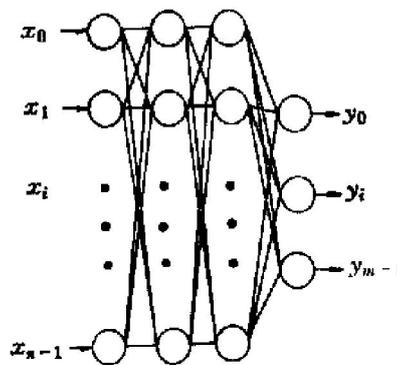


图 1 BP 网络结构

Fig. 1 Structure of BP neural networks

由数学分析可知: $f(u_j)$ 是一个连续可微函数, 满足非线性单调性, 对于多层网络具有精度高、容错性好等性能。另外, 也具有严格利用梯度法进行推算的性能。

将式(1), (2)推广至 4 层网络其输入量为 $X \in R^n$, $X = (x_0, x_1, \dots, x_{n-1})^T$; 第 2 层为 n_1 个神经元, $X' \in R^{n_1}$, $X' = (x'_0, x'_1, \dots, x'_{n_1-1})^T$; 第 3 层为 n_2 个神经元, $X'' \in R^{n_2}$, $X'' = (x''_0, x''_1, \dots, x''_{n_2-1})^T$; 输出量 $Y \in R^m$, $Y = (y_0, y_1, \dots, y_{m-1})^T$, 如输入与第 2 层之间的权为 w_{ij} , 阈值为

① [收稿日期] 2001- 02- 08; [修订日期] 2001- 05- 14

[作者简介] 双远华(1962-), 男, 副教授, 博士。

θ_j , 第 2 与第 3 层之间的权为 w_{jk} , 阈值为 θ_k , 第 3 层与最后层的权为 w_{kl} , 阈值为 θ_l , 各层神经元的输出满足:

$$\left. \begin{aligned} y_l &= f\left(\sum_{k=0}^{n_2-1} w_{lk} x''_k - \theta_l\right) \\ y''_k &= f\left(\sum_{j=0}^{n_1-1} w_{jk} x'_j - \theta_k\right) \\ x'_j &= f\left(\sum_{i=0}^{n_1-1} w_{ij} x_i - \theta_j\right) \end{aligned} \right\} \quad (3)$$

1.2 BP 学习算法

设输入学习样本为 P 个, 即 x^1, x^2, \dots, x^P , 其对应的教师为 t^1, t^2, \dots, t^P , 将实际输出 y^1, y^2, \dots, y^P , 与 t^1, t^2, \dots, t^P 的误差来修改其连接权和阈值, 使 y^l 与 t^l 尽可能接近。

1.3 改进算法

为了计算过程减少平坦区的迭代次数、加速收敛、防止振荡, 局部极小时迅速退出不灵敏区, 将算法做如下改进^[11]:

$$w_{sq}(n_0+1) = w_{sq}(n_0) + \eta(n_0) \sum_{s=1}^P \delta_s x_s^I + \alpha \Delta w_{sq}(n_0) \quad (4)$$

$$\text{当 } \Delta E < 0, \eta(n_0+1) = \eta(n_0) \phi, \alpha = \alpha \quad (5)$$

$$\text{当 } \Delta E > 0, \eta(n_0+1) = \eta(n_0) \beta, \alpha = 0 \quad (6)$$

式中 η 为步长; ϕ, β 为调节参数, $\phi > 1, \beta < 1$; ΔE 为相邻两次学习的误差增量, 且 $\Delta E(n_0) = E(n_0) - E(n_0-1)$; α 为动量因子, 并在 δ 反向误差项中增加了 γ 因子调节局部最小和平坦区设置因子。本文取 $\alpha = 0.6, \phi = 1.1, \beta = 0.3, \gamma = 5.0$ 。

2 实验数据及网络训练

2.1 训练样本的选择

实验在国内某钢铁公司进行, 实验数据按照文献[12]表 1 中 105 种试验工艺方案的测试结果安排。管形的测量采用自制的管形测量装置, 测量位置分别取水平和垂直纵剖面母线上四条以及毛管出口端圆周上一条, 同时测出内外表面偏差。已知工艺条件作为网络的输入向量, 其中毛管尺寸的外径间接反映其孔喉尺寸, 而在实验中顶头尺寸是不变的, 所以在确定的孔喉尺寸下, 其毛管尺寸也就确定了。因此, 选择如下输入参数:

辊型: 轧辊加工出锥角, ($^\circ$);

送进角: 通过转鼓调整的角度, ($^\circ$);

