

УДК 519.61

UDC 519.6

**РАЗРАБОТКА ГИБРИДНОГО  
МОДИФИЦИРОВАННОГО АЛГОРИТМА НА  
ПРИМЕРЕ РЕШЕНИЯ ТЕСТОВЫХ ЗАДАЧ****DEVELOPMENT OF HYBRID ALGORITHM  
ON A MODIFIED EXAMPLE OF THE  
SOLUTION OF TEST PROBLEMS**

Сушков Сергей Иванович  
д.т.н., профессор  
*Воронежская государственная лесотехническая  
академия, Воронеж, Россия*

Sushkov Sergey Ivanovich  
Dr.Sci.Tech. professor  
*Voronezh State Academy of Forestry and  
Technologies, Voronezh, Russia*

В статье приведены результаты экспериментов по оценке эффективности многоточечности и полигамности, составляющими основу предложенного смешанного эволюционного метода, в сравнении с известными генетическими методами

The article shows the results of experiments to assess the effectiveness of multipoint and polygamous, which form the basis of the proposed mixed-evolutionary method, in comparison with known genetic methods

Ключевые слова: ГЕНЕТИЧЕСКИЙ АЛГОРИТМ,  
ЭВОЛЮЦИОННЫЕ МЕТОДЫ, ТЕСТОВЫЕ  
ЗАДАЧИ, ОЦЕНКА КАЧЕСТВА

Keywords: GENETIC ALGORITHM,  
EVOLUTIONARY METHODS, TEST PROBLEMS,  
QUALITY ASSESSMENT

Генетические алгоритмы (ГА) выражают эволюцию популяции хромосом в направлении от начального поколения к окрестностям экстремума. Обоснование этого положения содержится в основной теореме генетического подхода – теореме схем (иначе называемой *schemata theorem* или теорема шаблонов) [1].

Ранее в работах [2, 3] рассматривался разработанный автором гибридный модифицированный эволюционный алгоритм и перспективы его применения для решения задач многокритериальной оптимизации. В этой статье приведены результаты экспериментов по оценке эффективности многоточечности и полигамности, составляющими основу предложенного смешанного эволюционного метода, в сравнении с известными генетическими методами. Для исследования эффективности ГА предложено несколько вариантов тестовых функций. Известен набор тестовых функций К. ДеДжонга, в котором имеются одно- и многоэкстремальные функции с различным рельефом, а также ряд других наборов [4].

В процессе управления сложными техническими и организационно-техническими системами необходимо постоянно принимать непростые

решения, связанные с учетом многих критериев качества и ограничений на ресурсы. Если такие решения принимать с использованием только интуиции и опыта руководителя, то будет достаточно сложно сделать оптимальный выбор. В этой связи необходимо разрабатывать и внедрять формализованные методы поддержки принятия решений.

Формальные математические модели принятия решений в настоящее время все более полно отражают сложность реальных практических проблем, что, с одной стороны, делает их более адекватными реальным системам, а с другой – приводит к необходимости решать все более сложные задачи оптимизации. Основные свойства реальных практических задач оптимизации - наличие многих критериев, существенных ограничений, разношкальных переменных и алгоритмическое задание функций – делают невозможным применение традиционных методов. Выходом из такой ситуации является использование адаптивных стохастических алгоритмов, успешно преодолевающих указанные трудности.

Одним из наиболее часто применяемых в такой ситуации подходов являются эволюционные алгоритмы, представляющие собой стохастические оптимизационные процедуры, имитирующие процессы естественной эволюции, в частности – ГА. Алгоритмическое задание функций и разношкальность переменных не представляют дополнительных трудностей для ГА, которые работают с бинаризованными представлениями решений и не требуют информации о свойствах целевых функций. Однако детальный анализ литературы показал [1-6], что при реализации ГА, возникает ряд трудно разрешимых недостатков, основными из которых являются:

- достаточно высокая ресурсоемкость ГА;
- предварительная сходимости алгоритмов в локальном оптимуме, в общем случае далеко от глобального;

– среди полученных с помощью ГА решений часто встречается большое количество непаретовских точек [2].

Таким образом, совершенствование существующих и разработка новых эффективных адаптивных поисковых алгоритмов многокритериальной оптимизации является на сегодняшний день актуальной научной задачей.

