

轧制

基于比例损失去噪自编码器的冷连轧轧制力预测分析

张海霞¹, 李 灿²

(1. 河南工业贸易职业学院 信息工程学院, 河南 郑州 450000; 2. 湖南大学 电气与信息工程学院, 湖南 长沙 410082)

摘要: 为了更加精确地预测冷连轧轧制力, 设计了一种通过分层提取和目标相关特征来实现的比例损失堆叠去噪自编码器。首先, 通过堆叠去噪自编码器 (SDAE) 构建深度网络并在 SDAE 顶层中加入输出层; 然后, 通过部分有标签样本实现网络权重变量的调节; 最后, 按照设定目标参数调节深度网络变量, 从而降低网络预测值和目标值的偏差。本方法通过在训练过程加入目标值信息实现了特征提取有效性的显著提升, 具有很好的预测稳定性。通过试验测试本算法, 其预测结果在 $\pm 3\%$ 误差内, 可以满足实际生产控制要求。本算法能够从输入层内找到和目标值关联的特征, 在预训练阶段完成目标值的整合。相比其他预测算法, 本算法获得了很小的预测误差, 能够更快完成收敛, 表现出了更优的预测精度和效率。

关键词: 冷连轧; 轧制力预测; 深度网络; 比例损失去噪自编码器; 预测误差

DOI: 10.13330/j.issn.1000-3940.2022.04.026

中图分类号: TG335 文献标志码: A 文章编号: 1000-3940 (2022) 04-0190-05

Rolling force prediction analysis of tandem cold rolling based on proportional loss denoising autoencoder

Zhang Haixia¹, Li Can²

(1. College of Information Engineering, Henan Vocational College of Industry and Trade, Zhengzhou 450000, China;

2. School of Electrical and Information Engineering, Hunan University, Changsha 410082, China)

Abstract: In order to predict the rolling force of tandem cold rolling more accurately, a proportional loss stack denoising autoencoder (SDAE) was designed by the hierarchical extraction and target correlation features. Firstly, the output layer was added to the top layer of SDAE by the stack denoising autoencoder. And then, the weight variables of network were adjusted through some labeled samples. Finally, the depth network variables were adjusted according to the set target parameters, so as to reduce the deviation between network predicted value and target value. Furthermore, by the method of adding target value information in the training process, the effectiveness of feature extraction was improved significantly and had a good predictive stability. The experimental results show that the prediction result of this algorithm is within $\pm 3\%$ error through test, which can meet the actual production control requirements. The algorithm can find the features associated with the target values from the input layer and complete the integration of target values in the pre-training stage. Compared with other prediction algorithms, this algorithm has a small prediction error and can complete convergence faster which shows better prediction accuracy and efficiency.

Key words: tandem cold rolling; rolling force prediction; deep network; proportional loss denoising autoencoder; prediction error

对带钢进行冷连轧加工时, 设置不同的轧制力会对轧制规程造成明显影响, 从而引起成品厚度与板形表面粗糙度的变化。由于轧制环境存在复杂的变化情况, 不同参量间会发生互相耦合, 因此, 构建机理算法时需设置较多假设条件, 无法确保获得

准确的预测结果^[1-4]。

随着数据驱动技术的进步, 计算机处理速度也迅速提升。到目前为止, 已有一些文献对综合运用人工智能技术与机器学习方法相结合的数据驱动算法来优化金属板材轧制工艺以及轧制力参数进行了报道^[5-6]。例如, Mahmoodkhanij Y 等^[7]利用迭代法处理摩擦力系数, 计算得到摩擦力系数和轧制力的变化规律, 确保轧制力的预测精度不超过 10%。魏立新等^[8]通过自组织方法构建仿真算法, 并分析在线序列极限学习机的轧制力。此算法通过量子粒子群算法实现权值变量的优化, 之后通过在线数据

收稿日期: 2022-02-17; 修订日期: 2022-03-16

基金项目: 河南省软科学研究计划项目 (152400410203); 河南省科技攻关项目 (192102210134)

作者简介: 张海霞 (1980-), 女, 硕士, 讲师

E-mail: zhxhngm@163.com

实现对网络结构的动态调节，由此达到实时预测轧制力的效果。赵文姣等^[9]通过信度分配方法构建小脑算法神经网络并实现了精确预测轧制力的功能。其中，输入参数包括轧制力算法输出结果与轧制力的影响因素，进一步优化了网络收敛效果，能够满足实际使用阶段的精度控制条件。

