

基于 GTDBO-Perceiver 的工件装配预测控制方法^{*}王 一^{1,2} 付智超¹ 程 佳^{1,2} 张靖轩^{1,2}

(1. 华北理工大学电气工程学院 唐山 063210; 2. 唐山市先进测试与控制技术重点实验室 唐山 063210)

摘 要: 针对复杂装配中建模困难、模型泛化能力弱等问题,提出一种融合改进蜣螂算法(GTDBO)与 Perceiver 模型的位姿预测方法。首先,建立理想装配体并采集六维扰动下的装配特征,通过插值构建耦合数据集。之后,Perceiver 模型学习特征偏差与位姿偏差之间的非线性映射关系,并借助 GTDBO 优化关键超参数。该算法结合了博弈论平衡控制、自适应角度扰动及动态觅食策略。在 CEC2017 测试集上的实验表明,该算法的收敛速度与解质量均优于对比算法。最后,在两类工件的预测控制实验中,将该模型与雅可比法、BP 网络、SVR 及原始 Perceiver 模型进行对比。结果显示,GTDBO-Perceiver 在测试集上的 MAE 分别达到 6.72×10^{-2} 和 9.96×10^{-2} ,其能在有限控制次数内将偏差收敛至公差范围,并在缺陷件场景下实现误差均衡分配,体现出良好的泛化能力。

关键词: 装配位姿预测;Perceiver 模型;超参数优化;GTDBO 算法;博弈论

中图分类号: TN98 **文献标识码:** A **国家标准学科分类代码:** 510.40

Predictive control of workpiece assembly based on GTDBO-Perceiver

Wang Yi^{1,2} Fu Zhichao¹ Cheng Jia^{1,2} Zhang Jingxuan^{1,2}

(1. College of Electrical Engineering, North China University of Science and Technology, Tangshan 063210, China;

2. Tangshan Key Laboratory of Advanced Measurement and Control Technology, Tangshan 063210, China)

Abstract: Aiming at the problems of modeling difficulty and weak model generalization ability in complex assemblies, a position prediction method fusing the Improved Dung Beetle Algorithm (GTDBO) and Perceiver model is proposed. First, the ideal assembly is built and the assembly features under six-dimensional perturbation are collected, and a coupled dataset is constructed by interpolation. After that, the Perceiver model learns the nonlinear mapping relationship between feature deviation and positional deviation and optimizes its key hyperparameters with the help of GTDBO. The algorithm combines game-theoretic equilibrium control, adaptive angular perturbation and dynamic foraging strategies. Experiments on the CEC2017 test set show that the algorithm outperforms the comparison algorithms in terms of convergence speed and solution quality. Finally, the model is compared with Jacobian's method, BP networks, SVR and the original Perceiver model in predictive control experiments on two types of artifacts. The results show that GTDBO-Perceiver achieves MAEs of 6.72×10^{-2} and 9.96×10^{-2} on the test set, respectively. Its ability to converge the deviation to the tolerance range within a finite number of control times and to achieve a balanced distribution of errors in defective piecewise scenarios demonstrates a good generalization capability.

Keywords: assembly position prediction; Perceiver model; hyperparameter optimization; GTDBO algorithm; game theory

0 引 言

随着现代制造业向智能化发展,高质量装配已成为保障产品性能与生产效率的核心环节。尤其在汽车制造、航空航天等对精度要求较高的场景中,装配质量直接关系到产品稳定性和使用寿命。面对多源误差干扰,如何实现复

杂工件的最佳装配已成为工业机器人控制领域的重要研究方向^[1-4]。

传统装配控制多依赖解析建模策略,常通过物理模型或数学映射函数描述偏差与补偿之间的关系。例如, Yang 等^[5]将线性化时变动力学集成到模型预测控制(model predict control, MPC)框架中,用于仅配备磁转子卫星的姿

态控制,从而在受限环境中实现可控的轨迹修正;仲训果等^[6]引入自抗扰控制结构,结合扩展状态观测器与非线性反馈,有效抑制了模型不确定性与外部扰动。在汽车装配中,文献[7]和文献[8]通过构建装配误差目标函数并融合引力搜索算法(gravitational search algorithm, GSA)、遗传算法(genetic algorithm, GA)实现了夹具位姿调整与钣金件匹配质量提升。然而,此类方法对参数调优依赖性强,模型泛化能力有限,难以应对多维扰动与高精度要求并存的复杂装配任务。

近年来,数据驱动方法正加速替代传统解析建模^[9]。反向传播神经网络(back propagation neural network, BPNN)、径向基函数网络(radial basis function, RBF)等浅层模型因结构简单被广泛用于预测建模。例如,韩顺杰等^[10]将 BP 网络与遗传算法结合,通过优化网络权重实现机械臂的无标定位伺服控制。但浅层模型在高维非线性建模中提取能力受限,难以适应复杂场景。为增强模型表达力,Hyen 等^[11]将人工神经网络(artificial neural network, ANN)引入模型预测控制框架,提出仿真预训练与实测微调结合的双阶段训练方案,显著提升了机器人跟踪精度。Transformer 模型因其卓越的特征提取能力,正日益成为预测控制领域的新趋势。Liu 等^[12]将其应用于多道焊缝路径预测任务,通过处理点云切片序列,实现了高精度轨迹拟合和速度预测。作为其高效变体的 Perceiver 模型,通过跨模态感知机制强化了对非结构化输入的建模能力,在表达能力和泛化性能上均具备优势。但该模型在应用中仍存在超参数敏感、训练不稳定、过拟合等问题,亟需结合智能优化算法构建高效稳定的训练机制。蜣螂优化算法(dung beetle optimizer, DBO)具备结构简洁、参数少、全局搜索能力强等优势,适用于高维非凸问题建模^[13]。其多行为机制增强了搜索多样性和跳出局部最优的能力,可有效缓解模型训练中的早熟收敛问题。相比其他智能优化算法,DBO 收敛更稳、参数依赖更低,便于与神经网络融合应用。

基于上述分析,针对复杂装配任务中预测精度受限与模型泛化能力不足的问题,提出一种基于改进蜣螂优化算法(game theory dung beetle optimizer, GTDBO)与 Perceiver 模型的混合训练方法。该方法以传感器采集的装配偏差为输入,输出六维偏移量,通过 Perceiver 模型学习非线性映射关系,并采用 GTDBO 算法自适应优化模型的超参数,提升训练的稳定性与预测性能。与传统解析模型和单一神经网络两类方法的对比验证表明,所提方法在多维扰动条件下展现出更优的预测精度和鲁棒性,为柔性装配控制提供了一种可行的技术路径。