毛管外径: 由于改变孔喉后相应毛管外径也发生变化, 在现场调试中孔喉尺寸较难测出, 因此用它代替孔喉尺寸, mm;

前伸量: 由顶杆螺纹调节顶头伸出孔喉的长度, mm;

入口温度: 在现场实测的坯料温度, $^\circ\text{C}$ 。

网络的输出向量选择管形的测试数据, 由于毛管质量集中反映在其管形与内部组织上, 在实测中内部组织只对最后的工艺进行了轧卡、测试实验。因此, 只选择管形进行分析。同样在表 1 测试数据栏中钢管形状一项中给出沿纵向所测试的外径、内径最大偏量, 以及横向外径、内径最大偏量, 由轧件的最大偏差量, 可以反映该轧件的质量好坏。因此输出向量选择:

轧件纵向外径最大偏差量, mm;

表 1 隐层 1 与输入实测数据样本训练权值和阈值

Table 1 Weights and thresholds of learning with experimental data samples between hidden layer 1 and inputs

Input	Units in hidden layer 1					Thresholds
	Cone angle/ $^\circ$	Feed angle/ $^\circ$	Shell size/mm	Plug advance/mm	Temperature/ $^\circ\text{C}$	
Unit 1	0.641 0	0.278 7	0.573 4	0.350 5	0.680 9	0.466 3
Unit 2	0.690 6	0.381 2	0.680 1	0.337 5	0.651 5	0.272 9
Unit 3	0.561 9	0.350 6	0.680 4	0.466 2	0.690 8	0.381 3
Unit 4	0.680 6	0.337 7	0.652 3	0.278 5	0.572 7	0.350 7
Unit 5	0.680 6	0.466 3	0.690 3	0.381 1	0.680 5	0.337 7
Unit 6	0.348 7	0.370 3	0.377 3	0.851 3	0.235 9	0.371 8
Unit 7	0.641 0	0.278 7	0.573 4	0.350 5	0.466 5	0.690 7
Unit 8	0.381 2	0.680 5	0.337 5	0.652 5	0.278 8	0.573 7

轧件纵向内径最大偏差量, mm;
 轧件横向外径最大偏差量, mm;
 轧件横向内径最大偏差量, mm。

2.2 实测数据网络的权值和阈值

经过实测数据网络训练后的权值和阈值, 反映了上述所选择输入向量与对应输出向量的对应关系, 其结果如表 1, 2 和 3 所示。

3 已知工艺参数模拟

为了与实测数据比较, 选择若干已知工艺方案, 计算毛管的纵向外、内径, 横向外、内径的最大偏差量, 其计算结果如表 4 所示。

由计算结果与实测结果比较可得出: 神经网络对工艺参数与毛管最大偏差之间的映射关系通常具有较高的精度。本实测数据, 由于其样本数量限制与实测数据未经筛选。在计算时, 迭代 100 000 次时相对误差大部分在 $\pm 12\%$ 之内。由此可见, 用神经网络对工艺参数与毛管精度的在线训练将能准确地给出管形质量的预测值。其中, 在线训练可随轧件的生产逐步积累起来, 且其精度将随着积累的程度逐步提高。但应该指出: 如果要在现在在线训练、预测, 首先要具有工艺参数与管形测量参数的在线检测装置。实测数据在人工神经网络的模拟映射过程中, 均没有考虑轧机刚度、顶杆的振动、坯料的加热不均等问题。而只将其辊型、送进角、孔喉、前伸量与入口平均温度作为其输入参数, 进行分

表 2 隐层 2 中实测数据样本训练权值和阈值与隐层中的对映关系

Table 2 Weights and thresholds of experimental data samples between hidden layer 2 and those in hidden layer 1

Hidden layer 1	Units in hidden layer 2							
	Unit 1	Unit 2	Unit 3	Unit 4	Unit 5	Unit 6	Unit 7	Unit 8
Unit 1	0.377 9	0.902 8	0.996 6	0.266 6	0.843 4	0.587 0	0.641 6	0.986 3
Unit 2	0.840 8	0.592 7	0.641 8	0.978 7	0.361 5	0.889 1	0.594 6	0.393 8
Unit 3	0.359 0	0.894 8	0.594 8	0.386 2	0.360 5	0.266 7	0.896 8	0.787 2
Unit 4	0.358 0	0.272 4	0.896 8	0.779 6	0.680 7	0.979 1	0.274 3	0.484 6
Unit 5	0.678 1	0.984 8	0.274 7	0.477 2	0.843 7	0.386 5	0.986 7	0.986 4
Unit 6	0.841 4	0.391 9	0.986 3	0.979 3	0.390 2	0.897 5	0.393 5	0.192 2
Unit 7	0.387 8	0.902 7	0.394 0	0.185 5	0.690 7	0.589 3	0.594 3	0.481 8
Unit 8	0.688 4	0.594 5	0.594 2	0.475 0	0.478 4	0.647 7	0.896 2	0.383 6
Thresholds	0.472 9	0.651 8	0.881 9	0.375 0	0.901 6	0.993 4	0.264 9	0.844 4

