

基于 GA-PELM 的板材热连轧轧制力预测

杨 静, 任 彦, 高晓文, 苏 楠

(内蒙古科技大学 信息工程学院, 内蒙古 包头 014010)

摘要: 在板材热连轧过程中, 轧制力的计算精度直接影响板带钢的实际厚度, 也是实现精准在线控制的前提。然而, 由于实际的轧制过程受多种因素影响, 使用传统模型进行预测的精度往往比较低。为了提高轧制力的预测精度, 提出了并行异构极限学习机 (PELM) 的轧制力预测模型, 该模型学习速度快且泛化能力强, 同时为了保证模型的稳定性, 采用遗传算法 (GA) 优化了该模型的权重和偏差。以包头某钢厂 2250 生产线的实际生产数据为例进行轧制力预测, 结果表明, 该算法训练的轧制力预测模型有很好的预测精度, 适用于热连轧过程的轧制力预测。

关键词: 带钢热连轧; 轧制力; 并行异构极限学习机; 遗传算法; 网络结构

DOI: 10.13330/j.issn.1000-3940.2022.01.006

中图分类号: TP183

文献标志码: A

文章编号: 1000-3940 (2022) 01-0043-06

Rolling force prediction of hot strip rolling based on GA-PELM

Yang Jing, Ren Yan, Gao Xiaowen, Su Nan

(School of Information Engineering, Inner Mongolia University of Science and Technology, Baotou 014010, China)

Abstract: In the process of hot strip rolling, the calculation accuracy of rolling force directly affects the actual thickness of strip steel, which is also the prerequisite of accurate online control. However, because the actual rolling process is affected by many factors, the prediction accuracy using the traditional model is often lower. Therefore, in order to improve the prediction accuracy of rolling force, the rolling force prediction model of parallel heterogeneous limit learning machine (PELM) was proposed, which had high learning speed and strong generalization ability, and at the same time, in order to ensure the stability of the model, the weight and deviation of the model was optimized by genetic algorithm (GA). Taking the actual production data of 2250 production line for a steel plant in Baotou as the example to predict the rolling force, the results show that the rolling force prediction model trained by the algorithm has good prediction accuracy and is suitable for the rolling force prediction of hot strip rolling process.

Key words: hot strip rolling; rolling force; parallel heterogeneous limit learning machine; genetic algorithm; network structure

在板材热连轧轧制过程中, 轧制力的预测值直接影响着辊缝的设定精度, 从而影响着板带钢厚度和板形的控制效果。传统的轧制力都是采用机理模型的方法进行计算的, 由于机理模型建立的过程存在着复杂性和非线性等问题, 因此简化和省略了很多影响因素^[1], 单纯的采用机理模型进行轧制力计算的结果与现场实际工况存在较大误差。随着人工智能的发展, 提出了采用机器学习的方法对轧制力进行预测, 通过机器学习算法对现场生产数据进行

训练, 可以很大程度上提高模型的预测精度^[2]。由于传统的神经网络算法在预测轧制力时存在学习速度较慢、预测准确率较低等缺点, 所以, 有学者提出了通过优化算法来预测轧制力。张飞等^[3]提出了基于均匀微分神经网络的厚板轧制力预测算法, 该算法可以快速求解神经网络结构和权值的优化问题, 提高了过程控制系统轧制力预测精度。刘明华等^[4]、冀秀梅等^[5]提出了基于机器学习的冷轧轧制力预测模型, 有效地提高了轧制力的预测精度。郑刚等^[6]提出了改进的神经网络轧制力预测模型, 包括 PSO-BP、LPSO-BP、MPSO-BP, 这些方法有效地减小了预测误差, 提高了模型的稳定性。王振华等^[7]提出了 ANN-GA 模型的热轧带钢弯曲力预测, 利用 GA 优化 ANN 网络的输入权重和偏差, 采用 ANN 网络进行预测, 该模型的结构简单、精度高。张振坤等^[8]提出了基于主成分分析的支持向量回归

