

析因-粒子群算法及其在海上运动目标搜寻中的应用

吕进锋^{1,2,3,4}, 赵怀慈^{1,3†}

(1. 中国科学院 沈阳自动化研究所, 沈阳 110016; 2. 中国科学院大学, 北京 100049; 3. 中国科学院 光电信息处理重点实验室, 沈阳 110016; 4. 河南科技大学 信息工程学院, 河南 洛阳 471023)

摘 要: 针对粒子群算法在处理多峰复杂函数优化问题时容易陷入局部极值,难以满足海上运动目标搜寻问题的需要,提出一种基于析因思想的改进粒子群算法. 所提算法结合种群智能思想与析因实验设计思想,利用随机化及区组化策略,设计参数在不同水平的组合,并得到相应的适应度值,获取各个参数的适应度曲线;分析各参数变化对适应度值的影响以及参数间的交互作用,基于此获取解空间形态;针对不同参数采用不同策略,利用种群迭代寻找全局最优解,使种群针对交互作用明显的参数侧重于全局搜索,针对交互作用不明显的参数侧重于局部搜索;最后将所提算法应用于海上运动目标搜寻问题,实验结果表明,相较其他几种对比算法,所提出的算法能够有效制定更优的搜寻计划.

关键词: 析因; 粒子群; 群智能; 优化; 海上搜寻; 运动目标

中图分类号: TP18

文献标志码: A

Factorial-based particle swarm optimization and its application to maritime moving target search

LYU Jin-feng^{1,2,3,4}, ZHAO Huai-ci^{1,3†}

(1. Shenyang Institute of Automation, Chinese Academy of Sciences, Shenyang 110016, China; 2. University of Chinese Academy of Sciences, Beijing 100049, China; 3. Key Laboratory of Opto-Electronic Information Processing, Chinese Academy of Sciences, Shenyang 110016, China; 4. School of Information Engineering, Henan University of Science and Technology, Luoyang 471023, China)

Abstract: When dealing with complex multimodal function optimization problems, the particle swarm optimization(PSO) algorithm trends to trap in local extreme. Aiming at the problem that it is hard for the PSO algorithm to meet the requirements of maritime moving target search, a factorial-based particle swarm optimization algorithm is presented, which combines swarm intelligence with factorial experiment design and employs the ideas of randomization and blocking. By designing multi combinations of parameters with different values and calculating the fitness value of each combination, the fitness curves of each parameter can be obtained. This algorithm analyzes the impact of each parameter on the fitness and the interaction between different parameters. Based on that, the shapes of solution spaces can be acquired, and the population can employ different strategies for different parameters to search for the global optima. For the parameters with significant interaction, the population will focus on global search. For the parameters with insignificant interaction, the population will focus on local search. Finally, this paper applies the proposed algorithm to solve maritime moving target search problems. The experimental results show that compared with other algorithms, the proposed algorithm can generate better search plans effectively.

Keywords: factorial; particle swarm; swarm intelligence; optimization; maritime search; moving target

0 引 言

在海上运动目标搜寻问题中,由于目标位置在任务执行期间会发生较大改变,目标的运动特性往往造成问题相应的解空间呈现为复杂的多峰形态.因此,为搜寻单位制定高质量的搜寻计划具有较大

难度.美国海上搜救最优规划系统(SAROPS)^[1]中的PLANNER模块在获取目标位置信息基础上,采用启发式方法为搜寻单位制定搜寻计划并确定搜寻路线;加拿大搜救系统(CANSAR)^[2]采用min/max方法生成搜寻区域;挪威搜救中心的Nassirou等^[3-5]能够为

收稿日期: 2017-06-19; 修回日期: 2018-03-05.

责任编辑: 孙秋野.

作者简介: 吕进锋(1990—),女,博士生,从事智能算法及其应用的研究;赵怀慈(1974—),男,研究员,博士,从事图像处理、人工智能等研究.

†通讯作者. E-mail: hczhao@sia.cn

搜寻单位制定精确的搜寻路径,但该方法生成的搜寻路径是不受约束的不规则路径,其没有考虑实际工作环境,搜寻单位在实际搜寻任务中难以按照其生成的搜寻路径执行搜寻.

粒子群算法是一种基于种群的随机优化方法,由于其机理简单、容易实现,自提出以来就被成功应用于多种实际优化问题^[6-8].然而,应用粒子群算法解决海上运动目标搜寻问题时,由于解空间为复杂多峰形态,算法极易陷入局部极值,出现早熟现象,从而无法为搜寻单位生成高质量的搜寻计划.针对该算法特点,研究者提出增加粒子群规模、引入早熟判断机制确定种群的局部的搜索范围^[9]、利用混沌搜索的全局搜索能力克服粒子群算法易陷入局部最优的缺陷^[10-11]、重组个体认知与社会认知以增加个体创造性思维能力^[12]等策略,这些改进在一定程度上可提高算法质量.但是,当优化问题的复杂程度较高时,已有算法在寻优质量和优化速度上依然不尽如人意.

