

动态蚁群算法在带时间窗车辆路径问题中的应用

刘云忠, 宣慧玉

(西安交通大学管理学院, 西安 710049)

[摘要] 蚁群算法是近年来新出现的一种随机型搜索寻优算法。自从在旅行商等著名问题中得到富有成效的应用之后, 已引起人们越来越多的关注和重视。将这种新型的生物优化思想扩展到物流管理中的带时间窗车辆路径问题, 设计了一种动态蚁群算法, 从数值计算上探索了这种新型蚁群算法的优化能力, 获得了满意的效果。

[关键词] 蚁群算法; 带时间窗车辆路径问题; 物流管理; 动态

[中图分类号] O22 **[文献标识码]** A **[文章编号]** 1009-1742(2005)12-0035-06

1 引言

蚁群算法 (ant algorithm) 是一种源于大自然中生物世界的新的仿生类算法^[1], 诞生至今只有短短的十几年时间。作为通用型随机优化算法, 它吸收了昆虫王国中蚂蚁的行为特性, 通过其内在的搜索机制, 在一系列困难的组合优化问题求解中取得了成效。由于模拟仿真中使用的是人工蚂蚁概念, 因此有时亦称为蚂蚁系统。

据昆虫学家的观察和研究, 发现生物世界中的蚂蚁有能力在没有任何可见提示下找出从其窝巢至食物源的最短路径, 并且能随环境的变化而变化, 适应性地搜索新的路径, 产生新的选择。作为昆虫的蚂蚁在寻找食物源时, 能在其走过的路径上释放一种蚂蚁特有的分泌物——信息激素 (pheromone), 使得一定范围内的其他蚂蚁能够察觉到并由此影响它们以后的行为。当一些路径上通过的蚂蚁越来越多时, 其留下的信息素轨迹 (trail) 也越来越多, 以致信息素强度增大 (当然, 随时间的推移会逐渐减弱), 后来蚂蚁选择该路径的概率也越高, 从而更增加了该路径的信息素强度, 这种选择过程被称为蚂蚁的自催化行为

(autocatalytic behavior)。由于其原理是一种正反馈机制, 因此, 也可将蚂蚁王国 (ant colony) 理解成所谓的增强型学习系统 (reinforcement learning system)。

自从蚁群算法在著名的旅行商问题^[2]上取得成效以来, 已陆续渗透到其他问题的求解上。笔者将这种新型的生物优化思想扩展到物流管理中的带时间窗车辆路径问题, 从数值计算上探索了蚁群算法的优化能力, 获得了满意的效果。

2 基本蚁群算法原理

用于优化领域的人工蚁群算法, 其基本原理吸收了生物界中蚂蚁群体行为的某些显著特征: a. 能察觉小范围区域内的状况并判断出是否有食物或其他同类的信息素轨迹; b. 能释放自己的信息素; c. 所遗留的信息素数量会随时间而逐步减少。由于自然界中的蚂蚁基本没有视觉, 既不知向何处去寻找和获取食物, 也不知发现食物后如何返回自己的巢穴, 因此它们仅仅依赖于同类散发在周围环境中的特殊物质——信息素的轨迹, 来决定自己何去何从。有趣的是, 尽管没有任何先验知识, 但蚂蚁们还是有能力找到从其巢穴到食物源的最佳

路径, 甚至在该路线上放置障碍物之后, 它们仍然能很快重新找到新的最佳路线。这里, 用一个形象化的图示来说明蚂蚁群体的路径搜索原理和机制^[3]:

假定障碍物的周围有两条道路可从蚂蚁的巢穴到达食物源 (见图 1): Nest—ABD—Food 和 Nest—ACD—Food, 分别具有长度 4 和 6。蚂蚁在单位时间内可移动一个单位长度的距离。开始时所有道路上都未留有任何信息素。

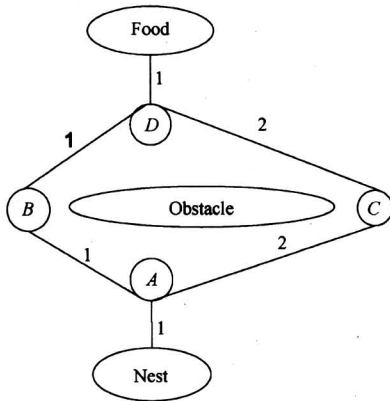


图 1 蚂蚁从巢穴移至食物源

Fig. 1 Ants move to food resource from nest

在 $t=0$ 时刻, 20 只蚂蚁从巢穴出发移动到 A。它们以相同概率选择左侧或右侧道路, 因此平均有 10 只蚂蚁走左侧, 10 只走右侧。

在 $t=4$ 时刻, 第一组到达食物源的蚂蚁将折回。

在 $t=5$ 时刻, 两组蚂蚁将在 D 点相遇。此时 BD 上的信息素数量与 CD 上的相同, 因为各有 10 只蚂蚁选择了相应的道路。从而有 5 只返回的蚂蚁将选择 BD 而另 5 只将选择 CD。