1 柔性装配控制系统

基于传感器反馈的装配控制系统,通过装配特征偏差引导调整机械臂末端执行器的位姿,该系统结构如图 1 所示。首先,机械臂携带工件移动至预先标定的理想装配位

姿。定位稳定后,由传感器扫描工件与基准零件间的关键位置,获取反映当前装配状态的特征信息(间隙和阶差)。




图 1 柔性装配控制系统

Fig. 1 Flexible assembly control system

随后,系统将采集到的测量数据输入至已训练完成的 GTDBO-Perceiver 控制器。该控制器基于深度感知模型,学习装配特征偏差与机器人末端位姿偏移量之间的非线性映射关系,输出工件在当前状态下的位姿补偿量 $\Delta \mathbf{X}$ 。该补偿量经由机器人控制器执行,实现工件的微调。调整完成后,系统再次采集装配特征信息,并计算当前特征与目标特征的偏差,判断是否满足装配公差要求。若仍存在超差,则重复“测量-预测-调整”闭环控制流程,直至各测量点的装配特征误差收敛至公差内,最终完成工件的最佳装配。

2 GTDBO-Perceiver 控制器

为构建装配特征偏差与机器人位姿偏移之间的非线性映射关系,本文采用 Perceiver 模型学习样本数据,并结合 GTDBO 算法优化该模型的关键超参数,在保证训练效率的同时提高位姿预测精度与泛化能力。

2.1 Perceiver 模型

Perceiver 是一种基于 Transformer 架构的通用感知模型,具备较强的模态适应性和结构扩展能力^[14]。区别于传统深度学习模型,Perceiver 不对输入样本维度或模态作预先约束,而是通过交叉注意力机制(cross-attention)将任意长度、维度的数据压缩至一组固定长度的隐向量中,从而实现多模态数据的处理。其整体架构如图 2 所示。

输入向量首先通过交叉注意力机制与一组可学习的隐向量融合,实现原始信息的有效压缩。随后,隐向量在 Transformer 自注意力模块中迭代更新,完成特征的深层提取。相较于传统 Transformer 的 $O(M^2)$ 计算复杂度,Perceiver 通过低维注意力瓶颈将其降至 $O(MN)$ (M 为输入长度, N 为隐向量数量且 $N \ll M$),显著减轻训练负担。为进一步提升表达能力并抑制过拟合,模型采用权重共享的交叉-自注意力模块,实现信息的深度融合与重复激活。

2.2 DBO 算法

1) 种群初始化

对于 d 维优化问题,算法通过随机化的方式生成种群。规模为 N 的种群矩阵如式(1)所示,其中第 i 只蜣螂的位置表示为 $\mathbf{x}_i = [x_{i1}, x_{i2}, \dots, x_{id}]$ 。

$$\mathbf{X} = \begin{bmatrix} x_{11} & \cdots & x_{1d} \\ \vdots & \ddots & \vdots \\ x_{N1} & \cdots & x_{Nd} \end{bmatrix}_{N \times d} \quad (1)$$




图 2 Perceiver 模型架构
Fig. 2 Perceiver model architecture

2) 滚球蜣螂

无障碍物时,蜣螂利用太阳导航保持粪球在直线上滚动,该数学模型如式(2)所示。

$$\begin{cases} \mathbf{x}_i(t+1) = \mathbf{x}_i(t) + \alpha \times k \times \mathbf{x}_i(t-1) + b \times \Delta \mathbf{x} \\ \Delta \mathbf{x} = |\mathbf{x}_i(t) - \mathbf{X}^*| \end{cases} \quad (2)$$

式中: $\mathbf{x}_i(t)$ 表示蜣螂*i*在第*t*次迭代时的位置, $\alpha \in \{-1, 1\}$ 为自然系数, $k \in (0, 0.2]$ 为偏转系数, $b \in (0, 1)$ 为常量, $\Delta \mathbf{x}$ 表示光照强度, $\mathbf{X}^*$ 为全局最差位置。

当遇到障碍物时,蜣螂通过跳舞调整角度。在确定新方向后继续滚球,公式如下:

$$\mathbf{x}_i(t+1) = \mathbf{x}_i(t) + \tan\theta \cdot |\mathbf{x}_i(t) - \mathbf{x}_i(t-1)| \quad (3)$$

式中: $\theta \in [0, \pi]$ 且 $\theta \in [0, \pi/2, \pi]$ 时,位置不变。

3) 育雏球

自然界中,粪球被雌性蜣螂滚到安全区并隐藏,为后代提供适宜的栖息地。产卵区域定义为:

$$\begin{cases} \mathbf{Lb}^* = \max(\mathbf{X}^* \times (1-R), \mathbf{Lb}) \\ \mathbf{Ub}^* = \min(\mathbf{X}^* \times (1+R), \mathbf{Ub}) \end{cases} \quad (4)$$

式中: $\mathbf{Lb}^*$ 、 $\mathbf{Ub}^*$ 分别表示产卵区域的下界和上界, $\mathbf{X}^*$ 为当前局局部最优解, $R = t/T$, T 为最大迭代次数, $\mathbf{Lb}$ 、 $\mathbf{Ub}$ 分别表示优化问题的下界和上界。确定产卵区域后,雌性蜣螂将在此区域内产下育雏球,可表示为:

$$\mathbf{B}_i(t+1) = \mathbf{X}^* + \mathbf{b}_1 \times (\mathbf{B}_i(t) - \mathbf{Lb}^*) + \mathbf{b}_2 \times (\mathbf{B}_i(t) - \mathbf{Ub}^*) \quad (5)$$

式中: $\mathbf{B}_i(t)$ 表示育雏球*i*在第*t*次迭代时的位置, $\mathbf{b}_1$ 、 $\mathbf{b}_2$ 为两个大小为 $1 \times d$ 的独立随机向量。

4) 小蜣螂

育雏球发育为小蜣螂后将从地下钻出,在最佳觅食区域寻找食物,具体公式如下:

$$\begin{cases} \mathbf{Lb}^b = \max(\mathbf{X}^b \times (1-R), \mathbf{Lb}) \\ \mathbf{Ub}^b = \min(\mathbf{X}^b \times (1+R), \mathbf{Ub}) \end{cases} \quad (6)$$

$$\mathbf{x}_i(t+1) = \mathbf{x}_i(t) + \mathbf{C}_1 \times (\mathbf{x}_i(t) - \mathbf{Lb}^b) + \mathbf{C}_2 \times (\mathbf{x}_i(t) - \mathbf{Ub}^b) \quad (7)$$

式中: $\mathbf{Lb}^b$ 、 $\mathbf{Ub}^b$ 为觅食区域的边界, $\mathbf{X}^b$ 为全局最佳位置, $\mathbf{C}_1$ 表示服从正态分布的随机向量, $\mathbf{C}_2$ 表示范围在 $(0, 1)$ 内的

