

控制参数值非线性调整策略的灰狼优化算法

魏政磊¹, 赵 辉¹, 李牧东¹, 王 渊¹, 柯益明²

(1.空军工程大学航空航天工程学院,西安,710038;2.空军工程大学信息与导航学院,西安,710077)

摘要 为了克服灰狼优化算法在解决函数优化问题时容易陷入局部最优的缺陷,提出采用正弦曲线、对数曲线、正切曲线、余弦曲线和 2 次曲线的非线性调整策略控制参数值。同时采用变异策略对智能个体位置进行处理,使其位置受适应度值大小影响。对 3 个标准测试函数进行仿真表明,余弦曲线和 2 次曲线调整策略优于线性调整策略,其他 3 种非线性调整策略劣于线性策略。

关键词 灰狼优化算法;控制参数;非线性策略;函数优化

DOI 10.3969/j.issn.1009-3516.2016.03.013

中图分类号 TP18 **文献标志码** A **文章编号** 1009-3516(2016)03-0068-05

A Grey Wolf Optimization Algorithm Based on Nonlinear Adjustment Strategy of Control Parameter

WEI Zhenglei, ZHAO Hui, LI Mudong, WANG Yuan

(1.Aeronautics and Astronautics Engineering College, Air Force Engineering University, Xi'an 710038, China; 2.Information and Navigation College, Air Force Engineering University, Xi'an 710077, China)

Abstract: Aimed at the problem that the Grey Wolf Optimization (GWO) algorithm is easily bogged down in local optimization in solving function optimization, this paper proposes a nonlinear adjustment strategy by adopting sinusoid, logarithmic, tangential, cosine and quadratic curves. And at the same time a strategy on mutating position of the agents is presented, whose position is influenced by fitness value. The experimental results for three standard test functions show that the proposed cosine and the quadratic curve strategies are superior to the classical linear strategy, and the others such as the sinusoid strategy, the logarithmic strategy, and the tangential curve strategy are inferior to the linear strategy.

Key words: Grey Wolf Optimization (GWO) algorithm; control parameter; nonlinear strategy; function optimization

群体智能方法^[1]是在 20 世纪 90 年代提出的一种从群居生物相互合作工作中得到启示,通过此原理设计出新的求解问题的算法,在函数优化、科学计算、工程应用领域有着广泛的应用。现有的群体智

能算法如遗传算法(GA)^[2-3]、蚁群算法(ACO)^[4-6]、粒子群算法(PSO)^[7-9]、人工蜂群算法(ABC)^[10]等,已经成功运用在很多优化问题上,但普遍存在易于陷入局部最优、进化后期收敛速度较慢、对复杂问题

收稿日期:2015-09-24

基金项目:国家自然科学基金(71501184);航空科学基金(20155196022)

作者简介:魏政磊(1991-),男,甘肃兰州人,硕士生,主要从事智能优化算法、无人机作战与技术研究。E-mail:187928050060@163.com

引用格式:魏政磊,赵辉,李牧东,等.控制参数值非线性调整策略的灰狼优化算法[J].空军工程大学学报:自然科学版,2016,17(3):68-72. WEI Zhenglei, ZHAO Hui, LI Mudong, et al. A Grey Wolf Optimization Algorithm Based on Nonlinear Adjustment Strategy of Control Parameter[J]. Journal of Air Force Engineering University: Natural Science Edition, 2016, 17(3): 68-72.

计算精度不高等缺点。

受狼群猎食行为的启发, Seyedali, Seyed 和 Andrew 提出了灰狼优化算法(GWO)^[11], 它是一种模仿灰狼的社会等级制度和猎食行为的新兴群智能优化算法。同其它进化算法相比, 灰狼算法具有实现简单、全局优化能力强、收敛速度快等特点, 已经成功解决了弹簧结构设计、焊接梁设计、压力容器设计等工程问题。传统灰狼算法^[11]的距离控制参数 a 值随迭代次数增大而线性递减, 较大时有利于跳出局部极小点, 较小的 a 有利于算法收敛。在解决多峰值函数问题时容易陷入局部最优, 因此很难达到全局最优。在实际问题中, 由于搜索过程复杂, 距离控制参数 a 线性递减策略^[12-14]很难适应实际情况。另一方面, 由于没有体现个体社会级别与重要程度, 解决函数优化问题时不易到达最优解。