在 $t=8$ 时刻, 前 5 只蚂蚁又返回巢穴, 而 AC, CD 和 BD 上各有 5 只蚂蚁。

在 $t=9$ 时刻, 前 5 只蚂蚁又回到 A 并且再次面对往左还是往右的选择。

这时, AB 上的轨迹数是 20 而 AC 上是 15, 因此增强了该路线的信息素。随着该过程的继续, 两条道路上信息素数量的差距将越来越大, 直至绝大多数蚂蚁都选择了最短的路线。正是由于一条道路要比另一条道路短, 因此, 在相同的时间区间内, 短的路线会有更多的机会被选择。记:

m 为蚂蚁个数

η_{ij} 为边弧 (i, j) 的能见度 (visibility), 即

$1/d_{ij}$;

τ_{ij} 为边弧 (i, j) 的轨迹强度 (intensity);

$\Delta\tau_{ij}^k$ 为蚂蚁 k 于边弧 (i, j) 上留下的单位长度轨迹信息素数量;

P_{ij}^k 为蚂蚁 k 的转移概率, 与 $\tau_{ij}^\alpha \cdot \eta_{ij}^\beta$ 成正比, j 是尚未访问节点。

轨迹强度的更新方程为

$$\tau_{ij}^{\text{new}} = \rho\tau_{ij}^{\text{old}} + \sum_k \Delta\tau_{ij}^k \quad (1)$$

其中 各参数的含义为:

α 为轨迹的相对重要性 ($\alpha \geq 0$);

β 为能见度的相对重要性 ($\beta \geq 0$);

ρ 为轨迹的持久性 ($0 \leq \rho < 1$), $1 - \rho$ 理解为轨迹衰减度 (evaporation)。

算法中的参数设定目前尚无理论上的依据, 已公布的试验结果都是针对特定问题而言的。针对车辆路径问题 (VRP) 本身的特点, 可定义如下形式的转移概率^[3]:

$$P_{ij} = \frac{\tau_{ij}^\alpha \eta_{ij}^\beta \mu_{ij}^\gamma K_{ij}^\lambda}{\sum_k \tau_{ih}^\alpha \eta_{ih}^\beta \mu_{ih}^\gamma K_{ih}^\lambda} \quad (2)$$

其中 $\mu_{ij} = d_{i0} + d_{j0} - d_{ij}$, $k_{ij} = (Q_i + q_j) / Q$, Q 为体现蚂蚁所留轨迹数量的一个常数。

采用人工蚂蚁方法进行求解的主要步骤如下:

Step 1 $n_c \leftarrow 0$ (n_c 为迭代步数或搜索次数), 各 τ_{ij} 和 $\Delta\tau_{ij}$ 初始化, 将 m 个蚂蚁置于 n 个顶点上;

Step 2 将各蚂蚁的初始出发点置于当前解集中, 对每个蚂蚁 k ($k=1, 2, \dots, m$), 按概率 P_{ij}^k 移至下一顶点 j , 将顶点 j 置于当前解集中;

Step 3 计算各蚂蚁的目标函数值 Z_k ($k=1, 2, \dots, m$), 记录当前的最好解;

Step 4 按更新方程修改轨迹强度;

Step 5 对各边弧 (i, j) , 置 $\Delta\tau_{ij} \leftarrow 0$, $n_c \leftarrow n_c + 1$;

Step 6 若 n_c 小于预定的迭代次数且无退化行为 (即找到的都是相同解), 则转 Step 2。

算法的时间复杂度为 $O(n_c mn^2)$ 。

3 动态蚁群算法

动态蚁群算法相对于基本蚁群算法, 主要改进有以下几点。基本蚁群算法依据信息素和启发函数选择目标城市。如何依据这两个因子选择城市对算法的性能是非常关键的。动态蚂蚁在迭代过程中,

