

## 基于机器学习的 K424 合金刻蚀深度预测

张青<sup>1,2,3</sup>, 乔红超<sup>1,2</sup>, 王顺山<sup>1,2,3</sup>, 赵吉宾<sup>1,2</sup>

(1. 中国科学院沈阳自动化研究所, 辽宁 沈阳 110016;

2. 中国科学院机器人与智能制造创新研究院, 辽宁 沈阳 110169; 3. 中国科学院大学, 北京 100049)

**摘要:**为探究水导激光加工过程中不同工艺参数对 K424 高温合金刻蚀深度的作用,对 K424 高温合金进行了包括激光功率、进给速度及加工次数在内的三个关键工艺参数的影响刻蚀实验,实验结果表明:较大的功率、较小的进给速度和多次加工会产生更深的刻蚀。此外采用 XGBoost、RF、BPNN 以及 SVR 四种模型建立了激光功率、进给速度和加工次数与加工深度之间的预测模型。在拟合效果上 XGBoost 与 SVR 模型表现优异,最大误差百分比均不到 0.3%;在预测结果方面显示,XGBoost 最大误差百分比 6.698%,优于另三种模型。最后得出 XGBoost 模型在拟合和预测 K424 高温合金加工深度方面有更好的性能。与传统的干式激光加工相比,水导激光加工技术减少了材料热损伤,提高了加工质量。该研究为水导激光加工 K424 高温合金提供了参考。

**关键词:**水导激光加工技术;K424 高温合金;XGBoost;刻蚀深度预测

中图分类号:TN249;TG665 文献标识码:A DOI:10.3969/j.issn.1001-5078.2024.05.007

## Depth prediction of K424 alloy etching based on machine learning

ZHANG Qing<sup>1,2,3</sup>, QIAO Hong-cai<sup>1,2</sup>, WANG Shun-shan<sup>1,2,3</sup>, ZHAO Ji-bin<sup>1,2</sup>

(1. Shenyang Institute of Automation, Chinese Academy of Sciences, Shenyang 110016, China;

2. Institutes for Robotics and Intelligent Manufacturing, Chinese Academy of Sciences, Shenyang 110169, China;

3. University of Chinese Academy of Sciences, Beijing 100049, China)

**Abstract:** In order to research the influence of process parameters on the etching depth of K424 high temperature alloy during water-jet guided laser (WJGL) processing, etching experiments on K424 high-temperature alloy are carried out on the influence of three key process parameters including laser power, feed rate and number of times of processing. The experimental results show that higher power, smaller feed rate and multiple times of machining produce deeper etching. In addition, the prediction model between laser power, feed rate and number of times of machining and depth of machining is established by using four models, XGBoost, RF, BPNN and SVR. The XGBoost and SVR models outperform in terms of fitting effect, with the maximum percentage of error being less than 0.3%; in terms of prediction results, it shows that XGBoost has a maximum percentage of error percentage of 6.698%, which is better than the other three models. Finally, it is concluded that XGBoost model has better performance in fitting and predicting the depth of machining of K424 high temperature alloy. The water-jet guided laser processing technique reduces material thermal damage and improves processing quality compared to conventional dry laser processing. This study provides a reference for water-guided laser processing of K424 high-temperature alloy.

基金项目:国家重点研发计划项目(No. 2022YFB4601600)资助。

作者简介:张青(1999-),男,硕士研究生,主要从事水导激光加工技术方面的研究。E-mail:zhangqing@sia.cn

通讯作者:乔红超(1982-),男,研究员,硕士研究生导师,主要从事激光加工方面的研究。E-mail:hcqiao@sia.cn

收稿日期:2023-08-07

**Keywords:** water-jet guided laser processing technology; K424 high-temperature alloy; XGBoost; etching depth prediction

## 1 引言

K424 高温合金是镍基沉淀硬化型等轴晶铸造高温合金,其特点是铝和钛元素含量高、密度低,具有较高的高温强度和塑性、良好的铸造性能<sup>[1]</sup>。由于其具有良好的物理性能,目前已广泛地应用于制作航空、航天发动机涡轮叶片、尾喷口调节器、整铸涡轮转子、导向器等部件<sup>[2]</sup>。由于 K424 合金中 Al 和 Ti 元素含量较高,导致合金中共晶组织含量多且尺寸大,存在明显的枝晶偏析,热裂倾向性较大<sup>[1-3]</sup>。因此 K424 高温合金加工难度大。沈嵘<sup>[4]</sup>等人通过电解磨削复合加工方法对 K424 高温合金进行加工,加工结果表明,该方法能实现镍基铸造高温合金的孔加工,加工效率高、锥度好、表面质量好。王旭<sup>[5]</sup>等人使用飞秒激光加工镍基高温合金喷油孔,得到了质量优良的孔壁。除此之外还有一些特种加工方法,如激光打孔、电火花打孔等。然而采用电解磨削复合加工的稳定性和精度无法保障,电解产物可能污染环境;电火花加工效率低,成本较高;而传统激光加工技术加工后的工件存在热影响区、毛刺、熔渣和重铸层等缺陷,且在加工过程中需要把激光光束聚焦到工件表面,不利于加工 K424 高温合金。利用水导激光加工技术可以很好的解决这些缺陷,该技术是利用全反射原理,激光光束在稳定的水射流内部中不断反射,最后抵达工件表面,这解决了激光加工过程中的聚焦问题,此外还通过水流冲刷和吸热等可以及时带走熔渣和多余的能量,提高加工质量。目前关于水导激光加工技术中的工艺参数对 K424 高温合金的加工质量影响方面的研究较少。而在当今的制造业中,利用机器学习辅助生产已经成为一种趋势<sup>[6]</sup>。使用机器学习算法来研究激光加工技术中工艺参数对工件加工质量影响的方法越来越重要,还可以通过已有数据训练,实现对加工质量参数的预测。

