

生物地理学优化算法综述

王存睿^{1,2} 王楠楠¹ 段晓东¹ 张庆灵²

(大连民族学院非线性信息技术研究所 大连 116600)¹ (东北大学系统科学研究所 沈阳 110004)²

摘要 生物地理学(Biogeography)是一门研究自然界种群迁移机制的科学,Dan Simon 用生物地理学的方法和机制来解决工程优化问题,提出了生物地理学优化算法(BBO,Biogeography-Based Optimization)。生物地理学优化算法以其独特的搜索机制和较好的性能在智能优化算法领域得到了广泛的关注。对生物地理学优化算法的设计原理、迁徙模型、算法流程及相应迁移和突变操作进行了综述。通过 BBO 算法在 14 个基准函数下与传统算法,如遗传算法、蚁群算法和粒子群等优化算法的性能比较,表明生物地理学优化算法是有效的。论述了算法与传统优化算法之间的差异以及 BBO 算法有待解决的问题。

关键词 优化算法,生物地理学优化算法,智能优化

中图分类号 TP18 **文献标识码** A

Survey of Biogeography-based Optimization

WANG Cun-rui^{1,2} WANG Nan-nan¹ DUAN Xiao-dong¹ ZHANG Qing-ling²

(The Research Institute of Nonlinear Information Technology, Dalian Nationalities University, Dalian 116600, China)¹

(The Research Institute of System Science, Northeastern University, Shenyang 110004, China)²

Abstract Biogeography is the study of the geographical distribution of biological organisms, Prof. Dan Simon took the mechanism to resolve engineering problems, and proposed a new optimization algorithm named Biogeography-Based Optimization (BBO). BBO algorithm has a wide attention by its unique search mechanism and good performance. We over-viewed the BBO's natural mechanism, the math model of BBO migration, the progress of BBO, migration and mutation operation of BBO. We listed the results of BBO tests on a set of 14 standard benchmarks and compared it with GA, ACO, and PSO etc to prove its good performance. This paper also discussed the difference of BBO with traditional optimization algorithms and the future problems of BBO.

Keywords Optimization algorithm, Biogeography-based optimization, Intelligence optimization

1 引言

通过研究自然界规律构建仿生算法,解决工程问题,一直是智能优化算法研究的基础。经过几十年的研究,利用生物遗传进化规律的演化计算^[1]、利用蚂蚁觅食规律的蚁群算法^[2]和利用鸟群行为规律及社会行为学的粒子群算法^[3]等都在工程和科研领域得到了广泛的应用和认可。

生物地理科学是一门研究生物种群在栖息地的分布、迁移和灭绝规律的科学。生物地理学由 Alfred Wallace^[4] 和 Charles Darwin^[5] 于 19 世纪提出,在 20 世纪 60 年代逐渐完善,形成了一门独立的学科^[6],目前该领域已发表 2.5 万多篇论文,提出了众多种群分布、迁移和灭绝的数学模型。这些规律和数学模型为构建优化算法提供了新的理念和发展动力。

Dan Simon 在 2008 年 IEEE Transactions on Evolutionary Computation 提出了生物地理学优化算法(BBO, Biogeography-Based Optimization)^[7]。本文将从生物地理学基本原理阐述生物地理学优化算法(BBO),对算法的设计原理、迁徙

模型、算法流程及相应迁移和突变操作进行系统论述。

2 生物地理学优化算法的设计原理

如图 1 所示,生物种群生活在不同的“栖息地”^[8],每个栖息地的适宜度指数(HIS, Habitat Suitability Index)是不同的^[9]。与 HSI 有关系的特征包括降雨量、植被的多样性、地质的多样性和气候等因素,这些特征变量形成一个描述栖息地适宜度的向量 SIV(SIV, Suitable Index Vector),其中的每个适宜度变量被称为 SIVs(Suitable Index Variables)。




图 1 BBO 算法中的多个栖息地

HSI 是影响栖息地种群分布和迁移的重要因素之一。栖息地的迁入率和迁出率可以描述 HSI 如何影响种群迁移和

到稿日期:2009-10-13 返修日期:2010-01-11 本文受国家自然科学基金(60573124),辽宁省自然科学基金(20072197),高校科研项目计划(20060146)资助。

