

# 基于 OS-ELM 估计与模糊增益调节的视场约束视觉伺服控制

姬心想, 王婷婷<sup>†</sup>

(河海大学 机电工程学院, 江苏 常州 213200)

**摘要:** 针对传统基于图像的视觉伺服 (IBVS) 在实际应用中存在的对图像雅可比模型依赖、固定增益适应性不足以及特征点易出视场等问题, 本文提出了一种改进的模糊在线极限学习机视觉伺服控制方法 (FA-OS-ELM-IBVS)。该方法以在线序列极限学习机 (OS-ELM) 直接从图像误差估计相机速度, 避免显式计算图像雅可比及其奇异性; 构建以误差范数、可操纵性与误差收敛角为输入的 Mamdani 模糊增益, 实现了伺服增益的非线性自适应调节; 并通过分层矩形区域与 sigmoid 平滑补偿实现连续、可控的视场保持。基于李雅普诺夫理论给出了所设计控制系统的稳定性分析与证明。仿真实验结果表明, 与经典 IBVS 相比, 所提方法的收敛时间缩短约 7.09%–16.7%, 相机轨迹长度降低约 27.48%–57.94%, 且 IAE、ITAE 等积分性能指标显著降低; 在假设深度与真实深度存在明显失配的情况下, 系统仍能保持稳定收敛。进一步与改进 IBVS 方法对比, 所提方法在收敛速度与伺服性能方面均表现出进一步优势。在六自由度 CGXi G6 机器人平台上的实验结果进一步验证了该方法在真实场景下的收敛效率提升, 以及所提无标定框架的鲁棒性与有效性。

**关键词:** 视觉伺服; 在线序列极限学习机 (OS-ELM); 模糊逻辑; 自适应增益; 视场保持

**中图分类号:** TP242 **文献标志码:** A

**DOI:** 10.13195/j.kzyjc.2025.1207

**引用格式:** 姬心想, 王婷婷. 基于 OS-ELM 估计与模糊增益调节的视场约束视觉伺服控制 [J]. 控制与决策, xxxx, x(x): xxxx-xxxx.

## Field-of-view-constrained visual servo control based on OS-ELM estimation and fuzzy gain tuning

Ji XINXIANG, Wang TINGTING<sup>†</sup>

(College of Mechanical and Electrical Engineering, Hohai University, Changzhou 213200, China)

**Abstract:** To address the limitations of traditional image-based visual servoing (IBVS), such as its heavy reliance on the image Jacobian model, insufficient adaptability under fixed gains, and susceptibility to feature-point loss from the camera field of view, this paper proposes an improved fuzzy adaptive online sequential extreme learning machine visual servoing method (FA-OS-ELM-IBVS). The proposed method employs an Online Sequential Extreme Learning Machine (OS-ELM) to directly estimate camera velocities from image errors, thereby circumventing the explicit computation of the image Jacobian and its associated singularities. A Mamdani-type fuzzy gain regulator, which takes the error norm, manipulability, and error convergence angle as inputs, is designed to enable nonlinear and adaptive adjustment of servo gains. Moreover, a hierarchical rectangular region strategy combined with sigmoid-based smooth compensation is introduced to achieve continuous and controllable field-of-view maintenance. The stability of the proposed control system is rigorously analyzed and proven based on Lyapunov theory. Simulation results demonstrate that, compared with conventional IBVS, the proposed method reduces the convergence time by approximately 7.09%–16.7% and shortens the camera trajectory length by about 27.48%–57.94%, while substantially decreasing integral performance indices such as IAE and ITAE. Notably, stable convergence is maintained even under a pronounced mismatch between the assumed and actual depths. Further comparisons with representative improved IBVS schemes confirm superior performance in both convergence speed and servoing accuracy. Experiments conducted on a six-DoF CGXi G6 robot platform corroborate these findings, verifying the improved convergence efficiency in real-world scenarios and demonstrating the robustness and effectiveness of the proposed uncalibrated framework.

**Keywords:** visual servoing; OS-ELM; fuzzy logic; adaptive gain; field of view constraint

收稿日期: xxxx-xx-xx; 录用日期: 2026-03-10.

基金项目: 常州市科技计划 (CJ20241126).

<sup>†</sup>通信作者. E-mail: 20121894@hhu.edu.cn.

## 0 引言

随着服务机器人、手术机器人及工业自动化系统的不断发展,视觉伺服技术作为实现精确运动控制的关键手段,受到广泛关注.其中,基于图像的视觉伺服(Image-Based Visual Servoing, IBVS)因其无需构建三维空间模型、对相机标定精度依赖较小等优势,尤其适用于非结构化、弱建模环境<sup>[1]</sup>.然而,该方法的控制律高度依赖图像雅可比矩阵的准确性,该矩阵受深度估计误差、相机内参漂移及目标变化影响显著,易导致系统收敛性差或发散.

为减轻模型依赖, Qian 与 Su 提出利用 Kalman-Bucy 滤波器实现图像雅可比矩阵的在线估计,可在高斯噪声假设下提供最小方差估计<sup>[2]</sup>.为提高收敛性能,辛菁等人进一步设计了自适应 Kalman 滤波算法以提升系统稳定性<sup>[3]</sup>, Kosmopoulos 则使用鲁棒统计实现非高斯噪声下的可靠估计<sup>[4]</sup>.尽管滤波器方法可在一定程度上修正估计误差,但仍面临初值依赖性、局部估计范围有限等限制.

在此基础上,仲训杲等人将径向基函数神经网络(RBF)与 Kalman 滤波器结合,建立雅可比矩阵的非线性映射模型<sup>[5]</sup>. Zhou 等人引入 LSTM 结构替代径向基函数网络,以更有效地捕捉时序特征并增强状态估计鲁棒性<sup>[6]</sup>.然而,以上方法仍依赖 Kalman 滤波器框架,难以有效缓解雅可比矩阵奇异性问题.为进一步摆脱对显式雅可比矩阵的依赖, Wen 与 Xie 提出基于 RNN 的加速度级 IBVS 策略,在未知结构场景中取得良好控制效果<sup>[7]</sup>.

为提升控制策略的自适应能力,研究者进一步关注于增益调节机制的设计. Yüksel 首次将模糊逻辑与极限学习机(Extreme Learning Machine, ELM)结合,实现了误差驱动的非线性增益控制<sup>[8]</sup>. Kang 等人引入 Q-learning 方法学习控制器增益调节策略<sup>[9]</sup>, Li 等人则结合 ELM 与强化学习实现了反馈增益的自适应调节<sup>[10]</sup>. Liang 等人针对未标定的视觉伺服系统,结合 DDPG 算法实现了多通道增益的联合训练与决策<sup>[11]</sup>, Fu 等人基于 DQN 结构提出特征约束 Q 网络以动态补偿 IBVS 控制误差<sup>[12]</sup>, Arend 团队开发了一种基于强化学习的在线自适应 PID 控制器,并在机器人臂任务中验证了该增益学习机制的有效性<sup>[13]</sup>.这些方法提升了控制系统的学习与泛化能力,但仍存在数据需求大、动作空间受限等问题.

另一方面,模型预测控制(Model Predictive Control, MPC)作为一种处理约束优化问题的有效方法,也被逐步引入 IBVS 研究. Qiu 等人设计了包含

FOV 与关节限制的约束型 IBVS-MPC 结构<sup>[14]</sup>, Liu 与 Dong 进一步提出基于极坐标误差动态的在线 MPC 策略,有效规避了雅可比矩阵奇异<sup>[15]</sup>. Ren 等人提出结合特征约束的优化控制方法<sup>[16]</sup>, Karras 等人和 Bechlioulis 等人分别构建了满足预设性能与 FOV 约束的鲁棒控制器,确保了任务执行期间的稳定性<sup>[17,18]</sup>.然而, MPC 方法普遍存在模型依赖强、实时计算负担大的问题.

为缓解 MPC 对模型精度与计算资源的依赖,部分研究尝试引入强化学习进行参数自适应优化, Li 等人提出利用 DDPG 算法训练 MPC 目标函数权重矩阵,以替代手动调参过程<sup>[19]</sup>. Zhu 等人将模糊逻辑引入 MPC 预测建模<sup>[20]</sup>,另有研究基于 Koopman 算子理论构建线性近似预测器,将优化问题转化为二次规划形式,提升了控制效率<sup>[21]</sup>.尽管上述方法在精度与灵活性方面取得突破,但依然难以在保障实时性的同时全面处理模型漂移、增益调整与视觉特征保持等多目标问题.

为此,本文提出一种改进的模糊在线极限学习机视觉伺服控制方法(FA-OS-ELM-IBVS),通过融合在线学习、自适应增益与图像空间约束策略,有效提升控制精度与系统鲁棒性.具体创新包括:

- 1) 采用 OS-ELM 学习能够等效近似传统项  $\hat{L}_s^+ e$  的“误差→控制”映射,在线更新用于补偿固定深度假设与离线建模残差;
- 2) 设计了以系统安全为首要准则的三输入模糊增益调节器,通过引入可操纵性指标与误差收敛角,实现收敛速度与稳定性的协同优化;
- 3) 提出了一种基于分层区域与 sigmoid 函数的视场保持策略,通过平滑的速度补偿,在有效防止特征丢失的同时显著改善了控制指令的连续性.

## 1 基于图像的视觉伺服控制

本节简要介绍经典基于图像的视觉伺服(IBVS)系统<sup>[22]</sup>,并给出一种眼在手上配置下的机器人的视觉伺服控制方法.针孔相机的中心投影模型如图 1 所示.




