

基于 IGWO-STCPF 的自主水下航行器跟踪方法*

邢传玺, 孟轶涵, 孟强, 保德彪

云南民族大学电气信息工程学院 / 云南省无人自主系统重点实验室, 云南昆明 650504

摘要: 提出了一种融合改进灰狼优化的强跟踪容积卡尔曼粒子滤波算法(IGWO-STCPF)。该方法首先利用强跟踪容积卡尔曼滤波(STCKF)结合观测信息动态调整粒子均值和协方差, 有效提高重要性采样的代表性; 随后在重采样阶段引入信息熵加权的灰狼优化策略, 以增强粒子的多样性并抑制退化现象。仿真实验表明, 相比 STCKF、标准粒子滤波(PF)、粒子群优化滤波(PSO-PF)和粒子群优化-立方卡尔曼粒子滤波(PSO-CPF)方法, 所提算法在轨迹估计精度上分别提升了 13.41%、18.58%、21.86% 和 21.33%。结果验证了 IGWO-STCPF 在复杂水下环境中具备更强的鲁棒性和跟踪性。

关键词: 水下自主航行器; 粒子滤波; 强跟踪容积卡尔曼滤波; 灰狼优化; 信息熵

中图分类号: TP24; TN713 **文献标志码:** A **文章编号:** 2097-0137(2026)01-0064-12

AUV tracking method based on Improved Grey Wolf Optimizer and Strong Tracking Cubature Kalman Particle Filter

XING Chuanxi, MENG Yihan, MENG Qiang, BAO Debiao

School of Electrical and Information Technology, Yunnan Minzu University / Yunnan Key Laboratory of Unmanned Autonomous System, Kunming 650504, China

Abstract: This paper proposes an Improved Grey Wolf Optimization-based Strong Tracking Cubature Kalman Particle Filter algorithm (IGWO-STCPF). The proposed method first employs a Strong Tracking Cubature Kalman Filter (STCKF) to incorporate measurement information for dynamically adjusting the particle mean and covariance, thereby enhancing the effectiveness of importance sampling. Then, an entropy-weighted GWO is introduced into the resampling stage to mitigate particle degeneration and improve estimation accuracy. Simulation results demonstrate that, compared with STCKF, PF, PSO-PF, and PSO-CPF algorithms, the proposed IGWO-STCPF improves trajectory estimation accuracy by 13.41%, 18.58%, 21.86%, and 21.33%, respectively. These results confirm the robustness and effectiveness of the proposed method in complex underwater scenarios.

Key words: autonomous underwater vehicle; PF; STCKF; GWO; information entropy

自主水下航行器(AUV)执行任务时, 容易受到风、浪、流等环境干扰, 造成实时状态难以测量或估计(Ge et al., 2024)。因此, 提升 AUV 在复杂浅海环境中的跟踪精度成为了当前的研究重点。Zhang

et al.(2023)提出了一种 Rao-Blackwellized 粒子滤波器, 通过引入异常检测与重采样策略, 有效抑制了地形辅助导航过程中因声速剖面误差或地形特征不足导致的异常观测, 显著增强了水下长程导航

* 收稿日期: 2025-09-05

录用日期: 2025-10-15

网络首发日期: 2025-10-27

基金项目: 国家自然科学基金(61761048); 云南省基础研究专项(202101AT070132)

作者简介: 邢传玺(1982年生), 男; 研究方向: 水下定位与导航等; E-mail: xingchuanxi@ymu.edu.cn

全文阅读



ZR20250190

的鲁棒性。Ge et al.(2024)进一步提出了非刚性地形变换粒子滤波器,通过柔性映射关系提升了滤波器在复杂海底地形下的适应性和精度。

近年,容积卡尔曼滤波(CKF)及其改进型强跟踪容积卡尔曼滤波(STCKF)逐渐成为处理非线性系统的重要方法,在轨迹跟踪和姿态估计中展现出更高精度和稳定性。但,STCKF在高维场景下依然存在计算负担大、参数敏感性强等问题。为此,Chu et al.(2023)在CKF框架下结合最大相关熵准则与自适应衰落因子,在非高斯噪声环境中显著提升了估计鲁棒性。Dai et al.(2024)则在姿态估计中引入四元数约束与高斯建模,以保证非线性与约束一致性。这些方法有效提升了鲁棒性,但在高维实时应用中保持计算可行性仍然是亟待解决的问题。

而,群智能优化算法与粒子滤波(PF)的结合为解决粒子退化问题提供了新思路。如遗传算法融入粒子滤波器,扩大了粒子搜索范围,缓解了退化问题,但其高维可扩展性未充分论证,且复杂度较高(Park et al., 2009)。近年,其他元启发式优化算法也被引入PF框架。Yang et al.(2023)提出的Harris Hawks优化粒子滤波器在水下目标跟踪中显著提升了粒子多样性。Peng et al.(2024)在灰狼优化(GWO)中引入黄金分割搜索策略,提出GSGWO-PF,用于无线传感器网络目标跟踪。同时,Zhang et al.(2024)提出的模糊更新鲁棒PF在地形特征稀疏场景下显著降低了粒子退化。Yilmaz et al.(2023)则在真实飞行试验中验证了基于PF的目标跟踪方法的有效性。国内学者尝试将布谷鸟搜索、蚁群优化等与PF结合应用于航迹预测和目标跟踪等(曾润等, 2022; 王力等, 2023; 申明亮等, 2024)。然而,在提升滤波精度与鲁棒性的同时控制优化过程带来的额外开销仍是领域的难题。

在众多群体智能优化方法中,灰狼优化算法具备参数设置简单、收敛过程稳定的特点。针对GWO重要性密度函数的选取,粒子退化等问题,本文提出了将STCKF与灰狼优化算法相结合以改进粒子滤波的水下目标跟踪新算法,增强了在不同阶段对优质个体的动态引导能力。

1 数学模型

1.1 AUV的坐标系与运动学模型

如图1所示,AUV需要两个坐标系表达其运动状态。固定坐标系 $\{E\}$ 是常用的地理参考坐标系,简称定系,用于描述AUV浮心的运动情况。另外,

还需建立以AUV自身为参考的运动坐标系 $\{B\}$,简称动系,用于描述AUV相对自身的运动情况。




图1 AUV坐标变换

Fig. 1 AUV coordinate transformation

AUV惯性坐标系下的运动参数 $[x, y, z, \psi, \theta, \varphi]$ 与随体坐标系下的运动参数 $[u, v, w, p, q, r]^T$ 的转换关系如式(1)所示。

$$\begin{bmatrix} \dot{x} \\ \dot{y} \\ \dot{z} \\ \dot{\psi} \\ \dot{\theta} \\ \dot{\varphi} \end{bmatrix} = J \begin{bmatrix} u \\ v \\ w \\ p \\ q \\ r \end{bmatrix}, \quad (1)$$