表 3 隐层 3 实测数据样本训练权值和阈值

Table 3 Weights and thresholds of learning with experimental data samples between hidden layer 2 and output layer

Hidden layer 2	Units in output layer			
	Outer diameter in longitudinal direction	Inner diameter in longitudinal direction	Inner diameter in circum direction	Outer diameter in circum direction
Unit 1	- 0.467 1	- 0.974 7	- 0.285 7	- 0.807 9
Unit 2	- 0.957 9	- 0.505 3	- 0.914 2	- 0.543 8
Unit 3	- 0.653 0	- 0.807 9	- 0.709 7	- 0.878 4
Unit 4	- 0.832 4	- 0.717 3	- 0.376 4	- 0.539 2
Unit 5	- 0.419 4	- 0.382 9	- 1.006 9	- 0.917 7
Unit 6	- 0.749 2	- 0.758 7	- 0.312 1	- 0.642 1
Unit 7	- 0.448 1	- 0.808 7	- 0.906 6	- 0.864 4
Unit 8	- 1.056 3	- 0.487 2	- 0.814 3	- 0.521 1
Thresholds	0.985 6	0.272 9	0.692 6	0.468 1

表 4 已知工艺参数的理论值与实测值比较

Table 4 Results of comparing theory with experiment by known technology parameters

No.	Cone angle / (°)	Feed angle / (°)	Shell size / mm	Plug advance / mm	Temperature / °C	Deviation tested in longitudinal direction / mm	Deviation tested in circum-direction / mm	Deviation calculated in longitudinal direction / mm	Deviation calculated in circum-direction / mm
1	3.50	8.00	80.00	45.00	1 150.00	3.43, 2.06	2.67, 1.70	3.15, 2.28	2.99, 1.90
2	3.50	8.00	79.60	42.00	1 210.00	1.89, 1.05	1.80, 2.52	2.07, 1.17	1.90, 2.26
3	3.50	7.00	83.00	45.00	1 200.00	4.03, 0.85	1.91, 1.45	3.60, 0.96	2.12, 6.50
4	3.50	7.00	83.40	40.00	1 130.00	2.22, 4.72	5.77, 1.23	1.99, 4.48	5.19, 1.32
5	3.50	9.00	83.80	45.00	1 160.00	3.04, 3.87	3.61, 1.50	2.88, 3.75	3.52, 2.05
6	3.50	9.00	82.00	40.00	1 190.00	2.04, 4.90	6.48, 2.23	2.24, 3.64	5.10, 2.33
7	2.50	8.00	82.50	45.00	1 170.00	2.06, 5.92	1.73, 2.63	2.12, 5.20	2.01, 2.40
8	2.50	8.00	82.60	40.00	1 160.00	1.90, 6.00	3.64, 4.71	1.97, 5.21	3.52, 4.09
9	2.50	7.00	83.80	45.00	1 180.00	1.94, 4.64	1.68, 5.89	2.11, 4.22	1.98, 5.10
10	2.50	7.00	85.00	40.00	1 150.00	2.17, 4.48	4.93, 4.11	2.25, 3.89	5.06, 3.74
11	2.50	9.00	84.30	45.00	1 120.00	2.37, 2.06	1.83, 1.05	2.25, 2.32	1.86, 1.13
12	2.50	9.00	85.80	42.00	1 110.00	3.28, 4.85	3.97, 2.65	2.95, 4.41	3.88, 2.33

Note: the two values in the deviation data are the largest deviation of inner and outer surface

析。这样必然将以上没有考虑的因素, 全部由这些输入量来承担。因此, 其优化值也将包含上述没有考虑的因素, 即将没有考虑的因素隐含在这些输入中。由此可见, 在应用神经网络时, 需要针对不同的机型做不同的分析, 训练样本则需要由所分析的穿孔机进行实测而得到其数据。这里特别要指出的是训练样本应该在同种工艺下多采集一些数据进行正交实验, 如果应用模糊数据处理, 则更有利于优化样本, 找出真正反映内在变化的样本数据, 本实测值由于实验条件的限制, 没有进行处理, 其误差也相应扩大。