针对上述问题, 本文引入正弦曲线、对数曲线、正切曲线、余弦曲线^[15]和 2 次曲线几种非线性曲线^[16]到控制参数中, 以此来探索狼群优化算法的性能。同时, 采用适应度值影响灰狼的位置更新。通过多组仿真实验验证了提出策略的有效性。

1 灰狼优化算法

灰狼优化算法模拟灰狼的社会等级制度和猎食行为, 视灰狼为猎食者顶端, 即处于食物链最上层。灰狼通常以 5 ~ 12 只为 1 个群, 领导狼群的灰狼是 α , 主要负责组织狼群猎食以及栖息地选择; 处于狼群等级第 2 阶层的灰狼是 β , 帮助 α 做决策; 最底层的灰狼是 ω , 服从于狼群其他阶层的灰狼; 比 ω 高 1 个阶层, 地位低于 α 和 β 的灰狼是 δ , 主要负责侦察、警戒、打围和看守。在灰狼优化算法寻找最优解过程中, 根据灰狼的适应度值和各阶层之间关系, 使狼群接近最佳位置, 即猎物。根据灰狼猎食的 3 个重要步骤, 即接近、包围、攻击猎物, GWO 算法建立了 1 个模型: 狼群中每 1 个灰狼代表了种群的 1 个潜在解, 其中 α 狼位置是最好的解, β 和 δ 位置分别为最优解和次优解, 其他的候选解是 ω 的位置。

灰狼优化算法随机初始化 1 群灰狼, 每个灰狼通过位置 X 描述。群体通过迭代过程找到最优解, 在迭代过程中, 通过计算个体的适应度值, 确定最优解、优解和次优解, 即得到 α 、 β 和 δ 的位置。

$$D = |C \cdot X_p(t) - X(t)| \quad (1)$$

$$X(t+1) = X_p(t) - A \cdot D \quad (2)$$

式中: D 为猎物与灰狼之间的距离; t 为迭代的次数; C 和 A 为系数向量; X_p 和 X 为猎物位置向量和灰狼位置向量。

A 和 C 向量的计算公式如下:

$$A = 2a r_1 - a \quad (3)$$

$$C = 2 r_2 \quad (4)$$

式中: a 为距离控制参数, r_1, r_2 是在 $[0, 1]$ 范围内的随机数。

狼群在随机搜索猎物, 不知道猎物的位置, 那么找到猎物最简单有效的办法就是搜索目前离猎物最近的灰狼周围区域。通过计算灰狼的适应度值, 得到最优解、优解和次优解, 其他灰狼的位置由 α 、 β 和 δ 的位置共同决定。从图 1 可以直观地看出智能个体根据 α 、 β 和 δ 位置更新自己的位置。算法流程见图 2。