式中 J 为量测模型。量测模型及其转换推导过程见王宁等(2024)。

1.2 AUV量测模型

如图2所示,假定单站有源声呐为观测站,观测站在进行AUV探测时,获取的目标AUV的距离为 r_k 、俯仰角为 θ_k 、偏航角为 φ_k 。则系统的量测方程为

$$Y_k = h(X_k) + V_k = h(r_k, \theta_k, \varphi_k) + V_k,$$

式中 $r_k = \sqrt{x_k^2 + y_k^2 + z_k^2}$, $\theta_k = \arctan(z_k / \sqrt{x_k^2 + y_k^2})$,




图2 三维空间运动模型

Fig. 2 Three-dimensional motion model

$\varphi_k = \arctan(y_k/x_k)$, \mathbf{Y}_k 表示 k 时刻目标的量测向量; $h(\mathbf{X}_k)$ 表示量测函数; \mathbf{X}_k 为 k 时刻系统状态; $\mathbf{V}_k \sim \mathcal{N}(0, \mathbf{R}_k)$ 表示 k 时刻声呐自身的测量噪声, $\mathbf{R}_k = \text{diag}(\sigma_{r_k}^2, \sigma_{\theta_k}^2, \sigma_{\varphi_k}^2)$ 为 k 时刻量测噪声的协方差矩阵, 浅海中海况会影响方差 $\sigma_r, \sigma_\theta, \sigma_\varphi$ 的有效大小。

2 融合 STCKF 的粒子滤波算法

2.1 标准粒子滤波

粒子滤波通过带权重的一组随机样本(粒子)来近似后验概率密度, 包括预测、更新、重采样 3 个步骤。根据获得的量测值 y_k , 可以更新粒子的重要性权值

$$\bar{w}(x_k^{(i)}) = \bar{w}(x_{k-1}^{(i)}) \frac{p(y_k | x_k^{(i)}) p(x_k^{(i)} | x_{k-1}^{(i)})}{q(x_k^{(i)} | x_{k-1}^{(i)}, y_{1:k})},$$

其中 $q(\cdot)$ 对滤波性能影响显著, 若其能接近后验分布, 将有效减缓粒子退化问题。在处理复杂动态场景时, 传统粒子滤波算法的不足主要表现为样本退化严重, 导致估计精度下降(Choppala et al., 2025)。对于高维系统, 标准 PF 需要大量粒子以维持估计精度, 会导致计算的复杂度增加。因此, 本文从密度函数和重采样两个步骤对标准 PF 算法进行改进。首先针对密度函数做出改进。

2.2 STCKF 算法

2.2.1 CKF 算法 CKF 算法以贝叶斯估计为理论基础, 其核心在于构造容积点并在状态与观测函数下进行数值积分, 直接估计非线性变换后的均值与协方差, 避免对系统函数的线性化假设, 兼顾了计算效率与估计精度(Arasaratnam et al., 2011)。CKF(谢少彪等, 2021)的主要步骤如表 1 所示。

然而, CKF 是一种递推最小均方估计器, 对于

表 1 CKF 的步骤
Table 1 Steps of CKF

步骤	计算内容
1 时间预测	
1.1 计算容积点: $\mathbf{X}_{i, k-1} = \sqrt{\mathbf{P}_{k-1}} \boldsymbol{\xi}_i + \hat{\mathbf{x}}_{k-1}, i = 1, \dots, 2n$	
1.2 传播容积点	
1.3 估计预测均值 $\hat{\mathbf{x}}_k$ 和协方差矩阵 \mathbf{P}_k	
2 量测更新	
2.1 计算容积点: $\mathbf{X}_{i, k} = \sqrt{\mathbf{P}_k} \boldsymbol{\xi}_i + \hat{\mathbf{x}}_k, i = 1, \dots, 2n$	
2.2 传播容积点 $\mathbf{Z}_{i, k} = h(\mathbf{X}_{i, k}, \mathbf{u}_k), i = 1, \dots, 2n$	
2.3 计算量测预测值 \hat{z}_k 、新息方差 $\mathbf{P}_{\Xi, k}$ 以及协方差矩阵 $\mathbf{P}_{\Sigma, k}$	
2.4 计算量测更新 $\mathbf{K}_k, \hat{\mathbf{x}}_k, \mathbf{P}_k$	

系统建模误差、突变干扰、非高斯噪声等情况的适应能力较弱, 易导致滤波性能退化甚至发散。

2.2.2 融入强跟踪滤波的 CKF 算法 算法在预测协方差中引入动态调整的渐消因子, 使滤波器具备自适应增益调整能力, 从而实现对突变或非建模动态的快速响应。渐消因子

$$\lambda_{k+1} = \begin{cases} \lambda_0, & \lambda_0 \geq 1, \\ 1, & \lambda_0 < 1, \end{cases}$$

其中

$$\lambda_0 = \frac{\text{tr}(\mathbf{N}_{k+1})}{\text{tr}(\mathbf{M}_{k+1})},$$

式中 $\text{tr}(\cdot)$ 为求矩阵迹的算子。

$$\mathbf{N}_{k+1} = \mathbf{V}_{k+1} - \mathbf{H}_{k+1} \mathbf{Q}_k \mathbf{H}_{k+1}^T - \beta \mathbf{R}_{k+1},$$

$$\mathbf{M}_{k+1} = \mathbf{H}_{k+1} \boldsymbol{\Phi}_{k+1|k} \mathbf{H}_{k+1}^T,$$

式中 $\beta \geq 1$ 为弱化因子, 本文取 $\beta = 1.2$; \mathbf{Q}_k 为系统过程噪声(王威等, 2024)。 $\boldsymbol{\Phi}_{k+1|k}$ 和 \mathbf{H}_{k+1} 为状态方程和测量方程的线性化矩阵, 可通过雅可比矩阵计算得到。

$$\mathbf{V}_{k+1} = \begin{cases} \boldsymbol{\varepsilon}_1 \boldsymbol{\varepsilon}_1^T, & k = 0, \\ \frac{\rho \mathbf{V}_k + \boldsymbol{\varepsilon}_{k+1} \boldsymbol{\varepsilon}_{k+1}^T}{1 + \rho}, & k \geq 1, \end{cases}$$

式中 \mathbf{V}_{k+1} 为残差协方差矩阵; $\rho (0 < \rho \leq 1)$ 为遗忘因子, 本文取 $\rho = 0.95$ 。

参数 ρ, β 的取值综合考虑了滤波器对历史新息的保留程度与当前观测响应速度之间的平衡, 兼顾了系统的稳健性与强跟踪能力。为了将渐消因子加入 CKF, 建立非线性系统下的 STF 算法(Zhang et al., 2019), 计算残差:

$$\begin{aligned} \hat{\mathbf{x}}_{k+1} &= \hat{\mathbf{x}}_{k+1|k} + \mathbf{K}_{k+1} \mathbf{e}_{k+1}, \\ \mathbf{e}_{k+1} &= \mathbf{z}_{k+1} - h(\hat{\mathbf{x}}_{k+1|k}), \end{aligned}$$

