

# 冷轧带材多通道板形并行预报方法

段伯伟<sup>1</sup> 王东城<sup>1,2\*</sup> 徐扬欢<sup>1</sup> 刘宏民<sup>1</sup>

1.燕山大学国家冷轧板带装备及工艺工程技术研究中心,秦皇岛,066004

2.金属成形技术与重型装备全国重点实验室,西安,710032

**摘要:**采用集成学习方法研究了一种精度高、泛化能力强的冷轧带材板形预报方法。以工业大数据为基础构建模型训练所需的数据集具有数据规模大、板形多样化程度高的特点。根据轧机与板形仪间的相对位置进行时间滞后补偿处理,消除数据之间的时间不同步。利用数据挖掘技术中的孤立森林算法对数据中的异常点进行清洗,提高了训练数据质量和模型性能。基于极端梯度提升算法搭建多通道板形并行预报架构,利用处理后生产数据对此架构进行训练,得到冷轧带材板形预报模型(CCFD\_M)。以模型 CCFD\_M 为基础,提出板形通道优化算法消除预报结果的“伪板形”问题,得到实用版冷轧带材板形预报模型 CCFD\_OM。经测试集验证,模型 CCFD\_OM 的预报误差指标 MAE(平均绝对误差)和 RMSE(均方根误差)分别达到 0.4044I 和 0.6816I,拟合性能指标  $R^2$  达到了 0.83,能够满足实际生产要求。

**关键词:**冷轧带材;板形预报;时间滞后补偿;孤立森林算法;极端梯度提升算法

**中图分类号:**TF35;TP181

DOI:10.3969/j.issn.1004-132X.2025.03.019

开放科学(资源服务)标识码(OSID):



## Multi-channel Flatness Parallel Prediction Method for Cold Rolled Strips

DUAN Bowei<sup>1</sup> WANG Dongcheng<sup>1,2\*</sup> XU Yanghuan<sup>1</sup> LIU Hongmin<sup>1</sup>

1.National Engineering Research Center for Equipment and Technology of Cold Rolling Strip, Yanshan University, Qinhuangdao, Hebei, 066004

2.National Key Laboratory of Metal Forming Technology and Heavy Equipment, Xi'an, 710032

**Abstract:** An ensemble learning method was employed to develop a high-accuracy, strong-generalization cold rolled strip flatness prediction approach. Firstly, a model training dataset was constructed based on industrial big data, which had large data scale and high degree of flatness diversity. The time lag compensation was employed to eliminate time asynchrony among data based on the relative position between rolling mill and flatness meter. The isolation forest algorithm of data mining technology was used to clean outliers in data, improving the quality of training data and model performance. Subsequently, an architecture of multi-channel flatness parallel prediction was constructed based on XGBoost algorithm. This architecture was trained using processed production dataset to obtain the cold rolled strip flatness prediction model(CCFD\_M). Lastly, based on CCFD\_M, a flatness channel optimization algorithm was proposed to eliminate the issue of “pseudo-flatness” in prediction results, and the practical version of cold rolled strip flatness prediction model(CCFD\_OM) was obtained. After verification on test set, the prediction error indicators mean absolute error(MAE) and root mean square error(RMSE) of model CCFD\_OM reach 0.4044I and 0.6816I, respectively. And the fitting performance indicator  $R^2$  reaches 0.83, which may meet the practical production requirements.

**Key words:** cold rolled strip; flatness prediction; time lag compensation; isolation forest algorithm; extreme gradient boosting(XGBoost) algorithm

## 0 引言

随着我国科技水平的快速提高,建筑、通信、电子、国防等行业对冷轧带材的需求量越来越

大<sup>[1]</sup>。与此同时,国内外市场对高端冷轧带材产品的质量要求也越来越高,达到近乎苛刻的程度。板形是冷轧带材产品质量的关键指标,板形不良定义为带材横向各部位是否产生波浪或瓢曲<sup>[2]</sup>。板形问题的影响因素复杂多变,如何实现精确、高效的板形控制一直是轧制领域的技术难题。

板形检测是实现板形控制的前提,工业上将板形检测设备称为板形仪,一般分为接触式<sup>[3-5]</sup>和

收稿日期:2024-02-05

基金项目:国家自然科学基金(U21A20118);河北省自然科学基金(E2023203065);金属成形技术与重型装备全国重点实验室(中国重型院)开放课题(S2208100.W04)

非接触式<sup>[6-8]</sup>两类。板形控制是最终目标,工业中常称为板形控制系统,其核心是模型体系,主要包括:板形预报模型、板形良好判别模型、板形标准曲线模型、板形模式识别模型和板形反馈控制模型等<sup>[9]</sup>。高精度的板形控制系统必须以板形预报模型为基础,实时精确计算板形调控影响矩阵或功效系数。因此,建立高精度、高速度、高鲁棒性的板形预报模型对提高板形控制精度至关重要。

板形预报模型的研究始于机理建模,其中,带材塑性变形模型和辊系弹性变形模型是两大基础模型。带材塑性变形建模方法主要有解析法<sup>[10]</sup>、变分法<sup>[11]</sup>、有限元法<sup>[12]</sup>、边界元法<sup>[13]</sup>和条元法<sup>[14]</sup>等。轧辊弹性变形建模方法主要有影响函数法<sup>[15]</sup>、差分法<sup>[16]</sup>、边界元法<sup>[17]</sup>和有限元法<sup>[18]</sup>等。带材塑性变形模型与辊系弹性变形模型之间存在相互耦合关系。SHOHET等<sup>[19]</sup>提出传统迭代法,该方法首先假设一组带材出口厚度横向分布值,然后采用带材塑性变形模型计算张应力与轧制压力横向分布,再采用辊系弹性变形模型计算新的带材出口厚度横向分布,不断迭代直至收敛。TARNOPLSKAYA等<sup>[20]</sup>提出反向迭代法,该方法同样首先假设一组带材出口厚度横向分布值,然后采用辊系弹性变形模型计算轧制压力横向分布,再采用带材塑性变形模型计算新的带材出口厚度横向分布,不断迭代直至收敛。笔者所在课题组<sup>[17-18,21]</sup>提出模型耦合法,该方法建立了一套包含带材塑性变形与辊型弹性变形的综合线性方程组,可以一次求解出全部变量,避免了两者之间的相互迭代。总体而言,板形预报机理模型具有规律性和拓展性强等优点,但普遍存在建模周期长、计算速度慢等缺点,通常需要在牺牲精度的基础上对模型进行大量简化。

近年来,随着人工智能理论的发展,智能算法在各个领域都得到了广泛应用<sup>[22-24]</sup>。智能算法能够自动学习数据中蕴含的重要特征和数据之间的相互映射关系,具有出色的非线性感知和泛化能力。在板形智能预报方面,WANG等<sup>[25]</sup>提出一种基于卷积神经网络的板形预报模型,采用数据折叠方法对输入特征进行处理,并将传统的卷积层替换为初始模块建立稀疏连接权值共享机制,达到较好的板形预测效果。文献<sup>[26]</sup>结合遗传算法、思想进化算法、主成分分析与多层感知神经网络提出了三种板形预报模型,通过结果分析得到一种性能较好的板形预报模型。LU等<sup>[27]</sup>采用定点法和包含改进 Swish 激活函数的 DNN 神经网络对冷轧板形进行预报,可以达到较好的板形

预报效果。LIU等<sup>[28]</sup>基于最小化原理,提出自动确定最优隐藏节点的误差最小化极限学习机,可在显著降低计算复杂度和训练时间的基础上实现冷轧带钢的板形预报。SUN等<sup>[29]</sup>基于生产数据,采用偏最小二乘法结合正交信号校正实现板形调控功效系数智能预报。

