

基于灰预测和正态云的参数自适应蚁群遗传算法

牟 峰¹, 袁晓辉², 王慈光¹, 景 云¹

(1. 西南交通大学 交通运输学院, 四川 成都 610031; 2. 西南交通大学 信息科学与技术学院, 四川 成都 610031)

摘要: 基于正反馈机制的蚁群算法, 在进行全局搜索时, 具有很强的全局收敛能力; 遗传算法则具有快速的全局搜索能力. 为了充分利用两种算法在寻优过程中的优势, 提出一种带有参数自适应调节能力的混合算法. 该算法利用灰预测对最大最小蚁群策略中的信息素上(下)界进行估计, 以达到实时控制信息素限界、避免算法陷入局部最优的目的. 同时, 通过云模型建立了一系列的关联规则, 利用算法在迭代过程中的反馈信息, 可实现算法参数的自适应控制, 有效减小算法对参数初始设置的依赖. 最后, 对车间调度问题(JSP)和旅行商问题(TSP)算例的仿真结果证明了算法的有效性.

关键词: 混合算法; 最大最小蚂蚁系统; 遗传算法; 正态云; 灰预测

中图分类号: TP18 **文献标识码:** A

Ant-colony-genetic algorithm with adaptive parameters based on grey prediction and normal cloud

MU Feng¹, YUAN Xiao-hui², WANG Ci-guang¹, JING Yun¹

(1. College of Traffic and Transportation, Southwest Jiaotong University, Chengdu Sichuan 610031 China;

2. School of Information Science & Technology, Southwest Jiaotong University, Chengdu Sichuan 610031, China)

Abstract: Ant colony algorithm with positive feedback has a good capability of global convergence; while the genetic algorithm(GA) is with a fast performance in global search. A hybrid algorithm with adaptive parameters is proposed to take advantages of the above two optimization algorithm. Using the grey prediction, we obtain in the ant colony strategy the estimates of the maximum (minimum) trail limits which are controlled for avoiding the immature convergence. Meanwhile, we employ the cloud models to build a set of association rules which are used to adaptively adjust algorithm parameters by information feedback during the iterative process, thus reducing the reliance on initial parameters. Simulation results for job-shop scheduling problem(JSP) and traveling salesman problem(TSP) validate the algorithm.

Key words: hybrid algorithm; max-min ant system(MMAS); genetic algorithm (GA); normal cloud; grey prediction

1 引言(Introduction)

蚁群算法^[1~3]和遗传算法^[4,5]是可用于求解复杂优化问题的两种常见的仿生优化算法. 前者是对蚂蚁群体通过信息素进行信息传递从而实现相互协作、完成复杂任务的行为进行模拟而建立的. 后者则是基于“优胜劣汰”的生物进化思想而建立的. 为了改善两种算法易于出现早期停滞(早熟现象)的问题, 学者们提出了各种改进措施. 在蚁群算法方面, Stützle和Hoos等人提出最大最小蚂蚁系统^[6,7], 该算法系统通过设定信息素浓度的最大和最小限界, 避免了因算法在每次循环中只更新最优路径信息而造成的某些路径弧段上信息素过高的现象, 很大程度上减少了算法陷入早期停滞的现象. 但所构造的限界往往是确定值, 使得信息素限界在算法运行

中前期的作用非常有限. 而文献[8]则基于云模型对信息素残留系数 $1 - \rho$ 和ant-cycle模型中影响算法收敛速度的信息素强度 Q 建立了相关的定性关联规则, 运用这些规则, 可实现对参数 $1 - \rho$ 和 Q 的自适应调节. 在遗传算法方面, 由于标准遗传算法采用固定的交叉及变异概率, 若二者过大, 会使得算法运行后期遗传种群中的优良基因片段易遭破坏; 若二者过小, 会使得算法运行初期遗传种群难于快速产生优良个体. 为此, 一些学者对交叉概率和变异概率的自适应控制策略进行了研究. 如文献[9]利用模糊理论中的隶属度函数建立自适应的控制策略, 但隶属度函数的确定往往基于经验原则, 难于准确刻画, 这很大程度上限制了参数控制策略的效果. 为了克服这一不足之处, 文献[10]构造了一种群体平均适应度值和

个体适应度值的关联关系,并利用正态云的随机性和稳定倾向性特征,通过云发生器生成自适应的交叉和变异概率.

