

基于 NSDBO 算法的超声振动挤压工艺参数优化

贾海利, 孙 锐

(天津职业技术师范大学 机械工程学院, 天津 300222)

摘要: 为获得表面硬度和残余应力的最优组合, 采用超声振动挤压工艺对 304 不锈钢工件进行正交实验, 获取了加工数据; 利用 PSO-SVR 算法和线性回归方法分别建立了表面硬度和残余应力的预测模型; 采用 NSDBO 算法对加工参数 (主轴转速、进给速度、超声功率及静挤压量) 进行了多目标优化设计; 最后, 对求解获得的工艺参数组合进行实验并验证了其有效性。结果表明, 主轴转速为 $115 \sim 347 \text{ r} \cdot \text{min}^{-1}$ 、进给速度为 $0.056 \sim 0.130 \text{ mm} \cdot \text{r}^{-1}$ 、静挤压量为 $49.8 \sim 71.7 \mu\text{m}$ 、超声功率为 $20.155 \sim 32.206 \text{ W}$ 时, 可获得表面硬度和残余应力之间的最佳平衡, 此时残余应力为 $-373.175 \sim -487.436 \text{ MPa}$ 、表面硬度为 $10.837 \sim 15.689 \text{ HRS}$ 。上述方法不仅可获得最优加工参数组合、提升表面性能和寿命, 同时可以缩短实验周期、降低成本, 提高加工效率, 也为超声振动挤压加工技术在航空航天及其他工业领域中的应用提供了理论基础和实验支持。

关键词: 超声振动挤压加工; 表面硬度; 残余应力; NSDBO 算法; 预测模型; 多目标优化

DOI: 10.13330/j.issn.1000-3940.2024.06.016

中图分类号: TG376.1

文献标志码: A

文章编号: 1000-3940 (2024) 06-0134-07

Optimization on ultrasonic vibration extrusion process parameters based on NSDBO algorithm

Jia Haili, Sun Rui

(School of Mechanical Engineering, Tianjin University of Technology and Education, Tianjin 300222, China)

Abstract: In order to obtain the optimal combination of surface hardness and residual stress, the orthogonal experiment of 304 stainless steel workpiece was carried out by ultrasonic vibration extrusion process to obtain the processing data, and the prediction models of surface hardness and residual stress were established respectively by PSO-SVR algorithm and linear regression method. Then, the multi-objective optimization design on the processing parameters of spindle speed, feeding speed, ultrasonic power and static extrusion amount was conducted by NSDBO algorithm. Finally, the validity of the process parameters combination obtained from the solution was experimentally verified. The results show that the optimal balance between surface hardness and residual stress is obtained as the residual stress range of $-373.175 \sim -487.436 \text{ MPa}$ and the hardness range of $10.837 \sim 15.689 \text{ HRS}$ when the spindle speed is $115 \sim 347 \text{ r} \cdot \text{min}^{-1}$, the feeding speed is $0.056 \sim 0.130 \text{ mm} \cdot \text{r}^{-1}$, the static extrusion amount is $49.8 \sim 71.7 \mu\text{m}$ and the ultrasonic power is $20.155 \sim 32.206 \text{ W}$. These methods can not only obtain the optimal combination of processing parameters, improve the surface properties and life, but also shorten the experimental period, reduce the cost, improve the machining efficiency, and also provide the theoretical basis and experimental support for the application of ultrasonic vibration extrusion processing technology in aerospace and other industrial fields.

Key words: ultrasonic vibration extrusion processing; surface hardness; residual stress; NSDBO algorithm; predictive models; multi-objective optimization

随着航空航天工业技术的发展, 对零件表面性能和寿命的要求越来越高。零件在使用中受力、温度和腐蚀等因素的影响^[1], 且长时间承受高载荷,

导致工作表面产生疲劳裂纹。此外, 裂纹随着损伤的累积而逐渐增长, 极易导致零件发生失效。其中, 轴类零件不停地承受循环载荷是最主要的失效形式之一。因此, 迫切需要通过表面强化技术来提高材料的抗疲劳性能。超声振动挤压强化技术^[2]是一种结合静挤压力和高频动态冲击力的表面强化技术, 通过静压和超声波振动^[3]作用在试样表面, 实现表面材料的塑性流动, 超声波振动可软化金属材料, 引起表层金属塑性变形, 提高试样表面变形层的均匀性, 显著提高处理试样的表面硬度^[4]、残余

收稿日期: 2024-03-09; 修订日期: 2024-05-25

基金项目: 2021 年天津市新一代人工智能科技重大专项 (21ZXJBGX00020)