图1 针孔相机的中心投影模型

假设  $n$  个固定的空间点, 其坐标为  $P_i = (X_i, Y_i, Z_i)^T \in R^{3 \times 1}, i = 1, \dots, n$ . 根据针孔成像模型, 其在图像平面上的投影为二维点  $s_i = (u_i, v_i)^T \in R^{2 \times 1}, i = 1, \dots, n$ .

$$s_i = \begin{bmatrix} u_i \\ v_i \end{bmatrix} = \begin{bmatrix} \frac{f}{\rho_u} & 0 \\ 0 & \frac{f}{\rho_v} \end{bmatrix} \begin{bmatrix} \frac{X_i}{Z_i} \\ \frac{Y_i}{Z_i} \end{bmatrix} + \begin{bmatrix} u_0 \\ v_0 \end{bmatrix} \quad (1)$$

其中,  $f$  为焦距,  $c = (u_0, v_0)$  为主点,  $\rho_u$  和  $\rho_v$  为像素的宽度和高度. 为了设计视觉伺服控制器, 需要建立图像特征速度  $\dot{s}_i$  与相机速度  $v_c = [v_x, v_y, v_z, \omega_x, \omega_y, \omega_z]^T \in R^{6 \times 1}$  之间的关系:

$$\begin{aligned} \dot{s}_i &= L_{s_i} v_c, i = 1, \dots, n. \\ L_{s_i} &= \begin{bmatrix} -\frac{f_x}{Z_i} & 0 & \frac{\bar{u}_i}{Z_i} & \frac{\bar{u}_i \bar{v}_i}{f_y} & -\frac{f_x^2 + \bar{u}_i^2}{f_x} & \frac{\bar{v}_i f_x}{f_y} \\ 0 & -\frac{f_y}{Z_i} & \frac{\bar{v}_i}{Z_i} & \frac{f_y^2 + \bar{v}_i^2}{f_y} & -\frac{\bar{u}_i \bar{v}_i}{f_x} & -\frac{\bar{u}_i f_y}{f_x} \end{bmatrix} \end{aligned} \quad (2)$$

其中,  $L_{s_i}$  是雅可比矩阵,  $\bar{u}_i = u_i - u_0$  和  $\bar{v}_i = v_i - v_0$  是相对于主点的像素坐标,  $f_x = f/\rho_u$  是在  $u$  轴上的归一化焦距,  $f_y = f/\rho_v$  是在  $v$  轴上的归一化焦距.

假设伺服目标四个可区分的特征点, 其坐标向量表示为  $s = [s_1; s_2; s_3; s_4] \in R^{8 \times 1}$ ; 期望的图像特征向量表示为  $s_d \in R^{8 \times 1}$ . 则图像特征误差向量为:

$$e = s - s_d \quad (3)$$

由于目标物体保持静止, 故  $s_d$  为常量. 因此相机速度与误差矢量的关系可表示为:

$$\dot{e} = L_s v_c \quad (4)$$

其中,  $L_s = [L_{s1}; L_{s2}; L_{s3}; L_{s4}]$ , 则相机的速度为:

$$v_c = -\lambda \hat{L}_s^+ e \quad (5)$$

其中,  $\lambda$  是伺服增益, 为一个正数,  $\hat{L}_s^+ \in R^{6 \times 8}$  是  $L_s$  的伪逆矩阵.

## 2 基于模糊在线极限学习的改进视觉伺服控制方法

基于本文提出的视觉伺服 (FA-OS-ELM-IBVS) 控制框架, 系统总体结构如图 2 所示.

伺服系统以图像特征误差向量作为主要输入, 首先由 OS-ELM 在线估计器实时近似视觉伺服控制律  $-\hat{L}_s^+ e$ ; 随后, 模糊逻辑模块根据系统状态动态调节伺服增益  $\lambda_f$ , 以实现自适应的收敛性能. 经视场保持修正后, 系统输出满足安全约束的相机速度指令. 最后, 结合机器人运动学模型与雅可比矩阵, 完成从

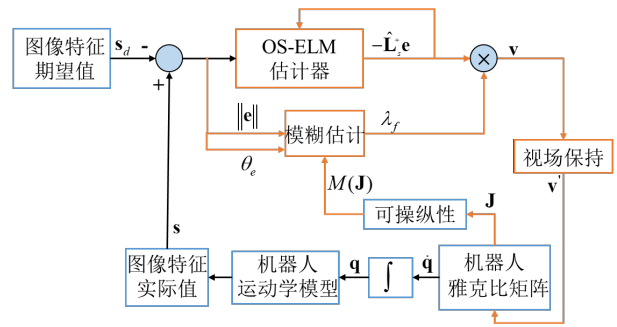


图2 系统总体框图

笛卡尔空间到关节空间的映射, 构成完整的闭环视觉伺服控制系统.

### 2.1 基于 OS-ELM 的雅可比在线近似

极限学习机是一种基于单层前馈神经网络 (Single-Layer Feedforward Network, SLFN) 的学习算法<sup>[23]</sup>. 其核心思想是随机确定输入层与隐藏层之间的连接权重与偏置, 并通过一次性求解 Moore-Penrose 广义逆获得隐藏层至输出层的权重向量, 从而避免传统神经网络复杂的迭代调优过程, 大幅提升训练速度. 该解析解为最小范数解, 具有正则化效应, 能够在有限样本条件下保持模型泛化能力.

假定共有  $N$  组训练样本  $S = \{(x_i, t_i)\}$ ,  $x_i \in R^{n \times p}$ ,  $t_i \in R^n$  激活函数为  $g(x)$ , 隐藏层数为  $\tilde{N}$ . 随机分配权重, 隐藏层与输出层的权重为  $\beta_i$ , 隐藏层与输入层的权重为  $a_i$ , 以及偏置  $b_i$ . ELM 的一般形式可写为:

$$\begin{aligned} f_{\tilde{N}}(x_j) &= \sum_{i=1}^{\tilde{N}} \beta_i g(a_i, b_i, x_j) = \\ & \sum_{i=1}^{\tilde{N}} \beta_i h_i(x_j) = t_j, j = 1, \dots, N \end{aligned} \quad (6)$$

其网络结构如图 3 所示.

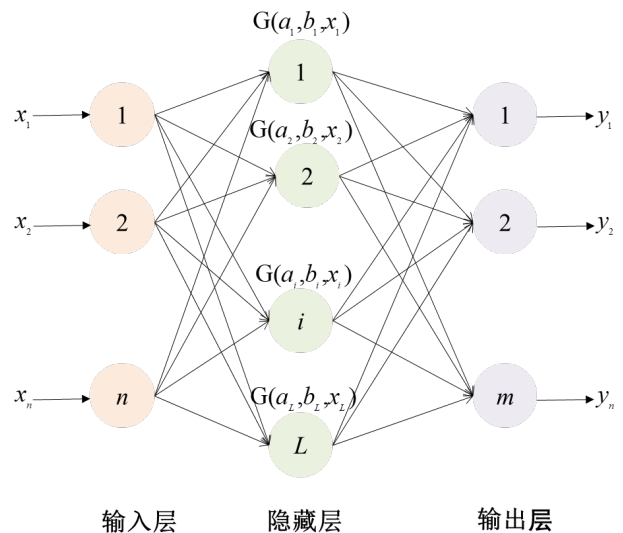


图3 极限学习机网络结构图

上式 (6) 也可写为矩阵形式.

$$\mathbf{H}_{N \times \tilde{N}} \boldsymbol{\beta}_{\tilde{N} \times 1} = \mathbf{T}_{N \times 1} \quad (7)$$

式 (7) 中,  $\mathbf{H}$  为隐藏层的输出矩阵;  $\boldsymbol{\beta}$  是连接层和输出层的权向量;  $\mathbf{T}$  是响应向量; 在训练过程中, 采用带约束的误差经验最小化方法对参数进行优化. 隐藏层和输出层之间的权重向量更新如下:

$$\hat{\boldsymbol{\beta}} = \mathbf{H}^+ \mathbf{T} = (\mathbf{H}^T \mathbf{H})^{-1} \mathbf{H}^T \mathbf{T} \quad (8)$$

在本文的视觉伺服框架中, 为简化模型, 假设目标特征点深度  $Z$  固定. 基于此假设, 雅可比矩阵  $\mathbf{L}_s$  (式 (2)) 理论上应为常数矩阵. 然而, 利用有限样本训练的离线 ELM 模型 (式 (8)) 对 IBVS 控制律 (式 (5)) 进行逼近时, 受限于样本数量有限, 模型不可避免地存在逼近残差. 此外, 相机镜头畸变等非线性因素也会引入误差, 导致在固定深度条件下, 从特征误差到相机速度的实际映射关系发生变化. 因此, 仅依赖 ELM 模型通常无法实现高精度收敛, 系统往往会在目标位置附近残留稳态误差.

为弥补这种偏差, 本文引入了在线序列极限学习机 (Online Sequential ELM, OS-ELM) 对离线模型进行在线精调<sup>[24]</sup>. OS-ELM 允许在新数据到达时逐批更新网络参数. 在伺服任务中, 当系统误差趋近稳态时 (误差范数  $\|\mathbf{e}\| < 20\text{pixels}$ ), 在线更新机制被激活.

本文采用离线和末端在线的混合策略, 可以兼顾效率与精度: 离线模型保证系统在伺服主要阶段的快速收敛与稳定性; 末端激活的 OS-ELM 则专门利用末端阶段采集的高相关性数据, 针对性地补偿局部模型偏差, 从而降低对初始训练样本数量的依赖, 并增强对不同任务的适应性. 该更新在当前伺服任务中实时生效, 用于即时修正控制律, 从而显著减小稳态误差并提升定位精度.