相对于传统机理算法，上述方法可以获得更快的训练速度以及更高的精度。但由于这些轧制力的预测方法均属于有监督算法，只能选择有标签参数来完成训练过程，因此会丢失许多无标签数据^[10-11]。进行实际生产时，无标签数据更容易得到，其数量也较多，受信息丢失的影响，预测精度只能得到有限的提升^[12-13]。为了更加精确地预测轧制力，本文先通过堆叠去噪自编码器（Stacked Denoising Autoencoder, SDAE）构建深度网络，由此提取出过程样本无监督特征。之后在 SDAE 顶层中加入输出层，并通过部分有标签样本实现网络权重变量的调节。根据以上研究结果，本文设计了一种通过分层提取和目标相关特征实现的改进堆叠去噪自编码器（Improved Stacked Denoising Autoencoder, I-SDAE），针对训练过程加入了目标值信息，实现了特征提取有效性的显著提升。

1 预测算法建立

1.1 算法建立

采用 SDAE 进行特征提取时未设置监督机制，同时，对其进行模型训练时也未建立特征和目标值之间的关联性，导致特征提取呈现明显的随机特性与盲目性。如果在初期训练过程中未提取出高阶特征，则会显著提高微调过程的处理难度。可以根据不同维度特征和目标值的关联状态，确保模型和目标值具有较大关联程度的特征来完成相应的重构过程。

以不同的特征维度对 SDAE 代价函数实施展开处理，得到以下重构代价表达式：

$$Q(x, z) = \sum_{i=1}^d \|x^{(i)} - z^{(i)}\|^2 \quad (1)$$

式中： $Q(x, z)$ 为重构代价表达式； x 和 z 为最初参数和重构数据； d 为训练参数特征维度； $x^{(i)}$ 为最初参数的第 i 维特征， $i = 1, 2, \dots, d$ ； $z^{(i)}$ 为重构数据的第 i 维特征。

通过分析发现，各个特征在预测目标值方面的准确性存在明显差异，需按照以下过程完成预处理。根据有标签数据，为输入特征 $x^{(i)}$ 和目标参数 y 之间建立对应系数，式 (2) 给出了 i 维特征相关系数表达式：

$$\rho^{(i)} = \frac{\sum_{j=1}^m (x_j^{(i)} - \bar{x}^{(i)})(y_j - \bar{y})}{\sqrt{\sum_{j=1}^m (x_j^{(i)} - \bar{x}^{(i)})^2} \times \sqrt{\sum_{j=1}^m (y_j - \bar{y})^2}} \quad (2)$$

式中： $\rho^{(i)}$ 为 i 维特征相关系数函数； j 为标签序号， $j = 1, \dots, m$ ； m 为标签的数据量； $x_j^{(i)}$ 为 j 标签序号下第 i 维特征的输入数据； y_j 为 j 标签序号下的目标参数值； $\bar{x}^{(i)}$ 为第 i 维特征的平均输入数据； \bar{y} 为平均目标参数值。

根据不同维度特征和目标值大小对初始重构代价函数进行运算，并在训练期间融合了目标值信息。式 (3) 是经过改进处理后得到的重构代价函数：

$$M_{\eta}(x, z) = \frac{\sum_{j=1}^m \sum_{i=1}^d \eta^{(i)} \|x_m^{(i)} - z_m^{(i)}\|^2}{m} \quad (3)$$

式中： $M_{\eta}(x, z)$ 为改进处理得到的重构损失函数； $\eta^{(i)}$ 为 i 维特征所占比例； $x_m^{(i)}$ 为改进处理特征的得到的第 i 维输入数据； $z_m^{(i)}$ 为改进处理特征的得到的第 i 维的重构数据。

