

基于交叉熵-遗传算法的武器目标分配问题研究

马金慧, 杨 玉, 李存华, 戴红伟

(江苏海洋大学计算机工程学院, 江苏 连云港 222005)

[摘要] 武器目标分配问题是军事领域中重要的研究课题,其主要任务是在一定的条件下将武器与来袭目标合理分配,以达到最大的作战收益.提出了一种将遗传算法融入交叉熵算法的混合算法.首先,通过交叉熵算法将原本的武器目标分配优化问题与估计问题联系起来,构建满足武器目标分配方案解的离散概率分布矩阵,进而根据矩阵生成代表解的多个样本.然后,利用遗传算法中的选择、交叉、变异操作增加样本的多样性.最后,利用推导出最优解的迭代公式来更新矩阵,当满足迭代终止条件时输出的矩阵即为最优解.分别针对二维单目标函数优化问题和武器目标分配问题进行计算对比,计算结果验证了交叉熵-遗传算法的有效性.

[关键词] 交叉熵,交叉熵-遗传算法,武器目标分配,最优化问题

[中图分类号] TP391 **[文献标志码]** A **[文章编号]** 1672-1292(2022)01-0068-07

Research on Weapon Target Assignment Problem Based on Cross Entropy-Genetic Algorithm

Ma Jinhui, Yang Yu, Li Cunhua, Dai Hongwei

(School of Computer Engineering, Jiangsu Ocean University, Lianyungang 222005, China)

Abstract: The issue of weapon target assignment (WTA) is an important research topic in the military field. The main task of WTA is to reasonably allocate weapons and incoming targets under certain conditions to achieve the greatest combat gains. This paper proposes a hybrid algorithm that integrates genetic algorithm into cross-entropy algorithm. Firstly, the original WTA optimization problem is connected with the estimation problem through the cross-entropy algorithm. Secondly, the discrete probability distribution matrix that satisfies the solution of the weapon target allocation scheme is constructed. Thirdly, some samples are generated according to the matrix, and then the selection, crossover, and mutation operators of genetic algorithm are used to increase the diversity of the samples. Then, the iterative formula are used to update the matrix. Finally, the matrix is a optimal output when the iteration termination condition is met. In the experimental part, simulation comparisons are carried out for the two-dimensional single-object function optimization problem and WTA problem, experimental results demonstrate the effectiveness of the cross-entropy-genetic algorithm proposed in this paper.

Key words: cross-entropy, cross-entropy genetic algorithm, weapon target allocation, optimization algorithm problem

武器目标分配(weapon target assignment, WTA)问题^[1]是作战指挥辅助决策研究的重要问题,是一种 N-P 完全问题. WTA 问题的关键就在于如何将不同损伤能力的武器分配到具有不同攻击态势威胁的来袭目标,以达到来袭目标损伤效果最大的结果.

WTA 问题作为非线性整数优化问题中的一种,一直备受各国学者的关注.虽然不同学者提出了不同求解 WTA 问题的算法,但在算法的有效性、稳定性方面还有提高的空间,因此研究 WTA 问题具有重要的理论与实际意义.

一般来说, WTA 问题可分为静态武器目标分配(static weapon target assignment, SWTA)问题^[2-4]和动态武器目标分配(dynamic weapon target assignment, DWTA)问题^[5-7].在 SWTA 中,所有武器同时分配给目标,所有信息都是已知的.然而在 DWTA 中,应该考虑许多动态变化,例如,时间窗和武器消耗.在这种情况下,

收稿日期:2021-08-31.

基金项目:国家自然科学基金项目(61873105).

