



(12) 发明专利申请

(10) 申请公布号 CN 111767977 A

(43) 申请公布日 2020.10.13

(21) 申请号 202010518110.2

(22) 申请日 2020.06.09

(71) 申请人 中国人民解放军国防科技大学  
地址 211101 江苏省南京市江宁区双龙大道双龙街60号

(72) 发明人 单雨龙 赵世军 李秋涵

(74) 专利代理机构 南京瑞弘专利商标事务所  
(普通合伙) 32249

代理人 陈建和

(51) Int. Cl.

G06N 3/00 (2006.01)

G06N 3/12 (2006.01)

G06F 17/15 (2006.01)

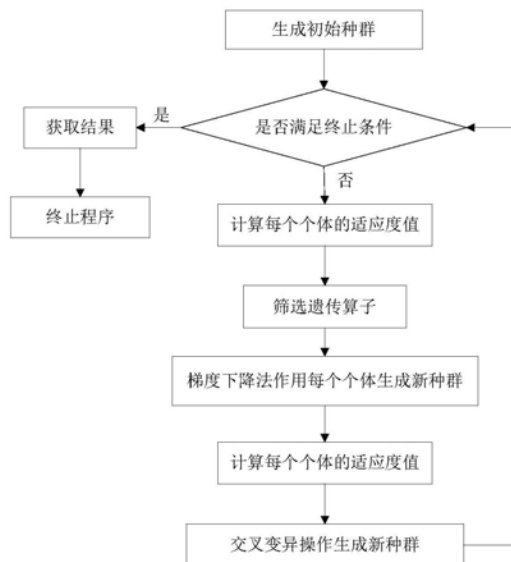
权利要求书2页 说明书13页 附图4页

(54) 发明名称

一种基于改进遗传算法的群粒子梯度下降算法

(57) 摘要

基于改进遗传算法的群粒子梯度下降算法，能快速准确地搜索到复杂函数条件下的全局最优解，群粒子梯度下降算法的步骤：生成初始种群是否满足终止条件、计算每个个体的适应度值；筛选遗传算子，梯度下降法作用每个个体生成新种群，计算每个个体的适应度值，交叉变异操作生成新种群；遗传算法的改进方法是：将种群内适应度值最大的前5个个体保留，剩余的新种群个体以轮盘选择法进行概率选择；将遗传算法的并行计算思想及进化机制引入梯度下降法中，即将原来单个点的寻优改为群体寻优，且不断有新的更接近最优解的种群同时沿着梯度方向寻找最优解。



1. 基于改进遗传算法的群粒子梯度下降算法,其特征是,能快速准确地搜索到复杂函数条件下的全局最优解,群粒子梯度下降算法的步骤:生成初始种群是否满足终止条件、计算每个个体的适应度值;筛选遗传算子,梯度下降法作用每个个体生成新种群,计算每个个体的适应度值,交叉变异操作生成新种群;

遗传算法的改进方法是:将种群内适应度值最大的前5个个体保留,剩余的新种群个体以轮盘选择法进行概率选择;

步骤一:初始化 $P_m, P_c, Num, Gen, maxk$ 参数,随机产生第一代种群 $Pop$ ,其中 $P_c$ 为交叉概率, $P_m$ 为变异概率, $Num$ 为种群规模, $Gen$ 为终止进化的代数, $maxk$ 为梯度下降法最大迭代次数。

步骤二:

初始化遗传进化迭代次数 $k$ ,令 $k=0$ ;

计算种群 $Pop$ 中每一个体的适应度值: $Fitness\_value(i) = fit(Pop(i))$ ,其中 $fit$ 为适应函数, $Fitness\_value(i)$ 为 $Pop$ 种群中第 $i$ 个个体的适应度值;

从种群 $Pop$ 中人工保留适应度值最大的前5个个体,剩余个体根据适应度以比例依照轮盘转法进行选择,产生新种群 $Pop\_new$ ;轮盘选择法的具体操作步骤为:首先对种群 $Pop$ 中每个个体的适应度值进行归一化处理,第 $i$ 个个体归一化后的适应度值记为 $Fitness\_value\_1(i)$ ,满足 $\sum_{i=1}^N Fitness\_value\_1(i) = 1$ , $N$ 为种群 $Pop$ 中的个体个数;其次计算每个个体被选择的概率区间,用累加的方式,如第 $j$ 个个体被选择的概率区间为:

$[\sum_{i=1}^{j-1} Fitness\_value\_1(i), \sum_{i=1}^j Fitness\_value\_1(i)]$ ;最后随机生成一个0-1之间的数,数字落在哪个区间即保留哪个个体;

初始化梯度下降迭代次数 $kk$ ,令 $kk=0$ ;

当 $kk \leq maxk$

梯度下降法作用种群 $Pop\_new$ 中每个个体,产生新的种群 $Pop\_new\_new$ ,且计算种群 $Pop\_new\_new$ 中每个个体的适应度值: $Fitness\_value(i) = fit(Pop\_new\_new(i))$ ,此时 $Fitness\_value(i)$ 为 $Pop\_new\_new$ 种群中第 $i$ 个个体的适应度值;记录适应度值最大的个体;