本文为了更好地研究水导激光加工技术中激光功率、进给速度和加工次数三个工艺参数对加工 K424 高温合金深度的影响,通过设计三因素刻蚀实验,利用显微镜测量刻蚀深度,根据结果总结规律。此外简述四种机器学习算法的基本原理,并利用这些机器学习算法对实验数据进行研究,来获得激光

功率、进给速度和加工次数三个工艺参数与加工深度之间的预测模型。

## 2 实验材料与方法

### 2.1 实验设备与材料

通过实验室已有的 K424 合金材料和波长为 550 nm 的绿光水导激光设备,进行多次刻蚀实验。水导激光设备基本结构如图 1 所示,由聚焦透镜、耦合腔、玻璃窗口、喷嘴等结构组成,激光源发射出的激光通过聚焦透镜、玻璃窗口进入耦合腔,之后在喷嘴处发生全反射耦合进稳定的水射流中。实验加工后的工件使用蔡康光学的电脑型体视显微镜 XTL-3400C 和搭配的 DS-3000 二维测量软件来观察和测量刻蚀深度。刻蚀深度结果对水导激光加工技术加工 K424 合金具有重要意义。

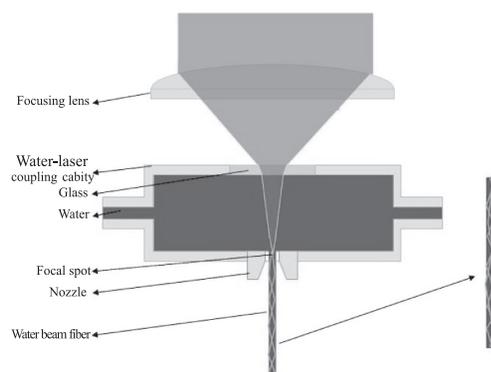


图 1 水导激光设备基本组成

Fig. 1 Basic components of water-jet guided laser equipment

在进行实验之前,先要对合金材料进行预处理。刻蚀实验采用厚度为 1 mm,利用水导激光加工技术切割成的 15 mm × 15 mm 大小的 K424 高温合金来作为待加工件,实验加工后的试件如图 2 所示。

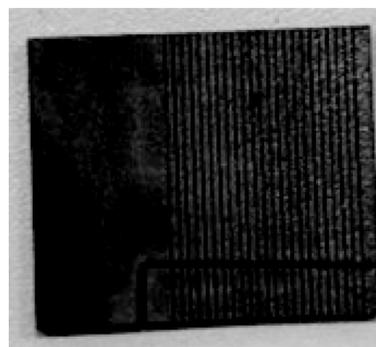


图 2 K424 高温合金试件

Fig. 2 K424 high temperature alloy test piece

在进行刻蚀实验前,先将 K424 高温合金试件用无水乙醇清洗干净,当表面无明显污垢后再通过水导激光进行刻蚀试验。为了便于进行刻蚀深度测量,在刻蚀实验结束后再对试件进行一次切片,之后使用砂纸 C2000 将 K424 高温合金切片两侧进行打磨,直至切片两侧光滑,并露出金属光泽后,利用显微镜进行深度测量。

### 2.2 实验方法

利用实验室水导激光装备通过图 3 所示的 1~3 次加工轨迹来回对材料试件进行刻蚀试验。试验部分加工效果与测量结果如图 4 所示。

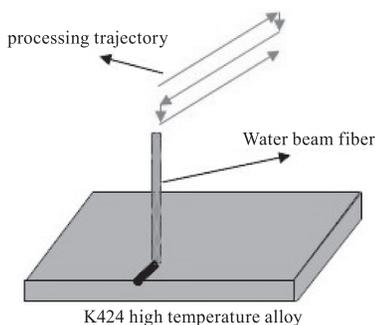


图 3 K424 高温合金 1~3 次刻蚀加工轨迹

Fig. 3 K424 high temperature alloy 1~3 times etching processing trajectory

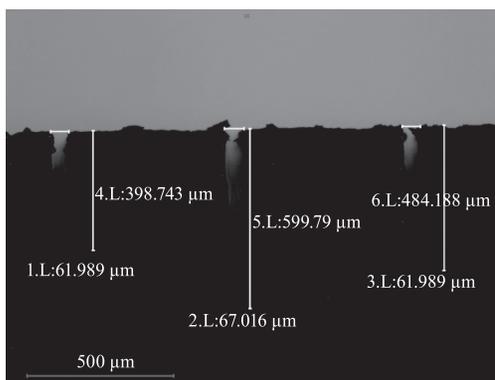


图 4 试验后试件刻蚀深度

Fig. 4 Etching depth of test piece after experiment

将水导激光设备参数设置为水流直径 60 μm,压力 225 bar,通过调整不同的激光功率、进给速度以及加工次数进行实验。实验完成后利用显微镜 XTL-3400C 测量通过水导激光技术加工后得到的试件刻蚀深度。图 4 中三道刻痕都是 3 次加工后的结果,从左到右工艺参数分别为激光功率百分比 17%,进给速度 2.5 mm/s;激光功率百分比 21%,进给速度 2 mm/s;激光功率百分比 13%,进给速度 2 mm/s。通过设计不同工艺参数,再利用实验室水导激光装备对 K424 试件材料开展刻蚀加工,从而得到一系列刻