通讯作者:戴红伟,博士,教授,研究方向:智能计算与最优化问题. E-mail: hwdai@jou.edu.cn

DWTA 问题的求解算法必须具有良好的实时性. 对 WTA 问题的求解,传统的数值优化算法,如分支定界法、枚举法、梯度下降法等,往往不适合求解较为复杂的 WTA 问题. 目前主要采用智能优化算法进行求解. 文献[8]提出一种基于遗传算法的一类武器目标分配方法研究,设计的编码方式将有约束的优化问题转化为无约束的优化问题. 文献[9]针对武器目标分配问题设计了一种改进的混合粒子群优化算法,增强了算法前阶段的全局寻优能力和后阶段的收敛能力,使得算法性能有明显改善. 文献[10]提出一种改进遗传算法的求解方法,对遗传操作过程进行改进并融入模拟退火机制,以增强算法对模型的寻优能力. 文献[11]将改进差分进化算法应用在解决武器目标分配问题,增强了算法的全局搜索能力与求解精度. 文献[12]提出统一效率矩阵,创建可适用于所有类型目标分配问题的可适应匈牙利算法来求解 WTA 问题,验证了其正确性与可行性. 尽管目前对 WTA 问题求解的算法很多,在寻优精度方面也有了一定的改进,但算法在收敛速度、易陷入局部最优解等方面还不尽如人意,尤其是面对大规模复杂问题,仍有进一步改进的空间.

本文提出了一种交叉熵-遗传算法来求解武器目标分配问题. 首先,对本文解决的武器目标分配问题进行了详细的介绍. 其次,介绍交叉熵算法、遗传算法的相关概念及其流程. 然后,分别针对二维的单目标函数优化问题和 WTA 问题进行计算对比,计算结果验证了交叉熵-遗传算法的有效性与鲁棒性. 最后,总结了本文的研究成果,并对后续的研究工作进行了展望.

1 WTA 问题描述和数学模型

1.1 WTA 问题描述

本文以水面舰艇编队联合防空作战为背景,在每座舰艇具备的武器数量有限的情况下,将舰艇防空武器合理与来袭目标进行关联,以实现空中目标进行拦截并实现毁伤效果最大化. 具体描述如下:假设水面舰艇编队有 m 座防空装置,每座防空装置分别有 μ_i 个($i=1,2,\dots,m$)火力通道,空中来袭的目标数量为 n ,每个目标的威胁系数为 ω_j ($j=1,2,\dots,n$),其含义是第 j 个来袭目标对舰艇的威胁值. 武器 i 对目标 j 的毁伤概率为 p_{ij} ($i=1,2,\dots,m,j=1,2,\dots,n$),不同的武器对同一个目标的毁伤效果不同,同一个武器对不同的目标毁伤效果也是不同的. x_{ij} ($i=1,2,\dots,m,j=1,2,\dots,n$)表示第 i 个防空装置是否拦截目标 j . 若拦截, $x_{ij}=1$,否则 $x_{ij}=0$.

1.2 数学模型

以作战武器对拦截目标毁伤最大化为目标,建立的武器目标分配模型为^[13]

$$\max F(x) = \sum_{i=1}^m \sum_{j=1}^n w_j p_{ij} x_{ij}, \quad (1)$$

$$\text{s.t. } \sum_{j=1}^n x_{ij} \leq \mu_i, \quad x_{ij} \in \{0,1\}. \quad (2)$$

式中, $i=1,2,\dots,m,j=1,2,\dots,n$. 目标函数(1)即为本文的适应度函数,约束条件 $x_{ij} \in \{0,1\}$ 表示每座防空装置 i 对目标 j 进行拦截时,防空装置的火力通道数不能超过 μ_i 个,约束条件 $x_{ij} \in \{0,1\}$ 表示决策变量 x_{ij} 的约束条件.

2 交叉熵-遗传算法

2.1 交叉熵算法^[14]

交叉熵算法(cross entropy algorithm,CEA)是1997年由Rubinstein等提出的一种针对小概率事件估计的重要度采样方法,该算法充分运用重要度采样技术,通过Kullback-Leibler(K-L)距离来对两个概率分布的差异进行度量并让其最小化.

