

**А. С. Акопов**<sup>1, 2</sup>, д-р техн. наук, доц.,  
проф. кафедры бизнес-аналитики<sup>1</sup>, вед. науч. сотр.<sup>2</sup>, e-mail: aakopov@hse.ru,  
**А. Л. Бекларян**<sup>1</sup>, канд. техн. наук, доц. кафедры бизнес-аналитики, e-mail: abeklaryan@hse.ru,  
**Н. К. Хачатрян**<sup>1, 2</sup>, канд. физ.-мат. наук,  
доц. кафедры бизнес-аналитики<sup>1</sup>, ст. науч. сотр.<sup>2</sup>, e-mail: nerses@cemi.rssi.ru; nkhatatryan@hse.ru,  
**А. В. Фомин**<sup>1</sup>, канд. экон. наук, ст. преподаватель, e-mail: afomin@hse.ru,  
<sup>1</sup>Национальный исследовательский университет "Высшая школа экономики",  
<sup>2</sup>Федеральное государственное бюджетное учреждение науки  
Центральный экономико-математический Институт РАН

### Разработка адаптивного генетического оптимизационного алгоритма с использованием методов агентного моделирования

*Представлен новый подход к разработке адаптивного генетического оптимизационного алгоритма (MAGAMO/A) с использованием методов агентного моделирования. Особенностью данного подхода является поддержка механизма адаптивного управления ключевыми характеристиками ГА, в частности, значениями вероятностей операторов кроссинговера и мутации, их типами и другими важными характеристиками, влияющими на разнообразие популяции и скорость сходимости ГА. Поддержка адаптивного управления обеспечивается за счет использования механизма карт состояний агента и заданных правил перехода между соответствующими состояниями, определяющими значения управляющих параметров ГА на индивидуальном уровне каждого агента-процесса. Проведен обзор наиболее популярных ГА, применяемых для задач многокритериальной оптимизации, в том числе, таких как SPEA2, NSGA, MOEA и др. Рассмотрены основные метрики оценки эффективности подобных ГА (Hypervolume, Generational Distance, расстояния между решениями на границе Парето и др.). Продемонстрирована эффективность разработанного подхода в решении оптимизационных задач большой размерности на нескольких тестовых примерах и в сравнении с другими известными ГА. Сформулированы основные направления дальнейших исследований в области разработки агентно-ориентированных генетических алгоритмов.*

**Ключевые слова:** генетический алгоритм, фронт Парето, эволюционные вычисления, агентное моделирование, многоцелевая оптимизация

#### Введение

Разработка эффективных алгоритмов поиска решений для многокритериальных оптимизационных задач большой размерности является весьма актуальным направлением. Высокая степень сложности таких задач во многом обусловлена значительными затратами, требуемыми для вычисления значений целевых функций и других модельных характеристик, участвующих в проверке соответствующих ограничений. В случае, когда целевой функционал может быть описан аналитически, для определения локальных экстремумов применяют различные градиентные методы поиска решений ненулевого порядка, например методы Ньютона и Коши и их различные

модификации. В противном случае применяют хорошо известные методы прямого поиска (т. е. без вычисления производных), такие как метод Хука—Дживса, метод Нелдера—Мида и др. При этом постановка задачи многоцелевой оптимизации предполагает определение набора наилучших (компромиссных) решений, при выборе которых относительный уровень снижения качества по одному или нескольким критериям не превосходит относительного уровня повышения качества по другим критериям. Таким образом, требуется нахождение решений, при которых значение каждого частного показателя, характеризующего систему, не может быть улучшено без ухудшения других показателей. Подобное множество решений относится к типу Парето-оптимальных. По-

строение приближенного множества (или некоторого репрезентативного подмножества) Парето относится к числу задач высокой вычислительной сложности [21].

Одним из наиболее эффективных методов решения подобных задач являются генетические оптимизационные алгоритмы (ГА), впервые предложенные в работах Дж. Холланда и Д. Гольберга [10, 13]. В настоящее время для решения задач многокритериальной оптимизации и построения фронта Парето применяют широкое семейство ГА, в том числе такие как NSGA-II, NSGA-III, OMOPSO, PAES, PESA-II, SPEA2, VEGA, MOEA/D, MAGAMO и др. [3, 4, 6, 8, 9, 19, 20]. Среди них следует выделить алгоритм SPEA2 (Strength Pareto Evolutionary Algorithm) [20], отличающийся учетом ранга Парето для отбираемых в процессе эволюционного поиска решений, а также относительно новый алгоритм MOEA/D [17], основанный на декомпозиции решаемой многоцелевой оптимизационной задачи на множество одноцелевых задач.

Важным преимуществом ГА по сравнению с другими методами многомерной оптимизации является возможность эффективного распараллеливания вычислительной процедуры [23–25]. При этом следует отметить два подхода. Первый, наиболее известный, подход основан на так называемой "островной" модели [17], когда из одной общей популяции возможных решений (удовлетворяющих правилам недоминирования Парето), именуемой "материком", выделяется несколько популяций меньшей длины, эволюция которых осуществляется параллельно с периодическим обменом наилучшими решениями с "материком". Достоинством данного подхода является существенное ускорение вычислительного процесса в условиях мультипроцессорной архитектуры. Однако с ростом размерности оптимизационной задачи, длина популяции решений начинает расти пропорционально числу переменных решений. Для преодоления данной проблемы нами ранее был предложен другой подход — алгоритм MAGAMO [4, 26], основанный на равномерном разбиении пространства решений между автономными агентами (являющимися самостоятельными ГА) в целях минимизации длины популяции на индивидуальном уровне агентов. Данный подход показал высокую эффективность для многокритериальных оптимизационных задач большой размерности, в которых целевые функционалы вычисляются в результате имитационного моделирования. Тем не менее вычислительная продуктивность MAGAMO была ограничена (например, вероятностью оператора мутации) и зависела в основном от значений параметров ГА, устанавливаемых равнозначными

для всех агентов-процессов. Для преодоления данной проблемы предлагается создание адаптивной модификации алгоритма MAGAMO/A с использованием возможностей методов агентного моделирования, в частности механизма карты состояний, являющейся, по сути, конечным автоматом для управления параметрами ГА на индивидуальном уровне в зависимости от качества эволюционного процесса каждого взаимодействующего агента.