Для решения указанных проблем в работе предлагается разработать гибридный эволюционный алгоритм, сочетающий в себе применение модифицированных генетических операторов (ГО), схем селекции и архитектур генетического поиска (ГП) [3].

Функционирование сложных технических систем (ТС) происходит в динамически изменяющихся условиях как объективной, так и субъективной природы.

К числу основных тестовых задач для проверки отдельных аспектов эффективности разрабатываемых методов относятся задачи маршрутизации транспортных средств с временными окнами, задача двумерной упаковки, задача синтеза топологии и распределения трафика в вычислительных сетях и др.

Большинство предложенных наборов включает задачи непрерывной оптимизации сравнительно малого размера.

Одной из основных тестовых задач отражающих особенности задач пространственно-временного синтеза, является задача синтеза расписаний – JSSP (Job Shop Scheduling Problem) [1, 4].

К исходным данным задачи JSSP относятся:

$Q$  – число стадий обслуживания каждой работы;

$A = \{A_1, A_2, \dots, A_n\}$  – множество работ;

$M = \{M_1, M_2, \dots, M_m\}$  – множество исполнителей (машин, единиц техники и т.п.);

$P = [P_{ij}]$  – матрица производительностей машин, где  $P_{ij}$  – затраты времени на выполнение работы  $i$  на машине  $j$ ;

$C = (C_1, C_2, \dots, C_m)$  – вектор цен, где  $C_j$  – цена за единицу времени работы машины  $M_j$ ;

$T = (T_1, T_2, \dots, T_n)$  – ограничения на время окончания работ, где  $T_i$  – предельное время для завершения работы  $i$ ;

$Q$  – штраф, добавляемый к общим затратам  $Z$  при нарушении какой-либо работой соответствующего ей временного ограничения.

Требуется составить расписание, при котором минимизируются затраты на выполнение всех работ с учетом штрафов.

Приведены результаты экспериментов по оценке эффективности многоточечности и полигамности, составляющими основу предложенного гибридного эволюционного алгоритма, в сравнении с известными генетическими методами. В качестве тестовой примем задачу JSSP. Для сравнительного анализа результатов тестирования кроме разработанного алгоритма (ГМЭА) примем к рассмотрению следующие методы: CGA (Classic Genetic Algorithm), HCM (Heuristics Combination Method), PSO (поведение толпы), ASO (колония муравьев), VEGA (Vector Evaluated Genetic Algorithm), FFGA (Fonseca and Fleming's Multiobjective Genetic Algorithm), NPGA (Niche Pareto Genetic Algorithm), SPEA (Strength Pareto Evolutionary Algorithm).

Выполненное исследование потенциала рекомбинации позволяет сделать вывод о наличии оптимальных значений длин фрагментов  $L$ , на которые разделяются хромосомы при кроссовере. Для подтверждения этого вывода было проведено экспериментальное исследование зависимости функций полезности от  $L$  на примере задачи JSSP.

Ранее отмечено, что снижение эффективности генетического поиска происходит из-за явления преждевременной стагнации. Это явление исследовалось на применении методов HCM и предложенного гибридного

алгоритма к задаче синтеза расписаний со следующими исходными данными: число стадий обслуживания работ  $q=4$  стадии, число работ  $n=105$ , число машин  $m=15$ . Результаты двух вариантов решения задачи при применении каждого из сравниваемых методов приведены в табл. 1, где  $N$  – число разрывов хромосом при кроссовере (отметим, что длина хромосомы в данной задаче равна  $q \cdot n=420$ ), Evals– число оценок целевой функции.

Таблица 1 – Решение задачи JSSP

Evals	270	20г	30г	40г	50г	75г	100г	125г
$N=20$	22570	22293	22121	21963	21901	21834	21821	21811
$N=20$	23498	22147	22073	21970	21850	21798	21789	21781
$N=1$	22570	22145	22126	22118	22118	22118	22118	22118
$N=1$	23498	22134	22119	22100	22099	22083	22072	22072

Результаты показывают, что при многоточечном кроссовере вероятность преждевременной стагнации уменьшается, соответственно удается заметно ближе подойти к точке экстремума.

На рис. 1 представлена зависимость коэффициента разнообразия генов  $r$  (доля генов, имеющих неодинаковые значения в хромосомах родителей в очередном акте кроссовера) от номера поколения.

