

А.А. ТЕРЗЯН, Г.Г. САРКИСЯН

ГЕНЕТИЧЕСКИЕ АЛГОРИТМЫ ПРИНЯТИЯ РЕШЕНИЯ

Рассмотрены генетические алгоритмы в сопоставлении с алгоритмами случайного поиска. В результате проведения значительного объема численных экспериментов показано, что эти алгоритмы, объединенные использованием моделей управления живой природы, эффективно решают многопараметрические нелинейные экстремальные задачи принятия решения.

Ключевые слова: генетические алгоритмы, алгоритмы случайного поиска, сопоставительный анализ алгоритмов принятия решения.

Алгоритмы принятия решения условно можно подразделить на:

- алгоритмы, основанные на моделях поведения живых организмов;
- алгоритмы, основанные на моделях эволюции живых организмов;
- алгоритмы, основанные на точных математических процедурах.

К первой группе относятся разнообразные алгоритмы случайного поиска. Введение элемента случайности как источника возможностей для организации целенаправленного управления придает этим алгоритмам ряд привлекательных особенностей, в частности, исключительно высокую гибкость и весьма слабую зависимость времени поиска экстремума от числа варьируемых переменных. В развитии алгоритмов случайного поиска значительную роль сыграли работы Л. Растригина [1].

Вторую группу составляют генетические алгоритмы, основанные на теории Дарвина о эволюции живых организмов с помощью естественного отбора (1857г.), использующего, в свою очередь, концепцию Мальтуса о популяциях (1798г.). Эти основополагающие принципы эволюции биологических систем как эффективное проявление оптимального управления в живой природе впервые были реализованы в виде машинных программ лишь в середине 80-х годов прошлого столетия Дж. Голандом [2]. Данное направление нелинейного математического программирования в настоящее время бурно развивается, к сожалению зачастую приобретая эмоциональный характер. Генетические алгоритмы также обладают высокой степенью гибкости и малой зависимостью от числа варьируемых переменных.

Наконец, к третьей группе следует отнести градиентные методы, методы последовательного спуска и др. Эта группа алгоритмов имеет свои преимущества. В частности, градиентные методы, в отличие от методов первых двух групп, осуществляют в каждой текущей точке гиперпространства поиска движение по наилучшему направлению. Вместе с тем эта особенность в значительной мере теряет свою привлекательность при решении нелинейных экстремальных задач с ограничениями, где эффективность поиска в основном определяется стратегией движения вдоль поверхностей ограничений. К привлекательным особенностям методов последовательного спуска следует отнести естественную

возможность решения целочисленных и дискретных экстремальных задач. Этими возможностями обладают также генетические алгоритмы. К недостаткам алгоритмов третьей группы следует отнести малую гибкость (скорее, отсутствие гибкости) и значительную зависимость времени от числа варьируемых переменных.

