

求解 VRPTW 问题的不确定性目标偏好蚁群算法 *

李世威, 王建强, 曾俊伟

(兰州交通大学 交通运输学院, 兰州 730070)

摘 要: 通过分析多目标的、有时间窗的车辆路径问题,对各个目标进行多属性不确定性语言评判,结合相关专家的综合意见以及决策者自身对专家意见的偏好,将决策者对目标属性的离散意见转换为对各目标的综合意见;通过定义一种综合排序指标来确定决策者对各目标的偏好权重,依据目标权重和各目标函数的规范化处理值,构建评价有时间窗的车辆路径问题的多目标偏好的综合适应度函数,将多目标问题转换为单目标问题,进而采用最大—最小蚂蚁系统算法对该问题进行求解;最后通过一个算例来说明该算法的有效性。

关键词: 车辆路径问题; 时间窗; 目标偏好; 不确定性语言信息; 蚁群算法; 最大—最小蚂蚁系统

中图分类号: TP301.6 **文献标志码:** A **文章编号:** 1001-3695(2012)03-0869-04

doi:10.3969/j.issn.1001-3695.2012.03.019

Uncertain linguistic information objectives preference VRPTW of ant colony algorithm

LI Shi-wei, WANG Jian-qiang, ZENG Jun-wei

(School of Traffic & Transportation, Lanzhou Jiaotong University, Lanzhou 730070, China)

Abstract: By analyzing the multi-objectives vehicle routing problem with time window, it uncertain evaluated multi-attributes of each objective, combined the comprehensive views of the relevant decision-makers, and transferred discrete levels of objective's attributes to integrated levels. After that, it defined an integrated index to determine each objective sorting weight, and determined the multi-objective integrated fitness function of vehicle routing problem with time window base on objective's weights and standardized objective function value, it transfered multi-objectives problem into single objective problem. Then it used max-min ant system algorithm to solve the problem. Finally, it used a case to illustrate the algorithm's effectiveness.

Key words: vehicle routing problem(VRP); time window; objectives preference; uncertain linguistic information; ant colony algorithm; max-min ant system(MMAS)

0 引言

基本车辆路径问题(VRP)只是已知 n 个客户的位置坐标和货物需求,在可供使用车辆数量及运载能力条件的约束下,每辆车都从起点出发,完成若干客户点的运送任务后再回到起点,要求以最少的车辆数、最小的总行程完成货物的派送任务。从本质上说,TSP 是 VRP 的基本问题^[1]。

有时间窗的车辆路径问题(vehicle routing problem with time window,VRPTW)更贴近实际的配送问题。该问题可以概括为:已知 n 个货物需求点(客户)的位置和需求,用多个车辆从中心仓库(或配送中心)配送货物到达这批需求点,要求必须在它的时间窗内为每个客户服务,如果车辆提前到达了客户所在地,也必须等待,直到允许为该客户服务为止。每量车辆载重量一定,每条线路不得超过车辆载重量,每个需求点的需求必须且只能由一辆车辆来提供,目标是 최소화总体车辆配送时间、总体车辆行驶距离和所需的车辆数目,很明显它是一个多目标问题^[2]。

1985 年,Savelsbergh 证明了 VRP 是一个 NP 难题,很难求得问题的最优解;1999 年 Bullnheimer 等学者首先将蚁群算法

的思想用于求解车辆路径问题,设计了一种改进的蚁群算法求解车辆路径问题;我国的马良、范炳全等学者提出了车辆路径问题的蚁群搜索算法,进一步扩展了蚁群算法在车辆路径问题中的应用。由此可见,蚁群算法是解决 VRPTW 的一个有效途径,但是这些算法并没有考虑到决策者目标偏好对路径选择的影响。因此,本文基于一种不确定性多目标综合评价方法,在决策者目标偏好的基础上,采用改进的蚁群算法寻找在满足多目标情况下的 VRPTW 最优方案。

1 不确定性多目标 VRPTW 综合评价

现实中车辆路径优化问题都是多目标问题,存在多个彼此冲突的目标。Parsopoulos 等学者率先采用传统线性加权法、“Bang-Bang”加权法和动态加权法将多目标问题转换为单目标问题^[1]。此后,很多学者基于目标加权算法的启发,开展了许多开放性的研究。但是现实生活中的多目标问题存在多个彼此冲突的目标,如何获取这些目标的协同最优解,一直都是学术界和工程界关注的焦点。多目标优化的本质在于对各目标进行协调权衡和折中处理,使所有目标函数尽可能达到最优,而问题的最优解是由数量众多,甚至无穷大的 Pareto 解组成。

收稿日期: 2011-08-16; **修回日期:** 2011-09-21 **基金项目:** 国家社科基金资助项目(11CJY067);甘肃省自然科学基金资助项目(096RJZA088)

