

# 热轧非稳态过程轧制力自学习模型优化

彭文<sup>1</sup>, 姬亚锋<sup>2</sup>, 陈小睿<sup>1</sup>, 张殿华<sup>1</sup>

(1. 东北大学 轧制技术及连轧自动化国家重点实验室, 辽宁 沈阳 110819; 2. 太原科技大学 机械工程学院, 山西 太原 030024)

**摘 要:** 为提高热连轧非稳态过程轧制力的预测精度,提出了一种轧制力自学习模型优化方法. 将模型自学习系数分解为层别学习系数和轧制状态学习系数,表征机架间轧制力预报偏差的遗传特性及实际轧辊状态对模型预报的影响. 在系数更新过程中,根据层别距离分别对学习系数进行更新,减小了轧制规格切换时轧制力的预报误差. 所提方法已成功应用于某热连轧过程,与原模型相比,优化后的自学习方法的预测偏差从2.8%降低到1.4%,均方差从3.3%降低到1.7%,有效提高了非稳态过程轧制力的预测精度和鲁棒性.

**关 键 词:** 热轧;轧制力;非稳态过程;层别距离;预测偏差

**中图分类号:** TG 335.5      **文献标志码:** A      **文章编号:** 1005-3026(2019)10-1408-05

## Optimization of Rolling Force Self-learning Model in Unsteady Process of Hot Rolling

PENG Wen<sup>1</sup>, JI Ya-feng<sup>2</sup>, CHEN Xiao-rui<sup>1</sup>, ZHANG Dian-hua<sup>1</sup>

(1. State Key Laboratory of Rolling and Automation, Northeastern University, Shenyang 110819, China;  
2. School of Mechanical Engineering, Taiyuan University of Science and Technology, Taiyuan 030024, China.  
Corresponding author: PENG Wen, E-mail: pengwen233@163.com)

**Abstract:** In order to improve the predicted precision of rolling force in unsteady process, an optimization method for rolling force self-learning model was proposed. The self-learning coefficient in the model was decomposed into the layer learning coefficient and rolling state learning coefficient, which characterized the genetic characteristics of rolling force prediction deviation between racks, and the effect of actual roll state on the model prediction. In the process of coefficient updating, the learning coefficients were updated according to the layer distance so that the prediction error of rolling force could be reduced, especially when the rolling specifications were switched. The proposed self-learning method has been successfully applied into a hot rolling process. Compared with the original model, the predicted deviation of the optimized self-learning method is reduced from 2.8% to 1.4%, and the mean square error is reduced from 3.3% to 1.7%, which effectively improve the accuracy and robustness of rolling force in unsteady process.

**Key words:** hot rolling; rolling force; unsteady process; layer distance; prediction deviation

在热连轧生产过程中,存在着大量的非稳态轧制过程,如停轧待料、规格切换等过程轧制力预报精度比较低. 为了提高轧制力模型的预报精度,许多学者进行了有益尝试,研究工作主要包括改进数学模型本身结构和模型系数优化方面,从模型结构角度对模型精度的提高程度十分有

限<sup>[1-5]</sup>. 更多的学者从模型自学习的角度进行了研究,文献[6]通过对轧制力模型自学习算法的研究分析,确立了自学习速度因子的选取策略及长期自学习的处理方法,并通过仿真验证了模型的有效性;文献[7]建立了温度和轧制力的目标函数,通过函数求解获得了轧制力和温度的在线

收稿日期: 2018-10-29

**基金项目:** 国家自然科学基金资助项目(51704067,51634002); 中央高校基本科研业务专项资金资助项目(N180704006); 轧制技术及连轧自动化国家重点实验室开放课题(2017RALKFKT009).

**作者简介:** 彭文(1987-),男,山东青州人,东北大学副研究员;张殿华(1963-),男,内蒙古赤峰人,东北大学教授,博士生导师.

优化过程;文献[8]提出了一种学习过程层别跳变的自整定方法,消除自学习系数间的震荡问题,提高轧制力预报精度;文献[9]采用神经网络对轧制力模型关键参数进行优化,提高了模型的预报精度.文献[10]提出了一种神经网络模型及人工智能的方法,并建立了轧制力自学习方法,通过离线分析验证了模型的有效性,但其计算过程需要大量数据进行训练,尚未实现在线使用.

