基于AGA-BO优化的数据驱动连退机组焊接焊缝厚度预测

王 卓[1] 王智璇[1] 王 浩[1] 张 冀[1] 李学通[1,2] 白振华[1,3*]
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.燕山大学亚稳材料科学与技术国家重点实验室,秦皇岛,066004
3.燕山大学深圳研究院,深圳,518000

摘要:针对传统数学模型在实现焊缝厚度预测的普适性方面存在的固有局限性,提出一种数据驱动的连退机组焊接焊缝厚度预测方法。创新性地引入自适应遗传算法(AGA)与贝叶斯优化(BO)相结合的改进优化策略AGA-BO,利用AGA的全局探索与BO的局部精炼对超参数组合进行交替寻优,并协同五折交叉验证构建了一个融合超参数寻优的回归预测架构。利用6321条有效数据,对比了类别梯度提升(CatBoost)和轻量级梯度提升机(LightGBM)等回归算法在该架构下的焊缝厚度预测性能。研究结果表明,CatBoost预测性能表现最优异。此外,结合该架构的LightGBM在预测精度和效率上表现出综合最优,其训练效率是CatBoost时的6~7倍,平均预测精度高达97%以上,相较于传统物理模型提高了9.35%。将预测模型应用于生产现场,模型预测误差波动范围绝大部分在±5%内,有效提高了焊缝厚度预测的准确性和稳定性。

关键词:数据驱动;连退机组;焊接;焊缝厚度;回归预测算法
中图分类号:TG44
DOI:10.3969/j.issn.1004-132X.2026.11.024 **开放科学(资源服务)标识码(OSID)**:

Data-driven Prediction of Welded Seam Thickness in Continuous Annealing Lines Based on AGA-BO Optimization

WANG Zhuo[1] WANG Zhixuan[1] WANG Hao[1] ZHANG Ji[1] LI Xuetong[1,2] BAI Zhenhua[1,3*]
1.National Engineering Research Center for Equipment and Technology of Cold Strip Rolling, Yanshan University, Qinhuangdao, Hebei, 066004
2.State Key Laboratory of Metastable Materials Science and Technology, Yanshan University, Qinhuangdao, Hebei, 066004
3.Shenzhen Research Institute, Yanshan University, Shenzhen, Guangdong, 518000

Abstract: To overcome the limit univerality of traditional mathematical models in welded seam thickness prediction, a data-driven methodology was proposed for predicting welded seam thickness in continuous annealing line(CAL) welding processes. An improved optimization strategy AGA-BO combining an adaptive genetic algorithm(AGA) and Bayesian optimization(BO) was introduced innovatively. The global exploration capabilities of the AGA and the local refinement strengths of BO were synergistically leveraged for the alternating optimization of hyperparameter combinations. Concurrently, a five-fold cross-validation scheme was integrated to construct a robust regression prediction architecture that incorporating the hyperparameter optimization. A filtered dataset was utilized by comprising 6321 valid entries, the welded seam thickness's prediction performance of various regression algorithms, including categorical boosting(CatBoost) and light gradient boosting machine(LightGBM), was experimentally evaluated under the proposed architecture. The results indicate that CatBoost achieves the best prediction performance. Furthermore, the LightGBM integrated with this architecture demonstrates the best overall balance between prediction accuracy and efficiency, with training efficiency 6~7 times that of CatBoost, and the average prediction accuracy above 97%, which is 9.35% higher than that of traditional physical models. Upon deployment of the prediction model in the production field, the fluctuation range of prediction errors is pre-

收稿日期:2025-07-21
基金项目:河北省自然科学基金重点项目(E2024203125);河北省数字产业创新发展专项(252F0303D);河北省创新应用场景专项(252Q0303D);唐山市科技计划(24140203C)

dominantly within ±5%, which effectively enhanced the accuracy and stability of welded seam thickness prediction.

Key words: data-driven; continuous annealing line; welding; welded seam thickness; regression prediction algorithm

0　引言

连退工艺是现代钢铁工业生产高性能冷轧带钢不可或缺的技术，其精细化控制水平直接决定了最终产品的质量和市场竞争力[1-4]。为确保生产效率和产品质量，连退机组借助焊机进行头尾焊接，从而连续不间断地工作。在焊接过程中，焊缝厚度是焊缝质量控制的一个关键参数，它不仅对抑制焊缝印等缺陷至关重要，还对确保板材的稳定通过和防止断带具有举足轻重的影响[5-7]。焊缝厚度过小会导致强度不足，进而引发断带；若焊缝厚度超出规定标准，则同样会被判定为不合格。由此可知，焊缝厚度控制一直是现场技术人员关注的焦点。以往学者对焊接工艺的研究主要集中在焊接电流、焊接热量和焊接原理等方面。刘亚星[8]在熔核所需热量模型的基础上建立了焊接工艺与带钢质量的综合优化控制技术。张宝平等[9]针对某连退机组电阻搭接焊所存在的虚焊与过烧等焊接质量问题提出了相应的优化与改进措施。朱爱辉等[10]介绍了连续退火机组电阻焊机的设备构造、焊接流程、焊接原理等，并通过生产试验总结了合理的焊接工艺参数。龚辉[11]以东芝三菱电机工业系统(TMEIC)公司的窄搭接滚压焊接机为研究对象，分析了其焊接原理及相关工艺参数的控制方法。