随机向量。

5) 盗贼蜣螂

种群中盗贼蜣螂活动在全局最佳位置周边,通过窃取其他蜣螂的粪球更新自身位置,公式为:

$$\mathbf{x}_i(t+1) = \mathbf{X}^b + S \times \mathbf{g} \times (|\mathbf{x}_i(t) - \mathbf{X}^*| + |\mathbf{x}_i(t) - \mathbf{X}^b|) \quad (8)$$

式中: S 为常量, $\mathbf{g}$ 表示大小为 $1 \times d$ 且服从正态分布的随机向量。

2.3 GTDBO 算法

1) 博弈论平衡控制策略

个体行为往往影响群体性能,将蜣螂个体视作理性博弈参与者来达到最大化自身收益。首先,个体的总收益综合考虑个体自身适应度及其对群体适应度的贡献,后者依据夏普利值(Shapley value)进行分配,确保个体间收益分配的公平性。其次,为保证个体行为与群体目标一致,引入纳什均衡(Nash equilibrium)概念^[15]。即在给定其他个体策略不变的情况下,任何个体无法通过单方面改变策略来提高自身收益。具体公式如下:

$$R_1(i) = f(i) - f_{\text{pre}}(i) \quad (9)$$

$$Shv = \frac{1}{N} \sum_{i=1}^N (f(i) - f_{\text{pre}}(i)) \quad (10)$$

$$R_T(i) = R_1(i) + Shv \quad (11)$$

式中: $R_1(i)$ 为第*i*只蜣螂的个体收益, $f(i)$ 、 $f_{\text{pre}}(i)$ 分别表示该个体的当前适应度值和上一代适应度值, $Shv(i)$ 为简化的夏普利值,此处假设每个个体对群体收益的贡献是均等的, $R_T(i)$ 为第*i*只蜣螂的总收益。

根据该个体的总收益情况,决定搜索方向:

$$\begin{cases} \mathbf{x}_i(t+1) = \mathbf{x}_i(t) + \mathbf{m} \cdot (\mathbf{X}^b - \mathbf{x}_i(t)), R_T(i) > 0 \\ \mathbf{x}_i(t+1) = \mathbf{X}^b + \mathbf{m} \cdot (\mathbf{X}^b - \mathbf{x}_i(t)), R_T(i) \leq 0 \end{cases} \quad (12)$$

式中: $\mathbf{m}$ 为大小为 $1 \times d$ 且服从正态分布的随机向量, $\mathbf{X}^b$ 为全局最佳位置。

当总收益为正时,该只蜣螂向全局最优解靠近,否则说明该个体适应度未得到提升或对群体收益贡献不足,则进行随机扰动探索新的解空间。此方式能够有效调和个

体与群体目标间的潜在冲突,提升全局搜索效率和收敛速度。

2) 自适应角度调整机制

滚球蜚螂在跳舞时角度 θ 是随机生成的。此种方式虽然简便,但缺乏方向性、无法适应每个个体的状态,导致蜚螂在搜索过程中频繁改变方向,浪费计算资源。基于此引入自适应角度调整机制,使搜索方向根据迭代次数和个体适应度动态调整,有效平衡全局探索与局部开发。公式为:

$$\theta_i = \theta_{\min} + (\theta_{\max} - \theta_{\min}) \cdot \frac{t}{T} \cdot \left(1 - \frac{f(i) - f_{\min}}{f_{\max} - f_{\min}}\right) \quad (13)$$

式中: $\theta_{\min}$ 、 $\theta_{\max}$ 分别为角度的最小、最大值, $\theta_{\min}$ 和 $\theta_{\max}$ 可根据问题复杂度调整,通常取 $0 \sim \pi$, T 为最大迭代次数, $f(i)$ 为当前个体的适应度, $f_{\min}$ 、 $f_{\max}$ 为当前种群的最小、最大适应度。

3) 动态转换觅食策略

算法求解过程中,适应度值是衡量当前解质量的关键指标。当个体适应度较大时,说明当前解的质量较差,可

能处于较复杂的解空间区域。此时应加大全局搜索力度,提高找到全局最优解的可能性。因此,根据不同小蜚螂的适应度情况,设计了一种基于个体适应度的动态转换觅食策略。动态阈值为:

$$threshold(i) = 0.15 \cdot \left(1 - \frac{f(i)}{f_{\max}}\right) \quad (14)$$

式中: $f(i)$ 为当前个体 i 的适应度值, $f_{\max}$ 为当前种群的最大适应度值。

$$\begin{cases} \mathbf{x}_i(t+1) = \mathbf{x}_i(t) + \mathbf{C}_1 \times (\mathbf{x}_i(t) - \mathbf{Lb}^b) + \\ \mathbf{C}_2 \times (\mathbf{x}_i(t) - \mathbf{Ub}^b), threshold < \eta \\ \mathbf{x}_i(t+1) = \mathbf{X}^b + (\sin(2\pi \cdot \frac{t}{T}) \cdot (\mathbf{x}_i(t) - \mathbf{X}^r)), \text{其他} \end{cases} \quad (15)$$

式中: η 为 $[0, 0.5)$ 的随机数, $\mathbf{X}^r = \mathbf{C}_1 \cdot \mathbf{x}_i(t) + \mathbf{C}_2 \cdot \sin(2\pi \cdot t/T)$ 为周期性扰动参考点。适应度较差的小蜚螂倾向于使用全局觅食策略,而较优个体倾向于使用周期性扰动和最优值引导的局部搜索策略,避免算法过早收敛。GTDBO 算法流程如图 3 所示。




图 3 GTDBO 算法流程

Fig. 3 GTDBO algorithmic flow

GTDBO-Perceiver 混合训练流程如图 4 所示。其中,均方误差(mean squared error, MSE)为训练损失函数, e_1 、 e_2 为超参数优化阶段和正式训练阶段的迭代停止阈值。

3 实验与结果分析

本文实验分为两部分:1)通过 CEC2017 基准函数集测试 GTDBO 算法的性能。2)基于仿真数据集混合训练 GTDBO-Perceiver 控制器,并对比其他预测控制方法。实验均在 CPU 为 i7-12700H 2.30 GHz,内存为 32 GB, GPU 为 NVIDIA RTX3050,显存为 4 GB,操作系统为 Windows 10 的计算机上完成。

3.1 CEC2017 函数集测试及分析

选用 CEC2017 基准函数集^[16],在 MATLAB 2020b 环境中对比其他优化算法评估 GTDBO 算法性能。该函数集包括单峰函数(F1~F3, F2 已剔除)、多峰函数(F4~F10)、混合函数(F11~F20)以及复合函数(F21~F30)。

