

基于智能体的多目标社会进化算法*

潘晓英¹⁺, 刘芳², 焦李成¹

¹(西安电子科技大学 智能信息处理研究所 智能感知与图像理解教育部重点实验室,陕西 西安 710071)

²(西安电子科技大学 计算机学院,陕西 西安 710071)

Multiobjective Social Evolutionary Algorithm Based on Multi-Agent

PAN Xiao-Ying¹⁺, LIU Fang², JIAO Li-Cheng¹

¹(Key Laboratory of Intelligent Perception and Image Understanding of the Ministry of Education of China, Institute of Intelligent Information Processing, Xidian University, Xi'an 710071, China)

²(School of Computer Science and Engineering, Xidian University, Xi'an 710071, China)

+ Corresponding author: E-mail: xiaoying_pan@163.com

Pan XY, Liu F, Jiao LC. Multiobjective social evolutionary algorithm based on multi-agent. Journal of Software, 2009,20(7):1703–1713. <http://www.jos.org.cn/1000-9825/3336.htm>

Abstract: In this paper, a multi-agent social evolutionary algorithm is proposed for multiobjective optimization problems. It completes the search process by the agent evolution. MOMASEA (multi-agent social evolutionary algorithm for multiobjective) defines the trust degree to denote the historical information of agents, and the neighborhood of agent is confirmed by it. According to the characteristic of multiobjective problems, three evolutionary operators are designed to complete the whole evolutionary process. The experimental results show that MOMASEA has a good convergence to the Pareto set. Furthermore, the analysis of the mode for instructs local environment verified that importing acquaintance net model can speed up the convergence effectively.

Key words: multiobjective optimization; multi-agent system; acquaintance net; trust degree; arena's principle

摘要: 提出了一种基于智能体的多目标社会进化算法用以求解多目标优化问题(multiobjective optimization problems,简称 MOPs),通过多智能体进化的思想来完成 Pareto 解集的寻优过程.该方法定义可信度来表示智能体间的历史活动信息,并据此确定智能体的邻域、控制智能体间的行为.针对多目标问题的特点,设计了3个进化算子分别体现适者生存、弱肉强食、多样性原则以及自学习的特性.同时采用擂台赛法则构造 Pareto 解的存储种群.仿真实验结果表明,该算法能够较好地收敛到 Pareto 最优解集上,并且具有良好的多样性.另外,通过对智能体局部邻域

* Supported by the National Natural Science Foundation of China under Grant Nos.60703107, 60703108, 60703109, 60702062 (国家自然科学基金); the National High-Tech Research and Development Plan of China under Grant No.2006AA01Z107 (国家高技术研究发展计划(863)); the National Research Foundation for the Doctoral Program of Higher Education of China under Grant No.20060701007 (国家教育部博士点基金); the National Basic Research Program of China under Grant No.2006CB705700 (国家重点基础研究发展计划(973)); the Program for Cheung Kong Scholars and Innovative Research Team in University of Ministry of Education of China under Grant No.IRT0645 (国家教育部长江学者和创新团队支持计划); the Natural Science Foundation of Shaanxi Province of China under Grant No.2007F32 (陕西省自然科学基金)

Received 2007-11-25; Revised 2008-02-04; Accepted 2008-04-02

环境建立方式的分析结果表明引入“关系网模型”可有效提高算法的收敛速度,并能在一定程度上提高解的质量.

关键词: 多目标优化;多智能体系统;关系网模型;可信任度;擂台赛法则

中图法分类号: TP18 **文献标识码:** A

多目标优化(multiobjective optimization)问题是工程中常见的问题,其主要特点是各目标之间的相互矛盾性使得问题实际上不可能存在某单个绝对最优解,而是存在“矛盾目标集”,即 Pareto 解集.求解 Pareto 解集的传统方法是,将多目标问题转换为多个不同的单目标优化问题分别加以求解.这些算法对于 Pareto 前端非凸的情形不能求出所有的 Pareto 最优解,而且多个目标之间很难进行比较.同时,这些方法为了获得近似的 Pareto 最优解集需要多次运行求解单目标优化问题,计算开销非常大,对于复杂的多目标优化问题,它们往往无能为力.进化算法基于种群的搜索方式实现了搜索的多向性和全局性,使得它非常适合于求解多目标优化问题.基于向量评估的 VEGA(vector evolution genetic algorithm)算法是第 1 种多目标进化算法,但本质上仍是加权和方法.在这之后,研究者相继提出了不同的多目标演化算法.例如 NSGA^[1],NPGA^[2],FFGA^[3],SPEA^[4],正交多目标演化算法^[5]以及基于个体密度距离的多目标进化算法^[6]等.这些算法都从不同的角度以进化算法对多目标优化问题进行了求解,在解决非凸性、阻止种群分化的发生等方面表现出较好的性能,但缺点是计算量大,目标函数较多时算法性能降低等.

多智能体技术是人工智能领域中的前沿学科之一,由于多智能体系统具有自主性、分布性、协调性以及自组织能力、学习能力和推理能力,使它在解决实际问题时具有很强的健壮性和可靠性,并具有较高的求解效率.达尔文的进化论则过分地强调了生存斗争,忽略了生物其他方面的种种联系,具有片面性.而事实上,整个系统复杂的自适应过程是由多子系统局部相互作用的协同进化过程.因此,借助多智能体系统中的协调协作机制以实现进化算法中个体的竞争和协作,无疑将加快算法的收敛和增强算法的优化能力.文献[7]利用多智能体进化的思想解决上万维的函数优化问题,体现了多智能体系统求解优化问题的优越性能.本文从智能体如何适应环境这个本质问题出发,将多智能体系统、遗传算法以及关系网模型相结合,提出了一种基于智能体的多目标社会进化算法.该方法定义可信任度表示智能体的历史活动信息,据此来确定智能体的邻域,控制智能体间的行为.同时,根据多目标优化问题的具体特点设计了 3 个有效的进化算子完成整个进化过程,分别体现适者生存、弱肉强食、多样性原则以及自学习特性;为保持较低的计算复杂度,采用擂台赛法则构造 Pareto 解的存储种群.

1 多目标优化问题

通常情况下,多目标优化问题可以定义为在一组约束条件下,极小化(或极大化)多个不同的目标函数.