考虑一般最大化问题,假设 X 是一个有限状态集合, S 为 X 上的实值性能函数,优化目标是找到在有限状态集 X 上函数 S 的最大值以及最大值所对应的状态,因此

$$S(X^*) = \gamma^* = \max_{X \in X} S(X). \quad (3)$$

式中, γ^* 为函数 S 的最大值, X^* 是 γ^* 对应的状态, X 是统计样本. 将式(3)中的优化问题与式(4)对应的估计问题关联起来:

$$l(\gamma) = P_\beta(S(X) \geq \gamma) = E_\beta I_{\{S(X) \geq \gamma\}}. \quad (4)$$

式中, γ 为接近 γ^* 的值, P_β 是条件 $\{S(X) \geq \gamma\}$ 的概率度量, E_β 是对应的期望, $I_{\{S(X) \geq \gamma\}}$ 为指标函数, 当满足条件 $\{S(X) \geq \gamma\}$ 时, 其值为 1, 否则为 0.

对概率 $l(\gamma)$ 最直接的估计方法是: 生成 N 个随机样本 X_1, X_2, \dots, X_N , 然而当概率 $l(\gamma)$ 很小时, 则需要很多的样本才能达到对罕见事件概率 $l(\gamma)$ 估计的精度, 因此采用重要度采样技术来对 $l(\gamma)$ 进行估计, 即根据一个重要度采样密度函数 $g(X)$ 来随机产生样本, 对 $l(\gamma)$ 的无偏估计量为:

$$\hat{l}(\gamma) = \frac{1}{N} \sum_{i=1}^N I_{\{S(X) \geq \gamma\}} \frac{f(X_i, \beta)}{g(X_i)}. \quad (5)$$

在式(5)中, X_i 是由 $g(X)$ 生成的样本, 对 $\hat{l}(\gamma)$ 的估计取决于 $g(X)$, 而其最优的函数 $g^*(X)$ 为:

$$g^*(X) = \frac{I_{\{S(X) \geq \gamma\}} f(X, \beta)}{l}. \quad (6)$$

$g^*(X)$ 和未知的 $l(\gamma)$ 有关, 考虑寻找一个参数 β , 使得 $g^*(X)$ 与 $f(\cdot, \beta)$ 之间的 K-L 距离最小, 即:

$$\min_{\beta} D(g^*(X), f(X, \beta)) = \min_{\beta} \int g^*(X) \ln \frac{g^*(X)}{f(X, \beta)} dX = \min_{\beta} \left(\int g^*(X) \ln g^*(X) dX - \int g^*(X) \ln f(X, \beta) dX \right). \quad (7)$$

将式(6)代入式(7), 最终可得到如下最大化问题:

$$\max_{\beta} E_{\beta} I_{\{S(X) \geq \gamma\}} \ln f(X, \beta) = \max_{\beta} \frac{1}{N} \sum_{i=1}^N I_{\{S(X) \geq \gamma\}} \ln f(X_i, \beta). \quad (8)$$

CE 算法同时构造阈值序列 $\{\gamma_k, k \geq 0\}$ 和参数序列 $\{\beta_k, k \geq 0\}$ 两个序列, 在经过 T 次迭代求解之后所求得的 γ_T 接近 γ^* , β_T 对应 $g^*(X)$ 中的参数, 在初始化 γ_0 与 β_0 后, 传统 CEA 的迭代求解的过程步骤如下^[15]:

步骤 1 设在第 $k(k > 0)$ 次迭代中, 参数 β 取值为 β_{k-1} , 从概率密度函数 $f(X, \beta_{k-1})$ 中随机生成 N 个样本 X_1, X_2, \dots, X_N , 分别计算 N 个样本的目标函数值 $S(X)$, 并将其降序排序 $S(X_1) \geq S(X_2) \geq \dots \geq S(X_N)$.

步骤 2 更新参数 γ_k . 根据公式 $\gamma_k = S(X_{\theta N})$ 来更新 γ_k , 其中 θ 为提前设定的稀薄参数, 通常取值在 0.01~0.1 之间.