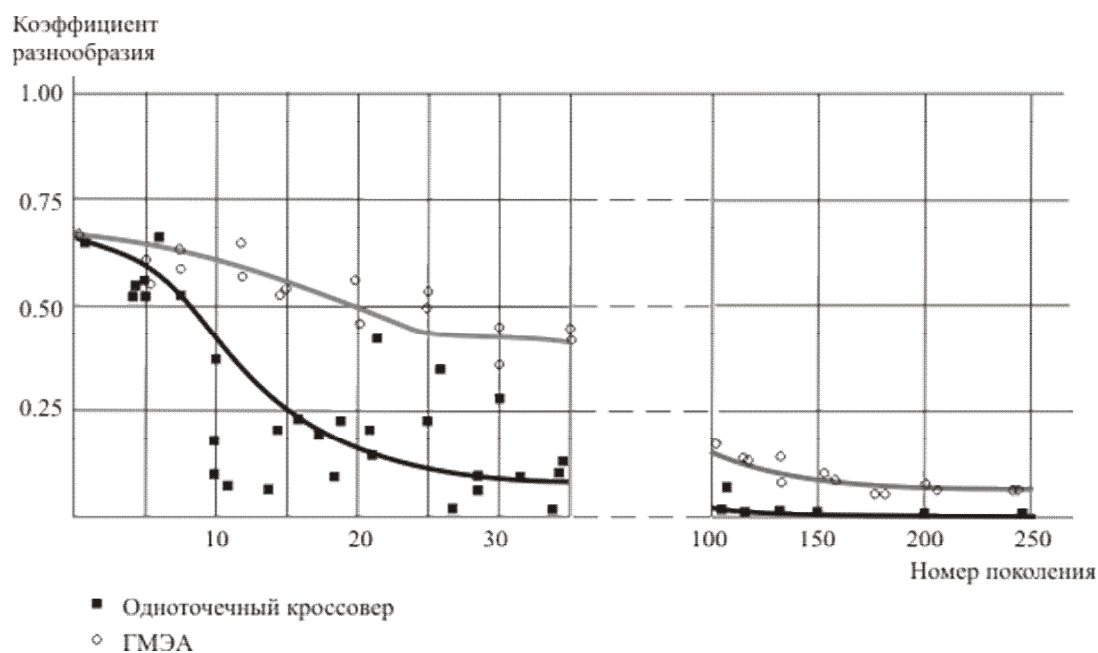


Рис. 1 Иллюстрация вырождения популяции с ростом числа поколений

На рисунке светлыми точками обозначены значения  $r$ , полученные в некоторых случайно выбранных актах кроссовера при применении разработанного метода, а темными точками – аналогичные значения, полученные при применении одноточечного кроссовера (CGA). Рисунок иллюстрирует заметно меньшую предрасположенность разработанного алгоритма к ранней стагнации.

В [5] приводится теоретическое обоснование наличия оптимальных значений длин фрагментов  $L$  в смешанном эволюционном методе. Для подтверждения теоретических результатов были проведены эксперименты по определению оптимальных значений  $L$ .

На рис. 2 представлены результаты решения задачи синтеза многостадийных расписаний с 4 стадиями, 200 работами и 15 машинами с помощью разработанного метода. Точки соответствуют отдельным вариантам решения, кривая отображает усредненную зависимость целевой функции от размера фрагмента  $L$ .




Рис. 2 Зависимость результатов решения задачи VRPTW от длины фрагментов  $L$

Полученные результаты позволяют сделать вывод: длина фрагментов  $L$  влияет на эффективность поиска. Для разработанного алгоритма в задаче JSSP оптимальные значения  $L$  находятся в диапазоне  $\{5, 40\}$  при общей длине хромосомы, равной 800. Следовательно, однородный и одноточечный кроссоверы не относятся к лучшим вариантам ГА.

Аналогичные результаты были получены при решении других тестовых задач. Рис. 2 иллюстрирует результаты решения задачи маршрутизации транспортных средств с временными окнами (VRPTW), в которой хромосомы содержат по 40 генов.

На рис. 3 показаны результаты решения задачи синтеза топологии и распределения трафика (СТРТ) в вычислительной сети с хромосомами длиной в 276 генов. В обоих случаях использовался метод ГМЭА.




Рис. 3 Зависимость результатов решения задачи СТРТ от длины фрагментов  $L$

Интерес представляет сравнение разработанного ГМЭА с методами PSO и ACO [6]. Результаты такого сравнения приведены на рис. 4.