王存睿(1980-),男,讲师,博士生,主要研究方向为智能优化,E-mail:cunrui@gmail.com。

分布。具有较高 HSI 的栖息地,趋向于荷载数量较大的种群,而较低 HSI 的栖息地能容纳种群数量较少。但是,较高 HSI 的栖息地伴随迁入种群数量的增多,栖息地容纳的种群数量趋于饱和,栖息地迁入率降低,迁出率增高,该栖息地的部分种群会迁移到附近的栖息地,以增加个体拥有的单位资源。具有较低 HSI 的栖息地其种群数量稀疏,因此生物种群迁入率较高。由于栖息地的 HSI 与生物多样性成正比,因此新种群的迁入使得该栖息地的 HSI 提高。如果该栖息地的 HIS 仍较低,则居住此栖息地的生物种群会趋于灭绝,或寻找另外的栖息地。可以看出,低 HSI 的栖息地的生物种群比高 HSI 栖息地的生物种群分布具有更加复杂的动态变化。

生物地理学也是研究生物种群的自然分配机制的科学。这种自然调节方法也可以用于解决工程问题。用生物地理学的分配机制构建的 BBO 算法,解决优化问题主要依赖以下 4 方面。

1) 栖息地的特征向量 SIV 对应优化问题的解。其中的栖息地的降雨量、植被的多样性、地质的多样性和气候等因素,相当于优化问题解向量的分量;栖息地的适宜度指数(HSI)是对适宜度的向量 SIV 优劣的度量值,对应于优化问题的度量函数值。好的解决方案对应具有较高 HIS 值的栖息地,反之亦然。

2) 栖息地的迁入和迁出机制对应优化算法中的信息交互机制。高 HSI 的解决方案以一定的迁出率进行相应操作,将信息共享给低 HSI 解决方案。低 HSI 解决方案从高 HSI 的解决方案接受许多新的特征,这些额外的新特征可以提高低 HSI 解决方案的质量。若栖息地较高 HIS 使得该栖息地种群数量增多,则调低迁入率、调高迁出率。

3) BBO 算法能够根据栖息地容纳种群数量的不同,计算相应的突变率,对栖息地进行突变操作,使得算法具备较强的自适应能力。

2 BBO 中的生物地理学迁徙模型

如图 2 所示,生物地理学中常用这个简单的数学模型来描述生物种群迁徙规律。该模型为单个栖息地的生物种群迁移模型^[6],横坐标表示栖息地容纳的种群数量 s ,纵坐标表示迁移的比率, $\lambda(s)$ 和 $\mu(s)$ 分别为种群数量的迁入率和迁出率函数。




图 2 生物地理学种群迁移模型^[6]

图 2 所示的 $\lambda(s)$ 迁入率函数最大值为 I , 当且仅当栖息地种群个数 $s=0$, 随着迁入该栖息地的生物种群增加, 栖息地渐趋拥挤, 越来越少的迁入种群能够幸存下来, 迁入率线性递减。当种群数量达到饱和 $s=S_{\max}$, $\lambda(s)$ 值为 0。

迁出函数 $\mu(s)$, 当栖息地的生物种群数量为 0, $\mu(s)=0$ 。伴随该栖息地生物种群数量的增加, 栖息地变得拥挤, 越来越多的生物种群选择离开该栖息地, 寻找其他可能的栖息地, 迁出率 $\mu(s)$ 增加。当群数量达到饱和 $s=S_{\max}$, 迁出率达到峰值

$$\mu(s)=E。$$

当 $\lambda(s)=\mu(s)$ 时, 该栖息地种群数量达到平衡点 S_0 , 迁入该栖息地的种群数量等于迁出该栖息地的种群数量。平衡点随栖息地的环境变化会发生偏移, S_0 增大为正偏移, S_0 减小为负偏移。正偏移的发生可能是由于其他种群突然迁入, 例如大量流离失所的生物从附近栖息地的迁入, 或由于基因突变导致变异而出现一些新物种形式, 例如寒武纪大爆炸; S_0 负偏移的发生可能是由于疾病、大量极其贪婪凶猛的肉肉种群侵入栖息地或者其它一些自然灾害。毕竟自然界在经历一场大的灾难后, 需要相当一段时间种群数量才能恢复平衡^[4,6]。