步骤 3 更新第 $k+1$ 次迭代过程的参数 β_k .

传统 CEA 的优点是能够有效地处理大部分的简单优化问题, 且收敛速度较快, 其不足之处是当待优化的目标函数较为复杂或者约束函数数目较多时, 传统的 CEA 很可能会出现计算精度不足或陷入局部最优的情况. 因此, 本文提出采用混合交叉熵-遗传算法来提高 CEA 求解武器目标分配问题的性能.

2.2 遗传算法

遗传算法(genetic algorithm, GA)^[16]是由美国的 Holland 教授于 1975 年提出的一类随机化搜索方法, 是通过借鉴生物界的进化规律演化而来的. 它首先确定实际问题的编码方案, 随机产生一个初始种群, 然后模拟繁殖机制生成新的种群, 再通过预先设定的适应度评价函数评价新种群个体的优劣, 依据适者生存, 优胜劣汰遗传机制以决定个体是否遗传到下一代, 引导进化过程向着最优逼近. 该算法具有内在的隐并行性和较好的全局快速寻优能力, 在诸多领域得到应用, 但也存在着收敛速度慢的缺陷^[17].

2.3 交叉熵-遗传算法

本文提出的交叉熵-遗传算法(cross entropy and genetic algorithm, CEGA), 将 GA 融入 CEA 寻求精英样本的过程中, CEGA 整体流程图如图 1 所示.

为了解决本文构建的 WTA 模型, 构建一个离散概率分布矩阵 M ,

$$M = \begin{pmatrix} p(1,1) & p(1,2) & \cdots & p(1,n) \\ p(2,1) & p(2,2) & \cdots & p(2,n) \\ \vdots & \vdots & & \vdots \\ p(m,1) & p(m,2) & \cdots & p(m,n) \end{pmatrix}_{m \times n}. \quad (9)$$

式中, $p(i, j)$, $i=1, 2, \dots, m, j=1, 2, \dots, n$, 表示作战单元 i

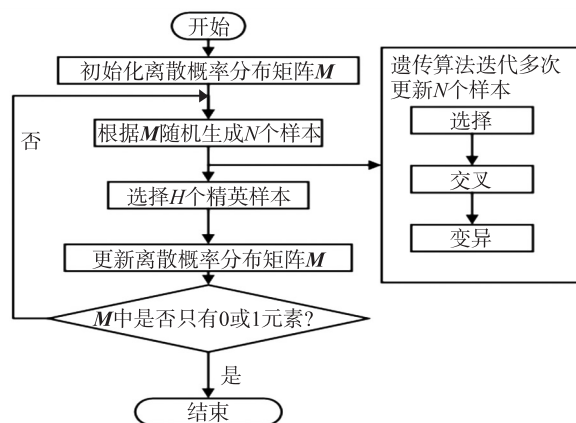


图 1 CEGA 整体流程图

Fig. 1 The overall flow chart of CEGA

分配武器给目标 j 的概率,当矩阵 \mathbf{M} 中所有元素的取值都为 0 或 1 时,则式(9)中的矩阵 \mathbf{M} 即为最终的分配方案解。

离散概率分布矩阵 \mathbf{M} 的初始化,

$$p(i, j) = \frac{1}{n}, \forall i \in (1, 2, \dots, m), j = 1, 2, \dots, n. \quad (10)$$

根据矩阵 \mathbf{M} ,可以得到概率分布函数 $f(X; \mathbf{M})$,

$$f(X; \mathbf{M}) = \prod_i \prod_j p(i, j)^{g(i, j)}, \quad (11)$$

$$g(i, j) = \begin{cases} 1, & X(j) = i, \\ 0, & \text{else.} \end{cases} \quad (12)$$

式中, $i = 1, 2, \dots, m, j = 1, 2, \dots, n$.

