

МИНИСТЕРСТВО ОБРАЗОВАНИЯ РОССИЙСКОЙ ФЕДЕРАЦИИ
Нижегородский государственный университет им. Н.И.Лобачевского
Радиофизический факультет

**БЕЗУСЛОВНЫЙ ЭКСТРЕМУМ.
ВВЕДЕНИЕ В ЧИСЛЕННЫЕ МЕТОДЫ**

Лабораторная работа для студентов радиофизического
факультета ННГУ

Нижегород 2001г.

УДК 518.5 Безусловный экстремум. Введение в численные методы. /сост. В.В.Кулинич,М.М.Новоженов,В.И.Сумин - Нижний Новгород, изд. ННГУ им.Н.И.Лобачевского, 2001 г. -24с.

В описании лабораторной работы приведены основные сведения о некоторых наиболее важных в идейном отношении методах численного решения задач на безусловный экстремум. Сформулированы вопросы для самопроверки, помогающие уяснить суть изложенных методов. Задания лабораторной работы требуют от студентов самостоятельного исследования этих методов в конкретных ситуациях.

Составители:

Виктор Валентинович Кулинич
Михаил Михайлович Новоженов
Владимир Иосифович Сумин

Нижегородский государственный университет им.Н.И.Лобачевского
2001 г.

Рассмотрим задачу нахождения безусловного минимума функции $f(x)$ векторного аргумента $x = \{x_1, x_2, \dots, x_n\}$, заданной на всем пространстве R^n , символически записываемую в виде

$$f(x) \rightarrow \min, x \in R^n. \quad (1)$$

Напомним, что точка \bar{x} называется точкой локального минимума в задаче (1), если существует число $\epsilon > 0$ такое, что для всех x удовлетворяющих условию $\|x - \bar{x}\| \leq \epsilon$, выполнено неравенство $f(x) \geq f(\bar{x})$; здесь и далее $\|x\| = \{x_1^2 + \dots + x_n^2\}^{1/2}$. Точка \bar{x} называется точкой глобального минимума в задаче (1), если $f(\bar{x}) \leq f(x), x \in R^n$.

Для численного решения задачи (1) обычно строят некоторую последовательность векторов $\{x^k\}_{k=0}^\infty$, обрывая процесс построения тогда, когда появляется уверенность, что последний из построенных элементов последовательности близок к точке минимума в том или ином смысле. Например, если элемент x^k удовлетворяет неравенству $\|x^k - \bar{x}\| < \bar{\delta}$, где \bar{x} - точка минимума в задаче (1), $\bar{\delta}$ - некоторое положительное число, то говорят, что x^k есть приближенное решение задачи (1) с точностью $\bar{\delta}$ по аргументу. Если же выполняется неравенство $|f(x^k) - \bar{f}| < \bar{\delta}$, где \bar{f} - минимальное значение функции $f(x)$ в R^n , то говорят, что число $f(x^k)$ дает приближенное решение задачи (1) с точностью $\bar{\delta}$ по функции.

Большинство процессов, используемых для приближенного решения задачи (1) можно представить как итерационные в виде

$$x^{k+1} = x^k + \alpha_k p^k, \quad (2)$$

где p^k - вектор, определяющий направление движения от точки x^k к точке x^{k+1} , α_k - числовой множитель, величина которого задает длину шага в направлении p^k . В различных итерационных процессах типа (2) для нахождения α_k и p^k привлекаются различные сведения о минимизируемой функции $f(x)$. Процессы, использующие

для этого только значения самой функции, называются процессами нулевого порядка или методами поиска. Процессы, требующие вычисления производных $f(x)$ до m -го порядка включительно, называют процессами m -го порядка. Если для определения a_k и p^k используется информация, полученная на S предыдущих итерациях, то итерационный процесс называется S -шаговым.

В качестве направления p^k естественно выбирать направление убывания функции $f(x)$. Такое направление называют направлением спуска. Метод (2) называют методом спуска, если при каждом k направление p^k — направление спуска, а число α_k таково, что

$$f(x^{k+1}) = f(x^k + \alpha_k p^k) < f(x^k). \quad (3)$$

Важной характеристикой итерационного процесса является скорость сходимости итерационной последовательности. Пусть итерационная последовательность $\{x^k\}_{k=0}^{\infty}$ сходится к \bar{x} , т.е.

$$\|x^k - \bar{x}\| \rightarrow 0, k \rightarrow \infty.$$

Говорят, что скорость сходимости последовательности

1) линейна, если существует число $q \in (0, 1)$ такое, что

$$\|x^{k+1} - \bar{x}\| \leq q \|x^k - \bar{x}\|, k = 0, 1, 2, \dots;$$

2) сверхлинейна, если существует последовательность чисел $\{q_k\}_{k=1}^{\infty}$, $q_k \rightarrow 0, k \rightarrow \infty$ такая, что

$$\|x^{k+1} - \bar{x}\| \leq q_k \|x^k - \bar{x}\|, k = 0, 1, 2, \dots;$$

3) квадратична, если существует постоянная $C > 0$ такая, что

$$\|x^{k+1} - \bar{x}\| \leq C \|x^k - \bar{x}\|^2, k = 0, 1, 2, \dots.$$

§1. Методы первого порядка.

Простейшими методами первого порядка являются одношаговые методы спуска, в которых на каждом шаге вектор p^k совпадает с направлением антиградиента функции $f(x)$:

$$p^k = -\nabla f(x^k).$$

Такие методы называют градиентными. Градиентные методы отличаются друг от друга способом выбора множителя α_k .

Ниже описаны два градиентных метода (п.п.1,2) и один двухшаговый метод первого порядка (п.3).

