

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 » 06 2017 г.

## МНОГОМЕРНАЯ ОПТИМИЗАЦИЯ МЕТОДАМИ ВТОРОГО 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 *C.A. Филист*

**Многомерная оптимизация методами второго порядка:** методические указания к лабораторным занятиям по дисциплине «Методы оптимизации» / Юго-Зап. гос. ун-т; сост.: Ж.Т. Жусубалиев. Курск, 2017. – 12 с.: табл. 1.– Библиограф.: с. 12.

Рассматриваются алгоритмы безусловной минимизации функций многих переменных методами второго порядка, а также вопросы их численной реализации с помощью ЭВМ.

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. Постановка задачи

Пусть дана функция  $f(X)$ , ограниченная снизу на множестве  $R^n$  и имеющая непрерывные частные производные во всех его точках.

Требуется найти локальный минимум функции  $f(X)$  на множестве допустимых решений  $X = R^n$ , т.е. найти такую точку  $X_* \in R^n$ , что  $f(X_*) = \min_{X \in R^n} f(X)$ ,  $f(X) \in C^2$

## 2. Метод Ньютона

Если функция  $f(X)$  является дважды дифференцируемой в  $R^n$ , то эффективность процесса поиска точки  $X_* \in R^n$  ее минимума можно повысить, используя информацию не только о градиенте  $\nabla f(X)$  этой функции, но и о матрице Гессе  $H(X)$ . Алгоритмы такого поиска обычно относят к *методу Ньютона*. В простейшем варианте алгоритма на каждой  $k$ -ой итерации целевая функция аппроксимируется в окрестности точки  $X_{k-1}$  (на первой итерации в окрестности начальной точки  $X_0$ ) квадратичной функцией  $\varphi_k(X)$  и затем определяется точка  $X_k$  минимума функции  $\varphi_k(X)$ . На следующей,  $(k+1)$ -й итерации строится новая квадратичная аппроксимация уже в окрестности точки  $X_k$  [1, 2, 3].

При помощи формулы Тейлора с остаточным членом в форме Пеано представим функцию  $f(X)$  в окрестности точки  $X_{k-1}$  в виде:

$$f(X) = f(X_{k-1}) + (\nabla f(X_{k-1}), X - X_{k-1}) + \\ + \frac{1}{2}(H(X_{k-1})(X - X_{k-1}), X - X_{k-1}) + o(|X - X_{k-1}|^2).$$

Пренебрегая последним слагаемым в правой части, получаем квадратичную функцию:

$$\varphi_k(X) = f(X_{k-1}) + (\nabla f(X_{k-1}), X - X_{k-1}) + \\ + \frac{1}{2}(H(X_{k-1})(X - X_{k-1}, X - X_{k-1})).$$

Если матрица Гессе  $H(X_{k-1})$  функции  $f(X)$ , вычисленная в точке  $X_{k-1}$ , является положительно определенной, то точка  $X_k$  минимума функции  $\varphi_k(X)$  единственна и может быть найдена из условия, что ее градиент равен нулевому вектору:

$$\nabla \varphi_k(X) = \nabla f(X_{k-1}) + H(X_{k-1})(X - X_{k-1}) = 0_n.$$

Отсюда получаем:

$$X_k = X_{k-1} - H^{-1}(X_{k-1})\nabla f(X_{k-1}), \quad k = 1, 2, \dots$$

Полученное соотношение можно трактовать как рекуррентное соотношение итерационной процедуры метода Ньютона, предназначенного для решения системы  $\nabla f(X) = 0_n$  нелинейных уравнений.

Построение последовательности  $\{X_k\}$  заканчивается в точке  $X_k$ , для которой  $\|\nabla f(X_k)\| < \varepsilon_1$ , где  $\varepsilon_1$  – заданное малое положительное 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  $\varepsilon_2$  – 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  $\nabla f(X)$  и матрицу Гессе  $H(X)$ .

Шаг 2. Положить  $k = 0$ .

Шаг 3. Вычислить  $\nabla f(X_k)$ .

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

- 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 матрицу  $H(X_k)$ .

Шаг 7. Вычислить матрицу  $H^{-1}(X_k)$ .

