

СРАВНИТЕЛЬНЫЙ АНАЛИЗ РАБОТЫ АДАПТИВНОГО ГЕНЕТИЧЕСКОГО АЛГОРИТМА ПРИ РЕШЕНИИ ЗАДАЧ КОМБИНАТОРНОЙ ОПТИМИЗАЦИИ

Семенкина О.Е.,

научный руководитель д-р физ.-мат. наук Попов Е. А.

Сибирский государственный аэрокосмический университет имени М.Ф. Решетнева

Одной из актуальных современных практических задач является создание систем поддержки принятия решений. В задачах принятия решений одной из наиболее часто встречающихся проблем является выбор между несколькими существующими вариантами действий. Формализованная постановка такой проблемы представляет собой задачу оптимизации. В связи с этим, оптимизация, в том числе и комбинаторная, является актуальной областью современной науки. Встречающиеся на практике задачи оптимизации достаточно сложны и классические методы, такие как линейное программирование, не справляются с их решением. Поэтому в настоящее время для решения сложных задач оптимизации широко применяются стохастические многоагентные алгоритмы, в том числе бионические алгоритмы. Поэтому можно сказать, что исследование таких алгоритмов является актуальной научной проблемой. В данной статье рассматривается классический метод решения задачи коммивояжера - эвристика Лина-Кернигана, а также некоторые бионические алгоритмы, такие как генетический алгоритм (Genetic Algorithm (GA или ГА)), адаптивный ГА (adaptive GA), алгоритм муравьиных колоний (Ant Colony Optimization (ACO)) и алгоритм умных капель (Intelligent Water Drops (IWDs)).

В данной работе рассматривается одна из задач комбинаторной оптимизации, называемая задачей коммивояжера (Travelling salesman problem (TSP)). Она имеет большое число практических применений, в том числе задача маршрутизации, задача составления плана для одного станка, задача нарезки рулонного материала, задача о сверлильном станке и т.д. Более того, задачами на перестановках являются также задачи составления расписания с ограничениями или задачи игрового типа поиска оптимальной стратегии.

Задача коммивояжера относится к классу NP-полных задач и формулируется следующим образом: *Пусть имеется заданное множество из n городов. Требуется найти замкнутый обход минимальной длины, при условии, что каждый город должен быть посещен единственный раз.*

Классическим методом решения задач оптимизации является локальный спуск, в том числе алгоритм 3-замены [1] (с мультистартом - эвристика Лина-Кернигана [2]). Суть алгоритма состоит в том, что относительно текущего решения, представленного циклическим графом f со значением целевой функции $c(f)$, рассматривается его окрестность, то есть множество циклических графов, которые можно получить из f удалением не более $3x$ ребер и заменой другими $3m_x$ ребрами. Если в этом множестве существует граф g , целевая функция которого $c(g) < c(f)$, то g назначается текущим решением. Процедура повторяется до тех пор, пока текущее решение не перестанет изменяться.

Основной идеей муравьиного алгоритма является заимствование некоторых принципов из поведения и организации колонии муравьев [3]. Муравьи практически слепые животные, но, тем не менее, они справляются с задачей отыскания кратчайшего пути от гнезда до источника пищи. Каждый отдельно взятый муравей является независимым агентом, действующим на свое усмотрение, но в то же время у них есть

некоторое подобие «общей памяти», с помощью которой происходит обмен информацией. Для этого муравьи оставляют на пройденном пути фермент, или точнее феромон. При выборе пути, по которому будет следовать муравей, с большей вероятностью выбирается тот путь, на котором находится большее количество феромона. Поэтому чем больше муравьев прошло по определенному пути, тем более «притягательным» он становится для следующих. АСО имеет несколько важных параметров: коэффициент ρ такой, что $(1-\rho)$ - это *испарение* следа, α - относительная важность следа, β - относительная важность расстояния между городами.

