

Документ подписан простой электронной подписью

Информация о владельце:

ФИО: Локтионова Оксана Геннадьевна

Должность: проректор по учебной работе

Дата подписания: 28.11.2022 09:06:59

Уникальный программный ключ:

0b817ca911e6668abb13a5d426d39e5f1c11eabbf73e943df4a4851fd456d089

МИНОБРНАУКИ РОССИИ

Федеральное государственное бюджетное
образовательное учреждение высшего образования
«Юго-Западный государственный университет»
(ЮЗГУ)

Кафедра Вычислительная техника



УТВЕРЖДАЮ

Проректор по учебной работе

О.Г. Локтионова

30» с. 6 2017

МИНИМАЗАЦИЯ МЕТОДАМИ ПЕРВОГО ПОРЯДКА

Методические указания к лабораторным занятиям
по дисциплине «Методы оптимизации» для студентов
направления подготовки 09.04.01

Курск 2017

УДК 519.8

Составитель Ж.Т. Жусубалиев

Рецензент
Доктор технических наук, профессор С.А. Филист

Минимизация методами первого порядка: методические указания к практическим занятиям по дисциплине «Методы оптимизации» / Юго-Зап. гос. ун-т; сост.: Ж.Т. Жусубалиев. Курск, 2017. – 16 с.: табл. 2. – Библиограф.: с. 16.

Рассматриваются методы безусловной минимизации функции нескольких переменных методами первого порядка, а также алгоритмы их численной реализации с помощью ЭВМ. Приводятся задачи для упражнений.

Методические указания соответствуют требованиям программы, утвержденной учебно-методическим объединением по направлению подготовки «Информатика и вычислительная техника».

Предназначены для студентов направления подготовки 09.04.01 дневной и заочной форм обучения.

Текст печатается в авторской редакции

Подписано в печать . Формат 60×84 $\frac{1}{16}$.
Усл. печ. л. . Уч.-изд. л. . Тираж 30 экз. Заказ . Бесплатно.
Юго-Западный государственный университет.
305040, г. Курск, ул. 50 лет Октября, 94..

1. Градиентные методы

Градиентные методы основаны на итерационной процедуре, реализуемой в соответствии с формулой:

$$X_{k+1} = X_k + \alpha_k S_k,$$

где α_k – параметр, характеризующий длину шага; S_k – направление поиска в пространстве управляемых переменных.

Направление поиска в градиентных методах совпадает с антиградиентом целевой функции $S_k = -\nabla f(X_k)$.

Таким образом

$$X_{k+1} = X_k - \alpha_k \nabla f(X_k), \quad k = 0, 1, \dots, \alpha_k > 0$$

означает, что из точки X_k на k -ой итерации алгоритма происходит спуск с шагом $\alpha_k |\nabla f(X_k)|$.

В зависимости от способа выбора значения α_k выделяют методы градиентного спуска с постоянным шагом и наискорейшего спуска.

1.1. Метод градиентного спуска с постоянным шагом

На первой итерации спуск начинают из выбранной начальной точки X_0 . Выбор величины шага α_k осуществляется пользователем и остается постоянным пока функция убывает в рассчитываемых точках последовательности $\{X_k\}$, $k = 0, 1, \dots$, что контролируется проверкой на каждой k -ой итерации выполнения неравенства:

$$f(X_{k+1}) - f(X_k) < 0 \text{ или } f(X_{k+1}) - f(X_k) < \varepsilon \|\nabla f(X_k)\|^2, \quad (1)$$

где $\varepsilon \in (0, 1)$ – величина, гарантирующая сходимость последовательности $\{\nabla f(X_k)\}$ к нулю.

Если на k -ой итерации не выполнено неравенство (1), то проводится дробление шага $\alpha_k = \alpha_k / 2$.

Построение последовательности $\{X_k\}$ заканчивается в точке X_k , для которой $\|\nabla f(X_k)\| < \varepsilon_1$, где ε_1 – заданное малое положительное число, или $k \geq M$, где M – предельное число итераций, или при двукратном одновременном выполнении двух неравенств

$\|X_{k+1} - X_k\| < \varepsilon_2$, $|f(X_{k+1}) - f(X_k)| < \varepsilon_2$, где ε_2 - малое положительное число.

Алгоритм градиентного спуска с постоянным шагом может быть представлен следующим образом.

