

# Численная оптимизация


## Функции многих переменных

12 ноября 2012 г.

- Методы прямого поиска:
  - поиск по симплексу;
  - метод Хука–Дживса;
  - метод сопряжённых направлений Пауэлла.
- Градиентные методы:
  - метод Коши;
  - метод Ньютона;
  - метод Марквардта;
  - квазиньютоновские методы;
- Методы решения задач о наименьших квадратах.

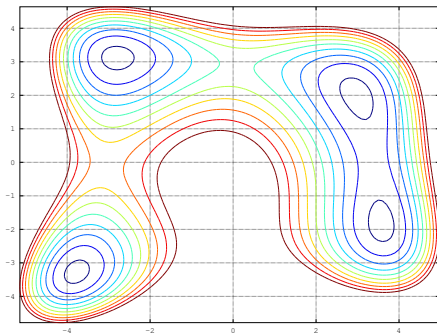
## Функция Розенброка

$$f(x) = \sum_{i=1}^{n-1} ((1 - x_i)^2 + 100(x_{i+1} - x_i^2)^2)$$



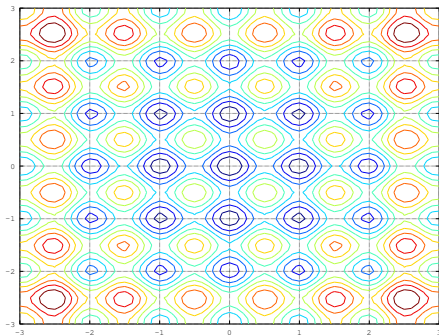
## Функция Химмельблау

$$f(x) = (x_1^2 + x_2 - 11)^2 + (x_1 + x_2^2 - 7)^2$$



## Функция Растргина

$$f(x) = An + \sum_{i=1}^{n-1} (x_i^2 - A \cos(2\pi x_i))$$



## Регулярный симплекс в $N$ -мерном пространстве

Многогранник, образованный  $N + 1$  равноотстоящими друг от друга точками–вершинами.

$x^{(0)}$  — базовая (начальная) точка

$$x^{(i)} = \begin{cases} x_j^{(0)} + \delta_1, & j \neq i, \\ x_j^{(0)} + \delta_2, & j = i, \end{cases} \quad i, j = 1, 2, \dots, N.$$

$$\delta_1 = \frac{\sqrt{N+1} + N - 1}{N\sqrt{2}}\alpha, \quad \delta_2 = \frac{\sqrt{N+1} - 1}{N\sqrt{2}}\alpha.$$

$\alpha$  — масштабный коэффициент

# Поиск по симплексу ( $S^2$ -метод)

$x^{(j)}$  — отражаемая точка

«Центр тяжести» оставшихся точек:

$$x_c = \frac{1}{N} \sum_{\substack{i=0,1,\dots,N \\ i \neq j}} x^{(i)}$$

$$x = x^{(j)} + \lambda(x_c - x^{(j)})$$

Новая точка:

$$x_{\text{нов}}^{(j)} = 2x_c - x_{\text{пред}}^{(j)}$$

# Поиск по симплексу ( $S^2$ -метод)

- 1 “Накрытие” точки минимума.
- 2 Циклическое движение

$$M = 1.65N + 0.05N^2$$

- 3 Критерий окончания поиска



## Преимущества

- 1 Сравнительная простота расчётов и логической структуры метода.
- 2 Невысокий уровень требований к объёму машинной памяти.
- 3 Небольшое число параметров: масштабный множитель  $\alpha$ , коэффициент уменьшения значения  $\alpha$  и параметры окончания поиска.
- 4 Алгоритм эффективен даже в случае большой ошибки вычисления целевой функции.


## Недостатки

- 1 Возможны проблемы с масштабированием.
- 2 Медленная работа алгоритма.
- 3 Не существует простого способа расширения симплекса, не требующего пересчёта значений целевой функции во всех точках образца.

# Поиск по симплексу ( $S^2$ -метод)

Пример: минимизация функции Розенброка

Количество итераций: 8277.