在选择目标城市的标准时，不是使用一个固定的标准，使之有利于减小进化停滞现象。在基本蚁群算法中，对信息素的强度没有限制，因而易陷入局部最优点。动态蚁群算法对信息素的强度给予一定的限制，从而大大改善了算法的性能。动态蚁群算法中挥发因子是动态变化，信息素浓度越高挥发因子越大，浓度越低挥发因子越小，这样对信息素浓度也进行限制，使信息素不可能无限增大，也不可能为零。基本蚁群算法中仅有最好蚂蚁所走路径上的信息素进行全局更新，如果能对更多路径上的信息素进行更新，则有可能加快演化的速度。

基本蚁群算法依据 $[\tau(r, s)]^\alpha [\eta(r, s)]^\beta$ 来选择下一个转移城市， α, β 是常数。在自然界中生物随着时间的推移对环境适应之后，不再对环境敏感。基于此原理，可认为蚂蚁随着时间的推移对信息素慢慢变得不敏感。在算法中体现为， $[\tau(r, s)]^\alpha$ 随着时间相对于 $[\eta(r, s)]^\beta$ 减小，这样信息素的影响减小了，而启发函数的影响相对加大，这样， α, β 由常数就变为与时间有关的函数。在旅行商问题 (TSP) 中 $\eta(r, s) = 1/d_{rs}$, d_{rs} 是城市 r 和城市 s 之间的距离。为简化计算，置 $\alpha = 1$ ，而 β 按迭代次数进行如下变化。

1~mn/3 次迭代 $\beta = 5$ ；mn/3~mn/2 次迭代 $\beta = 4$ ；mn/2~2mn/3 次迭代 $\beta = 3$ ；2mn/3~mn 次 $\beta = 2$ ；mn 是总的迭代次数。循环次数固定为 10 000 次。

在基本蚁群算法中，挥发因子是一个常数。而在真实世界中，信息素浓度越高，挥发越快，信息素浓度越低，挥发越慢，这样可以防止信息浓度无限制地增长，或者变为零，减小陷入局部最优的可能。在这种情况下挥发因子由常数变成以 $\tau(r, s)$ 为变量的函数。

局部信息素更新规则变为

$$\tau(r, s) \leftarrow (1 - \rho(\tau(r, s)))\tau(r, s) + \text{coe}(\tau(r, s))\Delta\tau \quad (3)$$

挥发函数对算法的性能有直接的影响，在实验中曾试过如图 2 所示 4 种类型函数 (X 轴为浓度，Y 轴为挥发因子)，实验表明图 2d 所对应的挥发函数的效果比较好。

基本蚁群算法仅对最好路径上的信息素进行全局更新，仅有一只蚂蚁对全局信息素的更新产生影响。如果有多只蚂蚁对全局信息素的更新产生影响，则可加速演化过程。更新规则如下：

$$\tau(r, s) \leftarrow (1 - \alpha(\tau(r, s)))\tau(r, s) + \text{coe}(\tau(r, s))\Delta\tau(r, s) \quad (4)$$




图 2 信息素浓度与挥发系数函数关系

Fig. 2 Function relationship between pheromone density and volatility coefficient

对两只蚂蚁所走路径上的信息素进行更新，即对最好路径及最差路径上的信息素进行全局更新，则参数

$$\text{coe} = \begin{cases} C & (r, s) \in \text{global-best-tour} \\ -C & (r, s) \in \text{global-worst-tour} \\ 0 & (r, s) \in \text{the-other} \end{cases} \quad (5)$$

式 (4) 变为

$$\tau(r, s) \leftarrow (1 - \alpha(\tau(r, s)))\tau(r, s) + C\Delta\tau(r, s) : \text{best} \quad (6)$$

$$\tau(r, s) \leftarrow (1 - \alpha(\tau(r, s)))\tau(r, s) + C\Delta\tau(r, s) : \text{worst} \quad (7)$$

其中

$$\Delta\tau(r, s) = \begin{cases} (L_{\text{gb}})^{-1}, & \text{if } (r, s) \in \text{global-best-tour} \\ (L_{\text{gw}})^{-1}, & \text{if } (r, s) \in \text{global-worst-tour} \end{cases} \quad (8)$$

L_{gb} 是最好蚂蚁所走路径长度， L_{gw} 是最差蚂蚁所走路径长度， $\alpha(\tau(r, s))$ 是全局信息素挥发因子。

4 带时间窗车辆路径问题

在许多物流配送系统中，管理者们需要采取有效的配送策略以提高服务水平、降低货费用。其中车辆路径问题是亟待解决的一个重要问题，此问题可描述如下：有一个货物需求点（或称顾客），已知每个需求点的需求量及位置，至多用 K 辆汽