灰预测^[11]在处理小样本贫信息的预测问题时具有良好的效果,而算法迭代过程中所反馈的信息恰恰具有灰色信息的特征,因此采用邻近几代的信息素限界信息预测下一代的信息素限界,达到控制信息素浓度变化范围的目的,可进一步避免因信息素浓度累积速度过快而造成的算法停滞现象.云模型^[12~14]是用语言值表示的定性概念与其定量表示之间的不确定性转换模型,它在很大程度上克服了模糊理论中隶属度函数边界“过硬”的缺陷.由云模型所建立的定性化关联规则体现了“专家系统中,对同一事物具有不同认识的思想”,具体采用哪种认识标准则通过随机决策决定,有效降低了由于采取固定认识标准造成决策失误的可能性.利用这一优点建立的云关联规则,可使算法参数得到满意的自适应调节效果.将最大最小蚂蚁系统和遗传算法作为同一算法的两个策略.让每代中蚁群策略所得的部分较好解按照某种规则替换遗传种群中部分较差的解,发挥遗传操作较强的全局搜索能力进行寻优,在改进遗传种群整体适应度水平的同时,也利用遗传种群中的优良个体所提供信息指导蚂蚁个体的寻优,进而减小蚁群策略陷入早期停滞的可能性.

2 算法思想(Algorithm)

2.1 最大最小蚁群策略(Max-min ant colony strategy)

2.1.1 蚂蚁路径的构造(Ant path construction)

在第 t 次循环过程中,每只蚂蚁 k 根据下列方式选择下一个访问节点:

$$j = \begin{cases} \{\arg \max\{\tau_{ij}^{\gamma(t)}[\eta_{ij}]\}, & q \leq q_0, \\ S, & \text{其他.} \end{cases} \quad (1)$$

其中: q 和 q_0 均为在 $[0,1]$ 上服从均匀分布的随机数, S 表示根据式(2)进行选择:

$$P_{ij}^k(t) = \frac{[\tau_{ij}^{\gamma(t)}][\eta_{ij}]}{\sum_{j \in \text{allow}_k} [\tau_{ij}^{\gamma(t)}][\eta_{ij}]}, \quad j \in \text{allow}_k. \quad (2)$$

其中: allow_k 为蚂蚁 k 下一步允许选择的节点集合, $\tau_{ij}(t)$ 和 $\gamma(t)$ 分别为第 t 次循环中节点 i 和 j 之间的信息素浓度和信息素相对重要程度参数, η_{ij} 为点 i 和 j 之间的期望启发式信息.

2.1.2 信息素的更新策略(Pheromone update)

信息素的更新分为局部(信息素)更新和全局(信息素)更新.局部更新是一种信息素的负反馈机制,它可增加未访问路径被选择的机会,从而扩大算法

的搜索空间,避免算法陷入局部最优;全局更新是信息素的正反馈机制,它使得全局最优解所经路径上的信息素增强,使算法最终收敛于最优解;信息素限制更新是将每一代信息素浓度的变化限定在一个合理的范围内,避免由于各种不确定因素引起的早期停滞现象.

1) 根据式(3)进行信息素的局部更新.

对于第 k 只蚂蚁,如果节点 i 和 j 是它所构造路径上的两个相邻节点,则有

$$\tau_{ij}(t) = [1 - \rho(t)]\tau_{ij}(t) + \rho(t)\tau_0. \quad (3)$$

否则,不予更新.其中 τ_0 为各路径弧段上信息素初值,为一定值.

2) 根据式(4)~(6)进行信息素的全局更新:

$$\tau_{ij}(t+1) = [1 - \rho(t)]\tau_{ij}(t) + \rho(t)\Delta\tau_{ij}(t), \quad (4)$$

其中 $\Delta\tau_{ij}(t)$ 是在本次迭代中,节点 i 和 j 之间的信息素增量,且有

$$\Delta\tau_{ij}(t) = \sum_{k=1}^m \Delta\tau_{ij}^k(t). \quad (5)$$

其中 $\Delta\tau_{ij}^k(t)$ 表示蚂蚁 k 在本次循环中遗留在节点 i 和 j 之间的信息素浓度,且有

$$\Delta\tau_{ij}^k(t) = \begin{cases} \frac{1}{l_{\text{best}}}, & (i,j) \in L_{\text{best}}, \\ 0, & \text{其他.} \end{cases} \quad (6)$$

其中: l_{best} 为历史最优路径长度, L_{best} 为历史最优路径.

3) 根据式(7)进行信息素的限制更新:

$$\tau_{ij}(t+1) = \begin{cases} \hat{\tau}_{\max}(t+1), & \tau_{ij}(t+1) > \hat{\tau}_{\max}(t+1), \\ \tau_{ij}(t+1), & \text{其他.} \end{cases} \quad (7)$$

其中 $\hat{\tau}_{\max}(t+1)$ 为第 $t+1$ 代中信息素浓度上界的预测估计,其具体确定方法在本文第2.4节中论述.