设上一阶段的最小化目标为:

$$\min_{\boldsymbol{\beta}} \|\mathbf{H}_0 \boldsymbol{\beta} - \mathbf{T}_0\| \quad (9)$$

当下一批数据 ( $X_1 = \{(x_i, t_i)\}_{i=N+1}^{N_0+N_1}$ ) 到达时, 最小化公式改变为:

$$\min_{\boldsymbol{\beta}} \left\| \begin{bmatrix} \mathbf{H}_0 \\ \mathbf{H}_1 \end{bmatrix} \boldsymbol{\beta} - \begin{bmatrix} \mathbf{T}_0 \\ \mathbf{T}_1 \end{bmatrix} \right\| \quad (10)$$

模型的更新考虑了  $X_0$  和  $X_1$ , 隐藏层和连接层的权向量更新如下所示:

$$\boldsymbol{\beta}^{(1)} = \left( \frac{I}{\gamma} + \begin{bmatrix} \mathbf{H}_0 \\ \mathbf{H}_1 \end{bmatrix}^T \begin{bmatrix} \mathbf{H}_0 \\ \mathbf{H}_1 \end{bmatrix} \right)^{-1} \begin{bmatrix} \mathbf{H}_0 \\ \mathbf{H}_1 \end{bmatrix}^T \begin{bmatrix} \mathbf{T}_0 \\ \mathbf{T}_1 \end{bmatrix} = \mathbf{K}_1^{-1} \begin{bmatrix} \mathbf{H}_0 \\ \mathbf{H}_1 \end{bmatrix}^T \begin{bmatrix} \mathbf{T}_0 \\ \mathbf{T}_1 \end{bmatrix}. \quad (11)$$

将式 (11) 改写表示  $\boldsymbol{\beta}^{(0)}$  和  $\boldsymbol{\beta}^{(1)}$  的迭代关系, 可表示为:

$$\begin{cases} \mathbf{K}_1 = \frac{I}{\gamma} + \begin{bmatrix} \mathbf{H}_0 \\ \mathbf{H}_1 \end{bmatrix}^T \begin{bmatrix} \mathbf{H}_0 \\ \mathbf{H}_1 \end{bmatrix} = \mathbf{K}_0 + \mathbf{H}_1^T \mathbf{H}_1 \\ \boldsymbol{\beta}^{(1)} = \boldsymbol{\beta}^{(0)} + \mathbf{K}_1^{-1} (\mathbf{T}_1 - \mathbf{H}_1^T \boldsymbol{\beta}^{(0)}) \end{cases} \quad (12)$$

同样的, 将式 (12) 推广, 第  $k$  批数据到来时的更新公式如下:

$$\begin{cases} \mathbf{K}_{k+1} = \mathbf{K}_k + \mathbf{H}_{k+1}^T \mathbf{H}_{k+1} \\ \boldsymbol{\beta}^{(k+1)} = \boldsymbol{\beta}^{(k)} + \mathbf{K}_{k+1}^{-1} \mathbf{H}_{k+1}^T (\mathbf{T}_{k+1} - \mathbf{H}_{k+1} \boldsymbol{\beta}^{(k)}) \end{cases} \quad (13)$$

该策略可在伺服任务末端实现模型的局部自适应修正, 从而显著减小稳态误差并提升定位精度. 模型在线更新过程如图 4 所示.




图4 OS-ELM 模型建立过程

在本文中, OS-ELM 的输入是式 (3) 中特征误差向量的元素. 为了避免在线计算雅可比伪逆  $\hat{\mathbf{L}}_s^+$  带来的奇异性问题, 选择直接近似  $\hat{\mathbf{L}}_s^+ \mathbf{e}$  作为 OS-ELM 的输出. 由于相机速度  $\mathbf{v}_c$  是一个 6 自由度的向量. 因此构建 6 个独立的单输出 OS-ELM 模型 (结构见图 5), 所有模型共享相同的误差向量  $\mathbf{e}$  作为输入, 分别负责估计速度向量的一个分量. 这种结构与单一多输出模型相比, 可以避免对高维耦合权重矩阵的复杂求解, 降低模型计算负担. OS-ELM 的最终输出是一个 6 自由度的向量  $\hat{\mathbf{v}}_{elm}$ .




图5 OS-ELM 结构图

## 2.2 基于模糊估计的自适应增益

伺服增益  $\lambda$  直接决定了视觉伺服系统的收敛时间和稳定性. 相比于固定增益, 自适应增益可根据系统运行状态实时调整控制强度, 从而在不同工况下兼顾快速性与稳定性.

模糊逻辑控制 (Fuzzy Logic Control, FLC) 是一种基于规则的智能控制方法, 具有设计直观、鲁棒性强、无需精确模型等优点, 尤其适用于 IBVS 这类具有强非线性和时变特性的系统. 本文设计了一种基

于模糊逻辑的自适应伺服增益调节器, 用于动态替代经典 IBVS 控制中的固定伺服增益。

模糊控制器综合以下三个关键指标作为输入, 通过模糊推理动态调整输出的伺服增益  $\lambda_f$ . 本文提出的 FA-OS-ELM-IBVS 完整控制律为:

$$\mathbf{v}_c = -\lambda_f \hat{\mathbf{v}}_{elm} \quad (14)$$

### 1) 误差范数

误差范数  $\|\mathbf{e}\|$  是反映了当前图像特征  $\mathbf{s}$  与目标特征  $\mathbf{s}_d$  之间的距离. 误差范数为欧几里得距离:

$$\|\mathbf{e}\| = \sqrt{\sum_{i=1}^n e_i^2} \quad (15)$$

其中,  $n$  是特征向量的维度,  $n=8$ .

### 2) 可操纵性

可操纵性  $M$  是衡量机器人在当前位姿下灵活运动能力的指标, 通常基于雅可比矩阵计算. 对于  $g$  关节机械手,  $\mathbf{J}(\mathbf{q})$  是关节构型  $\mathbf{q} \in \mathbf{R}^g$  处的机械手运动学雅可比矩阵, 因此可操纵性定义为<sup>[25]</sup>:

$$M(\mathbf{J}) = \sqrt{\det(\mathbf{J}(\mathbf{q}) \cdot \mathbf{J}(\mathbf{q})^T)} \quad (16)$$

### 3) 误差收敛角

误差收敛角  $\theta_e$  用于判断系统当前的收敛趋势. 分别计算 4 个特征点其误差变化率  $\dot{\mathbf{e}}_i$  和对应的收敛角  $\theta_{e,i}$ :

$$\dot{\mathbf{e}}_i = (\mathbf{e}_{i,t} - \mathbf{e}_{i,t-1}) / \Delta t \quad (17)$$

$$\theta_{e,i} = \arccos\left(\frac{\mathbf{e}_i^T \dot{\mathbf{e}}_i}{\|\mathbf{e}_i\| \cdot \|\dot{\mathbf{e}}_i\|}\right) \in [0^\circ, 180^\circ] \quad (18)$$

当  $\theta_{e,i} \approx 180^\circ$  时, 说明第  $i$  个特征点的方向与  $\mathbf{e}_i$  的方向相反, 表示该点的误差正在被快速消除. 为保证系统整体的收敛安全, 选取 4 个收敛角中的最小值作为输入.

$$\theta_e = \min(\theta_{e,1}, \theta_{e,2}, \theta_{e,3}, \theta_{e,4}) \quad (19)$$

为实现上述逻辑, 设计了一个三输入 ( $\|\mathbf{e}\|, M, \theta_e$ )、单输出 ( $\lambda_f$ ) 的 Mamdani 型模糊推理系统. 模糊隶属度函数采用三角型或高斯型分布, 输入和输出的隶属函数图像见图 6, 其语言变量定义如下:

$$\begin{cases} \|\mathbf{e}\| \in \{\text{Small, Medium, Large}\}, \\ M \in \{\text{Low, High}\}, \\ \theta_e \in \{\text{Small, Medium, Large}\}, \\ \lambda_f \in \{\text{VS, S, M, L, VL}\}. \end{cases} \quad (20)$$