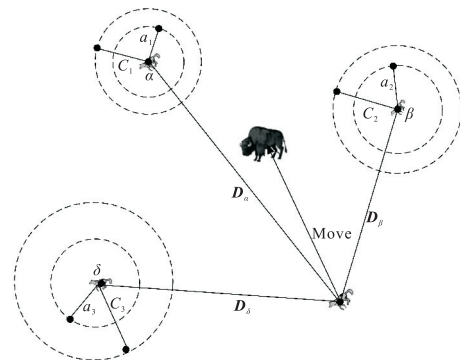


图 1 GWO 算法位置更新

Fig.1 Position updating in GWO

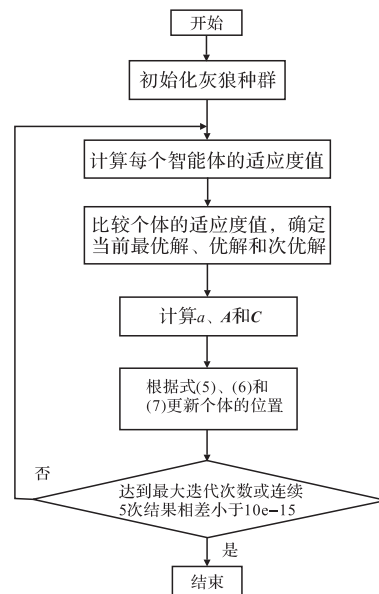


图 2 GWO 流程图

Fig.2 Flow Chart in GWO

$$D_\alpha = |C_1 \cdot X_\alpha - X|$$

$$D_\beta = |C_2 \cdot X_\beta - X| \quad (5)$$

$$D_\delta = |C_3 \cdot X_\delta - X|$$

$$X_1 = X_\alpha - A_1 \cdot (D_\alpha)$$

$$X_2 = X_\beta - A_2 \cdot (D_\beta) \quad (6)$$

$$X_3 = X_\delta - A_3 \cdot (D_\delta)$$

$$\mathbf{X}(t+1) = \frac{\mathbf{X}_1 + \mathbf{X}_2 + \mathbf{X}_3}{3} \quad (7)$$

控制参数 a 的设置影响了灰狼个体的全局搜索能力与局部搜索能力之间的平衡。一般情况,控制参数 a 取值在 $[0, 2]$ 范围内,且随着算法迭代次数增大而线性递减。当 a 较大时,算法搜索步长较大,全局搜索能力较强,有利于跳出局部最优;而当 a 较小时,主要是在当前解的附近搜索,局部搜索能力较强,有利于算法收敛。对应式(3), $|A| \geq 1$ 意味着灰狼进行全局搜索, $|A| < 1$ 表示灰狼在附近搜索。文献[11]仿真实验表明,解决单峰值函数问题时灰狼优化算法有较快的收敛速度;在解决多峰值函数问题时GWO算法全局搜索能力优于PSO和GA算法,但容易陷入局部最优。

2 非线性调整策略及其相应算法

相较于其他智能算法,传统灰狼算法在解决函数优化问题中,具有较快的收敛速度,全局搜索能力强。由于解决多峰值函数问题时,容易陷入局部最优;由于没有体现个体社会级别与重要程度,解决函数优化问题时达不到最优解。

2.1 控制参数非线性调整策略

虽然基本的灰狼优化算法具有快速收敛性、良好的全局搜索能力与局部搜索能力之间的平衡性和简单易行等优点,但是算法中控制参数 a 随迭代次数增大而线性递减,忽视了实际要解决的优化问题多样性,尤其在解决多峰值函数问题时容易陷入局部最优,因此很难达到全局最优。对于传统的灰狼优化算法,选择常见的正弦曲线、对数曲线、正切曲线、余弦曲线和二次曲线来设计控制参数 a 的调整策略。在调整策略中,为了让灰狼个体便于全局和局部搜索, a 随着迭代次数增加而非线性地减少。

文献[11]中的控制参数策略是:

$$a = a_{\max} - (a_{\max} - a_{\min})(t/t_{\max}) \quad (8)$$

式中: a_{\max} 和 a_{\min} 是控制参数的最大值和最小值,一般分别取 2 和 0; t 为当前迭代次数; t_{\max} 为最大迭代次数。

基于以上分析,利用文献[15]中的正弦曲线、对数曲线和正切曲线分别在区间 $[0, \pi/2]$ 、 $[1, e]$ 和 $[0, \pi/4]$ 上非线性递增,灰狼优化算法对应的控制参数调整公式与文献[15]表示的策略公式一样,分别简记为 SinGWO、LnGWO 和 TanGWO。

为了增加对比性与解决实际问题的多样性,通过余弦曲线在区间 $[0, \pi/2]$ 上非线性递减和 2 次曲线在区间 $[0, 1]$ 上非线性递增,对灰狼优化算法

