

# 基于神经网络规则抽取的带钢热镀锌质量监控模型

王建国<sup>1,2</sup>, 阳建宏<sup>1</sup>, 张文兴<sup>2</sup>, 徐金梧<sup>1</sup>

(1. 北京科技大学机械工程学院, 北京 100083; 2. 内蒙古科技大学机械工程学院, 内蒙古 包头 014010)

**摘要:** 为了克服传统神经网络产品质量监控模型中解释性差的困难, 提出了基于神经网络规则抽取的带钢热镀锌质量监控模型. 以带钢热镀锌生产中锌层重量监控为研究对象, 利用神经网络规则抽取方法对样本数据进行学习, 以知识规则的形式给出模型中输入(原料参数及生产控制参数)与输出(产品质量)间的定量关系, 用于对生产控制参数的设定与更新. 选取 756 个训练样本和 376 个测试样本分别对网络进行了训练和检验, 结果表明, 新模型中的知识规则覆盖率达到 94.8%, 并可根椐输出变量的目标区间快速地设定各输入变量的范围, 为产品质量的自动控制提供了有效的方法.

**关键词:** 神经网络; 规则抽取; 带钢热镀锌; 质量监控

**中图分类号:** TP183      **文献标识码:** A      **文章编号:** 1009-606X(2008)05-0957-05

## 1 前言

在冷轧带钢热镀锌生产中, 镀锌层厚度(或锌层重量)是一项重要的用户指标. 镀锌层过厚不仅会浪费锌锭等原材料, 而且会影响产品的点焊性、附着性等使用性能; 而镀锌层太薄则会影响产品的抗腐蚀性. 因此对镀锌层厚度的控制将直接影响热镀锌板的质量及成本. 影响锌层厚度的主要工艺参数有气刀与带钢的间距、气刀角度、气刀压力、气刀喷嘴类型、机组速度、气刀与液面距离等<sup>[1]</sup>. 以锌重质量监控模型的输出变量即锌层重量, 输入变量包括了气刀参数(如气刀压力)和生产工艺参数等. 建立质量控制模型, 可以为生产过程监控和质量管埋提供有效的分析方法和控制手段.

目前, 世界上各主要热镀锌工艺厂家锌重控制模型的主要思想是根据生产条件和控制目标要求, 使用相应的模型计算出控制参数设定值<sup>[2]</sup>. 在实际生产中, 气刀角度、气刀喷嘴类型、气刀与液面距离 3 个因素在操作中很少变化, 对镀锌层厚度的影响也不大, 所以可作为常数处理, 一般以气刀压力、气刀带钢的间距、机组速度为主要控制对象建立模型<sup>[1,2]</sup>. 常用的模型有: 根据空气动力学、边界层流理论、二维自由喷射理论等得出的经验计算公式、人工神经网络(Artificial Neural Network, ANN)<sup>[3,4]</sup>、核方法(Kernel Method)<sup>[5]</sup>和线性回归方程(Linear Regression, LR)<sup>[6]</sup>等. 然而, 这些方法在根据质量控制目标反求控制参数时, 都存在一定的局限性: 当存在多个输入变量耦合作用时, 直接求出输出变量与每个输入参数的定量关系常常比较困难, 甚至难以实现, 常用的方法是假设其他参数都不变, 并给定相应的初值,

利用模型反求出目标控制参数, 然后再不断改变初值和控制参数的组合, 最终达到控制要求. 这种思路在设定参数时需要进行大量的实验, 效率很低并且受主观经验的影响较大.

为了避免繁琐的反推计算, 本工作建立了基于神经网络规则抽取的带钢热镀锌质量监控模型, 通过从神经网络中提取出输入变量与输出变量之间的规则关系, 在一定的精度下可以定量地描述产品原料参数、生产控制参数与产品质量间的对应关系, 最后可根据不同锌重直接设定对应的控制参数值, 应用非常方便, 对生产过程的参数控制具有明确的指导意义.