本文借鉴确定性优化方法的思路,将实验设计中的随机化及区组化思想引入粒子群算法,分析各个因素对适应度值的影响.具体策略为:针对各个参数,随机生成其余参数为不同值的多个组合,分析参数变化对适应度值的影响,利用搜索过程中所得解分析解空间形态.根据参数对适应度值的影响,将参数分为异常因素、普通因素.分析因素间的交互作用,得到适应度值较高时各个参数值的范围,在此基础上制定搜索策略,利用种群在解空间更有效地搜索全局最优解.

1 海上运动目标搜寻

海上搜寻计划制定是海上搜救系统的一个重要组成部分.大部分海上搜寻目标均处于运动状态,而只有在搜寻任务执行期间位置发生明显改变的目标可被认为是运动目标.这一类目标往往有较大的运动速度,如有较强机动能力的舰艇,或受海风、洋流等环境因素影响而有较大运动速度的救生筏、落水人员等.不同的搜寻目标有不同的运动特征,搜救系统往往无法准确得知搜寻目标的运动速度及方向,即使是无机能力的目标,由于海风、洋流等气象数据信息精确度不够,也无法确定其漂移速度大小及方向.搜救系统可根据一定时间内目标在一定位置的概率、一段时间内粗略的环境数据信息,以及目标自身的特性(材料、形状、体积等),计算出目标可能的漂移轨迹及所在位置.总体而言,搜寻目标在任务执行期间内一般表现为非匀速、非直线的不规则运动.目标所在位置在搜救系统中常用位置概率分布图表示,目标在任务执行过程中位置的改变在搜救系统中体

现为相应的概率分布图随时间而改变.概率分布图由搜救系统生成,多为栅格化的海图,反映一定时间内目标位于海图上特定位置的概率.如图1所示,栅格中数字为目标存在于该区域的概率^[13].

0.00%	0.00%	0.00%	0.01%	0.02%	0.03%	0.03%	0.02%	0.01%	0.00%	0.00%	0.00%
0.00%	0.01%	0.02%	0.06%	0.12%	0.17%	0.17%	0.12%	0.06%	0.02%	0.01%	0.00%
0.00%	0.02%	0.09%	0.24%	0.47%	0.65%	0.65%	0.47%	0.24%	0.09%	0.02%	0.00%
0.01%	0.06%	0.24%	0.65%	1.28%	1.79%	1.79%	1.28%	0.65%	0.24%	0.06%	0.01%
0.02%	0.12%	0.47%	1.28%	3.52%	3.52%	2.51%	1.28%	0.47%	0.12%	0.02%	0.00%
0.03%	0.17%	0.65%	1.79%	4.93%	4.93%	3.52%	1.79%	0.65%	0.17%	0.03%	0.00%
0.03%	0.17%	0.65%	1.79%	3.52%	4.93%	4.93%	3.52%	1.79%	0.65%	0.17%	0.03%
0.02%	0.12%	0.47%	1.28%	2.51%	3.52%	3.52%	2.51%	1.28%	0.47%	0.12%	0.02%
0.01%	0.06%	0.24%	0.65%	1.28%	1.79%	1.79%	1.28%	0.65%	0.24%	0.06%	0.01%
0.00%	0.02%	0.09%	0.24%	0.47%	0.65%	0.65%	0.47%	0.24%	0.09%	0.02%	0.00%
0.00%	0.01%	0.02%	0.06%	0.12%	0.17%	0.17%	0.12%	0.06%	0.02%	0.01%	0.00%
0.00%	0.00%	0.00%	0.01%	0.02%	0.03%	0.03%	0.02%	0.01%	0.00%	0.00%	0.00%

图1 概率分布图

考虑实际环境数据信息及目标运动特性,在实际的海上搜寻任务中,搜救系统对目标的概率分布图通常每6h进行一次更新(如SAROPS).海上搜寻计划制定的实质是充分利用现有资源(物质资源、时间资源)以最大化任务成功率.对特定单位,需考虑单位搜寻能力,在目标的概率分布图上为单位确定搜寻区域,制定搜寻路线,使单位可在任务时间内实施搜寻.海上运动目标搜寻任务中,目标的概率分布图随时间发生改变,因此,搜寻单位的搜寻方式即搜寻线路至关重要.本文的研究对象为单目标搜寻任务,旨在为单个搜寻单位制定搜寻计划,使任务成功率尽可能达到最大.