蚀深度。

## 3 模型算法介绍

### 3.1 模型数据

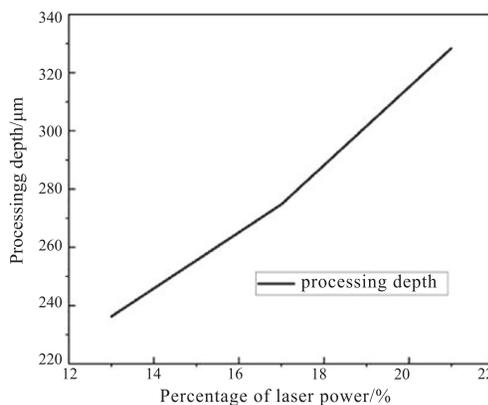
对激光功率可设置为 13%、17%、21% 三个区间对应功率为 5.8 W、7.4 W、9.02 W;设置进给速度为 1.5 mm/s、2 mm/s 和 3 mm/s;设置加工次数为 1、2、3。通过实际加工后,利用 XTL-3400C 显微镜测得的合金加工深度数据如表 1 所示。

表 1 刻蚀实验加工数据及加工结果

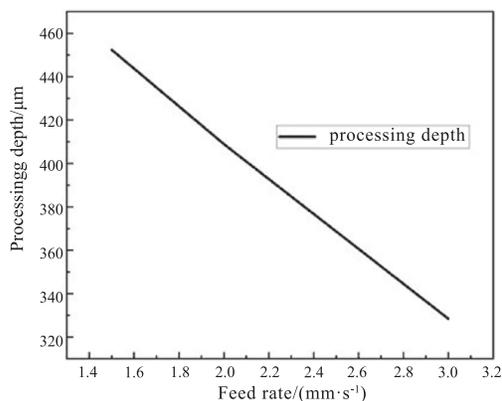
Tab. 1 Etching test processing data and processing results

serial number	Percentage of laser power / %	Feed rate / (mm · s <sup>-1</sup> )	Processing times	Processing depth / μm
1	21	2	1	204.398
2	13	2	1	172.277
3	17	1.5	1	209.424
4	17	3	1	152.461
5	17	3	2	274.764
6	17	2	2	370.303
7	13	1.5	2	360.209
8	13	3	2	236.23
9	21	1.5	2	452.356
10	21	2	2	408.874
11	21	3	2	328.377
12	17	1.5	3	598.115
13	17	3	3	398.743
14	21	2	3	599.79
15	13	2	3	484.188

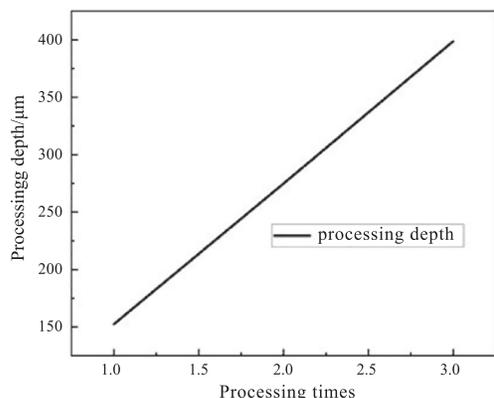
其中各工艺参数对加工 K424 高温合金深度影响如图 5 所示。



(a) 进给速度 3 mm/s、加工次数 2 时,刻蚀深度随激光功率百分比变化图



(b) 激光功率百分比21%、加工次数2时,刻蚀深度随进给速度变化图



(c) 激光功率17%、进给速度3 mm/s时,刻蚀深度随加工次数变化图

图5 各工艺参数对刻蚀深度的影响

Fig. 5 Effect of each process parameter on etching depth

由图5可知,当较大的激光功率、较小的进给速度以及多次加工的工艺参数可以用于加工 K424 高温合金更深的刻蚀。将表3数据用于回归分析来预测加工深度,解决回归问题的常用方法有线性回归、逻辑回归等等,本文采用了极端梯度提升算法(Extreme Gradient Boosting, XGBoost)、随机森林模型(Random Forests, RF)、BP神经网络(Back Propagation Neural Network, BPNN)、支持回归向量机(Support Vector Regression, SVR)四种方法进行分析,并通过对比各自的拟合误差,选择最优的模型算法。

### 3.2 XGBoost 模型

极端梯度提升算法是一种集成学习算法,具有灵活性高、可预测性强、泛化能力强、模型训练效率高优点。目前集成学习算法中集成方法主要有两种:Boosting 和 Bagging<sup>[7]</sup>。两者都是将多个弱模型结合成一个强模型的方法,不同的是 Boosting 方法训练时会根据训练结果调整训练集中样本比重,再进行下一次训练,赋予弱模型不同的权重,而 Bagging 方法则是每次训练都均匀抽取训练集中数据进