## 2 神经网络规则抽取

神经网络规则抽取起源于 1988 年 Gallant 设计的一个连接主义专家系统, 该系统最大的特点就是其知识库由一个神经网络来实现, 通过产生规则来解释神经网络得到的结论. 随后, 大量的研究者对神经网络的规则进行了研究, 新成果层出不穷并得到广泛的应用, 如文献[7]利用 RX(Rule Extraction)算法建立了肺癌的诊断模型, 文献[8]利用 SRE(Structure-based Neural Network Rule Extraction)算法建立银行贷款风险预警模型.

虽然 RX 和 SRE 算法都得到了很好的应用, 但仍存在一定的不足, 如 RX 算法需要对每个隐含层节点的激活值进行聚类, 当隐含层节点较多时, 其隐含层激活值的组合可能会非常多, 不利于规则抽取; SRE 算法采用权值聚类的方法对网络进行剪枝, 对于规模较大的神经网络, 剪枝后的网络结构仍然比较复杂, 在进行规则抽取时会存在一定的困难.

为了避免现有方法的局限性,本工作提出了一种新的神经网络规则抽取方法,采用权值衰减(Weight-decay)的方法对神经网络进行训练,在保证训练精度的前提下对网络进行剪枝.规则抽取时,把隐含层节点的输出近似地看成只有2种情况:0和1,减少了隐含层激活值组合的数量,并通过在隐含层和输出层激活函数中采用大于1的指数系数,使函数的输出可以更好地趋于0和1两种情况,便于规则的抽取与合并.

### 3 基本方法

本工作提出的神经网络规则抽取算法可分为3个步骤:(1)数据预处理,即对输入输出数据进行离散化;(2)神经网络训练,先选定合适的隐含层节点数,在训练过程中加入权值衰减函数<sup>[9,10]</sup>,并在保证训练精度的前提下根据连接权重对网络进行剪枝;(3)规则抽取与合并,对剪枝后的神经网络分层进行规则抽取,最终合并整理出输入变量与输出变量之间的规则关系.

#### 3.1 数据预处理

本工作建立的神经网络要求输入输出的数据为二值模式,即0或1.利用聚类算法可以使取值区间连续的数据离散化,然后对离散后的数据进行一定规则的编码,就可使之转化成二值模式,常用的编码方法有1/N编码、温度计编码等<sup>[11]</sup>.1/N编码的长度等于离散变量中不同类别的数目,码向量中除了代表码值的唯一的一个元素置1外,其余值均为0.如一含有3个元素的集合{A, B, C},表示C时,其编码是{0 0 1},表示A时则是{1 0 0}.温度计编码中,代表码值的元素及其后面的元素都置为1,如表示C时,其编码为{0 0 1},表示B则是{0 1 1},依次类推.本工作采用k均值聚类方法,先将输入输出数据分类,再选用温度计编码将输入数据转成二值模式,用1/N编码方式将输出数据转成二值模式.

#### 3.2 神经网络训练

本工作以均方差作为网络训练的性能误差函数,误差函数如下:

$$\text{Error} = \frac{1}{c} \sum_{i=1}^k \sum_{p=1}^c (S_{pi} - T_{pi})^2, \quad (1)$$

其中, $k$ 为输入样本的个数, $c$ 为输出变量的个数, $T_{pi}$ 为网络的第*i*个样本的第*p*个输出节点的期望输出, $S_{pi}$ 为网络的第*i*个样本的第*p*个输出节点的实际输出.网络训练的过程就是不断地对网络的权值进行迭代,从而找到最佳的权值组合,使误差函数值达到最小.

##### 3.2.1 隐含节点的选择

隐含节点数的选择目前还没有准确的理论依据,一般根据经验来选择,主观性比较大.本工作利用统计学中交叉检验的方法来确定隐层节点数,此方法对于参数的选择非常有效并广泛应用于神经网络的结构优化<sup>[12,13]</sup>.基本思想是先将样本数据分成*N*个子集,选取其中的*P*( $P < N$ )个子集作为训练集对网络进行训练,剩下的子集作为交叉检验集对网络进行预测,分别对含有不同隐含节点数的神经网络进行检验,最后选择预测精度最高的网络.

将样本数据分成5个子集,选取其中的4个子集进行训练,对剩下的1个子集进行预测,检验结果如表1.由表可知,当隐含节点数为3时,预测误差最小,因此,选择神经网络的隐含层节点数为3.

