

求解双层 CARP 优化问题的演化学习型遗传算法

邢立宁, 姚 锋

(国防科学技术大学信息系统与管理学院, 湖南 长沙 410073)

摘要: 双层有能力约束的弧路径优化问题(capacitated arc routing problem, CARP)的研究对象通常是某个城市或地区, 首先聚焦于该地物流系统的宏观配置, 然后考虑相关服务的完成问题。针对双层 CARP 优化问题, 提出了一种演化学习型遗传算法(learnable genetic algorithm, LGA)。建立了 LGA 的基本框架, 设计了构件知识和算子知识等知识形式。在 LGA 中, 采用扩展启发式方法辅助生成初始种群, 使用算子知识为选择、交叉和变异选择操作算子, 应用构件知识为交叉和变异操作选择断点位置, 同时借助局部替换程序不断地向当前种群中注入新个体。LGA 的框架为现有优化方法改进提供了一种有益借鉴。

关键词: 组合优化; 有能力约束的弧路径优化问题; 演化学习型遗传算法

中图分类号: TP 301.6

文献标志码: A

DOI: 10.3969/j.issn.1001-506X.2012.06.19

Learnable genetic algorithm to double-layer CARP optimization problems

XING Li-Ning, YAO Feng

(College of Information System and Management, National University of Defense Technology, Changsha 410073, China)

Abstract: In double-layer capacitated arc routing problems (CARP), both the high-level configuration problem and the low-level service problem are considered as optimization objects. Aiming to the double-layer CARP problems, a learnable genetic algorithm (LGA) is proposed. The basic architecture of LGA is constructed, and two different forms of knowledge are designed to provide an important foundation for the LGA. In LGA, two extended heuristic approaches are employed to generate initial populations, the performance knowledge of operators is used to select a proper operator for the selection, crossover and mutation, the component knowledge is employed to select a proper breakpoint location for each crossover and mutation, and the partial replacement procedure is used to maintain population diversity. To validate the performance of LGA, 24 benchmark problems are solved by LGA and some extended heuristic methods. The LGA architecture will act as a helpful reference to the improvement of optimization approaches.

Keywords: combination optimization; capacitated arc routing problem (CARP); learnable genetic algorithm (LGA)

0 引言

物流行业是国民经济发展的基础和命脉, 其发展程度已成为衡量一个国家现代化程度和综合国力的重要标志之一。快递物流配送是一种以道路为服务对象的路径优化问题, 研究重点是如何快速准确地完成分布在不同路径上的多个客户的物品配送。快递物流配送车辆的容量是有限的, 因此快递物流配送可被抽象为车辆带有容量限制的弧路径问题(capacitated arc routing problem, CARP)。现实

生活中存在着许多典型 CARP 问题: 邮件配送^[1]和校车接送^[2]的规划; 垃圾收集车^[3]和铺沙车^[4]的路由等。

Cooper 把选址与运输问题结合起来, 提出了选址-路线安排问题(location routing problem, LRP)。该问题寻求对设施选址和车辆路径选择的同时优化, 比车辆路径优化问题更加复杂。文献[5]采用混合遗传算法求解 LRP 问题。文献[6]采用混合整数规划模型求解小规模 LRP 问题, 采用启发式方法求解大规模 LRP 问题。文献[7]采用多目标超启发式方法求解 LRP 问题。文献[8]对冬天道路维护中

收稿日期: 2011-08-15; 修回日期: 2011-12-28。

基金项目: 国家自然科学基金重点项目(71031007); 国家自然科学基金(70971131, 71101150, 70801062); 高等学校博士学科点专项科研基金(20104307120019)资助课题

作者简介: 邢立宁(1980-), 男, 讲师, 博士, 主要研究方向为管理理论与管理决策技术。E-mail: xinglining@gmail.com

的选址-路线安排问题进行了综述。文献[9]使用两阶段启发式算法求解 LRP 问题。文献[10]建立了配送中心选址与车辆路径一体优化的双层规划模型。

根据笔者掌握的文献,现有 LRP 研究大多针对以点为服务对象的车辆路径优化,而针对以道路为服务对象的弧路径优化研究尚不多见。故本文将快递物流配送问题抽象成双层 CARP 问题:将某城市(地区)看作研究对象,首先考虑物流系统的宏观配置问题,如仓库位置、数目及车辆数目等;然后考虑配送任务的完成问题,如寻找所有车辆的最优路径使得那些必须被服务的路段能及时得到有效服务。

