

МУЛЬТИМОДАЛЬНАЯ ГЕНЕТИЧЕСКАЯ ОПТИМИЗАЦИЯ ЭКОНОМИЧЕСКИХ СИСТЕМ

Шаповалов Александр Борисович¹,

e-mail: shapovalov-ab@yandex.ru,

¹Московский университет имени С.Ю. Витте, г. Москва, Россия

В статье постулируется взаимодействие развивающихся экономических систем с биосферой, отклоняющейся от устоявшихся норм. Именно это актуализирует поиск наиболее оптимальных решений этого взаимодействия. Поэтому предложена оптимизация взаимодействия достижением допустимого компромисса между эффективностью экономических систем и безопасностью биосферы на основе генетических алгоритмов. В качестве научно-методического подхода предопределяются непрерывные механизмы мультимодальной генетической оптимизации экономических систем.

Ключевые слова: мультимодальность, генетический алгоритм, экономические системы, биосфера, оптимизация, функция Растргина

MULTIMODAL GENETIC OPTIMIZATION OF ECONOMIC SYSTEMS

Shapovalov A.B.¹,

e-mail: shapovalov-ab@yandex.ru,

¹Moscow Witte University, Moscow, Russia

The article postulates the interaction of developing economic systems with the biosphere, deviating from established norms. It is this that actualizes the search for the best solutions to this interaction. Therefore, the optimization of the interaction of achieving an acceptable compromise between the efficiency of economic systems and the safety of the biosphere based on genetic algorithms is proposed. As a scientific and methodical approach, continuous mechanisms of multimodal genetic optimization of economic systems are predetermined.

Keywords: multimodality, genetic algorithm, economic systems, biosphere, optimization, Rastrigin function

DOI 10.21777/2587-554X-2022-4-55-61

Введение

Несомненна актуальность современного взаимодействия стремительно развивающихся экономических систем с биосферой, флуктуирующей от устоявшихся норм [1].

Стремительно развитие современных экономических систем. Интенсифицируется трансформация ресурсов разнообразными (СИМ)¹ комплексными автоматизированными системами, технологическими прорывами, например, 3D аддитивной (послойного наращивания и синтеза объектов) печати² во всех направлениях экономических систем [2].

Современная трансформация ресурсов экономическими системами сопровождается генерацией отходов. Устойчивый рост³ вовлекаемых экономическими системами природных ресурсов (рост более 8 % за два года) сопровождается устойчивым сокращением (с 9,1 до 8,6 % за два года) использования отходов.

Генерируемые экономическими системами отходы определяют более чем на 30 % биологическую состоятельность социума [3]. Как итог – современные отходы экономических систем, поступающие в биосферу, дестабилизируют социум, а, соответственно, и сами экономические системы.

¹ СИМ – computer-integrated manufacturing, концепция управления всеми производственными процессами.

² Достижения в области аддитивного производства в 2022 году. – URL: <https://3dtoday.ru/blogs/stalker18118/dostizeniya-v-oblasti-additivnogo-proizvodstva-v-2022-godu> (дата обращения: 10.10.2022). – Текст: электронный.

³ CGRI 2021. Retrieved from. – URL: <https://www.circularity-gap.world/2021> (дата обращения: 10.10.2022). – Текст: электронный.

Поэтому оперативная адаптация экономических систем к изменяющимся как эндогенным, так и экзогенным факторам требует их оптимизации (лат. *optimus* – «наилучший», «наиболее соответствующий определенным условиям задачи»), которая выражается количественными критериями (минимум затрат, минимум времени и выбросов, максимум прибыли и т.п.).

Оптимизация экономических систем

Оптимизация экономических систем может быть сведена к задаче поиска множества значений переменных аргументов, задаваемых на произвольных множествах и обеспечивающих оптимальные сочетания значений критериев. Исходя из этого, постулируется, что (целевая функция) каждому элементу одного множества соответствует исключительно один элемент второго множества.

В результате постановка задачи выглядит следующим образом:

Определяется целевая функция $f(x) = f(x_1, \dots, x_n)$ (1) на множестве допустимых решений $D \in R^n$. Необходимо найти условное глобальное экстремальное значение $f(x)$. Например, находится минимум функции $f(x)$ на множестве D

$$f(x^*) = \min_{x \in D} (f(x)), \quad (1)$$

где $D = \{x | x_i \in [a_i, b_i], i = 1, \dots, n\}$.