目前有关连退带钢焊缝厚度的定量预测方面的研究仅停留在数学模型的构建，如李学通等[12]对焊缝厚度与搭接量、碾压轮压力、焊接电流、焊轮压力以及焊接速度等焊接工艺参数之间的关系进行了分析，建立了一套适合于连退焊接机组的焊缝厚度预测模型，给出了相应的模型特征参数计算方法。然而，建立传统的数学模型时往往具有较强的生产针对性，模型的待定系数需根据实际工况来确定，导致应用过程可能烦冗复杂。尽管机器学习模型本质上也是一种复杂的数学模型，但它在处理复杂非线性关系和大数据方面可展现出独特的优势。作为一种被广泛应用并得到有效验证的方法，机器学习已在各个领域替代或补充了传统的数学模型公式，成为解决回归问题和决策问题的主要手段[13-18]。因此，对于连退机组焊接焊缝厚度预测这类目标回归预测问题，利用机器学习方法通过从大量数据中学习内在规律，可以更灵活高效地构建预测模型。在钢铁行业的目标回归预测和优化算法应用方面，机器学习也已经有了一定的研究基础，证明它在钢铁行业的高效能力[19-21]。刘宏旭等[22]提出了一种基于深度学习算法的冷连轧带钢全长厚度连续预测模型，实现了从冷连轧工业生产数据到带钢全长厚度的映射。任鹏帆等[23]将修正的轧制力机理模型与遗传算法(GA)优化XGBoost参数相融合进而构建了高精度GA-XGBoost轧制力预测模型，该模型不仅考虑了轧制力的非线性问题，还将机理与数据相融合来实现轧制力的精准预测。贾瑞匣[24]构建了一种改进粒子群优化支持向量机(PSO-SVM)模型，该模型达到了更高精度的弯辊力预测精度。

综上，针对连退机组焊接焊缝厚度预测问题，本文的思路如下：分析连退机组焊机焊接核心过程，利用现有物理模型分析影响焊缝厚度的主要工艺参数，并结合回归预测的机器学习方法进行预测。基于此思路，本文首先构建了一个融合自适应遗传算法(AGA)与贝叶斯优化(BO)改进超参数寻优算法的回归预测架构，然后利用工业数据对比实验评估了多个模型的预测性能，最后讨论并验证了该架构与最优模型在实际生产线中应用的可行性。

1　连退机组焊机焊接核心过程

目前在连续退火机组上采用的焊接方法主要为窄搭接电阻焊，窄搭接电阻焊的焊缝处厚度通常超过母材厚度的10%～20%[25]。焊机的作用是将前后行带钢进行连接，以保证机组连续稳定地运行。如图1所示，焊接的原理是利用大电流(直流电流)通过上焊轮传到带钢再到下焊轮，对两带钢头尾加热熔融，最后经过碾压完成焊接。

2　数据采集与预处理

2.1　数据采集

焊缝厚度测量设备及测点位置如图2所示，焊缝厚度测量利用X射线，采用非接触式在线测厚的方法，设备型号为Thermo Scientific RM 100 CC，此板带测厚仪基于电离室的辐射检测器提供了优秀的测量稳定性和精度，有效地保证了测量

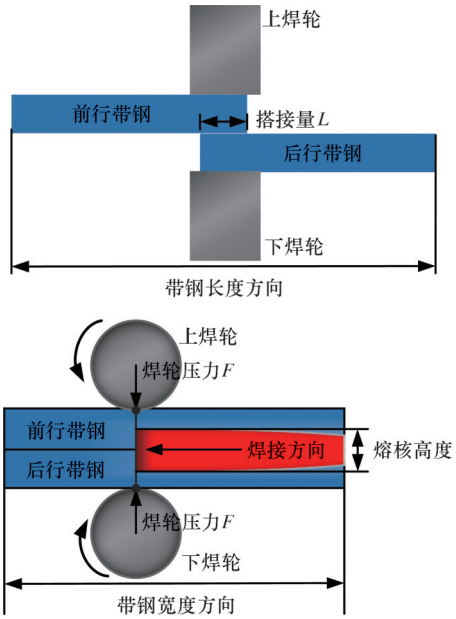
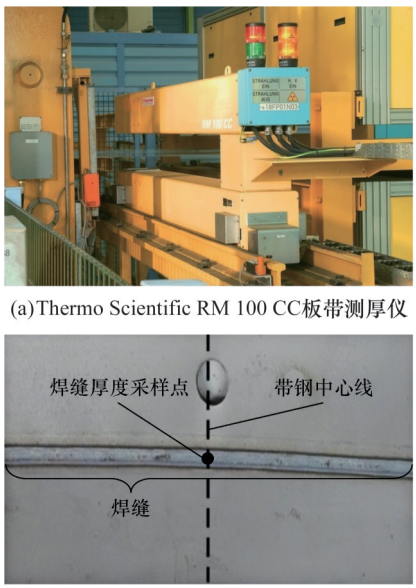


图1 焊接核心过程原理示意图

Fig.1 Schematic diagram of core welding process principle



(a)Thermo Scientific RM 100 CC板带测厚仪

(b)测点在焊缝处的位置

图2 焊缝厚度测量设备及测点位置

Fig.2 Welded seam thickness measurement equipment and measurement point location

数据的准确性。同时，基于某钢铁企业1550连退焊接机组产线布置的分布式传感器网络同步采集系统，以每次焊接的生产频率对参数数据进行获取。如表1所示，本研究持续跟踪采集了产线数据，包括焊接后中心线处焊缝厚度和焊接过程中对应的工艺参数，共计数据量为6870条。

2.2 特征筛选

在实际生产过程中，影响焊缝厚度的因素主要包括：①外部设备因素，主要指碾压轮的压力；②焊接过程参数，主要指有效焊接热量；③带钢基

表1 连退机组焊接过程参数

Tab.1 Welding process parameters for continuous annealing lines

机组	分类	序号	参数	单位
连退焊接机组	带钢属性参数	1	焊缝厚度H	mm
		2	搭接量L	mm
		3	前行带钢焊接碳当量C_{e1}	%
		4	后行带钢焊接碳当量C_{e2}	%
		5	前行带钢厚度h_1	mm
		6	后行带钢厚度h_2	mm
	焊接设备参数	7	碾压轮压力P	kN
	焊接过程参数	8	焊接电流I	kA
		9	焊接速度v	m/min
		10	焊轮压力F	kN

本参数，主要是搭接量参数。综合考虑上述因素对焊缝厚度的影响和原始数据采集中的各过程参数，选取前行带钢焊接碳当量C_{e1}、后行带钢焊接碳当量C_{e2}、前行带钢厚度h_1、后行带钢厚度h_2、碾压轮压力P、搭接量L、焊接电流I、焊接速度v和焊轮压力F作为特征参数。