定义 1. 一个多目标优化问题包含一个 n 个决策变量的集合、一个包含 k 个目标函数的集合和一个有 m 个约束条件的集合,其中,目标函数和约束条件是决策变量的函数.多目标优化问题的数学模型可以描述为

$$\begin{aligned} \min y = f(x) &= (f_1(x), f_2(x), \dots, f_k(x)) \\ \text{s.t. } e(x) &= (e_1(x), e_2(x), \dots, e_m(x)) \leq 0 \end{aligned} \quad (1)$$

其中, $x=(x_1, x_2, \dots, x_n) \in X$ 是变量向量, $y=(y_1, y_2, \dots, y_n) \in Y$ 为目标向量, X 和 Y 分别表示决策空间和目标空间.约束条件 $e(x) \leq 0$ 确定了可行解集.

定义 2. 对于任意两个目标向量 u 和 v ,

$$\begin{cases} u = v, & \text{iff } \forall i \in \{1, 2, \dots, k\}, u_i = v_i \\ u \geq v, & \text{iff } \forall i \in \{1, 2, \dots, k\}, u_i \geq v_i \\ u > v, & \text{iff } u \geq v \wedge u \neq v \end{cases} \quad (2)$$

定义 3. 对于任意两个决策向量 a 和 b ,二元关系 $>$, \geq 和 \sim 定义如下:

$$\begin{cases} a > b \text{ (} a \text{ dominates } b\text{)}, & \text{iff } f(a) > f(b) \\ a \geq b \text{ (} a \text{ weakly dominates } b\text{)}, & \text{iff } f(a) \geq f(b) \\ a \sim b \text{ (} a \text{ indifferent } b\text{)}, & \text{else} \end{cases} \quad (3)$$

在多目标优化问题中,不存在最优解使所有目标函数同时最优化,而是只能得到非劣解或 Pareto 解.Pareto 解的定义为:如果不存在 x 的任一可行解,使得 $f_i(x) \leq f_i(x^*)$, $i=1,2,\dots,k$,且只要不等号对至少有一个序号 i 成立,则 x^* 称为 Pareto 解.事实上,多目标优化问题的 Pareto 解是一个集合.所以,求解多目标优化问题的关键就是求出所有的 Pareto 解,形成解集,并寻求 Pareto 解集中的一个或多个满意解.

2 多智能体社会进化系统

2.1 多智能体进化思想

智能体 agent 是一个物理的或抽象的实体,它能作用于自身和环境,并能对环境做出反应.多智能体进化系统的基本思想为:将传统 GA 中的每个个体形成智能体,每个智能体采用进化机制,能够同时与环境和其他智能体交换信息,互相影响彼此的进化过程,使各个智能体之间能够产生协作行为,最终形成各个智能体之间以及智能体与环境之间的共同适应^[7].在多智能体进化模型中,将遵循以下的一些原则:每个 agent 都有初始能量;agent 具有局部性,其感知能力和行为只能针对有限的局部环境,即邻域;由于环境资源的有限性,agent 之间存在着激烈的竞争,能量较低的 agent 将死亡,这一行为称为适者生存原则;由于 agent 死亡而空余出来的节点会由其邻域内能量最高的 agent 产生一个子 agent 来替代,这一行为称为弱肉强食;或由随机生成的一个 agent 占据,这种行为称为多样化原则.每个 agent 具有交配能力,agent 在其邻域内找到合适的配偶进行交配,把优良的基因传给下一代.另外,agent 具有知识,它可以利用知识进行启发式搜索,以提高自身的能量和对环境的适应能力.

2.2 智能体协作机制——关系网模型

陈刚等人^[8]对 agent 社会组织方法和 agent 协作行为表现进行了研究,引入一个表示 agent 之间联系的“熟人关系网模型”,同时对 agent 之间的信任度关系进行了讨论.假设智能体 a 的属性包括: $name, address, capability$ 以及 $contact-list$,其中, $name(a)$ 表示名称; $address(a)$ 表示联系地址; $capability(a)$ 用于描述 a 对问题的求解能力; $contact-list(a)$ 表示 a 所有熟人通信信息的列表,表示为 $contact-list(a)=(L_1, L_2, \dots, L_s)$,列表中的每一个元素 L_i 称为熟人 i 的联系信息,有 $L_i=(name, address, trust)$,其中 $name(i), address(i), trust(i)$ 分别表示熟人 i 的名称、联系地址以及可信程度,与可信程度值大的熟人合作,成功的可能性也就越大.

定义 4. 可信程度:agent a 认为 b 在时间 t 的可信程度为 $trust(a,b,t)$,规定 $trust(a,b,t) \in [-1, +1]$ 并将初始时间 $t=0$ 时 b 的可信程度置为 0,即 $trust(a,b,0)=0$.

Agent 为了确定熟人的可信程度,需从与熟人合作成功与否来考虑:如果合作成功,则给该熟人的可信程度增加一个数量值;如果合作失败,则减少一个数量值.为了鼓励 agent 积极合作,假设在 agent 社会中,agent 遵循“知己难寻,冤家易结”的基本原则确定可信程度.设一次失败的合作对 agent 可信程度造成的损失为 γ ,一次成功的合作对 agent 可信程度带来的收益为 δ ,则 $\gamma > \delta$.一种简单的可信程度确定方法为可信程度积累策略.当 a 与 b 合作成功时: $trust(a,b,t+1)=trust(a,b,t)+\delta$;当 a 与 b 合作失败时: $trust(a,b,t+1)=trust(a,b,t)-\gamma$.一般地,可取 $\gamma=0.2, \delta=0.1$,也可根据具体问题进行适当地设置.

3 基于智能体的多目标社会进化算法

3.1 智能体定义

定义 5. 智能体 a 表示待优化函数的一个候选解,其能量等于根据 Zitzler^[4]所提出的适应度赋值方法计算所得的值,其目标为尽可能地增加智能体的能量.

智能体 a 可表示为 $a=(address, body, energy, neighbor)$,其中: $address$ 为智能体的联系地址,这里即为标号; $body$ 为智能体所包含的内容,以编码表示; $energy$ 为智能体的能量; $neighbor=(A_1, A_2, \dots, A_n)$ 表示智能体所能感知的局部环境,称为邻域.其中, $A_i=(address, trust)$ 为邻域中的一个智能体,其可信程度 $trust$ 表示两个智能体之间可信任的程度,用来控制智能体之间的行为.所有的智能体均生存在规模为 $lat \times lat$ 的网格上,每个智能体占据网格上一

个节点,且不能移动,如图 1 所示.




