

DOI:10.11918/202203093

基于机理与数据驱动的热连轧板凸度组合预测

陈楠¹,李旭¹,栾峰²,丁敬国¹,李影¹,张殿华¹

(1. 轧制技术及连轧自动化国家重点实验室(东北大学),沈阳 110819;2. 东北大学 计算机科学与工程学院,沈阳 110819)

摘要: 针对传统热连轧出口板凸度预测方法存在的模型精度低、解释性差等缺陷,提出了一种将机理与数据驱动相结合的热连轧板凸度组合预测模型。通过热连轧板凸度机理预测模型得到热连轧板凸度基准值,将该基准值与实际值之间的偏差量作为机器学习模型的预测变量,再将偏差量预测值与基准值进行求和得出组合预测模型的板凸度预测值,并将该组合预测策略应用至多个神经网络进行方法验证。研究结果表明,提出的热连轧板凸度组合预测模型相较于传统预测模型具有更好的预测性能,其中有97%以上预测数据的绝对误差小于0.02 mm,82%以上预测数据的绝对误差小于0.01 mm,同时该组合预测方法具有较好的可行性与普适性,所提出的模型能够实现机理模型与数据驱动模型的优势互补,使得模型更加符合实际物理意义,该组合模型既缓解了神经网络预测结果由于过程黑箱导致解释性差、可信度低的问题,又弥补了机理模型预测结果偏离生产工况、无法实时修正的缺陷,对热连轧板带钢的板形控制以及热连轧产品质量的改善具有重要意义。

关键词: 热连轧板凸度模型;组合预测;机理;数据驱动;偏差量

中图分类号: TG 335.56

文献标志码: A

文章编号: 0367-6234(2023)10-0074-08

Combined prediction of hot strip crowns of hot tandem rolling based on mechanism and data driving

CHEN Nan¹, LI Xu¹, LUAN Feng², DING Jingguo¹, LI Ying¹, ZHANG Dianhua¹

(1. State Key Laboratory of Rolling and Automation (Northeastern University), Shenyang 110819;

2. School of Computer Science and Engineering, Northeastern University, Shenyang 110819)

Abstract: To address defects of the traditional method for predicting the strip outlet crown of hot tandem rolling, which suffers from low accuracy and poor interpretability, a model for combined prediction of hot strip crowns based on mechanism and data driving is proposed. The strip crown reference value is obtained using the strip crown mechanism prediction model. The deviation between the reference value and the actual value is used as the prediction variable of machine learning models, and then the deviation prediction value and the reference value are summed to obtain the strip crown prediction value of the combined prediction model. This combined prediction strategy is verified using multiple neural networks. It is found that the proposed strip crown combined prediction model has better prediction performance than the traditional model, with over 97% of the predicted data having an absolute error of less than 0.02 mm and more than 82% of the predicted data showing an absolute error of less than 0.01 mm. Additionally, the model is both satisfactorily feasible and widely applicable. The proposed model integrates the relative strengths of the mechanism model and the data-driven model, resulting in a representation that is more closely aligned with the actual physical phenomena. The combined model not only alleviates the problems of poor interpretation and low reliability with the results from the black-box neural network prediction, but also compensates for the defects of the mechanism model, which often produces results that deviate from the production conditions and cannot be adjusted in real time. This proposed model makes a significant contribution to the shape control of hot strip and the improvement of hot strip product quality.

Keywords: strip crown model of hot tandem rolling; combined prediction; mechanism; data-driven; deviation

热轧带钢在整个工业体系中占据重要地位,其中板形是衡量其产品质量是否合格的一项重要指标,而有效控制板凸度可减少楔形等缺陷的出现,保

证良好的平直度^[1],确保带钢轧出板形良好,改善产品质量。传统控制手段一般将检测装置、数学模型、轧制制度、参数设定等因素有效结合,文献[2]

收稿日期: 2022-03-25;录用日期: 2022-06-16;网络首发日期: 2023-03-31

网络首发地址: <http://kns.cnki.net/kcms/detail/23.1235.T.20230331.1436.008.html>

基金项目: 国家自然科学基金(U20A20187);“兴辽英才计划”项目(XLYC2007087)

