

基于 GRA-DBN 的机器人打磨工艺多目标优化方法

陶永^{①*} 薛蛟^{**} 杨林^{**} 王潇桐^{**} 刘亚醉^{**} 魏洪兴^{*}

(* 北京航空航天大学机械工程及自动化学院 北京 100191)

(** 北京航空航天大学航空发动机研究院 北京 100191)

摘要 机器人打磨因其灵活性、广泛的工作空间和高可操作性,已成为提升民用飞机机身表面质量的重要加工方法之一。在民用飞机机身的打磨过程中,表面粗糙度与材料去除率之间存在一定的相互制约关系,因此,如何在二者之间实现最优平衡是当前研究中的一大难点。针对这一问题,本文提出了一种基于灰色关联分析(gray relational analysis, GRA)-深度置信网络(deep belief network, DBN)的机器人打磨工艺多目标优化方法。首先,通过主成分分析(principal component analysis, PCA)优化 GRA 得到机器人打磨多目标与工艺参数之间的映射关系,将多目标优化转化为单目标优化问题。然后,结合 DBN 建立机器人打磨工艺参数优化模型。最后,进行实验验证,结果表明,所提出的方法不仅能够有效平衡表面粗糙度与材料去除率,还能提高打磨工艺的稳定性和可靠性。

关键词 机器人打磨;民用飞机机身;多目标优化;灰色关联分析;深度置信网络

随着航空制造业的不断发展,民用飞机的质量要求日益提高,尤其是机身表面质量的控制成为了生产工艺中的关键环节。人工打磨存在表面一致性差、加工效率低等问题,使得去除量和接触力难以精确控制;数控机床打磨可以提高加工精度,但通用性较差。这两种方法都无法满足现代自动化发展的需要^[1-4]。机器人打磨技术凭借其灵活性、可调性和适应性,成为提升民用飞机机身表面质量的理想选择。然而,在民用飞机机身的打磨过程中,表面粗糙度(surface roughness, SR)和材料去除率(material removal rate, MRR)之间存在着相互制约的关系,提高材料去除率可能会导致表面粗糙度的增加,而严格控制表面粗糙度则可能影响去除率的提升^[5-8]。因此,如何在这两个目标之间实现最优平衡,成为机器人打磨技术研究中的核心问题。

国内外学者在打磨过程建模和优化方面开展了广泛的研究。Pandiyani 等人^[9]采用田口法设计实验来评价砂带打磨实验的结果,并根据收集到的数据

比较了 6 种不同统计回归预测模型。Pan 等人^[10]开发了一种反向传播神经网络预测模型,用于打磨过程中 SR 的准确预测。Yang 等人^[11]基于单个磨粒的运动轨迹,对不均匀接触砂轮弹性变形下的 MRR 进行了建模。Xu 等人^[12]研究了单个磨粒的表面形成过程,建立了用于机器人打磨叶片 SR 预测和评价的增强扇形高度模型。Zhang 等人^[13]利用 Preston 方程和多元线性回归方法建立了航空发动机叶片的非线性 MRR 模型。Xie 等人^[14]利用单因素和中心复合设计实验建立了 SR 预测模型。

上述研究只关注 SR 或 MRR 的单目标优化,在多目标优化方面,学者们通过大量实验获取基础实验数据,然后根据实验数据建立相应数学模型,利用智能算法,如方差分析^[15-16]、响应面法^[17-19]、遗传算法^[20-21]、灰色关联分析(gray relational analysis, GRA)^[22-23]等,优化寻求最优参数。Chen 等人^[24]基于田口法和 GRA 方法对碳化硅陶瓷工件表面的打磨工艺进行多目标优化,以获得最优的工艺参数组合。

① 男,1979 年生,博士,副教授;研究方向:智能制造机器人控制与集成;联系人,E-mail: taoy@buaa.edu.cn
(收稿日期:2025-03-14)