作者简介: 李世威(1981-),男,甘肃白银人,讲师,硕士,主要研究方向为数据挖掘、决策分析(lst9647@126.com);王建强(1980-),男,讲师,硕士,主要研究方向为数据挖掘、信息处理;曾俊伟(1982-),男,讲师,硕士,主要研究方向为数据挖掘、决策分析。

如何从庞大的 Pareto 解集中搜寻到让决策者满意的方案,成为多目标优化问题的一个主要发展方向^[3]。为了避免在庞大的 Pareto 解集中寻优的困难,本文基于不确定性多属性决策的基本原理构建评价多目标问题的综合适应度函数,将多目标问题转换为单目标问题。但问题在于如果 Pareto 解集是非凸或不连续集合,那么就会很难得到 Pareto 解集中的最优解。因此,该模型算法局限于解决 Pareto 解集为凸、连续集合的多目标决策问题。

面对一个多目标问题时,由于客观事物的复杂性、不确定性以及人类思维的模糊性,再加上专家们受到一些主客观因素制约,他们往往所给出的评估信息是不完全的^[4],通常根据个人偏好,通过比较给定目标属性的不确定性评价信息,采用不确定性多属性决策的基本原理,将这些不确定性评价信息转换为决策者目标偏好权重,从而确定决策者目标偏好的综合适应度函数,作为判断 Pareto 解优劣的适应度函数。

本文依据文献[4]的不确定多属性决策方法,对其决策者权重计算、目标属性权重计算和各目标值规范化处理进行修正,从而得到一个更加符合现实的目标排序,进而保证构建决策者目标偏好的综合适应度函数的正确性、客观性和公正性。

1.1 不确定性语言算子

定义 1 设不确定性语言集合为 $S, S = \{S_{-4}, S_{-3}, S_{-2}, S_{-1}, S_0, S_1, S_2, S_3, S_4\} = \{\text{极差, 很差, 差, 较差, 一般, 较好, 好, 很好, 极好}\}$ 。

定义 2^[4] 设 $\tilde{u} = [S_a, S_b]$, 其中 $S_a, S_b \in S, a < b, S_a, S_b$ 分别是 $\tilde{u}$ 的下限和上限, 则称 $\tilde{u}$ 为不确定语言变量。

对于任意不确定语言变量 $\tilde{u} = [S_a, S_b], \tilde{v} = [S_c, S_d]$ 和实数 $\beta \in [0, 1]$, 定义如下运算法则^[4]:

- a) $\tilde{u} \oplus \tilde{v} = [S_a \oplus S_c, S_b \oplus S_d] = [S_{a+c}, S_{b+d}]$;
- b) $\tilde{u} \otimes \tilde{v} = \tilde{v} \otimes \tilde{u}$;
- c) $\beta \cdot \tilde{u} = [\beta \cdot S_a, \beta \cdot S_b] = [S_{\beta a}, S_{\beta b}]$;
- d) $\beta \cdot (\tilde{u} \oplus \tilde{v}) = \beta \cdot \tilde{u} \oplus \beta \cdot \tilde{v}$ 。

定义 3^[4] 设 $\tilde{u} = [S_a, S_b], \tilde{v} = [S_c, S_d]$, 则 $\tilde{u} \geq \tilde{v}$ 的可能度定义为

$$P(\tilde{u} \geq \tilde{v}) = \max \{ 1 - \max (\frac{d-a}{(b-a)+(d-c)}, 0), 0 \}$$
 (1)

同理, $\tilde{v} \geq \tilde{u}$ 的可能度为

$$P(\tilde{v} \geq \tilde{u}) = \max \{ 1 - \max (\frac{b-c}{(b-a)+(d-c)}, 0), 0 \}$$

由定义 3 可知:

- a) $P(\tilde{u} \geq \tilde{v}) + P(\tilde{v} \geq \tilde{u}) = 1$, 特别地, $P(\tilde{u} \geq \tilde{u}) = 0.5$;
- b) $P(\tilde{u} \geq \tilde{v}) \geq 0.5$, 当且仅当 $a + b \geq c + d$ 。

定义 4 设有 n 个不确定语言变量 $\tilde{u}_i (i = 1, 2, \dots, n)$, 利用式(1)分别进行两两比较, 可以得到相应的可能度 $P(\tilde{u}_i \geq \tilde{u}_j) = p_{ij} (i, j = 1, 2, \dots, n)$, 并建立可能度互补判断矩阵 $P = (p_{ij})_{n \times n}$ 。