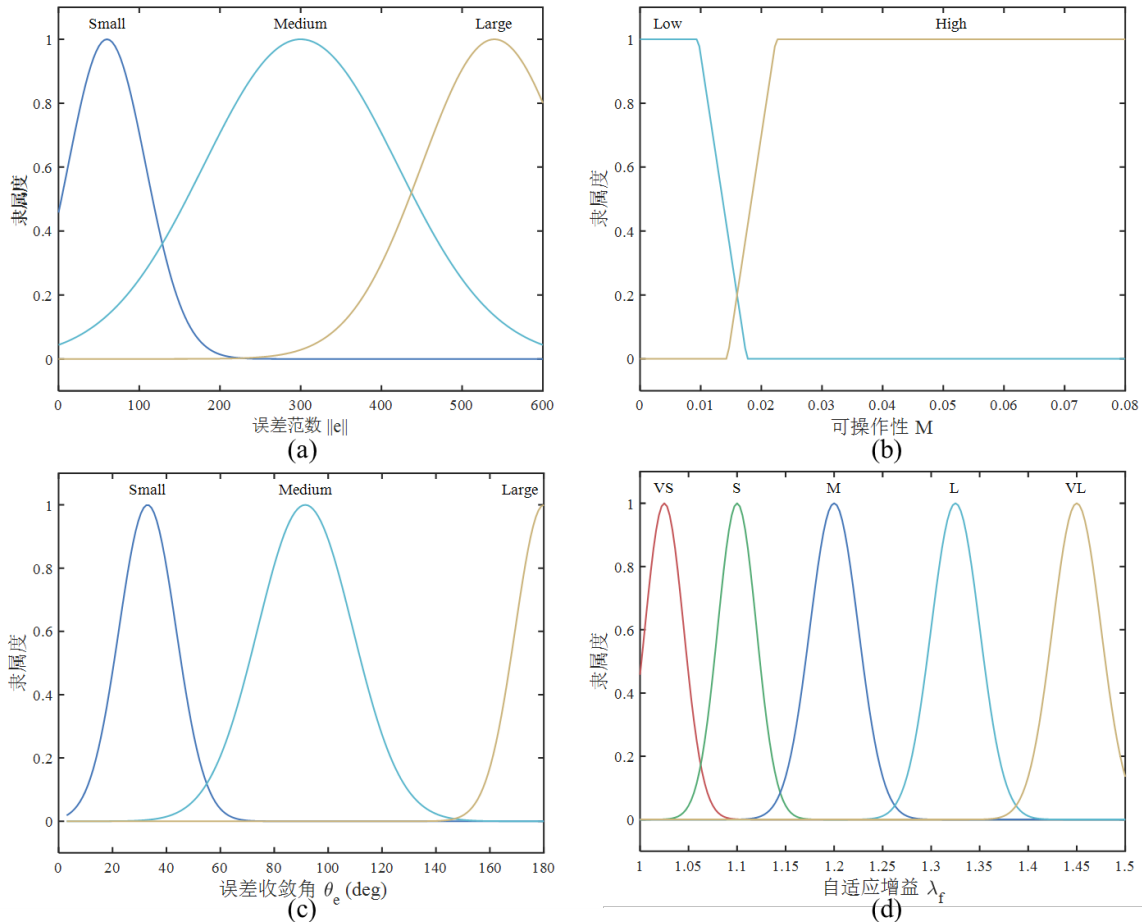


图6 隶属函数图像

其中, VS、S、M、L、VL 分别表示:非常小、小、中、大、非常大. 模糊推理采用 Mamdani 最小-最大复合运算, 解模糊阶段使用加权平均法 (Centroid Method)<sup>[26]</sup>:

$$\lambda_f = \frac{\sum_{i=1}^r \mu_i(\lambda_i) \lambda_i}{\sum_{i=1}^r \mu_i(\lambda_i)} \quad (21)$$

其中,  $\mu_i(\lambda_i)$  为第  $i$  条规则输出的隶属度值,  $r$  为有效规则条数.

完整的 18 条模糊推理规则如表 1 所示. 该规则库的设计思想是安全优先, 兼顾性能.

表1 模糊规则

序号	输入			输出
	$\ e\ $	$M$	$\theta_e$	
1	Small	Low	Large	S
2	Medium	Low	Large	S
3	Large	Low	Large	S
4	Small	Low	Medium	VS
5	Medium	Low	Medium	VS
6	Large	Low	Medium	VS
7	Small	Low	Small	VS
8	Medium	Low	Small	VS
9	Large	Low	Small	VS
10	Small	High	Large	M
11	Medium	High	Large	L
12	Large	High	Large	VL
13	Small	High	Medium	VS
14	Medium	High	Medium	S
15	Large	High	Medium	S
16	Small	High	Small	VS
17	Medium	High	Small	VS
18	Large	High	Small	VS

可操纵性 ( $M$ ) 被赋予最高优先级. 当  $M$  处于 Low 状态, 无论误差多大、收敛方向多好, 输出增益  $\lambda_f$  都会被限制在 S 或 VS. 当  $M$  处于 High 状态时, 系统处于安全, 如规则 10-12 为理想的收敛状态, 增益  $\lambda_f$  输出为大些的值.

### 2.3 视场保持

当目标图像特征离开摄像机视场时, 很难获得机器人视觉伺服控制律. 为了避免这一问题, 为每个图像特征定义了一个限制在图像平面内的约束函数.

现有文献提出了多种 FOV 保持策略. 例如, 基于势场法的方法通过引入排斥力将特征点推离边界, 但可能引入抖动<sup>[27]</sup>; 当特征点接近图像边界时, 通常通过切换控制律或执行 Z 轴后退来维持可见性<sup>[28]</sup>. 但该策略易造成速度不连续, 且可能带来与期望深度的偏差; 基于平滑阻尼函数的方法<sup>[16]</sup>通过一个连

续函数在接近边界时减小伺服速度, 但其干预可能不够及时.

针对上述方法的局限性, 本文提出了一种基于分层矩形区域 sigmoid 函数的主动速度补偿方法, 利用 sigmoid 函数内在平滑特性, 实现从无干预到强干预之间的平滑过渡.

本策略的核心是将图像平面划分为三个具有明确物理边界的嵌套矩形区域, 如图 7 所示. 并为每个区域指定不同的速度修正逻辑. 区域 A 为安全区, 无需采取修正策略. 区域 B 为危险区, 此区域内, 需要主动预防特征丢失. 区域 C 为禁止区, 需要立即将特征拉回视场.




图7 视场划分

记原始相机平面速度指令为  $\mathbf{v}_p = [v_x, v_y]^T$ , 通过引入一个平滑的补偿速度向量  $\mathbf{v}_{comp} = [v_{comp,x}, v_{comp,y}]^T$  进行修正. 修正后的平面速度输出  $\mathbf{v}_p^{fov}$  为:

$$\mathbf{v}_p^{fov} = \mathbf{v}_p + \mathbf{v}_{comp} \quad (22)$$

该补偿速度  $\mathbf{v}_{comp}$  的大小取决于特征点所处的区域. 为了达到速度平滑过渡补偿效果, 设置缓冲带, 当特征点即将进入区域 B, 且进入缓冲带时, 系统激活一个基于 sigmoid 函数的平滑过渡比  $\alpha(u)$  和  $\alpha(v)$ :

$$\alpha(u) = \begin{cases} 0 & \text{if } u \leq u_{RB} - u_{sa} \\ \frac{1}{1 + e^{(-k \cdot (\frac{u - u_B}{u_C - u_B}) - k/2)}} & \text{if } u_{RB} - u_{sa} < u \leq u_{RC} \\ 1 & \text{if } u > u_{RC} \end{cases} \quad (23)$$

$$\alpha(v) = \begin{cases} 0 & \text{if } v \leq v_{RA} - u_{sa} \\ \frac{1}{1 + e^{(-k \cdot (\frac{v - v_B}{v_C - v_B}) - k/2)}} & \text{if } v_{RB} - v_{sa} < v \leq v_{RC} \\ 1 & \text{if } v > v_{RC} \end{cases} \quad (24)$$

其中,  $u_B = 820\text{pixels}$ ,  $v_B = 820\text{pixels}$ , 是区域 B 的起始边界,  $u_C = 920\text{pixels}$ ,  $v_C = 920\text{pixels}$  是区域 C 的起始边界.  $k$  为 sigmoid 函数的增益因子, 本文  $k=10$ .  $u_{sa} = 40\text{pixels}$ ,  $v_{sa} = 40\text{pixels}$  为缓冲带宽度. 补偿速度  $v_{comp,x}$  的方向与特征点相对图像中心  $c$  的位置决定, 其大小由过渡比率  $\alpha(u)$  和一个最大补偿速度  $v_{x,max}$  共同决定:

$$v_{comp,x} = -\alpha(u) \cdot v_{x,max} \cdot \text{sign}(u - u_0) \quad (25)$$

$$v_{comp,y} = -\alpha(v) \cdot v_{y,max} \cdot \text{sign}(v - v_0) \quad (26)$$

其中,  $v_{x,max} = 0.55\text{m/s}$ ,  $v_{y,max} = 0.55\text{m/s}$ ,  $v_y$  方向的补偿  $v_{comp,y}$  同理计算. 本方法可以使速度平滑过渡. 补偿向量始终指向图像中心, 其符号由特征相对中心的位置决定.

最后, 为确保安全, 将修正后的总速度  $v_p^{fov}$  进行饱和和处理, 限制在最大允许速度  $\pm v_{max}$  之内. 经过视场保持之后, 最终输出的速度为:

$$v' = [v_p^{fov}, v_z, \omega_x, \omega_y, \omega_z] \quad (27)$$

## 2.4 稳定性证明

为证明系统稳定性, 做出如下基本假设:

假设 1: OS-ELM 网络的重构误差  $\varepsilon(t)$  有界, 即存在常数  $\varepsilon_{max} > 0$ , 使得  $\|\varepsilon(t)\| \leq \varepsilon_{max}, \forall t \geq 0$ .

假设 2: 在非奇异工作域  $\Omega$  内, 存在常数  $\alpha > 0$  使得  $\text{sym}(\hat{L}_s^+ L_s) = ((\hat{L}_s^+ L_s + (\hat{L}_s^+ L_s)^T)/2) \geq \alpha \mathbf{I}_6$ . 并且在  $e$  的某个邻域内存在常数  $\bar{O} > 0$  使  $\|O(e)\| \leq \bar{O}, \bar{O} < \alpha$ .

