

Лекція 13. Метод найшвидшого спуску

Складність, пов'язана із методом послідовної верхньої релаксації, чебишовськими процедурами прискорення і такого є типу методами, полягає в тому, що вони залежать від параметрів, правильний вибір яких іноді буває важким. Наприклад, для того щоб чебишовські процедури прискорення були вдалимими, потрібні добрі оцінки для найбільшого і найменшого власних значень відповідної матриці переходу G . Якщо ця матриця не улаштована особливим чином, то отримання їх в аналітичному вигляді, найімовірніше, неможливе, а обчислення – дороге.

На щастя, існує метод, в якому немає цієї трудності, – добре відомий метод спряжених градієнтів Хестенса-Штифеля (Hestenes M.R., Stiefel E. (1952)). Метод спряжених градієнтів (CG) хоча і є ітераційним, але збігається до істинного розв'язку лінійної системи за скінченне число ітерацій за відсутності похибок округлення. Вивід цього методу почнемо з методу найшвидшого спуску.

Найшвидший спуск

Почнемо з того, що обговоримо, як може відбуватися рискання при мінімізації функціонала $\varphi(x)$, що має вигляд

$$\varphi(x) = \frac{1}{2}(Ax, x) - (b, x),$$

де $b \in R^n$ і матриця $A \in R^{n \times n}$ вважається додатно визначеною і симетричною.

Лема 1. Мінімальне значення φ дорівнює $-\frac{1}{2}(A^{-1}b, b)$ і досягається при $x = A^{-1}b$. Таким чином, мінімізація φ і розв'язування системи $Ax = b$ – еквівалентні задачі.

Доведення. Запишемо функціонал $\varphi(x)$ як квадратичну форму

$$\varphi(x) = \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n a_{ij} x_i x_j - \sum_{i=1}^n b_i x_i.$$

Необхідною і достатньою умовою мінімуму цієї квадратичної форми є рівність її градієнта нулю:

$$\text{grad } \varphi(x) = 0.$$

Отже, маємо

$$\begin{aligned} \text{grad } \varphi(x) &= \left\{ \frac{\partial \varphi}{\partial x_i} \right\}_{i=1}^n = \left\{ \frac{1}{2} \frac{\partial}{\partial x_i} \left(\sum_{j=1}^n \sum_{k=1}^n a_{jk} x_j x_k + \sum_{i=1}^n a_{ii} x_i^2 \right) - b_i \right\}_{i=1}^n = \\ &= \left| \begin{array}{l} a_{ij} = a_{ji} \\ a_{ij} x_j + a_{ji} x_j = 2a_{ij} x_j \end{array} \right| = \left\{ \sum_{j \neq i}^n a_{ij} x_j + \sum_{i=1}^n a_{ii} x_i - b_i \right\}_{i=1}^n = \left\{ \sum_{i=1}^n a_{ij} x_j - b_i \right\}_{i=1}^n = Ax - b = 0 \end{aligned}$$

Таким чином, мінімізація функціонала еквівалентна розв'язуванню СЛАУ $Ax = b$, і досягається мінімум в точці $x = A^{-1}b$.

Однією із найпростіших стратегій мінімізації φ є метод найшвидшого спуску. В поточній точці x_c функція φ убуває найшвидше в напрямку антиградієнта:

$$- \text{grad } \varphi(x_c) = b - Ax_c.$$

Означення 1. Назвемо $r_c = b - Ax_c$ відхилом вектора x_c .

Якщо відхил ненульовий, то $\varphi(x_c + \alpha r_c) < \varphi(x_c)$ для деякого додатного α .

Лема 2. В методі найшвидшого спуску (з точною мінімізацією на прямій) вибираємо

$$\alpha = \frac{(r_c, r_c)}{(Ar_c, r_c)},$$

яке лоставляє мінімум для $\varphi(x_c + \alpha r_c)$.