Шаг 1. Задать X_0 , $0 < \varepsilon < 1$, $\varepsilon_1 > 0$, $\varepsilon_2 > 0$, M – предельное число итераций. Найти градиент функции в произвольной точке

$$\nabla f(X) = \left(\frac{\partial f(X)}{\partial x_1}, \dots, \frac{\partial f(X)}{\partial x_n} \right)^T.$$

Шаг 2. Положить $k = 0$.

Шаг 3. Вычислить $\nabla f(X_k)$.

Шаг 4. Проверить выполнение критерия окончания $\|\nabla f(X_k)\| < \varepsilon_1$:

- а) если неравенство выполнено, то расчет окончен и $X_* = X_k$,
- б) в противном случае перейти к шагу 5.

Шаг 5. Проверить выполнение неравенства $k \geq M$:

- а) если неравенство выполнено, расчет окончен и $X_* = X_k$,
- б) если нет, перейти к шагу 6.

Шаг 6. Задать величину шага α_k .

Шаг 7. Вычислить $X_{k+1} = X_k - \alpha_k \nabla f(X_k)$.

Шаг 8. Проверить выполнение условия $f(X_{k+1}) - f(X_k) < 0$ (или $f(X_{k+1}) - f(X_k) < -\varepsilon \|\nabla f(X_k)\|^2$):

- а) если условие выполнено, то перейти к шагу 9;
- б) если условие не выполнено, положить $\alpha_k = \frac{\alpha_k}{2}$ и перейти к шагу 7.

Шаг 9. Проверить выполнение условий $\|X_{k+1} - X_k\| < \varepsilon_2$, $|f(x_{k+1}) - f(x_k)| < \varepsilon_2$:

а) если оба условия выполнены при текущем значении k и $k = k - 1$, то расчет окончен, $X_* = X_{k+1}$,

б) если хотя бы одно из условий не выполнено, положить $k = k + 1$ и перейти к шагу 3.

Пример. Методом градиентного спуска с постоянным шагом $\alpha_k = 0,1$ из начальной точки $X_0 = (-2, 1)^T$ найти минимум функции $f(X) = 6x_1^2 - 4x_1x_2 + 3x_2^2 + 4\sqrt{5}(x_1 + 2x_2) + 22$.

Решение.

Шаг 1. Зададим $X_0 = (-2, 1)^T$, $\varepsilon_1 = 0,01$, $\varepsilon_2 = 10^{-3}$, $\varepsilon_3 = 10^{-4}$, $M = 20$. Градиент функции:

$$\nabla f(X) = (12x_1 - 4x_2 + 4\sqrt{5}, -4x_1 + 6x_2 + 4\sqrt{5})^T.$$

В таблице 1 приведены результаты вычислений.

Таблица 1

k	α_k	X_k^T	$f(X_k)$	$\ \nabla f(X_k)\ $
0	0,1	(-2,000; 1,000)	57,000	37,148
1	0,1	(-1,047; -0,594)	7,150	18,553
2	0,1	(-0,923; -2,446)	-15,976	10,309
3	0,1	(-1,688; -3,136)	-23,772	5,953
4	0,1	(-1,811; -3,719)	-26,494	3,508
5	0,1	(-2,020; -4,001)	-27,460	2,087
6	0,1	(-2,091; -4,197)	-27,806	1,248
7	0,1	(-2,155; -4,304)	-27,930	0,747
8	0,1	(-2,185; -4,372)	-27,975	0,448
9	0,1	(-2,206; -4,412)	-27,991	0,269
10	0,1	(-2,218; -4,436)	-27,997	0,161
11	0,1	(-2,225; -4,450)	-27,999	0,097
12	0,1	(-2,230; -4,459)	-28,000	0,058
13	0,1	(-2,232; -4,464)	-28,000	0,035
14	0,1	(-2,234; -4,467)	-28,000	0,021
15	0,1	(-2,235; -4,469)	-28,000	0,013
16	0,1	(-2,235; -4,470)	-28,000	0,008

На 16-й итерации выполнился критерий окончания $\|\nabla f(X_k)\| = 0,008 < \varepsilon_1$, следовательно $X_* \cong X_{16} = (-2,235; -4,470)^T$.

1.2. Метод наискорейшего градиентного спуска

Эффективность поиска минимума функции, использующего спуск в направлении антиградиента, можно повысить, если значение α_k на каждой итерации выбирать путем минимизации функции:

$$\varphi(\alpha_k) = f(X_k - \alpha_k \nabla f(X_k)) \rightarrow \min_{\alpha_k} .$$

Такой метод носит название метода наискорейшего спуска, или метода Коши.

