第 24 卷第 4 期
2007 年 8 月

控 制 理 论 与 应 用
Control Theory & Applications

Vol. 24 No. 4
Aug. 2007

文章编号：1000−8152(2007)04−0669−05

金属力学性能质量预测及其控制

王丹民[1], 李　擎[2], 李华德[2]

(1. 中冶京诚工程技术有限公司 技术研究院, 北京 100176; 2. 北京科技大学 信息工程学院, 北京 100083)

摘要: 为了在生产中能够对力学性能做出精确的预测, 在用神经网建立起由工艺参数预测力学性能的质量模型后, 又提出一种新的建模方法—逐层逼近法, 从测试的结果看, 后者预测精度明显高于前者. 然后, 对利用自适应逆控制方法实现对力学性能的在线控制进行了研究, 仿真结果证明了该方法的有效性.

关键词: 力学性能; 人工神经网络; 组织性能预测和控制; 自适应逆控制

中图分类号: TG335.5　　**文献标识码**: A

Quality prediction model and control of the metallic mechanical properties

WANG Dan-min[1], LI Qing[2], LI Hua-de[2]

(1. Research Institute, Capital Engineering & Research Incorporation Limited, Beijing 100176, China;
2. School of Information Engineering, University of Science and Technology Beijing, Beijing 100083, China)

Abstract: In order to precisely predict the mechanical properties, the model, that could predict the mechanical properties of hot-rolled steel strip with the technological parameter, is established based on artificial neural network. A new method by applying the technology of layer-to-layer prediction and impending is also proposed. The test result shows that the precision of the latter prediction is higher than that of the former. Then, the real time control method of the mechanical properties is researched and simulated with adaptive inverse control. Simulation result shows that this control method is effective.

Key words: mechanical properties; artificial neural network; structure property prediction and control; adaptive inverse control

1　引言(Introduction)

钢材的组织性能预测和控制技术SPPC(structure property prediction and control)是一门跨学科的实用技术. 利用该项技术可以实现以化学成分、轧制制度、冷却制度等生产工艺参数作为输入变量对屈服强度等力学性能进行预报[1].

2　利用逐层分类预测逐渐逼近法建模(Modeling with the method of layer-of-layer prediction and impending)

2.1　建模数据的准备(Preparation of modeling data)

从邯钢CSP生产线上获取钢种为SS400的2600组数据作为建模的训练数据, 另取899组数据作为测试数据, 以检测模型准确率. 模型的输入为生产参数集P, 输出为力学性能参数集O, P和O的内容如下:

$$P=[\mathrm{C}\ \mathrm{Mn}\ \mathrm{Si}\ \mathrm{P}\ \mathrm{S}\ \mathrm{Cu}\ \mathrm{Cr}\ \mathrm{N}i\ \mathrm{Nb}\ \mathrm{Ti}\ \mathrm{Als}\ \mathrm{Ca}\ \mathrm{Al}\ T_f\ H_s\ H_c\ H_r\ T_r\ T_1\ V_6\ T_e\ T_c],$$

$$O=[\sigma_s].$$

上式中: C,Mn,Si,P,S,Cu,Cr,Ni,Nb,Ti,Als,Ca,Al是轧件化学成分; T_f是出炉温度; H_s是板坯厚度; H_c是成品厚度; H_r是粗轧后坯厚; T_r是粗轧后温度; T_1是精轧机架1温度; V_6是轧制速度; T_e是终轧温度; T_c是卷取温度; σ_s 是屈服强度. 为使P和O中的参数在模型中充分发挥效用, 按公式(1)方法对数据做归一化处理, 把数据变换在[–1,1]之间, 方法如下:

$$x'=-1+2\times\frac{x-x_{\min}}{x_{\max}-x_{\min}}. \tag{1}$$

上式中: x'为归一化后的变量值; x为原始变量值; $x_{\min}$,$x_{\max}$为原始变量的最小值与最大值.

2.2　利用二层神经网络建模(Modeling with two layer ANN)

为了对比说明采用逐层分类预测逐渐逼近法建

收稿日期: 2005−10−8; 收修改稿日期: 2006−07−17.

模的优越性, 本文首先介绍没有隐层的二层神经网络建模的预测结果. 另外, 逐层分类预测逐渐逼近法的各层子模型也都是通过这种二层网模型实现的.

