

Методы оптимизации в машинном обучении

Метод сопряженных градиентов (семинар 4)

Родоманов А. О.

ВМК МГУ
26 сентября 2016

- Решаемая задача: $Ax = b$, где $A = A^T \succ 0$.
- Скорость работы метода определяется спектром матрицы A .
- Спектр можно улучшить с помощью эквивалентного преобразования системы:

$$Ax = b \Leftrightarrow (S^{-T}AS^{-1})(Sx) = S^{-T}b,$$

где $S \in \mathbb{R}^{n \times n}$ — невырожденная матрица.

- **Новая система:** $\tilde{A}\tilde{x} = \tilde{b}$, где

$$\tilde{A} := S^{-T}AS^{-1}, \quad \tilde{b} := S^{-T}b.$$

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

- Матрица $M := S^T S$ называется **предобуславливателем**.
- Если $M \approx A$, то $\tilde{A} \approx I \Rightarrow$ сходимость \approx за одну итерацию.

Обычный CG:

$$r_0 := Ax_0 - b;$$

$$d_0 := -r_0;$$

$$k := 0;$$

while $\|r_k\| > \varepsilon$ **do**

$$\alpha_k := \frac{r_k^\top r_k}{d_k^\top A d_k};$$

$$x_{k+1} := x_k + \alpha_k d_k;$$

$$r_{k+1} := r_k + \alpha_k A d_k;$$

$$\beta_k := \frac{r_{k+1}^\top r_{k+1}}{r_k^\top r_k};$$

$$d_{k+1} := -r_{k+1} + \beta_k d_k;$$

$$k := k + 1;$$

end

Обычный CG:

$$r_0 := Ax_0 - b;$$

$$d_0 := -r_0;$$

$$k := 0;$$

while $\|r_k\| > \varepsilon$ do

$$\alpha_k := \frac{r_k^\top r_k}{d_k^\top A d_k};$$

$$x_{k+1} := x_k + \alpha_k d_k;$$

$$r_{k+1} := r_k + \alpha_k A d_k;$$

$$\beta_k := \frac{r_{k+1}^\top r_{k+1}}{r_k^\top r_k};$$

$$d_{k+1} := -r_{k+1} + \beta_k d_k;$$

$$k := k + 1;$$

end

CG с предобуславливателем:

$$r_0 := Ax_0 - b;$$

$$d_0 := -M^{-1}r_0;$$

$$k := 0;$$

while $\|r_k\| > \varepsilon$ do

$$\alpha_k := \frac{r_k^\top M^{-1}r_k}{d_k^\top A d_k};$$

$$x_{k+1} := x_k + \alpha_k d_k;$$

$$r_{k+1} := r_k + \alpha_k A d_k;$$

$$\beta_k := \frac{r_{k+1}^\top M^{-1}r_{k+1}}{r_k^\top M^{-1}r_k};$$

$$d_{k+1} := -M^{-1}r_{k+1} + \beta_k d_k;$$

$$k := k + 1;$$

end


- Дополнительно нужна процедура решения системы $Mz_k = r_k$.

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: $M = \text{Diag}(A)$.



Линейный СГ:

$$r_0 := Ax_0 - b;$$

$$d_0 := -r_0;$$

$$k := 0;$$

while $\|r_k\| > \varepsilon$ **do**

$$\alpha_k := \frac{r_k^\top r_k}{d_k^\top A d_k};$$

$$x_{k+1} := x_k + \alpha_k d_k;$$

$$r_{k+1} := r_k + \alpha_k A d_k;$$

$$\beta_k := \frac{r_{k+1}^\top r_{k+1}}{r_k^\top r_k};$$

$$d_{k+1} := -r_{k+1} + \beta_k d_k;$$

$$k := k + 1;$$

end

Флетчер–Ривс:

$$g_0 := \nabla f(x_0);$$

$$d_0 := -g_0;$$

$$k := 0;$$

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

$$\alpha_k := \{\text{поиск по } d_k\};$$

$$x_{k+1} := x_k + \alpha_k d_k;$$

$$g_{k+1} := \nabla f(x_{k+1});$$

$$\beta_k := \frac{g_{k+1}^\top g_{k+1}}{g_k^\top g_k};$$

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

$$k := k + 1;$$

end

- Существует много вариантов нелинейного CG.
- Они все совпадают на строго выпуклой квадратичной функции.

Полак–Рибье:

$$\beta_k^{\text{PR}} := \frac{\mathbf{g}_{k+1}^\top \mathbf{y}_k}{\|\mathbf{g}_k\|_2^2}$$

Хестинс–Штифель:

$$\beta_k^{\text{HS}} := \frac{\mathbf{g}_{k+1}^\top \mathbf{y}_k}{\mathbf{d}_k^\top \mathbf{y}_k}$$

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:

$$\beta_k^{\text{DY}} := \frac{\|\mathbf{g}_{k+1}\|_2^2}{\mathbf{d}_k^\top \mathbf{y}_k}$$


Агер–Джан:

$$\beta_k^{\text{HZ}} := \frac{\mathbf{g}_{k+1}^\top}{\mathbf{d}_k^\top \mathbf{y}_k} \left(\mathbf{y}_k - \frac{2 \|\mathbf{y}_k\|_2^2}{\mathbf{d}_k^\top \mathbf{y}_k} \mathbf{d}_k \right)$$


Во всех формулах $\mathbf{y}_k := \mathbf{g}_{k+1} - \mathbf{g}_k$.

- В общем случае метод Флетчера–Ривса не гарантирует того, что направление d_k является направлением спуска.
- Однако можно доказать, что если на этапе поиска по прямой использовать сильные условия Вульфа с константой $c_2 \in (0, 0.5)$, то d_k будет направлением спуска (т. е. поиск должен быть точнее, чем обычно).
- Пример: рассмотрим функцию


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



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.


- На квадратичной функции CG сходится \leq за n итераций.
- Для функций общего вида это необязательно так.
- Многие функции вблизи оптимума очень 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 Пауэлла**:

$$\text{рестарт} \Leftrightarrow \frac{|g_k^\top g_{k+1}|}{\|g_{k+1}\|_2^2} \geq \nu.$$


Обычно берут $\nu = 0.1$.

- Основано на том, что в CG соседние градиенты ортогональны.


Пример: FR vs PR vs FR+restart




FR



PR




FR+restart




- Методы PR и FR+restart сходятся сильно быстрее, чем просто FR.

Пример #2: функция Розенброка

- Функция Розенброка: $f(x, y) := (1 - x)^2 + 100(y - x^2)^2$



- График сходимости:



Пример: логистическая регрессия


- Функция потерь:

$$f(w) := \sum_{i=1}^N \ln(1 + \exp(-y_i w^T x_i)) + \frac{\lambda}{2} \|w\|_2^2$$

- Модельные данные:

```
1 N, D = 10000, 500
2 np.random.seed(0)
3 X = np.random.randn(N, D)
4 w = np.random.randn(D)
5 y = np.sign(X.dot(w) + np.random.randn(N))
6 reg_coef = 1
```

- PR vs GD:



- Нелинейный CG является методом первого порядка.
- Существуют много разных вариантов, отличающихся выбором β_k .
- Используются сильные условия Вульфа с константой $c_2 \in (0, 0.5)$.
- Обычно присутствует рестарт.
- Метод Флетчера–Ривса без рестартов наименее эффективный.
- Наиболее популярным является метод Полака–Рибье.