Выбор значения α_k методом наискорейшего спуска гарантирует сходимость последовательности $\{\nabla f(X_k)\}$ к нулю. Поэтому в качестве условия прекращения итераций используется условие $\|\nabla f(X_k)\| < \varepsilon_1$, где ε_1 – заданное число. Построение последовательности $\{X_k\}$, $k = 0, 1, \dots$ заканчивается в точке X_k , если $k \geq M$, M – предельное число итераций, или при двукратном одновременном выполнении неравенств $|X_{k+1} - X_k| < \varepsilon_2$, $|f(X_{k+1}) - f(X_k)| < \varepsilon_2$, где ε_2 – малое положительное число.

Алгоритм метода наискорейшего спуска включает следующие этапы.

Шаг 1. Задать X_0 , $\varepsilon_1 > 0$, $\varepsilon_2 > 0$, M – предельное число итераций.

Найти градиент функции в произвольной точке

$$\nabla f(X) = \left(\frac{\partial f(X)}{\partial x_1}, \dots, \frac{\partial f(X)}{\partial x_n} \right)^T .$$

Шаг 2. Положить $k = 0$.

Шаг 3. Вычислить $\nabla f(X_k)$.

Шаг 4. Проверить выполнение критерия окончания $\|\nabla f(X_k)\| < \varepsilon_1$:

- а) если неравенство выполнено, то расчет окончен и $X_* = X_k$,
- б) в противном случае перейти к шагу 5.

Шаг 5. Проверить выполнение неравенства $k \geq M$:

- а) если неравенство выполнено, расчет окончен и $X_* = X_k$,
- б) если нет, перейти к шагу 6.

Шаг 6. Вычислить величину шага α_k из условия

$$\varphi(\alpha_k) = f(X_k - \alpha_k \nabla f(X_k)) \rightarrow \min_{\alpha_k}$$

Шаг 7. Вычислить $X_{k+1} = X_k - \alpha_k \nabla f(X_k)$.

Шаг 8. Проверить выполнение условий $\|X_{k+1} - X_k\| < \varepsilon_2$, $|f(X_{k+1}) - f(X_k)| < \varepsilon_2$:

- а) если оба условия выполнены при текущем значении k и $k = k - 1$, то расчет окончен, $X_* = X_k$;
- б) если хотя бы одно из условий не выполнено, положить $k = k + 1$ и перейти к шагу 3.

Поиск в соответствии с приведенным алгоритмом обеспечивает более высокую надежность по сравнению с градиентным методом с постоянным шагом.

Однако при решении ряда практических задач скорость сходимости метода остается недопустимо низкой. Это объясняется тем, что изменения переменных непосредственно зависят от величины градиента, которая стремится к нулю в окрестности точки минимума, и отсутствует механизм ускорения сходимости к точке минимума на последних итерациях.

Одно из главных преимуществ метода связано с его устойчивостью. Метод обладает важным свойством, которое заключается в том, что при достаточно малой длине шага итерации обеспечивают выполнение неравенства $f(X_{k+1}) < f(X_k)$.

Пример. Методом наискорейшего градиентного спуска из начальной точки $X_0 = (-2, 1)^T$ найти минимум функции $f(X) = 6x_1^2 - 4x_1x_2 + 3x_2^2 + 4\sqrt{5}(x_1 + 2x_2) + 22$ [2].

Решение.

Шаг 2. Зададим $X_0 = (-2, 1)^T$, $\varepsilon_1 = 0,01$, $\varepsilon_2 = 10^{-3}$, $\varepsilon_3 = 10^{-4}$, $M = 20$. Градиент функции:

$$\nabla f(X) = (12x_1 - 4x_2 + 4\sqrt{5}, -4x_1 + 6x_2 + 4\sqrt{5})^T.$$

В таблице 2 приведены результаты вычислений.