为进一步验证特征筛选结果与焊缝厚度的相关性，在此采用斯皮尔曼相关系数对特征筛选结果与焊缝厚度之间的关系进行量化分析，以证明影响特征选择的准确性，其中斯皮尔曼相关系数的计算表达式如下：

$$\rho=1-\frac{6\sum d_i^2}{n(n^2-1)} \tag{1}$$

式中：ρ为斯皮尔曼相关系数；i为样本编号；d_i为第i次对秩次差；n为样本数量。

ρ的取值范围在$-1\sim1$之间，ρ值越接近1表示有越强的正相关关系，越接近-1表示有越强的负相关关系，接近0表示单调关系不明显。各参数具体相关性分析如图3所示，可以明显得到碾压轮压力P、搭接量L、焊接电流I、焊接速度v和焊轮压力F这些特征参数与焊缝厚度存在相对更强的正负相关性，而前行带钢焊接碳当量C_{e1}、后行带钢焊接碳当量C_{e2}、前行带钢厚度h_1、后行带钢厚度h_2与焊缝厚度的相关性均低于0.1，由此可见这些特征参数与焊缝厚度的相关性较弱，因此应在本轮特征参数筛选环节予以筛除。

2.3 数据预处理

在特征筛选的基础上，为避免后续输入模型的数据存在异常值，应当对采集到的数据进行预处理。首先将数据进行归一化处理，归一化处理后的所有数据点均处于[0,1]范围内，归一化处理的具体方法如下：

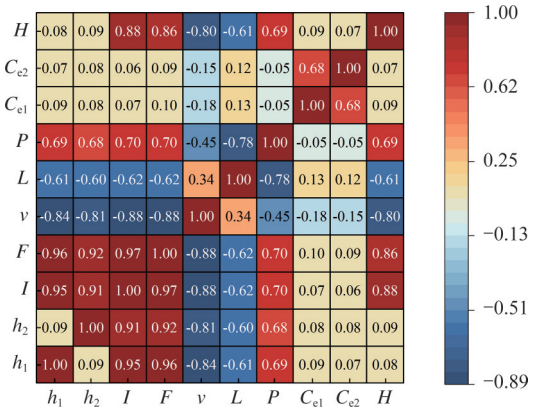


图3　焊接过程工艺参数与焊缝厚度之间的相关性

Fig.3　Correlation between welding process parameters and welded seam thickness

$$x_i'=\frac{x_i-x_{\min}}{x_{\max}-x_{\min}} \tag{2}$$

式中：x_i'为归一化后的数据点；x_i为实测的数据点；$x_{\max}$、$x_{\min}$分别为实测数据的最大点和最小点。

由于现场数据中可能存在噪声或振动干扰，以及所采集数据分布的不均匀性，本研究采用孤立森林算法对数据中异常点进行检测与处理。孤立森林算法是一种无监督的异常值检测方法。该算法通过随机选择特征与分割点构建二叉树结构，由于异常点路径长度较短，则异常点相较于正常点更易被隔离。异常分数$s(x_i',m)$的计算表达式如下：

$$s(x_i',m)=2^{-\frac{E(h(x_i'))}{c(m)}} \tag{3}$$

式中：$E(h(x_i'))$为路径长度的期望；$c(m)$为平均路径长度；m为特征筛选后的样本总数。

孤立森林算法的优化参数主要包括种子值和异常值比例。其中，异常值比例是关键参数之一，若设置过高，则可能导致正常值被误判；若设置过低，则可能无法有效隔离异常值。本文在0.02～0.12范围内调整异常值比例，以评估模型在不同参数下的性能。模型性能由模型的均方误差V_{MSE}(mean square error，MSE)、平均绝对误差V_{MAE}(mean absolute error，MAE)、均方根误差V_{RMSE}(root mean square error，RMSE)和决定系数R^2等指标进行评判，各指标具体公式如下：

$$\left.\begin{aligned}V_{\mathrm{MSE}}&=\frac{1}{m}\sum_{i=1}^{m}(x_i'-\hat{x}_i')^2\\V_{\mathrm{MAE}}&=\frac{1}{m}\sum_{i=1}^{m}|x_i'-\hat{x}_i'|\\V_{\mathrm{RMSE}}&=\sqrt{\frac{1}{m}\sum_{i=1}^{m}(x_i'-\hat{x}_i')^2}\\R^2&=1-\frac{\sum_{i=1}^{m}(x_i'-\hat{x}_i')^2}{\sum_{i=1}^{m}(x_i'-\overline{x'})^2}\end{aligned}\right\} \tag{4}$$

式中：x_i'为归一化后的第i个真实值；$\hat{x}_i'$为第i个归一化后的预测值；$\overline{x'}$为归一化后真实值的平均值。

图4所示的结果表明，当异常值比例为0.08时，模型的MSE、MAE、RMSE达到最小值，同时R^2取得最大值。因此，在本研究中将异常值比例设定为0.08，即筛选出8%的异常值时，模型表现出最优性能与最高精度。筛选完成后，最终累积得到6321条有效记录用于模型训练及验证。

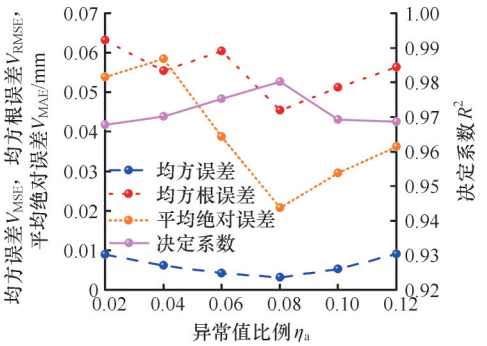


图4　异常值比例对模型性能的影响

Fig.4　Effect of abnormal value ratio on model performance

最后，为消除不同数据之间的尺度差异并提高模型的预测精度，将经异常值处理后的数据进行标准化处理，方法如下：

$$x_{i_\mathrm{s}}'=\frac{x_i'-\overline{x'}}{\sigma} \tag{5}$$

式中：x_{i_s}'为标准化后的数据点；σ为数据标准差。

3　连退机组焊接焊缝厚度预测架构

3.1　AGA-BO改进优化策略

自适应遗传算法-贝叶斯优化(AGA-BO)改进优化策略通过将AGA的全局探索能力与BO的局部精炼能力相结合，形成了一个高效且鲁棒性良好的超参数优化框架。相较于传统的固定参数遗传算法(GA)，AGA引入了自适应交叉概率和变异概率机制。这使得AGA在寻优初期能保持较高的多样性进行全局探索，而在接近最优解时能自动降低变异率以进行局部精细化，从而在全局探索阶段本身就具备了一定的局部收敛能力和效率。这种自适应性使得AGA能够更智能地引导BO进入更有希望的区域，减少BO的冷启动成本和探索范围。本文设计的AGA-BO交替机制并非简单的顺序执行，而是通过周期性地将AGA阶段发现的潜力范围作为BO的精细搜索范围来实现。这种机制允许BO在AGA已经初步探索过且更有潜力的区域进行深度挖掘，而不是从随机点开始。同时，AGA在每次BO迭代后，也会从BO的搜索结果中学习，调整其种群分