综上所述,尽管部分相关文献基于经典智能算法提出了一系列创新性的方法,并在板形预报方面展现出一定的潜力,然而,对所使用的训练数据规模却鲜有详细说明,部分研究仅依赖少量数据集,规模仅有几万组甚至更少,涵盖的产品规格也相对单一。对于板形预报这样的复杂工业问题,模型的性能与训练数据的多样性和覆盖面直接相关,小规模数据可能无法充分涵盖工业生产中的各种变化和特殊情况,从而使得模型的泛化能力受到限制。因此,未来的研究在强调方法创新的同时,应重视训练数据的规模和多样性,以确保模型在实际生产中具有可靠性和实用性。

为此,本文以工业大数据为基础,采用集成学习方法研究一种精度高、泛化能力强的冷轧带材板形预报方法。

## 1 数据采集与处理

### 1.1 板形检测原理

如图1所示,工业生产中通常在轧机出口配备板形仪。带材经过轧机压下到达板形仪后,受张力作用包覆在板形辊上。板形辊内部沿轴向布置有多个压力传感器,每个传感器检测一定宽度的带材径向压力,称为一个通道。检测到各通道径向压力分布后,可根据力平衡关系和应力应变关系得到板形分布。

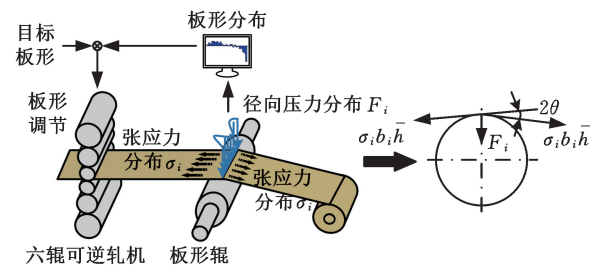


图1 板形测控系统

Fig.1 The flatness measurement and control system

根据力平衡关系可得

$$F_i = 2\sigma_i b_i \bar{h} \sin \theta \quad (1)$$

式中: $F_i$ 为带材对板形辊第*i*通道的径向压力; $\sigma_i$ 为第*i*通道上带材的张应力; $b_i$ 为第*i*通道宽度; $\bar{h}$ 为带材出口平均厚度; $\theta$ 为带材与板形辊包角的一半。

如果带材包覆总通道数为*n*,则其总张力*T*和平均张应力 $\bar{\sigma}$ 分别为

表 1 冷轧带材原始数据分布

Tab.1 The raw data distribution of cold rolled strip

序号	有效通道数	带宽 / mm	样本组数	序号	有效通道数	带宽 / mm	样本组数
1	11	290	40 212	21	19	500	11 733
2		305	12 560	22		520	6468
3		305	26 915	23		530	12 820
4		320	19 160	24		535	36 977
5		320	13 658	25		540	16 545
6	13	340	30 716	26	21	550	10 239
7		365	15 878	27		560	15 808
8		365	13 100	28		565	13 114
9		375	53 556	29		575	15 878
10		385	13 945	30		580	28 926
11	15	405	17 040	31	23	600	6815
12		410	5188	32		615	40 159
13		415	26 251	33		620	7782
14		420	36 931	34		630	14 450
15		430	32 787	35		640	34 098
16	17	450	8347	36	25	655	26 114
17		460	17 954	37		658	17 986
18		465	13 698	38		658	14 969
19		480	21 769	39		665	47 176
20		490	16 055	40		675	34 595

表 2 预报模型输入输出参数选取

Tab.2 Selection of input and output parameters for prediction model

序号	特征	单位	序号	特征	单位
1	带材宽度	mm	9	操作侧工作辊弯辊力	kN
2	入口厚度	μm	10	传动侧工作辊弯辊力	kN
3	出口厚度	μm	11	操作侧中间辊弯辊力	kN
4	入口厚差	μm	12	传动侧中间辊弯辊力	kN
5	出口厚差	μm	13	入口张力	kN
6	速度	m/min	14	出口张力	kN
7	轧制力	kN	15 ~ 36	分段冷却占空比	%
8	辊缝差	μm	37 ~ 63	出口板形	I




图 2 轧机与板形仪相对位置

Fig.2 Relative position of rolling mill and flatness meter

辊运动过程采集数据的滞后行数,然后根据滞后行数对数据进行错位处理,使其一一对应。带材的轧制速度是实时变化的,即每个数据记录周期带材走过的距离是不同的,因此需要进行累加操作:

$$T \sum_{i=1}^n v_i = L \tag{6}$$

$$T = \bar{h} \sum_{i=1}^n \sigma_i b_i = \frac{\sum_{i=1}^n F_i}{2 \sin \theta} \tag{2}$$

$$\bar{\sigma} = \frac{T}{Bh} \tag{3}$$

式中:  $B$  为带材宽度。

令  $B \approx nb_i$ , 则各通道的带材张应力为

$$\sigma_i = \frac{F_i}{2 \sin \theta b_i \bar{h}} = \bar{\sigma} \frac{F_i}{\bar{F}} \tag{4}$$

式中:  $\bar{F}$  为带材对板形辊径向压力的平均值,  $\bar{F} = \frac{1}{n} \sum_{i=1}^n F_i$ 。

根据应力应变关系可得各通道板形分布:

$$S_i = \frac{1-\nu^2}{E} (\bar{\sigma} - \sigma_i) = -\frac{1-\nu^2}{E} \frac{F_i - \bar{F}}{\bar{F}} \frac{T}{hB} \tag{5}$$

式中:  $S_i$  为第  $i$  通道板形;  $\nu$  为带材泊松比;  $E$  为带材弹性模量。

### 1.2 数据采集与特征提取

本文数据采集自国内某 800 mm 冷轧铜带生产线。此产线配备了燕山大学自主研制的整辊无线式板形仪,该板形仪的最大有效检测宽度为 702 mm,检测通道数为 27,传感器全部通道宽度均为 26 mm。带材每轧制一个道次,其过程数据单独保存为一个数据文件。关键工艺参数和板形参数均保存于此,包括:带材宽度、入口厚度、出口厚度、轧制力、入口板形、出口板形等 27 个特征参数,共 147 列变量。

首先按照板形有效通道数(即带宽)对数据进行划分,依次从有效通道数为 11、13、15、17、19、21、23、25 的 8 种规格中各选取 5 卷数据。40 卷实测数据构成冷轧带材原始数据集,共 858 414 组。数据分布如表 1 所示。

根据板形基本理论,本文提取带材宽度、带材厚度、轧制力、弯辊力、倾辊量等 15 个特征,共 36 个参数作为板形预报模型的输入参数。将出口板形(板形辊最大有效检测通道数为 27)的 27 个参数作为预报模型的输出参数,如表 2 所示(表中板形单位 II 表示  $10^{-5}$ )。提取的输入、输出参数共同构成冷轧带材板形数据集(YSU\_CCFD)。

### 1.3 时间滞后补偿

实际生产过程中,板形辊和轧机(包括轧制力检测仪表等)之间存在一定的距离,如图 2 所示,这会导致同一时刻采集的出口板形参数与其他工艺参数相比存在一定的时间滞后,直接用于后续模型训练可能会影响模型的精度和泛化能力。为此,需对数据进行滞后补偿处理。