为确保公平,所有算法的搜索代理个数均设定为 30,最大迭代次数设为 500,函数集变量设为 100 维。同时,各算法在函数集上独立运行 30 次,并记录最优值、平均值和标准差,作为性能评估指标。对比算法方面,选取了蜚螂优化算法^[17]、白鲸优化算法(beluga whale optimization, BWO)^[18]、长鼻浣熊优化算法(coati optimization




图 4 GTDBO-Perceiver 混合训练流程
Fig. 4 GTDBO-Perceiver hybrid training procedure

algorithm, COA)^[19]、鸽群优化算法 (pigeon-inspired optimization, PIO)^[20] 和黑翅鸢优化算法 (black-winged kite algorithm, BKA)^[21], 各算法参数如表 1 所示。

1) 优化结果分析

表 2 给出了不同算法在 CEC2017 上的测试结果。由

表 1 各算法参数设置

Table 1 Parameterization of algorithms

算法	参数设置
BWO	B_f 阈值=0.5, $\beta=1.5$, $W_f \in [0.05, 0.1]$
COA	合作捕猎: 分散逃离=0.5; 0.5
PIO	地图因子=0.7T, 指南因子=0.3T 淘汰比例=50%
BKA	$p=0.9$, $r \in \text{rand}[0, 1)$, $\mu=0$, $\delta=1$
DBO	$\alpha \in \{-1, 1\}$, $k=0.1$, $b=0.3$, $S=0.5$ 滚球: 育雏球: 觅食: 盗贼=0.2; 0.2; 0.25; 0.35 $\alpha \in \{-1, 1\}$, $k=0.1$, $b=0.3$
GTDBO	$S=0.5$, $\theta \in [0, \pi]$, $\eta \in \text{rand}[0, 0.5)$ 滚球: 育雏球: 觅食: 盗贼=0.2; 0.2; 0.25; 0.35

表可知, GTDBO 在各类测试函数上均取得了良好的优化效果。其最优值、平均值在 F1、F4、F13、F19、F30 等函数上优势显著, 体现出较好的全局搜索能力。而在个别函数上(F5、F21), GTDBO 与部分对比算法性能相当。

表 2 CEC2017 函数集测试结果(100 维)

Table 2 CEC2017 function set test results (dim=100)

函数	指标	BWO	COA	PIO	BKA	DBO	GTDBO
F1	Best	2.46×10^{11}	2.36×10^{11}	2.46×10^{11}	1.10×10^{11}	2.00×10^{10}	4.58×10^7
	Mean	2.59×10^{11}	2.67×10^{11}	2.72×10^{11}	1.55×10^{11}	1.04×10^{11}	1.02×10^8
	Std	5.65×10^9	1.19×10^{10}	1.42×10^{10}	3.80×10^{10}	7.26×10^{10}	4.81×10^7
F3	Best	3.38×10^5	3.05×10^5	3.67×10^5	2.19×10^5	3.53×10^5	2.63×10^5
	Mean	3.81×10^5	3.54×10^5	4.46×10^5	2.98×10^5	6.77×10^5	4.23×10^5
	Std	2.77×10^4	1.53×10^4	1.50×10^5	6.03×10^4	2.83×10^5	1.38×10^5
F4	Best	8.04×10^4	8.85×10^4	4.87×10^4	1.36×10^4	3.95×10^3	7.43×10^2
	Mean	9.75×10^4	1.17×10^5	7.41×10^4	2.80×10^4	2.32×10^4	8.89×10^2
	Std	7.90×10^3	1.31×10^4	1.33×10^4	1.84×10^4	1.88×10^4	9.66×10^1
F5	Best	2.05×10^3	2.06×10^3	2.08×10^3	1.36×10^3	1.36×10^3	1.15×10^3
	Mean	2.12×10^3	2.14×10^3	2.21×10^3	1.61×10^3	1.71×10^3	1.34×10^3
	Std	2.88×10^1	3.87×10^1	5.04×10^1	2.46×10^2	2.07×10^2	1.22×10^2
F6	Best	7.03×10^2	7.02×10^2	6.99×10^2	6.70×10^2	6.61×10^2	6.47×10^2
	Mean	7.13×10^2	7.12×10^2	7.17×10^2	6.80×10^2	6.79×10^2	6.73×10^2
	Std	3.11×10^0	4.12×10^0	4.98×10^0	8.65×10^0	1.27×10^1	1.11×10^1
F7	Best	3.64×10^3	3.78×10^3	3.95×10^3	3.24×10^3	2.34×10^3	1.83×10^3
	Mean	3.90×10^3	4.01×10^3	4.14×10^3	3.38×10^3	2.95×10^3	2.74×10^3
	Std	7.21×10^1	9.01×10^1	8.04×10^1	1.03×10^2	2.53×10^2	2.96×10^2
F8	Best	2.55×10^3	2.45×10^3	2.43×10^3	1.81×10^3	1.83×10^3	1.46×10^3
	Mean	2.60×10^3	2.58×10^3	2.64×10^3	1.98×10^3	2.10×10^3	1.79×10^3
	Std	2.66×10^1	5.33×10^1	7.37×10^1	1.78×10^2	2.07×10^2	2.16×10^2
F9	Best	7.43×10^4	7.22×10^4	8.84×10^4	3.12×10^4	4.29×10^4	2.34×10^4
	Mean	8.07×10^4	8.02×10^4	1.01×10^5	4.46×10^4	7.52×10^4	3.51×10^4
	Std	3.03×10^3	3.67×10^3	5.64×10^3	1.70×10^4	1.15×10^4	1.27×10^4

表 2(续)
Table 2 (continued)