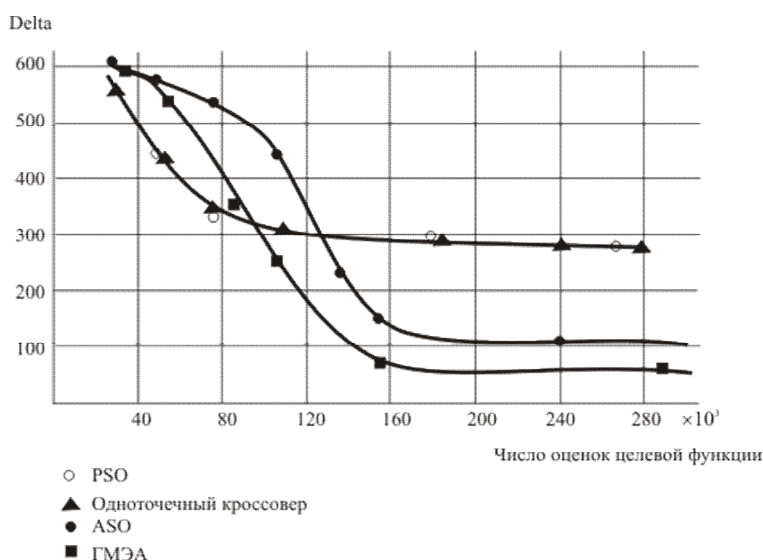


Рис. 4 Сравнение результатов решения задачи синтеза расписаний различными генетическими методами

Где Delta есть разность между полученным и наилучшим известным результатом решения тестовой задачи синтеза многостадийных расписаний с 105 работами. Эти результаты свидетельствуют о преимуществе разработанного метода перед другими сравниваемыми методами.



Оценка эффективности разработанного алгоритма проводилась на примере следующей разновидности тестовой задачи синтеза расписаний JSSP: задано:

1) Множество работ  $A=\{A_1, A_2, \dots, A_n\}$ , где каждая работа  $A_i$  последовательно проходит  $q$  стадий обслуживания;

2) На каждой стадии имеется  $m_k$  машин  $k = 1, \dots, q$ , общее число машин  $m = S \cdot m_k$ ;

3) Для обслуживания работы  $A_i$  на стадии  $k$ , выбирается одна из  $m_k$  машин;

4) Одновременно на одной машине может обслуживаться не более одной работы, начатое обслуживание не прерывается;

5) Все работы распределены по типам и, если соседние во времени исполнения работы, обслуживаемые на  $j$ -й машине, относятся к разным типам, то  $j$ -я машина должен пройти переналадку;

6) Задана матрица производительностей  $P$ , элемент  $P_{ij}$  равен времени обслуживания  $i$ -й работы на  $j$ -й машине;

7) Для каждой машины задана матрица переналадок  $E$ , элемент которой  $E_{ir}$  равен времени переналадки машины при переходе с обслуживания работы  $i$ -го типа на обслуживание работы  $r$ -го типа;

8) Заданы цены единицы времени обслуживания и переналадки каждой машины (соответственно  $C_j$  и  $R_j$ );

9) Заданы ограничения на сроки выполнения каждой  $i$ -й работы: «мягкие»  $D_i$  и «жесткие»  $T_i$  ограничения, причем  $T_i > D_i$ , из-за нарушения сроков налагаются штрафы  $G_1$  и  $G_2$ , соответственно,  $G_2 \gg G_1$ .

Требуется получить расписание, минимизирующее общие затраты, складывающиеся из штрафов, затрат на обслуживание всех работ на всех стадиях и затрат на переналадки всех машин.

В экспериментах принято: число работ 94, число машин 15, размер популяции 200. Усредненные по нескольким вариантам расчета

зависимости целевой функции  $F(X)$  от числа evals обращений к процедуре ее вычисления показаны на рис. 5.

