

## 連立 1 次方程式系、降下法

**復習**  $A \in \text{Mat}_{n \times n}(\mathbb{R})$  a symmetric positive definite matrix:  $\forall x \in \mathbb{R}^n, x \neq 0, x^T A x > 0$ .

記号:  $\langle x, y \rangle := x^T y$ ,  $\mathbb{R}^n$  上の自然な内積。  $\langle x, y \rangle_A := x^T A y$ ,  $A$  に対する内積。  $\langle x, y \rangle_A = 0$  のとき、 $x$  と  $y$  と  $A$ -直行で、あるいは**共役**だと言う。

$$Ax^* = b \Leftrightarrow g(x^*) = \min_{x \in \mathbb{R}^n} g(x), \quad \text{ただし } g(x) = \langle x, x \rangle_A - 2\langle x, b \rangle. \quad (1)$$

また、 $v \in \mathbb{R}^n$  に対して、もし  $\langle v, b - Ax \rangle \neq 0$  ならば、 $t = \frac{\langle v, b - Ax \rangle}{\|v\|_A^2}$  とすると  $g(x + tv) < g(x)$  が成り立つ。

### 一般的な降下法

$$\text{初期化} \left\{ \begin{array}{l} x^{(0)} \in \mathbb{R}^n, \text{ 初期ベクトル. (initial vector)} \\ r^{(0)} = b - Ax^{(0)} \text{ 初期残差 (first residual error)} \\ \text{降下方向 : } v^{(1)} = r^{(0)}, \text{ 最初の反復 (降下方向 } v^{(1)} \text{ を選ぶと、} t_1 \text{ も定まる).} \\ x^{(1)} = x^{(0)} + t_1 v^{(1)}, \text{ ただし } \mathbb{R} \ni t_1 = \frac{\langle v^{(1)}, r^{(0)} \rangle}{\|v^{(1)}\|_A^2} \end{array} \right. \quad (2)$$

次の反復は、以下の通りになる :

$$\left. \begin{array}{l} r^{(k)} = b - Ax^{(k)} \\ \text{降下方向 } v^{(k+1)} \text{ を選んで } t_{k+1} = \frac{\langle v^{(k+1)}, r^{(k)} \rangle}{\|v^{(k+1)}\|_A^2} \text{ を計算する。} \\ x^{(k+1)} = x^{(k)} + t_{k+1} v^{(k+1)}. \end{array} \right\} \quad (3)$$

降下方向  $v^{(2)}, \dots$  の選択では余裕があるが、その方向にどの程度行く (方向に沿って走る距離) のは定める :  $t_k$  の選択では余裕がない。

**最速降下 (最急降下、勾配降下とも言える) における降下方向の選択 :**

$$v^{(k+1)} = r^{(k)} (= b - Ax^{(k)}) \quad \text{とする。} \quad t_{k+1} = \frac{\|r^{(k)}\|_2^2}{\|r^{(k)}\|_A^2} \quad \text{となる。} \quad (4)$$

最速といっても、収束が遅く使われていない。

共役勾配法における降下方向の選択：

$$\begin{aligned} r^{(k)} &= b - Ax^{(k)}. && \langle \cdot, \cdot \rangle_A \text{ の内積に対する Gram-Schmidt による} \\ \text{降下方向 } v^{(k+1)} &= r^{(k)} - \sum_{\ell=1}^k \frac{\langle v^{(\ell)}, r^{(k)} \rangle_A}{\|v^{(\ell)}\|_A^2} v^{(\ell)}. \end{aligned} \quad (5)$$

**収束：**  $A$  は「不良条件」(ill-conditioned) の行列でなければ、 $\sqrt{n}$  反復程度だけでよい近似を与える。「不良条件」とは最大固有値と最低固有値の差が大きいという意味である。

ただ、反復ごとに  $\langle v^{(\ell)}, r^{(k)} \rangle_A$ ,  $\ell = 1, \dots, k-1$  を計算しなければならないし、また  $\|v^{(\ell)}\|_A^2$  の値を記録しなければならない。従って、効率ではない方法である。しかし、共役勾配法では、かなり工夫が入っていて降下方向の  $v^{(k)}$ 、それに付随する  $t_k$  などの計算を効率化したものである。

取りあえず、以下の結果を証明できるが、やや面倒で省く：

**定理 6：** 公式 (5) による定義した降下方向  $v^{(1)}, \dots, v^{(k)}$  とし、公式 (3) による定まる、 $t_1, \dots, t_k, x^{(1)}, \dots, x^{(k)}, r^{(1)}, \dots, r^{(k)}$  とする。

$$\forall i = 1, \dots, k \quad \langle r^{(k)}, v^{(i)} \rangle = 0. \square$$

降下方向  $v^{(k)}$  の選択に関する効率化：

$$v^{(k)} = r^{(k-1)} + s_{k-1}v^{(k-1)}, \quad \text{ただし} \quad s_{k-1} = -\frac{\langle v^{(k-1)}, r^{(k-1)} \rangle_A}{\|v^{(k-1)}\|_A^2} \quad (6)$$

をすれば、公式 (5) における Gram-Schmidt による  $v^{(k)}$  と同値だと証明できる。その上、以下の等式が成立することになる (証明を省く)。

$$\begin{cases} \langle v^{(k)}, v^{(i)} \rangle_A = 0, & \forall i = 1, \dots, k-1 \\ \langle v^{(k)}, r^{(k)} \rangle = 0. \\ \langle r^{(i)}, r^{(j)} \rangle = 0 & i \neq j \text{ のとき } \forall 1 \leq i \leq k, \forall 1 \leq j \leq k, \end{cases}$$