1. Метод наискорейшего спуска. В этом методе α_k выбирается из условия минимума функции $f(x)$ вдоль направления p^k , т.е.

$$f(x^k + \alpha_k p^k) = \min_{\alpha > 0} f(x^k + \alpha p^k).$$

Таким образом, в методе наискорейшего спуска на каждом шаге необходимо решать задачу минимизации функции одной переменной.

Замечание. Точная нижняя грань функции $f_k(\alpha) = f(x^k + \alpha p^k)$ на полуоси $\alpha > 0$ может и не достигаться. Но даже, если она достигается, точное определение величины α_k как точки глобального на полуоси минимума функции $f_k(\alpha)$ не всегда возможно. Поэтому на практике имеет смысл заменить задачу нахождения $\min_{\alpha > 0} f_k(\alpha)$ задачей отыскания минимума $f_k(\alpha)$ на том или ином (достаточно большом) отрезке $[0, a]$. В случае, когда $f_k(\alpha)$ унимодальна на $[0, a]$, для приближенного решения последней задачи применяют методы одномерного поиска, описанные в §3. См. также [4], гл.5, §1.

2. Градиентный метод с дроблением шага. Опишем два варианта метода. В обоих вариантах параметрами метода являются величины $\alpha > 0$ и $\lambda \in (0, 1)$. В варианте Б) параметром будет также $\epsilon \in (0, 1)$. Параметр λ называется коэффициентом дробления. Значения параметров выбираются наперед; они одни и те же для всех итераций.

А) Выбор α_k происходит следующим образом. Положив сначала $\bar{\alpha} = \alpha$, проверим неравенство

$$f(x^k + \bar{\alpha} p^k) < f(x^k). \quad (4)$$

Если оно выполнено, то берем $\alpha_k = \bar{\alpha}$. В противном случае значение $\bar{\alpha}$ изменяем, домножив его на λ (дробление $\bar{\alpha}$). Снова проверяем (4). И так до тех пор, пока неравенство (4) не выполнится. То значение $\bar{\alpha}$, при котором это произойдет впервые, и выбираем в качестве α_k .

Б) В этом варианте для того, чтобы выбор α_k гарантировал существенное убывание функции $f(x)$ при переходе от точки x^k к точке x^{k+1} , стараются удовлетворить не неравенству (3) как в

варианте А), а более сильному неравенству

$$f(x^{k+1}) = f(x^k + \alpha_k p^k) < f(x^k) - \epsilon \alpha_k \|\nabla f(x^k)\|^2.$$

Выбор α_k происходит так. Положив сначала $\bar{\alpha} = \alpha$, проверим неравенство

$$f(x^k + \bar{\alpha} p^k) < f(x^k) - \epsilon \bar{\alpha} \|\nabla f(x^k)\|^2. \quad (5)$$

Если оно выполнено, то берем $\alpha_k = \bar{\alpha}$. В противном случае производим постепенное дробление $\bar{\alpha}$, домножая его на λ , до тех пор, пока не выполнится (5). То значение $\bar{\alpha}$, при котором это произойдет впервые, выберем в качестве α_k .

3. Метод сопряженных градиентов. В этом методе α_k выбирается, как и в методе наискорейшего спуска, из условия

$$f(x^k + \alpha_k p^k) = \min_{\alpha > 0} f(x^k + \alpha p^k)$$

(см. замечание в п.1). При этом вектор p^k зависит не только от градиента функции $f(x^k)$, но и от градиента в предыдущей точке $\nabla f(x^{k-1})$ (т.е. метод является двухшаговым), и строится либо по правилу

$$\begin{aligned} \text{А) } p^k &= -\nabla f(x^k) + \beta_k p^{k-1}, \\ \beta_0 &= 0, \beta_k = \frac{(\nabla f(x^k), \nabla f(x^k) - \nabla f(x^{k-1}))}{\|\nabla f(x^{k-1})\|^2}, k = 1, 2, \dots; \end{aligned}$$

либо по правилу

$$\text{Б) } p^k = -\nabla f(x^k) + \beta_k p^{k-1},$$

$$\beta_k = \begin{cases} 0, k = 0, n, 2n, \dots; \\ \frac{(\nabla f(x^k), \nabla f(x^k) - \nabla f(x^{k-1}))}{\|\nabla f(x^{k-1})\|^2}, \\ k = 1, \dots, n-1, n+1, \dots, 2n-1, 2n+1, \dots \end{cases}$$

Напомним, что n - размерность пространства независимых переменных. Вариант Б) отличается от варианта А) тем, что содержит так называемую процедуру обновления - для каждого k , кратного n , переход из точки x^k в точку x^{k+1} выполняется как в методе наискорейшего спуска. Заметим, что переход из точки x^0 в точку x^1 выполняется как в методе наискорейшего спуска и в случае А) и в случае Б).

4. Сходимость. Сходимость любого метода зависит от свойств $f(x)$, выбора начальной точки x^0 и параметров итерационного процесса. Полезная следующая теорема.

Теорема 1. ([1], с.47,83; [4], с.265). Пусть функция $f(x)$ ограничена снизу, а ее градиент удовлетворяет условию Липшица. Если построение минимизирующей последовательности $\{x^k\}$ производится по способу п.1, либо п.2 Б), либо п.3 Б), то какова бы ни была начальная точка x^0 ,

$$\|\nabla f(x^k)\| \rightarrow 0, k \rightarrow \infty.$$

Если точка x^0 такова, что множество $K(x_0) = \{x : f(x) \leq f(x^0)\}$ ограничено, то последовательность $\{x^k\}$ сходится к множеству $S = \{x : \nabla f(x) = 0\}$ стационарных точек функции $f(x)$, т.е.

$$\inf_{x \in S} \|x - x^k\| \rightarrow 0, k \rightarrow \infty.$$

Заметим, что класс функций, указанный в теореме 1, весьма широк, и среди стационарных точек таких функций могут быть не только точки глобальных экстремумов, но и точки локальных экстремумов, а также седловые точки. Однако, как указано в [5], градиентные методы, например, "почти никогда" не сходятся к точке максимума или седловой точке. В то же время они не различают точек локального и глобального минимума и сходятся к произвольной из них (точнее см. [5], с.168).