的控制参数调整策略简记为 CosGWO 和 SquareGWO,其中调整策略公式为:

$$a = (a_{\max} - a_{\min})\cos(t/t_{\max}) \quad (9)$$

$$a = a_{\max} - (a_{\max} - a_{\min})(t/t_{\max})^2 \quad (10)$$

2.2 位置更新调整策略

在狼群的接近目标过程中,位置更新方程(7)表现出 α 、 β 和 δ 解的同等重要性,但是忽略了 α 、 β 和 δ 解的不同特征, α 灰狼的领导位置与最优解的所占比例没有被体现在式(7)中。

对于没有体现 α 、 β 和 δ 解特点的位置更新方程,智能群体算法一般用适应度值去体现个体的重要性。变异概率与个体的适应度值成比例,适应度值越低的个体,变异的概率越大^[1]。因此,本文对位置更新方程(7)进行改进,创建一个与适应度值成比例的概率分布后,通过该分布进行变异 α 、 β 和 δ 这 3 个解:

$$1/f = 1/f_{\alpha} + 1/f_{\beta} + 1/f_{\delta} \quad (11)$$

$$\mathbf{X}(t+1) = \frac{(1/f_{\alpha})\mathbf{X}_1 + (1/f_{\beta})\mathbf{X}_2 + (1/f_{\delta})\mathbf{X}_3}{1/f} \quad (12)$$

式中: f_{α} 、 f_{β} 和 f_{δ} 分别为 α 、 β 和 δ 的适应度值。

2.3 改进优化算法描述

根据以上的分析和模型建立,本文在控制参数 a 线性递减 GWO 算法中引入非线性递减策略,根据适应度值的高低计算变异概率,改变灰狼位置更新式(7),以期获得更高性能的 GWO 算法。算法的主要步骤如下:

Step 1 初始化灰狼种群,即随机产生 n 个智能个体的位置;初始化 a 、 A 和 C ;初始化 X_{α} 、 X_{β} 和 X_{δ} 的值。

Step 2 计算每个智能体的适应度值。

Step 3 比较智能个体的适应度值和 X_{α} 、 X_{β} 和 X_{δ} 的适应度值,确定当前的最优解 X_{α} 、优解 X_{β} 和次优解 X_{δ} 。

Step 4 根据新的非线性策略计算 a 、 A 和 C 。

Step 5 对每个智能个体,根据式(12),更新当前智能个体的位置。

Step 6 如果达到结束条件(最大迭代次数或连续 5 次结果相差小于 10^{-15}),则结束;否则转到 Step 2。

3 仿真实验

3.1 实验设置

为验证改变策略后的灰狼优化算法的有效性和性能提高,采用 3 个著名的测试函数^[17] Griewank、Rastrigin 和 Rosenbrock 对改进的灰狼优化算法进

进行测试,具体函数形式如下:

1)Griewank 函数

$$F_1(x) = 1 + \frac{1}{4000} \sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos\left(\frac{x_i}{\sqrt{i}}\right) \quad (13)$$

式中: $x_i \in [-600, 600]$; $F_1^*(x) = 0.0$ 。

2)Rastrigin 函数

$$F_2(x) = \sum_{i=1}^n (x_i^2 - 10\cos(2\pi x_i) + 10) \quad (14)$$

式中: $x_i \in [-5.12, 5.12]$; $F_2^*(x) = 0.0$ 。

3)Rosenbrock 函数

$$F_3(x) = \sum_{i=1}^{n-1} [100(x_{i+1} - x_i^2)^2 + (x_i - 1)^2] \quad (15)$$

式中: $x \in [-30, 30]$; $F_3^*(x) = 0.0$ 。

在实验中,为了和传统灰狼优化算法作性能比较,3 个测试函数均分别采用 GWO、SinGWO、LnGWO、TanGWO、CosGWO 和 SquareGWO 方法进行控制参数的调整策略。其中,灰狼种群大小设置为 30, a_{\max} 和 a_{\min} 分别设置为 2 和 0,迭代次数为 500,在达到最大迭代次数或者当连续 5 次结果相差小于 10^{-15} 时输出结果。采用 Matlab 8 进行仿真。