式中 $\hat{\mathbf{x}}_{k+1}$ 为 $k+1$ 时刻的状态估计值; \mathbf{K}_{k+1} 为滤波增益; \mathbf{z}_{k+1} 为 $k+1$ 时刻的实际测量值; $h(\hat{\mathbf{x}}_{k+1|k})$ 是量测预测值; \mathbf{e}_{k+1} 表示滤波残差。

基于 CKF 的算法框架, 将渐消因子融入至量测更新的量测误差协方差矩阵和互协方差矩阵, 最终形成了 STCKF, 即

$$\mathbf{P}_{\Xi, k}^\lambda = \lambda_k \left(\frac{1}{2n} \sum_{i=1}^{2n} \mathbf{Z}_{i, k} \mathbf{Z}_{i, k}^T - \hat{z}_k \hat{z}_k^T \right) + \mathbf{R}_k,$$

$$\mathbf{P}_{\Sigma, k}^\lambda = \lambda_k \left(\frac{1}{2n} \sum_{i=1}^{2n} \mathbf{X}_{i, k} \mathbf{Z}_{i, k}^T - \hat{\mathbf{x}}_k \hat{z}_k^T \right),$$

式中 $\mathbf{P}_{\Xi, k}^\lambda$ 与 $\mathbf{P}_{\Sigma, k}^\lambda$ 为引入渐消因子后的新息方差和协方差矩阵。

最后, 利用 $\mathbf{P}_{\Xi, k}^\lambda$ 和 $\mathbf{P}_{\Sigma, k}^\lambda$ 重新计算 \mathbf{K}_{k+1} 、最终估计

状态 \hat{x}_{k+1} 和误差协方差 P_{k+1} 。STCKF 算法结合了 CKF 的数值积分优点与 STF 的自适应能力, 构成一种兼具精度与鲁棒性的非线性自适应滤波器。

3 IGWO-STCPF 算法设计

3.1 灰狼优化算法

在 GWO 中, 灰狼被分为四个等级: α 、 β 、 δ 和 ω 狼, 如图 3 所示, 其中 α 、 β 、 δ 狼代表当前搜索空间中最优的 3 个解, 用以引导其余个体 (ω 狼) 向解空间的潜在最优区域移动。算法通过对猎物位置的逼近过程 (如图 4 所示), 实现个体在解空间的不断更新与收敛。




图3 灰狼社会等级制度

Fig. 3 Hierarchical social structure of grey wolves




图4 GWO 位置更新机制

Fig. 4 Position update mechanism of GWO

GWO 算法核心公式为:

$$X(t+1) = X_p(t) - A \cdot D,$$

$$D = |C \cdot X_p - X(t)|,$$

$$X_p(t+1) = \frac{1}{3} \sum_{i=1,2,3} X_i(t+1),$$

式中 $X_p(t)$ 为当前猎物的位置; $X(t)$ 为当前灰狼的位置; \cdot 为 Hadamard 乘积; A 、 C 表示更新系数, $A = 2a \cdot r_1 - a$, $C = 2 \cdot r_2$, r_1 和 r_2 为 $[0, 1]$ 之间的随机向量; a 为收敛因子, 是随着迭代次数在 $[0, 2]$ 中线性递减的控制参数。

3.2 改进的灰狼优化算法

针对 GWO 算法的改进主要集中在两个方面:

(1) 采用全新的非线性收敛因子更新策略。(2) 为克服标准灰狼优化算法中 3 头精英个体对种群更新引导作用的平均化缺陷, 本文引入基于信息熵的适应度加权机制。

3.2.1 非线性收敛因子 a 优化策略 标准的 GWO 算法中收敛因子 a 采用的是线性递减策略, 容易陷入局部最优。已有研究表明, 在迭代开始阶段, a 应该缓慢减小以提高算法的探索性; 在迭代后期, a 的减小速度应减缓以提高算法的开采性。对参数 a 重新定义如下:

$$a(t) = a_{\text{end}} + (a_{\text{start}} - a_{\text{end}}) \times \frac{1}{1 + e^{\frac{10b(t)(2t)}{T_{\text{max}} - 1}}},$$

$$b(t) = b_{\text{end}} + (b_{\text{start}} - b_{\text{end}}) \times \left(\frac{t}{T_{\text{max}}}\right)^2,$$

式中 a_{start} 为初始权重, 设定为 2; a_{end} 为迭代后的最终权重, 设为 0; $b(t)$ 是控制权重下降陡峭度的系数; t 为当前迭代次数; T_{max} 为最大迭代次数。

丁瑞成等 (2022) 的收敛因子更新策略为

$$a_1 = a_{\text{min}} + (a_{\text{max}} - a_{\text{min}}) e^{-\left(\frac{1.5t}{T}\right)^4},$$

$$a_2 = 2 \times \left(1 - \frac{t}{T}\right)^{\frac{1}{3}},$$

$$a_3 = (a_{\text{max}} - a_{\text{min}}) \cos \frac{t}{T},$$

$$a_4 = a_{\text{max}} - (a_{\text{max}} - a_{\text{min}}) \times \left(\frac{t}{T}\right)^2.$$

图 5 为不同 a 更新策略的对比结果。从图中可知, 本文的策略使得 a 在迭代初期具有较大的取值且衰减速度较缓, 显著增强了算法的全局搜索能力, 有助于引导种群在更大的解空间内进行探索, 降低陷入局部最优的风险。随着迭代的进行, a 在后期迅速减小, 增强了算法的局部开发能力, 提升了解空间局部区域的搜索精度, 加快了收敛速度。

3.2.2 基于信息熵的适应度加权更新策略 设 3 头精英狼 α 、 β 、 δ 的适应度函数值分别为 f_α 、 f_β 、 f_δ , 首先对适应度进行归一化处理, 得到个体贡献概率

$$p_i = \frac{1/(f_i + \varepsilon)}{\sum_{j=\alpha,\beta,\delta} 1/(f_j + \varepsilon)},$$

其中 ε 为防止分母为 0 的小常数。随后, 依据概率分布计算个体信息熵 $E_i = -p_i \cdot \log(p_i + \varepsilon)$, 并以熵的反比关系确定初始权重 $w_i^* = 1 - E_i$ 。

为防止权重过小导致个体贡献退化, 引入下限约束 $w_i = \max(w_i^*, \xi)$, $\xi \in [10^{-6}, 10^{-3}]$, 进行归一化修正, 得到动态权重系数




