考虑刀具磨损的TB6钛合金镗削表面粗糙度预测及工艺参数优化

乐庾忻[1,2] 李聪波[1*] 黄康华[2] 汪广平[2] 苏 栗[1,2] 安庆强[2]
1.重庆大学高端装备机械传动全国重点实验室,重庆,400044
2.昌河飞机工业(集团)有限责任公司,景德镇,333002

摘要:针对TB6钛合金镗削加工中刀具磨损严重、表面质量差、加工效率低等问题,开展了考虑刀具磨损的TB6钛合金镗削表面粗糙度预测及工艺参数优化研究。首先分析TB6钛合金镗削表面粗糙度的影响因素,然后结合一维卷积神经网络、多头注意力机制和双向门控循环神经网络建立刀具磨损监测模型;在此基础上,基于刀具磨损监测数据和工艺参数,利用支持向量机回归算法建立表面粗糙度预测模型;最后建立以表面粗糙度和加工时间为目标的工艺参数优化模型,并利用改进多目标哈里斯鹰优化算法求解,获取综合考虑表面粗糙度和加工时间的最优工艺参数组合。案例研究结果表明,优化后表面粗糙度减小了10.68%,加工时间缩短了17.14%,验证了所提方法的有效性。

关键词:TB6钛合金;镗削加工;表面粗糙度预测;工艺参数优化;刀具磨损
中图分类号:TH161
DOI:10.3969/j.issn.1004-132X.2026.08.016 **开放科学(资源服务)标识码(OSID)**:

Surface Roughness Prediction and Process Parameter Optimization for TB6 Titanium Alloy Boring Considering Tool Wear

LE Yuxin[1,2] LI Congbo[1*] HUANG Kanghua[2] WANG Guangping[2] SU Li[1,2] AN Qingqiang[2]
1.State Key Laboratory of Mechanical Transmission for Advanced Equipment, Chongqing University, Chongqing, 400044
2.Changhe Aircraft Industry (Group) Co., Ltd., Jingdezhen, Jiangxi, 333002

Abstract: To address the issues of severe tool wear, poor surface quality, and low machining efficiency during the boring process of TB6 titanium alloy, has been conducted on the prediction of surface roughness considering tool wear and the optimization of process parameters for TB6 titanium alloy boring. Firstly, the factors influencing the surface roughness of TB6 titanium alloy boring were analyzed. Secondly, a tool wear monitoring model was established by integrating the 1D convolutional neural network, multi-head attention mechanism, and bidirectional gated recurrent unit network. On this basis, a surface roughness prediction model was established using the support vector machine regression algorithm based on tool wear monitoring data and process parameters. Then, a process parameter optimization model was established with surface roughness and machining time as the objectives. And the model was solved using an improved multi-objective Harris hawks optimization (MOHHO) algorithm to obtain the optimal combination of process parameters that comprehensively considers both surface roughness and machining time. The case study results show that the surface roughness value is reduced by 10.68% and the machining time is shortened by 17.14% after the optimization, verifying the effectiveness of the method.

Key words: TB6 titanium alloy; boring process; surface roughness prediction; process parameter optimization; tool wear

0 引言

TB6钛合金是一种近β型钛合金,具有比强度高、韧性好和抗腐蚀性强等优良性能,被广泛应用于直升机主桨毂和飞机起落架等关键承力核心部件。但因其导热性差、弹性模量小、高温化学活性强等特点,导致其加工性能较差,工件镗削加工时易发生加工硬化和热变形现象[1],最终造成刀具磨损严重、表面质量差、加工效率低等问题,严重制约了TB6钛合金更进一步的发展空间。因此,研究考虑刀具磨损的TB6钛合金镗削表面粗糙度预测及工艺参数优化具有重要意义。

收稿日期:2025-06-25
基金项目:国家自然科学基金(92367107);高端装备机械传动全国重点实验室自主研究课题重点项目(SKLMT-ZZKT-2024Z06)

表面粗糙度是衡量表面质量的关键指标之一，国内外学者对表面粗糙度预测进行了深入研究。ZHAO等[2]提出了一种基于支持向量机集成学习的表面粗糙度预测算法模型，用于氧化铝陶瓷的纵向超声振动辅助磨削的表面粗糙度预测。WANG等[3]构建了一种结合理论模型和数据驱动的表面粗糙度耦合预测模型，并进行了方法对比与结果验证。CAO等[4]以工艺参数和纤维取向作为输入，使用遗传算法优化的反向传播神经网络建立了表面粗糙度预测模型，模型精度达90.39%。LIU等[5]构建了一种基于多源异构数据的贝叶斯量化回归模型，模型预测误差为15.05%。由于实际加工中存在刀具磨损这一动态变化因素，若不考虑刀具磨损的差异而对表面粗糙度直接进行预测，将极大地限制表面粗糙度预测模型的预测精度。CHENG等[6]将考虑和不考虑刀具磨损的表面粗糙度预测模型进行了对比，结果显示，不考虑刀具磨损时，表面粗糙度的预测精度下降了99.21%。WANG等[7]发现，考虑刀具磨损时，表面粗糙度预测模型的RMSE值为0.027～0.089，而不考虑刀具磨损时，模型的RMSE值则为0.067～0.189，预测精度大大降低。且由于TB6钛合金自身的难加工特性，其镗削过程中的刀具磨损情况严重，会对表面粗糙度造成极大影响，是一个不容忽视的关键影响因素，因此，TB6钛合金表面粗糙度预测时，还需考虑如何获取变工艺条件下的刀具磨损情况，故需对刀具磨损监测进行研究。

在刀具磨损监测方面，国内外学者已经进行大量研究。HE等[8]提出了一种基于堆叠稀疏自编码器和多传感器特征融合的刀具磨损监测模型，实验证明多传感器融合与深度学习结合可显著提高模型监测精度。KUNTOĞLU等[9]通过集成切削力、振动等传感器，构建车削刀具磨损监测模型。CAGGIANO[10]基于主成分分析进行多传感器信号特征提取，以切削力、声发射和振动信号作为输入，通过人工神经网络精准监测刀具后刀面磨损值。在刀具磨损监测研究中，切削力信号和振动信号的应用比较广泛和成熟，并且通过深度学习自动提取多源信号中的刀具磨损关联特征，避免了人工经验依赖，可提高刀具磨损间接监测模型的精度。但由于待提取的多源信号数据量较大，如何快速全面地提取各传感器信号数据特征信息，并突出与刀具磨损强相关的特征，会在很大程度上影响刀具磨损监测模型的监测精度。

国内外学者针对工艺参数优化开展了大量研究。RUDRAPATI等[11]以工艺参数作为输入，利用响应面法建立了不锈钢材料外圆磨削时的振动和表面粗糙度的数学模型，并利用多目标遗传算法进行求解。LEONE等[12]以激光加工参数为决策变量，以T3铝合金的材料去除率和表面粗糙度为目标函数，采用多响应优化算法进行工艺参数优化求解。JOSHI等[13]以表面粗糙度和材料去除率为目标，算法对比结果表明，多目标蚁狮优化算法可显著节省成本。鄢威等[14]以切削三要素和纤维方向为变量，以CFRP铣削的能耗和表面粗糙度为目标，提出DM-PSO和AHP集成优化方法进行求解。目前，工艺参数优化多通过实验分析优选参数或利用智能算法对优化模型进行求解，且当前研究的对象主要是基础通用型材料的常规车削、铣削、磨削等工艺，对TB6钛合金的镗削工艺参数优化问题还需进一步研究和解决。