对种群 $Pop\_new\_new$ 执行交叉变异操作,形成新的 $Pop\_new\_new$ 种群,用新的 $Pop\_new\_new$ 取代 $Pop$ 。交叉操作步骤为:首先针对每一个染色体,随机生成一个0至1之间的数,若生成的数字不大于交叉概率 $P_c$ ,则该染色体被选中用于后期的交叉操作;其次将选中的染色体两两随机配对,若每个个体的染色体长度记为 $M$ ,针对每一组两两配对的染色体,均随机生成一个1至 $M$ 的整数 $m$ ,两个染色体中 $m$ 至 $M$ 之间的基因序列进行交换,完成交叉操作,形成新种群;变异操作步骤为:首先将种群中的所有基因进行排序,记共 $T$ 个基因;随机生成 $T$ 个0至1之间的数,若随机数小于变异概率 $P_m$ ,则其对应的基因进行变异操作,即原有基因值取反,形成新的种群;

步骤三:输出适应度值最大的个体。

2. 根据权利要求1所述的基于改进遗传算法的群粒子梯度下降算法,其特征是,利用群粒子梯度下降算法寻找测试函数最优解,测试函数的解析式如下,

$$f(x, y) = \frac{\sin(x - 7)}{(x - 7)^2 + 1} \times \frac{\sin(y - 7)}{(y - 7)^2 + 1}$$

设置群粒子梯度下降算法中的结果精度为0.0001,种群规模为50,交配概率为0.24,遗传算法迭代上限和梯度下降迭代上限均为10,梯度下降步长为3,梯度下降收敛精度为0.00001;进行N次基于群粒子梯度下降算法的寻优实验;将遗传算法的并行计算思想及进化机制引入梯度下降法中,即将原来单个点的寻优改为群体寻优,且不断有新的更接近最优解的种群同时沿着梯度方向寻找最优解。

3. 根据权利要求2所述的基于改进遗传算法的群粒子梯度下降算法,设置遗传算法的种群规模为100,结果精度为0.0001,交配概率为0.24,迭代次数上限为200,利用MATLAB软件自带rand函数随机生成指定区间内的数值作为初始种群。

## 一种基于改进遗传算法的群粒子梯度下降算法

### 技术领域

[0001] 本发明涉及一种决策和选址方面的寻优方法,涉及函数寻优算法,尤其能求解复杂函数条件下的寻优问题。

### 背景技术

[0002] 人工智能网络训练、自动控制、模式识别等领域多目标规划问题范围极广,其中如决策和选址方面的寻优方法在现实中极有意义:如救援基地选址问题。救援基地选址需 考虑到救援距离、救援时间、建设成本、建设可行性等问题,该问题属于多目标规划 问题,可建立与其目标相一致的适应函数,根据该适应函数中的底层参数变量,如救援 点位置,可用于求解救援距离、救援时间、建设成本、建设可行性等需求目标值。底层 参数变量具有自己的取值范围,基于改进遗传算法的群粒子梯度下降算法可用于求解各 一个底层参数变量的最优化组合,使得适应函数的取值最优。

[0003] 选址方面的寻优应用场景极宽,如电动汽车充电站寻址;又如城市换乘枢纽的寻 址, 以及一些具有公共用品的集散寻址等。各种寻址中,如救援基地选址问题属于多目标 规划问题,基于改进遗传算法的群粒子梯度下降算法相较于传统算法可更快更准的求解 多 目标规划问题。而多目标规划问题涉及到人工智能网络训练、自动控制、模式识别、工 程设计及智能故障诊断等各个领域,因此本发明具有较强的应用潜力及科学价值。

[0004] 人工神经网络技术是当前最热门的技术之一,而算法是人工智能技术的核心。倘 若 将人工智能比作计算机模拟人类的思维活动,那么为实现机器智能思索所构建的结构 体 则可类比为人类的思维结构,而智能算法则可类比为人类的思维方法。尽管目前已有 多种算法可达到智能搜索目的,但算法之间在收敛速度、搜索范围、收敛到全局最优解的 成功率等方面仍有较大差异。与此同时,随着现代人工智能网络结构越来越复杂,当前 算法在收敛速度以及收敛到全局最优解的成功率上越加不能够满足科技和生产日益发 展提出的新时代要求。目前已有多种算法被提出用于求解函数寻优问题,如遗传算法、 蚁群算法、粒子群算法、模拟退火算法及梯度下降算法等。遗传算法是最常用的智能搜 索算法,是 Holland 于 1975 年提出。随后,很多学者对其进行了改进,主要改进领域 涉及遗传选择策略、适应度函数设计、遗传算子及控制参数等。由于遗传算法不受优化 函数的连续性约束,且并行计算能力强,具有较好的全局搜索能力,因此该算法是最为 广泛应用的智能搜索算法之一,目前该算法已被应用于自动控制、计算科学、模式识别、 工程设计及智能故障诊断等领域。但由于遗传算法在搜索过程中需要进行大量的计算, 因此会比较费时。M. Dorigo 等人于 1996 年借鉴真实蚁群搜索食物的行为提出了人工蚁 群算法。该算法最早应用于旅行商 (TSP) 问题,并取得了较好的效果。随后中外学者 在信息素调整策略、搜索策略等方面对其进行了改进,有效提高了算法的性能,并将其 应用范围拓展到作业调度、数据挖掘等领域。但由于初始信息素缺乏,需要较长的搜索 时间,故该算法收敛速度慢。同时,该算法搜索到一定程度后,所有个体的解完全一致, 不能对空间进行进一步搜索,易陷入局部最优。Kenney 与 Eberhart 借鉴自然界鸟群觅 食行为提出一种基于群体协作的随机搜索算法-