作者简介: 贾海利 (1979-), 女, 博士, 副教授, 硕士生导师

E-mail: highly0811@163.com

通信作者: 孙 锐 (1999-), 男, 硕士研究生

E-mail: sl2692492580@outlook.com

应力和耐腐蚀^[5]等性能。超声波振动系统的运动能转化为加工面层中的塑性变形能，加工表面的硬度增加，表面和沿试件深度方向的残余应力发生变化。在静态挤压和动态冲击共同作用下，试件的硬化面层与未硬化部分形成界面，可提高强度和耐磨性。

通过优化工艺参数^[6]来提高材料的表面性能，二者之间并非简单的单调递增关系。一些学者^[7]指出，残余应力和硬度这两个指标往往不会同时达到最佳状态，且过度的超声振动挤压可能会造成表面损伤，从而降低材料的疲劳性能。查旭明等^[8]研究了超声冲击工艺对钛合金性能的影响，发现优化参数存在优化临界值，因此，需要更加谨慎地进行工艺参数的选择和优化。为了对工艺参数进行目标优化，Lu X H 等^[9]采用响应面方法建立了维氏硬度预测模型，并根据其对 Inconel 718 镍基合金表面维氏硬度的影响对参数进行了排序。陈云峰等^[10]为了改善 0Cr13Ni5Mo 不锈钢的综合性能，通过实验和数值模拟的方法研究了不同超声振动滚压静压力对其残余应力和粗糙度的影响。Tang J Y 等^[11]提出了一种考虑试件的初始梯度残余应力和显微硬度的数值模型，通过沿深度方向对试件进行划分和逐层分配材料属性，可以提高残余应力的预测精度。张剑飞等^[12]提出了结合遗传算法和混合蛙跳算法改进 BP 神经网络，并进行了表面粗糙度优化。

综上所述，国内外众多研究学者对超声振动挤压表面强化进行了单一性能的研究，但对超声振动挤压过程中工件的表面性能（表面硬度、残余应力）的多目标综合分析相对较少。为获得 304 不锈钢良好的表面性能和寿命，本文采用正交实验设计方法对 304 不锈钢棒料进行了超声振动挤压加工实验，研究了主轴转速、进给速度、静挤压量及超声功率对表面性能的影响；运用 PSO-SVR 算法建立并检验了表面硬度和残余应力预测模型；应用一种新型多目标优化算法——非支配排序的蜣螂优化算法（Non-dominated Sorting Dung Beetle Optimizer, NSDBO）获得了最优的加工参数组合；通过实验验证了预测值与实验值的误差低于 5.00%，表明该方法在提升超声挤压加工技术的生产效率、降低成本方面具有显著效果。

1 超声振动挤压加工实验与分析

超声振动挤压加工技术是一种具有巨大潜力的

先进制造技术。该工艺系统通常包括超声波发生器、换能器、变幅杆、工具头及数控车床等关键组件，构成了一个综合的加工平台。这套系统利用超声波能量直接作用于材料加工过程，通过换能器将电能转化为机械能，再经变幅杆放大后传递至工具头，从而在数控车床的精确控制下实现加工目标。超声振动挤压加工原理如图 1 所示，其中， n 为主轴转速， V_f 为进给速度， d 为静挤压量， P 为超声功率。

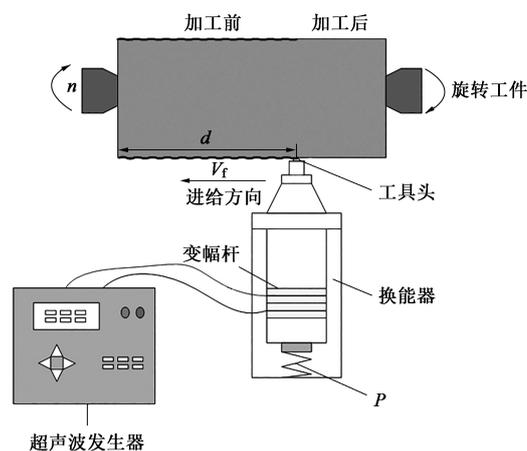


图 1 超声振动挤压加工原理图

Fig. 1 Principle diagram of ultrasonic vibration extrusion processing

为探究超声振动挤压加工参数对 304 不锈钢棒料的影响，本次超声振动挤压加工实验试件选用长度为 100 mm、直径为 $\Phi 20$ mm 的 304 不锈钢棒料。在试件进行超声振动挤压加工之前，对其进行了车削粗加工，车削后的工件初始表面状态的硬度值为 6.9 HRS，残余应力值为 -180.22 MPa。304 不锈钢材料的物理及力学性能如表 1 所示。

