

基于人工神经网络的热轧碳钢变形抗力预报

韩丽琦 臧勇 邹家祥 章博

北京科技大学机械工程学院,北京 100083

摘要 以恒应变速率凸轮压缩试验机得到的实验数据为基础,采用人工神经网络的方法建立了碳钢变形抗力与应变、应变速率及温度对应关系的预测模型,与多元非线性回归模型比较,神经网络模型具有较高的预测精度。

关键词 人工神经网络;变形抗力;凸轮压缩试验机

分类号 TF301

金属的变形抗力是表示钢材压力加工性能的一个基本量,正确确定不同变形条件下的金属的变形抗力,是制定合理的轧制工艺规程的必要条件。以往许多研究者在建立变形抗力与变形量、变形速率及温度的关系模型时,采用多元非线性回归对实测的数据进行处理,得到相应的变形抗力模型^[1,2]。

这种方法首先要对变形抗力模型的函数类型作出假设(如通常采用指数型函数),而实际上变形抗力的变化规律并不能在大范围内与所选择的函数类型完全一致。特别是当考虑静态再结晶、应变积累、动态再结晶、相变等因素的影响时,变形抗力的变化很复杂,难以用所选定的函数来描述,因而这种方法势必带来较大的误差^[3]。人工神经网络是模拟脑神经对外部环境进行学习过程建立起来的一种人工智能模式识别方法,具有自适应学习功能和处理复杂非线性特点,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。在塑性加工领域,人工神经网络被用来预报热轧后钢的力学性能^[4,5]以及轧制过程中的各道次的轧制力^[6-8],都取得了令人满意的结果。

本文利用热模拟实验得到的实测数据,利用神经网络实现应力—应变的直接映射,直接从实验数据学习应力—应变关系,不需要假设数学模型的类型,因而可以避免上述误差。通过与利用多元非线性回归方法得到的计算值相比较表明,神经网络方法具有良好的学习和预报精度。

1 样本数据

样本数据取自金属的塑性变形抗力数据库^[9,10]。通过用恒应变速率凸轮压缩试验机进行热模拟压缩试验,实测了热轧条件下的金属变形抗力,利用微机高速数据采集系统进行数据采集,将数据存入金属塑性变形抗力数据库。

样本钢种及其化学成分见表1,变形条件见表2。

表1 样本的化学成分(质量分数)

Table 1 Chemical Composition of Samples %

钢号	C	Mn	Si	Cu	S	P
08F	0.06	0.31	0.005	0.10	0.015	0.012
AD ₁	0.08	0.30	0.150	0.09	0.018	0.019
AD ₂	0.09	0.40	0.260	0.09	0.013	0.009
B ₁ F	0.11	0.36	0.010	0.11	0.015	0.009
B ₂ F	0.15	0.43	0.010	0.16	0.021	0.017
A ₂	0.14	0.45	0.240	0.08	0.031	0.022
A ₃	0.23	0.62	0.270	0.12	0.033	0.011
A ₃ F	0.20	0.43	0.140	0.12	0.030	0.011

表2 实验的变形条件

Table 2 Deformation conditions of experiment

$t_{\text{变形}}/^{\circ}\text{C}$	850	900	950	1000	1050	1100	1150
$\dot{\varepsilon}/\text{s}^{-1}$	5	10	20	30	55	80	
ε	0.05~0.69						

2 神经网络模型

神经网络作为实现复杂非线性系统的建模估计、预测、诊断和自适应控制的有效工具已得到了广泛应用。BP网络(Error Back-Propagation Networks)是一种反馈式全连接多层神经网络,