收稿日期: 2021-01-21; 修订日期: 2021-04-06

基金项目: 国家自然科学基金资助项目 (62063027); 内蒙古自然科学基金资助项目 (2019MS06002); 内蒙古自治区研究生教育创新计划

作者简介: 杨 静 (1996-), 女, 硕士研究生

E-mail: 15191734@qq.com

通信作者: 任 彦 (1977-), 女, 博士, 教授

E-mail: 1121996049@qq.com

热轧轧制力预测,使用主成分分析选取对轧制力影响较大的因素作为支持向量机的输入,该模型有效地提高了预测的准确性和效率。杨彦博等^[9]提出了基于均匀形变的动态轧制模型,首先建立了动态速度模型和动态边界条件模型,然后基于能量法求解动态轧制过程的总功率方程,该模型具有较高的预测精度。彭文等^[10]提出了热轧非稳态过程轧制力自学习模型,将自学习系数分解为层别学习和轧制状态学习,该模型有效地提高了预测的精度和鲁棒性。孙一康^[11]、曹建国等^[12]介绍了轧制力的理论基础、建模方法、模型自学习以及板形控制等内容。何飞等^[13]提出了基于多模态和加权支持向量机的热轧轧制力智能预报,使用聚类进行生产状态区分,采用加权支持向量机进行轧制力预测,有效地提高了轧制力的预测精度。洪悦等^[14]提出基于数据子空间 PLS 建模技术的热轧轧制力优化设定,采用偏小二乘方法建立轧制力数据模型,利用改进粒子群算法对模型进行优化,提高产品质量的同时降低了能耗。周富强等^[15]提出了将数学模型和神经网络相结合的冷连轧轧制力在线计算模型,提高了在线控制轧制力模型的计算精度。宋勇等^[16]根据轧制数量、测量数据质量和轧制力的预报误差的影响,建立了轧制力自学习速度因子优化模型。魏立新等^[17]针对冷连轧生产中难以建立准确的轧制力数学模型的问题,提出了基于半监督深度网络的轧制力预报模型,有效地提高了轧制力预测精度。陈丹等^[18]、章顺虎等^[19]提出了基于大数据的轧制模型的研究,将大数据分析的思路和方法应用于提高轧制力模型精度,有效地提升了模型的预测精度。

本文以板带材热连轧精轧轧制过程为例,开展了轧制力预测模型的研究。针对轧制过程多变量、多约束、强耦合等特点,建立了 PELM 轧制力预测模型。该模型将 ELM 的单隐层网络结构拓展为并行网络结构,并采用 GA 对模型的输入权重 w 和偏差 b 进行优化,进一步提高了模型的预测精度和训练速度。该模型保留了 ELM 泛化能力强、计算复杂度低、训练速度快等优点,同时,弥补了 ELM 预测精度低和网络结构不稳定等缺点。

1 极限学习机预测模型

1.1 极限学习机介绍

极限学习机 (ELM) 的输入权重和偏差具有随机设定性,且设定后无需再调整,除此之外,隐含

层和输出层之间的权重可通过公式一次性求解,避免了多次迭代调整。

假设有 n 个实例的训练数据集 $S = \{(\mathbf{x}_i, \mathbf{y}_i) \mid \mathbf{x}_i \in \mathbf{R}^N, \mathbf{y}_i \in \mathbf{R}^M, i = 1, 2, 3, \dots, n, l = 1, 2, \dots, m\}$, 其中 \mathbf{x}_i 和 \mathbf{y}_i 分别为示例的输入向量和输出向量, n 为示例总数, N 和 M 分别为输入向量和输出向量的维数。

$$\mathbf{Y}_p = \mathbf{H} \cdot \boldsymbol{\beta} \quad (1)$$

$$f(x) = \frac{1}{1 + e^{-x}} \quad (2)$$

$$\min E = \|\mathbf{H}\boldsymbol{\beta} - \mathbf{Y}\|^2 \quad (3)$$

$$\boldsymbol{\beta} = \mathbf{H}^+ \mathbf{Y} \quad (4)$$

$$\mathbf{H}^+ = (\mathbf{H}^T \mathbf{H})^{-1} \mathbf{H}^T \quad (5)$$

式中: \mathbf{Y}_p 为极限学习机网络的输出; \mathbf{H} 为隐藏层输出; $\boldsymbol{\beta}$ 为输出权重; $f(x)$ 为激活函数; $\min E$ 为最小值; \mathbf{Y} 为样本的期望输出; \mathbf{H}^+ 为 $\mathbf{H} = [H_1, H_2, \dots, H_L]^T$ 的广义逆矩阵。