Fig.1 Sketch map of agent lattice

图 1 智能体网格结构图

3.2 邻域的建立及其更新

在多智能体进化系统中,智能体的感知能力与行为只能针对有限的局部环境,因此,如何定义智能体的邻域是一个非常关键的问题.在已有的多智能体进化系统中,大多采用位置相邻的概念,即选取某智能体位置上相邻的多个智能体作为其邻域,且在整个进化过程中保持不变.这种定义方式简单、直接,通过位置上的相邻将信息扩充到整个智能体网格中.但在多智能体系统中,智能体会根据自身所具有的自主性与协调性,自主地选择更有利的对象进行协作.因此,仅根据位置相邻这一点来确定“邻域”存在着一定的不足之处.

鉴于多智能体系统的活动在很大程度上是一种社会现象,文献[8]提出了一种新的智能体协作机制.本文采用该机制,以人类社会的“关系网模型”来完成智能体邻域的建立及更新,使其更符合真实的复杂适应系统,进一步加快了信息的扩散过程,快速而有效地完成了整体进化过程,其过程如图 2 所示.




Fig.2 Sketch map of neighbor variation

图 2 智能体邻域环境变化示意图

邻域初始化.对智能体种群中的智能体 a ,随机选择 4 个智能体形成其初始邻域,放入 $a.neighbor$ 中;

邻域更新.随着智能体与智能体及环境之间不断的相互作用,其局部感知环境也在不断地发生变化.文献[8]中指出,agent 系统的活动从很大程度上看是一种社会现象,可以通过构造 agent 社会关系网模型来表示协作 agent 的基本信息.因此,类似于“熟人关系网”模型中熟人圈子的扩充方式,设计智能体邻域扩充方式如下:

Strategy 1:令 $a=(address,body,energy,neighbor)$,其中 $a.neighbor=(l_1,l_2,\dots,l_s)$.在网格中随机选取位于 (i,j) 上的智能体 b 加入到 a 的邻域中,即 $a.neighbor=(l_1,l_2,\dots,l_s,b)$,其中 $trust(a,b)=0$.

Strategy 2:若 $b \in a.neighbor, c \in b.neighbor$,且 $trust(a,b)=1, trust(b,c)=1$,则 $c \in a.neighbor, trust(a,c)=0$.

类似地,其邻域缩减方式为:若 $a.neighbor=(l_1,l_2,\dots,l_s,b), trust(a,b)=-1$,则 $a.neighbor=(l_1,l_2,\dots,l_s)$.

3.3 算法策略分析

根据多智能体社会进化模型中需要遵循的一些原则以及多目标优化问题的特点,算法设计了以下策略:采用两个种群,一个为普通的智能体种群,另一个为存储 Pareto 解的存储种群;在智能体种群中,每个智能体视为一个节点,以可信任度作为连接的权值,并据此确定智能体的邻域,控制智能体间的行为.竞争算子体现了适者生存、弱肉强食以及多样性原则.协作算子体现了个体的交配,将优良的基因保留到下一代.自学习算子则完成智能体利用自身知识进行启发式搜索的过程,并采用擂台赛法则构造 Pareto 解的存储种群.

3.3.1 竞争行为

竞争行为模拟的是“社会中的竞争,失败的 agent 将无法继续生存”.对种群中的每个智能体,都将与其邻域内能量最大的智能体进行竞争操作.当智能体的能量小于其邻域中智能体的最大能量时,该智能体即无法继续

存活,其位置由新的智能体来替代.通过竞争算子,可以剔除种群中能量较低的智能体,提高群体总的能量水平.具体描述为:

设网格内某智能体为 $a=((i,j)(a_1,a_2,\dots,a_n),energy,neighbor)$, $m=((k,l)(m_1,m_2,\dots,m_n),energy,neighbor)$ 为智能体 a 的邻域内能量最高的智能体.如果 $a.energy < m.energy$,则 a 死亡,并产生一个新的智能体 $child=((i,j)(c_1,c_2,\dots,c_n),energy,neighbor)$ 来代替 a .其中, $child.neighbor=a.neighbor$, $body$ 部分 (c_1,c_2,\dots,c_n) 根据公式(4)式来产生:

$$c_i = m_i + U(-1,1) \times (m_i - a_i), i=1,2,\dots,n \quad (4)$$

其中, $U(\cdot,\cdot)$ 表示均匀分布的随机数.

为了同时体现弱肉强食和多样性原则,采用占据概率 $poccupy$ 来确定以何种方式产生的智能体去替代原智能体的位置.若 $rand \leq poccupy$,则以产生的 $child$ 替代;否则,以随机产生一个智能体来替代.竞争操作的主要目的是清除能量较低的智能体,以提高整个智能体系统的整体能量.因此, $poccupy$ 的取值应较大为宜.

3.3.2 协作行为

协作行为模拟了“从别处获得经验”.对于生存在环境中的智能体,它与其局部环境中的智能体发生协作关系,以提高自身能量.智能体将以概率 $pcross+trust \times 0.1$ 与其局部环境当中的所有智能体进行合作操作,保证智能体与其所信任的智能体之间会有更多的概率进行合作.这一点非常符合人类社会中的协作机制,减少了一些可能无效的操作,可进一步加快搜索速度.

假设 $(a',b')=cooperate(a,b)$,判断 a 和 a' 的占优情况.若 $a > a'$,则认为合作失败,保持原有的 a 不变,同时令 $trust(a,b)=trust(a,b)-0.2$;若 $a < a'$,则合作成功,以 a' 替代原有的 a ,并令 $trust(a,b)=trust(a,b)+0.1$;若 $a \sim a'$,则根据其拥挤程度来选择保留的 agent.这里所遵循的是人类社会中“知己难觅,冤家宜结”的原则,即一次失败的合作对其信任度的影响要大于一次成功的合作.

正交交叉算子^[9]是一种有效的算子,它利用正交设计来产生新个体.由于通常情况下并不知道最优解位置的信息,而正交矩阵可以确定一些数量较小的并在搜索空间中均匀分布的个体,因而可以产生少量的具有代表性的个体.同时,文献[5]也说明了以基于正交方式的多目标演化算法是十分有效的.因此,将正交交叉算子作用在 $a.body$ 及其邻域内的智能体上,形成邻域正交交叉算子,完成智能体的协作行为.