# Поиск по симплексу ( $S^2$ -метод)

Модификация Нелдера–Мида

## Поиск по деформируемому многограннику

$$x = x^{(j)} + (1 + \theta) \cdot (x_c - x^{(j)})$$

(1, 0.5, 2)

(1, 0.25, 2.5)

Количество итераций при минимизации функции Розенброка: 398  
(1211)

- Исследующий поиск
- Поиск по образцу

- 1 Определить: начальную точку  $x^{(0)}$ ; приращения  $\Delta_i$ ,  $i = 1, 2, \dots, N$ ; коэффициент уменьшения шага  $\alpha > 1$ ; параметр окончания поиска  $\varepsilon > 0$ ;
- 2 Провести исследующий поиск.
- 3 Если исследующий поиск был удачный, то перейти к шагу 5.
- 4 Если  $\|\Delta x\| < \varepsilon$ , то прекратить поиск.  
Иначе — уменьшить приращения по формуле

$$\Delta_i \leftarrow \Delta_i / \alpha, \quad i = 1, \dots, N.$$

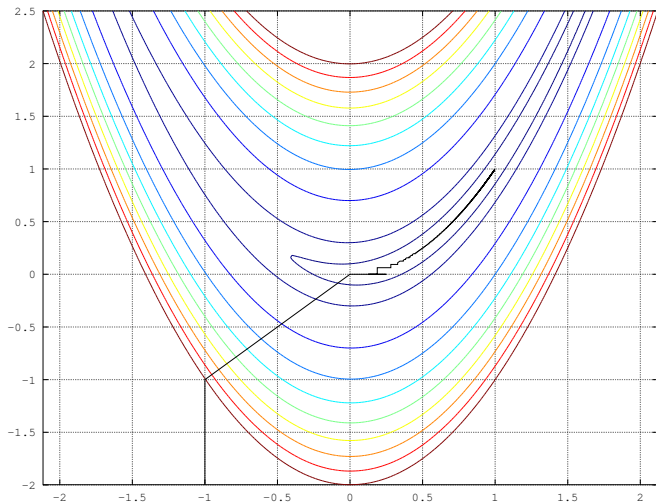
Перейти к шагу 2.

5. Провести поиск по образцу

$$x_p^{(k+1)} = x^{(k)} + (x^{(k)} - x^{(k-1)}).$$

6. Провести исследующий поиск, используя  $x_p^{(k+1)}$  в качестве базовой точки; пусть  $x^{(k+1)}$  — полученная в результате точка.
7. Если  $f(x^{(k+1)}) < f(x^{(k)})$ , то  $x^{(k-1)} \leftarrow x^{(k)}$ ,  $x^{(k)} \leftarrow x^{(k+1)}$  и перейти к шагу 5.  
Иначе перейти к шагу 4.

Минимизация функции Розенброка: 1609 итераций.





Метод ориентирован на решение задач с квадратичными целевыми функциями.

- 1 Квадратичная функция представляет собой простейший вид нелинейных функций, для которых может быть построена задача безусловной оптимизации.
- 2 В окрестности точки оптимума любую гладкую нелинейную функцию можно аппроксимировать квадратичной функцией.

Если квадратичная функция  $N$  переменных приведена к виду суммы полных квадратов, то её оптимум может быть найден в результате реализации  $N$  одномерных поисков по преобразованным координатным направлениям.

# Метод сопряжённых направлений Пауэлла

$C$  — симметричная  $N \times N$ -матрица.

Направления  $s^{(1)}, s^{(2)}, \dots, s^{(r)}$ ,  $r \leq N$ , называются  $C$ -сопряжёнными, если эти направления линейно независимы и

$$s^{(i)\top} C s^{(j)} = 0 \text{ для всех } i \neq j.$$

$C$ -сопряжённые направления задаются системой векторов  $T$ , которая приводит  $C$  к диагональному виду:

$$T^\top C T = D$$

## Свойство параллельного пространства

Пусть заданы квадратичная функция  $q(x)$ , две произвольные несовпадающие точки  $x^{(1)}$  и  $x^{(2)}$ , а также направление  $d$ . Если точка  $y^{(1)}$  минимизирует  $q(x^{(1)} + \lambda d)$ , а точка  $y^{(2)}$  минимизирует  $q(x^{(2)} + \lambda d)$ , то направление  $y^{(2)} - y^{(1)}$  сопряжено с  $d$ .