Таблица 2

k	α_k	X_k^T	$f(X_k)$	$\ \nabla f(X_k)\ $
0	—	(-2,000; 1,000)	57,000	37,148
1	0,09	(-0,283; -1,872)	-5,154	15,182
2	0,145	(-2,173; -3,001)	-21,860	9,985
3	0,09	(-1,711; -3,773)	-26,350	4,081
4	0,145	(-2,219; -4,077)	-27,556	2,684
5	0,09	(-2,095; -4,284)	-27,881	1,097
6	0,145	(-2,231; -4,336)	-27,968	0,721

k	α_k	X_k^T	$f(X_k)$	$\ \nabla f(X_k)\ $
7	0,09	(-2,198; -4,422)	-27,991	0,295
8	0,145	(-2,235; -4,444)	-27,998	0,194
9	0,09	(-2,226; -4,459)	-27,999	0,079
10	0,145	(-2,236; -4,464)	-28,000	0,052
11	0,09	(-2,233; -4,468)	-28,000	0,021
12	0,145	(-2,236; -4,470)	-28,000	0,014
13	0,09	(-2,235; -4,471)	-28,000	0,006

На 13-й итерации выполнился критерий окончания
 $\|\nabla f(X_{13})\| = 0,006 < \varepsilon_1$, следовательно $X_* \cong X_{13} = (-2,235; -4,471)^T$.

2. Метод Флетчера-Ривса

Среди методов первого порядка поиска минимума целевой функции $f(X)$ особое место занимают методы, основанные на свойствах векторов, сопряженных относительно некоторой квадратной матрицы. Одним из таких методов является метод Флетчера-Ривса [Fletcher R., Reeves C.M.].

Итерации проводятся по правилу:

$$X_{k+1} = X_k + \alpha_k S_k, k = 0, 1, \dots,$$

где α_k – величина шага определяется для каждого значения k из условия $\varphi(\alpha_k) = f(X_k - \alpha_k S_k) \rightarrow \min_{\alpha_k}$;

$S_k = -\nabla f(X_k) + \beta_{k-1} S_{k-1}$ – направление поиска, $S_0 = -\nabla f(X_0)$,

$$\beta_{k-1} = \frac{\|\nabla f(X_k)\|^2}{\|\nabla f(X_{k-1})\|^2}$$

или

$$\beta_{k-1} = \begin{cases} \frac{(\nabla f(X_k), [\nabla f(X_k) - \nabla f(X_{k-1})])}{\|\nabla f(X_{k-1})\|^2}, & k \notin J; \\ 0, & k \in J, \end{cases}$$

где $J = \{0, n, 2n, \dots\}$ – множество номеров итераций, называемых моментами обновления алгоритмов. Обновление алгоритма состоит в периодическом через заданное число итераций обнулении β_{k-1} , что

позволяет избежать накопления вычислительных погрешностей и уменьшения вероятности построения после каждой n итераций линейно зависимых направлений спуска.

Построение последовательности $\{X_k\}$ заканчивается в точке, для которой $\|\nabla f(X_{jk})\| < \varepsilon_1$, где ε_1 – заданное число, или при $k \geq M$, M – предельное число итераций, или при двукратном одновременном выполнении двух неравенств $|X_{k+1} - X_k| < \varepsilon_2$, $|f(x_{k+1}) - f(x_k)| < \varepsilon_2$, где ε_2 – малое положительное число.

Алгоритм метода включает следующие шаги.

Шаг 1. Задать X_0 , $\varepsilon_1 > 0$, $\varepsilon_2 > 0$, M – предельное число итераций. Найти градиент $\nabla f(X)$.

Шаг 2. Положить $k = 0$.

Шаг 3. Вычислить $\nabla f(X_k)$.

Шаг 4. Проверить выполнение критерия окончания $\|\nabla f(X_k)\| < \varepsilon_1$:

- а) если неравенство выполнено, то расчет окончен и $X_* = X_k$,
- б) в противном случае перейти к шагу 5.

Шаг 5. Проверить выполнение неравенства $k \geq M$:

- а) если неравенство выполнено, расчет окончен и $X_* = X_k$,
- б) если нет, то при $k = 0$ перейти к шагу 6, а при $k \geq 1$ перейти к шагу 7.

Шаг 6. Определить $S_0 = -\nabla f(X_0)$.

Шаг 7. Определить

$$\beta_{k-1} = \frac{\|\nabla f(X_{k-1})\|^2}{\|\nabla f(X_k)\|^2}, \quad \beta_{k-1} = \begin{cases} \frac{(\nabla f(X_k), [\nabla f(X_k) - \nabla f(X_{k-1})])}{\|\nabla f(X_k)\|^2}, & k \notin J, \\ 0, & k \in J, \end{cases}$$

Шаг 8. Определить $S_k = -\nabla f(X_k) + \beta_{k-1} S_{k-1}$.