3.2 实验结果与分析

首先测试给定迭代次数下采用非线性策略的灰狼优化算法达到最优目标函数值,GWO、SinGWO、LnGWO、TanGWO、CosGWO 和 SquareGWO 分别进行 20 次随机试验。对于全局最小化问题,采用 20 次随机试验的最优目标函数值平均值和最优目标函数值来评价算法的性能。

从表 1、表 2 可以看出,采用 CosGWO 和 SquareGWO 策略的灰狼优化算法在优化函数时有明显的改进,最优目标函数值相较 GWO、SinGWO、LnGWO 和 TanGWO 是比较小的。对于 Griewank 函数测试结果中,CosGWO 策略平均最优值达到 0;对于 Rosenbrock 函数测试结果中,SquareGWO 策略平均最优值达到 0。表 3 中可以看出,这 5 种非线性策略相较于传统算法没有明显改进。

表 1 使用 Griewank 函数测试结果比较

Tab.1 Testing results comparison of Griewank function

算法	平均最优值	最优值
GWO	0.004 867	0
SinGWO	0.006 011	3.330 7e-16
LnGWO	0.004 084	0
TanGWO	0.010 999	0
CosGWO	0	0
SquareGWO	0.002 745	0

表 2 使用 Rastrigin 函数测试结果比较

Tab.2 Testing results comparison of Rastrigin function

算法	平均最优值	最优值
GWO	2.093 6	5.684 3e-14
SinGWO	3.292 3	2.216 9e-12
LnGWO	3.727 8	1.016 9
TanGWO	8.232 0	3.799 8
CosGWO	9.473 9e-15	0
SquareGWO	0	0

表 3 使用 Rosenbrock 函数测试结果比较

Tab.3 Testing results comparison of Rosenbrock function

算法	平均最优值	最优值
GWO	27.298 5	26.160 8
SinGWO	27.133 4	26.302 3
LnGWO	27.270 5	26.235 0
TanGWO	27.511 4	27.116 1
CosGWO	26.888 3	26.000 5
SquareGWO	26.753 5	26.320 3

为了直观地反映各种算法的寻优性能,给出了 4 个函数的平均最优适应度值随迭代次数变化曲线,见图 3、图 4 和图 5,其中平均最优适应度值为 20 次实验每一代最优适应度值的平均值。由图可知,对于给定的 3 个测试函数,各策略都能在指定的迭代次数内找到最优值,但是优化结果有所不同。在迭代初期,各策略的优化效果大致相当,但是随着迭代的进行,它们的差异逐渐表现出来。总的来说,在提出的策略中,CosGWO 和 SquareGWO 策略好于 GWO,而 SinGWO、LnGWO 和 TanGWO 策略性能低于 GWO。




图 3 Griewankl 函数平均最优适应度值曲线
Fig.3 Fitness value curve of Griewankl function




图 4 Rastrigin 函数平均最优适应度值曲线
Fig.4 Fitness value curve of Rastrigin function




图5 Rosenbrock 函数平均最优适应度值曲线

Fig.5 Fitness value curve of Rosenbrock function

4 结语

灰狼优化算法从灰狼群体的社会行为中得到启发,是一种新的群智能优化算法,其实现简单,但是控制参数 a 直接影响 GWO 的全局搜索能力与局部搜索能力之间的平衡,而传统 GWO 采用统一的线性策略,忽视了优化问题的多样性。基于对灰狼优化算法以上特点进行分析,本文对控制参数采用非线性调整策略,同时利用变异策略处理智能个体位置的更新,通过仿真验证改进后算法的性能。仿真结果表明,采用余弦曲线和二次曲线调整策略在测试函数优化过程中的性能高于传统灰狼优化算法以及采用其他 3 种非线性调整策略的灰狼优化算法。

参考文献 (References):