作者简介: 陈楠(1996—),男,硕士研究生;李旭(1981—),男,教授,博士生导师

通信作者: 李旭, fly2000lixu@163.com

考虑影响轧辊磨损的几个主要因素得出简单使用的磨损预报模型, 具有较高预报精度。文献[3]提出一种新的板凸度分配设定方法, 开发了计算板凸度调整 and CVC 工作辊横移设定的软件, 其结果优于现场设定结果。文献[4]建立了热轧带钢工作辊平均磨损的简易计算公式, 最大误差在 10% 左右。文献[5-6]根据工作辊磨损规律以及磨损轮廓曲线建立工作辊磨损预报模型, 以遗传算法优化参数, 使得模型精度可靠实用, 此外针对不均匀“猫耳”磨损轮廓现象, 提出了一种基于指数阻尼正弦函数的 VSS 换挡策略, 降低局部“猫耳”轮廓值, 提高凸度高精度率。文献[7]提出了一种引入磨损速率修正系数的轧辊磨损预报模型的改进方法, 并对模型参数进行优化, 提高了轧辊磨损预报精度。文献[8]提出一种适用于 1 250 mm 热连轧工作辊磨损的控制策略, 减小工作辊磨损量, 且磨损更均匀, 延长工作辊寿命。但实际轧制过程具有强耦合、多变量、非线性、时变性等特点, 其内在机理十分复杂, 存在不确定的未知因素, 很难获得精准的数学模型, 也难以通过有限元法进行精准表述, 板形控制技术的发展出现了瓶颈。

由于神经网络自身的非线性以及自适应信息处理能力, 诸多研究人员已成功应用机器学习来解决轧制领域问题, 例如: 文献[9]将人工神经网络与遗传算法相结合, 选择最佳工艺参数, 获得良好平直度。文献[10]使用最小二乘支持向量机和偏差更新的热轧机软传感器设计, 使用带有偏差更新项的软传感器准确地对整个过程进行建模。文献[11]以有限元计算值为训练样本, 采用改进的快速 BP 训练算法, 提高训练速度, 加快网络收敛速度。文献[12]将 GA-PIDNN 控制器用于有效控制板凸度的缺陷, 快速跟踪板凸度的目标值, 提高控制精度, 实现良好控制。文献[13]提出了一种基于 KNN 回归算法的轧制力预测模型, 该法在训练时间和训练精度方面均优于线性回归算法。文献[14]提出一种采用 DE 算法优化 SVR 的凸度预测模型, 相较 GA-SVR 模型在提高精度的同时明显减少训练时间。文献[15]建立了基于随机森林集成方法的宽厚板板凸度预测模型, 利用 PCA 与聚类方法处理数据并提出基于关联规则的关键工艺参数调控策略, 经仿真分析, 该方法可较好地控制板凸度。

本文立足于热连轧现场轧制过程中多积累的大量工业数据, 基于现场数据的深度挖掘, 将现有的板凸度机理预测模型与数据驱动模型相结合进而构建热连轧出口板凸度组合预测模型, 对热连轧出口板凸度预测模型进行性能指标分析, 评估该方法的应

用性与可行性, 从而达到提高板凸度预测精度的目的。

1 热连轧板凸度机理预测模型

热轧板带钢凸度取决于有载辊缝形状, 在轧制过程中, 其受到多方面因素的影响, 主要包括使辊系弯曲变形的轧制力和弯辊力、改变轧辊辊型的轧辊热变形和轧辊磨损变形等。因此可由以下方程^[16]进行描述:

$$C = \frac{P}{K_p} + \frac{F}{K_f} + E_c \omega_c + E_\Sigma (\omega_H + \omega_W + \omega_0) + E_0 \Delta \quad (1)$$

式中: C 为热轧板带钢凸度; P 、 F 分别为使辊系发生弯曲变形的轧制力和弯辊力; K_p 、 K_f 分别为轧机轧制力横向刚度、弯辊力横向刚度; ω_c 为可控辊型辊凸度, 根据具体采用的技术 (如 PC、CVC 等) 来确定; ω_H 为由轧辊热膨胀导致的轧辊热凸度; ω_W 为由轧辊磨损导致的轧辊磨损凸度; ω_0 为轧辊初始辊凸度; Δ 为入口带钢凸度; E_0 、 E_c 、 E_Σ 为相应系数。