表1 交叉检验结果

Table 1 The results of cross-validation					
Hidden unit	1	2	3	4	5
Mean square error	0.16	0.089	0.0079	0.010	0.0095
Hidden unit	6	7	8	9	10
Mean square error	0.0103	0.011	0.0096	0.0095	0.0095

##### 3.2.2 激活函数的指数系数

为了使隐节点的输出能更好的地于0或1,本工作在激活函数的指数上加入一个正的系数*a*,激活函数为

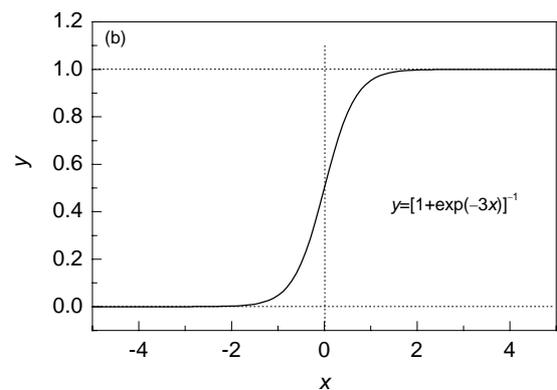
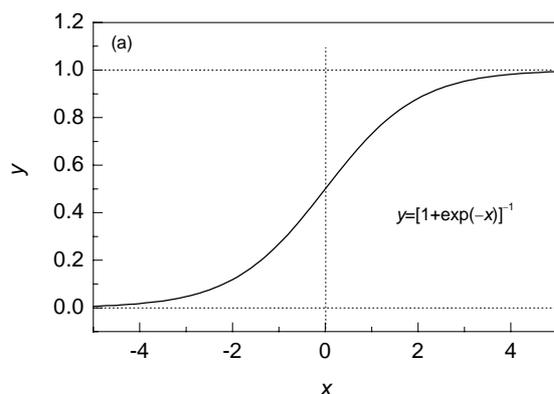


图1 不同指数系统的logsig函数对比

Fig.1 Comparison of logsig functions with different exponent coefficients

$f(x)=(1+e^{-ax})^{-1}$ , 如图 1 所示, 其中图 1(a)的自适应系数  $a=1$ , 图 1(b)的自适应系数  $a=3$ . 当  $a=1$  时, 函数曲线变化比较平缓; 当  $a=3$  时, 函数的曲线变化较快, 0 点附近的函数值快速地逼近 0 或 1. 因此本工作要求  $a>1$ .

由图 1(b)可知, 当  $x>0$  时,  $f(x)$ 的函数值随着  $x$  的增大而迅速地趋于 1, 当  $x<0$  时,  $f(x)$ 的函数值随着  $x$  的减少而迅速地趋于 0, 从而可使函数的输出更好地向 2 个极值逼近, 便于后续的规则抽取, 这里取  $a=3$ .

### 3.2.3 神经网络剪枝

神经网络的规则抽取实质上是一个搜索过程. 经过训练并达到预期精度的全连接神经网络通常具有太多的神经元和链枝, 从中提取规则非常困难. 网络剪枝的目的就是删除那些不影响(或影响可以忽略)模型准确性的神经元和链枝, 从而得到简化的神经网络, 以便于后续的规则抽取. 由于在激活函数上加入了指数系数  $a$ , 因此本工作在文献[9]的剪枝算法中做了一些改进, 具体剪枝步骤如下:

(1) 给定 2 个正数  $\eta_1$  和  $\eta_2$ , 使  $\eta_1+\eta_2<0.5$ ( $\eta_1$  为误差范围,  $\eta_2$  为决定权值被删除的极限值), 通常  $\eta_1$  和  $\eta_2$  分别取为 0.35 和 0.1; (2) 读取一个训练好的神经网络, 设  $(w, v)$  为神经网络的权值; (3) 对每个输入层到隐含层的权值  $w_{ml}$ , 如果满足