Оценку скорости сходимости последовательности $\{x^k\}$ для каждого из методов п.п.1 – 3 можно дать лишь на достаточно узких классах функций, предъявляя весьма жесткие требования к гладкости и выпуклости функций $f(x)$. Рассмотрим, например, класс дважды непрерывно дифференцируемых сильно выпуклых функций. Дважды непрерывно дифференцируемая функция $f(x)$ называется сильно выпуклой в R^n , если существует постоянная l , $l > 0$, такая, что для всех $x \in R^n$ имеем

$$l\|y\|^2 \leq (\nabla^2 f(x)y, y), y \in R^n,$$

где $\nabla^2 f(x)$ -матрица Гессе (гессиан) функции $f(x)$,

$$\nabla^2 f(x) = \begin{pmatrix} f''_{x_1x_1}(x) & f''_{x_1x_2}(x) \cdots & f''_{x_1x_n}(x) \\ \cdots & \cdots & \cdots \\ f''_{x_nx_1}(x) & f''_{x_nx_2}(x) \cdots & f''_{x_nx_n}(x) \end{pmatrix}.$$

Каждая функция указанного класса имеет единственную точку минимума - глобальную точку минимума в R^n (см. [4], гл.4, §3).

Теорема 2. ([2], с.55, 61). Пусть $f(x)$ дважды непрерывно дифференцируема и существуют постоянные $L, l, 0 < l \leq L$, такие, что для всех $x \in R^n$ имеем

$$l\|y\|^2 \leq (\nabla^2 f(x)y, y) \leq L\|y\|^2, y \in R^n. \quad (6)$$

Если построение последовательности $\{x^k\}$ производится по способу п.2 Б) или п.1, то при любой начальной точке x^0 последовательность $\{x^k\}$ сходится к точке минимума \bar{x} с линейной скоростью. В случае способа п.1 постоянная $q = (L - l)/(L + l)$.

Если поверхности уровня минимизируемой функции имеют сложную сильно вытянутую (овражную) структуру, то направление антиградиента сильно отличается от направления на точку минимума и сходимость градиентных методов замедляется. Это явление называется овражным эффектом. Показателем овражности в окрестности точки минимума \bar{x} функции $f(x)$ является отношение наибольшего собственного числа матрицы Гессе $\nabla^2 f(\bar{x})$ к наименьшему (см. [5], с.28). Чем больше этот показатель, тем более вытянутым и крутым является "овраг" поверхности уровня $f(x)$ в окрестности \bar{x} и тем медленнее сходятся в этой окрестности градиентные методы (см. [5], с.150).

Метод сопряженных градиентов - наилучший по скорости из рассмотренных методов первого порядка (см. [5], гл.3, §2). Для метода сопряженных градиентов в случае числа итераций, существенно большем размерности n , справедлив следующий результат (см. [5], с.74).

Теорема 3. Пусть функция $f(x)$ трижды дифференцируемая сильно выпуклая функция. Тогда последовательность $\{x^k\}$, построенная по способу п.3 Б), сходится к точке минимума \bar{x} функции $f(x)$, причем в некоторой окрестности точки \bar{x} имеет место оценка скорости сходимости

$$\|x^{(k+1)n} - \bar{x}\| \leq C\|x^{kn} - \bar{x}\|^2, k = 1, 2, \dots$$

Для квадратичных функций $f(x) = \frac{1}{2}(Ax, x) - (b, x)$ (A - положительно определенная симметричная матрица) метод сопряженных градиентов сходится за конечное число шагов, не превышающее числа n . При этом последовательные направления p^k

удовлетворяют соотношению $(Ap^i, p^j) = 0, i \neq j$, т.е. являются ортогональными в метрике, задаваемой матрицей A , A – ортогональными (A – сопряженными). Отсюда – название метода (см. [1], гл.2, §3).

О роли теорем сходимости для практических вычислений см., например, [5], с.39-43.

5. Критерии окончания итерационных процессов. Теорема 1 позволяет для окончания итерационного процесса пользоваться условием вида

$$\|\nabla f(x^k)\| < \delta, \quad (7)$$

где $\delta > 0$ – некоторое заданное число. На практике в качестве критерия окончания итерационных процессов часто используют также следующие неравенства.

При решении задачи (1) с заданной точностью по функции:

$$|f(x^k) - f(x^{k-1})| < \delta \quad \text{или} \quad \frac{|f(x^k) - f(x^{k-1})|}{1 + |f(x^{k-1})|} < \delta. \quad (8)$$

При решении задачи (1) с заданной точностью по аргументу:

$$\|x^k - x^{k-1}\| < \delta \quad \text{или} \quad \frac{\|x^k - x^{k-1}\|}{1 + \|x^{k-1}\|} < \delta. \quad (9)$$

Применяют и различные комбинации критериев (7) – (9).

Выбор величины δ определяется заданной точностью $\bar{\delta}$ (см. стр.3). Однако, правильный выбор δ по заданной величине $\bar{\delta}$ во многом зависит от искусства вычислителя. ”К сожалению, надежных критериев окончания счета, которые гарантировали бы получение решения задачи (1) с требуемой точностью, и применимых к широкому классу задач, пока нет” ([4], с.264). Это замечание относится и к другим методам, описанным ниже.

§2. Методы второго порядка.