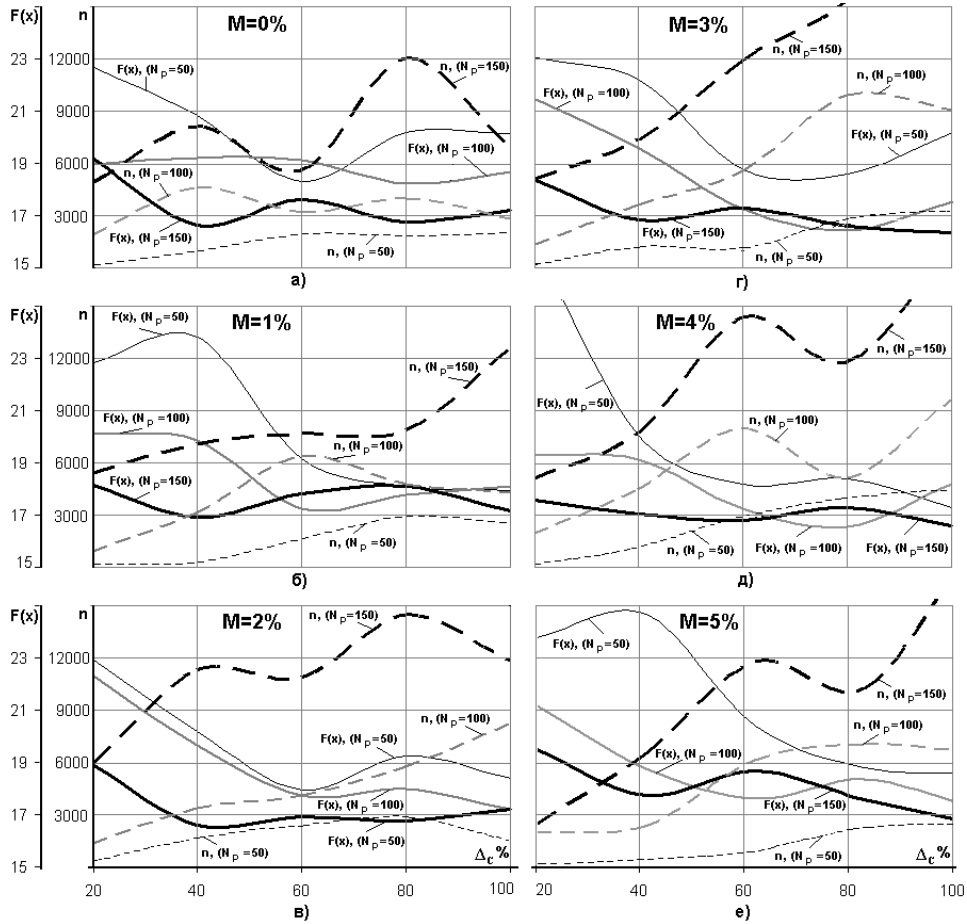


Рис.1. Зависимости целевой функции ($F(x)$) и количества обращений (n) к модели от селекции (количества отбираемых особей в популяции $\Delta_c, \%$ для скрещивания) при различных значениях мутации ($M, \%$) и начальной популяции (N_p) в генетическом алгоритме

Следует также отметить, что градиентные и генетические алгоритмы, а также ряд алгоритмов случайного поиска объединяет весьма существенное обстоятельство – естественная возможность параллельного счета, что может

стать решающим фактором при использовании вычислительных кластеров или GRID технологий.

Рассмотрим генетические алгоритмы в сопоставлении с алгоритмами случайного поиска при использовании последовательных вычислителей. Эти алгоритмы, как было отмечено, объединяет использование моделей управления живой природы, и потому они отличаются большим разнообразием. Среди этого разнообразия алгоритмов в численном эксперименте из методов случайного поиска примет участие гиперсферический случайный поиск с пересчетом [3], предусматривающий в случае неудачного пробного шага продолжение m случайных выборок (при максимальном числе m_{max}) из исходной точки до первой удачной выборки и рабочий шаг в этом направлении. Принятый алгоритм предусматривает также управление длиной шага перемещения h_t . Так, если количество попыток превосходит заданное число m , шаг уменьшается (делится пополам). В случае успешного продвижения, т.е. когда лучшая точка находится при числе попыток меньше m , предусматривается увеличение (удвоение) шага (не более h_{max}). Оптимальная точка считается найденной, если в процессе поиска экстремума шаг снижается до предельно заданного h_{min} .

Рассмотренный генетический алгоритм, имитирующий эволюционный отбор в живой природе, по сравнению со своим природным аналогом является простейшим, вместе с тем содержит все основные операторы природного аналога – селекцию, скрещивание и мутацию. На каждом шаге итерации объектом рассмотрения служит популяция возможных решений задачи (хромосом, состоящих из генов). Причем эти решения могут быть представлены как в физических единицах, так и в кодированном (битами) виде. В нашем случае хромосомы представлены в кодированном виде.