图 2 用直线简化表示了 $\lambda(s)$ 和 $\mu(s)$ 两个函数, 但实际上, 这两个函数可能是非常复杂的非线性函数, 该模型只是给出了栖息地种群迁入和迁出一个大体的描述。

为简化表示, 当栖息地种群数量为 s 时, 迁入率 $\lambda(s)$ 和迁出率 $\mu(s)$ 分别记为 λ_s 和 μ_s , 同时设栖息地容纳 s 种生物种群的概率为 P_s , 式(1)给出了 P_s 从时间 t 到 $t+\Delta t$ 的函数模型。

$$P_s(t+\Delta t)=P_s(t)(1-\lambda_s\Delta t-\mu_s\Delta t)+P_{s-1}\lambda_{s-1}\Delta t+P_{s+1}\mu_{s+1}\Delta t \quad (1)$$

栖息地要在 $(t+\Delta t)$ 时刻拥有 s 个生物种群, 必须满足下列条件:

- 1) 在时间 t 时, 栖息地有 s 个生物种群, 当且仅当在时间 t 到 $(t+\Delta t)$ 之间无种群迁入和迁出;
- 2) 在时间 t 的时候有 $s-1$ 个生物种群, 当且仅当有 1 个生物种群迁入;
- 3) 在时间 t 的时候有 $s+1$ 个生物种群, 当且仅当有 1 个生物种群迁出。

假设 Δt 非常小以至于期间的种群迁入或迁出的概率可以忽略。令 $\Delta t \rightarrow 0$, 对式(1)求极限, 可以得到式(2)。

$$P_s' = \begin{cases} -(\lambda_s + \mu_s)P_s + \mu_{s+1}P_{s+1}, & s=0 \\ -(\lambda_s + \mu_s)P_s + \lambda_{s-1}P_{s-1} + \mu_{s+1}P_{s+1}, & 1 \leq s \leq S_{\max} - 1 \\ -(\lambda_s + \mu_s)P_s + \lambda_{s-1}P_{s-1}, & s=S_{\max} \end{cases} \quad (2)$$

定义 $n=S_{\max}$, $P=[P_0 \cdots P_n]^T$, P 的定义如下:

$$P' = AP \quad (3)$$

矩阵 A 在式(4)中给出:

$$A = \begin{bmatrix} -(\lambda_0 + \mu_0) & \mu_1 & 0 & \cdots & 0 \\ \lambda_0 & -(\lambda_1 + \mu_1) & \mu_2 & \ddots & \vdots \\ \vdots & \ddots & \ddots & \ddots & \vdots \\ \vdots & \ddots & \lambda_{n-2} & -(\lambda_{n-1} + \mu_{n-1}) & \mu_n \\ 0 & \cdots & 0 & \lambda_{n-1} & -(\lambda_n + \mu_n) \end{bmatrix} \quad (4)$$

根据图 2 所示迁移模型, 给定种群数量 k , 可以计算出:

$$\mu_k = \frac{Ek}{n} \quad (5)$$

$$\lambda_k = I(1 - \frac{k}{n})$$

对于图 2 中所示迁移函数, 考虑特殊情况 $E=I$, 如式(6)所示, 等式成立:

$$\lambda_k + \mu_k = E \quad (6)$$

则矩阵 A 变成式(7):

$$A=E \begin{bmatrix} -1 & \frac{1}{n} & 0 & \cdots & 0 \\ \frac{n}{n} & -1 & \frac{2}{n} & \ddots & \vdots \\ \vdots & \ddots & \ddots & \ddots & \vdots \\ \vdots & \ddots & \frac{2}{n} & -1 & \frac{n}{n} \\ 0 & \cdots & 0 & \frac{1}{n} & -1 \end{bmatrix} = EA' \quad (7)$$