车从中心仓库（或配送中心）到达这批需求点，每辆汽车载重量一定，安排汽车路线使运距最短且满足每条路线不超过汽车载重量和每个需求点的需求量必须且只能由一辆汽车来满足的约束条件。车辆路径问题是一个 NP 完全问题，只有在需求点数和路段数较少时才有可能寻求其精确解。带时间窗车辆路径问题（VRPTW, vehicle routing problem with time windows）是在车辆路径问题上加了客户要求访问的时间窗口。由于在现实生活中许多问题都可以归结为 VRPTW 来处理，但处理的好坏将直接影响到一个企业的效益和顾客的服务质量，所以对它的研究越来越受到人们的重视，目前对它的求解主要集中在启发式算法上。

20 世纪 90 年代后，遗传算法、禁忌搜索算法、模拟退火算法和人工神经网络算法等启发式算法的出现，为求解 VRPTW 提供了新的工具。文献 [4~6] 用遗传算法求解了 VRPTW；文献 [7~9] 用网络启发式算法、分派启发式算法和 C-W 算法求解了 VRPTW；文献 [10] 用一种修正的最近距离搜索启发式算法求解了 VRPTW。但是，遗传算法存在“早熟性收敛”问题，其他算法也存在一些不尽人意的地方。如何针对带时间窗车辆路径问题的特点，构造运算简单、寻优性能优异的启发式算法，这不仅对于物流配送系统而且对于许多可转化为带时间窗车辆路径问题求解的优化组合问题均具有十分重要的意义。笔者运用蚁群算法求解带时间窗车辆路径问题，并对其运算过程和结果进行分析。实际数据表明蚁群算法行之有效，不失为一种求解带时间窗车辆路径问题的性能优越的启发式算法。

带时间窗车辆路径问题可描述如下：给定车辆集合 V ，分店集合 C 和有向图 G 。此有向图有 $|C|+2$ 个顶点，顶点 $1, 2, \dots, n$ 表示分店，顶点 0 表示离开时的中心仓库，顶点 $n+1$ 表示返回时的中心仓库，把顶点 $0, 1, \dots, n+1$ 记作集合 N 。分店之间以及分店与中心仓库之间的弧记作集合 A ，并且没有弧开始于 $n+1$ 顶点，也没有弧终止于 0 顶点，每条弧 (i, j) 对应一个物耗值 c_{ij} 和一个时间值 t_{ij} 。每辆车有一个容量 q ，每个分店 i 有一个需求 d_i 和一个时间窗口 $[a_i, b_i]$ ，这个时间窗口说明车辆必须在 b_i 之前到达分店 i ，在 a_i 之前车辆虽然可以到达分店 i ，但是车辆必须等待而不能马上为分店服务。中心仓库也有一个时间窗口

$[a_0, b_0]$ ，这个时间窗口说明车辆在 a_0 之前不能离开中心仓库，并且必须在 b_0 或之前返回中心仓库。在这里，假设 q, a_i, b_i, d_i 和 c_{ij} 是非负整数， t_{ij} 是正整数。

对于每条弧 (i, j) ($i \neq j, i \neq n+1, j \neq 0$) 和车辆 k 定义变量 x_{ijk} ：

$$x_{ijk} = \begin{cases} 0 & \text{如果车辆 } k \text{ 没有从节点 } i \text{ 到达节点 } j, \\ 1 & \text{如果车辆 } k \text{ 从节点 } i \text{ 到达节点 } j. \end{cases}$$

对于每个分店 i 和车辆 k 定义变量 s_{ik} ，它表示车辆 k 在 s_{ik} 开始对分店 i 进行访问，如果车辆 k 不访问分店 i ，则 s_{ik} 不表示任何意义。假设 $a_0 = 0$ ，这样对于所有的车辆 k ， $s_{0k} = 0$ 。对于每辆车，设计一条费用最小的路径，此路径开始于顶点 0 ，终止于顶点 $n+1$ ，同时还要保证每个分店被精确地访问一次，但不能违背各时间窗口和车辆的能力约束。