3.3.3 自学习行为

自学习行为模拟了“根据自身能力学习环境以提升能量”.在该行为中,智能体利用自己的知识来提高自身的能量,以增强竞争能力.为了减少计算量,该行为只作用于当前代能量最优的智能体上.假设该代中 Pareto 最优解的智能体为 $CSAgent$,其中 $CSAgent.body=(v_1,v_2,\dots,v_n)$,根据公式(5)产生一个新的解 (c_1,c_2,\dots,c_n) .

$$c_i = \begin{cases} v_i, & U(0,1) < 1/n \\ v_i + G(0,1/t), & \text{otherwise} \end{cases}, i=1,2,\dots,n \quad (5)$$

其中, $G(0,1/t)$ 表示高斯分布的随机数产生器, t 为进化代数.若新的解支配原有的解,则替代原有解成为 $CSAgent.body$.该算子即在原有的 Pareto 解上增加一个随机扰动,相当于在该解的附近寻找一个更好的解.因为在智能体网格所包含的候选解中,其 Pareto 最优解附近更有可能存在更好的解,因此,该算子的作用为对 Pareto 最优解进行局部爬山操作.

3.3.4 存储集种群构造规则

在基于 Pareto 的优化算法中,多目标进化群体的最优解集都是通过构造当前进化群体的非支配集来实现的.为尽量减小时间复杂度,这里采用了擂台赛法则^[10]来构造非支配集,并形成存储集种群.假设 L 为 k 个目标的多智能体进化群体,初始时令非支配集 $Nds=\emptyset$,并令 $Q=L$.具体过程可描述如下:

- (1) 从 Q 中任意选取一个个体 x ,作为比较对象;
- (2) 令 $Q=Q-x, RK=\emptyset, R=\emptyset$;
- (3) 若 Q 为空,则转步骤(5),否则转步骤(4);
- (4) 一次从 Q 中取一个个体 y ,与 x 比较其相互关系:
 - (4.1) 若 $x > y$,则令 $Q=Q-y$,转步骤(3);

- (4.2) 若 $y > x$, 则令 $x=y, Q=Q-y, RK=RK \cup R, R=\emptyset$;
 (4.3) 若 x 与 y 无关, 则令 $R=R \cup \{y\}, Q=Q-y$, 转步骤(3);
 (5) 令 $RK'=\{y \in RK | \text{not}(x > y)\}, Nds=Nds \cup \{x\}$;
 (6) 令 $Q=RK' \cup R$, 若 $|Q| > 1$, 则转步骤(1); 否则, 令 $Nds=Nds \cup Q$, 结束.

3.4 算法描述

假设多智能体种群 L 的规模为 N , 存储集种群为 P , 规模为 M , 占据概率为 $poccupy$, 交叉概率为 $pcross$.

- Step 1. 初始化 $L(0)$, 同时计算每个智能体的能量值, 令 $P \leftarrow \emptyset, gen \leftarrow 0$.
 Step 2. 停机条件判断. 若满足停机条件, 则算法停止运行并输出结果, 否则到下一步.
 Step 3. 存储集种群构造. 对智能体种群 L 中的智能体根据擂台赛法则构造非支配集, 将其添加到存储集种群 P 中, 并删除 P 中的劣解, 若 P 的规模大于预设规模 M , 则删除较拥挤的解, 结果仍记为 P .
 Step 4. 对 $L(gen)$ 中的每个智能体执行邻域竞争操作, 得到 $L(gen+1/3)$.
 Step 5. 对 $L(gen+1/3)$ 中的每个智能体执行邻域协同操作, 得到 $L(gen+2/3)$, 并更新智能体局部环境.
 Step 6. 对 $L(gen+2/3)$ 中的 Pareto 最优个体进行自学习操作, 得到下一代的初始智能体 $L(gen+1)$.
 Step 7. 令 $gen \leftarrow gen+1$, 并转 Step 2 继续操作.

3.5 算法分析

MOMASEA 是一种将多智能体技术和传统演化技术相结合的多目标算法, 该算法将遗传机制融合到多智能体系统中, 将进化算法中的个体作为一个具有局部感知、竞争协作和自学习能力的智能体, 通过智能体与环境以及智能体间的相互作用达到全局优化的目的. 利用遗传变异和适者生存机理以及多智能体的相互竞争和自学习的特性, 使得算法表现出优越的性能. 由于该算法利用了智能体的自学习特性, 所以能够充分利用它本身所具有的先验知识. 通过智能体之间的竞争作用, 使得能量较高的智能体具有较强的竞争能力, 能够更容易生存下去. 采用正交叉算子完成智能体间的协作过程, 使得智能体种群中的个体多样性增加. 利用“关系网模型”完成多智能体邻域的建立及更新过程, 更贴近真实的复杂适应系统, 可以更加快速而有效地完成整体进化过程. 利用“擂台赛法则”构造存储集种群可以有效地降低构造非支配集的复杂度, 提高运行效率. 由于各种因素的综合作用, 使得 MOMASEA 在求解多目标优化问题的 Pareto 解集上具有较优越的性能.

时间复杂度分析. 假设智能体种群 L 的规模为 $lat \times lat$, 记为 N , 算法迭代一次的时间复杂度可按以下方式进行分析: 存储集种群构造的时间复杂度为 $O(krN)$, 其中, k 为优化目标数目, r 为智能体种群中提取出的非支配个体数目, $r \leq N$. 设存储集规模为 M , 则删除劣解或拥挤解的时间复杂度为 $O(M)$, 邻域竞争操作的时间复杂度为 $O(N)$, 邻域协作操作的时间复杂度为 $O(wN)$, 其中, w 为邻域内智能体的个数, 且 $w \leq N$. 因此, 所需的总时间复杂度为 $O(krN) + O(M) + O(N) + O(wN)$. 一般地, 存储集规模 M 要小于等于智能体种群的规模 N , 根据 O 的运算法则并化简可知, 算法运行一次所需的时间复杂度为 $O(krN)$.