图 5 不同 a 更新策略的对比

Fig. 5 Comparison of decreasing strategies for different a

$$\tilde{w}_i = \frac{w_i}{w_\alpha + w_\beta + w_\delta}$$

由此,改进的灰狼位置更新公式为

$$X_i(t+1) = \tilde{w}_\alpha X_\alpha + \tilde{w}_\beta X_\beta + \tilde{w}_\delta X_\delta,$$

其中 \tilde{w}_α , \tilde{w}_β 和 \tilde{w}_δ 由信息熵机制动态生成,可自适应反映精英个体优劣,实现搜索引导能力的动态调节,从而增强全局探索能力并加快收敛速度。

选用一个经典的非线性系统用于标准 GWO 和改进 GWO 算法的性能分析。

系统状态方程为

$$x(k) = 0.5x(k-1) + \frac{2.5x(k-1)}{1+x(k-1)^2} + 8 \cos(1.2k) + w(k).$$

观测方程为

$$Z(k) = \frac{x(k)^2}{20} + v(k),$$

式中 $w(k)$ 为过程噪声,其方差为 Q ; $v(k)$ 为测量噪声,其方差为 R 。

试验中,初始状态时间 $x_0 = 0$,总步长 $T = 100$,随机噪声为高斯分布,取两组噪声分别进行测试。第 1 组的 $Q=R=1$;第 2 组的 $Q=R=10$ 。

试验结果显示,在图 6 的低噪声场景下,标准 GWO 算法的 RMSE 为 2.498 4 m,而改进后的 GWO 算法的 RMSE 降低至 2.182 9 m,误差下降约 12.31%。在图 7 的高噪声环境下,标准 GWO 的 RMSE 为 5.292 3 m,改进 GWO 的 RMSE 为 4.179 4 m,误差下降达到 21.03%。上述结果表明,改进 GWO 算法抗噪能力方面展现出明显优势,尤其在高噪声复杂环境中,其改进效果更为显著。

3.3 IGWO-STCPF 算法流程

IGWO-STCPF 算法流程如图 8 所示。本文将强




图 6 $Q=R=1$ 时的跟踪误差

Fig. 6 Tracking errors when $Q=R=1$




图 7 $Q=R=10$ 时的跟踪误差

Fig. 7 Tracking errors when $Q=R=10$

跟踪容积卡尔曼滤波、改进灰狼优化算法与粒子滤波有机融合,形成新型 IGWO-STCPF 算法。

该算法的核心步骤为:(1)初始化。设粒子数为 N ,从先验分布 $p(x_0)$ 中采样 $\{x_0^i\}$,初始权重为 $w_0^i = 1/N$ 、均值为 \bar{x}_0^i 、方差为 p_0^i 。设定 GWO 的最大迭代次数 T_{\max} 和收敛因子 a 。(2)STCKF 更新与权重归一化。由 STCKF 算法更新粒子集 $\{\hat{x}_k^i, \hat{p}_k^i\}$,计算其归一化权重 \tilde{w}_k^i 。(3)IGWO 优化重采样。首先,计算适应度函数 $f(X_k^i)$;然后,进行精英筛选与保留,即选出适应度最优的 α, β, δ ;其次,进行参数更新。更新收敛因子 a ,计算 A, C ;并进行熵权计算,由 $f(\alpha), f(\beta)$ 和 $f(\delta)$ 计算 p_i, E_i ,得到 \tilde{w}_i ;同时,进行位置更新 $X_i(t+1) = \tilde{w}_\alpha X_\alpha + \tilde{w}_\beta X_\beta + \tilde{w}_\delta X_\delta$;重复熵权计算和位置更新

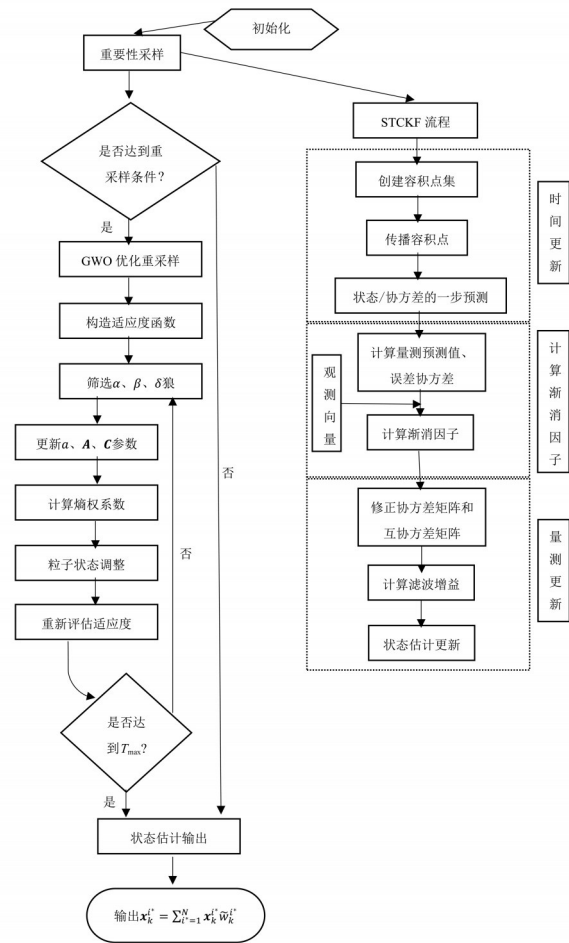


图 8 IGWO-STCPF 算法流程
Fig. 8 IGWO-STCPF algorithm flowchart

过程进行迭代优化,直到达到 T_{max} 。

STCKF 不仅提供每个粒子的状态预测与协方差传播,还通过引入渐消因子动态调节预测误差协方差,使得粒子采样更符合观测更新条件下的后验分布。STCKF 的引入实际上改变了重要性密度函数的形式,使其在贝叶斯更新中更接近真实后验概率密度,从而在理论上优化了粒子滤波的最优重要性函数近似问题。

在此基础上,以 IGWO 算法替代传统的重采样机制。IGWO 基于目标观测残差构建适应度函数,引导粒子在高维空间中围绕状态估计均值进行协同更新。特别是通过引入信息熵加权策略以及改进的非线性收敛因子策略,通过将 3 头精英的位置按熵权自适应加权,并在重采样阶段以优化形式对粒子位置进行协同更新,从而在保留重要粒子的同时提高粒子位置的均匀性与代表性,显著抑制退化并提升估计精度。

IGWO-STCPF 形成了预测-更新-重采样 3 阶段紧密耦合的协同滤波框架。每个阶段之间信息充分

传递,状态估计不仅受到当前观测的影响,还在灰狼优化中得到粒子集整体结构的反馈调控,构建了一个信息驱动的闭环更新路径。这种设计在理论上可以归类为强化型粒子滤波框架,在收敛性上具备更优的误差控制能力。因此,IGWO-STCPF 不仅在算法结构上具有逻辑闭环的合理性,而且其融合方式在功能层面具备显著的互补性,在目标跟踪等动态系统中的实际应用中具有广泛的适应性。

