

Генетический алгоритм для задачи маршрутизации мультисалонных транспортных средств со стохастическими запросами

J. Mendoza, B. Castanier, C. Gueret, A. L. Medaglia, N. Velasco

Автор перевода: Александрова О.А.

Источник: <http://webhost.ua.ac.be/eume/workshops/eume08/papers/paper34.pdf>

ВВЕДЕНИЕ

Классическая задача маршрутизации транспортного средства (ЗМТ) обычно, предполагает совершенное знание параметров задачи, таких как запросы клиентов, время в пути и обслуживания. Однако, в реальных мировых планах, очень часто это - сильное предположение, и стохастическая природа таких параметров должна быть обращена к специальным целенаправленным алгоритмам [2]. Чтобы заняться этим аспектом, большое исследовательское усилие было посвящено изучению так называемой стохастической ЗМТ (СЗМТ).

Одна из наиболее исследованных СЗМТ - ЗМТ со стохастическими запросами (ЗМТСС) [4]. Задача состоит в нахождении оптимального набора допустимых маршрутов для обслуживания ряда клиентов, спрос которых - случайная переменная известного распределения. ЗМТСС признана тяжелой в вычислительном отношении [4], и большие примеры могут быть обработаны только эвристическими подходами [2]. Обобщение ЗМТСС – ЗМТ с мультисалонами со стохастическими запросами (ЗМТ-МОСС), задача, где клиенты имеют стохастические запросы на несколько продуктов, но из-за несовместимости ограничений, они должны быть транспортированы в отдельных салонах.

Практически, ЗМТ-МССС естественно возникает в молочной промышленности. Ежедневно, молоко от различных поколений молочного рогатого скота должно быть собрано у большого количества ферм, расположенных в пригороде. Так как каждый тип молока - компонент для различных продуктов, транспортные средства со множественными салонами препятствуют тому, чтобы различные типы молока смешались. Неопределенность спросов исходит из случайных факторов, которые воздействуют на производительность рогатого скота и из лучшей экономической стратегии производителей.

Интерес в решении реальной мировой ЗМТ с мультисалонами (МС-VRPS) увеличился в последние годы. Avella и др. [1] решили задачу распределения, где различные типы топлива поставляются в танкерах со мультисалонами. Orpen и Lokkentangen [7] имели целью задачу транспортировки домашнего скота, когда различные животные транспортируются от ранчо до скотобоен в независимых салонах, чтобы избежать напряжения, которое может привести к низкому качеству мяса. Позже, El Fallahi и др. [3] занялись вариантом МС-ЗМТ, где каждый продукт может быть поставлен клиентам различным транспортным средством, хотя полная поставка отдельного продукта должна быть выполнена только одним транспортным средством.

Несмотря на практическую применимость ЗМТ-МССС, единственная полезная рекомендация по задаче - набор конструктивной эвристики, предложенной в [6]. Чтобы заполнить эту пустоту, эта статья представляет генетический алгоритм (ГА), спроектированный для решения ЗМТ-МССС. Алгоритм соединяет компоненты, оказавшиеся эффективными для детерминированной ЗМТ с двумя различными стратегиями оценки, разработанными чтобы

вести поиск, рассматривая стохастическую природу задачи. Чтобы проанализировать производительность обеих стратегий, алгоритм был проверен на большом наборе примеров.

1 ПОСТАНОВКА ЗАДАЧИ

Формально, ЗМТ-МССС может быть определена на законченном и неориентированном графе $G = (N; E)$, где $N = \{0, \dots, n\}$ является набором узлов и E набор ребер. Узлы $i = 1 \dots n$ представляют клиентов, и узел $i = 0$ представляет склад. Расстояние d_e связано с ребром $e = (i, j) = (j, i) \in E$, и это представляет стоимость путешествия между узлами i и j . Предполагается, что треугольное неравенство удовлетворено (то есть, $d_{(i,j)} + d_{(j,k)} \geq d_{(i,k)}$). Существует набор $P = \{1, \dots, p, \dots, m\}$ продуктов, которые должны быть транспортированы в независимых салонах. Следовательно, у каждого транспортного средства есть специализированный салон установленной грузоподъемности Q_p для каждого продукта. Все транспортные средства идентичны и размер парка неограниченный. На продукт p клиент i имеет независимый случайный спрос $\xi_{i,p}$ согласно нормальному распределению $N(\mu_{i,p}, \sigma_{i,p})$. Фактические значения реализации известны только по прибытию в местоположение клиента, и вся реализация является неотрицательной и меньше грузоподъемности соответствующего салона Q_p . Наконец, каждый узел должен быть посещен точно одним маршрутом, и полная длина каждого маршрута l_r не может превысить максимальное расстояние L .