Основной целью данной работы является разработка многоагентного адаптивного генетического оптимизационного алгоритма, обеспечивающего эффективный процесс коэволюционного поиска в условиях мультипроцессорной системной архитектуры для многокритериальных оптимизационных задач большой размерности (несколько целевых функций, сотни переменных, множественные ограничения). Данный подход был успешно апробирован для решения сложных эколого-экономических оптимизационных задач [1, 2], для управления поведением агентов-спасателей при чрезвычайных ситуациях [5] и др.

## 1. Концептуальная модель многоагентного ГА

Примером использования методов агентного моделирования для построения генетического оптимизационного алгоритма является работа [4]. В данной работе был предложен многоагентный генетический алгоритм MAGAMO, основанный на принципе распределения пространства решений между агентами-процессами и организацией коэволюционной процедуры, в рамках которой центральный процесс отвечает за формирование Парето-оптимальных решений, а локальные процессы обеспечивают направленный поиск наилучших решений для назначенных их переменных. Эффективность подобного алгоритма достигалась за счет существенного снижения длины популяции (и, как следствие, сокращения временных затрат на оценку фитнес-функций) на уровне локальных агентов-процессов и обеспечения непрерывного обмена значениями наилучших недоминируемых решений с глобальным архивом.

Отметим, что принципы построения MAGAMO существенно отличаются от классической "островной" модели, в которой нет распределения искомым переменных между процессами, а эффективность достигается по сути за счет более диверсифицированной эволюции. Кроме того, в MAGAMO есть существенные отличия от "роевых" алгоритмов (*swarm optimization* [16]), функциональность которых основана на движении частиц в пространстве решений и

обмене полезной информацией между ними. В частности, число агентов в MAGAMO, как правило, выбирается равным числу процессоров, на которых могут быть запущены исполняемые потоки. В "роевых" алгоритмах число агентов-частиц может измеряться тысячами, что и позволяет достичь наибольшей эффективности за счет максимального быстрого сканирования ландшафта целевых функционалов и определения целевой точки. Однако временные затраты на обмен информацией между агентами-частицами в большой популяции и отсутствие операторов мутации существенно ограничивают применимость подобных алгоритмов к сложным задачам многоцелевой оптимизации, требующим определения фронта Парето (в особенности, имеющего множественные разрывы, являющегося невыпуклым и др.). Поэтому предлагается, сохранив базовую функциональность MAGAMO, обеспечить его максимальную эффективность за счет адаптивного управления параметрами на индивидуальном уровне агентов-процессов. Для этого предлагается изменять значение одного или нескольких параметров ГА в зависимости от качества эволюционного процесса — темпов роста приспособленности популяции и степени разнообразия генотипов популяции (удаленности решений друг от друга участвующих в селекции). Данный подход экспериментально демонстрирует свою эффективность. Однако, когда популяция решений эволюционирует в рамках одного процесса, определить наилучшие значения параметров ГА, являющиеся рациональными для всех решений, не всегда удастся ввиду их неоднородности (значения одних переменных требуют более быстрой эволюции, другие должны лишь немного корректироваться и т. д.). Потому более эффективным представляется подход, основанный на принципах адаптивного управления параметрами ГА на индивидуальном уровне агентов-процессов. Отметим, что преимущества адаптивных ГА ранее были исследованы в работе [22].

Для разработки адаптивных ГА можно использовать систему управления состояниями каждого агента-процесса на основе метода конечных автоматов (FSM) реализуемого посредством карт состояний агента (*statecharts*). Переходы между состояниями каждого агента-процесса осуществляются в зависимости от текущей эффективности ГА, оцениваемой с использованием различных критериев, например, критерия "гиперобъема" (*Hypervolume*), расстояния между решениями на фронте Парето GD, IGD, Spacing и другие метрики [7, 11, 14].

Отметим, что данный подход является эффективным при значительном времени эволюционного процесса, когда возможны множествен-

ные изменения состояний и параметров ГА, т. е. именно для оптимизационных задач большой размерности. На начальном шаге все искомые переменные равномерно распределяются между агентами-процессами и далее обмениваются друг с другом информацией о наилучших (с точки зрения приспособленности фитнес-функции) значениях собственных переменных, удовлетворяющих критерию Парето-оптимальности.

## 2. Формальное описание адаптивного генетического алгоритма

Итак, рассматривается ансамбль взаимодействующих агентов-процессов, являющихся автономными ГА и имеющих следующие возможные состояния для каждого агента.

1. **Состояние 0.** *Начальная локальная эволюция* — состояние агента-процесса для первых стадий ГА, при котором применяются стандартные значения параметров ГА. В данном состоянии обмен наилучшими решениями (значениями искомого переменных) с другими агентами-процессами осуществляется на каждой итерации (эпохе) ГА.

