

Численная оптимизация

Функции многих переменных: условная оптимизация

26 ноября 2012 г.

$$\begin{aligned} f(x) &\rightarrow \min, \quad x \in \mathbb{R}^n \\ g_j(x) &\geq 0, \quad j = 1, \dots, J \\ h_k(x) &= 0, \quad k = 1, \dots, K \\ x_i^{(l)} &\leq x_i \leq x_i^{(u)}, \quad i = 1, \dots, N \end{aligned}$$

Штрафная функция

$$P(x, R) = f(x) + \Omega(R, g(x), h(x))$$

R — набор штрафных параметров

Ω — штраф

Методы внешней точки: $x^{(i)}$ — недопустимые точки.

Методы внутренней точки (барьерные методы): $x^{(i)}$ — допустимые точки.

Методы на основе преобразования задачи

Виды штрафов

Квадратичный:

$$\Omega = R \cdot h(x)^2.$$

«Бесконечный»:

$$\Omega = 10^{20} \sum_{j \in \bar{J}} |g_j(x)|, \quad \bar{J} = \{j \in \{1, \dots, J\} \mid g_j(x) < 0\}.$$

Логарифмический:

$$\Omega = -R \cdot \ln(g(x)).$$

Штраф, задаваемый обратной функцией:

$$\Omega = R \cdot g(x)^{-1}.$$

Штраф типа квадрата срезки:

$$\Omega = R \cdot \langle g(x) \rangle, \quad \langle \alpha \rangle = \begin{cases} \alpha^2, & \alpha < 0, \\ 0, & \alpha \geq 0. \end{cases}$$

Методы на основе преобразования задачи

Пример: квадратичный штраф

$$f = (x_1 - 4)^2 + (x_2 - 4)^2 \rightarrow \min, \quad h = x_1 + x_2 - 5 = 0$$

Штрафная функция:

$$P = f + R \cdot h^2$$

Решением системы уравнений

$$\frac{\partial P}{\partial x_1} = 0, \quad \frac{\partial P}{\partial x_2} = 0$$



будет

$$x_1 = \frac{4 + 5R}{1 + 2R}, \quad x_2 = \frac{4 + 5R}{1 + 2R}$$

Методы на основе преобразования задачи

Пример: квадратичный штраф



$$R = \{0, 1, 10, 100\}$$



Методы на основе преобразования задачи

Пример: квадратичный штраф

$$R = \{0, 1, 10, 100\}$$



Методы на основе преобразования задачи

Пример: квадратичный штраф

$$(x_1 - 4)^2 + (x_2 - 4)^2 \rightarrow \min \quad x_1 + x_2 - 5 = 0$$

```
f <- function(x) sum((x-c(4,4))^2) # f → min
h <- function(x) x[1]+x[2]-5      # h = 0

R <- 0
P <- function(x) f(x)+R*h(x)^2    # штрафная функция

x <- c(0,0)
X <- x
for (R in c(0,0.1,1,10,1000,10^6,10^15))
{
  x <- optim(x,P,method="BFGS")$par
  X <- cbind(X,x)
}
```

0 4 3.75 3 2.571429 2.50075 2.500001 2.5

0 4 3.75 3 2.571429 2.50075 2.500001 2.5

Методы на основе преобразования задачи

Пример: штраф типа квадрата срезки

$$(x_1 - 4)^2 + (x_2 - 4)^2 \rightarrow \min, \quad 5 - (x_1 + x_2) \geq 0$$

```
f <- function(x) sum((x-c(4,4))^2)
h <- function(x) 5-(x[1]+x[2])

R <- 0
P <- function(x) f(x)+R*ifelse(h(x)>=0,0,h(x)^2)




x <- c(0,0)
X <- x
for (R in c(0,0.1,1,10,1000,10^6,10^15))
{
  x <- optim(x,P,method="BFGS")$par
  X <- cbind(X,x)
}
```

```
0 4 3.75 3 2.571429 2.50075 2.499845 2.499845
0 4 3.75 3 2.571429 2.50075 2.499845 2.499845
```