带材轧制速度与运动时间的乘积即为带材的运行距离,由此可以推导出带材从轧机到板形

式中:  $T$  为数据记录周期;  $v_i$  为带材的轧制速度;  $L$  为轧机与板形仪之间的距离。

#### 1.4 数据剔除与数据清洗

带材建立张力后开始轧制, 速度未达到板形调控的速度阈值(60 m/min)之前, 板形控制系统处于关闭状态, 此时依靠设定值和人工保证板形质量。接近带尾时, 轧机开始减速, 当速度小于阈值后板形自动控制功能自动关闭。上述两种情况均处于非稳定轧制区, 轧制参数变化较为剧烈, 且板形仪在这种情况下测得的数据误差也较大。如果将上述非稳定区的数据也用于后续模型训练, 会影响模型的预报精度。为此, 将数据轧制速度小于 60 m/min 的数据剔除, 保留稳定轧制区的数据。

在稳定轧制阶段, 也可能存在数据采集异常情况, 具体原因可能包括: 板形检测数据丢包(UDP 通信时经常出现), 某一时刻突然由正常值变为零; 检测设备通信网线受到其他电信号干扰, 导致信号丢失或异常; 轧制生产中, 设备、带材发生振动或其他不稳定因素导致张力计、测厚仪、激光测速仪、板形仪等检测设备在某一时刻的数值发生突变。当发生这些情况时, 数据在某些时刻会出现较大的波动, 数据处理领域称为“异常点”。如果数据集中存在过多异常点, 可能会影响数据的正常分布, 进而影响模型预报性能。为此,

表 3 数据清洗后的数据分布

Tab.3 The data distribution after data cleaning

带宽 / mm	原始样本组数	非稳样本组数	异常样本组数	最终样本组数	带宽 / mm	原始样本组数	非稳样本组数	异常样本组数	最终样本组数
290	40 212	1325	2139	36 748	500	11 733	1198	580	9955
305	12 560	467	666	11 427	520	6468	295	340	5833
305	26 915	1115	1419	24 381	530	12 820	285	689	11 846
320	19 160	802	1010	17 348	535	36 977	1948	1927	33 102
320	13 658	1248	683	11 727	540	16 545	420	887	15 238
340	30 716	6869	1311	22 536	550	10 239	2595	421	7223
365	15 878	11 223	256	4399	560	15 808	418	847	14 543
365	13 100	810	676	11 614	565	13 114	256	708	12 150
375	53 556	701	2907	49 948	575	15 878	510	846	14 522
385	13 945	671	731	12 543	580	28 926	506	1564	26 856
405	17 040	398	916	15 726	600	6815	396	352	6067
410	5188	319	268	4601	615	40 159	818	2164	37 177
415	26 251	3793	1236	21 222	620	7782	611	394	6777
420	36 931	307	2015	34 609	630	14 450	1356	721	12 373
430	32 787	815	1759	30 213	640	34 098	422	1852	31 824
450	8347	417	436	7494	655	26 114	963	1384	23 767
460	17 954	347	968	16 639	658	17 986	982	936	16 068
465	13 698	640	719	12 339	658	14 969	790	780	13 399
480	21 769	917	1147	19 705	665	47 176	846	2549	43 781
490	16 055	762	842	14 451	675	34 595	1981	1794	30 820

本文利用数据挖掘理论中的孤立森林算法<sup>[30]</sup>清洗异常点。

孤立森林算法将异常点定义为“容易被孤立的点”, 即分布稀疏且远离密度较高群体的点。其主要思想是使用一个随机的超平面分割数据空间后形成两个子空间, 循环往复, 直到每个子空间只有一个数据点时停止。分布稀疏的点(异常点)需要分割的次数远小于正常点, 因此, 以每个点被完全分割的次数判定其是否为异常点。

表 3 给出了对数据集 YSU\_CCFD 进行数据剔除和数据清洗后得到的非稳样本数量、异常样本数量以及最终样本数量。以 YSU\_CCFD 数据集中的一卷轧制数据为例, 利用孤立森林算法筛选后, 对正常点和异常点进行可视化分析。由于数据特征维度过高无法直接具象化, 利用主成分分析法(PCA)将特征维度分别压缩至二维和三维, 并在二维和三维空间中画出筛选的正常点和异常点, 结果如图 3 所示。可以看出, 大部分正常点都集中聚集在一个密度较高的小区域范围内, 而异常点的分布较为松散且密集程度较低, 说明孤立森林算法可有效避免数据中异常点带来的干扰。经过孤立森林算法筛选出的异常点数据量占整体数据量的 5.5%。

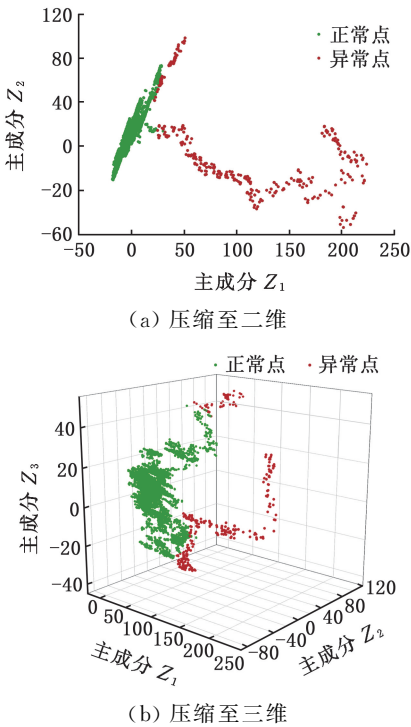


图 3 孤立森林算法异常点筛选结果

Fig.3 Outlier detection results based on isolation forest algorithm

## 2 多通道板形并行预报模型

### 2.1 XGBoost 算法

极端梯度提升(XGBoost)算法<sup>[31]</sup>是一种有效的集成学习算法,其基本思想是将多个基学习器进行组合,通过优势互补达到强学习器的效果。每次使用全部数据训练一系列基学习器,且每次训练均基于上一轮训练结果的残差,当数据残差满足要求时停止训练,可以达到较高的预测精度。如果采用 CART 回归树作为基学习器,加入正则项控制模型的复杂度,则可有效防止模型过拟合。在计算代价函数时进行二阶泰勒展开,使代价函数更加精确。此外,训练前对数据进行预先排序,以块(Block)的形式保存,实现数据特征维度的并行计算。

定义数据集  $D = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n) \mid x_i \in \mathbf{R}^m, y_i \in \mathbf{R}\}$ , 其中,  $x_i$  为  $m$  维特征向量,  $y_i$  为数据标签。假设一棵决策树共有  $T$  个叶子节点,每个节点处的节点值记为  $w_j$ ,每个数据根据其不同特征会到达这棵决策树的不同节点,将落在第  $j$  个叶子节点的数据集合记为  $I_j$ ,则每个数据通过决策树的预测值可表达为

$$f(x_i) = w_{q(x_i)} \quad (7)$$

式中:  $f(x_i)$  为该决策树的输出;  $w_{q(x_i)}$  为每个叶子节点对应的节点值;  $q(x_i)$  为数据与决策树叶子节点的映射关系,有  $I_j = \{i \mid q(x_i) = j\}$ 。

XGBoost 可以包含多个基学习器,其输出为所有基学习器输出之和。假设一个包含  $K$  棵回归树的 XGBoost,其数学表达式为

$$\hat{y}_i = \sum_{s=1}^K f_s(x_i) = \sum_{s=1}^{K-1} f_s(x_i) + f_K(x_i) \quad (8)$$

式中:  $\hat{y}_i$  为模型对数据  $x_i$  的预测值;  $\sum_{s=1}^{K-1} f_s(x_i)$  为  $K-1$  棵树累加的结果;  $f_K(x_i)$  为第  $K$  棵回归树的结果。

XGBoost 的目标函数  $Obj^{(k)}$  由两项组成:损失函数项和正则化项。损失函数项用于评估模型预测值与真实值之间的误差,正则化项用于控制模型复杂度,避免过拟合。第  $k$  棵树的目标函数表达式为

$$Obj^{(k)} = \sum_{i=1}^n L(y_i, \hat{y}_i^{(k)}) + \sum_{s=1}^k \Omega(f_s) \quad (9)$$