2.2 遗传策略(Genetic strategy)

2.2.1 染色体的构造(Chromosome construction)

在第 t 次循环过程中,每个染色体按照下列的转移概率选择下一位基因:

$$P_{ij}^k(t) = \frac{\eta_{ij}}{\sum_{j \in \text{allow}_k} \eta_{ij}}, \quad j \in \text{allow}_k. \quad (8)$$

其中 allow_k 和 η_{ij} 的意义与蚁群策略中相同符号类似.

2.2.2 杂交操作(Crossover operation)

在交叉操作中,采用基于位置的非常规码杂交法,即随机选择一组杂交位,把一个父代串在这组位

置上的元强加到另一个父代串对应的位置上, 其余的元顺序填入其余的位置. 例如:

假设所选杂交位由下划线表示, 则有

父代A: 123456789 → 子代A: 162435879;

父代B: 462531978 → 子代B: 423651987.

2.2.3 变异操作(Mutate operation)

在变异操作中, 本文采用交换变异算子, 即: 随机选择两个基因位, 相互交换这两个位置上的基因. 例如:

假设所选变异位由下划线表示, 则有

父代A: 123456789 → 子代A: 183456729.

2.3 几个控制参数(Several control parameters)

在这一节中, 将引入一些新的控制参数用于建立灰预测模型和云关联规则.

2.3.1 适应度改进测度(Fitness-improvement measure)

定义2个适应度改进测度 $\theta_A(t)$ 和 $\theta_G(t)$ 如下:

$$\theta_A(t) = \frac{F_{A_{\text{best}}}(1) - \bar{F}_{A_{\text{best}}}(t)}{F_{A_{\text{best}}}(1)}, \quad (9)$$

$$\theta_G(t) = \frac{F_{G_{\text{ave}}}(0) - F_{G_{\text{ave}}}(t)}{F_{G_{\text{ave}}}(0)}. \quad (10)$$

其中: $\bar{F}_{A_{\text{best}}}(t)$ 为前 t 次循环中每代最优蚂蚁路径的平均适应度值, $F_{A_{\text{best}}}(t)$ 和 $F_{G_{\text{ave}}}(t)$ 为第 t 次循环中所得最优蚁群路径的适应度值和遗传种群的平均适应度值, 它们被分别定义如下:

$$F_{A_{\text{best}}}(t) = \min_{k \in m_A} \{F_A^k(t)\}, \quad (11)$$

$$\bar{F}_{A_{\text{best}}}(t) = \frac{\sum_{i=1}^{t-1} F_{A_{\text{best}}}(i)}{t-1}, \quad (12)$$

$$F_{G_{\text{ave}}}(t) = \frac{\sum_{k=1}^{m_G} F_G^k(t)}{m_G}. \quad (13)$$

其中: $F_A^k(t)$ 为第 t 次循环中第 k 只蚂蚁所构造路径的适应度值, m_A 为蚁群规模. $F_G^k(t)$ 为第 t 次循环中第 k 个染色体的适应度值, m_G 为遗传种群规模.

适应度改进测度是执行云关联规则的基础. 当使用云关联规则进行参数的自适应控制时, $\theta_A(t)$ 和 $\theta_G(t)$ 将作为规则前件的输入.

2.3.2 沟通参数(Communion parameter)

选择 $C(t)$ 个蚁群策略所得最好解去替换本代原有遗传种群中最差的 $C(t)$ 个解, 由 $C(t)$ 的实际作用, 将其称为沟通参数. $C(t)$ 根据式(14)选取:

$$C(t) = \begin{cases} [\theta_G(t) \times m_A] + 1, & \theta_G(t) > 0, \\ 0, & \text{其他.} \end{cases} \quad (14)$$

其中 $[\theta_G(t) \times m_A]$ 表示对 $\theta_G(t) \times m_A$ 取整数.

2.3.3 信息素极差函数(Range of pheromone matrix measure function)

传统的MMAS中, 信息素浓度界值 τ_{max} 和 τ_{min} 是根据具体问题构造的定值, 用以改善因信息素的累积而造成的正反馈过剩的现象. 在算法运行初期, 由于全局信息的匮乏, 使得各路径间的信息素浓度差距不大, 所以给定的 τ_{max} 和 τ_{min} 几乎没有作用, 换言之, 它们仅在算法的中后期发挥作用, 以避免算法陷入局部最优、扩大搜索范围. 为了自适应地控制信息素浓度界值, 定义信息素极差函数如下:

$$d(t) = \tau_{\text{max}}(t) - \tau_{\text{min}}(t). \quad (15)$$

其中: $\tau_{\text{max}}(t)$ 和 $\tau_{\text{min}}(t)$ 分别为第 t 次循环中信息素上界和信息素下界, $d(t)$ 为单调不减函数, 且有 $d(0) = 0$.