再对优化重构代价函数实施最小化，最终确定最优权重变量。图 1 为 I-SDAE 训练流程。

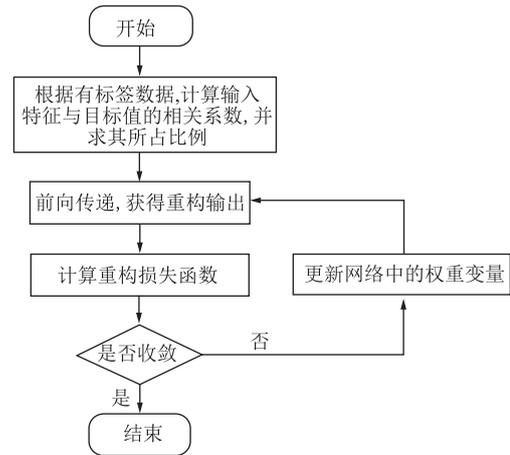


图 1 I-SDAE 训练流程图

Fig. 1 Flow chart of I-SDAE training

1.2 预报模型

采用本算法能够利用无标签数据学习和输出具有复杂结构的抽象特征，非常适合构建轧制力的预测算法^[14-15]。图 2 显示了通过本算法构建得到的轧制力预测原理。以本算法建立轧制力预测算法的过程包括 2 个部分，主要为有监督反向微调以及半监督逐层预训练。其中， W_1, \dots, W_{n+1} 分别为输出层的权重矩阵， b_1, \dots, b_{n+1} 分别为输出层的偏置

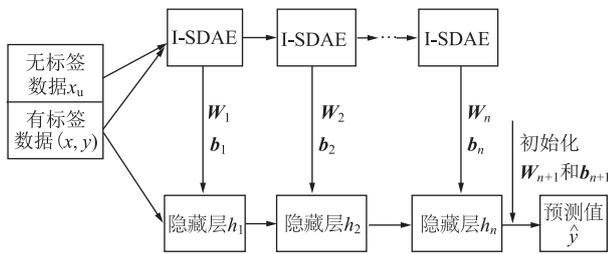


图 2 预测算法原理图

Fig. 2 Principle diagram of prediction algorithm

向量, h_1, \dots, h_{n+1} 分别为隐藏层, n 为层数。先对各 I-SDAE 开展逐层训练, 由此获得各编码层的权重。利用上述权重变量完成有监督深度网络的初始化。最后, 按照设定的目标参数调节深度网络变量, 从而降低网络预测值和目标值的偏差。

以下为通过本算法预测轧制力的建立过程。

第 1 步: 针对工业过程的物理特性设置合适的工艺变量, 确定训练集与测试集数据, 再利用归一化方法处理数据;

第 2 步: 根据图 2 给出的训练方法, 通过原始数据对第 1 个 I-SDAE 实施训练, 之后根据输入数据特征 $x^{(i)}$ 和目标值 y 之间的相关性计算出 $\eta^{(i)}$;

第 3 步: 把第 1 个 I-SDAE 隐藏层输入到第 2 个 I-SDAE 中, 再根据图 2 方法对其实施训练, 代价函数特性比例则根据 h_1 和目标值 y 的相关性进行计算得到;

第 4 步: 利用上述方法对各 I-SDAE 进行逐层训练, 同时保存编码层的权重;

第 5 步: 预训练结束后, 把所有 I-SDAE 编码层权重变量融入到有监督神经网络内, 并将其组成初始变量, 按照随机初始化的方式计算得到输出层的权重变量;

第 6 步: 按照监督训练标准完成网络变量的微调, 直到算法方式收敛或满足最大迭代次数为止;

第 7 步: 获得最终变量后, 再利用测试集完成测试, 经过多次测试获得最佳变量。

2 结果与讨论

本研究构建算法时, 以 BKD-136 轧机上收集得到的在线数据作为样本集, 轧钢类型为 st16。试验所采用的轧机是单辊驱动双辊同步轧制试验机, 轧机的参数见表 1。通过安装在立柱内侧受力部分的压磁式传感器测试轧制力, 整个测试过程通过 Matlab 平台无间断读取, 并取均值输出。轧制生产线的轧制效率每小时为 500~600 道次, 年产量为 2000~3000 t。通过初步筛选得到轧制阶段的 20000 条无标

表 1 BKD-136 试验轧机参数

Table 1 Parameters of BKD-136 test mill

参数	数值
轧辊直径/mm	$\Phi 136$
轧辊宽度/mm	280
最大轧缝/mm	18
最大轧制力距/(kN·m)	5
最大扭力/kN	260
轧制速度/(r·min ⁻¹)	5~32