综上所述，由于TB6钛合金自身的难加工特性，其镗削过程中的刀具磨损情况严重，表面粗糙度预测时考虑刀具磨损是十分必要的；刀具磨损监测时如何快速全面地提取各传感器信号数据的特征信息并突出其中的强相关特征，会显著影响模型的监测精度；对TB6钛合金的镗削工艺参数优化问题还需进一步研究和解决。本文提出了考虑刀具磨损的TB6钛合金镗削表面粗糙度预测及工艺参数优化方法，并通过实验验证和算法对比分析验证了所提方法的有效性和优越性。

1 TB6钛合金镗削表面粗糙度的影响因素分析及实验数据的获取

1.1 TB6钛合金镗削表面粗糙度影响因素分析

结合镗削加工特性和镗削表面粗糙度的形成机理，系统梳理TB6钛合金镗孔表面粗糙度的影响因素，其主要影响因素如图1所示。

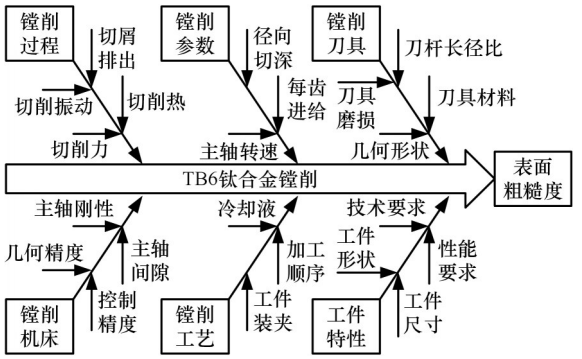


图1 TB6钛合金镗削表面粗糙度的影响因素

Fig.1 Influencing factors of surface roughness in TB6 titanium alloy boring

由于实际生产中，考虑到每种TB6钛合金零部件的形状尺寸和加工特征等特性，镗削机床、镗削刀具的种类、镗削工艺中的冷却液和工件装夹方式等条件均已确定，而镗削过程中的切削力、切削振动等动态过程因素都受镗削参数的影响，故本文主要针对镗削参数（主轴转速n、每齿进给量f_z、径向切削深度a_p）和刀具磨损值V_B开展TB6钛合金镗削表面粗糙度预测与工艺参数优化研究。

1.2　TB6钛合金镗削实验数据的获取

现实生产中无法在每次镗削加工前都进行刀具磨损测量，因为这样不仅会打断TB6钛合金零部件的连续镗削过程，还可能由此产生加工误差，影响加工质量，故本研究利用工艺参数、振动信号和切削力信号建立TB6钛合金镗削刀具磨损监测模型，从而节约刀具磨损测量时间和成本。本文TB6钛合金镗削实验数据的获取主要是通过传感器、工业相机和表面粗糙度仪采集力、振动等动态数据和刀具磨损值、表面粗糙度等静态数据，为建立刀具磨损监测模型和表面粗糙度预测模型提供数据支撑，数据获取整体框架如图2所示。

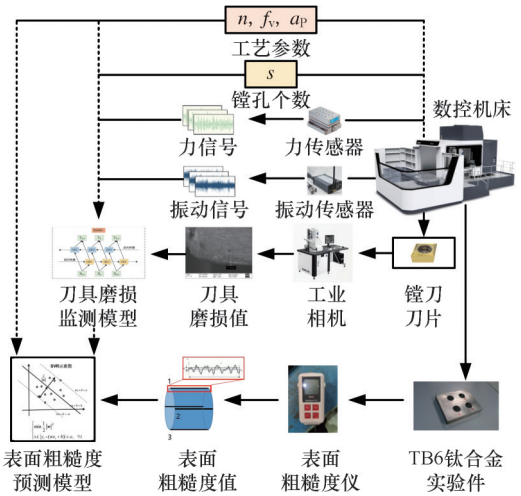


图2　TB6钛合金镗削实验数据的获取

Fig.2　Data acquisition for the TB6 titanium alloy boring experimental

首先设计刀具磨损监测和表面粗糙度预测实验的实验方案，使用不同工艺参数进行TB6钛合金镗削加工：①在刀具磨损监测实验中，使用力传感器和振动传感器采集机床三向力信号和三向振动信号等动态数据；使用工业相机测量镗刀刀片后刀面最大磨损带宽度作为刀具磨损值V_B；以工艺参数、镗孔个数、力信号和振动信号作为输入，以V_B作为输出，建立刀具磨损监测模型。②在表面粗糙度预测实验中，将工艺参数、力信号和振动信号输入刀具磨损监测模型，得到刀具磨损监测数据；使用表面粗糙度仪测量TB6钛合金实验件镗孔的表面粗糙度Ra；以工艺参数和刀具磨损监测数据作为输入，以Ra作为输出，建立表面粗糙度预测模型。

2　考虑刀具磨损的TB6钛合金镗削表面粗糙度预测模型

2.1　TB6钛合金镗削刀具磨损监测模型

本文结合一维卷积神经网络（1DCNN）、多头注意力机制（MHA）和双向门控循环神经网络（BiGRU）建立刀具磨损监测模型，其工作原理如图3所示。模型主要包括三部分：首先利用1DCNN对振动和力信号进行自动特征提取，并与人工提取的工艺参数特征拼接作为特征向量；然后，MHA模块为特征向量中的每个特征值分配权重，突出关键特征表达；最后通过BiGRU双向解析加权特征矩阵的组别关联性，通过正反向状态传递捕捉刀具磨损的变化情况，经全连接层和回归层映射输出刀具磨损监测结果。

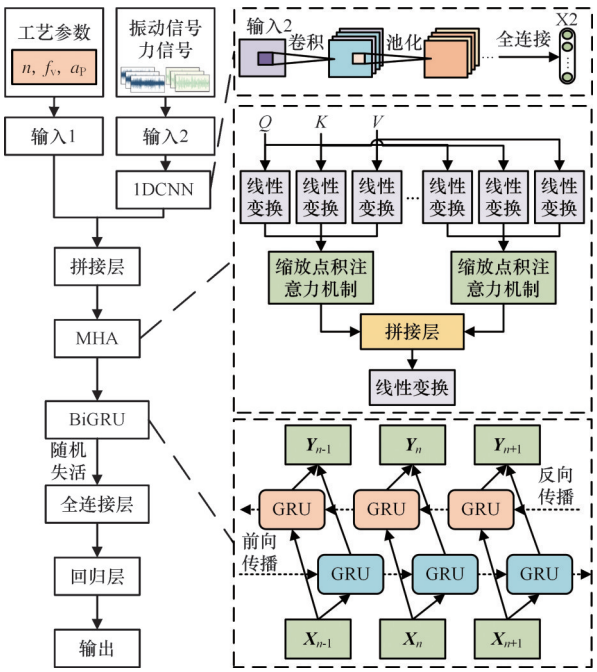


图3　刀具磨损监测模型的工作原理

Fig.3　Working principle of the tool wear monitoring model

基于1DCNN-MHA-BiGRU的刀具磨损监测模型主要由1DCNN模块、MHA模块和BiGRU模块三部分组成。

1）1DCNN。针对TB6钛合金镗削过程中的振动信号和力信号等高频动态数据的高维特性，本文采用1DCNN对振动信号和力信号等动态数据进行自动特征提取[15]。1-DCNN通过卷积层

与池化层的交替堆叠实现动态数据特征的自动提取，其原理是通过卷积核在振动与力信号等数据上进行卷积池化操作，将其转换为特征矩阵。本文选用最大池化运算降低特征映射维度，提高模型的训练速度和泛化能力。