粒子群算法。由于该算法结构构造简单、需要调节的参数较少,因此受到了很多学者的关注。目前该算法已经被成功的应用到求解多目标优化问题、非线性整数和混合整数约束优化问题、信号处理和神经网络训练等。尽管很多学者对粒子群算法进行了改进,但其理论基础仍旧薄弱,且该算法易陷入局部最优,因此该算法还存在许多需要改进的地方。Metropolis借鉴物理中固体退火过程提出了模拟退火算法,后人将其应用至组合优化问题。尽管很多学者在退火策略、搜索结构、初始状态及控温方式上对模拟退火算法进行了改进,但其降温的速度始终与算法收敛到全局最优解的概率存在较大的矛盾。数学家Cauchy于1847年提出一种经典数值优化算法—梯度下降法,至今其仍为机器学习领域的核心算法之一。但由于该算法是一种局部搜索算法,因此不适用于求解复杂非线性优化问题。因此,以上算法均不能同时具备较快的收敛速度以及较强的全局搜索能力,而这种特性正是搜索算法未来的发展方向,并且以上固有算法均存在较大的概率收敛到局部最优解。为解决固有算法存在的复杂函数求解条件下的收敛速度慢、收敛到全局最优解的成功率不高的问题,本发明首先对遗传算法进行改进,提高该算法的全局搜索能力及收敛速度。其次在充分挖掘遗传算法的全局搜索能力以及梯度下降法的快速收敛能力的基础上,提出一种基于改进遗传算法的群粒子梯度下降算法。

## 发明内容

[0005] 本发明目的是,提出一种多目标规划问题的求解,包括决策和选址方面的寻优方法;尤其是利用基于改进遗传算法的群粒子梯度下降算法应用于多目标规划问题的求解,即对决策和选址方面进行寻优的方法。

[0006] 本发明的技术方案是,基于改进遗传算法的群粒子梯度下降算法,其特征是,能快速准确地搜索到复杂函数条件下的全局最优解,群粒子梯度下降算法的步骤:生成初始种群是否满足终止条件、计算每个个体的适应度值;筛选遗传算子,梯度下降法作用每个个体生成新种群,计算每个个体的适应度值,交叉变异操作生成新种群;

[0007] 遗传算法的改进方法是:将种群内适应度值最大的前5个个体保留,剩余的新种群个体以轮盘选择法进行概率选择;

[0008] 步骤一:初始化 $P_m, P_c, Num, Gen, maxk$ 参数,随机产生第一代种群 $Pop$ ,其中 $P_c$ 为交叉概率, $P_m$ 为变异概率, $Num$ 为种群规模, $Gen$ 为终止进化的代数, $maxk$ 为梯度下降法最大迭代次数。

[0009] 步骤二:

[0010] 初始化遗传进化迭代次数 $k$ ,令 $k=0$ ;

[0011] 计算种群 $Pop$ 中每一个体的适应度值: $Fitness\_value(i) = fit(Pop(i))$ ,其中 $fit$ 为适应函数, $Fitness\_value(i)$ 为 $Pop$ 种群中第 $i$ 个个体的适应度值;

[0012] 从种群 $Pop$ 中人工保留适应度值最大的前5个个体,剩余个体根据适应度以比例依照轮盘转法进行选择,产生新种群 $Pop\_new$ ;轮盘选择法的具体操作步骤为:首先对种群 $Pop$ 中每个个体的适应度值进行归一化处理,第 $i$ 个个体归一化后的适应度值记为 $Fitness\_value\_1(i)$ ,满足 $\sum_{i=1}^N Fitness\_value\_1(i) = 1$ , $N$ 为种群 $Pop$ 中的个体个数;其次计算每个个体被选择的概率区间,用累加的方法 $[\sum_{i=1}^{j-1} Fitness\_value\_1(i), \sum_{i=1}^j Fitness\_value\_1(i)]$ ;

最后随机生成一个0-1之间的数，数字落在哪个区间即保留哪个个体。

[0013] 初始化梯度下降迭代次数kk,令kk=0;

[0014] 当kk≤maxk

[0015] 梯度下降法作用种群Pop\_new中每个个体,产生新的种群Pop\_new\_new,且计算种群Pop\_new\_new中

[0016] 每个个体的适应度值:  $Fitness\_value(i) = fit(Pop\_new\_new(i))$ ,此时  $Fitness\_value(i)$  为Pop\_new\_new

[0017] 种群中第i个个体的适应度值;记录适应度值最大的个体;

[0018] 对种群Pop\_new\_new执行交叉变异操作,形成新的Pop\_new\_new种群,用新的Pop\_new\_new取代Pop。交叉操作步骤为:首先针对每一个染色体,随机生成一个0至1之间的数,若生成的数字不大于交叉概率Pc,则该染色体被选中用于后期的交叉操作;其次将选中的染色体两两随机配对,若每个个体的染色体长度记为M,针对每一组两两配对的染色体,均随机生成一个1至M的整数m,两个染色体中m至M之间的基因序列进行交换,完成交叉操作,形成新种群;变异操作步骤为:首先将种群中的所有基因进行排序,记共T个基因;随机生成T个0至1之间的数,若随机数小于变异概率Pm,则其对应的基因进行变异操作,即原有基因值取反,形成新的种群;