函数	指标	BWO	COA	PIO	BKA	DBO	GTDBO
F10	Best	3.10×10^4	3.15×10^4	3.10×10^4	1.63×10^4	1.71×10^4	1.37×10^4
	Mean	3.24×10^4	3.29×10^4	3.30×10^4	2.07×10^4	2.94×10^4	1.71×10^4
	Std	5.97×10^2	5.60×10^2	6.81×10^2	3.28×10^3	3.93×10^3	1.46×10^3
F11	Best	2.05×10^5	1.67×10^5	1.41×10^5	3.54×10^4	1.60×10^5	7.47×10^3
	Mean	3.74×10^5	2.77×10^5	2.12×10^5	6.84×10^4	2.51×10^5	2.02×10^4
	Std	7.65×10^4	5.44×10^4	4.00×10^4	3.13×10^4	5.70×10^4	1.73×10^4
F12	Best	1.67×10^{11}	1.77×10^{11}	6.89×10^{10}	2.64×10^{10}	4.01×10^9	3.59×10^7
	Mean	1.89×10^{11}	2.10×10^{11}	9.64×10^{10}	6.22×10^{10}	6.68×10^9	1.39×10^8
	Std	1.10×10^{10}	1.28×10^{10}	1.29×10^{10}	3.66×10^{10}	2.16×10^9	1.56×10^8
F13	Best	2.48×10^{10}	3.85×10^{10}	7.74×10^9	1.91×10^9	1.71×10^7	3.40×10^4
	Mean	4.35×10^{10}	4.99×10^{10}	1.51×10^{10}	1.14×10^{10}	3.00×10^8	3.42×10^5
	Std	4.55×10^9	4.41×10^9	2.91×10^9	1.04×10^{10}	2.26×10^8	1.17×10^6
F14	Best	3.80×10^7	2.63×10^7	2.39×10^7	6.01×10^5	3.38×10^6	3.69×10^5
	Mean	7.86×10^7	9.25×10^7	7.19×10^7	3.26×10^6	1.54×10^7	1.96×10^6
	Std	2.31×10^7	4.09×10^7	2.61×10^7	4.66×10^6	8.65×10^6	2.41×10^6
F15	Best	1.67×10^{10}	1.49×10^{10}	2.86×10^9	6.00×10^5	6.19×10^4	2.15×10^4
	Mean	2.30×10^{10}	2.59×10^{10}	5.31×10^9	2.38×10^9	8.81×10^7	7.24×10^4
	Std	2.77×10^9	4.74×10^9	8.95×10^8	4.39×10^9	1.30×10^8	3.83×10^4
F16	Best	1.97×10^4	1.82×10^4	1.30×10^4	7.29×10^3	7.32×10^3	5.33×10^3
	Mean	2.30×10^4	2.40×10^4	1.44×10^4	1.10×10^4	9.34×10^3	6.56×10^3
	Std	1.50×10^3	2.86×10^3	8.42×10^2	3.94×10^3	1.51×10^3	8.49×10^2
F17	Best	3.58×10^5	2.14×10^6	1.12×10^4	5.14×10^3	7.62×10^3	4.87×10^3
	Mean	5.87×10^6	1.22×10^7	2.37×10^4	1.33×10^5	9.90×10^3	6.45×10^3
	Std	3.36×10^6	8.68×10^6	1.05×10^4	4.63×10^5	1.61×10^3	8.44×10^2
F18	Best	1.09×10^8	7.02×10^7	5.23×10^7	6.62×10^5	7.18×10^6	4.49×10^5
	Mean	2.09×10^8	2.82×10^8	1.27×10^8	3.09×10^6	2.43×10^7	3.50×10^6
	Std	7.04×10^7	1.33×10^8	3.63×10^7	1.77×10^6	1.27×10^7	4.48×10^6
F19	Best	1.79×10^{10}	1.27×10^{10}	1.48×10^9	1.93×10^7	4.46×10^6	3.46×10^3
	Mean	2.31×10^{10}	2.60×10^{10}	5.30×10^9	2.60×10^9	1.11×10^8	4.40×10^5
	Std	2.55×10^9	5.11×10^9	1.34×10^9	6.33×10^9	2.12×10^8	7.08×10^5
F20	Best	6.98×10^3	6.67×10^3	7.64×10^3	4.79×10^3	5.70×10^3	5.29×10^3
	Mean	7.77×10^3	7.80×10^3	8.09×10^3	5.73×10^3	7.44×10^3	6.16×10^3
	Std	3.24×10^2	3.84×10^2	2.43×10^2	7.02×10^2	7.35×10^2	6.94×10^2
F21	Best	4.49×10^3	4.69×10^3	3.94×10^3	3.51×10^3	3.73×10^3	3.18×10^3
	Mean	4.79×10^3	5.09×10^3	4.11×10^3	4.21×10^3	3.99×10^3	3.55×10^3
	Std	1.19×10^2	1.80×10^2	1.04×10^2	2.93×10^2	1.34×10^2	2.70×10^2
F22	Best	3.35×10^4	3.35×10^4	3.36×10^4	1.80×10^4	2.19×10^4	1.78×10^4
	Mean	3.48×10^4	3.51×10^4	3.56×10^4	2.32×10^4	3.05×10^4	2.07×10^4
	Std	5.88×10^2	8.00×10^2	6.80×10^2	2.51×10^3	4.53×10^3	1.78×10^3
F23	Best	5.68×10^3	6.22×10^3	4.54×10^3	4.63×10^3	4.16×10^3	3.89×10^3
	Mean	6.15×10^3	6.83×10^3	4.71×10^3	5.15×10^3	4.79×10^3	4.33×10^3
	Std	1.68×10^2	2.75×10^2	1.32×10^2	3.04×10^2	2.31×10^2	2.68×10^2

表 2(续)

Table 2 (continued)

函数	指标	BWO	COA	PIO	BKA	DBO	GTDBO
F24	Best	8.37×10^3	9.21×10^3	5.54×10^3	5.92×10^3	5.21×10^3	4.31×10^3
	Mean	9.37×10^3	1.06×10^4	5.87×10^3	6.80×10^3	6.13×10^3	5.21×10^3
	Std	4.13×10^2	8.46×10^2	1.98×10^2	8.81×10^2	3.29×10^2	4.76×10^2
F25	Best	2.59×10^4	2.65×10^4	2.30×10^4	8.47×10^3	4.68×10^3	3.41×10^3
	Mean	2.81×10^4	3.01×10^4	2.91×10^4	1.34×10^4	9.36×10^3	3.59×10^3
	Std	1.03×10^3	1.56×10^3	2.67×10^3	4.17×10^3	6.75×10^3	1.28×10^2
F26	Best	4.80×10^4	4.82×10^4	3.00×10^4	3.07×10^4	2.07×10^4	1.65×10^4
	Mean	5.07×10^4	5.32×10^4	4.73×10^4	3.78×10^4	2.72×10^4	2.07×10^4
	Std	1.21×10^3	2.24×10^3	1.01×10^4	5.71×10^3	3.99×10^3	3.18×10^3
F27	Best	1.11×10^4	1.25×10^4	5.53×10^3	4.74×10^3	4.16×10^3	3.20×10^3
	Mean	1.28×10^4	1.47×10^4	6.54×10^3	6.47×10^3	4.69×10^3	3.26×10^3
	Std	6.27×10^2	1.24×10^3	4.02×10^2	1.83×10^3	4.85×10^2	2.69×10^2
F28	Best	2.62×10^4	2.81×10^4	2.62×10^4	9.50×10^3	7.17×10^3	3.30×10^3
	Mean	2.77×10^4	3.06×10^4	3.25×10^4	1.72×10^4	1.84×10^4	3.59×10^3
	Std	6.52×10^2	1.47×10^3	2.44×10^3	5.39×10^3	6.22×10^3	1.37×10^2
F29	Best	8.15×10^4	1.66×10^5	2.14×10^4	9.99×10^3	9.36×10^3	5.82×10^3
	Mean	4.58×10^5	8.55×10^5	3.49×10^4	2.25×10^4	1.23×10^4	8.29×10^3
	Std	1.71×10^5	4.87×10^5	9.15×10^3	2.73×10^4	1.60×10^3	1.40×10^3
F30	Best	3.58×10^{10}	2.08×10^{10}	4.92×10^9	4.15×10^8	5.22×10^7	5.88×10^4
	Mean	4.10×10^{10}	4.24×10^{10}	7.31×10^9	7.31×10^9	2.62×10^8	2.96×10^6
	Std	2.44×10^9	7.30×10^9	1.49×10^9	8.00×10^9	1.52×10^8	5.86×10^6