- [1] ANDRIES P Engelbrecht. 计算群体智能基础[M].北京:清华大学出版社,2009.
ANDRIES P Engelbrecht. Fundamentals of Computational Swarm Intelligence[M]. Beijing: Tsinghua University Press, 2009. (in Chinese)
- [2] HOLLAND J H. Adaptation in Natural and Artificial Systems[J]. MIT Journals Press, 2015, 6(2): 126-137.
- [3] 杨洪敏,林孔元,杨庆江.一种基于改进遗传算法的多峰函数优化研究[J].计算机工程与科学,2000,22(1):28-31.
YANG Hongmin, LIN Kongyuan, YANG Qingjiang. On Multimodal Function Optimization Based on an Improved Genetic Algorithm[J]. Computer Engineering & Science, 2000, 22(1): 28-31. (in Chinese)
- [4] DORIGO M, GAMBARDELLA L M. Ant Colonies for the Travelling Salesman Problem[J]. Biosystems, 1997, 43(2): 73-81.
- [5] MIDDENDORF Martin, REISCHLE Frank, SCHMECK Hartmut. Multi Colony Ant Algorithms[J]. Journal of Heuristics, 2002, 8(3): 305-320.
- [6] 魏平,熊伟清.用于一般函数优化的蚁群算法[J].宁波大学学报:理工版,2001,14(4):52-55.
WEI Ping, XIONG Weiqing. Ant Colony Algorithm for General Function Optimization Problems[J]. Journal of Ningbo

- University; Natural Science and Engineering Edition, 2001, 14(4): 52-55. (in Chinese)
- [7] KENNEDY J. The Particle Swarm: Social Adaptation of Knowledge[C]//Proceedings of the IEEE International Conference on Evolutionary Computation, 1997: 303-308.
- [8] 高海昌,冯博琴,侯芸,等.自适应变异的混合粒子群优化策略及其应用[J].西安交通大学学报,2006,40(6):663-666.
GAO Haichang, FENG Boqin, HOU Yun, et al. Hybrid Particle Swarm Optimization Strategy with Adaptive Mutation and Its Applications[J]. Journal of Xi'an Jiaotong University, 2006, 40(6): 663-666. (in Chinese)
- [9] EBERHART R C, SHI Y. Particle Swarm Optimization: Developments, Applications and Resources[C]//Proceedings of the IEEE Congress on Evolutionary Computation, 2001, 5(1): 27-30.
- [10] 高卫峰,刘三阳,张建科.混合人工蜂群算法[J].系统工程与电子技术,2011,33(5):1167-1169.
GAO Weifeng, LIU Sanyang, ZHANG Jianke. Hybrid Artificial Bee Colony Algorithm[J]. Systems Engineering and Electronics, 2011, 33(5): 1167-1169. (in Chinese)
- [11] MIRJALILI Seyedail, MIRJALILI Seyed Mohammad, LEWIS Andrew. Grey Wolf Optimizer[J]. Advances in Engineering Software, 2014, 69: 46-61.
- [12] EBERHART R C, SHI Y. Comparing Inertia Weights and Constriction Factors in Particle Swarm Optimization [J]. IEEE Service Center, 2000, 1(5): 84-88.
- [13] KIRKPATRICK S. Optimization by Simulated Annealing-Quantitative Studies[J]. Journal of Statistical Physics, 1984, 34(5): 975-986.
- [14] SHI Y, EBERHART R C. Parameter Selection in Particle Swarm Optimizer[C]//Proceedings of the IEEE Congress on Evolutionary Computation, 1998: 591-600.
- [15] 周敏,李太勇.粒子群优化算法中的惯性权重值非线性调整[J].计算机工程,2011,37(5):204-206.
ZHOU Min, LI Taiyong. Nonlinear Adjustment Strategy of Inertia Weight in Particle Swarm Optimization Algorithm[J]. Computer Engineering, 2011, 37(5): 204-206. (in Chinese)
- [16] CHATTERJEE A, SIARRY P. Nonlinear Inertia Weight Variation for Dynamic Adaptation in Particle Swarm Optimization[J]. Computers & Operations Research, 2006, 33(3): 859-871.
- [17] GUO Tao, KANG Lishan. A New Evolutionary Algorithm for Function Optimization[J]. Wuhan University Journal of Natural Sciences, 1999, 4(4): 409-414.

(编辑:姚树峰)