表 1 304 不锈钢的物理及力学性能

Table 1 Physical and mechanical properties of 304 stainless steel

参数	密度/ ($\text{g} \cdot \text{cm}^{-3}$)	抗拉强 度/MPa	屈服强 度/MPa	伸长 率/%	弹性模 量/GPa	电阻率/ ($\times 10^{-6} \Omega \cdot \text{m}$)
数值	7.93	520	205	40	200	0.73

实验选用了 4 因素 5 水平的正交实验方案，共进行了 25 组超声振动挤压加工实验，检测主轴转速、进给速度、超声功率和静挤压量对表面硬度和表面残余应力的影响情况。通过在试件表面施加预定载荷并测量印痕的深度来测量试件表面硬度，选用衢州爱普计量仪器有限公司的 HRS-150C 洛氏硬度计。试件表面残余应力的测量选用 PROTO/LXRD 高速 X 射线衍射仪。超声振动挤压加工实验现场及

加工完成后的试件分别如图 2 和图 3 所示。实验设计及测量数据如表 2 所示。

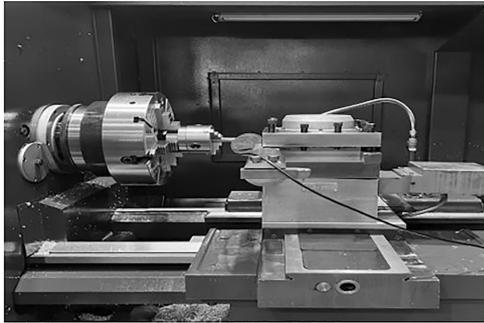


图 2 超声振动挤压加工现场图

Fig. 2 Site map of ultrasonic vibration extrusion processing



图 3 加工完成后的 304 不锈钢棒料

Fig. 3 304 stainless steel bars after processing

实验数据表明, 超声振动挤压加工后工件的表面硬度和残余应力得到显著改善。实验 13 和实验 25 的表面硬度值最高; 实验 1、实验 7 和实验 16 的表面残余应力值较高。同时, 主轴转速、进给速度、静挤压量和超声功率对表面硬度和残余应力的影响存在明显的交互耦合作用, 例如在一定的加工范围内, 提高主轴转速有助于增加表面硬度, 但对控制表面残余应力的效果较差。因此, 需基于以上实验数据构建以表面硬度和残余应力为优化目标的数学预测模型, 以求得最佳超声振动挤压工艺参数组合。

2 基于 PSO-SVR 算法的超声振动挤压加工优化模型

粒子群优化 (Particle Swarm Optimization, PSO) 算法^[13], 源自对自然界中鸟群和鱼群行为的观察, 属于启发式全局优化算法的范畴。借鉴生物群体的社会行为特征, 尤其是个体间的协作和信息共享机制, 用以寻求多维复杂优化问题的解决策略。算法初始化时随机生成解空间中一群“粒子”, 每个

表 2 超声振动挤压加工实验数据

Table 2 Experiment date of ultrasonic vibration extrusion processing

序号	主轴转速 $n/(\text{r} \cdot \text{min}^{-1})$	进给速度 $V_f/(\text{mm} \cdot \text{r}^{-1})$	静挤压量 $d/\mu\text{m}$	超声功率 P/W	表面硬度/HRS	表面残余应力/MPa
1	150	0.01	20	10	8.0	-576.17
2	150	0.03	40	20	7.3	-465.58
3	150	0.06	60	30	8.8	-465.77
4	150	0.09	80	40	9.2	-495.90
5	150	0.12	100	50	7.8	-254.10
6	200	0.01	40	30	9.8	-511.18
7	200	0.03	60	40	12.2	-598.35
8	200	0.06	80	50	10.4	-179.61
9	200	0.09	100	10	14.4	-367.42
10	200	0.12	20	20	7.9	-262.60
11	250	0.01	60	50	10.3	-457.96
12	250	0.03	80	10	13.6	-392.29
13	250	0.06	100	20	16.1	-438.75
14	250	0.09	20	30	9.4	-267.96
15	250	0.12	40	40	14.3	-475.32
16	300	0.01	80	20	12.6	-518.24
17	300	0.03	100	30	14.2	-438.66
18	300	0.06	20	40	9.7	-409.54
19	300	0.09	40	50	9.6	-217.10
20	300	0.12	60	10	13.2	-202.13
21	350	0.01	100	40	10.4	-399.84
22	350	0.03	20	50	7.4	-286.49
23	350	0.06	40	10	9.5	-239.03
24	350	0.09	60	20	13.9	-406.72
25	350	0.12	80	30	16.2	-470.75