Из чего логично следует, что целевая функция, в широком смысле, формализуется математическим выражением критериев качества одного объекта (решения, системы, процесса и т.п.) в сравнении с другим. Поэтому оптимизация сводится к нахождению экстремумов (минимума или максимума) целевой функции в области конечномерного векторного пространства, ограниченного набором линейных и/или нелинейных равенств и/или неравенств. Таким образом, оптимизация целевой функции определяется набором значений аргументов (переменных) в рамках наложенных на них технических ограничений в форме равенств и неравенств.

Прикладная оптимизация на основе тестовых функций (искусственных ландшафтов) позволяет оценить характеристики алгоритмов оптимизации: скорость сходимости, точность, робастность (устойчивость к помехам), общая производительность.

Классическая оптимизация (ньютоновские, сопряженных градиентов, допустимых направлений, барьерные и т.д.) сводится к глобальному решению задачи только на выпуклых функциях [3].

Однако подавляющее большинство практических задач экономических систем обладают большой размерностью (от десятков до сотен переменных) и многочисленными локальными экстремальными решениями. Собственно, именно это и отражается в сложном рельефе целевой функции. Множество локальных экстремумов целевой функции предопределяет ее мультимодальность – более чем одну «моду» или оптимум. Поэтому подавляющее большинство практических экстремальных задач оказываются невыпуклыми [3].

Невыпуклые мультимодальные функции имеют один или несколько ложных оптимумов. С другой стороны, возможно наличие и нескольких глобальных оптимумов, например, несколько различных значений аргументов функции, при которых она достигает минимума, что иллюстрирует представленная на рисунке 1 мультимодальная функция Растригина⁴ двух переменных аргументов, тестирующая эффективность алгоритмов для одной цели оптимизации.

Для проведения исследований алгоритмов оптимизации используются множество тестовых функций (практически около 30)⁵. В зависимости от специфики тестирования различают функции для одной цели оптимизации, условной оптимизации и многокритериальной оптимизации [4]. Это позволяет проводить объективное сравнение разных алгоритмов оптимизации.

⁴ Предложена в 1974 году Леонардом Растригиным (1929–1998). В 1991 году была обобщена на высшие размерности (Mühlenbein H., Schomisch D. and Born J. The Parallel Genetic Algorithm as Function Optimizer. Parallel Computing, 17, pages 619–632, 1991).

⁵ Тестовые функции для глобальной оптимизации. – URL: <https://github.com/Harrix/HarrixTestFunctions> (дата обращения: 20.10.2022). – Текст: электронный.




Рисунок 1 – Функция Растригина для двух переменных аргументов⁶

Генетический алгоритм оптимизации

Вычислительные методы поиска решения перебором всевозможных вариантов при увеличении шага теряют точность. Возможно, за максимальное может быть принято значение на склоне глобального максимума. При уменьшении шага очевидно точность растет, но и увеличивается (часто до неприемлемых величин) время расчета. Методы случайного исчисления тем более не обеспечивают достоверностью. Поэтому вычислительные методы неприменимы к нахождению абсолютных экстремумов мультимодальных функций.

Вполне естественным образом природная биологическая самоорганизация на основе генетических механизмов послужила предпосылкой для разработки сложных алгоритмов решения различных оптимизационных задач [5; 6]. Аналогично естественному генетическому отбору в природе создаются несколько групп особей по целому ряду итераций, случайным подбором, комбинированием и вариацией искомым параметров. Такой механизм позволяет определять глобальные или близкие к глобальным оптимумам решения.

Генетические алгоритмы оперируют не одним решением, а совокупностью особей (популяцией), которые представляют собой строки, кодирующие одно из решений задачи. Функция приспособленности среди всех особей популяции выделяет наиболее приспособленных (более подходящие решения). Выделенные особи скрещиваются и дают потомство, а наихудшие (плохие решения) удаляются из популяции и не дают потомства. В итоге преобразования одного конечного множества промежуточных решений в другое выделяются особенности:

- каждая популяция состоит исключительно из «жизнеспособных» хромосом;
- каждая новая популяция «лучше» (в смысле целевой функции) предыдущей;
- каждая последующая популяция зависит исключительно от предыдущей [7].