Шаг 8. Проверить выполнение условия  $H^{-1}(X_k) > 0$ :

- а) если  $H^{-1}(X_k) > 0$ , то перейти к шагу 9;
- б) если нет, то перейти к шагу 10, положив  $S_k = -\nabla f(X_k)$

Шаг 9. Определить шаг спуска  $S_k = -H^{-1}(X_k)\nabla f(X_k)$ .

Шаг 10. Найти точку  $X_{k+1} = X_k + S_k$ .

Шаг 11. Проверить выполнение условий:

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

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

б) в противном случае положить  $k = k + 1$  и перейти к шагу 3.

**Пример.** Найти локальный минимум квадратичной функции  $f(X) = 8x_1^2 + 4x_1x_2 + 5x_2^2$  методом Ньютона.

### Решение.

Определение точки, в которой выполняется по крайней мере один критерий окончания расчетов.

Шаг 1. Зададим  $X_0$ ,  $\varepsilon_1 > 0$ ,  $\varepsilon_2 > 0$ ,  $M$ :  $X_0 = (10; 10)^T$ ;  $\varepsilon_1 = 0,1$ ;  $\varepsilon_2 = 0,15$ ;  $M = 10$ . Найдем градиент функции  $\nabla f(X) = (16x_1 + 4x_2; 4x_1 + 10x_2)^T$  и матрицу Гессе  $H(X) = \begin{pmatrix} 16 & 4 \\ 4 & 10 \end{pmatrix}$ .

Шаг 2. Положим  $k = 0$ .

Шаг 3. Вычислим  $\nabla f(X_0)$ :  $\nabla f(X_0) = (200; 140)^T$ .

Шаг 4. Проверим выполнение критерия окончания  $\|\nabla f(X_0)\| < \varepsilon_1$ :

$$\|\nabla f(X_0)\| = 244,13 > 0,1$$

Переходим к шагу 5.

Шаг 5. Проверим выполнение неравенства  $k \geq M$ :  $0 < 10$ . Переходим к шагу 6.

Шаг 6. Вычислим матрицу Гессе в точке  $X_0$ :  $H(X_0) = \begin{pmatrix} 16 & 4 \\ 4 & 10 \end{pmatrix}$ .

Шаг 7. Вычислим матрицу  $H^{-1}(X_0)$ :  $H^{-1}(X_0) = \begin{pmatrix} \frac{10}{144} & -\frac{4}{144} \\ -\frac{4}{144} & \frac{16}{144} \end{pmatrix}$ .

Шаг 8. Проверим выполнение условия  $H^{-1}(X_0) > 0$ . Так как  $\Delta_1 = \frac{10}{144} > 0$ ,  $\Delta_2 = \frac{4}{144} > 0$ , то согласно критерию Сильвестра  $H^{-1}(X_0) > 0$ .

Шаг 9. Определим

$$S_0 = -H^{-1}(X_0)\nabla f(X_0) = -\begin{pmatrix} \frac{10}{144} & -\frac{4}{144} \\ -\frac{4}{144} & \frac{16}{144} \end{pmatrix} \begin{pmatrix} 200 \\ 140 \end{pmatrix} = \begin{pmatrix} -10 \\ -10 \end{pmatrix}.$$

Шаг 10. Вычислим точку

$$X_1 = X_0 + S_0 = (10, 10)^T + (-10, -10)^T = (0, 0)^T.$$

Шаг 11. Проверим выполнение условий:

$$\|X_1 - X_0\| < \varepsilon_2, f(X_1) - f(X_0) < \varepsilon_2: \|X_1 - X_0\| = 14,14 < 0,15 = \varepsilon_2;$$

$$f(X_1) - f(X_0) = 1700 > 0,15 = \varepsilon_2.$$

Полагаем  $k = 1$  и переходим к шагу 3.

Шаг 3. Вычислим  $\nabla f(X_1)$ :  $\nabla f(X_1) = (0; 0)^T$ .

Шаг 4. Проверим выполнение критерия окончания  $\|\nabla f(X_1)\| < \varepsilon_1$ :

$\|\nabla f(X_0)\| = 0 < 0,1$ . Расчет окончен. В точке  $X_1$  выполняется необходимое условие первого порядка, поэтому она является стационарной точкой.

