基于小样本数据驱动的H13钢表面激光硬化及抛光工艺参数优化

梁 强[1,2*] 徐彬源[1] 徐永航[1] 胡开群[1,2] 陈伟灵[1] 陈 红[1]
1.重庆工商大学机械工程学院,重庆,400067
2.重庆工商大学智能装备绿色设计与制造重庆市重点实验室,重庆,400067

摘要:为实现通过激光加工对H13模具钢表面进行硬化处理并改善表面形貌,以激光功率、扫描速度和搭接率3个工艺参数为变量,对试样的淬透深度和相邻扫描道次的峰谷差值、表面粗糙度进行了优化。首先采用拉丁超立方抽样进行试验设计,并基于得到的小样本数据建立了多目标优化模型。然后采用多目标优化算法进行工艺参数寻优。最后采用多准则妥协解排序法结合客观赋权法构建了一种综合评价方法,对非劣解集进行排序以得到最佳工艺参数组合。在最佳工艺参数组合下进行试验,结果表明H13钢表面硬化效果显著,同时有效降低了表面粗糙度。

关键词:H13钢;激光抛光;激光硬化;小样本数据驱动;参数优化
中图分类号:TN249;TG356.28
DOI:10.3969/j.issn.1004-132X.2026.08.011 **开放科学(资源服务)标识码(OSID)**:

Optimization of Laser Hardening and Polishing Parameters of H13 Steel Surfaces with Small Sample Data Driven Process

LIANG Qiang[1,2*] XU Binyuan[1] XU Yonghang[1] HU Kaiqun[1,2] CHEN Weiling[1] CHEN Hong[1]
1.School of Mechanic Engineering, Chongqing Technology and Business University, Chongqing, 400067
2.Chongqing Key Laboratory of Green Design and Manufacturing of Intelligent Equipment, Chongqing Technology and Business University, Chongqing, 400067

Abstract: This paper investigated the optimization of processing parameters for surface hardening and morphology improvement of H13 mold steels using laser processing. Laser power, scanning speed, and overlap ratio were selected as processing variables, and their effects on hardening depth, peak-valley height between adjacent scanning tracks, and surface roughness were optimized. Initially, Latin hypercube sampling was employed for experimental design, followed by the development of a multi-objective optimization model based on the obtained small-sample data. A multi-objective optimization algorithm was then used to optimize the processing parameters. Finally, a comprehensive evaluation method was proposed by integrating the multi-criteria decision-making approach with an objective weighting method to rank the non-dominated solutions and identify the optimal parameter combination. Experimental results conducted under the optimal parameter combination demonstrate significant surface hardening of H13 steels along with effective reduction in surface roughness.

Key words: H13 steel; laser polishing; laser hardening; small sample data driven; parameter optimization

0 引言

激光加工技术能够对模具复杂型腔表面指定区域进行柔性化加工,不仅能有效提高模具表面质量及其寿命,而且能合理降低能源消耗,提高模具生产加工效率,减少生产成本。

目前,很多研究人员对模具表面激光硬化与抛光技术进行了研究。VESELÝ等[1]开发了一种选择性激光硬化的方法,发现对部分区域进行热处理可以改变材料的表面热量吸收率,最终实现特定区域的硬化效果。WAGH等[2]通过设计正交试验分析了激光束功率、扫描速度、扫描间距与材料表面硬度、耐磨性之间的联系,发现在最佳工艺参数下,材料表面硬度可从基体的208 HV提高至833 HV,同时材料耐磨性显著提高。CHEN等[3]发现通过激光扫描可以有效提高QT700-2的

收稿日期:2025-01-06
基金项目:重庆市自然科学基金创新发展联合基金(CSTB2022NSCQ-LZX0011);重庆市高校创新研究群体项目(CXQT21024)

硬度及其耐磨损性，在最佳工艺参数下硬化层的硬度值可达到基体（250 HV）的3倍。杨仁人等[4]对比分析了激光重熔和激光淬火对硬化层的影响，发现激光重熔后的马氏体含量更多、微观组织更均匀致密，从而表现出更好的硬化效果。激光扫描不仅可以实现表面硬化，还可以有效降低表面粗糙度，研究人员发现激光扫描可以同步改善材料的表面硬度和粗糙度。ZHAO等[5]提出了一种基于脉冲激光器多次重熔循环的激光抛光方案，可将表面粗糙度*Sa*从20.958 μm降至0.242 μm，表面显微硬度提高了22%，重熔深度为22 μm。LIU等[6]使用纳秒脉冲激光对Zr基金属玻璃进行激光抛光，研究了工艺参数对表面质量和硬度的影响，发现抛光后表面粗糙度降低了90%，表面硬度提高了11%，重熔深度小于10 μm。YI等[7]研究了扫描速度和扫描时间对镍基高温合金表面质量的影响，发现合理调节工艺参数可将表面粗糙度*Ra*从0.702 μm降至0.354 μm，同时表面硬度略有提高。

为得到良好的材料表面性能，通过大量的试验可以较好地建立工艺参数与响应目标之间的联系，但也带来了工作量大、耗费材料多的问题。为解决该问题，一些学者对容量及维度均较少的小样本数据进行了个性化研究，发现可以快捷、精准地得到工艺参数优化组合。周梦等[8]利用改进BPNN算法对5组样本量为20的数据进行建模，发现模型精度较高、具备较强的泛化能力。赵腾远等[9]利用高斯过程回归方法建立了软土回弹模量数学模型，在训练集数量为30的情况下即可得到较为良好的训练效果以及泛化效果。易茜等[10]采用BBD试验收集了28组试验数据，通过结合BPNN-MOGWO-熵权-TOPSIS混合算法实现了滚齿工艺参数低碳优化。

目前针对激光表面改性，研究人员更关注单一的激光硬化效果或抛光效果而较少研究两者的同步耦合性。虽然已有研究发现激光扫描可以同时改善表面硬度和粗糙度，但对硬化及抛光效果进行同步优化以实现优异的同步硬化及抛光效果的研究报道较少。此外，基于小样本数据驱动的工艺参数优化方法有待进一步研究。为实现良好的表面硬化效果同时改善表面粗糙度，本研究提出了一种基于小样本数据的H13钢表面激光硬化及抛光多目标优化方法。首先建立了工艺参数与响应目标之间的多目标预测模型，然后利用多目标优化算法进行工艺参数寻优求解，并采用多准则妥协优化解法（vlsekriterijumska optimizacija i kompromisno resenje，VIKOR）结合客观赋权法（criteria importance though intercrieria correlation，CRITIC）对得到的解集进行排序，最终对得到的最优参数组合进行试验验证。

1 基于小样本数据的多目标优化策略

为得到H13钢表面激光硬化同步激光抛光的最佳工艺参数组合，本文提出基于小样本数据的多目标优化策略，其流程图见图1。首先基于试验数据构建H13钢表面激光硬化同步激光抛光多目标预测模型，然后经过多目标优化和综合评价排序后得到最优工艺参数组合，最后进行试验验证。