结合实际生产现场对板凸度模型进行简化, 简化后机理预测模型 (mechanism prediction model, MPM) 表达式如下:

$$C = k_1 P + k_2 F + k_3 (\omega_H + \omega_W) + k_4 \quad (2)$$

其中轧辊热凸度及磨损凸度通过计算求得, 轧制力、弯辊力则通过实际轧制现场提取。相关系数从实际生产现场所得, 见表 1。

表 1 机理预测模型系数
Tab. 1 Coefficients of the MPM

k_1	k_2	k_3	k_4
1.244×10^{-5}	-2.172×10^{-5}	0.003 61	-0.036 4

综上, 热连轧出口板凸度的机理预测模型表达式为

$$C = 1.244 \times 10^{-5} \cdot P - 2.172 \times 10^{-5} \cdot F + 0.003\ 61 (\omega_H + \omega_W) - 0.036\ 4 \quad (3)$$

在轧制过程中, 由于轧辊内部存在的不均匀温度场而产生不均匀热膨胀, 轧辊热膨胀导致的轧辊热变形会影响板带钢的板凸度, 轧辊热凸度通过以下公式^[17]进行求解:

$$\omega_H = 2(1 + \nu) \frac{\beta_i}{R} \int_0^R r [T(r, z) - T_0(r, z)] dr \quad (4)$$

$$\beta_i = \frac{\Delta L}{L \cdot \Delta T} \quad (5)$$

式中: β_i 为轧辊的热膨胀系数; ν 为轧辊的泊松系数; $T(r, z)$ 为坐标位于 (r, z) 处的温度; $T_0(r, z)$ 为轧辊初始温度; ΔL 为带钢在温度变化为 ΔT 时的热膨胀量; L 为膨胀前的长度。

在实际热轧生产过程中, 轧辊和轧件的热量传递、温度分布较为复杂且不易精确定, 为了使模型

简化处理,近似将轧辊温度看作均匀分布,因此轧辊热凸度表达式如下:

$$w_n = (1 + \nu)\beta_i \cdot R \cdot \Delta T \tag{6}$$

随着热连轧过程的不断进行,轧制长度不断累加,轧辊磨损也处于一个变化与积累的过程,加速轧辊磨损程度,直接影响着带钢板凸度。但轧辊磨损很难从机理上推导出精准公式,通常采用现场经验来建立模型,经由下述轧辊磨损量的经验公式^[18]进行求解:

$$w_n = k \sum P_{in} \cdot l_{in} (1 + \alpha X^4) / w \tag{7}$$

$$l_{in} = \frac{L_n \times B_n \times H_n}{b_{in} \times h_{in}} \tag{8}$$

式中: w_n 为轧辊磨损量; P_{in} 为第 n 架轧机轧第 i 卷钢时的轧制力; w 为带钢宽度; l_{in} 为第 n 架轧机轧第 i 卷钢时的轧制长度; k 为与轧辊材质和带钢材质有关的系数,根据实际生产现场选定 $k = 0.001\ 3$; α 为轧辊磨损系数,与轧制带钢长度、轧制力、轧辊材质有关,可在 $[0.000\ 4, 0.006]$ 区间内进行人工设定,选定 $\alpha = 0.006$; l_{in} 、 b_{in} 、 h_{in} 分别为第 n 架轧机轧第 i

卷钢时的轧后长度、宽度、厚度; L_n 、 B_n 、 H_n 分别为带钢轧前长度、宽度、厚度。

当 $X = 0$ 时,对应带钢中心线处,此时, $w_0 = k \sum P_{in} \cdot l_{in} / w$; 当 $X = \pm 1$ 时,对应带钢边部,此时, $w_1 = k \sum P_{in} \cdot l_{in} (1 + \alpha) / w$ 。

轧辊磨损凸度表示为

$$\omega_w = w_0 - w_1 = -0.001\ 3\alpha \sum P_{in} \cdot l_{in} / w \tag{9}$$

2 热连轧板凸度数据驱动模型

2.1 生产数据的采集与预处理

以国内某钢铁企业 1 100 mm 热连轧生产线为本文背景,该生产线能够生产常见钢种的带钢,并配备相对应的测量设备。将实际热连轧现场的生产数据存入轧制过程数据库,对历史数据做适当预处理用于训练数据驱动模型并保存,再将当前数据输入训练好的模型并进行板凸度预测,将预测结果储存板凸度预测数据库中并用于现场生产。预测过程见图 1。