2.4 信息素浓度限界的灰色预测控制(Grey prediction control of pheromone limits)

20世纪80年代, 邓聚龙教授建立了灰色理论(见文献[11]). 该理论被广泛的应用于具有贫信息和小样本特征的系统建模和预测. 通过生成和挖掘部分已知信息, 达到描绘和认知现实世界的目的. 由于每次循环中的信息素矩阵所提供的信息符合灰色信息的特征, 因此对其建立灰色模型以预测和控制信息素浓度限界, 使得整个控制过程具有更好的适应性.

为了证明信息素局部更新以后, 信息素矩阵中的元素介于 $\tau_{\text{max}}(t)$ 和 $\tau_{\text{min}}(t)$ 之间, 引入信息素浓度局部更新有界定理如下:

定理 1 若 $d'(t)$ 和 $d(t)$ 分别为本次循环中信息素局部更新后和未更新时的信息素极差函数值, 则有 $d'(t) \leq d(t)$.

证 令 $\tau'(t)$ 为通过式(3)进行信息素局部更新后信息素矩阵中的任一元素, $\tau(t) = \tau_0 + \Delta$ 为未进行信息素局部更新时信息素矩阵中对应元素的值, 而 τ_{max} 和 τ_{min} 分别为信息素矩阵中的当前最大值和最小值. 其中, Δ 代表第 t 次循环之前该元素的累积增量(正增量或负增量), Δ_{max} 和 Δ_{min} 分别表示未经信息素局部更新时信息素矩阵中的最大和最小增量. 根据式(3)有

$$\tau'(t) = \tau_0 + [1 - \rho(t)]\Delta,$$

则

$$\tau(t) - \tau'(t) = \rho(t)\Delta.$$

因为 $0 < \rho(t) \leq 1$, 所以当 $\Delta_{\text{min}} \leq \Delta \leq 0$ 时, 易得

$$\tau_{\min} \leq \tau(t) \leq \tau'(t).$$

又因为 $\Delta_{\max} \geq 0$, 所以

$$\tau'(t) - \tau_{\max} = [1 - \rho(t)]\Delta - \Delta_{\max} \leq 0,$$

故有

$$\tau_{\min} \leq \tau'(t) \leq \tau_{\max}.$$

同理可得, 当 $\Delta > 0$ 时, 有

$$\tau_{\min} \leq \tau'(t) \leq \tau(t) \leq \tau_{\max}.$$

结合信息素极差函数的定义(式(15))可知, $d'(t) \leq d(t)$ 成立. 证毕.

定理1说明了只需要对信息素全局更新后的信息素矩阵进行限界的控制即可.

信息素限界的控制方法如下:

Step 1 对第 $t-1$ 次循环中的信息素矩阵进行信息素全局更新, 得更新后的矩阵 $[\tau_{ij}(t)]_{n \times n}$;

Step 2 令 $\hat{\tau}_{\min}(t) = \min[\tau_{ij}(t)]_{n \times n}$, 则有 $\hat{\tau}_{\max}(t) = \hat{\tau}_{\min}(t) + \hat{d}(t)$;

Step 3 利用式(7), 对信息素矩阵进行信息素限制更新, 且通过下式得到信息素浓度限界值,

$$\tau_{\max}(t) = \max[\tau_{ij}(t)]_{n \times n}, \quad (16)$$

$$\tau_{\min}(t) = \min[\tau_{ij}(t)]_{n \times n}. \quad (17)$$

Step 4 利用式(15), 得到第 t 次循环的信息素极差函数值 $d(t)$, 并将其加入序列 $\{d(t)\}$. 利用部分序列建立灰模型, 预测第 $t+1$ 次循环中信息素极差函数值 $\hat{d}(t+1)$.

信息素极差函数的影响因素众多, 但邻近几次循环中的各影响因素所起作用最为重要, 故用传统的4数据灰建模(利用序列 $\{d(t)\}$ 中的数据 $d(t-3)$, $d(t-2)$, $d(t-1)$ 和 $d(t)$ 建立模型)对信息素极差函数值进行预测估计.

