http://bhxb.buaa.edu.cn jbuaa@buaa.edu.cn
DOI: 10.13700/j.bh.1001-5965.2024.0623

基于 IGWO-STCKF 的目标跟踪算法

王威[1]，宫淑丽[1,*]，李晓明[2]

(1. 南京航空航天大学 民航学院，南京 210016；2. 航天时代飞鸿技术有限公司，北京 100094)

摘 要：针对容积卡尔曼滤波 (CKF) 算法滤波噪声先验确定且目标机动时跟踪精度下降2个问题，提出一种结合改进灰狼优化和强跟踪滤波的容积卡尔曼滤波 (IGWO-STCKF) 算法。分析了 CKF 计算流程；利用灰狼优化实现过程噪声协方差的自适应，针对灰狼优化 (GWO) 算法易得到局部最优及搜索慢的缺点，提出采用佳点集理论初始化种群，嵌入调节参数非线性调整策略，越界处理策略和动态权重调整策略形成改进的灰狼优化算法 (IGWO)；借鉴强跟踪滤波 (STF)，引入双渐消因子调整 CKF 算法量测更新时的协方差矩阵，实时调整滤波增益，最终形成 IGWO-STCKF 算法。将 IGWO-STCKF 和 IGWO-CKF、STCKF、IMM-CKF 和 CKF 算法运用到具有动态噪声的二维机动目标跟踪仿真实验中，对跟踪轨迹图、算法运行时间、位置和速度均方根误差曲线和累计均方根误差值进行分析。结果表明：IGWO-STCKF 算法跟踪精度和稳定性更优。

关 键 词：容积卡尔曼滤波；灰狼优化；强跟踪滤波；渐消因子；目标跟踪
中图分类号：V249.4
文献标志码：A **文章编号**：1001-5965(2026)11-4098-09

目标跟踪旨在利用计算机和相关导航设备结合算法实时预测与估计目标运动状态[1]。实际应用中，目标状态转移模型或量测方程多具有非线性特征，非线性滤波问题的难点在于估计状态的后验概率密度函数 (probability density function, PDF)[2]。常用的最优估计方法，如粒子滤波器 (particle filter, PF)，滤波精度好，但计算量大，实时性差[3]。高斯近似滤波法一般假设 PDF 为高斯分布，通过非线性函数近似或概率密度函数近似计算非线性函数的均值和方差[4]，目前已经发展出不敏卡尔曼滤波 (unscented Kalman filter, UKF)[5]、高斯-埃米特卡尔曼滤波 (Gauss-Hermite Kalman filter, GHKF)[6] 和容积卡尔曼滤波 (cubature Kalman filter, CKF)[7] 等算法。UKF 引入不敏变换 (unscented transform, UT)，利用$2n+1$个 (n为状态维数) 采样点计算状态向量概率分布，具有三阶精度，但对于高维系统滤波稳定性不佳[5]。GHKF 基于高斯-厄米特准则求解高斯积分，滤波精度高，但易发生维数灾难[6]。CKF 算法基于三阶球面-径向求积准则，较 UKF 滤波稳定性好，在目标跟踪中得到了广泛的应用。但在目标发生机动时，滤波精度和鲁棒性仍有待提升；此外，CKF 中滤波噪声一般根据前人经验或试错法设置为固定值，耗费实验精力且有悖于实际。针对上述两方面问题，目前的研究主要有：罗亚伦利用渐消因子增强 CKF 算法的鲁棒性并结合交互多模型实现对高超目标的跟踪[8]；Sahl 等利用 M 估计增强 CKF 算法的鲁棒性实现了在测量值缺失情况下的目标跟踪[9]；Lu 等利用最大相关熵准则处理在过程噪声或者量测噪声未知时 CKF 算法[10]；Li 等提出迭代正交单纯型容积卡尔曼滤波，依据球面单纯型径向容积准则和二阶高斯拉盖尔求积公式计算新的容积点并应用于目标跟踪，但计算过程繁琐[11]；杨

收稿日期：2024-08-27；**录用日期**：2024-10-18；**网络出版时间**：2024-11-06 14:00
网络出版地址：link.cnki.net/urlid/11.2625.V.20241106.1035.003
基金项目：国家自然科学基金 (U2033201)；南京航空航天大学研究生科研与实践创新项目 (xcxjh20230717)
* **通信作者**. E-mail：gong_shuli@nuaa.edu.cn

引用格式：王威，宫淑丽，李晓明. 基于 IGWO-STCKF 的目标跟踪算法 [J]. 北京航空航天大学学报，2026，52（11）：4098-4106.
Wang W，Gong S L，Li X M. Target tracking algorithm based on IGWO-STCKF[J]. Journal of Beijing University of Aeronautics and Astronautics，2026，52（11）：4098-4106（in Chinese）.

永建等基于最小化新息准则推导调整系数得到修正平方根容积卡尔曼滤波[12]; 杜坤引入非线性收敛因子改进灰狼算法, 实现滤波噪声的动态自适应调整[13]; 游航航等利用灰狼算法实时更新滤波参数[14]; 宋春宁等采用郊狼算法对状态误差协方差阵及滤波噪声进行寻优[15]。

本文分析了 CKF 的计算流程, 采用奇异值分解代替乔姆斯基分解以提高 CKF 数值迭代的稳定性; 利用灰狼优化 (grey wolf optimizer, GWO) 算法对 CKF 的过程噪声进行自适应调整, 同时为改善灰狼优化易陷入局部最优及收敛慢等缺点, 使用佳点集理论初始化灰狼保证种群分布的均匀性; 对越界的灰狼个体设计处理策略提高算法迭代时个体分布的多样性; 引入非线性收敛因子和动态权重调整策略改善算法收敛速度; 为提高 CKF 算法在目标机动时的鲁棒性, 在量测更新阶段的协方差矩阵计算中嵌入渐消因子; 最终形成改进灰狼优化的强跟踪容积卡尔曼滤波算法 (improved grey-wolf optimization algorithm-strong tracking CKF, IGWO-STCKF)。最后设计仿真实验, 将本文算法应用于二维机动目标跟踪以验证该算法的有效性。

1　容积卡尔曼滤波

对于具有加性噪声非线性离散时间跟踪系统, 状态空间方程表示为

$$\begin{cases} \boldsymbol{x}_k &= f(\boldsymbol{x}_{k-1})+\boldsymbol{w}_{k-1} \\ \boldsymbol{z}_k &= h(\boldsymbol{x}_k)+\boldsymbol{v}_k \end{cases} \tag{1}$$

式中: $\boldsymbol{x}_k$为k时刻状态向量; $\boldsymbol{z}_k$为k时刻量测向量; $\boldsymbol{w}_{k-1}$为方差为$\boldsymbol{Q}_{k-1}$的过程高斯白噪声; $\boldsymbol{v}_k$为方差为$\boldsymbol{R}_k$的测量高斯白噪声; $f(\cdot)$和$h(\cdot)$分别为状态转移函数和量测函数。

非线性滤波的核心任务是利用具有噪声的量测值得到系统状态的最小方差估计[16], 关键问题在于求解如下形式的积分:

$$I(f)=\int f(\boldsymbol{x})\exp(-\boldsymbol{x}^{\mathrm{T}}\boldsymbol{x})\mathrm{d}\boldsymbol{x} \tag{2}$$

CKF 的核心是利用三阶球面-相径容积准则选取容积点。具体分析如下:

令$\boldsymbol{x}=r\boldsymbol{y}$, $\boldsymbol{y}$为n维单位方向矢量, 式 (3) 在球面-径向坐标系中划分为n维球面积分$S(r)$和一维径向积分$R(r)$:

$$I(f)=\int_0^{\infty}\int_{U_n} f(r\boldsymbol{y})r^{n-1}\exp(-r^2)\mathrm{d}\sigma(\boldsymbol{y})\mathrm{d}r = \int_0^{\infty} r^{n-1}\exp(-r^2)\mathrm{d}r\int_{U_n} f(r\boldsymbol{y})\mathrm{d}\sigma(\boldsymbol{y}) \tag{3}$$

$$S(r)=\int_{U_n} f(r\boldsymbol{y})\mathrm{d}\sigma(\boldsymbol{y})\approx\sum_{i=1}^{N_y} w_{y,i}f(r\boldsymbol{y}_i) \tag{4}$$

$$R(r)=\int_0^{\infty} S(r)r^{n-1}\mathrm{e}^{-r^2}\mathrm{d}r\approx\sum_{j=1}^{N_r} w_{r,j}S(r_j) \tag{5}$$

式中: $U_n=\{\boldsymbol{y}\in R^n|\boldsymbol{y}^{\mathrm{T}}\boldsymbol{y}=1\}$, $\mathrm{d}\sigma(\boldsymbol{y})$表示球面$U_n$微元; 式 (4) 中球面积分权重$w_f(\boldsymbol{y})=1$, 径向积分权重$w_f(r)=r^{n-1}\mathrm{e}^{-r^2}$; $\boldsymbol{y}_i$和$w_{y,i}$为球面积分求积点及权重; r_j和$w_{r,j}$为径向积分求积点及权重。式 (4) 可表示为

$$I(f)\approx\sum_{i=1}^{N_y}\sum_{j=1}^{N_r} w_{y,i}w_{r,j}f(r_j\boldsymbol{y}_i) \tag{6}$$

将式 (7) 应用于高斯加权积分, 可得

$$\int g(x)N(x;0,I)\mathrm{d}x=\frac{1}{\sqrt{\pi^n}}\sum_{i=1}^{N_y}\sum_{j=1}^{N_r} w_{y,i}w_{r,j}g(\sqrt{2}r_j\boldsymbol{y}_i) \tag{7}$$

综上, 三阶球面-相径容积准则写为

$$I(g)=\int g(\boldsymbol{x})\exp(-\boldsymbol{x}^{\mathrm{T}}\boldsymbol{x})\mathrm{d}\boldsymbol{x}\approx \frac{\sqrt{\pi^n}}{2n}\sum_{i=1}^{2n} g\left(\sqrt{\frac{n}{2}}[\boldsymbol{B}]_i\right)=\sum_{i=1}^{2n}\theta_i g(\boldsymbol{\xi}_i) \tag{8}$$

式中: n为状态维数; $\boldsymbol{B}$ 为全 1 向量。

$$\begin{cases} \boldsymbol{\xi}_i=\sqrt{n}\left[\begin{pmatrix}1\\0\\\vdots\\0\end{pmatrix}\cdots\begin{pmatrix}0\\0\\\vdots\\1\end{pmatrix}\begin{pmatrix}-1\\0\\\vdots\\0\end{pmatrix}\cdots\begin{pmatrix}0\\0\\\vdots\\-1\end{pmatrix}\right] \\ \theta_i=\dfrac{1}{2n} \end{cases} \tag{9}$$

基于上述三阶球面-相径容积准则, $\boldsymbol{x}_k\sim N(\hat{\boldsymbol{x}}_k,\boldsymbol{P}_k)$的 CKF 计算流程如图 1 所示。

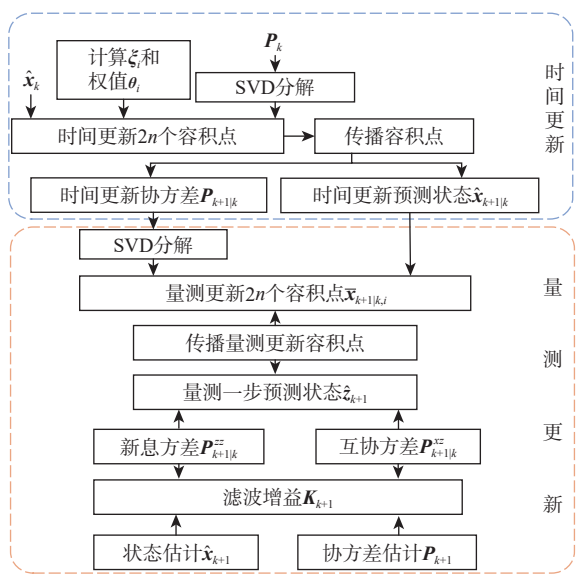

图 1　CKF 计算流程

Fig. 1　CKF algorithm flow

1) 滤波初始化

初始时刻的状态向量$\hat{\boldsymbol{x}}_0$和误差协方差$\boldsymbol{P}_0$为

$$\begin{cases}\hat{\boldsymbol{x}}_0 = E(\boldsymbol{x}_0)\\ \boldsymbol{P}_0 = E\left[(\boldsymbol{x}_0-\hat{\boldsymbol{x}}_0)(\boldsymbol{x}_0-\hat{\boldsymbol{x}}_0)^{\mathrm{T}}\right]\end{cases} \tag{10}$$

2）时间更新

① 计算容积点。用奇异值分解 (singular value decomposition, SVD) 代替 Chol 分解[17]，提高滤波的稳定性和鲁棒性。

$$\boldsymbol{P}_{k|k} = \boldsymbol{U}_k\boldsymbol{S}_k\boldsymbol{V}_k^{\mathrm{T}} \tag{11}$$

式中：$\boldsymbol{U}_k$和$\boldsymbol{V}_k^{\mathrm{T}}$为奇异值分解的正交矩阵；$\boldsymbol{S}_k$为奇异值分解的对角矩阵。

$$\boldsymbol{x}_{k,i} = \hat{\boldsymbol{x}}_k + \boldsymbol{U}_k\sqrt{\boldsymbol{S}_k}\boldsymbol{\xi}_i \tag{12}$$

②传播容积点：

$$\boldsymbol{x}_{k+1|k,i} = f(\boldsymbol{x}_{k,i}) \tag{13}$$

③计算状态一步预测值$\hat{\boldsymbol{x}}_{k+1|k}$：

$$\hat{\boldsymbol{x}}_{k+1|k} = \sum_{i=1}^{2n}\theta_i\boldsymbol{x}_{k+1|k,i} \tag{14}$$

$$\boldsymbol{P}_{k+1|k} = \sum_{i=1}^{2n}\theta_i(\boldsymbol{x}_{k+1|k,i}-\hat{\boldsymbol{x}}_{k+1|k})(\boldsymbol{x}_{k+1|k,i}-\hat{\boldsymbol{x}}_{k+1|k})^{\mathrm{T}} + \boldsymbol{Q}_k \tag{15}$$

式中：$\boldsymbol{Q}_k$为过程噪声协方差矩阵。

3）量测更新

①计算容积点：

$$\begin{cases}\boldsymbol{P}_{k+1|k} = \boldsymbol{U}_{k+1|k}\boldsymbol{S}_{k+1|k}\boldsymbol{V}_{k+1|k}^{\mathrm{T}}\\ \bar{\boldsymbol{x}}_{k+1|k,i} = \hat{\boldsymbol{x}}_{k+1|k} + \boldsymbol{U}_{k+1|k}\sqrt{\boldsymbol{S}_{k+1|k}}\boldsymbol{\xi}_i\end{cases} \tag{16}$$

②容积点传播：

$$\boldsymbol{z}_{k+1,i} = h(\bar{\boldsymbol{x}}_{k+1|k,i}) \tag{17}$$

③量测一步预测：

$$\hat{\boldsymbol{z}}_{k+1} = \sum_{i=1}^{2n}\theta_i\boldsymbol{z}_{k+1,i} \tag{18}$$