Фактически, работа генетического алгоритма заключается в циклической последовательности выполняемых селекции, скрещивания и генерации все новых и новых поколений. В этом процессе выживают только самые приспособленные особи, то есть самые оптимальные решения. На рисунке 2 представлена блок-схема работы генетического алгоритма.

⁶ Источник: https://ru.wikipedia.org/wiki/Функция_Растригина.

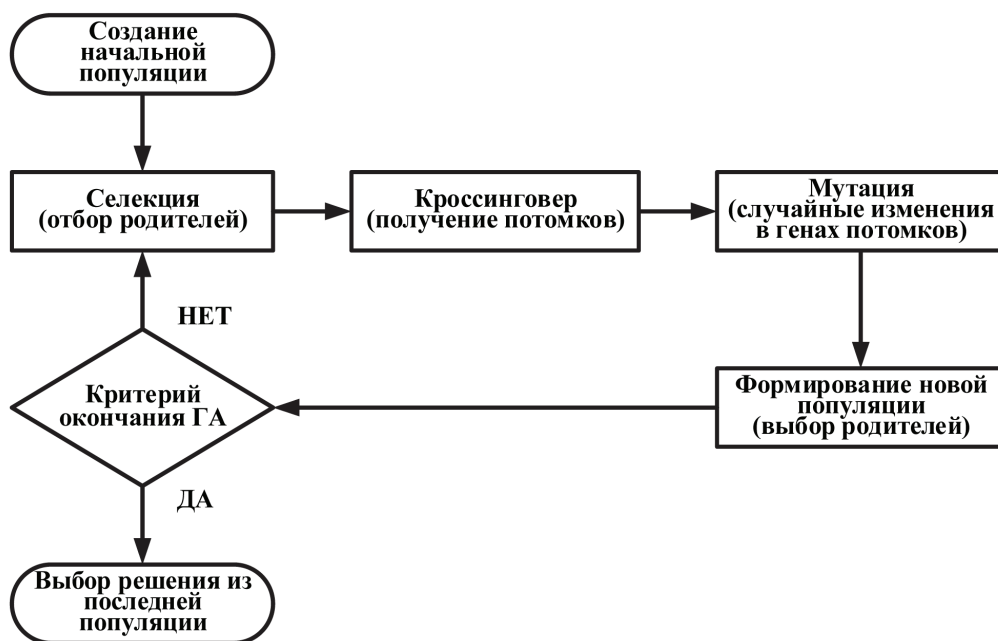


Рисунок 2 – Блок-схема простого классического генетического алгоритма⁷

Как следует из блок-схемы, основные принципы работы генетического алгоритма реализуются следующим образом:

1. Начальная популяция формируется случайным образом генерацией n хромосом (особей) и не изменяется в течение работы всего генетического алгоритма. Каждая особь генерируется как случайная L -битная строка, где L – длина кодировки особи, длина одинакова для особей.

2. Генерация промежуточной популяции (*intermediate generation*) и отбор (*selection*) текущего поколения.

3. Скрещивание (*recombination*) особей промежуточной популяции и кроссинговер (бинарная рекомбинация) (*crossover*) – получение двух потомков от двух родителей.

4. Мутации (*mutation*) необходимы для «выбивания» популяции из локального экстремума, препятствуя преждевременной сходимости. Для мультимодальных функций применяют самоадаптирующуюся оценку вероятности мутации.

5. Формирование новой популяции особями пропорционально их приспособленности. Наиболее приспособленные особи могут записываться в популяции неоднократно. Наименее приспособленные с большой вероятностью вообще не попадут в новую популяцию. Набор особей новой популяции получает право размножаться.

6. Определяется остановка итерации, при удовлетворении лучшим ответом на данном шаге. Генетический алгоритм не предполагает 100 % точность в оптимальном решении. Поэтому существуют разные критерии остановки.

Показательно сравнение быстродействия генетического алгоритма и метода перебора решений [8]. Так, на рисунке 3 представлена зависимость времени решения задачи оптимизации методом перебора от заданной точности поиска и количества параметров от 1 до 4. Решение той же задачи на основе генетического алгоритма представлено на рисунке 4 при тех же параметрах (1–4).