Методы на основе преобразования задачи

Пример: штраф типа квадрата срезки

$$R = \{0.1, 1, 10\}$$



Методы на основе преобразования задачи

Пример: штраф, задаваемый обратной функцией

$$(x_1 - 4)^2 + (x_2 - 4)^2 \rightarrow \min, \quad 5 - (x_1 + x_2) \geq 0$$

```
f <- function(x) sum((x-c(4,4))^2)
h <- function(x) 5-(x[1]+x[2])

R <- 0
P <- function(x) f(x)+R/h(x)


x <- c(0,0)
X <- x
for (R in c(1000,100,10,1,0.1,0.001))
{
  x <- optim(x,P,method="BFGS")$par
  X <- cbind(X,x)
}
```

```
0 -2.046769 2.500425 2.500425 2.500425 2.500425 3.999944
0 -2.046769 2.500425 2.500425 2.500425 2.500425 3.999944
```

Методы на основе преобразования задачи

Пример: штраф, задаваемый обратной функцией

$$R = \{10, 1, 0.1\}$$



Методы на основе преобразования задачи

Метод модифицированной функции Лагранжа (метод множителей)

Функция Лагранжа:

$$L(x, u, v) = f(x) - \sum_j u_j g_j(x) - \sum_k v_k h_k(x)$$

Если определённым образом модифицировать функцию Лагранжа, то полученная в результате функция будет достигать своего *безусловного минимума* в точке Куна–Таккера исходной задачи.

Методы на основе преобразования задачи

Метод модифицированной функции Лагранжа (метод множителей)

Модифицированная функция Лагранжа

$$P(x, \sigma^{(i)}, \tau^{(i)}) = f(x) + R \sum_{j=1}^J \left(\langle g_j(x) + \sigma_j^{(i)} \rangle^2 - (\sigma_j^{(i)})^2 \right) + \\ + R \sum_{k=1}^K \left((h_k(x) + \tau_k^{(i)})^2 - (\tau_k^{(i)})^2 \right)$$

$x^{(i)}$ — точка минимума $P(x, \sigma^{(i)}, \tau^{(i)})$

R — *постоянный* весовой (нормирующий) коэффициент

Методы на основе преобразования задачи

Метод модифицированной функции Лагранжа (метод множителей)

Пересчёт множителей при переходе к $(i + 1)$ -й итерации:

$$\begin{aligned}\sigma_j^{(i+1)} &= \langle g_j(x) + \sigma_j^{(i)} \rangle, \quad j = 1, \dots, J, \\ \tau_k^{(i+1)} &= h_k(x) + \tau_k^{(i)}, \quad k = 1, \dots, K\end{aligned}$$

Методы на основе преобразования задачи

Пример

$$(x_1 - 4)^2 + (x_2 - 4)^2 \rightarrow \min, \quad x_1 + x_2 - 5 = 0$$

```
f <- function(x) sum((x-c(4,4))^2)
h <- function(x) x[1]+x[2]-5



x <- c(0,0); X <- x

R <- 1; tau <- 0
P <- function(x) f(x)+R*((h(x)+tau)^2-tau^2)
for (i in 1:7)
{
  x <- optim(x,P,method="BFGS")$par
  X <- cbind(X,x)
  tau <- h(x)+tau
}
```

```
0 3 2.666667 2.555556 2.518519 2.506173 2.502058 2.500686
0 3 2.666667 2.555556 2.518519 2.506173 2.502058 2.500686
```




Методы на основе преобразования задачи

Пример



Методы на основе преобразования задачи

Пример



Подготовка задачи к решению:

- 1 Исключение ограничений в виде равенств.
- 2 Определение начальной допустимой точки.