定义 5^[4] 设可能度互补判断矩阵 $P = (p_{ij})_{n \times n}$, 定义行和归一化方法求得权重向量 $\omega = (\omega_1, \omega_2, \dots, \omega_n)$ 满足

$$\omega_i = \frac{1}{n(n-1)} (\sum_{j=1}^n p_{ij} + \frac{n}{2} - 1) \quad i = 1, 2, \dots, n$$
 (2)

1.2 不确定性多目标 VRPTW 综合评价步骤

对于一个多目标 VRPTW 决策问题, 设 O, U 和 D 分别为目标集、属性集和决策者集, 该算法的步骤为:

- a) 确定决策者权重 ω^D 。

(a) 根据决策者集 D , 制定评价决策者重要性的相关指标集, 分别在各指标下对不同决策者进行不确定性语言评价, 得到决策者指标评判矩阵;

(b) 分别对各指标进行不确定语言评价, 得到各指标偏好信息;

(c) 根据定义 4 和 5, 将各指标偏好信息转换为指标权重向量 ω^I ;

(d) 根据 ω^I 分别对各决策者的指标评判信息进行加权求和, 得到决策者综合指标后的不确定语言变量信息 I ;

(e) 根据定义 4 和 5, 将决策者综合指标后的不确定语言变量信息转换为决策者权重 ω^D 。

- b) 确定属性权重 ω^U 。

(a) 分别对属性集 U 中的各属性进行不确定性语言评判, 得到属性偏好信息;

- (b) 根据定义 4 和 5, 将属性偏好信息转换为属性权重 ω^U 。

- c) 确定目标权重 ω^O 。

(a) 各决策者在不同目标的各属性下进行不确定语言评判, 得到决策者评价信息;

(b) 根据决策者权重 ω^D , 分别对决策者评价信息中不同目标的各属性评判信息进行加权求和, 得到属性综合评判矩阵 D ;

(c) 根据属性权重 ω^U , 分别对矩阵 D 中各目标的评判信息进行加权求和, 得到目标综合评判矩阵 D' ;

(d) 根据定义 4 和 5, 将目标综合评判信息转换为目标权重 ω^O 。

- d) 对各目标值 f_i 进行规范化处理。

如果是成本型目标, 则规范化后的目标值为

$$f'_i = \frac{f_i^{\max} - f_i}{f_i^{\max} - f_i^{\min}}$$
 (3)

如果是收益型目标, 则规范化后的目标值为

$$f'_i = \frac{f_i - f_i^{\min}}{f_i^{\max} - f_i^{\min}}$$
 (4)

其中: $f_i^{\max}, f_i^{\min}$ 分别表示第 i 目标的最大值和最小值, 通常根据研究问题的特性来选定。

- e) 确定决策者目标偏好的综合适应度函数 F 。

依照决策者目标偏好权重 ω^O , 对规范化处理的各目标函数 f'_i 采用线性加权法构建决策者目标偏好的综合适应度函数 F 为

$$F = \sum \omega_i^O f'_i$$
 (5)

2 最大—最小蚂蚁系统 VRPTW 算法

最大—最小蚂蚁系统(MMAS)的基本思想是: 仅让每一代中的最好个体所走路径上的信息量作调整, 从而更好地利用历史信息, 以加快收敛速度。但这样更容易出现过早收敛的停滞现象。为了避免算法过早收敛于局部最优解, 将各条路径上的信息量限制在 $[\tau_{\min}, \tau_{\max}]$ 之内, 超出这个范围的值将被限制为信息量允许值的上下限, 这样可以有效地避免某条路径上的信息量远大于其他路径而造成的所有蚂蚁都集中到同一条路径上, 从而使算法不再扩散, 加快收敛速度。MMAS 是解决 TSP、QAP、VRP 等离散域优化问题的最好蚁群算法之一, 很多对蚁群算法的改进算法都渗透着 MMAS 的思想^[1]。

显而易见, $\tau_{\min}$ 与 $\tau_{\max}$ 的设定对算法性能至关重要。因为每次迭代路径上增加的最大信息素为 $1/L(s^{el})$, 其中 $L(s^{el})$ 为

全局最好路径的长度,所以每当更新最好解时,需要同时更新 $\tau_{\min}$ 与 $\tau_{\max}$ 。 $\tau_{\max}$ 与信息素的挥发率 $(1-\rho)$ 以及 $L(s^{gl})$ 成反比,而与精英蚂蚁的数量成正比。因此,可以按以下策略动态调整 $\tau_{\max}$ 与 $\tau_{\min}$ ^[2]:

a) 初始化 $\tau_{\max}$ 与 $\tau_{\min}$ 。

$$\tau_{\max}(t) = \frac{1}{2(1-\rho)} \times \frac{1}{L(s^{gl})} \quad (6)$$

$$\tau_{\min}(t) = \frac{\tau_{\max}}{20} \quad (7)$$

b) 一旦信息素更新后,调整 $\tau_{\max}$ 。

$$\tau_{\max} = \frac{1}{2(1-\rho)} \times \frac{1}{L(s^{gl})} + \frac{\sigma}{L(s^{gl})} \quad (8)$$