ЗМТ-МССС может быть сформулирована как двухступенчатая модель программирования. На первой стадии выбирается набор R априорных маршрутов. Каждый маршрут $r \in R$ является последовательностью узлов $r = (0, i_1, \dots, i_k, \dots, i_{n_r}, 0)$, где $i_k \in N \setminus \{0\}$ и n_r является числом узлов клиентов в маршруте r . На второй стадии выполняется каждый запланированный маршрут, пока не случается «провал» маршрута. «Провал» маршрута, как говорят, происходит всякий раз, когда грузоподъемность одного салона превышена, посещая клиента. Терпя неудачу, салон загружается согласно его грузоподъемности, и имеет место *регрессный иск*. Регрессный иск определен как возврат на склад, чтобы разгрузить салоны, сопровождаемый поездкой назад в местоположение клиента, чтобы завершить обслуживание. После завершения обслуживания маршрут продолжается от того пункта, на котором был первоначально запланирован. Задача состоит в том, чтобы тогда определить набор маршрутов R , который минимизирует полную ожидаемую стоимость $E[C]$ данную как:

$$E[C] = \sum_{r \in R} l_r + \sum_{r \in R} E[G_r(R, \xi)] \quad (1)$$

где первое слагаемое - запланированная длина маршрутов для R и $E[G_r(R, \xi)]$ является ожидаемой длиной возвратных поездок, вызванных провалами маршрута.

2 ГЕНЕТИЧЕСКИЙ АЛГОРИТМ

2.1 Общая структура

Предложенный ГА кодирует решения ЗМТ-МССС в генотип мультиперестановки, известный как генетическое представление транспортного средства (ГПТ) [8]. Определенно, каждая перестановка содержит упорядоченный набор клиентов, представляющих маршрут. Начинаясь с начальной совокупности $P(0)$, составленный из P особей, алгоритм следует эволюционному процессу из T генераций. На каждой генерации t , применяются операторы

кроссинговера и мутации с вероятностью p_c и p_m для каждой особи популяции $P(t)$. Потомство, произведенное генетическими операторами, формирует новую дочернюю популяцию $C(t) = C_c(t) \cup C_m(t)$. И $C(t)$ и $P(t)$ потом объединяются в расширенную популяцию $E(t)$, откуда выбираются лучшие P особей, чтобы стать частью новой популяции $P(t+1)$.

Чтобы ускорить алгоритмическую сходимость, начальная популяция генерируется на основе стохастической эвристики ближайшего соседа (СБС) [6]. Понятие *самого близкого соседа* в эвристике СБС базируется не только на расстоянии к последнему добавленному узлу, но также и на приращении стоимости регресса результирующего тура. Фенотипичные клоны устраняются и заменяются в соответствии со случайно сгенерированными решениями, приводя к разнообразной начальной популяции с решениями хорошего качества.

Оператор кроссинговера основан на кроссинговере ГПТ, предложенном Pereira и др. [8], в котором потомок наследовал все признаки (маршруты) от одного родителя и маленькой части генетического материала (подмаршрут) от другого родителя (донор). Подмаршрут случайно выбирается у донора и вставляется в потомка за самую низкую стоимость вставки. Чтобы ускорить процедуру, стоимость вставки вычисляется, принимая во внимание только детерминированную часть целевой функции (1). Повторяющиеся узлы устраняются у потомка, сохраняя те во вставляемом подмаршруте.

Оператор мутации, известный как *инверсная мутация*, реверсирует порядок посещения всех узлов в случайно выбранном подмаршруте. Так как ожидаемая стоимость регресса маршрута не симметрична в обоих направлениях [4], инверсная мутация разносторонне развивает поиск не только в отношении структуры маршрута, но также и в отношении направления поездки.