$$q(x) = a + b^T x + \frac{1}{2} x^T C x$$

$$x = x^{(1)} + \lambda d, \quad \frac{\partial q}{\partial \lambda} = \frac{\partial q}{\partial x} \frac{\partial x}{\partial \lambda} = (b^T + x^T C) d$$

$$(y^{(1)})^T C + b^T) d = 0, \quad (y^{(2)})^T C + b^T) d = 0$$

$$(y^{(2)} - y^{(1)})^T C d = 0$$

## Обобщённое свойство параллельного пространства


Если точка  $y^{(1)}$  найдена в результате поиска из точки  $x^{(1)}$  вдоль каждого из  $M$  ( $< N$ ) сопряжённых направлений, а точка  $y^{(2)}$  получена в результате поиска из точки  $x^{(2)}$  вдоль каждого из тех же  $M$  сопряжённых направлений  $s^{(1)}, s^{(2)}, \dots, s^{(M)}$ , то вектор  $y^{(2)} - y^{(1)}$  задаёт направление, сопряжённое со всеми выбранными  $M$  направлениями.

# Метод сопряжённых направлений Пауэлла

- 1 Задать начальную точку  $x^{(0)}$  и систему  $N$  линейно независимых направлений.
- 2 Минимизировать  $f(x)$  при последовательном движении по  $N + 1$  направлениям. При этом полученная ранее точка минимума берётся в качестве исходной, а направление  $X^{(N)}$  используется как при первом, так и при последнем поиске.
- 3 Определить новое сопряжённое направление с помощью обобщённого свойства параллельного подпространства.
- 4 Заменить  $s^{(1)}$  на  $s^{(2)}$  и т.д. Заменить  $x^{(N)}$  сопряжённым направлением и перейти к шагу 2.

# Метод сопряжённых направлений Пауэлла

Минимизация функции Розенброка: 10 итераций.



# Метод Коши (метод наискорейшего спуска)

$$f(x) = f(\tilde{x}) + \nabla f(\tilde{x})\Delta x + \dots$$
$$s(\tilde{x}) = -\nabla f(\tilde{x})$$

## Простейший градиентный метод

$$x^{(k+1)} = x^{(k)} - \alpha \cdot \nabla f(x^{(k)})$$

Недостатки:

- 1 Необходимо выбрать подходящее значение  $\alpha$ .
- 2 Низкая скорость сходимости в окрестности точки минимума.

## Метод Коши

$$x^{(k+1)} = x^{(k)} - \alpha^{(k)} \cdot \nabla f(x^{(k)})$$



$$f(x) = f(\tilde{x}) + \nabla f(\tilde{x})\Delta x + \frac{1}{2}\Delta x^\top \nabla^2 f(\tilde{x})\Delta x + \dots$$

$$\hat{f}(x, \tilde{x}) = f(\tilde{x}) + \nabla f(\tilde{x})\Delta x + \frac{1}{2}\Delta x^\top \nabla^2 f(\tilde{x})\Delta x$$

$$\nabla \hat{f}(x, \tilde{x}) = \nabla f(\tilde{x}) + \nabla^2 f(\tilde{x})\Delta x$$

$$s(\tilde{x}) = -\nabla^2 f(\tilde{x})^{-1} \nabla f(\tilde{x})$$


## Метод Ньютона

$$x^{(k+1)} = x^{(k)} - \nabla^2 f(x^{(k)})^{-1} \cdot \nabla f(x^{(k)})$$

## Модифицированный метод Ньютона

$$x^{(k+1)} = x^{(k)} - \alpha^{(k)} \cdot \nabla^2 f(x^{(k)})^{-1} \cdot \nabla f(x^{(k)})$$

Минимизация функции Розенброка: 13 итераций.



Объединение методов Коши и Ньютона.

Направление поиска

$$s(x^{(k)}) = - \left( \nabla^2 f(x^{(k)}) + \lambda^{(k)} E \right)^{-1} \cdot \nabla f(x^{(k)})$$

- 1 Задать:  $x^{(0)}$  — начальное приближение,  $M$  — максимальное число итераций,  $\varepsilon$  — параметр сходимости.
- 2  $k = 0$ ,  $\lambda^{(0)} = 10^4$
- 3 Вычислить коэффициенты  $\nabla f(x^{(k)})$ .
- 4 Если  $\|\nabla f(x^{(k)})\| < \varepsilon$ , то перейти к шагу 11.
- 5 Если  $k \geq M$ , то перейти к шагу 11.
- 6 Вычислить

$$s(x^{(k)}) = - \left( \nabla^2 f(x^{(k)}) + \lambda^{(k)} E \right)^{-1} \cdot \nabla f(x^{(k)}).$$