其中: σ 表示精英蚂蚁的个数。

$\tau_{\min}$ 利用式(7)进行调整。

2.1 路径构造

每只蚂蚁选择下一个城市时,在满足车辆容量和时间窗约束的条件下,需要考虑两个方面的因素:

a) 通往下一个城市的路径长度以及路径上信息素的多少。

b) 时间窗的择优选择性,由下一个客户 j 的时间窗宽度和所在客户 i 到达客户 j 的时间等因素决定,所以这种择优性的优先选择为:需等待时间较短优先原则和时间窗较小优先原则^[2]。

综合以上两个方面的因素,第 k 条路径上的蚂蚁在城市 v_i 选择城市 v_j 的概率计算式^[2]为

$$P_{ij}^k = \begin{cases} \frac{\omega_1 \frac{(\tau_{ij})^\alpha (\eta_{ij})^\beta}{\sum_{h \in \Omega} (\tau_{ih})^\alpha (\eta_{ih})^\beta} + \omega_2 \frac{\frac{1}{|t_{ij} - a_j| + |t_{ij} - b_j|}}{\sum_{h \in \Omega} \frac{1}{|t_{ih} - a_h| + |t_{ih} - b_h|}}}{\omega_1 \frac{(\tau_{ij})^\alpha (\eta_{ij})^\beta}{\sum_{h \in \Omega} (\tau_{ih})^\alpha (\eta_{ih})^\beta} + \omega_2 \frac{\frac{1}{|t_{ij} - a_j| + |t_{ij} - b_j|}}{\sum_{h \in \Omega} \frac{1}{|t_{ih} - a_h| + |t_{ih} - b_h|}}}, v_j \in \Omega \\ 0, \text{otherwise} \end{cases} \quad (9)$$

其中: $\Omega = \{v_j | v_j \text{ 为可被访问的城市} \} \cup \{v_0\}$, v_0 为配送中心; ω_1 和 ω_2 为权重系数,满足 $0 \leq \omega_1, \omega_2 \leq 1$, 且 $\omega_1 + \omega_2 = 1$; $[a_j, b_j]$ 为客户 j 的时间窗; t_{ij} 为由客户 i 到达客户 j 的时间,即开始为客户 i 服务的时间 + 客户 i 所需的服务时间 + 从客户 i 到客户 j 的路程消耗时间; α 和 β 为轨迹上的信息素和该轨迹可见性的权重系数; τ_{ij} 为 v_i 与 v_j 之间轨迹上的信息素,且 $\tau_{ij} \in [\tau_{\min}, \tau_{\max}]$; η_{ij} 为轨迹的可见性,本文取 $\eta_{ij} = 1/d_{ij}$, d_{ij} 为客户 i 与 j 之间的距离。

2.2 信息素更新

信息素更新有局部更新和全局更新两种方法^[1]。本文采用全局更新方法,只将最好的蚂蚁用于信息素的更新,将路径构造中排名前几位的精英蚂蚁用于信息素的更新。

更新规则^[1]为

$$\tau_{ij}^{new} = (1-\rho)\tau_{ij}^{old} + \sum_{h=1}^{\sigma-1} \Delta\tau_{ij}^h + \Delta\tau_{ij}^* \quad (10)$$

其中,当且仅当轨迹 (v_i, v_j) 被排名第 h 好的蚂蚁利用时,其信息素才增加 $\Delta\tau_{ij}^h = (\sigma - \mu)/L_h$, L_h 为排名为 h 的路径长度;所有属于当前最好路径轨迹上的信息素都被统一加强 $\Delta\tau_{ij}^* = 1/L^*$, L^* 为当前最好解路径的长度。

由于单纯使用该方法,使得算法收敛速度缓慢,而且其全局优化性能也不明显。为了加快其收敛速度,同时又不影响全局优化能力,在该规则基础上加入一个复合规则:在迭代过程中,对出现优于上一代解的本代解给予激励,对于劣于上一代解的本代解给予惩罚,从而加快算法的收敛速度。对更新过的路径具体激励与惩罚计算式^[1]为

$$\tau_{ij}^{new} = \tau_{ij}^{new} + \tau_{ij}^{new} \frac{L_{new} - L_{old}}{L_{old}} \quad (11)$$