对于运动目标的搜寻任务,若搜寻区域为 X_{area} ,任务时间为 T ,则概率分布图每隔时间 T' 更新一次,其中 $T' \leq T$.若在任务执行过程中概率分布图有 $n(n \geq 1)$ 次变化,则整个任务过程共有 $n + 1$ 个概率分布图.将任务开始时间作为时间起点0,在 $0 \sim T_1$ 时间段,目标位置概率分布如第1个概率分布图 M_1 所示,单位完成的搜寻区域为 M_1 上的区域 X_{area}^1 ;在 $T_1 \sim T_2$ 时间段,目标位置概率分布如第2个概率分布图 M_2 所示,单位完成的搜寻区域为 M_2 上的区域 X_{area}^2 ;直至在 $T_n \sim T$ 时间段,目标位置概率分布如第 $n + 1$ 个概率分布图 M_{n+1} 所示,单位完成的搜寻区域为 M_{n+1} 上的区域 X_{area}^{n+1} .此时,有 $X_{area} =$

$\sum_i X_{\text{area}}^i$, 则在各个时间段内任务的成功率依次为

$$\begin{aligned} \text{Pos}(X_{\text{area}}^1, T_1) &= \int_{T_1} \iint_{X_{\text{area}}^1} p_d(x, y, t) \cdot p_c(x, y, t) dx dy dt, \\ \text{Pos}(X_{\text{area}}^2, T_2 - T_1) &= \int_{T_2 - T_1} \iint_{X_{\text{area}}^2} p_d(x, y, t) \cdot p_c(x, y, t) dx dy dt, \\ &\vdots \\ \text{Pos}(X_{\text{area}}^{n+1}, T - T_n) &= \int_{T - T_n} \iint_{X_{\text{area}}^{n+1}} p_d(x, y, t) \cdot p_c(x, y, t) dx dy dt. \end{aligned} \quad (1)$$

其中: $p_c(x, y, t)$ 为目标位置概率, 表示目标在时间 t 位于海图上位置 (x, y) 的概率, $p_c(x, y, t)$ 可由相应时间的概率分布图表示; $p_d(x, y, t)$ 为搜寻单位探测概率, 表示目标在时间 t 存在于位置 (x, y) 时, 搜寻单位可成功发现目标的概率, $p_d(x, y, t)$ 由搜寻单位的能力及相应的客观环境决定. 一般而言, 搜寻单位的搜寻速度越快, 成功发现目标的概率越小.

为方便表示, 将 T_1 记作 $T_1 - T_0$, 将 $T - T_n$ 记作 $T_{n+1} - T_n$. 整个任务的成功率为

$$\text{CPos}(X_{\text{area}}, T) = \sum_{i=0}^n \text{Pos}(X_{\text{area}}^{i+1}, T_{i+1} - T_i). \quad (2)$$

最常见的搜寻单位是船只. 为方便任务执行, 实际的搜寻任务要求船只的搜寻路线为等距、等长的平行线, 搜寻区域为规则的矩形^[8]. 船只在执行搜寻任务时往往保持匀速运动. 搜寻单位的探测概率由实际搜寻环境及搜寻单位的能力确定. 针对实际搜寻任务, 本文旨在为单个搜寻单位(船只)制定规范可行的搜寻计划, 确定目标的搜寻区域及搜寻路线, 尽可能使任务成功率达到最高, 即 $\max \text{CPos}$.

搜寻计划包括搜寻区域的位置、大小及相应的路线. 船只的搜寻计划可用六维向量表示为 (x, y, l, w, r, d) . 其中: x, y 分别表示矩形区域中心位置的横纵坐标; l, w 分别表示矩形区域的长、宽; r 表示矩形区域相对于水平方向的倾斜方向; d 表示搜寻单位的搜寻方式, 包括搜寻起始位置及相应的搜寻方向. 对于任一搜寻区域, d 有 8 种可选的值, 分别表示搜寻方式为自上而下顺时针、自上而下逆时针、自下而上顺时针、自下而上逆时针、自右而左顺时针、自右而左逆时针、自左而右顺时针、自左而右逆时针. 值得注意的是, 参量 d 同时确定了搜寻单位的起始位置和搜寻方向. 搜寻区域、搜寻单位起始位置、搜寻方向共同决定船只的搜寻路线. 各个参数上下界由相应问题规模决定. 图 2 为一船只的搜寻方案示例, 图中的搜寻方式为自上而下顺时针.

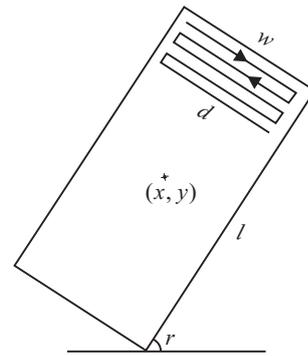


图 2 搜寻方案示例

在海上搜寻任务中, 评价搜寻计划优劣的指标即其所能获得的任务成功率. 对搜寻计划 $P = (x, y, l, w, r, d)$, 其搜寻区域及搜寻路线可由 (X_{area}, T) 表示. 在相应的优化方法中, 评价粒子的适应度函数为

$$f_{\text{fitness}}(P) = \text{CPos}(P) = \text{CPos}(X_{\text{area}}, T) = \sum_{i=0}^{i=n} \text{Pos}(X_{\text{area}}^{i+1}, T_{i+1} - T_i). \quad (3)$$

在运动目标搜寻任务中, 搜寻单位的的最佳计划 P_{best} 可以表示为

$$P_{\text{best}} = \arg \max \text{CPos} = \arg \max \text{CPos}(X_{\text{area}}, T). \quad (4)$$