图 1 热连轧出口板凸度预测过程

Fig. 1 Strip outlet crown prediction process for hot tandem rolling


综合考虑板凸度机理以及实际生产现场,板凸度受多方面因素的影响,主要与轧制过程中的轧辊、带钢尺寸以及轧制条件有关,轧辊状态主要包括轧辊温度、表面状况、轧辊热膨胀以及轧辊磨损等方面,对辊缝产生影响进而影响热连轧板凸度的变化;带钢尺寸主要包括带钢厚度、宽度以及材质等物理特性,通过影响轧制力和轧机弹跳进而影响热连轧板凸度;轧制条件主要包括轧制力、弯辊力、轧制速度、轧制温度等方面,其中轧制温度会影响带钢变形抗力进而改变轧制力能参数导致热连轧板凸度的变化,而轧制速度会直接影响轧制力与辊缝使热连轧

板凸度产生影响。根据轧制过程中的实测数据与过程自动化级的计算数据,为使得最终训练后模型的鲁棒性强且泛化性好,选取了 10 种影响因素作为板凸度预测的输入变量,影响因素的描述见表 2,其中以轧辊热膨胀量与轧辊轧制长度反映轧辊热凸度与磨损凸度的变化规律进而反映轧辊状态,以带钢厚度、宽度、变形抗力反映带钢尺寸状态,以轧制力、弯辊力、轧件入口温度和出口温度、轧件速度反映轧制条件。并从该厂采集八机架连轧板带钢的在线数据,分析热连轧生产线相应的 PDA 数据,并提取数据共计 1 797 组。


表 2 热连轧出口板凸度的影响因素

序号	变量名称	数据类别	单位
1	轧机轧制力	实测数据 (F1 ~ F8)	kN
2	轧件出口厚度	计算数据 (F1 ~ F7)、实测数据 (F8)	mm
3	轧件入口温度	实测数据 (F1)	℃
4	轧件出口速度	实测数据 (F1 ~ F8)	m/s
5	轧辊热膨胀量	计算数据 (F8)	mm
6	轧机弯辊力	实测数据 (F1 ~ F8)	kN
7	轧件出口宽度	实测数据 (F8)	mm
8	轧件出口温度	实测数据 (F8)	℃
9	轧机轧制长度	计算数据 (F1 ~ F8)	m
10	轧件变形抗力	计算数据 (F1 ~ F8)	kPa

以热连轧板凸度的影响因素中的轧机轧制力、轧机弯辊力、轧件出口厚度以及轧件出口宽度为例构建数据三维可视化图像。在图 2 中,数据的可视化图像显示了影响热连轧出口板凸度的变量的分布,其呈现出无序化分布,由此可得,数据量大的同时也具有明显的无序性与分散性,可部分证明在实际生产中使用数据集开发的模型具有较强的鲁棒性。



(a)轧制力、弯辊力对应板凸度数据三维可视化分布图



(b)出口厚度、出口宽度对应板凸度数据三维可视化分布图

图 2 数据三维可视化

Fig. 2 Three-dimensional visualization of data

由于实际热连轧生产过程中所得到的原始数据大多可能包含少量会产生误导性预测的噪声和异常值,因而为保证所采用的数据集具有客观性与真实性,在模型建立与预测时能够获得可靠的分析结果,必须在使用数据之前先对其进行预处理。

采用 PauTa 准则去除异常值、离散点,为了求取 99% 置信区间,设置置信区间上限为 $\bar{y} + 3S_y$,设置置信区间下限为 $\bar{y} - 3S_y$,将绝对偏差超过限制的数据点视作异常值并移除,采用的 PauTa 准则表示如下:

$$|y_i - \bar{y}| > 3S_y \tag{10}$$

$$\bar{y} = \frac{1}{L} \sum_{i=1}^L y_i \tag{11}$$

$$S_y = \sqrt{\frac{1}{L} \sum_{i=1}^L (y_i - \bar{y})^2} \tag{12}$$

式中 $\bar{y}$ 为 y_i 的平均值, S_y 为样品的标准偏差值。基于 PauTa 准则的数据异常值处理见图 3,共计删除了 16 组数据,用于消除数据噪音。