3.4 全局收敛性与时间复杂度分析

3.4.1 全局收敛性分析 Solis 和 Wets 曾提出随机优化算法全局收敛性准则,本文采用该收敛准则证明 IGWO 的全局收敛性。

条件 1 $f(D(x, \xi)) \leq f(x)$; 若 $\xi \in S$, 则有 $f(D(x, \xi)) \leq f(\xi)$ 。其中 f 为目标函数; S 为搜索空间; $D(x, \xi)$ 表示算法在 $t + 1$ 次迭代中的结果; ξ 为算法搜索过的解。

条件 2 对于搜索空间 S 中的任意 Borel 子集 A , 满足 $\nu(A) > 0$ (ν 为 Lebesgue 测度), 有

$$\prod_{t=0}^{\infty} (1 - \mu_t(A)) = 0,$$

式中 $\mu_t(A)$ 表示算法第 t 次迭代时所得解在集合 A 上的概率测度。

定理 1 设函数 f 可测, 搜索空间 S 是 \mathbf{R}^n 中的可测子集, 随机优化算法满足条件 1 和条件 2, x_t 是算法迭代过程中产生的序列, 则存在

$$\lim_{t \rightarrow \infty} P[x_t \in S^*] = 1,$$

式中 $P[\cdot]$ 表示算法第 t 次迭代的结果落在集合 S^* 中的概率; S^* 表示全局最优解集合。

由 IGWO 算法的迭代过程分析, 其属于随机搜索算法。

证明 在 IGWO 中, α, β, δ 狼始终保留历史最优解

$$f(X_{\alpha}^{t+1}) = \min(f(X_{\alpha}^t), f(\text{new candidates})).$$

当算法采用精英保留机制且在每一代只在非精英个体上执行随机扰动或更新时, 全局最优(或当前最优)适应度值在代际间是非增的(即不会比上一代更差)。因此 $f(X_{\alpha}^{t+1}) \leq f(X_{\alpha}^t)$, 目标函数值具有非增性, 即满足收敛条件 1。对于系数 $A = 2a \cdot r_1 - a, C = 2 \cdot r_2$, 信息熵权重 w_i 的动态调整不改变随机性本质, 满足算法搜索空间对任意子集 Borel 集都有非零采样概率; 由 A, C 的均匀分布保证全空间可达, 即

对任意 A 满足 $\nu(A) > 0$, 存在 $\epsilon > 0$ 使得概率 $\mu_t(A) \geq P(\text{至少 1 个粒子通过随机项落入 } A) \geq \epsilon \nu(A)$,

即经过无限次迭代后,仍不能发现全局最优解的概率为0,满足条件2。由定理1可知,IGWO收敛于全局最优。

粒子滤波的收敛性则由以下定理保证:

定理2 若重要性密度函数满足 $q(\mathbf{x}_k|\mathbf{x}_{k-1}, \mathbf{z}_k) = p(\mathbf{x}_k|\mathbf{x}_{k-1}, \mathbf{z}_k)$, 且粒子数 $N \rightarrow \infty$, 则粒子集近似后验分布 $p(\mathbf{x}_{1:k}|\mathbf{z}_{1:k})$ 的概率测度弱收敛于真实后验分布。

卡尔曼滤波的收敛性可通过数学证明来阐述。假设系统状态满足线性高斯状态空间模型,并且观测噪声和过程噪声都满足正态分布。则卡尔曼滤波可得到如下状态估计方程:

$$\hat{\mathbf{x}} = \mathbf{A}^T \mathbf{P} \mathbf{A} \mathbf{x} + \mathbf{A} \mathbf{P} \mathbf{C} \mathbf{z},$$

式中 $\hat{\mathbf{x}}$ 表示状态估计值, \mathbf{P} 表示状态协方差矩阵, \mathbf{A} 表示系统状态转移矩阵, \mathbf{C} 表示观测矩阵, \mathbf{z} 表示观测值。卡尔曼滤波的状态估计本质上是预测值和观测值的最优加权融合,其权重分配由卡尔曼增益矩阵和观测噪声协方差矩阵共同决定。由于卡尔曼增益和观测噪声方差都是正数,因此状态估计值会随着观测值的增加而逐渐趋近于真实值,即卡尔曼滤波具有收敛性。

考虑融合结构,设定算法的复合状态传播过程为

$$\mathbf{X}_k = \mathcal{R}_{\text{IGWO}} \circ \mathcal{S}_{\text{STCKF}}(\mathbf{X}_{k-1}),$$

式中 $\mathcal{S}_{\text{STCKF}}$ 表示由观测更新后的状态先验估计, $\mathcal{R}_{\text{IGWO}}$ 为信息熵加权重采样操作; \circ 为算子复合符号。在该复合映射下,粒子集状态呈现马尔可夫性,且引导策略具备全局收敛性与粒子多样性维持机制,因此整体序列 $\{\mathbf{X}_k\}_{k=1}^T$ 在迭代过程中将稳定趋近于后验状态分布的最优估计,满足

$$\lim_{k \rightarrow \infty} P(\|\mathbf{X}_k - \mathbf{X}^*\| > \epsilon) = 0, \epsilon > 0.$$

综上,证明了IGWO-STCPF的全局收敛性。

为了评估算法的收敛性与稳定性,进行500次蒙特卡洛试验,检验位置估计性能。对自主水下飞行器利用该算法进行仿真实验。仿真涉及的参数如表2所示。

设置IGWO-STCPF的 $a_{\text{start}} = 2, a_{\text{end}} = 0$, 系统的更新状态周期 $\Delta t = 10$ s。由图9可见,随着试验次数的增加,算法误差呈现逐步收敛的特性,并趋于稳定,表明所提出的IGWO-STCPF算法具有良好的全局收敛性能,能够有效提升水下目标的位置估计精度与稳定性。

3.4.2 时间复杂度 IGWO-STCPF算法主要由ST-CKF重要性采样与IGWO优化重采样两部分组

表2 AUV仿真参数设置
Table 2 AUV simulation parameter settings

类别	参数	数值
	声呐位置	(0, 0, 0)
	AUV初始位置	(0, 0, 0)
初始条件	初始速度/(m·s ⁻¹)	10
	初始俯仰角	$\pi/4$
	初始偏航角	$\pi/10$
	偏航角速度/(rad·s ⁻¹)	0.25
采样与仿真	采样时间间隔 t/s	1
	仿真时间 T/s	100
	粒子数 N	100
噪声设置	过程噪声 \mathbf{Q}	diag(1, 1, 1, 0.1, 0.01, 0.01)
	测量噪声 \mathbf{R}	diag(2, 0.01 ² , 0.01 ²)
	初始协方差矩阵 $\mathbf{P}_{0,0}$	diag(1, 1, 1, 0.1, 0.01, 0.01)