文献[7]计算出当 A' 的特征值为 0, 相应的特征向量如式(8)所示, 其中 $\text{ceil}()$ 函数为取形参的上限整数。

$$v = [v_1 \cdots v_{n+1}]$$

$$v_i = \begin{cases} \frac{n!}{(n-1-i)! (i-1)!}, (i=1, \cdots, \text{ceil}(\frac{n+1}{2})) \\ v_{n+2-i}, (i=\text{ceil}(\frac{n+1}{2})+1, \cdots, n+1) \end{cases} \quad (8)$$

并给出推论: 栖息地的最大种群数量等于 n 时, 不同种群数量对应的概率组成的向量如式(9)所示:

$$P(n) = [P(s_1) \cdots P(s_n)] = \frac{v}{\sum_{i=1}^{n+1} v_i} \quad (9)$$

当 $n=10$ 时, $P(10) = [0.001 \ 0.001 \ 0.044 \ 0.117 \ 0.205 \ 0.246 \ 0.205 \ 0.117 \ 0.044 \ 0.001 \ 0.001]$, 其分布如图 3 所示。




图 3 $n=10$ 时各种种群数量对应的概率

图 3 表明, 当栖息地最大种群数为 10 时, 其各个数量的种群稳定的概率曲线是一个关于平衡点的偶对称函数, 数量较大种群和数量较少种群的稳定概率都较低, 存在概率较小, 平衡点附近的种群数量稳定且概率较高。

3 生物地理学优化算法(BBO)[7]

本节介绍生物地理学优化算法的算法流程和相应操作。生物地理学优化算法中, 算法由 n 个栖息地组成, 每个栖息地由 D 维适宜度变量组成, 其向量 $x_i = (x_{i1}, x_{i2}, \cdots, x_{iD})$, $i=1, 2, \cdots, n$ 代表优化问题在 D 维搜索空间中潜在的解。栖息地 i 的适宜度可以通过 $f(x_i)$ 进行度量。全局的变量还包括系统迁移率 P_{mod} 和系统突变率 m_{max} 。

栖息地 i 参数还包括其容纳的种群数量 s_i , s_i 根据栖息地的适宜度 $f(x_i)$ 进行计算, s_i 小于等于设定的最大种群数量 S_{max} ; 种群数量 s_i 可通过式(5)计算出其对应的迁入率 $\lambda(s_i)$ 和迁出率 $\mu(s_i)$, 式(2)可计算出栖息地 i 容纳 s_i 种生物种群的概率 $P(s_i)$ 。

3.1 BBO 算法流程

生物地理学优化算法的具体算法流程如下:

Step 1 初始化 BBO 算法参数, 设定栖息地数量 n 、优化问题的维度 D 、栖息地种群最大容量 S_{max} ; 设定迁入率函数最大值 I 和迁出率函数最大值 E 、最大变异率 m_{max} 、迁移率 P_{mod} 和精英个体留存数 z 。

Step 2 随机初始化每个栖息地的适宜度向量 x_i , $i=1, 2, \cdots, n$ 。每个向量都对应于一个潜在的对于给定问题的解。

Step 3 计算栖息地 i 的适宜度 $f(x_i)$, $i=1, 2, \cdots, n$, 并计算栖息地 i 对应的物种数量 s_i 、迁入率 $\lambda(s_i)$ 以及迁出率 μ

(s_i) , $i=1, 2, \cdots, n$ 。

Step 4 利用 P_{mod} 循环(栖息地数量 n 作为循环次数)判断栖息地 i 是否进行迁入操作。若栖息地 i 被确定发生迁入操作, 则循环利用迁入率 $\lambda(s_i)$ 判断栖息地 i 的特征分量 x_{ij} 是否发生迁入操作(问题维度 D 作为循环次数), 若栖息地 i 的特征分量 x_{ij} 被确定, 则利用其他栖息地的迁出率 $\mu(s_k)$ 进行轮盘选择, 选出栖息地 k 的对应位替换栖息地 i 的对应位。重新计算栖息地 i 的适宜度 $f(x_i)$, $i=1, 2, \cdots, n$ 。

Step 5 根据式(2)更新每个栖息地的种群数量概率 $P(s_i)$ 。然后根据式(10)计算每个栖息地的突变率, 进行突变操作, 突变每一个非精英栖息地, 用 $m(s_i)$ 判断栖息地 i 的某个特征分量是否进行突变。重新计算栖息地 i 的适宜度 $f(x_i)$ 。