经上述描述，VRPTW 的数学模型可以表示为：

$$\min \sum_{k \in V} \sum_{i \in N} \sum_{j \in N} c_{ij} x_{ijk} \quad (9)$$

$$\text{s. t. : } \sum_{k \in V} \sum_{j \in N} x_{ijk} = 1, \forall i \in N \quad (10)$$

$$\sum_{i \in N} d_i \sum_{j \in N} x_{ijk} \leq q, \forall k \in K \quad (11)$$

$$\sum_{j \in N} x_{0jk} = 1, \forall k \in V \quad (12)$$

$$\sum_{i \in N} x_{ikh} - \sum_{j \in N} x_{hjk} = 0, \forall k \in V, \forall h \in C \quad (13)$$

$$\sum_{i \in N} x_{i, n+1, k} = 1, \forall k \in V \quad (14)$$

$$s_{ik} + t_{ij} - K(1 - x_{ijk}) \leq s_{jk}, \\ \forall k \in V, \forall i, j \in N \quad (15)$$

$$a_i \leq s_{ik} \leq b_i, \forall k \in V, \forall i \in N \quad (16)$$

$$x_{ijk} \in \{0, 1\}, \forall k \in V, \forall i, j \in N \quad (17)$$

在上述表达式中，约束条件式 (10) 表达了每个分店仅能被访问一次；式 (11) 表达了被调用的车辆都满足能力约束条件；式 (12) 和式 (13) 保证了每辆车始于中心仓库，访问分店后，最终回到中心仓库；不等式 (15) 表达了车辆 k 在从 i 分店向 j 分店行驶的过程中，在 $s_{ij} + t_{ij}$ 之前不能到达分店 j ，其中 k 是一个较大的标量；约束条件式 (16) 表达了在车辆的行驶过程中，要满足时间窗的约束；条件式 (17) 是整数化的约束。

这个模型通用性很强，经过参数的不同设定，可以将其转换为其他组合优化问题的数学模型。如

果设 $a_i = 0, b_i = M$ (M 是一个很大的数), 则可以把时间约束式 (15) 和式 (16) 去掉, 这样, VRPTW 模型就变成了普通的 VRP 模型; 如果仅有一辆车被利用, 则该问题就变成了旅行商问题; 如果有多辆车被利用, 并且附加条件 $c_{0j} = 1, j \in C$ 和 $c_{ij} = 0$, 就得到了装箱问题的数学模型。如果去掉能力约束式 (11), 则该模型就变成了 $m - TSPTW$ 模型; 如果仅有一辆车被利用, 又变成了 TSPTW 模型; 如果去掉约束式 (10), 则模型变成了基本的有时间窗和能力约束的最短路径问题, 由于所有的车辆均相同, 所以每辆车的最短路径也是相同的。

5 数值计算结果

在实验中选择的参数如下:

$m = 10, \text{coe}(\tau(r, s)) = 0.1, C = 0.1, a = 1, \alpha(\tau(r, s)) = 0, \delta = 0.5$, 迭代次数 $mn = 10\ 000$, 挥发函数选择如图 2d 所示函数。

有 8 个分店和 1 个配送中心, 各分店的需求量为 d_{ij} ($i = 1, 2, \dots, 8$) (t), 装货 (卸货) 时间 T_i (h) 以及分店要求的服务时间范围 $[a_i, b_i]$ 由表 1 给出。这些分店由容量为 8 t 的车辆完成配送, 配送中心与各分店的距离 (km) 由表 2 给出。要求合理安排车辆的行驶路线, 使总的运距最短。

表 1 任务的特征及需求^[4]

Table 1 Characteristics and demand of task

分店	1	2	3	4	5	6	7	8
需求/t	2	1.5	4.5	3	1.5	4	2.5	3
时间 T/h	1	2	1	3	2	2.5	3	0.8
时间窗/h	[1, 4]	[4, 6]	[1, 2]	[4, 7]	[3, 5]	[2, 5]	[5, 8]	[1, 5]

表 2 分店间及分店与配送中心的距离^[4]

Table 2 Distance among branches & distance between distributive center and branches km

分店	0	1	2	3	4	5	6	7	8
0	0	40	60	75	90	200	100	160	80
1	40	0	65	40	100	50	75	110	100
2	60	65	0	75	100	100	75	75	75
3	75	40	75	0	100	50	90	90	150
4	90	100	100	100	0	100	75	75	100
5	200	50	100	50	100	0	70	90	75
6	100	75	75	90	75	70	0	70	100
7	160	110	75	90	75	90	70	0	100
8	80	100	75	150	100	75	100	100	0

计算结果见表 3, 可见, 运用动态蚁群算法求解的结果优于节约法、分派算法和遗传算法, 不失为带时间窗车辆路径问题一个较优的满意解, 不难看到蚁群算法在大多数情况下比其他算法具有较好的寻优效果。