[0019] 步骤三:输出适应度值最大的个体。

[0020] 利用群粒子梯度下降算法寻找测试函数最优解,测试函数的解析式如下,X、Y没有具体意义,仅是测试函数,

$$[0021] \quad f(x,y) = \frac{\sin(x-7)}{(x-7)^2+1} \times \frac{\sin(y-7)}{(y-7)^2+1}$$

[0022] 设置群粒子梯度下降算法中的结果精度为0.0001,种群规模为50,交配概率为0.24,遗传算法迭代上限和梯度下降迭代上限均为10,梯度下降步长为3,梯度下降收敛精度为0.00001;进行N次基于群粒子梯度下降算法的寻优实验。将遗传算法的并行计算思想及进化机制引入梯度下降法中,即将原来单个点的寻优改为群体寻优,且不断有新的更接近最优解的种群同时沿着梯度方向寻找最优解。

[0023] 每次实验下的每一次迭代结束后的收敛情况见实施方式的表。基于群粒子梯度下降算法进行寻优的过程中,只需1次遗传迭代便可以寻找到函数最优解,不仅大大减少了遗传迭代次数,而且极大提高了搜索到全局最优解的成功率。

[0024] 改进后的选择机制不仅能保证以适应度值为参考标准的概率选择机制的正常运作,同时能够保证种群中最优个体一定能够被保留下来进行遗传操作,加快进化速度。同时,将遗传算法的并行计算思想及进化机制引入梯度下降法中,即将原来单个点的寻优改为群体寻优,且不断有新的更接近最优解的种群同时沿着梯度方向寻找最优解。

[0025] 开展了两次寻优实验用于验证新算法相对传统遗传算法和改进后的遗传算法的优越性。

[0026] 设置遗传算法的种群规模为100,结果精度为0.0001,交配概率为0.24,迭代次数上限为200,本实验利用MATLAB软件自带rand函数随机生成指定区间内的数值作为初始种群。

[0027] 筛选机制改进前后每一次实验的收敛情况。可得,若不改变原有的轮盘选择法,在

200次迭代完成后,30次实验中仅有9次实验收敛到了最优解,成功率仅有30%,且收敛到最优解的平均所需迭代次数为117次;若将人工选择与轮盘选择相结合,则200次迭代范围内收敛到最优解的成功率达到96.7%,且收敛到最优解的平均所需迭代次数仅为39次,极大改善了原有算法的寻有效率。

[0028] 有益效果:传统的遗传算法以轮盘选择法为筛选机制,是一种完全基于适应度值的概率选择机制。本发明将人工选择与概率选择相结合,即将种群内适应度值最大的前5个个体通过人为的方式进行保留,剩余的个体以轮盘选择法进行概率选择。改进后的选择机制不仅能保证以适应度值为参考标准的概率选择机制的正常运作,同时能够保证最优个体一定能够被保留下来进行遗传操作,加快进化速度。同时,将遗传算法的并行计算思想及进化机制引入梯度下降法中,即将原来单个点的寻优改为群体寻优,且不断有新的更接近最优解的种群同时沿着梯度方向寻找最优解。

[0029] 由于群粒子梯度下降算法是遗传算法和梯度下降法的有机结合,每一次的遗传迭代过程均对种群中的每个个体进行了梯度下降计算,因此尽管群粒子梯度下降算法的遗传迭代次数大大减少,但总迭代次数增多。由于梯度下降算法的收敛速度比遗传算法的收敛速度快很多,且其收敛速度也可以通过改变步长来调节,因此尽管群粒子梯度下降算法的总迭代次数高于遗传算法迭代次数,两种算法收敛到最优解的时间却相差不大。

[0030] 综上,基于人工选择与概率选择相结合的遗传选择机制相比于传统的轮盘法选择机制拥有较大的优势,不仅加快了遗传算法的收敛速度,同时使算法收敛到最优解的成功率大大提升。并且,基于改进遗传算法的群粒子梯度下降算法相比遗传算法也拥有较为明显的优势,主要表现为大大提高了算法收敛到最优解的概率。同时,群粒子梯度下降算法也可以通过调节梯度下降的迭代次数和步长来调节算法的收敛速度。

[0031] 本发明是基于传统遗传算法及梯度下降法技术思路,提出了一种遗传算法改进思路及群粒子梯度下降算法。经实验验证,相较于固有的遗传算法,改进后的算法及新的群粒子梯度下降算法拥有更快的收敛速度及更高的收敛到全局最优解的概率,为求解函数寻优问题提供了新的技术参考。函数寻优问题涉及到人工智能网络训练、自动控制、模式识别、工程设计及智能故障诊断等各个领域,因此本发明具有较强的应用潜力及科学价值。

## 附图说明

[0032] 图1为本发明的算法流程图;

[0033] 图2为本发明对一测试函数在定义域内的示意图(a)及最小值(b)位置;

[0034] 图3为本发明的算法流程图;在筛选机制改进前后条件下利用遗传算法各做30次寻优实验,遗传算法筛选机制改进之后的每一次实验下的收敛过程见图3(a),遗传算法筛选机制改进之前的每一次实验下的收敛过程见图3(b)。

[0035] 图4为schaffer测试函数在此定义域内的示意图(a)及最小值(b)位置。

## 具体实施方式

[0036] 算法流程图见附图1,算法伪代码如下:

## 群粒子梯度下降法伪代码

步骤一：初始化 P\_m, P\_c, Num, Gen, maxk 等参数，随机产生第一代种群 Pop，其中 P\_c 为交叉概率，P\_m 为变异概率，Num 为种群规模，Gen 为终止进化的代数，maxk 为梯度下降法最大迭代次数。

步骤二：

K=1 //初始化迭代次数

While (k<=Gen) do

{计算种群 Pop 中每一个体的适应度}

do

{从种群 Pop 中人工保留适应度值最大的前 5 个个体，剩余个体根据适应度以比例依照轮盘转法进行选择，产生新种群 Pop\_new}

kk=0 //初始化迭代次数

While (kk<=maxk) do

{梯度下降法作用种群 Pop\_new 中每个个体，产生新的种群 Pop\_new\_new，且计算种群 Pop\_new\_new 中每个个体的适应度值，记录适应度值最大的个体}

kk=kk+1

End

If (rand(0, 1) < P\_c) do

{对 2 个个体按交叉概率 P\_c 执行交叉操作}

End

If (rand(0, 1) < P\_m) do

{对种群按变异概率 P\_m 执行变异操作}

end

do

{将新个体加入种群 Pop\_new\_new 中，用种群 Pop\_new\_new 取代 Pop}

K=K+1

End

步骤三：输出适应度值最大的个体

[0037]

[0038]

[0039] 开展了两次寻优实验用于验证新算法相对传统遗传算法和改进后的遗传算法的优越性。

[0040] 实验一：测试函数的解析式如下，

$$[0041] \quad f(x,y) = \frac{\sin(x-7)}{(x-7)^2+1} \times \frac{\sin(y-7)}{(y-7)^2+1}$$



[0042] 目的为寻找该函数在 $x, y \in [0, 10]$ 范围内的最小值。已知该函数在 $[0, 10]$ 区间范围内的最小值为 $-0.1913$ ,此时 $x=7.7984, y=6.2019$ 或 $x=6.2019, y=7.7984$ 。该函数在定义域内的示意图及最小值位置见附图2。

[0043] 设置遗传算法的种群规模为100,结果精度为0.0001,交配概率为0.24,迭代次数上限为200,本实验利用MATLAB软件自带rand函数随机生成指定区间内的数值作为初始种群。为避免实验结果的随机性对算法性能的影响,在筛选机制改进前后条件下利用遗传算法各做30次寻优实验,遗传算法筛选机制改进之后的每一次实验下的收敛过程见附图3(a),遗传算法筛选机制改进之前的每一次实验下的收敛过程见附图3(b)。

[0044] 下表为筛选机制改进前后每一次实验的收敛情况。可得,若不改变原有的轮盘选择法,在200次迭代完成后,30次实验中仅有9次实验收敛到了最优解,成功率仅有30%,且收敛到最优解的平均所需迭代次数为117次;若将人工选择与轮盘选择相结合,则200次迭代范围内收敛到最优解的成功率达到96.7%,且收敛到最优解的平均所需迭代次数仅为39次,极大改善了原有算法的寻有效率。

[0045]

实验次数	筛选机制改进前		筛选机制改进后	
	是否收敛到最优解	收敛到最优解所需迭代次数	是否收敛到最优解	收敛到最优解所需迭代次数
1	Yes	200	Yes	20
2	No	---	Yes	16
3	No	---	Yes	48
4	No	---	Yes	37
5	Yes	57	Yes	19
6	No	---	Yes	40
7	No	---	Yes	25
8	No	---	Yes	32
9	Yes	70	Yes	5
10	No	---	Yes	25
11	No	---	Yes	3
12	Yes	110	Yes	40
13	No	---	Yes	14
14	No	---	No	---
15	No	---	Yes	188
16	No	---	Yes	25
17	No	---	Yes	52
18	Yes	45	Yes	10
19	Yes	188	Yes	25
20	No	---	Yes	14
21	Yes	110	Yes	15
22	No	---	Yes	13
23	Yes	140	Yes	21
24	No	---	Yes	11

[0046]	25	No	---	Yes	47
	26	Yes	133	Yes	45
	27	No	---	Yes	57
	28	No	---	Yes	91
	29	No	---	Yes	31
	30	No	---	Yes	167
	收敛到最优解所需迭代次数平均	117		39	
	200次迭代范围内收敛到最优解的成功率	30%		96.7%	

[0047] 下面利用群粒子梯度下降算法寻找测试函数最优解。设置群粒子梯度下降算法中的结果精度为0.0001,种群规模为50,交配概率为0.24,遗传算法迭代上限和梯度下降迭代上限均为10,梯度下降步长为3,梯度下降收敛精度为0.00001。为避免实验结果的随机性对算法性能的影响,进行了30次基于群粒子梯度下降算法的寻优实验。每次实验下的每一次迭代结束后的收敛情况见下表。可得,基于群粒子梯度下降算法进行寻优的过程中,只需1次遗传迭代便可以寻找到函数最优解,不仅大大减少了遗传迭代次数,而且极大提高了搜索到全局最优解的成功率。

实验次数	是否收敛到最优解	收敛到最优解所需遗传迭代次数
1	Yes	1
2	Yes	1
3	Yes	1
4	Yes	1
5	Yes	1
6	Yes	1
7	Yes	1

[0049]