智能优化方法为诸如双层 CARP 优化等复杂问题的求解提供了切实可行的解决方案。近年来,越来越多的学者开始研究智能优化过程中演化与学习之间的交互^[11-14]。文献[15]将已经获得个体的部分优良特征看作是一些信念,将这些信念保存在外部存储器中,并基于信念不断改进后续个体。文献[16]将已获较优个体储存于外部存储器,以这些个体为标准来改进后续演化过程中产生的个体。文献[17]采用基于案例的推理方法从案例存储器中选择特征来改进后续个体。部分学者也采用学习演化模型来实现演化与学习之间的交互^[18-19]。文献[14]提出了一种学习型遗传框架来实现演化与学习之间的交互。现有研究表明:演化与学习之间存在交互的可能性;多种平台如版本空间^[20]、AQ-学习系统^[17]和基于案例的存储器^[17]及 Q-学习系统^[21-22]等都用来实现它们之间的交互;通过这种交互,智能优化的优化效率能够得到有效提高^[14]。

1 问题描述

1.1 输入条件

假设有向图 $G=(V, A)$ 包含 N_V 个节点与 N_A 条弧段, V 表示节点集, A 表示弧段集;弧段 $u \in A$ 存在空车成本 $d(u)$ (车辆通过弧段时产生的行驶成本)。从弧段 $u \in A$ 转向 $v \in A$ 的惩罚项为 $pen(u, v)$ (可转向时惩罚项为 0)。弧段集 $R \subseteq A$ 内任意弧段都必须被服务;对于弧段 $u \in R$, 其需求量及服务成本依次为 $q(u)$ 和 $s(u)$ 。仓库构建成本为 C_1 , 车辆购置成本为 C_2 。车辆限定容量及速度分别为 Q 和 S 。行驶距离与空车成本之间的转换系数是 α 。在单个服务周期中,假设最大服务时间为 T 。同时,在给定的期限内,假定相同任务被重复地执行 M 次。

1.2 输出条件

- (1) 仓库位置 $D = \{d_1, d_2, \dots, d_{(N_V)}\}$ 与数目 N_1, d_i 是布尔变量, $d_i = 1$ 说明节点 i 将被用作仓库。
- (2) 车辆分布 $DT = \{dt_1, dt_2, \dots, dt_{(N_V)}\}$ 与数目 N_2, dt_i 表示在第 i 个仓库内应配置的车辆数目。
- (3) 车辆的最优路径集 $L = \{l_1, \dots, l_j, \dots, l_{(N_2)}\}$ 和弧段服务标识 $f_j(\mu_{ij}), \mu_{ij}$ 表示路径 l_j 上的第 i 条弧段, $l_j = \{\mu_{1j}, \dots, \mu_{ij}, \dots, \mu_{(m_j)j}\}, m_j$ 表示路径 l_j 上的弧段数目, $f_j(\mu_{ij})$ 是布尔变量。当车辆遍历路径 l_j 时,若对弧段 μ_{ij} 实施了服务, $f_j(\mu_{ij}) = 1$;反之, $f_j(\mu_{ij}) = 0$ 。
- (4) 所有路径的开始节点序号,即车辆出发的仓库编号。

1.3 优化目标

优化目标是成本 F 最小化

$$F = CF + CR \tag{1}$$

式中, CF 代表固定成本:

$$CF = C_1 N_1 + C_2 N_2 \tag{2}$$

CR 代表运行成本:

$$CR = M \sum_{j=1}^{N_2} Cost(l_j) \tag{3}$$

$Cost(l_j)$ 代表路径 l_j 的总成本:

$$Cost(l_j) =$$

$$\sum_{i=1}^{m_j} s(\mu_{ij}) f_j(\mu_{ij}) + \sum_{i=1}^{m_j} d(\mu_{ij}) + \sum_{i=1}^{m_j-1} pen(\mu_{ij}, \mu_{(i+1)j}) \tag{4}$$