Beaula 等人^[25]将 GRA 和主成分分析(principal component analysis,PCA)相结合对 EN18 合金钢工件表面的打磨工艺进行分析,使表面粗糙度和比能最小化。Rekha 等人^[26]以工件速度、纵向进给、横向进给和冷却液流速为输入变量,以 SR 和 MRR 为响应,应用 GRA 确定了 SS304 钢工件的最佳外圆打磨工艺参数。尽管前人进行了较为深入的研究,但在平衡打磨质量(表面粗糙度 SR)与打磨效率(材料去除率 MRR)这两个关键目标时,存在顾此失彼的情况,难以全面反映实际打磨过程中的复杂非线性关系,且在民用飞机机身打磨工艺的多目标优化方面相关研究较少,优化方法还存在较大改进空间。

针对上述问题,本文提出了一种基于 GRA-深度置信网络(deep belief network, DBN)的机器人打磨工艺参数多目标优化方法,首先利用主成分分析优化灰色关联分析建立工艺参数与优化目标之间的关系,并通过计算关联度将多目标优化转化为单目标优化问题。然后,结合 DBN 构建机器人打磨工艺参数的优化模型,从而实现了对打磨工艺参数的智能化调节,解决机器人打磨过程中由于多种打磨工艺参数耦合造成的打磨质量与打磨效率存在制约的难题。

1 多目标优化转单目标优化

在机器人打磨工艺的优化过程中,通常需要同时考虑多个性能指标,如 SR 和 MRR。由于这两个指标之间存在复杂的相互制约关系,直接进行多目标优化可能会导致计算过程的复杂性和解的非唯一性。因此,将多目标问题转化为单目标问题是实现有效优化的常见方法。本文通过主成分分析优化灰色关联分析得到机器人打磨多目标与工艺参数之间的映射关系,将多目标优化转化为单目标优化问题。

1.1 主成分分析

主成分分析法是多元统计学中降维方法的一种^[27],其基本思想是用较少的不相关的新变量代替原有较多的相关变量,新变量为原有变量的线性组合。具体步骤如下。

(1)对打磨数据进行正向化处理,即逆向指标

取其相反数,再将数据通过 Z-score 法进行标准化处理。

$$P_{ij} = \frac{X_{ij} - \bar{X}_j}{\sigma} \quad (1)$$

式中: P_{ij} 为标准化数据, X_{ij} 为正向化数据, \bar{X}_j 为指标均值, σ 为样本标准差。

(2)计算相关矩阵 $R = (r_{ij})$

$$r_{ij} = \frac{\text{cov}(X_i, X_j)}{\sqrt{D(X_i)} \times \sqrt{D(X_j)}} \quad (2)$$

式中: D 为绝对差值, r_{ij} 反映指标 X_i 和 X_j 的相关程度, $\text{cov}(X_i, X_j)$ 为协方差。

(3)计算相关矩阵 r_{ij} 的特征值 λ_i 。如果 R 有 q 个大于 0 的特征值,特征值对应的规范正交特征向量为 $A = (a_1, a_2, \dots, a_q)$,则 q 个主成分为

$$\begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_q \end{bmatrix} = \begin{bmatrix} a_{11} & a_{21} & \cdots & a_{p1} \\ a_{12} & a_{22} & \cdots & a_{p2} \\ \vdots & \vdots & \cdots & \vdots \\ a_{1q} & a_{2q} & \cdots & a_{pq} \end{bmatrix} \begin{bmatrix} X_1 \\ X_2 \\ \vdots \\ X_q \end{bmatrix} \quad (3)$$

式中: p 表示第 p 组实验样本, q 代表第 q 个优化目标。

(4)计算第 g 个主成分的方差贡献率 w_i

$$w_i = \frac{\lambda_i}{\sum_{j=1}^n \lambda_j} \quad (4)$$

(5)计算前 m 个主成分的累积方差贡献率。若前 m 个主成分的累积方差贡献率 ρ 达到 85%,则取前 m 个主成分替代原有的 p 个指标。

$$\rho = \frac{\sum_{i=1}^m \lambda_i}{\sum_{j=1}^n \lambda_j} \quad (5)$$

(6)对 m 个主成分加权求和。综合评价函数如式(6)所示。

$$f = w_1 y_1 + w_2 y_2 + \cdots + w_m y_m \quad (6)$$

1.2 基于 PCA 的 GRA 优化

在机器人打磨工艺优化中,灰色关联分析被广泛应用于衡量工艺参数与优化目标之间的关联度。通过建立灰色关联分析模型,可以定量评估各工艺参数对打磨目标的影响程度,为优化过程提供理论依据。然而,由于 SR 与 MRR 对打磨质量的影响程