布，形成一种双向反馈和协同进化。这种混合方法不仅能够加速超参数的搜索过程，而且能够更有效地找到高质量的超参数组合，从而显著提高机器学习模型的性能和泛化能力。它在处理复杂、高维且计算成本昂贵的超参数优化问题时可展现出优于单一优化算法的性能。

每次AGA阶段结束后，自动将AGA的潜力解传递给BO并切换到BO阶段；BO阶段结束后，则进入下一个回合的AGA阶段。这种切换是周期性的，旨在确保全局探索和局部精细化的平衡。

AGA-BO改进优化迭代机制如表2所示，整个优化过程的总回合数设置为5个，以确保提供足够的迭代次数，使AGA和BO能够充分交替作用，既保证了对超参数空间的充分探索，又确保了对最优区域的深度挖掘。同时，此设置下目标函数通常能达到稳定收敛，继续增加回合数带来的性能提升并不明显，且会显著增加总计算时间。其中，AGA迭代次数设置为50，以确保AGA有足够的探索能力和种群多样性，同时30个种群个体足以在每次迭代中覆盖超参数空间的一个有代表性的样本，确保了一定的多样性，从而可有效开展全局探索；由于BO的每次评估成本较高，但其局部搜索效率很高，因此将BO迭代次数设置为15。这种设置可使AGA能快速定位到有潜力的区域，BO则在该区域进行高效的深度挖掘。在实际“交替寻优”中，监控每个回合中模型性能的提升情况。若在连续的几个回合中最优解的提升幅度非常小，且变化趋于平稳，则可以提前终止寻优过程，并认为模型已达到收敛。

表2 AGA-BO改进优化迭代机制

Tab.2 AGA-BO hybrid optimization iteration mechanism

迭代回合个数	AGA迭代次数	种群大小	BO迭代次数
5	50	30	15

3.2 连退机组焊接焊缝厚度预测架构建立

如图5所示，本研究所建立的连退机组焊接焊缝厚度的预测架构主要由如下三个部分组成：①数据的加载和特征的前处理；②对超参数进行AGA-BO改进迭代优化循环、五折交叉验证、优化目标函数计算以及目标模型的迭代和训练；③最优超参数组合下目标模型的训练和性能评估。所建立的架构能够提高模型的预测性能和泛化能力，只需要结合高效的回归类算法作为目标模型即可实现预测，应用不同的算法也会存在性能的差异。

在AGA-BO改进优化的每次迭代中，对当前

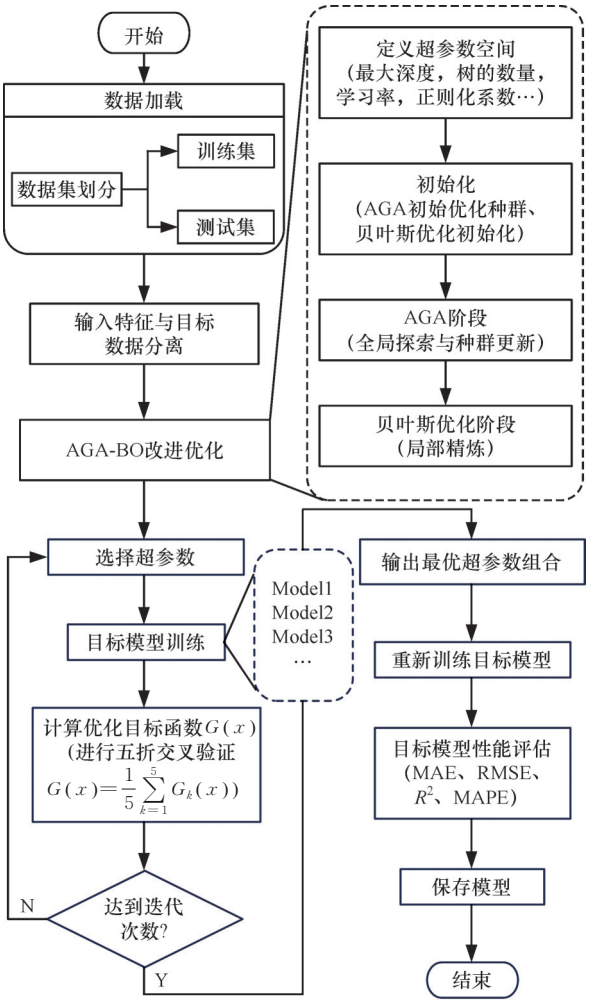


图5 连退机组焊接焊缝厚度预测架构

Fig.5 Prediction framework for welded seam thickness in continuous annealing lines

超参数组合执行五折交叉验证，即每次将数据划分为80%的子训练集和20%的子测试集，并重复此过程5次，以确保所有数据被覆盖。五折交叉验证避免了模型出现过拟合情况，可以有效提高模型评估的稳定性，更加接近模型的真实性能，其数据分配和验证流程如图6所示。