2）MHA。为提高TB6钛合金镗削刀具磨损监测精度，强化数据间的全局关联性并实现特征信息的权重分配，本文在数据提取与刀具磨损结果监测间引入了MHA模块[16]。该模块通过并行学习多组独立注意力分布，显著增强了网络对样本关键特征的提取能力，同时降低非重要信息的干扰，实现数据特征的权重分配。MHA将输入刀具磨损数据特征矩阵拆分为h个子矩阵，每个子矩阵独立进行缩放点积注意力运算，最终拼接所有子矩阵输出并通过线性层整合。

3）BiGRU。本文基于BiGRU网络模型[17]对刀具磨损进行监测，BiGRU模型的结构和计算原理如图4所示，它主要由前向GRU和后向GRU组成，前向GRU利用历史刀具磨损数据进行学习，后向GRU利用下一组合的刀具磨损数据进行学习，前后两个通道的输出状态拼接在一起作为整个BiGRU网络的输出，即可获得第n组的刀具磨损监测值。

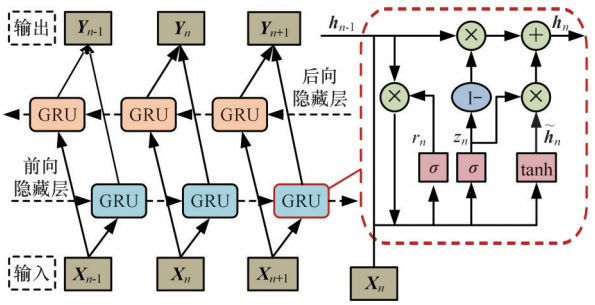


图4 BiGRU架构

Fig.4 Schematic architecture of the BiGRU

2.2 基于支持向量机回归的表面粗糙度预测模型

在上节建立的TB6钛合金镗削刀具磨损监测模型的基础上，本文利用支持向量机回归算法[18]（SVR）构建考虑刀具磨损的TB6钛合金镗削表面粗糙度预测模型。

通过上节的刀具磨损监测模型获取刀具磨损监测值V_{BM}，将工艺参数（n，f_z，a_p）和刀具磨损监测值V_{BM}相结合，形成了输入数据集$X_i=\{(n, f_z, a_p, V_{BM}), i=1,2,\cdots,h\}$，并与对应的输出值$y_i$（表面粗糙度$Ra$）共同构成表面粗糙度预测的数据集$Q=\{(X_i, y_i), i=1,2,\cdots,h\}$，其中，$h$为样本数量。TB6钛合金镗削表面粗糙度预测模型可表示为

$$Ra=\mathrm{SVR}(n, f_z, a_p, V_{BM}) \tag{1}$$

在实际加工过程中，由于整个加工系统的不确定性，在机床、刀具和辅助设备等工艺条件相同的情况下，TB6钛合金镗削表面粗糙度仍会受到随机误差的影响。为了模拟这种不确定性，本文在预测模型中加入了高斯噪声ε（$\varepsilon\sim N(\mu, \sigma^2)$）[19]。结合基于实验数据建立的表面粗糙度预测模型和考虑加工不确定性的高斯噪声ε，最终得到考虑刀具磨损的TB6钛合金镗削表面粗糙度预测模型：

$$Ra=\mathrm{SVR}(n, f_z, a_p, V_{BM})+\varepsilon \tag{2}$$

2.3 模型评价方法

本文选取决定系数（R^2）、平均绝对误差（MAE）、均方根误差（RMSE）和平均绝对百分比误差（MAPE）对刀具磨损监测模型和表面粗糙度预测模型的性能进行评价，其中，R^2越接近1，MAE、RMSE、MAPE值越小，模型性能越好。各评价指标计算方法略。

3 面向表面粗糙度和加工时间的TB6钛合金镗削工艺参数多目标优化

3.1 TB6钛合金镗削工艺参数优化模型

3.1.1 目标函数

1）表面粗糙度目标函数。根据第2节建立的考虑刀具磨损的TB6钛合金镗削表面粗糙度预测模型，表面粗糙度目标函数可表示为式（2）。

2）加工时间目标函数。考虑到数控机床的开机和快速进给等动作花费的时间较短，故忽略不计。并且在TB6钛合金镗削加工过程中，工人为确保表面粗糙度值达标，半精镗后无论刀具磨损严重与否都会进行统一换刀，所以整个镗削过程的换刀时间固定，故将其并入到待机时间，统一设置为定值。则TB6钛合金镗削加工的总加工时间可分为待机时间t_{stdb}、空切时间t_{air}、切削时间t_{cut}、调刀时间t_{adjm}。考虑到TB6钛合金的整个镗削工艺包含了多个工步，加工时间目标函数最终可表示为

$$t_{total}=t_{stdb}+\sum_{i=1}^{m}t_{air}^{i}+\sum_{i=1}^{m}t_{cut}^{i}+t_{adjm}=$$
$$t_{stdb}+\sum_{i=1}^{m}\frac{L_{air}^{i}}{n_i f_z^{i}}+\sum_{i=1}^{m}\frac{L_{cut}^{i}}{n_i f_z^{i}}+\left(\frac{\Delta}{a_p}-1\right)t_0 \tag{3}$$

式中：L_{air}^{i}、L_{cut}^{i}分别为第i个工步的空切路径长度和轴向切削深度；Δ为镗孔的加工余量；t_0为每次调刀花费的时间。

3.1.2 优化变量

在每种TB6钛合金零部件的实际镗削加工过程中，机床型号、刀具型号以及冷却液等因素均已确定，故在确定优化变量时不予考虑。由于无

法对刀具磨损进行优化，故刀具磨损同样不纳入考虑范围，将其设为常数。本文选取主轴转速n、每齿进给量f_z和径向切削深度a_p作为优化变量，优化变量集合如下：

$$X=\{x_1,x_2,x_3|n,f_z,a_p\} \tag{4}$$

3.1.3 约束条件

TB6钛合金镗削工艺参数的选取，除了要追求表面粗糙度值最小和加工时间最短的目标，还受实际加工情况和设备条件的约束，需要限制在机床和刀具厂商规定的安全系数范围内。因此，设置具体约束条件如下：

$$n_{min}\leqslant n\leqslant n_{max}\quad f_{zmin}\leqslant f_z\leqslant f_{zmax}$$
$$a_{pmin}\leqslant a_p\leqslant a_{pmax}\quad P_c\leqslant \eta P_{max}$$
$$F_c\leqslant F_{cmax}$$

式中：n_{min}、n_{max}分别为数控加工中心说明书上规定的机床主轴允许使用的最小、最大转速；f_{zmin}、f_{zmax}分别为TB6钛合金镗孔工序的每齿进给量的最大和最小值；a_{pmin}、a_{pmax}分别为TB6钛合金镗孔工序的最小和最大径向切削深度；P_{max}为机床额定功率；η为机床功率的有效系数；F_{max}为机床主轴能承受的最大切削力。

综上所述，建立面向表面粗糙度和加工时间的TB6钛合金镗削工艺参数多目标优化模型：

$$\min F(n,f_z,a_p)=(\min Ra,\min t_{total})$$
$$\text{s.t. } n_{min}\leqslant n\leqslant n_{max}$$
$$f_{zmin}\leqslant f\leqslant f_{zmax}$$
$$a_{pmin}\leqslant a_p\leqslant a_{pmax}$$
$$P_c\leqslant \eta P_{max}$$
$$F_c\leqslant F_{cmax}$$