2 析因-粒子群算法

2.1 PSO算法基本原理

PSO 是一种经典的基于群智能的启发式优化方法^[14-15], 其核心思想在于使种群围绕已发现的具有较好质量的解展开搜索. 由于其机理简单, 易于实现, 对局部寻优有明显的优势, 自被提出以来得到了广泛的应用. 种群中各个粒子的位置及速度更新公式为

$$v_{id}(t) = \omega v_{id}(t-1) + c_1 r_1 (p_{id} - y_{id}(t)) + c_2 r_2 (p_{gd} - y_{id}(t)), \quad (5)$$

$$y_{id}(t+1) = y_{id}(t) + v_{id}(t). \quad (6)$$

其中: $v_{id}(t)$ 为第 t 次迭代时第 i 个粒子在 d 维的速度; p_{id} 为第 i 个粒子在迭代过程中的最佳位置的第 d 维; p_{gd} 为整个种群在迭代过程中的最佳位置的第 d 维; ω 为惯性权重; c_1, c_2 为加速因子, 代表个体向自身极值和全局极值推进的随机加速权重; 第 t 次迭代中第 i 个粒子速度由 3 部分组成: 个体自身速度 v_{id} , 与个体自身所到最佳位置 p_{id} 的距离, 以及与整个种群最佳位置 p_{gd} 的距离.

然而, 多数实际优化问题的解空间并不是简单的单峰形态, 且当解空间形态较复杂, 即在局部峰值周围梯度变化较大时, 多数启发式优化算法(包括粒子群算法)容易陷入局部极值^[16-17]. 海上运动目标搜寻问题的解空间呈现为复杂的多峰形态, 现有方法难以

满足问题需要。

2.2 析因设计的主要思想

工程设计中,需要进行实验来研究多个因素的效应(如淬火溶液温度对合金硬度的影响)。析因设计对这类实验是最有效的^[18]。所谓析因设计是指,在这类实验的每一次完全试验或每一次重复中,所有因素水平的所有可能组合都能被研究到。通过分析所有组合的响应值,可以得到每个因素的水平变化对响应值的影响。因素之间往往存在交互作用,即一个因素的水平间的响应差随其他因素的水平不同而不同。通过析因设计能够有效确定因素间是否交互作用,并分析交互作用显著与否。

图3所示的析因实验,有两个因子(因素)A和B,它们各有两个水平,分别为A⁻、A⁺、B⁻和B⁺。不同实验不同组合的响应值分别如图3中数值所示。由图3可知:对因子B的低水平B⁻,A的效应为 $A = 50 - 20 = 30$;而对B的高水平B⁺,A的效应为 $A = 12 - 40 = -28$ 。可见,A的效应很大程度上依赖于因子B所选的水平,此时A与B之间存在较大的交互作用,交互作用的大小为两个A效应的平均差,即 $AB = (-28 - 30)/2 = -29$ 。显然,在此实验中交互作用是较大的。

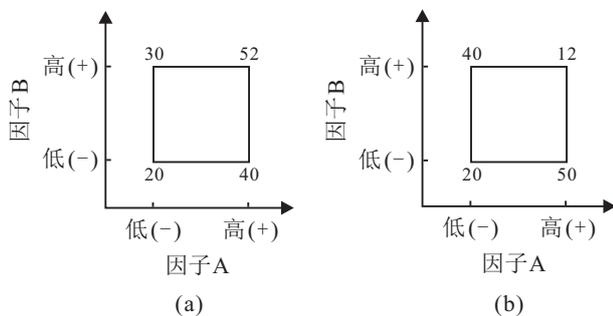


图3 二因子的析因实验,其响应显示在各角点上

交互作用可更直观地由响应图看出。图3的响应数据图如图4所示。图4(a)为图3(a)的响应数据图,B⁻与B⁺直线几乎平行,此时因子A与B之间交互作用可忽略不计。图4(b)为图3(b)的响应数据图,可以明显看出因子A与B之间存在交互作用。