1.4 约束条件

每台车在执行完任务后必须回到其出发仓库;在单个服务周期中,任何车辆的行驶时间都不能超过最大服务时间 T ;在执行每次任务时,单台车完成的服务需求之和应小于等于其限定容量 Q ;从每个仓库派出的车辆数目不能超过该仓库储存的车辆数目;部分服务不被允许,每条必需服务路段在单个周期中必须并且只能接受一次服务。

1.5 双层 CARP 优化问题的求解框架

双层 CARP 优化问题主要涉及两方面:宏观配置优化问题和微观路径优化问题。前者主要确定仓库位置、数目及各仓库应被配置的车辆数目,后者主要确定各台车辆的最佳行驶路径,确保所有必需服务路段能够得到及时服务。双层 CARP 优化问题的求解框架如图 1 所示。

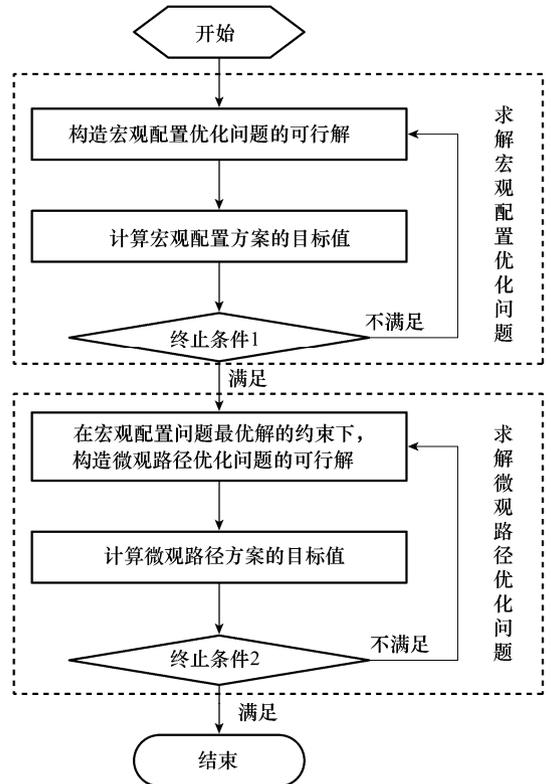


图 1 双层 CARP 优化问题的求解框架

在现有启发式方法中,PS(path-scanning)及 UH(Ulusoy’s heuristic)不但能有效地求解标准的 CARP 问题,且常用于求解各种扩展的 CARP 问题。鉴于此,针对双层 CARP 优化问题中的微观路径优化问题,笔者将这两种启发式方法改进后得到两种扩展启发式方法^[13];ERPS (extended random path-scanning)和 ERUH(extended random Ulusoy’s heuristic)。在求解微观路径优化问题时,ERPS 和 ERUH 在优化结果方面没有明显差异;在计算效率方面 ERPS 明显优于 ERUH。为了最大程度地减少宏观配置问题的求解时间,使用 ERPS 对某种配置方案中各个目标值进行求解。

本文采用多种方法求解双层 CARP 问题:借助 ERPS 方法求解宏观配置优化问题,采用多种不同方法来求解给定配置方案下的微观路径优化问题。因此,下文提及到“采用 X 方法(如 ERPS,ERUH 或演化学习型遗传算法(learnable genetic algorithm, LGA)求解”,即使用 ERPS 方法求解宏观配置问题,采用 X 方法求解微观路径问题。