行训练,弱模型权重相同。

XGBoost 模型首先被 Chen 和 Guestrin<sup>[8]</sup>提出,模型使用了一种新的稀疏感知算法,用于稀疏数据和加权分位数草图的近似树学习,并在许多机器学习挑战中使用。该模型可将许多弱模型组合到一起形成一个强模型,通过对这些弱模型赋予不同的权重,再进行加法等方式将弱模型输出结果组合到一起得到最终输出来提高预测性能。XGBoost 算法的弱模型可以使用决策树模型或者线性分类器,其中决策树可通过节点递归分裂的贪心准则来进行生成,同时并且为了避免过拟合,在损失函数中引入了 L1、L2 正则化项以及可以像随机森林一样支持列采样。XGBoost 模型是一种大规模并行增强树模式,是目前最快、最好的增强树模型,在许多领域得到应用<sup>[9]</sup>。Zhang<sup>[10]</sup>等人利用光谱和极端梯度提升决策树(XGBoost)研究了火箭储罐用铝锂合金激光焊缝强度的回归预测,并提出了一种新的回归模型 PFP-CA-XGBoost,并于其他预测模型进行对比后发现新模型在 R2 值上表现最好。Lu<sup>[11]</sup>等人基于 XGBoost 模型基础上,提出了一种基于时间序列的分割算法(T-XGBoost),通过对高速钢(W18Cr4V)、碳素结构钢(Q235A)和 2A12 铝合金三种材料进行切削分析,得出 T-XGBoost 算法明显优于 XGBoost 算法。

### 3.3 随机森林模型

随机森林指的是利用多棵决策树对样本进行训练并预测的一种分类器。该分类器是由 Leo Breiman<sup>[12]</sup>等人在 2001 年提出的一种机器学习算法。该模型是以决策树为基本分类器的一个集成学习模型,在模型训练任务中增加了随机属性选择,具有很高的预测准确率和泛化性,较好的克服了使用决策树时可能产生的过拟合缺陷。通过各个决策树对输入样本的输出结果进行投票或者取平均值来决定最终模型输出。随机森林是 Bagging 集成方法中最具有代表性的算法,该算法简单、易于实现、计算开销小,在很多现实任务中展现出强大的性能<sup>[7]</sup>。相比 Boosting 集成方法,Bagging 可以实现并行计算,可节省训练时间。Kwak<sup>[13]</sup>等人采用随机森林回归机器学习算法预测了定向凝固 TiAl 合金的力学性能,并且对比了双输入变量与单输入变量预测模型,结果表明用双输入变量预测优于单输入变量预测结果。董师师<sup>[14]</sup>等人对随机森林理论进行了系统的分析,并

介绍了随机森林算法改进方向。

### 3.4 BP 神经网络

目前,人工神经网络具有复杂模式和进行联想、推理记忆的功能,它是解决某些传统方法所无法解决的问题的有力工具<sup>[15]</sup>。其中 BP 神经网络在 1986 年,由 Rumelhart<sup>[16]</sup> 等人描述了一种按照误差逆向传播算法训练的多层前馈神经网络。神经网络的基本单元类似人脑中的神经元,由输入层(input layer)、隐含层(hidden layer)和输出层(output layer)构成,如图 6 所示。

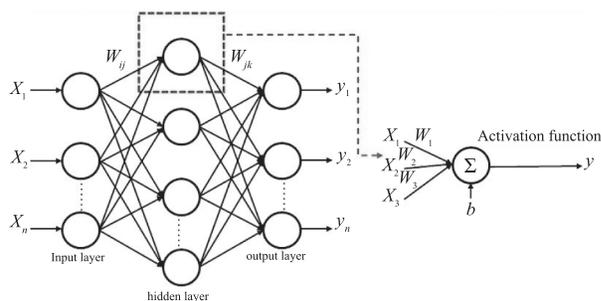


图 6 神经网络基本单元

Fig. 6 Neural network basic unit

图中输入 $[X_1, X_2, \dots, X_n]$ 到输入层,经过图 5 右侧乘以权重  $W_{ij}$  后加上  $b$  再经过激活函数(activation function)输出  $y$  到输出层,即一个神经元的输出是另一个神经元的输入。BPNN 中的反向误差传播是指利用最后一层神经网络输出值与实际值的误差,通过算法对权重  $W_{ij}$  和  $b$  进行更新来优化网络。Gao<sup>[17]</sup> 等人通过 BPNN、RF 算法和响应面法(RSM)方法建立了沉积输入参数与加工状态参数、几何形态和力学性能参数之间的预测关系,分析了 30 组 316L 不锈钢单轨槽覆层的加工温度和熔池特性,预测结果表明 BPNN 模型优于 RF 模型和 RSM 方法。金峤<sup>[18]</sup> 等人针对 BPNN 改进提出了动量法、遗传算法、混沌法等方法。目前 BPNN 在神经网络中应用广泛。

### 3.5 支持回归向量机

支持回归向量机(SVR)是支持向量机(SVM)的一种,可用于回归预测。1995 年, Cortes<sup>[19]</sup> 等人提出了支持向量机技术,且证明了利用多项式输入变换的支持向量网络具有较高的泛化能力。SVM 应用广泛,可在语音识别、文字识别、人脸检测等领域使用。目前对 SVM 改进有很多方法,例如对 SVM 中核函数进行修改,像 PmSVM、DAG-SVM 等;在或者将 SVM 与其他模型结合,如 KNN、AdaBoost 等<sup>[20]</sup>。Sun<sup>[21]</sup> 等人提出并采用了一种改进的网格搜索算法,对 SVR 中的核函数和

惩罚函数进行优化,再训练 SVR 得到最优解,并通过实验得到验证。

## 4 结果与分析

XGBoost、SVR、BP 神经网络以及 Random Forests 可以在 python 环境中进行配置。XGBoost 所需模块 xgboost、sklearn、sklearn.model\_selection 和 sklearn.metrics 等;RF 所需模块 sklearn.ensemble、sklearn.metrics 等;BPNN 所需模块 tensorflow、pandas 等;SVR 模型所需模块 sklearn.svm、sklearn.model\_selection 等。