度不同,如何合理评估各因素的贡献并确定其在优化模型中的权重成为关键问题。本文采用 PCA 计算各目标的贡献率,并相应调整其在 GRA 中的权重,最终将 SR 与 MRR 转换为单一的灰色关联度(gray relational grade, GRG),从而实现将多目标优化问题转化为单目标优化问题。具体步骤如下。

步骤 1: 归一化

将打磨参数数据作归一化处理:

$$x_i^*(k) = \frac{x_i^o(k) - \min x_i^o(k)}{\max x_i^o(k) - \min x_i^o(k)} \quad (7)$$

式中: $x_i^o(k)$ 为打磨参数的初始序列; $x_i^*(k)$ 为比较序列, $k = 1, 2, \dots, q, i = 1, 2, \dots, p$, 其中, p 和 q 分别是实验次数和相应的目标数量。

步骤 2: 计算灰色关联系数

设 $x_0^*(k)$ 为参考序列,则灰色关联系数 γ 可定义如下:

$$\gamma(x_0^*(k), x_i^*(k)) = \frac{\Delta_{\min} + \lambda \Delta_{\max}}{\Delta_{0i}(k) + \lambda \Delta_{\max}}, \quad 0 < \gamma(x_0^*(k), x_i^*(k)) \leq 1 \quad (8)$$

式中: $\Delta_{0i}(k)$ 为 k 项指标的参考序列与比较序列之间的绝对差值,可表示为

$$\Delta_{0i}(k) = |x_0^*(k) - x_i^*(k)| \quad (9)$$

$\Delta_{\min} = \min_{i,j} \Delta_{0i}(k)$ 为参考序列与比较序列中最小绝对差值; $\Delta_{\max} = \max_{i,j} \Delta_{0i}(k)$ 为参考序列与比较序列中最大绝对差值; $\lambda \in [0, 1]$ 为分辨系数(一般取 0.5)。

步骤 3: 计算打磨参数权重

通过 PCA 计算出每一个打磨参数的权重 $\beta_k (k = 1, 2, \dots, n)$ 。

步骤 4: 计算灰色关联度

灰色关联系数的加权和即为灰色关联度,其计算公式如式(10)所示。

$$\gamma(x_0^*, x_i^*) = \sum_{k=1}^n \beta_k \gamma(x_0^*(k), x_i^*(k)) \quad (10)$$

式中: $\gamma(x_0^*, x_i^*)$ 表示参考序列与比较序列的关联度。灰色关联度越大,匹配参数组合越接近响应变量的最优值。此外,灰度关联度还反映了打磨参数等级对打磨质量特性的影响程度。

2 基于 GRA-DBN 的多目标优化方法

传统的优化算法如遗传算法和粒子群优化在处理高维、非线性优化问题时可能面临较大的挑战。遗传算法虽然通过模拟自然进化过程来搜索最优解,但其编码方式、选择策略和交叉变异操作的设计往往较为复杂,且容易陷入局部最优解。粒子群优化则通过模拟鸟群觅食行为来搜索最优解,但其粒子间的信息共享机制可能不够完善,同样存在陷入局部最优解的风险。DBN 作为一种深度学习模型,以其强大的非线性映射能力著称,能够有效地捕捉打磨工艺参数与优化目标之间复杂的非线性关系。通过多层受限玻尔兹曼机的堆叠和反向传播算法的微调,DBN 能够学习到数据中的深层特征,并据此对新的打磨参数输入进行精准预测。这使得 DBN 在优化过程中能够迅速收敛到全局最优解,提高了优化效率和准确性。因此,在将多目标优化问题转化为单目标优化后,本文进一步通过深度置信网络构建了机器人打磨工艺参数的优化模型。打磨工艺参数(如进给速度、磨具压力等)作为模型的输入,GRG 作为输出。DBN 通过多层非线性映射,能够有效地捕捉打磨过程中输入参数与 GRG 之间的复杂的非线性关系。训练完成后,针对新的打磨参数输入,模型能够实时计算其对应的 GRG 值,并与已有的 GRG_{best} 进行比较。基于这一比较结果,确定最优的打磨参数组合,从而实现对机器人打磨过程的动态优化和调整。其技术流程如图 1 所示。