具有较强的联想记忆和推广能力,可以以任意精度逼近任何非线性函数,是目前使用最广泛的一种人工神经网络.它的结构简单,工作状态稳定. BP算法的学习过程,由正向传播和反向传播2个过程组成.在正向传播过程中,输入信息从输入层经隐蔽单元层逐层处理,并传向输出层,前一层神经元的状态只影响下一层神经元的状态.如果在输出层不能得到期望的输出,则转入反向传播,将误差信号沿原来的连接通路返回,通过修改各层神经元的权值,使得误差信号最小.本文中,变形抗力的神经网络模型结构为1个输入层、1个输出层和1个隐层.输入层有9个输入量,它们是钢的化学成分以及变形温度 $t_{\text{变形}}$, 变形程度 ε 和变形速率 $\dot{\varepsilon}$; 输出层只有1个输出量即变形抗力 σ , 即采用1个 $9 \times 18 \times 1$ 的3层网络结构.输入量取值必须在 $[0,1]$ 之间,用公式(1)进行归一化处理:

$$f(x) = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (1)$$

式中, $f(x)$ 为输入量归一化后的值; x_{\max} 为参量 x 变化区间的极大值; x_{\min} 为参量 x 变化区间的极小值.

对于活化函数,输入层神经元取线性函数,隐层神经元取 Sigmoid 函数:

$$f(\text{net}_j) = \frac{1}{1 + \exp[-(\text{net}_j + \theta_j)]} \quad (2)$$

式中, net_j 为隐层第 j 个神经元的输入值; θ_j 为阈值.

在网络学习阶段,通过调整所有连接权值和阈值,使系统平均误差 E 达到最小值:

$$E = \frac{1}{2} \sum_{k=1}^n (t_k - \theta_k)^2 \quad (3)$$

式中: t_k 为目标输出值; θ_k 为网络实际输出值; n 为样本数.每一层权值都用公式(4)进行调整:

$$W_{ij}(\tau+1) = W_{ij}(\tau) + \eta \delta_j x_i + \alpha (W_{ij}(\tau) - W_{ij}(\tau-1)) \quad (4)$$

式中: η 为增益项,也称为学习因子, $\eta \in (0,1)$; α 为比例常数,也称为惯性因子, $\alpha \in (0,1)$; x_i 为节点 i 的输出值; δ_j 为节点 j 的误差项; $W_{ij}(\tau)$ 为在 τ 时间由隐层节点 i 到节点 j 的权值.

在样本的学习过程中, η 和 α 的取值对学习的效率有很大的影响.较大的 η 值有助于加快网络的学习过程,但可能使网络在快速下降过程中产生振荡; α 能抑制振荡的产生,但可能使学习速度变慢,这2个值的选取要由实验确定.

3 结果与分析

从金属属性变形抗力数据库中读取8个钢种2400条记录(每条记录对应于1组实验数据)作为训练样本,经16万次训练后,每个样本的输出值与网络输出值的相对误差在 $\pm 8\%$ 内.

3.1 BP神经网络推广能力的验证

用上述训练好的神经网络,对训练样本以外的实验数据进行预测和分析.另取同样8个钢种各8条记录作为预报样本,利用学习好的网络对预报样本(实验数据)进行预测,验证网络的推广能力.通过预报结果与实验数据对比,其预测值与实测值的偏差不超过8%.由此可见,训练好的神经网络模型具有很好的推广能力,由于训练样本中不包含预报样本,预报结果具有普遍意义.

3.2 与回归模型的对比

回归模型采用公式(5)结构形式^[10]:

$$\sigma = \sigma_0 \exp(a_1 T + a_2) \left(\frac{\dot{\varepsilon}}{\dot{\varepsilon}_0} \right)^{a_3 T + a_4} \left[a_5 \left(\frac{\varepsilon}{\varepsilon_0} \right)^{a_6} + (1 - a_5) \left(\frac{\varepsilon}{\varepsilon_0} \right) \right] \quad (5)$$

式中, $T = \frac{t_{\text{变形}} + 273}{1000}$, 表示变形温度, K; σ_0 为基准变形抗力,即化学成分、组织状态以及变形条件一定时的变形抗力, MPa; ε_0 为基准变形抗力时的变形程度(对数应变); $\dot{\varepsilon}_0$ 为基准变形抗力时的