2 LGA

LGA 把智能优化模型(遗传算法)与知识模型有效结合起来,以前者为基础并突出后者的作用,达到二者之间的优势互补,从而提高演化学习型遗传算法的优化绩效。

2.1 基本框架和运行机制

本文提到的知识大部分都是显性知识,即可明确表示的知识。这些知识都能表示成计算机语言并被存储,还可通过其他模型进行更新和应用。在本文中,演化学习型遗传算法被定义为:将遗传算法和知识模型有效结合起来的混合方法,其基本框架如图 2 所示。LGA 的运行机制如图 3 所示。遗传算法使用“邻域搜索”机制来搜索优化问题的可行空间;经过数次迭代后,遗传算法收敛到最适应环境的个体。知识模型从前期优化过程中抽取有用知识,再借其指导后续优化过程。在知识模型的辅助下,LGA 能更快地收敛于某个满意解或得到更高质量的解。

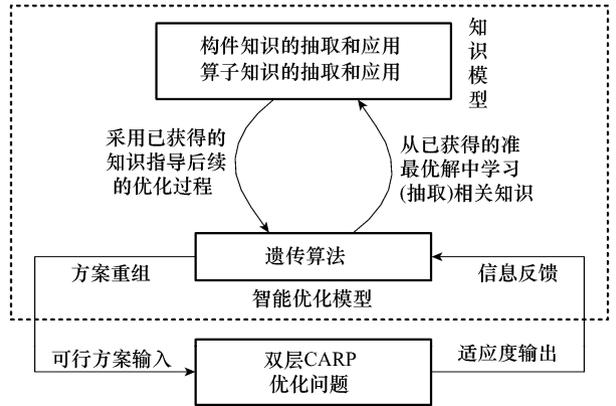


图 2 LGA 的基本框架

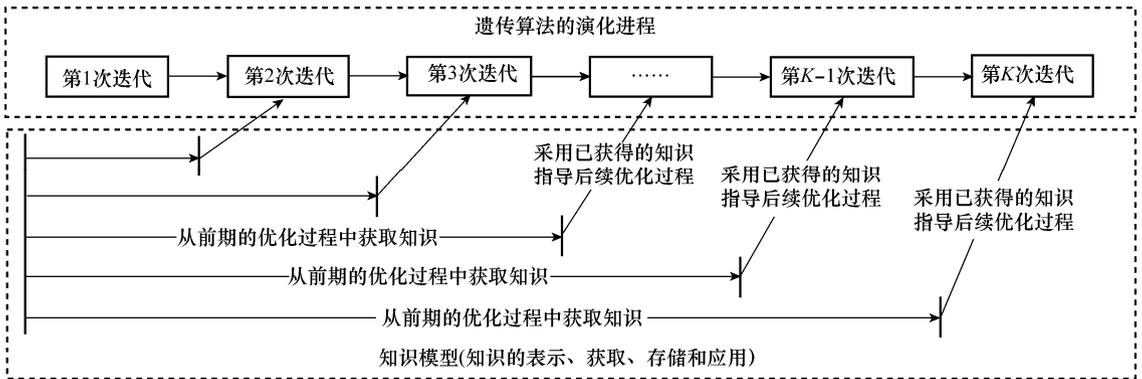


图 3 LGA 的运行机制

2.2 知识模型

本文将知识定义为:用来解决问题的一些有价值的结构化数据。本文讨论的大部分知识都是显性知识,它们既可被明确表达出来,还可通过多种编码方式如语言、文字和书籍及数据库等传播。文中所使用的显性知识可表示成计算机语言并被存储,还可通过其他模型进行更新和应用。

知识模型定义为:用来实现知识表达、获取、存储及应用的技术及方法的集合体。本文中的知识大都表示成一维或多维数组;这些数组具有特定含义,每个元素具有明确意义。在 LGA 中,知识获取主要是指从演化过程中挖掘(学习)有用知识。本文仅采用统计方式完成对不同类型知识的挖掘。

由于知识被表示成一维或多维数组,知识存储就相对简单。在相关程序中,只要使用全局变量对数组进行定义,无论何时任何模型都能够访问或更新这些数组。在 LGA 中,知识应用就是如何采用知识来指导后续优化过程。

2.3 知识形式及应用方式

2.3.1 构件知识

构件是指构成优化问题可行方案的部件,构件知识是指有助于构建优化问题可行方案的特征信息。构件顺序知识(component priority knowledge, CPK)体现了构件之间的先后服务顺序。本文将构件顺序知识矩阵的列宽度设置为固定数值。其优点在于:既可有效节省存储空间,还可大