2.5 参数自适应控制(Adaptive control of parameters)

20世纪90年代, 李德毅教授建立了云理论, 提出了云模型^[12, 13]的概念. 正态云模型是一种将定性概念和定量概念相互转化的有效工具, 通过期望 E_x , 熵 E_n 和超熵 H_e 这三个数字特征, 能够有效表达不确定概念的模糊性、随机性以及它们之间的相互关系. 因此, 由云模型所构造的关联关系具有良好的柔性. 本节将提出基于云关联规则^[14]的参数控制方法.

2.5.1 蚁群策略的参数控制(Parameters control of ACO strategy)

由式(9)可知, $\theta_A(t)$ 越大, 说明蚁群策略在第 t 次循环过程中所搜索到的解越好, 因此这些路径弧段

上的信息素浓度越应增强, 蚂蚁之间越应加强协作, 与其协调一致的是信息素挥发系数 $\rho(t)$ 和启发因子 $\gamma(t+1)$ 都应越大; 反之, 亦然. 根据此定性原则建立参数 $\rho(t)$ 和 $\gamma(t+1)$ 的云关联控制规则, 有:

规则 1 如果 $\theta_A(t)$ 越大, 且 $\theta_A(t) \geq 0$, 那么 $\rho(t)$ 越大, $\gamma(t+1)$ 越大.

规则 2 如果 $\theta_A(t)$ 越小, 且 $\theta_A(t) < 0$, 那么 $\rho(t)$ 越小, $\gamma(t+1)$ 越小.

这些规则的实现方式可以一致地解释如下: 首先, $\theta_A(t)$ 作为输入, 通过规则前件(规则前件为云模型 $C_\theta(E_{x\theta}, E_{n\theta}, H_{e\theta})$), 得到确定度 $\mu(t)$. 随后, 将 $\mu(t)$ 输入到规则后件, 通过云 $C_\rho(E_{x\rho}, E_{n\rho}, H_{e\rho})$ 和 $C_\gamma(E_{x\gamma}, E_{n\gamma}, H_{e\gamma})$ 分别得到参数 $\rho(t)$ 和 $\gamma(t+1)$ 的值. 其中, $E_{x\rho}$ 和 $E_{x\gamma}$ 为两个经验常数.

2.5.2 遗传策略的参数控制(Parameters control of genetic strategy)

由式(10)可知, $\theta_G(t)$ 越大, 说明遗传种群中的优良基因片段越多, 因此越应减少交叉(交叉概率 $P_c(t)$ 越小)和变异(变异概率 $P_m(t)$ 越小), 以免破坏优良基因片段; 反之, 亦然. 根据此定性原则建立参数 $P_c(t)$ 和 $P_m(t)$ 的云关联规则, 有:

规则 3 如果 $\theta_G(t)$ 越大, 且 $\theta_G(t) \geq 0$, 那么 $P_c(t)$ 越小, $P_m(t)$ 越小.

规则 4 如果 $\theta_G(t)$ 越小, 且 $\theta_G(t) < 0$, 那么 $P_c(t)$ 越大, $P_m(t)$ 越大.

其中, 交叉概率云和变异概率云分别为 $C_{P_c}(E_{xP_c}, E_{nP_c}, H_{eP_c})$ 和 $C_{P_m}(E_{xP_m}, E_{nP_m}, H_{eP_m})$. 规则的实现方法与规则1和规则2的实现方法类似.

3 算法步骤(Algorithm form)

Step 1 初始化蚁群规模 m_A 、遗传种群规模 m_G 以及其他参数;

Step 2 利用式(8)随机产生规模为 m_G 的遗传初始种群, 计算遗传种群的平均适应度值 $F_{G_{ave}}(0)$, 记录最优解 L_{best} ;

Step 3 令 $t := 1$;

Step 4 将 m_A 只蚂蚁随机置于 n 个城市节点上;

Step 5 每只蚂蚁 k 根据式(1)和式(2)选择下一访问的城市节点;

Step 6 根据式(3)局部更新信息素;

Step 7 若每只蚂蚁都访问了所有 n 个城市节点, 则计算各蚂蚁解的适应度值, 记录本次迭代最优蚂蚁解 $L_{A_{best}}(t)$, 若其优于历史最优解 L_{best} , 则令 $L_{best} := L_{A_{best}}(t)$, 根据式(4)~(6)进行信息素的全局更新并利用式(7)进行信息素的限制更新; 否则, 返回Step 5;