根据离散概率分布矩阵 \mathbf{M} 随机生成 N 个样本,分别记为 X_1, X_2, \dots, X_N ,其中样本表示为 $X_k = (x_1, x_2, \dots, x_n)$. x_j 表示拦截第 j 个目标的防空装置号. 在生成 N 个样本之后,利用 GA 中的选择、交叉、变异操作,对 N 个样本进行多次迭代更新,寻找更多优秀的样本,具体过程为:

(1) 选择:将 N 个样本按照适应度值大小降序排序,从中选择适应度值较高的 15% 的样本复制 2 份,中间的 70% 复制 1 份,剩下的样本直接淘汰。

(2) 交叉:采用单点随机定位的交叉运算,根据交叉概率确定 N 个样本中进行交叉运算的样本个数,从中随机选择两个样本,在样本中随机选择一个交叉点,从交叉点到样本的最后一位编码之间进行交叉运算。

(3) 变异:采用单点随机定位的变异运算,根据变异概率确定 N 个样本中进行变异运算的样本个数,从每个参与变异运算的样本中随机选择一个变异位进行变异运算。

GA 迭代之后,得到更新寻优后的 N 个样本,分别计算这 N 个样本的适应度值 $F(X)$,并将这 N 个样本根据样本的适应度值降序排序 $F(X_1) \geq F(X_2) \geq \dots \geq F(X_N)$,令 $H = \theta N$,从 N 个样本中选择前 H 个目标函数值较大的初始样本 X_1, X_2, \dots, X_H ,确定为最终的 H 个精英样本,根据 H 个精英样本更新离散概率分布矩阵 \mathbf{M} ,根据式(8)可得到优化问题(13):

$$\begin{cases} \max_M \sum_{s=1}^H \ln(f(X_s; \mathbf{M})), \\ \text{s.t.} \sum_{j=1}^n p(i, j) = 1, \quad p(i, j) \geq 0. \end{cases} \quad (13)$$

式中, $i = 1, 2, \dots, m, j = 1, 2, \dots, n$.

将式(11)代入式(13)得如下优化问题(14),

$$\begin{cases} \max_M \sum_{s=1}^H \sum_{i=1}^m \sum_{j=1}^n g_s(i, j) \ln(p(i, j)), \\ \text{s.t.} \sum_{j=1}^n p(i, j) = 1, \quad p(i, j) \geq 0. \end{cases} \quad (14)$$

式中, $i = 1, 2, \dots, m, j = 1, 2, \dots, n$. 问题(14)属于凸优化问题,因此可构造拉格朗日函数,

$$L(p(i, j), \lambda_i, a_{ij}) = - \sum_{s=1}^H \sum_{i=1}^m \sum_{j=1}^n g_s(i, j) \ln(p(i, j)) + \sum_{i=1}^m \lambda_i \left(\sum_{j=1}^n p(i, j) - 1 \right) + \sum_{i=1}^m \sum_{j=1}^n a_{ij} p(i, j). \quad (15)$$

根据 Karush-Kuhn-Tucker (KKT) 条件,可推导出

$$\begin{cases} p(i, j) = \left(\sum_{s=1}^H g_s(i, j) \right) / H, \\ a_{ij} = 0, \\ \lambda_i = H. \end{cases} \quad (16)$$

因此,可得到离散概率分布矩阵 \mathbf{M} 的迭代更新公式

$$p(i, j) = \left(\sum_{s=1}^H g_s(i, j) \right) / H. \quad (17)$$

3 实验与分析

为了验证 CEGA 算法的有效性和鲁棒性,分别针对带约束的二维的单目标 Benchmark 问题和 WTA 问题,采用不同的对比算法进行验证. 本实验的软件环境为 MATLAB R2020b, 硬件环境为 Intel (R) Core (TM) i5-9500 CPU@3.00GHz,8GB 内存.