Анализ точки  $X_1$ .

Функция  $f(X) = 8x_1^2 + 4x_1x_2 + 5x_2^2$  является строго выпуклой, так как ее матрица вторых производных  $\begin{pmatrix} 16 & 4 \\ 4 & 10 \end{pmatrix} > 0$  в силу того, что

$\Delta_1 = 16 > 0$ ,  $\Delta_2 = 4 > 0$ . Найденная точка  $X_1 = (0, 0)^T$  есть точка локального и одновременно глобального минимума  $f(X)$ .

Сходимость метода Ньютона существенно зависит от выбора начального приближения. Если функция сильно выпуклая и для любых точек  $X, Y \in R^n$  относительно матрицы Гессе  $H(X)$  целевой функции выполнено неравенство  $\|H(X) - H(Y)\| \leq L|X - Y|$ ,  $L > 0$ , а начальное приближение выбрано удачно (точка  $X_0$  расположена до-

статочно близко к точке  $X_*$  минимума), то алгоритм метода Ньютона обладает квадратичной скоростью сходимости, т.е. справедлива оценка

$$|X_k - X_*| \leq C |X_{k-1} - X_*|^2, \quad k = 1, 2, \dots, \quad C = \text{const} \quad [1, 2, 3].$$

Это позволяет для такой функции использовать в качестве условия прекращения итераций выполнение неравенства  $|X_k - X_{k-1}| < \varepsilon$ , где  $\varepsilon$  - заданное достаточно малое положительное число. Но в случае, когда функция не является сильно выпуклой или же начальное приближение находится далеко от искомой точки  $X_*$ , метод Ньютона может расходиться.

Квадратичная скорость сходимости, а также возможность контроля за соблюдением достаточного условия минимума функции  $f(X)$  на каждой  $k$ -ой итерации при помощи матрицы Гессе  $H(X_{k-1})$  этой функции способствуют высокой эффективности рассматриваемого алгоритма.

Одним из условий применения метода Ньютона является сохранение положительной определенности матрицы Гессе  $H(X_{k-1})$  функции  $f(X)$  на каждой  $k$ -ой итерации, так как иначе вектор  $S_k = -H^{-1}(X_k) \nabla f(X_k)$  может не соответствовать направлению спуска, вдоль которого эта функция убывает. Более того, матрица  $H(X_{k-1})$  может быть вырожденной и не иметь обратной матрицы [1, 2].

### 3. Метод Ньютона-Рафсона

Если начальное приближение  $X_0$  находится на значительном расстоянии от точки минимума  $X_*$ , шаг по методу Ньютона может оказаться чрезмерно большим. Вследствие этого метод может не сходиться. Метод Ньютона можно модифицировать с тем, чтобы обеспечить уменьшение значения минимизируемой функции от итерации к итерации. Последовательность итераций строится в соответствии с формулой:

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

Заметим, что в методе Ньютона  $\alpha_k = 1$ .

Выбор шага  $\alpha_k$  осуществляется таким образом, чтобы  $\varphi(\alpha_k) = f(X_{k+1}) \rightarrow \min$ .

Построение последовательности  $\{X_k\}$  заканчивается в точке  $X_k$ , для которой  $\|\nabla f(X_k)\| < \varepsilon_1$ , где  $\varepsilon_1$  – 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  $\varepsilon_2$  – малое положительное число.

Алгоритм модифицированного метода Ньютона включает следующие шаги:

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

Шаг 2. Положить  $k = 0$ .

Шаг 3. Вычислить  $\nabla f(X_k)$ .

Шаг 4. Проверить выполнение условия  $\|\nabla f(X_k)\| \leq \varepsilon_1$ :

- а) если неравенство выполнено, то расчет закончен,  $X_* = X_k$ ;
- б) если нет, перейти к шагу 5.

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

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

Шаг 6. Вычислить матрицу  $H(X_k)$ .

Шаг 7. Вычислить матрицу  $H^{-1}(X_k)$ .