Алгоритм умных капель [4] в некотором смысле имитирует законы взаимодействия отдельных потоков, или множеств капель, как друг с другом, так и с окружающей средой, в процессе формирования маршрута реки. Для каждого отдельного множества капель река является окружающей средой, которая в значительной мере влияет на его поведение, но подобное влияние двунаправлено. Существенным фактором в формировании маршрута реки является тип грунта в русле реки и его сопротивление. Выбирая определенный маршрут, вода следует принципу наименьшего сопротивления, то есть если на определенном пути меньше количества грунта, чем на остальных, то он будет более предпочтительным. Более того, пройдя определенный путь, вода уносит с него часть грунта, причем количество переносимого грунта прямо пропорционально скорости движения капель. Таким образом, чем больше капель воды выбирают определенный путь, тем меньше количество грунта на нем остается. А значит, тем быстрее двигаются капли на этом участке, и тем «притягательнее» он становится для следующих капель. Алгоритм IWDs имеет большое число настраиваемых параметров: коэффициенты обновления скорости a_v , b_v и c_v , коэффициенты обновления грунта a_s , b_s и c_s , локальный параметр обновления грунта ρ_n , глобальный параметр обновления грунта ρ_{IWD} , начальное количество грунта между городами $InitSoil$, начальная скорость каждой капли $InitVelocity$, параметры обновления грунта на маршруте N_I и α .

В основе генетического алгоритма [5] лежит идея заимствования из природы некоторых принципов эволюции. Решение в GA представляется хромосомой индивида в популяции (множество решений), в частности в GA для задачи коммивояжера хромосома представляет собой перестановку из n чисел (номеров городов) в порядке их посещения. GA имеет несколько операторов, следующих друг за другом: селекция, рекомбинация и мутация. GA имеет большое количество настраиваемых параметров, таких как вероятность мутации, тип селекции – турнирная (с выбором размера турнира), пропорциональная, ранговая с линейным и ранговая с экспоненциальным ранжированием (с выбором параметра $\lambda \in [0;1]$).

Серьезным недостатком как GA, так и остальных бионических алгоритмов, является большое количество настраиваемых параметров, выбор которых сам по себе является трудной задачей, в том числе и для специалиста. Поэтому множество исследований посвящено попыткам автоматизировать выбор параметров [6]. В данной работе был выбран способ настройки, описанный в [7]. В этом случае для каждого оператора выбор варианта его настройки осуществляется отдельно. При этом в начале работы алгоритма все варианты настройки оператора равновероятны, а на каждом поколении лучшим выбирается тот вариант оператора, который имеет большую эффективность, и вероятность его выбора увеличивается за счет вероятностей выбора остальных операторов. В данной работе Adaptive GA имел выбор из 8 вариантов селекции – турнирная с размером турнира 2, 4 и 8, ранговая с линейным ранжированием, ранговая с экспоненциальным ранжированием с параметром λ равным 0.95, 0.8 и 0.5 и пропорциональная, а также 5 вариантов мутации – очень низкая, низкая, средняя, высокая и очень высокая.

Эффективность работы приведенных выше сравнивалась на двух задачах – Eil51 и Oliver30. Причем бионическим алгоритмам давалось столько ресурсов, сколько в среднем требовал для своей работы алгоритм 3-замены - 52800 вычислений целевой функции на задаче Oliver30 и 342210 на задаче Eil51. В таблице 1 приведено сравнение Adaptive GA с другими алгоритмами при их лучших, худших, а также «средних» настройках на задаче.

Таблица 1 – Сравнение Adaptive GA с другим алгоритмами на задаче Oliver30

		Лучший		Средний		Средне-квадратичное отклонение	Отклонение худшего от лучшего, %
		значение	ошибка	значение	ошибка		
Adaptive GA		423,741	0	434,485	10,7437	12,7539	10,317
GA	лучший	423,741	0	431,647	7,9057	11,3784	8,98636
	средний	424,1391	0,398124	442,9816	19,2406	12,8611	9,62995
	худший	425,267	1,52571	469,459	45,7179	27,0638	23,625
ACO	лучший	423,741	0	424,04	0,298825	0,429862	0,22448
	средний	428,6838	4,92983	443,7713	20,03043	11,71506	10,38272
	худший	461,453	37,7118	504,088	80,3472	28,0251	20,1145
IWDs	лучший	423,741	0	426,413	2,67193	3,19925	2,49468
	средний	423,9651	0,224108	434,7496	11,00865	10,17409	9,229506
	худший	424,692	0,950775	449,307	25,5656	19,0374	18,4417
3-opt		423,741	0	434,61	10,8691	11,931	15,3708