本文在分析轧制力偏差的基础上,从钢种/厚度层别和机架轧制状态两个角度将模型自学习系数进行了分解,一方面考虑了厚度、温度偏差等对各机架轧制力预报影响的普遍性,另一方面考虑了实际轧制状态对轧制力预报造成的影响.在系数更新的过程中,采用学习系数动态更新的策略,有效地提高了规格切换时的轧制力预报精度,对于提高产品质量具有重要意义.

# 1 轧制力模型基本原理

## 1.1 轧制力模型

模型的自学习功能是根据实际生产工况不断变化的情况,利用当前实测数据对模型系数进行实时、在线修正,使数学模型不断适应变化的生产状态,保证模型的在线预报精度.以 SIMS 模型为例,轧制力模型基本结构为

$$F=\lambda B l_c Q_p K_m. \tag{1}$$

式中: $F$ 为轧制力,kN; $\lambda$ 为自学习系数; $B$ 为轧件宽度,mm; $l_c$ 为轧件接触弧的水平投影长度,mm; $Q_p$ 为应力状态影响系数,无量纲; $K_m$ 为根据实验或统计数据得出的变形抗力,MPa.

在轧制力自学习模型中,仅使用自学习系数 $\lambda$ 来考虑轧制过程中的设备特性、润滑条件及温度预报偏差等的影响,将各因素对轧制力预报的影响统一处理,难以区分各因素对轧制力预报的影响,从而会造成规格切换时无法对轧制力进行有针对性的预测,从而影响到控制效果.

## 1.2 轧制力自学习模型

轧制力的自学习过程是基于实际轧制过程中的工况条件计算得到的,各机架出入口厚度是根据末机架出口实际厚度并按照秒流量恒定原则计算得到,各机架的出入口温度和宽度分别根据温度、宽度预测和自学习模型计算得到<sup>[11~14]</sup>.通过再计算得到各机架的出口宽度 $B'$ 、接触弧长度 $l'_c$ 、应力状态影响系数 $Q'_p$ 和变形抗力 $K'_m$ ,将得到的轧制力再预报值 $F'$ 与实测轧制力 $F^*$ 相比,从而得到新的模型自学习系数.模型自学习系数计

算式为

$$\lambda'=\frac{F^*}{F'}=\frac{F^*}{B'l'_cQ'_pK'_m}. \tag{2}$$

自学习系数的更新一般按照指数平滑法进行<sup>[15]</sup>:

$$\lambda^*=\alpha\lambda+(1-\alpha)\lambda'. \tag{3}$$

式中: $\lambda'$ 为自学习系数计算值; $\lambda$ 为自学习系数旧值; $\alpha$ 为平滑系数, $0<\alpha<1$ .

在实际生产过程中,一般使用钢种和厚度划分层别来实现不同规格轧制力自学习系数的存放,某热轧线的钢种层别和厚度层别划分如表 1 和表 2 所示.厚度层别一般按照其尺寸范围进行区间划分,在某一厚度范围之内内的产品均使用同样的自学习系数.

表 1 钢种层别划分  
Table 1 Steel layers division

钢种层别号	代表钢种	钢种层别号	代表钢种
1	IF, STW25	4	SM490, Q450
2	SPHC, ST12	5	X65, J55
3	SS400, 45#, 65Mn	6	L360

表 2 厚度层别划分  
Table 2 Thickness layers division mm

厚度层别号	厚度范围	厚度层别号	厚度范围
1	≤1.5	6	4.6~6.0
2	1.5~2.0	7	6.0~8.0
3	2.0~2.7	8	8.0~10.0
4	2.7~3.5	9	10.0~14.0
5	3.5~4.6	10	>14

注:厚度范围包含上限节点.

带钢层别使用坐标(厚度层别、钢种层别)表述,但在生产过程中,若所生产规格在厚度节点附近很小范围变化时,如 2.70 mm 和 2.71 mm 分属不同厚度层别,当现场进行公差轧制时,很容易出现层别跳变,此时模型会调用不同的学习系数,从而对轧制力的预报造成影响.