DBN 网络由多个限制玻尔兹曼机 (restricted Boltzmann machine, RBM) 连接和一个回归层组合而成,并通过梯度下降和反向传播对产生的深度网络进行微调来创建,形成最佳的模型。受限玻尔兹曼机作为 DBN 的基本组成部分^[28],是一种生成式随机人工神经网络,它可以从输入中学习概率分布,受限玻尔兹曼机的结构如图 2 所示。RBM 由可见层(visible layers, v)和隐藏层(hidden layers, h)这 2 层组成,可见层用来接收训练数据,本文中用来接受机器人的打磨参数;隐藏层的输入是可见层的输出,用来提取特征。两层神经元之间存在“层内无连接,层间全连接”的关系。可见层和隐藏层之间是

权重矩阵 w^p, v, h 分别代表可见层和隐藏层向量, b^v, b^h 分别代表可见层和隐藏层的偏置。

将多层 RBM 和反向传播层(最后 1 层)进行堆叠,组合成 DBN 网络,如图 3 所示。

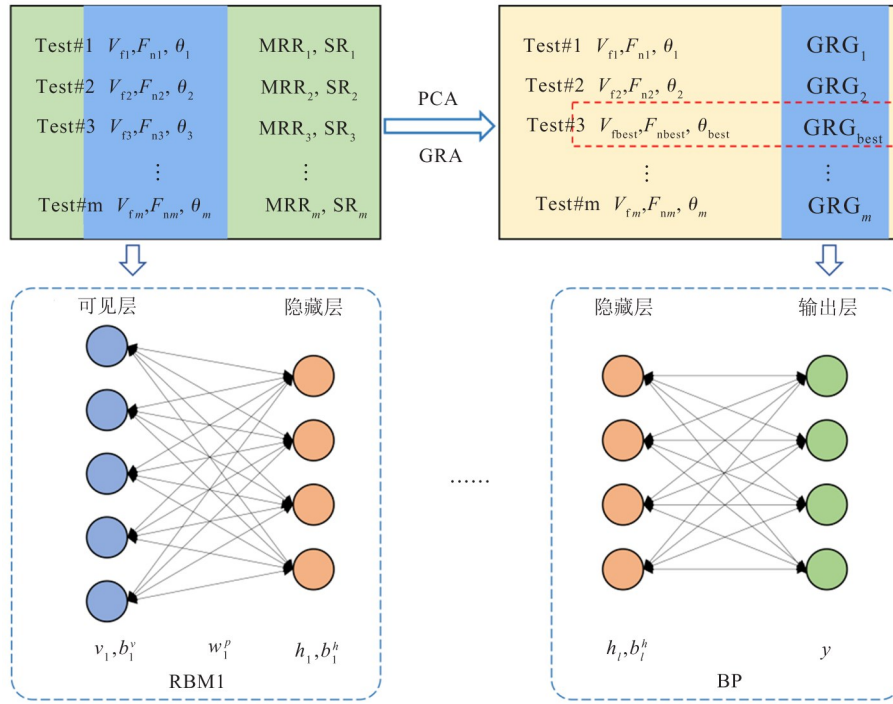


图 1 基于 GRA-DBN 的机器人打磨工艺参数多目标优化方法流程图




图 2 受限玻尔兹曼机 (RBM) 的结构

第 1 层 RBM 由可见层 v_1 和隐含层 h_1 共同组成,而第 2 层 RBM 的可见层 v_2 为第 1 层 RBM 的隐含层 h_1 , 即 $v_2 = h_1$, 以此类推;DBN 通过多个 RBM 的堆叠实现其逐层学习,从而用于对打磨数据的特征提取,DBN 的最后 1 层设置 BP(back propagation)网络,接收 RBM 的输出特征向量作为它的输入特征向量。