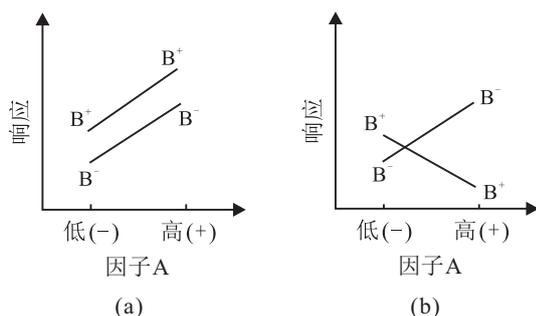


图4 因子的响应曲线

在海上运动目标搜寻问题中,搜寻区域位置、搜寻方式等因素共同决定船只的搜寻路线,即六维向量 (x, y, l, w, r, d) 确定相应的搜寻方案及任务成功率。向量中每一维参数均可看作影响搜寻任务成功率的因子,不同因素之间均存在交互作用,但因素之间的交互作用强弱有较大差异。一般而言,若确定搜寻区域中心位置,而适当调整搜寻区域的长宽比,则搜寻任务成功率不会有很大变化。对于部分搜寻任务,若确定搜寻区域的形状和搜寻方式,而改变搜寻区域中心位置,则任务成功率往往有较大变化。对于绝大多数搜寻任务,搜寻方式的改变往往会带来任务成功率的剧烈变化。本文引入析因策略,提出析因-粒子群算法,并将其应用于解决海上运动目标搜寻问题。在有效分析不同因素对任务成功率影响的基础上制定相应策略,利用改进的启发式方法求解海上运动目标搜寻问题,尽可能生成高质量的搜寻方案,获得较高的任务成功率。

2.3 析因-粒子群算法

多数启发式算法并不考虑解空间的形态,在搜索过程中获得的数据大部分被直接忽略,从而造成资源浪费,且种群容易陷入局部极值。析因-粒子群算法引入实验设计中的析因策略,分析各因素对适应度值的影响,利用历史数据试探分析解空间的形态。在此基础上制定策略,能够使种群更高效地搜索全局最优解。析因设计要求所有因素水平的可能组合都被研究到,这在优化问题中往往因为问题复杂度较高而难以实现。本文对此提出改进策略:利用随机化和区组化策略,针对每个因素随机设定其余因素水平,观测该因素水平变化对适应度值的影响,获取每个因素的适应度曲线。通过分析因素的适应度曲线,分析因素间的交互作用,确定各个因素对适应度的影响。

对于各个因素,根据问题规模确定其上下界。对于第*i*个因素,在其上下界范围内等间隔选择该因素的 n_i 个水平。对于第*i*个因素,随机抽选其余因素的水平,分别计算固定其余因素水平时该因素在 n_i 个水平的适应度值,得到第*i*个因素的适应度曲线。

以运动目标搜寻问题为例,任一备选搜寻计划可由六维向量 (x, y, l, w, r, d) 表示。此时,任一参数可看作决定适应度值(即任务成功率)的因子。对于因素 x ,选择水平 x_1, x_2, \dots, x_{n_1} ;对于因素 y ,选择水平 y_1, y_2, \dots, y_{n_2} ;对于因素 l ,选择水平 l_1, l_2, \dots, l_{n_3} ;对于因素 w ,选择水平 w_1, w_2, \dots, w_{n_4} ;对于因素 r ,选择水平 r_1, r_2, \dots, r_{n_5} ;对于因素 d ,选择水平 d_1, d_2, \dots, d_{n_6} 。对于因素 x ,随机选择其余因素的水平,有

$$\begin{aligned} y^1 &= \text{rand}\{y_1, y_2, \dots, y_{n_2}\}, \\ l^1 &= \text{rand}\{l_1, l_2, \dots, l_{n_3}\}, \\ w^1 &= \text{rand}\{w_1, w_2, \dots, w_{n_4}\}, \\ r^1 &= \text{rand}\{r_1, r_2, \dots, r_{n_5}\}, \\ d^1 &= \text{rand}\{d_1, d_2, \dots, d_{n_6}\}. \end{aligned}$$

计算因素 x 在所有不同水平时的适应度值为 $f_{\text{fitness}}(x_i y^1 l^1 w^1 r^1 d^1)$, $i = 1, 2, \dots, n_1$. 得到其余因素值为 $y^1 l^1 w^1 r^1 d^1$ 时因素 x 的适应度曲线. 重新随机选择其余因素的水平, 计算因素 x 在所有不同水平时的适应度值 $f_{\text{fitness}}(x_i y^2 l^2 w^2 r^2 d^2)$, 重复 a 次, 获得 $f_{\text{fitness}}(x_i y^a l^a w^a r^a d^a)$. 对于同一个因素的多个适应度曲线可认为是一个区组. 对于其余因素, 采用同样策略获得适应度曲线及相应的区组.