Шаг 8. Проверить выполнение условия  $H^{-1}(X_k) > 0$ :

- а) если условие выполняется, то найти  $S_k = -H^{-1}(X_k)\nabla f(X_k)$ ;
- б) если нет, то положить  $S_k = -\nabla f(X_k)$ .

Шаг 9. Определить  $X_{k+1} = X_k + \alpha_k S_k$ .

Шаг 10. Найти шаг  $\alpha_k$  из условия  $\varphi(\alpha) = f(X_k + \alpha S_k) \rightarrow \min_{\alpha}$ , т.е. путем решения задачи одномерной минимизации.

Шаг 11. Вычислить  $X_{k+1} = X_k + \alpha_k S_k$ .

Шаг 12. Проверить выполнение неравенств:

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

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

б) в противном случае положить  $k = k + 1$  и перейти к шагу 3.

**Пример.** Найти локальный минимум квадратичной функции  $f(X) = 8x_1^2 + 4x_1x_2 + 5x_2^2$  методом Ньютона-Рафсона.

**Решение.**

Определение точки, в которой выполняется по крайней мере один критерий окончания расчетов.

Шаг 1. Зададим  $X_0$ ,  $\varepsilon_1 > 0$ ,  $\varepsilon_2 > 0$ ,  $M$ :  $X_0 = (10; 10)^T$ ;  $\varepsilon_1 = 0,1$ ;  $\varepsilon_2 = 0,15$ ;  $M = 10$ . Найдем градиент функции  $\nabla f(X) = (16x_1 + 4x_2; 4x_1 + 10x_2)^T$  и матрицу Гессе  $H(X) = \begin{pmatrix} 16 & 4 \\ 4 & 10 \end{pmatrix}$ .

Шаг 2. Положим  $k = 0$ .

Дальнейшие вычисления представлены в таблице 1.

Таблица 1

$k$	$X_k$	$\nabla f(X_k)$	$H(X_k)$	$H^{-1}(X_k)$	$S_k$	$\alpha_k$	$X_{k+1}$
0	$\begin{pmatrix} 10 \\ 10 \end{pmatrix}$	$\begin{pmatrix} 200 \\ 140 \end{pmatrix}$	$\begin{pmatrix} 16 & 4 \\ 4 & 10 \end{pmatrix}$	$\frac{1}{144} \begin{pmatrix} 10 & -4 \\ -4 & 16 \end{pmatrix}$	$\begin{pmatrix} -10 \\ -10 \end{pmatrix}$	1	$\begin{pmatrix} 0 \\ 0 \end{pmatrix}$
1	$\begin{pmatrix} 0 \\ 0 \end{pmatrix}$	$\begin{pmatrix} 0 \\ 0 \end{pmatrix}$					

$\|\nabla f(X_1)\| = 0 < 0,1$ , следовательно, расчет окончен:  $X_* = X_1$ .

Метод Ньютона-Рафсона менее чувствителен к выбору начальной точки  $X_0$  по сравнению с «классическим» методом Ньютона. Последовательность  $\{X_k\}$  сходится к точке минимума  $X_*$  с квадратичной скоростью [1, 2].

#### 4. Метод Марквардта

Метод является комбинацией градиентного метода и метода Ньютона, в котором сочетаются положительные свойства обоих методов. Вместе с тем при использовании метода Марквардта требуется информация о значениях вторых производных функции. Градиент указывает направление наибольшего локального увеличения функции, а движение в направлении, противоположном градиенту, из точ-

ки  $X_0$ , расположенной на значительном расстоянии от точки минимума  $X_*$ , приводит к существенному уменьшению функции. Направления эффективного поиска в окрестности точки минимума определяются по методу Ньютона. Простая идея объединения градиентного метода и метода Ньютона была положена в основу алгоритма, разработанного Марквардтом в 1963 г. В соответствии с этим методом направление поиска определяется равенством:

$$S_k = -[H(X_k) + \mu_k E]^{-1} \nabla f(X_k), \quad k = 0, 1, \dots$$

Здесь  $\mu_k$  позволяет не только изменять направление поиска, но и регулировать длину шага. На начальном шаге параметру  $\mu_0$  назначается большое значение (например,  $\mu_0 = 10^4$ ).