Здесь было рассмотрено 24 варианта настройки генетического алгоритма: селекция - турнирная (с размером турнира 2, 4 или 8), пропорциональная, ранговая – линейная, экспоненциальная (с параметром 0.95, 0.8 или 0.5); мутация: очень низкая, низкая, средняя. Для алгоритма ACO рассматривалось 16 вариантов настройки параметров: $\alpha = 1, 2, 5$ или 10; $\beta = 1, 2, 5$ или 10. И для IWDs 24 варианта настроек: $InitSoil = 1000, 10000$; $InitVel = 20, 200$; $\rho_n = 0.9, 0.7$; $\alpha = 0.1, 0.3, 0.5$. Был взят именно такой набор параметров, потому что на «легких» тестовых задачах остальные варианты параметров либо не оказывали существенного влияния на эффективность алгоритмов, либо давали худший результат по сравнению с теми, что были перечислены выше.

Как видно из результатов, приведенных в таблице, Adaptive GA хотя и уступает результатам других алгоритмов при лучших их настройках, но в то же время превосходит их при «средних» настройках. Стоит отметить, что увеличение вариантов операторов, между которыми Adaptive GA осуществляет выбор в процессе работы, увеличит время его работы незначительно, в то время как увеличение вариантов настроек для стандартного GA существенно усложнит обоснованный выбор между ними. К тому же в условиях ограниченности ресурсов может просто не быть возможности перебрать несколько вариантов настроек, а узнать заранее какими настройки будут оптимальными на конкретной задаче невозможно. Более того, в сложных задачах может не быть оптимального набора настроек алгоритма, и отдельные варианты операторов будут являться наиболее предпочтительными на разных этапах работы алгоритма. На рисунках 1 и 2 приведены примеры изменения вероятностей вариантов операторов селекции и мутации в зависимости от номера поколения.

Видно, что очень низкая вероятность мутации является наиболее предпочтительной на всех этапах работы алгоритма. А вот для оператора селекции на протяжении одного прогона алгоритма ведется активная борьба между несколькими вариантами – турнирная с размером турнира 8 и 4, ранговая с экспоненциальным ранжированием и параметром $\lambda=0.5$, а на последних поколениях еще и с $\lambda=0.8$.




Рис. 1. Вероятности выбора вариантов селекции на различных поколениях Adaptive GA.




Рис. 2. Вероятности выбора вариантов мутации на различных поколениях Adaptive GA.

Таким образом, в данной статье были рассмотрены некоторые алгоритмы комбинаторной оптимизации, исследована эффективность этих алгоритмов на задаче коммивояжера, проведен сравнительный анализ их работы. Также рассмотрено понятие адаптации на примере генетического алгоритма, показана ее значимость и эффективность применения.

Библиографический список:

1. Пападимитриу Х., Стайглиц К. Комбинаторная оптимизация. Алгоритмы и сложность. Издательство «МИР», Москва, 1984.
2. Lin S. Computer Solutions of the Traveling Salesman Problem, BSTJ, 44, No. 10 (December 1965), p.2245-2269.
3. Dorigo M., Gambardella L. M. Ant Colony System: A Cooperative Learning Approach to the Traveling Salesman Problem // IEEE Transactions on Evolutionary Computation, 1997, P. 53–66.
4. Shah-Hosseini H. Optimization with the Nature-Inspired Intelligent Water Drops Algorithm // Evolutionary Computation, Wellington Pinheiro dos Santos (Ed.), ISBN: 978-953-307-008-7, InTech, 2009.
5. Holland J.H. Adaptation in Natural and Artificial Systems // The University of Michigan Press, 1975.
6. Schaefer, R., Cotta, C., Kołodziej, J., Rudolph, G. Parallel Problem Solving from Nature – PPSN XI 11th International Conference, Kraków, Poland, September 11-15, 2010.
7. Семенкин Е.С., Семенкина М.Е. Проектирование ансамблей интеллектуальных информационных технологий самоконфигурируемым алгоритмом генетического программирования // Вестник Сибирского государственного аэрокосмического университета им. академика М.Ф. Решетнева. 2012. № 4. С. 89-96.