对于每个区组, 分析其中的适应度曲线. 若记 $f_{\text{fitness}}(x_i y^1 l^1 w^1 r^1 d^1)$ ($i = 1, 2, \dots, n_1$) 为 $f_{\text{fitness}}(x^1)$, 其余类似, 则相应地对因素 x , 区组内有 a 条曲线 $f_{\text{fitness}}(x^1), f_{\text{fitness}}(x^2), \dots, f_{\text{fitness}}(x^a)$. 分析各个曲线的梯度变化, 设定梯度阈值, $i = 1, 2, \dots, a$. 若适应度曲线存在梯度变化大于该阈值, 则该因素可被视为“异常因素”, 在利用种群搜索解空间过程中需采用特殊策略. 对各个适应度曲线, 计算适应度均值及方差 $\text{mean}(f_{\text{fitness}}(x^i))$ 、 $D(f_{\text{fitness}}(x^i))$, $i = 1, 2, \dots, a$. 适应度曲线相应的方差越大, 可认为该因素对适应度的影响越大. 统计同一区组中每个适应度曲线获得较高适应度值时因素的水平, 记为“重要水平”. 对于任一因素, 若其所有适应度曲线的重要水平较为吻合, 则可认为其余因素对该因素的交互作用较弱, 且该水平可获得较高适应度值. 若各个曲线重要水平相差较大, 则可认为因素间交互作用明显, 该解空间呈现为多峰形态. 记录每个区组中适应度值达到最大的各个因素水平. 根据析因分析得到的解空间形态信息, 为种群制定策略搜索全局最优解. 具体策略包括: 1) 对交互作用不明显的因素, 可直接初始化较多粒子的该维数值在重要水平范围内, 且在粒子迭代过程中, ω 取值较小, c_1 取值比 c_2 略大. 2) 对交互作用明显的因素, ω 取值较大, c_1 取值比 c_2 略小, 使种群更侧重于全局搜索, 以避免种群陷入局部极值. 3) 根据适应度曲线的梯度变化, 因素可分为“异常因素”和“普通因素”两类. 对“异常因素”, 在多次迭代并未产生更优解的情况下, 每次迭代随机选择部分粒子, 改变“异常因素”的值, 试探性搜索全局最优解.

2.4 析因-粒子群算法步骤

按照上述讨论, 本文析因-粒子群算法 (Factorial-based particle swarm optimization, FB-PSO) 的具体执

行流程如下.

Step 1: 根据问题规模选择各个因素的水平;

Step 2: 针对每个因素的各个水平, 随机选择其余因素的水平, 根据式 (3) 计算每个组合的适应度值, 得到各个因素的适应度曲线区组;

Step 3: 分析每个区组的适应度曲线, 计算相应的梯度、均值和方差, 判断因素间是否存在交互作用, 得到无交互作用 (或交互作用不明显) 因素的“重要水平”, 并根据梯度判断因素是否为“异常因素”;

Step 4: 设置析因-粒子群算法的控制参数, 包括种群规模, 总迭代次数, 以及所有因素迭代公式中的 ω 、 c_1 和 c_2 值;

Step 5: 初始化种群, 对无交互作用因素, 使较多粒子相应的值在其“重要水平”范围内;

Step 6: 根据式 (5) 和 (6) 进行迭代计算, 更新粒子各维的位置和速度;

Step 7: 若多次迭代并未产生更优解, 则每次迭代随机选择部分粒子, 随机改变“异常因素”的值, 试探性搜索全局最优解;

Step 8: 输出算法最优解, 算法结束.

3 仿真实验及性能分析

为检验析因-粒子群算法的性能, 本文将其与统一粒子群智能算法 (Unified particle swarm intelligence algorithm, UPSO)、基于适应度-距离比例的粒子群算法 (Fitness-distance-ratio-based PSO, FDRPSO)、综合学习粒子种群优化算法 (Comprehensive learning particle swarm optimizer, CLPSO) 作比较, 共同对多个运动目标搜寻问题进行仿真实验.

实验输入为任务时间内的概率分布图、任务时间、搜寻单位能力等. 概率分布图的大小为 $100 \text{ cm} \times 150 \text{ cm}$, 比例尺为 $1:200\,000$. 搜寻方案的区域长宽精度为 1 km , 在不同的环境条件下, 搜寻单位搜寻时速为 $200 \text{ km}^2/\text{h} \sim 300 \text{ km}^2/\text{h}$ 不等, 任务时间为 $24 \text{ h} \sim 48 \text{ h}$ 不等. 实验输出为单位的搜寻方案, 包括搜寻区域及搜寻方式. 在实际应用中, 算法的运行时间往往是决定算法实用性的一个重要指标. 因此, 本文从算法的运行时间及任务成功率两方面对所提方法与其余几种改进的粒子群算法进行比较, 以此验证算法的可行性和有效性.

实验环境为 Windows 7 32 bit, CPU 为 Pentium Dual-core 2.70 GHz, 内存为 2.0 GB, Matlab 2010. 在所有实验中, 种群规模为 500, 取值范围为 $[0.4, 1.3]$, c_1 和 c_2 的取值范围为 $[1.5, 3.5]$. 仿真实验结果如表 1 所示. 其中, 实际最佳方案成功率为穷举所有备选解得到的全局最优解代表的搜寻计划的成功率. 针对每

表1 实验结果

概率分布图尺寸/cm ²	任务时间/h	实际最佳方案成功率/%	算法	任务成功率均值/%	任务成功率方差	平均运行时间
100×150	24	38	FB-PSO	36	1.21e-04	8 m 23 s
			UPSO	25	4.72e-03	6 m 15 s
			FDRPSO	32	1.12e-03	6 m 22 s
			CLPSO	26	4.01e-03	7 m 55 s
100×150	36	55	FB-PSO	50	5.24e-04	8 m 41 s
			UPSO	29	3.85e-03	7 m 32 s
			FDRPSO	39	1.11e-03	6 m 56 s
			CLPSO	31	3.58e-03	8 m 17 s
100×150	48	69	FB-PSO	62	6.90e-04	9 m 11 s
			UPSO	42	5.16e-03	8 m 17 s
			FDRPSO	52	2.47e-03	8 m 26 s
			CLPSO	46	3.35e-03	8 m 57 s

个搜寻任务,每个算法重复运行20次.每个算法的任务成功率均值即该算法所对应的20个任务成功率的平均值.对于每个算法,其任务成功率均值越接近实际最佳方案成功率,代表该算法性能越好.