3.2 基于改进多目标哈里斯鹰优化算法的工艺参数优化模型求解

多目标哈里斯鹰优化算法[20](multi-objective Harris hawks optimization algorithm，MOHHO)融合了粒子群多目标优化框架和哈里斯鹰优化算法。由于其初始种群是随机生成的，可能导致哈里斯鹰初始种群在空间内分布不均匀，使种群的多样性受限，会降低算法的优化求解能力，故对MOHHO算法进行改进，通过引入Tent混沌映射，增强初始种群的均匀性，减少种群个体的扎堆现象，避免算法陷入局部最优，从而增强算法的全局寻优性能，实现对MOHHO算法的改进。本文优化算法(TC-MOHHO)的求解流程如图5所示。

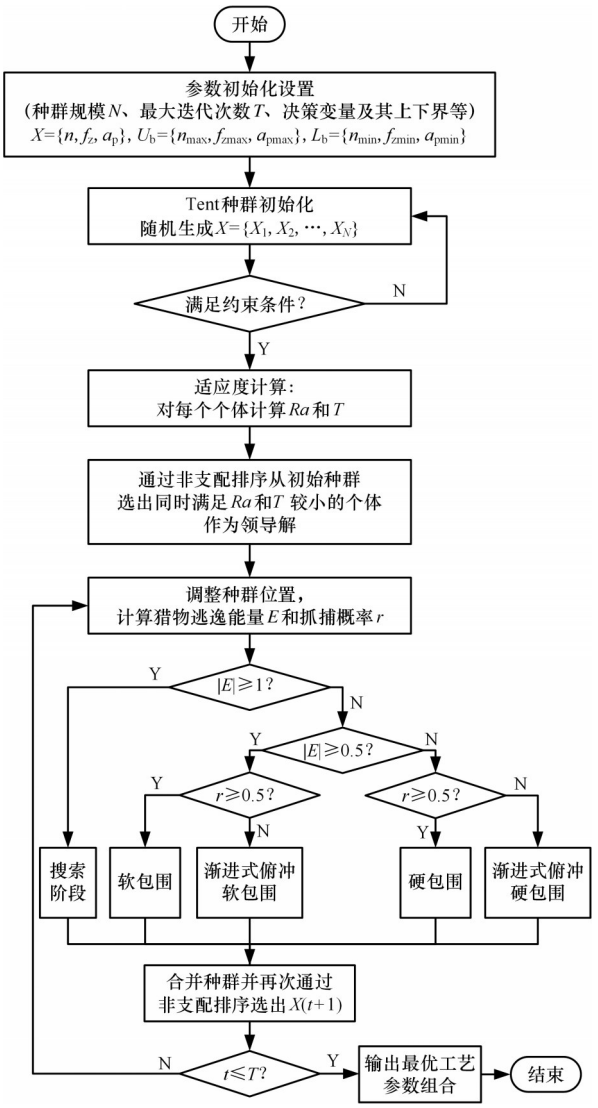


图5　TC-MOHHO算法流程图

Fig.5　Flowchart of the TC-MOHHO

4　案例分析及验证

4.1 实验设备及条件

本研究在某直升机制造厂的直升机主桨毂中央件精加工产线的MIKROMAT 12V5D数控五坐标高精度镗铣加工中心上开展TB6钛合金镗削加工，使用的镗刀各组件规格型号具体包括：SECO品牌的精镗头A78010，加长镗杆M4012011C，刀片CCGT060204L-UX CP500，待加工实验件为经退火热处理的TB6钛合金锻件(480 ℃/4 h)，尺寸规格为110 mm×140 mm×20 mm，镗孔直径为25 mm。

本文使用WTVB02-485型号三轴加速度振动传感器和LZ-SWL6型号三轴力传感器同步采集机床主轴X、Y、Z三个方向上的加速度信号和切削力信号，采样频率均设为5 kHz；使用ZLA0381S型号USB转RS-485串口通讯器将各传感器采集的信号通过USB端口导入电脑，导入格式为.csv，实验设备安装布置情况如图6所示。

镗削加工后，使用洛司XDS-10A高清工业相机测量刀具磨损值。根据ISO 3685：1993标准，结合实际镗削中刀片各刀面的实际磨损情

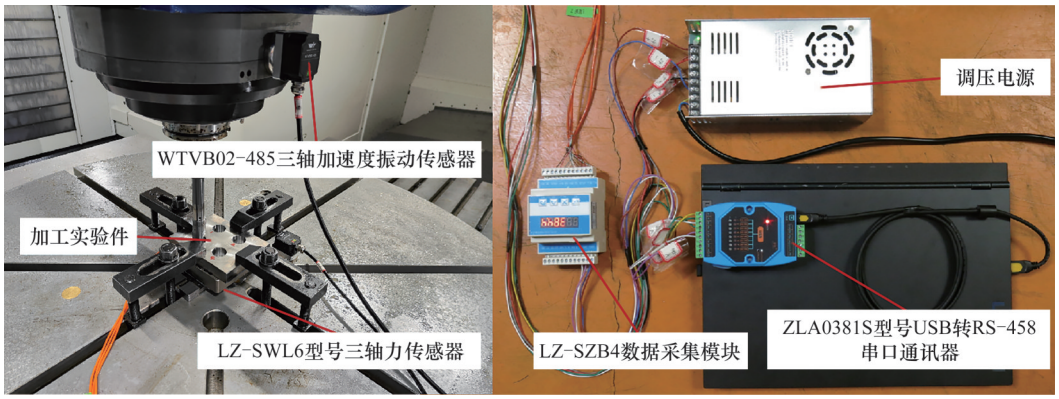
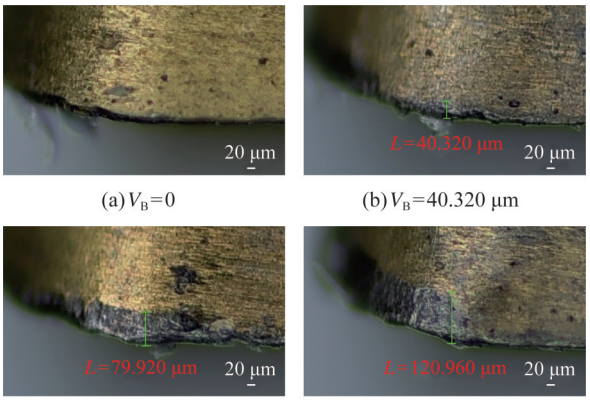


图6 数据采集设备设置

Fig.6 Data acquisition equipment setup

况，将后刀面磨损带最大宽度V_B作为本文刀具磨损的量化指标，部分刀具磨损测量结果如图7所示。



(a) V_B=0　(b) V_B=40.320 μm

(c) V_B=79.920 μm　(d) V_B=120.960 μm

图7 工业相机下的刀具磨损

Fig.7 Tool wear captured by industrial cameras

本文使用德国马尔公司的MarSurf PS10表面粗糙度仪测量TB6实验件镗孔的表面粗糙度，取样长度为0.8 mm，评定长度为4.0 mm。为减小测量误差，将镗孔的4条径向取样段的平均值作为该镗孔的表面粗糙度，具体测量情况如图8所示。