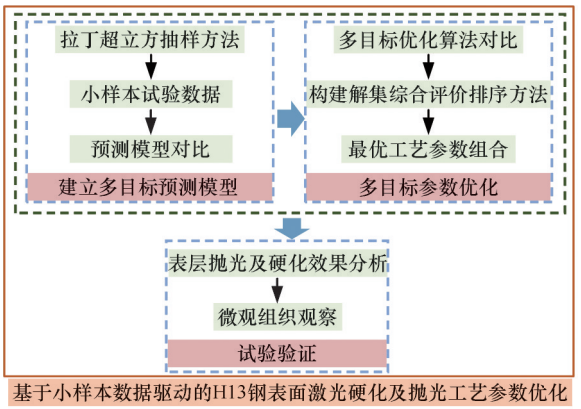


图1 多目标优化策略流程图

Fig.1 Flowchart of multi-objective optimization strategy

1.1 多目标预测模型

机器学习算法因其良好的预测性能已被广泛应用于机械加工领域[11-13]。为建立激光工艺参数与表面硬化及抛光效果之间的映射关系，采用极限梯度提升（extreme gradient boosting，XGBOOST[14]）算法构建多目标预测模型。XGBOOST算法具备优异的预测性能[15]。首先从一个简单的模型开始逐步添加新模型以减小预测误差，然后通过计算损失函数的梯度确定需要添加的新模型的方向和程度，并在损失函数中添加了正则化项以提高模型的泛化能力。XGBOOST模型的拟合效果与超参数*n_estimators*、*learning_rate*、*subsample*、*colsample_bytree*等的选择密切相关。而在选择超参数的过程中，若仅靠传统经验进行选择，难以获得最佳的超参数组合，若要得到良好的拟合效果，往往需要花费较多的时间。为了充分发挥XGBOOST模型的预测性能，采用鱼鹰算法（osprey optimization alorithm，OOA）优化XGBOOST模型的超参数，以构建更准确的多目标预测模型，其训练流程如图2所示。MOHAMMAD等[16]通过模拟鱼鹰的捕食行为提出

了OOA算法，它主要分为2个阶段：第一阶段为全局探索——鱼鹰识别鱼的位置并捕鱼，第二阶段为局部开采——把鱼带至合适位置进食。OOA算法具备优异的全局探索能力，同时兼具良好的灵活性、适用性、抗干扰性，研究人员使用该算法在优化模型超参数方面取得了不错的应用效果[17-19]。

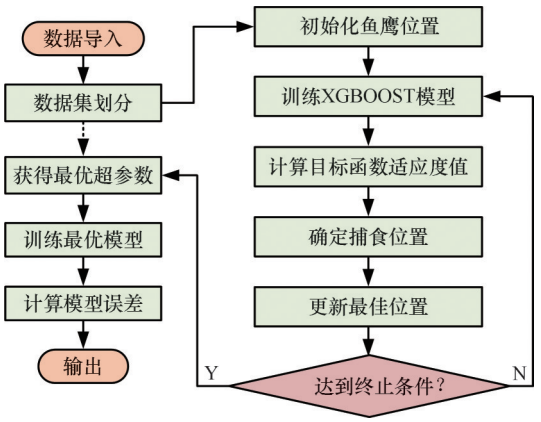


图2　OOA算法优化XGBOOST模型训练流程图

Fig.2　Flowchart of OOA algorithm to optimize XGBOOST model

为更好地评估模型的预测性能，引入决定系数R^2、平均绝对百分比误差(mean absolute percentage error，MAPE)、均方根误差(root mean square error，RMSE)3种常用的评估预测模型准确性的指标，其计算公式略。R^2越大，MAPE值和RMSE值越小，表明模型的拟合效果越好。

1.2　多目标优化算法

非支配排序遗传算法-Ⅱ(non-dominated sorting genetic algorithm Ⅱ，NSGA-Ⅱ)[20]在解决多目标优化问题方面具有优异的求解效果，是一种经典的多目标优化算法。但该算法在使用精英策略进行寻优时容易陷入局部最优解，由此本文提出一种改进的DNSGA-Ⅱ(dynamic non-dominated sorting genetic algorithm Ⅱ)算法，分别对种群初始化部分及种群迭代部分进行改进，以促进解集的均匀性，其流程如图3所示。首先初始化种群[21]，然后在NSGA-Ⅱ基础上增添了对拥挤度环境的检测及调整。传统NSGA-Ⅱ的迭代方式是对相邻解距离进行排序，优选迭代的父代，这容易导致解的均匀性不佳或陷入局部最优解。在DNSGA-Ⅱ中，采用动态检测的方式主动检测相邻解集的拥挤度后，对稀疏区域进行高斯扰动插补，然后计算对目标函数的适应度，排序优选后作为父代：

$$Y_n = Y_0(1+\lambda) \tag{1}$$

式中：Y_n为调整后的新解位置；Y_0为原始的解位置；λ为服从正态分布的随机数。

为量化评价优化算法的优化效果，采用超体积(hypervolume，HV)和反世代距离(inverted generational distance，IGD)两种指标对算法的优化性能进行对比分析。HV考量的是占据目标空间的体积，它计算的是由Pareto解集与一个参考点之间围成的区域的体积，该值越大表明Pareto解集的多样性越好、分布越合理，计算公式为

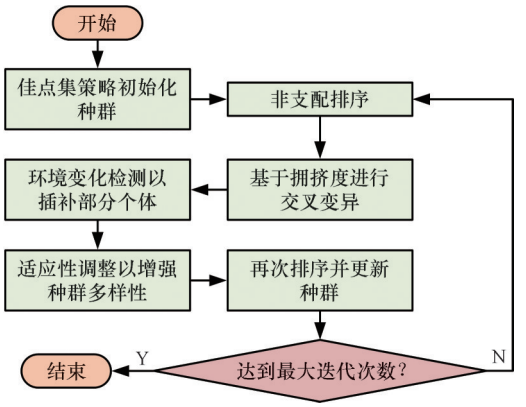


图3　改进DNSGA-Ⅱ算法流程图

Fig.3　Flowchart of the improved DNSGA-II algorithm

$$HV = \eta\left(\bigcup_{i=1}^{|S|} v_i\right) \tag{2}$$

IGD考量的是Pareto解集与理想解之间的距离，该值越小，表明所得Pareto解集越逼近理想情况，计算公式为

$$IGD(P_1, P_1^*) = \frac{1}{|P_1^*|}\sum_{k_1^* \in P_1^*} \min_{k_1 \in P_1} dis(k_1^*, k_1) \tag{3}$$

式中：η为lebesgue测度；S为Pareto解集的数量；v_i为参考点与第i个解集点所构成的超体积；P_1为所得解集；P_1^*为一组参考解集；$dis(k_1^*, k_1)$为参考集P_1^*中的点k_1^*与解集P_1中的点k_1之间的欧氏距离。

1.3　构建综合评价排序方法

为了对得到的Pareto解集进行综合评价以选择出最佳的工艺参数组合，采用VIKOR法[22-23]结合CRITIC法[24]构建综合评价排序方法对解集进行排序，其计算流程如图4所示，具体步骤如下。

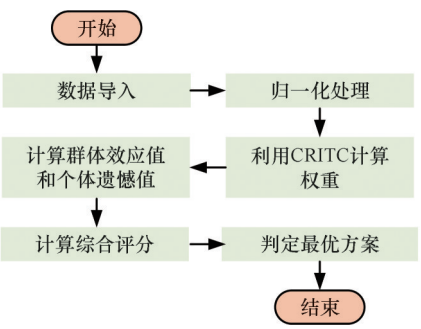


图4　VIKOR-VRITIC流程图

Fig.4　Flowchart of VIKOR-VRITIC

1)建立决策矩阵及规范化处理。经多目标优化算法得到的Pareto解集组成决策矩阵T_{ij}，对决策矩阵中不同属性的各响应目标进行正向化和归

一化处理，得到标准矩阵$\boldsymbol{X}_{ij}$。

2）CRITIC法权重计算。CRITIC是一种客观赋权法，综合考虑了样本的相对强度和响应目标之间的潜在冲突，相对强度用标准差σ表征，目标间潜在冲突用C值表征，最终权重值W则由σ和C综合计算得出，相关计算公式为

$$\left.\begin{aligned}\sigma_j&=\sqrt{\frac{1}{n-1}\sum_{i=1}^{n}(x_{ij}-\bar{x}_j)^2}\\C_j&=\sum_{j=1,k\neq j}^{m}(1-r_{jk})\\W_j&=C_j/\sum_{j=1}^{m}C_j\end{aligned}\right\}\tag{4}$$

