

基于直觉模糊熵的粒子群多目标优化

苏丁为 周创明 王毅

(空军工程大学防空反导学院 西安 710051)

摘要 针对现有多目标算法存在的收敛性不强、分散性不高等问题,提出了一种基于直觉模糊熵的粒子群多目标优化算法(IFEMOPSO)。首先,计算出种群的直觉模糊熵(IFE),作为衡量种群在多目标空间下多样性的测度;其次,设计基于 IFE 的惯性权重动态变化、外部档案调用以及变异操作等 3 种增强算法探索力度的策略,建立了直觉模糊多目标规划模型,有效地提高了群体进化过程中的多样性,防止了算法陷入局部收敛;最后,仿真结果表明,所提算法很好地提高了所得非劣解集的收敛性和分散性,有效地解决了多目标优化问题。

关键词 直觉模糊熵,粒子群算法,多样性,多目标优化问题

中图分类号 TP301 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2016.8.053

Particle Swarm Algorithm for Multi-objective Optimization Based on Intuitionistic Fuzzy Entropy

SU Ding-wei ZHOU Chuang-ming WANG Yi

(Air and Missile Defense College, Air Force Engineering University, Xi'an 710051, China)

Abstract A particle swarm algorithm for multi-objective optimization problems based on intuitionistic fuzzy entropy was proposed to overcome the deficiency that the performance of algorithm's convergence and distribution is not high. Firstly, the algorithm uses a metric based on intuitionistic fuzzy entropy to measure the diversity of the population in the case of multi-objective space. Then, three strategies, namely dynamic changes of inertia weight, use of the external archive and mutation operator mechanism based on intuitionistic fuzzy entropy, was designed and intuitionistic fuzzy multi-objective programming model was built to enhance the extent of the algorithm's exploration, increasing the diversity of the evolving population and prevent premature convergence. At last, results of simulation indicate that the proposed algorithm has good performance of convergence and distribution, and it is useful for dealing with multi-objective optimization problems.

Keywords Intuitionistic fuzzy entropy, Particle swarm optimization, Diversity, Multi-objective optimization

1 引言

多目标优化问题是科学实践中常见的一种问题,由于多个目标之间存在制约,采用将多个目标转化为单个目标等传统算法难以得到最优解。而与传统求解多目标问题的算法相比,进化算法具有隐含的并行求解的优势,一次操作可以得到多个非劣解,适合求解多目标优化问题。因此, Schaffer 于 1985 年提出了与进化算法相结合的向量评价遗传算法(VEGA)^[1],而后各种多目标进化算法被相继提出,如非劣分类遗传算法(NSGA-II)^[2]等。粒子群优化算法(PSO)^[3]是由 Kennedy 等人于 1995 年提出的一种模拟鸟群捕食行为的智能计算方法。其由于具有结构简单、快速收敛的特点,在许多方面得以成功应用;且并行处理的特性使其逐渐运用到对多目标优化问题的研究中,如利用外部档案中的非劣解获得全局最优解进而控制粒子飞行速度的算法^[4,5],或采用变异机制来改善种群多样性的 PSO 算法^[6]。但上述算法在进化的过程中都没有考虑到与当前种群收敛情况相结合后是否进行增加

种群多样性的操作,增加了种群进化过程中的不可控性,难以得到最优解。

为了控制多目标粒子群算法的进化过程,防止陷入局部最优解,本文提出一种基于直觉模糊熵的粒子群多目标优化算法(IFEMOPSO),即通过种群直觉模糊熵动态改变惯性权重来提高粒子群的搜索性能,同时采用基于直觉模糊熵的外部档案调用以及变异操作来增加种群的多样性,从而控制多目标优化的过程。