④计算误差协方差$\boldsymbol{P}_{k+1|k}^{zz}$和互协方差$\boldsymbol{P}_{k+1|k}^{xz}$：

$$\boldsymbol{P}_{k+1|k}^{zz} = \sum_{i=1}^{2n}\theta_i(\boldsymbol{z}_{k+1,i}-\hat{\boldsymbol{z}}_{k+1})(\boldsymbol{z}_{k+1,i}-\hat{\boldsymbol{z}}_{k+1})^{\mathrm{T}} + \boldsymbol{R}_{k+1} \tag{19}$$

$$\boldsymbol{P}_{k+1|k}^{xz} = \sum_{i=1}^{2n}\theta_i(\bar{\boldsymbol{x}}_{k+1|k,i}-\hat{\boldsymbol{x}}_{k+1|k})(\boldsymbol{z}_{k+1,i}-\hat{\boldsymbol{z}}_{k+1})^{\mathrm{T}} \tag{20}$$

⑤计算增益矩阵$\boldsymbol{K}_{k+1}$：

$$\boldsymbol{K}_{k+1} = \boldsymbol{P}_{k+1|k}^{xz}\left(\boldsymbol{P}_{k+1|k}^{zz}\right)^{-1} \tag{21}$$

⑥计算$k+1$时刻的状态估计：

$$\begin{cases}\hat{\boldsymbol{x}}_{k+1} = \hat{\boldsymbol{x}}_{k+1|k} + \boldsymbol{K}_{k+1}(\boldsymbol{z}_{k+1}-\hat{\boldsymbol{z}}_{k+1})\\ \boldsymbol{P}_{k+1} = \boldsymbol{P}_{k+1|k} - \boldsymbol{K}_{k+1}\boldsymbol{P}_{k+1}^{zz}\boldsymbol{K}_{k+1}^{\mathrm{T}}\end{cases} \tag{22}$$

2 IGWO-CKF 算法

过程噪声和量测噪声作为 CKF 算法的滤波输入参数，是影响目标跟踪精度的重要因素之一。量测噪声源于量测设备，其值可依据量测设备参数确定；过程噪声则会在目标运动过程动态变化。为提高 CKF 算法的滤波精度，可以利用灰狼优化对过程噪声协方差进行动态调整。

2.1 灰狼优化算法

GWO 算法通过模拟灰狼群社会等级制度和狩猎行为完成对最优解的搜索[18]，算法中每个灰狼的位置对应一个可行解，依靠灰狼的适应度值完成种群的金字塔式社会分级如图 2 所示。α、β和δ对应适应度值前三的灰狼个体，负责追踪猎物和引导狼群，其他设置为ε狼，负责围捕猎物。

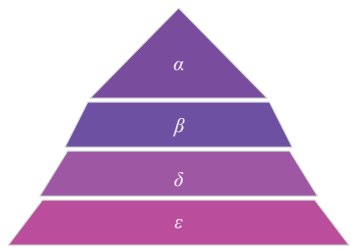

图 2 灰狼社会等级制度

Fig. 2 Social hierarchy of grey wolves

灰狼的搜索行为描述为

$$\begin{cases}\boldsymbol{X}(t+1) = \boldsymbol{X}_{\mathrm{p}}(t) - \boldsymbol{A}\boldsymbol{D}\\ \boldsymbol{D} = \left|\boldsymbol{C}\boldsymbol{X}_{\mathrm{p}} - \boldsymbol{X}(t)\right|\end{cases} \tag{23}$$

式中：t为当前迭代的次数；$\boldsymbol{X}_p(t)$为当前猎物的位置，即当前最优灰狼位置；$\boldsymbol{X}(t)$为当前灰狼位置；扰动因子$\boldsymbol{A}$和$\boldsymbol{C}$的计算式如下：

$$\boldsymbol{A} = 2\boldsymbol{a}\boldsymbol{r}_1 - \boldsymbol{a} \tag{24}$$

$$\boldsymbol{C} = 2\boldsymbol{r}_2 \tag{25}$$

$$\boldsymbol{a} = 2(1-t/t_{\max}) \tag{26}$$

式中：$\boldsymbol{r}_1$和$\boldsymbol{r}_2$为[0,1]中的随机向量；$t_{\max}$为最大迭代次数。

在寻找最佳解决方案 (猎物的位置) 过程中，α狼带领β狼和δ狼逐渐逼近猎物，对于ε狼而言，越靠近 3 头精英狼，离猎物的位置就越近，采用式 (27) 计算灰狼个体最终移动的方向和距离。灰狼的位置更新机制如图 3 所示。

$$\begin{cases}\boldsymbol{D}_\alpha = |\boldsymbol{C}_1\boldsymbol{X}_\alpha(t) - \boldsymbol{X}(t)|\\ \boldsymbol{D}_\beta = \left|\boldsymbol{C}_2\boldsymbol{X}_\beta(t) - \boldsymbol{X}(t)\right|\\ \boldsymbol{D}_\delta = |\boldsymbol{C}_3\boldsymbol{X}_\delta(t) - \boldsymbol{X}(t)|\\ \boldsymbol{X}_1 = \boldsymbol{X}_\alpha - \boldsymbol{A}_1\boldsymbol{D}_\alpha\\ \boldsymbol{X}_2 = \boldsymbol{X}_\beta - \boldsymbol{A}_2\boldsymbol{D}_\beta\\ \boldsymbol{X}_3 = \boldsymbol{X}_\delta - \boldsymbol{A}_3\boldsymbol{D}_\delta\\ \boldsymbol{X}(t+1) = (\boldsymbol{X}_1+\boldsymbol{X}_2+\boldsymbol{X}_3)/3\end{cases} \tag{27}$$

式中：$\boldsymbol{X}_\alpha$、$\boldsymbol{X}_\beta$和$\boldsymbol{X}_\delta$表示当前α、β和δ狼的位置；$\boldsymbol{D}_\alpha$、$\boldsymbol{D}_\beta$和$\boldsymbol{D}_\delta$表示α、β和δ狼与狼之间的距离ε。

每次更新后，再次计算各灰狼适应度值并筛选

新的 3 头精英狼进行下一次迭代。迭代结束后, 最终α狼的位置就是问题的最优解。

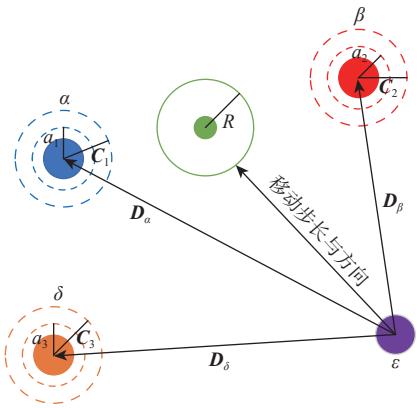

图 3　GWO 位置更新机制

Fig. 3　Positions updating of grey in GWO

2.2　多策略改进灰狼优化算法

GWO 算法因为结构简单, 输入参数少、易实现等优点, 广泛应用于路径规划、经济调度和最优控制等领域。许多学者也对 GWO 算法做出改进, 综合来看: 目前对于灰狼优化的改进主要集中在初始种群生成、搜索机制及算法参数的改进 3 个部分[18]。本文基于前人的研究, 以提高搜索速度和得到全局最优为目标, 对这 3 个部分均提出了相应的改进方法。

2.2.1　佳点集初始化策略

GWO 算法中, 初始灰狼种群个体位置表示为

$$\boldsymbol{X}_i=\boldsymbol{G}_{\rm lb}+{\rm rand}(\boldsymbol{G}_{\rm ub}-\boldsymbol{G}_{\rm lb}) \tag{28}$$

式中: $\boldsymbol{G}_{\rm ub}$、$\boldsymbol{G}_{\rm lb}$为灰狼的上下限。

以二维灰狼种群为例, 在 [0,10] 内生成 300 个灰狼个体。图 4(a) 为采用式 (28) 进行初始化的灰狼群, 此时种群在整个解空间分布不均匀, 多样性欠佳, GWO 算法对整个搜索空间的利用率不高且易陷入局部最优。对此, 引入佳点集理论初始化灰狼种群[19]。新的初始化策略为

$$\boldsymbol{X}_i=\boldsymbol{G}_{\rm lb}+\{\boldsymbol{P}_n(k)\}(\boldsymbol{G}_{\rm ub}-\boldsymbol{G}_{\rm lb}) \tag{29}$$