无监督预训练(pre-training)和微调(supervised fine-tuning)是 DBN 训练的 2 个过程。在预训练过




图 3 深度置信网络 (DBN) 的结构

程中采用贪婪算法,将前一个 RBM 训练得到的结果作为下一个 RBM 的输入,直到所有 RBM 都完成训练,同时得到各个 RBM 的初始参数。定义 RBM 的能量函数为

$$E(\mathbf{v}, \mathbf{h}; \theta) = - \sum_{i=1}^m b_i^v v_i - \sum_{j=1}^n b_j^h h_j - \sum_{i,j=1}^{m,n} w_{ij}^p v_i h_j \quad (11)$$

$$\theta = \{w_{ij}^p, b_{ii}^v, b_j^h\} \quad (12)$$

式中: m 和 n 为可视层与隐藏层的节点数。

基于能量函数,可求得概率分布 P 为

$$P(\mathbf{v}, \mathbf{h}; \theta) = \frac{1}{Z(\theta)} \exp(-E(\mathbf{v}, \mathbf{h}; \theta)) \quad (13)$$

式中: $Z(\theta)$ 为归一化因子, $Z(\theta) = \sum_{\mathbf{v}, \mathbf{h}} \exp(-E(\mathbf{v}, \mathbf{h}; \theta))$ 。

隐藏层和可见层的状态概率分别为

$$P(h_j = 1/\mathbf{v}; \theta) = \varphi(b_j^h + \sum_{i=1}^n \mathbf{w}_{ij} v_i) \quad (14)$$

$$P(v_i = 1/\mathbf{h}; \theta) = \varphi(b_i^v + \sum_{j=1}^n \mathbf{w}_{ij} h_j) \quad (15)$$

式中: φ 为激活函数, $\varphi(x) = \frac{1}{1 + e^{-x}}$ 。

微调是指在预训练结束后,用 BP 算法对整个网络进行训练,使整个 DBN 处于最佳状态。假设 y 和 \hat{y} 分别是 DBN 的实际输出和期望的输出。输出层的损失函数为

$$F(\tau) = \frac{1}{2} \sum_1^N (\hat{y} - y)^2 \quad (16)$$

式中: τ 是迭代次数, N 是训练样本数。

网络最后一层的隐含层和输出层之间的权重 w_{out} 通过更新函数进行迭代:

$$w_{out}(\tau + 1) - w_{out}(\tau) = -\eta \frac{\partial F(\tau)}{\partial w_{out}(\tau)} \quad (17)$$

式中, η 为学习率。

DBN 节点的隐藏层数最大设置为 4 层,隐藏层的节点数范围为 (10, 101), 初始学习率为 0.01, 动量因子为 0.8。

3 实验验证

为验证所提出算法的可行性和精度,基于 SIASUN GCR20-1100 机器人打磨实验平台进行验证。该平台由机器人本体、磨片及传感器组成,机器人的重复定位精度 ± 0.05 mm,有效负载 20 kg,工作空间 1 100.00 mm,磨片选用 125.00 mm \times 6.30 mm \times 22.23 mm,力传感器选用 ACF/110/04,最大作用力 100 N,行程 35.50 mm,如图 4 所示。实验工件设计为 400.00 mm \times 250.00 mm 的不锈钢板件,本次实验主要考虑进给速度 V_f 和接触力 F_n 对打磨效果的

影响。进给速度 V_f 决定了砂轮在叶片表面移动的速度,进给速度的大小直接影响磨粒去除工件表面材料的速度,进而影响材料去除的深度。打磨正压力 F_n 决定了砂轮与叶片表面之间的接触力度,直接影响磨削效果和工具头的磨损情况,适当的正压力可以使砂轮与叶片表面紧密贴合,提高打磨效果。




图 4 机器人打磨实验平台

为了降低实验成本,保证数据充足,采用田口正交实验,打磨工艺参数和参数水平如表 1 所示。

表 1 打磨工艺参数和水平

实验参数	符号	单位	参数水平		
			水平 1	水平 2	水平 3
进给速度	V_f	$\text{mm} \cdot \text{s}^{-1}$	120	140	160
最终接触力	F_n	N	30	35	40

分别采用三坐标测量仪(海克斯康 GLOBAL STATUS 9128)和粗糙度仪(Mitutoyo SJ-210)对加工后的工件表面单次打磨去除量和表面粗糙度等指标进行检测,如图 5 所示。实验结果如表 2 所示。



