

Методы оптимизации

Дополнительный материал 3: Методы сопряженных
градиентов

ВМК, осень 2018

Метод сопряженных градиентов (CG). Общая схема

Решаемая задача: $Ax = b$, где $A \in \mathbb{S}_{++}^n$, $b \in \mathbb{R}^n$.

Эквивалентно: $f(x) := \frac{1}{2}\langle Ax, x \rangle - \langle b, x \rangle \rightarrow \min_{x \in \mathbb{R}^n}$.

- ▶ Метод спуска: $x_{k+1} = x_k + \alpha_k d_k$.
- ▶ Для квадратичной функции можно аналитически найти

$$\alpha_k = \underset{\alpha \geq 0}{\operatorname{argmin}} f(x_k + \alpha d_k) = \frac{-\langle g_k, d_k \rangle}{\langle Ad_k, d_k \rangle}, \quad g_k := Ax_k - b$$

Сопряженные направления: $\langle Ad_i, d_j \rangle = 0$ для $i \neq j$.

Возможные варианты:

- ▶ Ортогональные собственные векторы q_1, \dots, q_n матрицы A .
- ▶ Любые л.н.з. векторы + модифицированный процесс Грамма-Шмидта.

Это все неэффективно для больших матриц!

Метод сопряженных градиентов (CG). Общая схема – 2

Основная идея: строить d_k онлайн (в итерациях алгоритма):

- ▶ Пусть уже есть d_0, \dots, d_k , т. ч. $\langle Ad_i, d_j \rangle = 0$ для $i \neq j$.
- ▶ Ищем d_{k+1} как линейную комбинацию g_{k+1} и d_k :

$$d_{k+1} = -g_{k+1} + \beta_k d_k.$$

- ▶ Коэффициент β_k найдем из условия сопряженности:

$$0 = \langle Ad_k, d_{k+1} \rangle = -\langle d_k, Ag_{k+1} \rangle + \beta_k \langle Ad_k, d_k \rangle.$$

Отсюда

$$\beta_k = \frac{\langle Ad_k, g_{k+1} \rangle}{\langle Ad_k, d_k \rangle}.$$

- ▶ Таким образом мы обеспечили лишь $\langle Ad_k, d_{k+1} \rangle = 0$.
Оказывается, что если выбрать $d_0 = -g_0$ (**это важно!**), то
автоматически будет $\langle Ad_i, d_{k+1} \rangle = 0$ для $i < k$.

Метод сопряженных градиентов (CG). Общая схема – 3

Метод сопряженных градиентов (неэффективная версия):

$$\begin{array}{ll} 1. \quad g_k \leftarrow Ax_k - b \\ 2. \quad \alpha_k \leftarrow \frac{-\langle g_k, d_k \rangle}{\langle Ad_k, d_k \rangle} \\ 3. \quad x_{k+1} \leftarrow x_k + \alpha_k d_k \end{array}$$

$$\begin{array}{ll} 4. \quad g_{k+1} \leftarrow Ax_{k+1} - b \\ 5. \quad \beta_k \leftarrow \frac{\langle g_{k+1}, Ad_k \rangle}{\langle Ad_k, d_k \rangle} \\ 6. \quad d_{k+1} \leftarrow -g_{k+1} + \beta_k d_k \end{array}$$

- Недостаток: **три** матрично-векторных произведения.

Устраним этот недостаток:

1. Важное свойство CG: $\langle g_i, g_{k+1} \rangle = 0$ и $\langle g_{k+1}, d_i \rangle = 0$ для $i \leq k$.
2. Заметим, что $g_{k+1} = A(x_k + \alpha_k d_k) - b = g_k + \alpha_k Ad_k$.
3. Отсюда $Ad_k = \alpha_k^{-1}(g_{k+1} - g_k)$. Значит,

$$\begin{aligned}\beta_k &= \frac{\langle g_{k+1} - g_k, g_{k+1} \rangle}{\langle g_{k+1} - g_k, d_k \rangle} = \frac{\|g_{k+1}\|^2}{-\langle g_k, d_k \rangle} \\ &= \frac{\|g_{k+1}\|^2}{-\langle -g_k + \beta_{k-1} d_{k-1}, g_k \rangle} = \frac{\|g_{k+1}\|^2}{\|g_k\|^2}\end{aligned}$$

4. Аналогично $\alpha_k = \frac{\|g_k\|^2}{\langle Ad_k, d_k \rangle}$.