Если  $f(X_k - (H(X_k) + \mu_k E)^{-1} \nabla f(X_k)) < f(X_k)$ , то  $\mu_{k+1} = \frac{\mu_k}{2}$ . В противном случае  $\mu_{k+1} = 2\mu_k$ . Легко видеть, что алгоритм Марквардта в зависимости от величины  $\mu_k$  на каждом шаге по своим свойствам либо приближается к алгоритму Ньютона, либо к алгоритму градиентного спуска.

Построение последовательности  $\{X_k\}$  заканчивается, когда либо выполняется условие  $\|\nabla f(X_k)\| < \varepsilon_1$ , либо число итераций  $k \geq M$ , где  $\varepsilon_1$  – малое положительное число, а  $M$  – предельное число итераций.

Шаги алгоритма Марквардта:

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

Шаг 2. Положить  $k = 0$ ,  $\mu_k = \mu_0$ .

Шаг 3. Вычислить  $\nabla f(X_k)$ .

Шаг 4. Проверить выполнение условия  $\|\nabla f(X_k)\| \leq \varepsilon_1$ :

- а) если неравенство выполнено, то расчет окончен,  $X_* = X_k$ ;
- б) если нет, перейти к шагу 5.

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

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

Шаг 6. Вычислить  $H(X_k)$ .

Шаг 7. Вычислить  $H(X_k) + \mu_k E$ .

Шаг 8. Вычислить  $[H(X_k) + \mu_k E]^{-1}$ .

Шаг 9. Вычислить  $S_k = -[H(X_k) + \mu_k E]^{-1} \nabla f(X_k)$ .

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

Шаг 11. Проверить выполнение условия  $f(X_{k+1}) < f(X_k)$ :

- а) если неравенство выполняется, то перейти к шагу 12;
- б) если нет, перейти к шагу 13.

Шаг 12. Положить  $k = k + 1$ ,  $\mu_{k+1} = \frac{\mu_k}{2}$  и перейти к шагу 3.

Шаг 13. Положить  $\mu_k = 2\mu_k$  и перейти к шагу 7.

Метод Марквардта характеризуется относительной простотой, свойством убывания целевой функции при переходе от итерации к итерации, высокой скоростью сходимости в окрестности точки минимума  $X_*$ . Главный недостаток метода заключается в необходимости вычисления матрицы Гессе и последующего решения системы линейных уравнений для определения шага спуска.

## 5. Задачи для упражнений

1. Найти минимум функции  $f(X) = [x_1^2 + (x_2 + 1)^2] \cdot [x_1^2 + (x_2 - 1)^2]$  из начальной точки  $X_0 = (4, 3)^T$ .
2. Для функции  $f(X) = 100 \cdot (x_2 - x_1^2)^2 + (1 - x_1)^2$  и начальной точки  $X_0 = (-1,2; 0)^T$  найдите точку, которой соответствует минимальное значение  $f(X)$ .

3. Найдите координаты точек минимума функции Химмельблау  $f(X) = (x_1^2 + x_2 - 11)^2 + (x_1 + x_2^2 - 7)^2$  из начальных точек:  $X_0 = (5; 5)^T$ ;  $X_0 = (5; -5)^T$ ;  $X_0 = (0; 0)^T$ ;  $X_0 = (-5; -5)^T$ ;  $X_0 = (5; 0)^T$ .

4. 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)  $f(X) = e^{-x_2} + (x_2 + x_1^2)^2$ ,  $X_0 = (0,5; 0,5)^T$ ;
- 16)  $f(X) = x_2^2 - \cos(x_1 - 1)$ ,  $X_0 = (0; 0)^T$ ;
- 17)  $f(X) = x_1^2 + e^{x_2} - 3x_2$ ,  $X_0 = (0; 0)^T$ ;
- 18)  $f(X) = e^{x_2} + x_1^2 + x_2^2$ ,  $X_0 = (1; 1)^T$ ;
- 

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

2. Аттетков, А.В. Методы оптимизации: 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.

3. Marquardt, D.W. An Algorithm for Least Squares Estimation of Non-Linear Parameters / D.W. Marquardt; SIAM J., 11. Pp. 431 – 441.