式中：$\bar{x}_j$为第j列的均值；n为解集中解的数量；m为指标数量；r_{jk}为第j列与第k列响应目标间Pearson相关系数；C_j为第j个响应目标包含的信息熵；W_j为最终计算所得权重。

3）计算综合评分并判定最优解。结合VIKOR和CRITIC，通过下式对解集进行排序：

$$\left.\begin{aligned}S_i&=\sum_{j=1}^{m}\frac{W_j(x_j^+-x_{ij})}{x_j^+-x_j^-}\\R_i&=\max\frac{W_j(x_j^+-x_{ij})}{x_j^+-x_j^-}\\Q_i&=\frac{u(S_i-S^-)}{S^+-S^-}+\frac{(1-u)(R_i-R^-)}{R^+-R^-}\end{aligned}\right\}\tag{5}$$

式中：x_j^+、x_j^-分别为$\boldsymbol{X}_{ij}$中各响应目标的正理想解和负理想解，分别是第j列响应目标的最大值和最小值；S_i为群体效益；S^+、S^-分别为S_i的最大值和最小值；R_i为个体遗憾值；R^+、R^-分别为R_i的最大值和最小值；u为决策系数；Q_i为第i组解集的综合评价指标。

其中，群体效益S_i反映了该组解与理想解的总体接近程度，体现了解的绝对表现。个体遗憾R_i代表一个解集在各标准下相对于最差解的表现，是反映方案相对优劣的一种度量。u取决于决策者对于S_i和R_i的倾向方向，此处取$u=0.5$，对方案进行折中处理。最终计算得到综合评分Q_i，Q_i值越小表明该方案越优。判定条件如下：

$$\left.\begin{aligned}&Q_i-Q_{i-1}>\frac{1}{i-1}\qquad\text{C.1}\\&R_1==R^-\quad S_1==S^-\qquad\text{C.2}\end{aligned}\right\}\tag{6}$$

当按照Q_i升序排列时，需要对最终排序前2的解进行判定，以选出最优方案。若不满足条件C.1则向后递归继续判定，直到第i个方案满足，则第1至i个解均为最优解；若仅满足条件C.1，则前2个解均为最优解；若判定条件均满足，则排序第1的解为最优解。

2 激光硬化及抛光试验研究

2.1 试验方法

本次试验所用激光扫描系统主要由以下部分组成：RFL-C3000光纤输出半导体激光器、FANUC六轴机器人、TS-6A激光头、TFLW-3000水冷装置等共计17个关键零部件。激光光束为高斯光束，光斑直径2 mm，为防止激光加工过程中表面氧化，试验过程中同轴吹气，辅助气体为氩气，气体流量13 L/min。采用激光光谱共聚焦显微镜KC-X1000完成激光扫描前后的表面形貌观察，扫描区域大小为15 mm×15 mm；采用SJ5760-PR表面粗糙度轮廓仪对扫描前后的表面粗糙度进行测量，测量依据为ISO 4288：1996和ISO 4287：2010，其中取样长度为2.5 mm，评定长度取12.5 mm；采用Leica DVM6超景深显微仪对扫描后的淬透深度和峰谷差值进行测量；采用HV-1000B维氏显微硬度计对表面硬度进行测量，加载力500 g，保压时间10 s。

试验所用材料为H13钢，尺寸大小22 mm×170 mm×10 mm，其化学成分见表1。

表1 H13钢主要化学成分（质量分数）

Tab.1 Main chemical compositions of H13 steel

（mass fraction） %

w(C)	w(Si)	w(Mn)	w(Cr)	w(Mo)	w(V)	w(P)	w(S)	w(Fe)
0.32～0.45	0.80～1.20	0.20～0.50	4.75～5.50	1.10～1.75	0.80～1.20	≤0.03	≤0.03	其余

为获得良好的初始表面，试验前对表面进行粗磨、铣削、除锈处理，然后采用乙醇和超声波对表面进行清洗并烘干。激光扫描区域大小为15×15 mm，扫描路径为“弓”字形，扫描路径示意图见图5。抛光后表面粗糙度测量方向垂直于扫描路径，测量3次后取平均值。淬透深度H及峰谷差值ΔH的测量位置为垂直于硬化路径的截面，考虑到重熔区和热影响区厚度较小且区分度较低，单独测量一个区域容易导致较大的测量误差，由此选择测量“重熔区＋热影响区”的厚度作为淬透深度H，如图5所示。为达到良好的淬硬效果，相邻扫描道次应充分搭接，故提出以淬硬区

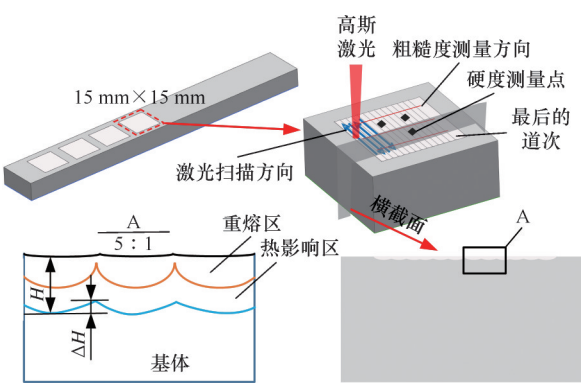


图5 加工与测量方式示意图

Fig.5 Schematic diagram of measurement method

域的相邻峰谷差值ΔH作为评价指标。选择测量相邻道次开始出现珠光体至该道次珠光体与马氏体分界波谷的距离作为ΔH。考虑到单道次所得H和ΔH的代表性较差，故选择测量3个硬化区域的值再取平均值作为最终测量结果。测量H和ΔH前，对截面进行研磨、抛光，然后使用4%（体积分数）的硝酸酒精溶液进行腐蚀并使用无水乙醇清洁。

2.2　试验设计及测量结果

在激光扫描过程中，激光器的功率P、扫描速度v显著影响着材料表面的热变化过程，而搭接率δ则主导着相邻道次的搭接效果。为较好地评价激光扫描后的硬化及抛光效果，选择淬透深度H及峰谷差值ΔH作为评价硬化层优劣的指标，选择材料表面的粗糙度Ra作为评价表面形貌质量的指标。故选择P、v、δ这3个工艺参数作为试验因素，测量相应的H、ΔH、Ra作为响应目标。

本研究采用拉丁超立方抽样（latin hypercube sampling，LHS）进行试验设计[25-28]。基于设备工艺范围及期望目标进行前期预试验，确定各工艺参数的取值范围：$P\in[520,920]$ W，$v\in[5,15]$ mm/s，$\delta\in[10\%,70\%]$，采用LHS法进行试验设计，图6所示为LHS法设计的试验点空间分布情况，试验方案及测量结果见表2。

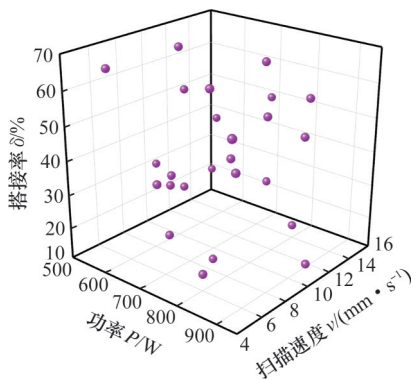


图6　工艺参数分布情况

Fig.6　Distribution of process parameters

2.3　模型的构建

采用OOA-XGBOOST算法构建激光硬化及抛光多目标预测模型。从25组样本中随机抽选20个样本作为训练集，其余样本组成测试集，训练集与测试集比例为4∶1。XGBOOST超参数的取值范围：*n_estimators*为0～100，*max_features*为1～5，*max_depth*为1～20，*learning_rate*为0.1～0.5，*subsample*为0.6～1.0，*colsample_bytree*为0.6～1.0。在OOA优化算法中，设置鱼鹰数量为20，迭代次数为100，以测试集的均方误差（mean square error，MSE）作为适应度值，通过寻优获得XGBOOST最优超参数。