8	Yes	1
9	Yes	1
10	Yes	1
11	Yes	1
12	Yes	1
13	Yes	1
14	Yes	1
15	Yes	1
16	Yes	1
17	Yes	1
18	Yes	1
19	Yes	1
20	Yes	1
21	Yes	1
22	Yes	1
23	Yes	1
24	Yes	1
25	Yes	1
26	Yes	1
27	Yes	1
28	Yes	1
29	Yes	1
30	Yes	1
收敛到最优解 所需迭代次数平均	1	
10次遗传迭 代范围内收敛到最 优解的成功率	100%	

[0050] 下表为改进前后的遗传算法与群粒子梯度下降算法寻找到最优解所需时间的比较。为避免实验结果的随机性对算法性能的影响,分别基于三种算法进行30次寻优实验。

为更好的观察三种算法寻找最优解的效率,将遗传算法的最大迭代次数设为500,即若经过500次迭代仍没有找到最优解,则重新开始当次实验。为加快群粒子梯度下降法的收敛速度,将梯度下降的迭代上限设为5,步长仍为3。用于计算的电脑处理器为 i3-3227U,电脑运行内存为4G。由下表可得,筛选机制改进后的遗传算法相比筛选机制改进前的遗传算法在寻找最优解的时间效率上有了较大的提升。同时,尽管群粒子梯度下降算法的总迭代次数高于遗传算法迭代次数,但由于梯度下降算法拥有非常快的收敛速度,故两者在寻找最优解所耗费的时间上差别不大。

[0051]

实验次数	群粒子梯度下降算法 所需时间 (s)	改进后的遗传算法所 需时间 (s)	改进前的遗传算法 所需时间 (s)
1	3.74	3.84	18.24
2	2.77	2.29	18.17
3	2.59	5.00	15.33
4	3.21	1.01	11.58
5	2.68	0.28	6.97
6	5.61	2.61	30.00
7	8.70	2.40	13.91
8	13.68	3.63	13.72
9	4.09	2.40	4.02
10	1.91	2.04	12.68
11	4.20	4.65	12.94
12	5.87	2.58	28.72
13	8.16	1.00	7.37
14	5.25	0.86	17.35
15	4.76	1.00	14.91
16	3.99	3.26	12.88
17	2.06	1.81	12.55

	18	7.78	4.07	30.89
	19	1.90	1.78	21.43
	20	6.54	0.28	26.74
	21	5.91	1.89	15.80
	22	1.92	2.04	16.14
	23	1.91	11.95	15.76
	24	2.97	2.20	22.19
[0052]	25	2.29	1.62	10.31
	26	2.60	1.83	16.68
	27	2.31	0.56	15.11
	28	4.36	1.57	2.43
	29	2.74	1.57	7.06
	30	6.19	3.37	12.82
	平均时间 (s)	4.42	2.51	15.49

[0053] 实验二:测试函数为schaffer函数,解析式如下

$$[0054] \quad f(x,y) = 0.5 + \frac{(\sin\sqrt{x^2 + y^2})^2 - 0.5}{(1 + 0.001 \times (x^2 + y^2))^2}$$

[0055] 目的为寻找该函数在 $x, y \in [-10, 10]$ 范围内的最小值。已知该函数在此区间范围内的最小值为0,最小值对应的 $x$ 值和 $y$ 值均为0。该schaffer函数在此定义域内的示意图及最小值位置见附图4。

[0056] 基于实验一同样的软硬件条件,利用改进前后的遗传算法及群粒子梯度下降算法分别独立地对schaffer函数进行30次寻优实验。设置遗传算法的种群规模为100,结果精度为0.0001,交配概率为0.24。由于实验二的寻优难度相比实验一要困难,因此将遗传算法的迭代次数上限为500;设置群粒子梯度下降算法中的结果精度为0.0001,种群规模为100,交配概率为0.48,遗传算法迭代上限为10,梯度下降迭代上限为40,梯度下降步长为0.1,梯度下降收敛精度为0.00001。下表为改进前后的遗传算法及群粒子梯度下降算法每一次的实验结果,可得,在30次寻优实验中,筛选机制改进后的遗传算法收敛到schaffer函数最小值的成功率为10%,筛选机制改进前的成功率为7%。两种算法收敛到最优解的平均所需迭代次数分别为322和324次。可知,由于目标函数较为复杂,遗传算法收敛到最优解的成功率大大降低,且收敛到最优解的平均所需迭代次数也较高。同时,群粒子梯度下降法收敛到最小值的成功率可以达到93.3%,且平均所需的遗传迭代次数仅为1,相比

于改进后的遗传算法拥有较大的优势。

[0057]

实验次数	群粒子梯度下降算法		筛选机制改进前		筛选机制改进后	
	是否收敛到最优解	收敛到最优解所需迭代次数	是否收敛到最优解	收敛到最优解所需迭代次数	是否收敛到最优解	收敛到最优解所需迭代次数
1	Yes	1	No	---	No	---
2	Yes	1	No	---	No	---
3	Yes	1	No	---	No	---
4	Yes	1	No	---	Yes	150
5	Yes	1	Yes	293	No	---
6	Yes	1	No	---	No	---
7	Yes	1	No	---	No	---
8	Yes	1	No	---	No	---
9	Yes	2	No	---	Yes	325
10	No	---	No	---	Yes	496
11	Yes	1	No	---	No	---
12	Yes	1	No	---	No	---
13	Yes	1	No	---	No	---
14	Yes	1	No	---	No	---
15	Yes	1	No	---	No	---