Step 6 是否满足停止条件。如不满足, 跳转到 Step 3, 否则输出迭代过程中的最优解。

3.2 BBO 的迁移(Migration)操作

BBO 算法利用迁移操作与其它栖息地进行信息交换, 进而对解空间进行广域搜索。适应度较高的栖息地包含的种群较多, 适宜度较低的栖息地对应种群较少。BBO 算法需建立一个栖息地适宜度与种群数量的映射函数。该映射函数先将所有栖息地按适宜度优劣进行排序, 并设 $S_{\text{max}} = n$, 则 $S(x_i) = S_{\text{max}} - i$, $i=1, 2, \cdots, n$ (向量 x_i 中的 i 是经过排序后的标号)。

图 4 中 s_1 代表低适宜度的栖息地, s_2 代表高适宜度的栖息地; s_1 的迁入率 $\lambda(s_1)$ 大于 s_2 的迁入率 $\lambda(s_2)$, s_1 的迁出率 $\mu(s_1)$ 小于 s_2 的迁出率 $\mu(s_2)$ 。在迁移策略调节栖息地生态系统的过程中, 栖息环境被更改的概率正比于其迁入率, 且引入特征的来源栖息地正比于其迁出率。




图 4 生物地理学种群迁移模型[3]

首先, 利用全局的迁移概率 $P_{\text{mod}} \in [0, 1]$ 来决定栖息地 i 是否被选择进行信息引入。如被选择, 则利用其迁入率 $\lambda(s_i)$ 来决定 x_i 的适宜度变量 x_{ij} , $j=1, \cdots, D$ 是否被更改(且须将所有栖息地的迁入率映射到 $[0, 1]$ 区间, 因为生成的随机数为 $[0, 1]$ 间均匀分布的随机数)。如果方法 x_i 的 x_{ij} 被选择更改, 那么利用其它栖息地的迁出率 $\mu(s_k)$, $k \neq i$, $k \in [1, n]$ 进行选择, 如选出栖息地 k 作为迁入对象, 则将向量 x_k 的变量 x_{kj} 替代向量 x_i 的 x_{ij} 。该选择过程类似遗传算法中的轮盘选择, 先将其它所有栖息地的迁出率进行累加, 并计算其中每个栖息地的累积概率, 然后取随机数落在相应区间, 进而选取相应的栖息地。

BBO 迁移操作与进化策略类似, 适宜度较高的栖息地特征变量能够概率较大地被传播。不同之处在于进化策略迭代中产生新的方法, 而 BBO 迁移只是改变已存在的方法; 进化策略中的全局重组是一个再生过程, 而在 BBO 算法中迁移是一个适应过程, 可动态地调整栖息地的生态环境。同时, 在 BBO 算法迭代过程中, 保持一定数量的最优或较优栖息地进入下次迭代, 可以避免由于特征迁入而导致的算法退化。

3.3 BBO 算法突变 (Mutation) 操作

灾难性事件,如疾病和自然灾害等因素能够彻底地改变一个栖息地的生态环境,导致该栖息地的种群数量脱离平衡点。一个栖息地的适宜度会因为此类随机事件发生非常突然的变化。BBO 算法采用突变操作模拟这种现象,根据栖息地 i 的种群数量概率 $P(s_i)$, $i \in [1, n]$ 对栖息地的特征变量进行突变。

如何根据栖息地拥有种群数量概率给出相应的突变率,是 BBO 突变操作的核心问题。从图 3 中可以看出,适宜度较高的栖息地和适宜度较低的栖息地对应的种群数量概率都较低,平衡点对应数量概率则较高。每个栖息地的数量概率表示对于给定问题预先存在的可能性。如果一个栖息数量概率较低,则该方法存在的概率较小。如果发生突变,它很有可能突变成更好的方法。相反地,具有较高数量概率的方法则具有很小的可能性突变到其它方法。因此突变概率函数与该栖息地的数量概率成反比,相应的函数如式(10)所示:

$$m(x_i) = m_{\max} \left(\frac{1 - P(s_i)}{P_{\max}} \right) \quad (10)$$

式中, m_{\max} 为用户定义突变率的最大值。突变可以增加方法集的多样性。该突变函数可使低适宜度的方案以较大概率发生突变,为该栖息地增加更多的机会搜索目标。但该突变方法还会破坏较优方案的栖息地特征。可在算法迭代过程中,部分保留群体精英个体,使得这些较好栖息地特征得到有效保护。处于平衡点的栖息地应该尽量避免发生突变,因为这些方案最有可能得到有效改善,突变反而破坏了寻优过程。BBO 突变机制具有问题依赖性,可根据问题的不同进行相应调整。

3.4 BBO 和其他基于种群的优化算法的不同

BBO 是一种基于种群的优化算法,但是它不需要繁殖或者产生下一代。BBO 算法利用迁入率 $\lambda(s_i)$ 决定栖息地 i 需要引入的特征变量的比例,而且迁入的特征变量来自不同的个体;遗传算法中交叉操作无法根据适应值的不同来控制交叉基因的比例,而且交叉的基因片段来自同一个体,这些是与遗传算法的显著不同之处。BBO 也有别于 ACO 算法,ACO 算法在每一代产生一系列方法,BBO 则保持方法不变。BBO 和 PSO 以及 DE 较为相似,因为这些算法都将产生的方案保存到下一代,每一方案都能与其邻居进行信息交互,从而进行调整。PSO 通过速度向量间接改变位置,DE 算法直接地变化其方案,而 BBO 算法采用了根据不同栖息地种群数量选择不同操作强度的生物激励机制。这些不同之处都表明,BBO 算法是一种独特的优化算法。

4 仿真结果

Dan Simon 为研究 BBO 算法的性能,用 14 个基准函数测试 BBO 算法,并与另外 7 种基于种群的优化算法进行性能比较^[7]。这 7 种算法是 ACO 算法^[2]、DE^[10-12] 算法、ES 算法^[13-15]、GA 算法^[1]、PBIL^[16]、PSO 算法^[3,17-19] 和 SGA^[20] 算法。

用于测试的基准函数大部分存在多个局部极小值,这可以检验算法的性能。基准函数的维度都设为 20。这些函数有些局部极值是孤立的,有些是关联的;有的极值点分布规则,有的不规则。基准函数详如表 1 所列。

表 1 基准函数

ID	名称	多级值	孤立	极值分布	定义域
1	Ackley	是	否	规则	± 30
2	Flwtcher-Powell	是	否	不规则	$\pm \pi$
3	Griewank	是	否	规则	± 600
4	Penalty #1	是	否	规则	± 50
5	Penalty #2	是	否	规则	± 50
6	Quartic	否	是	规则	± 1.28
7	Rastrigin	是	是	规则	± 5.12
8	Rosenbrock	否	否	规则	± 2.048
9	Schwefel 1.2	否	否	规则	± 65.536
10	Schwefel 2.21	否	否	不规则	± 100
11	Schwefel 2.22	是	否	不规则	± 10
12	Schwefel 2.26	是	是	不规则	± 512
13	Sphere	否	是	规则	± 5.12
14	Step	否	是	不规则	± 200

其中对于 BBO 算法,参数设置如下: $P_{\text{mod}} = 1$; 迁入概率边界 $[0, 1]$, 每一个栖息地的最大迁入率与迁出率等于 1, 突变概率 0.005 (对于 BBO 算法, 突变主要对算法种群规模较小有利)。其他 7 种算法的参数详见文献^[7]。每个算法的种群大小都为 50, 共运行 50 次迭代。

表 2 和表 3 列出了仿真结果。表 2 列出了在 100 次蒙特卡洛实验中每个算法的平均极小值, 平均极小值表示算法平均性能。表 3 列出了在 100 次蒙特卡洛实验中每个算法的最好极小值, 表示算法的最好性能。