2 直觉模糊熵

信息熵是 Shannon 将熵引入信息论中而提出的,用其作为度量信息状态不确定性的尺度,而后产生了模糊熵。模糊熵^[7]是 Zadeh 教授在 1965 年基于模糊集理论提出的概念,用来度量事件的模糊不确定性,而直觉模糊熵(IFE)是模糊熵理论的拓展, Burillo 等人分别对其给出了公理化定义^[8,9],它能有效描述群体状态及其与系统能量变化的关系。随着直觉模糊集的不断发展和应用,直觉模糊熵也被应用到许多领

到稿日期:2015-06-25 返修日期:2015-09-25 本文受国家自然科学基金(61402517),中国博士后基金(2013M542331),陕西省自然科学基金(2013JQ8035)资助。

苏丁为(1992-),男,硕士生,主要研究方向为智能信息处理, E-mail: xingmohun@163.com; 周创明(1967-),男,副教授,主要研究方向为智能信息处理、信息安全; 王毅(1979-),男,博士后,主要研究方向为智能信息处理与智能决策。

域,如将直觉模糊集熵与进化算法结合来解决大规模整数规划问题^[10],与动态直觉模糊法结合来解决空战多目标威胁评估问题^[11]。

把多目标优化问题中的解空间作为粒子群体,在进化的过程中,粒子会收敛于最优点或极值点。通过每次迭代求其熵值就可以了解种群的进化快慢,但种群中偶有一些粒子落单,用模糊集无法准确描述这些粒子,而直觉模糊集比模糊集增加了非隶属度和“非此非彼”的犹豫度,可以更好地将每个粒子分类,使求出的直觉模糊熵能更好更全面地描述种群进化的过程,控制种群的多样性。因而本文采用直觉模糊熵作为粒子群多样性的测度,将当前的所有粒子根据粒子目标间的距离进行分类,再根据每类中粒子的个数分别计算出各类的隶属度、犹豫度以及非隶属度。

定义 1 规定在第 t 代中,根据群体 pop 中的每个粒子(种群规模为 N)的目标向量间的相似程度,将种群划分为 k 个不同种群子集 P_1, P_2, \dots, P_k ;落单的粒子,即没有与之相似的单个粒子,称为孤点,所有孤点组成的集合为 P_{k+1} ;各子集中的粒子数目分别为 $|P_1|, |P_2|, \dots, |P_k|, |P_{k+1}|$,其中每个子集的粒子个数 $|P_i| \geq 2, i=1, 2, \dots, k$,且 $\forall i, j \in \{1, 2, \dots, k, k+1\}$ 时,都有 $P_i \cap P_j = \emptyset, \bigcup_{i=1}^{k+1} P_i = pop$,由上述条件可定义:

$$\mu_i^t = \frac{|P_i|}{N}, \pi_i^t = \frac{|P_{k+1}|}{N}, \nu_i^t = 1 - \mu_i^t - \pi_i^t \quad (1)$$

其中, $i=1, 2, \dots, k$; μ_i^t 为第 t 代中所有粒子隶属于第 i 个子集的程度, $\mu_i^t \in [0, 1]$; π_i^t 为孤点的犹豫度, $\pi_i^t \in [0, 1]$; ν_i^t 为所有粒子不隶属于第 i 个子集的程度, $\nu_i^t \in [0, 1]$ 。

定义 2(直觉模糊熵^[9]) 设 H^t 是种群的直觉模糊熵,其定义如下:

$$H^t = \frac{1}{k} \sum_{i=1}^k \frac{\min(\mu_i^t, \nu_i^t) + \pi_i^t}{\max(\mu_i^t, \nu_i^t) + \pi_i^t} \quad (2)$$

其中, $H^t \in [0, 1]$,当所有粒子收敛于一点时, $k=1, H^t=0$;当所有粒子为孤点,即 $k=N$ 时, $H^t=1$;当所有粒子分配得越平均时, H^t 越大。