Среди методов второго порядка основными являются методы, связанные с идеей локальной аппроксимации заданной функции квадратичной функцией.

1.Метод Ньютона. Для получения итерационной формулы этого метода используем следующие эвристические соображения

(см. [5], с.36). Запишем для функции $f(x)$ в окрестности точки x^k формулу Тейлора 2-го порядка

$$f(x) = Q_k(x) + o(\|x - x^k\|^2), \|x - x^k\| \rightarrow 0;$$

$$Q_k(x) = f(x^k) + (\nabla f(x^k), (x - x^k)) + \frac{1}{2}(\nabla^2 f(x^k)(x - x^k), (x - x^k)). \quad (10)$$

В случае, когда гессиан $\nabla^2 f(x^k)$ положительно определен, квадратичная функция $Q_k(x)$ достигает глобального минимума в точке

$$x^{k+1} = x^k - [\nabla^2 f(x^k)]^{-1} \nabla f(x^k), \quad (11)$$

($\nabla Q_k(x^{k+1}) = 0$). Если точка x^{k+1} достаточно близка к x^k , то в силу (10) справедливо неравенство

$$f(x^{k+1}) < f(x^k),$$

т.е. x^{k+1} естественно взять следующим за x^k приближением к решению задачи (1). Формула (11) и есть итерационная формула метода Ньютона. Таким образом, в этом методе $\alpha_k = 1$,

$$p^k = -[\nabla^2 f(x^k)]^{-1} \nabla f(x^k). \quad (12)$$

Практически p^k удобнее искать не по формуле (12), а решая систему линейных уравнений

$$[\nabla^2 f(x^k)]p^k = -\nabla f(x^k) \quad (13)$$

одним из прямых или итерационных методов (см. соответствующие лабораторные работы), исключая тем самым операцию обращения матрицы Гессе. Отметим, что для квадратичной функции $f(x)$ метод Ньютона сходится за один шаг. Для достаточно гладкой функции $f(x)$ с положительно определенной матрицей Гессе при удачном выборе начального приближения x^0 итерационная последовательность $\{x^k\}$ метода Ньютона сходится к точке минимума с квадратичной скоростью. Однако, найти удачное начальное приближение - задача довольно сложная, требующая определенного искусства. Модифицируя метод Ньютона введением переменного множителя α_k , получают методы спуска, сходящиеся при любом начальном приближении x^0 .

2. Метод Ньютона-Рафсона. В этом методе направление спуска определяется формулой (12), а множитель α_k , регулирующий длину шага, можно выбирать, одним из следующих способов:

А) как и в методе наискорейшего спуска из условия минимума

$$f(x^k + \alpha_k p^k) = \min_{\alpha > 0} f(x^k + \alpha p^k)$$

(см. замечание в п.1 §1);

Б) так, чтобы выполнялось неравенство

$$f(x^k + \alpha_k p^k) \leq f(x^k) + \epsilon \alpha_k (\nabla f(x^k), p^k),$$

где $\epsilon \in (0, 1/2)$ -наперед заданная постоянная, одна и та же для всех итераций. Алгоритм нахождения множителя α_k здесь такой же, как и в градиентном методе с дроблением шага. Начальное значение $\alpha = 1$.

Теорема 4. (см. [2], гл.2, §2, п.2). Пусть функция $f(x)$ дважды непрерывно дифференцируема и выполняется (6), а вторые производные f удовлетворяют условию Липшица. Тогда итерационная последовательность метода Ньютона-Рафсона сходится к точке минимума с квадратичной скоростью, какова бы ни была начальная точка x^0 . Если условие Липшица для вторых производных не выполняется, то скорость сходимости сверхлинейна.

Для окончания итерационных процессов в методах второго порядка используют те же критерии, что и в методах первого порядка.

К основным недостаткам методов второго порядка следует отнести необходимость вычисления вторых производных, а также то, что сходимость заведомо гарантируется лишь при положительной определенности гессиана функции $f(x)$. Важность последнего положения демонстрируется в [1] на с.59-61.

§3. Методы нулевого порядка.

В задачах безусловной минимизации методы нулевого порядка сходятся, как правило, хуже методов, использующих информацию о производных. Однако этот недостаток зачастую перекрывается тем достоинством методов поиска, что они требуют гораздо меньше времени на подготовку задачи к решению (исключаются, например, такие трудные операции, как вычисление производных).

1. Метод покоординатного спуска. Для построения минимизирующей последовательности используется формула (2). При

этом вектор p^k определяется по правилу (циклический покоординатный спуск):

$$p^k = e_{k-[k/n]n+1}, k = 0, 1, 2, \dots,$$

где $[t]$ -целая часть числа t , $e_j = \{0, \dots, 0, 1, 0, \dots, 0\}$ (единица стоит на j -ом месте), $j = 1, \dots, n$. Число $\alpha_k \in (-\infty, \infty)$ можно определять, например, следующим способом

$$f(x^k + \alpha_k p^k) = \min_{-\infty < \alpha < \infty} f(x^k + \alpha p^k).$$

Здесь можно сделать замечание, аналогичное замечанию из п.1, §1.

2. Одномерный поиск. Большинство методов поиска для функций нескольких переменных, как и метод п.1, сводится по существу к решению ряда задач поиска минимума функций одной переменной (одномерный поиск). К таким задачам приводят, как мы видели в §1, §2, и методы первого и второго порядков. Ниже описаны два эффективных метода одномерного поиска для унимодальной функции. Функция $f(x)$, определенная и непрерывная на отрезке $[a, b]$, называется унимодальной на этом отрезке, если существуют числа $\alpha, \beta, a \leq \alpha \leq \beta \leq b$, такие, что

- 1) $f(x)$ строго монотонно убывает на $[a, \alpha]$ (если $a < \alpha$);
- 2) $f(x)$ строго монотонно возрастает на $[\beta, b]$ (если $\beta < b$);
- 3) $f(x)$ постоянна на $[\alpha, \beta]$.