Метод сопряженных градиентов (CG). Общая схема – 4

Метод сопряженных градиентов (эффективная версия):

$$g_0 \leftarrow Ax_0 - b$$

$$d_0 \leftarrow -g_0$$

$$k \leftarrow 0$$

while $\|g_k\| > \varepsilon \|b\|$ **do**

$$\alpha_k \leftarrow \frac{\|g_k\|^2}{\langle Ad_k, d_k \rangle}$$

$$x_{k+1} \leftarrow x_k + \alpha_k d_k$$

$$g_{k+1} \leftarrow g_k + \alpha_k Ad_k$$

$$\beta_k \leftarrow \frac{\|g_{k+1}\|^2}{\|g_k\|^2}$$

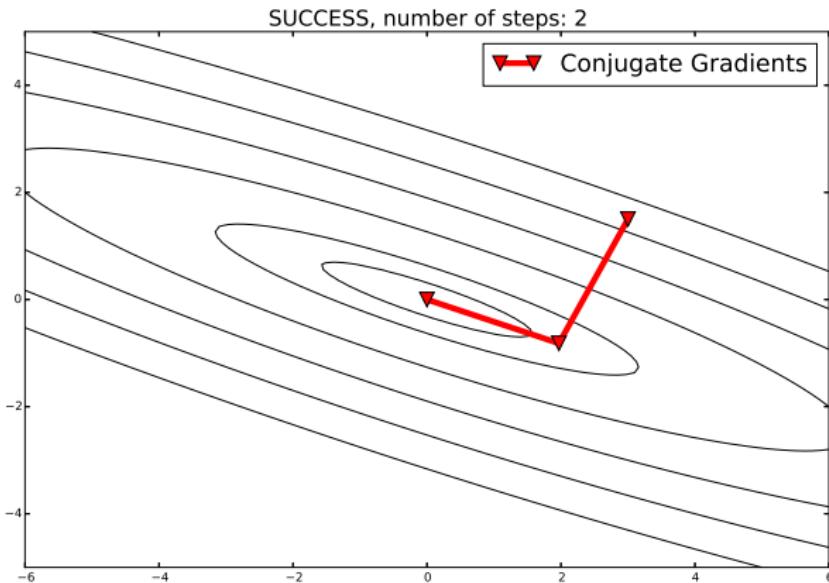
$$d_{k+1} \leftarrow -g_{k+1} + \beta_k d_k$$

$$k \leftarrow k + 1$$

end while

- ▶ Одно матрично-векторное произведение за итерацию!

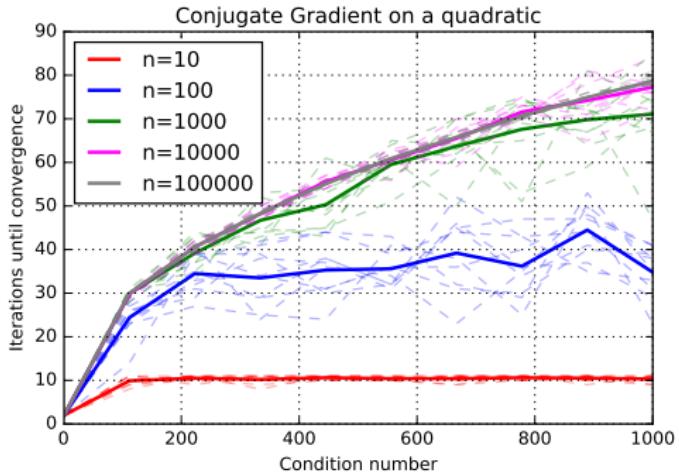
Метод сопряженных градиентов: траектория



- ▶ Всегда ≤ 2 итерации в двумерном случае.

Зависимость от обусловленности и размерности задачи

$$A = \text{Diag}(a), \quad b \equiv \mathcal{N}(0, I_n), \quad a_i = \begin{cases} 1, & i = 1 \\ \text{Unif}(1, \kappa), & 2 \leq i \leq n - 1 \\ \kappa, & i = n \end{cases}$$