而两粒子间相似性的判断方法如下。

Step 1:分别求出群体 pop 在 r 个目标中的最小值 f_i^{\min} 与最大值 $f_i^{\max}, i=1, 2, \dots, r$ 。

Step 2:求出群体 pop 中的每个粒子 x 在目标 f_i 上的值 $f_i(x)$,再根据 f_i^{\max} 与 f_i^{\min} 对每个粒子进行归一化,每个粒子 x 归一化的目标向量记为:

$$f'(x) = (f'_1(x), f'_2(x), \dots, f'_r(x)) \quad (3)$$

其中, $f'_i(x) = (f_i(x) - f_i^{\min}) / (f_i^{\max} - f_i^{\min})$ 。

Step 3:分别对群体 pop 中每两个已经归一化的粒子 x 和 x' 的目标向量进行欧拉距离(d)计算,即 $d = \|f'(x) - f'(x')\|$ 。若 $d < \delta$,则粒子 x 和 x' 划分进一个子集 C_j ,若粒子与其他所有粒子的欧拉距离 d 都大于 δ ,则此粒子为孤点,所有孤点组成一个子集 C ,如此划分,直至所有粒子处理完毕,满足 $\forall x \in C_j, \exists x' \in C_j, 有 d < \delta$,其中 $x \neq x'$,参数 $\delta = \sqrt{(1/N)^2 * r}, \delta \in [0, 1], \delta$ 取此值的目的在于使群体中粒子沿着各目标均匀分布,以维持种群较好的多样性。

3 基于直觉模糊熵的粒子群多目标优化算法

3.1 基于 IFE 的惯性权重动态变化

在粒子群优化算法中惯性权重 ω 的大小表明了历史速度

对当前速度的影响的强弱。当其值较大时,可提高粒子的全局搜索性能;其值较小时,可改善粒子的局部搜索性能。在粒子群多目标优化中,常使惯性权重随着种群迭代次数动态变化,以便于最优解的搜索,但对于某些特定的优化问题,惯性权重常取固定常数。而在 IEFMOPSO 算法中,采用惯性权重随着迭代次数和种群熵值动态变化的策略,以便解决多种多目标优化问题,同时更有效地得到全局最优解。 ω 的变化公式如下:

$$\omega = (\omega_{\max} - (\omega_{\max} - \omega_{\min}) \times \frac{t}{MaxIt}) \times (0.5 + H^t) \quad (4)$$

其中, ω_{\max} 为惯性权重初始值, ω_{\min} 为惯性权重最终值, t 为当前迭代次数, $MaxIt$ 为最大迭代次数。随着迭代次数的增加, ω 从 ω_{\max} 逐渐递减到 ω_{\min} ,以减小粒子历史速度信息对当前速度的影响,同时加大全局最优解和局部最优解对粒子的影响。当 $H^t < 0.5$ 时,加快 ω 的递减;当 $H^t > 0.5$ 时,减慢 ω 的递减。本文取 $\omega_{\max} = 0.9, \omega_{\min} = 0.4$ 。

3.2 基于 IFE 的外部档案调用

在 IFEMOPSO 算法中设置一个外部档案来存放迭代过程中搜索到的非劣解,从而得到多目标优化问题的一个近似 Pareto 前端;同时,在每次迭代的过程中,根据种群熵值从外部档案中选出一个解作为粒子的全局最优解,即在进化的过程中,将每代产生的非劣解存入外部档案中,剔除当前外部档案中的被支配解,再计算外部档案中非劣解拥挤距离,得到一个拥挤距离由大到小排序且非劣解个数在 $DMax$ 范围内的外部档案。通过当前种群的熵 H^t 值,计算出 N_1 的值,其中 $N_1 = (H^t)^2 * S$,再从排好序的非劣解集中调出第 N_1 位置上的非劣解作为全局最优解 g_{best} ,其中 S 为外部档案中非劣解的个数。若 H^t 值越小,对应 N_1 值也越小,则算法选取拥挤度大的作为全局最优解,以提高种群多样性。