$$\text{Max}_p |v_{pm} w_{ml}| \leq 16\eta_2/a^2,$$

则  $w_{ml}$  可被删除, 其中,  $w_{ml}$  为第  $m$  个隐节点与第  $l$  个输入节点的连接权值,  $v_{pm}$  为第  $p$  个输出节点与第  $m$  个隐节点的连接权值,  $a$  为激活函数的指数系数; (4) 对每个隐含层到输出的权值  $v_{pm}$ , 如果满足  $|v_{pm}| \leq 4\eta_2/a$ , 则  $v_{pm}$  可被删除; (5) 如果没有权值满足步骤(2)和(3), 则对于每个  $w_{ml}$ , 删除  $\text{Max}_p |v_{pm} w_{ml}|$  中最小的  $w_{ml}$ ; (6) 对网络重新训练, 如果网络训练的准确率低于一个可以接受的水平, 例如 95%的正确率, 则停止, 并选用上一次的权值, 否则转至第(3)步.

由于步骤(3)和(4)是根据权值的大小进行剪枝, 因此必须保证神经网络在训练过程中其权值不能过大, 同时, 较小的权值要更快地趋于 0. 因此, 本工作引入了如下的权值衰减函数:

$$P(w, v) = \varepsilon_1 \left( \sum_{m=1}^h \left( \sum_{l=1}^k \frac{\beta w_{ml}^2}{1 + \beta w_{ml}^2} + \sum_{p=1}^c \frac{\beta v_{pm}^2}{1 + \beta v_{pm}^2} \right) \right) + \varepsilon_2 \sum_{m=1}^h \left( \sum_{l=1}^k w_{ml}^2 + \sum_{p=1}^c v_{pm}^2 \right), \quad (2)$$

其中,  $\varepsilon_1, \varepsilon_2, \beta$  为正的权值衰减系数, 由 2 个子函数共同组成, 函数后一部分可以抑制权值在训练过程中变得过

大, 函数前一部分可使权值在训练过程中较小的权值更快地趋于 0. 包含了衰减函数的误差函数为

$$\text{Error} = \frac{1}{c} \sum_{i=1}^k \sum_{p=1}^c (S_{pi} - T_{pi})^2 + P(w, v). \quad (3)$$

本工作采用 LM(Levenberg-Marquardt)算法来训练神经网络, 对于中等规模的前馈神经网络, LM 算法收敛速度更快, 且该算法能获得比其他任何一种算法更小的均方误差<sup>[14]</sup>.

### 3.3 规则抽取

本方法要求神经网络节点带有阈值, 且激活函数为 logsig, 基本思想是, 当网络节点的输入大于其阈值时, 认为该节点被激活, 其输出趋于 1, 反之, 其输出趋于 0, 即假设网络节点的输出只有 2 种情况: 0 和 1. 如果输入组合与其相应的权值乘积大于该节点的阈值, 则认为该节点的输出为 1, 从而得到相应规则; 如果输入组合与其相应的权值乘积小于该节点的阈值, 则认为该节点的输出为 0, 也可得到相应规则.

规则抽取首先从输出层开始, 先得到隐含层到输出层之间的规则, 然后得到输入层到隐含层之间的规则, 最后将 2 个规则合并, 即得到输入层到输出层之间的规则.

## 4 冷轧带钢热镀锌产品质量监控模型

由于在实际的冷轧带钢热镀锌生产过程中, 带钢的规格、材质、目标锌层重量等都可能随生产计划而发生变化, 因而必须根据气刀调节的能力及产品的制造要求对气刀间距、压力等参数作出及时调整, 避免锌层厚度超差而影响产品质量. 考虑到实际生产过程中的各工艺参数的控制条件, 锌重质量模型的输出变量为锌重, 输入变量选为气刀压力、气刀到带钢的距离及机组的速度.

选取某钢厂的冷轧带钢热镀锌生产线的实际生产数据, 以每一卷带钢为取样点, 收集气刀的压力、气刀到带钢的距离、机组运行速度等工艺参数和带钢下表面的锌层重量, 共有 1132 组数据. 选取 756 个样本进行训练, 376 个样本进行测试.