2. **Состояние 1.** *Быстрая эволюция* — состояние агента-процесса для последующих эпох ГА, при котором применяются параметры ГА, обеспечивающие максимальные темпы эволюционного процесса, например, двухточечный оператор кроссинговера; три-четыре родительских особи; множество генерируемых потомков; почти нулевая вероятность оператора мутации и др. В данном состоянии обмен наилучшими решениями с другими агентами-процессами осуществляется на каждой итерации ГА. Отметим, что рассматриваемое состояние может привести к преждевременной сходимости ГА. Кроме того, данное состояние требует постоянных коммуникационных затрат на взаимодействие с другими агентами, что влияет на скорость эволюционных вычислений.

3. **Состояние 2.** *Медленная эволюция с низким разнообразием популяции*, — состояние агента-процесса для последующих эпох ГА, при котором применяются параметры ГА, обеспечивающие низкие темпы эволюционного процесса, например, одноточечный оператор кроссинговера, две родительских особи с двумя потомками, небольшая вероятность оператора мутации и др. При входе и выходе из данного состояния осуществляется обмен наилучшими решениями с другими агентами. Отметим, что данное состояние может привести к замедлению работы ГА и предотвращению преждевременной сходимости за счет оператора мутации.

4. **Состояние 3.** *Медленная эволюция с высоким разнообразием популяции* — состояние агента-

Значения основных параметров ГА в зависимости от состояния агента-процесса

Параметры ГА	Состояния ГА			
	0	1	2	3
Вероятность оператора кроссинговера	1	0,85	0,5	0,5
Вероятность оператора мутации	0	0,001	0,01	0,2
Тип оператора кроссинговера	Одноточечный	Двухточечный	Одноточечный	Равномерный
Тип оператора мутации	Нет	Стандартный	Стандартный	Комбинированный
Число родительских особей	2	3 и более	2	3 и более
Число особей-потомков	2	3 и более	2	3 и более
Максимальное число эпох ГА, допустимых для данного состояния	100	1000	300	100
Частота обмена наилучшими решениями с другими агентами-процессами	На каждой итерации	На каждой итерации	Только на входе и выходе из состояния	Только на входе и выходе из состояния

процесса для последующих эпох ГА, при котором применяются параметры ГА, обеспечивающие низкие темпы эволюционного процесса, но наибольший уровень диверсификации популяции за счет множественных (комбинированных) мутаций. При входе и выходе из данного состояния осуществляется обмен наилучшими решениями с другими агентами. Отметим, что данное состояние гарантированно обновляет популяцию, но также может привести к редукции ГА (т. е. к разрушению приспособленности популяции) в случае длительного нахождения ГА в данном режиме.

**5. Состояние 4. Завершение локальной эволюции** — состояние агента-процесса, при котором найдено подмножество наилучших значений искомым переменных, принадлежащих данному агенту и удовлетворяющих критерию оптимальности по Парето (т. е. решений, имеющих наивысший ранг Парето). Одним из условий перехода к данному состоянию является стабилизация средней приспособленности локальной популяции (т. е. она становится однородной) до требуемого уровня сходимости. В случае невозможности достижения глобальной сходимости в течение значительного числа эпох ГА (например, более 1000), возможен возврат к состоянию быстрой эволюции.

**6. Состояние 5. Окончание глобальной эволюции** — состояние агента-процесса, при котором найдены окончательные наилучшие значения искомым переменных, принадлежащих всем агентам-процессам.

Значения параметров ГА, соответствующие первым четырем состо-

стояниям, представлены в табл. 1. Последние два состояния характеризуются отсутствием эволюционного процесса.

На рис. 1 представлена карта состояний агента-процесса, реализованная в системе AnyLogic, используемой для реализации адаптивного многоагентного генетического алгоритма (MAGAMO/A) на языке программирования Java.

Приведем формальное описание правил перехода к соответствующим состояниям для предложенного генетического алгоритма.

Введем следующие обозначения:

- $t \in \{t_0, t_0 + 1, \dots, t_0 + T\}$  — индекс эпох (внутреннее время) ГА,  $T$  — максимальное допустимое число эпох ( $T = 10\,000$ );

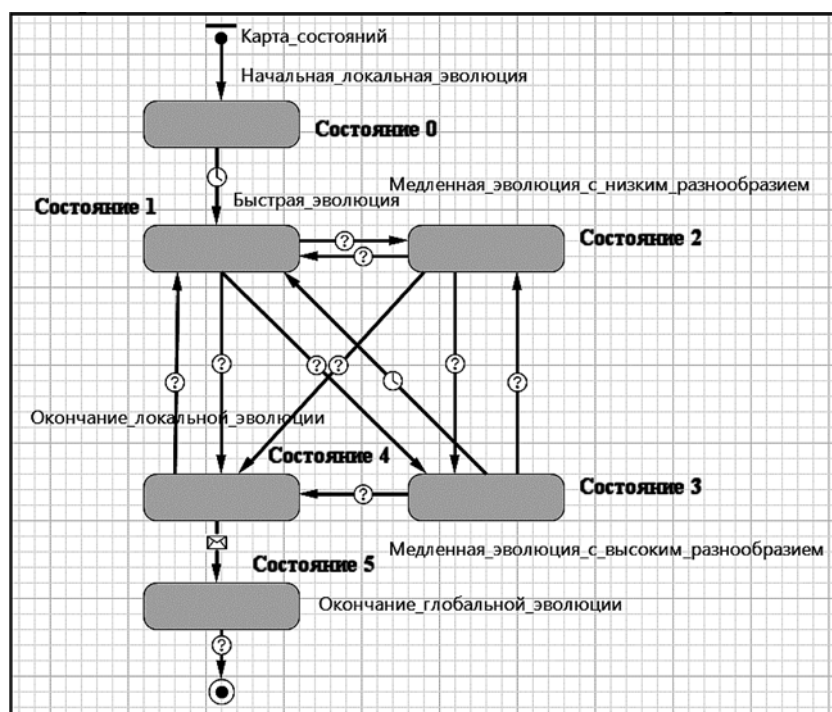


Рис. 1. Карта состояний агента-процесса (генетического алгоритма MAGAMO/A)