2.3 初始解构造

在构造初始解时,需要确定 $\tau_{\min}$ 与 $\tau_{\max}$ 的值,而确定它们的值首先要明确 $L(s^{gl})$ 的值,所以在最初就必须有一个较好的可行解。由于 VRPTW 的复杂性,导致产生一个可行的初始解非常复杂。本文采用文献[1]中一种基于客户时间窗下限较小优先的快速产生初始解的算法。该算法选择下一个客户的策略为:从当前路径的最后一个客户出发,到所有未访问过的客户中开始服务时间最早的那个客户。只有当开始服务时间超过这个客户的时间窗时,才需要新开辟一条路径,并从未访问过的客户中重新选择出发点,将所有未访问过的客户中开始服务时间最早的那个客户作为新路径的第一个客户。该算法流程^[1]为:

a) 初始化。

b) 将所有未被访问过的客户放入集合 C 中。

c) $C = \{c_0, \dots, c_i, \dots, c_j, \dots\}$, C 中的元素按如下规则进行排列:对任意的 $i \leq j$, 设 c_i 是当前路径 R 最后一个客户时所花费的总时间,用 W_i 表示, c_j 是当前路径 R 最后一个客户时所花费的总时间,用 W_j 表示(当前路径 R 是随着时间动态更新的),满足 $W_i \leq W_j$; 令 $k = 1$ 。

d) 如果集合 C 为空,转至 g)。

e) 如果 $W(c_k, c_i) = T$, 保存当前路径 R ; 重新开辟一条路径,从当前未被访问的客户中随机选择一个客户 c_r 作为新路径的出发点, $C = C - c_r$; 转至 c)。其中, $W(c_k, c_i)$ 的返回值为 $\max(c_k \text{ 的开始服务时间} + c_k \text{ 的服务所需时间} + \text{从 } c_k \text{ 到 } c_i \text{ 的行驶时间})$ 。如果到达 c_i 的时间晚于客户 i 的时间窗,则 $W(c_k, c_i)$ 返回一个很大的 T 值,表示该客户不能加入路径。

f) 如果客户 k 为当前路径 R 的合法客户,将 c_k 加入当前路径 R 中; $C = C - c_k$; $k = k + 1$; 转至 d)。

g) 输出计算结果,程序结束。

3 算例分析

假设有三名专家辅助一名决策者解决有三个目标(总体行驶时间最少 f_1 、总体行驶路程最短 f_2 、总体使用车辆数目最少 f_3)的车辆路径优化问题,他们从盈利能力、客户满意度、配送可靠性三个属性来综合平衡三个目标,他们的评价是不确定性语言,评价信息如表 1 所示。其中,属性权重是决策者对各属性重要程度的不确定性语言评判。

表 1 决策者对各目标的不确定性评判信息

目标	决策者/专家 1/专家 2/专家 3		
	盈利能力	客户满意度	配送可靠性
时间最短	$[s_3, s_4] / [s_2, s_3] /$	$[s_2, s_3] / [s_2, s_3] /$	$[s_{-2}, s_{-1}] / [s_{-1}, s_0] /$
	$[s_2, s_3] / [s_2, s_3]$	$[s_2, s_3] / [s_2, s_3]$	$[s_0, s_1] / [s_{-2}, s_{-1}]$
路程最短	$[s_1, s_2] / [s_1, s_2] /$	$[s_1, s_2] / [s_1, s_2] /$	$[s_{-1}, s_0] / [s_0, s_1] /$
	$[s_2, s_3] / [s_2, s_3]$	$[s_1, s_2] / [s_0, s_1]$	$[s_0, s_1] / [s_{-2}, s_{-1}]$
车辆最少	$[s_2, s_3] / [s_1, s_2] /$	$[s_{-2}, s_{-1}] / [s_0, s_1] /$	$[s_{-1}, s_0] / [s_0, s_1] /$
	$[s_1, s_2] / [s_2, s_3]$	$[s_{-1}, s_0] / [s_{-1}, s_0]$	$[s_0, s_1] / [s_{-1}, s_0]$
属性权重	$[s_3, s_4]$	$[s_2, s_3]$	$[s_2, s_3]$

决策者对自身和专家的评价从信任度、了解度、客观性和风险观念四个方面的指标进行权衡,采用不确定性语言对这四个指标的重要性,以及对自身和专家的决策重要程度进行评价,由此可以得到综合有效的决策者权重。该决策者的评价指

标信息如表 2 所示。

表 2 决策者评价指标信息

指标	指标权重	决策者	专家 1	专家 2	专家 3
信任度	$[S_3, S_4]$	$[S_2, S_3]$	$[S_3, S_4]$	$[S_1, S_2]$	$[S_1, S_2]$
了解度	$[S_2, S_3]$	$[S_2, S_3]$	$[S_3, S_4]$	$[S_1, S_2]$	$[S_2, S_3]$
客观性	$[S_2, S_3]$	$[S_2, S_3]$	$[S_2, S_3]$	$[S_2, S_3]$	$[S_1, S_2]$
风险观念	$[S_1, S_2]$	$[S_2, S_3]$	$[S_2, S_3]$	$[S_2, S_3]$	$[S_1, S_2]$