粒子代表潜在的解。通过迭代过程, 粒子根据个体和群体的经验更新自身的位置和速度, 逐步逼近全局最优解。PSO 算法的实现简洁、计算成本较低, 使其在求解连续非线性问题上尤为有效。然而, PSO 算法在应对高维问题和复杂约束条件时可能面临挑战, 特别是在不可能穷尽所有变量组合以寻找最优解的场景下。

针对此种情况, 支持向量回归 (Support Vector Regression, SVR) 提供了一种有效的辅助手段。SVR 能在满足自变量与响应变量之间约束的基础上, 优化一个或多个响应变量。结合 PSO 算法, 可以在维持变量约束条件的同时, 对解决方案进行优化, 以实现响应变量的最大化或最小化处理。这种整合方法, 通过迭代更新粒子的速度和位置 (式 (1) 和式 (2)), 不断优化解决方案, 以求达到或超越预期的性能指标。

$$V_j(k) = w \times V_j(k-1) + c_1 \times rand_1 \times [p_{best} - X_j(k-1)] + c_2 \times rand_2 \times [g_{best} - X_j(k-1)] \quad (1)$$

$$X_j(k) = X_j(k-1) + V_j(k) \quad (2)$$

式中： $V_j(k)$ 为第 k 次迭代时第 j 个粒子的速度； $V_j(k-1)$ 为第 $(k-1)$ 次迭代时第 j 个粒子的速度； w 为惯性权重向量； c_1 和 c_2 分别为个体和社会学习因子； $rand_1$ 和 $rand_2$ 为 $[0, 1]$ 之间的随机数； $X_j(k)$ 为第 k 次迭代时第 j 个粒子的位置； $X_j(k-1)$ 为第 $(k-1)$ 次迭代时第 j 个粒子的位置； p_{best} 为粒子的最佳位置； g_{best} 为整个群体的最佳位置。

2.1 基于粒子群优化算法的 SVR 的实现

PSO-SVR 算法是以 PSO 算法为核心，结合 SVR^[14] 以解决模型预测问题，在经历过相同的归一化处理后，开始初始化 SVR 模型中的超参数，包括核函数类型、惩罚参数 C 、核函数参数等。可以将优化问题视为在高维空间中进行二次回归求解，其函数表达式为：

$$F(x') = w \times \varphi(x') + b \quad (3)$$

式中： $F(x')$ 为输入变量 x' 的函数表达式； $\varphi(x')$ 为模型输入变量 x' 的映射变换； b 为偏差项，用来确定超平面与原点之间的距离。

根据参考文献 [13]，回归支持向量机可以表示为：

$$\min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l (\xi_i + \xi_i^*) \quad (4)$$

$$\text{s. t. } \begin{cases} F(x_i) - y_i \leq \varepsilon + \xi_i^* \\ y_i - f(x_i) \leq \varepsilon + \xi_i \\ \xi_i, \xi_i^* \geq 0 \end{cases} \quad (5)$$

式中： C 为正实数惩罚因子，表示控制训练误差的成本，通常用于平衡规则项和经验误差项； ξ_i 为第 i 个训练样本的正松弛变量； ξ_i^* 为第 i 个训练样本的松弛程度在对偶中的表示，反映了第 i 个训练样本在 SVR 对偶问题优化过程中的松弛程度； $i=1, 2, \dots, l$ ； l 为训练样本的总数； y_i 为第 i 个训练样本的类别标签； ε 为允许的训练损失，决定了预测值与实际值之间的偏差在此范围内时不会被惩罚； x_i 为第 i 个训练样本的特征向量； $f(x_i)$ 为决策边界函数。

使用粒子群算法来优化 SVR 模型的超参数。这涉及到初始化种群，设定适应度函数（即需要最小化的目标函数），并通过迭代更新种群中个体的位置和速度，以寻找最优的超参数组合。由于残余应力和硬度优化目标的绝对值越大越好，为求解方便，将硬度设置为负数来求解极值，式 (6) 为目标函数和自变量的约束条件。

$$\begin{cases} \min \sigma(n, V_f, d, P) \\ \min [-H(n, V_f, d, P)] \\ 150 \text{ r} \cdot \text{min}^{-1} \leq n \leq 350 \text{ r} \cdot \text{min}^{-1} \\ 0.01 \text{ mm} \cdot \text{r}^{-1} \leq V_f \leq 0.12 \text{ mm} \cdot \text{r}^{-1} \\ 20 \mu\text{m} \leq d \leq 100 \mu\text{m} \\ 10 \text{ W} \leq P \leq 50 \text{ W} \end{cases} \quad (6)$$