签参数与 10000 条有标签参数共同构成训练集。为了对算法进行准确性验证, 选择同机架未经过训练的 1000 条有标签数据进行测试。

表 2 给出了冷轧机在轧制阶段的变量区间。为了对算法进行准确性验证, 选择同机架未经过训练的 1000 条数据进行测试。

表 2 机架轧制变量选择

Table 2 Selection of frame rolling variables

参数	取值
原料宽度/mm	800~1200
原料厚度/mm	3.6~5.2
入口厚度/mm	1.15~1.82
出口厚度/mm	0.58~0.86
入口张力/kN	60.68
出口张力/kN	38.42
轧辊压扁半径/mm	240.380
出料带线速度/(m·s ⁻¹)	2.9
轧制力/kN	4100~5200

以 min-max 标准化方法把各训练数据缩放至 $[0, 1]$ ^[16]。根据多隐层神经网络运算过程进行建模, 分别对本算法半监督预训练以及有监督深度神经网络进行了微调处理。利用分批次试验的方式确定了算法的各项超参数^[17]。预训练过程中, 对本算法加入的高斯噪声比例为 2%, 学习率为 0.01, 总共迭代 300 次, 到达微调阶段时学习率为 0.2, 共迭代 1000 次。为更快地完成算法训练过程, 选择小批量梯度下降的处理方法, 结合前期经验控制算法批量为 128。

为优化函数逼近效果, 通过试验得到 5 个隐藏层、且隐藏层神经元数为 7 的深度网络结构。图 3 是对本算法进行预测所得的结果。显示本算法预测结果参数拟合点在 $\pm 3\%$ 误差内, 可以满足实际生产控制要求。

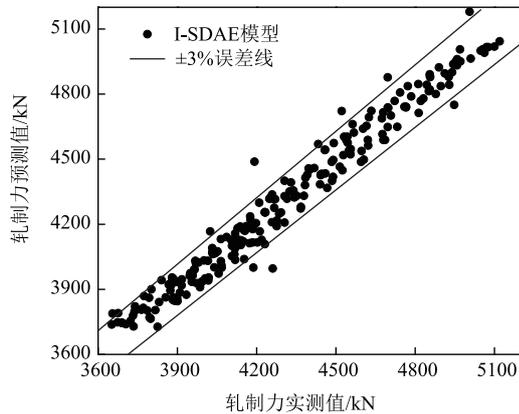


图 3 本算法轧制力预测值分布

Fig. 3 Predicted value distribution of rolling force for this algorithm

将本算法与其他预测算法实施对比，图 4 给出了具体的测试结果。对比了本算法和在线序列极限学习机（CDOS-ELM）算法^[4]的性能差异性。可以看到，CDOS-ELM 算法共包含了 240 个算法维度与 260 个粒子，隐藏层中存在 30 个初始神经元。为了对上述方法进行有效性验证，对比了本算法和 SDAE 算法的运算性能。考虑到测试数据集的规模较大，不能满足全部显示的要求，图 4 只给出了对 100 个测试样本进行预测得到的误差。根据图 4 可知，本算法获得了很小的预测误差，相对其他预测算法表现出了更优的预测精度。

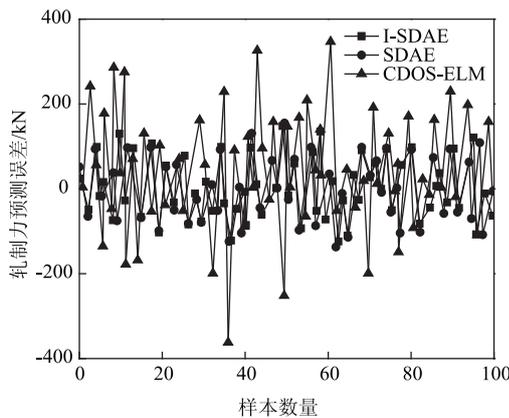


图 4 不同算法的预测误差分布

Fig. 4 Prediction error distributions of different algorithms

表 3 给出了以不同预测算法进行轧制力预测的结果。根据表 3 可知，虽然可以通过 CDOS-ELM 算法来实现快速训练的功能，但考虑到此算法属于浅层网络结构，无法达到理想的预测与泛化效果，无法实现高精度预测的要求。考虑到多层神经网络（Multilayer NN）算法是以随机初始化方法计算得到权重变量，较易在训练阶段出现局部最优的情况，

表 3 预测结果参数统计

Table 3 Parameter statistics of prediction results

模型	均方根误差	平均相对误差/%	时间/s
CDOS-ELM	138.56	2.61	26.68
SAE	76.62	1.16	79.96
SDAE	70.88	1.12	60.22
I-SDAE	55.46	0.85	16.42
Multilayer NN	未收敛	未收敛	103.22