[0058]

16	Yes	1	No	---	No	---
17	Yes	1	No	---	No	---
18	Yes	1	No	---	No	---
19	Yes	1	No	---	No	---
20	Yes	1	No	---	No	---
21	No	---	No	---	No	---
22	Yes	1	No	---	No	---
23	Yes	1	No	---	No	---
24	Yes	2	Yes	350	No	---
25	Yes	1	No	---	No	---
26	Yes	1	No	---	No	---
27	Yes	1	No	---	No	---
28	Yes	1	No	---	No	---
29	Yes	1	No	---	No	---
30	Yes	1	No	---	No	---
收敛到最优解所需迭代次数平均		1		322		324
收敛到最优解的成功率		93.3%		7%		10%

[0059] 由于遗传算法收敛到schaffer函数最小值的概率很低,因此本发明不将这三种算法收敛到最优解的时间进行比较。



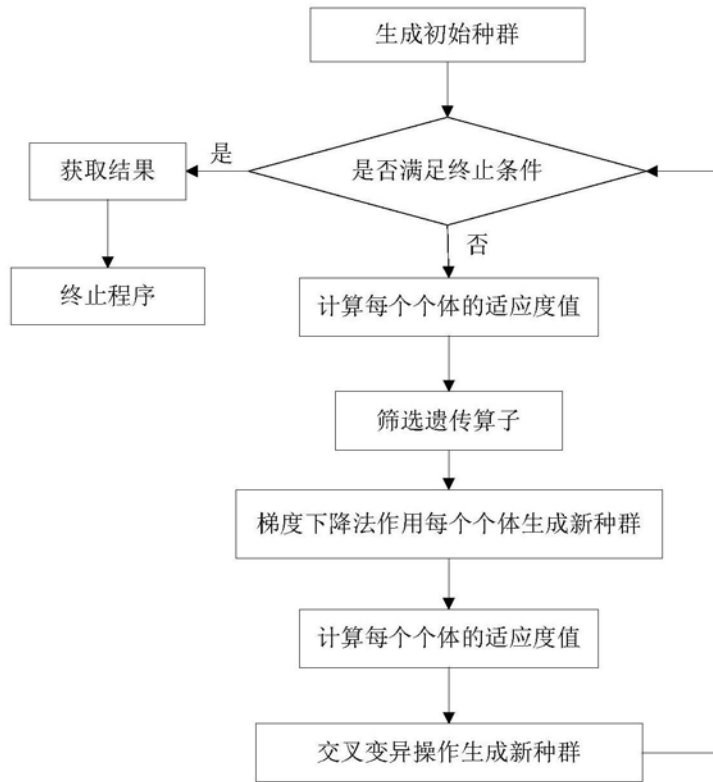


图1

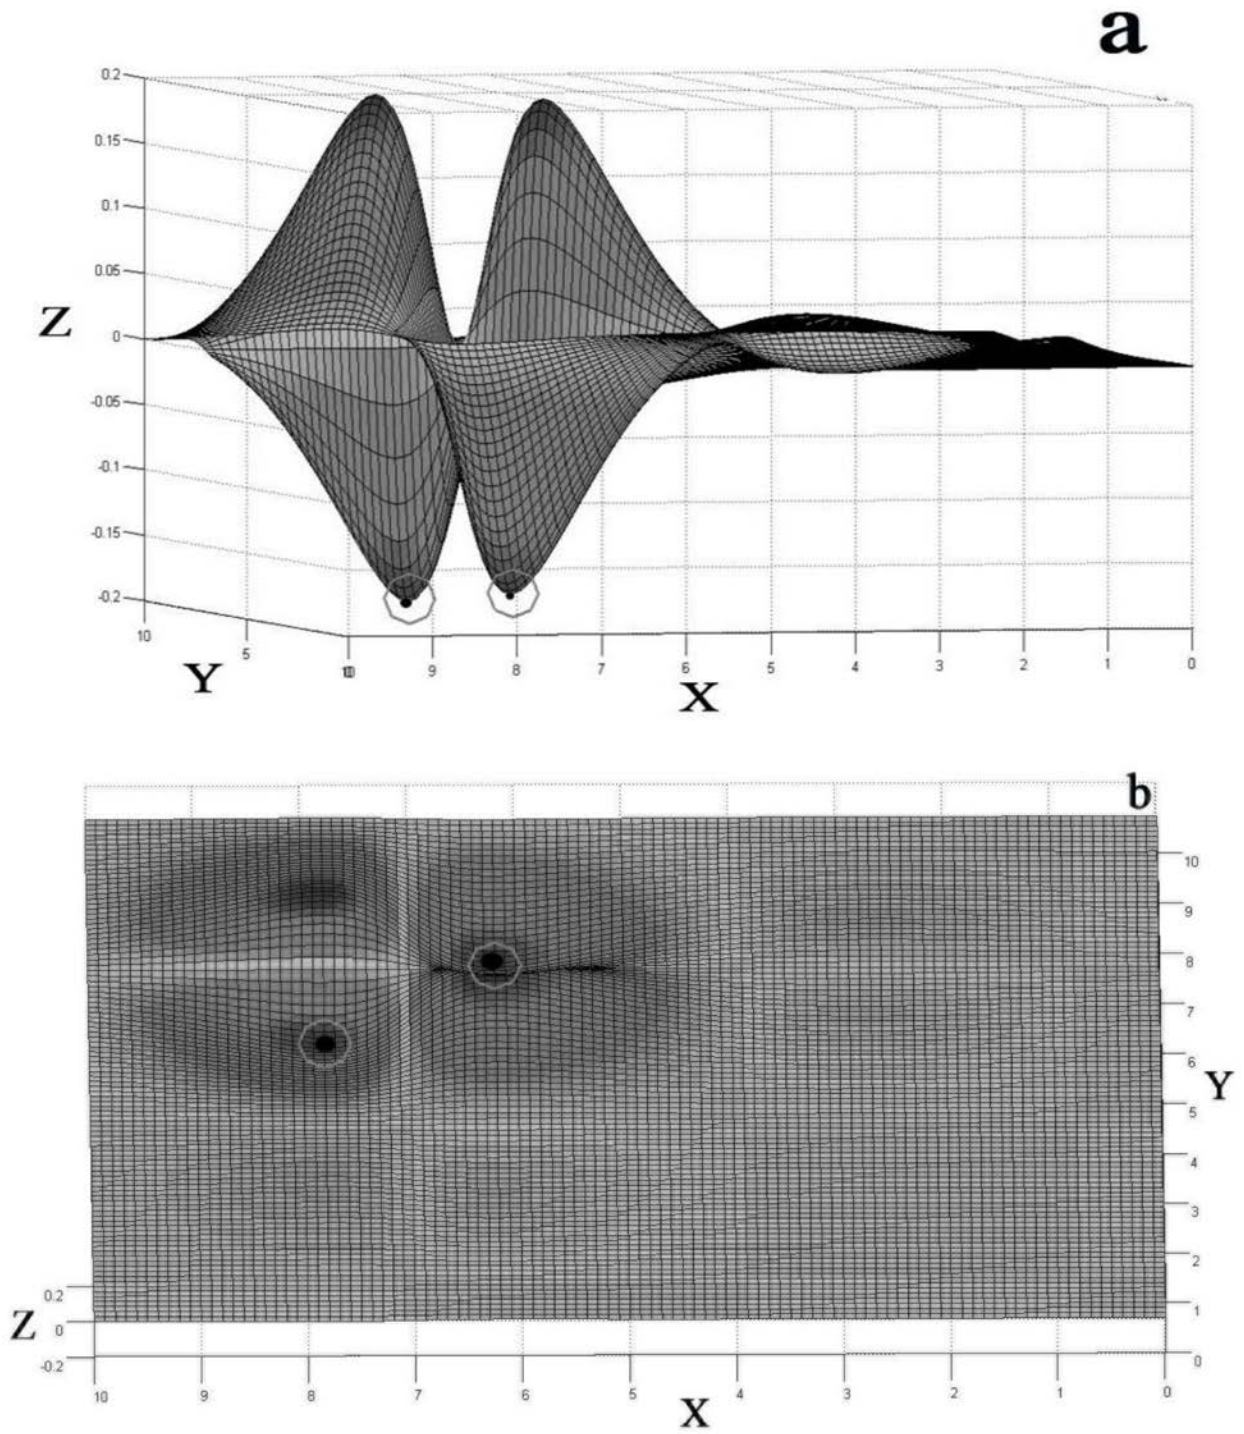


图2

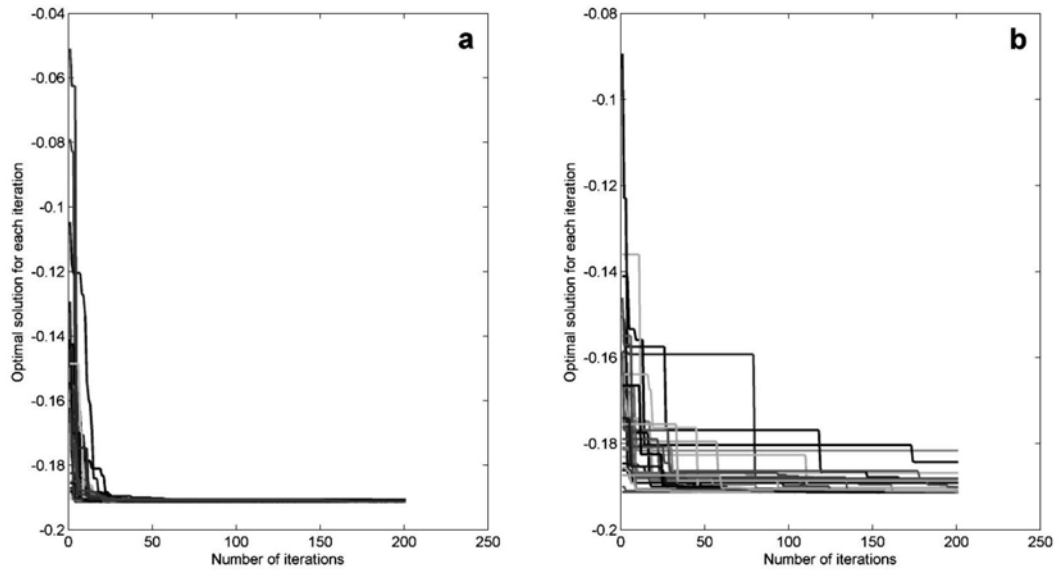


图3




图4