由于所建热轧板材质量模型的输入(生产参数集P)是22维的, 属于高维输入网络, 对训练样本的数量要求非常大, 根据Moody准则[2] 关于实值神经网络结构设计最简原则, 若想提高网络的泛化能力, 需采用尽量简单的网络结构;另外, 由于所建模型将要用于在线质量预测及在线控制, 所以模型结构越简单越好, 以减少在线计算时间, 满足生产需要. 因此, 为满足以上两个要求, 本文提出了利用没有隐层的二层神经网来建立热轧板材的屈服强度质量预测模型. 神经网结构如图1所示. 预测结果如表1所示.

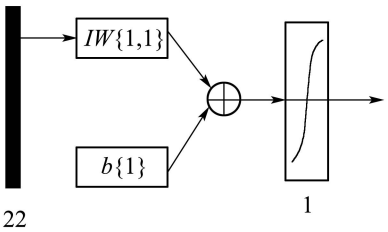

图 1 二层神经网的网络结构

Fig. 1 Structure of two layers ANN

表1中: $|err|$表示预测值与实际值偏差的绝对值相对于实际值的百分比, 第2行表示对应于该预测偏差范围的命中率. 从该表可以看出模型预测结果的5%命中率是67%.

表 1 二层神经网的预测结果

Table 1 Prediction results of two layers ANN

$\|err\|\leqslant 5\%$	$5\%<\|err\|\leqslant 10\%$	$10\%<\|err\|\leqslant 15\%$	$\|err\|>15\%$
67.0%	23.5%	8.0%	1.6%

2.3 利用逐层分类预测逐渐逼近法建模(Modeling with the method of layer-of-layer prediction and impending)

为进一步提高模型预测精度, 经试验研究发现, 当用于建模的训练数据范围减小到屈服强度值变化在40 $\mathrm{N/mm^2}$以内时, 5%命中率可提高到80%左右, 所以本文提出一种在这里把它命名为“逐层分类预测逐渐逼近”的建模方法. 其思想是建立多层预测模型, 模型结构采用二叉树结构, 如图2所示.

图2中的每一个节点代表一个子模型, 各子模型都采用上面介绍的二层神经网来建模, 父节点与左、右子节点的编号关系如下:

左子节点:

$$l = 2\times k + 1; \tag{2}$$

右子节点:

$$m = 2\times k + 2. \tag{3}$$

上式中: k为父节点编号; l为左子节点编号; m为右子节点编号. 每层模型的预测范围不同, 第1层是在屈服强度值的全范围内(255 $\mathrm{N/mm^2}\sim$ 515 $\mathrm{N/mm^2}$)建立一个预测模型, 第2层开始依次按二叉树结构建模, 每个二叉树子模型的预测值范围是父模型预测值范围的一半, 考虑到父模型的预测偏差, 在选取训练数据时, 再增加父模型预测值范围的25%, 将它们的和作为子模型在训练阶段的预测值范围, 按此规律前3层各子模型在训练阶段的预测值范围选取如图3所示, 图中圆圈内数字对应图2中的模型编号.

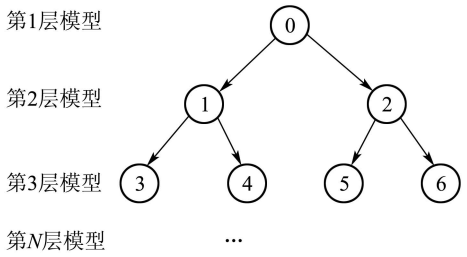

图 2 模型结构

Fig. 2 Structure of model

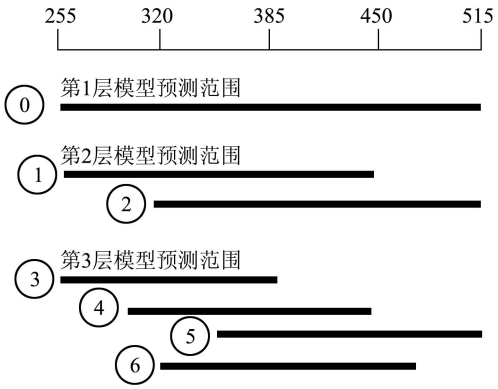

图 3 各层的预测范围

Fig. 3 Prediction range of different layer

按上面的思想, 各子模型预测值范围左右边界的确定方法如下:

左子树:

$$a_{\mathrm{left}(n)} = a_{\mathrm{left}(n-1)}, \tag{4}$$

$$a_{\mathrm{right}(n)} = a_{\mathrm{left}(n-1)} + 0.75\times\big(a_{\mathrm{right}(n-1)} - a_{\mathrm{left}(n-1)}\big), \tag{5}$$

右子树:

$$a_{\mathrm{left}(n)} = a_{\mathrm{left}(n-1)} + 0.25\times\big(a_{\mathrm{right}(n-1)} - a_{\mathrm{left}(n-1)}\big), \tag{6}$$

$$a_{\mathrm{right}(n)} = a_{\mathrm{right}(n-1)}. \tag{7}$$

式中: $a_{\mathrm{left}(n)}$为第n层屈服强度预测范围的左边界; $a_{\mathrm{right}(n-1)}$为第$n-1$层屈服强度预测范围的右边界.

当模型层数为8层时, 最底层模型预测值范围已缩小为35 N/mm^2, 预测命中率已很高. 为减小计算量, 加快模型在线应用时的计算速度, 各子模型都采用最简单的二层网络来建模, 利用其预测范围内对应的生产参数集P和力学性能参数集O中的数据对网络进行训练. 将以上各层子模型组合起来, 即构成热轧板材质量的总模型, 建模的程序框图如图4所示.

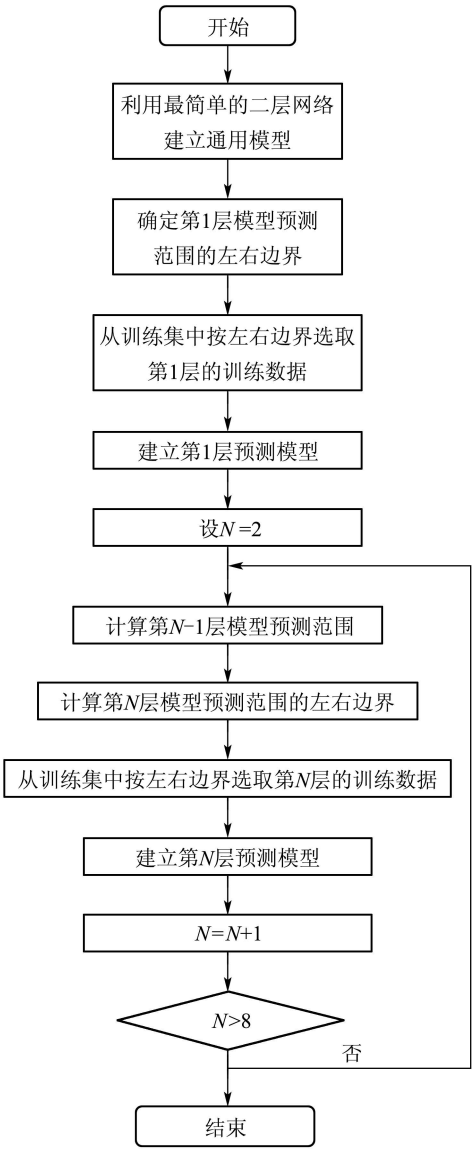

图 4　建模程序框图

Fig. 4　Diagram of modeling

模型运行过程的程序框图如图5所示. 首先将待预测的生产参数集P送入第1层编号为0的模型进行预测, 将预测结果与该模型预测范围中心点值进行比较, 每个子模型预测值范围中心点的计算方法如下:

$$x_{\mathrm{mid}(k)} = \frac{a_{\mathrm{left}(k)} + a_{\mathrm{right}(k)}}{2}. \tag{8}$$

式中: $x_{\mathrm{mid}(k)}$是编号为k的子模型的左、右边界中心点值; $a_{\mathrm{left}(k)}$是编号为k的子模型的左边界点值; $a_{\mathrm{right}(k)}$是编号为k的子模型的右边界点值. 若该节点的模型预测值小于中心点值, 则将生产参数集P送入该节点的下一层左子节点模型, 再进行预测; 若大于中心点值, 则将生产参数集P送入该节点的下一层右子节点模型, 再进行预测. 如此重复上述过程, 生产参数集P不断被送入更深一层模型进行预测, 随着模型深度的增加, 预测命中率不断提高.