Шаг 9. Найти α_k из условия $\varphi(\alpha) = f(X_k + \alpha S_k) \rightarrow \min_{\alpha}$.

Шаг 10. Вычислить $X_{k+1} = X_k + \alpha_k S_k$.

Шаг 11. Проверить выполнение условий

$\|X_{k+1} - X_k\| < \varepsilon_2$, $|f(X_{k+1}) - f(X_k)| < \varepsilon_2$:

а) в случае выполнения обоих условий в двух последовательных итерациях с номерами k и $k = k - 1$ расчет окончен, и найдена точка $X_* = X_{k+1}$,

б) если не выполняется хотя бы одно из условий, полагаем $k = k + 1$ и переходим к шагу 3.

Замечание

Если целевая функция $f(X)$ является квадратичной с неотрицательно определенной матрицей H ($H > 0$), то метод Флетчера-Ривса обеспечивает отыскание точки минимума не более чем за n шагов.

3. Квазиньютоновские методы

Среди алгоритмов многомерной оптимизации следует выделить группу алгоритмов, которые объединяют достоинства метода наискорейшего спуска и метода Ньютона. Такие алгоритмы принято относить к квазиньютоновским методам. Особенность этих алгоритмов состоит в том, что при их применении нет необходимости вычислять и обращать матрицу Гессе минимизируемой функции и в то же время удается сохранить высокую скорость сходимости алгоритмов, присущую методу Ньютона и его модификациям.

Элементы последовательности $\{X_k\}$, $k = 0, 1, \dots$ при минимизации функции $f(X)$ (т.е. $f(X_{k+1}) < f(X_k)$), непрерывно дифференцируемой в R^n , строят по правилу:

$$X_{k+1} = X_k - \alpha_k A_k \nabla f(X_k), \quad k = 0, 1, \dots,$$

где $-\nabla f(X_k)$ – антиградиент функции $f(X)$ в точке X_k ; A_k – положительно определенная матрица размера $n \times n$, обновляемая на k -ой итерации.

Матрицы $\{A_k\}$ определяются таким образом, чтобы последовательность $\{A_k\}$ при $k \rightarrow \infty$ имела предел, равный $H^{-1}(X_*)$, где – матрица Гессе минимизируемой функции, вычисленная в точке минимума X_* .

На k -ой итерации алгоритма происходит спуск из точки X_k с шагом спуска $|\alpha_k A_k \nabla f(X_k)|$, величина шага α_k определяется для

каждого значения k из условия $\varphi(\alpha_k) = f(X_k + \alpha_k A_k \nabla f(X_k)) \rightarrow \min_{\alpha_k}$.

На первой итерации ($k = 1$) спуск начинают из выбранной пользователем точки X_0 , при этом в качестве A_1 берут единичную матрицу порядка n . Таким образом первая итерация алгоритма совпадает с итерацией метода наискорейшего спуска.

Используя при конструировании матрицы A_k аппроксимацию матрицы $H^{-1}(X_k)$ с учетом информации о градиенте минимизируемой функции в той же точке, можно существенно упростить процедуру нахождения направления спуска на k -ой итерации. Именно эти соображения лежат в основе построения квазиньютоновских методов. Рассмотрим метод Дэвидона-Флетчера-Паузлла

Идея метода заключается в построении элементов последовательности $\{X_k\}$, $k = 0, 1, \dots$ при минимизации функции $f(X)$ по правилу:

$$X_{k+1} = X_k - \alpha_k A_k \nabla f(X_k), \quad k = 0, 1, \dots,$$

где матрица A_k вычисляется в соответствии с:

$$A_{k+1} = A_k + \Delta A_k, \quad A_0 = E.$$

Здесь ΔA_k – положительно определенная матрица порядка n , называемая поправочной. Способ ее выбора и определяет метод Дэвидона-Флетчера-Паузлла (ДФП-метод):

$$\Delta A_k = \frac{\Delta X_k (\Delta X_k)^T}{(\Delta X_k)^T \Delta g_k} - \frac{A_k \Delta g_k (\Delta g_k)^T}{(\Delta g_k)^T A_k \Delta g_k},$$

где $\Delta X_k = X_{k+1} - X_k$, $\Delta g_k = \nabla f(X_{k+1}) - \nabla f(X_k)$.