图5 检测工具

表2 打磨工艺实验参数表

实验次数	前倾角度, 侧倾角度/ $^{\circ}$	进给速度/ $\text{mm} \cdot \text{s}^{-1}$	初始接触力/N	最终接触力/N	行间距/mm	斜坡时间/s	粗糙度均值/ μm	去除高度/mm
1	-30,6	120	10	30	2.500	0.01	3.14	0.241
2	-30,6	140	10	30	2.500	0.01	2.96	0.226
3	-30,6	160	10	30	2.500	0.01	2.85	0.205
4	-30,6	120	10	35	2.500	0.01	3.09	0.233
5	-30,6	140	10	35	2.500	0.01	2.98	0.211
6	-30,6	160	10	35	2.500	0.01	2.38	0.196
7	-30,6	120	10	40	2.500	0.01	2.93	0.297
8	-30,6	140	10	40	2.500	0.01	3.06	0.301
9	-30,6	160	10	40	2.500	0.01	2.97	0.286




图6 GRG 结果

要求,工艺参数组合为前倾/侧倾角度 -30° 和 6° , 进给速度 120 mm/s , 初始接触力 10 N , 最终接触力 40 N , 行间距 2.5 mm 。

表3 灰色关联分析结果

实验次数	$\Delta_{0i}(k)$		灰色关联系数		GRG
	SR	MRR	SR	MRR	
1	0.000 0	0.198 7	1.000 0	0.333 3	0.711 9
2	0.056 0	0.248 8	0.961 5	0.363 6	0.703 2
3	0.091 1	0.318 9	0.882 4	0.400 0	0.674 0
4	0.017 0	0.225 9	0.987 2	0.344 8	0.709 6
5	0.050 3	0.299 3	0.937 5	0.357 1	0.686 7
6	0.242 7	0.348 2	0.703 1	0.500 0	0.615 2
7	0.066 2	0.012 6	1.000 0	0.642 9	0.845 7
8	0.025 5	0.000 0	0.970 6	0.571 4	0.798 1
9	0.053 2	0.049 5	0.921 9	0.589 7	0.778 3

通过 PCA 计算得到 SR 和 MRR 的权重分别为 0.568 和 0.432, 将表 2 中的实验结果进行 GRA 分析, 结果如图 6 和表 3 所示。结果表明, 第 7 组的 GRG 最大, 即 GRG_{best} , 说明该组工艺参数最满足多目标

在获得 GRG 之后,通过 DBN 建立 GRG 和工艺参数之间的映射关系。通过对实验数据进行训练, DBN 能够有效地学习到工艺参数与 GRG 之间的非线性关系。图 7 为实验结果与 DBN 计算结果的对比,结果表明, DBN 模型能够准确地预测 GRG 值,并且与实际实验结果高度一致。当接收到新的打磨参数输入时,模型能够即时计算出相应的 GRG 值,并将此值与已知的 GRG_{best} 进行对比,确定出最佳的打磨参数组合,进而实现对机器人打磨作业过程的动态优化与调整。

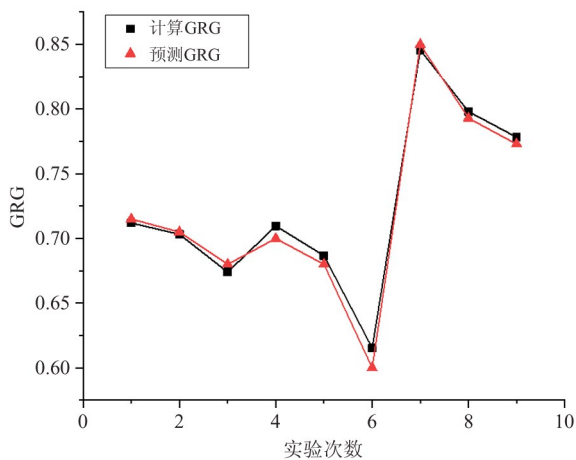


图 7 实验结果与 DBN 计算结果对比

4 结论

本文提出了一种基于 GRA-DBN 的机器人打磨工艺参数多目标优化方法,旨在解决民机机身打磨过程中表面粗糙度与材料去除率之间的相互制约问题。通过对比实验和模型验证,得出以下结论。

(1) 有效的多目标优化转化与智能化建模:利用 PCA 优化 GRA,成功将多目标优化转化为单目标优化问题。DBN 建立了精准的工艺参数优化模型,能够有效预测 GRG,实现打磨工艺参数的智能化调节,解决了由于多种工艺参数耦合导致的打磨质量与效率之间的矛盾。