В частности, если $\alpha = \beta$, то $f(x)$ называется строго унимодальной на $[a, b]$ (см.[4], с.13). Очевидно, что $[\alpha, \beta]$ - множество точек минимума функции $f(x)$ на отрезке $[a, b]$.

Методы поиска для унимодальных функций основаны на следующем их свойстве. Пусть $f(x)$ унимодальна на $[a, b]$, а $[\alpha, \beta]$ -отрезок из приведенного выше определения унимодальности. Назовем отрезком неопределенности (в задаче минимизации $f(x)$ на $[a, b]$) любой принадлежащий $[a, b]$ отрезок, имеющий непустое пересечение с неизвестным отрезком $[\alpha, \beta]$ точек минимума функции $f(x)$. Вычислив значения $f(x^1)$ и $f(x^2)$ в любой паре точек $x^1, x^2 \in [a, b], x^1 < x^2$, можно найти отрезок неопределенности более узкий, чем первоначальный отрезок $[a, b]$. Действительно, если $f(x^1) < f(x^2)$, то это будет отрезок $[a, x^2]$, если $f(x^1) > f(x^2)$, то таким отрезком будет отрезок $[x^1, b]$, а в случае $f(x^1) = f(x^2)$ - отрезок $[x^1, x^2]$.

Используя последовательно указанное свойство, можно постепенно сужать отрезок неопределенности. Правило сужения определяется законом выбора точек x^1, x^2 , в которых должна быть вычислена функция $f(x)$. Метод поиска тем эффективней, чем быстрее убывает при возрастании числа m отношение $E_m = \Delta_m / \Delta_0$, где Δ_0 - длина первоначального отрезка неопределенности, а Δ_m - длина отрезка неопределенности, полученного после m вычислений функции.

Критерием окончания процесса поиска может служить достижение отрезком неопределенности некоторой наперед заданной длины δ . При этом за точку минимума приближенно принимается средняя точка последнего отрезка неопределенности.

А) Метод половинного деления. В этом методе точки x^1 и x^2 на каждом отрезке неопределенности $[a, b]$ выбираются по правилу

$$x^1 = \frac{a+b}{2} - \frac{\epsilon}{2}, x^2 = \frac{a+b}{2} + \frac{\epsilon}{2},$$

где $\epsilon > 0$ - некоторое достаточно малое наперед выбранное число. Показатель эффективности метода равен $E_m = 2^{-m/2} + (1 - 2^{-m/2})\epsilon(b-a)^{-1}$.

Б) Метод золотого сечения. Поиск с помощью метода золотого сечения основан на разбиении отрезка неопределенности на две части, известном как "золотое сечение". При этом отношение длины всего отрезка к большей части равно отношению большей части к меньшей и равно числу $\tau = 2^{-1}(1 + \sqrt{5}) \simeq 1.6118$ (τ -корень уравнения $\tau^2 = 1 + \tau$). В методе золотого сечения точки x^1 и x^2 на каждом отрезке неопределенности $[a, b]$ выбираются по правилу

$$x^1 = b - (b-a)/\tau, x^2 = a + (b-a)/\tau.$$

Показатель эффективности метода равен $E_m = \tau^{1-m}$.

Вопросы для самопроверки.

1. Каков угол между направлением спуска p^k и p^{k+1} в методе наискорейшего спуска?

2. Проведите два шага минимизации методом наискорейшего спуска, начиная с точки $x^0 = \{1, 1\}$, для функции $f(x_1, x_2) = x_1^2 + 2x_2^2$.

3. Пусть $\{x^k\}$ -итерационная последовательность некоторого метода спуска для функции $f(x)$, $x \in R^n$. Ломаную в R^n , соединяющую последовательно точки $x^0, x^1, \dots, x^n, \dots$, называют траекторией поиска. Начертите на плоскости (x_1, x_2) траекторию поиска предыдущей задачи.

4. Задача минимизации функции $f(x_1, x_2) = x_1^2 + 2x_2^2$ решается методом п.2 Б) §1, причем $x^0 = \{1, 1\}$, $\epsilon = 0.5$, $\alpha = 1$, $\lambda = 0.5$. Сколько дроблений будет произведено для определения множителей α_0 и α_1 ? Начертите траекторию поиска.

5. Замедлится или ускорится поиск минимума в предыдущей задаче, если взять:

а) $\epsilon = 0.5, \alpha = 1, \lambda = 0.1$;

б) $\epsilon = 0.5, \alpha = 0.5, \lambda = 0.5$;

в) $\epsilon = 0.9, \alpha = 1, \lambda = 0.5$;

г) $\epsilon = 0.1, \alpha = 1, \lambda = 0.5$?

6. Определите начальное направление спуска по методу Ньютона для функции $f(x_1, x_2) = x_1^2 + 2x_2^2$ из точки $x^0 = \{1, 1\}$. Найдите первое приближение. Сделайте то же самое для произвольной точки x^0 .

7. Найдите первые три приближения к точке минимума функции $f(x_1, x_2) = x_1^2 + x_2^4$ по методу Ньютона, взяв $x^0 = \{1, 1\}$. Сколько итераций потребуется, чтобы приблизиться к точке минимума на расстояние не большее, чем 0.01?

8. Найдите первое приближение к минимуму функции $f(x_1, x_2) = x_1^2 + x_2^4$ по методу Ньютона-Рафсона, взяв $x^0 = \{1, 1\}$ (модификация А)).