- 1 Сгенерировать $P \approx 2N$ допустимых точек.
- 2 Отобразить точку с наибольшим значением целевой функции через центр тяжести остальных точек ($\alpha = 1.3$).
- 3 Сделать отражённую точку допустимой.
 - 1 Новая точка допустимая, и значение целевой функции в ней не совпадает с максимальным значением всей совокупности точек.
 - 2 Новая точка допустимая, и значение целевой функции в ней совпадает с максимальным значением всей совокупности точек: передвинуть точку на половину расстояния до ранее найденного центра тяжести.
 - 3 Новая точка недопустимая: уменьшаем в два раза расстояние до вычисленного раньше центра тяжести.
- 4 Процедура поиска продолжается, пока многогранник не будет стянут в центр тяжести в пределах заданной точности и/или пока разница значений функции в вершинах не станет достаточно малой.

Прямые выборочные процедуры:

- метод совместного поиска;
- метод серий (выборки с уменьшением интервала).

Комбинированные эвристические процедуры:

- адаптивный алгоритм случайного поиска с переменным шагом;
- комбинаторный эвристический алгоритм.

Выборка с уменьшением интервала

Дано: начальное допустимое решение x^0 ; оценка величины начального интервала l^0 , где $x^0 - l^0/2 \leq x \leq x^0 + l^0/2$; параметр ε , определяющий уменьшение интервала ($0 < \varepsilon < 1$). Q — количество серий, P — количество точек в серии. $q = 1$ — номер серии.

- 1 Для $i = 1, \dots, N$ вычислить $x_i^p = x_i^{q-1} + r l_i^{q-1}$, где $r \sim \mathcal{U}[-\frac{1}{2}, \frac{1}{2}]$.
- 2
 - x^p — недопустимая точка и $p < P$: повторить шаг 1.
 - x^p — допустимая точка: запомнить x^p и $f(x^p)$ и повторить шаг 1.
 - $p = P$: найти среди всех допустимых точек x^p точку с наименьшим значением $f(x^p)$ и положить её равной x^q .
- 3 Уменьшить интервал, полагая $l_i^q = (1 - \varepsilon) l_i^{q-1}$.
- 4 Если $q > Q$, закончить вычисления. В противном случае увеличить q и продолжать вычисления, начиная с шага 1.

Адаптивный алгоритм случайного поиска с переменным шагом

Даны параметры $\alpha_s = 1.618$, $\alpha_f = 0.618$ и $M = 3N$ и начальная допустимая точка x^0 . Начальная величина шага α полагается равной 1, а m — число испытаний, не дающих улучшения, — принимается равным 0.

- 1 Получить случайный вектор d единичной длины и положить $x^1 = x^0 + \alpha d$.
- 2 Если x^1 — допустимая точка и $f(x^1) < f(x^0)$, положить $y = x^0 + \alpha_s(x^1 - x^0)$ и перейти к шагу 3. В противном случае принять $m = m + 1$ и перейти к шагу 4.
- 3 Если y — допустимая точка и $f(y) < f(x^0)$, положить $\alpha = \alpha_s \alpha$, $x^1 = y$ и перейти к шагу 5. В противном случае перейти к шагу 1.
- 4 Если $m > M$, положить $\alpha = \alpha_f \alpha$, $m = 0$ и перейти к шагу 5. В противном случае сразу перейти к шагу 5.
- 5 Перейти к шагу 1, если не выполнено условие окончания вычислений.

Комбинаторный эвристический алгоритм

- 1 Построить случайную допустимую начальную точку x^0 и положить $F_{\min} = f(x^0)$. Для каждой координаты i , $i = 1, \dots, N$, выполнить следующую последовательность вычислений.
 - 1 Выбрать случайным образом возможные значения i -й координаты для нахождения q дополнительных допустимых точек с лучшим значением целевой функции по сравнению с текущей базовой точкой. Если такие точки получить не удаётся, повторить шаг 2 для координаты $i + 1$.
 - 2 Определить наилучшее из q допустимых решений и положить значение целевой функции T_{\min} .
 - 3 Произвести «упреждающий» поиск.
 - 1 Для каждого из q допустимых решений, найденных на шаге 2.1, провести случайных выбор одного из q возможных значений координаты $(i + 1)$ для определения допустимого значения этой координаты, дающего лучшее значение целевой функции по сравнению с T_{\min} .
 - 2 Выбрать наилучшую из q допустимых точек. Зафиксировать значение координаты i , соответствующее этой точке как оптимальное.
 - 4 Если $i = N$, перейти к шагу 3. В противном случае выполнить шаг 2 для координаты $(i + 1)$.
- 3 Провести случайный поиск для определения наилучшего значения координаты N при фиксированных значениях других координат, соответствующих текущим базовым точкам. Найденную точку принять на новую базисную точку, а значение целевой функции в ней — за новое значение F_{\min} .
- 4 Перейти к шагу 2 с $i = 1$, если не выполнены условия окончания вычислений.