3.1 单目标函数优化问题

针对二维的单目标函数优化问题,本文选取 5 种不同的带约束的二维单目标优化测试函数^[18] (5 种测试函数均为求最小值且最小值都为 0),对比 CEGA、CEA、GA 与禁忌搜索算法(SA)、粒子群算法(PSO)、差分进化算法(DEA)这 6 种算法,比较计算 30 次所求函数最小值均值和标准差这两个指标上的性能,实验结果如表 1 所示. CEGA 与 CE 算法设置相同的均值与方差,样本数为 100, $\theta=0.1$,另 4 种算法的种群规模皆为 100, 6 种算法的收敛条件均为迭代次数达到 100. 其中 SA、PSO、DEA 的实验结果来自 PlatEMO3.0^[19] 平台.

由表 1 可知,在收敛条件相同时,在 5 种测试函数上,本文提出的 CEGA 所求的最小值均值和标准差都更优于另 5 种算法,因此具有更优的寻优精度和更好的鲁棒性.

表 1 单目标优化函数实验结果
Table 1 Experimental results of single objective optimization function

测试函数	CEGA		CEA		GA	
	均值	标准差	均值	标准差	均值	标准差
f_1	$1.800\ 0\times10^{-199}$	0	$1.021\ 1\times10^{-97}$	$4.477\ 9\times10^{-97}$	$7.232\ 5\times10^{-4}$	$3.961\ 4\times10^{-3}$
f_2	$1.260\ 7\times10^{-200}$	0	$1.184\ 2\times10^{-49}$	$2.636\ 9\times10^{-49}$	$1.250\ 6\times10^{-4}$	$6.849\ 6\times10^{-4}$
f_3	0	0	$4.207\ 8\times10^{-19}$	$2.304\ 7\times10^{-18}$	$2.056\ 9\times10^{-3}$	$1.542\ 9\times10^{-2}$
f_4	$4.754\ 0\times10^{-193}$	0	$8.210\ 2\times10^{-49}$	$1.407\ 3\times10^{-48}$	$2.313\ 9\times10^{-3}$	$1.505\ 6\times10^{-2}$
f_5	0	0	$3.919\ 4\times10^{-2}$	$1.201\ 5\times10^{-1}$	$7.256\ 8\times10^{-3}$	$6.466\ 1\times10^{-2}$

测试函数	SA		PSO		DEA	
	均值	标准差	均值	标准差	均值	标准差
f_1	$6.592\ 0\times10^{-20}$	$6.660\ 0\times10^{-20}$	$7.617\ 9\times10^{-37}$	$1.010\ 0\times10^{-36}$	$2.730\ 6\times10^{-7}$	$3.350\ 0\times10^{-7}$
f_2	$1.053\ 1\times10^{-44}$	$6.440\ 0\times10^{-45}$	$1.228\ 6\times10^{-19}$	$1.060\ 0\times10^{-19}$	$9.627\ 4\times10^{-5}$	$6.160\ 0\times10^{-5}$
f_3	$1.873\ 5\times10^{-19}$	$2.180\ 0\times10^{-19}$	$1.434\ 8\times10^{-36}$	$1.910\ 0\times10^{-36}$	$5.277\ 3\times10^{-7}$	$5.000\ 0\times10^{-7}$
f_4	$8.041\ 5\times10^{-44}$	$5.270\ 0\times10^{-44}$	$6.924\ 5\times10^{-19}$	$5.270\ 0\times10^{-19}$	$4.857\ 0\times10^{-4}$	$2.840\ 0\times10^{-4}$
f_5	$2.087\ 6\times10^{-2}$	$1.880\ 0\times10^{-2}$	$7.823\ 3\times10^{-3}$	$8.490\ 0\times10^{-3}$	$3.337\ 2\times10^{-3}$	$3.260\ 0\times10^{-3}$

3.2 WTA 问题

为进一步验证 CEGA 算法性能,将 CEGA 针对 3 种不同规模 WTA 问题求解,每种算法实验计算 200 次,CEA 与本文提出的 CEGA 的实验结果性能对比如表 2 所示.