Доведення. Запишемо

$$\begin{aligned} \varphi(x_c + \alpha r_c) &= \frac{1}{2} (A(x_c + \alpha r_c), x_c + \alpha r_c) - (b, x_c + \alpha r_c) = \\ &= \frac{1}{2} (Ax_c, x_c) + \alpha (Ax_c, r_c) + \frac{1}{2} \alpha^2 (Ar_c, r_c) - \alpha (b, r_c) - (b, x_c) = \\ &= \frac{1}{2} \alpha^2 (Ar_c, r_c) + \alpha (Ax_c - b, r_c) + \frac{1}{2} (Ax_c - 2b, x_c). \end{aligned}$$

Оскільки припускається, що матриця A є додатно визначеною, то $(Ar_c, r_c) > 0$ і квадратний трьохчлен $q(\alpha) = \varphi(x_c + \alpha r_c)$ досягає мінімуму при $q'(\alpha) = 0$, тобто при

$$\alpha = \frac{(b - Ax_c, r_c)}{(Ar_c, r_c)} = \frac{(r_c, r_c)}{(Ar_c, r_c)}.$$

Отже отримуємо алгоритм

$$k = 0; \quad x_0 = 0; \quad r_0 = b;$$

while $r_k \neq 0$

$$k = k + 1;$$

$$\alpha_k = \frac{(r_{k-1}, r_{k-1})}{(Ar_k, r_k)};$$

$$x_k = x_{k-1} + \alpha_k r_{k-1};$$

$$r_k = b - Ax_k;$$

end

Вибір початкового вектора у вигляді $x_0 = 0$ не є обмеженням. Якщо x вважається кращим посатковим наближенням, то ми просто застосуємо (1), замінивши b на $b - Ax$. В такому випадку шуканий розв'язок апроксимується векторами $x_k + x$.

(1)

Теорема (про збіжність методу найшвидшого спуску). Наближення методу найшвидшого спуску задовольняють співвідношення

$$\Phi_0(x_k) \leq \left(\frac{\lambda_{\max} - \lambda_{\min}}{\lambda_{\max} + \lambda_{\min}} \right)^{2k} \Phi_0(x_0),$$

де $\Phi_0(x) = (A(x - \bar{x}), x - \bar{x})$, $\lambda_{\min} \leq \lambda_i(A) \leq \lambda_{\max}$ – мінімальне і максимальне власне число матриці A , відповідно.

Доведення. Покладемо $y_k = x_k$ і зробимо одну ітерацію допоміжного оптимального однокрокового процесу

$$y_{k+1} = y_k - \frac{2}{\lambda_{\max} + \lambda_{\min}} (Ay_k - b).$$

Похибки ітерацій $r_k = y_k - \bar{x}$ пов'язані співвідношенням

$$r_{k+1} = \left(I - \frac{2}{\lambda_{\max} + \lambda_{\min}} A \right) r_k.$$

Нехай $\{e_i\}_{i=1}^n$ – ортонормована система власних векторів матриці A : $Ae_i = \lambda_i e_i$,

$$(e_i, e_j) = \begin{cases} 1, & \text{якщо } i = j, \\ 0, & \text{якщо } i \neq j. \end{cases}$$

Оскільки $\lambda_{\min} \leq \lambda_i(A) \leq \lambda_{\max}$, то для всіх індексів i виконуються співвідношення

$$-\frac{\lambda_{\max} - \lambda_{\min}}{\lambda_{\max} + \lambda_{\min}} \leq 1 - \frac{2}{\lambda_{\max} + \lambda_{\min}} \lambda_i \leq \frac{\lambda_{\max} - \lambda_{\min}}{\lambda_{\max} + \lambda_{\min}}.$$

Це впливає із таких співвідношень:

$$\begin{aligned} \lambda_{\min} \leq \lambda_i \leq \lambda_{\max} &\Rightarrow -\lambda_{\max} \leq -\lambda_i \leq -\lambda_{\min} \Rightarrow \\ \Rightarrow -\frac{2}{\lambda_{\max} + \lambda_{\min}} &\leq -\frac{2}{\lambda_{\max} + \lambda_{\min}} \lambda_i \leq -\frac{2}{\lambda_{\max} + \lambda_{\min}} \Rightarrow \\ \Rightarrow 1 - \frac{2}{\lambda_{\max} + \lambda_{\min}} &\leq 1 - \frac{2}{\lambda_{\max} + \lambda_{\min}} \lambda_i \leq 1 - \frac{2}{\lambda_{\max} + \lambda_{\min}} \Rightarrow \\ \Rightarrow -\frac{\lambda_{\max} - \lambda_{\min}}{\lambda_{\max} + \lambda_{\min}} &\leq 1 - \frac{2}{\lambda_{\max} + \lambda_{\min}} \lambda_i \leq \frac{\lambda_{\max} - \lambda_{\min}}{\lambda_{\max} + \lambda_{\min}}. \end{aligned}$$