空间复杂度分析. 该算法主要的内存需求来自于存储当前代的智能体种群和存储集种群, 因此, 需存储的智能体个数最多为 $num(agent) = N + M$. 对于每个智能体, 需记录 $address, body, energy$ 和 $neighbor$ 这 4 个元素, 其中: $address$ 和 $energy$ 分别占一个单元; $body$ 为决策变量的编码, 当其变量个数为 n 时, 该部分即需占据 n 个存储单元; $neighbor$ 中每个智能体需占据 2 个存储单元, 因此 $neighbor$ 共需占据 $2w$ 个单元. 每个智能体所占的单元数为 $units(agent) = 2w + n + 2$. 因此, 算法所需的存储总单元数为 $num(units) = (N + M)n + (2w + 2)(N + M)$, 在最坏情况下为 $(N + M)n + 2N \times N + (2M + 2)N + 2M$. 因此, 该算法的空间复杂度为 $O(N^2)$.

4 实验结果及其分析

4.1 性能评价方法

(1) ζ 测度: Coverage of Two Sets

ζ 测度方法由 Zitzler 和 Thiele 提出, 假设 $X', X'' \subseteq X$ 是目标空间中的两个非劣解集. 函数 ζ 如下定义:

$$\zeta(X', X'') = \frac{|\{a'' \in X''; \exists a' \in X': a' \succ a''\}|}{|X''|} \quad (6)$$

其中, \succ 表示 Pareto 不劣于. 其中, $\zeta(X', X'')=1$ 表示集合 X'' 中的所有解均劣于集合 X' 中的解; 相反地, $\zeta(X', X'')=0$ 表示集合 X'' 中没有解劣于集合 X' 中的解. 该测度的缺点是不能度量 Pareto 前端的均匀性和宽广性.

(2) S 测度: Spacing

Srinivas 和 Deb 提出了一个度量 Pareto 前端均匀性的参数 S . 对于目标空间 X 中的非劣解集 X' , 有

$$S = \sqrt{\frac{1}{|X'|-1} \sum_{i=1}^{|X'|} (\bar{d} - d_i)^2} \quad (7)$$

其中, $d_i = \min_j \left\{ \sum_{k=1}^p |f_k(x_i) - f_k(x_j)| \right\}, x_i, x_j \in X', i, j = 1, \dots, |X'|$. \bar{d} 表示 d_i 的平均值, p 为目标函数的个数. S 越小, Pareto 前端的均匀分布越好, 该测度的缺点在于不能描述非劣解集 X' 与理想 Pareto 前端的逼近程度.

从以上定义可知, 第 1 种度量指标能够显示出两种算法得到的有效解集相互之间的支配关系, 第 2 个指标能够显示出算法得到的有效解集在目标空间中的分布情况. 一般情况下, 将两者混合起来进行算法性能的评价.

4.2 多目标函数优化问题测试

本文采用了非常普遍的 6 个多目标测试函数来验证基于智能体的多目标社会进化算法 MOMASEA 的性能, 并与 SPEA2^[11] 和 NSGAI^[12] 进行了算法性能的比较. 6 个测试函数见表 1, 这几个函数均包含两个目标函数, 在目标空间上的可行区域的凸性不同, 函数的维数也不同, 能够较全面地测试一种算法的求解性能. 其中: SCH 是一个凸函数, 且 Pareto 是连续的; KUR 是一个非凸函数, 且 Pareto 是非连续的; ZDT2 和 ZDT3 取搜索空间维数为 $D=30$, ZDT2 的最优前沿是非凸的, ZDT3 的最优前沿是间断的; ZDT4 和 ZDT6 的搜索空间维数为 $D=10$, ZDT4 具有 21^{N-1} 个局部 Pareto 最优前沿, ZDT6 的最优前沿是非凸且非均匀的; 所有的 ZDT 函数的 Pareto 最优前沿均满足 $g(x)=1$. 在以下的实验中, MOMASEA 的参数设置为 $N=100, M=100, p_{occupy}=0.85, p_{cross}=0.3$. SPEA2 的参数设置为: 种群规模为 100, 变异概率为 0.3, 交叉概率为 0.8, 外部存储集的大小为 100. NSGAI 的参数设置为: 交叉概率为 0.9, 变异概率为 $1/n$, 其中, n 为决策变量的个数. 3 种算法的迭代停止条件均为进化 100 代.

Table 1 Description of test functions

表 1 测试问题描述

Problem	n	Variable bounds	Objective functions	Optimal solutions	Comments
SCH	1	$[-10^3, 10^3]$	$f_1(x)=x^2; f_2(x)=(x-2)^2$	$x \in [0, 2]$	Convex
KUR	3	$[-5, 5]$	$f_1(x) = \sum_{i=1}^{n-1} \left(-10 \exp \left(-0.2 \sqrt{x_i^2 + x_{i+1}^2} \right) \right)$ $f_2(x) = \sum_{i=1}^n (x_i ^{0.8} + 5 \sin x_i^3)$	/	Nonconvex
ZDT2	30	$[0, 1]$	$f_1(x)=x_1$ $f_2(x)=g(x)[1-(x_1/g(x))^2]$ $g(x) = 1 + 9 \left(\sum_{i=2}^n x_i \right) / (n-1)$	$x_1 \in [0, 1]$ $x_i = 0$ $i=2, \dots, n$	Nonconvex
ZDT3	30	$[0, 1]$	$f_1(x) = x_1$ $f_2(x) = g(x) \left[1 - \sqrt{x_1/g(x)} - x_1/g(x) \sin(10\pi x_1) \right]$ $g(x) = 1 + 9 \left(\sum_{i=2}^n x_i \right) / (n-1)$	$x_1 \in [0, 1]$ $x_i = 0$ $i=2, \dots, n$	Convex, disconnected
ZDT4	10	$x_1 \in [0, 1]$ $x_i \in [-5, 5]$ $i=2, \dots, n$	$f_1(x) = x_1$ $f_2(x) = g(x) \left[1 - \sqrt{x_1/g(x)} \right]$ $g(x) = 1 + 10(n-1) + \sum_{i=2}^n [x_i^2 - 10 \cos(4\pi x_i)]$	$x_1 \in [0, 1]$ $x_i = 0$ $i=2, \dots, n$	Nonconvex
ZDT6	10	$[0, 1]$	$f_1(x) = 1 - \exp(-4x_1) \sin^6(6\pi x_1)$ $f_2(x) = g(x) [1 - (f_1(x)/g(x))^2]$ $g(x) = 1 + 9 \left[\left(\sum_{i=2}^n x_i \right) / (n-1) \right]^{0.25}$	$x_1 \in [0, 1]$ $x_i = 0$ $i=2, \dots, n$	Nonconvex, nonuniformly spaced