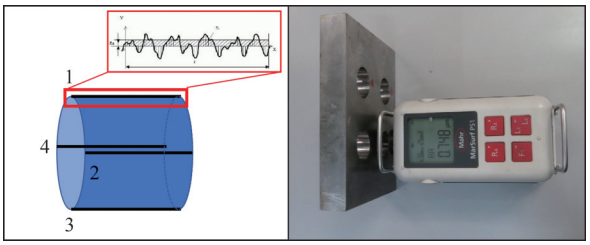


图8 镗孔表面粗糙度测量

Fig. 8 Measurement of boring surface roughness

4.2 考虑刀具磨损的表面粗糙度预测案例分析

4.2.1 刀具磨损监测案例分析

4.2.1.1 数据准备

为建立刀具磨损监测模型，本文基于正交试验法设计了三因素三水平$L_9(3^3)$的刀具磨损监测实验，具体参数如表1所示。使用全新刀片分别在9组不同工艺参数下连续进行12次TB6钛合金镗削加工，一共进行108组，部分实验结果如表2所示。

表1 刀具磨损监测实验各因素水平表

Tab. 1 Factor level table for the tool wear monitoring experiment

因素水平	n/(r·min^{-1})	f_z/mm	a_p/mm
1	130	0.05	0.025
2	240	0.1	0.055
3	350	0.15	0.085

表2 部分刀具磨损监测实验结果

Tab. 2 Selected tool wear monitoring experiment results

序号	镗孔个数s	n/(r·min^{-1})	f_z/mm	a_p/mm	V_B/μm
1	4	130	0.05	0.085	16.368
2	8	130	0.05	0.085	22.812
3	12	130	0.05	0.085	28.393
⋮	⋮	⋮	⋮	⋮	⋮
53	20	350	0.05	0.055	30.455
54	24	350	0.05	0.055	32.695
55	28	350	0.05	0.055	34.286
⋮	⋮	⋮	⋮	⋮	⋮
106	40	130	0.1	0.085	59.574
107	44	130	0.1	0.085	69.255
108	48	130	0.1	0.085	79.662

每组刀具磨损监测实验中，使用三轴加速度振动传感器和三轴力传感器同步采集振动信号与力信号，采样频率为5 kHz。针对采集的原始数据，选取镗削处于平稳状态的同一时段的2048个数据点，将三向振动信号和切削力信号数据堆叠为6通道样本，构建维度为108×2048×6的多维时间序列数据集。

4.2.1.2 刀具磨损监测模型的建立

基于准备好的刀具磨损监测数据集建立TB6钛合金镗削刀具磨损监测模型。针对振动

信号和切削力信号等时序动态数据，通过1DCNN进行自动特征提取，该网络包含4个卷积层、4个池化层和1个全连接层，其中卷积层参数配置如表3所示，池化核尺寸为3×1，卷积步长为2，全连接层节点数为64，最后输出的特征值为$\{x_1,x_2,\cdots,x_{64}\}$。

表3　卷积层参数

Tab.3　Parameters of the convolutional layers

卷积层	卷积核个数	卷积核大小	输入通道数	激活函数
C1	16	3	6	ReLU
C2	64	3	16	ReLU
C3	128	3	64	ReLU
C4	64	3	128	ReLU

将动态数据特征和工艺参数、镗孔数量等静态数据特征融合，组合形成最终特征集$\{x_1,x_2,\cdots,x_{64},n,f_z,a_p,s\}$。将最终特征集输入MHA模块中，它由两个并行子层(h=2)构成，每个子层通过$\boldsymbol{Q}$、$\boldsymbol{K}$、$\boldsymbol{V}$标准向量实现注意力权重计算，其维度为$d_q=d_k=d_v=34$。将双注意力头输出的加权特征拼接并通过线性层映射至68维特征空间，输出权重赋值后的特征向量。

将加权特征向量输入BiGRU模块，它由两个各含34个神经元的GRU层构成双向循环结构。网络配置包含：随机失活层($Dropout$=0.4)以防止模型过拟合，ReLU激活函数增强网络非线性映射能力，全连接层(节点数为32)实现特征空间压缩，最终经线性回归层输出刀具磨损监测值。

4.2.1.3　*刀具磨损监测结果及对比分析*

1)刀具磨损监测结果。将刀具磨损监测数据集划分出96组为训练集，12组为测试集。对建立的刀具磨损监测模型进行训练，建立的刀具磨损监测模型在测试集的整体监测效果如图9所示。可知，测试集中的刀具磨损监测数据和实测数据的变化趋势基本一致，且监测值均位于实测值的95%置信区间内，说明本文建立的刀具磨损监测模型能够有效监测TB6钛合金刀具磨损值，为TB6钛合金表面粗糙度预测模型提供了较为准确的刀具磨损监测数据。

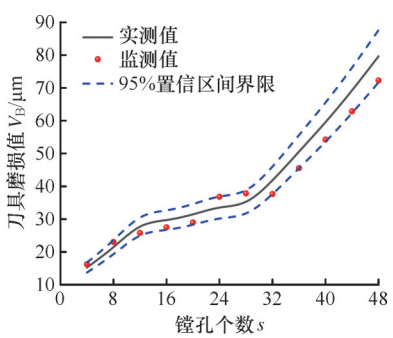


图9　测试集的刀具磨损监测效果

Fig.9　Effectiveness of tool wear monitoring for test set

2)对比分析。为展现本文基于1DCNN-MHA-BiGRU所建立的刀具磨损监测模型(模型M)的优势，将其与以下模型进行对比分析：模型1为通过人工手动提取振动信号、力信号的均值、方差等时域、频域特征值和工艺参数，基于MHA-BiGRU建立的模型；模型2为基于无注意力机制的1DCNN-BiGRU预测模型；模型3为基于1DCNN-MHA-BiLSTM建立的模型。

利用训练集数据对上述3个模型进行训练，本文模型(模型M)和上述3个模型在测试集对V_B值的监测偏差分布情况如图10所示，各模型评价指标如表4所示。

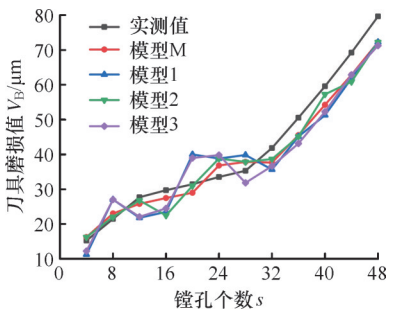


图10　各模型在测试集的刀具磨损监测结果对比

Fig.10　Comparison of tool wear monitoring results across different models in the test set

表4　各刀具磨损监测模型的评价指标

Tab.4　Evaluation indexes of each tool wear monitoring model

模型	R^2	RMSE值	MAPE值	MAE值
模型M	0.9527	4.0981	0.0836	3.6042
模型1	0.8854	6.3767	0.1746	6.2291
模型2	0.8934	6.1487	0.1625	5.9490
模型3	0.9392	4.6447	0.0873	3.7225

由对比分析可知，本文方法建立的刀具磨损监测模型(模型M)的R^2、RMSE值、MAPE值和MAE值分别为0.9527、4.0981、0.0836、3.6042，各项评价指标均优于其他监测模型，证明了本文模型具有较大优势。

4.2.2　**表面粗糙度预测案例分析**

4.2.2.1　*数据准备*

本文使用4种不同磨损程度的刀片在27组不同工艺参数组合下对TB6钛合金实验件进行镗削加工，镗削完成后测量TB6钛合金实验件镗孔的表面粗糙度值Ra，并通过刀具磨损监测模型获取刀具磨损监测值V_{BM}。表面粗糙度预测实验的部分实验结果如表5所示。