式中:  $\hat{y}_i^{(k)}$  为当输入数据为  $x_i$  时第  $k$  棵回归树的预测结果。

目标函数中的正则化项也由两项组成:决策树惩罚项和 L2 正则化项。决策树惩罚项通过决策树的叶子节点数及其系数控制树的复杂度。当叶子节点数过多时,可通过调整惩罚系数控制惩罚力度,达到抑制模型复杂度的目的。L2 正则项用于控制叶子节点的权重分数。正则化项的定义为

$$\Omega(f_s) = \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T \|w_j\|^2 \quad (10)$$

式中:  $T$  为第  $k$  棵树的叶子节点数;  $\gamma$  为叶子节点数的惩罚系数;  $w_j$  为第  $k$  棵回归树节点所对应的值;  $\lambda$  为 L2 正则化项的惩罚系数。

式(9)可以改写成

$$Obj^{(k)} = \sum_{i=1}^n L(y_i, \hat{y}_i^{(k)}) + \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T \|w_j\|^2 \quad (11)$$

通过统计数据集合计算式(11)中的损失函数,数据点最终都会落到决策树的不同节点处,构成数据集合  $I_j$ 。为了方便后续推导,通过叶子节点统计的方式代替数据统计计算损失函数,可得

$$Obj^{(k)} = \gamma T + \sum_{j=1}^T \left[ \sum_{i \in I_j} L(y_i, \hat{y}_i^{(k-1)} + w_j) + \frac{1}{2} \lambda \sum_{j=1}^T \|w_j\|^2 \right] \quad (12)$$

XGBoost 采用二阶泰勒展开来近似和简化目标函数,二阶泰勒展开式一般形式为

$$f(x + \Delta x) \cong f(x) + f'(x)\Delta x + \frac{1}{2} f''(x)\Delta x^2 \quad (13)$$

对损失函数进行二阶泰勒展开,式(12)改写成

$$Obj^{(k)} \cong \gamma T + \sum_{j=1}^T \left[ \sum_{i \in I_j} (g_i w_j +$$

$$\frac{1}{2}h_i w_j^2] + \frac{1}{2}\lambda \sum_{j=1}^T \|w_j\|^2 \quad (14)$$

$$g_i = L'(y_i, \sum_{s=1}^{k-1} f_s(x_i)) \quad h_i = L''(y_i, \sum_{s=1}^{k-1} f_s(x_i))$$

式中:  $g_i$  为一阶梯度;  $h_i$  为二阶梯度。

将式(14)继续展开得到

$$Obj^{(k)} \cong \gamma T + \sum_{j=1}^T [(\sum_{i \in I_j} g_i)w_j + \frac{1}{2}(\sum_{i \in I_j} h_i)w_j^2] + \frac{1}{2}\lambda \sum_{j=1}^T \|w_j\|^2 \quad (15)$$

式中:  $\sum_{i \in I_j} g_i$  为节点  $j$  所有数据一阶梯度的和;  $\sum_{i \in I_j} h_i$  为节点  $j$  所有数据二阶梯度的和。

$$\text{令 } G_j = \sum_{i \in I_j} g_i, H_j = \sum_{i \in I_j} h_i, \text{ 可得}$$

$$Obj^{(k)} \cong \gamma T + \sum_{j=1}^T [G_j w_j + \frac{1}{2}(H_j + \lambda)w_j^2] \quad (16)$$

为求目标函数  $Obj^{(k)}$  的最优值  $\text{argmin } Obj^{(k)}$ , 需要求得每个叶子节点的最优值  $w_j^*$ , 而  $(H_j + \lambda) \geq 0, Obj^{(k)}$  为凸函数, 则节点最优值

$$w_j^* = -\frac{G_j}{H_j + \lambda} \quad (17)$$

将节点最优值代回式(16), 可以得到目标函数最小值表达式:

$$Obj^{(k)*} \cong \gamma T - \frac{1}{2} \sum_{j=1}^T \frac{G_j^2}{H_j + \lambda} \quad (18)$$

## 2.2 板形预报模型

本文基于 XGBoost 算法构建冷轧带材板形预报模型, 利用多个 XGBoost 算法搭建一个多通道并行预报架构。每个子 XGBoost 算法负责预报一个通道的板形, 各通道板形预报是相互独立的。本文并未对数据集 YSU\_CCFD 进行归一化处理, 常规机器学习算法是基于梯度下降算法优化的, 因此需要对数据进行归一化处理, 消除数据不同特征之间尺度及量纲的差异。而本文使用的 XGBoost 算法是基于回归树模型的, 该模型对输入特征的尺度并不敏感。对 2.1 节构建的冷轧带材板形数据集 (YSU\_CCFD) 进行划分, 从 YSU\_CCFD 中每卷数据随机抽取 15% 作为测试集, 用于模型性能测试, 记为 YSU\_CCFD\_Test。剩余数据用于模型训练, 记为 YSU\_CCFD\_Train。

超参数的选择在很大程度上决定 XGBoost 算法的最终性能, 合理的参数对防止过拟合、提高训练模型性能具有重要意义。本文利用网格搜索法确定超参数, 并且以决定系数  $R^2$  作为网格搜索的评估标准。最终确定训练超参数如下: 回归树模型数量为 130; 单个回归树的最大深度为 6; 学习率为 0.4; 叶子节点最小样本数为 1.5; 样本下采样比例为 0.8; L1 正则项权重为 2.6; L2 正则项

权重为 0.5。在模型训练时采用五折交叉验证的方法, 如图 4 所示。将 YSU\_CCFD\_Train 随机分成 5 份, 每次选取 4 份作训练集, 1 份作验证集, 重复 5 次, 将性能最优模型保存, 作为冷轧带材板形预报模型, 记为 CCFD\_M。

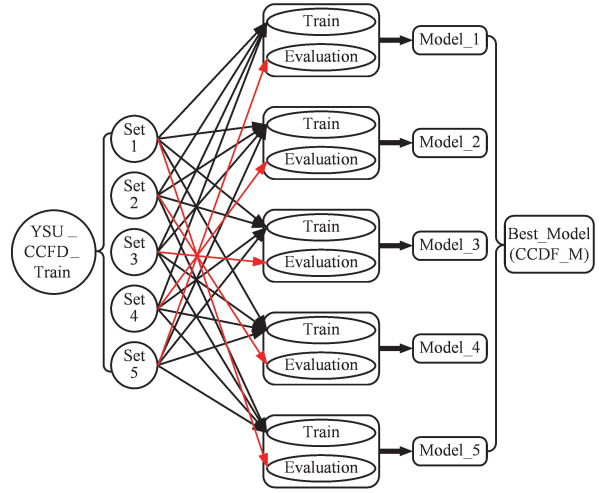


图 4 五折交叉验证

Fig.4 Five-fold cross-validation

## 2.3 板形通道维度优化

利用上述 CCFD\_M 模型对测试集 YSU\_CCFD\_Test 进行板形预报时发现如下问题: CCFD\_M 预报的板形通道维度均与训练集 YSU\_CCFD\_Train 中板形最大规格维度相同。进一步观察发现, 预报板形相比真实板形多出的边部通道, 其板形值与中间有效通道板形值相差 100 倍之多, 属于噪声值, 本文将其定义为“伪板形”。

为此, 根据输入数据中的带材宽度特征设计了板形通道维度优化算法, 如下所示:

输入:  $M_{\text{pred}}$  为预报板形  $n$  行  $m$  列,  $W_{\text{strip}}$  为带材宽度,  $W_{\text{roll}}$  为板形辊单通道检测宽度,  $C_{\text{roll}}$  为板形辊最大通道数量;

1. 计算理论有效通道维度  $C_{\text{theory}} = \lfloor \frac{W_{\text{strip}}}{W_{\text{roll}}} \rfloor$ ;
2. 判断是否满足  $C_{\text{theory}} \% 2 = 0$ ? 满足转到步骤 3, 否则转到步骤 4;
3. 令  $C_{\text{theory}} = C_{\text{theory}} - 1$ , 设置临时变量  $i = 0$ ;
4. 判断是否满足  $i = \lfloor (C_{\text{roll}} - C_{\text{theory}}) / 2 \rfloor$ ? 满足转到步骤 5, 否则转到步骤 7;
5. 令  $M_{\text{pred}}[0:n][i] = 0, M_{\text{pred}}[0:n][C_{\text{roll}} - i] = 0, i \leftarrow i + 1$ ;
6. 判断是否满足  $M_{\text{pred}}[0:n][i] = 0$ ? 若满足转到步骤 7, 否则转到步骤 4;
7. 结束。

根据带材宽度  $W_{\text{strip}}$  和板形辊单通道检测宽度  $W_{\text{roll}}$  计算理论通道维度  $C_{\text{theory}}$ :

$$C_{\text{theory}} = \lfloor \frac{W_{\text{strip}}}{W_{\text{roll}}} \rfloor \quad (19)$$

式中： $\lfloor \cdot \rfloor$ 为向下取整符号。

若  $C_{theory}$  为偶数，则令  $C_{theory} = C_{theory} - 1$ ，若  $C_{theory}$  为奇数，则不做任何处理。进而与预报板形通道维度进行对比，置零所有“伪板形”通道板形值。该方法简单高效，能够有效解决“伪板形”问题。图 5 给出了融合板形通道优化算法后最终的冷轧带材板形预报架构，最终得到实用版冷轧带材板形预报模型，记为 CCFD\_OM。

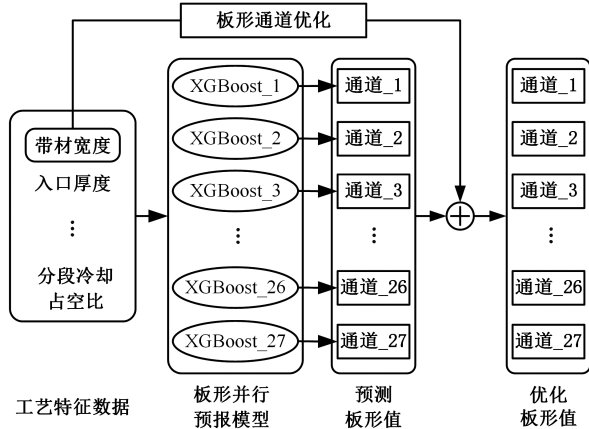


图 5 多通道板形并行预报架构

Fig.5 Multi-channel flatness parallel prediction architecture

### 3 结果分析

本文选用均方根误差 (RMSE)  $E_{RMSE}$ 、决定系数 ( $R^2$ ) 和平均绝对误差 (MAE)  $E_{MAE}$  来评估模型的预报精度。其中 RMSE 和 MAE 用于衡量预报板形与真实板形之间的误差，值越小代表模型性能越好； $R^2$  用于评估预报板形与真实板形间的相关性， $R^2$  的值越接近 1 代表模型性能越好。这三个评价指标的数学表达式为：

$$\left. \begin{aligned} E_{RMSE} &= \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \\ E_{MAE} &= \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \\ R^2 &= 1 - \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (\bar{y} - y_i)^2} \end{aligned} \right\} \quad (20)$$

式中： $y_i$  为第  $i$  个样本的真实值； $\hat{y}_i$  为第  $i$  个样本的预测值； $\bar{y}$  为所有样本真实值的均值。

表 4 还给出了进行异常值处理和未进行异常值处理的对比结果。可以看出，进行异常值处理后，无论是误差指标还是模型拟合度指标，模型预报性能都得到一定程度的提高。为比较 CCFD\_OM 的模型性能，本文还额外选取了 3 种经典集成学习算法构建了板形预报模型，包括 GBDT、

AdaBoost、HisGBoost。将测试集 YSU\_CCFD\_Test 输入 CCFD\_OM 和其他 3 种模型中进行板形预报，结果对比如表 4 所示。可以看出，模型 CCFD\_OM 在测试集 YSU\_CCFD\_Test 上的 MAE 值和 RMSE 值分别达到 0.4044I 和 0.6816I，在 4 个模型中表现最好。评价模型拟合性能的指标  $R^2$  达到了 0.83，也是 4 个模型中最高的，说明 CCFD\_OM 模型能够很好地拟合训练数据。

表 4 四种模型在 YSU\_CCFD\_Test 上的预报结果

Tab.4 Prediction result of four models on YSU\_CCFD\_Test

模型	数据处理	MAE/I	RMSE/I	$R^2$
XGBoost	剔除、清洗	<b>0.4044</b>	<b>0.6816</b>	<b>0.83</b>
HistGBoost		0.4747	0.8016	0.77
GBDT		0.6732	1.1750	0.59
AdaBoost		1.2840	2.0102	0.35
XGBoost	剔除、未清洗	<b>0.6201</b>	<b>0.8341</b>	<b>0.75</b>
HistGBoost		0.7912	1.5247	0.59
GBDT		0.9824	2.1242	0.35
AdaBoost		2.5425	3.5510	0.22

分别计算测试集每个样本预报板形与真实板形的平均绝对误差 MAE，结果如图 6 所示。将所有样本的 MAE 按照升序排列，绿色点表示绝对误差在全部样本的前 80%，蓝色点表示绝对误差在全部样本的前 80%~95%之间，红色点表示绝对误差在后 5%。图中还给出了 80% 和 95% 的绝对误差控制线，本文构建的 CCFD\_OM 模型的误差控制线均为最低，说明本文方法所构建的模型具有较强的稳定性。

目前，工业生产要求不同机型、不同厚度冷轧铜带板形控制精度不大于 7I (带材 95% 范围)。板形预报模型主要用于辊型优化、弯辊力设定和闭环控制系统的影响系数计算，模型预报精度最终也体现为板形控制精度。本文构建的 CCFD\_OM 模型在测试集中的 MAE 值为 0.4044I，测试集的 80% 误差控制线为 0.8539I，测试集的 95% 误差控制线为 1.3436I，可满足实际生产对板形精度的要求。

为了更全面地展示 CCFD\_OM 的性能，从 YSU\_CCFD\_Test 中随机抽取 8 种规格各一卷数据分别进行局部和全局板形可视化，结果如图 7 和图 8 所示。图 7 给出了不同规格数据中随机抽取的单个样本板形分布对比图，红色点线代表预报板形，青色柱代表真实板形 (板形仪实测值)。由图可知，无论对于哪种规格，CCFD\_OM 模型的预报板形与真实板形吻合度都比较高。