表2　试验方案及结果

Tab.2　Test program and results

序号	P/W	v/(mm·s^{-1})	δ/%	H/μm	ΔH/μm	Ra/μm
1	534	10	31	712.7033	473.9808	2.4318
2	547	6	65	764.7600	69.0054	2.7549
3	567	14	24	659.2067	659.2067	2.7285
4	581	14	41	706.8433	254.5815	2.6617
5	586	11	54	753.3067	76.4454	3.4433
6	606	10	68	816.2033	34.7314	3.2717
7	617	10	27	763.1167	251.2191	3.3295
8	647	8	32	844.8267	184.5580	3.4072
9	650	8	35	919.3367	108.0334	2.8930
10	677	7	20	994.9333	286.3463	2.8464
11	681	6	37	1011.3400	167.0627	3.7995
12	707	15	50	735.7467	111.0918	3.1009
13	726	14	26	730.7833	230.8106	3.5365
14	731	9	11	856.8400	387.3315	3.0025
15	755	8	63	1129.2933	254.8948	2.9192
16	776	12	66	826.0200	66.7878	2.3739
17	778	9	43	1067.8363	140.6478	2.3718
18	801	6	16	1131.5800	399.9582	3.0312
19	811	11	53	856.7667	115.4971	2.9085
20	826	13	18	863.1000	366.2251	2.6999
21	852	7	45	1140.0633	76.7062	3.1529
22	861	13	57	863.1600	69.4323	4.3345
23	877	12	48	893.1933	108.8696	4.8046
24	904	5	59	1540.2567	216.6558	4.3540
25	916	11	14	1040.8467	352.9074	4.3978

为验证OOA-XGBOOST模型在预测性能方面的优越性，建立反向神经网络预测模型（back propagation neural network，BPNN）、决策树预测模型（decision trees，DT）、随机森林预测模型（random forest，RF）、XGBOOST模型进行对比。BPNN由输入层、隐藏层和输出层三层通过正向信息传输和反向误差传输完成建模[29-30]。DT是一种简单适用的分类回归方法，通过树形结构的内部节点、树叶节点、分支等完成对数据特征的划分及回归预测[31]。RF模型[32]是一种集成学习方法，通过构建多个决策树并结合它们的预测结果来提高模型的准确性和泛化能力。

在训练集和测试集数据保持不变的前提下，对其他4种模型进行建模，模型中各参数均为默认值，其结果如图7和表3所示。OOA-XGBOOST模型的预测准确性和拟合程度均高于BPNN、DT、RF和XGBOOST模型。综上，OOA-XGBOOST模型具有较好的预测能力和泛

化能力，可为后续H13钢表面激光硬化及抛光工艺参数优化提供可靠的预测模型支持。

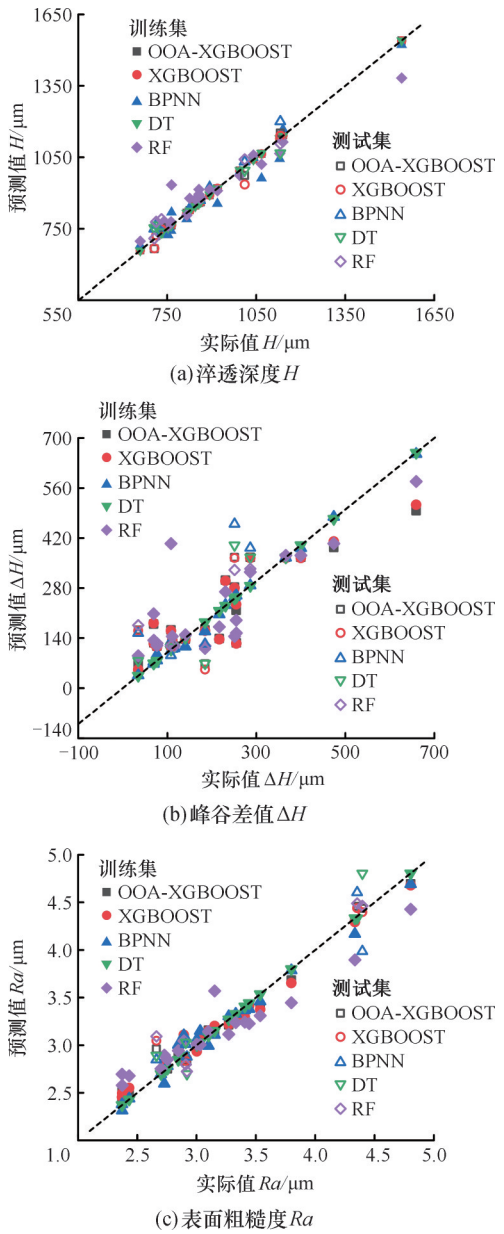


图7 预测模型对H、ΔH和Ra的拟合效果

Fig.7 Effectiveness of fitting the prediction model to H、ΔH and Ra

2.4 工艺参数多目标优化

为达到良好的表面淬硬-抛光效果，对各响应目标提出期望方向。其中，H应尽量大，以获取足够厚的淬硬层；ΔH应尽量小，从而保证有效的淬硬层厚度；Ra应尽量小，以改善原始的粗糙轮廓形貌，实现较平缓的表面形貌。将优化的目标函数表示为

$$\left.\begin{aligned}&\max H(P,v,\delta)\\&\min \Delta H(P,v,\delta)\\&\min Ra(P,v,\delta)\end{aligned}\right\} \tag{7}$$

通过对3个响应目标的寻优，以实现良好的表面淬硬-抛光效果。基于预实验并综合考虑寻优过程的收敛效果，将约束条件设置为

$$\left.\begin{aligned}&200\ \text{W}\leqslant P\leqslant 1000\ \text{W}\\&5\ \text{mm/s}\leqslant v\leqslant 30\ \text{mm/s}\\&5\%\leqslant \delta\leqslant 70\%\end{aligned}\right\} \tag{8}$$

在改进DNSGA-Ⅱ算法中，设置初始种群数量为200，迭代次数为200，交叉比例为0.9，变异概率为0.1，相邻解集检测数为3，高斯扰动标准差为0.1。

为比较分析改进DNSGA-Ⅱ算法的优异性，增加多目标灰狼优化(MOGWO)算法和多目标粒子群优化(MOPSO)进行对比。采用勘探和开发策略的组合，可以高效且有效地探索解决方案空间[33]。MOPSO算法适用于解决非线性连续和组合优化问题[34-35]。MOGWO算法设置如下：种群规模200，迭代次数200，采用默认的线性收敛因子。MOPSO算法的设置如下：种群规模200，迭代次数200，惯性权重0.5，学习因子1.5，自适应网格等分量2。最终得到的前70组Pareto解集分布情况如图8所示。

4种优化算法相应的HV值及IGD值见表4，

表3 模型准确性对比

Tab.3 Comparison of model accuracy

评估指标	BPNN		
	R^2	MAPE值	RMSE值
Ra	0.904	5.411	0.236
H	0.939	4.332	44.002
ΔH	0.876	27.652	15.883
评估指标	DT		
	R^2	MAPE值	RMSE值
Ra	0.903	6.024	0.238
H	4.362	42.955	0.899
ΔH	41.352	0.903	6.024
评估指标	RF		
	R^2	MAPE值	RMSE值
Ra	0.912	6.240	0.227
H	4.580	43.433	0.933
ΔH	33.629	0.912	6.240
评估指标	XGBOOST		
	R^2	MAPE值	RMSE值
Ra	0.943	4.185	0.168
H	0.952	3.493	39.125
ΔH	0.989	8.243	13.918
评估指标	OOA-XGBOOST		
	R^2	MAPE值	RMSE值
Ra	0.961	3.988	0.151
H	0.973	3.172	29.117
ΔH	0.991	4.366	11.998