Начальная популяция N_p образуется посредством генератора псевдослучайных чисел. Оператор селекции, в соответствии со значениями функции приспособленности (близости к решению задачи), осуществляет отбор хромосом с целью их участия в последующем процессе репродукции (путем скрещивания), т.е. порождения новых элементов популяции. После соответствующей селекции оператор скрещивания (кроссовер) осуществляет обмен частями хромосом между двумя (либо более) хромосомами в популяции. Как показали наши исследования, вид кроссовера значительно влияет на эффективность генетического алгоритма. Здесь возможны одноточечный, либо многоточечный кроссовер. В случае одноточечного кроссовера родительские структуры случайным образом разрываются на два сегмента, затем соответствующие сегменты различных родителей объединяются, образуя два генотипа потомков. В алгоритме предусмотрен также оператор мутации, который осуществляет стохастическое изменение генетической строки, т.е. части хромосом.

При синтезе поискового алгоритма важное значение имеет критерий останова. Если в алгоритме случайного поиска критерием останова нами принят шаг поиска (h_t), т.е. процесс поиска завершается при достижении наперед заданного минимального значения шага (h_{min}), то в генетическом алгоритме в качестве критерия останова принято минимальное значение (ξ) отклонения целевой функции (в худшей строке популяции) в $k+1$ -й и k -й итерациях.

Успех оптимизации во многом определяется выбором поискового метода, набором управляющих операторов (структурная адаптация), что, в свою очередь,

обусловлено природой задачи - ее особенностями. Эффективность поиска не в меньшей мере зависит от значений управляющих параметров (параметрическая адаптация). Небольшие изменения значений управляющих параметров могут изменить результат поиска.

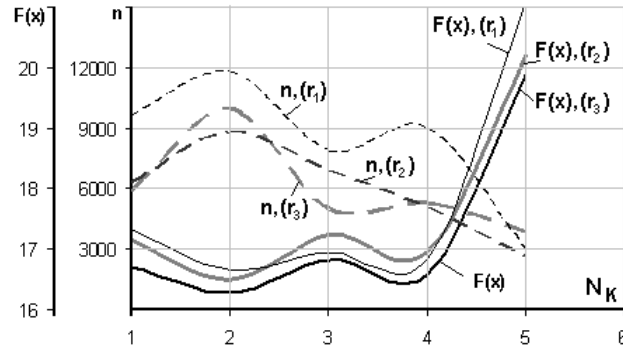


Рис.2. Зависимости целевой функции ($F(x)$) и количества обращений (n) к модели от вида (количества точек разрыва хромосомы) кроссовера (спаривания) N_k из различных начальных точек (r) в генетическом алгоритме

Для исследования работоспособности алгоритма в различных ситуациях и сравнительной оценки эффективности алгоритмов в одинаковых ситуациях обычно используют тестовые функции. Однако, несмотря на большое разнообразие, существующие тестовые функции не могут в полной мере отразить все особенности реальных задач и пока остаются лишь средством для имитации экстремальных задач без ограничений.

В качестве тестовой модели в работе принята модель синхронного явнополюсного генератора мощностью 20 кВт. Сформулируем следующую задачу оптимизации.

Найти минимальный активный объем генератора $D_a^2 l$ вариацией внешнего диаметра статора D_a , относительного диаметра расточки статора D_i/D_a , относительной высоты спинки статора $2h_a/(D_a - D_i)$, относительной ширины паза d/t , длины статора l , числа эффективных проводников в пазу S_n , коэффициента полюсного перекрытия α_i , относительной ширины полюса b_m/b_p , относительного воздушного зазора δ/δ_m , плотности тока возбуждения J_b при следующих ограничениях в виде неравенств: КПД η , отношение короткого замыкания ОКЗ, максимальные значения индукций в зубцах B_z , спинке $B_{сп}$, полюсах B_p , продольные переходная и сверхпереходная реактивности x'_d и x''_d , фактор нагрева статора $AS \cdot J_a$, потери в обмотке возбуждения P_b , суммарная масса меди $G_{мед}$, сечение, занимаемое катушкой возбуждения $S_{вт}$.