分别假设以 MOMASEA, NSGAI 和 SPEA2 所得到的 Pareto 解集为 $X(M), X(N)$ 以及 $X(S)$, 则测度 $\zeta(X(M), X(N))$ 和 $\zeta(X(N), X(M))$ 反映了 MOMASEA, NSGAI 所求得的 Pareto 解间的关系; 而测度 $\zeta(X(M), X(S))$ 和 $\zeta(X(S), X(M))$ 则反映了 MOMASEA 和 SPEA2 所求得的 Pareto 解之间的关系. 表 2 为所测试函数以不同算法各独立运行 20 次所获得的 ζ 测度值比较. 其中, 每个指标中的第 1 行 mean 表示所得 ζ 测度的平均值, 而第 2 行 variance 表示的则是偏差值. 从表 2 中可以看出, 在 6 个函数所得的结果中, 相对于平均值来说, $\zeta(X(M), X(N))$ 均大于 $\zeta(X(N), X(M))$, $\zeta(X(M), X(S))$ 也均大于 $\zeta(X(S), X(M))$. 即在通过 MOMASEA 所求得的 Pareto 解中, 有大部分能够支配以 NSGAI 或 SPEA2 所求得的解; 反过来则不然. 另外我们注意到, 在 20 次独立运行当中, 偏差值 variance 都保持在一个较小的值, 说明 MOMASEA 在求解这些问题上的优越性是很稳定的. 特别地, 对于函数 ZDT4, 由 MOMASEA 所得的解可以全部支配由 NSGA-II 和 SPEA2 所得解, 说明算法能够很好地收敛到 Pareto Front 上.

Table 2 Mean and variance of the coverage of two sets

表 2 各算法对不同问题的 ζ 测度

Index		SCH	KUR	ZDT2	ZDT3	ZDT4	ZDT6
$\zeta(X(M), X(N))$	Mean	0.987 452	0.924 563	0.895 421	0.854 242	1.000 000	0.724 156
	Variance	0.002 154	0.003 255	0.001 215	0.002 141	0.000 000	0.002 568
$\zeta(X(N), X(M))$	Mean	0.352 458	0.325 147	0.798 563	0.741 545	0.000 000	0.265 478
	Variance	0.003 210	0.002 845	0.001 452	0.002 112	0.000 000	0.003 124
$\zeta(X(M), X(S))$	Mean	0.854 788	0.896 542	0.887 575	0.896 545	1.000 000	0.685 471
	Variance	0.002 659	0.002 698	0.001 632	0.001 985	0.000 000	0.004 152
$\zeta(X(S), X(M))$	Mean	0.532 654	0.412 574	0.801 254	0.785 421	0.000 000	0.325 648
	Variance	0.002 586	0.003 012	0.001 325	0.001 548	0.000 000	0.004 563

对于多目标优化问题, 除了要求所得到的解尽量收敛到有效解集之外, 还希望解能够在目标空间中分布得尽量均匀. 因此, 仅仅以 ζ 测度并不能完全说明一种算法的性能. 表 3 给出了各算法对 6 个测试函数分别独立运行 20 次所得结果的 S 测度, 该测度可以很好地反映算法所得的有效解集在目标空间中的分布情况. S 测度越小, 则说明所得解集在 Pareto 前端分布的均匀性越好.

Table 3 Mean and variance of the spacing

表 3 各算法对不同问题的 S 测度

Algorithm		SCH	KUR	ZDT2	ZDT3	ZDT4	ZDT6
NSGAI	Mean	1.021 110	0.852 990	0.755 148	0.672 938	0.798 463	0.849 389
	Variance	0.004 372	0.002 619	0.004 521	0.003 587	0.014 616	0.002 713
SPEA2	Mean	0.449 265	0.442 195	0.435 112	0.575 606	0.479 475	0.644 477
	Variance	0.002 062	0.001 498	0.004 607	0.005 078	0.009 841	0.005 042
MOMASEA	Mean	0.215 421	0.312 454	0.201 545	0.321 545	0.251 478	0.386 542
	Variance	0.002 145	0.001 542	0.002 536	0.003 124	0.004 574	0.003 258

从表 3 中可以看出, 算法 MOMASEA 对于 6 个测试问题所得的 S 测度值均在 0.2~0.4 之间, 说明通过该算法所得到的有效解集在 Pareto 的前端分布较均匀. 而且与 NSGAI 以及 SPEA2 相比, 其 S 测度也都小于这两种算法所得的值. 因此, 综合 ζ 测度和 S 测度这两项指标可以认为, MOMASEA 在解多目标优化问题上具有比 NSGAI 和 SPEA2 更优越的性能.

为了更直观地说明本文算法在求解多目标优化问题上的优越性, 我们以图形方式给出了这几个典型问题的仿真结果, 如图 3 所示. 图中从上到下依次为问题 SCH, KUR, ZDT2, ZDT3, ZDT4 和 ZDT6 的测试结果, 从左到右的 3 幅图像分别为算法 NSGAI, SPEA2 和 MOMASEA 所求得的非劣解集. 其中, 星状点表示所求得的优化解, 线条表示了理想的 Pareto 前沿面.

从这个图中我们可以看出, 对于 SCH 问题, NSGAI 和 SPEA2 所得的结果都不甚理想. 虽然大部分解都可以收敛到 Pareto Front 上, 但是均匀性比较差; 而 MOMASEA 所得的结果不但全部收敛到了 Pareto Front 上, 而且呈均匀分布状态; KUR 为一个三维两个目标的最小化问题, 其 Pareto Front 是不连续的. 可以看到, 对于这样 3 变量的最小化问题, MOMASEA 具有更加明显的优势. 首先, 相对于 SPEA2 和 NSGAI, MOMASEA 可以找到最多的非支配解, 而且 MOMASEA 所找到的最优解大部分都支配着其他两种算法找到的最优解. 同时, SPEA2 和 NSGAI 所求得的解仅能收敛到其中的两个片段上, 而 MOMASEA 求得的解可以收敛到所有片段上, 且均匀性

分布较好.对于问题 ZDT2,3 种算法所得的结果相差不大,但是 MOMASEA 所得解的均匀性分布要更好一些.问题 ZDT3 的 Pareto Front 为 5 个不连续的片段,虽然三者得到的结果其收敛性较好,但是 SPEA2 所得的解没有收敛到所有的有效区间上;对于问题 ZDT4,这是一个较难解决的问题,SPEA2 和 NSAGII 都未能求得收敛到 Pareto Front 上的解,但是 MOMASEA 所求结果不但收敛性非常好,而且在有效的目标空间中均匀分布.问题 ZDT6 的结果也同样说明了算法 MOMASEA 的优越性.另外,综合表 2、表 3 和图 3,数值结果与图形结果是一致的.