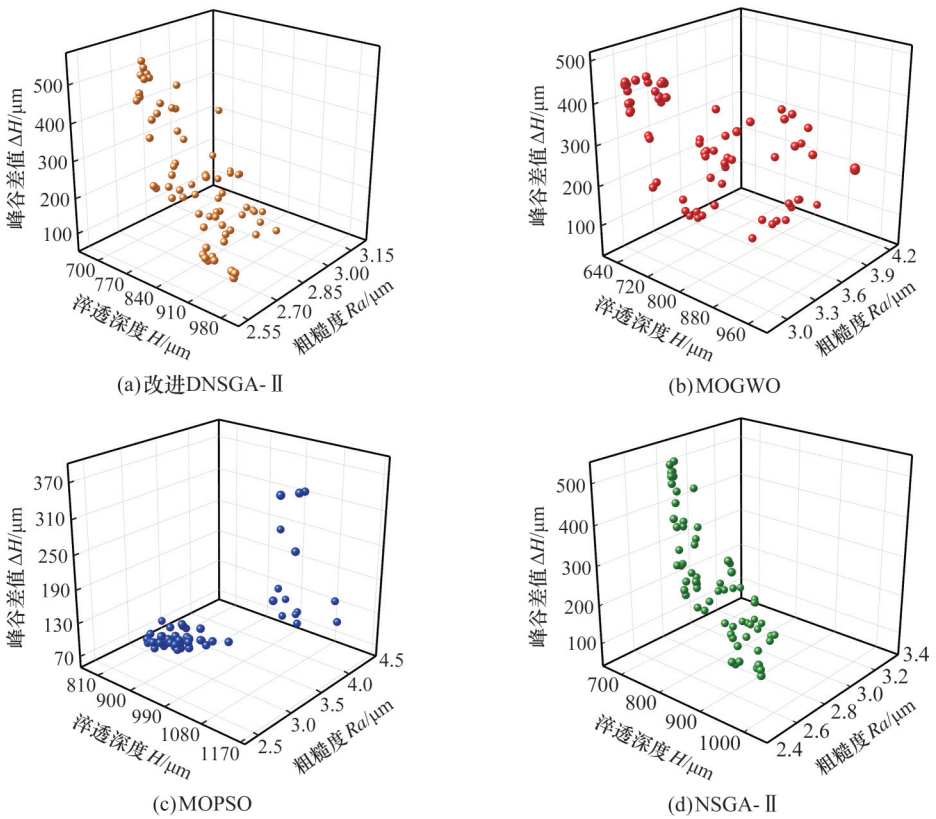


图8　各优化算法所得Pareto解集

Fig.8　The set of Pareto solutions obtained by each optimization algorithm

可看出改进DNSGA-Ⅱ的HV值大于另外3种算法的HV值，表明该算法在寻优过程中更善于探索解集的多样性。同时可见改进DNSGA-Ⅱ的IGD值小于另外3种算法的IGD值，表明该算法的搜索能力更强。以上表明改进DNSGA-Ⅱ算法在寻优过程中展现了更优异的综合性能，故选择该算法所得解集作为最终的寻优解集。

表4　算法性能对比

Tab. 4　Algorithm performance comparison

评估指标	MOPSO	MOGWO	NSGA-Ⅱ	改进DNSGA-Ⅱ
HV	2.53×10^5	2.16×10^5	2.92×10^5	3.03×10^5
IGD	15.9	32.1	6.89	6.19

通过VIKOR结合CRITIC对得到的Pareto解集进行重新排序，最终得到的排序前5位结果见表5。通过1.3节判定条件进行最优方案判定，发现Q_1仅满足判定条件C.1，故Q_1和Q_2对应的解集均为最优方案。

表5　综合评价排名前5组解

Tab.5　Top 5 groups of solutions ranked by comprehensive evaluation

序号	P/W	v/(mm·s^{-1})	δ/%	Ra/μm	H/μm	ΔH/μm	S_i	R_i	Q_i
1	793.0291	9.2820	41.8260	2.5715	982.6173	144.3267	0.0570	0.0570	0.0009
2	787.7155	9.4735	41.9124	2.5759	978.6181	145.5351	0.0645	0.0578	0.0070
3	774.4715	9.0337	43.5136	2.5765	969.5222	143.4933	0.0726	0.0564	0.0101
4	774.4715	9.0337	41.0374	2.5760	975.5882	152.6799	0.0725	0.0627	0.0197
5	792.5727	10.3157	41.8353	2.6071	901.2695	131.3647	0.1516	0.0819	0.1003

3　优化结果验证

由第2节得Q_1、Q_2均为最优方案，但这2种方案的响应目标极为相近(响应目标相对差值均小于1%)，由此取Q_1为最优方案，取整后进行工艺试验，即P=793 W，v=9.3 mm/s，δ=41.8%。采用2.1节所述测量方式，得到扫描后的H为994.9038 μm，与预测值的相对误差为1.23%；ΔH为138.7315 μm，与预测值的相对误差为3.88%；表面粗糙度Ra为2.4335 μm，与预测值的相对误差为5.4%，这表明模型的预测精度良好。其垂直于激光运动方向的截面如图9所示，可见激光从右向左依次搭接，且相邻道次的硬化层搭接效果较好。如图10所示，扫描后的3条路径的表面粗糙度分别为2.3258、2.2480、2.7267 μm，比扫描前的平均表面粗糙度5.2674 μm降低了53.8%，可见

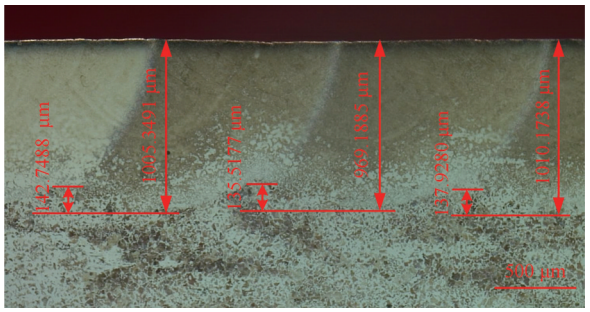


图9 激光扫描后的截面

Fig.9 Cross-section after laser scanning

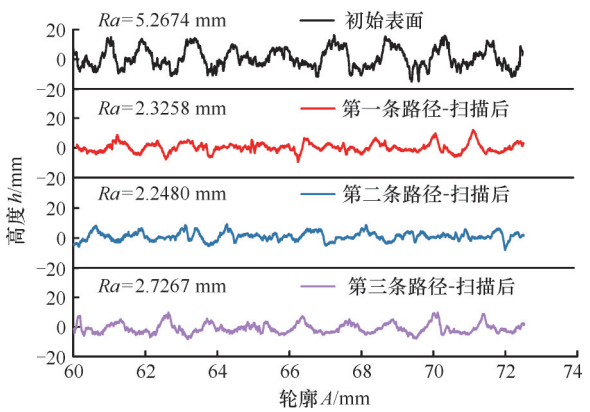


图10 抛光前后表面轮廓

Fig.10 Surface profile before and after polishing

激光扫描有效降低了H13钢表面原始粗糙度。

为进一步验证表面硬化及抛光效果，对H13钢表面激光扫描前后的三维形貌及硬化层硬度进行观察与分析。如图11所示，可见经过激光扫描，原始形貌已被重构，表面呈现规律性的道次分布。这是由于在高斯激光的作用下，受热区域熔化形成熔池。一般认为熔池主要在毛细力、热毛细力和反冲压力的作用下进行微观流动，其中毛细力主要受原始表面形貌的表面曲率的影响，热毛细力主要受高斯激光能量密度导致的表面温度梯度的影响，而反冲压力主要受材料蒸发速率的影响。三者共同主导着熔池的流动过程。在熔化阶段，随着温度升高，热毛细力占据主导地位，导致单道激光扫描后形成中间低、两侧高的形貌。随着温度持续升高，在激光中心部分可能存在蒸发区域，这会导致反冲压力，进一步促进中间低、两侧高的形貌生成。随着激光的移动，表面温度快速降低，熔池开始逐渐凝固，最终形成中间略低、两侧略高的“M”形表面结构[36]。