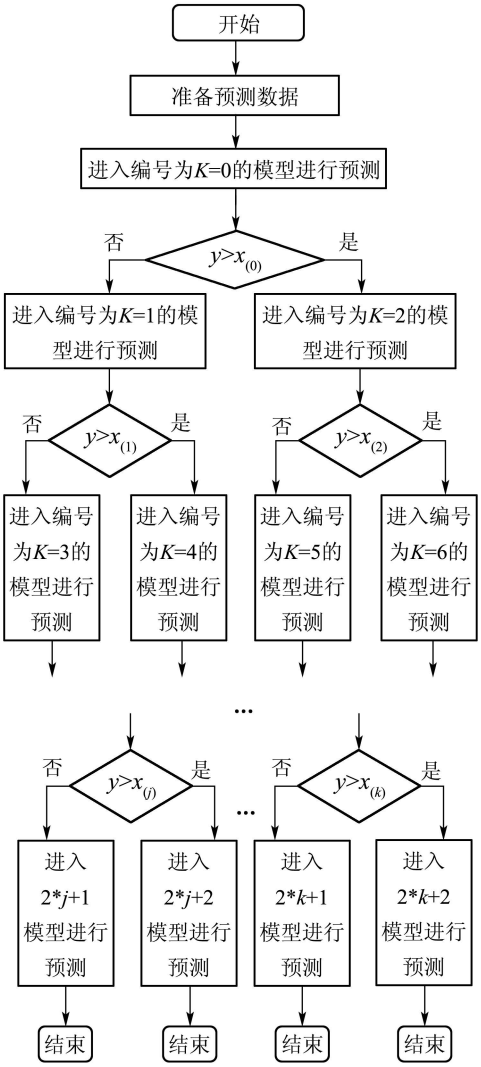

图 5　模型的运行程序框图

Fig. 5　Running diagram of model

采用以上方法对屈服强度进行预测的结果如表2所示.

表 2　用逐层逼近法建模的预测结果

Table 2　Prediction results of layer-of-layer impending

$\lvert err\rvert \leqslant 5\%$	$5\% < \lvert err\rvert \leqslant 10\%$	$10\% < \lvert err\rvert \leqslant 15\%$	$\lvert err\rvert > 15\%$
72.1%	24.5%	2.1%	1.3%

从表2可以看出使用逐层分类预测逐渐逼近法所建模型预测结果的5%命中率达到72.1%.SS400型钢的屈服强度要求标准是大于270N/mm^2, 邯钢

在实际生产设计中往往把屈服强度的目标值设定为350 N/mm^2, 从表2可以看出, 屈服强度值在350 N/mm^{2}附近即使偏差20%, 也不会产生误判, 也就是说理论上可实现对全部的钢卷作出正确判断, 所以, 完全可以满足当前生产的要求. 逐层分类预测逐渐逼近法模型的5%命中率高的原因可通过下图给以解释.

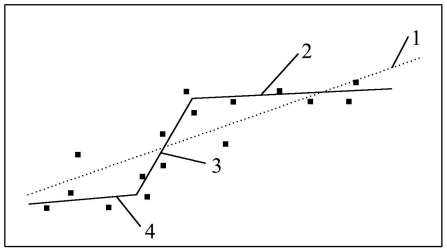

图 6 分段建模的示意图

Fig. 6 Sketch of partitional modeling

在图6中, 可以采用两种方法对样本点进行拟和. 一种是利用虚线1进行拟合; 另一种是将2,3,4等3条线段联合起来对样本进行拟和. 不难看出, 后者的拟合效果好于前者. 逐层分类预测逐渐逼近法就是基于上面的原理, 上层模型对应于虚线1, 下层模型对应于2,3,4线段, 并将此过程反复迭代逐层逼近. 应该说, 层数越多, 则分段越细, 拟合效果越好.

3 屈服强度的实时控制(Real time control of yield strength)

3.1 卷取温度对屈服强度的影响(Relation between mechanical properties and coil temperature)

基于前面介绍的屈服强度预测模型, 就卷取温度(T_c)对屈服强度(σ_s)的影响分析如下. 从训练数据集中选取一组数据, 该组数据可被视为一个命名为a的工作点, 其$\sigma_s = 350\,\mathrm{N/mm^2}$, 生产参数如表3所示.