为分析各算法的解分布特性,图 5 展示了各算法在部分函数上的箱型图。在 F1 上,GTDBO 解的波动最小,表

现出优良的精度和稳定性;在 F5 与 F11 上,其中位数更优且分布更为集中,体现出较强的鲁棒性;在复杂函数 F16




图 5 部分函数箱型图

Fig. 5 Partial function box plots

和 F25 上,部分算法存在明显离群点,而 GTDBO 结果分布紧凑,未出现明显异常值,进一步表明其在不同类型问题下的稳定性。


2) 收敛曲线对比

为进一步验证该算法的收敛性,图 6 展示了各算法在 CEC2017 函数集上的收敛曲线。相较于其他算法,GTDBO 在迭代初期下降迅速,整体曲线平滑,体现出更快的收敛速度和更高的寻优能力。在处理单峰、多峰函数时,除 BKA 外,其他对比算法普遍陷入局部最优,而 GTDBO 不仅在初期快速定位全局最优区域,还能持续提升解的精度。对于高维复合、混合函数,GTDBO 在保持全

局搜索能力的同时兼顾局部开发能力,有效跳出收敛停滞区。相较于 DBO,改进算法在寻优精度和脱困能力方面均有明显提升,验证了改进策略的有效性。

3) Wilcoxon 秩和检验

为评估 GTDBO 与其他 5 种对比算法的差异性,采用 Wilcoxon 秩和检验进行非参数统计分析。当 $P < 0.05$ 时,表明改进算法与对比算法在该测试函数上的结果存在显著差异。检验结果如表 3 所示,其中加粗部分为差异不显著。GTDBO 在大多数测试函数上与其他算法存在显著差异,仅在少数单峰、混合函数上相似度较高,表明该算法在整体性能上优势显著。






图 6 各算法收敛曲线
Fig. 6 Convergence curves for algorithms

表 3 Wilcoxon 秩和检验结果
Table 3 Results of Wilcoxon test

函数	BWO	COA	PIO	BKA	DBO
F1	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}
F3	4.38×10^{-1}	2.71×10^{-2}	7.28×10^{-1}	7.74×10^{-6}	8.15×10^{-5}
F4	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}
F5	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}	3.01×10^{-7}	5.46×10^{-9}
F6	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}	4.51×10^{-2}	1.15×10^{-1}
F7	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}	3.69×10^{-11}	2.62×10^{-3}
F8	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}	1.25×10^{-4}	1.61×10^{-6}
F9	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}	8.56×10^{-4}	2.15×10^{-10}
F10	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}	1.31×10^{-8}	1.46×10^{-10}
F11	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}	5.07×10^{-10}	3.02×10^{-11}
F12	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}
F13	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}
F14	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}	2.51×10^{-2}	2.61×10^{-10}
F15	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}	1.46×10^{-10}
F16	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}	1.46×10^{-10}	5.07×10^{-10}
F17	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}	3.01×10^{-7}	4.50×10^{-11}
F18	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}	4.64×10^{-1}	2.37×10^{-10}
F19	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}
F20	6.12×10^{-10}	6.72×10^{-10}	8.15×10^{-11}	3.50×10^{-3}	2.20×10^{-7}
F21	3.02×10^{-11}	3.02×10^{-11}	1.21×10^{-10}	1.55×10^{-9}	6.53×10^{-8}
F22	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}	1.02×10^{-5}	8.99×10^{-11}
F23	3.02×10^{-11}	3.02×10^{-11}	3.26×10^{-7}	1.09×10^{-10}	1.07×10^{-7}
F24	3.02×10^{-11}	3.02×10^{-11}	7.09×10^{-8}	1.78×10^{-10}	1.01×10^{-8}
F25	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}
F26	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}	5.53×10^{-8}
F27	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}	1.96×10^{-10}
F28	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}
F29	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}	8.15×10^{-11}	3.82×10^{-10}
F30	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}

3.2 预测控制实验及分析

1)数据集构建与处理

在 CATIA P3 V5-6R2020 环境下构建简化装配体模型(图 7),其中矩形框体为基准件,长方体为标准待装

配件。

(1)理想装配位姿标定:首先确定关键测量位置及对应的装配特征(间隙、阶差),设定其理想值和公差要求。构建与装配件固联的局部坐标系,作为姿态调整的参考基




图 7 装配体模型
Fig. 7 Assembly model

准。调整装配件位姿,利用 CATIA 内置测量模块获取各测量点的特征。当所有测量数据逼近理想值时,记录该装配状态的位姿,作为后续扰动的基准,如表 4 所示。

(2)位姿扰动采样:基于理想位姿对装配件进行六自由度扰动采样。其中,沿 X、Y、Z 三轴分别施加 $\pm 1\text{ mm}$ 、 $\pm 2\text{ mm}$ 、 $\pm 3\text{ mm}$ 和 $\pm 4\text{ mm}$ 的线性位移;绕 X、Y、Z 轴分别施加 $\pm 0.1^\circ$ 、 $\pm 0.2^\circ$ 、 $\pm 0.3^\circ$ 和 $\pm 0.4^\circ$ 的角度旋转,共构造 48 组扰动位姿,并获取对应状态下的装配特征测量值。将

表 4 理想装配参数

Table 4 Ideal assembly parameters

装配特征	理想值	公差	位置 1	位置 2	位置 3	位置 4	位置 5	位置 6
间隙/mm	5	± 0.5	4.990	4.990	5.010	5.010	4.999	5.001
阶差/mm	0	± 0.2	0.002	0.002	0.002	0.002	0.002	0.002
理想位姿	(60.210 mm, -6.023 mm, 11.269 mm, 2.87°, 1.76°, -0.92°)							