式中： H 为表面硬度； δ 为残余应力。

多元线性回归模型是一种统计模型，用于描述被解释变量与多个解释变量之间的线性关系。该模型假设被解释变量可以通过线性组合和权重系数与多个解释变量的相互作用进行解释。这种模型的目标是通过最小化预测值与实际观测值之间的差异来找到最佳的线性关系，如式 (7) 所示。

$$y' = k_0 + k_1 n + k_2 V_f + k_3 d + k_4 P \quad (7)$$

式中： y' 为目标函数； k_0 为当所有自变量均为 0 时， y' 的值； $k_1 \sim k_4$ 分别为 n 、 V_f 、 d 、 P 的权重系数。

通过此模型，可以很好地预测和分析主轴转速、进给速度、静挤压量、超声功率对工件表面硬度和残余应力的影响，也可以利用该模型优化工艺参数。结合实验数据最终获得的表面硬度 H 和残余应力 σ 的多元二次回归方程为：

$$-H = 4.5292 + 0.017257n + 11.8264V_f + 0.046712d - 0.043943P \quad (8)$$

$$\sigma = -463.574 + 0.19257n + 779.4472V_f - 0.6359d + 0.76894P \quad (9)$$

2.2 优化模型预测值与实验值的分析

对经过优化的 SVR 模型进行了训练，以便精确识别并学习训练集样本中的模式与特征。为了全面评价模型的预测准确度，通过对比预测结果与实际值，获得的统计指标包括确定系数 R^2 、均方根误差 $RMSE$ 和均方误差 MSE ，这些指标显示了模型的拟合质量与预测能力。其中，确定系数 R^2 值 (0.99867、0.99964) 接近 1，表明模型能够极为精确地反映观测数据的变异性。此外，较低的均方根误差 $RMSE$ 值 (1.88、4.16) 和均方误差 MSE 值 (3.54、7.37) 进一步确认了模型在预测时的精确性和可靠性。制作预测结果与真实结果对比图及误差迭代曲线图，如图 4 和图 5 所示，通过对比发现，模型预测结果与实验数据之间的一致性较高，验证了模型的有效性及其高预测精度。

3 基于 NSDBO 算法的加工工艺多目标优化

多目标优化方法提供了一种解决涉及多个相互

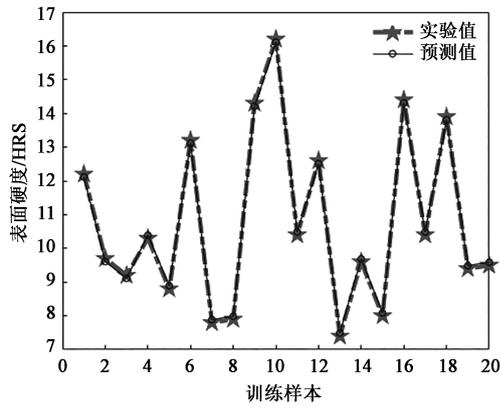


图 4 表面硬度实验值与预测值对比

Fig. 4 Comparison of surface hardness between experimental and predicted values

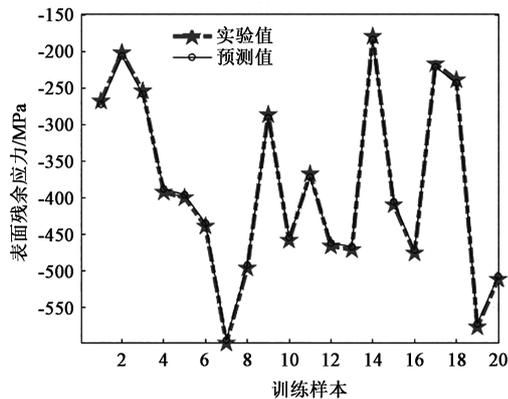


图 5 表面残余应力实验值与预测值对比

Fig. 5 Comparison of surface residual stress between experimental and predicted values

独立目标的复杂模型优化问题的有效策略。2022 年提出的蜣螂优化算法^[15]是一种新兴的基于非支配排序机制的群体智能优化技术。该算法受到蜣螂自然行为模式的启发，如滚球、繁殖、觅食及偷窃等，依据这些行为设计了一套综合的搜索策略，称为“Roll-rolling-spawning-foraging-stealing”模型。在加工表面多目标优化时，如需平衡表面粗糙度、残余应力、疲劳强度与硬度等多方面的性能指标，蜣螂优化算法展现出其寻找最优加工参数组合的潜力，有效地整合和平衡了各项目标指标，以达成最优化加工效果。