2.2 Восстановление и оценка фитнес-функции

Генетические операторы могут генерировать недопустимые решения в отношении ограничений расстояния. Чтобы исправить особей, ГА использует процедуру, основанную на механизме разбиения, предложенном Prins [9]. Разбиение требует, чтобы генотип ГПТ был преобразован в хромосому без разделителей маршрута; то есть, отдельная перестановка узлов (см. верх рисунка 1). Из хромосомы строится вспомогательный граф G' и используется, чтобы найти оптимальное разделение перестановкой в допустимые маршруты. Направленный граф $G' = (N', A)$ составляется из набора узлов $N = \{0, I_1, \dots, I_k, \dots, I_n\}$ и набора дуг A . Узлы $i_1, \dots, i_n \in N \setminus \{0\}$ и узел 0 являются вспомогательными узлами. Дуга $(i_k, i_{k+nr}) \in A$ представляет допустимый маршрут r с длиной l_r , начинающийся и заканчивающийся на складе и пересекающий последовательности узлов клиентов от i_{k+1} до i_{k+nr} . Процедура разбиения состоит в нахождении набора дуг (то есть, маршрутов) вдоль самого короткого пути, соединяющего 0 и i_n в G' . Рисунок 1 иллюстрирует процедуру разбиения. ГПТ особь, содержащая недопустимый маршрут ($L = 60$), преобразовывается в отдельную хромосому, сопровождаемую разделением на два допустимых маршрута используя разбиение.

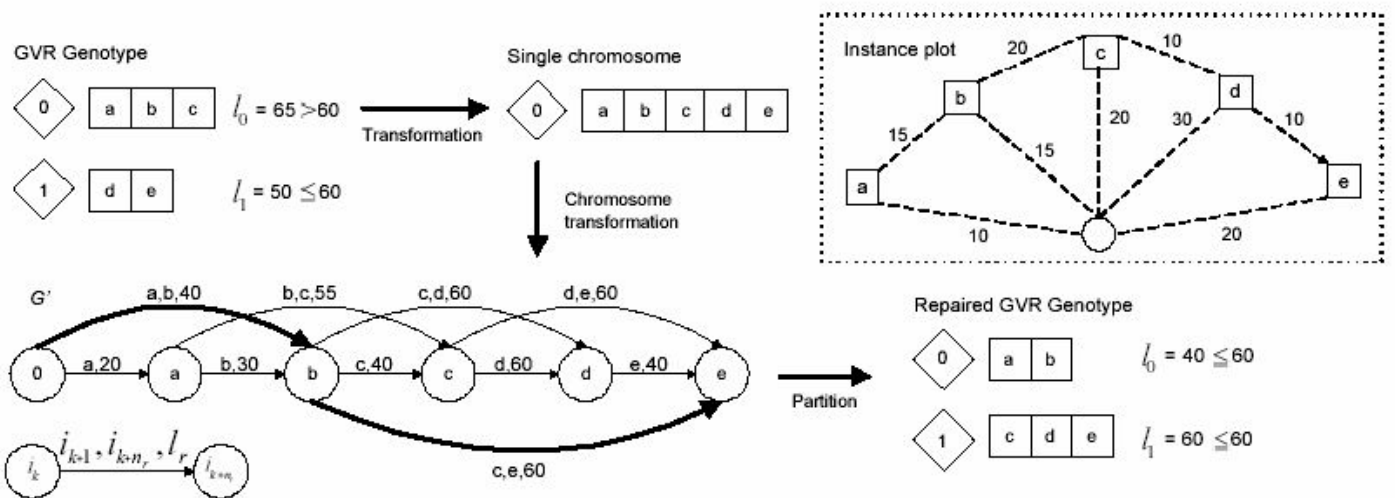


Рисунок 1 - Процедура разбиения для исправления особи

По мультисалонному сценарию, оценивание точного значения $p(z(i_k) = 1)$ - сложный и трудоёмкий процесс, для чего ГА использует аппроксимацию, предложенную в [5]:

$$p(z(i_k) = 1) = \sum_{j=0}^{k-1} \left[\prod_{p=1}^m F(i_{j+1}, i_{k-1}, p) - \prod_{p=1}^m F(i_{j+1}, i_k, p) \right] \times p(z(i_j) = 1) \quad (3)$$

где $F(i_{j+1}, i_{k-1}, p)$ является совокупной вероятностью, что полный спрос на продукт p , собранный между узлами в позиции $j + 1$ и $k - 1$ в маршруте r , не превышает грузоподъемности салона Qp .