表5 部分表面粗糙度预测实验结果

Tab.5 Selected surface roughness prediction experiment results

序号	n/(r·min^{-1})	f_z/mm	a_p/mm	V_{BM}/μm	Ra/μm
1	130	0.05	0.025	9.832	0.339
2	130	0.05	0.055	11.304	0.363
3	130	0.05	0.085	11.113	0.584
…	…	…	…	…	…
53	130	0.10	0.025	79.534	0.648
54	130	0.10	0.055	82.329	0.652
55	130	0.10	0.085	86.421	0.842
…	…	…	…	…	…
106	350	0.15	0.025	118.234	1.852
107	350	0.15	0.055	125.324	2.298
108	350	0.15	0.085	131.421	2.574

4.2.2.2 表面粗糙度预测模型的建立

本文基于SVR的表面粗糙度预测模型中采用RBF核函数构建非线性映射关系，正则化系数C=1000，核带宽参数γ=0.01。

本文基于多组重复性实验所得表面粗糙度Ra的实际波动情况，对测量结果进行了统计分析。结果表明，Ra的随机波动近似服从均值为0、方差为0.0144 μm^{2}的正态分布。因此，在预测模型中引入高斯噪声ε($\varepsilon \sim N(\mu, \sigma^2)$)以表征该加工不确定性，高斯噪声中的均值和方差分别为μ=0，σ^2=0.0144 μm^2。

4.2.2.3 表面粗糙度预测结果及对比分析

1)表面粗糙度预测结果。将表面粗糙度预测数据集输入表面粗糙度预测模型进行训练，训练集与测试集比例为4∶1，模型在测试集的整体预测效果如图11所示，可以看出训练好的表面粗糙度预测模型预测性能较好，能够比较精准地预测TB6钛合金镗削表面粗糙度。

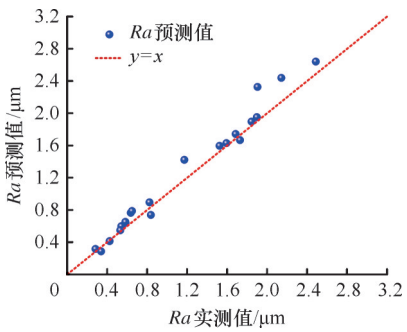
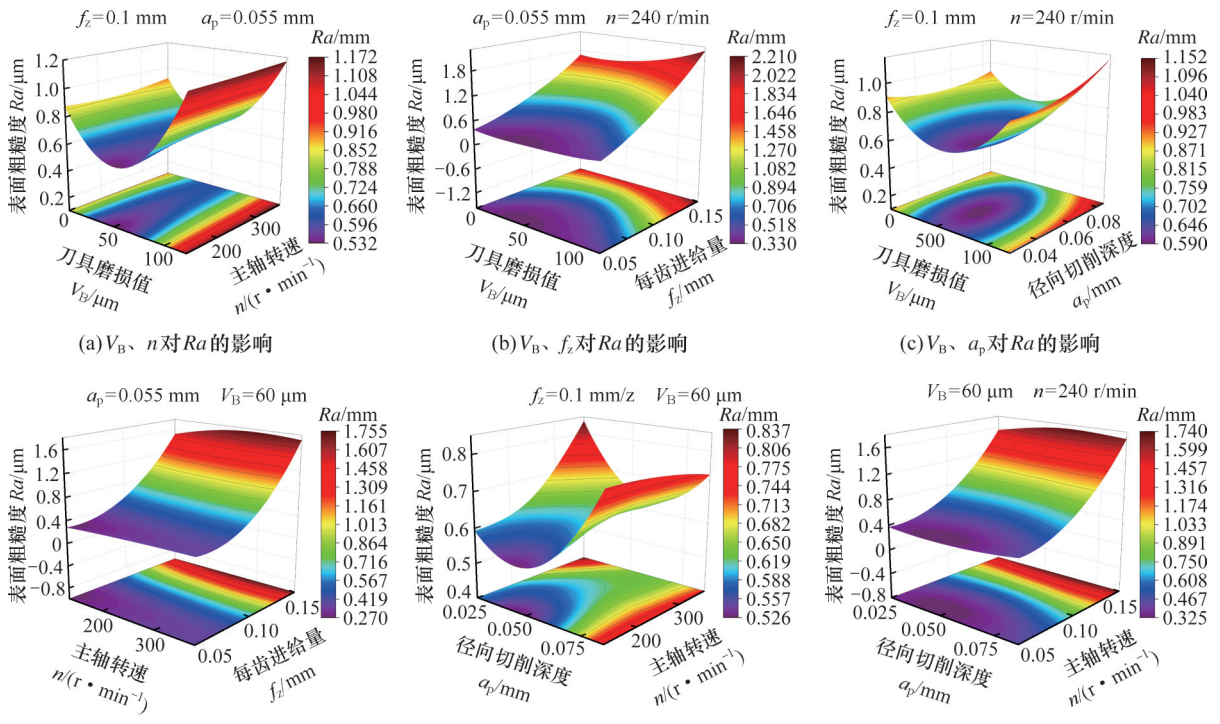


图11 表面粗糙度预测效果

Fig.11 Effectiveness of surface roughness prediction

2)影响规律分析。通过训练好的表面粗糙度预测模型，可以分析刀具磨损、工艺参数与表面粗糙度之间的关联关系。通过改变两个参数，保持其他参数不变，利用控制变量法研究两个参数的相互作用对表面粗糙度的影响，结果如图12所示。

由图12a～图12c可看出，在这4个参数中，刀具磨损V_B对表面粗糙度的影响程度仅次于每齿进给量f_z，并且随着V_B的增加，表面粗糙度呈现先减小后增大的变化趋势。这是由于在刀具的初期磨



(a)V_B、n对Ra的影响 (b)V_B、f_z对Ra的影响 (c)V_B、a_p对Ra的影响

(d)n、f_z对Ra的影响 (e)a_p、n对Ra的影响 (f)a_p、f_z对Ra的影响

图12 刀具磨损和工艺参数对表面粗糙度的影响规律

Fig.12 The influence of tool wear and process parameters on surface roughness

损和正常磨损阶段，锋利的切削刃因轻微磨损而钝化，钝化的刃口可能使切削力分布更均匀，减少因刀具锋利度过高导致的材料局部撕裂或塑性变形，表面粗糙度暂时降低。而随着刀具开始剧烈磨损，切削刃几何形状发生明显改变，则会导致切屑与前刀面、后刀面与已加工表面的摩擦增加，产生更多划痕和凹坑。同时，由于TB6钛合金导热性差，随着V_B的增大，切削热积聚导致材料软化并黏附在刀具表面，形成积屑瘤。积屑瘤的周期性脱落会使加工表面产生撕裂和毛刺。过度磨损的刀具因为无法有效切断材料，造成工件表面层的反复挤压和塑性变形，也会显著增大表面粗糙度。

此外，由图12b、图12d和图12f可看出，表面粗糙度随着f_z的增大而增大。由图12e可看出，相较于主轴转速n，径向切削深度a_p对表面粗糙度的影响更为显著，主轴转速n仅在较小切深时对表面粗糙度有影响。

3）对比分析。为展现本文基于SVR建立的考虑刀具磨损的表面粗糙度预测模型的优势，将其与以下模型进行对比分析：一是SVR(s)模型。基于SVR建立模型，不考虑刀具磨损，仅以工艺参数作为模型输入；二是GPR模型。基于GPR建立模型，以刀具磨损监测值和工艺参数作为模型输入；三是RFR模型。基于RFR建立模型，以刀具磨损监测值和工艺参数作为模型输入。