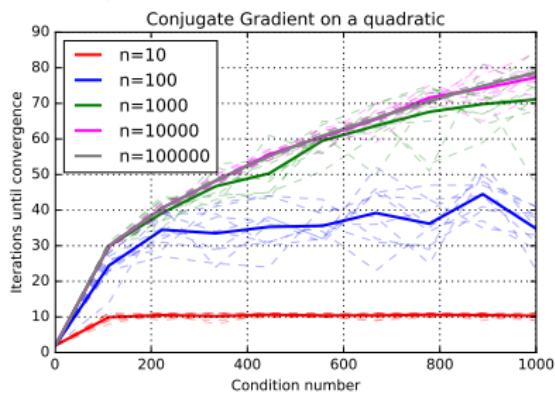
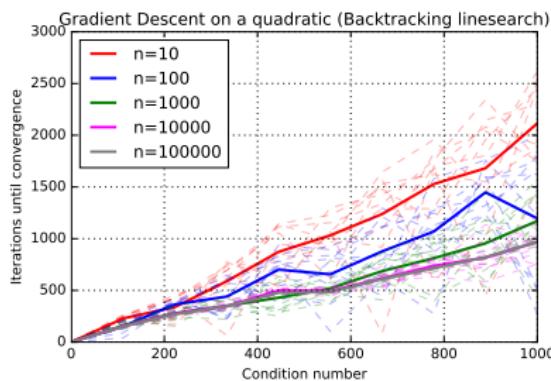
- ▶ Всегда $\leq n$ итераций (м.б. чуть больше из-за погрешностей).
- ▶ В худшем случае: $O(\sqrt{\kappa})$ (κ — число обусловленности).
- ▶ С ростом размерности число итераций не увеличивается!

Сравнение CG с градиентным спуском

Квадратичная функция: $f(x) = \frac{1}{2} \langle Ax, x \rangle - \langle b, x \rangle$.

$$A = \text{Diag}(a), \quad b \equiv \mathcal{N}(0, I_n),$$

$$a_i = \begin{cases} 1, & i = 1 \\ \text{Unif}(1, \kappa), & 2 \leq i \leq n-1 \\ \kappa, & i = n \end{cases}$$



- ▶ $O(\kappa)$ против $O(\sqrt{\kappa})$ (κ – число обусловленности).
- ▶ Огромная разница уже даже при небольших κ !

Предобуславливание в методе сопряженных градиентов

Оригинальная задача: $Ax = b$, где $A \in \mathbb{S}_{++}^n$, $b \in \mathbb{R}^n$.

- ▶ Выполним эквивалентное преобразование системы:
$$Ax = b \Leftrightarrow (S^{-T}AS^{-1})(Sx) = S^{-T}b,$$
где $S \in \mathbb{R}^{n \times n}$ — невырожденная матрица.

Новая задача: $\tilde{A}\tilde{x} = \tilde{b}$, где $\tilde{A} := S^{-T}AS^{-1}$, $\tilde{b} := S^{-T}b$.

- ▶ Решение исходной системы: $x = S^{-1}\tilde{x}$.

Предобуславливатель: $M := S^T S$.

- ▶ Идеальный предобуславливатель: $M \approx A$
$$\tilde{A} \approx S^{-T}(S^T S)S^{-1} = I_n$$

В этом случае сходимость будет примерно за одну итерацию.

Схема предобусловленного CG

Обычный CG:

```
g0 ← Ax0 – b  
d0 ← –g0  
k ← 0  
while ||gk|| > ε||b|| do  
    αk ←  $\frac{\|g_k\|^2}{\langle Ad_k, d_k \rangle}$   
    xk+1 ← xk + αkdk  
    gk+1 ← gk + αkAdk  
    βk ←  $\frac{\|g_{k+1}\|^2}{\|g_k\|^2}$   
    dk+1 ← –gk+1 + βkdk  
    k ← k + 1  
end while
```

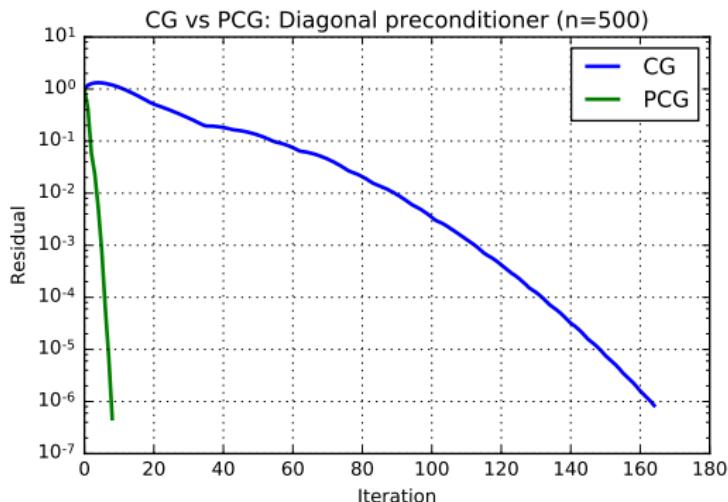
Предобусловленный CG:

```
g0 ← Ax0 – b  
d0 ← –M-1g0  
k ← 0  
while ||gk|| > ε||b|| do  
    αk ←  $\frac{\langle M^{-1}g_k, g_k \rangle}{\langle Ad_k, d_k \rangle}$   
    xk+1 ← xk + αkdk  
    gk+1 ← gk + αkAdk  
    βk ←  $\frac{\langle M^{-1}g_{k+1}, g_{k+1} \rangle}{\langle M^{-1}g_k, g_k \rangle}$   
    dk+1 ← –M-1gk+1 + βkdk  
    k ← k + 1  
end while
```