Step 8 根据式(12)计算并记前 t 次循环中每代最优蚂蚁路径的平均适应度值 $\bar{F}_{A_{best}}(t)$, 根据式(9)和式(10)计算适应度改进测度 $\theta_A(t)$ 和 $\theta_G(t)$ 的值, 根据式(14)计算沟通参数 $C(t)$ 的值, 并选择蚁群中较好的 $C(t)$ 个解替换遗传种群中较差的 $C(t)$ 个解;

Step 9 根据云关联规则1和云关联规则2, 自适应控制蚁群策略参数, 得参数 $\rho(t)$ 和 $\gamma(t+1)$ 的值;

Step 10 根据云关联规则3和云关联规则4, 自适应控制遗传策略参数, 得参数 $P_c(t)$ 和 $P_m(t)$ 的值;

Step 11 随机选择 m'_G (当 $[P_c(t) \times m_G]$ 为偶数时, 有 $m'_G := [P_c(t) \times m_G]$, 当 $[P_c(t) \times m_G]$ 为奇数时, 有 $m'_G := [P_c(t) \times m_G] + 1$)个染色体进行交叉操作, 随机选择 $[P_m(t) \times m_G]$ 个染色体, 进行变异操作;

Step 12 计算遗传种群中各染色体的适应度值, 记录遗传种群最优解并与历史最优解比较, 若优于历史最优解, 则替换历史最优解. 根据式(13)计算遗传种群平均适应度值 $F_{G_{ave}}(t+1)$. 根据终止规则, 若算法终止, 则输出历史最优解 L_{best} ; 否则令 $t := t+1$, 返回Step 4.

4 算法分析(Algorithm analysis)

4.1 时间复杂度分析(Time complexity analysis)

设 n 为TSP的规模, m_A 和 m_G 分别为蚁群规模和遗传种群规模, 循环变量为 N_c , 最大循环次数为 N_{max} . 在 n 足够大的情况下, 忽略时间复杂度为低次幂的部分, 算法中具有较大运算量部分的时间复杂度见表1所示.

表 1 算法时间复杂度

Table 1 Time complexity analysis of the algorithm

计算模块	时间复杂度
蚂蚁解的构造	$O(N_c \times n^2 \times m_A)$
信息素局部更新	$O(N_c \times n^2 \times m_A)$
信息素全局更新/信息素限制更新	$O(N_c \times n^2)$
交叉操作/变异操作	$O(N_c \times m_G)$

4.2 云模型数字特征的设定(Numerical characteristics setting of cloud model)

文献[15]利用统计方法分析了云滴群对定性概念的贡献, 提出了所谓的“ $3E_n$ 规则”, 该规则指出对于论域中的定性概念, 有贡献的定量值主要落在区间 $[E_x - 3E_n, E_x + 3E_n]$ 上, 占99.7%. 文献[16]分析了正态云的形态随超熵的变化情况, 指出随着 H_e 值的增大, 云滴开始离散, 云开始向雾转化, 并指出滴落入区间 $[E_n - 3H_e, E_n + 3H_e]$ 的概率为99.7%. 对算

法中云模型数字特征的设定问题, 可基于经验原则寻找一个相对保守的 E_x 值, 通过估计 E_x 的上(下)限, 再结合文献[15]和[16]的相关结论, 确定 E_n 和 H_e 的值.

5 算例仿真(Experiments)

本节中, 各算法均用C语言编译, 而且各实验均在频率为2.0 GHz的Intel Core2处理器和频率为667 MHz的1024 MB DDR2内存的Window XP系统环境下运行. 根据4.2节分析, 算法中的云模型参数取值如下:

$$\begin{aligned}
 &C_\theta(0.0000, 0.1666, 0.0555), \\
 &C_\rho(0.0150, 0.0050, 0.0016), \\
 &C_\gamma(3.0000, 0.8333, 0.2777), \\
 &C_{P_c}(0.6180, 0.1273, 0.0424), \\
 &C_{P_m}(0.1000, 0.0333, 0.0111).
 \end{aligned}$$

蚁群规模 $m_A = n$, 遗传种群规模 $m_G = 1.5n$, 其中 n 为问题的规模.

表2给出了Muth和Thompson在1963年提出的 6×6 的JSP数据, 运用本文提出算法进行仿真得到的一个优化解见表3.