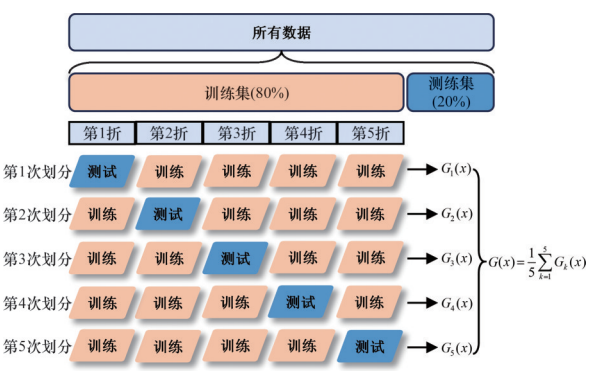


图6 五折交叉验证流程图

Fig.6 Five-fold cross validation process diagram

为筛选出最优的超参数组合，同时建立如下优化目标函数：

$$G(x)=\sqrt{\frac{1}{n'}\sum_{i=1}^{n'}(x_i''-\hat{x}_i'')^2} \tag{6}$$

式中：$G(x)$为优化目标函数；n'为异常值处理后的有效样本数；x_i''为目标真实值；$\hat{x}_i''$为模型预测值。

达到AGA-BO改进优化的迭代次数后，确定最优的超参数组合并输入到目标模型中重新训练，经对比得到性能最优的模型。为评价各个模型的性能，使用测试集对每个模型的预测值与实测值的MAE、RMSE、R^2和平均绝对百分比误差V_{MAPE}(mean absolute percentage error，MAPE)进行计算，其中MAPE的计算表达式如下：

$$V_{\mathrm{MAPE}}=\frac{1}{n'}\sum_{i=1}^{n'}\left|\frac{x_i''-\hat{x}_i''}{x_i''}\right| \tag{7}$$

最后保存模型并结束。

4　试验及结果分析

4.1　预测架构算法选择

以所建立的连退机组焊接焊缝厚度预测架构为基础，从多个回归预测问题的高效算法中选择最优的组合，包括自适应增强(adaptive boosting，AdaBoost)、极限梯度提升(extreme gradient boosting，XGBoost)、随机森林(random forest，RF)、类别梯度提升(categorical boosting，CatBoost)、多层感知机(multi-layer perceptron，MLP)和轻量级梯度提升机(light gradient boosting machine，LightGBM)，各个算法对应的部分超参数寻优范围如表3所示。

表3　各个算法部分超参数寻优范围

Tab.3　Optimization range of some hyperparameters of each algorithm

超参数	AdaBoost	XGBoost	RF	CatBoost	MLP	LightGBM
最大深度	1～10	1～10	1～20	4～10		3～15
树的数量	50～500	50～500	50～500	100～1000		50～500
学习率	0.01～1.00	0.01～1.00		0.01～0.30	10^{-4}～0.1	0.01～0.30
正则化系数		0.1～0.5			10^{-5}～0.1	0.1～1.0
子采样比例		0.5～1.0		0.6～1.0		0.6～1.0
特征子采样比例		0.5～1.0		0.6～1.0		0.6～1.0
叶子节点最小样本数			1～10	1～20		1～100
叶子L2正则化项系数		0.1～0.5		10^{-6}～10		0.1～1.0

将经过异常值处理与标准化后的6321条数据作为输入，各算法在该架构下的运行结果如图7所示。其中RMSE、MAE和MAPE的数值越接近于0说明误差越小，预测精度越高；R^2数值越接近于1说明模型的拟合性能越好，精度越高。从RMSE、MAE和MAPE指标来看，CatBoost的各误差值均最小，其次是LightGBM；从R^2指标来看，CatBoost、LightGBM两个算法依然表现出更优的性能，且CatBoost优于LightGBM。

同时，对图8所示的各算法模型预测绝对误差进行分析，可见所有模型均表现出良好的无偏性。然而，在误差的稳定性和对异常值的处理方面，AdaBoost等基于决策树的模型更优于MLP模型。MLP模型虽然也能将误差中心控制在0附近，但其误差分布的离散程度更高，且更易产生较大的极端误差。对比各算法绝对误差范围可知，LightGBM和CatBoost的绝对误差范围明显更加集中，其中CatBoost的绝对误差范围集中在−0.086～0.079 mm之间，其预测结果的误差波动性最小，稳定性最高；LightGBM的绝对误差范围集中在−0.093～0.081 mm之间，虽然其绝对误差

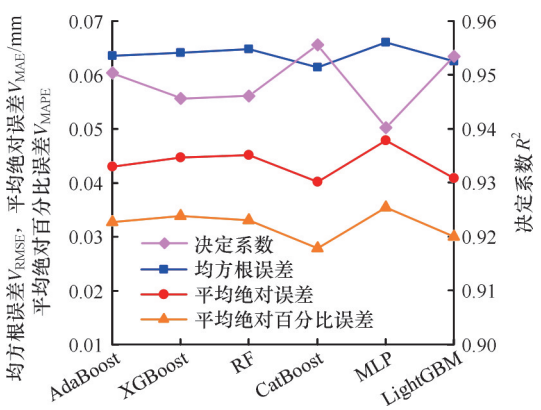


图7　各算法模型性能对比

Fig.7　Performance comparison of different algorithmic models

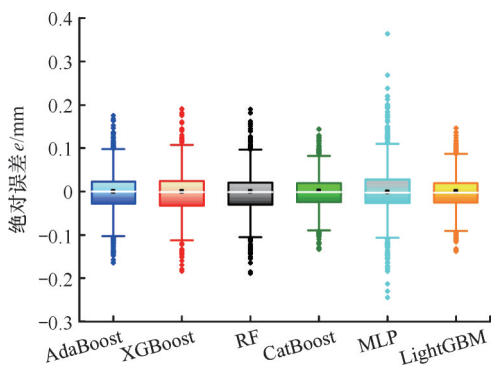


图8　各算法模型预测绝对误差对比

Fig.8　Comparison of absolute prediction errors across different algorithmic models

范围较CatBoost略大，但也表现出了很高的预测精度和稳定性。

如表4所示，为进一步对比LightGBM和CatBoost的算法性能和工程的实用性，统计两个算法的训练时间（使用处理器为13th Gen Intel(R) Core(TM) i5-13490F进行训练）和性能指标值大小，同时利用相同数据集对应各项参数代入物理模型计算其平均预测精度。表4表明两个算法在各个指标性能相近的情况下，LightGBM训练时间只有CatBoost训练时间的1/7～1/6（即训练效率为6～7倍）。从R^2、RMSE、MAE和MAPE的指标来看，两个算法的性能均表现良好，且均优于物理模型；从平均预测精度来看，两个算法的预测精度均在97%以上，LightGBM相比于传统的物理模型预测精度提高9.35%，能够满足工程上的精度要求。