根据神经网络的泛逼近性质, 其实际输出可表示为:

$$\hat{v}_{elm} = \hat{L}_s^+ e + \varepsilon(t) \quad (28)$$

将式 (28) 带入式 (14), 则闭环系统的误差动力学方程可推导为:

$$\dot{e} = L_s v_C = -\lambda_f(t) L_s \hat{L}_s^+ e - \lambda_f(t) L_s \varepsilon(t) \quad (29)$$

本文采用 4 个点为特征, 故矩阵  $L_s \hat{L}_s^+ \in \mathbb{R}^{8 \times 8}$  的秩最多为 6, 故一般不可能在  $\mathbb{R}^{8 \times 8}$  上正定. 为研究局部渐近稳定性, 定义 6 维误差变量  $e' = \hat{L}_s^+ e$ , 对其求导得:

$$\dot{e}' = \hat{L}_s^+ \dot{e} + \dot{\hat{L}}_s^+ e \quad (30)$$

因非奇异邻域内  $\hat{L}_s^+$  随状态平滑变化, 故  $\dot{\hat{L}}_s^+ e$  在  $e$  的邻域内存在  $O(e)$  使  $\dot{\hat{L}}_s^+ e = O(e)e'$ ,  $O(e) \in \mathbb{R}^{6 \times 6}$ , 当  $e = 0$ ,  $O(e) = 0$ . 将 (29) 代入 (30) 得:

$$\dot{e}' = -\lambda_f(t)(\hat{L}_s^+ L_s + O(e))e' - \lambda_f(t)\hat{L}_s^+ L_s \varepsilon(t) \quad (31)$$

构造李雅普诺夫函数:  $V(t) = (e'^T e')/2$ , 对其

求导得:

$$\begin{aligned} \dot{V}(t) &= -\lambda_f(t)e'^T \text{sym}(\hat{L}_s^+ L_s + O(e))e' - \\ &\lambda_f(t)e'^T \hat{L}_s^+ L_s \varepsilon(t). \end{aligned} \quad (32)$$

由假设 1、2 得:  $e'^T \text{sym}(\hat{L}_s^+ L_s + O(e))e' \geq (\alpha - \bar{O})\|e'\|^2$ .

利用柯西施瓦茨不等式对交叉项放缩, 即:  $|e'^T \hat{L}_s^+ L_s \varepsilon(t)| \leq \|e'\| \|\hat{L}_s^+ L_s\| \varepsilon_{max}$ . 由模糊规则设计可知,  $\lambda_f(t)$  在正实数区间  $[\lambda_{fmin}, \lambda_{fmax}]$  内, 且  $\lambda_{fmin} > 0$ . 令  $C = \sup_{e \in \Omega} \|\hat{L}_s^+ L_s\|$ , 故:

$$\dot{V}(t) \leq -\lambda_{fmin}(\alpha - \bar{O})\|e'\|^2 + \lambda_{fmax} C \varepsilon_{max} \|e'\| \quad (33)$$

当  $\|e'\| > \frac{\lambda_{fmax} C \varepsilon_{max}}{\lambda_{fmin}(\alpha - \bar{O})}$  时,  $\dot{V}(t) < 0$ , 故  $e'$  一致最终有界, 系统在非奇异工作域  $\Omega$  内一致最终有界.

## 3 仿真实验与结果分析

为系统验证所提出 FA-OS-ELM-IBVS 控制方法的有效性, 在 MATLAB/Simulink 环境下搭建了基于 PUMA560 六自由度机械臂的视觉伺服仿真平台. 该平台集成了 Robotics System Toolbox 与 Computer Vision Toolbox 模块, 采用 eye-in-hand 安装方式的相机. 相机的主要参数如表 2 所示. 为保证数值稳定性与安全性, 控制器将末端线速度与角速度分别限制为 0.5m/s 和 0.5rad/s.

表2 摄像机参数

参数名称	参数值
焦距/m	0.008
采样时间/s	0.04
主点/pixel	(512, 512)
分辨率/pixel	1024×1024

本节设计了 6 组仿真实验和 1 组物理实验. 实验一, 与经典 IBVS 进行基准对比, 验证在理想环境下的收敛性能. 实验二, 验证本文方法在噪声干扰下的鲁棒性. 实验三, 验证本文方法视场保持机制的有效性. 实验四, 通过剥离在线学习机制, 验证 OS-ELM 在提升控制精度中的作用. 实验五, 设置模型失配场景, 改变深度信息, 验证本文方法在深度假设与实际情况不符时的鲁棒性. 实验六将本文方法与改进 IBVS 方法对比. 实验七为物理实验, 验证本文方法在真实场景下的有效性.

### 3.1 视觉伺服评估指标

为定量评价 IBVS 系统性能, 定义以下指标<sup>[8]</sup>:

1) 收敛时间: 系统达到稳态所需的时间. 对于定步长系统, 定义为:

$$t_c = \operatorname{argmin}(\|e(t)\| \leq e_{thr}) \quad (34)$$

其中,  $e_{thr}$  为收敛阈值, 可以根据精度要求设定, 本文设置为 3 pixels.

2) 摄像机轨迹长度: 相机在伺服过程中所经历的路径长度:

$$l_c = \sum_{t=2}^{t_c} \|\mathbf{p}_t - \mathbf{p}_{t-1}\| \quad (35)$$

其中,  $\mathbf{p}_t$  为相机在第  $t$  步的笛卡尔坐标位置.

3) 误差代价: 选取积分绝对误差  $e_{IAE}$  和时间加权积分绝对误差  $e_{ITAE}$  两种误差积分指标来评估控制性能.

$$e_{IAE} = \int_0^{t_c} \|e(t)\| dt \quad (36)$$

$$e_{ITAE} = \int_0^{t_c} t \cdot \|e(t)\| dt \quad (37)$$

### 3.2 实验一: 基准对比实验

在进行仿真前, 首先采集数据并离线训练 OS-ELM 模型. 激活函数选用 sigmoid, 隐藏层神经元数为 30. 训练数据来源于经典 IBVS 控制过程, 共采集 10 种不同相机末端位姿 (深度固定为 2m, 伺服增益为 1). 数据按 70%、15%、15% 划分为训练集、验证集与测试集. 训练结果如表 3 所示.

表3 OS-ELM 模型训练结果

OS-ELM	RMSE
OS-ELM1	0.1221e-04
OS-ELM2	0.8359e-04
OS-ELM3	0.6604e-04
OS-ELM4	0.5521e-04
OS-ELM5	0.6355e-04
OS-ELM6	0.2628e-04

实验一对比经典 IBVS( $\lambda = 1$ ) 与 FA-OS-ELM-IBVS 在特征轨迹、相机轨迹、速度及误差收敛方面的性能. 记笛卡尔坐标系的点为  $\mathbf{P}$ , 特征点期望位置为  $\mathbf{s}_d$ , 机械臂的关节角初始值为  $\mathbf{q}_0$ . 结果如图 8 所示.

$$P = \begin{bmatrix} 1.5 & 1.5 & 1.5 & 1.5 \\ -0.25 & 0.25 & 0.25 & -0.25 \\ 0.25 & 0.25 & -0.25 & -0.25 \end{bmatrix} \quad (38)$$

$$\mathbf{s}_d = \begin{bmatrix} 700 & 300 & 300 & 700 \\ 300 & 300 & 700 & 700 \end{bmatrix} \quad (39)$$

$$\mathbf{q}_0 = \left[ 0, \frac{\pi}{4}, \pi, 0, \frac{0.9\pi}{4}, -\frac{\pi}{4} \right] \quad (40)$$

图 8(a)-(d) 为传统视觉伺服的结果, (e)-(i) 为本文提出方法的结果. 图 8(j) 为两者在伺服过程中可操纵性的对比图. 评价指标计算结果见表 4.

由图 8(a)-(h) 和表 4 的分析结果表明, 本文方法在收敛性能方面具有显著优势. 由 (c) 和 (g) 可以看

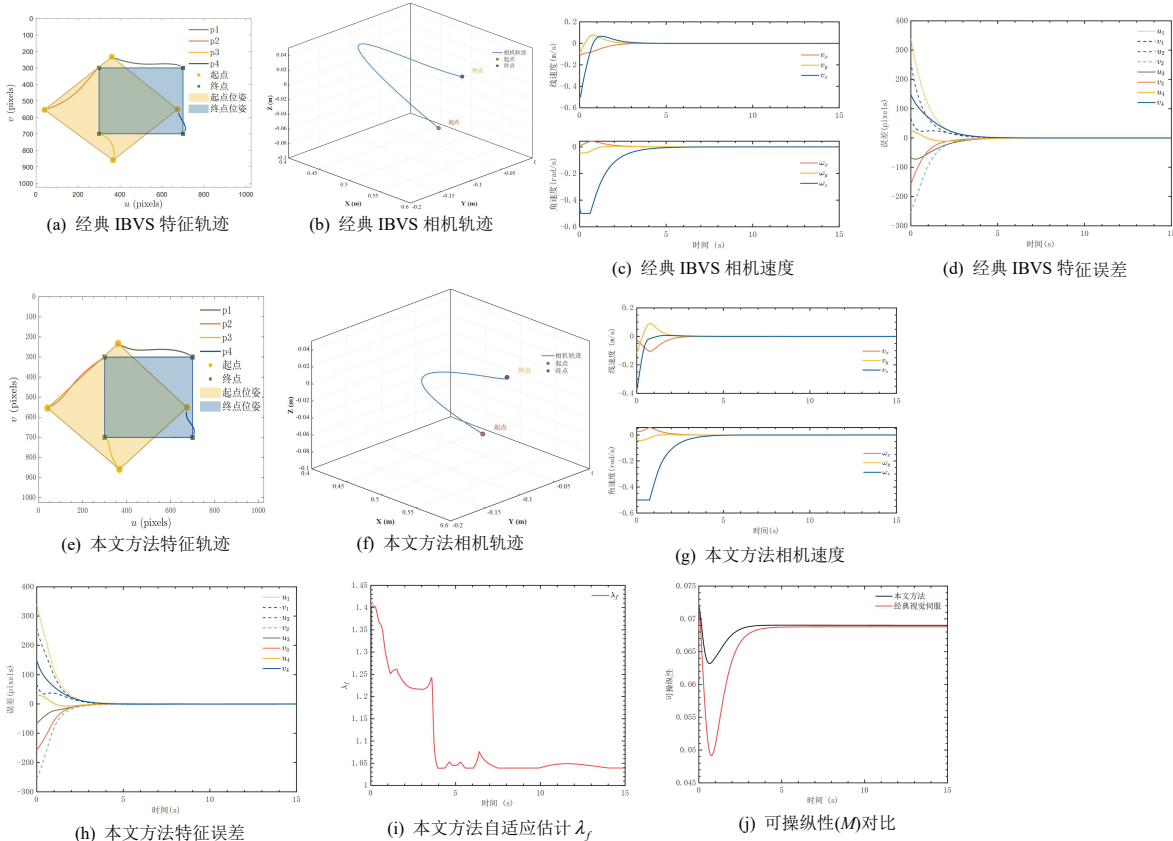


图8 实验一仿真结果

表4 实验一结果对比

	IBVS	FA-OS-ELM-IBVS	改进率%
$t_c/s$	5.08	4.72	7.09↓
$l_c/m$	0.3359	0.2436	27.48↓
$e_{IAE}$	523	521	0.34↓
$e_{ITAE}$	483	430	11.08↓

出, 两种方法的速度均被限制在最大速度的范围内.