表 2 Muth & Thompson 6×6 车间调度问题

Table 2 Muth & Thompson 6×6 JSP

工件	(加工机器序号, 加工时间)					
	工序1	工序2	工序3	工序4	工序5	工序6
1	(3,1)	(1,3)	(2,6)	(4,7)	(6,3)	(5,6)
2	(2,8)	(3,5)	(5,10)	(6,10)	(1,10)	(4,4)
3	(3,5)	(4,4)	(6,8)	(1,9)	(2,1)	(5,7)
4	(2,5)	(1,5)	(3,5)	(4,3)	(5,8)	(6,9)
5	(3,9)	(2,3)	(5,5)	(6,4)	(1,3)	(4,1)
6	(2,3)	(4,3)	(6,9)	(1,10)	(5,4)	(3,1)

表 3 Muth & Thompson 6×6 车间调度问题优化解

Table 3 Optimal solution to the Muth & Thompson 6×6 JSP

工件	工序完成时刻					
	工序1	工序2	工序3	工序4	工序5	工序6
1	1	4	31	38	44	55
2	8	13	23	37	50	54
3	6	10	18	30	32	45
4	16	21	27	30	38	53
5	22	25	30	41	53	55
6	11	14	27	40	49	50

利用文献[8]提出的基于云模型理论的蚁群算法

(CACO)和本文提出的基于灰预测和正态云的参数自适应蚁群遗传算法(GCACGA),对3个TSP问题分别运行50次,最大代数1000代,对比分析结果见表4. CACO算法中,蚁群规模等于城市节点总数 n ,其余参数设置同文献[8].

利用文献[10]中提出的云自适应遗传算法(CAGA)和GCACGA,对3个Muth & Thompson JSP问题分别运行50次,最大代数1000代,对比分析结果见表5. CAGA算法中,遗传种群规模为作业总数 n 的1.5倍,其余参数设置同文献[10].

表4 CACO和GCACGA的性能比较

Table 4 Performance comparison of CACO and GCACGA

TSP	最优适应度值		平均最优适应度值		相对误差/%		平均耗时/s	
	CACO	GCACGA	CACO	GCACGA	CACO	GCACGA	CACO	GCACGA
Oliver30	424	424	433.3	430.1	2.19	1.44	4.1	4.6
Att48	33772	33587	34288.6	33890.2	1.53	0.90	5.4	6.9
Eil51	431	428	440.4	433.5	2.18	1.28	5.7	6.7

表5 CAGA和GCACGA的性能比较

Table 5 Performance comparison of CAGA and GCACGA

JSP	最优适应度值		平均最优适应度值		相对误差/%		平均耗时/s	
	CAGA	GCACGA	CAGA	GCACGA	CAGA	GCACGA	CAGA	GCACGA
6 × 6	55	55	58.5	59.1	6.36	7.45	5.2	5.9
10 × 10	960	960	1044.8	1032.2	8.83	7.52	15.3	18.8
20 × 5	1231	1178	1359.5	1281.2	10.43	8.76	15.6	18.5

实际上,除了Oliver30和6 × 6的JSP问题,其余算例都未搜索到目前为止已知的最优解,但从表4和表5可以看出,各算法运行50次所得结果中,GCACGA所搜索到的最优解在适应度值和平均最优适应度值总体上优于其余两种算法.这说明算法在收敛能力和稳定性上都能取得满意的效果.值得注意的是,在6个算例中,GCACGA均采用相同的参数设置方案,这说明该算法对各问题具有较强的适应能力,可有效避免由于参数设置不当所造成的算法搜索质量降低的问题.

6 结论(Conclusion)

本文提出的GCACGA算法,利用灰预测对最大最小蚁群策略的信息素全局更新加以实时控制,有效避免了算法陷入早期停滞.通过运用云模型,建立了算法参数的自适应关联规则,利用此规则并结合算法迭代过程中的反馈信息可使算法参数得到满意的自适应调节效果,有效地减少了算法对参数设置的依赖程度.用蚁群中部分较好的解去替换遗传种群中部分较差的解,其功能类似于基本遗传算法的选择操作.但通过此方法“选择”的解一般来说具有更为优良的适应度,而当

本代中所有遗传操作都结束后,遗传种群中的最优个体又可为蚂蚁种群的寻优提供指导.这样将两个算法策略集成为一个整体,既发挥了蚁群优化精确寻优和正反馈机制下的快速收敛能力,又发挥了遗传算法的快速全局收敛能力,动态的实现两种算法的优势互补.