Функция $f(x)$ аппроксимируется *линейной* функцией

$$\tilde{f}(x; x^0) = f(x^0) + \nabla f(x^0) \cdot (x - x^0).$$

x^0 — точка линеаризации

Методы линеаризации

Непосредственное использование последовательности задач линейного программирования: случай линейных ограничений

Алгоритм Франка–Вульфа

- 1 Вычислить $\nabla f(x^{(i)})$. Если $\|\nabla f(x^{(i)})\| < \varepsilon$, то прекратить вычисления.
- 2 Решить задачу линейного программирования:

$$\nabla f(x^{(i)})y \rightarrow \min, \quad Ay \leq b, \quad y \geq 0.$$

- 3 $\alpha^{(i)} = \arg \min_{0 \leq \alpha \leq 1} f(x^{(i)} + \alpha \cdot (y^{(i)} - x^{(i)}))$
- 4 $x^{(i+1)} = x^{(i)} + \alpha^{(i)} \cdot (y^{(i)} - x^{(i)})$
- 5 Прекратить вычисления, если

$$\begin{aligned} \|x^{(i+1)} - x^{(i)}\| &\leq \delta \|x^{(i+1)}\|, \\ \|f(x^{(i+1)}) - f(x^{(i)})\| &\leq \varepsilon \|f(x^{(i+1)})\|. \end{aligned}$$

Методы линеаризации

Общая задача нелинейного программирования

Вместо

$$\begin{aligned} f(x) &\rightarrow \min, \\ g_j(x) &\geq 0, \quad j = 1, \dots, J \\ h_k(x) &= 0, \quad k = 1, \dots, K \\ x_i^{(l)} &\leq x_i \leq x_i^{(u)}, \quad i = 1, \dots, N \end{aligned}$$

на каждом шаге решается

$$\begin{aligned} f(x^{(i)}) + \nabla f(x^{(i)})(x - x^{(i)}) &\rightarrow \min, \\ g_j(x^{(i)}) + \nabla g_j(x^{(i)})(x - x^{(i)}) &\geq 0, \quad j = 1, \dots, J \\ h_k(x^{(i)}) + \nabla h_k(x^{(i)})(x - x^{(i)}) &= 0, \quad k = 1, \dots, K \\ x_i^{(l)} &\leq x_i \leq x_i^{(u)}, \quad i = 1, \dots, N \end{aligned}$$

$$f(x) \rightarrow \min, \quad g_j(x) \geq 0, \quad j = 1, \dots, J$$

$x^{(1)}$ — начальная точка, удовлетворяющая ограничениям:

$$g_j(x^{(1)}) \geq 0, \quad j = 1, \dots, J$$

- $g_j(x^{(1)}) = 0$ — связывающее (активное) ограничение
- $g_j(x^{(1)}) > 0$ — несвязывающее ограничение

Вектор d определяет подходящее направление поиска, если:

- d — направление спуска:

$$\nabla f(x^{(1)})d < 0;$$

- точки луча

$$x(\alpha) = x^{(1)} + \alpha d, \quad \alpha \geq 0,$$

являются допустимыми по крайней мере на небольшом расстоянии от $x^{(1)}$.

Точки вдоль d будут допустимыми, если для всех связывающих в $x^{(1)}$ ограничений выполняется условие

$$g_j(x^{(1)}) + \nabla g_j(x^{(1)})(x - x^{(1)}) \geq 0.$$

Так как

$$g_j(x^{(1)}) = 0 \text{ и } x - x^{(1)} = \alpha d, \quad \alpha \geq 0$$

то

$$\nabla g_j(x^{(1)})d \geq 0$$

для всех связывающих ограничений.