式中: $\boldsymbol{P}_n(k)$为佳点集。

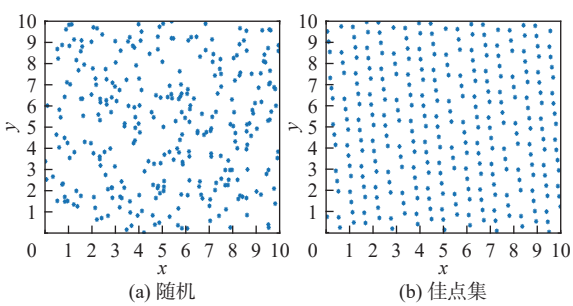

图 4　初始化灰狼种群

Fig. 4　Initialization of grey wolves population

图 4(b) 为运用佳点集理论生成的初始化灰狼种群, 此时灰狼个体均匀分布在整个搜索空间, 初始种群质量和稳定性提高, 有利于算法摆脱局部最优, 获得全局最优解。

2.2.2　越界处理策略

GWO 算法在迭代计算过程中一般令越界个体与限值相等, 若越界个体较多, 则灰狼位置趋同, 破坏了种群多样性, 搜索易陷入局部最优[20]。为维持种群个体多样性, 对越界灰狼的位置二次更新表达式如下:

$$\boldsymbol{X}_{i,\rm new}=\begin{cases}\boldsymbol{G}_{\rm lb} & \mu>1-\sigma,\quad \boldsymbol{X}<\boldsymbol{G}_{\rm lb}\\ \boldsymbol{G}_{\rm lb}+\mu(\boldsymbol{G}_{\rm ub}-\boldsymbol{G}_{\rm lb}) & \mu<\sigma,\quad \boldsymbol{X}<\boldsymbol{G}_{\rm lb}\\ \boldsymbol{G}_{\rm lb}+\mu(\boldsymbol{G}_{\rm ub}-\boldsymbol{G}_{\rm lb}) & \mu<\sigma,\quad \boldsymbol{X}>\boldsymbol{G}_{\rm ub}\\ \boldsymbol{G}_{\rm ub} & \mu>1-\sigma,\quad \boldsymbol{X}>\boldsymbol{G}_{\rm ub}\end{cases} \tag{30}$$

式中: μ为 [0,1] 之间均匀分布随机数; σ为越界处理参数, 本文取 0.5。

2.2.3　非线性收敛因子策略

为平衡算法前期探索和后期开采的能力, GWO 算法中收敛因子a在 [0,2] 之间线性递减, 此时算法易陷入局部最优。综合现有针对收敛因子的改进策略可以看出: 在迭代开始阶段, a应缓慢减小以提高算法的勘探性, 在迭代后期, a的减小速度应减缓以提高算法的开采性[21]。因此, 利用指数函数来衰减:

$$a=a_{\min}-(a_{\max}-a_{\min}){\rm e}^{-\left(\frac{2t}{t_{\max}}\right)^4} \tag{31}$$

2.2.4　动态权重调整策略

GWO 算法中灰狼位置更新采用灰狼朝向 3 头精英狼前进步长的算术平均值, 未体现 3 头精英狼在位置变更和引导过程的优先等级, 与灰狼进行等级划分策略不一致, 且收敛速度有待提高。为此, 以各精英狼的适应度值作为分配权重的判断依据, 利用加权平均值作为灰狼的位置更新[22]。改进后灰狼的位置更新计算为

$$\begin{cases}\boldsymbol{X}(t+1)=\dfrac{1}{3}\displaystyle\sum_{i=1,2,3}\theta_i\boldsymbol{X}_i(t+1)\\ \theta_i=\dfrac{f(\boldsymbol{X}_i(t+1))}{\displaystyle\sum_{i=1,2,3}f(\boldsymbol{X}_i(t+1))}\end{cases} \tag{32}$$

式中: $f(\boldsymbol{X}_i)(i=1,2,3)$表示$\alpha$、$\beta$和$\delta$狼的适应度值; θ_i表示各精英狼在位置更新中的权重。

2.3　基于改进灰狼优化的滤波噪声自适应

运用 IGWO 算法对 CKF 算法中的过程噪声协方差矩阵$\boldsymbol{Q}$进行优化, 实现算法的自适应调参。$\boldsymbol{Q}$为对角矩阵, 将 IGWO 算法中的灰狼位置设置为$\boldsymbol{Q}$的对角元素, 进行迭代计算, 具体过程如下:

步骤 1　初始化种群规模N, 最大迭代次数$t_{\max}$, 收敛因子a, $\boldsymbol{A}$, $\boldsymbol{C}$。

步骤 2　采用佳点集理论初始化种群位置, 使灰狼个体均匀分布在搜索空间, 灰狼种群位置记为

$\{\boldsymbol{X}_1,\boldsymbol{X}_2,\cdots,\boldsymbol{X}_N\}$。

步骤 3 选取滤波新息的实际方差为适应度函数，如式 (33) 所示，并计算各灰狼适应度值，筛选出 3 头精英狼，对应位置为$\boldsymbol{X}_\alpha$、$\boldsymbol{X}_\beta$和$\boldsymbol{X}_\delta$。

步骤 4 依据式 (31) 更新非线性收敛因子并计算干扰因子$\boldsymbol{A}$和$\boldsymbol{C}$。

步骤 5 依据式 (27) 和式 (32) 更新灰狼个体位置$\boldsymbol{X}_k$，并处理越界个体，重新计算各灰狼的适应度值$f(\boldsymbol{X}_k)$。

步骤 6 更新α、β和δ的位置和适应度。

步骤 7 判断迭代是否达到要求，未达到则返回步骤 4；达到则返回最优解$\boldsymbol{X}_\alpha(t)=[q_1,q_2,q_3,q_4,q_5]$，这 5 个元素作为优化后的$\boldsymbol{Q}$的对角元素，优化后的$\boldsymbol{Q}$作为下一时刻的输入。

利用 IGWO 算法对滤波噪声寻优的过程中，设计恰当的适应度函数可以指导灰狼种群的总体移动方向，同时也可作为迭代终止的有效条件。滤波新息作为量测实际值与预测值的差，其方差与$\boldsymbol{Q}$关系密切，所以将适应度函数设置为新息的实际方差，函数值越小，目标跟踪精度越高[23]：

$$l=\min((\boldsymbol{z}_{k+1}-\hat{\boldsymbol{z}}_{k+1})(\boldsymbol{z}_{k+1}-\hat{\boldsymbol{z}}_{k+1})') \tag{33}$$

式中：l为新息的实际方差；$\boldsymbol{z}_{k+1}$和$\hat{\boldsymbol{z}}_{k+1}$为对应时刻的量测值和量测预测值。

3 IGWO-STCKF 算法

当系统模型不准确或目标机动时，CKF 的目标跟踪精度会迅速下降。为提高 CKF 的鲁棒性，将强跟踪滤波 (strong tracking filter, STF) 中的渐消因子引入量测更新的协方差中，设计强跟踪容积卡尔曼滤波 (strong tracking CKF, STCKF) 算法。

3.1 强跟踪滤波

STF 基于衰减记忆滤波，利用渐消因子调整$\boldsymbol{P}_{k+1|k}$，迫使残差序列正交，以期全部提取残差序列的信息，保证滤波在模型不准确或状态发生突变时的鲁棒性[24]。

标准 STF 以扩展卡尔曼滤波为基础，对系统函数和量测函数具有连续可微的要求且计算涉及雅可比矩阵，计算繁琐。为在 CKF 中嵌入渐消因子，需要建立非线性系统下的 STF 算法[25]。算法核心仍是计算残差：

$$\begin{cases}\hat{\boldsymbol{x}}_{k+1}=\hat{\boldsymbol{x}}_{k+1|k}+\boldsymbol{K}_{k+1}\boldsymbol{e}_{k+1}\\ \boldsymbol{e}_{k+1}=\boldsymbol{z}_{k+1}-\boldsymbol{h}(\hat{\boldsymbol{x}}_{k+1|k})\end{cases} \tag{34}$$