3.3 非劣解的拥挤距离计算

对于每个非劣解经式(3)归一化的目标函数按大小排序后得到的点,规定每个点所在立方体为不包含其它点的最大立方体,该点的拥挤距离即为所在立方体对应不同目标函数相邻点的边长(即相邻非劣解归一化目标函数值之差)之和^[6]。拥挤距离的大小表明解的分布疏密程度和多样性大小,越小则表明解的分布越密集,且多样性越小;越大则表明解的分布越稀疏,且多样性越大。当外部档案个数大于 $DMax$ 时,则要对非劣解进行删减操作,即将拥挤距离小的非劣解进行删除,从而使所得的 Pareto 前端分布更均匀,更具多样性。

3.4 基于 IFE 的变异操作

由于 PSO 算法在进化过程中收敛速度快,可能导致多目标优化算法陷入局部最优,难以得到 Pareto 最优解,但通过变异操作,可以使当前种群获得新的个体,从而增加种群的多样性,避免陷入局部收敛。因此在 IFEMOPSO 算法中,采用了根据种群熵值 H^t 大小来判断对第 t 代种群是否进行变异以及选取多少粒子进行变异的的操作。即当 $H^t < \alpha$ 时,进入变异操作,再计算出种群中要变异的个数 N' ,其中 $N' = \lceil \alpha * (1 - H^t)^2 * N \rceil$,再对 N' 中的每个解根据 $rand(1)$ 是否小于变异概率 $P = \alpha - H^t$ 进行判断,若 $rand(1) < P$,则进行变异操作,否则,此解不进行变异操作;而当 $H^t \geq \alpha$ 时,种群不进行变异操作。其中 $\lceil \cdot \rceil$ 表示不小于 \cdot 的最小整数; N 为种群规模;本文参数 $\alpha = 0.5$ 。

3.5 IFEMOPSO 算法步骤

IFEMOPSO 算法的详细步骤如下。

Step 1: 算法参数设定。种群规模为 N , 迭代的最大次数为 $MaxIt$, 当前的迭代次数 $t=1$, 外部档案 A 的规模为 $DMax$ 。

Step 2: 在解空间中随机产生规模为 N 的种群 P , 计算 P 中每个粒子所对应的目标向量, 求出非劣解并将其存储到外部档案 A 中。

Step 3: 进入迭代循环, 通过 3.3 节计算外部档案 A 中非劣解的拥挤距离得到排序后的非劣解集, 再通过式(2)计算出种群的直觉模糊熵 H^t , 而后通过 3.2 节调用外部档案得到全局最优解 g_{best} , 而局部最优解 p_{best} 通过种群中每个粒子的历史最佳位置决定。

Step 4: 通过粒子的速度和位置更新公式更新当前的种群, 其第 i 个粒子的第 d 维 ($1 \leq d \leq D$) 的速度和位置更新公式如下:

$$v_{id}^{t+1} = \omega \times v_{id}^t + c_1 \times r_1 \times (p_{best} - x_{id}^t) + c_2 \times r_2 \times (g_{best} - x_{id}^t) \quad (5)$$

$$x_{id}^{t+1} = x_{id}^t + v_{id}^{t+1}$$

其中, ω 为惯性权重, 表明粒子历史速度信息对当前速度影响; c_1, c_2 为学习因子, 用来平衡个体和群体认知能力; r_1, r_2

是分布在 $[0, 1]$ 上相互独立的随机数; D 为解空间的维数。本文中取 $c_1=2, c_2=2$ 。

Step 5: 通过种群的直觉模糊熵对种群进行 3.4 节所示的变异操作。

Step 6: 计算当前种群的目标函数适应值, 将得到的非劣解整合到外部档案中。

Step 7: $t=t+1$, 直到 $t > MaxIt$ 时, 结束迭代循环, 并将当前外部档案中的非劣解集作为近似 Pareto 最优解集输出, 算法结束; 否则, 返回 Step 3。