图 7 中 8 种规格带材的板形实测数据均采集

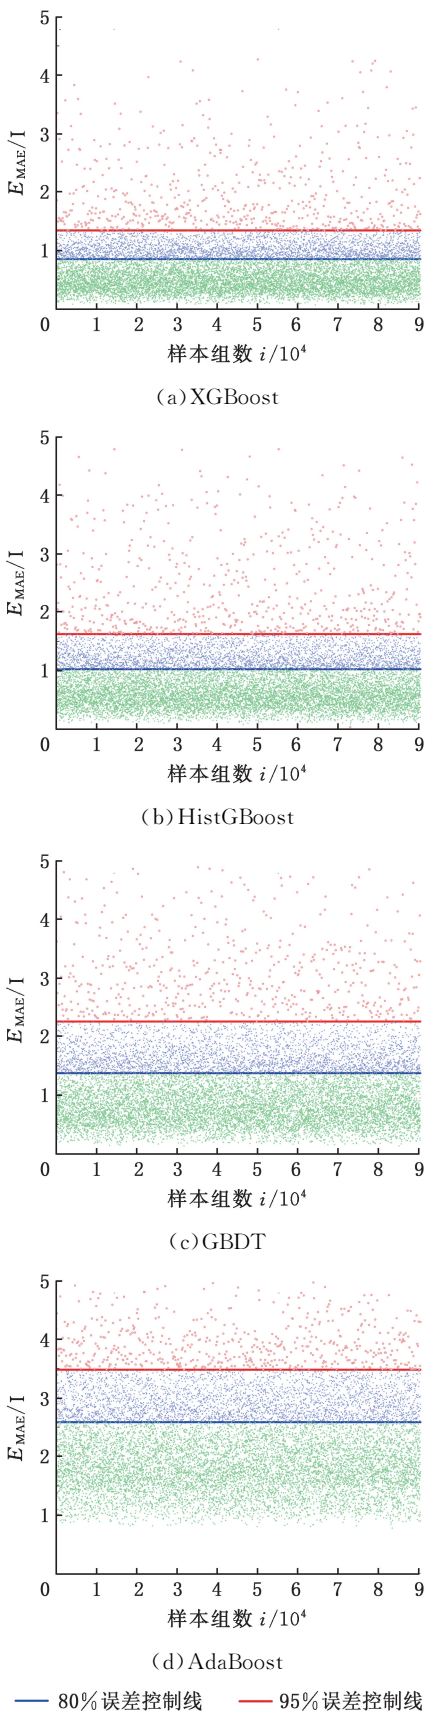


图6 YSU\_CCFD\_Test 每个样本的 MAE 散点图  
Fig.6 MAE scatter plot of each sample of YSU\_CCFD\_Test

于同一台铜带可逆冷轧机,该轧机主要轧制紫铜、黄铜的退火带和成品带。其中,退火带厚度较大,

大部分需要连续轧制多个道次,每道次压下率较大,轧制完毕后再进行退火;成品带厚度较小,一般只轧制一个道次,压下率较小。轧制退火带时,典型的板形分布特征是四分浪和双紧边。造成这种现象的主要原因是多道次冷轧引起的边缘降累积,通常压下率越大、轧制道次越多,这种现象越明显。通过弯辊、倾辊和精细冷却功能很难完全消除此类板形不良,图 7a、图 7b、图 7e、图 7f、图 7g、图 7h 的板形分布均具有这种特征。


轧制成品带时,压下率较小,而且通常只轧制一个道次,板形分布受边缘降影响较小,可以明显体现出二次分布特征(边浪或中浪),通过弯辊、倾辊和精细冷却功能可以使实测板形与目标板形吻合良好。图 7d 所示为轧制成品带并且板形控制系统刚投入时的实测板形,此时单边浪特征较为明显,板形闭环控制系统投入后,单边浪会快速消除。在轧制时速度较高(接近 480 m/min)时,单位时间发热量较大,此时还可能出现另外一种较为特殊的板形缺陷,如图 7c 所示,在带材中部出现一条明显的浪形。这是由于冷却液流量偏低,工作辊不能得到充分冷却,在辊身中部热膨胀较大,此时必须增加冷却液流量才能消除这种特殊的板形缺陷。

图 8 对不同规格数据集进行了全局可视化,其中,左列为真实板形,右列为预报板形。可以看出,经过模型预报的板形基本能拟合真实板形,但在细节纹理方面模型对预报结果细节部分进行了模糊处理,说明模型具备一定的泛化能力,对不同规格数据也能够达到较好的性能。


#### 4 结论

1) 本文基于生产现场采集了规模大、板形多样化程度高的冷轧带材生产数据。为消除同一时刻采集的出口板形参数与其他工艺参数之间存在的时间滞后,根据轧机与板形仪间的相对位置对数据进行时间滞后补偿处理。最后,在剔除非稳定数据基础上,利用数据挖掘技术中的孤立森林算法,对数据中的异常点进行清洗,在模型性能测试中验证了数据清洗的有效性。


2) 利用多个极端梯度提升算法搭建一个相互独立的多通道板形并行预报架构,采用网格搜索法和五折交叉验证法搜寻最优超参数并训练模型,得到冷轧带材板形预报模型。针对预报结果中出现的“伪板形”问题提出了板形通道优化算法。经测试集验证,本文方法的预报板形与真实板形间的误差指标 MAE 和 RMSE 分别达到