幅度减少相关计算量。在本文中,构件顺序知识主要是从已获得的准最优解中抽取出来的。

本文采用大小为 $N_R \times Dim$ 的矩阵 **CPK** 表示弧段顺序知识; N_R 是必需服务弧段的数目, Dim 是矩阵 **CPK** 的列宽度。表 1 给出了构件顺序知识的一个简单实例。在该表中,每行前 3 列(0.5Dim)代表距该行所示弧段最近的 3 条弧段;其后 3 列指给定弧段在已获准最优解中出现的次数。表 1 中,第 2 行第 1 列中的 1 指弧段 1 距离弧段 2 最近;第 2 行第 6 列的 13 指弧段序列(2,3)在已获准最优解中共出现 13 次;弧段序列(2,3)表示弧段 2 先于弧段 3 执行。实验结果表明,将 **CPK** 矩阵的列宽度设置为 20 比较合理;可采用前 5%~20%的个体来抽取构件顺序知识。

假设方案 C 被用来更新 **CPK** 矩阵,且方案 C 只含有一条路径 T_1 ,相应的弧段服务顺序为 $3 \rightarrow 4 \rightarrow 2 \rightarrow 1$ 。将其中含有的 3 个序列(3,4)、(4,2)和(2,1)在已获得的准最优解中出现的次数各自增加 1,进行更新,更新后的 **CPK** 矩阵如表 2 所示。

表 1 CPK 知识矩阵的简单实例

弧段	第 1 列	第 2 列	第 3 列	第 4 列	第 5 列	第 6 列
1	2	3	4	12	8	10
2	1	4	3	6	11	13
3	1	4	2	9	10	11
4	3	2	1	5	9	16

表 2 更新后的 CPK 知识矩阵

弧段	第 1 列	第 2 列	第 3 列	第 4 列	第 5 列	第 6 列
1	2	3	4	12	8	10
2	1	4	3	7	11	13
3	1	4	2	9	11	11
4	3	2	1	5	10	16

构件顺序知识的应用模式如下所述。以表 2 为例,假设当前个体为 $4 \rightarrow 3 \rightarrow 2 \rightarrow 1$,从表中得知弧段序列(4,3),(3,2)和(2,1)出现在已获得的准最优解中的次数分别是 5 次、11 次及 7 次,这些弧段序列中出现断点的概率为 54%、8%和 38%,计算方式如图 4 所示。

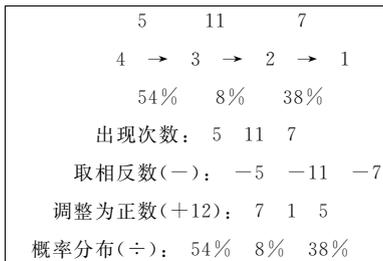


图 4 断点概率的计算实例

2.3.2 算子知识

通常各种算子都有一定的适用范围:某算子对某些实

例效果相对明显,而在其他实例中却表现较差;通常很难找到一种能求解各种实例的万能算子。鉴于此,本文同时使用多种算子来提高遗传算法的优化绩效,并试图挖掘出对当前实例最有效的算子。

假设采用某算子进行某种操作,操作之前的个体集合为 C_B ,操作之后的个体集合为 C_A ,如果 C_A 中最优个体比 C_B 中最优个体优秀,则认为该算子的本次操作是成功的。算子优化绩效可以这样理解:某算子在求解过程中取得的成功求解次数。

表 3 给出了算子知识抽取和应用实例。假设某遗传算法共使用 3 种不同算子来执行相关变异操作。若第 k 种算子成功地执行了当前变异操作,它的优化绩效 $N(k)$ 就被增加 1。那么下次变异前,将根据式(5)来推算使用每种算子的概率:

$$P(i) = \frac{N(i)}{\sum_{i=1}^3 N(i)} \tag{5}$$

式中, $P(i)$ 指第 i 种算子的被选概率。如表 3 所示,初始化操作时,各种算子优化绩效的初始值都为 1,依照式(5),可得到它们的被选概率都为 33%。若第 1 次变异过程中使用了第 2 种算子,且该次操作是成功的,那么该变异算子的优化绩效就被更新为 2,各算子的被选概率依次被更新为 25%、50%和 25%。算子知识的使用模式总结如下:多种算子被同时用于执行遗传算法,从优化过程中抽取它们的优化绩效,优先选择那些高绩效算子来执行后续优化操作。这种模式适用于各种智能优化方法和各种优化问题。