图9 位置RMSE随Monte Carlo实验次数的变化

Fig. 9 RMSE of position versus Monte Carlo trial index

成。对于状态维数为 L , 粒子数为 N , 灰狼优化最大迭代次数为 T_{max} 的算法, 整体的时间复杂度约为 $O(T(NL^3 + T_{\text{max}}NL))$, 其中ST-CKF的三维容积点传播与矩阵运算为主要耗时瓶颈, 而IGWO重采样优化部分则通过熵权加权实现全局引导搜索, 复杂度受迭代次数和粒子数影响。整体上算法具有较高的精度与稳定性。各算法时间复杂度和运行时间如表3~4所示。

可以看出, IGWO-STCPF平均迭代时间为 10^3 数量级, 相较于系统状态更新周期 $\Delta t = 10$ s 的尺度, 这个运行时间完全可以接受。

表3 不同算法的时间复杂度

Table 3 Time complexity under different algorithms

算法	时间复杂度
STCKF	$O(TL^3)$
PF	$O(TNL^2)$
PSO-PF	$O(TT_{\max}NL)$
PSO-CPF	$O(T(NL^3 + T_{\max}NL + NL^2))$
IGWO-STCPF	$O(T(NL^3 + T_{\max}NL))$

表4 不同算法的运行时间

Table 4 Runtime under different algorithms

算法	运行时间	平均迭代时间
STCKF	0.036 6	0.000 366
PF	0.063 4	0.000 634
PSO-PF	0.909 3	0.009 093
PSO-CPF	1.726 1	1.007 261
IGWO-STCPF	0.769 7	0.007 697

4 仿真结果分析

4.1 仿真背景

以某自主水下航行器及其声纳系统为研究对象,比较 STCKF、PF、PSO-PF、PSO-CPF、IGWO-STCPF 算法在轨迹跟踪中的表现。除表2中涉及的参数以外,蒙特卡洛次数设置为100,IGWO-STCPF 的 $a_{\text{start}} = 2$ 、 $a_{\text{end}} = 0$ 。

初始值 $\omega_{\max} = 0.9$,终止值 $\omega_{\min} = 0.4$,惯性权重采用指数衰减方式更新:

$$\omega^{(t)} = \omega_{\min} + (\omega_{\max} - \omega_{\min}) \cdot \exp[-\alpha(t - 1)],$$

式中 $\alpha = 0.2$ 。个体学习因子 c_1 从2.0递减至1.0,全局学习因子 c_2 从1.5上升至2.0,以平衡局部开发与全局搜索。最大迭代次数设置为20,粒子搜索边界根据目标状态的物理范围设置为

$$\mathbf{LB} = [-300, -300, -300, 0, -\pi/2, -\pi]^T,$$

$$\mathbf{UB} = [300, 300, 0, 10, \pi/2, \pi]^T.$$

所有 PSO 计算均在此边界内执行,以避免不合

理的粒子对系统稳定性造成干扰。其他参数设定,详见文献(杜睿山等,2025;张文宇等,2025;朱凯鹏等,2025)的经验值,并结合本文三维目标状态估计任务的实际分布特性进行了适配调整。

4.2 结果分析

4.2.1 RMSE 对比分析 从位置误差、角度误差以及 X - Y 平面偏移程度方面分析对比本文算法、STCKF、PF、PSO-PF、PSO-CPF 算法的性能,如图10~16所示。图10表明,5种算法均能够有效地跟踪 AUV 运动的轨迹。图11为5种算法位置估计误差曲线,其中 IGWO-STCPF 算法的误差和波动较小,显示其在位置估计精度方面优于其他算法。




图10 AUV跟踪曲线

Fig. 10 AUV tracking curves

图12~13为 X 和 Y 方向的跟踪误差曲线。结果表明,5种跟踪算法中 IGWO-STCPF 在 X 和 Y 方向的均方误差最小,且波动幅度平缓,绝大多数误差在2 m以内,验证了其在位置跟踪方面的优越性。图14~15为俯仰角(Pitch)和航向角(Yaw)误差曲线。结果表明,IGWO-STCPF 的 Pitch 和 Yaw 误差最小,且波动幅度较小,进一步验证了 IGWO-STCPF 综合性能的优越性。

4.2.2 IGWO-STCPF 算法性能 如表5所示,与其他算法相比,IGWO-STCPF 的位置估计 RMSE 分别

表5 不同算法的位置和角度 RMSE

Table 5 Position and angle RMSE of different algorithms

算法	位置误差/m	X 方向跟踪误差/m	Y 方向跟踪误差/m	Pitch 误差/rad	Yaw 误差/rad
STCKF	1.337 3	0.999 8	1.009 0	0.079 0	0.111 7
PF	1.422 2	1.204 4	1.201 6	0.080 4	0.093 7
PSO-PF	1.481 8	1.042 0	1.107 9	0.091 3	0.090 9
PSO-CPF	1.471 4	1.042 4	1.090 1	0.090 9	0.089 1
IGWO-STCPF	1.157 9	0.877 5	0.880 8	0.060 2	0.076 0

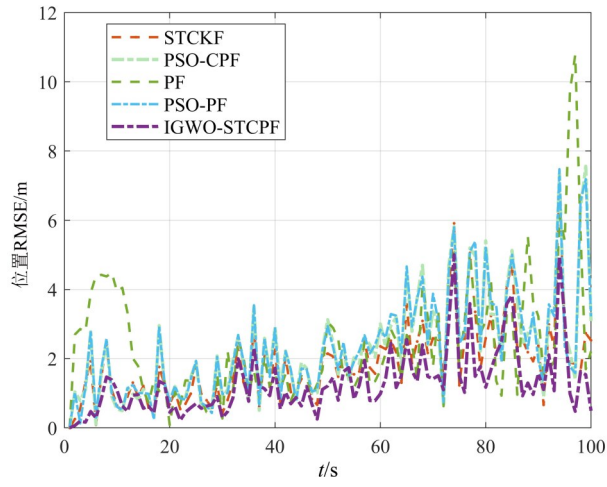


图 11 AUV 跟踪误差曲线

Fig. 11 Position error curve for AUV tracking




图 14 Pitch 误差曲线

Fig. 14 Pitch error curve




图 12 X 方向跟踪误差曲线

Fig. 12 Tracking error curve in the X direction




图 15 Yaw 误差曲线

Fig. 15 Yaw error curve




图 13 Y 方向跟踪误差曲线

Fig. 13 Tracking error curve in the Y direction




图 16 X - Y 平面偏移程度

Fig. 16 X - Y plane offset level

提升 16.46%、27.04%、25.44%、25.03%; X 方向跟踪误差分别提升 12.23%、27.14%、15.79%、15.82%, Y 方向跟踪误差分别提升 12.71%、26.69%、20.50%、19.20%。俯仰角误差分别降低 23.80%、25.12%、34.06%、33.77%, 航向角误差分别减少 31.96%、18.89%、16.39%、14.70%。