9. Найдите несколько первых итераций и постройте траекторию поиска минимума функции $f(x_1, x_2) = x_1^2 + x_2^4$ по методу Ньютона-Рафсона (модификация Б)), взяв $x^0 = \{1, 1\}$, $\epsilon = 1/3$, $\lambda = 1/2$.

10. Проведите два шага минимизации методом сопряженных градиентов, начиная с точки $x^0 = \{1, 1\}$, для функции $f(x_1, x_2) = x_1^2 + 2x_2^2$. Постройте траекторию поиска.

11. Выполните задание пункта 10 для функции $f(x_1, x_2) = x_1^2 + x_2^4$.

12. Проведите два шага минимизации методом покоординатного спуска, начиная с точки $x^0 = \{1, 1\}$, для функции $f(x_1, x_2) = x_1^2 + 2x_2^2$. Постройте траекторию поиска.

13. Сколько вычислений функции нужно сделать, чтобы умень-

шить длину первоначального отрезка неопределенности $[0,1]$ в 10 раз; а) методом половинного деления для $\epsilon = 0.01, \epsilon = 0.05$; б) методом золотого сечения ?

14. Вычислите показатель овражности в точке минимума для функции $f(x_1, x_2) = x_1^2 + 2x_2^2$ (точка минимума - $\{0, 0\}$) и для функции Розенброка $f(x_1, x_2) = 100[x_2 - x_1^2]^2 + (1 - x_1)^2$ (точка минимума - $\{1, 1\}$).

15. Вычислите показатель овражности в точке минимума для функции $f(x_1, x_2) = 2^{-1}(x_1^2 + Lx_2^2)$, где $L > 1$ (точка минимума - $\{0, 0\}$). Взяв за начальную точку $\{1, 1/L\}$, найдите итерационную последовательность метода наискорейшего спуска. Проверьте, что расстояние элементов этой последовательности до точки минимума убывает как геометрическая прогрессия со знаменателем $(L - 1)/(L + 1)$. Налицо проявление овражного эффекта - чем больше число L и показатель овражности, тем медленнее сходимость. Этот пример показывает также, что, вообще говоря, метод наискорейшего спуска сходится не быстрее, чем с линейной скоростью.

Задания лабораторной работы.

В лабораторной работе требуется по указанию преподавателя выполнить некоторые из следующих заданий.

1. Для заданной функции провести теоретическое исследование применимости заданного метода минимизации.

2. Для заданной функции n переменных при заданном критерии окончания и заданной точности $\bar{\delta}$ решить численно указанным методом задачу безусловной минимизации:

а) составить программу решения задачи минимизации для произвольной функции n переменных (алгоритм оформить в виде подпрограммы);

б) провести отладку программы на какой-либо "простой" функции (например, $f(x_1, x_2) = x_1^2 + 2x_2^2$);

в) с помощью одной из программ, приведенных в приложении, нарисовать картинку линий уровня минимизируемой функции в окрестности предполагаемой точки экстремума (если $n = 2$);

г) используя результаты расчетов на ЭВМ, начертить траекторию поиска, наложив ее на рисунок линий уровня (если $n = 2$);

д) проанализировать полученные результаты.

3. Исследовать с помощью ЭВМ зависимость числа итерации M , необходимых для численного решения задачи минимизации заданной функции указанным методом, от:

- а) выбора начальной точки;
- б) параметров метода;
- в) выбора критерия окончания;
- г) величины δ .

5. Сравнить поведение различных методов при численном решении одной и той же задачи минимизации.

Требования к программам.

Подпрограмму, реализующую алгоритм минимизации, необходимо сделать независимой от конкретного вида минимизируемой функции. Этого можно достичь выносом вычисления целевой функции и производных от нее в отдельные подпрограммы. Например, так, как это сделано ниже.

ВЫЧИСЛЕНИЕ ЦЕЛЕВОЙ ФУНКЦИИ

```
real function  $f(x, n)$ 
real  $x(n)$ 
 $f = \dots$ 
return
end
```

ВЫЧИСЛЕНИЕ ГРАДИЕНТА

```
subroutine grad( $gr, x, n$ )
real  $x(n), gr(n)$ 
 $gr(1) = \dots$ 
 $gr(2) = \dots$ 
...
return
end
```

Здесь многоточием заменены операторы, отвечающие за вычисление функции ($f = \dots$) и частных производных ($gr(1) = \dots, gr(2) = \dots$). Теперь во всех случаях, когда необходимо вычислить, например, значение функции, достаточно в программе в соответствующем месте вставить оператор $y = f(x, n)$. При необходимости сменить функцию, достаточно заменить в подпрограмме f и grad операторы, отмеченные многоточием, оставив без изме-

Список тестовых функций.

функция $f(x, y)$	точка минимума	начальная точка
1. $(2/3)x^3 + (1/3)y^3 - x^2y + xy^2 - 5x$	{1.925, 0.8}	{3, 2}
2. $100(y - x^2)^2 + (1 - x)^2$	{1, 1}	{-1.2, 1}
3. $(y - x^2)^2 + (1 - x)^2$	{1, 1}	{0.5, 0.5}
4. $100(y - x^3)^2 + (1 - x)^2$	{1, 1}	{-1.2, 1}
5. $(y - x^2)^2 + 100(1 - x)^2$	{1, 1}	{-1.2, 1}
6. $(1.5 - x(1 - y))^2 + (2.25 - x(1 - y)^2)^2 + (2.625 - x(1 - y^3))^2$	{3, 0.5}	{2.0}
7. $(x^2 + y - 11)^2 + (x + y^2 - 7)^2$	а) {3, 2} б) {3.58, -1.85} в) {-3.78, -3.29} г) {-2.81, 3.13}	а) {1, 1} б) {-2, 1} в) {-2, 4} г) {-4, 3}