- $i \in \{1, 2, \dots, I\}$  — индекс агента-процесса;
- $st_i(t) \in \{0, 2, \dots, 5\}$  — возможные состояния агента-процесса (рис. 1).
- $HV_i(t)$  — среднее (медианное) значение метрики "гиперобъема", вычисляемое на основе оценки площади над аппроксимируемым фронтом Парето, ограниченным точкой надира с известными координатами (т. е. соответствующей наихудшим значениям целевых функционалов оптимизационной задачи, рис. 2). Отметим, что данный индикатор является наиболее важным при оценке эффективности ГА для задач многокритериальной оптимизации.
- $HV$  — минимально допустимое значение метрики "гиперобъема";
- $IGD_i(t)$  — среднее (медианное) значение инвертированного расстояния от каждого Парето-оптимального решения к ближайшему решению аппроксимируемого фронта Парето (рис. 3);
- $IGD$  — максимально допустимое значение инвертированного расстояния между решениями.

Отметим, что для стандартных задач минимизации целевых функционалов (см. рис. 2), значения метрики "гиперобъема" максимизируют (т. е. чем дальше мы от наихудшего сценария, тем лучше).

Инвертированное расстояние между решениями (рис. 3), лежащими на аппроксимируемом фронте Парето, и ближайшими решениями из сформированного множества решений является одной из метрик качества решений, что обусловлено важным требованием к аппроксимируемому фронту Парето — необходимости наличия близко расположенных (к фактическому подмножеству) решений.

- $SP_i(t)$  — среднее (медианное) значение расстояния между Парето-оптимальными решениями, лежащими на фронте (рис. 4);
- $SP$  — минимально допустимое значение расстояния между решениями, лежащими на фронте Парето.

Минимально допустимый темп роста приспособленности популяции (минимально допустимая скорость эволюции) равна

$$F_i(t) = \frac{1}{t} \sum_{\zeta=t_0}^t \tilde{f}_i(\zeta), \quad (1)$$

$$t \in \{t_0, t_0 + 1, \dots, t_0 + T\}, i \in \{1, 2, \dots, I\},$$

где  $\zeta$  — индекс текущей итерации ГА,  $\zeta \in \{t_0, t_0 + 1, \dots, t_0 + T\}$ ;  $\tilde{f}_i(\zeta)$  — среднее значение приспособленности популяции в момент времени  $\zeta$ , вычисляемое на основе оценки значений фитнес-функций для всех решений — членов данной популяции;

- $G_i(t)$  — сходимость (конвергенция)  $i$ -го агента-процесса (локального ГА), оцениваемая как среднее (медианное) расстояние Хэмминга между членами популяции;
- $\bar{G}$  — требуемый уровень локальной сходимости (малое число), при котором останавливается работа  $i$ -го агента-процесса (локального ГА), т. е.  $G_i(t) \leq \bar{G}$  при условии, что  $t > t^*$ , где  $t^*$  — минимально допустимое время (число эпох ГА), необходимое для предотвращения преждевременной сходимости ( $t^* = 100$ );




Рис. 2. Оценка метрики Hypervolume на примере задачи минимизации двух целевых функционалов

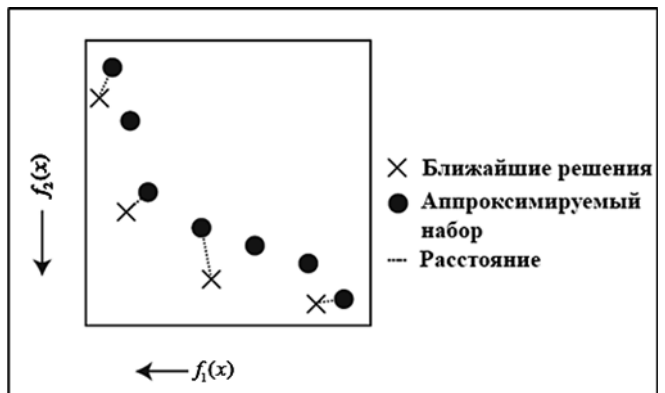


Рис. 3. Инвертированное расстояние между решениями




Рис. 4. Расстояние между решениями, лежащими на фронте Парето

- $\bar{G}$  — требуемый уровень глобальной сходимости (малое число) при котором останавливается работа всех агентов-процессов;
- $\tau_{i1}(t)$ ,  $\tau_{i2}(t)$ ,  $\tau_{i3}(t)$  — максимально допустимое время нахождения агента-процесса в первом, втором и третьем состоянии соответственно.