### 4.1 预测模型参数设置

对于 XGBoost 模型,设置  $\text{max\_depth} \in \{3, 4, 5\}$ ;  $\text{n\_estimators} \in \{400, 500, 600\}$ ;  $\text{learning\_rate} \in \{0.1, 0.2, 0.3, 0.4\}$ ;  $\text{gamma} \in \{0.1, 0.2, 0.3\}$ ;  $\text{min\_child\_weight} \in \{1, 2, 3\}$ ;  $\text{subsampling} \in \{0.5, 0.6, 0.7\}$ ;  $\text{colsample\_bytree} \in \{0.7, 0.8, 0.9, 1\}$ 。通过 GridSearchCV 函数,先将除  $\text{max\_depth}$  外参数固定,再全局手搜索  $\text{max\_depth}$  最优参数,之后再依次搜索其他的参数,这样做可以减少调参时间。最后得到最优参数为  $\text{param\_grid} = \{ 'max\_depth': [4], 'n\_estimators': [600], 'learning\_rate': [0.4], 'gamma': [0.3], 'reg\_alpha': [0.1], 'reg\_lambda': [0.1], 'min\_child\_weight': [1], 'colsample\_bytree': [0.7], 'subsampling': [0.6] \}$ , 分类器选择线性分类器,损失函数设置为“r2”。

对于 RF 模型,设置  $\text{n\_estimators}$  为 95,  $\text{criterion} = 'mse'$ , 利用 spearmanr, pearsonr 两个函数观察实验值和模型预测值之间的 Spearman 秩相关系数和皮尔森相关性系数以及相应的  $P$  值,分别为  $\{0.982, 8.16 \times 10^{-11}\}$ 、 $\{0.992, 6.41 \times 10^{-13}\}$ 。可以看到  $P$  值均小于 0.05,说明模型预测值与实验值成正相关线性比例。

对于 BPNN 模型,由于训练数据集很少,所以采用三层神经网络结构。输入层单元个数与工艺参数个数一致为 3。中间隐含层的单元个数设置为  $\{5, 6, 7, 8, 9, 10, 11, 12\}$ , 迭代次数设置 300, 学习率 0.05, 损失函数参数设置“MAE”, 设置从数据集中切分出验证集的比例 validation\_split 为 0.2, 优化器参数设置“adam”, 激活函数选择 softplus 函数,因此需要对训练数据中加工深度进行最大最小值均一化处理,最终预测结果为最终输出值乘以加工深度最大值减去最小值的数值,再加上最小值。通过函数

mean\_absolute\_error 来计算模型预测值和实际实验数据值之间的平均绝对误差来选择最优的单元个数,如图7所示。

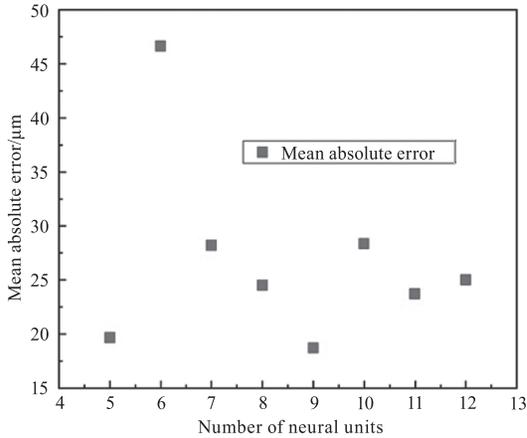


图7 不同隐含层神经元个数训练后的平均绝对误差  
Fig. 7 Mean absolute error after training with different number of hidden layer neural units

根据图7,可知当隐含层神经元个数为9时平均绝对误差最小,此时的损失收敛图如图8所示。

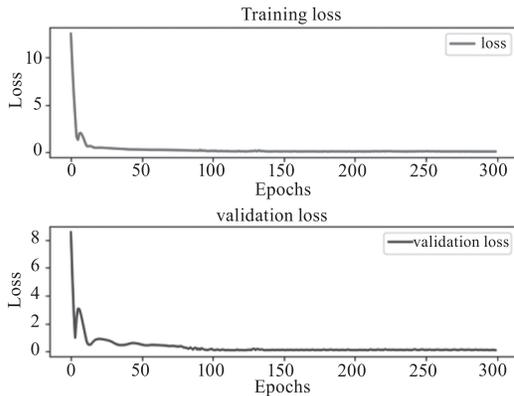


图8 损失收敛图  
Fig. 8 Loss convergence plot

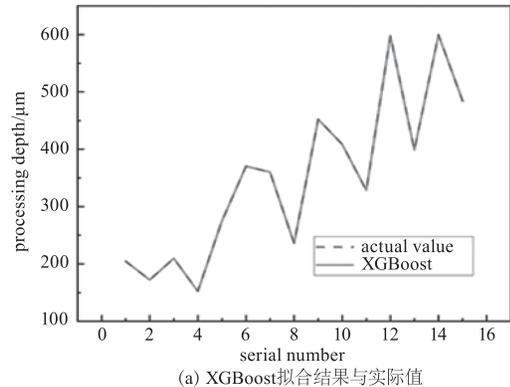
通过图8,可知训练集损失 loss 与验证集损失 validation loss 走势基本一致,训练网络过程正常,无过拟合现象。