测量结果与理想值作差,构造输入、输出数据集。

(3)样本扩充:由于原始样本均对应单一自由度的扰动,难以支撑模型对多维耦合关系的学习。因此在归一化处理,从原始样本中任选两个样本对,按照随机权重进行插值,生成新的样本。以组合数 $C(48,2)$ 为基础,每对样本插值 2 组中间样本,扩展得到 2 256 组复合样本,连同原始数据构成 2 304 组样本。该方法避免了噪声注入带来的不确定性和非物理性变化,有助于提升模型对高维扰动空间的拟合能力。

(4)数据集划分:将扩充后的样本按 8:1:1 的比例划分为训练集、验证集和测试集,分别用于模型训练、超参数调优和泛化性能评估。

2)训练 GTDBO-Perceiver 模型




混合训练阶段,以 MSE 作为优化目标函数,设置 GTDBO 算法的种群规模为 30,最大迭代次数为 20, $e_1 = 0.1$ 、 $e_2 = 1 \times 10^{-3}$,其它参数同表 1。对每组候选超参数组合进行 20 轮快速评估。优化变量包括隐向量数量(Num_latents)、隐向量维度(Latent_dim)、网络深度(Depth)、学习率(lr)及 L2 正则化系数(ω)。优化过程在 PyCharm 2024 环境中进行。

得到最优超参数组合后,对 Perceiver 模型做 200 轮正式训练,并在测试集上验证模型性能。评价指标为平均绝对误差(mean absolute error, MAE)和决定系数 R^2 ,分别衡量模型预测的精度和拟合一致性,结果如表 5 所示。此外,图 8 展示了测试集在 6 个输出维度上的预测-真实对比曲线,表明模型在各维度均达到较好的预测一致性。

表 5 最优超参数及训练结果

Table 5 Optimal hyperparameters and training results

参数	隐向量数量	隐向量维度	网络深度	学习率	L2 正则化系数
取值范围	(16,64)	(32,128)	(2,8)	(1×10^{-4} , 5×10^{-3})	(1×10^{-6} , 1×10^{-2})
最优值	48	62	2	2.41×10^{-3}	1.37×10^{-5}
MAE	6.19×10^{-3}				
R^2	0.999 6				






图 8 测试集各维度拟合结果

Fig. 8 Fitting results for each dimension of the test

3) 装配验证与对比分析

为全面评估 GTDBO-Perceiver 控制器在不同工况下的适应能力,设计了两类装配对象:(1)标准件,该类工件的装配偏差可通过位姿补偿抵消。(2)缺陷件,用来模拟实际生产中存在轻微尺寸偏差的零件。

在 CATIA 中分别对两类工件建模,每类对象随机生成 10 组不同的装配位姿,并记录对应状态下的装配特征

信息。分别采用雅可比矩阵法;BP 神经网络:隐藏层为 20、激活函数为 $ReLu$ 、 $lr=1\times 10^{-3}$ 、 $\omega=1\times 10^{-3}$;支持向量回归法(support vector regression,SVR);核函数为 RBF 、 $C=100$ 、 $\gamma=0.1$;Perceiver: $Num_latents=40$ 、 $Latent_dim=80$ 、 $Depth=5$ 、 $lr=1\times 10^{-3}$ 、 $\omega=1\times 10^{-3}$ 以及本文所提出的 GTDBO-Perceiver 控制器进行预测。各方法在测试数据上的评价结果如表 6 所示。

表 6 各模型预测性能对比

Table 6 Comparison of predictive performance of models


实验对象	评价指标	Jacobian	SVR	BP	Perceiver	GTDBO-Perceiver
标准件	MAE	1.96×10^{-1}	1.67×10^{-1}	1.50×10^{-1}	1.77×10^{-1}	6.72×10^{-2}
	R^2	0.969	0.925	0.968	0.930	0.986
缺陷件	MAE	1.65×10^{-1}	7.86×10^{-2}	1.58×10^{-1}	2.04×10^{-1}	9.96×10^{-2}
	R^2	0.975	0.939	0.971	0.950	0.986

实验结果表明,GTDBO-Perceiver 在 MAE 与 R^2 综合指标上优于对比方法。其中,MAE 表示预测值与真实值之间的平均绝对偏差,数值越小代表整体预测误差越低; R^2 则反映模型输出对真实数据波动的解释能力,其值越接近 1 表示模型拟合效果越好。MAE 主要衡量模型在全局范围内的误差水平,强调准确性; R^2 则衡量模型对扰动趋势的捕捉能力,体现解释性与泛化能力。二者结合可综合评价模型的预测精度与泛化性能。

图 9、图 10 分别展示了各方法在标准件样本与缺陷件样本上的拟合曲线,直观比较了其在不同干扰类型下的输出表现。由图可知,GTDBO-Perceiver 在大多数自由度上

均可准确捕捉扰动趋势,拟合效果更贴合实际,表现出更强的稳定性。相比之下,部分对比方法存在明显的过拟合或欠拟合问题。尤其在处理缺陷件时,雅可比法与原始 Perceiver 模型在旋转维度 A、C 上拟合偏差显著,难以适应复杂扰动带来的非线性特征变化,模型泛化能力不足。

从上述两类对象中各随机抽取 1 份样本,模拟工业机器人装配过程。考虑到实际操作中的控制精度及安全,设定控制精度阈值为:平移方向 $\pm 0.2\text{ mm}$ 、旋转方向 $\pm 0.02^\circ$,并设置运动极限约束为:平移 $\pm 5\text{ mm}$ 、旋转 $\pm 0.5^\circ$ 。根据 GTDBO-Perceiver 控制器输出的偏移量逐步调整工件姿态,直至各装配偏差收敛至公差范围内,如图 11 所示。






图 9 各模型拟合结果(标准件)

Fig. 9 Results of fitting models (standard)




图 10 各模型拟合结果(缺陷件)

Fig. 10 Results of fitting models (defective)




图 11 位姿补偿及装配特征变化量

Fig. 11 Position compensation and assembly feature variation

工件装配偏差变化如图 12 所示。结果表明,该控制器在有限次数内将所有装配偏差控制到公差范围内,且在缺陷件装配中实现了误差的均匀分配,验证了模型在复杂非理想装配场景下的性能。




图 12 工件偏差直方图

Fig. 12 Histogram of workpiece deviations

4 结 论

本文围绕复杂装配场景中建模困难和控制精度不足的问题,提出了一种基于 GTDBO 优化的 Perceiver 装配位姿预测方法。该方法融合 Perceiver 感知结构与群体智能优化策略,建立了特征偏差与位姿补偿之间的映射关系。通过引入博弈论控制、自适应角度扰动和动态觅食机制,显著提升了模型的搜索效率及训练效果。仿真装配实验表明,GTDBO-Perceiver 在预测精度、收敛速度及拟合稳定性方面均优于对比方法,能够实现高效、准确的装配偏差预测。未来工作将聚焦于实际装配线的数据采集和在线控制,进一步提升模型在实际环境下的预测性能。