由于 Sigmoid 函数 (式 (2)) 以及其反函数具有单调递增等性质,所以,常被用作 ELM 的激活函数。ELM 的目标是使损失函数最小^[20-21], 损失函数可以表示为式 (3)。

输出权重 $\boldsymbol{\beta} = [\beta_1, \beta_2, \dots, \beta_L]^T$, 其一旦确定,便能够获得唯一的 ELM 模型。但是,ELM 存在矩阵运算和逆运算会占据大量的运行时间和预测精度低等缺点。

1.2 并行异构极限学习机 (PELM)

为了克服 ELM 存在的问题、提高模型预测精度和运行效率,在单隐层 ELM 的基础上提出了并行异构极限学习机 (PELM)^[22-23], 其结构如图 1 所示, L 为隐藏层神经元个数, m 为输出层神经元个数; n 为输入层神经元个数。




图 1 PELM 网络结构图

Fig. 1 PELM network structure diagram

该模型将输入层的数据通过不同的非线性激活函数同时映射到并行的隐藏层, 两个隐藏层同时进行计算, 求出网络的输出权重, 进而求出网络的输出值 Y_p , 即可在减少网络运算时间的同时提高模型的预测精度。输入层通过非线性映射可以计算出隐藏层 $H = [H_1, H_2, \dots, H_L]^T$ 和 $G = [G_1, G_2, \dots, G_L]^T$, H 和 G 代表两个不同的隐藏层, w_1 和 b_1 为隐藏层 H 的输入权重和偏差, $w_1 = [w_{11}, w_{12}, \dots, w_{1L}]^T$ 和 $b_1 = [b_{11}, b_{12}, \dots, b_{1L}]^T$, w_2 和 b_2 为隐藏层 G 的输入权重和偏差, $w_2 = [w_{21}, w_{22}, \dots, w_{2L}]^T$ 和 $b_2 = [b_{21}, b_{22}, \dots, b_{2L}]^T$ 。 H 和 G 的计算公式如式 (6) ~ 式 (7) 所示:

$$H(w, x, b) = \begin{bmatrix} f(w_{11} \cdot x_1 + b_{11}) & \cdots & f(w_{1L} \cdot x_1 + b_{1L}) \\ \vdots & \ddots & \vdots \\ f(w_{11} \cdot x_n + b_{11}) & \cdots & f(w_{1L} \cdot x_n + b_{1L}) \end{bmatrix} \quad (6)$$

$$G(w, x, b) = \begin{bmatrix} g(w_{21} \cdot x_1 + b_{21}) & \cdots & g(w_{2L} \cdot x_1 + b_{2L}) \\ \vdots & \ddots & \vdots \\ g(w_{21} \cdot x_n + b_{21}) & \cdots & g(w_{2L} \cdot x_n + b_{2L}) \end{bmatrix} \quad (7)$$

输入向量和输出向量的关系为:

$$y_{pl} = \sum_{i=1}^L \sum_{j=1}^n \sum_{l=1}^m \beta_{1l} f(w_{1i} \cdot x_j + b_{1i}) + \sum_{i=1}^L \sum_{j=1}^n \sum_{l=1}^m \beta_{2l} g(w_{2i} \cdot x_j + b_{2i}) \quad (8)$$

式中: x_j 为网络的输入; β_{1l} 为第 1 个隐藏层的输出权重; β_{2l} 为第 2 个隐藏层的输出权重。

输出权重 $\beta = [\beta_1 \ \beta_2]$, 可以根据式 (4) 计算出, β 一旦确定, 便能够获得唯一的 PELM 网络模型。

$$\beta = \begin{bmatrix} H \\ G \end{bmatrix}^+ Y \quad (9)$$

并行极限学习机网络的输出值 Y_p 为:

$$Y_p = [\beta_1 \ \beta_2] \begin{bmatrix} H \\ G \end{bmatrix} \quad (10)$$

1.3 遗传算法优化的并行异构极限学习机 (GA-PELM)

遗传算法 (GA) 秉承着“物竞天择, 适者生存”的思想, 通过 N 代的遗传、变异、交叉和复制, 为复杂、非线性系统的优化问题提供了一种普适的求解框架, 它具备搜索速度快、不易陷入局部最优等优势。由于 PELM 的输入权重和偏差是随机设定的, 这可能导致 PELM 的网络输出不稳定甚至