3.1 NSDBO 优化算法流程

NSDBO 优化算法的灵感来源于生物进化机制，通过模拟蜣螂群体的行为模式来寻求优化解。算法通过随机初始化一群蜣螂个体，为搜索过程提供初始解集。基于每个蜣螂个体当前所处的位置，计算其适应度值，即对应的多目标函数值，从而

评估每个个体的性能。此外，记录下每个蜣螂个体在搜索过程中发现的最优位置。随着迭代的进行，NSDBO 算法根据每个蜣螂的当前位置和速度，以及群体中个体的局部和全局最优解信息，更新蜣螂的速度和位置。算法的主要步骤包括种群初始化、适应度计算、位置与速度的更新、最优解的追踪与更新，以及终止条件的判断。这一过程持续进行，直至迭代次数 k 达到最大迭代次数 k_{max} 。算法流程如图 6 所示。

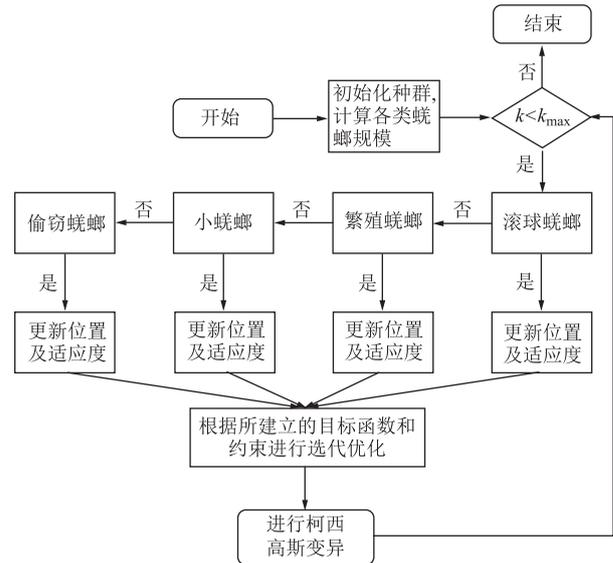


图 6 NSDBO 算法流程图

Fig. 6 Flow chart of NSDBO algorithm

3.2 NSDBO 算法参数设置及结果分析

在 NSDBO 算法的执行过程中，种群大小和搜索范围是两个关键参数，他们直接影响算法的搜索能力和计算复杂度。种群较小，可能导致搜索空间未被充分探索，限制了解的多样性；而过大的种群尺寸则会显著增加计算资源的需求，影响算法的执行效率。基于此，将种群大小设置为 100，能够在保证解的多样性和加快算法收敛的同时，有效平衡计算负担。同样，搜索范围设定为 500，以覆盖广泛的潜在解空间。随着迭代次数的增加，Pareto 前沿解集趋于均匀分布，且前沿曲线更加平滑，表明解的质量得到了显著提升。较高的迭代次数也意味着较低的运算速度。综合考虑效率和效果，最终选择 1000 次迭代作为终止条件。Pareto 最优解集的分布情况如图 7 所示。

以表面硬度和残余应力为多目标，经优化后确定了超声振动挤压加工的最优工艺参数范围，具体数据如表 3 所示。

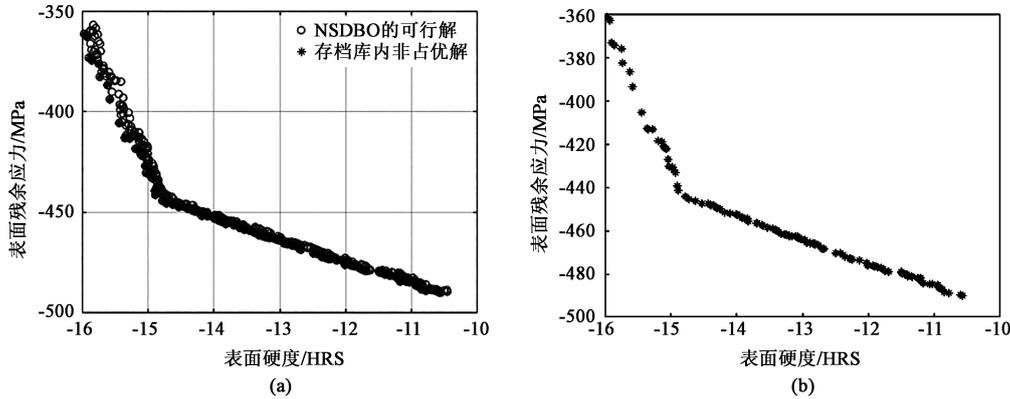


图 7 Pareto 迭代图

(a) 迭代第 1000 次 (b) Pareto 前沿解集

Fig. 7 Pareto iterative diagrams

(a) Iteration for 1000 times (b) Frontier solution set for Pareto

表 3 NSDBO 算法的 Pareto 优解集和目标函数值

Table 3 Optimal solution set and objective function values of Pareto for NSDBO algorithm