式中：$\hat{\boldsymbol{x}}_{k+1}$为$k+1$时刻的状态估计值；$\boldsymbol{e}_{k+1}$表示滤波残差；$\boldsymbol{K}_{k+1}$为$k+1$时刻的滤波增益。渐消因子$\lambda_{k+1}$计算如下：

$$\begin{cases}\lambda_{k+1}=\max\left(1,\dfrac{\mathrm{tr}(\boldsymbol{N}_{k+1})}{\mathrm{tr}(\boldsymbol{M}_{k+1})}\right)\\ \boldsymbol{N}_{k+1}=\boldsymbol{V}_{0,k+1}-\boldsymbol{H}_{k+1}\boldsymbol{Q}_k\boldsymbol{H}_{k+1}^{\mathrm{T}}-\kappa\boldsymbol{R}_{k+1}\\ \boldsymbol{M}_{k+1}=\boldsymbol{H}_{k+1}\boldsymbol{P}_{k+1|k}^{x}\boldsymbol{H}_{k+1}^{\mathrm{T}}\\ \boldsymbol{H}_{k+1}=\boldsymbol{P}_{k+1|k}^{xz,l}(\boldsymbol{P}_{k+1|k}^{l})^{-1}\\ \boldsymbol{P}_{k+1|k}^{xz,l}=\sum_{i=1}^{2n}\theta_i(\boldsymbol{\chi}_{k+1|k,i}^{l}-\hat{\boldsymbol{x}}_{k+1|k})(\boldsymbol{h}(\boldsymbol{\chi}_{k+1|k,i}^{l})-\hat{\boldsymbol{z}}_{k+1}^{l})\end{cases} \tag{35}$$

式中：$\boldsymbol{P}_{k+1|k}^{x}$为未考虑渐消因子及过程噪声协方差的状态预测误差协方差阵；$\boldsymbol{P}_{k+1|k}^{l}$为含有$\boldsymbol{Q}_k$的状态预测误差方差阵，即$\boldsymbol{P}_{k+1|k}^{l}=\boldsymbol{P}_{k+1|k}^{x}+\boldsymbol{Q}_k$；$\kappa\geqslant 1$为弱化因子，本文取 4；$\boldsymbol{P}_{k+1|k}^{xz,l}$为未引入渐消因子的互相关协方差阵；$\boldsymbol{\chi}_{k+1|k,i}^{l}$为在未引入强跟踪滤波时对于状态向量的预测值；$k+1$时刻实际残差协方差阵$\boldsymbol{V}_{k+1}$的估算公式为

$$\boldsymbol{V}_{0,k+1}=\begin{cases}\boldsymbol{e}_1\boldsymbol{e}_1^{\mathrm{T}} & k=0\\ \dfrac{\rho\boldsymbol{V}_{0,k}+\boldsymbol{e}_{k+1}\boldsymbol{e}_{k+1}^{\mathrm{T}}}{1+\rho} & k>0\end{cases} \tag{36}$$

式中：$\rho\in[0.95,0.995]$表示遗忘因子，一般取$\rho=0.95$。

3.2 强跟踪容积卡尔曼滤波

基于 CKF 的计算框架，在量测更新中量测误差协方差阵和互协方差阵中分别嵌入渐消因子，形成 STCKF，即在式 (22) 和式 (23) 的基础上得到：

$$\begin{cases}\boldsymbol{P}_{k+1|k}^{zz,\lambda}=\lambda_{k+1}\left(\sum_{i=1}^{2n}\theta_i(\boldsymbol{z}_{k+1,i}-\hat{\boldsymbol{z}}_{k+1})(\boldsymbol{z}_{k+1,i}-\hat{\boldsymbol{z}}_{k+1})^{\mathrm{T}}\right)+\boldsymbol{R}_{k+1}\\ \boldsymbol{P}_{k+1|k}^{xz,\lambda}=\lambda_{k+1}\left(\sum_{i=1}^{2n}\theta_i(\bar{\boldsymbol{x}}_{k+1|k,i}-\hat{\boldsymbol{x}}_{k+1|k})(\boldsymbol{z}_{k+1,i}-\hat{\boldsymbol{z}}_{k+1})^{\mathrm{T}}\right)\end{cases} \tag{37}$$

式中：$\boldsymbol{P}_{k+1|k}^{zz,\lambda}$和$\boldsymbol{P}_{k+1|k}^{xz,\lambda}$分别为引入渐消因子后的新息协方差和互协方差。

利用$\boldsymbol{P}_{k+1|k}^{zz,\lambda}$和$\boldsymbol{P}_{k+1|k}^{xz,\lambda}$重新计算得到滤波增益$\boldsymbol{K}_{k+1}$和最终的状态估计$\hat{\boldsymbol{x}}_{k+1}$和误差协方差$\boldsymbol{P}_{k+1}$。

结合 2.3 节所述 IGWO-CKF 和 STCKF 算法形成 IGWO-STCKF 算法，IGWO-STCKT 算法流程如图 5 所示。

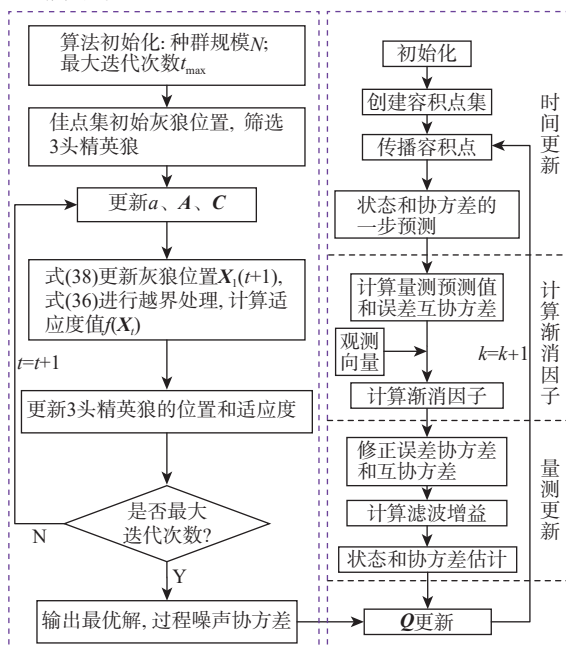

图 5 IGWO-STCKF 算法流程

Fig. 5 Flowchart of IGWO-STCKF algorithm

4 仿真验证

为检验 IGWO-STCKF 的有效性，以二维机动目

标为例, 蒙特卡罗仿真实验 100 次, 并选取 IGWO-STCKF、IGWO-CKF、STCKF、IMM-CKF 和 CKF 算法对仿真结果进行对比分析。利用仿真结果包括跟踪轨迹图、位置及速度均方根误差 (root mean square error, RMSE) 曲线、累计均方根误差 (accumulated root mean square error, ARMSE)、算法的平均运行时间及渐消因子的响应曲线:

$$\begin{cases} R_{\mathrm{RMSEpos}} = \sqrt{\dfrac{1}{N}\displaystyle\sum_{i=1}^{N}\left[(x_k^i-\hat{x}_k^i)^2+(y_k^i-\hat{y}_k^i)^2\right]} \\ A_{\mathrm{RMSEpos}} = \sqrt{\dfrac{1}{N}\displaystyle\sum_{n=1}^{N}\dfrac{1}{K}\sum_{k=1}^{K}[(x_k^i-\hat{x}_k^i)^2+(y_k^i-\hat{y}_k^i)^2]} \end{cases} \tag{38}$$

式中: (x_k^i, y_k^i)和$(\hat{x}_k^i, \hat{y}_k^i)$分别为第$i$次仿真实验中$k$时刻目标真实位置和估计位置, 同理可得速度的均方根误差和累计均方根误差。