ПРИЛОЖЕНИЕ

Приведем описание программы РІСТ, предназначенной для распечатки на экране линий уровня функций двух переменных $f(x, y)$. В начале программа РІСТ по заданному прямоугольнику $\Pi = [x^{\min}, x^{\max}] * [y^{\min}, y^{\max}]$ и заданному размеру рисунка $fh * fu$ (fh - количество символов по горизонтали; fu - количество символов по вертикали) определяет шаги по координатам x и y по формулам

$$h_x = (x^{\max} - x^{\min}) / (fh - 1), h_y = (y^{\max} - y^{\min}) / (fu - 1).$$

Результатом выполнения программы РІСТ будет отображение на экране шести линий уровня, соответствующих значениям

$$f_j = f_{\min} + (j - 1)(f_{\max} - f_{\min}) / 5, j = 1, 2, 3, 4, 5, 6.$$

Здесь $f_{\max} = \max f(x, y)$, $f_{\min} = \min f(x, y)$, где максимум и минимум берутся по "сеточному прямоугольнику" Π_h , образованному узлами сетки с шагами h_x и h_y , $\Pi_h \subset \Pi$. На экран также выводятся значения f_j и символы, с помощью которых "рисуются" соответствующие линии уровня.

Обращение к программе:

call РІСТ(fnc, k, fh, fu, xt, xn, yt, yn)

Входные параметры:

fnc - имя внешней подпрограммы, с помощью которой вычисляются значения $f(x, y)$. Подпрограмма-функция *fnc* должна иметь структуру, аналогичную той, которая приведена в рекомендациях по оформлению программ. Ее необходимо описать оператором EXTERNAL;

k - параметр целого типа, задающий количество строк между соседними вы печатаваемыми координатными линиями, параллельными оси x ;

fh - переменная целого типа, задающая число символов в строке. Если ввести значение *fh*, лежащее вне полуинтервала $[0, 117)$, то программа скорректирует его, положив $fh = 61$;

fu - переменная целого типа, задающее число строк в рисунке. Если $fh < 1$, то происходит коррекция $fu = 61$;

xm, xn - соответственно левая и правая границы Π , переменные вещественного типа;

ym, yn - соответственно нижняя и верхняя границы Π , переменные вещественного типа.

Выходные параметры: отсутствуют.

Требуемые подпрограммы: *fnc*.

Текст программы приводится ниже.

Замечание. Программа на самом деле "рисует" не линии уровня, соответствующие значению функции f_j , а некоторую "полоску", состоящую из точек $\{x, y\}$ сеточного прямоугольника Π_h , удовлетворяющих условию $f_j - w < f(x, y) < f_j + w$, w - внутренний параметр программы, $w = (f_{\max} - f_{\min})/40$.

```
external f
integer fh, fu
fh = 31
fu = 41
k = 5
xm = -4
xn = 4
ym = -2
yn = 2
call pict(f, k, fh, fu, xm, xn, ym, yn)
end
```

```

real function  $f(x, n)$ 
real  $x(n)$ 
 $f = 0.25 * x(1) * *2 + x(2) * *2$ 
return
end
subroutine pict(fnc,  $f$ ,  $fh$ ,  $fu$ ,  $xmin$ ,  $xmax$ ,  $ymn$ ,  $ymx$ )
integer  $fh$ ,  $fu$ ,  $f$ ,  $d$ ,  $d1$ 
real  $x(2)$ ,  $fl(9)$ 
real*8  $aa(2)$ ,  $ab$ ,  $ac$ ,  $ad(2)$ 
character*1  $fmt(16)$ 
logical*1  $cl(117)$ ,  $c(6)$ ,  $blk$ ,  $pnt$ 
equivalence ( $fmt(1)$ ,  $aa(1)$ ), ( $x(1)$ ,  $xx$ ), ( $x(2)$ ,  $y$ ),
* ( $fmn$ ,  $fl(1)$ ), ( $fmx$ ,  $fl(6)$ )
data  $aa$  /'(g14.5, ', ' 117a1)'/
1      ,  $ab$  /'(g14.5, ' / ,  $ac$  /'(14x, ' /
2      ,  $ad$  /'(7x, 10(' , ' f10.2))'/
data  $c$  /' +', ' x', ' y', ' z', ' g', ' *' / ,  $blk$ ,  $pnt$  /'', ' ./
if( $fh.le.1$ .or. $fh.gt.117$ )  $fh = 61$ 
if( $fu.le.1$ )  $fu = 61$ 
 $hx = (xmax-xmin)/(fh - 1)$ 
 $hy = (ymx-ymn)/(fu - 1)$ 
 $xx = xmin$ 
 $y = ymn$ 
 $fmx = fnc(x, 2)$ 
 $fmn = fmx$ 
 $y = ymn - hy$ 
do 5  $j = 1, fu$ 
 $y = y + hy$ 
 $xx = xmin - hx$ 
do 4  $i = 1, fh$ 
 $xx = xx + hx$ 
 $fl(3) = fnc(x, 2)$ 
 $fmn = amin1(fmn, fl(3))$ 
4  $fmx = amax1(fmx, fl(3))$ 
5 continue
 $werr = (fmx - fmn) / 5.$ 
do 15  $i = 2, 5$ 
15       $fl(i) = fmn + (i - 1) * werr$ 