- 7  $x^{(k+1)} = x^{(k)} + s(x^{(k)})$

8. Если  $f(x^{(k+1)}) \geq f(x^{(k)})$ , то перейти к шагу 10.
9.  $\lambda^{(k+1)} = \lambda^{(k)}/2$ ,  $k \leftarrow k + 1$ .  
Перейти к шагу 3.
10.  $\lambda^{(k)} \leftarrow 2\lambda^{(k)}$ .  
Перейти к шагу 6.
11. Вывод результатов. Закончить вычисления.

$$x^{(k+1)} = x^{(k)} + \alpha^{(k)} \cdot s(x^{(k)})$$
$$A^{(k)} s(x^{(k)}) = -\nabla f(x^{(k)})$$

## Аппроксимация матрицы Гессе

$$A^{(k+1)} = A^{(k)} + A_c^{(k)}$$

$A_c^{(k)}$  — корректирующая матрица

$$s_k = x^{(k+1)} - x^{(k)}, \quad y_k = \nabla f(x^{(k+1)}) - \nabla f(x^{(k)})$$

## Квазиньютоновское условие

$A^{(k+1)}$  правильно отражает кривизну  $f$  вдоль  $s_k$ :

$$A^{(k+1)} s_k = y_k$$

## Поправка ранга один

$$A^{(k+1)} = A^{(k)} + uv^T$$

$$A^{(k+1)}s_k = (A^{(k)} + uv^T)s_k = y_k$$

$$u(v^T s_k) = y_k - A^{(k)}s_k$$

Вектор  $u$  должен быть параллелен  $y_k - A^{(k)}s_k$

Если задан вектор  $v$  (не ортогональный  $s_k$ ), то

$$A^{(k+1)} = A^{(k)} + \frac{1}{v^T s_k} (y_k - A^{(k)}s_k)v^T$$



Для сохранения симметрии матрицы вектор  $v$  должен быть коллинеарен  $u$ .

### Поправка ранга 1

$$A^{(k+1)} = A^{(k)} + \frac{1}{(y_k - A^{(k)}s_k)^\top s_k} (y_k - A^{(k)}s_k)(y_k - A^{(k)}s_k)^\top$$

$y_k - A^{(k)}s_k$  и  $(y_k - A^{(k)}s_k)^\top s_k$  предполагаются ненулевыми

$$A_1 = A^{(k)} + \frac{1}{v^\top s_k} (y_k - A^{(k)} s_k) v^\top$$

$$A_2 = \frac{1}{2} (A_1 + A_1^\top)$$

$$A_{2j+1} = A_{2j} + \frac{1}{v^\top s_k} (y_k - A_{2j} s_k) v^\top$$

$$A_{2j+2} = \frac{1}{2} (A_{2j+1} + A_{2j+1}^\top)$$

$$j = 0, 1, \dots$$

### Поправка ранга 2

Для любого вектора  $v$ , не ортогонального  $s_k$ :

$$A^{(k+1)} = A^{(k)} + \frac{1}{v^\top s_k} \left( (y_k - A^{(k)} s_k) v^\top + v (y_k - A^{(k)} s_k)^\top \right) - \frac{(y_k - A^{(k)} s_k)^\top s_k}{(v^\top s_k)^2} v v^\top$$

- $v = y_k - A^{(k)} s_k$  — формула с поправкой ранга 1;
- $v = s_k$  — симметричная формула Пауэлла–Бройдена;
- $v = y_k$  — формула Дэвидона–Флетчера–Пауэлла.

Формула Дэвидона–Флетчера–Пауэлла:

$$A^{(k+1)} = A^{(k)} - \frac{1}{s_k^\top A^{(k)} s_k} A^{(k)} s_k s_k^\top A^{(k)} + \\ + \frac{1}{y_k^\top s_k} y_k y_k^\top + (s_k^\top A^{(k)} s_k) w_k w_k^\top,$$

$$w_k = \frac{1}{y_k^\top s_k} y_k - \frac{1}{s_k^\top A^{(k)} s_k} A^{(k)} s_k$$

$$w_k \perp s_k$$

Семейство однопараметрических формул:

$$A^{(k+1)} = A^{(k)} - \frac{1}{s_k^\top A^{(k)} s_k} A^{(k)} s_k s_k^\top A^{(k)} +$$
$$+ \frac{1}{y_k^\top s_k} y_k y_k^\top + \phi_k(s_k^\top A^{(k)} s_k) w_k w_k^\top,$$
$$w_k = \frac{1}{y_k^\top s_k} y_k - \frac{1}{s_k^\top A^{(k)} s_k} A^{(k)} s_k$$