Тогда правило перехода к новым состояниям  $i$ -го агента-процесса ( $i \in \{1, 2, \dots, I\}$ ) в рамках алгоритма MAGAMO/A в момент времени  $t \in \{t_0, t_0 + 1, \dots, t_0 + T\}$  может быть представлено в следующей форме:

$$st_i(t) = \begin{cases} 0, & \text{если выполняется I,} \\ 1, & \text{если выполняется II,} \\ 2, & \text{если выполняется III,} \\ 3, & \text{если выполняется IV,} \\ 4, & \text{если выполняется V,} \\ 5, & \text{если выполняется VI,} \end{cases} \quad (2)$$

где

- I.  $t \leq t^*$  или  $st_i(t) \notin \{1, 2, 3, 4, 5\}$ ;
- II.  $t^* < t \leq \tau_{i1}(t)$  и  $F \leq F_i(t) \leq \bar{F}$  и  $HV_i(t) \geq \underline{HV}$  и  $IGD_i(t) \leq \overline{IGD}$  и  $SP_i(t) \geq \underline{SP}$  и  $G_i(t) > \bar{G}$  и  $st_i(t) \notin \{0, 5\}$ ;
- III.  $t \leq \tau_{i2}(t)$  и  $F_i(t) > \bar{F}$  и  $HV_i(t) \geq \underline{HV}$  и  $IGD_i(t) \leq \overline{IGD}$  и  $SP_i(t) \geq \underline{SP}$  и  $G_i(t) > \bar{G}$  и  $st_i(t) \notin \{0, 4, 5\}$ ;
- IV.  $t \leq \tau_{i3}(t)$  и  $(F_i(t) > \bar{F})$  или  $HV_i(t) < \underline{HV}$  или  $IGD_i(t) > \overline{IGD}$  или  $SP_i(t) < \underline{SP}$  и  $G_i(t) > \bar{G}$  и  $st_i(t) \notin \{0, 4, 5\}$ ;
- V.  $G_i(t) \leq \bar{G}$  и  $\sum_{i=1}^I G_i(t) > \bar{G}$  и  $st_i(t) \notin \{0, 5\}$ ;
- VI.  $\sum_{i=1}^I G_i(t) \leq \bar{G}$ .

Далее с использованием системы AnyLogic был реализован прототип адаптивного много-агентного генетического алгоритма с использованием диаграммы действий **actionChart** (рис. 5).

Важной особенностью предложенного алгоритма (рис. 5) является поддержка механизма перехода к новым состояниям агента по результатам оценки качества эволюционного процесса (метрики "гиперобъема", расстояния между решениями на фронте Парето и др.), что обеспечивает возможность адаптивного управления параметрами ГА и повышает эффективность генетического алгоритма.

### 3. Результаты оптимизационных экспериментов

Отметим, что формальное описание тестовых многокритериальных оптимизационных задач представлено в работе [18]. В табл. 2 полужирным шрифтом выделены результаты (медианное значение метрики "гиперобъем"), соответствующие наилучшим значениям, полученные посредством множественных (50) прогонов ГА. Также отметим, что время, выделяемое для оценки данной метрики для всех рассматриваемых ГА было одинаковым (для сопоставимости оценки качества фронта Парето). Тем не менее временная эффективность (время достижения сходимости) у рассматриваемых ГА различная (указана в скобках). Все расчеты были проведены на персональном компьютере Intel Core i7-2670QM CPU@ 2.20GHz, 8Gb RAM. Расчеты для алгоритмов  $\epsilon$ -MOEA, NSGAII и SPEA2 выполнялись с использованием программного продукта MOEAFramework [13]. Расчеты для алгоритма MAGAMO/A выполнялись с использованием Java-классов, созданных в AnyLogic и импортированных в IntelliJ IDEA для организации параллельных вычислений.




Рис. 5. Алгоритм агента-процесса (локальный ГА) в рамках модели MAGAMO/A

Оценка метрики "гиперобъем" (Hypervolume)

Тестовая оптимизационная задача	MAGAMO/A	$\epsilon$ -MOEA	NSGAII	SPEA2
<b>UF1</b> (30 переменных, 2 целевых функционала)	Min: 0.364 Median: 0.461 Max: 0.535 ( <b>30 c</b> )	Min: 0.321 Median: 0.459 Max: 0.539 (34 c)	Min: 0.136 Median: 0.479 Max: 0.544 (39 c)	Min: 0.416 <b>Median: 0.515</b> Max: 0.545 (84 c)
<b>DTLZ2_2</b> (11 переменных, 2 целевых функционала)	Min: 0.212 Median: 0.211 Max: 0.213 ( <b>20 c</b> )	Min: 0.213 <b>Median: 0.213</b> Max: 0.214 (23 c)	Min: 0.212 Median: 0.212 Max: 0.213 (29 c)	Min: 0.213 Median: 0.213 Max: 0.214 (232 c)
<b>DTLZ7_5</b> (24 переменных, 5 целевых функционалов)	Min: 0.671 <b>Median: 0.698</b> Max: 0.761 ( <b>22 c</b> )	Min: 0.386 Median: 0.428 Max: 0.745 (26 c)	Min: 0.602 Median: 0.657 Max: 0.695 (44 c)	Min: 0.608 Median: 0.672 Max: 0.708 (426 c)
<b>DTLZ7_7</b> (26 переменных, 7 целевых функционалов)	Min: 0.381 <b>Median: 0.551</b> Max: 0.668 ( <b>24 c</b> )	Min: 0.155 Median: 0.184 Max: 0.305 (26 c)	Min: 0.379 Median: 0.501 Max: 0.627 (43 c)	Min: 0.135 Median: 0.469 Max: 0.655 (731 c)
<b>ZDT5</b> (80 переменных, 2 целевых функционала)	Min: 0.843 <b>Median: 0.855</b> Max: 0.891 ( <b>11 c</b> )	Min: 0.777 Median: 0.843 Max: 0.872 (17 c)	Min: 0.841 Median: 0.850 Max: 0.873 (22 c)	Min: 0.842 Median: 0.850 Max: 0.881 (390 c)

Из табл. 2 следует, что для многокритериальных оптимизационных задач большой размерности среди сравниваемых алгоритмов наиболее эффективным (как по критерию временной эффективности, так и по критерию "гиперобъема") является предложенный адаптивный многоагентный генетический алгоритм MAGAMO/A.