目标状态向量 $\boldsymbol{X}_k=[x,\dot{x},y,\dot{y},\omega]^{\mathrm{T}}$, x,y表示位置, $\dot{x},\dot{y}$表示对应方向速度, ω表示角速度。$\boldsymbol{X}_0=[1\,000\ \mathrm{m}, 200\ \mathrm{m/s}, 1\,000\ \mathrm{m}, 0\ \mathrm{m/s}, 2(°)/\mathrm{s}]$, 仿真时长 100 s, 采样周期 $T=1$ s。交互式多模型 (interacting multiple model, IMM) 中的子模型包括匀速运动模型和协调转弯运动模型, 模型初始化概率$\boldsymbol{\mu}_0=[0.1,0.9]^{\mathrm{T}}$, 模型自转移概率为 0.9, 互转移概率设置为 0.1。目标运动状态转移模型为

$$\begin{aligned} \boldsymbol{X}_k &= f(\boldsymbol{X}_{k-1})+\boldsymbol{w}_{k-1}+\boldsymbol{u}_{k-1} = \\ &\begin{bmatrix} 1 & \dfrac{\sin(\omega T)}{\omega} & 0 & \dfrac{\cos(\omega T)-1}{\omega} & 0 \\ 0 & \cos(\omega T) & 0 & -\sin(\omega T) & 0 \\ 0 & \dfrac{1-\cos(\omega T)}{\omega} & 1 & \dfrac{\sin(\omega T)}{\omega} & 0 \\ 0 & \sin(\omega T) & 0 & \cos(\omega T) & 0 \\ 0 & 0 & 0 & 0 & 1 \end{bmatrix}\cdot \\ &\boldsymbol{X}_{k-1}+\boldsymbol{w}_{k-1}+\boldsymbol{u}_{k-1} \end{aligned} \tag{39}$$

式中: $\boldsymbol{u}_{k-1}$表示系统机动输入, 设定目标在$t=40$ s和$t=60$ s发生机动, 持续时间为 5 s, 机动输入为

$$\begin{cases} \boldsymbol{u}_{t=40\,\mathrm{s}} = \begin{bmatrix} 0\ \mathrm{m} & -20\ \mathrm{m/s} & 0\ \mathrm{m} & 20\ \mathrm{m/s} & 1(°)/\mathrm{s} \end{bmatrix}^{\mathrm{T}} \\ \boldsymbol{u}_{t=60\,\mathrm{s}} = \begin{bmatrix} 0\ \mathrm{m} & 20\ \mathrm{m/s} & 0\ \mathrm{m} & -20\ \mathrm{m/s} & -1(°)/\mathrm{s} \end{bmatrix}^{\mathrm{T}} \end{cases} \tag{40}$$

其中: $\boldsymbol{w}_{k-1}$表示协方差为$\boldsymbol{Q}_{k-1}$的过程噪声。$\boldsymbol{Q}_0=\mathrm{diag}(1\ 1\ 1\ 1\ 1)$, 10～20 s 时, $\boldsymbol{Q}_t=2\boldsymbol{Q}_0$; 50～60 s 时, $\boldsymbol{Q}_t=3\boldsymbol{Q}_0$; 80～90 s 时, $\boldsymbol{Q}_t=4\boldsymbol{Q}_0$。量测噪声协方差为 $\boldsymbol{R}=\mathrm{diag}(100,100)$。仿真在 Intel(R)i9-14900K、64 位 Windows10 环境中 MATLAB R2021b 中进行。

图 6 为某次仿真实验中本文算法的跟踪轨迹、量测值及目标的真实运动轨迹; 图 7 为 IGWO-STCKF 与 STCKG、IGWO-CKF 和 CKF 算法在x和y方向的位置和速度 RMSE 曲线; 图 8 为渐消因子λ的响应曲线。

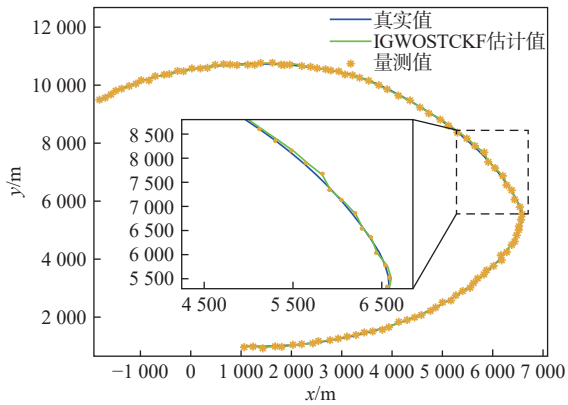

图 6　目标运动轨迹

Fig. 6　Target moving trajectory

仿真结果表明: 5 种算法均未出现滤波发散, 目标跟踪效果较好。由位置和速度均方根误差曲线可以看出, 在目标未机动且过程噪声发生变化时, IGWO-STCKF 和 IGWO-CKF 算法通过对过程噪声协方差的实时调整, 得到了比 STCKF 和 CKF 算法更高的跟踪精度; 目标机动时, STCKF 和 IGWO-STCKF 算法对目标位置和速度的跟踪误差相比于 CKF 和 IGWO-CKF 算法明显下降; IMM-CKF 算法使用 2 个子模型描述目标的运动状态以期贴近目标的真实运动情况, 目标非机动时不可避免地会引入不匹配模型状态估计带来的误差且认为过程噪声固定, 所以 IGWO-STCKF 算法较 IMM-CKF 算法滤波精度更高; 在出现未知状态的突变时, 模型的切换具有滞后性且模型集覆盖不完备导致 IMM-CKF 算法的误差仍然较 IGWO-STCKF 算法更大。从自适应渐消因子响应曲线分析: 目标机动时, 自适应渐消因子迅速增大, 随后又减小至 1, 保证 STCKF 和 IGWO-STCKF 算法对目标状态的强跟踪能力, 也可避免滤波增益过调节。在整个仿真周期中, IGWO-STCKF 算法均能保持较优的跟踪精度。

表 1 对比了 5 种滤波方法对目标位置和速度的累计均方根误差值和算法的平均运行时间, 由表可知: IGWO-CKF 算法的估计精度优于 CKF 算法, 表明 IGWO 算法在过程噪声变化的环境中, 实现了对过程噪声协方差的自适应调整; 相比于 IGWO-CKF 和 STCKF 算法, IGWO-STCKF 算法的滤波精度更优, 表明对存在状态突变的机动目标跟踪时, 引入渐消因子可以提高算法的鲁棒性, 保证较好的跟踪效果; IMM-CKF 算法设置过程噪声固定且无法准确识别未知机动, 因而速度和位置均方根误差仅较 CKF 算法略优; IGWO-STCKF 相比于 CKF 算法, 其位置和速度累计均方根误差分别减小了 71.5% 和 17.7%。从算法平均运行时间分析, IGWO-STCKF