可能导致发散, 极大地影响了模型的稳定性, 因此, 选择合适的参数对提高模型的预测精度和效率至关重要。针对 PELM 存在的问题, 提出了基于遗传算法的并行异构极限学习机 (GA-PELM), 利用遗传算法寻找最优的输入权重 w 和偏差 b , 一旦 w 和 b 被确定, 就会提高模型的预测精度和效率, 同时 GA-PELM 的模型即可唯一确定。GA-PELM 的优化步骤如图 2 所示。

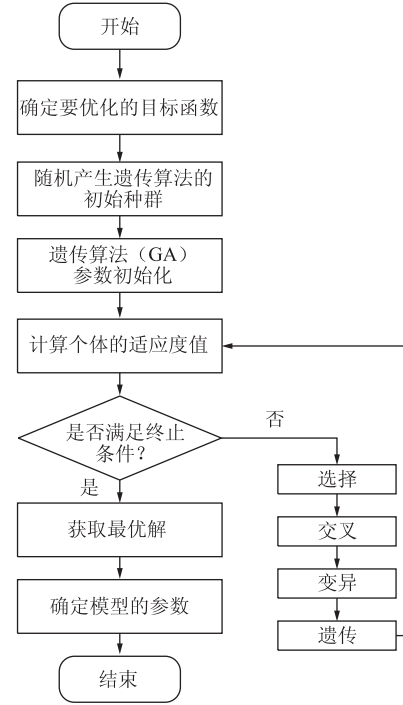


图 2 GA 优化的 PELM 流程

Fig. 2 PELM process optimized by GA

(1) 对热连轧精轧制力预测进行建模, 确定优化目标函数 w_1 、 w_2 和 b_1 、 b_2 。

(2) 确定 PELM 网络结构, 随机产生初始 w_1 、 w_2 和 b_1 、 b_2 , 作为遗传算法的初始种群。

(3) 对遗传算法参数进行初始化, 确定种群规模、染色体长度、迭代次数、交叉概率、变异概率等。

(4) 确定适应度函数 S 。

$$S = \|Y_p - Y\|^2 =$$

$$\frac{1}{N} \left\| \left\{ \sum_{i=1}^L \sum_{j=1}^n \sum_{l=1}^m \beta_{1l} f(w_{1i} \cdot x_j + b_{1i}) + \sum_{i=1}^L \sum_{j=1}^n \sum_{l=1}^m \beta_{2l} g(w_{2i} \cdot x_j + b_{2i}) \right\} - y_l \right\|^2 \quad (11)$$

(5) 对初始种群进行交叉、变异、遗传等操作, 以适应度函数 S 最小为目标, 选择最优解, 若满足最优解条件, 则输出最优个体。若不满足则根据适应度值的大小, 选择个体组成新的种群, 然后

再进行交叉、变异、遗传等操作,直到确定最优解。

(6) 确定 w_1 、 w_2 和 b_1 、 b_2 , 以及 β_1 、 β_2 , PELM 训练完成。

2 模型分析与仿真

板材热连轧的生产过程十分复杂。连铸生产的板坯,经过上料辊道被送到步进式连续加热炉内进行加热,板坯在加热炉内加热到轧制所需的温度后,经过出炉辊道送入粗轧除磷机,对板坯所产生的氧化铁皮进行处理,再经定宽压力机控制板坯宽度后,将其送入粗轧机轧制为一定宽度和厚度的中间坯,将中间坯切头切尾后进行二次除磷,然后将其送入精轧机组。CVC 精轧机组采用 CVC 辊形、工作辊液压窜辊与液压弯辊系统液压机对带钢板形进行高精度控制,采用液压压下系统对带钢厚度进行高精度控制。待精轧机组将板带钢轧制完成后,送至层流冷却,将板材温度迅速冷却到所要求的卷曲温度,经卷取机进行卷曲。

基于以上分析,对轧制力作出准确的预测是热连轧过程控制的关键。根据现场轧制条件和工艺参数对轧制力的影响情况,并结合轧制变形机理可得式(12):

$$P = Bl'_c Q_p K K_T \quad (12)$$

式中: P 为轧制力; B 为带宽; l'_c 为轧辊与轧件接触弧的水平投影长度; Q_p 为内应力状态的影响系数; K 为金属变形阻力; K_T 为前后张力对轧制力的影响系数。