1) 确定决策者权重,利用定义 4 对表 2 指标权重的不确定语言数据进行两两比较,建立指标权重的可能度互补判断矩阵 P_1 为

$$P_1 = \begin{bmatrix} 0.5 & 1 & 1 & 1 \\ 0 & 0.5 & 0.5 & 1 \\ 0 & 0.5 & 0.5 & 1 \\ 0 & 0 & 0 & 0.5 \end{bmatrix}$$

根据式(2)得到可能度互补判断矩阵 P_1 指标权重向量 $\omega^I = (0.375, 0.250, 0.250, 0.125)^T$ 。

运用 ω^I 分别对各决策者的指标评判信息进行加权求和,得到决策者综合指标后的不确定语言变量信息向量 $I = (I_1, I_2, I_3, I_4)^T$:

$$\begin{aligned} I_1 &= 0.375 \cdot [S_2, S_3] \oplus 0.250 \cdot [S_2, S_3] \oplus 0.250 \cdot [S_2, S_3] \oplus 0.125 \cdot [S_2, S_3] = [S_2, S_3] \\ I_2 &= 0.375 \cdot [S_3, S_4] \oplus 0.250 \cdot [S_3, S_4] \oplus 0.250 \cdot [S_2, S_3] \oplus 0.125 \cdot [S_2, S_3] = [S_{2.625}, S_{3.625}] \\ I_3 &= 0.375 \cdot [S_1, S_2] \oplus 0.250 \cdot [S_1, S_2] \oplus 0.250 \cdot [S_2, S_3] \oplus 0.125 \cdot [S_2, S_3] = [S_{1.375}, S_{2.375}] \\ I_4 &= 0.375 \cdot [S_1, S_2] \oplus 0.250 \cdot [S_2, S_3] \oplus 0.250 \cdot [S_1, S_2] \oplus 0.125 \cdot [S_1, S_2] = [S_{1.25}, S_{2.25}] \end{aligned}$$

利用定义 4 对向量 I 的不确定语言数据进行两两比较,建立决策者综合指标后的可能度互补判断矩阵 P_2 :

$$P_2 = \begin{bmatrix} 0.5 & 0.187 & 0.813 & 0.875 \\ 0.813 & 0.5 & 0.948 & 1 \\ 0.187 & 0.052 & 0.5 & 0.562 \\ 0.125 & 0 & 0.438 & 0.5 \end{bmatrix}$$

根据式(2)得到可能度互补判断矩阵 P_2 决策者权重向量 $\omega^D = (0.281, 0.355, 0.192, 0.172)^T$ 。

2) 确定属性权重,利用定义 4 对表 1 属性权重的不确定语言数据进行两两比较,建立属性权重的可能度互补判断矩阵 P_3 :

$$P_3 = \begin{bmatrix} 0.5 & 1 & 1 \\ 0 & 0.5 & 0.5 \\ 0 & 0.5 & 0.5 \end{bmatrix}$$

根据式(2)得到可能度互补判断矩阵 P_3 属性权重向量 $\omega^U = (0.500, 0.250, 0.250)^T$ 。

3) 确定目标权重,根据决策者权重向量 ω^D 对表 1 中不同目标的各属性评判信息进行加权求和:

$$\begin{aligned} D_{11} &= 0.218 \cdot [S_3, S_4] \oplus 0.355 \cdot [S_2, S_3] \oplus 0.192 \cdot [S_2, S_3] \oplus 0.172 \cdot [S_2, S_3] = [S_{2.281}, S_{3.281}] \end{aligned}$$

以此类推,得到属性综合评判矩阵 D :

$$D = \begin{bmatrix} [S_{2.281}, S_{3.281}] & [S_{2.000}, S_{3.000}] & [S_{-1.261}, S_{-0.261}] \\ [S_{1.364}, S_{2.364}] & [S_{0.828}, S_{1.828}] & [S_{-0.625}, S_{0.375}] \\ [S_{1.453}, S_{2.453}] & [S_{-0.926}, S_{0.074}] & [S_{-0.453}, S_{0.547}] \end{bmatrix}$$

根据属性权重向量 ω^U 对属性综合评判矩阵 D 中各目标的评判信息进行加权求和:

$$D'_{11} = 0.500 \cdot [S_{2.281}, S_{3.281}] \oplus 0.250 \cdot [S_2, S_3] \oplus 0.250 \cdot$$

$$[S_{-1.261}, S_{-0.261}] = [S_{1.325}, S_{2.325}]$$

以此类推,得到目标综合评判矩阵 D' :

$$D' = ([S_{1.325}, S_{2.325}], [S_{0.733}, S_{1.733}], [S_{0.382}, S_{1.382}])^T$$

利用定义 4 对目标综合评判矩阵 D' 的不确定语言数据进行两两比较,建立目标综合评判可能度互补判断矩阵 P_4 :

$$P_4 = \begin{bmatrix} 0.5 & 0.796 & 0.971 \\ 0.204 & 0.5 & 0.675 \\ 0.029 & 0.325 & 0.5 \end{bmatrix}$$