Метод допустимых направлений

Алгоритм

$x^{(t)}$ — допустимая точка, $I^{(t)}$ — множество индексов ограничений, активных в пределах заданной погрешности

$$I^{(t)} = \{j \mid 0 \leq g_j(x^{(t)}) \leq \varepsilon, j = 1, \dots, J\}.$$

- 1 Решить задачу линейного программирования:

$$\begin{aligned} & \theta \rightarrow \max \\ & \begin{cases} \nabla f(x^{(t)})d \leq -\theta, \\ \nabla g_j(x^{(t)})d \geq \theta, & j \in I^{(t)}, \\ -1 \leq d_i \leq 1, & i = 1, \dots, n. \end{cases} \end{aligned}$$

$d^{(t)}$ и $\theta^{(t)}$ — полученные решения.

2 Если $\theta^{(t)} \leq 0$, то закончить итерацию. Иначе найти

$$\bar{\alpha} = \min\{\alpha \mid g_j(x^{(t)} + \alpha d^{(t)}), j = 1, \dots, J, \text{ и } \alpha \geq 0\}.$$

Если не существует $\bar{\alpha} > 0$, то $\bar{\alpha} = \infty$.

3 Найти $\alpha^{(t)}$:

$$\alpha^{(t)} = \arg \min_{0 \leq \alpha \leq \bar{\alpha}} f(x^{(t)} + \alpha d^{(t)}).$$

$$x^{(t+1)} = x^{(t)} + \alpha^{(t)} d^{(t)}.$$

Метод допустимых направлений

Метод ε -возмущений

- 1 В точке $x^{(t)}$ при заданном $\varepsilon^{(t)} > 0$ определить $I^{(t)}$ и выполнить шаг 1 основного алгоритма.
- 2
 - Если $\theta^{(t)} \geq \varepsilon^{(t)}$, положить $\varepsilon^{(t+1)} \geq \varepsilon^{(t)}$ и продолжать одномерный поиск как в основном методе.
 - Если $\theta^{(t)} < \varepsilon^{(t)}$, то положить $\varepsilon^{(t+1)} = \frac{1}{2}\varepsilon^{(t)}$ и продолжать одномерный поиск как в основном методе.
 - Если $\theta^{(t)} < 0$, то точка Куна–Таккера найдена.

Активные ограничения не используются.

$$\begin{aligned} & \theta \rightarrow \max \\ & \begin{cases} \nabla f(x^{(t)})d \leq -\theta, \\ \nabla g_j(x^t)d \geq \theta, & j = 1, \dots, J, \\ -1 \leq d_i \leq 1, & i = 1, \dots, n. \end{cases} \end{aligned}$$

Методы проекции градиента

Линейные ограничения

$$f(x) \rightarrow \min, \quad a^\top x = b$$

$$\forall s \in \mathbb{R}^N : s = s' + s''$$

$$s' = \gamma a, \quad a^\top s'' = 0$$

$$a^\top s = a^\top (\gamma a) + a^\top s'' = a^\top (\gamma a)$$

$$\gamma = (a^\top a)^{-1} a^\top s$$

$$s'' = s - a(a^\top a)^{-1} a^\top s = \underbrace{(I - a(a^\top a)^{-1} a^\top)}_P s$$

P — проекционная матрица (симметричная и положительно определённая)

Методы проекции градиента

Линейные ограничения

$$Ax = b \quad a_k^\top x = b_k, \quad k = 1, \dots, K$$

$$s = s' + s'' = A^\top \gamma + s''$$

A — матрица со строками a_k^\top

$$\gamma = (AA^\top)^{-1}As$$

$$s'' = (I - A^\top(AA^\top)^{-1}A)s = Ps$$

Свойства проекций:

- 1 $s = -P \cdot \nabla f$ — направление спуска.
- 2 Если $s = 0$, то точка $x^{(t)}$ удовлетворяет необходимым условиям Лагранжа.
- 3 Вектор множителей Лагранжа задаётся выражением

$$q = (AA^T)^{-1}A \cdot \nabla f.$$

Методы проекции градиента

Линейные ограничения

Алгоритм

Вычислить P в предположении, что векторы a_k линейно независимы, заданы допустимая точка $x^{(t)}$ и допустимая погрешность сходимости $\varepsilon > 0$.