Чтобы оценить фитнес-значение особи, предложены две стратегии. Первая стратегия (разбиение) состоит из применения процедуры разбиения, сопровождаемой оценкой целевой функции исправленного решения. С другой стороны, вторая стратегия (s-разбиение) состоит из стохастического варианта процедуры разбиения, которая одновременно исправляет и оценивает особь. Следуя тому же самому принципу её детерминированной копии s-разбиение делит единственную хромосому на допустимые маршруты, находя самый короткий путь в вспомогательном графе G' . Однако, вес каждой дуги $(i_k, i_{k+nr}) \in$ определяется как $lr + E[G_r(R, \xi)]$ вместо lr . Рисунок 2 иллюстрирует процедуру s-разбиения на примере, показанном на рисунке 1.




Рисунок 2 - Процедура s-разбиения для исправления особи и оценки

3 ВЫЧИСЛИТЕЛЬНЫЕ ЭКСПЕРИМЕНТЫ

После хорошей настройки набора параметров (P , T , p_c , and p_m) для каждой стратегии оценки, ГА был проверен на большом наборе случайно сгенерированных примеров. Задачи с 50, 100, и 150 узлами клиентов и 3 продуктами были сгенерированы со следующими характеристиками. Для каждого спроса значение $\mu_{i,p}$ было случайно сгенерировано в пределах [20 100]; тогда как значение $\sigma_{i,p}$ было установлено случайным выбором коэффициента вариации $\sigma_{i,p}/\mu_{i,p} \in \{0.1\ 0.2\ 0.3\}$. Чтобы установить грузоподъемность салонов, коэффициент плотности $(\sum_{i \in N \setminus \{0\}} \xi_{i,p})/Q_p$ был установлен в двух различных значениях, а именно, 5 и 15. Тридцать примеров были сгенерированы для каждой комбинации количества клиентов и отношения плотности. Для каждой из 180 ($3 \times 2 \times 30$) задач, максимальное расстояние L было случайно установлено как 3 или 4 расстояния от самого дальнего узла до склада.

Чтобы сравнить оценочные стратегии, были вычислены четыре различных показателя: во-первых, среднее усовершенствование относительно лучшего решения в $P(0)$ (после разбиения или s -разбиения); во-вторых, средний промежуток относительно лучшего решения, найденного ГА; в-третьих, число лучших найденных решений; и в-четвертых, процессорное время. Результаты приведены в таблице 1.

Таблица 1 Сравнение оценочных стратегий разбиения и s -разбиения для ЗМТ-МССС

Тип примера		Средн усоверш-е		Средн промежуток		Кол-во лучших решений		Время выполнения (сек)	
клиент	плотн	разбиение	s -разбиение	разбиение	s -разбиение	разбиение	s -разбиение	разбиение	s -разбиение
50	5	14.17%	12.11%	1.75%	0.52%	10	20	89	322
50	15	12.45%	11.22%	0.57%	0.78%	19	11	98	310
100	5	19.17%	17.84%	1.43%	0.63%	12	18	223	1279
100	15	13.40%	12.39%	1.77%	0.54%	11	19	256	1266
150	5	20.11%	18.58%	1.25%	1.02%	12	18	438	3310
150	15	14.96%	12.32%	0.60%	0.74%	15	15	408	2329
Ср/Общее		15.76%	14.08%	1.23%	0.70%	79	101	-	-