表4 LightGBM和CatBoost的训练表现

Tab. 4 Training performance of LightGBM and CatBoost

名称	训练时间/s	R^2	RMSE/mm	MAE/mm	MAPE	平均预测精度/%
LightGBM	27	0.9535	0.0625	0.0409	0.0299	97.01
CatBoost	180	0.9556	0.0614	0.0402	0.0278	97.22
物理模型		0.8743	0.1586	0.1047	0.1233	87.66

综合各项指标分析，在性能相近的情况下LightGBM比CatBoost更加具有实用性，更加适合在生产线在线部署，具有进一步推广使用的价值。同时，本研究所建立的连退机组焊接焊缝厚度预测方法很好地监控了焊缝厚度的大小，提高了焊缝厚度检测的效率，从而保证了很好的焊缝质量。此外，受训练设备和数据采集精度等因素限制，该预测架构仍具备进一步开发的潜能。

4.2 AGA-BO改进寻优效果评估

为验证所提出的AGA-BO改进优化策略在连退机组焊接焊缝厚度预测模型超参数寻优中的有效性，本节记录了应用LightGBM作为目标模型时，优化过程中验证集上目标损失函数（Loss）随模型评估次数的变化，并绘制收敛曲线于图9。由图9可以清晰地看出在AGA和BO的协同作用下，算法具有高效的收敛能力和良好的稳定性，同时损失函数最终收敛至0.0625 mm，表明模型在焊缝厚度预测上达到了较高的精度，具有实际应用价值。

同时，为全面验证所提出的AGA-BO改进优化策略相对于现有方法的优势，本节设计并进行了对比实验。将AGA-BO策略与单独的自适应遗传算法（AGA）、单独的贝叶斯优化（BO）以及

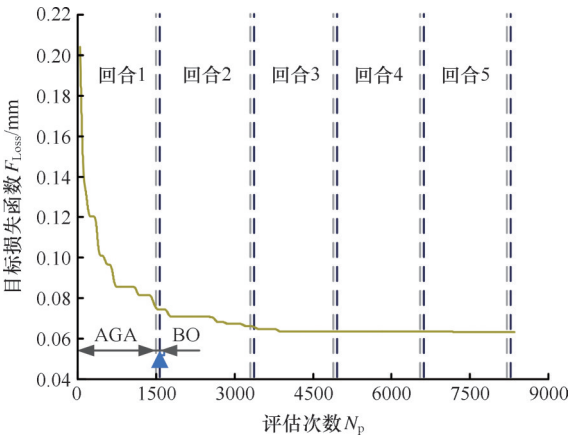


图9 目标损失函数收敛曲线

Fig.9 Objective loss function convergence curve

随机搜索（random search，RS）在统一的硬件环境和数据集划分下进行比较，并严格遵循以相同的总模型评估次数为计算资源预算，从而确保公平性。对比结果如表5所示，可知AGA-BO策略在MAE、RMSE和R^2三项指标上均取得了最优结果。最后，综合收敛曲线和最终模型性能对比结果，本研究提出的AGA-BO改进优化策略通过其独特的自适应性和动态协同机制，在相同计算资源预算下显著优于单一的AGA、BO以及RS。这充分验证了AGA-BO策略在连退机组焊缝厚度预测模型超参数寻优中的有效性、稳定性和优越性。

表5 各优化策略下模型在测试集上的性能对比

Tab. 5 Comparison of model performance on the test set under various optimization strategies

优化策略	MAE/mm	RMSE/mm	R^2
AGA-BO	0.0409	0.0625	0.9535
AGA	0.0538	0.0751	0.9233
BO	0.0533	0.0724	0.9316
RS	0.0802	0.0958	0.8527

4.3 现场应用效果

连退机组焊接焊缝厚度预测模型在实际工业应用中的实时响应能力和计算资源消耗是衡量其工程实用性的核心指标。本研究对已训练完成的连退机组焊接焊缝厚度预测模型（基于AGA-BO改进优化LightGBM算法）进行现场应用性能评估。在13th Gen Intel(R) Core(TM) i5-13490F CPU、32 GB RAM的计算配置下，模型单次焊缝厚度预测的平均推理时间约为7 ms。该模型文件大小约为3.4 MB，与传统的迭代式物理模型相比，该预测模型在预测过程中无需复杂的迭代求解，计算效率得到显著提高，足以满足连退机组生产线上毫秒级的实时预测需求。此外，本焊缝厚度预测模型的结构相对轻量，对计算资源和内存的占用较低，这极大地便利了它在工业控制系统

或边缘计算设备中的部署，为实现焊接过程的在线优化与智能控制奠定了坚实基础。

将模型部署到现场后作为辅助决策工具进行实时预测，并进行了为期一个月的生产数据验证，模型预测值与真实值误差的波动范围统计如图10所示，可以看出模型对焊缝厚度预测表现出良好趋势，绝大部分预测值与真实值的相对误差ε分布在±5%之间。考虑到连退机组生产环境的复杂性和多变性，本模型展现出更高的预测准确性和稳定性，有效降低了焊缝厚度超差的风险，对提高产品质量和生产效率具有积极意义。

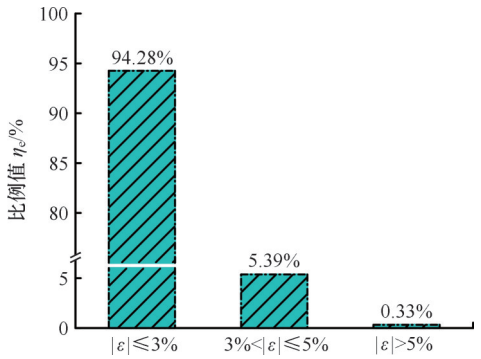


图10　模型预测值与真实值误差波动范围统计

Fig.10　Statistical distribution of prediction error range between model predictions and true values

5　结论

本文针对连退机组焊接焊缝厚度预测的问题，分析了连退机组焊机的焊接核心过程，结合传统物理模型确定了影响焊缝厚度的主要工艺参数，建立了结合自适应遗传算法与贝叶斯优化(AGA-BO)改进优化策略的连退机组焊接焊缝厚度预测架构并进行了实验研究，得出如下结论：