(2) 提高打磨工艺的稳定性和可靠性:本文所提出的优化方法不仅在实验中验证了其在平衡 SR 和 MRR 方面的有效性,还提高了打磨工艺的稳定性和可靠性。该方法为机器人打磨技术在民机机身表面质量提升中的应用提供了有力支持,具有广阔

的应用前景。

(3) 广泛的应用潜力与可扩展性:尽管本文提出的优化方法主要应用于民机机身表面质量控制,但其关键技术同样适用于其他制造领域,如航天或汽车工业。通过调整模型参数和算法结构,该方法可灵活适应不同领域的打磨需求,展现出良好的可扩展性和适用性。

参考文献

- [1] Ren X, Huang X, Gao K, et al. A review of recent advances in robotic belt grinding of superalloys[J]. The International Journal of Advanced Manufacturing Technology, 2023, 127(3):1447-1482.
- [2] Zhang B, Wu S, Wang D, et al. A review of surface quality control technology for robotic abrasive belt grinding of aero-engine blades[J]. Measurement, 2023, 220: 113381.
- [3] Li J, Zou L, Luo G, et al. Enhancement and evaluation in path accuracy of industrial robot for complex surface grinding[J]. Robotics and Computer-Integrated Manufacturing, 2023, 81:102521.
- [4] Xiao G, Liu X, Song K, et al. Research on robotic belt grinding method of blisk for obtaining high surface integrity features with variable inclination angle force control[J]. Robotics and Computer-Integrated Manufacturing, 2024, 86:102680.
- [5] Ke X, Yu Y, Li K, et al. Review on robot-assisted polishing: Status and future trends[J]. Robotics and Computer-integrated manufacturing, 2023, 80:102482.
- [6] Zeng X, Zhu G, Gao Z, et al. Surface polishing by industrial robots: a review[J]. The International Journal of Advanced Manufacturing Technology, 2023, 125(9): 3981-4012.
- [7] Liu J, Zhang J, Li J, et al. Research on fuzzy impedance force control technology of robot-assisted abrasive cloth wheel polishing blade[J]. The International Journal of Advanced Manufacturing Technology, 2023, 127(5): 2537-2551.
- [8] Zhang W, Gong Y, Xu Y, et al. Experimental research on material removal in robot abrasive belt grinding[J]. Materials and Manufacturing Processes, 2024, 39(1): 123-129.