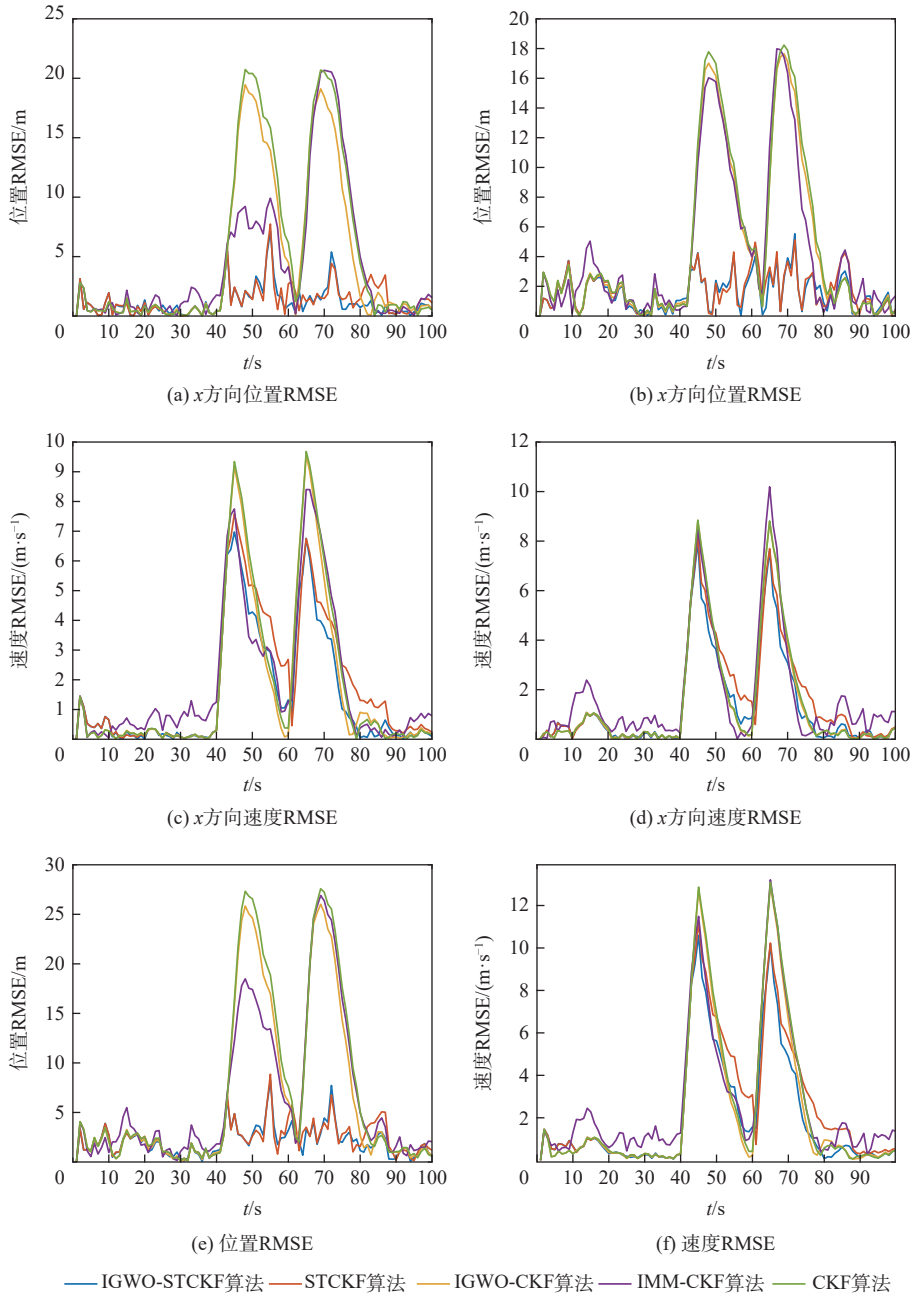

图 7 目标跟踪均方根误差曲线

Fig. 7 RMSE curve of target tracking

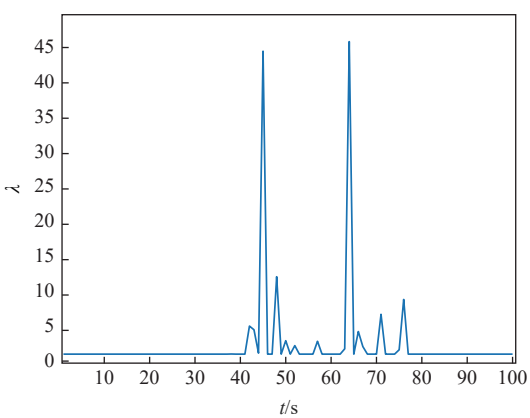

图 8 渐消因子响应曲线

Fig. 8 Response curve of fading factors

表 1 5 种算法 ARMSE 对比

Table 1 Comparison of ARMSE the ARMSE for five algorithm

算法	位置ARMSE/m	速度ARMSE/(m·s^{-1})	运行时间/s
IGWO-STCKF	2.116 7	2.061 9	0.656 9
STCKF	2.332 1	2.524 5	0.565 6
IGWO-CKF	6.764 7	2.394 2	0.620 8
IMM-CKF	6.631 0	2.575 2	0.553 2
CKF	7.428 9	2.605 5	0.522 9

和 IGWO-CKF 算法在每次滤波估计时，都需要利用 IGWO 算法进行多次迭代计算，对过程噪声进行实时调整，算法的计算量和复杂度均增加，实时性

较 STCKF 和 CKF 算法下降; 此外, 与 IGWO-CKF 算法相比, IGWO-STCKF 算法设计渐消因子的计算, 所以实时性较差。但总的看来, 4 种算法的运行时间相差不大, 后续研究将在本文基础上针对降低 IGWO-STCKF 算法的计算量, 提高算法实时性进行研究。

5　结　论

1) 本文利用 IGWO 算法实现 CKF 中的过程噪声协方差的自适应调整; 嵌入自适应渐消因子保证算法的强跟踪能力, 提升了 CKF 的滤波精度和鲁棒性。

2) 通过仿真实验证明本文 IGWO-STCKF 算法相比于 CKF 算法, 位置 ARMSE 减小 71.5%, 速度 ARMSE 减小 17.7%, 表明本文算法具有更好的跟踪精度和稳定性, 在目标跟踪领域具有一定的应用价值。

参考文献（References）

[1] 张文杰, 王世元, 冯亚丽, 等. 基于 Huber 的高阶容积卡尔曼跟踪算法[J]. 物理学报, 2016, 65(8): 088401.
Zhang W J, Wang S Y, Feng Y L, et al. Huber-based high-degree cubature Kalman tracking algorithm[J]. Acta Physica Sinica, 2016, 65(8): 088401(in Chinese).

[2] Ito K, Xiong K. Gaussian filters for nonlinear filtering problems[J]. IEEE Transactions on Automatic Control, 2000, 45(5): 910-927.

[3] 韩博, 徐红丽, 邱少雄, 等. 基于边界约束粒子滤波的多 UUV 纯方位协同目标跟踪[J]. 水下无人系统学报, 2024, 32(2): 250-259.
Han B, Xu H L, Qiu Shaoxiong, et al. Multi-UUV collaborative bearing-only target tracking based on boundary constrained particle filter[J]. Journal of Unmanned Undersea Systems, 2024, 32(2): 250-259(in Chinese).

[4] 崔乃刚, 张龙, 王小刚, 等. 自适应高阶容积卡尔曼滤波在目标跟踪中的应用[J]. 航空学报, 2015, 36(12): 3885-3895.
Cui N G, Zhang L, Wang X G, et al. Application of adaptive high-degree cubature Kalman filter in target tracking[J]. Acta Aeronautica et Astronautica Sinica, 2015, 36(12): 3885-3895(in Chinese).

[5] Julier S, Uhlmann J, Durrant-whyte H F. A new method for the nonlinear transformation of means and covariances in filters and estimators[J]. IEEE Transactions on Automatic Control, 2000, 45(3): 477-482.

[6] Arasaratnam I, Haykin S, Elliott R J. Discrete-time nonlinear filtering algorithms using Gauss-Hermite quadrature[J]. Proceedings of the IEEE, 2007, 95(5): 953-977.

[7] Arasaratnam I, Haykin S. Cubature Kalman filters[J]. IEEE Transactions on Automatic Control, 2009, 54(6): 1254-1269.

[8] 罗亚伦, 廖育荣, 李兆铭, 等. 高超目标强跟踪 CKF 自适应交互多模型跟踪算法[J/OL]. 北京航空航天大学学报. (2022-09-28)[2024-06-03]. https://doi.org/10.13700/j.bh.1001-5965.2022.0587.
Luo Y L, Liao Y R, Li Z M, et al. Strong tracking CKF adaptive interacting multiple-model algorithm based on maneuvering hypersonic-target tracking[J/OL]. Journal of Beijing University of Aeronautics and Astronautics. (2022-09-28)[2024-06-03]. https://doi.org/10.13700/j.bh.1001-5965.2022.0587(in Chinese).