Данный способ пересчета матрицы A_k сохраняет ее свойство положительной определенности на каждой k -ой итерации.

Для неквадратичных функций $f(X)$ алгоритм перестает быть конечным. Чтобы ослабить влияние накапливающихся погрешностей на сходимость ДФП-метода и уменьшить вероятность появления линейно зависимых направлений спуска, применяют процедуру обновления алгоритма, в соответствие с которой через каждые n итераций в качестве матрицы A_k используют единичную матрицу, т.е.:

$$A_k = \begin{cases} E, & k \in J, J = \{0, n, 2n, \dots\}, \\ A_{k-1} + \Delta A_{k-1}, & k \notin J. \end{cases}$$

Построение последовательности $\{X_k\}$ заканчивается в точке X_k , для которой $\|\nabla f(X_k)\| < \varepsilon_1$, где ε_1 – заданное малое положительное число, или $k \geq M$, где M – предельное число итераций, или при двукратном одновременном выполнении двух неравенств $\|X_{k+1} - X_k\| < \varepsilon_2$, $|f(X_{k+1}) - f(X_k)| < \varepsilon_2$, где ε_2 – малое положительное число.

Алгоритм ДФП-метода

Шаг 1. Задать X_0 , $\varepsilon_1 > 0$, $\varepsilon_2 > 0$, M – предельное число итераций.
Найти градиент $\nabla f(X)$.

Шаг 2. Положить $k = 0$, $A_0 = E$.

Шаг 3. Вычислить $\nabla f(X_k)$.

Шаг 4. Проверить выполнение критерия окончания $\|\nabla f(X_k)\| < \varepsilon_1$:

- а) если неравенство выполнено, то расчет окончен и $X_* = X_k$,
- б) в противном случае перейти к шагу 5.

Шаг 5. Проверить выполнение неравенства $k \geq M$:

- а) если неравенство выполнено, расчет окончен и $X_* = X_k$,
- б) если нет, то при $k = 0$ перейти к шагу 10, а при $k \geq 1$ перейти к шагу 6.

Шаг 6. Вычислить $\Delta g_{k-1} = \nabla f(X_k) - \nabla f(X_{k-1})$.

Шаг 7. Вычислить $\Delta X_{k-1} = X_k - X_{k-1}$.

Шаг 8. Вычислить $\Delta A_{k-1} = \frac{\Delta X_{k-1}(\Delta X_{k-1})^T}{(\Delta X_{k-1})^T \Delta g_{k-1}} - \frac{A_{k-1} \Delta g_{k-1} (\Delta g_{k-1})^T}{(\Delta g_{k-1})^T A_{k-1} \Delta g_{k-1}}$.

Шаг 9. Вычислить $A_k = A_{k-1} + \Delta A_{k-1}$.

Шаг 10. Вычислить $S_k = -A_k \nabla f(X_k)$.

Шаг 11. Вычислить α_k из условия: $\varphi(\alpha) = f(X_k + \alpha S_k) \rightarrow \min_{\alpha}$.

Шаг 12. Вычислить $X_{k+1} = X_k + \alpha_k S_k$.

Шаг 13. Проверить выполнение условий:

$\|X_{k+1} - X_k\| < \varepsilon_2$, $|f(X_{k+1}) - f(X_k)| < \varepsilon_2$:

а) в случае выполнения обоих условий в двух последовательных итерациях с номерами k и $k = k - 1$ расчет окончен, и найдена точка $X_* = X_{k+1}$,

б) если не выполняется хотя бы одно из условий, полагаем $k = k + 1$ и переходим к шагу 3.

Замечание

■ Алгоритм ДФП-метода в применении к квадратичной функции $f(X) = \frac{1}{2}(H(X), X) + (b, X)$ с положительно определенной матрицей Гессе H обеспечивает отыскание минимума $X_* = Hb$ не более чем за n шагов.

Пример. С помощью ДФП-метода найти точку минимума функции $f(X) = 4x_1^2 + 3x_2^2 - 4x_1x_2 + x_1$, $X_0 = (0, 0)^T$.

Решение.

Шаг 1. Зададим $X_0 = (0, 0)^T$, $\varepsilon_1 = 0,1$, $\varepsilon_2 = 0,01$, $M = 10$.

$$\nabla f(X) = (8x_1 - 4x_2 + 1; 6x_2 - 4x_1)^T.$$

Шаг 2. $k = 0$, $A_0 = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}$.