4 实验结果与分析

4.1 测试函数

将 IFEMOPSO 算法与文献[2]中的非劣分类遗传算法 NSGA-II 和文献[5]中的多目标粒子群算法 MOPSO 进行对比研究。3 种算法的种群规模均设为 100, 迭代次数为 500, 外部档案规模为 100, 3 种算法均采用实数编码。对于 NSGA-II 算法, 交叉概率为 0.9, 采用锦标赛选择机制, 变异概率为 $1/n$ (n 为变量的个数); 对于 MOPSO 算法, 惯性权重置为 0.4, 加速因子均置为 2。如表 1 所列, 选用 D-eb 提出的 DEB 目标函数和常用目标测试函数 ZDT1-ZDT6^[12] 作为本次实验的测试函数, 3 个算法分别都进行 10 次独立实验。

表 1 测试函数

问题	n	变量取值范围	目标函数
DEB	2	[0, 1, 1]	$f_1(x) = x_1$ $f_2(x) = g(x_2)/x_1$ $g(x_2) = 2.0 - \exp(-(\frac{x_2 - 0.2}{0.004})^2) - 0.8 \exp(-(\frac{x_2 - 0.6}{0.4})^2)$
ZDT1	10	[0, 1]	$f_1(x) = x_1$ $f_2(x) = g(x)(1 - \sqrt{x_1/g(x)})$ $g(x) = 1 + 9(\sum_{i=2}^n x_i)/(n-1)$
ZDT2	10	[0, 1]	$f_1(x) = x_1$ $f_2(x) = g(x)(1 - (x_1/g(x))^2)$ $g(x) = 1 + 9(\sum_{i=2}^n x_i)/(n-1)$
ZDT3	10	[0, 1]	$f_1(x) = x_1$ $f_2(x) = g(x)(1 - \sqrt{x_1/g(x)} - \frac{x_1}{g(x)} \sin(10\pi x_1))$ $g(x) = 1 + 9(\sum_{i=2}^n x_i)/(n-1)$
ZDT4	3	$x_1 \in [0, 1], x_i \in [-5, 5], i=2, 3, \dots, n$	$f_1(x) = x_1$ $f_2(x) = g(x)(1 - \sqrt{x_1/g(x)})$ $g(x) = 1 + 10(n-1) + \sum_{i=2}^n x_i^2 - 10 \cos(4\pi x_1)$
ZDT6	6	[0, 1]	$f_1(x) = 1 - \exp(-4x_1) \sin^6(6\pi x_1)$ $f_2(x) = g(x)[1 - (f_1(x)/g(x))^2]$ $g(x) = 1 + 9[(\sum_{i=2}^n x_i)/(n-1)]^{0.25}$

4.2 算法性能评价指标

本文采用算法所得非劣解与 Pareto 最优解之间的距离的 GD 值^[13]来衡量算法的收敛性; 用算法所得非劣解的分布情况, 即非劣解的间隔距离 SP 值^[14]来衡量算法所求解的多样性。GD 指标反映了算法所得的非劣解集与 Pareto 最优解集的逼近程度, GD 值越小, 逼近程度越高, 即非劣解集越收敛于 Pareto 最优解集; SP 指标表示非劣解前端上所有解呈均匀分布程度, SP 值越小, 非劣解前端分布越均

匀。其取值如下:

$$GD = \frac{1}{n} \sqrt{\sum_{i=1}^n d_i^2} \quad (6)$$

其中, d_i 为第 i 个解到 Pareto 最优解集的最小距离, n 为算法所得非劣解的个数。

$$SP = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (D - d_i^2)} \quad (7)$$

其中, $d_i = \min(|f_1^i(x) - f_1^j(x)| + |f_2^i(x) - f_2^j(x)|), i, j =$

1, 2, ..., n, n, i ≠ j, D 是所有 d_i 的均值, n 是算法所得的非劣解的数目。

4.3 测试结果与分析

IFEMOPSO, NSGA-II 以及 MOPSO 3 种算法的测试结果如图 1—图 6 所示, 图中显示了所得非劣解集与真实 Pareto 前端的对比情况, 而表 2、表 3 分别显示了 6 个目标函数在 3 种算法测试下得到的 GD 值以及 SP 值的平均值和标准差。