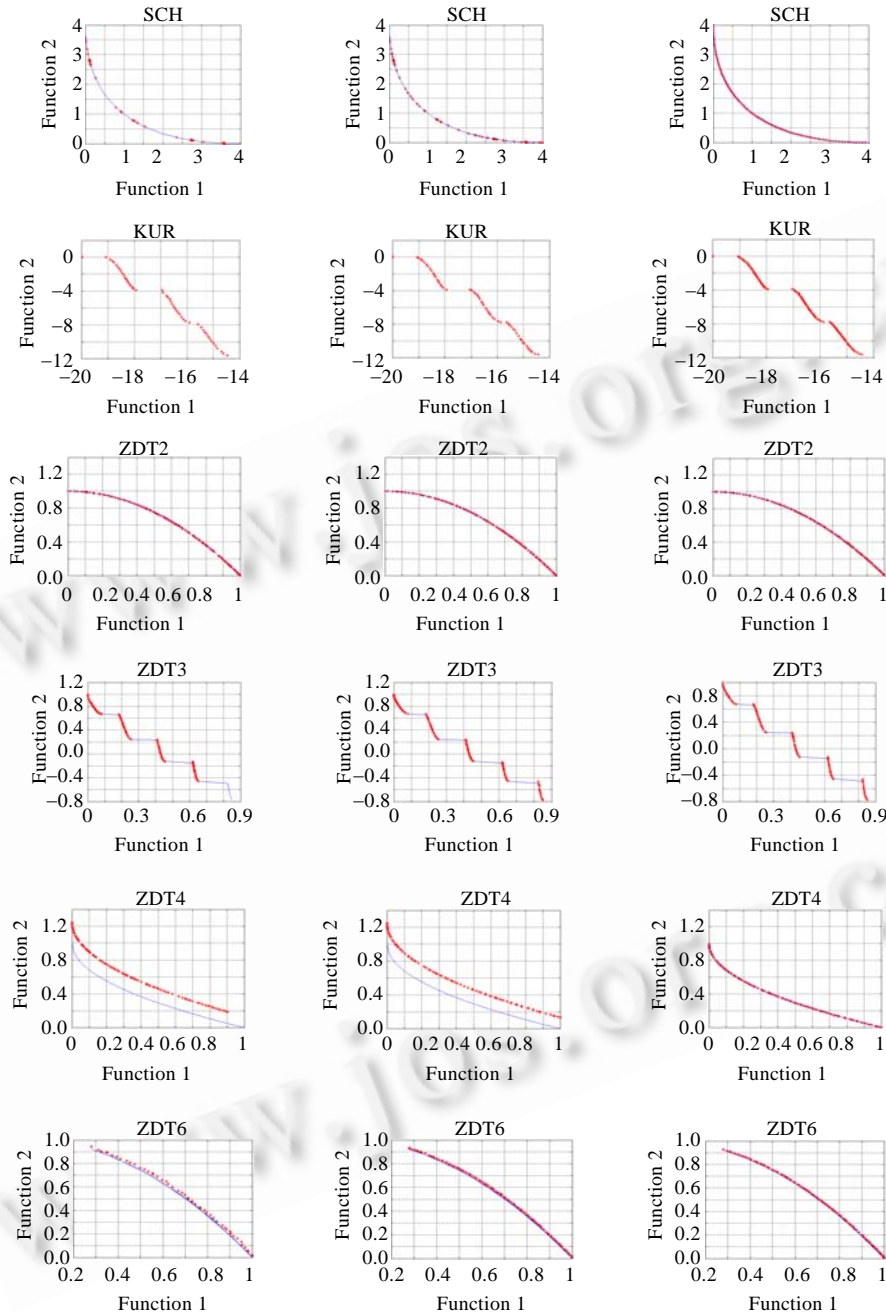


Fig.3 Nondominated solutions with SPEA2, NSGAI and MOMASEA

图 3 SPEA2,NSAG-II 以及 MOMASEA 对 6 个问题的测试结果

4.3 智能体邻域建立方式分析

在 MOMASEA 算法中,借鉴人类社会的“关系网模型”思想,定义了可信任度来表示智能体历史合作信息,控制智能体之间的行为,并据此来建立智能体所能感知的邻域环境.为了说明该机制对算法的影响,分别对测试函数 SCH,KUR 以及 ZDT4 进行以下实验.在实验中,其余设置完全与 MOMASEA 相同,只是在确定智能体邻域时仅仅采用位置相邻的概念,以 MAGA^[10]中的方式确定智能体邻域.为方便起见,记该算法为 MOMAGA.表 4 为算法对这 3 个函数分别独立运行 20 次后所得的平均 ζ 测度和 S 测度,其中 $X(M)$ 和 $X(G)$ 分别为由算法 MOMASEA 和 MOMAGA 所求得的 Pareto 解集.