参考文献

- [1] DROUOT A, ZHAO R, IRVING L, et al. Measurement assisted assembly for high accuracy aerospace manufacturing [J]. IFAC-Papers Online, 2018, 51(11):393-398.
- [2] 喻洋,王耀兵,魏世民,等. 基于柔顺控制的机器人装配技术[J]. 北京邮电大学学报, 2020, 43(4):1-6.
YU Y, WANG Y B, WEI SH M, et al. Robot assembly technology based on compliance control [J]. The Journal of China Universities of Posts and Telecommunications, 2020, 43(4):1-6.
- [3] 曹凯,朱勇,高强,等. 深度强化学习在自动控制领域研究现状与展望[J]. 排灌机械工程学报, 2023, 41(6):638-648.
CAO K, ZHU Y, GAO Q, et al. Research status and prospect of deep reinforcement learning in automatic control [J]. Journal of Drainage and Irrigation Machinery Engineering, 2023, 41(6):638-648.
- [4] 姚建均,张宜坤,柯运,等. 基于模型预测控制的机器人姿态控制策略研究[J]. 机械工程学报, 2024, 60(19):88-100.
YAO J J, ZHANG Y K, KE Y, et al. Research on robot attitude control strategy based on model

predictive control[J]. Chinese Journal of Mechanical Engineering, 2024, 60(19):88-100.

- [5] YANG S, LING V K, WANG ZH H, et al. Multiplexed model predictive attitude control for nadir-pointing satellite using only magnetorquers [J]. Control Engineering Practice, 2025, 162:106381.
- [6] 仲训果,仲训显,彭侠夫,等. 未知雅可比建模的机器人视觉伺服自抗扰控制方法[J]. 厦门大学学报(自然科学版), 2022, 61(2):231-238.
ZHONG X G, ZHONG X Y, PENG X F, et al. Unknown Jacobian modeling robot visual servoing with active disturbance rejection control method [J]. Journal of Xiamen University(Natural Science), 2022, 61(2):231-238.
- [7] ZHU CH X, WAN X J, ZHOU ZH J, et al. Grasping point optimization for sheet metal part based on GSA-Kriging model in a multi-robot assembly system[J]. The International Journal of Advanced Manufacturing Technology, 2023, 125(5/6):2225-2242.
- [8] SON D, PARK M, SHIN C, et al. Development of an adjustment algorithm for assembly joint locations of autobody components for optimal door gap/flushness quality[J]. Transactions of the Korean Society of Mechanical Engineers A, 2020, 44(5):391-397.
- [9] YAN A J, GU T T. Model prediction and optimal control of gas oxygen content for a municipal solid waste incineration process[J]. Instrumentation, 2024, 11(1):101-111.
- [10] 韩顺杰,符金鑫,单新超. 无标定图像视觉伺服控制方法研究[J]. 计算机应用与软件, 2023, 40(4):236-240.
HAN SH J, FU J X, SHAN X CH. Visual servo control method of uncalibrated image[J]. Computer Applications and Software, 2023, 40(4):236-240.
- [11] HYEON S H, BENJAMIN A, TRISTAN K, et al. Artificial neural network-based model predictive visual servoing for mobile robots[J]. Robotica, 2024, 42(8):2825-2847.
- [12] LIU K, SHENG ZH X, ZHANG W, et al. A novel robotic multi-layer multi-pass welding adaptive path generation method based on point cloud slicing and Transformer for saddle-shaped weld seams [J]. Journal of Manufacturing Processes, 2025, 141:1578-1594.
- [13] 朱国庆,韩东颖,米振涛,等. 多策略改进的蜣螂优化算法及其工程实例应用[J]. 电子测量技术, 2024, 47(21):82-99.
ZHU G Q, HAN D Y, MI ZH T, et al. Multi-strategy improved dung beetle optimization algorithm and its

- application in engineering examples [J]. Electronic Measurement Technology, 2024, 47(21): 82-99.
- [14] JAEGLE A, GIMENO F, BROCK A, et al. Perceiver: General perception with iterative attention [EB/OL]. [2021-06-23]. <https://arxiv.org/abs/2103.03206>.
- [15] PELEGRINA D G, SIRAJ S, DUARTE T L, et al. Explaining contributions of features towards unfairness in classifiers: A novel threshold-dependent Shapley value-based approach [J]. Engineering Applications of Artificial Intelligence, 2024, 138: 109427.
- [16] AJOSE L. Conference Report on 2017 IEEE Congress on evolutionary computation [J]. IEEE Computational Intelligence Magazine, 2017, 12(4): 5-6.
- [17] 周亚中, 何怡刚, 邢致恺, 等. 基于 IDBO-ARIMA 的电力变压器振动信号预测 [J]. 电子测量与仪器学报, 2023, 37(8): 11-20.
- ZHOU Y ZH, HE Y G, XING ZH K, et al. Power transformer vibration signal prediction based on IDBO-ARIMA [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(8): 11-20.
- [18] LIU SH, DU L, CAO T, et al. Research on a passenger flow prediction model based on BWO-TCLS-Self-Attention [J]. Electronics, 2024, 13(23): 4849.
- [19] 秦敏敏, 刘立芳, 齐小刚. 面向维修资源分配调度的遗传-长鼻浣熊混合优化算法 [J]. 智能系统学报, 2023, 18(6): 1322-1335.
- QIN M M, LIU L F, QI X G. Hybrid genetic long-nosed raccoon optimization algorithm for maintenance resource allocation and scheduling [J]. CAAI Transactions on Intelligent Systems, 2023, 18(6): 1322-1335.
- [20] ALASHJAE M A, ALEISA N H, DAREM A, et al. A hybrid object detection approach for visually impaired persons using pigeon-inspired optimization and deep learning models [J]. Scientific Reports, 2025, 15(1): 9688.
- [21] ZHANG X, WU K Y, ZHANG CH, et al. An enhanced black-winged kite algorithm boosted machine learning prediction model for patients waiting time [J]. Biomedical Signal Processing and Control, 2025, 105: 107425.

作者简介

王一, 博士, 教授, 主要研究方向为视觉测量与视觉感知、工业机器人控制技术等。

E-mail: 3643496104@qq.com

付智超(通信作者), 硕士研究生, 主要研究方向为优化算法与智能控制。

E-mail: 2267687411@qq.com

程佳, 硕士, 实验师, 主要研究方向为检测技术及自动化装置。

张靖轩, 博士, 副教授, 主要研究方向为复杂系统故障诊断与可靠性评估。