图 1 DEB 测试函数的实验和真实 Pareto 前端




图 2 ZDT1 测试函数的实验和真实 Pareto 前端




图 3 ZDT2 测试函数的实验和真实 Pareto 前端




图 4 ZDT3 测试函数的实验和真实 Pareto 前端




图 5 ZDT4 测试函数的实验和真实 Pareto 前端




图 6 ZDT6 测试函数的实验和真实 Pareto 前端

从图 1—图 3 可知, IFEMOPSO 算法所产生的非劣解集在真实 Pareto 前端的分布比 MOPSO 和 NSGA-II 算法更均匀, 对真实 Pareto 前端的覆盖率也比 MOPSO 和 NSGA-II 算法要高; 从图 4—图 6 可知, IFEMOPSO 算法所产生的非劣解集比 MOPSO 和 NSGA-II 算法更逼近真实的 Pareto 前端, 更接近真实的解。这是因为直觉模糊熵值很好地反映了当前种

群的状态, 从而基于熵值求出的惯性权重、全局最优解以及变异种群能更好地调控种群多样性, 特别是种群进化中后期, 熵值减小引起变异次数的增多, 有效地防止种群陷入局部最优。

从表 2 可知, 对于 ZDT3 测试函数, IFEMOPSO, MOPSO 和 NSGA-II 3 种算法对应的 GD 平均值分别为 0.000178, 0.024500 和 0.000369, 而 GD 值越小, 算法所得非劣解越逼近真实 Pareto 前端, 因而 IFEMOPSO 算法所得非劣解集更收敛于真实 Pareto 前端; 对于 ZDT4 测试函数, 3 种算法对应的 GD 值为 0.000165, 0.179100 和 0.051100, 而 ZDT6 测试函数中 3 种算法对应的 GD 平均值依次为 0.000222, 0.000248 和 0.060900, 表明了 GD 最小的 IFEMOPSO 算法更收敛于真实 Pareto 前端, 与图 4—图 6 显示的结果相吻合。对于另外的 DEB, ZDT1 和 ZDT2 测试函数, IFEMOPSO 对应的 GD 平均值和标准差整体上要小于 MOPSO 和 NSGA-II 算法, 说明了 IFEMOPSO 算法的稳定性要好, 且 IFEMOPSO 算法的收敛性整体上要强于 MOPSO 和 NSGA-II 算法。

表 2 测试函数的 GD 值

函数	GD	IFEMOPSO	MOPSO	NSGA-II
DEB	平均值	0.006800	0.008700	0.007400
	标准差	0.000341	0.004900	0.001800
ZDT1	平均值	0.000318	0.007500	0.000141
	标准差	0.000017	0.012800	0.000030
ZDT2	平均值	0.000023	0.008000	0.000086
	标准差	0.000001	0.017700	0.000055
ZDT3	平均值	0.000178	0.024500	0.000369
	标准差	0.000014	0.022500	0.000161
ZDT4	平均值	0.000165	0.179100	0.051100
	标准差	0.000021	0.135200	0.048500
ZDT6	平均值	0.000222	0.000248	0.060900
	标准差	0.000017	0.000019	0.028400

SP 指标表明算法所得非劣解的分散性, SP 越小说明分布越均匀。而从表 3 可知, IFEMOPSO, MOPSO 和 NSGA-II 3 种算法在 DEB 测试函数中得到的 SP 平均值分别为 0.036400, 0.058900 和 0.042500, 表明 IFEMOPSO 算法所得非劣解集在真实 Pareto 前端上的分布比另两种算法更均匀; 而对于 ZDT1 测试函数, 3 种算法的 SP 平均值依次为 0.005200, 0.056200 和 0.007200, 而 Z-DT2 测试函数中 3 种算法对应的 SP 值为 0.006700, 0.065400 和 0.006800, 也说明了算法 IFEMOPSO 的分散性比 MOPSO 和 NSGA-II 算法更好, 与图 1—图 3 的显示结果相符。且对于 ZDT3, ZDT4 和 ZDT6 测试函数, IFEMOPSO 算法的 SP 平均值都比 MOPSO 以及 N-SGA-II 算法要小, 因此, IFEMOPSO 算法的分布均匀性整体上比 MOPSO 和 NSGA-II 算法都要强。