利用训练集数据对上述3个模型进行训练，本文模型和上述3个模型在测试集的预测结果如图13所示，各模型评价指标如表6所示。

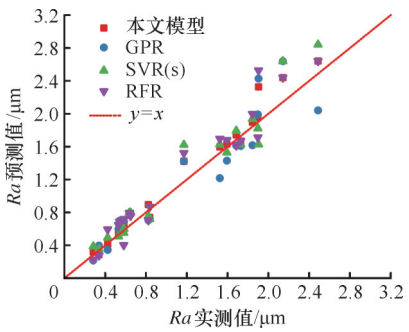


图13　各模型在测试集的表面粗糙度预测结果对比

Fig.13　Comparison of surface roughness prediction results across different models in the test set

表6　各表面粗糙度预测模型的评价指标

Tab.6　Evaluation indexes of each surface roughness prediction model

模型	R^2	RMSE值	MAPE值	MAE值
本文模型	0.953	0.145	0.100	0.105
SVR(s)模型	0.881	0.231	0.172	0.184
GPR模型	0.917	0.195	0.136	0.143
RFR模型	0.904	0.207	0.175	0.164

通过对比分析可知，采用本文方法建立的表面粗糙度预测模型的R^2、RMSE值、MAPE值和MAE值分别为0.953、0.145、0.100、0.105，各项评价指标均优于其他预测模型，证明了本文模型具有较大优势。

4.3　工艺参数优化案例分析

本文TC-MOHHO优化算法求解工艺参数多目标优化模型，优化算法的关键参数包括：Tent混沌映射系数a、惯性权重w、初始种群数量N_{pop}、最大迭代次数T_{max}等。

算法参数设置采用控制变量法，选取反世代距离指标(IGD)和超体积(HV)作为评价指标，其中，IGD指标越小、HV指标越大说明该算法的收敛性和多样性越好，通过20次独立实验统计评价指标的均值以确定算法参数的最优值，部分算法调参结果如图14所示。

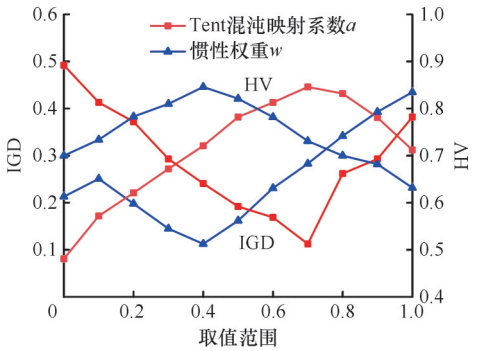


图14　部分算法调参结果

Fig.14　Partial algorithm parameter adjustment result

由图14可知，当Tent混沌映射系数a=0.7，惯性权重w=0.4时，IGD值最小，HV值最大，算法性能最优。通过经验选取初始种群数量N_{pop}=50，此时算法迭代约120次后，IGD、HV值趋于稳定，故选取最大迭代次数T_{max}=150以保证收敛充分。此外，选取Pareto解集N=20，领导选择压力P_1=2，删除选择压力P_2=2。

求解得到的20组Pareto解集如图15红色点集所示，分别选取第1和第20个解作为表面粗糙度最小的解和加工时间最短的解。其中，第一个解虽然表面粗糙度最小，但加工时间过长，加工效率太低，易造成生产计划的延误；第20个解虽然加工时间最短，但表面粗糙度值过大，不符合实际生产加工中的表面粗糙度要求。由于两个目标之间存在矛盾冲突关系，无法同时满足两个目标的最小化，故使用乌托邦点方法来选取综合最优解，即选取最接近“理想中完美解”(乌托邦点)以最小化两个目标函数。

本文采用权重为w_{Ra}=0.4，w_T=0.6来计算

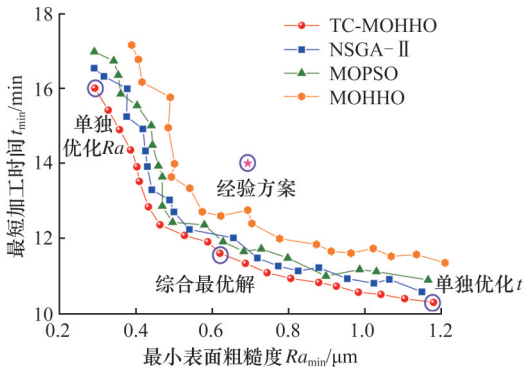


图15 各算法Pareto解集对比

Fig.15 Comparison of Pareto solution sets of various algorithms

每个解到乌托邦点的距离，最终选取第11个点作为本文多目标优化问题的最优解，TC-M0HHO优化求解的各Pareto解的具体数值如表7所示。

表7 各Pareto解的具体数值

Tab.7 The specific values of each Pareto solution

Pareto解	Ra/μm	t/min	欧氏距离D	排名
1	0.292	16	0.775	20
2	0.327	15.4	0.694	19
3	0.357	14.9	0.627	17
4	0.389	14.4	0.561	15
5	0.402	13.9	0.495	13
6	0.409	13.5	0.443	10
7	0.432	12.8	0.354	7
8	0.463	12.4	0.310	4
9	0.527	12.1	0.296	2
10	0.588	11.9	0.303	3
11	0.619	11.6	0.292	1
12	0.686	11.3	0.312	5
13	0.744	11.1	0.340	6
14	0.806	10.9	0.375	8
15	0.879	10.8	0.424	9
16	0.925	10.7	0.454	11
17	0.983	10.6	0.494	12
18	1.042	10.5	0.535	14
19	1.104	10.4	0.578	16
20	1.180	10.3	0.632	18

具体各个解的优化结果对比如表8所示，由表8可知，单独优化Ra，表面粗糙度值减小了57.86%，但加工时间延长了14.29%；单独优化T，加工时间缩短了26.43%，但表面粗糙度值增大了71.13%；而综合优化Ra和T，表面粗糙度减小了10.68%，且加工时间也缩短了17.14%，在保证比经验方案的表面粗糙度略有下降的前提下，应尽可能缩短加工时间。

为证明本文TC-MOHHO算法的优势，将本文方法与第二代非支配排序遗传算法[21](NSGA-Ⅱ)、多目标粒子群算法[22](MOPSO)以及多目标哈里斯鹰优化算法(MOHHO)进行对比分析，各算法的Pareto解集如图15所示。此外，选取IGD和HV指标对上述算法进行评价。各算法的IGD和HV指标结果如图16所示。结果表明，本文TC-MOHHO算法的Pareto解集相对最优，分布最好，算法收敛性和多样性更好。

表8 优化结果对比

Tab.8 Comparison of optimization results

优化方案	n/(r·min^{-1})	f_z/mm	a_p/mm	Ra/μm	t/min
综合优化Ra&T	242	0.068	0.075	0.619	11.6
单独优化Ra	202	0.065	0.025	0.292	16
单独优化T	346	0.146	0.078	1.180	10.3
经验方案	216	0.093	0.03	0.693	14

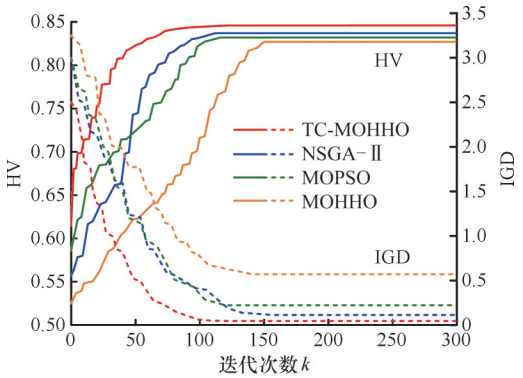


图16 IGD和HV指标结果

Fig. 16 The results of IGD and HV metric

4.4 实验验证

为验证本文优化结果的真实性，使用综合优化Ra和t、单独优化Ra、单独优化t这三种优化方案中的工艺参数组合在某机型中央件上进行镗削加工实验，每个方案均进行3次镗削实验，每次镗削加工完成后，测量并计算Ra和t，最后计算平均值作为该方案最终得到的Ra和t，各方案的优化结果和实验结果如表9所示。