对于 SVR 模型,设置错误项的惩罚因子  $C \in \{0.1, 1, 10, 100, 1000\}$ ;核函数 kernel  $\in \{ "rbf", "poly", "sigmoid" \}$ ;核函数的系数 gamma  $\in \{ 1 \times 10^{-7}, 1 \times 10^{-4}, 1 \times 10^{-3}, 1 \times 10^{-2}, 0.1 \}$ ;多项式核函数的次数 degree  $\in \{ 3, 4 \}$ 。通过 GridSearchCV 函数全局搜索最优参数为: {“C”:1000,“degree”:3,“gamma”:0.1,“kernel”:rbf},训练后模型在训练集上得分0.999。

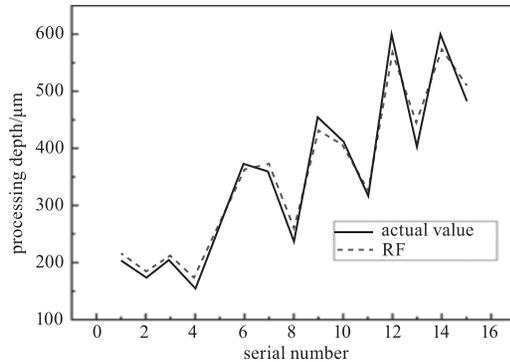
#### 4.2 拟合结果对比

四种网络模型经过参数设置和实验数据训练

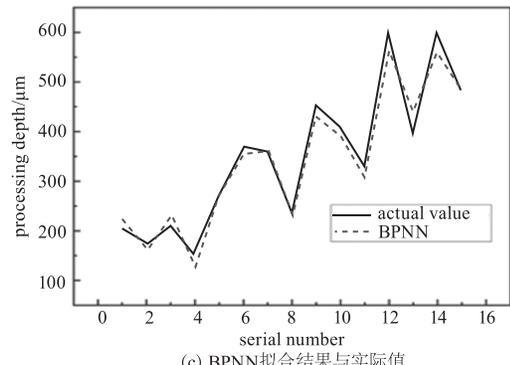
后,得到最优模型。再将模型对实验数据进行拟合输出结果如图9所示。



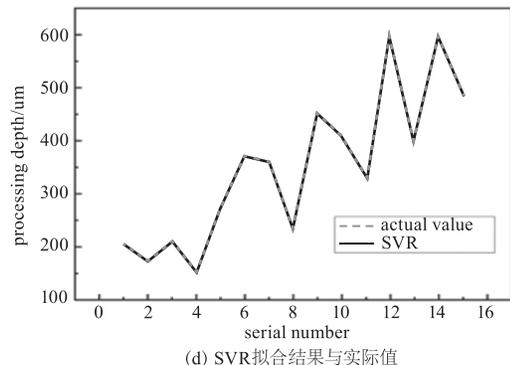
(a) XGBoost拟合结果与实际值



(b) RF拟合结果与实际值



(c) BPNN拟合结果与实际值



(d) SVR拟合结果与实际值

图9 不同模型拟合结果与实际结果对比图

Fig. 9 Plot of different model fitting results vs. actual results

通过图9中四个图的对比,可以看 XGBoost 模型与 SVR 模型对实验数据的拟合曲线与实际刻蚀

深度曲线基本重合,最大误差百分比分别是 0.223 %、0.105 %,平均绝对误差百分比分别是 0.081 %、0.039 %,误差均在 1 μm 以内;而 RF 与 BPNN 模型对实验数据拟合后与实际刻蚀深度的最大误差百分比分别是 11.373 %、16.142 %,平均绝对误差百分比分别是 4.934 %、5.848 %,最大误差在 40 μm 左右,其余误差基本在 20 μm 以内。如图 10 所示,XGBoost 模型与 SVR 模型对实验数据拟合后的深度数据值与实际刻蚀深度的残差明显小于另两种模型。

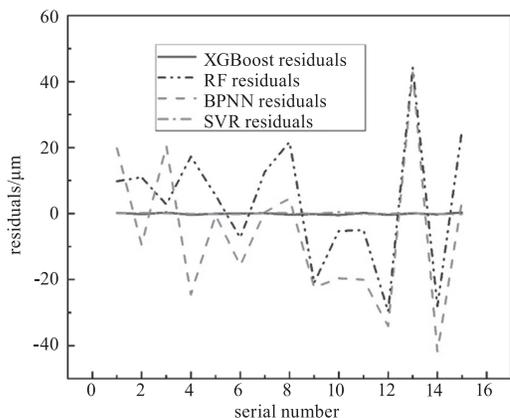


图 10 四种模型拟合结果与实际加工深度的残差  
Fig. 10 Residuals of the four model fitting results versus the actual depth of machining

利用 sklearn 模块中的三个函数分别计算 4 个模型的均方根误差 RMSE、平均绝对误差 MAE 以及 R2 的值,并进行对比,如表 2 所示。

根据表 2 中三种误差的大小,明显看出 SVR 模型的拟合效果最好、其次是 XGBoost、RF、BPNN 模型。在训练集上四种算法的 R2 大小都近似为 1,这

证明四种算法的拟合效果较好。

表 2 三种误差分析

Tab. 2 Three types of error analysis

Network Models	RMSE/μm	MAE/μm	R2
XGBoost	0.265	0.234	0.999
RF	20.010	16.453	0.979
BPNN	22.841	18.701	0.973
SVR	0.147	0.122	0.999