表 3 测试函数的 SP 值

函数	GD	IFEMOPSO	MOPSO	NSGA-II
DEB	平均值	0.036400	0.058900	0.042500
	标准差	0.004300	0.054200	0.010500
ZDT1	平均值	0.005200	0.056200	0.007200
	标准差	0.000339	0.098600	0.000633
ZDT2	平均值	0.006700	0.065400	0.006800
	标准差	0.000502	0.177200	0.000916
ZDT3	平均值	0.007500	0.048200	0.007700
	标准差	0.001100	0.065400	0.000977
ZDT4	平均值	0.005500	1.109000	0.008300
	标准差	0.000803	1.098200	0.000693
ZDT6	平均值	0.004500	0.005100	0.145600
	标准差	0.000460	0.000992	0.201700

通过对 6 个典型的多目标函数的测试可知,本文提出的 IFEMOPSO 算法能更好地收敛于真实 Pareto 前端,且其所产生的非劣解集的分布也更加均匀。

结束语 本文提出的基于直觉模糊集熵的粒子群多目标优化算法 IFEMOPSO 通过基于直觉模糊熵的动态惯性权重调整、种群变异操作以及外部档案使用,很好地控制了种群进化过程中的多样性以及收敛速度,避免了算法的早熟,使其能更有效地在多目标优化问题的空间中进行搜索。实验结果表明,与已有的 MOPSO 和 NSGA-II 算法相比,IFEMOPSO 算法所产生的非劣解集具有更好的收敛性和分散性,能有效地解决多目标优化问题。

参 考 文 献

- [1] Schaffer J D. Multiple objective optimization with vector evaluated genetic algorithms[C]//Proc. of the 1st IEEE International Conference on Genetic Algorithms. 1985:93-100
- [2] Deb K, Pratap A, Agarwal S, et al. A fast and elitist multi-objective genetic algorithm: NSGA-II [J]. IEEE Trans. on Evolutionary Computation, 2002, 6(2): 182-197
- [3] Kennedy J, Eberhart R C. Particle swarm optimization [C] // Proc. of IEEE International Conference on Neural Networks. 1995:1942-1948
- [4] Coello C A C, Lechuga M S. MOPSO: A proposal for multiple objective particle swarm optimization [C] // Proc. IEEE Int. Conf. on Evolutionary Computation. Piscataway: IEEE Service Center, 2002, 2: 1051-1056
- [5] Coello C A C, Pulido G T, Lechuga M S. Handling multiple objectives with particle swarm optimization [J]. IEEE Trans. on Evolutionary Computation, 2004, 8(3): 256-279
- [6] Wang Hui, Qian Feng. Improved PSO-based multi-objective optimization by crowding with mutation and particle swarm optimization dynamic changing [J]. Control and Decision, 2008, 23

(11): 1238-1242 (in Chinese)