表9 优化结果与实验结果对比

Tab.9 Comparison of optimization and experimental

方案	Ra优化结果/μm	Ra实验结果/μm	误差/%	t优化结果/min	t实验结果/min	误差/%
1	0.619	0.667	7.75	11.6	13.3	14.66
2	0.292	0.318	8.90	16	18.3	14.38
3	1.180	1.287	9.07	10.3	11.8	14.56

结果显示，三种方案下中央件镗削实验的表面粗糙度和加工时间的实验结果均大于优化结果。这可能是由于中央件自身形状与TB6钛合金试验件存在差异，其叉耳孔处的刚性相较于方正的试验件孔的刚性来说较差，故其镗削表面粗糙度较大。同时，由于工装方案的不同，不仅会对

加工表面质量造成影响，两者装夹花费的时间也会存在较大差异。此外，加工和测量时的随机误差可能也会产生影响。本研究现有实测样本数据源于刚性较好的工艺系统，所提方法仅在工件结构与刚性、夹具方案与实验件高度相似的工艺系统中具有最高的预测与优化精度。当面临工件结构突变、工艺系统刚性显著变化、材料批次性差异等工况改变时，模型的直接应用可能受限，建议进行模型迁移或重新校准。尽管如此，表面粗糙度的实验结果与预测结果的绝对百分比误差在10%以内，加工时间的实验结果与预测结果的绝对百分比误差在15%以内，验证了本文建立的考虑刀具磨损的TB6钛合金镗削表面粗糙度预测模型以及面向表面粗糙度和加工时间的TB6钛合金镗削工艺参数多目标优化模型的有效性和真实性。

5　结论

1)本文基于刀具磨损监测数据和工艺参数，利用SVR建立了考虑刀具磨损的TB6钛合金镗削表面粗糙度预测模型，并与其他预测模型进行了对比分析，结果表明：本文模型的各项评估指标均为最优，R^2、RMSE、MAPE、MAE值分别为0.9533、0.1446、0.1003、0.1045，体现了本文模型的有效性和优越性。

2)构建了以表面粗糙度和加工时间为优化目标、工艺参数为优化变量的多目标优化模型，利用TC-MOHHO算法进行求解，得到综合优化表面粗糙度和加工时间的最优工艺参数组合，与经验方案对比，表面粗糙度减小了10.68%，加工时间缩短了17.14%。并以实际加工案例对本文模型进行了验证，证明了本文预测方法和优化方法的可靠性和真实性。

3)本文的研究主要基于特定实验条件构建模型，未来可拓展到不同刀具类型(如涂层刀片、陶瓷刀片)、不同孔径、不同机床等条件下的表面粗糙度预测，可以探索利用迁移学习与小样本学习在这方面的应用，以此增强模型的泛化能力。

参考文献：

[1] 张美娟，南海，鞠忠强，等. 航空铸造钛合金及其成型技术发展[J]. 航空材料学报，2016，36(3)：13-19.
ZHANG Meijuan，NAN Hai，JU Zhongqiang，et al. Aeronautical Cast Ti Alloy and Forming Technology Development[J]. Journal of Aeronautical Materials，2016，36(3)：13-19.

[2] ZHAO Mingli，XUE Boxi，LI Bohan，et al. Ensemble Learning with Support Vector Machines Algorithm for Surface Roughness Prediction in Longitudinal Vibratory Ultrasound-assisted Grinding[J]. Precision Engineering，2024，88：382-400.

[3] WANG Jingshu，CHEN Tao，KONG Dongdong. Knowledge-based Neural Network for Surface Roughness Prediction of Ball-end Milling[J]. Mechanical Systems and Signal Processing，2023，194：110282.

[4] CAO Huajun，LIU Lei，WU Bo，et al. Process Optimization of High-speed Dry Milling UD-CF/PEEK Laminates Using GA-BP Neural Network[J]. Composites Part B：Engineering，2021，221：109034.

[5] LIU Weichao，WANG Pengyu，YOU Youpeng. Surface Roughness Prediction Using Multi-source Heterogeneous Data and Bayesian Quantile Regression in Milling Process[J]. Journal of Manufacturing Processes，2023，95：446-460.

[6] CHENG Minghui，JIAO Li，YAN Pei，et al. Prediction and Evaluation of Surface Roughness with Hybrid Kernel Extreme Learning Machine and Monitored Tool Wear[J]. Journal of Manufacturing Processes，2022，84：1541-1556.

[7] WANG Yahui，WANG Yiwei，ZHENG Lianyu，et al. Online Surface Roughness Prediction for Assembly Interfaces of Vertical Tail Integrating Tool Wear under Variable Cutting Parameters[J]. Sensors，2022，22(5)：1991.

[8] HE Zhaopeng，SHI Tielin，XUAN Jianping. Milling Tool Wear Prediction Using Multi-sensor Feature Fusion Based on Stacked Sparse Autoencoders[J]. Measurement，2022，190：110719.

[9] KUNTOĞLU M，SAĞLAM H. Investigation of Signal Behaviors for Sensor Fusion with Tool Condition Monitoring System in Turning[J]. Measurement，2021，173：108582.

[10] CAGGIANO A. Tool Wear Prediction in Ti-6Al-4V Machining through Multiple Sensor Monitoring and PCA Features Pattern Recognition[J]. Sensors，2018，18(3)：823.

[11] RUDRAPATI R，PAL P K，BANDYOPADHYAY A. Modeling and Optimization of Machining Parameters in Cylindrical Grinding Process[J]. The International Journal of Advanced Manufacturing Technology，2016，82(9)：2167-2182.

[12] LEONE C，GENNA S，TAGLIAFERRI F. Multiobjective Optimisation of Nanosecond Fiber Laser Milling of 2024 T3 Aluminium Alloy[J]. Journal of Manufacturing Processes，2020，57：288-301.

[13] JOSHI M，GHADAI R K，MADHU S，et al. Comparison of NSGA-II，MOALO and MODA for Multi-objective Optimization of Micro-Machining Processes[J]. Materials，2021，14(17)：5109.

[14] 鄢威，王欣怡，张华，等. 考虑切削能耗和表面质量的碳纤维增强树脂基复合材料加工工艺参数优化决策[J]. 中国机械工程，2024，35(10)：1834-1844.
YAN Wei，WANG Xinyi，ZHANG Hua，et al. Optimization Decision of CFRP Processing Parameters Considering Cutting Energy Consumption and Surface Quality[J]. China Mechanical Engineering，2024，35(10)：1834-1844.

[15] KIRANYAZ S，AVCI O，ABDELJABER O，et al. 1D Convolutional Neural Networks and Applications：a Survey[J]. Mechanical Systems and Signal Processing，2021，151：107398.

[16] VOITA E，TALBOT D，MOISEEV F，et al. Analyzing Multi-head Self-Attention：Specialized Heads Do the Heavy Lifting，the Rest Can Be Pruned[C]//Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics. ACL，2019：5797-5808.

（下转第**1988**页）