序号	主轴转速 $n/(r \cdot \text{min}^{-1})$	进给速度 $V_f/(\text{mm} \cdot \text{r}^{-1})$	静挤压量 $d/\mu\text{m}$	超声功率 P/W	表面硬度/HRS	表面残余应力/MPa
I	115	0.120	60.0	21.083	10.837	-487.436
II	173	0.120	57.0	30.147	11.866	-476.581
III	192	0.081	67.0	20.309	12.178	-373.175
IV	216	0.110	49.8	30.324	12.603	-468.660
V	235	0.120	70.0	20.266	12.956	-464.246
VI	281	0.090	55.0	30.806	13.704	-456.254
VII	302	0.070	57.0	20.155	14.050	-452.500
VIII	317	0.130	63.2	30.495	14.350	-448.352
IX	345	0.056	60.0	30.447	15.312	-408.372
X	347	0.088	71.7	32.206	15.689	-382.384

分析表 3 发现，最优工艺参数为：主轴转速为 $115 \sim 347 \text{ r} \cdot \text{min}^{-1}$ 、进给速度为 $0.056 \sim 0.130 \text{ mm} \cdot \text{r}^{-1}$ 、静挤压量为 $49.8 \sim 71.7 \mu\text{m}$ 、超声功率为 $20.155 \sim 32.206 \text{ W}$ ，对应的最佳表面残余应力为 $-373.175 \sim -487.436 \text{ MPa}$ 、表面硬度为 $10.837 \sim 15.689 \text{ HRS}$ 。为验证 NSDBO 算法在超声振动挤压工艺参数优化中的有效性，从优化结果中随机选择了 5 组，即第 II、III、V、VIII 和 X 组进行了实验验证。表 4 为实验值与优化值之间的对比结果。

通过对 NSDBO 算法在超声振动挤压工艺参数优化中的实验验证，可以清晰看到实验结果与优化结果的误差小于 5.00%，且 NSDBO 算法能够在不同目标之间找到一组最优解，使得各个目标函数均能得到较好的优化结果，为以表面残余应力和表面硬度为多目标的优化问题提供了有效的解决方案。

表 4 表面性能的实验值和优化值

Table 4 Experimental and optimal values of surface properties

序号	表面硬度			表面残余应力		
	优化值/ HRS	实验值/ HRS	误差/ %	优化值/ MPa	实验值/ MPa	误差/ %
II	11.866	11.475	3.41	-476.581	-460.770	3.43
III	12.178	12.750	4.49	-373.175	-389.057	4.08
V	12.956	12.671	2.25	-464.246	-443.810	4.60
VIII	14.350	13.775	4.17	-448.352	-437.739	2.42
X	15.689	14.970	4.80	-382.384	-400.550	4.54

4 结论

(1) 通过 PSO-SVR 算法和线性回归方法分别

建立表面硬度和残余应力的优化模型, 并通过评估指标确定系数 R^2 、均方根误差 $RMSE$ 和均方误差 MSE 进行了模型精度验证, 表明模型预测精度较高, 可利用该模型进行工艺参数优化。

(2) 采用 NSDBO 算法完成多目标优化求解, 获得超声振动挤压加工最优工艺参数组合, 并经实验验证了有效性。最优的工艺参数为: 主轴转速为 $115 \sim 347 \text{ r} \cdot \text{min}^{-1}$, 进给速度为 $0.056 \sim 0.130 \text{ mm} \cdot \text{r}^{-1}$, 静挤压量为 $49.8 \sim 71.7 \mu\text{m}$, 超声功率为 $20.155 \sim 32.206 \text{ W}$ 。对应的最佳表面残余应力为 $-373.175 \sim -487.436 \text{ MPa}$ 、表面硬度为 $10.837 \sim 15.689 \text{ HRS}$ 。

(3) 实验验证表明, 求解获得的最优参数可实现良好的加工质量、提高生产率。优化模型的优化值与实验数据之间的误差小于 5.00% , 反映了该方法在工艺参数优化及结果预测中的准确性和可靠性。

参考文献:

- [1] 王鑫, 郑彬, 赵运才. 机械零件的寿命影响因素分析 [J]. 机械设计, 2021, 38 (S1): 87-90.
Wang X, Zheng B, Zhao Y C. Analysis of factors affecting the life of mechanical parts [J]. Journal of Machine Design, 2021, 38 (S1): 87-90.
- [2] 朱昌规. 基于超声振动挤压的表面光整加工强化技术研究 [D]. 南京: 南京理工大学, 2021.
Zhu C G. Research on Strengthening Technology of Surface Finishing Based on Ultrasonic Vibration Extrusion [D]. Nanjing: Nanjing University of Science and Technology, 2021.
- [3] Mousavi S A A A, Feizi H, Madoliat R. Investigations on the effects of ultrasonic vibrations in the extrusion process [J]. Journal of Materials Processing Technology, 2007, 187: 657-661.
- [4] Deng G Y, Zhao X, Su L H, et al. Effect of high pressure torsion process on the microhardness, microstructure and tribological property of Ti6Al4V alloy [J]. Journal of Materials Science & Technology, 2021, 94: 183-195.
- [5] Nouri M, Li D Y. Maximizing the benefit of aluminizing to AZ31 alloy by surface nanocrystallization for elevated resistance to wear and corrosive wear [J]. Tribology International, 2017, 111: 211-219.
- [6] 常金鑫, 贾海利. 基于响应曲面法的超声挤压工艺参数优化 [J]. 新技术新工艺, 2023, (8): 60-66.
Chang J X, Jia H L. Optimisation of ultrasonic extrusion process parameters based on response surface method [J]. New Technology & New Process, 2023, (8): 60-66.
- [7] Luo X, Ren X P, Jin Q, et al. Microstructural evolution and surface integrity of ultrasonic surface rolling in Ti6Al4V alloy [J]. Journal of Materials Research and Technology, 2021, 13: 1586-1598.
- [8] 查旭明, 袁智, 秦浩, 等. 钛合金超声冲击强化研究现状及发展趋势 [J]. 中国机械工程, 2023, 34 (19): 2269-2287.
Zha X M, Yuan Z, Qin H, et al. Ultrasonic impact strengthening of titanium alloys: State-of-the-art and perspectives [J]. China Mechanical Engineering, 2023, 34 (19): 2269-2287.
- [9] Lu X H, Jia Z Y, Wang H, et al. The effect of cutting parameters on micro-hardness and the prediction of Vickers hardness based on a response surface methodology for micro-milling Inconel 718 [J]. Measurement, 2019, 140: 56-62.
- [10] 陈云峰, 尹丹青, 倪锋. 超声滚压静压力对 0Cr13Ni5Mo 不锈钢残余应力和粗糙度的影响 [J]. 锻压技术, 2023, 48 (10): 161-168.
Chen Y F, Yin D Q, Ni F. Influence of static pressure on residual stress and roughness during ultrasonic rolling for 0Cr13Ni5Mo stainless steel [J]. Forging & Stamping Technology, 2023, 48 (10): 161-168.
- [11] Tang J Y, Shi Y, Zhao J Y, et al. Numerical modeling considering initial gradient mechanical properties and experiment verification of residual stress distribution evolution of 12Cr2Ni4A steel generated by ultrasonic surface rolling [J]. Surface and Coatings Technology, 2023, 452: 129127.
- [12] 张剑飞, 王磊, 刘明, 等. 基于改进遗传算法优化 BP 神经网络的表面粗糙度误差预测 [J]. 高师理科学刊, 2023, 43 (7): 33-40.
Zhang J F, Wang L, Liu M, et al. Prediction of surface roughness error based on BP neural network optimized by improved genetic algorithm [J]. Journal of Science of Teachers' College and University, 2023, 43 (7): 33-40.
- [13] Zhao X, Ji Y X, Ning X L. Accelerometer calibration based on improved particle swarm optimization algorithm of support vector machine [J]. Sensors and Actuators A: Physical, 2024, 369: 115096.
- [14] Chen L P, Wang X C, Xia W J, et al. PSO-SVR predicting for the Ehull of ABO₃-type compounds to screen the thermodynamic stable perovskite candidates based on multi-scale descriptors [J]. Computational Materials Science, 2022, 211: 111435.
- [15] 易望远, 尹瑞雪, 田应权, 等. 数控铣削能耗预测及切削参数多目标优化研究 [J]. 重庆理工大学学报: 自然科学, 2024, 38 (3): 240-249.
Yi W Y, Yin R X, Tian Y Q, et al. Research on energy consumption prediction and multi-objective optimization of cutting parameters in CNC milling [J]. Journal of Chongqing University of Technology: Natural Science, 2024, 38 (3): 240-249.