根据式(2)得到可能度互补判断矩阵 P_4 目标偏好权重向量 $\omega^O = (0.461, 0.313, 0.226)^T$ 。

由于行驶时间、行驶路程和使用车辆数目都是成本型目标函数,因此采用式(3)进行规范化处理,得到规范化后的目标函数 $f'_i (i=1, 2, 3)$ 。

4) 根据各目标偏好权重向量 ω^O 和规范化后的目标函数 f'_i ,确定决策者目标偏好综合适应度函数 F :

$$F = \sum \omega_i^O f'_i = 0.461 f'_1 + 0.313 f'_2 + 0.226 f'_3$$

将构建的决策者目标偏好综合适应度函数 F 应用于 MMAS 算法中,采用文献[1]中所述的标准 VRPTW 数据集。该数据集共有 56 个实例,每个实例均含有 100 个客户和 1 个中心仓库,并规定了车辆负载、客户的时间窗和车辆的运行时间。实例分为 $R_1, R_2, C_1, C_2, RC_1, RC_2$ 六类,其中 R_1 和 R_2 中的客户为随机分布, C_1 和 C_2 中的客户有聚类趋势, RC_1 和 RC_2 中的客户兼有 R 类和 C 类的特征。

实验过程中,在每个城市放置一只蚂蚁(蚂蚁个数等于客户数目),设置 $\alpha=1.0, \beta=5.0$;信息素挥发系数 ρ 在 $0.02 \sim 0.3$ 取值;精英蚂蚁个数 σ 在 $3 \sim 6$ 取值;路径上的信息素初始化为 τ_{max} ;权重系数的取值范围设定为 $0.5 < \omega_1 < 1.0, 0 < \omega_2 < 0.5$ 。图 1 和 2 分别描述了实例 RC_{101} 和 RC_{102} 在决策者目标偏好综合适应度函数 F 作用下的收敛曲线。




图 1 实例 RC_{101} 收敛曲线

图 2 实例 RC_{102} 收敛曲线

从图中可以看出,该算法在初期就能使得当前解得到很好的改善,并且收敛速度较快,为求解有时间窗的车辆路径问题提供了一种有效的方法。

4 结 束 语

本文针对决策者在面对多目标的、有时间窗的车辆路径问题时,对各个目标进行不确定性评判,结合专家的综合意见以及决策者自身对专家意见的偏好,将决策者对目标属性的离散意见转换为对各目标的综合意见;通过定义一种不确定性综合排序指标来确定决策者对各目标的偏好权重,依据目标权重和各目标函数的规范化处理,构建评价有时间窗的车辆路径问题的多目标综合适应度函数,进而采用 MMAS 算法对该问题进行求解。本文最后采用标准实验数据集进行验证,结果表明该算法能够有效地解决多目标的、有时间窗的车辆路径问题,为解决带有时间窗的车辆路径多目标问题提供了一种现实可行的方法。

误差最大,该模型不能很好地表达非线性的耕地面积变化系统;BPNN 的预测精度指标均高于 MLR 模型,但结构设计和参数确定困难,并且十分不稳定,很容易出现过拟合现象;LSSVM 相对于 BPNN,其预测精度有了很大程度的提高,这表明 LSSVM 适合于小样本耕地面积数据的预测,很好地克服了 BPNN 的过拟合、局部极小等缺陷,更加全面地描述了耕地面积复杂的非线性变化规律;同时,PSO-LSSVM 预测精度高于 GA-LSSVM,再一次证明了 PSO 对 LSSVM 参数优化要优于 GA。




图2 几种模型的拟合结果




图3 几种模型的预测结果

3 结束语

耕地面积变化受多种因素影响,是一种复杂的非线性系统。传统线性的耕地面积预测模型不能满足实际耕地面积分析与预测要求,神经网络模型虽然具有处理多因素、非线性问题的能力,但其基于经验风险最小原则,对于小样本的耕地面积数据,不能保证模型具有很好的泛化推广性。LSSVM 模型是一种专门针对小样本、多因素的算法,具有不需要对数据分布性质作任何假设且通用性较强等优点。因此,本文将 PSO-LSSVM 引入到耕地面积预测中,结果表明 PSO-LSSVM 非常适合于小样本的耕地面积建模与预测,各项性能评价指标优于 MLR、BPNN 和 GA-LSSVM 模型,是一种快速、高精度的耕地面积预测方法。

参考文献:

[1] 王群.城市化进程中土地资源持续利用问题[J].中国土地科学,2003,17(2):47-51.