表 3 算子知识的抽取与应用

	第 1 种算子		第 2 种算子		第 3 种算子	
	优化绩效	被选概率	优化绩效	被选概率	优化绩效	被选概率
初始化操作	1	33%	1	33%	1	33%
第 1 次变异	1	25%	2	50%	1	25%
第 2 次变异	2	40%	2	40%	1	20%
第 3 次变异	2	40%	2	40%	1	20%
...

2.4 优化流程

图 5 展示了 LGA 的基本优化流程。该算法的特点主要体现在:

(1) 基于构件顺序知识为每次交叉及变异操作选择合适的断点位置。如果某弧段序列频繁出现在已获准最优解中,则以较小概率在其间选择断点位置;否则,以较大概率在其间选择断点位置。

(2) 算子知识的抽取与应用。基于操作算子的成功率来动态选择下一步操作使用的操作算子,既保证了尽可能使用高成功率的算子,又确保了算子选择的随机性与多样性。

(3) 启发式方法的有效融入。使用 ERPS 与 ERUH 来生成初始种群,有效改善了初始种群的个体质量。采用 2-Opt 实施变异操作,增加了变异操作的成功概率。

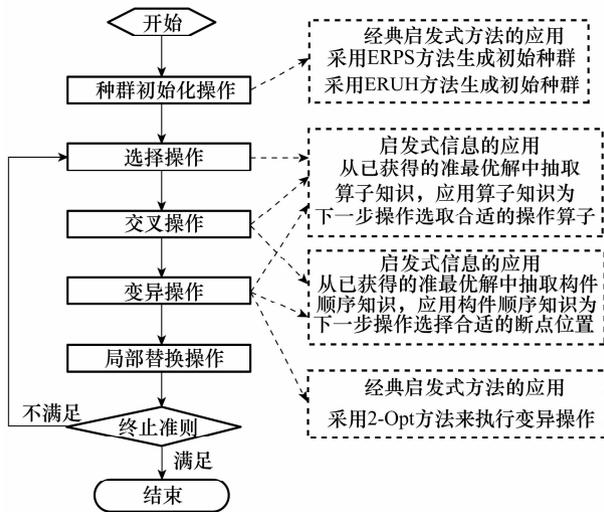


图 5 LGA 的优化流程

3 实验结果及分析

本文构建了 24 个测试实例来充分验证 ERPS、ERUH 及 LGA 的优化绩效。这些实例的最优值都是未知的,故本文借助最优下限估计方法对各实例的最优下限进行估值,

并将这些最优下限值视为最优值,以便估算每种方法的误差。

本文使用 Visual C++ 语言来实现 ERPS、ERUH 及 LGA 方法。求解双层 CARP 优化问题的 LGA 的最佳参数组合见表 4。在本文中,各实例被不同方法求解 50 次,将所有求解结果的平均值视为最终实验结果。

表 4 LGA 的参数设置

符号	含义	取值
P_S	种群规模(所含染色体的数目)	50
N_I	获得一个全新个体所需的最大尝试次数	100
R_M	主搜索与重搜索中的变异概率	0.05
N_L	单次变异的重复执行次数	5
N_P^M	主搜索阶段中可行方案的最大评价次数	5 000
N_R	重搜索的最大执行次数	5
N_S	局部替换中需要被替换的个体数目	10
N_F^R	每个重搜索阶段可行方案的最大评价次数	2 000