# 2 轧制力模型自学习算法优化

变形抗力的预报偏差主要来源于化学成分波动、厚度及温度预报偏差.由于轧制过程中化学成分不会再次产生波动,实际成分与目标成分之间的偏差对各机架的影响是一致的.粗轧机组能够精确控制中间坯厚度,同时文献[1]指出,即便出现入口厚度偏差,机架本身也可以降低厚差对下游机架的轧制力影响.由于变形过程中轧件温度

的不可测性,温度是变形抗力偏差产生的最主要因素.轧制特性分析的结果表明<sup>[16-17]</sup>:温度预测偏差会遗传到下游机架,并在各机架呈近似线性分布,将这种遗传特性用层别自学习系数 $\lambda_k$ 来表征,层别自学习系数使用钢种层别和厚度层别划分,进一步使用最小二乘法进行线性回归得到该系数.另一方面,轧制力的预报与各机架磨损程度、润滑状态有关,各机架相互独立,因此使用轧制状态自学习系数 $\lambda_s$ 来表示各机架轧制状态的差异对轧制力预报造成的影响.因此,第*i*机架轧制力自学习系数为

$$\lambda_i = \lambda_{k,i} + \lambda_{s,i} = (\lambda_{\text{off}} + \lambda_{\text{slope}} \cdot i) + \lambda_{s,i}. \quad (4)$$

式中, $\lambda_{\text{off}}$ 和 $\lambda_{\text{slope}}$ 为最小二乘法得到的回归系数.

轧制力模型自学习系数优化流程如图 1 所示.主要包括以下步骤:

- 1) 基于实际轧制过程中的工况条件对轧制力进行再预报,得到第*i*机架的轧制力再预报值 $F'_i$ .
- 2) 与得到第*i*机架的轧制力预测偏差 $\Delta F_i = F_i^* - F'_i$ ,利用式(2)计算得到学习系数再计算值 $\lambda'_i = \frac{F_i^*}{F'_i}$ .

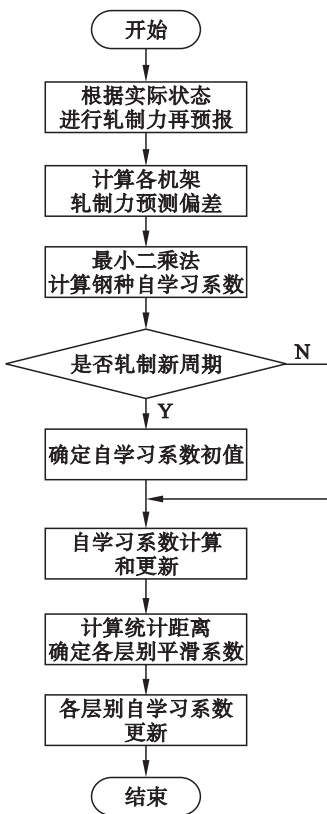


图 1 轧制力模型自学习系数优化流程  
Fig. 1 Flow chart of optimized strategy for the self-learning model

- 3) 使用最小二乘法回归层别自学习系数, $\lambda_{\text{off}}$ 和 $\lambda_{\text{slope}}$ 计算式为
- $$\left. \begin{aligned} \lambda_{\text{off}} &= \frac{(\sum i^2)(\sum \Delta F_i) - (\sum i)(\sum i\Delta F_i)}{n(\sum i^2) - (\sum i)^2}, \\ \lambda_{\text{slope}} &= \frac{n(\sum i\Delta F_i) - (\sum i)(\sum \Delta F_i)}{n(\sum i^2) - (\sum i)^2}. \end{aligned} \right\} \quad (5)$$

4) 自学习系数的初值判断:若轧辊更换后在新的轧制周期,将机架轧制状态自学习系数初始化为 0;否则使用上一带钢的轧制状态自学习系数.

5) 自学习系数的计算和更新:对回归得到的系数 $\lambda_{\text{off}}$ 和 $\lambda_{\text{slope}}$ 采用式(3)所示的方法平滑处理后,计算得到第*i*机架层别自学习系数 $\lambda_{k,i} = \lambda_{\text{off}} + \lambda_{\text{slope}} \cdot i$ ,然后计算机架轧制状态自学习系数 $\lambda_{s,i} = \lambda'_i - \lambda_{k,i}$ ,同理,需要采用式(3)进行平滑处理.