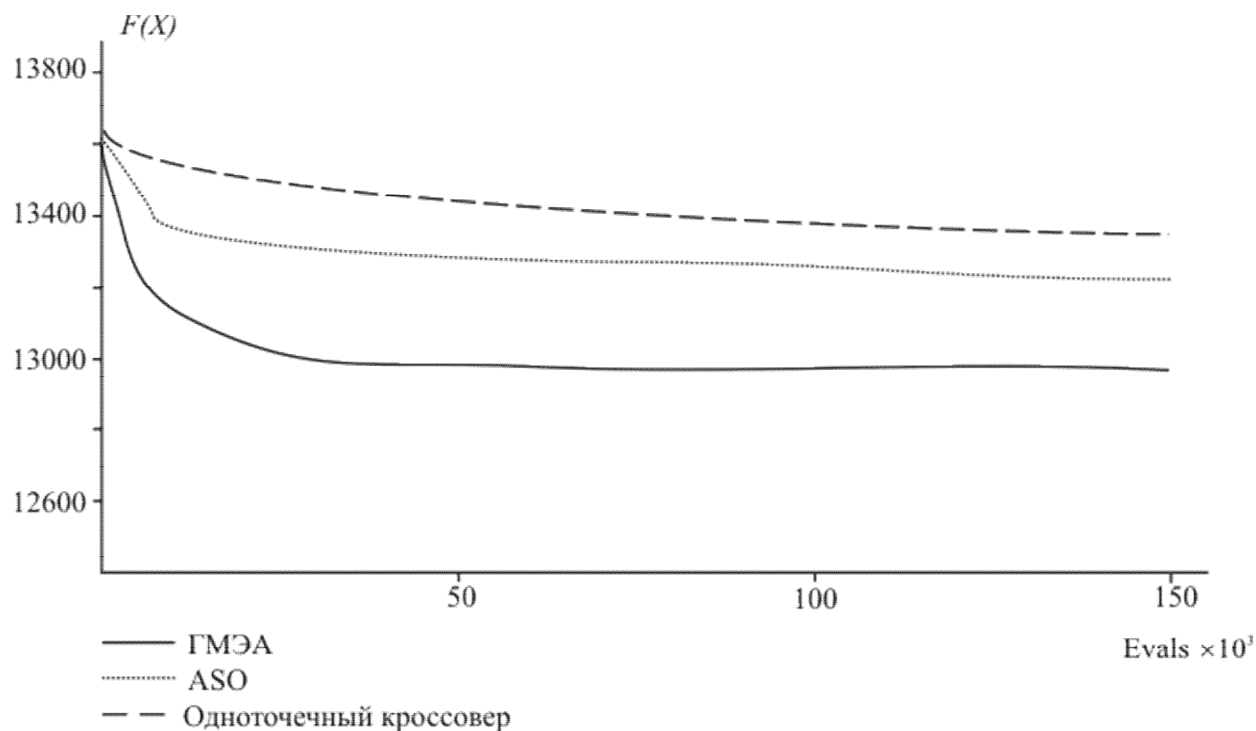


Рис. 5 Сравнительные результаты поиска разными методами

Эксперименты показали, что разработанный ГМЭА обеспечивает результат более точный по сравнению с результатами применения неадаптивных генетических алгоритмов в среднем на 7-10%.

Вывод. Проведенные исследования показали существенное преимущество разработанного алгоритма перед существующими методами, а так же перспективность применения метагенетического подхода, сочетающего ГА и классические методы оптимизации.

**Список литературы:**

1. Норенков И.П., Арутюнян Н.М. Эволюционные методы в задачах выбора проектных решений // Наука и образование электронное издание №9, 2007
2. Яковлев К.А., Муратов А.В. Разработка модифицированного эволюционного алгоритма решения задач многокритериальной оптимизации на всех этапах жизненного цикла парка транспортно-технологических машин // Вестник Воронежского государственного технического университета – 2010.– Т.6. – №7. – С. 33-38
3. Яковлев К.А. Решение задачи многоцелевой оптимизации подвижности лесотехнических машин // Вестник Воронежского государственного технического университета – 2010.– Т.6. – №7. – С. 64-67
4. Genetic Algorithms (Evolutionary Algorithms): Repository of Test Functions. - <http://www.cs.uwo.edu/~wspears/functs.html>.
5. Гладков Л.А. Генетические алгоритмы / Гладков Л.А., Курейчик В.В., Курейчик. – М.: ФИЗМАТЛИТ, 2006. – 243 с.
6. Osyczka A., Kundu S. A new method to solve generalized multicriteria optimization problems using the simple genetic algorithm // Structural Optimization. 1995. Vol. 10. P. 94-99