表 3 工作点a的生产参数

Table 3 Technological parameters of position a

H_s/mm	H_r/mm	T_f/℃	T_r/℃	T_e/℃	H_c/mm	T_1/℃	V_6/(m·s^{-1})	T_c/℃	C/%	Mn/%
70.2	37	1032	1114	857	2.333	1004	7.77	648.01	0.19	0.41
Si/%	P/%	S/%	Cu/%	Cr/%	Ni/%	Nb/%	Ti/%	Als/%	Ca/%	Al/%
0.06	0.017	0.005	0.016	0.018	0.008	0.003	0.0032	0.0214	0.002	0.0233

将上表中除卷取温度T_c以外的其他生产参数值保持不变, 而将T_c在550℃~750℃之间以步长为1℃递增取值, 代入屈服强度预测模型中, 得到σ_s随T_c变化的关系图, 如图7所示.

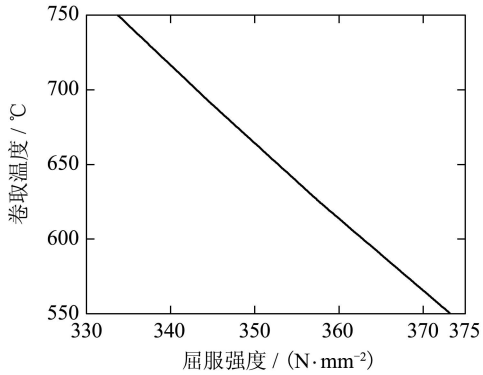

图7 工作点a的屈服强度与卷取温度之间的关系

Fig. 7 Relation between yield strength and coil temperature of position a

为确定图7所描述的屈服强度与卷取温度之间的关系是否具有普遍意义, 再随机另取几个工作点做上面的试验, 发现如下规律: 对于不同工作点, 曲线的弯曲程度不同, 当卷取温度变化范围相同时, 屈服强度值随所选工作点的不同, 其变化范围不同, 但变化趋势是一致的, 即屈服强度值随着卷取温度值的上升而下降.

3.2 用自适应逆控制实现对屈服强度的实时控制(Real time control of yield strength with adaptive inverse control)

自适应逆控制(adaptive inverse control)采用开环控制方式, 它把被控对象传递函数的逆作为串联控制器, 使得控制器与被控对象的级联传递函数是1, 从而确保对象的输出跟踪指令输入. 本系统自适应逆控制的实现方法如图8所示.

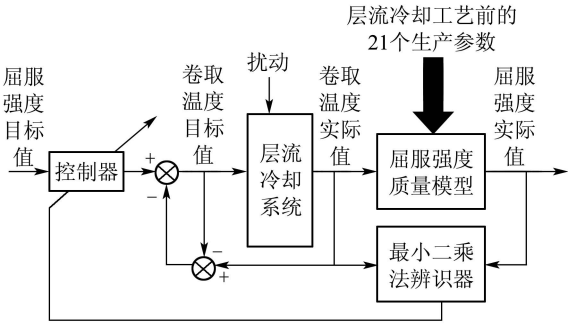

图 8 自适应逆控制图

Fig. 8 Diagram of adaptive inverse control

图8中, 输入为屈服强度目标值, 输出为产品屈

服强度实际值. 屈服强度质量模型是前面介绍的利用逐层分类预测逐渐逼近法建立的屈服强度预测模型. 在理想情况下, 带钢经过层流冷却后, 由温度检测设备对产品进行测温后所得到的卷取温度实际值应该与卷取温度目标值相等, 即上图中的层流冷却系统的传递函数是1, 当控制器为屈服强度预测模型对应的卷取温度→屈服强度关系的逆时, 可实现产品的屈服强度实际输出值对输入目标值的跟踪. 但由于室温、水温、水压等因素的变化影响, 使得层流冷却的输入与输出值并不相等, 在这里, 把这些影响因素都作为扰动来处理, 利用比较后得到的温度偏差对控制器输出的卷取温度目标值进行调整, 从而抵消了扰动的影响. 由于不同钢卷或同一钢卷不同控制段的生产工艺参数不同, 使得屈服强度与卷取温度之间如图7所示的对应关系曲线是不同的, 所以, 需要不断地对逆控制器中的模型参数进行自适应修改, 在这里采用最小二乘法对上述关系曲线内的参数进行不断地辨识. 可见, 控制器对于每一个控制段(或工作点)来说是静态的, 而每一个控制段非常小, 所以, 控制器不断地对各控制段进行自适应.