- ▶ Дополнительно нужна процедура вычисления $M^{-1}g_k$.
- ▶ Обычно применяют для хорошо структурированных M .
 - ▶ Примеры: диагональная, ленточная, разреженная и т. д.

Предобуславливание: пример

- ▶ Система $Ax = b$ размера $n = 500$, где $b := (1, \dots, 1)$ и
$$a_{ij} := \begin{cases} 1 + i^{1.2} & \text{если } i = j \\ 1 & \text{если } |i - j| = 1 \text{ или } |i - j| = 100 \\ 0 & \text{иначе} \end{cases}$$
- ▶ Диагональный предобуславливатель: $M := \text{Diag}(A)$.



- ▶ Хороший предобуславливатель существенно ускоряет метод.

Нелинейный метод CG. Версия Флэтчера–Ривса

Обычный CG:

```
g0 ← Ax0 – b  
d0 ← –g0  
k ← 0  
while ||gk|| > ε||b|| do  
    αk ←  $\frac{\|g_k\|^2}{\langle Ad_k, d_k \rangle}$   
    xk+1 ← xk + αkdk  
    gk+1 ← gk + αkAdk  
    βk ←  $\frac{\|g_{k+1}\|^2}{\|g_k\|^2}$   
    dk+1 ← –gk+1 + βkdk  
    k ← k + 1  
end while
```

Метод Флэтчера–Ривса:

```
g0 ←  $\nabla f(x_0)$   
d0 ← –g0  
k ← 0  
while ||gk|| > ε|| $\nabla f(x_0)$ || do  
    αk ← {линейный поиск}  
    xk+1 ← xk + αkdk  
    gk+1 ←  $\nabla f(x_{k+1})$   
    βk ←  $\frac{\|g_{k+1}\|^2}{\|g_k\|^2}$   
    dk+1 ← –gk+1 + βkdk  
    k ← k + 1  
end while
```

Другие схемы нелинейного метода CG

Существует много версий нелинейного CG. Все они отличаются лишь выбором коэффициента β_k :

Полак–Рибье:

$$\beta_k^{\text{PR}} := \frac{\langle g_{k+1}, y_k \rangle}{\|g_k\|^2}$$

Хестинс–Штифель:

$$\beta_k^{\text{HS}} := \frac{\langle g_{k+1}, y_k \rangle}{\langle d_k, y_k \rangle}$$

Полак–Рибье+:

$$\beta_k^{\text{PR+}} := \max\{0, \beta_k^{\text{PR}}\}$$

Гильберт–Ноусидаль:

$$\beta_k^{\text{GN}} := \max\{-\beta_k^{\text{FR}}, \min\{\beta_k^{\text{PR}}, \beta_k^{\text{FR}}\}\}$$

Дай–Юань:

$$\beta_k^{\text{DY}} := \frac{\|g_{k+1}\|^2}{\langle d_k, y_k \rangle}$$

Агер–Джан:

$$\beta_k^{\text{HZ}} := \frac{\langle g_{k+1}, y_k - \frac{2\|y_k\|^2}{\langle d_k, y_k \rangle} d_k \rangle}{\langle d_k, y_k \rangle}$$

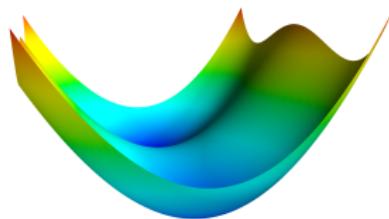
Во всех формулах $y_k := g_{k+1} - g_k$.

- ▶ Все эти схемы совпадают на строго выпуклой квадратичной функции.
- ▶ На неквадратичной функции их поведение различается.