Шаг 3. $\nabla f(X_0) = (1; 0)^T$.

Шаг 4. $\|\nabla f(X_0)\| = 1 > \varepsilon_1$, переходим к шагу 5.

Шаг 5. $k = 0 < M$, переходим к шагу 10.

Шаг 10. $S_0 = -\nabla f(X_0) = (-1; 0)^T$.

Шаг 11. $\varphi(\alpha) = f(-\alpha; 0) = 4\alpha^2 - \alpha \rightarrow \min_{\alpha}$, $\alpha_0 = 1/8$.

Шаг 12. $X_1 = X_0 + \alpha_0 S_0 = (0; 0)^T + \frac{1}{8}(-1; 0)^T = (-1/8; 0)^T$.

Шаг 3. $\nabla f(X_1) = (0; 1/2)^T$.

Шаг 4. $\|\nabla f(X_1)\| = 0,5 > \varepsilon_1$.

Шаг 5. $k = 1 < M$.

Шаг 6. $\Delta g_0 = \nabla f(X_1) - \nabla f(X_0) = (0; 1/2)^T - (1; 0)^T = (-1; 1/2)^T$.

Шаг 7. $\Delta X_0 = X_1 - X_0 = (-1/8; 0)^T - (0; 0)^T = (-1/8; 0)^T$.

Шаг 8. $\Delta A_0 = \frac{\Delta X_0 (\Delta X_0)^T}{(\Delta X_0)^T \Delta g_0} - \frac{A_0 \Delta g_0 (\Delta g_0)^T}{(\Delta g_0)^T A_0 \Delta g_0} =$

$$= \frac{(-1/8; 0)^T (-1/8; 0)}{(-1/8; 0)(-1; 1/2)^T} - \frac{\begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} (-1; 1/2)^T (-1; 1/2)}{(-1; 1/2) \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} (-1; 1/2)^T} =$$

$$\begin{pmatrix} 1/8 & 0 \\ 0 & 0 \end{pmatrix} - \begin{pmatrix} 4/5 & -2/5 \\ -2/5 & 1/5 \end{pmatrix} = \begin{pmatrix} -27/40 & 2/5 \\ 2/5 & -1/5 \end{pmatrix}.$$

Шаг 9. $A_1 = A_0 + \Delta A_0 = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} + \begin{pmatrix} -27/40 & 2/5 \\ 2/5 & -1/5 \end{pmatrix} = \begin{pmatrix} 13/40 & 2/5 \\ 2/5 & 4/5 \end{pmatrix}$.

Шаг 10. $S_1 = -A_1 \nabla f(X_1) = \begin{pmatrix} -13/40 & -2/5 \\ -2/5 & -4/5 \end{pmatrix} \begin{pmatrix} 0 \\ 1/2 \end{pmatrix} = \begin{pmatrix} -1/5 \\ -2/5 \end{pmatrix}$.

Шаг 11. $\varphi(\alpha) = f(-1/8 - 1/5\alpha; -2/5\alpha) = 8/25\alpha^2 - 1/5\alpha - 1/16 \rightarrow \min_{\alpha}, \alpha_1 = 5/16$.

Шаг 12. $X_2 = X_1 + \alpha_1 S_1 = (-1/8; 0)^T + \frac{5}{16}(-1/5; -2/5)^T = (-3/16; -1/8)^T$.

Шаг 3. $\nabla f(X_2) = (0; 0)^T$.

Шаг 4. $\|\nabla f(X_2)\| = 0 < \varepsilon_1$, расчет окончен и $X_* = X_2$.

4. Задачи для упражнений

1. Методами градиентного и наискорейшего градиентного спуска найти минимум функции $f(X) = x_1^3 + x_1x_2 + x_2^2 - 2x_1 + 3x_2 - 4$, $X_0 = (0, 0)^T$.

2. Методами градиентного и наискорейшего градиентного спуска, методами Флетчера-Ривса и Д-Ф-П найти минимум функции $f(X) = (x_2 + x_1^2)^2 + (1 - x_1)^2$, $X_0 = (0, 0)^T$.

3. Методами градиентного и наискорейшего градиентного спуска, методами Флетчера-Ривса и Д-Ф-П найти минимум функции $f(X) = [(x_2 + 1)^2 + x_1^2] \cdot [x_1^2 + (x_2 - 1)^2]$ из начальных точек $X_0 = (0,5; 0)^T$ и $X_0 = (-0,1; -0,5)^T$.