王辉, 钱峰. 基于拥挤度与变异的动态微粒群多目标优化算法 [J]. 控制与决策, 2008, 23(11): 1238-1242

- [7] Zadeh L A. Fuzzy sets [J]. Information and Control, 1965, 8(3): 338-356
- [8] Burillo P, Bustice H. Entropy on intuitionistic fuzzy sets and on interval-valued fuzzy sets [J]. Fuzzy Sets and Systems, 1996, 78(3): 305-316
- [9] Wang Yi, Lei Ying-jie. A technique for constructing intuitionistic fuzzy entropy [J]. Control and Decision, 2007, 12(22): 1390-1394 (in Chinese)
王毅, 雷英杰. 一种直觉模糊熵的构造方法 [J]. 控制与决策, 2007, 12(22): 1390-1394
- [10] Wang Yu-zhe, Lei Ying-jie, Zhou Lin, et al. Intuitionistic fuzzy discrete particle swarm algorithm [J]. Control and Decision, 2012, 27(11): 1735-1740 (in Chinese)
汪禹喆, 雷英杰, 周林, 等. 直觉模糊离散粒子群算法 [J]. 控制与决策, 2012, 27(11): 1735-1740
- [11] Zhang Kun, Wang Xue. Evaluating and sequencing of air target threat based on IFE and dynamic intuitionistic fuzzy sets [J]. Systems Engineering and Electronics, 2014, 36(4): 697-701 (in Chinese)
张堃, 王雪. 基于 IFE 动态直觉模糊法的空战目标威胁评估 [J]. 系统工程与电子技术, 2014, 36(4): 697-701
- [12] Zitzler E, Deb K, Thiele L. Comparison of multi-objective evolutionary algorithms: Empirical results [J]. Evolutionary Computation, 2000, 8(2): 173-195
- [13] Van Veldhuizen D A, Lamont G B. Multi-objective evolutionary algorithm research: A history and analysis [R]. Ohio: Air Force Institute of Technology, 1998
- [14] Schott J. Fault tolerant design using single and multicriteria genetic algorithm optimization [D]. Cambridge: Massachusetts Institute of Technology, 1995

(上接第 243 页)

- [9] Krishnanand K N, Ghose D. Detection of multiple source locations using a glowworm metaphor with applications to collective robotics [C] // Proc of IEEE Swarm Intelligence Symposium. Piscataway: IEEE Press, 2005: 84-91
- [10] Huang Zheng-xin, Zhou Yong-quan. Self-adaptive step glowworm swarm optimization algorithm for optimizing multimodal functions [J]. Computer Science, 2011, 32(10): 220-224 (in Chinese)
黄正新, 周永权. 自适应步长萤火虫群多模态函数优化算法 [J]. 计算机科学, 2011, 38(7): 220-224
- [11] Liu Jia-kun, Zhou Yong-quan. Glowworm swarm optimization algorithm based on max-min luciferin [J]. Application Research of Computers, 2011, 28(10): 3662-3664 (in Chinese)
刘佳昆, 周永权. 一种最大最小萤光素值人工萤火虫算法 [J]. 计算机应用研究, 2011, 28(10): 3662-3664
- [12] Wu Wei-min, Kang Shao-jiang, Lin Zhi-yi, et al. Multimodal function optimisation based on improved glowworm swarm optimisation [J]. Computer Applications and Software, 2014(1): 283-285, 302 (in Chinese)
吴伟民, 亢少将, 林志毅, 等. 基于改进萤火虫算法的多模态函数优

化 [J]. 计算机应用与软件, 2014, (1): 283-285, 302

- [13] Davis L. Job shop scheduling with genetic algorithms [C] // International Conference on Genetic Algorithms and Their Applications. Mahwah, NJ, Lawrence Erlbaum Associate, 1985: 136-140
- [14] Ge Hong-wei. The research of some optimization problems based on computational intelligence [D]. Jilin: Jilin University, 2006 (in Chinese)
葛宏伟. 基于计算智能的若干优化问题研究 [D]. 吉林: 吉林大学, 2006
- [15] Carlier J. Scheduling with disjunctive constraints [J]. Operations Research, 1978, 12(4): 333-350
- [16] Taillard E. Scheduling instances [OL]. (2015-06-03). <http://mistic.heg-vd.ch/taillard/problems.dir/ordonnancement.dr/ordonnancement.html>
- [17] Wang Shu-ting. Studies on permutation flow shop scheduling using genetic algorithm variable neighborhood search [D]. Changsha: Huazhong University of Science and Technology, 2013 (in Chinese)
王书婷. 基于遗传变邻域算法的置换流水车间调度问题研究 [D]. 长沙: 华中科技大学, 2013