4 反向模拟预测理想工艺参数

利用以上正向模拟有关数据, 对各层单元进行逆向计算所得到的权值和阈值, 可建立反向模拟数学模型。将生产中所要求的毛管精度代入反向模拟网络中, 可直接计算出对应的工艺参数。本文假设管形偏差为: 纵向外径 σ ; 纵向内径 σ ; 横向外径 σ ; 纵向内径 σ 。

经预测优化后其对应的工艺方案为:

辊型: 4.165 082°;

送进角: 8.050 296°;

毛管尺寸: d 83.141 212 mm;

前伸量: 42.493 069 mm;

入口温度: 1 166.446 045 °C。

应该指出: 该工艺方案需经现场实验验证才能确定其具有的精度, 该方法可作为寻找合理工艺参

数的尝试办法。如果达到正向模拟所提供的精度, 那么, 反向模拟则可优化工艺参数。

5 结论

应用实测数据建立了神经网络 BP 算法在斜轧穿孔中工艺参数与质量参数之间的数学模型。通过对比理论计算结果与实测数据, 分析了网络模型误差的计算精度和训练过程。认为斜轧穿孔中应用神经网络算法, 在解决管材的质量问题中具有明显的实用性, 其计算结果可靠。通过网络逆向计算, 尝试了反向预测理想的工艺方案。

[REFERENCES]

- [1] Целиков А И. The calculation principle of mechanics on rolling mill [J]. Metallurgy, 1962, 4(3): 494.
- [2] Blazynski T Z. Theoretical and experimental assessment of roll and plug forces and roll torque in the combined rotary piercing- elongation process [J]. Inter J Mech Sci, 1968, 10(11): 903- 925.
- [3] Целиков А И. Working manual of rolling principle(轧制原理手册) [M]. Beijing: Metallurgical Industry Press, 1989.
- [4] Roberts W L. Mathematical modal of the three-roll piercing operation [J]. Iron and Steel Engineer, 1975, 4: 56 - 63.
- [5] Urbanski S, Kazanecki J. Assessment of the strain distribution in the rotary piercing process by the finite element method [J]. J Mater Process Technol, 1994, 45: 335-

- 340.
- [6] CHAI Tian-you(柴天佑), XIE Shu-ming(谢书明), DU Bin(杜斌), et al. 基于RBF神经网络的转炉炼钢终点预报[J]. The Chinese Journal of Nonferrous Metals(中国有色金属学报), 1999, 9(4): 868- 872.
- [7] SHUANG Yuan-hua(双远华), FAN Jian-cheng(樊建成), LAI Ming-dao(赖明道). 人工神经网络对管材张减精度预测[J]. Iron & Steel(钢铁), 2000, 35(2): 28- 31.
- [8] LÜ Dong(吕冬), DING Ke(丁柯), HE Dan-nong(何丹农), et al. 基于神经网络的拉深力智能化预测系统[J]. The Chinese Journal of Nonferrous Metals(中国有色金属学报), 2000, 10(3): 420- 425.
- [9] CHEN S, Billings S A. Neural networks for nonlinear dynamic system modeling and identification [J]. Int J Control, 1992, 56(2): 319- 346.
- [10] Kumpati S, Rendra S N. Identification and control of dynamical systems using neural networks [J]. IEEE Transactions on Neural Networks, 1990, 1(1): 4- 27.
- [11] ZHANG Li-ming(张立明). Models and Application of Artificial Neural Networks(人工神经网络的模型及其应用) [M]. Shanghai: Fudan University Press, 1992. 17- 21.
- [12] SHUANG Yuan-hua(双远华). 斜轧(穿孔)过程质量控制理论与实验研究[D]. Qinhuangdao: Yanshan University, 1999. 156- 162.

Application of artificial neural networks on predicting deviation of tube in cross piercing process

SHUANG Yuan-hua¹, LAI Ming-dao²

(1. Department of Engineering, Taiyuan Heavy Machinery Institute,
Taiyuan 030024, P. R. China;

2. College of Mechanical Engineering, Yanshan University, Qinhuangdao 066004, P. R. China)

[Abstract] The quality of tube hollow in cross piercing process is concerned with complicated factors, such as technical parameters including roller shape, feed angle, plug advance and temperature, and the piercing mill properties including stiffness and precision of the mill manufactured, vibration of the plug and driven systems. It is difficult to solve further problems on qualities using traditional rolling theory, and the prediction of tube hollow qualities is even more difficult. The artificial neural networks were used to solve the above problems easily. Weights and thresholds of the networks were learnt by experimental data and the model has been established in production. Technical parameters optimized and deviation of tube have been predicted.

[Key words] cross piercing; artificial neural networks; mathematical modal

(编辑 龙怀中)