为了客观评价 ERPS、ERUH 和 LGA 这 3 种方法的优化绩效,它们的终止准则被统一设为最大计算时间。测试实例最长计算时间预设为 2 000 s。采用 ERPS、ERUH 和 LGA 求解 24 个测试实例的平均误差如图 6 所示(横坐标的 C1~C24 代表 24 个不同测试实例,纵坐标表示采用不同方法求解各个实例的计算误差)。从图 6 的实验结果中不难看出,在优化绩效方面,LGA 明显优于 ERPS 和 ERUH。

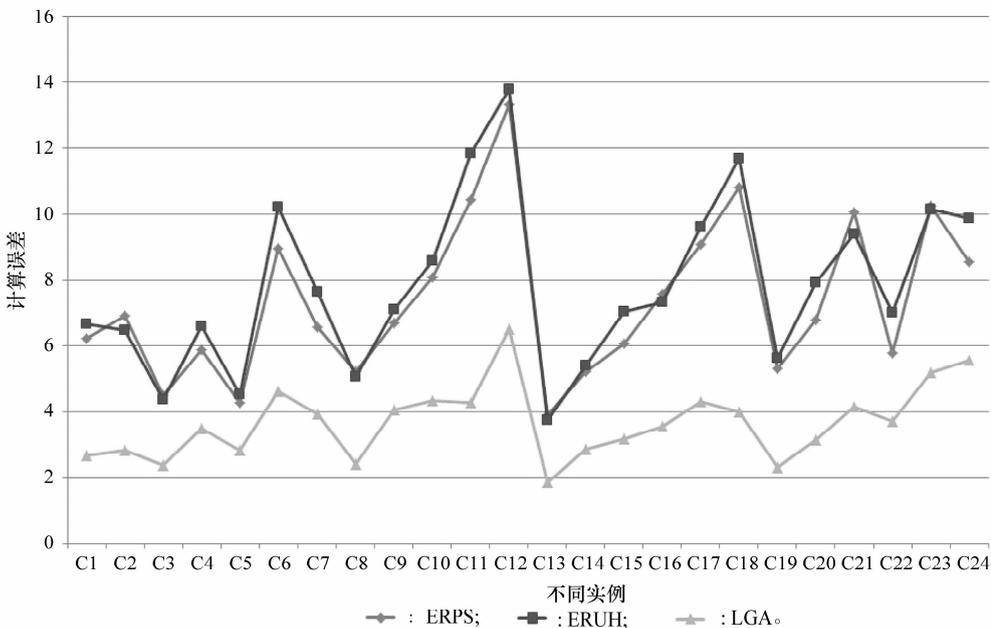


图 6 采用 ERPS、ERUH 和 LGA 求解 24 个测试实例的平均计算误差

4 结束语

针对双层 CARP 优化问题,构建了演化学习型遗传算

法的基本框架。该框架将遗传算法和知识模型有效结合起来,极大提高了演化学习型遗传算法的优化绩效,为现有优化方法的改进提供了一种有益借鉴。同时,还提出了构件

知识和算子知识等知识形式,为演化学习型遗传算法嵌入知识奠定了重要基础。实验结果表明,LGA 在优化性能方面优于其他几种方法。

后续研究方向:①扩展知识种类,可将专家对实际问题的经验知识抽象出来,应用经验知识来有效指导优化过程;②采用新的知识挖掘方式,可采用机器学习或数据挖掘等先进的知识挖掘方式从优化过程中发现有知识。

参考文献:

- [1] Aráoz J, Fernández E, Zoltan C. Privatized rural postman problems[J]. *Computers & Operations Research*, 2006, 33(12): 3432-3449.
- [2] Bektas T, Elmastas S. Solving school bus routing problems through integer programming[J]. *Journal of the Operational Research Society*, 2006, 58(12): 1599-1604.
- [3] Dijkgraaf E, Gradus R H J M. Fair competition in the refuse collection market [J]. *Applied Economics Letters*, 2007, 14(10): 701-704.
- [4] Handa H, Chapman L, Yao X. Robust route optimization for gritting / salting trucks: a CERCIA experience[J]. *IEEE Computational Intelligence Magazine*, 2006, 1(1): 6-9.
- [5] Prins C, Prodhon C, Calvo R W. A memetic algorithm with population management (MA vertical bar PM) for the capacitated location-routing problem [J]. *Lecture Notes in Computer Science*, 2006, 3906(1): 183-194.
- [6] Gunnarsson H, Ronnqvist M, Carlsson D. A combined terminal location and ship routing problem[J]. *Journal of the Operational Research Society*, 2006, 57(8): 928-938.
- [7] Lin C K Y, Kwok R C W. Multi-objective metaheuristics for a location-routing problem with multiple use of vehicles on real data and simulated data[J]. *European Journal of Operational Research*, 2006, 175(3): 1833-1849.
- [8] Perrier N, Langevin A, Campbell J F. A survey of models and algorithms for winter road maintenance, part III: vehicle routing and depot location for spreading[J]. *Computers and Operations Research*, 2007, 34(1): 211-257.
- [9] 张潜, 高立群, 刘雪梅, 等. 定位-运输路线安排问题的两阶段启发式算法[J]. *控制与决策*, 2004, 6(7): 773-777. (Zhang Q, Gao L Q, Liu X M, et al. A two-phase heuristic approach to the location routing problem[J]. *Control and Decision*, 2004, 6(7): 773-777.)
- [10] 曾庆成, 杨忠振, 蒋永雷. 配送中心选址与车辆路径一体优化模型与算法[J]. *武汉理工大学学报(交通科学与工程版)*, 2009, 33(2): 267-270. (Zeng Q C, Yang Z Z, Jiang Y L. Optimization model and algorithm of coordinated distribution center location and vehicle routing[J]. *Journal of Wuhan University of Technology (Transportation Science & Engineering)*, 2009, 33(2): 267-270.)
- [11] Xing L N, Chen Y W, Yang K W. Double layer ant colony optimization for multi-objective flexible job shop scheduling problems[J]. *New Generation Computing*, 2008, 26(4): 313-327.
- [12] Xing L N, Chen Y W, Yang K W. A hybrid approach combining an improved genetic algorithm and optimization strategies for the asymmetric traveling salesman problem[J]. *Engineering Applications of Artificial Intelligence*, 2008, 21(8): 1370-1380.
- [13] Xing L N, Rohlfschagen P, Chen Y W, et al. An evolutionary approach to the multi-depot capacitated arc routing problem[J]. *IEEE Trans. on Evolutionary Computation*, 2010, 14(3): 356-374.
- [14] Ho N B, Tay J C, Lai E M K. An effective architecture for learning and evolving flexible job-shop schedules[J]. *European Journal of Operational Research*, 2007, 179(2): 316-333.
- [15] Chung C J, Reynolds R G. A testbed for solving optimization problems using cultural algorithm[C]// *Proc. of the 5th Annual Conference on Evolutionary Programming*, 1996: 225-236.
- [16] Branke J. Memory-enhanced evolutionary algorithms for dynamic optimization problems[C]// *Proc. of the Congress on Evolutionary Computation*, 1999: 1875-1882.
- [17] Louis S J, McDonnell J. Learning with case-injected genetic algorithms[J]. *IEEE Trans. on Evolutionary Computation*, 2004, 8(4): 316-328.
- [18] Michalski R S. Learnable evolution model: evolution process guided by machine learning[J]. *Machine Learning*, 2000, 38(1): 9-40.
- [19] Wojtusiak J. The LEM3 system for multitype evolutionary optimization[J]. *Computing and Informatics*, 2009, 28(2): 225-236.
- [20] Reynolds R G. An introduction to cultural algorithms[C]// *Proc. of the 3rd Annual Conference on Evolutionary Programming*, 1994: 131-139.
- [21] Kamall K, Jiang L J, Yen J, et al. Using Q-learning and genetic algorithms to improve the efficiency of weight adjustments for optimal control and design problems[J]. *Journal of Computing and Information Science in Engineering*, 2007, 7(4): 302-308.
- [22] Juang C F, Lu C M. Ant colony optimization incorporated with fuzzy Q-learning for reinforcement fuzzy control[J]. *IEEE Trans. on Systems, Man, and Cybernetics Part A: Systems and Humans*, 2009, 39(3): 597-608.