Результаты показывают, что обе оценочные стратегии ведут ГА к среднему усовершенствованию 14.92 % над лучшим решением в начальной популяции. Более детальный просмотр таблицы 1 показывает, что это усовершенствование больше на примерах с низкими коэффициентами плотности. Вероятное объяснение, то, что на таких примерах ожидается меньше провалов. Следовательно, там больше альтернатив маршрутов, которые избегают провалов, или это возможно распределить их в удобных позициях. Итерационный процесс ГА использует это условие лучше, чем однопроходный СБС, генерируя существенные усовершенствования стоимости регресса. С другой стороны, результаты показывают, что усовершенствование менее существенно на примерах с низким числом клиентов. Как и в других вариантах ЗМТ [3] вероятно, что в ЗМТ-МССС конструктивная эвристика, как СБС, очень конкурентоспособна для маленьких примеров, позволяя к маленьким краям ГА для улучшения. Сосредотачиваясь на сравнении между стратегиями оценки, дальнейший анализ показывает немного лучшую производительность s -разбиения над разбиением. Из этих 180 примеров s -разбиение показало лучшее решение в 101 против 79 для разбиения. Отметим, однако, что в отношении точности решения это неравенство могло бы быть не существенным, так как различие в среднем промежутке относительно лучшего решения составляет меньше чем 1 %

(1.23 %-0.70 %). Напротив, в отношении процессорного времени результаты ясно показывают, что разбиение превосходит по быстродействию s-разбиение. Следовательно, если предоставить обмен между точностью и эффективностью, разбиение, кажется, лучше для полной производительности ГА.

ЗАКЛЮЧЕНИЕ

Эта статья представляет ГА для ЗМТ-МССС, который включает методики, оказавшиеся эффективными для детерминированной ЗМТ с двумя различными стратегиями оценки фитнес-функции, которые учитывают стохастическую природу задачи. Эксперименты, проведенные на наборе случайных примеров, показывают, что генетические итерации ответственны за усовершенствования 14.92 % (в среднем) относительно лучшего решения в начальной популяции, найденной мультиначальной конструктивной эвристикой. Время выполнения изменяется от 1.48 до 38.81 минут в зависимости от размера примера и выбранной стратегии оценки. Исследование в настоящее время включает реализацию процедур локального поиска и методик управления популяцией, специально адаптированных, чтобы усилить предложенный ГА.

ЛИТЕРАТУРА

1. P. Avella, M. Boccia, and A. Sforza (2004): “Solving a fuel delivery problem by heuristic and exact approaches”. In: *European Journal of Operational Research* 152, 170–179.
2. L. Bianchi, M. Birattari, M. Chiarandini, M. Manfrin, M. Mastrolilli, L. Paquete, O. Rossi-Doria, and T. Schiavinotto (2006): “Hybrid metaheuristics for the vehicle routing problem with stochastic demands”. In: *Journal of Mathematical Modelling and Algorithms* 5, 91–110.
3. A. El Fallahi, C. Prins, and R. Wolfler Calvo (2008): “A memetic algorithm and a tabu search for the multi-compartment vehicle routing problem”. In: *Computers and Operations Research* 35, 1725–1741.
4. M. Gendreau, G. Laporte, and R. S´eguin (1996): “Stochastic vehicle routing”. In: *European Journal of Operational Research* 88, 3–12.
5. J. E. Mendoza, B. Castanier, C. Gu´eret, A. L. Medaglia, and N. Velasco (2008): “Approximating the expected cost of recourse on a multi-compartment vehicle routing problem with stochastic demands”. Tech. Rep. 08/03/AUTO, Ecole des Mines de Nantes, France.
6. J. E. Mendoza, C. Gu´eret, B. Castanier, A. L. Medaglia, and N. Velasco (2008): “Constructions heuristics for the multi-compartment vehicle routing problem with stochastic demands”. In *XIV Latin Ibero-American Congress on Operations Research (CLAIO)*.
7. J. Oppen and A. Løkketangen (2008): “The livestock collection problem”. In *21st European Conference on Operational Research*.

8. F. B. Pereira, J. Tavares, P. Machado, and E. Costa (2002): “GVR: a new genetic representation for the vehicle routing problem”. In: Proceedings of AICS 2002 - 13th Irish Conference on Artificial Intelligence and Cognitive Science.
9. C. Prins (2004): “A simple and effective evolutionary algorithm for the vehicle routing problem”. In: Computers and Operations Research 31, 1985–2002.