Рост времени (рисунок 3) поиска решения переборным методом от точности оценивается как экспоненциальный [8]. Рост времени же работы генетического алгоритма (рисунок 4) прямо пропорционален требуемой точности. Из чего следует, что для сложных задач генетические алгоритмы обеспечивают большее быстродействие⁸ без потери точности. Более того, зависимость времени работы

⁷ Разработан автором.

⁸ NeuroProject: AI & data analysis. «НейроПроект», 1998–2011. – URL: <http://neuroproject.ru/> (дата обращения: 15.10.2022). – Текст: электронный.

генетического алгоритма от точности на небольшом интервале позволяет достоверно оценить время достижения необходимой точности.




Рисунок 3 – Зависимость времени поиска решения методом перебора от точности и количества параметров (1–4) [8]




Рисунок 4 – Зависимость времени поиска решения посредством генетического алгоритма от точности и количества параметров (1–4) [8]

Таким образом, можно утверждать, что генетические алгоритмы ускоряют решение задачи в 100–1000 раз, что крайне актуально при большем количестве переменных [6]. Кроме того, генетические алгоритмы находят решение, даже когда точное решение не может быть найдено или его поиск представляет вычислительную сложность.

Многочисленные исследования генетических алгоритмов в программной среде Matlab выявили устойчивые тенденции в их реализации.

Так, размер популяции не влияет на точность работы алгоритма, а количество особей определяется поставленной задачей [9]. Установлено, что каждая приспособленная особь представляет одно из

решений поставленной задачи [8]. При большом количестве итераций наблюдается смещение данных в сторону минимума целевой функции [9]. На маленьких популяциях наблюдается преждевременная сходимость классических генетических алгоритмов [10].

Одним из наиболее важных преимуществ генетических алгоритмов является толерантность к поведению функции и влиянию возможных разрывов на процессы оптимизации [11].

Мультимодальная оптимизация возможна и с добавлением второй цели посредством образования слабого парето-оптимального фронта на основе самоадаптивного генетического алгоритма без предварительного указания параметров [12].

Генетические алгоритмы эффективны не только для решения традиционных оптимизационных задач, но и позволяют выбирать оптимальные структуры иерархических нейронных сетей, как основы управления сложных систем [11]. Из чего следует, что генетические алгоритмы позволяют синтезировать нейронные сети. Таким образом, генетические алгоритмы перспективны при создании искусственного интеллекта.

Вполне логично, что генетические алгоритмы объективно могут составить основу научно-методического подхода по созданию механизмов согласования стремительно развивающихся экономических систем в условиях взаимодействия с флуктуирующей от устоявшихся норм биосферой.

Заключение

Актуальна задача согласования стремительно развивающихся экономических систем в условиях взаимодействия с флуктуирующей биосферой. Основу научно-методического подхода по поиску наиболее оптимальных решений предопределяет использование генетического алгоритма.

При этом под оптимизацией качества согласования экономических систем и биосферы подразумевается достижение допустимого компромисса между эффективностью экономических систем и безопасностью биосферы.

Важно отметить, что динамично изменяющиеся параметры как экономических систем, так и биосферы предопределяют непрерывность механизмов мультимодальной генетической оптимизации экономических систем.