3.3　仿真结果(Simulation)

选取A, B两组屈服强度分别为340 N/mm^{2}和360 N/mm^{2}的钢卷数据, 把它们视为同一钢卷上的A, B两个控制段(或工作点), 分别将两组数据中的生产工艺参数带入图8中的屈服强度质量预测模型中, 通过调节卷取温度, 把两个控制段的屈服强度分别由原来的340 N/mm^{2}和360 N/mm^{2}都调整为350 N/mm^2. 按照图8对系统进行如下仿真, 屈服强度的目标值都设定为350 N/mm^2, 并在0.6 s附近施加一个20℃的卷取温度扰动(实际生产中的卷取温度波动幅度一般在10℃以内), 在1 s处由A段的生产工艺参数改变为B段的生产工艺参数. 仿真结果如图9所示.

图9中, 对于控制段A, 系统控制器参数的设置是针对该段的生产参数而自适应的结果. 在保持除卷取温度以外的其他生产工艺参数不变的情况下, 当卷取温度调节为609.7℃时, 屈服强度值由原来的340 N/mm^{2}变为351.3 N/mm^2, 比设定值高出1.3 N/mm^2, 由于在实际生产中对屈服强度的计量精度是5 N/mm^2, 所以, 该偏差在现实生产中可完全忽略不计;同样, 对于控制段B, 当卷取温度调节为683.2℃时, 屈服强度值由原来的360 N/mm^{2}变为349.2 N/mm^2, 比设定值低0.8 N/mm^2. 总的来看, 采用自适应逆控制, 通过调节卷取温度, 实现输出性能值对输入目标设定值的跟踪效果还是很好的. 另外, 由于自适应逆控制采用的是消除扰动技术, 而不是抑制扰动, 所以, 从仿真结果来看, 在0.6 s附近施加的卷取温度扰动对于屈服强度没有任何影响.

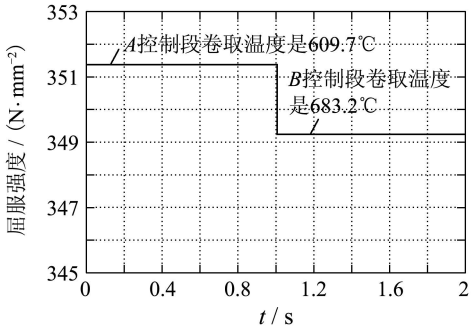

图 9　仿真结果

Fig. 9　Simulation result

4　结论(Conclusion)

本文提出使用逐层逼近法建立屈服强度质量预测模型, 模型预测结果的5%命中率达到72.1%, 完全可以满足生产需要. 在此模型基础上, 提出利用自适应逆控制实现对屈服强度的实时控制, 仿真结果表明该方案可行.

参考文献(References):

[1] 干勇. 薄板坯连铸连轧(TSCR)热轧过程组织性能预报技术的开发[J]. 钢铁, 2003, 38(8): 10 – 15.
(GAN Yong. The R & D of Process modeling in thin slab hot strip rolling[J]. *Iron and Steel*, 2003, 38(8): 10 – 15.

[2] MOODY J E. The effective number of parameters：An analysis of generalization and regularization in nonlinear learning system[C]//*NIPS 4*. San Mateo, CA: [s.n.], 1992: 847 – 854.

作者简介:

王丹民　(1970—), 男, 博士, 中冶京诚工程技术有限公司, 研究方向为智能控制与轧钢过程自动化, E-mail: wdm512003@yahoo.com.cn;

李　擎　(1971—), 男, 副教授, 博士, 目前研究方向为变频调速技术, E-mail: liqing@ies.ustb.edu.cn;

李华德　(1941—), 男, 教授, 博士生导师, 研究方向为电力电子及电力传动、热工过程控制系统、轧钢过程自动化、伺服控制系统, E-mail: lihuade@ies.ustb.edu.cn.