Следует отметить, что тестовые оптимизационные задачи DTLZ7\_5, DTLZ7\_7 и ZDT5 являются достаточно сложными, например, для задачи DTLZ7\_7, характеризующейся наличием 26 искоемых переменных и 7 целевых функционалов, формируемый Парето-фронт имеет разрывы.

Отметим, что при решении стандартных малоразмерных многокритериальных оптимизационных задач целесообразность использования MAGAMO/A недостаточно обоснована. При этом наиболее близко по эффективности к нему находится алгоритм  $\epsilon$ -MOEA, предложенный в работе [10]. Однако недостатком последнего является необходимость подбора индивидуальных значений параметра  $\epsilon$  для каждой решаемой оптимизационной задачи. Для малоразмерных многокритериальных оптимизационных задач целесообразно использовать алгоритм NSGA-II [9] и его современные модификации NSGA-III [8], RVEA [6] и др.

### Заключение

В данной работе предложен новый подход к разработке адаптивного генетического оптимизационного алгоритма с использованием методов агентного моделирования. Особенностью данного подхода является поддержка механизма адап-

тивного управления ключевыми характеристиками ГА, в частности, значениями вероятностей операторов кроссинговера и мутации, их типами и другими важными характеристиками ГА, влияющими на разнообразие популяции, скорость сходимости ГА, качество Парето-оптимальных решений и др. В результате проведенных численных экспериментов продемонстрирована высокая эффективность предложенного алгоритма (MAGAMO/A) для задач многокритериальной оптимизации большой размерности.

Дальнейшим направлением исследования является реализация предложенного алгоритма с использованием MPI на языке программирования C++, интеграция MAGAMO/A с имитационными моделями агентного типа, применение технологии CUDA [24] для организации эффективных взаимодействий между агентами-процессами при параллельных вычислениях и др.

*Исследование выполнено за счет гранта Российского научного фонда (проект № 17-71-10116).*

### Список литературы

1. Akopov A. S., Beklaryan L. A., Saghatelyan A. K. Agent-based modelling for ecological economics: A case study of the Republic of Armenia // Ecological Modelling. 2017. Vol. 346. P. 99–118.
2. Akopov A. S., Beklaryan A. L., Saghatelyan A. K., Sahakyan L. V. Control system for ecological modernization of enterprises (on the example of the Republic of Armenia) // Business Informatics. 2016. N. 2 (36). P. 71–78.
3. Akopov A. S. Parallel genetic algorithm with fading selection // International Journal of Computer Applications in Technology. 2014. Vol. 49. N. 3/4. P. 325–331.
4. Akopov A. S., Hevencev M. A. A Multi-agent genetic algorithm for multi-objective optimization // Proceedings of IEEE International Conference on Systems, Man and Cybernetics, 2013. Manchester: IEEE, 2013. P. 1391–1395.