1)通过斯皮尔曼相关性验证对连退机组焊机焊接过程工艺参数进行特征筛选，影响焊缝厚度的主要工艺参数为：焊接电流、焊轮压力、焊接速度、碾压轮压力和搭接量。

2)所建立的融合AGA-BO改进优化策略的回归预测架构具备高效稳定的超参数寻优能力，同时兼顾了各个子模型的训练性能，通过对比不同高效算法与架构结合的预测性能可知，LightGBM在预测精度和训练速度上综合最优，平均预测精度大于97%，相比于传统的物理模型预测精度提高9.35%，很好地监控了焊缝厚度的大小，提高了焊缝厚度检测的效率，从而保证了很好的焊缝质量。

3)将本研究提出的基于AGA-BO改进优化LightGBM算法的连退机组焊接焊缝厚度预测模型应用于生产现场，其轻量化结构和实时性完全满足生产线对在线预测的严苛要求，模型预测误差的波动范围绝大部分在±5%以内，有效提高了焊缝厚度预测的准确性和稳定性，为连退机组的在线优化与智能控制提供了坚实基础，并对提升产品质量和生产效率具有重要实践意义。

本文构建的焊缝厚度预测架构能够有效预测焊接焊缝厚度，满足工程实际应用的精度要求。尽管存在训练设备和数据采集精度等限制，但该架构仍具备进一步开发的潜力。通过结合迁移学习技术，有望推广应用于其他产线或解决类似的目标预测问题，具有广阔的实际应用前景。

参考文献：

[1] 白振华，王瑞，张岩岩，等. 连退过程中带钢板形在线控制技术[J]. 钢铁，2016，51(2)：62-66.
BAI Zhenhua，WANG Rui，ZHANG Yanan，et al. On-Line Shape Control Technology of Steel Strip during Continuous Annealing[J]. Iron & Steel，2016，51(2)：62-66.

[2] 刘亚星，方永，滕华湘，等. 带钢退火关键工艺与产品质量综合控制技术概述[J]. 轧钢，2022，39(4)：27-34.
LIU Yaxing，FANG Yong，TENG Huaxiang，et al. Overview of Key Process and Product Quality Comprehensive Control Technology for Strip Steel Annealing[J]. Steel Rolling，2022，39(4)：27-34.

[3] 钱胜，张文军，林威，等. 热镀锌连退过程C翘机理及其预报模型[J]. 钢铁，2021，56(9)：88-95.
QIAN Sheng，ZHANG Wenjun，LIN Wei，et al. Mechanism of C-Camber and Its Prediction Model in Hot-dip Galvanizing Continuous Annealing Process[J]. Iron & Steel，2021，56(9)：88-95.

[4] MA C，LU H，LI C，et al. Study on the Effect of Continuous Annealing Process on Mechanical Properties of Cold Rolled Strip Steel[J]. Journal of Globe Scientific Reports，2025，7(2)：31-40.

[5] 白振华，徐纪栓，赵圳，等. 镀锡板连退平整过程焊缝印形成机理及其预测模型[J]. 塑性工程学报，2019，26(5)：232-238.
BAI Zhenhua，XU Jishuan，ZHAO Zhen，et al. Formation Mechanism and Prediction Model of Weld Mark in Continuous Annealing and Skin Pass Process for Tinplate[J]. Journal of Plasticity Engineering，2019，26(5)：232-238.

[6] 李学通，翟乾俊，姚利辉，等. 平整过程以焊缝印防治为目标的工艺参数综合优化[J]. 塑性工程学报，2021，28(4)：199-205.
LI Xuetong，ZHAI Qianjun，YAO Lihui，et al. Comprehensive Optimization of Process Parameters Aiming at Prevention and Control of Weld Mark in Skin Pass Process[J]. Journal of Plasticity Engineering，2021，28(4)：199-205.

[7] 姚利辉，张岩岩，翟乾俊，等. 连退平整机组以焊缝印防治为目标的轧辊工艺综合优化技术[J]. 塑性工程学报，2021，28(8)：195-201.
YAO Lihui，ZHANG Yanyan，ZHAI Qianjun，et al. Comprehensive Optimization Technology of Roller Process Aiming at Prevention and Control of Weld Mark in Continuous Annealing and Skin Pass Line[J]. Journal of Plasticity Engineering，2021，28(8)：195-201.

[8] 刘亚星. 连退机组关键工艺模型及带钢质量综合控制技术研究[D]. 秦皇岛：燕山大学，2017.
LIU Yaxing. Research on Key Process Models and Comprehensive Control Technology for Strip Quality in Continu-

ous Annealing Line[D]. Qinhuangdao: Yanshan University, 2017.

[9] 张宝平,袁文振,周莲莲,等. 连退机组搭接焊工艺数模与焊缝质量控制技术[J]. 中国冶金,2017,27(7):29-33.
ZHANG Baoping, YUAN Wenzhen, ZHOU Lianlian, et al. Mathematical Model of Lap Welding Process and Weld Quality Control Technology in Continuous Annealing Line[J]. China Metallurgy, 2017, 27(7):29-33.

[10] 朱爱辉,吕爽,刘明炜. 窄搭接电阻焊机在连续退火机组上的成功应用[J]. 热处理技术与装备,2013,34(2):58-60.
ZHU Aihui, LYU Shuang, LIU Mingwei. Successful Application of Narrow Lap Resistance Welder in Continuous Annealing Line[J]. Heat Treatment Technology and Equipment, 2013, 34(2):58-60.

[11] 龚辉. 镀铬机组TEMIC窄搭接焊机及其控制技术[J]. 自动化技术与应用,2012,31(8):67-70.
GONG Hui. TEMIC Narrow Lap Welder and Its Control Technology in Chromium Plating Line[J]. Techniques of Automation and Applications, 2012, 31(8):67-70.

[12] 李学通,翟乾俊,姚利辉,等. 连退机组焊机焊缝厚度预报模型及其影响因素[J]. 钢铁,2021,56(4):57-63.
LI Xuetong, ZHAI Qianjun, YAO Lihui, et al. Prediction Model of Weld Thickness and Its Influencing Factors for Welder in Continuous Annealing Line[J]. Iron & Steel, 2021, 56(4):57-63.