表 2 平均标准最优化结果以及在基准函数上的 CPU 运行时间

ID	ACO	BBO	DE	ES	GA	PBIL	PSO	SGA
1	182	100	146	197	197	232	192	103
2	1013	100	385	494	415	917	799	114
3	162	117	272	696	516	2831	1023	100
4	2.22 _{E7}	1.16 _{E4}	9.70 _{E4}	1.26 _{E6}	2.46 _{E5}	2.82 _{E7}	2.09 _{E6}	100
5	5.02 _{E5}	715	5862	4.23 _{E4}	1.06 _{E4}	5.37 _{E5}	6.35 _{E4}	100
6	3213	262	1176	7008	2850	4.81 _{E4}	8570	100
7	454	100	397	536	421	634	470	134
8	1711	102	253	716	428	1861	516	100
9	202	100	391	425	166	606	592	110
10	161	100	227	162	184	265	179	146
11	688	100	290	1094	500	861	665	142
12	108	118	137	140	142	177	142	100
13	1347	100	250	910	906	2785	1000	109
14	248	112	302	813	551	3271	1161	100
时间	3.2	2.4	3.3	2.3	2.1	1.0	2.9	2.1

表 3 在基准函数上的最好标准优化结果

ID	ACO	BBO	DE	ES	GA	PBIL	PSO	SGA
1	205	100	178	220	224	325	262	114
2	1711	109	527	544	632	1974	1451	100
3	240	181	576	1081	404	4665	2241	100
4	100	3660	2.67 _{E5}	5.47 _{E7}	6198	1.65 _{E10}	4.05 _{E7}	1090
5	100	4651	3.42 _{E7}	4.69 _{E8}	8.79 _{E5}	2.60 _{E16}	1.13 _{E9}	4878
6	1.64 _{E4}	432	4847	2.50 _{E4}	4378	1.57 _{E5}	3.51 _{E4}	100
7	541	100	502	564	466	798	544	123
8	2012	100	418	615	443	2696	558	103
9	391	174	1344	1209	186	2091	1742	100
10	259	109	571	381	249	597	307	100
11	779	100	374	560	468	1297	670	142
12	100	119	215	174	161	231	188	104
13	1721	115	278	111	751	5196	1445	100
14	279	106	585	1155	530	5595	1580	100

从表 2 可以看出, BBO 和 SGA 算法在 14 个基准函数中有 7 个表现得最好。表 3 列出各个算法的最优结果, 结果表明 SGA 算法在发现函数极小值方面是最有效的, BBO 算法其次, 其中的 4 个结果最好, ACO 算法在 3 个基准上表现最

好。表2中的CPU平均计算时间表明,PBIL算法是最快的优化算法,BBO在8个算法中列第5。不过,在大量现实的工程应用中,适应度函数估计消耗的计算是种群优化算法中代价最大的一部分。

Dan Simon也在文献[7]中表明,实验中没有刻意调整优化算法参数,因为不同的参数值可导致优化算法中性能的大幅变化;其二,验证结果是以基准函数为基础的,基准函数选取的是算法测试中常用的函数;现实优化问题与基准函数关系不大,但对于不同问题相应结果可能会发生改变,出现不同的结论;因此,该实验意在表明算法处理常规优化问题是十分有效的,也表明生物地理学优化算法是一种基于种群的、能够解决工程优化问题的有效算法。

结束语 生物地理学优化算法是一种新颖的优化算法。其独特的机制为智能优化算法研究领域注入了新的理念,而且生物地理学众多的研究成果也将为该算法的进一步研究提供深厚的理论基础。实验结果也表明,该算法在一般优化问题上其性能可靠、有效,在一些问题上其性能超过传统优化算法。这些结果也深层次地表明,生物地理学中的机制是大自然长期进化形成的规律,其在优化问题处理方面是独特、有效的。

此外,如图5所示,生物地理学优化算法的自适应机制不仅存在于生物栖息地迁移过程,在经济学的市场调节机制中的均衡价格形成机制就与BBO中的种群迁徙机制类似。可见这种自适应机制在很多领域中起到了重要作用。这些生物迁徙规律和人类社会中的经济运行机制及其研究成果也可作为优化算法理论有益的补充,为研究优化算法的内在机制提供更多支持。