5. **Beklaryan A. L., Akopov A. S.** Simulation of Agent-rescuer Behaviour in Emergency Based on Modified Fuzzy Clustering // AAMAS'16: Proceedings of the 2016 International Conference on Autonomous Agents & Multiagent Systems. Richland: International Foundation for Autonomous Agents and Multiagent Systems, 2016. P. 1275–1276.
6. **Cheng R., Jin Y., Olhofer M., Sendhoff B.** A reference vector guided evolutionary algorithm for many-objective optimization // IEEE Transactions on Evolutionary Computation. 2016. Vol. 20. N. 5. P. 773–791.
7. **Coello Coello C. A., Lamont G. B., Van Veldhuizen D. A.** Evolutionary Algorithms for Solving Multi-Objective Problems. New York: Springer Science + Business Media LLC, NY, 2007. 800 p.
8. **Deb K., Jain H.** An evolutionary many-objective optimization algorithm using reference-point-based nondominated sorting approach, part i: Solving problems with box constraints // IEEE Transactions on Evolutionary Computation. 2014. Vol. 18, N. 4. P. 577–601.
9. **Deb K., Pratap A., Agarwal S., Meyarivan T.** A fast elitist multi-objective genetic algorithm: NSGA-II // IEEE Transactions on Evolutionary Computation. 2000. Vol. 6, N. 2. P. 182–197.
10. **Deb K., Mohan M., Mishra S.** A fast multi-objective evolutionary algorithm for finding well-spread Pareto-optimal solutions. KanGAL Report No. 2003002, Kanpur Genetic Algorithms Laboratory (KanGAL), Indian Institute of Technology, Kanpur, India, 2003.
11. **Knowles J., Corne D.** On metrics for comparing non-dominated sets // Proc. of Congress on Evolutionary Computation (CEC 2002), Honolulu, HI, 2002. P. 711–716.
12. **Goldberg D. E.** Genetic Algorithms in Search, Optimization and Machine Learning (1st ed.). Addison-Wesley Longman Publishing Co., Inc., Boston, MA, USA, 1989.
13. **Hadka D.** Beginner's Guide to the MOEA Framework. Great Space Independent Publishing Platform, 2017. 214 p.
14. **Hadka D., Reed P.** Diagnostic assessment of search controls and failure modes in many-objective evolutionary optimization // Evolutionary Computation, 2012. Vol. 20. N. 3. P. 423–452.
15. **Holland J. H.** Adaptation in natural and artificial systems. University of Michigan Press, Ann Arbor, 1975.
16. **Poli R.** Analysis of the publications on the applications of particle swarm optimisation // Journal of Artificial Evolution and Applications. 2008. Vol. 2008. P. 1–10.
17. **Whitley D., Rana S., Heckendorn R. B.** The Island Model Genetic Algorithm: On Separability, Population Size and Convergence // Journal of Computing and Information Technology. 1998. Vol. 7. P. 33–47.
18. **Zhang Q., Zhou Q., Zhao S., Suganthan P. N., Liu W., Tiwari S.** Multiobjective optimization Test Instances for the CEC 2009 Special Session and Competition. Technical Report CES-487, 2009.
19. **Zhang Q., Liu W., Li H.** The performance of a new version of MOEA/D on CEC09 unconstrained MOP test instances // Proc. of Congress on Evolutionary Computation (CEC 2009), Trondheim, Norway, 2009. P. 203–208.
20. **Zitzler E., Laumanns M., Thiele L.** SPEA2: Improving the Strength Pareto Evolutionary Algorithm For Multiobjective Optimization. Barcelona, Spain, International Center for Numerical Methods in Engineering (CIMNE), 2002.
21. **Березкин В. Е., Каменев Г. К., Лотов А. В.** Гибридные адаптивные методы аппроксимации невыпуклой многомерной границы Парето // Журнал вычислительной математики и математической физики. 2006. Т. 46, № 11. С. 2009–2023.
22. **Зинченко Л. А., Курейчик В. М.** Многоальтернативные генетические алгоритмы поиска экстремума функции // Известия Российской академии наук. Теория и системы управления. 2003. № 4. С. 82–91.
23. **Кныш Д. С., Курейчик В. М.** Параллельные генетические алгоритмы: обзор и состояние проблемы // Известия Российской академии наук. Теория и системы управления. 2010. № 4. С. 72–82.
24. **Лунин Д. В., Скворцов С. В.** Разработка параллельного генетического алгоритма для решения задачи коммивояжера на платформе CUDA // Системы управления и информационные технологии. 2015. Т. 60. № 2. С. 50–55.
25. **Мокшин В. В., Якимов И. М.** Метод формирования модели анализа сложной системы // Информационные технологии. 2011. № 5. С. 46–51.
26. **Хивинцев М. А., Акопов А. С.** Применение многоагентного генетического алгоритма для поиска оптимальных стратегических и оперативных решений // Бизнес-информатика. 2014. № 1 (27). С. 23–33.

**A. S. Akopov**, D. Sc. Professor, e-mail: aakopov@hse.ru,  
 National Research University Higher School of Economics, Moscow,  
 Central Economics and Mathematics Institute RAS, Moscow,  
**A. L. Beklaryan**, Ph. D., Associate Professor, e-mail: abeklaryan@hse.ru,  
 National Research University Higher School of Economics, Moscow,  
**N. K. Khachatryan**, Ph. D., Associate Professor, e-mail: nerses@cemi.rssi.ru, nkhachatryan@hse.ru,  
 National Research University Higher School of Economics, Moscow, 101000,  
 Central Economics and Mathematics Institute RAS, Moscow, 117418,  
**A. V. Fomin**, Ph. D., Senior Lecturer, e-mail: afomin@hse.ru,  
 National Research University Higher School of Economics, Moscow, 101000, Russian Federation

## Development of an Adaptive Genetic Optimization Algorithm using Agent Modeling Methods



This article presents a new approach to developing an adaptive genetic optimization algorithm (MAGAMO/A) using agent modeling techniques. The peculiarity of this approach is the support of the mechanism of adaptive control of key characteristics of GA, in particular, the values of the probabilities of crossover operators and mutations, their types and other important characteristics that affect the population diversity and the rate of convergence of GA. Support for adaptive control is provided by using the mechanism of agent state charts and the specified rules of transition between the corresponding states that determine the values of the control parameters of the GA at the individual level of each agent-process. The review of the most popular GAs used for multicriteria optimization, including SPEA2, NSGA, MOEA, etc., is reviewed. The main metrics for evaluating the effectiveness of such GAs (Hypervolume, Generational Distance, distance between solutions on the Pareto boundary, etc.) are considered. The efficiency of the developed approach in the solution of optimization problems of large dimension on several test examples and in comparison with other known GA is demonstrated. The main directions of further research in the field of development of agent-oriented genetic algorithms are formulated.