综合来看, IGWO-STCPF 在位置精度、坐标轴方向跟踪误差及姿态估计方面均优于对比算法, 平均精度提升幅度达 10%~35%, 展现出良好的稳定性, 特别适用于 AUV 等复杂目标的状态估计任务。

4.2.3 不同噪声及粒子数下的算法性能 图 17 为初始条件不变的情况下测量噪声对 IGWO-STCPF 算法跟踪误差的影响。 R_1 为正常测量噪声协方差, 噪声设置为 R_1 、 $5R_1$ 、 $10R_1$, 其对应的误差分别为 1.362 5、2.728 3、2.963 5 m。结果表明, IGWO-STCPF 对位置的估计受测量噪声影响较小, 表现出良好的鲁棒性。图 18 为 $N = 50$ 、100、500 时的位置估计误差。对应的位置估计误差分别为 1.260 0、1.284 2、1.195 3 m。这说明该算法在粒子数较少情况下也可以维持较高精度的跟踪能力。

4.2.4 混合高斯噪声下算法的性能 混合高斯噪声下 AUV 跟踪曲线如图 19 所示。观测噪声采用混




图 18 不同粒子数下的位置 RMSE

Fig. 18 Position RMSE with varying particle counts

合高斯分布, 包括高概率的小方差噪声以及低概率的大方差异常噪声, 以模拟实际海洋环境中可能出现的突发干扰。比较 PF、PSO-PF、PSO-CPF 以及 IGWO-STCPF 算法在该噪声条件下的位置 RMSE, 能够直观评估算法的精度和稳健性。

将量测模型中的测量噪声 V_k 改写为

$$p(\mathbf{e}) = (1 - \varepsilon_e)N(\mathbf{0}, \mathbf{R}_1) + \varepsilon_e N(\mathbf{0}, \mathbf{R}_2),$$

式中 $\varepsilon_e = 0.05$ 为异常噪声出现概率, $\mathbf{R}_2 = 10\mathbf{R}_1$ 为异常测量噪声协方差。

由于 STCKF 的假设前提为噪声近似高斯分布, 因此其滤波性能在混合高斯干扰下明显下降, RMSE 表现不稳定且易出现异常偏差。为保证实验结果的可比性, 本节的对比主要集中在对非高斯噪声具有较强鲁棒性的粒子滤波及其改进算法。

由图 20 和表 6 可知, 在混合高斯噪声下各个算法的位置和角度 RMSE 都有不同程度的增大, 但 IGWO-STCPF 的整体位置误差依旧最小 (1.523 4 m), X/Y 方向跟踪和姿态 RMSE 也优于 PF、PSO-PF 和 PSO-CPF, 这表明其在复杂噪声环境下具有更高的跟踪精度和鲁棒性。PSO-PF 与 PSO-CPF 对位置有一定优化, 但姿态误差高于 IGWO-STCPF; PF 性能最差, 易受噪声干扰。




图 17 不同测量噪声下的位置 RMSE

Fig. 17 Position RMSE with varying measurement noise

表 6 混合高斯噪声下各算法的位置和角度 RMSE

Table 6 Position and angle RMSE of different algorithms under mixed Gaussian noise

算法	位置误差/m	X 方向跟踪误差/m	Y 方向跟踪误差/m	Pitch 误差/rad	Yaw 误差/rad
PF	3.303 3	1.374 4	1.453 6	0.076 5	0.124 1
PSO-PF	2.394 1	1.050 5	1.151 4	0.095 7	0.101 7
PSO-CPF	2.462 7	1.051 8	1.149 6	0.100 8	0.102 9
IGWO-STCPF	1.523 4	0.923 0	0.962 9	0.061 5	0.096 7




图 19 混合高斯噪声下 AUV 跟踪曲线

Fig. 19 AUV tracking trajectory under mixed Gaussian noise

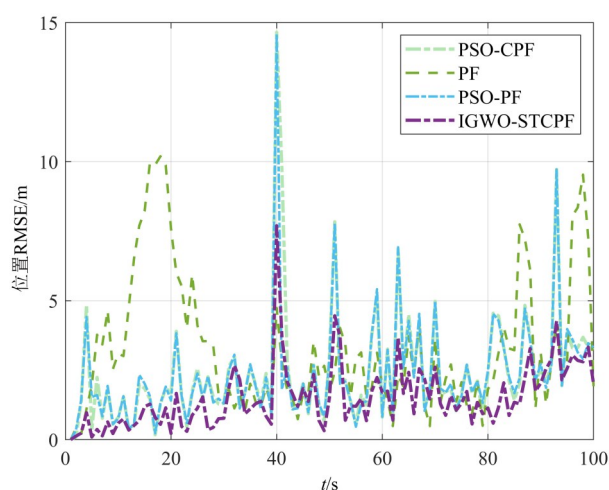


图 20 混合高斯噪声下 AUV 跟踪误差

Fig. 20 AUV position error under mixed Gaussian noise

4.3 真实数据集测试

选取公开发布的基于高精度传感器的水下航行器导航数据集进行实验验证。该数据集是在自然环境中收集的,涵盖了湖泊及近海等多种区域。由于这些数据是通过自主水下航行器的导航过程生成的,因此可以认为其导航数据符合 AUV 的运动学模型,所使用的 AUV 及其传感器等相关信息来自 Wang et al.(2023)。

试验选取的数据为前 1 000 个。所选用的数据集为 20220822_0_7,测试地点为渤海区域。为了统一单位,本文采用通用横轴墨卡托投影(UTM)将经纬度转换为米。

实验中,声呐与 AUV 的初始位置设定为 $(0, 0, -12.094 1)$ 。随机噪声为高斯分布,过程噪声 $Q = \text{diag}(1, 1, 1)$,测量噪声方差为 $R = 2 \times \text{eye}(1)$,

采样时间间隔为 $t = 1 \text{ s}$ 、时间步长 $T = 1 000$ 、粒子数为 $N = 100$ 、 $P_{0,0} = \text{diag}(0.1, 0.1, 0.1)$ 。

图 21 为各算法在真实海事数据集上的轨迹跟踪结果。结果表明,所有算法均能有效跟踪 AUV 的运动轨迹,验证了算法在实际应用场景中的可行性和鲁棒性。图 22 为各算法的位置估计误差。IGWO-STCPF 算法的平均 RMSE 为 1.285 3 m,优于其他算法。相比 STCKF 算法(3.680 0 m),位置估计精度提升 65.07%;相比传统 PF 算法(6.623 6 m),位置估计精度提升 80.59%;相比 PSO-CPF 算法(3.414 9 m),提升了 62.37%的定位精度。