Таким образом, решается нелинейная многопараметрическая задача

$$F(\bar{x}) = F(x_1, x_2, \dots, x_k) \rightarrow \min_{x \in D} \Rightarrow \bar{x}^*$$

с множеством ограничений типа неравенств

$$D: \varphi_i(\bar{x}) = \varphi_i(x_1, x_2, \dots, x_k) \geq 0, \quad i = 1, 2, \dots, l.$$

Для входа в допустимую область D используется дополнительная неотрицательная функция [3]

$$Q(\bar{x}) = \sum_{\varphi_i < 0} \frac{|\varphi_i|}{|\varphi_i| + 1}.$$

При оценке эффективности алгоритмов нас прежде всего будет интересовать скорость и точность сходимости поиска. Под скоростью поиска будем понимать значение, обратное количеству обращений к модели. При такой формулировке скорость сходимости является интегральным критерием и определяет эффективность алгоритма поиска в течение всех шагов от некоторой исходной позиции до достижения цели.

Для настройки управляющих параметров рассмотренных алгоритмов проведем комплекс численных экспериментов на сформулированной тестовой модели.

На рис.1,2 представлены результаты численных исследований генетического алгоритма с различными значениями управляющих параметров. Приведенные результаты весьма убедительно свидетельствуют о значительной зависимости эффективности генетического алгоритма от численных значений управляющих параметров, что, в свою очередь, подтверждает важность параметрической адаптации [4].




Рис.3. Зависимости целевой функции ($F(x)$) и количества обращений (n) к модели от количества случайных выборок (m) в текущей точке при различных значениях максимального количества выборок (m_{\max}) в алгоритме гиперсферического случайного поиска

Из анализа результатов численных экспериментов (рис.1) явствует, что наилучший результат по целевой функции ($F(x)=16,5$) получен при числе обращений $n=5500$ и следующих управляющих параметрах: начальная популяция $N_p=100$, селекция $\Delta_c = 80\%$, мутация $M= 4\%$ (рис.1 д).

Таблица

strand	Координаты варьируемых переменных в оптимальной точке										$F(x)10^3 \text{ см}^3$	n
	X ₁	X ₂	X ₃	X ₄	X ₅	X ₆	X ₇	X ₈	X ₉	X ₁₀		
Генетический алгоритм (M=4%, N_k=2, N_p=100, Δ_c = 80%)												
84	381,0	0,686	0,687	0,598	113,8	11	0,768	0,618	1,35	3,56	16,51502	8580
24	386,8	0,686	0,698	0,594	112,2	11	0,770	0,621	1,36	3,54	16,30320	9820
1005	386,4	0,687	0,701	0,594	112,3	11	0,770	0,600	1,36	3,56	16,39212	10460
18	403,0	0,680	0,668	0,578	112,9	11	0,766	0,603	1,36	3,49	16,81780	4940
79	381,1	0,684	0,673	0,598	116,2	11	0,770	0,626	1,35	3,56	16,74127	9060
238	383,2	0,686	0,701	0,594	113,0	11	0,769	0,597	1,35	3,59	16,29848	10260
401	384,3	0,686	0,705	0,594	112,0	11	0,770	0,622	1,36	3,60	16,33808	12940
319	388,9	0,683	0,712	0,594	112,1	11	0,769	0,911	1,36	3,59	16,56253	10460
1890	396,8	0,681	0,666	0,582	112,5	11	0,764	0,623	1,36	3,56	16,78358	7420
6222	381,0	0,689	0,687	0,594	115,3	11	0,769	0,627	1,36	3,60	16,65403	11100
Алгоритм случайного поиска (m=75, m_{max}=100, h_{нач}=0,1, h_{max}=0,5, h_{min}=0,00001)												
84	381,0	0,689	0,708	0,593	113,5	11	0,770	0,624	1,35	3,58	16,47076	8681
24	381,0	0,678	0,670	0,582	112,9	11	0,770	0,609	1,35	3,57	16,38584	6011
1005	381,0	0,687	0,690	0,595	112,6	11	0,770	0,627	1,35	3,54	16,33933	4975
18	381,0	0,688	0,693	0,593	113,5	11	0,770	0,628	1,35	3,46	16,46999	6671
79	381,0	0,685	0,692	0,585	116,3	11	0,770	0,581	1,35	3,59	16,88878	7063
238	381,0	0,678	0,671	0,582	112,8	11	0,770	0,604	1,35	3,58	16,37243	6589
401	381,0	0,685	0,694	0,595	112,6	11	0,770	0,630	1,35	3,57	16,34419	3897
319	381,0	0,676	0,663	0,583	113,8	11	0,770	0,609	1,35	3,57	16,52593	5682
1890	381,0	0,692	0,693	0,595	114,5	11	0,770	0,538	1,35	3,60	16,61675	6339
6222	381,0	0,683	0,680	0,596	113,6	11	0,770	0,629	1,358	3,46	16,50239	3796