### 4.3 预测结果对比

使用测试集中三个工艺参数设置激光设备加工后,刻蚀加工效果与测量结果如图 11 所示。

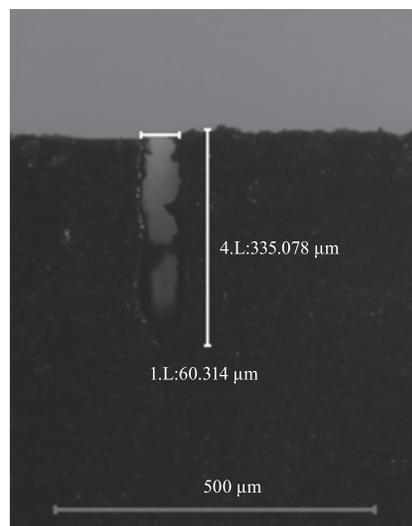


图 11 测试集经过试验后刻蚀深度

Fig. 11 Etching depth of the test set after testing

图 11 中刻痕对应的工艺参数为激光功率百分比 13 %,进给速度 2 mm/s,加工次数两次。测试集水导激光设备参数设置如表 3 所示。

表 3 测试数据及网络模型预测结果

Tab. 3 Test data and network model prediction results

serial number	Laser power percentage / %	Feed rate / (mm · s <sup>-1</sup> )	Processing times	actual value/μm	Xgboost / μm	RF/μm	BPNN/μm	SVR/μm
1	13	2	2	355.078	335.966	352.977	320.175	319.996
2	17	1.5	2	412.225	422.712	380.504	395.273	414.676
3	21	1.5	1	233.167	217.549	241.937	263.084	244.359

根据表 3 中的数据,绘制柱状图如图 12 所示。通过观察可知,XGBoost 模型以及随机森林模型在泛化性能上相比另外两种模型好一些,SVR 虽然拟合效果强但是泛化性能不如 XGBoost 模型。XGBoost 模型、RF 模型、BPNN 模型以及 SVR 模型最大

预测误差分别为 6.698 %、7.695 %、12.831 % 和 9.880 %,平均绝对预测误差分别为 4.875 %、4.016 %、8.924 % 和 5.092 %。其中 XGBoost 模型的预测误差均不超过 10 %,且拟合效果良好,误差基本在 20 μm 以内。

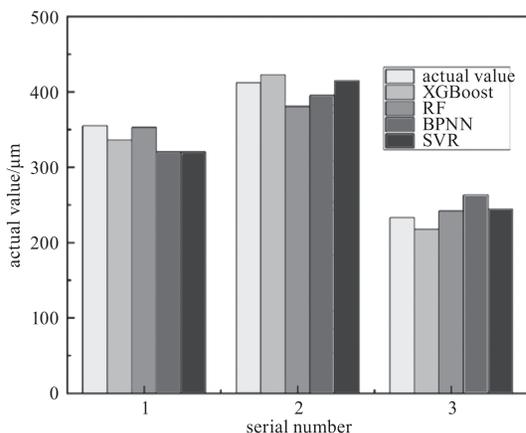


图 12 四种模型预测深度与实际刻蚀深度的柱状图

Fig. 12 Histogram of the predicted depth for the four models versus the actual etching depth

## 5 结 论

本文通过 XGBoost、RF、BPNN 以及 SVR 四种模型建立了水导激光三个参数:激光功率、进给速度、加工次数与加工 K424 高温合金深度之间的关系,得到以下结论:

(1) 通过刻蚀实验结果表明:较大的功率、较小的进给速度和多次加工会产生更深的刻蚀;

(2) 在训练集拟合方面,XGBoost 和 SVR 模型明显优于 RF 和 BPNN。XGBoost 和 SVR 模型的最大误差百分比分别是 0.223%、0.105%,平均绝对误差百分比分别是 0.081%、0.039%,明显优于 RF 与 BPNN 的最大误差百分比 11.373%、16.142% 和平均绝对误差百分比 4.934%、5.848%,且最大误差都出现在加工深度较浅的数据上;

(3) 在测试集方面,XGBoost 最大预测误差 6.698%、平均绝对预测误差 4.875%,且拟合效果良好,在预测 K424 高温合金深度方面明显优于 RF、SVR 和 BPNN 模型;

(4) 不足之处在于实际测量刻蚀深度时存在测量误差,水导激光加工过程中也会有其他因素干扰刻蚀结果;最后的数据集数量较少,不支持深层神经网络训练。

综上,XGBoost 模型在基于水导激光三个加工参数,即激光功率、进给速度以及加工次数,对 K424 高温合金刻蚀深度预测方面优于 RF、BPNN 和 SVR 模型。本文为水导激光技术加工 K424 高温合金研究提供了参考。

## 参考文献:

[1] Teng Xiaotian, Qiao Hongchao, Cao Zhihe, et al. Research

on thermal damage mechanism of K424 superalloy processed with water-jet guided laser[J]. Laser & Infrared, 2022, 52(2): 170-175. (in Chinese)

滕啸天, 乔红超, 曹治赫, 等. 水导激光加工 K424 高温合金热损伤机制研究[J]. 激光与红外, 2022, 52(2): 170-175.

[2] Zhao Zhan, Dong Jianxin, Zhang Maicang, et al. Microstructure and susceptibility to hot tearing of K424 nickel-based superalloys for turbocharger turbine wheels[J]. Chinese Journal of Engineering, 2016, 38(10): 1429-1437. (in Chinese)

赵展, 董建新, 张麦仓, 等. 增压涡轮用 K424 高温合金组织特征及热裂倾向性[J]. 工程科学学报, 2016, 38(10): 1429-1437.