6) 各层别自学习系数的更新:为消除换规格后层别改变造成的学习系数跳变的影响,在本层别系数更新时,其他层别的系数也进行相应更新;距当前层别越近,系数更新幅度越大,距当前层别越远,系数更新幅度越小;同时由表 2 可以看出,厚度范围不同,同一学习系数覆盖的厚度区间不同,厚度间距与层别间距不一致,如 3.00 mm 和 3.40 mm 规格属于同一厚度层别 4,但 3.00 mm 更靠近在层别 3,3.40 mm 更靠近层别 5,因此在系数更新过程需要对层别厚度区间进行无量纲归一化处理,如图 2 所示,再根据层别距离远近确定自学习平滑系数,层别*M*的平滑系数 $\alpha_M$ 计算式为

$$\alpha_M = \frac{\lambda_D^*}{\lambda'_D} \exp \left( - \left( \frac{x_{DM}}{m} \right)^2 \right). \quad (6)$$

式中: $\lambda_D^*$ 为层别*D*的学习系数新值; $\lambda'_D$ 为层别*D*的学习系数再计算值; $x_{DM}$ 为归一化后层别*D*和*M*间的距离;*m*为归一化后两层别间最小距离,可调整,此处取*m*=0.5;

将厚度层别无量纲归一化后的距离定义为 1 个单位长度,不同厚度层别将会归一为同样的区间长度,将实际生产规格坐标由厚度层别、钢种层别改为由厚度归一坐标、钢种层别表述.以钢种层别 3,厚度 3.00 mm 规格为例,传统方式下用坐标*D*(4,3)表示,归一化后使用(4.375,3)表示,此种方式处理后更能够体现所生产规格在本层别中的具体位置,如图 3 所示;在计算层别间距离时,其余层别用中心点位置作为层别基准点,

由此得到层别  $D$  和  $M$  间距离  $x_{DM} = \sqrt{(4.375 - 5.50)^2 + (3 - 1)^2} = 2.30$ , 根据式 (6) 计算该层别的学习系数的平滑系数, 从而完成各层别系数的更新过程.




图 2 厚度层别归一化

Fig. 2 Thickness layer normalization




图 3 层别划分示意图

Fig. 3 Schematic of layers division

### 3 现场实际应用效果

本文提出的轧制力优化算法已成功应用于某 7 机架热连轧生产线, 为验证优化之后轧制力自学习算法的有效性, 在两个轧制周期内, 采用同样的生产计划, 分别使用传统自学习方法和优化之后的自学习方法, 轧制力预报偏差均值统计结果如图 4 所示.

在图 4 中, 初始阶段表示换辊后轧制开始, 层别更换发生在第 16, 第 47, 第 104, 第 141 和第 166 块. 可以看出, 换辊开始时, 在新的轧制环境下, 轧制力的预报偏差分别为 10.4% 和 6.7%; 换规格时的轧制力预报偏差分别由 4.8%, 6.3%, 5.0%, 5.9% 和 8.7% 降低到 0.1%, 3.1%, 4.8%, 1.7% 和 6.6%. 统计数据表明, 优化前后

的平均轧制力预报偏差由 2.8% 降低到 1.4% 左右, 轧制力预报均方差由 3.3% 降低到 1.7%. 可以看出, 本方法能够有效提高轧制力的预报精度.




图 4 优化前后轧制力预报偏差比较

Fig. 4 Comparison of rolling force prediction deviation before and after optimization

### 4 结 论

1) 提出了针对非稳态过程轧制力模型自学习优化算法, 用两种学习系数对轧制力的影响因素进行划分.

2) 在学习系数更新时, 按照层别间距离对所有层别的学习系数进行更新, 减小了由于规格切换或轧制状态发生变化时轧制力模型的预报误差.

3) 实际生产数据表明, 采用优化之后的自学习算法, 平均轧制力预报偏差降低到 1.4%, 轧制力预报均方差降低到 1.7%, 有效提高了轧制力的预报精度.