### Формула Бroyдена–Флетчера–Гольдфарба–Шанно (BFGS)

$$A^{(k+1)} = A^{(k)} - \frac{1}{s_k^\top A^{(k)} s_k} A^{(k)} s_k s_k^\top A^{(k)} + \frac{1}{y_k^\top s_k} y_k y_k^\top$$

$$A^{(k)} > 0 \quad \Rightarrow \quad \exists R: A^{(k)} = R^T R$$

Для формулы BFGS:

$$A^{(k+1)} = R^T W R$$
$$W = I - \frac{1}{\bar{s}^T \bar{s}} \bar{s} \bar{s}^T + \frac{1}{\bar{y}^T \bar{s}} \bar{y} \bar{y}^T$$

$$\bar{s} = R s_k, \quad \bar{y} = (R^T)^{-1} y_k$$

$$\lambda_1 + \lambda_2 = \frac{\bar{y}^T \bar{s} + \bar{y}^T \bar{y}}{\bar{y}^T \bar{s}}, \quad \lambda_1 \lambda_2 = \frac{\bar{y}^T \bar{s}}{\bar{s}^T \bar{s}}$$

# Задача о наименьших квадратах

$$F(x) = \frac{1}{2} \sum_{i=1}^m f_i(x)^2 = \|f(x)\|_2^2 \rightarrow \min$$

$f(x)$  — нелинейная векторная функция с  $m$  компонентами

$\|f(x)\|_2$  — невязка в точке  $x$



# Задача о наименьших квадратах

$$\min_{x \in \mathbb{R}^n} \int_{t_0}^{t_1} (\phi(x, t) - \mathcal{F}(t))^2 dt$$

$$\min_{x \in \mathbb{R}^n} \sum_{i=1}^m (\bar{\phi}(x, t_i) - \bar{\mathcal{F}}(t_i))^2$$

# Задача о наименьших квадратах

$J(x)$  —  $m \times n$ -матрица Якоби для  $f(x)$

$G_i(x)$  — матрица Гессе для  $f_i(x)$

Градиент функции  $F(x)$

$$g(x) = J(x)^\top f(x)$$

Матрица Гессе функции  $F(x)$

$$G(x) = J(x)^\top J(x) + Q(x), \quad Q(x) = \sum_{i=1}^m f_i(x) G_i(x)$$

# Задача о наименьших квадратах

Метод Гаусса–Ньютона

Метод Ньютона:

$$(J_k^\top J_k + Q_k)p_k = -J_k^\top f_k$$

Если при приближении  $x_k$  к оптимуму  $\|f_k\|$  приближается к нулю, то матрица  $Q_k$  также будет приближаться к нулевой.

Аппроксимация ньютоновского направления

$$J_k^\top J_k p_k = -J_k^\top f_k$$

Линейная задача о наименьших квадратах

$$\min_{p \in \mathbb{R}^n} \frac{1}{2} \|J_k p + f_k\|_2^2$$

# Задача о наименьших квадратах

Метод Левенберга–Марквардта

$$(J_k^\top J_k + \lambda_k I)p_k = -J_k^\top f_k$$

$\lambda_k$  — некоторое неотрицательное число

$$x_{k+1} = x_k + p_k$$

$$\min_{p \in \mathbb{R}^n} \frac{1}{2} \|J_k p + f_k\|_2^2$$

$$\|p\|_2 \leq \Delta$$

$\Delta$  — параметр, связанный с  $\lambda_k$

# Задача о наименьших квадратах

## Квазиньютоновские методы

$$(J_k^\top J_k + M_k)p_k = -J_k^\top f_k$$

### Квазиньютоновское условие

$$(J_{k+1}^\top J_{k+1} + M_{k+1})s_k = y_k$$

$$s_k = x_{k+1} - x_k$$

$$y_k = J_{k+1}^\top f_{k+1} - J_k^\top f_k$$

# Задача о наименьших квадратах

## Квазиньютоновские методы

На основе BFGS:

$$M_{k+1} = M_k - \frac{1}{s_k^\top W_k s_k} W_k s_k s_k^\top W_k^\top + \frac{1}{y_k^\top s_k} y_k y_k^\top$$

$$W_k = J_{k+1}^\top J_{k+1} + M_k$$