```

```

werr=werr/8.
write(*,90)(c(i),fl(i),i=1,6),xmin,xmax,hx,ymn,ymx,hy
do 16i=1,fh
16    cl(i)=blk
y=ymx+hy
do 50i=1,fu
y=y-hy
if(mod(i,f).ne.1) go to 20
aa(1)=ab
do 18k=1,fh
18    cl(k)=pnt
go to 22
20 do 21k=1,fh
21cl(k)=blk
aa(1)=ac
22    xx=xmin-hx
do 40j=1,fh
xx=xx+hx
if(mod(j,10).eq.1)cl(j)=pnt
do 30k=1,6
if(abs(fnc(x,2)-fl(k)).ge.werr) go to 30
cl(j)=c(k)
30 continue
40 continue
if(aa(1).eq.ab) write(*,fmt)y,(cl(k),k=1,fh)
if(aa(1).eq.ac) write(*,fmt)(cl(k),k=1,fh)
50 continue
aa(1)=ad(1)
aa(2)=ad(2)
j=0
xmin=xmin-hx
do 55i=1,fh
xmin=xmin+hx
if(mod(i,10).ne.1) go to 55
j=j+1
fl(j)=xmin
55 continue
write(*,fmt)(fl(i),i=1,j)

```

```

return
90 format(' обозначения'//6(2x, a1, 2x, g12.5/)/
12x, ' xmin=' , g10.3, 5x, ' xmax=' , g10.3, 5x, ' hx =' , g10.3/
22x, ' ymin=' , g10.3, 5x, ' ymax=' , g10.3, 5x, ' hy =' , g10.3//)
end

```

На следующей странице на рис.1 приводится картинка линий уровня функции

$$f(x, y) = 0.25x^2 + y^2$$

в прямоугольнике $\Pi = [-4, 4] \times [-2, 2]$, полученная при помощи программы РІСТ. В верхней части распечатки дана таблица значений функции $f(x, y)$ (на каждой из шести линий уровня) и символов, которыми изображается соответствующая линия уровня. Ниже напечатаны значения

$$x^{\min}, x^{\max}, y^{\min}, y^{\max}, hx, hy.$$

Распечатка получена при следующих значениях входных параметров:

$$fh = 31, fu = 41, k = 5, xt = -4, xn = 4, yt = -2, yn = 2.$$

Заметим, что изображения линий уровня несколько "размыты" из-за того, что программа на самом деле "рисует" не линии уровня, соответствующие значению функции f , а некоторую "полоску", состоящую из точек сеточного прямоугольника Π_h , каждая из которых удовлетворяет условию

$$| f(x, y) - f_j | < w.$$

Значение w , являющееся внутренним параметром программы, выбрано равным $w = (f_{\max} - f_{\min})/40$.

```

обозначения:
+ 0.17615E-11
x 1.6000
y 3.2000
z 4.8000
g 6.4000
* 8.0000
xmin= -4.00      xmax= 4.00      hx= 0.267
ymin= -2.00      ymax= 2.00      hy= 0.100

2.0000  *..g....zz.....zz....g..*
.      z .          . z      .
. g z . yyyyy . z g .
.g z yyy yyy z g.
g z yy yy z g
1.5000  g..z...yy.....yy...z..g
. z y . xxxxx . y z .
.z y .xxxxxxxxx. y z.
.z y xx xx y z.
1.0000  ....y....xx.....xx....y...z
z y xx. .xx y z
z y xx . .xx y z
0.50000 ..y...x.....x...y..
. y x . +++ . x y .
. y x . +++++ . x y .
. y xx . ++++++ . xx y .
0.12442E-05..y..xx.....+++++.....xx..y..
. y xx . ++++++ . xx y .
. y x . +++++ . x y .
. y x . +++ . x y .
-0.50000 ..y...x.....x...y..
z y xx . .xx y z
z y xx. .xx y z
-1.00000 z...y....xx.....xx....y...z
.z y xx xx y z.
.z y .xxxxxxxxx. y z.
. z y . xxxxx . y z .
-1.5000  g..z...yy.....yy...z..g
.g z yyy yyy z g.
. g z . yyyyyy . z g .
.      z .          . z      .
-2.0000  *..g....zz.....zz....g..*
-4.00    -1.33      1.33      4.00

```

Рис. 1. Линии уровня функции $f(x, y) = 0.25x^2 + y^2$, нарисованные на экране программой PICT

Для отображения линий уровня функции

$$f(x, y) = 0.25x^2 + y^2$$

можно использовать и интегрированные системы, например, MATLAB.

Здесь достаточно выполнить операторы

```
clear
[x,y]=meshgrid([-4:0.1:4],[-2:0.1:2]);
f=0.25* x.^2+ y.^2;
c=contour(x,y,f);
clabel(c)
xlabel('x')
ylabel('y').
```

В результате будем иметь на экране картину, приведенную на рис.2




Рис. 2. Линии уровня функции $f(x, y) = 0.25x^2 + y^2$

ЛИТЕРАТУРА

1. Моисеев Н.Н., Иванюков Ю.П., Столярова Е.М. Методы оптимизации. М.: Наука, 1978.
2. Пшеничный Б.П., Данилин Ю.М. Численные методы в экстремальных задачах. М.: Наука, 1975.
3. Химмельблау Д. Прикладное нелинейное программирование. М.: Мир, 1975.
4. Васильев Ф.П. Численные методы решения экстремальных задач. М.: Наука, 1988.
5. Поляк Б.Т. Введение в оптимизацию. М.: Наука, 1983.

БЕЗУСЛОВНЫЙ ЭКСТРЕМУМ
ВВЕДЕНИЕ В ЧИСЛЕННЫЕ МЕТОДЫ

Составители:

Кулинич

Виктор Валентинович

Новоженков

Михаил Михайлович

Сумин

Владимир Иосифович

Подписано к печати . Формат 60x84 1/16.

Печать офсетная. Бумага оберточная. Усл.печ.л. 1.7.

Тираж 500 экз. Заказ . Бесплатно.

Нижегородский государственный университет им.Н.И.Лобачевского.

603600 ГСП-20, Н.Новгород, просп.Гагарина, 23.

Типография ННГУ. 603600, Н.Новгород, ул.Б.Покровская, 37.