4. Методами градиентного и наискорейшего градиентного спуска, методами Флетчера-Ривса и Д-Ф-П найти минимум функции

$f(X) = (x_2^2 + x_1^2 - 1)^2 + (x_1 + x_2 - 1)^2$ из начальных точек $X_0 = (0, 3)^T$ и $X_0 = (3, 0)^T$.

5. Методами градиентного и наискорейшего градиентного спуска, методами Флэтчера-Ривса и Д-Ф-П найти минимум функции $f(X) = -x_1^2 \cdot \exp[1 - x_1^2 - 20,25(x_1 - x_2)^2]$ из начальной точки $X_0 = (0,1; 0,5)^T$.

6. Задана функция $f(X)$ и начальная точка X_0 . Найдите минимум функции $f(X)$:

- 1) $f(X) = x_1^3 - x_1 x_2 + x_2^2 - 2x_1 + x_2 - 4$, $X_0 = (-1; 1)^T$;
- 2) $f(X) = x_1^2 + 2x_2^2 - 4x_1 - 4x_2$, $X_0 = (0; 0)^T$;
- 3) $f(X) = x_1^2 + 10(x_2 - \sin x_1)^2$, $X_0 = (1; 1)^T$;
- 4) $f(X) = e^{x_1^2} + x_2 + (x_1 - x_2)^2$, $X_0 = (0; 0)^T$;
- 5) $f(X) = e^{x_2^2 - x_1} + e^{x_1}$, $X_0 = (-1; -1)^T$;
- 6) $f(X) = e^{-x_1} + x_1^2 + x_2^2$, $X_0 = (0,5; 0,5)^T$;
- 7) $f(X) = e^{-x_2} + \cos(x_1^2 + x_2)$, $X_0 = (0; 0)^T$;
- 8) $f(X) = e^{x_1} + x_2^2 - 2x_1$, $X_0 = (0; 0)^T$;
- 9) $f(X) = x_1^2 - \cos(x_2 - 1)$, $X_0 = (0; 0)^T$;
- 10) $f(X) = x_2^2 + e^{x_1} - 3x_1$, $X_0 = (0; 0)^T$;
- 11) $f(X) = e^{x_1 - x_2} + x_1^2 + x_2^2$, $X_0 = (1; 1)^T$;
- 12) $f(X) = e^{x_1^2 - x_2} + e^{x_2}$, $X_0 = (-1; -1)^T$;
- 13) $f(X) = e^{x_1} + (x_1 - x_2^2)^2$, $X_0 = (0,5; 0,5)^T$;
- 14) $f(X) = e^{x_1} + x_1^2 + x_2^2$, $X_0 = (-1; -1)^T$;
- 15) $f(X) = e^{x_2^2 - x_1} + x_1^2$, $X_0 = (0; 0)^T$;
- 16) $f(X) = e^{-x_1} - \cos(x_1^2 + x_2^2)$, $X_0 = (0; 0)^T$;
- 17) $f(X) = e^{-x_2} + (x_2 + x_1^2)^2$, $X_0 = (0,5; 0,5)^T$;
- 18) $f(X) = e^{x_1 + x_2} + x_1^2 + x_2^2$, $X_0 = (-1; -1)^T$;

- 19) $f(X) = x_2^2 - \cos(x_1 - 1)$, $X_0 = (0; 0)^T$;
- 20) $f(X) = x_1^2 + e^{x_2} - 3x_2$, $X_0 = (0; 0)^T$;
- 21) $f(X) = e^{x_2} + x_1^2 + x_2^2$, $X_0 = (1; 1)^T$;
- 22) $f(X) = e^{-x_1} + x_2^2 + 2x_1$, $X_0 = (0; 0)^T$.
-

1. Пантелеев, А.В. Методы оптимизации в примерах и задачах [Текст]: учеб. пособие / А.В. Пантелеев, Т.А. Летова; 2-е изд., испрavl. – М.: Высш. шк., 2005. – 544 с.: ил.

2. Аттетков, А.В. Методы оптимизации [Текст]: учебник для вузов / А.В. Аттетков, С.В. Галкин, В.С. Зарубин / Под ред. В.С. Зарубина, А.П. Крищенко; 2-е изд. – М.: Изд-во МГТУ им. Н.Э. Баумана, 2003. – 440 с.