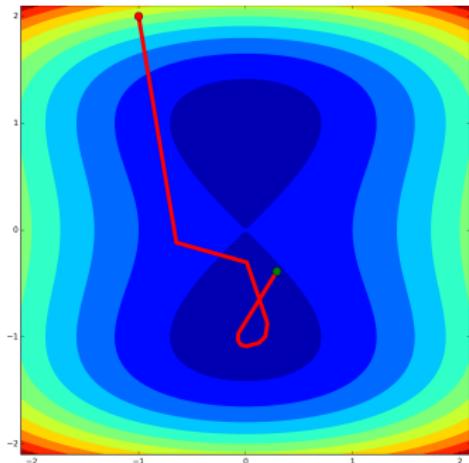
Флетчер–Ривс и направление спуска

- ▶ В общем случае метод Флетчера–Ривса не гарантирует того, что направление d_k является направлением спуска.
- ▶ Однако можно доказать, что если в линейном поиске использовать сильные условия Вульфа с константой $c_2 < 0.5$, то d_k будет направлением спуска (т. е. поиск должен быть точнее, чем обычно).
- ▶ Пример: рассмотрим двумерную функцию

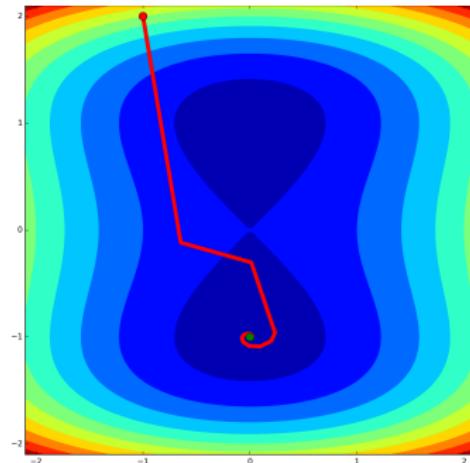
$$f(x) := \frac{1}{2}x_1^2 + \frac{1}{4}x_2^4 - \frac{1}{2}x_2^2,$$



Флетчер–Ривс и направление спуска 2



$$c_2 = 0.9$$



$$c_2 = 0.2$$

- ▶ При $c_2 > 0.5$ метод может не сходиться.
- ▶ При $c_2 < 0.5$ метод сходится.

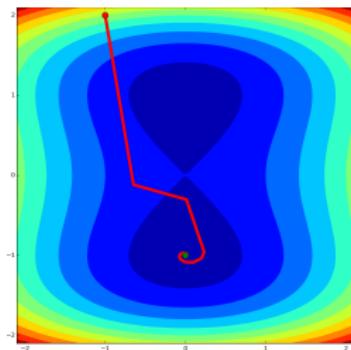
Нелинейный метод CG и рестарт

- ▶ На квадратичной функции CG сходится \leq за n итераций. Для функций общего вида это необязательно так.
- ▶ Многие функции вблизи оптимума близки к квадратичной.
Как гарантировать быструю сходимость в окрестности оптимума?
- ▶ Для линейного CG очень важно, что $d_0 = -g_0$.
- ▶ Этого можно добиться, если **делать рестарт** каждые n итераций.
- ▶ Такое условие неэффективное, т.к. на практике метод обычно запускается на менее чем n итераций (например, $n \sim 10^6$). Более эффективным условием является **условие Паузла**:

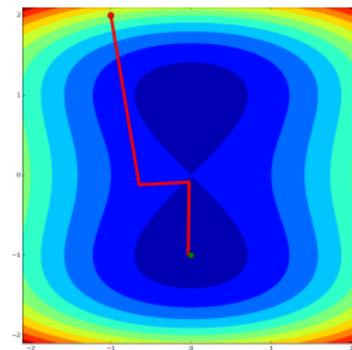
$$\text{рестарт} \Leftrightarrow |\langle g_k, g_{k+1} \rangle| \geq \nu \|g_{k+1}\|^2.$$

Обычно берут $\nu = 0.1$. Основано на том, что в CG соседние градиенты ортогональны.