[2] 杨东,刘强.基于 GM(1,1)模型的河西地区城镇化与耕地利用变化研究——以张掖市甘州区为例[J].西北师范大学学报:自然科学版,2010,46(3):111-115.

[3] 邵晓梅,杨勤业,张洪业.山东省耕地变化趋势及驱动力研究[J].地理研究,2001,20(3):298-306.

[4] 李玉平,蔡运龙.浙江省耕地变化与粮食安全的分析及预测[J].长江流域资源与环境,2007,16(4):466-470.

[5] 赵永华,何兴元,胡远满,等.岷江上游汶川县耕地变化及驱动力研究[J].农业工程学报,2006,22(2):94-97.

[6] 李景刚,何春阳,史培军,等.近 20 年中国北方 13 省的耕地变化与驱动力[J].地理学报,2005,59(2):274-282.

[7] 李立辉,胡月明,陈联诚.神经网络模型在种植业劳均耕地面积预测中的应用[J].系统工程理论与实践,2000(9):130-133-140.

[8] 胡喜生,洪伟,吴承祯.基于 BP 神经网络的福建省耕地预测模型[J].福建农林大学学报:自然科学版,2008,37(4):425-427.

[9] 张明光,阎威武,李战明.基于支持向量机的非线性系统辨识研究[J].计算机应用研究,2006,23(5):47-48,82.

[10] 向昌盛,周子英,武丽娜.基于 ARIMA 和 DSVM 的松毛虫发生面积预测[J].湖南农业大学学报:自然科学版,2010,36(4):430-433.

[11] 向昌盛,周子英.基于支持向量机的害虫多维时间序列预测[J].计算机应用研究,2010,27(10):3694-3697.

[12] 张占录,殷秀云.基于灰色系统及趋势测算的有效耕地面积计算方法[J].农业工程学报,2011,27(3):288-294.

[13] 杨柳,刘艳芳.将微粒群和支持向量机用于耕地驱动因子选择的研究[J].武汉大学学报:信息科学版,2010,35(2):248-251.

(上接第 872 页)

该算法问题在于如果 Pareto 解集是非凸集合,那么就会很难得到 Pareto 解集中的最优解。因此,算法只局限于解决 Pareto 解集为凸集的多目标 VRPTW 决策问题。对于如何解决 Pareto 解集为非凸集合的多目标 VRPTW 决策问题,将是本文今后进一步研究的方向。

参考文献:

[1] 汪定伟,王俊伟,王洪峰,等.智能优化方法[M].北京:高等教育出版社,2007:198-205.

[2] 马良,朱刚,宁爱兵.蚁群优化算法[M].北京:科学出版社,2008:85-115.

[3] 雷德明,严新平.多目标智能优化算法及其应用[M].北京:科学出版社,2009:12-19.

[4] 徐泽水.不确定多属性决策方法及应用[M].北京:清华大学出版社,2004:201-214.

[5] 李世威,王建强,曾俊伟.一种模糊偏好排序的多目标粒子群算法[J].计算机应用研究,2011,28(2):477-480.

[6] 万旭,林健良,杨晓伟.改进的最大—最小蚂蚁算法在有时间窗车辆路径问题中的应用[J].计算机集成制造系统,2005,11(4):572-576.

[7] 刘志硕,申金升,柴跃廷.基于自适应蚁群算法的车辆路径问题研究[J].控制与决策,2005,20(5):562-566.

[8] MOHAMMAD A, MIGUEL M. Application of an ant algorithm for layout optimization of tree network[J]. Engineering Optimization, 2006,38(3):353-369.

[9] CHEN C H, TING C J. An improved ant colony system algorithm for the vehicle routing problem[J]. Journal of the Chinese Institute of Industrial Engineers, 2006,23(2):115-126.

[10] BAHREININEJAD A, HESAMFAR P. Subdomain generation using emergent ant colony optimization[J]. Computers and Structures, 2006,4(5):1719-1728.

[11] ISSMAIL E, CALAMAI P, BASIR O. Exchange strategies for multiple ant colony system[J]. Journal of Information Sciences, 2006,3(1):46-63.

[12] SIQUEIRA P H, STEINER M T, SCHEER S. A new approach to solve the traveling salesman problem[J]. Neurocomputing, 2006,70(4):1013-1021.

[13] BIANCHI L, KNOWLES J, BOWLER J. Local search for the probabilistic traveling salesman problem: correction to the 2-p-opt and 1-shift algorithms[J]. European Journal of Operational Research, 2005,162(1):206-219.