[13] 王双莲,冷心悦,赵名扬,等. 基于BP神经网络18%～25%Cr奥氏体耐热钢持久性能预测[J]. 钢铁研究学报,2025,37(1):104-116.
WANG Shuanglian, LENG Xinyue, ZHAO Mingyang, et al. Prediction of Creep Properties for 18%～25%Cr Austenitic Heat-resistant Steel Based on BP Neural Network [J]. Journal of Iron and Steel Research,2025,37(1):104-116.

[14] 周乐君,王万林,计熠,等. 机器学习在连铸过程应用研究进展[J]. 中国冶金,2024,34(11):10-21.
ZHOU Lejun, WANG Wanlin, JI Yi, et al. Research Progress on Application of Machine Learning in Continuous Casting Process [J]. China Metallurgy, 2024, 34 (11): 10-21.

[15] 王军生,林利,张宇,等. 基于数据治理的钢铁材料数字化研发[J]. 中国冶金,2024,34(6):1-13.
WANG Junsheng, LIN Li, ZHANG Yu, et al. Digital R&D of Steel Materials Based on Data Governance [J]. China Metallurgy,2024,34(6):1-13.

[16] 杨累,赵帆,姜磊,等. 机器学习辅助2000 MPa级弹簧钢成分和热处理工艺开发[J]. 金属学报,2023,59(11):1499-1512.
YANG Lei, ZHAO Fan, JIANG Lei, et al. Machine Learning-assisted Development of Composition and Heat Treatment Process for 2000 MPa Grade Spring Steel[J]. Acta Metallurgica Sinica,2023,59(11):1499-1512.

[17] 吴吉展,魏沛堂,吴少杰,等. 航空齿轮钢滚动接触疲劳性能预测与表面完整性优化[J]. 机械工程学报,2024,60(8):81-93.
WU Jizhan, WEI Peitang, WU Shaojie, et al. Prediction of Rolling Contact Fatigue Properties and Optimization of Surface Integrity for Aviation Gear Steel[J]. Journal of Mechanical Engineering,2024,60(8):81-93.

[18] 高志玉,樊献金,高思达,等. 基于多模型机器学习的合金结构钢回火力学性能研究[J]. 材料导报,2023,37(6):148-154.
GAO Zhiyu, FAN Xianjin, GAO Sida, et al. Study on Mechanical Properties of Tempered Alloy Structural Steel Based on Multi-model Machine Learning[J]. Materials Reports,2023,37(6):148-154.

[19] 魏清华,熊杰,孙升,等. 多目标机器学习钢的四种力学性能[J]. 中国科学:技术科学,2021,51(6):722-736.
WEI Qinghua, XIONG Jie, SUN Sheng, et al. Multi-objective Machine Learning for Four Mechanical Properties of Steel[J]. Scientia Sinica Technologica, 2021, 51(6): 722-736.

[20] 刘瑜. 机理融合数据的热连轧过程板带质量预测与控制[D]. 太原:太原科技大学,2023.
LIU Yu. Mechanism-data Integrated Prediction and Control of Strip Quality in Hot Continuous Rolling Process [D]. Taiyuan: Taiyuan University of Science and Technology,2023.

[21] 何欣,高秀华,施宗翔,等. 基于机器学习和多目标优化的耐候钢性能预测和逆向设计研究[J]. 塑性工程学报,2023,30(11):167-177.
HE Xin, GAO Xiuhua, SHI Zongxiang, et al. Performance Prediction and Inverse Design of Weathering Steel Based on Machine Learning and Multi-objective Optimization[J]. Journal of Plasticity Engineering, 2023, 30(11): 167-177.

[22] 刘宏旭,李旭,丁敬国,等. 基于随机森林特征选取和遗传算法优化的带钢厚度预测[J]. 轧钢,2024,41(6):76-85.
LIU Hongxu, LI Xu, DING Jingguo, et al. Strip Thickness Prediction Based on Random Forest Feature Selection and Optimized by Genetic Algorithm [J]. Steel Rolling, 2024, 41(6):76-85.

[23] 任鹏帆,王振华,贾燚,等. 机理和数据融合的304不锈钢极薄带轧制力模型[J]. 钢铁,2024,59(10):64-76.
REN Pengfan, WANG Zhenhua, JIA Yan, et al. Rolling Force Model for 304 Stainless Steel Ultra-thin Strip Based on Mechanism and Date Fusion[J]. Iron & Steel, 2024, 59 (10):64-76.

[24] 贾瑞匣. 基于PSO-SVM改进模型的冶金板冷连轧弯辊力预测研究[J]. 山西冶金,2023,46(11):98-99.
JIA Ruixia. Prediction of Bending Force in Cold Tandem Rolling of Metallurgical Strip Based on Improved PSO-SVM Model [J]. Shanxi Metallurgy, 2023, 46 (11): 98-99.

[25] 张文军,张燕东,林威,等. 连退机组焊接质量影响模型及其影响因素的研究[J]. 中国机械工程,2022,33(15):1876-1881.
ZHANG Wenjun, ZHANG Yandong, LIN Wei, et al. Influence Model of Welding Quality and Its Influencing Factors in Continuous Annealing Line[J]. China Mechanical Engineering, 2022, 33(15):1876-1881.

（编辑　胡佳慧）

作者简介：王　卓，男，2000年生，博士研究生。研究方向为轧钢设备与工艺、带钢焊接质量控制。E-mail：615707414@qq.com。
白振华*（通信作者），男，1975年生，教授、博士研究生导师。研究方向为高品质板带质量智能综合控制。E-mail：bai_zhenhua@aliyun.com。

本文引用格式：

王卓，王智璇，王浩，等. 基于AGA-BO优化的数据驱动连退机组焊接焊缝厚度预测[J]. 中国机械工程，2026，37(11)：2918-2926.

WANG Zhuo, WANG Zhixuan, WANG Hao, et al. Data-driven Prediction of Welded Seam Thickness in Continuous Annealing Lines Based on AGA-BO Optimization[J]. China Mechanical Engineering,2026,37(11):2918-2926.