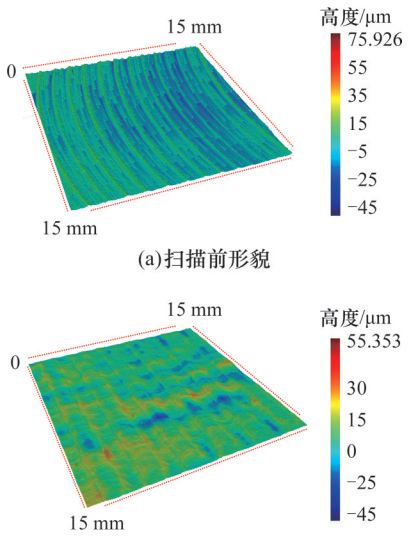


图11 激光扫描前后表面形貌

Fig.11 Surface morphology before and after laser scanning

对硬化层进行硬度测试，如图12所示，测试按以下两种方式进行：①相邻的3个道次且距离表面100 μm的深度处，每个道次内测试3个点位，共计测试9个点位（依次命名为No.1～No.9）；②单个道次内以100 μm为间距向下等距测量9个点位，测量3组，共计27个点位（依次命名为D1～D9）。

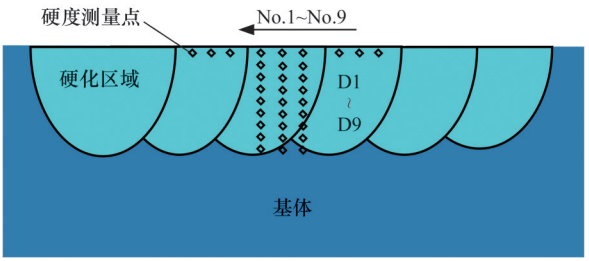


图12 测量方式示意图

Fig.12 Schematic diagram of measurement method

不同深度下硬度测量结果如图13所示，硬化层截面组织如图14所示。硬度测试结果显示：不同道次、同一深度（距离表面100 μm）处的平均硬度达510.67±19.11 HV0.5，约为基体硬度156.7±5.9 HV0.5的3.3倍，硬化效果显著，同时该深度下的硬度值波动较小，硬度均匀性较好，相邻道次的搭接效果良好。这是因为H13基体组织由珠光体及铁素体构成，如图14b所示，其硬度较低；而在激光的作用下H13钢表面发生组织相变，如图14d所示，组织转变为马氏体，使得表面产生硬化，硬度值上升。如图13所示，在深度100～700 μm区间内，平均硬度值较为接近，硬度值波动均较小，随着深度的增加，在距离表面900 μm处，平均硬度为294.03±102.41 HV0.5，可见此深度下的硬化效果下降，同时硬度值波动较大。这是由于在较深区域热量较低，在高斯激光的能量特性下，单个道次的较边缘部分吸收能量更少，导致该区域加热温度不高，奥氏体化不完全，出现类似亚温淬火的情况。如图14e、图14f所示，在较深的相邻道次交界区域，同时分布着珠

光体＋铁素体＋马氏体组织，硬度测量结果表明相邻道次的交界区域存在明显的硬度较低部分。综上所述，经过激光扫描，H13钢表层硬化效果显著，硬化层整体硬度分布较为接近，相邻道次搭接效果良好。

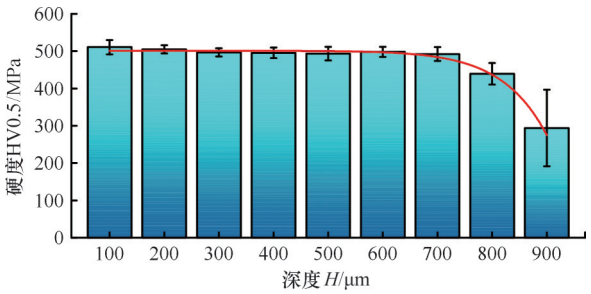
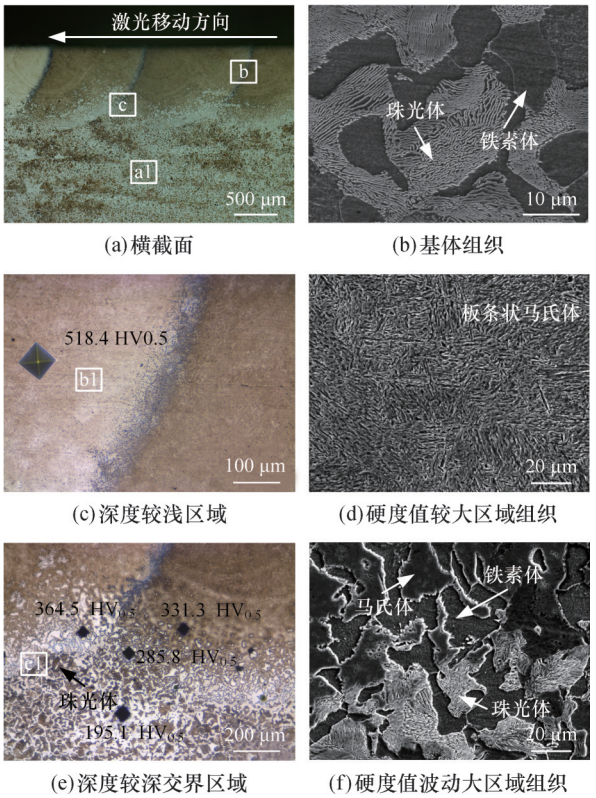


图13　不同深度硬度变化规律

Fig.13　Changing trend of hardness at different depths



(a)横截面　(b)基体组织

(c)深度较浅区域　(d)硬度值较大区域组织

(e)深度较深交界区域　(f)硬度值波动大区域组织

图14　硬化层截面组织

Fig. 14　Cross-section organization of the hardened layer

采用X射线衍射仪在30°～110°的衍射角范围对激光作用前后的H13钢表面进行扫描，步长为0.02°，每个衍射角保持时间0.5 s，结果如图15所示。通过对比PDF卡片可以发现，H13钢基体主要由α-Fe、$(Fe,Cr)_7C_3$、FeC_3构成，扫描后表面主要由α-Fe、γ-Fe、$(Fe,Cr)_7C_3$、FeC_3构成，其中基体中的α-Fe主要以铁素体及珠光体的组织形式存在，扫描后表面的α-Fe主要以马氏体的组织形式存在。这可以从衍射峰的变化得到相应解释，相比于初始表面，激光扫描后第2个衍射峰略微升高，第3个衍射峰略微降低，表明有更多的碳元素固溶到马氏体中从而有效硬化表层。由于激光扫描过程中较大的冷却速度增强了过冷奥氏体的稳定性，导致表面硬化后存在残余奥氏体。采用TESCAN VEGA扫描电镜及能谱仪对垂直于扫描路径截面的硬化区域与非硬化区域进行EDS线扫描，分别观察H13钢主要组成元素的变化情况。测量方式及其结果如图16所示，可见两个区