不能满足算法的实际训练要求。为 SAE 算法设置了预训练机制，从而避免深度网络出现局部最优的问题，更快完成训练过程。SDAE 算法按照设定的去噪规则提取得到高阶去噪特征，显著改善了算法泛化能力，实现预测误差的有效控制。但由于 SDAE 算法重点在于对输入空间各维度采用同样的重构方法，不能确保各层特性均达到跟目标值的良好相关性。本算法能够从输入层内找到和目标值关联的特征，在预训练阶段完成目标值的整合。通过对比可知，本算法具备比其他数据驱动预测算法更优的预测效果。

图 5 给出了算法预测误差在不同迭代次数下的变化特征。可以发现，Multilayer NN 算法相对其他算法获得了更大的初始预测误差。这是由于 Multilayer NN 算法的权重变量通过随机初始化确定，其他算法则通过分层预训练的 SDAE 实现权重变量的初始化，从而获得更优的初始参数。进行后续处理时，Multilayer NN 算法存在局部极值点的问题，无法完成训练过程，同时预测误差也无法继续降低，导致算法不能实现收敛过程。本算法相对于 SDAE 算法能够更快完成收敛，其中，前者经过 100 次迭代即达到了收敛性要求，而 SDAE 算法总共需经过 200 次迭代后才收敛。

3 结论

(1) 建立了基于比例损失去噪自编码器的冷连轧制力预测模型，通过试验测试得到本算法的预测结果在±3%误差内，可以满足实际生产控制要求。

(2) 本算法能够从输入层内找到和目标值关联的特征，在预训练阶段完成目标值的整合。相对其他预测算法，本算法获得了很小的预测误差并能够更快完成收敛，表现出了更优的预测精度和效率。

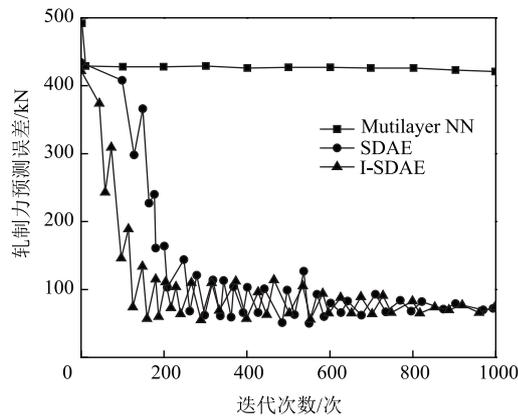


图 5 预测误差随迭代次数的变化

Fig. 5 Chang of prediction error with iteration times

参考文献:

- [1] 朱永波, 张飞, 张勇军, 等. 基于粒子群优化的带钢凸度神经网络预测模型研究 [J]. 冶金自动化, 2019, 43 (2): 11-15, 28.
Zhu Y B, Zhang F, Zhang Y J, et al. Prediction model of strip crown based on particle swarm optimization neural network [J]. Metallurgical Automation, 2019, 43 (2): 11-15, 28.
- [2] 王付杰, 毛飞龙, 双远华, 等. 管材斜连轧过程的运动学分析及实验研究 [J]. 锻压技术, 2021, 46 (4): 215-222.
Wang F J, Mao F L, Shuang Y H, et al. Kinematics analysis and experimental study of pipe tanque rolling process [J]. Forging & Stamping Technology, 2021, 46 (4): 215-222.
- [3] 孙孟乾, 孙建亮, 韩辉, 等. 大型铝合金筒节轧制过程圆度控制及影响因素分析 [J]. 燕山大学学报, 2021, 45 (2): 108-115.
Sun M G, Sun J L, Han H, et al. Roundness control and analysis of influencing factors in rolling process of large aluminum alloy barrel [J]. Journal of Yanshan University, 2021, 45 (2): 108-115.
- [4] 李飞飞, 宋勇, 刘超, 等. 热轧带钢力学性能预报模型的误差分布建模研究 [J]. 冶金自动化, 2019, 43 (6): 28-33.
Li F F, Song Y, Liu C, et al. Error distribution modeling of prediction model for mechanical properties of hot rolled strip [J]. Metallurgical Automation, 2019, 43 (6): 28-33.
- [5] 阎昱, 李嘉欣. 不同加载路径下的 AZ31B 镁合金的成形极限 [J]. 锻压技术, 2021, 46 (2): 40-46.
Yan Y, Li J X. Forming limit of AZ31B magnesium alloy under different loading paths [J]. Forging & Stamping Technology, 2021, 46 (2): 40-46.
- [6] 乔及森, 王兵. 深冷轧制备超细晶纯铝的微观组织与热稳定性研究 [J]. 塑性工程学报, 2021, 28 (2): 102-108.
Qiao J S, Wang B. Microstructure and thermal stability of ultrafine crystalline pure aluminum prepared by deep cold rolling [J]. Journal of Plasticity Engineering, 2021, 28 (2): 102-108.
- [7] Mahmoodkhani Y, Wells M A, Song G. Prediction of roll force in skin pass rolling using numerical and artificial neural network methods [J]. Ironmaking & Steelmaking, 2016, 44 (4): 281-286.
- [8] 魏立新, 张宇, 孙浩, 等. 基于改进 OS-ELM 的冷连轧在线轧制力预测 [J]. 计量学报, 2019, 40 (1): 111-116.
Wei L X, Zhang Y, Sun H, et al. On-line rolling force prediction of cold continuous rolling based on improved OS-ELM [J]. Acta Metrology Sinica, 2019, 40 (1): 111-116.
- [9] 赵文姣, 闫洪伟, 杨枕, 等. 基于 CA-CAMC 网络的轧制力自学习预测算法 [J]. 冶金自动化, 2016, 40 (2): 7-10.
Zhao W J, Yan H W, Yang Z, et al. Rolling force self-learning prediction algorithm based on CA-CAMC network [J]. Metallurgical Automation, 2016, 40 (2): 7-10.
- [10] Yao L, Ge Z Q. Deep learning of semi-supervised process data with hierarchical extreme learning machine and soft sensor application [J]. IEEE Transactions on Industrial Electronics, 2017, 25 (6): 1490-1498.
- [11] 曹建国, 江军, 赵秋芳, 等. 基于数据挖掘的宽厚板板凸度控制 [J]. 中南大学学报: 自然科学版, 2019, 50 (11): 2743-2752.
Cao J G, Jiang J, Zhao Q F, et al. Control of plate crown for wide and thick plates based on data mining [J]. Journal of Central South University: Science and Technology, 2019, 50 (11): 2743-2752.
- [12] 王强, 吕政, 王霖青, 等. 基于深度去噪核映射的长期预测算法 [J]. 控制与决策, 2019, 34 (5): 989-996.
Wang Q, Lyu Z, Wang L Q, et al. Long term prediction algorithm based on deep denoising kernel mapping [J]. Control and Decision, 2019, 34 (5): 989-996.
- [13] Bengio Y, Lamblin P, Popvici D, et al. Greedy layer-wise training of deep networks [J]. Advances in Neural Information Processing Systems, 2007, 19: 153-160.
- [14] 魏立新, 魏新宇, 孙浩, 等. 基于深度网络训练的铝热轧轧制力预测 [J]. 中国有色金属学报, 2018, 28 (10): 2070-2076.
Wei L X, Wei X Y, Sun H, et al. Rolling force prediction of aluminum hot rolling based on deep network training [J]. Chinese Journal of Nonferrous Metals, 2018, 28 (10): 2070-2076.
- [15] 马湧, 王晓鹏, 马莎莎. 基于 Keras 深度学习框架下 BP 神经网络的热轧带钢力学性能预测 [J]. 冶金自动化, 2019, 43 (2): 6-10.
Ma Y, Wang X P, Ma S S. Prediction of mechanical properties of hot rolled strip based on BP neural network based on Keras deep learning framework [J]. Metallurgical Automation, 2019, 43 (2): 6-10.
- [16] 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 rolling force self-learning model for cold tandem rolling based on big data platform [J]. Metallurgical Automation, 2020, 44 (6): 25-29, 61.
- [17] 曹建国, 江军, 邱澜, 等. 新一代高技术宽带钢冷轧机全机组一体化板形控制 [J]. 中南大学学报: 自然科学版, 2019, 50 (7): 1584-1591.
Cao J G, Jiang J, Qiu L, et al. Integrated shape control of new generation high technology wide strip cold rolling mill [J]. Journal of Central South University: Science and Technology, 2019, 50 (7): 1584-1591.