表 2 WTA 问题求解结果
Table 2 Experimental results of WTA problem

规模	算法	平均适应度	最高适应度	平均迭代次数	时间/s
$m=5,n=15$	CEA	6.509 5	7.127 6	56.355	2.570
	GA	7.523 4	7.524 4	100.000	5.056
	CEGA	7.523 5	7.524 4	1.030	6.193
$m=10,n=25$	CEA	8.486 2	9.840 4	65.130	26.334
	GA	11.178 8	11.413 4	100.000	31.567
	CEGA	11.269 3	11.418 3	1.625	34.502
$m=22,n=37$	CEA	12.021 7	14.017 1	72.140	97.673
	GA	16.506 2	17.007 3	100.000	58.871
	CEGA	17.128 4	17.493 0	2.820	76.485

由表 2 的实验结果可以得知,本文提出的 CEGA 算法在 3 种规模下,所求的平均适应度值与最高适应度值都明显高于传统的 CEA、GA 两种算法所求的结果,而且大大提高了收敛速度,故实验计算时间也相对减少. 本文提出的 CEGA 算法在寻优能力、收敛性、稳定性上都是优于传统的 CEA、GA 两种算法的.

为更加清晰对比不同算法收敛过程的差异,图 2、图 3、图 4 给出了 CEA、GA 与 CEGA 求解 3 种规模下

的收敛过程.

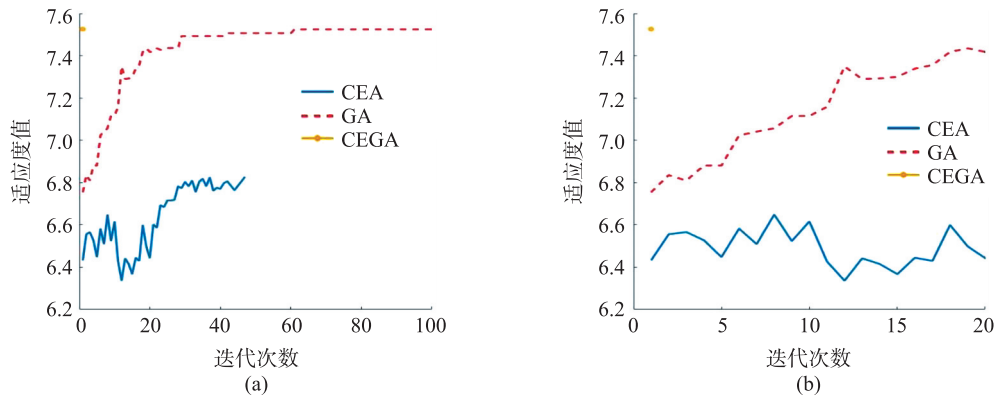


图 2 当 $m=5, n=15$ 时迭代收敛过程

Fig. 2 Iterative convergence process when $m=5, n=15$




图 3 当 $m=10, n=25$ 时迭代收敛过程

Fig. 3 Iterative convergence process when $m=10, n=25$




图 4 当 $m=22, n=37$ 时迭代收敛过程

Fig. 4 Iterative convergence process when $m=22, n=37$

4 结论

为提高求解 WTA 问题的精度和鲁棒性,本文在一般 CEA 求解 WTA 问题的基础上,提出了一种融合 GA 的 CEGA 算法来求解 WTA 问题. 在随机生成样本之后,加入了遗传算法中选择、交叉、变异操作,来提高样本的多样性以及精英样本的质量. 为验证本文提出的 CEGA 算法求解 WTA 问题的有效性,分别针对 3 种不同规模 WTA 问题,传统 CEA、GA 与本文提出的改进的 CEGA 算法进行对比,实验结果验证了本文提出的 CEGA 算法的有效性. 对比一般 CEA,CEGA 算法具有寻优精度高、稳定性强、收敛速度较快的优点. 在未来的研究中,将通过样本选择和适当的参数设置,重点关注计算效率和复杂多目标优化问题的应用.