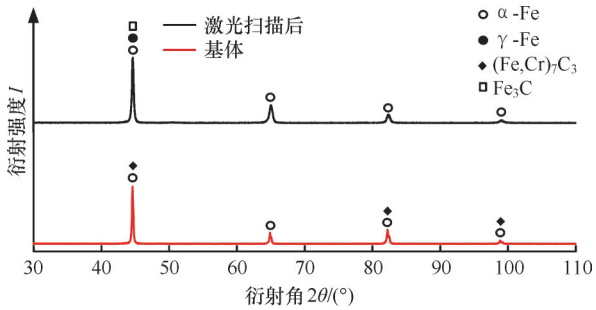


图15　激光扫描前后的表面XRD

Fig.15　Surface XRD before and after laser scanning

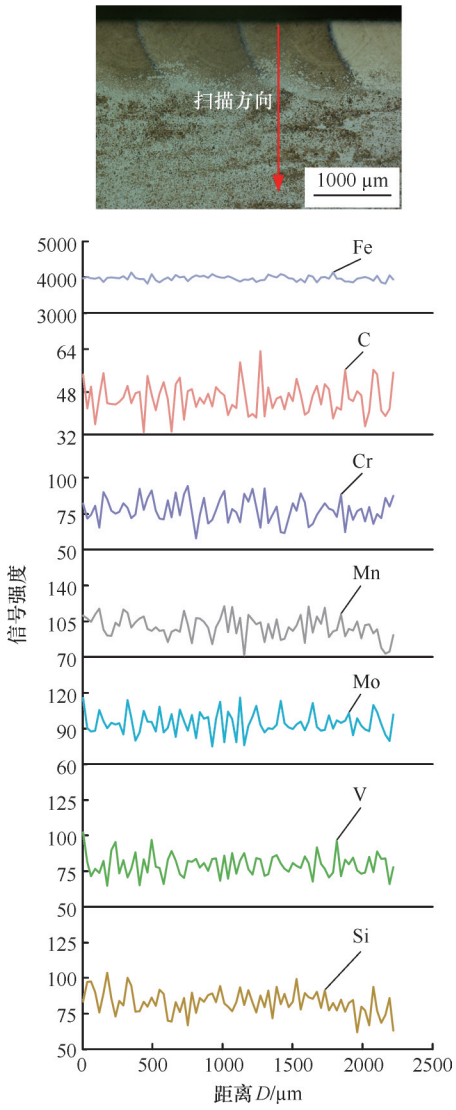


图16　EDS线扫描结果

Fig.16　EDS line scanning results

域的表面元素含量相近，硬化表面元素变化不明显。

4 结论

1)基于小样本数据驱动，以拉丁超立方抽样进行试验设计，构建激光扫描工艺参数激光功率P、扫描速度v和搭接率δ与淬透深度H、峰谷差值ΔH、表面粗糙度Ra三个响应目标之间的多目标预测模型并评估其预测能力，结果显示OOA-XGBOOST模型表现出更好的预测性能与泛化能力。

2)相比于MOPSO、MOGWO和NSGA-Ⅱ算法，改进DNSGA-Ⅱ算法在对小样本驱动的预测模型进行寻优的过程中表现出更好的多样性及搜索能力。

3)通过VIKOR结合CRITC构建综合评价排序方法对Pareto解集进行排序，得到最佳工艺参数组合。在该参数组合下进行试验，预测值与实际值的相对误差在6%以内，表明模型的预测精度良好。经激光扫描后H13钢表面粗糙度Ra降至2.4335 μm，降低了53.8%，最大平均硬度达510.67±19.11 HV0.5，约为基体的3.3倍，硬化与抛光效果显著。本文方法可为模具钢表面改性及其工艺参数寻优提供参考。

参考文献：

[1] VESELÝ Z, HONNEROVÁ P, HRUŠKA M, et al. Analysis of Laser Surface Absorptivity Modification for Selective Laser Hardening[J]. International Journal of Thermal Sciences, 2024, 200: 108982.

[2] WAGH S V, MORE S R, VENU MADHAV V V, et al. Effects of Low-power Laser Hardening on the Mechanical and Metallurgical Properties of Biocompatible SAE 420 Steel[J]. Journal of Materials Research and Technology, 2024, 30: 1611-1619.

[3] CHEN Zhenyu, YU Xiaodong, DING Ning, et al. Wear Resistance Enhancement of QT700-2 Ductile Iron Crankshaft Processed by Laser Hardening[J]. Optics & Laser Technology, 2023, 164: 109519.

[4] 杨仁人，林英华，彭龙生，等. 连续高功率激光辐照对55号钢组织和硬度的影响[J]. 中国激光，2023，50(16)：163-174.
YANG Renren, LIN Yinghua, PENG Longsheng, et al. Effect of Continuous High-power Laser Irradiation on Microstructure and Hardness of 55 Steel[J]. Chinese Journal of Lasers, 2023, 50(16): 163-174.

[5] ZHAO Shuang, YU Mingjie, YAN Ruopeng, et al. Surface Roughness and Microhardness Improvement of Laser Cladding Stainless-steel 316 by Laser Polishing Based on Multiple Remelting [J]. Optics & Laser Technology, 2024, 176: 110903.

[6] LIU Bo, HONG Jing, QIAN Yongfeng, et al. Simultaneous Improvement in Surface Quality and Hardness of Laser Shock Peened Zr-based Metallic Glass by Laser Polishing [J]. Optics & Laser Technology, 2024, 179: 111323.

[7] YI Chengnuo, CHEN Xiaoxiao, ZHOU Yuhang, et al. Effects of Scanning Speed and Scanning Times on Surface Quality of Line Spot Laser Polishing of Nickel-based Superalloys[J]. Journal of Materials Research and Technology, 2023, 26: 2179-2190.

[8] 周梦，吕志刚，邸若海，等. 基于小样本数据的BP神经网络建模[J]. 科学技术与工程，2022，22(7)：2754-2760.
ZHOU Meng, LÜ Zhigang, DI Ruohai, et al. BP Neural Network Modeling Based on Small Sample Data[J]. Science Technology and Engineering, 2022, 22(7): 2754-2760.

[9] 赵腾远，宋超，何欢. 小样本条件下江苏软土路基回弹模量的贝叶斯估计——基于静力触探数据与高斯过程回归的建模分析[J]. 岩土工程学报，2021，43(增刊2)：137-141.
ZHAO Tengyuan, SONG Chao, HE Huan. Bayesian Estimation of Resilience Modulus of Soft Soil Subgrade in Jiangsu Province under Small Sample Conditions—Modeling Analysis Based on Cone Penetration Data and Gaussian Process Regression[J]. Chinese Journal of Geotechnical Engineering, 2021, 43(S2): 137-141.

[10] 易茜，柳淳，李聪波，等. 基于小样本数据驱动的滚齿工艺参数低碳优化决策方法[J]. 中国机械工程，2022，33(13)：1604-1612.
YI Qian, LIU Chun, LI Congbo, et al. A Low Carbon Optimization Decision Method for Gear Hobbing Process Parameters Driven by Small Sample Data[J]. China Mechanical Engineering, 2022, 33(13): 1604-1612.

[11] 李泽亚，罗敏，张超勇，等. 数控铣床低碳高质建模及工艺参数优化[J]. 中国机械工程，2024，35(10)：1845-1851.
LI Zeya, LUO Min, ZHANG Chaoyong, et al. Low Carbon and High Quality Modeling and Processing Parameter Optimization of CNC Milling Machines[J]. China Mechanical Engineering, 2024, 35(10): 1845-1851.