根据对锌重( $w, \text{g/m}^3$ )的不同要求, 将其分成 3 个类别, 即  $w \geq 115$ 、 $80 \leq w < 115$ 、 $w < 80$ , 然后用 1/N 编码对锌重进行编码, 对应的编码分别是 {1 0 0}, {0 1 0}, {0 0 1}. 输入变量为气刀的压力  $p$ 、气刀到带钢的距离  $d$ 、机组速度  $v$ , 输入输出数据的统计结果如表 2 所示. 利用聚类的方法对数据离散化, 用温度计编码后得到 17 个输入变量.

表 2 气刀参数和锌层重量的统计结果

Table 2 The statistical results of air-knife parameters and zinc layer weight

Operation	Variable	Maximum value	Minimum value	Mean	Standard error
Input	Air-knife pressure (kPa)	46.998	7.500	25.786	77.59
	Distance from air-knife to strip (mm)	32.20	9.99	14.29	3.95
	Galvanizing set velocity (m/min)	150.00	37.78	113.98	26.51
Output	Mean of zinc layer weight (g/m <sup>2</sup> )	149.00	40.00	85.84	20.72

建立神经网络，结构如图 2 所示。利用编码后的数据对神经网络进行训练，对神经网络进行剪枝，并保证剪枝后的训练精度在 95% 以上，保存网络的权值。

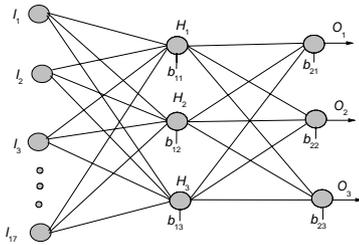


图 2 剪枝前的神经网络结构  
Fig.2 Neural network structure before pruning

选择一个连接较少且训练精度较高的神经网络进行规则抽取，网络结构如图 3 所示，该网络的训练精度为 95.5%，测试精度为 94.9%。

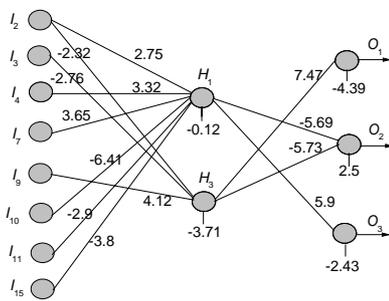


图 3 剪枝后的神经网络结构  
Fig.3 Neural network structure after pruning

根据图 3 的神经网络结构进行规则抽取。首先提取隐含层到输出层的相应规则，如要获取  $O_1$  类别的规则，必须满足  $O_1=1$ ，由与  $O_1$  相连接的隐含节点及相应权值推出  $7.47H_3-4.32>0$ ，得  $H_3=1$ ；接着从输入层到隐含层提取相应的规则，对隐含节点  $H_3$ ，必须满足  $H_3=1$ ，根据与  $H_3$  相连接的输入节点及相应权值推出  $-2.23I_2-2.76I_3+4.12I_9-3.71>0$ ，搜索满足不等式的可能组合，得  $I_2=0, I_3=0, I_9=1$ 。

合并规则得，若  $I_2=0, I_3=0, I_9=1$ ，则  $O_1=1$ ；对照温度计编码，还原到初始的输入变量，得规则为：若  $p \leq 32.9$  且  $d \geq 19.5$ ，则  $w \geq 115$ 。同理可获得  $O_2, O_3$  类别的规则，抽取到的所有规则如下：

- 规则 1：若  $p \leq 32.9$  且  $d \geq 19.5$ ，则  $w \geq 115$ 。
- 规则 2：若  $p > 36, d \geq 17.5, v > 90$ ，则  $80 \leq w < 115$ 。

- 规则 3：若  $36 \geq p > 32.9, d \geq 17.5$ ，则  $80 \leq w < 115$ 。
- 规则 4：若  $36 \geq p > 29.35, 19.5 > d \geq 17.5$ ，则  $80 \leq w < 115$ 。
- 规则 5：若  $29.35 \geq p > 18.65, d < 19.5, v > 90$ ，则  $80 \leq w < 115$ 。

- 规则 6：若  $p \leq 18.65$  且  $d < 19.5$ ，则  $80 \leq w < 115$ 。
- 规则 7：若  $p > 36, d < 17.5, v \leq 90$ ，则  $w < 80$ 。
- 规则 8：若  $36 \geq p > 29.35, d < 17.5, v > 90$ ，则  $w < 80$ 。
- 规则 9：若  $29.35 \geq p > 18.65, d < 17.5$ ，则  $w < 80$ 。