[9] Sahl S, Song E B, Niu D B. Robust cubature Kalman filter for moving-target tracking with missing measurements[J]. Sensors, 2024, 24(2): 392.

[10] Lu T, Zhou W D, Tong S. Improved maximum correntropy cubature Kalman and information filters with application to target tracking under non-Gaussian noise[J]. International Journal of Adaptive Control and Signal Processing, 2024, 38(4): 1199-1221.

[11] Li Z M, Yang X Y, Li L, et al. Iterated orthogonal simplex cubature Kalman filter and its applications in target tracking[J]. Applied Sciences, 2024, 14(1): 392.

[12] 杨永建, 甘轶, 李春辉, 等. 基于最小化新息协方差的修正 SRCKF 算法[J]. 北京航空航天大学学报, 2023, 49(1): 138-144.
Yang Y J, Gan Y, Li C H, et al. Amended SRCKF algorithm based on minimum variance of innovation[J]. Journal of Beijing University of Aeronautics and Astronautics, 2023, 49(1): 138-144(in Chinese).

[13] 杜坤. 变电站在线监测系统设计及关键技术研究[D]. 杭州: 杭州电子科技大学, 2021: 29-43.
Du K. Design of substation online monitoring system and research on key technologies[D]. Hangzhou: Hangzhou Dianzi University, 2021: 29-43(in Chinese).

[14] 游航航, 余敏建, 吕艳, 等. 基于改进灰狼算法优化的 UKF 在空战轨迹预测中的应用[J]. 战术导弹技术, 2020(1): 91-98.
You H H, Yu M J, Lyu Y, et al. Application of UKF optimized by improved gray wolf algorithm in air combat trajectory prediction[J]. Tactical Missile Technology, 2020(1): 91-98(in Chinese).

[15] 宋春宁, 苏有平, 莫伟县, 等. 基于 COA-ASRCKF 的单液流锌镍电池 SOC 估计[J]. 电池, 2021, 51(4): 351-355.
Song C N, Su Y P, Mo W X, et al. SOC estimation of single-flow zinc-nickel battery based on COA-ASRCKF[J]. Battery Bimonthly, 2021, 51(4): 351-355(in Chinese).

[16] 秦康, 董新民, 陈勇. 基于 Huber 的鲁棒高阶容积卡尔曼滤波算法[J]. 计算机工程与应用, 2017, 53(7): 21-29.
Qin K, Dong X M, Chen Y. Huber-based robust high-degree cubature Kalman filter algrithm[J]. Computer Engineering and Applications, 2017, 53(7): 21-29(in Chinese).

[17] 成怡, 刘铭阳, 徐国伟. 高机动目标的改进强跟踪 CKF 自适应 IMM 算法[J]. 中国惯性技术学报, 2024, 32(7): 715-723.
Cheng Y, Liu M Y, Xu G W. Improved strong tracking CKF adaptive IMM algorithm for high maneuvering targets[J]. Journal of Chinese Inertial Technology, 2024, 32(7): 715-723(in Chinese).

[18] 张晓凤, 王秀英. 灰狼优化算法研究综述[J]. 计算机科学, 2019, 46(3): 30-38.
Zhang X F, Wang X Y. Comprehensive review of grey wolf optimization algorithm[J]. Computer Science, 2019, 46(3): 30-38(in Chinese).

[19] 闫少强, 杨萍, 朱东林, 等. 基于佳点集的改进麻雀搜索算法[J]. 北京航空航天大学学报, 2023, 49(10): 2790-2798.
Yan S Q, Yang P, Zhu D L, et al. Improved sparrow search algorithm based on good point set[J]. Journal of Beijing University of Aeronautics and Astronautics, 2023, 49(10): 2790-2798(in Chinese).

[20] 王振东, 汪嘉宝, 李大海. 一种增强型麻雀搜索算法的无线传感器网络覆盖优化研究[J]. 传感技术学报, 2021, 34(6): 818-828.
Wang Z D, Wang J B, Li D H. Study on WSN optimization coverage of an enhanced sparrow search algorithm[J]. Chinese Journal of Sensors and Actuators, 2021, 34(6): 818-828(in Chinese).

[21] 丁瑞成, 周玉成. 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, 2022, 58(23): 74-82.
Ding R C, Zhou Y C. Improved grey wolf optimization algorithm based on levy flight and dynamic weight strategy[J]. Computer Engineering and Applications, 2022, 58(23): 74-82(in Chinese).

[22] 游航航, 韩其松, 余敏建, 等. 基于 AIGWO-IMMUKF 的目标跟踪算法[J]. 北京航空航天大学学报, 2020, 46(10): 1826-1833.
You H H, Han Q S, Yu M J, et al. Target tracking algorithm based on AIGWO-IMMUKF[J]. Journal of Beijing University of Aeronautics and Astronautics, 2020, 46(10): 1826-1833(in Chinese).

[23] 齐美彬, 伍坤江, 赵谦, 等. SRCKF-GM-PHD 多目标跟踪算法的优化[J]. 现代雷达, 2023, 45(4): 31-39.
Qi M B, Wu K J, Zhao Q, et al. Optimization of SRCKF-GM-PHD multi-target tracking algorithm[J]. Modern Radar, 2023, 45(4): 31-39(in Chinese).

[24] Zhang H W, Xie J W, Ge J A, et al. Strong tracking SCKF based on adaptive CS model for manoeuvring aircraft tracking[J]. IET Radar, Sonar & Navigation, 2018, 12(7): 742-749.

[25] Zhang A, Bao S D, Gao F, et al. A novel strong tracking cubature Kalman filter and its application in maneuvering target tracking[J]. Chinese Journal of Aeronautics, 2019, 32(11): 2489-2502.

Target tracking algorithm based on IGWO-STCKF

WANG Wei[1], GONG Shuli[1,*], LI Xiaoming[2]

(1. College of Civil Aviation, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China;
2. Aerospace Times FeiHong Technology Company Limited, Beijing 100094, China)

Abstract: Aiming at the problems the cubature Kalman filter(CKF) algorithm needs to predetermine the filtering noise and that the tracking accuracy decreases when the target is maneuvering, a strong tracking cubature Kalman filter algorithm based on improved grey wolf optimization (IGWO-STCKF) is proposed. Firstly, the process of CKF is introduced. Secondly, the grey wolf optimization is used to achieve the adaptability of the process noise covariance. The good point set theory is used to obtain the initial population, embedding the nonlinear adjustment strategy of control parameters, the out-of-bounds processing strategy, and the dynamic weight adjustment strategy, in order to address the shortcomings of the grey wolf optimization (GWO) algorithm, which include its slow search speed and ease of achieving a local optimum. Meanwhile, the fading factor, which takes reference from a strong tracking filter (STF), is used to adjust the covariance matrix during the measurement update period and adjust the filtering gain in real time. Finally, IGWO-STCKF algorithm is formed. IGWO-STCKF, IGWO-CKF, STCKF, IMM-CKF and CKF algorithms are applied to a two-dimensional maneuvering target tracking simulation experiment with dynamic noise, and the tracking trajectory diagram, algorithm execution time, the root mean square error curves of position and velocity, and cumulative root mean square error are analyzed. The results show that IGWO-STCKF algorithm has high filtering accuracy, strong robustness, and better tracking effect.

Keywords: cubature Kalman filter; grey wolf optimizer; strong tracking filter; fading factor; maneuvering target tracking

Received: 2024-08-27; **Accepted**: 2024-10-18; **Published Online**: 2024-11-06 14:00
URL: link.cnki.net/urlid/11.2625.V.20241106.1035.003
Foundation items: National Natural Science Foundation of China (U2033201); Postgraduate Research and Practical Innovation Projects of Nanjing University of Aeronautics and Astronautics (xcxjh20230717)

* **Corresponding author**. E-mail: gong_shuli@nuaa.edu.cn