图 3 基于 PauTa 准则去除异常值

Fig. 3 Removing outliers based on PauTa criterion

同时,不同的评价指标往往具有不同的维度,为了消除维度带来的影响,需要对处理后的数据集进行标准化处理。本文通过 Min-Max 归一化的方法将数据的平面分布扩展为类圆形分布,即为将数据进行线性变换,使得结果映射为 0 和 1 之间的值,以便消除数据量级之间的差异,公式如下:

$$y'_i = \frac{y_i - y_{\min}}{y_{\max} - y_{\min}} \tag{13}$$

式中: y'_i 为归一化后的数据, y_i 为原始数据, $y_{\min}$ 为数据集中最小的数据, $y_{\max}$ 为数据集中最大的数据。

再选取其中 70% (约 1 247 块) 作为训练集,用于训练网络并调整网络的参数,选取其中的 30% (约 535 块) 作为测试集,用于测试训练后的神经网络对热连轧板凸度预测的性能,测试模型的准确性。部分试验数据见表 3。

表 3 部分实验数据
Tab.3 Part of experimental data

样本序号	轧制力 F1/kN	弯辊力 F1/kN	入口温度 F1/℃	出口温度 F8/℃	轧制公里数 F1/m	...	板凸度/mm
1	7 876.85	357.01	1 009.48	910.97	66.869	...	0.021
2	7 978.55	345.73	1 017.87	875.80	133.779	...	0.012
3	8 210.33	340.48	1 017.07	873.38	201.271	...	0.022
4	8 891.07	361.45	1 014.42	871.77	271.021	...	0.014
5	9 072.67	362.86	1 006.02	877.81	340.900	...	0.012
⋮	⋮	⋮	⋮	⋮	⋮		⋮
1 781	10 308.17	402.44	974.10	848.51	4 090.849	...	-0.010

2.2 数据驱动模型

深度神经网络 (deep neural networks, DNN) 又名多层感知机 (multi-layer perception, MLP), 从 DNN 按照不同层级的位置划分, 其内部的层级可以分为输入层、隐含层以及输出层。图 4 为 DNN 的结构图, 由图 4 可知, 在神经网络中, 各个层级之间是全连接的, 即任意一层中的任意一个神经元皆与前后两层的神经元相连接。不同于单隐层神经网络, DNN 增加了隐层数量, 因此 DNN 通过深层结构能够从训练数据中学习一些复杂的非线性关系, 从而实现对复杂数据分布的逼近, 进而解决复杂问题。模型所采用的隐含层结构为 “50-50-50”。选 Sigmoid 激活函数, 采用均方差来度量损失, 在确定损失函数后, 选用 Lookahead 优化器算法^[19] 来更新和计算影响模型训练和模型输出的网络参数, 选择不等间隔退火策略的余弦退火算法^[20] 来调节模型学习率。




图 4 深度神经网络 DNN 结构
Fig. 4 Structure of DNN

随机配置网络 (stochastic configuration network, SCN)^[21] 具有对回归和分类分析的强大功能。图 5 为 DNN 的结构图。传统上, 正确确定神经网络的适当架构是非常具有挑战性的, 以便培训的模型可以实现学习和泛化的优异性能。与单隐式层前馈神经

网络的已知随机学习算法相比, SCN 随机分配隐藏的输入权重和偏差在监督机制中的节点。由于隐藏层中的参数在均匀分布中随机产生, 因此假设有最佳的随机性。SCN 中权重和偏差的随机化值是在序列 $\text{Lambdas} = [0.5, 1, 5, 10, 30, 50, 100, 150, 200, 250]$ 对应的 $[-\lambda, \lambda]$ 的范围内选择的, 该扩展范围设置允许更大的范围, 可以找到满足不等式约束的合适权重和偏差。此外, 设置收缩因子为 $[0.9, 0.99, 0.999, 0.9999, 0.99999, 0.999999]$ 。针对每个已知候选项的不等式约束进行测试的随机值池大小为 250, 迭代节点的最大数量选择为 150。




图 5 随机配置网络 SCN 结构
Fig. 5 Structure of SCN

2.3 热连轧板凸度组合预测模型

在传统热连轧出口板凸度的预测过程中, 直接将板带钢凸度作为神经网络的输出值, 仅依靠神经网络进行参数预测, 其预测产生的误差范围较大, 模型的预测精度降低, 且与实际物理原理贴合度不够, 可说服力、解释性低, 因此提出一种将机理与神经网