(a) 规格一




(b) 规格二




(c) 规格三




(d) 规格四




(e) 规格五



(f) 规格六



(g) 规格七



(h) 规格八

图 7 模型 CCFD\_OM 在 YSU\_CCFD\_Test 的局部板形可视化

Fig.7 Local flatness visualization of CCFD\_OM on YSU\_CCFD\_Test

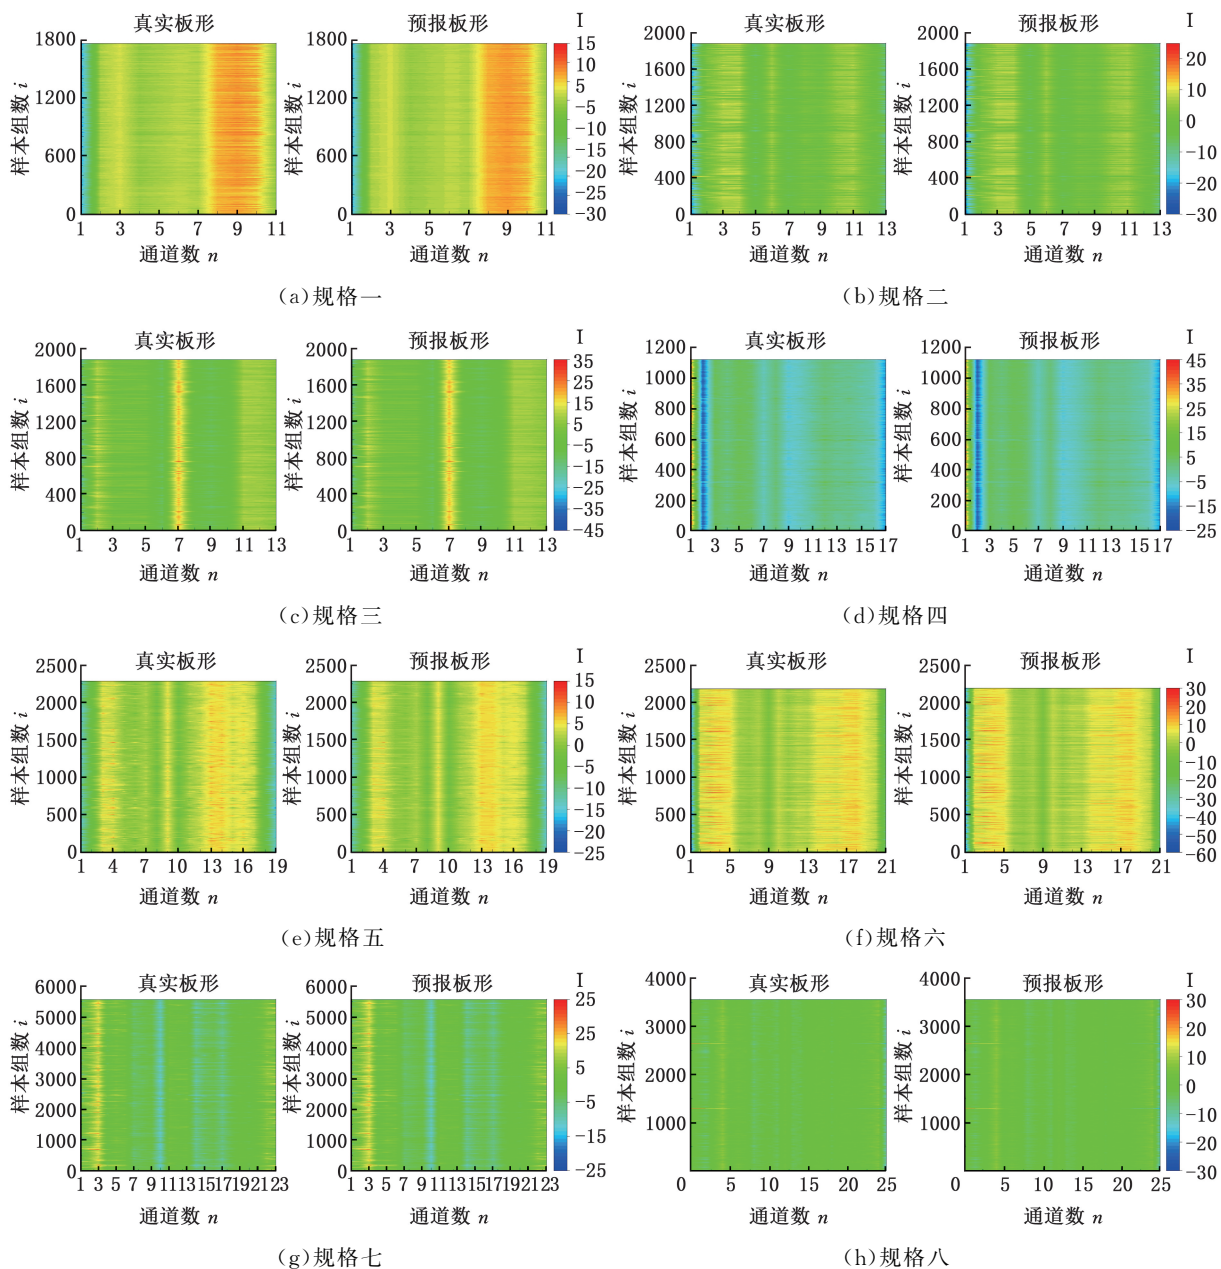


图 8 模型 CCFD\_OM 在 YSU\_CCFD\_Test 的全局板形可视化

Fig.8 Global flatness visualization of CCFD\_OM on YSU\_CCFD\_Test

0.4044I和0.6816I,模型的拟合性能指标  $R^2$  也达到了0.83,能够满足实际生产要求。

3)本文方法在数据方面体现了规模大、轧制规格和板形多样化程度高等特点,在测试集上的预报性能优秀,展示出很好的应用潜力。

参考文献:

[1] 王国栋,刘振宇,张殿华,等. 钢铁企业创新基础设施及研究进展[J]. 钢铁, 2023, 58(9):2-14.  
WANG Guodong, LIU Zhenyu, ZHANG Dianhua, et al. Steel Enterprise Innovation Infrastructure (SEII) and Its Research Development [J]. Iron & Steel, 2023, 58(9):2-14.

[2] 刘宏民,于华鑫,王东城,等. 冷轧带钢板形测控前

沿技术的创新方略[J]. 钢铁, 2023, 58(4):77-86.

LIU Hongmin, YU Huaxin, WANG Dongcheng, et al. Innovative Strategy on Frontier Flatness Measurement and Control Technology of Cold Strip Steel Rolling[J]. Iron & Steel, 2023, 58(4):77-86.

[3] 刘宏民,刘军,于丙强,等. 带钢冷轧机整辊无线式板形仪和智能板形控制系统[J]. 机械工程学报, 2017, 53(12):87-93.

LIU Hongmin, LIU Jun, YU Bingqiang, et al. Entire Roller Wireless Shape Meter and Intelligent Shape Control System for Cold Steel Strip Mills[J]. Journal of Mechanical Engineering, 2017, 53(12):87-93.

[4] 于华鑫,张桐源,张帅,等. 整辊式板形辊挠曲影响信号的快速识别和消除[J]. 仪器仪表学报, 2021,

- 42(3):192-200.
- YU Huaxin, ZHANG Tongyuan, ZHANG Shuai, et al. Fast Recognition and Elimination of the Interference Signal Caused by Bending Deformation of the Whole Roller Seamless Flatness Meter[J]. Chinese Journal of Scientific Instrument, 2021, 42(3): 192-200.
- [5] 郝亮, 邸洪双, 龚殿尧, 等. 气动轴承板形仪测量原理与应用[J]. 轻合金加工技术, 2011, 39(12):31-33.
- HAO Liang, DI Hongshuang, GONG Dianyao, et al. Working Principle and Application of Air Bearing Shape Meter[J]. Light Alloy Fabrication Technology, 2011, 39(12):31-33.
- [6] GUAN Ben, ZANG Yong, HAN Xiaohui, et al. Cold-rolled Strip Steel Stress Detection Technology Based on a Magnetoresistance Sensor and the Magnetoelastic Effect[J]. Sensors, 2018, 18(5):1638.
- [7] 杨西荣, 王快社, 张兵, 等. 激光热轧板带钢板形检测方法的研究[J]. 重型机械, 2005(4):17-19.
- YANG Xirong, WANG Kuaishe, ZHANG Bing, et al. Study on Laser Profile Measurement in Hot Rolling[J]. Heavy Machinery, 2005(4):17-19.
- [8] 刘江, 姜丽华, 王长松, 等. 直线型激光板形检测系统[J]. 钢铁研究学报, 2003, 15(5):60-63.
- LIU Jiang, JIANG Lihua, WANG Changsong, et al. Study on Linear Laser System for Steel Strip Flatness Control[J]. Journal of Iron and Steel Research, 2003, 15(5):60-63.
- [9] 刘宏民, 于华鑫, 王东城, 等. 冷轧带钢板形测控技术的发展状况和关键问题[J]. 钢铁, 2022, 57(11):22-32.
- LIU Hongmin, YU Huaxin, WANG Dongcheng, et al. Development State and Key Problems on Flatness Measurement and Control Technology of Cold Strip Steel Rolling[J]. Iron & Steel, 2022, 57(11): 22-32.
- [10] YAO Chihuan, HE Anrui, SHAO Jian, et al. A Real-time Quasi-3D Metal Flow Model for Hot Strip Rolling[J]. International Journal of Mechanical Sciences, 2019, 159:91-102.
- [11] 连家创, 段振勇. 软件宽展量的研究[J]. 钢铁, 1984(11):15-20.
- LIAN Jiachuang, DUAN Zhenyong. Research on the Lateral Spread of Rolled Stock[J]. Iron and Steel, 1984(11):15-20.
- [12] 张清东, 李博, 张晓峰. 带钢平整轧制板形控制行为及效应的研究[J]. 机械工程学报, 2014, 50(8):45-52.
- ZHANG Qingdong, LI Bo, ZHANG Xiaofeng. Research on the Behavior and Effects of Flatness Control in Strip Temper Rolling Process[J]. Journal of Mechanical Engineering, 2014, 50(8): 45-52.
- [13] 肖宏, 申光宪, 连家创. 三维弹塑性边界元法模拟板带轧制过程[J]. 钢铁, 1993(3):39-43.
- XIAO Hong, SHEN Guangxian, LIAN Jiachuang. Simulation of Strip Rolling Process by 3-dimensional Elastoplastic Boundary Element Method[J]. China Industrial Economics, 1993(3):39-43.
- [14] LIU Hongmin, ZHENG Zhenzhong, PENG Yan. Streamline Strip Element Method for Analysis of the Three-dimensional Stresses and Deformations of Strip Rolling[J]. International Journal for Numerical Methods in Engineering, 2001, 50(5): 1059-1076.
- [15] CAO Jianguo, CHAI Xueting, LI Yanlin, et al. Integrated Design of Roll Contours for Strip Edge Drop and Crown Control in Tandem Cold Rolling Mills[J]. Journal of Materials Processing Technology, 2018, 252:432-439.
- [16] 孔繁甫, 何安瑞, 邵健. 快速辊系变形在线计算方法研究[J]. 机械工程学报, 2012, 48(2):121-126.
- KONG Fanfu, HE Anrui, SHAO Jian. Research on Rapid Online Calculation Methods of Roll Stack Deformation[J]. Journal of Mechanical Engineering, 2012, 48(2):121-126.
- [17] 王东城, 张威, 王志杰, 等. 六辊冷轧机板形快速预报方法[J]. 钢铁, 2016, 51(9):51-56.
- WANG Dongcheng, ZHANG Wei, WANG Zhijie, et al. Fast Shape Prediction Method for Six-high Cold Rolling Mill[J]. Iron & Steel, 2016, 51(9): 51-56.
- [18] WANG Dongcheng, LIU Hongmin. A Model Coupling Method for Shape Prediction[J]. Journal of Iron and Steel Research International, 2012, 19(2):22-27.
- [19] SHOHET K N, TOWNSEND N A. Roll Bending Methods of Crown Control in Four-high Plate Mills[J]. Journal of the Iron and Steel Institute, 1968(11):1088-1098.
- [20] TARNOPLSKAYA T, De HOOG F R. An Efficient Method for Strip Flatness Analysis in Cold Rolling[J]. Mathematical Engineering in Industry, 1998, 7(1):71-95.
- [21] 王东城, 赵章献, 刘宏民. 冷轧带钢板形高效分析与设定软件及其应用[J]. 钢铁, 2015, 50(7):54-60.
- WANG Dongcheng, ZHAO Zhangxian, LIU Hongmin. High-efficiency Software and Its Application for Shape Analysis and Presetting of Cold Rolling Strip[J]. Iron & Steel, 2015, 50(7): 54-60.