对比 (d) 和 (h), 两种方法的特征误差均以指数函数递减, 但本文方法相对于经典 IBVS 在收敛速度上缩短了 7.09%, 轨迹长度缩短了 27.4%. 在  $e_{IAE}$  和  $e_{ITAE}$  两个误差指标上均优于传统 IBVS 方法. 这表明该控制器能有效抑制误差振荡并加快收敛.

从图 8(i) 看出, 由于初始阶段误差和可操纵性  $M$  较大, 收敛方向较好, 模糊推理系统输出了较大的伺服增益, 以便快速收敛. 而后, 由于可操纵性的值

下降, 增益也随着下降. 最后, 误差收敛到很小, 模糊推理系统输出了小增益, 以便机械臂精确调整到最终位姿.

从图 8(j) 看出, 与经典 IBVS 相比, 本文方法在整个伺服过程中保持较高的  $M$  值, 说明机械臂远离奇异位形, 运动更灵活. 从而使得机械臂在降低速度限制的情况下仍能完成视觉伺服任务.

### 3.3 实验二: 抗噪声实验

当视觉伺服系统接近收敛时, 特征误差较小, 特征中的噪声可能会引起振荡. 系统对这些扰动的鲁棒性是非常重要的. 因此在实验一相同设置的基础上, 向图像特征点坐标中加入均值为 0, 方差为 0.2 的高斯白噪声. 对比两种方法在干扰条件下的收敛精度与轨迹平滑性, 结果如图 9 所示, 主要指标对比见表 5.

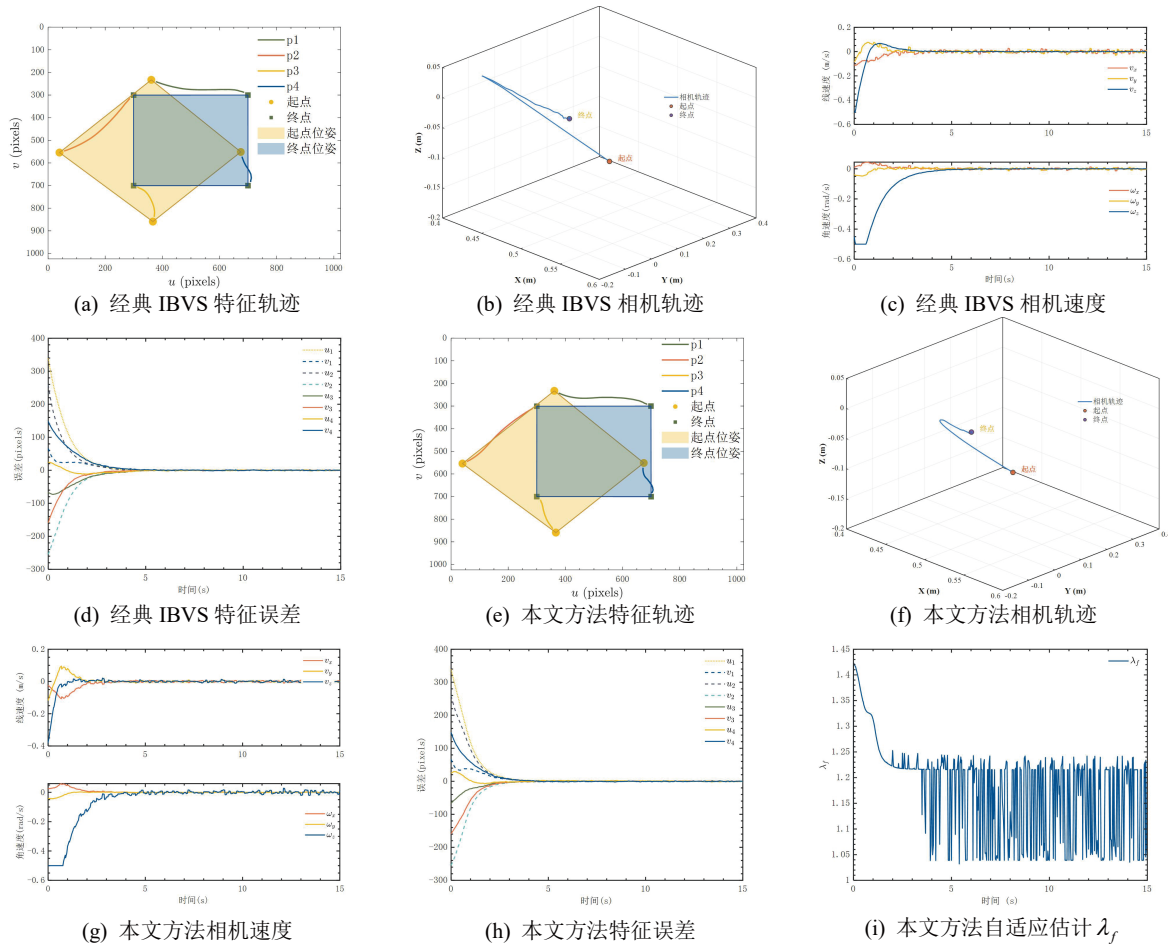


图9 实验二仿真结果

表5 实验二结果对比

	IBVS	FA-OS-ELM-IBVS	改进率%
$t_c/s$	5.16	4.3	16.7↓
$l_c/m$	0.3569	0.2486	30.3↓
$e_{IAE}$	523	512	2.2↓
$e_{ITAE}$	488	406	16.9↓

图 9(a)-(d) 为经典 IBVS 的结果, (e)-(i) 为本文方法结果. 结合图 9 和表 5 分析. 相比实验一, 由于噪声干扰, 经典 IBVS 的收敛时间和相机轨迹长度均增加.

本文方法的相机轨迹更加平滑, 轨迹长度与收敛时间较短. 相机轨迹长度缩短 30.3%, 收敛时间缩短 16.7%. 相比实验一的整体改进率增加, 这验证了

本文方法在应对误差干扰时,表现出较强的鲁棒性与抗扰动能力.

图9(i)表明,当误差中叠加噪声时,模糊系统会短暂提升伺服增益 $\lambda_f$ ,以维持快速响应,但不会引起速度突变.

### 3.4 实验三: 视场约束实验

实验三验证本文方法在运动过程中的视场保持能力.为此,设置一个使得特征点容易移出边界的初始位姿,观察在本文方法的约束下,图像特征点是否始终保持在相机视野之内.设置初始关节角 $\mathbf{q}_0$ 和期望特征点的坐标 $\mathbf{s}_d$ .

$$\mathbf{q}_0 = \left[ 0, \frac{0.95\pi}{4}, \pi, -0.05\pi, \frac{0.95\pi}{4}, -\frac{0.95\pi}{4} \right] \quad (41)$$

$$\mathbf{s}_d = \begin{bmatrix} 740 & 340 & 340 & 740 \\ 350 & 350 & 750 & 750 \end{bmatrix} \quad (42)$$

如图10(a)所示,其中区域B的厚度为100pixels,

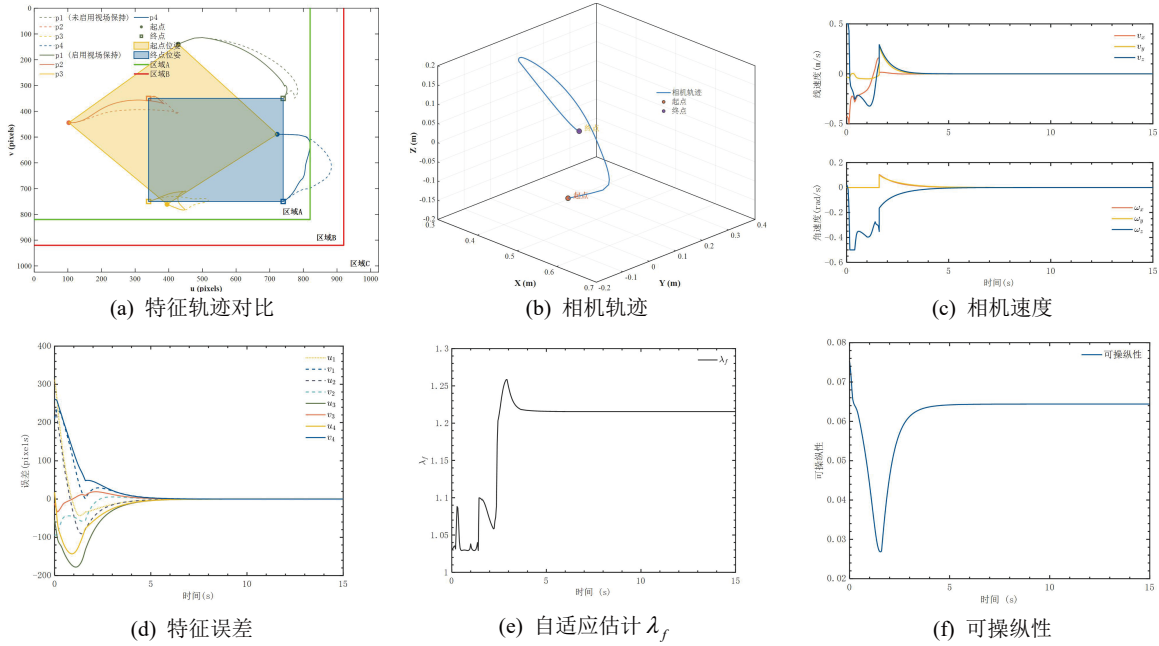


图10 实验三仿真结果

### 3.5 实验四: 消融实验

实验四为了验证 OS-ELM 实现的无标定视觉伺服相比 ELM 实现的优越性.采用相同的原始数据划分形式和训练数据对 ELM 进行训练.本实验模糊估计伺服增益模块不变.改变机械臂初始关节角 $\mathbf{q}_0$ 和期望特征点坐标 $\mathbf{s}_d$ 为:

$$\mathbf{q}_0 = \left[ 0, \frac{0.98\pi}{4}, \pi, \frac{\pi}{4}, -\frac{0.8\pi}{4} \right] \quad (43)$$

$$\mathbf{s}_d = \begin{bmatrix} 700 & 300 & 300 & 700 \\ 300 & 300 & 700 & 700 \end{bmatrix} \quad (44)$$

区域C的厚度为124pixels.

图10(a)中显示了启用与未启用视场保持机制下的特征轨迹对比.未启用保持视场时,特征会到达区域B,启用视场保持时,特征始终被约束在安全区域A内.图10(b)显示的相机轨迹也平滑过渡,没有因为视场保持呈现出曲折和振荡.

图10(c)与10(d)可以看出,在1.5秒附近,此时视场保持开始介入补偿,使得特征在接触到区域A边界后,反向离开.该视场保持系统保证了速度平滑性,确保了速度连续.

图10(e)与10(f)分别给出了自适应估计伺服增益 $\lambda_f$ 和可操纵性 $M$ .初始阶段由于 $M$ 较低,模糊系统输出较小增益以保证安全性;随着机械臂远离边界, $M$ 值提升,输出增益随之增大,从而加快最终收敛速度.该实验验证了本文方法的视场保持策略能有效防止特征丢失,并在保持速度连续性的同时提升系统稳定性.

如表6所示,OS-ELM在整体性能上优于传统ELM.相比之下,收敛时间更短,且在视觉伺服的后期阶段,由于特征误差进入小量区间,算法难以进一步加速收敛.依靠在线权重更新机制,OS-ELM能够更快达到收敛,使系统沿更小误差的轨迹运行,从而


表6 实验四结果

	FA-ELM-IBVS	FA-OS-ELM-IBVS	改进率%
$t_c/s$	5.6	4.28	23↓
$l_c/m$	0.4428	0.3736	18.52↓
$e_{IAE}$	669	637	5.85↓
$e_{ITAE}$	696	548	31.4↓


缩短相机运动路径. 误差指标的对比结果进一步表明, 本文方法在振荡抑制方面表现更为稳健.

### 3.6 实验五: 模型失配实验


实验五主要验证本文方法在深度假设与实际情况严重不符时的鲁棒性. OS-ELM 模型是在深度  $Z=2\text{m}$  的假设下训练的, 若真实深度为  $10\text{m}$ , 则会导致初始的、巨大的模型偏差. 为评估在明显深度改变条件下的伺服性能与鲁棒性, 在实验一的基础上, 将真实深度修改为  $Z = 10\text{m}$ . 结果见图 11 和表 7 所示.



(a) 特征轨迹对比



(b) 经典 IBVS 相机轨迹



(c) 本文方法相机轨迹

图11 实验五仿真结果

表7 实验五结果对比

	经典视觉伺服	FA-OS-ELM-IBVS	改进率%
$t_c/s$	5.48	4.72	13.87↓
$l_c/m$	0.5792	0.2436	57.94↓
$e_{IAE}$	662	523	20.91↓
$e_{ITAE}$	680	430	36.82↓

经典 IBVS 控制律 (式 5) 高度依赖基于深度假设估计的雅可比矩阵  $\hat{L}^+_s$ . 当实际深度变为  $Z = 10\text{m}$  时,  $\hat{L}^+_s$  存在严重的尺度误差, 导致控制增益失配. 如

图 11(a) 和 11(b) 所示, 经典 IBVS 在应对深度估计失衡的状况, 特征轨迹会更长, 相机轨迹显著偏离.

如表 7 所示, 本文方法在收敛时间、轨迹长度和误差代价上优于经典 IBVS. 且与实验一的结果对比, 本文方法的指标结果没有变差, 经典 IBVS 的指标结果整体变差. 这充分表明, 本文方法能够适应环境参数的显著漂移, 实现精确鲁棒的伺服控制.

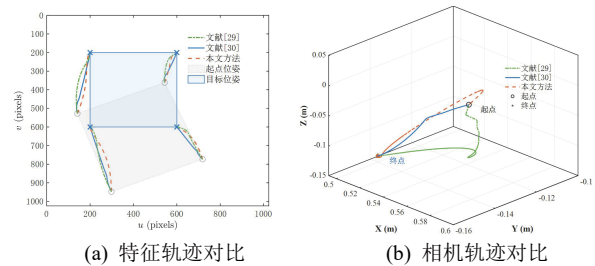
### 3.7 实验六: 与改进 IBVS 方法对比实验

为进一步评估本文方法的有效性, 将该方法与近年改进 IBVS 方法对比. 文献 [29] 利用鲁棒卡尔曼滤波在线估计图像雅可比矩阵, 并借助前馈神经网络在线补偿系统的估计误差; 文献 [30] 利用卡尔曼滤波在线估计复合雅可比矩阵, 并借助秃鹰算法优化极限学习机在线补偿系统的估计误差, 同时采用了模糊增益自适应估计. 为突出 OS-ELM 模型对不同初始姿态的泛化能力, 本实验采用与训练数据差异较大的起始位姿和目标. 即机械臂初始关节角  $q_0$  和期望特征点坐标  $s_d$  为:

$$q_0 = \left[ 0, \frac{11\pi}{40}, \pi, 0, \frac{\pi}{4}, -\frac{3\pi}{8} \right] \quad (45)$$

$$s_d = \begin{bmatrix} 600 & 200 & 200 & 600 \\ 200 & 200 & 600 & 600 \end{bmatrix} \quad (46)$$

图 12 对比了三种方法的特征轨迹和相机轨迹. 具体结果如表 8 所示. 相较于文献 [29] 和 [30], 本文方法在各项指标上均表现最优: 收敛时间  $t_c$  缩短至  $3.12\text{s}$ , 轨迹长度  $l_c$  优化至  $0.2218\text{m}$ , 且累积误差  $e_{IAE}$  与  $e_{ITAE}$  显著降低. 同时, 即便在文献 [30] 同样采用模糊自适应增益的情况下, 本文算法依然展现出更快的收敛速度与更高的轨迹控制精度, 对不同视觉伺服实验也具有有效性.



(a) 特征轨迹对比

(b) 相机轨迹对比

图12 实验六仿真结果

表8 实验六结果对比

	文献[29]	文献[30]	本文方法
$t_c/s$	4.92	3.4	<b>3.12</b>
$l_c/m$	0.2279	0.2295	<b>0.2218</b>
$e_{IAE}$	343	300	<b>249</b>
$e_{ITAE}$	317	181	<b>124</b>

3.8 实验七: 物理实验

为了验证本文方法的有效性, 以 CGX G6 机器人为实验主体, 采用眼在手上安装方式 Intel RealSense D435i 相机, 采样时间为 0.01s, 搭建无标定视觉伺服控制系统实验平台, 如图 13. 伺服目标为 4 个黑色圆形 (直径 10mm), 间距 100mm, 如图 14, 包括初始图像特征和期望图像特征. 本节考虑两种情况验证, 实验结果见图 15 和表 9.



图13 无标定视觉伺服实验平台

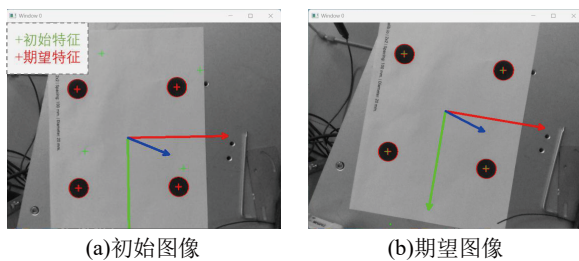


图14 伺服目标

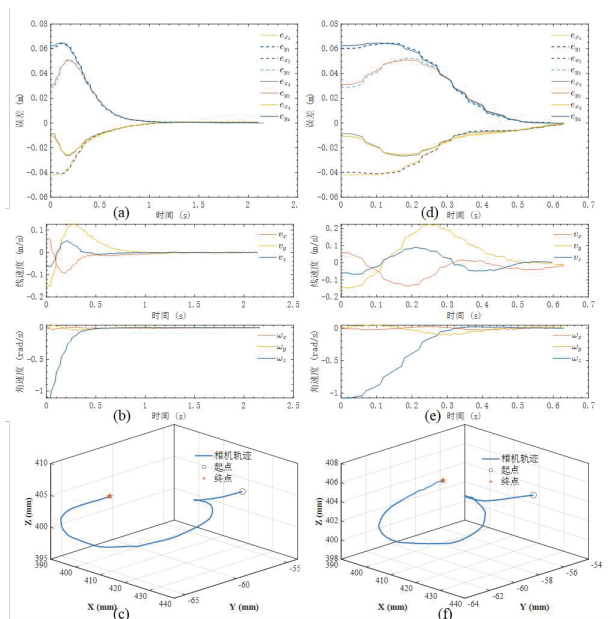


图15 实验七结果

图 15(a)-(c) 为 OS-ELM-IBVS, 固定增益  $\lambda = 4$  的结果, (d)-(f) 为 FA-OS-ELM-IBVS, 采用模糊自适

表9 实验七结果对比

	OS-ELM-IBVS	FA-OS-ELM-IBVS
$l_c/m$	0.0704	0.0749
$e_{IAE}$	0.1529	0.1128
$e_{ITAE}$	0.0466	0.0214

应增益的结果. (a)-(c) 依次代表特征误差、相机速度和相机轨迹.