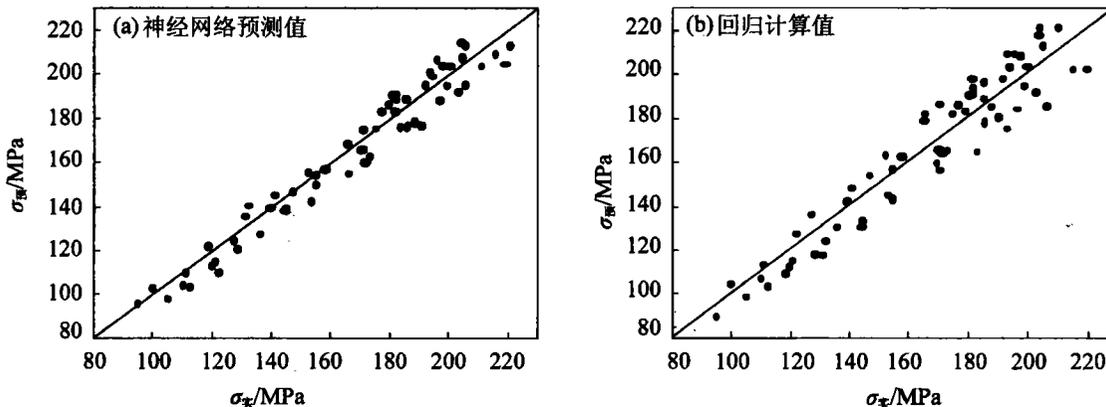


图1 神经网络预测值和回归计算值的比较

Fig.1 Comparison of σ prediction values by neural network and σ calculation values by regression

变形速率, s^{-1} ; $\alpha_1 \sim \alpha_6$ 为回归系数.

回归模型计算得到的 σ 值与实测 σ 值之间的偏差基本在 $\pm 10\%$ 以内, 其结果见图 1, BP 神经网络的预报精度高于回归模型计算的结果.

4 结论

利用神经网络模型可以较好地预测热轧变形抗力值随变形温度、变形程度、变形速率的变化而变化的情况, 与回归模型相比, 神经网络模型具有更高的预测精度. 神经网络预报热轧变形抗力模型与数学模型相结合, 可应用于板带热连轧生产中的轧制力高精度预设定.

参考文献

- 1 周纪华, 管克智. 金属塑性变形阻力. 北京: 机械工业出版社, 1989.221
- 2 Ginzburg V B. Basic Principles of Customized Computer

Models for Cold and Hot Strip Mill. Iron and Steel Engineer, 1985,62(9):21

- 3 王国栋, 刘相华. 金属轧制过程人工智能优化. 北京: 冶金工业出版社, 2000.324
- 4 王殿辉, 刘振宇, 王国栋. 利用神经网络预测热轧板带力学性能. 钢铁, 1995, 30(1): 28
- 5 刘振宇, 王昭东, 王国栋. 应用神经网络预测热轧 C-Mn 钢力学性能. 钢铁研究学报, 1995, 7(4): 61
- 6 李元, 刘文仲, 孙一康. 神经元网络在热连轧精轧机组轧制力预报的应用. 钢铁, 1996, 31(1): 54
- 7 吕程, 王国栋, 刘相华. 基于神经网络的热连轧精轧机组轧制力高精度预报. 钢铁, 1998, 33(3): 33
- 8 王秀梅, 王国栋, 刘相华. 轧制力预报中的神经网络和数学模型. 东北大学学报, 1999, 20(3): 319
- 9 韩丽琦. 金属塑性变形抗力数据库及轧制力能参数分析:[硕士学位论文]. 北京:北京科技大学, 1995
- 10 程伟, 韩丽琦. 金属塑性变形抗力数据库接口软件. 北京科技大学学报, 1997, 19(增刊 1): 33

Prediction of Flow Stress of Carbon Steel in Hot Strip Rolling by Artificial Neural Network

HAN Liqi, ZANG Yong, ZOU Jiexiang, ZHANG Bo

Mechanical Engineering School, UST Beijing, Beijing 100083, China

ABSTRACT On the basis of the data obtained on Cam Plastometer with constant strain rate, the predicting model for the relation between flow stress and deformation strain, strain rate and temperature of carbon steel has been developed by Artificial Neural Network method. Compared with nonlinear regression method, the neural network model gives better results.

KEY WORDS artificial neural network; flow stress; cam plastometer