表 3 优化结果比较

Table 3 Comparison of Optimization Results

算法	优化解 /km	车数 /辆	对应路径		
			1	2	3
节约算法	910	3	0-8-5-7-0	0-6-4-0	0-3-1-2-0
分派算法	1 020	3	0-3-1-5-0	0-6-4-0	0-8-2-7-0
遗传算法	805	3	0-6-7-2-0	0-3-1-0	0-8-5-4-0
蚁群算法	780	3	0-2-7-4-0	0-3-1-0	0-8-5-6-0

6 结语

车辆路径问题已广泛用于生产, 生活的各个方面, 如报纸投递及线路的优化, 牛奶配送及送达线路的优化, 电话预订货物的车辆载货和线路设计, 垃圾车的线路优化及垃圾站选址优化, 连锁商店的送货及线路优化等等。目前, 研究水平已有很大发展, 其理论成果除在汽车运输领域外, 在水运、航空、通信、电力、工业管理、计算机应用等领域也有一定的应用, 还用于航空乘务员轮班安排, 轮船公司运送货物经过港口与货物安排的优化设计, 交通车线路安排, 生产系统中的计划与控制等多种组合优化问题。物流配送车辆路径问题, 是物流配送优化中关键的一环, 也是电子商务活动不可缺少的内容。对货运车辆进行优化调度, 可以提高物流经济效益、实现物流科学化。对货运车辆优化调度理论与方法进行系统研究是物流集约化发展、建立现代调度指挥系统、发展智能交通运输系统和开展电子商务的基础。

在物流配送系统中, 合理安排车辆路线是减少浪费提高经济效益的重要手段, 然而由于问题的 NP 完全性质, 精确求解非常困难, 研究启发式算法不失为一种可行的方向。通过对带时间窗车辆路径问题的分析, 笔者建立了基于蚁群算法的带时间窗车辆路径问题的启发式算法, 设计了一种新型动态蚁群算法, 试验证明该算法性能较好, 可以较快地找到问题的优化解或近似优化解, 是求解带时间窗车辆路径问题的一个较好的方案。

参考文献

- [1] Dorigo M, Maniezzo V, Colomi A. Ant system: optimization by a colony of cooperative agents [J]. IEEE Trans on Systems, Man, and Cybernetics, 1996, 26(1): 29~41
- [2] Dorigo M, Gambardella L M. Ant colony system: a cooperative learning approach to the traveling salesman problem [J]. IEEE Trans on Evolutionary Computation, 1997, 1(1): 53~66
- [3] 马良, 项培军. 蚁群算法在组合优化中的应用[J]. 管理科学学报, 2001, 4(2): 32~37
- [4] 张丽萍, 柴跃廷, 曹瑞. 有时间窗车辆路径问题的改进遗传算法[J]. 计算机集成制造系统——CIMS, 2002, 8(6): 451~454
- [5] 冷德惠, 张金海, 李大卫. 遗传算法在有时间窗车辆路径问题上的应用[J]. 鞍山钢铁学院学报, 2001, 22(3): 129~132
- [6] 李大卫, 王莉, 王梦光. 遗传算法在有时间窗车辆路径问题上的应用[J]. 系统工程理论与实践, 1999, (8): 65~69
- [7] 李军. 有时间窗的车辆调度问题的网络启发式算法[J]. 系统工程, 1999, 17(2): 66~71
- [8] 李军. 车辆调度问题的分派启发式算法[J]. 系统工程理论与实践, 1999, (1): 27~33
- [9] 李军. 有时间窗的车辆路线安排问题的启发式算法[J]. 系统工程, 1996, 14(5): 45~50
- [10] 李大卫, 王莉, 王梦光. 一个求解有时间窗口约束的车辆路径问题的启发式算法[J]. 系统工程, 1998, 16(4): 20~24, 29

Application Research on Vehicle Routing Problem With Time Windows Based on Dynamic Ant Algorithm

Liu Yunzhong, Xuan Huiyu

(Management School of Xi'an Jiaotong University, Xi'an 710049, China)

[Abstract] Ant algorithm is a newly emerged stochastic searching optimization algorithm in recent years. It has been paid much attention to since the successful application in the famous traveling salesman problem. This paper further extends the idea of this new biological optimization strategy to vehicle routing problem with time windows in logistic management and designs a new kind of dynamic ant algorithm. The ability of optimization of this new ant algorithm is tested through numerical computation which gives encouraging results.

[Key words] ant algorithm; vehicle routing problem with time windows; logistic management; dynamic