[参考文献](References)

- [1] KLINE A, AHNER D, HILL R. The weapon-target assignment problem[J]. Computers and Operations Research, 2019, 105: 226–236.
- [2] KLINE A G, AHNER D K, LUNDAY B J. Real-time heuristic algorithms for the static weapon target assignment problem[J]. Journal of Heuristics, 2019, 25(3): 377–397.
- [3] ZHOU Y L, LI X B, ZHU Y F, et al. A discrete particle swarm optimization algorithm applied in constrained static weapon-target assignment problem[C]//Proceedings of the World Congress on Intelligent Control and Automation (WCICA), Guilin, China, 2016: 3118–3123.
- [4] 张迎新, 徐元子, 郭栋, 等. 基于进化多目标优化的对地打击武器目标分配[J]. 电光与控制, 2021, 28(9): 34–38.
- [5] LAI C M, WU T H. Simplified swarm optimization with initialization scheme for dynamic weapon-target assignment problem[J]. Applied Soft Computing, 2019, 82: 105542.
- [6] CHANG T, KONG D, HAO N, et al. Solving the dynamic weapon target assignment problem by an improved artificial bee colony algorithm with heuristic factor initialization[J]. Applied Soft Computing, 2018, 70: 845–863.
- [7] XU W, CHEN C, DING S, et al. A bi-objective dynamic collaborative task assignment under uncertainty using modified MOEA/D with heuristic initialization[J]. Expert Systems with Applications, 2020, 140: 112844.
- [8] 王玮, 程树昌, 张玉芝. 基于遗传算法的一类武器目标分配方法研究[J]. 系统工程与电子技术, 2008, 30(9): 1708–1711.
- [9] 刘陈曼, 周凤星. 改进粒子群算法的舰载武器目标分配[J]. 火力与指挥控制, 2018, 43(11): 72–76.
- [10] 张明双, 徐克虎. 基于最小火力浪费的火力优化分配[J]. 电光与控制, 2020, 27(9): 55–59.
- [11] 吴文海, 郭晓峰, 周思羽, 等. 改进差分进化算法求解武器目标分配问题[J]. 系统工程与电子技术, 2021, 43(4): 1012–1021.
- [12] 张进, 郭浩, 陈统. 基于可适应匈牙利算法的武器-目标分配问题[J]. 兵工学报, 2021, 42(6): 1339–1344.
- [13] 武从猛, 王公宝. 遗传-蚁群算法在目标分配问题中的应用研究[J]. 兵工自动化, 2014, 33(4): 8–11.
- [14] 赵舵, 唐启超, 余志斌. 一种采用改进交叉熵的多目标优化问题求解方法[J]. 西安交通大学学报, 2019, 53(3): 66–74.
- [15] 任超, 张航, 李洪双. 随机优化的改进交叉熵方法[J]. 北京航空航天大学学报, 2018, 44(1): 205–214.
- [16] 任斌, 丰镇平. 改进遗传算法与粒子群优化算法及其对比分析[J]. 南京师范大学学报(工程技术版), 2002, 2(2): 14–20.
- [17] HU L, YI G X, HUANG C, et al. Research on dynamic weapon target assignment based on cross-entropy[J]. Mathematical Problems in Engineering, 2020: 8618065.
- [18] YAO X, LIU Y, LIN G. Evolutionary programming made faster[J]. IEEE Transactions on Evolutionary Computation, 1999, 3(2): 82–102.
- [19] TIAN Y, CHENG R, ZHANG X Y, et al. PlatEMO: a MATLAB platform for evolutionary multi-objective optimization educational forum[J]. IEEE Computational Intelligence Magazine, 2017, 12(4): 73–87.

[责任编辑: 陈 庆]