图 21 数据集下 AUV 跟踪曲线

Fig. 21 AUV tracking curve in dataset

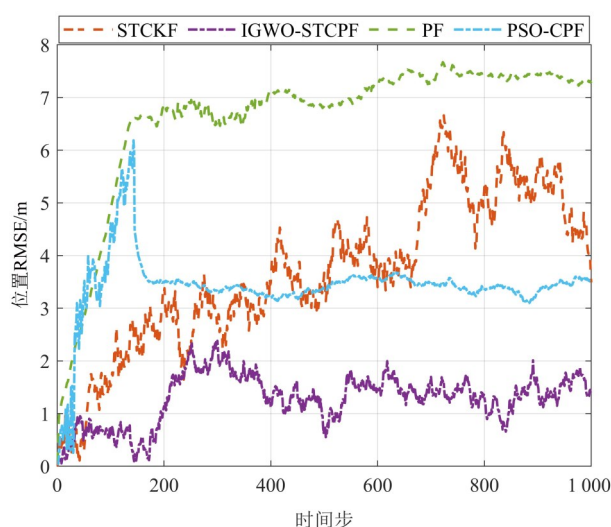


图 22 数据集下 AUV 位置误差曲线

Fig. 22 AUV position error curve under the dataset

特别值得注意的是,IGWO-STCPF 算法不仅实现了最小的估计误差,还表现出优异的稳定性,误差始终保持在 2 m 以内的较低水平。

5 结论

本文提出的IGWO-STCPF算法针对传统的粒子滤波做了两点改进。一是在重要性采样阶段中采用STCKF算法融合最新的观测值生成更精确的粒子,使其更接近真实后验概率密度,增强滤波精度和稳定性;二是利用IGWO算法代替粒子滤波的

重采样过程,通过改进非线性收敛因子和位置更新机制,加快粒子收敛过程,提高粒子的整体质量和目标跟踪的准确性。仿真结果表明,IGWO-STCPF在位置、角度估计上都优于STCKF和PF等扩展算法,尤其是在高噪声和粒子数较低的情况下仍然可以维持较好的跟踪精度。真实的浅海环境下的实验证明其具有良好的应用前景。

参考文献:

- 丁瑞成,周玉成,2022.引入莱维飞行与动态权重的改进灰狼算法[J].计算机工程与应用,58(23):74-82.
- 杜睿山,井远光,付晓飞,等,2025.采用动态种群策略的多目标粒子群优化算法[J].吉林大学学报(理学版),63(3):845-854.
- 申明亮,唐骏,黄豆豆,等,2024.改进布谷鸟算法优化粒子滤波的多目标跟踪方法[J].电子测量技术,47(3):84-90.
- 王力,贾欣雨,2023.基于PSO-PF-SVM的模拟电路故障诊断[J].江苏大学学报(自然科学版),44(2):221-228+234.
- 王宁,谷海涛,高浩,等,2024.深海AUV无动力垂直下潜运动特性研究[J].舰船科学技术,46(6):104-111.
- 王威,宫淑丽,李晓明,2024.基于IGWO-STCKF的目标跟踪算法[J/OL].北京航空航天大学学报,1-13.doi:10.13700/j.bh.1001-5965.2024.0623.
- 谢少彪,张宇,温凯瑞,等,2021.非合作目标强跟踪容积卡尔曼滤波运动状态估计[J].吉林大学学报(工学版),51(4):1482-1489.
- 曾润,田杰,江虹,等,2022.改进粒子滤波的无人机航迹预测方法[J].传感器与微系统,41(5):148-151.
- 朱凯鹏,王全政,杨文政,等,2025.基于改进粒子群优化算法的船舶避碰研究[J].传感器与微系统,44(4):40-43+47.
- 张文宇,高岳林,郭灿,2025.基于自适应混合粒子群算法的无人机三维路径规划[J/OL].西安理工大学学报,1-14.https://kns.cnki.net/kcms2/article/abstract?v=Ks9d5KSMf4X3INpb2giyOM3o0Y0tpJqFYriUqfuPVgoho9mbnPA-XTDSsxjPTXuHvhFPfbB4xq5XQp8BBU-3jG5ZeQiDvkzSW2mywpxg7JDpsWC9zGxRHGgmlW1lm6L158uXwNsOhrAg4-47k_pwFABVGqq8Qa6xAz2qvnVFexdjVXGUxZzw=&uniplatform=NZKPT&language=CHS.
- ARASARATNAM I, HAYKIN S, 2011. Cubature Kalman smoothers[J]. Automatica, 47(10):2245-2250.
- CHOPPALA P B, ADEOGUN R, 2025. Auxiliary particle filtering with multitudinous lookahead sampling for accurate target tracking [J]. IEEE Access, 13: 42874-42886.
- CHU S, QIAN H M, YAN S Y, et al, 2023. Adaptive robust maximum correntropy Cubature Kalman Filter for spacecraft attitude estimation[J]. Adv Space Res, 72(8): 3376-3385.
- DAI Q, XIAO G R, ZHOU G H, et al, 2024. A novel Gaussian sum quaternion constrained Cubature Kalman Filter algorithm for GNSS/SINS integrated attitude determination and positioning system [J]. Front Neurorobot, 18: 1374531.
- GE J Y, CHENG J H, QI B, 2024. A non-rigid terrain transformation particle filter suitable for terrain-aided navigation without sound velocity profile[J]. Ocean Eng, 294: 116858.
- PARK S, HWANG J P, KIM E, et al, 2009. A new evolutionary particle filter for the prevention of sample impoverishment [J]. IEEE Trans Evol Comput, 13(4): 801-809.
- PENG D, XIE K, LIU M S, 2024. Application of Gray Wolf Particle Filter algorithm based on golden section in wireless sensor network mobile target tracking [J]. Electronics, 13(13):2440.
- WANG C, CHENG C S, YANG D Y, et al, 2023. Underwater AUV navigation dataset in natural scenarios [J]. Electronics, 12(18):3788.
- YANG J Y, YAO Y T, YANG D H, 2023. Particle filter based on Harris hawks optimization algorithm for underwater visual tracking[J]. J Mar Sci Eng, 11(7):1456.
- YILMAZ M K, BAYRAM H, 2023. Particle filter-based aerial tracking for moving targets [J]. J Field Robot, 40(2):368-392.
- ZHANG A, BAO S D, GAO F, et al, 2019. A novel strong tracking cubature Kalman filter and its application in maneuvering target tracking [J]. Chin J Aeronaut, 32(11):2489-2502.
- ZHANG J Y, ZHANG T, LIU S D, 2023. An outlier-robust Rao-Blackwellized particle filter for underwater terrain-aided navigation[J]. Ocean Eng, 288:116006.
- ZHANG J, ZHANG T, LIU S D, et al, 2024. A robust particle filter for ambiguous updates of underwater terrain-aided navigation[J]. Mechatronics, 98:103133.

(责任编辑 王海蓉)