图5 市场中的均衡价格形成示意图

生物地理学优化算法的研究刚刚起步,其中很多问题没有解决,例如栖息地数量和拓扑结构、迁移模型等因素对算法性能的影响还需要进一步阐释。BBO算法在动态优化问题、多目标优化问题和组合优化问题中的性能如何?如何构建更为有效的机制提高算法效率?这些问题都有待进一步深入研究。

(上接第15页)

- [30] Ma Zhongming, Pant G, Liu Sheng, et al. Interest-based Personalized Search [J]. ACM Transaction on Information Systems, 2007, 25(1)
- [31] Esuli A, Sebastiani F. SentiWordNet: A Publicly Lexical Resource for Opinion Mining [C]// 5th Conference on Language Resources and Evaluation, 2006: 417-422
- [32] Al Masum Shaikh M, Prendinger H, Ishizuka M. SenseNet: A Linguistic Tool to Visualize Numerical-Valance Based Sentiment of Textual Data [C]// Proceedings of 5th International Conference

- [1] 汪定伟. 智能优化方法[M]. 北京: 高等教育出版社, 2007
- [2] Dorigo M, Stutzle T. 蚁群优化[M]. 张军, 译. 北京: 清华大学出版社, 2007
- [3] 段晓东, 王存睿, 刘向东. 粒子群算法及其应用[M]. 沈阳: 辽宁大学出版社, 2007
- [4] Wallace. The Geographical Distribution of Animals [M]. Boston, MA: Adamant Media Corporation, 2005
- [5] Darwin. The Origin of Species [M]. New York: Gramercy, 1995
- [6] MacArthur R, Wilson E. The Theory of Biogeography [M]. Princeton, NJ: Princeton Univ. Press, 1967
- [7] Simon D. Biogeography-based Optimization [J]. IEEE Trans. Evolutionary Computation, 2008, 12(6): 702-713
- [8] Gilpin H M. Meta Population Biology [M]. New York Academic, 1997
- [9] Wesche T, Goertler G, Hubert W. Modified habitat suitability index model for brown trout in southeastern Wyoming [J]. North Amer. J. Fisheries Manage, 1987, 7: 232-237
- [10] Onwubolu G, Babu B. New Optimization Techniques in Engineering [M]. Berlin; Germany: Springer-Verlag, 2004
- [11] Storn R. Differential evolution [J]. Dr. Dobb's Journal, 1997, 22: 18-20
- [12] Storn R. System design by constraint adaptation and differential evolution [J]. IEEE Trans. Evol. Comput, 1999, 3: 22-34
- [13] Michalewicz Z. Genetic Algorithms Data Structures Evolution Programs [M]. New York: Springer, 1992
- [14] Beyer H. The Theory of Evolution Strategies [M]. New York: Springer, 2001
- [15] Mezura-Montes E, Coello C. A simple multimembered evolution strategy to solve constrained optimization problems [J]. IEEE Trans. Evol. Comput, 2005, 9: 1-17
- [16] Parmee I. Evolutionary and Adaptive Computing in Engineering Design [M]. New York: Springer, 2001
- [17] Eberhart R, Shi Y, Kennedy J. Swarm Intelligence [M]. San Mateo, CA: Morgan Kaufmann, 2001
- [18] Eberhart R, Shi Y. Special issue on particle swarm optimization [J]. IEEE Trans. Evol. Comput, 2004, 8(3): 201-228
- [19] Clerc M. Particle Swarm Optimization [M]. Amsterdam, The Netherlands: ISTE Publishing, 2006
- [20] Khatib W, Fleming P. The stud GA: A mini revolution? in Parallel Problem Solving from Nature [M]. New York: Springer, 1998
- rence on Natural Language Processing, Hyderabad, India, 2007: 147-152
- [33] Thomas M, Pang Bo, Lee Lillian. Get out the vote: Determining support or opposition from Congressional floor-debate transcripts [C]// Proceedings of EMNLP, 2006: 327-335
- [34] 姜德成, 姚天防. 汉语句子语义极性分析和观点抽取方法的研究 [J]. 计算机应用, 2006, 26(11): 2643-2625
- [35] 李其维. “认知革命”与“第二代认知科学”刍议 [J]. 心理学报, 2008, 40(12): 1306-1327