Отже,

$$\left| 1 - \frac{2}{\lambda_{\max} + \lambda_{\min}} \lambda_i \right| \leq \frac{\lambda_{\max} - \lambda_{\min}}{\lambda_{\max} + \lambda_{\min}}. \quad (2)$$

Нехай $r_k = \sum_{i=1}^n c_i e_i$. Тоді мають місце співвідношення

$$\begin{aligned} (Ar_k, r_k) &= \left(\sum_{i=1}^n c_i \lambda_i e_i, \sum_{i=1}^n c_i e_i \right) = \sum_{i=1}^n \lambda_i c_i^2, \\ r_{k+1} &= \sum_{i=1}^n d_i e_i, \text{ де } d_i = \left(1 - \frac{2}{\lambda_{\max} + \lambda_{\min}} \right) c_i, \end{aligned}$$

$$(Ar_{k+1}, r_{k+1}) \leq \sum_{i=1}^n \lambda_i d_i^2 = \sum_{i=1}^n \lambda_i \left(1 - \frac{2\lambda_i}{\lambda_{\max} + \lambda_{\min}}\right)^2 c_i^2.$$

Із урахуванням (2) отримуємо

$$(Ar_{k+1}, r_{k+1}) \leq \left(\frac{\lambda_{\max} - \lambda_{\min}}{\lambda_{\max} + \lambda_{\min}}\right)^2 (Ar_k, r_k).$$

Оскільки $\varphi_0(y_k) = (Ar_k, r_k)$, то це означає, що

$$\varphi_0(y_{k+1}) \leq \left(\frac{\lambda_{\max} - \lambda_{\min}}{\lambda_{\max} + \lambda_{\min}}\right)^2 \varphi_0(y_k) = \left(\frac{\lambda_{\max} - \lambda_{\min}}{\lambda_{\max} + \lambda_{\min}}\right)^2 \varphi_0(x_k).$$

Тепер наближення y_{k+1} запишемо в формі, подібній до методу найближчого спуску

$$y_{k+1} = x_k + \alpha \operatorname{grad} \varphi(x_k), \quad \alpha = \frac{1}{\lambda_{\max} + \lambda_{\min}}, \quad (3)$$

де $\varphi(x_k) = (Ax_k, x_k) - 2(b, x_k)$.

Оскільки на x_{k+1} , що отримується за методом найшвидшого спуску, досягається мінімум $\varphi(x)$ серед усіх наближень вигляду (3), то $\varphi(x_{k+1}) \leq \varphi(y_{k+1})$. Звідси випливає оцінка

$$\varphi_0(x_{k+1}) \leq \varphi_0(y_{k+1}) \leq \left(\frac{\lambda_{\max} - \lambda_{\min}}{\lambda_{\max} + \lambda_{\min}}\right)^2 \varphi_0(x_k) \leq \left(\frac{\lambda_{\max} - \lambda_{\min}}{\lambda_{\max} + \lambda_{\min}}\right)^{2k} \varphi_0(x_0).$$

Зауваження 1. Із теореми і оцінок

$$\lambda_{\min} \|y - \bar{x}\|_2^2 \leq \varphi_0(y) \leq \lambda_{\max} \|y - \bar{x}\|_2^2$$

випливає, що

$$\begin{aligned} \|x_k - \bar{x}\|_2 &\leq \sqrt{\frac{\varphi_0(x_k)}{\lambda_{\min}}} \leq \left(\sqrt{\varphi_{0,\max}}\right)^k \sqrt{\frac{\varphi_0(x_0)}{\lambda_{\min}}} \leq \left(\sqrt{\varphi_{0,\max}}\right)^k \sqrt{\frac{\lambda_{\max}}{\lambda_{\min}}} \|x_0 - \bar{x}\|_2 \\ \|x_k - \bar{x}\|_2 &\leq \left(\frac{\lambda_{\max} - \lambda_{\min}}{\lambda_{\max} + \lambda_{\min}}\right)^k \sqrt{\frac{\lambda_{\max}}{\lambda_{\min}}} \|x_0 - \bar{x}\|_2. \end{aligned}$$

Зауваження 2. Наближення методу найшвидшого спуску задовольняють співвідношення

$$\|x_k - \bar{x}\|_2 \leq \left(1 - \frac{\lambda_{\min}}{\lambda_{\max}}\right)^k \|x_0 - \bar{x}\|_2.$$