**Keywords:** genetic algorithm, Pareto front, evolutionary computation, accentual modeling, multi-objective optimization

## References

1. Akopov A. S., Beklaryan L. A., Saghatelyan A. K. Agent-based modelling for ecological economics: A case study of the Republic of Armenia, *Ecological Modelling*, 2017, vol. 346, pp. 99–118.
2. Akopov A. S., Beklaryan A. L., Saghatelyan A. K., Sahakyan L. V. Control system for ecological modernization of enterprises (on the example of the Republic of Armenia), *Business Informatics*, 2016, no. 2 (36), pp. 71–78.
3. Akopov A. S. Parallel genetic algorithm with fading selection, *International Journal of Computer Applications in Technology*, 2014, vol. 49, no. 3/4, pp. 325–331.
4. Akopov A. S., Hevencev M. A. A Multi-agent genetic algorithm for multi-objective optimization, in: *Proceedings of IEEE International Conference on Systems, Man and Cybernetics*, 2013. Manchester, IEEE, 2013, pp. 1391–1395.
5. Beklaryan A. L., Akopov A. S. Simulation of Agent-rescuer Behaviour in Emergency Based on Modified Fuzzy Clustering, in: *AAMAS'16: Proceedings of the 2016 International Conference on Autonomous Agents & Multiagent Systems. Richland: International Foundation for Autonomous Agents and Multiagent Systems*, 2016, pp. 1275–1276.
6. Cheng R., Jin Y., Olhofer M., Sendhoff B. A reference vector guided evolutionary algorithm for many-objective optimization, *IEEE Transactions on Evolutionary Computation*, 2016, vol. 20, no. 5, pp. 773–791.
7. Coello Coello C. A., Lamont G. B., Van Veldhuizen D. A. *Evolutionary Algorithms for Solving Multi-Objective Problems*, New York, Springer Science + Business Media LLC, NY, 2007, 800 p.
8. Deb K., Jain H. An evolutionary many-objective optimization algorithm using reference-point-based nondominated sorting approach, part i: Solving problems with box constraints, *IEEE Transactions on Evolutionary Computation*, 2014, vol. 18, no. 4, pp. 577–601.
9. Deb K., Pratap A., Agarwal S., Meyarivan T. A fast elitist multi-objective genetic algorithm: NSGA-II, *IEEE Transactions on Evolutionary Computation*, 2000, vol. 6, no. 2, pp. 182–197.
10. Deb K., Mohan M., Mishra S. *A fast multi-objective evolutionary algorithm for finding well-spread Pareto-optimal solutions*, KanGAL Report No. 2003002, Kanpur Genetic Algorithms Laboratory (KanGAL), Indian Institute of Technology, Kanpur, India, 2003.
11. Knowles J., Corne D. On metrics for comparing non-dominated sets, in *Congress on Evolutionary Computation (CEC 2002)*, Honolulu, HI, 2002, pp. 711–716.
12. Goldberg D. E. *Genetic Algorithms in Search, Optimization and Machine Learning* (1st ed.). Addison-Wesley Longman Publishing Co., Inc., Boston, MA, USA, 1989.
13. Hadka D. *Beginner's Guide to the MOEA Framework*. GreatSpace Independent Publishing Platform, 2017. 214 p.
14. Hadka D., Reed P. Diagnostic assessment of search controls and failure modes in many-objective evolutionary optimization, *Evolutionary Computation*, 2012, vol. 20, no. 3, pp. 423–452.
15. Holland J. H. *Adaptation in natural and artificial systems*, Ann Arbor, University of Michigan Press, 1975.
16. Poli R. Analysis of the publications on the applications of particle swarm optimisation, *Journal of Artificial Evolution and Applications*, 2008, vol. 2008, pp. 1–10.
17. Whitley D., Rana S., Heckendorn R. B. The Island Model Genetic Algorithm: On Separability, Population Size and Convergence, *Journal of Computing and Information Technology*, 1998, vol. 7, pp. 33–47.
18. Zhang Q., Zhou Q., Zhao S., Suganthan P. N., Liu W., Tiwari S. Multiobjective optimization Test Instances for the CEC 2009 Special Session and Competition. Technical Report CES-487, 2009.
19. Zhang Q., Liu W., Li H. The performance of a new version of MOEA/D on CEC09 unconstrained MOP test instances, in *Congress on Evolutionary Computation (CEC 2009)*, Trondheim, Norway, 2009, pp. 203–208.
20. Zitzler E., Laumanns M., Thiele L. SPEA2: Improving the Strength Pareto Evolutionary Algorithm For Multiobjective Optimization. Barcelona, Spain, International Center for Numerical Methods in Engineering (CIMNE), 2002.
21. Berezkin V. E., Kamenev G. K., Lotov A. V. Hybrid adaptive methods for approximating a nonconvex multidimensional Pareto frontier, *Computational Mathematics and Mathematical Physics*, 2006, vol. 46, no. 11, pp. 1918–1931.
22. Zinchenko L. A., Kureichik V. M. Multialternative genetic algorithms for the search of a function extremum, *Journal of Computer and Systems Sciences International*, 2003, vol. 42, no. 4, pp. 575–583.
23. Knysh D. S., Kureichik V. M. Parallel genetic algorithms: A survey and problem state of the art, *Journal of Computer and Systems Sciences International*, 2010, vol. 49, no. 4, pp. 579–589.
24. Lunin D. V., Skvortsov S. V. Razrabotka paralelnogo geneticheskogo algoritma dlja reshenija zadachi kommivojzhhjora na platforme CUDA, *Sistemy upravlenija i informacionnye tekhnologii*, 2015, vol. 60, no. 2, pp. 50–55.
25. Mokshin V. V., Yakimov I. M. Metod formirovanija modeli analiza slozhnoj sistemy, *Informacionnye Tehnologii*, 2011, no. 5, pp. 46–51.
26. Khivintcev M. A., Akopov A. S. Primenenie mnogo-agentnogo geneticheskogo algoritma dlja poiska optimal'nyh strategicheskij i operativnyh reshenij, *Biznes-informatika*, 2014, no. 1 (27), pp. 23–33.