На рис.2 приведены зависимости целевой функции $F(x)$ и количество обращений к модели от вида кроссовера, т.е. от количества точек разрыва хромосомы N_k в генетическом алгоритме. Как видно из рисунка, наилучшие результаты получены при двухточечном кроссовере. Для настройки управляющих параметров принятого алгоритма случайного поиска на рис.3 представлены соответствующие результаты численных экспериментов.

Из рис.3 видно, что такой же результат $F(x)=16,5$, полученный генетическим алгоритмом, случайным поиском достигается за 3800 обращений к модели при следующих управляющих параметрах : $m=75$, $m_{max}=100$.

Приняв полученные настройки в качестве базовых управляющих параметров, был проведен комплекс численных экспериментов по решению поставленной задачи генетическим алгоритмом и алгоритмом случайного поиска из различных начальных позиций (strand).

Из сопоставительного анализа полученных результатов (табл.) явствует, что точность рассмотренных алгоритмов примерно одинаковая. При этом поиск по генетическому алгоритму достигает цели за несколько большее количество обращений к модели, чем по случайному поиску. Вместе с тем следует отметить, что в случае использования параллельного вычислителя картина может быть иной.

СПИСОК ЛИТЕРАТУРЫ

1. **Растрингин Л.А.** Статистические методы поиска.- М.: Наука, 1968. - 376 с.
2. **Holland J.H.** Adaptation in Natural and Artificial Systems, University of the Michigan Press, 1975.
3. **Терзян А.А.** Автоматизированное проектирование электрических машин.- М.: Энергоатомиздат, 1983. – 256 с.
4. **Терзян А.А., Сукиасян Г.С., Казарян Д.С., Григорян А.А.** К автоматической адаптации в задачах принятия решений // Изв. НАН РА и ГИУА. Сер.ТН. – 2003. - Т.56, №3. - С. 468-475.

ГИУА. Материал поступил в редакцию 12.11.2004.

Հ.Ա. ԹԵՐԶՅԱՆ, Գ.Գ. ՍԱՐԳՍՅԱՆ

ՈՐՈՇՈՒՄՆԵՐԻ ԸՆԴՈՒՆՄԱՆ ԳԵՆԵՏԻԿ ԱԼԳՈՐԻԹՄԵՐ

Դիտարկված են գենետիկ ալգորիթմերը՝ պատահական որոնման ալգորիթմ-ների համադրությամբ: Մեծածավալ թվային գիտափորձի իրականացման արդյուն-քում ցույց է տրված, որ այդ ալգորիթմերը, միավորված լինելով կենդանի բնության կառավարման մոդելներով, արդյունավետորեն լուծում են որոշումների ընդունման բազմապարամետրիկ ոչ գծային էքստրեմալ խնդիրներ:

A.A. TERZIAN, G.G. SARGSYAN

GENETICAL ALGORITHMS OF DECISION MAKING

Genetical algorithms compared with random search algorithms are con-sidered. The results of conducting considerable volume of numerical experiments show that these algorithms united by using control models of living nature efficiently solve multiparametric extremum decision making problems.