- [9] Pandiyan V, Caesarendra W, Glowacz A, et al. Modeling of material removal in abrasive belt grinding process; a regression approach[J]. *Symmetry*, 2020,12(1):99.
- [10] Pan Y, Wang Y, Zhou P, et al. Activation functions selection for BP neural network model of ground surface roughness [J]. *Journal of Intelligent Manufacturing*, 2020,31(8):1825 – 1836.
- [11] Yang Z, Chu Y, Xu X, et al. Prediction and analysis of material removal characteristics for robotic belt grinding based on single spherical abrasive grain model[J]. *International Journal of Mechanical Sciences*, 2021,190:106005.
- [12] Xu X H, Ye S T, Yang Z Y, et al. Analysis and prediction of surface roughness for robotic belt grinding of complex blade considering coexistence of elastic deformation and varying curvature [J]. *Science China Technological Sciences*, 2021,64(5):957 – 970.
- [13] Zhang H, Li L, Zhao J, et al. Theoretical investigation and implementation of nonlinear material removal depth strategy for robot automatic grinding aviation blade [J]. *Journal of Manufacturing Processes*, 2022,74:441 – 455.
- [14] Xie Y, Chang G, Yang J, et al. Process optimization of robotic polishing for mold steel based on response surface method[J]. *Machines*, 2022,10(4):283.
- [15] Nguyen H K, Van Dong P, Tran V Q. Investigation of influence of grinding wheel and cutting parameters on surface roughness and surface hardening when relieving grinding the gear milling teeth surface based on the Archimedes' spiral[J]. *International Journal of Metrology and Quality Engineering*, 2023,14:1.
- [16] Ermergen T, Taylan F. Investigation of DOE model analyses for open atmosphere laser polishing of additively manufactured Ti – 6Al-4V samples by using ANOVA[J]. *Optics & Laser Technology*, 2024,168:109832.
- [17] Sanjeevi R, Kumar G A, Krishnan B R. Optimization of machining parameters in plane surface grinding process by response surface methodology[J]. *Materials Today: Proceedings*, 2021,37:85 – 87.
- [18] Rekha R, Kumar S V, Raj V A, et al. Optimization of cylindrical grinding process parameters on austenitic stainless steel 304 using Taguchi based Grey Relational Analysis[J]. *Materials Today: Proceedings*, 2023,72:2569 – 2573.
- [19] Roy R, Ghosh S K, Kaiser T I, et al. Multi-response optimization of surface grinding process parameters of AISI 4140 alloy steel using response surface methodology and desirability function under dry and wet conditions[J]. *Coatings*, 2022,12:104.
- [20] Wang J, Tian Y, Hu X, et al. Predictive modelling and Pareto optimization for energy efficient grinding based on ANN-embedded NSGA II algorithm[J]. *Journal of Cleaner Production*, 2021,327:129479.
- [21] Xiao G J, Gao H, Zhang Y, et al. An intelligent parameters optimization method of titanium alloy belt grinding considering machining efficiency and surface quality[J]. *The International Journal Advanced Manufacturing Technology*, 2023,125:513 – 527.
- [22] Raman K, Kumar V S S. Evaluation of process parameter of friction stir processing of AA2024-T351 alloy using RSM and GRA [J]. *Journal of Adhesion Science and Technology*, 2023,2023:1 – 27.
- [23] Garg R K, Singh R P, Trehan R, et al. Modern manufacturing systems[M] // Kulshrestha A S, Dargar A K, Unune D R. Parametric optimization of electrodischarge face grinding: a hybrid machining process. New York: Apple Academic Press, 2022:343 – 355.
- [24] Chen X, Xu S, Meng F, et al. Multi-objective optimization in ultrasonic polishing of silicon carbide via Taguchi method and grey relational analysis[J]. *Materials*, 2023,16(16):5673.
- [25] Beaula M J H, Jayakumar K. Enhancement of grinding performances using fabricated pore aligned grinding wheels with PCA-GRA[J]. *Materials and Manufacturing Processes*, 2023,38(1):39 – 49.
- [26] Rekha R, Kumar S V, Raj V A, et al. Optimization of cylindrical grinding process parameters on austenitic stainless steel 304 using Taguchi based grey relational analysis[J]. *Materials Today: Proceedings*, 2023,72:2569 – 2573.
- [27] Kurita T. Principal component analysis (PCA) [M]. Computer vision: a reference guide. Cham: Springer International Publishing, 2021:1013 – 1016.
- [28] Gao S, Xu L, Zhang Y, et al. Rolling bearing fault diagnosis based on SSA optimized self-adaptive DBN[J]. *ISA Transactions*, 2022,128:485 – 502.

A multi-objective optimization method for robot polishing process based on GRA-DBN

Tao Yong^{*}, Xue Jiao^{**}, Yang Lin^{**}, Wang Xiaotong^{**}, Liu Yazui^{**}, Wei Hongxing^{*}
(^{*} School of Mechanical Engineering and Automation, Beihang University, Beijing 100191)
(^{**} Research Institute of Aero Engine, Beihang University, Beijing 100191)

Abstract

Robot polishing has become an important machining method for improving the surface quality of civil aircraft fuselages due to its flexibility, extensive workspace, and high operability. In the polishing process of civil aircraft fuselages, there exists a mutual constraint relationship between surface roughness and material removal rate. Therefore, achieving optimal balance between surface roughness and material removal rate is a significant challenge in current research. To address this issue, this paper proposes a multi-objective optimization method for robot polishing processes based on GRA (grey relational analysis)-DBN (deep belief networks). Initially, principal component analysis (PCA) is employed to optimize GRA and establish the mapping relationship between multi-objectives and process parameters. Subsequently, the multi-objective optimization is transformed into a single-objective optimization problem. Furthermore, integrating DBN facilitates the construction of an optimization model for robot polishing process parameters. Experimental validation demonstrates that the proposed method not only effectively balances surface roughness and material removal rate but also enhances the stability and reliability of the polishing process.

Key words: robot polishing, civil aircraft fuselage, multi-objective optimization, grey relational analysis, deep belief network