上面规则的本样本覆盖率统计结果如表 3，其中“/”前面的数据为规则覆盖到的样本个数，后面的数据为实际的样本个数。

表 3 样本的覆盖率

Table 3 The overcast ratio of samples

Class	Training	Testing	Overall
Zinc weight $\geq 115$	36/38	17/18	53/56
$80 \leq$ Zinc weight $< 115$	517/540	256/269	773/809
Zinc weight $< 80$	166/178	81/89	247/267
Overall	719/756	354/376	1073/1132

这些规则全面地包含了各变量之间的对应关系，可以帮助工作人员更深入地认识冷轧带钢连续热镀锌生产过程的规律，可以在连续生产过程中，根据不同的锌层重量要求选择合适的控制参数，进行实时控制。如要获得大于  $115 \text{ g/m}^2$  的锌层重量的带钢，则可以根据规则 1 将气刀压力控制在小于  $32.9 \text{ kPa}$  的范围内，并且气刀到带钢的距离控制在  $19.5 \text{ mm}$  以上。这样既保证了产品的质量，又提高了生产效率。

本工作根据样本的覆盖率大小与 RX 和 SRE 方法进行对比，结果如表 4 所示。由表中的数据可知，本工作的方法比 RX 和 SRE 方法具有更高的覆盖率。

表 4 与 RX, SRE 方法比较

Table 4 Comparison with RX (rule extraction) method and SRE (structure-based neural network rule extraction) method

Class	Structure-based neural network rule extraction	Rule extraction	Proposed
Zinc weight $\geq 115$	53/56 (94.6%)	53/56 (94.6%)	53/56 (94.6%)
$80 \leq$ Zinc weight $< 115$	646/809 (79.8%)	757/809 (93.5%)	773/809 (95.5%)
Zinc weight $< 80$	242/267 (90.6%)	218/267 (81.6%)	247/267 (92.5%)
Overall	941/1132 (83.1%)	1028/1132 (90.8%)	1073/1132 (94.8%)

## 5 应用分析

### 5.1 关于输入输出数据的聚类

对生产质量模型输入输出数据的聚类处理是为了满足神经网络输入输出二值化的要求。对这些数据的聚类处理可以根据已有的先验知识直接进行分类, 例如, 作为输出数据的产品质量通常会有一定的分级, 则可按照不同级别的参数范围直接对输出数据进行分类。若无可利用的分类依据, 则直接根据数据本身的分布规律自动进行聚类处理。聚类时应使类别数目尽可能少的同时保证类内距离最小、类间距离最大。

### 5.2 规则的推理

从剪枝后的神经网络中可以得到若干等式或不等式, 由于网络输入输出数据只能是0或1, 所以根据权值的具体数值可以推出各节点输入可能的取值, 再根据编码规则就能换算出原始参数区间所对应的规则。由于这种规则的推理属于一种穷举遍历过程, 因此可以利用计算机自动完成搜索, 实现自动的规则推理与合并。

### 5.3 算法的工程应用

在实际的冷轧带钢热镀锌生产和调试中, 锌层重量的控制主要依赖于操作人员的工作经验, 经验的多少决定了实际的生产成本和生产效率, 且具有较强的主观性。本工作采用神经网络规则提取方法, 利用实际的生产数据提取质量参数和控制参数之间的对应关系, 为参数的控制提供客观的指导, 特别是对于工作经验欠缺的操作人员, 具有重要的指导意义。

## 6 结论

采用神经网络规则抽取的建模方法, 建立了热镀锌带钢的质量监控模型, 利用交叉检验方法确定了最优的神经网络初始结构; 在神经网络训练中引入权值衰减方

法, 提高了神经网络的剪枝效果, 降低了规则的搜索复杂度; 有效地提取了规则形式的输入与输出变量之间的对应关系, 为新工艺的生产调试和产品质量控制提供了有效的理论依据, 对改善生产工艺、节约生产成本、提高生产效率和产品质量等方面具有重要的现实意义。