络模型相结合的热连轧出口板凸度组合预测模型,以求得的机理预测模型计算值设定为热连轧出口板凸度的基准值,该基准值与实际值的数量级接近,而二者间偏差的波动范围相比之下较小,由此向模型中引入偏差量的概念,即热连轧出口板凸度基准值与生产线实测数据的差值,以热连轧出口板凸度偏差量作为神经网络模型的输出变量进行预测,再将偏差量预测值与基准值相加得到组合预测模型的板凸度预测值,以此对传统热连轧出口板凸度预测模型进行修正,具体预测过程见图 6。

误差 S_{SMAPE} 以及相关系数 R ,对比评估预测结果,表达如下所示:

$$M_{\text{MSE}} = \frac{1}{n} \sum_{i=1}^n (y_i - y'_i)^2 \tag{14}$$

$$R_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - y'_i)^2} \tag{15}$$

$$M_{\text{MAE}} = \frac{1}{n} \sum_{i=1}^n |y_i - y'_i| \tag{16}$$

$$S_{\text{SMAPE}} = \frac{100\%}{n} \sum_{i=1}^n \frac{|y_i - y'_i|}{(|y_i| + |y'_i|)/2} \tag{17}$$

$$R = \sqrt{1 - \frac{\sum_{i=1}^n (y_i - y'_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}} \tag{18}$$

分析模型的预测指标,基于 DNN 的组合预测前后的预测结果见图 7,基于 SCN 的组合预测前后的预测结果见图 8,数据点清晰、规则地分布,可以看出相比于传统的数据驱动模型,数据驱动与机理相结合引入偏差量这一概念后,数据分布更集中于对角线,误差更小,性能更好。基于 DNN 的热连轧出口板凸度组合预测模型的预测性能见图 9,基于 SCN 的热连轧出口板凸度组合预测模型的预测性能见图 10,通过不同颜色标识对绝对误差进行分级;当颜色由黑色到灰色,绝对误差从 0 增加到 0.02 mm,当颜色为白色时,则表示绝对误差超过 0.02 mm,对于更高的生产要求,测量值和目标冠之间的绝对误差预计 <0.02 mm,甚至 <0.01 mm。对于基于 DNN 的热连轧出口板凸度组合预测模型,有 97.96% 的预测数据绝对误差 <0.02 mm,有 82.59% 的预测数据绝对误差 <0.01 mm。对于基于 SCN 的热连轧出口板凸度组合预测模型,有 99.07% 的预测数据绝对误差 <0.02 mm,有 85.19% 的预测数据绝对误差 <0.01 mm,符合实际生产要求。




图 6 组合预测模型原理

Fig. 6 Workflow of combined prediction model

在建立热连轧出口板凸度组合预测模型后,对热连轧出口板凸度的偏差量进行预测,再将该偏差量的预测值与热连轧出口板凸度的基准值进行求和,得到机理与数据驱动模型结合后的热连轧出口板凸度组合预测模型的预测值。

3 效果分析及验证

通过将数据导入本文提出的热连轧板凸度组合预测模型,经由性能指标均方误差 M_{MSE} 、平均绝对误差 M_{MAE} 、均方根误差 R_{RMSE} 、对称平均绝对百分比




图 7 基于 DNN 的组合预测前后预测结果对比

Fig. 7 Comparison of prediction results before and after combined prediction based on DNN




图 8 基于 SCN 的组合预测前后预测结果对比

Fig. 8 Comparison of prediction results before and after combined prediction based on SCN




图 9 基于 DNN 的组合预测模型预测性能

Fig. 9 Prediction performance of combined prediction model based on DNN

由图 11 及表 4 可以看出,相比于直接预测板凸度、直接采用数学模型预测板凸度的这两类模型,以引入偏差量的方式进行数据驱动与机理相结合所建立的基于 DNN 的组合预测模型的 M_{MAE} 、 S_{SMAPE} 和 R_{RMSE} 等误差指标的值显著降低, M_{MAE} 、 S_{SMAPE} 和 R_{RMSE} 值分别为 0.004 7 mm、53.25% 和 0.006 2 mm。充分证明了所提出的以偏差量的形式进行数据驱动与机理