Список литературы

1. Шаповалов А.Б. Основы энергогенерации: монография. – М.: МАКС Пресс. – 2021. – 224 с.
2. Busse A., Meudt T., Metternich J. Einsatz digitaler Systeme zur Prozessüberwachung // Zeitschrift für wirtschaftlichen Fabrikbetrieb: ZWF. – 2018. – Vol. 112, No. 10. – P. 652–657.
3. Черноуцкий И.Г. Практическая оптимизация и невыпуклые задачи // Научно-технические ведомости СПбГПУ. – 2013. – № 4 (176). – С. 79–86.
4. Сергиенко А.Б. Тестовые функции для глобальной оптимизации. – Красноярск: Изд-во СГАУ, 2015. – 112 с.
5. Shapovalov A.B. The Criterion for the Existence of Ecology as an Area of a Chain Process of Continuous Directed Self-organization / In: A.V. Semenov, I.A. Sokolov (eds) // Sustainable Development: Society, Ecology, Economy. Earth and Environmental Sciences Library. – Springer, Cham, 2021. – P. 9–15.
6. Карпенко А.П. Современные алгоритмы поисковой оптимизации. Алгоритмы, вдохновленные природой. – М.: Изд-во МГТУ им. Н.Э. Баумана, 2017. – 447 с.
7. Растринин Л.А. Статистические методы поиска. – М.: Наука, 1968. – 376 с.
8. Иванченко Е.П., Выходцев Я.Н. Тестирование простого генетического алгоритма // Записки Горного института. – 2012. – Т. 196. – С. 319–324.
9. Эволюционный алгоритм для задачи оптимизации мультимодальной функции / П.Е. Вдовых, К.А. Елсуфьев, Я.И. Муравьева [и др.] // COLLOQUIUM-JOURNAL. – 2018. – № 10-1. – С. 11–14.
10. Рыбак В.А. Применение генетических алгоритмов для решения задач оптимизации качества окружающей среды // Системный анализ и прикладная информатика. – 2015. – № 2. – С. 65–70.
11. Кондратьев Т.Н. Эволюционные вычисления: нейронные сети и генетические алгоритмы // Международная конференция по мягким вычислениям и измерениям. – 2019. – Т. 1. – С. 418–421.

12. Saha A., Deb K. A Bi-criterion Approach to Multimodal Optimization: Self-adaptive Approach // Lecture Notes in Computer Science. – 2010. – Vol. 6457. – P. 95–104.

References

1. Shapovalov A.B. Osnovy energogeneracii: monografiya. – M.: MAKS Press. – 2021. – 224 s.
2. Busse A., Meudt T., Metternich J. Einsatz digitaler Systeme zur Prozessüberwachung // Zeitschrift für wirtschaftlichen Fabrikbetrieb: ZWF. – 2018. – Vol. 112, No. 10. – P. 652–657.
3. Chernoruckij I.G. Prakticheskaya optimizaciya i nevyuklye zadachi // Nauchno-tehnicheskie vedomosti SPbGPU. – 2013. – № 4 (176). – S. 79–86.
4. Sergienko A.B. Testovye funkcii dlya global'noj optimizacii. – Krasnoyarsk: Izd-vo SGAU, 2015. – 112 s.
5. Shapovalov A.B. The Criterion for the Existence of Ecology as an Area of a Chain Process of Continuous Directed Self-organization / A.V. Semenov, I.A. Sokolov (eds) // Sustainable Development: Society, Ecology, Economy. Earth and Environmental Sciences Library. – Springer, Cham, 2021. – P. 9–15.
6. Karpenko A.P. Sovremennye algoritmy poiskovoj optimizacii. Algoritmy, vdohnovlennye prirodoj. – M.: Izd-vo MGTU im. N.E. Baumana, 2017. – 447 s.
7. Rastrigin L.A. Statisticheskie metody poiska. – M.: Nauka, 1968. – 376 s.
8. Ivanchenko E.P., Vyhodcev Ya.N. Testirovanie prostogo geneticheskogo algoritma // Zapiski Gornogo instituta. – 2012. – T. 196. – S. 319–324.
9. Evolyucionnyj algoritm dlya zadachi optimizacii mul'timodal'noj funkicii / P.E. Vdovyh, K.A. El'suf'ev, Ya.I. Murav'yova [i dr.] // COLLOQUIUM-JOURNAL. – 2018. – № 10-1. – S. 11–14.
10. Rybak V.A. Primenenie geneticheskikh algoritmov dlya resheniya zadach optimizacii kachestva okruzhayushchej sredy // Sistemnyj analiz i prikladnaya informatika. – 2015. – № 2. – S. 65–70.
11. Kondrat'ev T.N. Evolyucionnye vychisleniya: nejronnye seti i geneticheskie algoritmy // Mezhdunarodnaya konferenciya po myagkim vychisleniyam i izmereniyam. – 2019. – T. 1. – S. 418–421.
12. Saha A., Deb K. A Bi-criterion Approach to Multimodal Optimization: Self-adaptive Approach // Lecture Notes in Computer Science. – 2010. – Vol. 6457. – R. 95–104.