### 参考文献:

- [1] 李九龄. 带钢连续热镀锌 [M]. 北京: 北京工业出版社, 1981. 179-256.
- [2] 林莉军. 宝钢热镀锌机组锌层重量控制模型的应用 [J]. 宝钢技术, 2007, (4): 33-36.
- [3] 王宸煜, 王敏, 董溯攀. 人工神经网络在镀锌钢板点焊性能检测中的应用 [J]. 上海交通大学学报, 2001, 35(3): 420-423.
- [4] Sanchez A P, Blanco I D, Vega A A C, et al. Virtual Sensor Design for Coating Thickness Estimation in a Hot Dip Galvanising Line Based on Interpolated SOM Local Models [A]. IEEE. IEEE Industrial Electronics Society, 2002 28<sup>th</sup> Annual Conference of the Industrial Electronics Society [C]. New York: IEEE Press, 2002. 1584-1589.
- [5] 姚林, 阳建宏, 何飞, 等. 基于核偏最小二乘的锌层重量预测模型 [J]. 控制工程, 2008, 15(2): 154-157.
- [6] 姚林, 阳建宏, 徐金梧, 等. 基于偏最小二乘回归模型的带钢热镀锌质量监控方法 [J]. 北京科技大学学报, 2007, 29(6): 627-631.
- [7] Setiono R. Extracting Rules from Pruned Neural Networks for Breast Cancer Diagnosis [J]. Artificial Intelligence in Medicine, 1996, 8(1): 37-51.
- [8] 赵林, 杨保安, 谢志鸣. 一种新的基于结构的神经网络规则抽取方法 [J]. 计算机应用与软件, 2007, 24(6): 28-48.
- [9] Setiono R. A Penalty-function Approach for Pruning Feedforward Neural Networks [J]. Neural Computation, 1995, 9(1): 185-204.
- [10] Ennett C M, Frize M. Weight-elimination Neural Networks Applied to Coronary Surgery Mortality Prediction [J]. IEEE Transactions on Information Technology in Biomedicine, 2003, 7(2): 86-92.
- [11] 宋擒豹, 沈钧毅. 神经网络数据挖掘方法中的数据准备问题 [J]. 计算机工程与应用, 2000, 36(12): 102-104.
- [12] Schenker B, Agarwal M. Cross-validated Structure Selection for Neural Networks [J]. Comp. Chem., 1996, 20(2): 175-186.
- [13] Andersen T, Martinez T. Cross Validation and MLP Architecture Selection [A]. IEEE. Proceedings of the IEEE International Joint Conference on Neural Network [C]. Washington, DC: IEEE Press, 1999. 1614-1619.
- [14] Hagan M T, Demuth H B, Beale M H. 神经网络设计 [M]. 戴葵, 等译. 北京: 机械工业出版社, 2006. 239-244.

## Strip Hot-dip Galvanizing Quality Monitoring Model Based on Neural Network Rule Extraction

WANG Jian-guo<sup>1,2</sup>, YANG Jian-hong<sup>1</sup>, ZHANG Wen-xing<sup>2</sup>, XU Jin-wu<sup>1</sup>

(1. Mechanical Engineering School, University of Science and Technology Beijing, Beijing 100083, China;

2. Mechanical Engineering School, University of Science and Technology Inner Mongolia, Baotou, Inner Mongolia 014010, China)

**Abstract:** To overcome the difficulty of production quality monitoring model based on traditional neural network which is usually used poorly, a strip hot-dip galvanizing quality monitoring model based on neural network rule extraction is proposed. Taking the quality monitoring of zinc coating weight in strip hot-dip galvanizing as the investigated subject, the sample datasets are trained by neural network rule extraction method to obtain the quantitative relationships in the form of knowledge rules among input variables (such as the parameters of raw materials and control parameters of production) and output ones (the quality parameters), with which the production control parameters can be set and updated easily. 756 training and 376 testing examples are chosen as variables of the network. The results show that the new model has a rule-overcast-ratio of 94.8% and has provided an effective tool for auto-control of product quality, because in the new model the range of each input variable can be readily set up based on the target range of the output variables.

**Key words:** neural network; rule extraction; strip hot-dip galvanizing; quality monitoring