相结合后的热连轧出口板凸度模型对提高板凸度预测精度具有有效性。分别采用 DNN 与 SCN 对该组合预测方法进行建模,对比组合预测前后的误差指标,对于上述 2 个网络该组合预测模型精度均优于直接预测板凸度的模型,部分证明了该方式具有可行性与普适性,同时更贴合于实际物理过程。




图 10 基于 SCN 的组合预测模型预测性能

Fig. 10 Prediction performance of combined prediction model based on SCN




图 11 板凸度预测误差直方图

Fig. 11 Strip crown prediction error histogram

表 4 预测模型误差指标

Tab. 4 Error indexes of proposed models

序号	模型类型	M_{MSE}/mm	R_{RMSE}/mm	M_{MAE}/mm	$S_{SMAPE}/\%$	R
1	数据驱动模型 (DNN)	3.59×10^{-4}	0.018 9	0.015 0	71.19	0.873
2	数据驱动模型 (SCN)	7.89×10^{-5}	0.008 9	0.006 6	66.73	0.871
3	机理预测模型 (MPM)	5.51×10^{-5}	0.007 4	0.005 7	68.25	0.909
4	机理 + 数据驱动模型 (DNN + MPM)	9.81×10^{-6}	0.006 2	0.004 7	53.25	0.940
5	机理 + 数据驱动模型 (SCN + MPM)	4.77×10^{-5}	0.006 9	0.005 3	60.22	0.922

4 结 论

1) 热连轧板凸度机理与数据驱动组合预测模型通过神经网络对偏差量进行了修正,使预测误差进一步降低,其中有 97% 以上预测数据的绝对误差 < 0.02 mm,有 82% 以上预测数据的绝对误差 < 0.01 mm。

2) 将基于 DNN 的热连轧板凸度组合预测策略应用至 SCN,结果表明,基于 SCN 的组合预测模型精度比传统 SCN 模型的 S_{SMAPE} 降低了 6.51%, R 提高了 5.94%,证明了本文所提出的组合策略具有有效性以及普适性。

3) 热连轧板凸度机理与数据驱动组合预测模型有效改善了传统机理模型难以准确求解、传统数据驱动模型学习特征不完全等缺点,在提高模型预测精度的同时也使其更加符合实际物理意义。

参考文献

[1] 刘宏民, 贾春玉, 单修迎. 智能方法在板形控制中的应用[J]. 燕山大学学报, 2010, 34(1): 1
LIU Hongmin, JIA Chunyu, SHAN xiuying. Application of intelligent method in shape control [J]. Journal of Yanshan University, 2010, 34(1): 1

[2] 何安瑞, 张清东, 曹建国, 等. 热轧精轧机组工作辊磨损分析及预报[J]. 冶金设备, 1999(3): 25
HE Anrui, ZHANG Qingdong, CAO Jianguo, et al. Wear analysis and prediction of work roll of hot rolling finishing mill [J]. Metallurgical Equipment, 1999(3): 25

[3] 刘立忠, 吕程, 刘相华, 等. CVC 热连轧机的板凸度计算模型[J]. 东北大学学报(自然科学版), 2001(1): 95
LIU Lizhong, LÜ Cheng, LIU Xianghua, et al. Calculation model of plate crown of CVC hot tandem mill [J]. Journal of Northeast University (Natural Science), 2001(1): 95

[4] CASTANEDA R S, GUILLEN F E, GONZALEZ R T, et al. Development of simple equation for calculating average wear of hot strip mill work rolls[J]. Ironmaking and Steelmaking, 2014, 41(5): 369. DOI: 10.1179/1743281213Y.0000000162

[5] 曹建国, 张杰, 甘健斌, 等. 无取向硅钢热轧工作辊磨损预报模型[J]. 北京科技大学学报, 2006(3): 286
CAO Jianguo, ZHANG Jie, GAN Jianbin, et al. Wear prediction model of non-oriented silicon steel hot rolling work roll[J]. Journal of Beijing University of Science and Technology, 2006(3): 286. DOI:10.13374/j. issn1001-053x.2006.03.018

[6] CAO Jianguo, XIONG Haitao, HUANG Xiaohai, et al. Work roll shifting strategy of uneven “cat ear” wear control for profile and flatness of electrical steel in schedule-free rolling[J]. Steel Research International, 2020, 91(9): 1