- 1 Вычислить $s^{(t)} = -P \cdot \nabla f$.
- 2 Если $\|s^{(t)}\| \leq \varepsilon$, то вычислить v :

$$v = (AA^T)^{-1}A \cdot \nabla f$$

и закончить вычисления. В противном случае продолжить вычисления.

- 3 Определить максимальную длину шага

$$\alpha_{\max} = \min \left\{ \max \left(0, \frac{b_k - a_k^T x^{(t)}}{a_k^T s^{(t)}} \text{ или } \infty, \text{ если } a_k^T s^{(t)} = 0 \right); k = \overline{1, K} \right\}$$

- 4 Решить задачу одномерного поиска

$$f(x^{(t)} + \alpha s^{(t)}) \rightarrow \min, \quad 0 \leq \alpha \leq \alpha_{\max}.$$

- 5 Положить $x^{(t+1)} = x^{(t)} + \alpha_{opt} s^{(t)}$ и перейти к шагу 1.

Методы проекции градиента

Нелинейные ограничения

$I^{(t)}$ — множество активных в точке $x^{(t)}$ ограничений

$w^{(t)}$ — недопустимая точка, достигнутая при перемещении из $x^{(t)}$ вдоль направления $s^{(t)}$

Направление, перпендикулярное к поверхностям ограничений:

$$s = A(w^{(t)})^\top \gamma$$

где столбцами $A(w^{(t)})^\top$ являются градиенты $\nabla h_k(w^{(t)})$, $k = 1, \dots, K$, а также $\nabla g_l(w^{(t)})$, $l \in I^{(t)}$

Методы проекции градиента

Нелинейные ограничения

h — вектор ограничений–равенств и активных ограничений–неравенств

$$h(w^{(t)} + A^\top \gamma) = h(w^{(t)}) + A(w^{(t)})A(w^{(t)})^\top \gamma = 0$$

$$\nabla_\gamma h = \frac{dh}{dx} \frac{dx}{d\gamma}$$

$$\gamma = -(AA^\top)^{-1}h$$

$$w^{(t+1)} - w^{(t)} = -A^\top (AA^\top)^{-1}h$$

Методы проекции градиента

Нелинейные ограничения

Алгоритм

Дано: $x^{(0)}$ — допустимая точка, $\varepsilon_1 > 0$ — допустимая погрешность сходимости, ε_2 — погрешность определения активных ограничений

- 1 Определить активное множество в $x^{(t)}$
- 2 Вычислить P и $s = -P \cdot \nabla f(x^t)$
- 3 Если $\|s^t\| > \varepsilon_1$, то перейти к шагу 4.

В противном случае вычислить множители Лагранжа $(u, v) = (AA^T)^{-1}A \cdot \nabla f$ и найти $u_m = \min\{u_l : l \in I^{(t)}\}$.

Если $|u_m| \leq \varepsilon_1$, то закончить вычисления. В противном случае исключить ограничение m из $I^{(t)}$ и перейти к шагу 2.

- 4 Определить такую максимальную длину шага α_{\max} , что $g_l(w(\alpha)) \geq 0$ для всех $l \notin I^{(t)}$.
- 5
 - Используя ограничивающий поиск по α , $0 \leq \alpha \leq \alpha_{\max}$, определить $\alpha_1, \alpha_2, \alpha_3$ и $w(\alpha_1), w(\alpha_2)$ и $w(\alpha_3)$, которые локализуют минимум $f(x)$ на кривой $h(w(\alpha)) = 0$.
 - При помощи квадратичной интерполяции оценить α .