[12] 李光保，高栋，路勇，等. 自适应卡尔曼滤波与PSO-GA-BP算法的机器人误差补偿[J]. 中国机械工程，2023，34(20)：2456-2465.
LI Guangbao, GAO Dong, LU Yong, et al. Adaptive Kalman Filtering and PSO-GA-BP Algorithm for Robot Error Compensation[J]. China Mechanical Engineering, 2023, 34(20): 2456-2465.

[13] 龚伟，赵文华，王心田，等. 基于机器学习的激光微纳加工研究：应用和前景[J]. 中国激光，2023，50(20)：2000001.
GONG Wei, ZHAO Wenhua, WANG Xintian, et al. Machine Learning for Laser Micro/Nano Manufacturing: Applications and Prospects[J]. Chinese Journal of Lasers, 2023, 50(20): 2000001.

[14] CHEN Tianqi, GUESTRIN C. XGBoost: a Scalable Tree Boosting[C]//ACM SIGKDD Conference on Knowledge Discovery and Data Mining. San Francisco, 2016: 785-794.

[15] ZHANG Fan, ZHU Zhengyang, LIU Jiefeng, et al. A Novel Concentration Prediction Technique of Carbon Monoxide (CO) Based on Beluga Whale Optimization-extreme Gradient Boosting (BWO-XGBoost)[J]. Journal of the Taiwan Institute of Chemical Engineers, 2025, 171: 106045.

[16] DEHGHANI M, TROJOVSKÝ P. Osprey Optimization Algorithm: a New Bio-inspired Metaheuristic Algorithm for Solving Engineering Optimization Problems[J]. Frontiers in Mechanical Engineering, 2023, 8: 1126450.

[17] LIANG Qiang, XU Yonghang, XU Binyuan, et al. Parameter Optimization for In-situ Synthesized TiB_2/TiC Par-

ticle Composite Coatings by Laser Cladding Based on OOA-RFR and U-NSGA-III[J]. Optics & Laser Technology, 2025, 181: 111755.

[18] YAN Pengcheng, LI Guodong, WANG Wenchang, et al. Qualitative and Quantitative Detection of Microplastics in Soil Based on LIF Technology Combined with OOA-ELM/SPA-PLS[J]. Microchemical Journal, 2024, 201: 110632.

[19] GAO Yan, CAO Baifu, YU Wenhao, et al. Short-term Wind Speed Prediction for Bridge Site Area Based on Wavelet Denoising OOA-transformer[J]. Mathematics, 2024, 12(12): 1910.

[20] DEB K, PRATAP A, AGARWAL S, et al. A Fast and Elitist Multiobjective Genetic Algorithm: NSGA-II[J]. IEEE Transactions on Evolutionary Computation, 2002, 6(2): 182-197.

[21] 郭庆辉，李媛，杨东升. 一种改进麻雀搜索算法的收敛性分析及应用[J]. 控制与决策，2024，39(8)：2502-2510.
GUO Qinghui, LI Yuan, YANG Dongsheng. Convergence Analysis and Application of an Improved Sparrow Search Algorithm[J]. Control and Decision, 2024, 39(8): 2502-2510.

[22] YANG Guangchao, WANG Liuhong, GU Wen, et al. Soil Ecological Risk Assessment of Ten Industrial Areas in China Based on the TRIAD and VIKOR Methods[J]. Ecological Indicators, 2024, 166: 112270.

[23] ATANGANA NJOCK P G, SHEN Shuilong, ZHOU Annan, et al. A VIKOR-based Approach to Evaluate River Contamination Risks Caused by Wastewater Treatment Plant Discharges[J]. Water Research, 2022, 226: 119288.

[24] LUO Yuyan, YANG Ziwei, QIN Yong. A Hybrid BWM-CRITIC-VIKOR Approach for Assessing Oil and Gas Risk Scenarios in Probabilistic Linguistic Term Set[J]. Heliyon, 2024, 10(19): e38514.

[25] DING Tingting, LIU Shushen, WANG Zejun, et al. A Novel Mixture Sampling Strategy Combining Latin Hypercube Sampling with Optimized One Factor at a Time Method: a Case Study on Mixtures of Antibiotics and Pesticides[J]. Journal of Hazardous Materials, 2024, 461: 132568.

[26] BOURCET J, KUBILAY A, DEROME D, et al. Representative Meteorological Data for Long-term Wind-driven Rain Obtained from Latin Hypercube Sampling — Application to Impact Analysis of Climate Change[J]. Building and Environment, 2023, 228: 109875.

[27] MCKAY M D, BECKMAN R J, CONOVER W J. A Comparison of Three Methods for Selecting Values of Input Variables in the Analysis of Output from a Computer Code[J]. Technometrics, 2000, 42(1): 55-61.

[28] VOŘECHOVSKÝ M. Hierarchical Refinement of Latin Hypercube Samples[J]. Computer-Aided Civil and Infrastructure Engineering, 2015, 30(5): 394-411.

[29] WANG Yujing, ZHAO Yanqing. Predicting Bedrock Depth under Asphalt Pavement through a Data-driven Method Based on Particle Swarm Optimization-back Propagation Neural Network[J]. Construction and Building Materials, 2022, 354: 129165.

[30] SHEN Qingkai, XUE Jiaxiang, ZHENG Zehong, et al. Machine Learning-based Prediction of $CoCrFeNiMo_{0.2}$ High-entropy Alloy Weld Bead Dimensions in Wire Arc Additive Manufacturing[J]. Materials Today Communications, 2024, 41: 110359.

[31] RIVERA-LOPEZ R, CANUL-REICH J, MEZURA-MONTES E, et al. Induction of Decision Trees as Classification Models through Metaheuristics[J]. Swarm and Evolutionary Computation, 2022, 69: 101006.

[32] BREIMAN L. Random Forests[J]. Machine Learning, 2001, 45(1): 5-32.

[33] HARANE P P, UNUNE D R, AHMED R, et al. Multi-objective Optimization for Electric Discharge Drilling of Waspaloy: a Comparative Analysis of NSGA-II, MOGA, MOGWO, and MOPSO[J]. Alexandria Engineering Journal, 2024, 99: 1-16.

[34] YukuiMEN, DONG Yanfang, ZENG Si, et al. Multi-objective Optimization of Solar-driven Hollow Fiber Membrane Dehumidification System Based on MOPSO[J]. Energy, 2024, 304: 132084.

[35] ZENG Quan, WANG Kelu, LU Shiqiang, et al. Modeling and Optimization of Energy Consumption, Surface Quality and Relative Density in GH3625 Superalloy by Laser Powder Bed Melting via RSM MOPSO and CRITIC-TOPSIS[J]. Optics & Laser Technology, 2025, 184: 112411.

[36] ZHANG Hang, SUN Xiaoyu, XU Xuebo, et al. Numerical Simulation of Surface Structures in Single and Multi-track Laser Polishing of NiP Alloy[J]. Journal of Manufacturing Processes, 2024, 132: 404-415.

（编辑　陈　勇）

作者简介：梁　强*（通信作者），男，1988年生，副教授。研究方向为表面激光改性、精密塑性成形工艺及优化等。E-mail：2017015@ctbu.edu.cn。

本文引用格式：

梁强，徐彬源，徐永航，等. 基于小样本数据驱动的H13钢表面激光硬化及抛光工艺参数优化[J]. 中国机械工程，2026，37(8)：1917-1927.

LIANG Qiang, XU Binyuan, XU Yonghang, et al. Optimization of Laser Hardening and Polishing Parameters of H13 Steel Surfaces with Small Sample Data Driven Process[J]. China Mechanical Engineering, 2026, 37(8): 1917-1927.