[7] 张长利, 王秋娜, 朱鹤鸣, 等. 1 580 mm 热轧轧辊磨损预报模型的优化[J]. 轧钢, 2016, 33(4): 27
ZHANG Changli, WANG Qiuna, ZHU Heming, et al. Optimization of 1 580 mm roll wear prediction model of hot rolling [J]. Steel Rolling, 2016, 33(4): 27. DOI:10.13228/j. boyuan. issn1003-9996.20150150

[8] 王四海, 翟德家, 刘立辉, 等. 1 250 mm 热连轧工作辊磨损控制策略[J]. 钢铁, 2020, 55(9): 57
WANG Sihai, ZHAI Dejia, LIU Lihui, et al. Wear control strategy of work roll in 1 250 mm hot continuous rolling[J]. Iron and Steel, 2020, 55(9): 57. DOI:10.13228/j. boyuan. issn0449-749x.20200017

[9] JOHN S, SIKDAR S, SWAMY P K, et al. Hybrid neural-GA model to predict and minimise flatness value of hot rolled strips[J]. Journal of Materials Processing Technology, 2008, 195(1/2/3): 314

[10] SHARDT A W, MEHRKANOON S, ZHANG Kai, et al. Modelling the strip thickness in hot steel rolling mills using least-squares support vector machines [J]. The Canadian Journal of Chemical Engineering, 2017, 96(1): 171

[11] 杜凤山, 薛涛, 王超, 等. 基于 FEM-ANN 的冷轧板带板凸度预报[J]. 钢铁, 2013, 48(8): 40
DU Fengshan, XUE Tao, WANG Chao, et al. Prediction of cold rolled strip crown based on FEM-ANN[J]. Iron and Steel, 2013, 48(8): 40. DOI:10.13228/j. boyuan. issn0449-749x.2013.08.004

[12] ZHANG Xiuling, XU Teng, ZHAO Liang, et al. Research on flatness intelligent control via GA-PIDNN[J]. Journal of Intelligent Manufacturing, 2015, 26(2): 359

[13] WANG Weiyuan, HUA Huo, ZHANG Baoshen. Prediction model of rolling force based on KNN[J]. International Core Journal of Engineering, 2020, 6(9): 158

[14] 刘元铭, 王振华, 王涛, 等. 热轧带钢出口凸度数据驱动建模及智能化预测分析[J]. 中国机械工程, 2020, 31(22): 2728
LIU Yuanming, WANG Zhenhua, WANG Tao, et al. Data-driven modeling and intelligent prediction analysis for hot strip outlet crowns[J]. China Mechanical Engineering, 2020, 31(22): 2728

[15] 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
CAO Jianguo, JIANG Jun, ZHAO Qiufang, et al. Convexity control of wide and thick plate based on data mining[J]. Journal of Central South University (Natural Science), 2019, 50(11): 2743

[16] 孙一康. 带钢热连轧的模型与控制[M]. 北京: 冶金工业出版社, 2002: 68
SUN Yikang. Model and control of hot strip continuous rolling[M]. Beijing: Metallurgical Industry Press, 2002: 68

[17] 董志奎. 热轧带钢板凸度和板形在线控制模型及应用研究[D]. 秦皇岛: 燕山大学, 2011: 27
DONG Zhikui. Study on models and application of strip crown and shape online control for hot strip mill[D]. Qinhuangdao: Yanshan University, 2011: 27

[18] 朱从波. 热轧板型控制[D]. 武汉: 武汉理工大学, 2003: 10
ZHU Congbo. Control profiles of hot rolling[D]. Wuhan: Wuhan University of Technology, 2003: 10

[19] RUDER S. An overview of gradient descent optimization algorithms [Z/OL]. (2017-06-15) [2021-09-15]. <http://arxiv.org/abs/1609.04747v2>

[20] LOSHCHILOV I, HUTTER F. SGDR: Stochastic gradient descent with warm restarts[Z/OL]. (2017-05-03) [2021-09-03]. <http://arxiv.org/abs/1608.03983v5>

[21] WANG Dianhui, LI Ming. Stochastic configuration networks: Fundamentals and algorithms [J]. IEEE Transactions on Cybernetics, 2017, 47(10): 3466