参考文献(References):

- [1] COLORNI A, DORIGO M, MANIEZZO V. Distributed Optimization by Ant Colonies[C] // *Proceedings of ECAL91 European Conference on Artificial Life*. Paris: Elsevier, 1991: 134 - 142.
- [2] DORIGO M, GAMBARELLA L M. Ant colony system: a cooperative learning approach to the traveling salesman problem[J]. *IEEE Transactions on Evolutionary Computation*, 1997, 1(1): 53 - 66.
- [3] DORIGO M, BIRATTARI M, STÜTZLE T. Ant colony optimization: artificial ants as a computational intelligence technique[J]. *IEEE Computing Intelligence Magazine*, 2006, 11(4): 28 - 39.
- [4] HOLLAND J H. *Adaptation in Natural and Artificial Systems*[M]. Ann Arbor, American: University of Michigan Press, 1975.
- [5] GOLDBERG D E. *Genetic Algorithms in Search, Optimization and Machine Learning*[M]. New York: Addison Wesley, 1989.
- [6] STÜTZLE T, HOOS H. MAX-MIN ant system and local search for the traveling salesman problem[C] // *Proceedings of the 1997 IEEE*

- International Conference on Evolutionary Computation*. New York: IEEE, 1997, 8: 309 – 314.
- [7] STÜTZLE T, HOOS H. Improvements on the ant system, introducing the MAX-MIN ant system[C] // *Proceedings of the Third International Conference Artificial Neural Networks and Genetic Algorithms*. Germany: Springer-Verlag, 1997.
- [8] 段海滨, 王道波, 余秀芬, 等. 基于云模型理论的蚁群算法改进研究[J]. 哈尔滨工业大学学报, 2005, 37(1): 115 – 119.
(DUAN Haibin, WANG Daobo, YU Xiufen, et al. Improvement of ant colony algorithm based on cloud models theory[J]. *Journal of Harbin Institute of Technology*, 2005, 37(1): 115 – 119.)
- [9] HERRERA F, LOZANO M. Adaptive genetic operators based on co-evolution with fuzzy behaviors[J]. *IEEE Transactions on Evolutionary Computation*, 2001, 5(2): 149 – 165.
- [10] 戴朝华, 朱云芳, 陈维荣. 云自适应遗传算法[J]. 控制理论与应用, 2007, 24(4): 646 – 650.
(DAI Chaohua, ZHU Yunfang, CHEN Weirong. Adaptive genetic algorithm based on cloud theory[J]. *Control Theory & Applications*, 2007, 24(4): 646 – 650.)
- [11] 邓聚龙. 灰理论基础[M]. 武汉: 华中科技大学出版社, 2002.
- [12] 李德毅, 孟海军, 史雪梅. 隶属云和隶属云发生器[J]. 计算机研究与发展, 1995, 32(6): 15 – 20.
(LI Deyi, MENG Haijun, SHI Xuemei. Membership clouds and membership cloud generators[J]. *Journal of Computer Research and Development*, 1995, 32(6): 15 – 20.)
- [13] 李德毅, 刘常昱. 论正态云模型的普适性[J]. 中国工程科学, 2004: 6(8): 28 – 34.
(LI Deyi, LIU Changyu. Study on the universality of the normal cloud model[J]. *Engineering Science*, 2004, 6(8): 28 – 34.)
- [14] LI D Y, DI K C, LI D R, et al. Mining association rules with linguistic cloud model[J]. *Journal of Software*, 2000, 11(2): 143 – 158.
- [15] 刘常昱, 李德毅, 潘莉莉. 基于云模型的不确定知识表示[J]. 计算机工程与应用, 2004, 40(2): 32 – 35.
(LIU Changyu, LI Deyi, PAN Lili. Uncertain knowledge representation based on cloud model[J]. *Computer Engineering and Applications*, 2004, 40(2): 32 – 35.)
- [16] 刘常昱, 李德毅, 杜鹤, 等. 正态云模型的统计分析[J]. 信息与控制, 2005, 32(2): 236 – 239, 248.
(LIU Changyu, LI Deyu, DU Yi, et al. Some statistical analysis of the normal cloud model[J]. *Information and Control*, 2005, 32(2): 236 – 239, 248.)

作者简介:

牟峰 (1980—), 男, 博士研究生, 目前研究方向为现代优化理论及算法、不确定性分析、运输组织优化、交通运输系统工程, E-mail: circleone1980@hotmail.com;

袁晓辉 (1981—), 男, 博士研究生, 目前研究方向为射频通讯技术、智能控制, E-mail: yeuman@163.com;

王慈光 (1946—), 男, 教授, 博士生导师, 目前研究方向为运输组织优化、交通运输系统工程、组合优化、统计分析, E-mail: wangciguang@163.com;

景云 (1981—), 男, 博士研究生, 目前研究方向为运输组织优化、交通运输系统工程、不确定分析、现代优化理论及算法, E-mail: jingyun1205@yahoo.com.cn.