通过主成分分析确定模型的输入为进出口宽度、进出口厚度、进出口张力、轧制温度、轧制速度等,输出为 F1 机架的轧制力预测值。本实验所有数据均来自包头某钢厂热轧生产线的实际生产数据,每个板带钢的轧制时间约为 60~80 s,所以,采集的数据每组时间间隔大约为 60~80 s。用 3- σ 法则剔除异常值和缺失值后,共获得 5061 组数据,采集的部分轧制数据如表 1 所示。其中训练集占比为 0.8,测试集占比为 0.2。分别用 ELM、PELM、GA-PELM 进行了轧制力预测实验,并从准确性和稳定性以及效率等方面进行分析,得出了 GA-PELM 算法具有更好的性能。

本实验所有仿真均是在 Python3.7 环境下进行的,在 ELM 中激活函数选择为 Sigmoid 函数,隐藏层数为 1 层,隐藏节点数为 90。PELM 是在 ELM 网络结构的基础上,再拓展一个并行网络结构,激活函数分别选择 Sigmoid 函数和 Tanh 函数。GA 算法的迭代次数 $c=500$,种群 $z=20$,交叉率 $\alpha=0.5$,变异率 $\varphi=0.2$ 。用 1044 组数据对 3 种模型进行了测试,本文选用均方根误差 $RMSE$ 和平均绝对误差 $RAPE$ 作为评价指标,其表达式分别见式(13)和式(14),其结果如表 2 所示, $RMSE$ 和 $RAPE$ 的值越小,说明模型的性能越好。

$$RMSE = \sqrt{\frac{1}{m} \sum_{l=1}^m (y_{pl} - y_l)^2} \quad (13)$$

$$MAPE = \frac{1}{m} \sum_{l=1}^m \frac{|y_{pl} - y_l|}{y_l} \quad (14)$$

表 1 精轧轧制力数据

Table 1 Data of finishing rolling force

张力/ kN	轧制速度/ ($m \cdot s^{-1}$)	精轧入口 宽度/mm	精轧出口 宽度/mm	精轧入口 温度/ $^{\circ}C$	精轧出口 温度/ $^{\circ}C$	精轧入口 厚度/mm	精轧出口 厚度/mm	变形抗力/ kN	轧制力/kN
6.00	8.33	1569.92	1543.82	940.18	900.17	43.20	5.02	21735.61	21132.04
6.00	11.50	1567.64	1539.20	954.55	902.93	42.98	4.95	20045.43	21790.59
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
5.99	10.18	1325.14	1304.59	953.72	887.70	43.97	4.52	20195.13	22026.05

表 2 算法对比

Table 2 Algorithm comparison

算法	误差在 5% 以内/%	误差在 10% 以内/%	均方根误差/ kN	平均绝对 误差/kN
ELM	90.02	99.51	617.81	0.0235
PELM	91.20	99.70	603.07	0.0226
GA-PELM	91.80	99.80	601.30	0.0225

通过对 3 种模型的误差情况进行对比,可以得出采用 PELM 模型的预测误差在 5% 和 10% 以内的概率要高于 ELM,且 PELM 模型的均方根误差和平均绝对误差均要小于 ELM 模型,该结果证明将单隐层 ELM 网络结构拓展为并行结构可有效地提高预测准确率。GA-PELM 预测误差在 5% 和 10% 以内的概率要高于 PELM,且 GA-PELM 模型的均方根误差和

平均绝对误差均要小于 PELM 模型, 该结果证明采用 GA 对 PELM 的 w 和 b 进行优化后, 可以使模型的网络结构更加稳定, 并且有效地提高了预测准确率。

结合测试数据, 为了便于分析, 随机截取了 50 个样本对 3 个模型进行了预测曲线拟合, ELM 的预测曲线如图 3 所示, PELM 的预测曲线如图 4 所示, GA-PELM 的预测曲线如图 5 所示, 误差曲线如图 6 所示。