分析实验结果可知,相较其他几种算法,本文提出的析因-粒子群算法获得的搜寻方案质量最佳.在任务时间为24h时生成方案任务成功率均值为36%,其余算法生成方案任务成功率均值最高为32%(FDRPSO),最低为25%(UPSO).在任务时间为48h时生成方案任务成功率均值为62%,其余算法生成方案任务成功率均值最高为52%(FDRPSO),最低为42%(UPSO).FB-PSO生成的方案任务成功率与实际最佳方案成功率差距较小,任务时间为24h时与最佳方案成功率差距均值为3%,任务时间为48h时与最佳方案成功率差距均值为7%.其余算法中的FDRPSO表现最佳,在任务时间为24h时与实际最佳方案任务成功率差距为6%,但在任务时间为48h时,FDRPSO生成的方案与最佳方案成功率差距均值为17%.由分析实验结果可知:FDRPSO利用适应度与距离比这一信息,使种群有较好的全局搜索;CLPSO利用了搜索过程中产生的知识,因此有较好的表现;而UPSO不考虑全局形状信息,所以更容易陷入局部最优解.本文算法首先分析因素对适应度值的影响,有效地利用历史数据分析解空间形态,在此基础上制定策略,利用种群搜索解空间,可有效地获得高质量的解.

同时,由表1中可知,所有算法生成的方案质量都会随问题复杂度的上升而下降.当问题复杂度较低时,析因-粒子群算法生成的解与全局最优解的接近程度较高,随着任务时间的增加,任务时间内概率分布图的增多,析因-粒子群算法仍能获得较好的方案.这说明析因-粒子群算法能够有效分析不同因素对适应度值的影响,对海上运动目标搜寻问题有更好

的适用性.

除任务成功率均值外,表1还给出了各个算法的任务成功率方差.本文提出的算法针对每个搜寻任务均有最小的任务成功率方差,这说明析因-粒子群算法针对海上运动目标搜寻问题具有较好的稳定性,进一步表明了该方法在搜索最优解的过程中针对不同因素采用不同策略的有效性.其余几种算法方差较大,一定程度上说明其余几种算法在海上搜寻问题上的稳定性较差.

就算法运行时间而言,本文提出的算法相较其余几种算法耗时较长,但整体上运行时间仍在可接受范围.析因-粒子群算法针对每个因素,随机设定其余因素水平,观测该因素水平变化对适应度值的影响,获取每个因素的适应度曲线,计算相应的梯度,在此基础上制定策略,利用种群进行迭代寻优,此过程较为耗时,这是导致算法运行时间较长的主要原因.对于任一运动目标搜寻任务,可用六维向量 (x, y, l, w, r, d) 确定搜寻计划,若对各个因素设定 N 个水平,任意抽取 M 个其余因素水平组合,则获取因素适应度曲线的计算复杂度为 $O(MN)$.搜寻计划相应的任务成功率可通过式(2)计算获得,若搜寻区域大小为 $N \times N / \text{km}^2$,则任务成功率的计算复杂度可视为 $O(N^2)$.由此可知,析因-粒子群算法在分析因素对适应度值的影响过程耗费一定的时间资源,导致算法运行时间较长.

在实验过程中发现:对搜寻区域的中心位置,往往能通过较少次数的采样确定其能达到较高任务成功率的水平;固定其余因素,搜寻区域长宽比与倾斜角度的轻微变化通常不会引起任务成功率的明显变化;搜寻方式与搜寻区域形状及位置有关,搜寻方式的改变最容易引起成功率的明显变化,种群通常有针对性地改变搜寻方式进行试探寻优.种群在进行迭代寻优的过程中,针对不同因素有不同的迭代策略,

相较其他几种算法,析因-粒子群算法通常可通过较少的迭代次数收敛到具有较高质量的解。总体而言,析因-粒子群算法在耗费时间资源的同时能有效提高任务成功率。

4 结论

本文通过分析粒子群算法的局限性,提出了一种适用于海上运动目标搜寻问题的新型析因-粒子群算法(FB-PSO)。该算法引入实验设计中的析因策略,随机化并区组化设计参数在不同水平的组合,分析各参数变化对适应度值的影响,并利用历史数据分析解空间的形态,基于此为不同因素采用不同的更新策略,在种群无法产生更优解时根据因子间存在的交互作用调整该因素值,避免种群陷入局部极值。实验结果表明,析因-粒子群算法能够有效获得更优解,在海上运动目标搜寻问题中有较高的应用价值。

参考文献(References)