[3] Yang Jingming, Lou Yanchun, Tai Guoyan, et al. Effect of heat treatment process on microstructure and properties of K424 superalloy[C]//China Mechanical Engineering Society, Foundry Productivity Promotion Center. Proceedings of the 2018 China Foundry Activity Week, 2018: 12. (in Chinese)

杨敬明, 娄延春, 税国彦, 等. 热处理工艺对 K424 高温合金组织和性能的影响[C]//中国机械工程学会, 铸造行业生产力促进中心. 2018 中国铸造活动周论文集, 2018: 12.

[4] Shen Zhenrong, Xu Zhengyang, Zhu Di. The study on electrochemical grinding drilling of cast nickel-base superalloy[C]//Specialty Machining Branch of Chinese Mechanical Engineering Society. Proceedings of the 14th National Conference on Special Machining. Harbin Institute of Technology Press, 2011: 5. (in Chinese)

沈峥嵘, 徐正扬, 朱荻. 镍基高温合金 K424 电解磨削复合打孔技术研究[C]//中国机械工程学会特种加工分会. 第 14 届全国特种加工学术会议论文集. 哈尔滨工业大学出版社, 2011: 5.

[5] Wang Xu, Zhang Zhihao, Li Liqun, et al. Femtosecond laser precision machining of fuel injection holes in nickel-based superalloys[J]. Optical and Precision Engineering, 2023, 31(6): 849-859. (in Chinese)

王旭, 张子浩, 李俐群, 等. 镍基高温合金喷油孔的飞秒激光精密加工[J]. 光学精密工程, 2023, 31(6): 849-859.

[6] Hao J B, Yang S, Le X W, et al. Bead morphology prediction of coaxial laser cladding on inclined substrate using machine learning[J]. Journal of Manufacturing Processes, 2023, 98: 159-172.

- [7] Lü Hongyan, Feng Qian. A review of random forest algorithm[J]. Journal of Hebei Academy of Sciences, 2019, 36(3):37-41. (in Chinese)  
吕红燕,冯倩. 随机森林算法研究综述[J]. 河北省科学院学报, 2019, 36(3):37-41.
- [8] Chen T, Guestrin C. XGBoost: a scalable tree boosting system[J/OL]. <https://arxiv.org/pdf/1603.02754.pdf>.
- [9] Zou M, Jiang W G, Qin Q H, et al. Optimized XGBoost model with small dataset for predicting relative density of Ti-6Al-4V parts manufactured by selective laser melting [J]. Materials, 2022, 15(15):5298.
- [10] Zhang Z F, Huang Y M, Qin R, et al. XGBoost-based on-line prediction of seam tensile strength for Al-Li alloy in laser welding: Experiment study and modelling[J]. Journal of Manufacturing Processes, 2021, 64:30-44.
- [11] Lu C, Fei J Y, Meng X Z, et al. Thermal error prediction and compensation of digital twin laser cutting based on T-XGBoost[J]. Sensors, 2022, 22(18):7022.
- [12] Breiman L. Random forests[J]. Machine Learning, 2001, 45(1):5-32.
- [13] Kwak S M, Kim J W, Ding H S, et al. Machine learning prediction of the mechanical properties of  $\gamma$ -TiAl alloys produced using random forest regression model[J]. Journal of Materials Research and Technology, 2022, 18:520-530.
- [14] Dong Shishi, Huang Zexue. A brief theoretical overview of random forests [J]. Journal of Integration Technology, 2013, 2(1):1-7. (in Chinese)  
董师师,黄哲学. 随机森林理论浅析[J]. 集成技术, 2013, 2(1):1-7.
- [15] Zhou Zheng. Survey of current progress in BP neural network[J]. Shanxi Electronic Technology, 2008, 137(2):90-92. (in Chinese)  
周政. BP神经网络的发展现状综述[J]. 山西电子技术, 2008, 137(2):90-92.
- [16] Rumelhart D, Hinton G, Williams R. Learning representations by back-propagating errors [J]. Nature, 1986, 323(9):533-536.
- [17] Gao J L, Wang C, Hao Y B, et al. Prediction of molten pool temperature and processing quality in laser metal deposition based on back propagation neural network algorithm [J]. Optics & Laser Technology, 2022, 155:108363.
- [18] Jin Q, Fang Suai, Yan Shi, et al. Methods to Improve BP network[J]. Journal of Shenyang Arch. and Civ. Eng. Univ., 2001, (3):197-199, 205. (in Chinese)  
金峤,方帅,阎石,等. BP网络模型的改进方法综述[J]. 沈阳建筑工程学院学报:自然科学版, 2001, (3):197-199, 205.
- [19] Cortes C, Vapnik V. Support-vector networks [J]. Mach Learn, 1995, 20(9):273-297.
- [20] Liu Fangyuan, Wang Shuihua, Zhang Yudong. Overview on models and applications of support vector machine [J]. Computer System and Applications, 2018, 27(4):1-9. (in Chinese)  
刘方园,王水花,张煜东. 支持向量机模型与应用综述[J]. 计算机系统应用, 2018, 27(4):1-9.
- [21] Sun Y, Ding S, Zhang Z. et al. An improved grid search algorithm to optimize SVR for prediction [J]. Soft Comput, 2021, 25(4):5633-5644.