由图 15 结果表明, 两种情况在真实环境中均能正常收敛到设定阈值. 结合表 9 分析, 采用模糊自适应增益可以提高收敛速度, 误差指标  $e_{IAE}$  和  $e_{ITAE}$  分别降低了 26.23% 和 54.08%. 在真实环境下模糊控制降低了系统的刚度, 导致相机轨迹增加 6.39%, 但仍可以收敛到误差设定阈值.

4 结论

1) 通过引入 OS-ELM, 构建了直接映射图像误差到视觉伺服控制律的非线性估计器. 该方法不仅规避了对雅可比矩阵的显式估计, 而且其在线更新机制能有效补偿离线模型的残差与深度假设偏差, 显著提升了系统的稳态精度和对模型参数漂移的鲁棒性.

2) 设计的三输入模糊增益控制器, 融合了可操纵性指标与误差收敛趋势, 实现了安全为主、兼顾性能的增益调节. 该机制能在保证机械臂远离奇异位形的同时, 有效平衡收敛速度与抗噪声能力.

3) 提出的分层 sigmoid 视场保持策略, 实现了从安全区到危险区的平滑速度干预. 该策略能在不引入控制抖动的前提下, 可靠地将图像特征约束于视野内, 保证了伺服任务的连续性.

本文仅针对点特征开展研究, 而工业场景中区域特征 (如图像矩等) 通常具有更强的抗遮挡与抗噪能力. 因此, 在未来的工作中将根据这些特征进行改进.

参考文献 (References)

- [1] 陶波, 龚泽宇, 丁汉. 机器人无标定视觉伺服控制研究进展[J]. 力学学报, 2016, 48(4): 767-783. (Tao B, Gong Z Y, Ding H. Survey on uncalibrated robot visual servoing control[J]. Chinese Journal of Theoretical and Applied Mechanics, 2016, 48(4): 767-783.)
- [2] Qian J, Su J B. Online estimation of image Jacobian matrix by Kalman-Bucy filter for uncalibrated stereo vision feedback[C]. Proceedings 2002 IEEE International Conference on Robotics and Automation. Washington, 2002: 562-567.
- [3] 辛菁, 白蕾, 刘丁. 基于自适应 Kalman 滤波的机器人 6DOF 无标定视觉定位[J]. 系统仿真学报, 2014, 26(3): 586-591.

- (Xin J, Bai L, Liu D. Adaptive Kalman filter-based robot 6DOF uncalibrated vision positioning[J]. *Journal of System Simulation*, 2014, 26(3): 586-591.)
- [4] Kosmopoulos D I. Robust Jacobian matrix estimation for image-based visual servoing[J]. *Robotics and Computer-Integrated Manufacturing*, 2011, 27(1): 82-87.
- [5] 仲训昊, 徐敏, 仲训昱, 等. 基于雅可比预测的机器人无模型视觉伺服定位控制[J]. *控制与决策*, 2018, 33(10): 1813-1819.  
(Zhong X G, Xu M, Zhong X Y, et al. Jacobian prediction-based for robot model-free visual servoing positioning control[J]. *Control and Decision*, 2018, 33(10): 1813-1819.)
- [6] Zhou Z Y, Zhang R X, Zhu Z F. Robust Kalman filtering with long short-term memory for image-based visual servo control[J]. *Multimedia Tools and Applications*, 2019, 78(18): 26341-26371.
- [7] Wen L Y, Xie Z T. A data-driven acceleration-level scheme for image-based visual servoing of manipulators with unknown structure[J]. *Frontiers in Neurorobotics*, 2024, 18: 1380430.
- [8] Yüksel T. Intelligent visual servoing with extreme learning machine and fuzzy logic[J]. *Expert Systems with Applications*, 2017, 72: 344-356.
- [9] Kang M, Chen H, Dong J X. Adaptive visual servoing with an uncalibrated camera using extreme learning machine and  $Q$ -learning[J]. *Neurocomputing*, 2020, 402: 384-394.
- [10] Li J S, Peng X Y, Li B, et al. Adaptive visual servoing for the robot manipulator with extreme learning machine and reinforcement learning[J]. *Asian Journal of Control*, 2024, 26(1): 280-296.
- [11] Wang B S, Dong J X. A visual servo reinforcement learning control of uncalibrated manipulators with multi-channel gain decision[J]. *Transactions of the Institute of Measurement and Control*, 2025, 47(2): 265-277.
- [12] Fu G, Chu H Y, Liu L W, et al. Deep reinforcement learning for the visual servoing control of UAVs with FOV constraint[J]. *Drones*, 2023, 7(6): 375.
- [13] Arend D, Singh Padda A T, Schwung A, et al. Online-adaptive PID control using reinforcement learning[C]. *The 11th International Conference on Control, Decision and Information Technologies*. Split, 2026: 8-15.
- [14] Qiu Z, Hu S Q, Liang X W. Model predictive control for constrained image-based visual servoing in uncalibrated environments[J]. *Asian Journal of Control*, 2019, 21(2): 783-799.
- [15] Liu S T, Dong J X. Robust online model predictive control for image-based visual servoing in polar coordinates[J]. *Transactions of the Institute of Measurement and Control*, 2020, 42(4): 890-903.
- [16] Ren X L, Li H W, Li Y C. Image-based visual servoing control of robot manipulators using hybrid algorithm with feature constraints[J]. *IEEE Access*, 2020, 8: 223495-223508.
- [17] Karras G C, Fourlas G K, Nikou A, et al. Image based visual servoing for floating base mobile manipulator systems with prescribed performance under operational constraints[J]. *Machines*, 2022, 10(7): 547.
- [18] Bechlioulis C P, Heshmati-alamdari S, Karras G C, et al. Robust image-based visual servoing with prescribed performance under field of view constraints[J]. *IEEE Transactions on Robotics*, 2019, 35(4): 1063-1070.
- [19] Li J S, Peng X Y, Li B, et al. Model predictive control for constrained robot manipulator visual servoing tuned by reinforcement learning[J]. *Mathematical Biosciences and Engineering*, 2023, 20(6): 10495-10513.
- [20] Zhu T Q, Mao J L, Han L Y, et al. Fuzzy adaptive model predictive control for image-based visual servoing of robot manipulators with kinematic constraints[J]. *International Journal of Control, Automation and Systems*, 2024, 22(1): 311-322.
- [21] Jin Y H, Hou L, Ge X D, et al. A novel data-driven modeling and efficient model predictive control framework for non-autonomous nonlinear systems based on the Invertible Koopman Network[J]. *Nonlinear Dynamics*, 2025, 113(16): 20605-20631.
- [22] Hutchinson S, Hager G D, Corke P I. A tutorial on visual servo control[J]. *IEEE Transactions on Robotics and Automation*, 1996, 12(5): 651-670.
- [23] Huang G B, Zhu Q Y, Siew C K. Extreme learning machine: Theory and applications[J]. *Neurocomputing*, 2006, 70(1/2/3): 489-501.
- [24] Liang N Y, Huang G B, Saratchandran P, et al. A fast and accurate online sequential learning algorithm for feedforward networks[J]. *IEEE Transactions on Neural Networks*, 2006, 17(6): 1411-1423.
- [25] Yoshikawa T. Manipulability of robotic mechanisms[J]. *The International Journal of Robotics Research*, 1985, 4(2): 3-9.
- [26] Mamdani E H, Assilian S. An experiment in linguistic synthesis with a fuzzy logic controller[J]. *International Journal of Man-Machine Studies*, 1975, 7(1): 1-13.
- [27] Mezouar Y, Chaumette F. Path planning for robust image-based control[J]. *IEEE Transactions on Robotics and Automation*, 2002, 18(4): 534-549.
- [28] Malis E, Chaumette F. 2 1/2 D visual servoing with respect to unknown objects through a new estimation scheme of camera displacement[J]. *International Journal of Computer Vision*, 2000, 37(1): 79-97.
- [29] 焦建军, 李宗刚, 李龙雄, 等. 无标定视觉伺服多轴孔装配定位方法研究[J]. *中南大学学报: 自然科学版*, 2024, 55(10): 3731-3741.  
(Jiao J J, Li Z G, Li L X, et al. Research on positioning method of uncalibrated visual servo multiple peg-in-hole assembly[J]. *Journal of Central South University: Science and Technology*, 2024, 55(10): 3731-3741.)
- [30] Zhou Z, Hu Y, Ji J, et al. Robot manipulator visual servoing via Kalman filter-optimized extreme learning machine and fuzzy logic[J]. *Ksii Transactions On Internet And Information Systems*, 2022, 16(8): 23.

## 作者简介

姬心想 (2002-), 男, 硕士生, 主要研究方向为机器人视觉伺服, E-mail: 241312010028@hhu.edu.cn;

王婷婷 (1983-), 女, 硕士生导师, 副教授, 主要研究方向为机器人控制, E-mail: 20121894@hhu.edu.cn.