- [1] Thomas M K, Lawrence D S, John R F. Search and rescue optimal planning system[C]. The 13th Conf on Information Fusion. Edinburgh: IEEE, 2010: 1-8.
- [2] Canadian Coast Guard. National search and rescue manual[M]. Ottawa: Department of National Defence/Canadian Coast Guard, 2000.
- [3] Nassirou L, Jean B, Martin N. Toward optimizing static target search path planning[C]. The 5th IEEE Symposium on Computational Intelligence for Security and Defence Applications. Ottawa: IEEE, 2012: 1-7.
- [4] Jean B, Nassirou L, Martin N. A new multi-target, multi-agent search-and-rescue path planning approach[J]. Int J of Computer, Information, Systems and Control Engineering, 2014, 8(6): 902-912.
- [5] Jean B, Nassirou L. An innovative multi-agent search-and-rescue path planning approach[J]. Computers & Operations Research, 2015, 53: 24-31.
- [6] 陈志敏, 薄煜明, 吴盘龙, 等. 基于自适应粒子群优化的新型粒子滤波在目标跟踪中的应用[J]. 控制与决策, 2013, 28(2): 193-200.
(Chen Z M, Bo Y M, Wu P L, et al. Novel particle filter algorithm based on adaptive particle swarm optimization and its application to radar target tracking[J]. Control and Decision, 2013, 28(2): 193-200.)
- [7] 白国振, 荆鹏翔. 基于改进粒子群算法的并联机械手运动学参数辨识[J]. 信息与控制, 2015, 44(5): 545-551.
(Bai G Z, Jing P X. Kinematic parameter identification of parallel manipulator based on improved particle swarm algorithm[J]. Information and Control, 2015, 44(5): 545-551.)
- [8] 刘勇, 贾庆轩, 陈钢, 等. 基于多目标粒子群优化算法的自由漂浮空间机器人负载最大化轨迹优化[J]. 机器人, 2014, 36(4): 402-410.
(Liu Y, Jia Q X, Chen G, et al. Load maximization trajectory optimization for free-floating space robot using multi-objective particle swarm optimization algorithm[J]. Robot, 2014, 36(4): 402-410.)
- [9] 齐名军, 杨爱红. 一种混沌优化机制的双量子粒子群优化算法[J]. 计算机工程与应用, 2009, 45(30): 34-36.
(Qi M J, Yang A H. Double quantum delta particle swarm optimization based on chaos optimization strategy[J]. Computer Engineering and Applications, 2009, 45(30): 34-36.)
- [10] 刘道华, 原思聪, 兰洋, 等. 混沌映射的粒子群优化设计[J]. 西安电子科技大学学报, 2010, 37(4): 764-768.
(Liu D H, Yuan S C, Lan Y, et al. Method of particleswarm optimization based on the chaos map[J]. J of Xidian University, 2010, 37(4): 764-768.)
- [11] 匡芳君, 徐蔚鸿, 张思扬. 基于改进混沌粒子群的混合核SVM参数优化及应用[J]. 计算机应用研究, 2013, 31(3): 671-674.
(Kuang F J, Xu W H, Zhang S Y. Parameter optimization and application of SVM with mixtures kernels based on improved chaotic particle swarm optimization[J]. Application Research of Computers, 2013, 31(3): 671-674.)
- [12] 唐苏妍, 朱一凡, 张伟, 等. 一种基于创造性思维的粒子群优化算法[J]. 控制与决策, 2011, 26(8): 1181-1186.
(Tang S Y, Zhu Y F, Zhang W, et al. Particle swarm optimization algorithm based on creative thinking[J]. Control and Decision, 2011, 26(8): 1181-1186.)
- [13] 国际海事组织/国际民用航空组织. 国际航空和海上搜寻救助手册[M]. 北京: 人民交通出版社, 2002: 148-154.
(IMO/International Civil Aviation Organization. International aeronautical and maritime search and rescue manual volume II[M]. Beijing: China Communications Press, 2002: 148-154.)
- [14] Eberhart R, Kennedy J. A new optimizer using particle swarm theory[C]. Proc of the 16th Int Symposium on Micro Machine and Human Science. Piscataway: IEEE Service Center, 1995: 39-43.
- [15] Kennedy J, Eberhart R. Particle swarm optimization[C]. IEEE Int Conf on Networks. Perth: IEEE Press, 1995: 1942-1948.
- [16] Bergh F V D, Engelbrecht A P. A new locally convergent particle swarm optimizer[C]. Proc of the IEEE Int Conf on Systems, Man and Cybernetics. Portland: IEEE, 2002, 3(3): 94-99.
- [17] Bergh F V D. An analysis of particle swarm optimizers[D]. Pretoria: Department of Computer Science, University of Pretoria, 2001.
- [18] Montgomery D C. 实验设计与分析[M]. 北京: 人民邮电出版社, 2009: 134-138.
(Montgomery D C. Design and analysis of experiments[M]. Beijing: The People's Posts and Telecommunications Press, 2009: 134-138.)