Table 4 Comparison of MOMAGA and MOMASEA

表 4 MOMAGA 和 MOMASEA 的比较

Index		Generations	SCH	KUR	ZDT4
Coverage of two sets	$\zeta(X(G),X(M))$	20	0.135 641	0.215 563	0.169 854
		50	0.296 354	0.301 258	0.356 845
		100	0.635 874	0.635 847	0.612 589
	$\zeta(X(M),X(G))$	20	0.748 652	0.723 654	0.736 258
		50	0.945 633	0.921 546	0.926 644
		100	0.975 236	0.963 852	0.985 321
Spacing	MOMAGA	20	0.536 242	0.642 356	0.489 652
		50	0.321 457	0.446 985	0.352 147
		100	0.256 4 84	0.332 145	0.298 759
	MOMASEA	20	0.365 241	0.415 785	0.332 569
		50	0.245 214	0.368 577	0.268 541
		100	0.215 421	0.312 454	0.251 478

首先来分析 ζ 测度.在进化到 20 代时,对于 3 个测试函数,由 MOMASEA 所得的解集中就有 70% 左右的解不劣于由 MOMAGA 所得到的解;在进化到 50 代时,这样的比例达到了 90% 以上;当进化代数 100 时,解集 $X(M)$ 中的大部分解都已经非劣于 $X(G)$ 中的解了.反过来,在 20 代进化后, $X(G)$ 中的解仅有 20% 左右的解非劣于 $X(M)$ 中的解;50 代之后也仅达到了 30% 左右,100 代之后这样的比例为 60% 左右.这说明,采用人类社会“关系网模型”建立智能体的邻域环境之后,不但能在一定程度上加快算法的收敛速度,而且解的质量也有所提高.再者,在 S 测度方面,虽然两者的差别不是很大,但很显然, $X(M)$ 中解的均匀性要略好于 $X(G)$ 中的解.

在 MOMASEA 中,主要的两个操作算子——竞争算子以及协作算子均作用在智能体所能感知的局部邻域环境之上,因此,邻域环境的选择是比较关键的.借鉴和智能体系统具有类似结构以及发展特性的人类社会中所存在的“关系网模型”,以“可信任度”来记录智能体间的历史活动信息,动态控制每个智能体的局部环境,使具有有利信息的智能体能够较快地把其优良的基因扩散到整个智能体网格当中,实现智能体之间、智能体与环境之间的平衡.表 4 的结果表明了该思想的有效性.

5 结 论

针对多目标优化传统算法中存在的一些问题,引入了人工智能领域中的多智能体技术,同时结合遗传算法、关系网模型来形成多智能体社会进化系统求解多目标优化问题.首先根据“关系网模型”的思想来确定智能体所能感知的邻域环境,构建多智能体社会进化系统,并根据问题的具体特点设计了竞争算子、协作算子以及自学习算子来完成多智能体的进化过程,以达到最终的智能体之间、智能体与环境之间的平衡.仿真结果表明,算法 MOMASEA 具有良好的性能,在解决多目标优化问题时能够找到比其他两种算法更高质量的 Pareto 的解集.同时,通过对邻域环境建立方式的分析,说明借鉴“关系网模型”的思想,以可信任度动态控制局部环境的方式能够有效地提高算法收敛速度,并在一定程度上提高解集的质量.

References:

- [1] Srinivas N, Deb K, Multiobjective optimization using nondominated sorting in genetic algorithms. Evolutionary Computation, 1994, 2(3):221-248.

- [2] Horn J, Nafpliotis N, Goldberg DE. A niched Pareto genetic algorithm for multiobjective optimization. In: Proc. of the 1st IEEE Conf. on Evolutionary Computation. Piscataway: IEEE World Congress on Computational Computation, 1994,1:82-87.
- [3] Fonseca CM, Fleming PJ. Multiobjective optimization and multiple constraint handling with evolutionary algorithms—Part I: A unified formulation. IEEE Trans. Systems, Man, and Cybernetics, 1998,28(1):26-37.
- [4] Zitzler E, Thiele L. Multiobjective evolutionary algorithms: A comparative case study and the strength Pareto approach. IEEE Trans. Evolutionary Computation, 1999,3(9):257-271.
- [5] Zeng SY, Wei W, Kang LS, Yao SZ. A multi-objective evolutionary algorithm based on orthogonal design. Chinese Journal of Computers, 2005, 28(7):1153-1162 (in Chinese with English abstract).
- [6] Lei DM, Wu ZM. Crowding-Measure based multi-objective evolutionary algorithm. Chinese Journal of Computers, 2005,28(8): 1320-1326 (in Chinese with English abstract).
- [7] Zhong WC, Liu J, Xue MZ, Jiao LC. A multiagent genetic algorithm for global numerical optimization. IEEE Trans. on Systems, Man and Cybernetics, 2004,34(2):1128-1141.
- [8] Chen G, Lu RQ. The relation Web model: An organizational approach to agent cooperation based on social mechanism. Journal of Computer Research and Development, 2003,40(1):107-114 (in Chinese with English abstract).
- [9] Leung YW, Wang Y. An orthogonal genetic algorithm with quantization for global numerical optimization. IEEE Trans. on Evolutionary Computation, 2001,5(1):41-53.
- [10] Zheng JH, Jiang H, Kuang D, Shi ZZ. An approach of constructing multi-objective Pareto optimal solutions using arena's principle. Journal of Software, 2007,18(6):1287-1297 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/18/1287.htm>
- [11] Zitzler E, Laumanns M, Thiele L. SPEA2: Improving the strength Pareto evolutionary algorithm. In: Giannakoglou K, Tsahalis D, Periaux J, Papailou P, Fogarty T, eds. Proc. of the EUROGEN 2001, Evolutionary Methods for Design, Optimization and Control with Applications to Industrial Problems. Athens, 2002. 95-100.
- [12] Deb K, Pratap A, Agarwal S, Meyarivan T. A fast and elitist multiobjective genetic algorithm: NSGA-II. IEEE Trans. on Evolutionary Computation, 2002,6(2):182-197.

附中文参考文献:

- [5] 曾三友,魏巍,康立山,姚书振.基于正交设计的多目标演化算法.计算机学报,2005,28(7):1153-1162.
- [6] 雷德明,吴智铭.基于个体密集距离的多目标进化算法.计算机学报,2005,28(8):1320-1326.
- [8] 陈刚,陆汝钤.关系网模型——基于社会合作机制的多 Agent 协作组织方法.计算机研究与发展,2003,40(1):107-114.
- [10] 郑金华,蒋浩,邝达,史忠植.用擂台赛法则构造多目标 Pareto 最优解集的方法.软件学报,2007,18(6):1287-1297. <http://www.jos.org.cn/1000-9825/18/1287.htm>



潘晓英(1981—),女,浙江缙云人,博士生,主要研究领域为多智能体系统,数据挖掘,进化计算.



焦李成(1959—),男,博士,教授,博士生导师,CCF 高级会员,主要研究领域为人工免疫系统,模式识别,神经网络,数据挖掘,图像处理.



刘芳(1963—),女,教授,博士生导师,主要研究领域为智能信息处理,模式识别.