图3 ELM 预测曲线

Fig. 3 ELM prediction curves




图4 PELM 预测曲线

Fig. 4 PELM prediction curves




图5 GA-PELM 预测曲线

Fig. 5 GA-PELM prediction curves




图6 误差曲线

Fig. 6 Error curves

通过对比图 3、图 4、图 5 可以得出, GA-PELM 模型的预测曲线与真实值曲线的吻合度最高, 预测效果优于 PELM 和 ELM。通过图 6 可以得出, GA-PELM 的预测误差最小, 误差绝大多数均在 5% 以内, 可以满足现场热连轧轧制的要求。

3 结语

轧制力作为轧制过程中最重要的参数之一, 其预测精度直接影响成品的质量。本文针对轧制过程中轧制力的预测问题, 提出了并行异构极限学习机 (PELM), 与极限学习机 (ELM) 相比, 很大程度上提高了模型的预测精度和运行效率。为了弥补 PELM 网络结构不稳定的缺点, 提出了遗传算法优化的并行极限学习机 (GA-PELM) 的建模方法, 该模型有很好的全局寻优能力, 可以更好地确定模型的参数, 使模型的网络结构更稳定, 同时大大提高了模型的预测精度和运行效率。

参考文献:

- [1] Liu J, Liu X, Le B T. Rolling force prediction of hot rolling based on GA-MELM [J]. Complexity, 2019, (4): 1-11.
- [2] 郝心耀. 基于机器学习算法的轧机轧制力预测 [J]. 现代电子技术, 2016, 39 (20): 114-116, 120.
Hao X Y. Rolling mill rolling force prediction based on machine learning algorithm [J]. Modern Electronics Technique, 2016, 39 (20): 114-116, 120.
- [3] Zhang F, Zhao Y T, Shao J, et al. Rolling force prediction in heavy plate rolling based on uniform differential neural network [J]. Journal of Control Science & Engineering, 2016: 1-9.
- [4] 刘明华, 张强, 刘英华, 等. 基于机器学习的热轧轧制力预测 [J]. 锻压技术, 2021, 46 (10): 233-241.
Liu M H, Zhang Q, Liu Y H, et al. Prediction of rolling force in