- [22] 李向杰, 张向文. 基于人工蜂群支持向量机的电动汽车制动意图识别方法[J]. 中国机械工程, 2021, 32(17):2125-2135.  
LI Xiangjie, ZHANG Xiangwen. Recognition Method of Braking Intention of Electric Vehicles Based on ABC-SVM Algorithm[J]. China Mechanical Engineering, 2021, 32(17):2125-2135.
- [23] 郭伟, 邢晓松. 基于改进卷积生成对抗网络的少样本轴承智能诊断方法[J]. 中国机械工程, 2022, 33(19):2347-2355.  
GUO Wei, XING Xiaosong. Intelligent Fault Diagnosis of Bearings with few Samples Based on an Improved Convolutional Generative Adversarial Network [J]. China Mechanical Engineering, 2022, 33(19):2347-2355.
- [24] 李东阳, 袁东风, 张海霞, 等. 云边端协同的机床刀具故障智能诊断系统研究[J]. 中国机械工程, 2023, 34(5):584-594.  
LI Dongyang, YUAN Dongfeng, ZHANG Haixia, et al. Research on Intelligent Tool Fault Diagnosis System of Machine Tools with Cloud-edge-device Collaboration[J]. China Mechanical Engineering, 2023, 34(5):584-594.
- [25] WANG Yu, LI Changsheng, PENG Liangui, et al. Application of Convolutional Neural Networks for Prediction of Strip Flatness in Tandem Cold Rolling Process [J]. Journal of Manufacturing Processes, 2021, 68:512-522.
- [26] WANG Zhenhua, MA Gengsheng, GONG Dianyao, et al. Application of Mind Evolutionary Algorithm and Artificial Neural Networks for Prediction of Profile and Flatness in Hot Strip Rolling Process[J]. Neural Processing Letters, 2019, 50(3):2455-2479.
- [27] LU Ningyun, JIANG Bin, LU Jianhua. Data Mining-based Flatness Pattern Prediction for Cold Rolling Process with Varying Operating Condition [J]. Knowledge and Information Systems, 2014, 41(2):355-378.
- [28] LIU Jingyi, WAN Lushan, XIAO Dong. Flatness Prediction of Cold Rolled Strip Based on EM-TELM[J]. IEEE Access, 1891, 9:51484-51493.
- [29] SUN Jie, SHAN Pengfei, WEI Zhen, et al. Data-based Flatness Prediction and Optimization in Tandem Cold Rolling[J]. Journal of Iron and Steel Research International, 2021, 28(5):563-573.
- [30] LIU F T, TING Kai ming, ZHOU Zhihua. Isolation Forest[C]//2008 Eighth IEEE International Conference on Data Mining.Pisa, 2008:413-422.
- [31] CHEN Tianqi, GUESTRIN C. XGBoost: a Scalable Tree Boosting System[C]//Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. San Francisco, 2016:785-794.

(编辑 王旻玥)

作者简介:段伯伟,男,1996年生,博士研究生。主要研究方向为带材板形检测与控制。E-mail:bwduan1@163.com。王东城\*(通信作者),男,1981年生,副教授、博士研究生导师。主要研究方向为高端带材产品质量智能检测与控制、板带轧制理论与技术。E-mail:wdc-731@163.com。

**本文引用格式:**

段伯伟,王东城,徐扬欢,等.冷轧带材多通道板形并行预报方法[J].中国机械工程,2025,36(3):558-569.

DUAN Bowei, WANG Dongcheng, XU Yanghuan, et al. Multi-channel Flatness Parallel Prediction Method for Cold Rolled Strips[J]. China Mechanical Engineering, 2025, 36(3):558-569.

## 中国机械工程学会 2025 年期刊工作会议在江西南昌举行

2025年3月7日,中国机械工程学会2025年期刊工作会议在江西省南昌市举行。中国机械工程学会驻会副理事长王国彪,副秘书长陈超志、左晓卫、王淑芹,秘书长助理栾大凯,华东交通大学副校长黄志超,学会部分专业分会总干事,以及来自学会主办期刊、专业分会会刊、期刊联盟的部分期刊代表近60人参加会议。

中国机械工程学会副秘书长王淑芹作了题为“守正创新 融合赋能”的工作报告。报告汇报了学会38种期刊发展现状和近两年学会刊群建设情况,梳理了2025年学会期刊开展的重点工作。报告强调,学会期刊要加强各刊质量提升,共同促进学会刊群高质量发展。

会议设置了专题分享和工作交流两个议题。在专题分享环节,围绕当前技术发展的新趋势,就AI赋能期刊

工作主题,《机械工程学报》《特种铸造及有色合金》《中国机械工程》3刊代表分享了在实际工作中利用新技术的探索实践。在业务交流环节,各刊就特色亮点工作进行总结汇报。来自学会专业分会的总干事就学会期刊发展中存在的问题提出了建设性意见。

中国机械工程学会驻会副理事长王国彪作会议总结讲话。他表示要加大对期刊工作的监管和支撑力度,真正做大做强学会刊群。他分析了当前学会发展的新形势,以及期刊面临的新要求。他认为此次会议在凝聚共识、守正创新等方面发挥了重要作用。期望学会期刊在今后能够继续坚持不懈,持续打造高水平期刊,为会员提供优质服务,为学科前沿的探索提供支撑,为学会可持续发展注入动力。

(工作总部)