### 参考文献:

- [1] 孙一康. 冷轧板带轧机的模型与控制[M]. 北京: 冶金工业出版社, 2010: 245 - 248.  
(Sun Yi-kang. Model and control of cold and hot strip rolling [M]. Beijing: Metallurgical Industry Press, 2010: 245 - 248.)
- [2] Lenard J G. Primer on flat rolling [M]. London: Elsevier, 2007.
- [3] Peng W, Zhang D H, Zhao D W. Application of parabolic velocity field for the deformation analysis in hot tandem rolling [J]. International Journal of Advanced Manufacturing Technology, 2017, 91 (5/6/7/8): 2233 - 2243.
- [4] 章顺虎, 王晓南, 赵德文, 等. 角平分屈服准则解析热轧厚板展宽轧制力[J]. 辽宁科技大学学报, 2016, 39(6): 418 - 423.  
(Zhang Shun-hu, Wang Xiao-nan, Zhao De-wen, et al. Analysis of broadside rolling force for hot heavy plate using angle bisector yield criterion [J]. Journal of University of Science and Technology Liaoning, 2016, 39(6): 418 - 423.)
- [5] 李维刚, 陈水宣, 刘相华. 热轧带钢精轧过程考虑相变的轧制力模型[J]. 东北大学学报(自然科学版), 2013, 34



- (10):1425–1429.  
(Li Wei-gang, Chen Shui-xuan, Liu Xiang-hua. Rolling force model considering phase transformation for hot strips during finishing process [J]. *Journal of Northeastern University (Natural Science)*, 2013, 34(10):1425–1429. )
- [6] 王健, 肖宏, 张晶旭. 热带钢精轧机组轧制力预设定模型自主学习研究 [J]. 中南大学学报(自然科学版), 2014, 45(10):3398–3407.  
(Wang Jian, Xiao Hong, Zhang Jing-xu. Research on self-learning of hot strip finishing setup model for rolling force [J]. *Journal of Central South University (Science and Technology)*, 2014, 45(10):3398–3407. )
- [7] Peng W, Liu Z Y, Yang X L, et al. Optimization of temperature and force adaptation algorithm in hot strip mill [J]. *Journal of Iron and Steel Research, International*, 2014, 21(3):300–305.
- [8] 丁敬国, 曲丽丽, 胡贤磊, 等. 中厚板轧制力自主学习过程层别跳变的自整定方法 [J]. 东北大学学报(自然科学版), 2011, 32(1):64–66, 71.  
(Ding Jing-Guo, Qu Li-li, Hu Xian-lei, et al. Self-adjusting for plate thickness layer skipping in rolling force learning process [J]. *Journal of Northeastern University (Natural Science)*, 2011, 32(1):64–66, 71. )
- [9] Son J S, Lee D M, Kim I S, et al. A study on on-line learning neural network for prediction for rolling force in hot-rolling mill [J]. *Journal of Materials Processing Technology*, 2005, 164/165:1612–1617.
- [10] 陈治明, 罗飞, 黄晓红, 等. 基于混沌优化支持向量机的轧制力预测 [J]. 控制与决策, 2009, 24(6):808–812.  
(Chen Zhi-ming, Luo Fei, Huang Xiao-hong, et al. Rolling force prediction based on chaotic optimized support vector machine [J]. *Control and Decision*, 2009, 24(6):808–812. )
- [11] Vladimir P. Model for prediction of strip temperature in hot strip steel mill [J]. *Applied Thermal Engineering*, 2007, 27(14/15):2404.
- [12] Park C J, Hwang I C. Width control systems with roll force automatic width control and finishing vertical mill automatic width control in hot strip mill [J]. *Journal of Materials Processing Technology*, 2008, 206(1/2/3):143–151.
- [13] Pen G W, Liu Z Y, Yang X L, et al. Optimization of temperature and force adaptation algorithm in hot strip mill [J]. *Journal of Iron and Steel Research (International)*, 2014, 21(3):300–305.
- [14] 马更生, 彭文, 刘元铭, 等. 带钢精轧阶段高精度宽度控制策略 [J]. 轧钢, 2017, 34(3):61–63.  
(Ma Geng-sheng, Peng Wen, Liu Yuan-ming, et al. High precision controls strategy of strip width in hot finishing rolling [J]. *Steel Rolling*, 2017, 34(3):61–63. )
- [15] Davies R, Coole T, Osipyw D. The application of time series modeling and Monte Carlo simulation: forecasting volatile inventory requirements [J]. *Applied Mathematics*, 2014, 5(8):1152–1168.
- [16] Zhao T Y, Xiao H. Improved model to solve influence coefficients of work roll deflection [J]. *Journal of Central South University of Technology*, 2010, 17(5):1000–1005.
- [17] Peng W, Chen S Z, Gong D Y, et al. Adaptive threading strategy based on rolling characteristics analysis in hot strip rolling [J]. *Journal of Central South University*, 2017, 24(9):1560–1572.