- hot rolling based on machine learning [J]. Forging & Stamping Technology, 2021, 46 (10): 233-241.
- [5] 冀秀梅, 王龙, 高克伟, 等. 极限学习机在中厚板轧制力预报中的应用 [J]. 钢铁研究学报, 2020, 32 (5): 393-399.
- Ji X M, Wang L, Gao K W, et al. Application of ELM to predict plate rolling force [J]. Journal of Iron and Steel Research, 2020, 32 (5): 393-399.
- [6] Zheng G, Ge L H, Shi Y Q, et al. Dynamic rolling force prediction of reversible cold rolling mill based on BP neural network with improved PSO [A]. 2018 Chinese Automation Congress (CAC) [C]. 2018.
- [7] Wang Z H, Gong D Y, Li X, et al. Prediction of bending force in the hot strip rolling process using artificial neural network and genetic algorithm (ANN-GA) [J]. International Journal of Advanced Manufacturing Technology, 2017, 93 (4): 1-14.
- [8] Zhang Z K, Luan F, Li D, et al. Prediction of rolling force in the hot strip rolling using support vector regression with principal components analysis [A]. 2019 2nd International Conference on Information Systems and Computer Aided Education (ICISCAE) [C]. IEEE, 2020.
- [9] Yang Y B, Peng Y. Dynamic rolling model based on uniform deformation [J]. Journal of Manufacturing Processes, 2020, 58: 1334-1347.
- [10] 彭文, 姬亚锋, 陈小睿, 等. 热轧非稳态过程轧制力自学习模型优化 [J]. 东北大学学报: 自然科学版, 2019, 40 (10): 1408-1412.
- Peng W, Ji Y F, Chen X R, et al. Optimization of rolling force self-learning model in unsteady process of hot rolling [J]. Journal of Northeastern University: Natural Science, 2019, 40 (10): 1408-1412.
- [11] 孙一康. 冷热轧板带轧机的模型与控制 [M]. 北京: 冶金工业出版社, 2010.
- Sun Y K. Model and Control of Cold and Hot Strip Rolling Mill [M]. Beijing: Metallurgical Industry Press, 2010.
- [12] 曹建国, 张杰, 张少军. 轧钢设备及自动控制 [M]. 北京: 化学工业出版社, 2010.
- Cao J G, Zhang J, Zhang S J. Rolling Equipment and Automatic Control [M]. Beijing: Chemical Industry Press, 2010.
- [13] 何飞, 石露露, 黎敏, 等. 基于多模态和加权支持向量机的热轧轧制力智能预报 [J]. 工程科学学报, 2015, 37 (4): 517-521.
- He F, Shi L L, Li M, et al. Intelligent prediction of rolling force in hot rolling based on a multi-model and weighted support vector machine [J]. Journal of Engineering Science, 2015, 37 (4): 517-521.
- [14] 洪悦, 唐立新, 张颜颜. 基于数据子空间 PLS 建模技术的热轧轧制力优化设定 [J]. 控制与决策, 2014, 29 (7): 1199-1204.
- Hong Y, Tang L X, Zhang Y Y. Optimization of rolling force of hot rolling by using data subspace PLS modeling technique [J]. Control and Decision, 2014, 29 (7): 1199-1204.
- [15] 周富强, 曹建国, 张杰, 等. 冷连轧机轧制力在线计算模型 [J]. 北京科技大学学报, 2006, 28 (9): 859-862.
- Zhou F Q, Cao J G, Zhang J, et al. On-line calculation model of rolling force for tandem cold rolling mill [J]. Journal of University of Science and Technology Beijing, 2006, 28 (9): 859-862.
- [16] 宋勇, 苏岚, 荆丰伟, 等. 热轧带钢轧制力模型自学习算法优化 [J]. 北京科技大学学报, 2010, 32 (6): 802-806.
- Song Y, Su L, Jin F W, et al. Self-learning algorithm optimization for the rolling force model of hot strips [J]. Journal of University of Science and Technology Beijing, 2010, 32 (6): 802-806.
- [17] 魏立新, 翟博豪, 赵志伟, 等. 基于半监督深度网络的冷连轧轧制力预报 [J]. 塑性工程学报, 2020, 27 (11): 70-76.
- Wei L X, Zhai B H, Zhao Z W, et al. Prediction of cold continuous rolling force based on semi-supervised deep network [J]. Journal of Plasticity Engineering, 2020, 27 (11): 70-76.
- [18] 陈丹, 邵健, 殷实, 等. 基于大数据平台的冷连轧轧制力自学习模型优化 [J]. 冶金自动化, 2020, 44 (6): 25-29, 61.
- Chen D, Shao J, Yin S, et al. Optimization of self-learning model of cold rolling force based on big data platform [J]. Metallurgical Industry Automation, 2020, 44 (6): 25-29, 61.
- [19] 章顺虎, 姜兴睿, 尤凤翔, 等. 融合工业大数据的热轧厚板轧制力模型研究 [J]. 精密成形工程, 2020, 12 (2): 8-14.
- Zhang S H, Jiang X R, You F X, et al. Investigation on the model of rolling force by integrating industrial big data [J]. Journal of Netshape Forming Engineering, 2020, 12 (2): 8-14.
- [20] 孙全龙, 梅益, 杨幸雨. 压铸模型腔曲面铣削表面粗糙度 GA-ELM 预测 [J]. 机械设计与制造, 2020, (8): 188-191, 196.
- Sun Q L, Mei Y, Yang X Y. GA-ELM Prediction of surface roughness of die casting die cavity surface milling [J]. Machinery Design & Manufacture, 2020, (8): 188-191, 196.
- [21] Wang Y Q, Dou Y, Liu X W, et al. PR-ELM: Parallel regularized extreme learning machine based on cluster [J]. Neurocomputing, 2016, 173: 1073-1081.
- [22] 陈则王, 李福胜, 林娅, 等. 基于 GA-ELM 的锂离子电池 RUL 间接预测方法 [J]. 计量学报, 2020, 41 (6): 735-742.
- Chen Z W, Li F S, Lin Y, et al. Indirect prediction method of rul for lithium-ion battery based on GA-ELM [J]. Acta Metrologica Sinica, 2020, 41 (6): 735-742.
- [23] 马威, 李维刚, 赵云涛, 等. 基于深度学习的热连轧轧制力预测 [J]. 钢铁研究学报, 2019, 31 (9): 805-815.
- Ma W, Li W G, Zhao Y T, et al. Prediction of hot-rolled roll force based on deep learning [J]. Journal of Iron and Steel Research, 2019, 31 (9): 805-815.