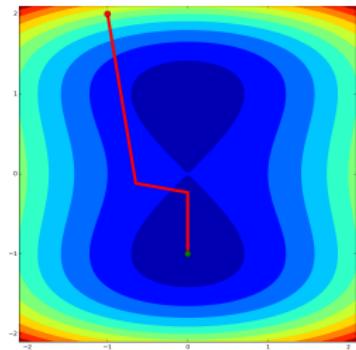
Сравнение версий FR, PR и FR+restart



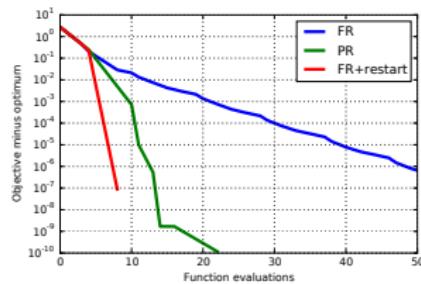
FR



PR



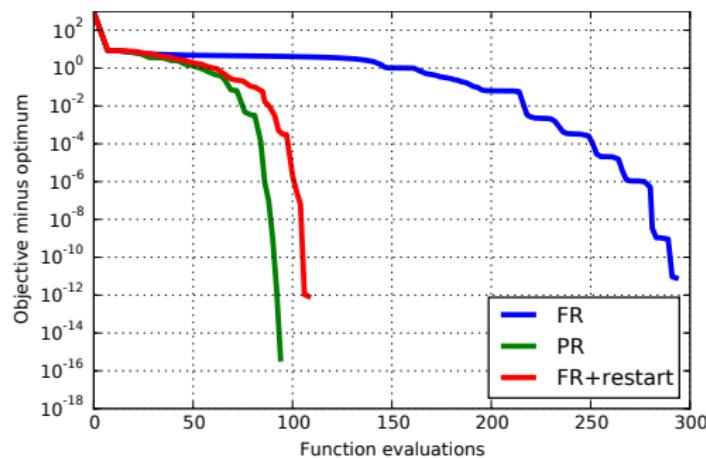
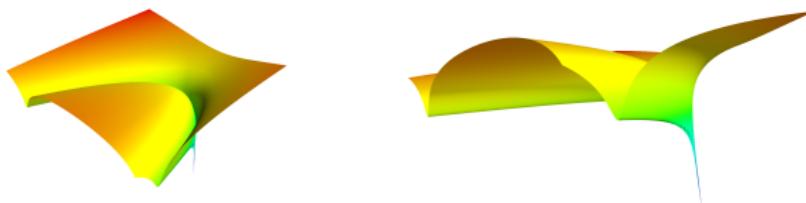
FR+restart



- ▶ Методы PR и FR+restart сходятся сильно быстрее, чем просто FR.
- ▶ Метод PR делает «автоматический» рестарт.

Пример 2. Функция Розенброка

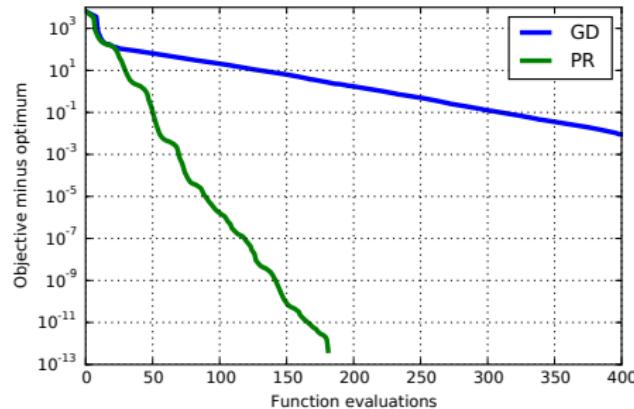
Функция Розенброка: $f(x) := (1 - x_1)^2 + 100(x_2 - x_1^2)^2$.



Сравнение нелинейного CG и градиентного спуска

Логистическая регрессия с ℓ^2 -регуляризатором:

$$f(x) := \sum_{i=1}^m \ln(1 + e^{\langle a_i, x \rangle}) + \frac{\tau}{2} \|x\|^2 \quad \rightarrow \quad \min_{x \in \mathbb{R}^n} .$$



- ▶ На практике нелинейный метод сопряженных градиентов работает существенно быстрее градиентного спуска.

Нелинейный метод CG: заключение

- ▶ Нелинейный метод CG является методом первого порядка.
- ▶ Существуют много разных вариантов, отличающихся лишь выбором коэффициента β_k .
- ▶ В линейном поиске обычно используются сильные условия Вульфа с константой $c_2 < 0.5$. Также обычно применяют рестарт.
- ▶ Метод Флетчера–Ривса без рестартов является наименее эффективным. Наиболее популярным является метод Полака–Рибье.