$t_k, s_k, r^{(k)}$  の計算に関する効率化： 上述された降下方向  $v^{(k)}$  の計算を効率化できるだけではなく、共役勾配法におけるほかの値  $t_k, s_k, r^{(k)}$  も効率化できる。ここも、証明を省く。

$$t_k = \frac{\|r^{(k-1)}\|_2^2}{\|v^{(k)}\|_A^2}, \quad r^{(k)} = r^{(k-1)} - t_k A v^{(k)}, \quad s_k = \frac{\|r^{(k)}\|_2^2}{\|r^{(k-1)}\|_2^2},$$

共役勾配法のステップ (まとめ)：

1. 最初の反復 ( $k = 0$ )  $\rightarrow$  最速降下法と同じ、公式 (2) で  $x^{(0)}, r^{(0)}, v^{(1)} = r^{(0)}, t_1, x_1$  が定まる。
2. 第 2 回目の反復から  $k = 1, 2, \dots$ 、以下の順番で計算する。

$$(a) \quad t_k = \frac{\|r^{(k-1)}\|_2^2}{\|v^{(k)}\|_A^2}.$$

$$(b) \quad x^{(k)} = x^{(k-1)} + t_k v^{(k)}$$

$$(c) \quad r^{(k)} = r^{(k-1)} - t_k A v^{(k)}$$

$$(d) \quad s_k = \frac{\|r^{(k)}\|_2^2}{\|r^{(k-1)}\|_2^2}$$

$$(e) \quad v^{(k+1)} = r^{(k)} + s_k v^{(k)}$$

**Exercise 1** The purpose of this exercise is to compare the steepest descent method and the conjugate gradient descent method on the following system of linear equation:

$$A = \begin{pmatrix} 4 & 3 \\ 3 & 4 \end{pmatrix}, \quad b = \begin{pmatrix} 2 \\ 5 \end{pmatrix} \quad A \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = b.$$

- (a) Verify that  $A$  is symmetric definite positive (the simplest way may be to use “criterion (iv) of Preliminary 2” in the sheet “Report 3-1” date December 1st ).
- (b) (initialization) Use Formula (2) to compute  $r^{(0)}$ ,  $v^{(1)}$ ,  $t_1$  and  $x^{(1)}$ , starting with initial approximation  $x^{(0)} = (0, 0)^T$ .
- (c) Use the iteration (4) of the steepest descent method to compute  $r^{(1)} = v^{(2)}$ ,  $t_2$  and finally  $x^{(2)}$ .
- (d) Use Gram-Schmidt orthogonalization (5) on  $r^{(0)} = v^{(1)}$ ,  $r^{(1)} = v^{(2)}$  to compute  $V^{(1)} = v^{(1)}$  and  $V^{(2)}$  such that  $\langle V^{(2)}, V^{(1)} \rangle_A \approx 0$ . Deduce  $T_2 \in \mathbb{R}$  and  $X^{(2)} \in \mathbb{R}^2$  using Formula (3).
- (e) Check that you will get the same value  $X^{(2)}$  by using directly the conjugate gradient formula (a)-(e) (共役勾配法のステップ (まとめ) )

Remark: 10 iterations of the steepest descent gives the approximation:  $x^{(10)} = (-0.989, 1.978)^T$ . ■  
Thus the steepest descent is very slow.

**Exercise 2** In the general step of the conjugate gradient iteration (共役勾配法のステップ (まとめ)(a)-(e)), how many products matrix/vector are necessary ? How many vector/vector products?

If you would use Gram-Schmidt formula (5), how many matrix/vector products and vector/vector products?

**Exercise 3** In the example of Exercise 1 (d)-(e),  $n = 2$  iterations are sufficient to get an *exact* solution.

This is no coincidence, according to the following theorem.

**Theorem 1** Consider a system  $Ax = b$ , where  $b \in \mathbb{R}^n$  and  $A \in \text{Mat}_{n \times n}(\mathbb{R})$  is symmetric definite positive.

Suppose that a descent method computes descent directions  $v^{(1)}, v^{(2)}, \dots, v^{(n)}$  that are pairwise conjugate. Then for any initial vector  $x^{(0)}$ , the sequence of vectors  $x^{(1)}, x^{(2)}, \dots, x^{(n)}$  computed from Formula (3) exactly, without approximation verify:  $Ax^{(n)} = b$  (that is the  $n$ -th approximation  $x^{(n)}$  is an exact solution). ■

**Remark:**

- Here, such a descent method is therefore a *direct method*, not iterative.
- The conjugate gradient method verifies the assumption of the theorem, therefore the conjugate gradient can be seen as a direct method as well.

- However it is never used as a direct method since there are better direct methods for positive definite matrix, and ...
- ...for large  $n$ , sparse matrices, and when the eigenvalues of  $A$  are not too far away, we expect that only  $\sqrt{n}$  iterations yield a good approximation. Therefore the conjugate gradient method is used as an iterative method.

- (a) Show that it suffices to prove that  $\langle Ax^{(n)} - b, v^{(k)} \rangle = 0$  for all  $k = 1, \dots, n$ .
- (b) Prove that  $Ax^{(n)} = Ax^{(0)} + t_1 Av^{(1)} + t_2 Av^{(2)} + \dots + t_n Av^{(n)}$  (use Formula (3) assuming  $v^{(i)}, v^{(j)}$  are conjugate when  $i \neq j$ ).
- (c) Deduce that  $\langle Ax^{(n)} - b, v^{(k)} \rangle = \langle Ax^{(0)} - b, v^{(k)} \rangle + t_k \langle v^{(k)}, v^{(k)} \rangle_A$  (Remember that  $\langle v^{(i)}, v^{(k)} \rangle_A = \langle v^{(i)}, Av^{(k)} \rangle$ )
- (d) (questions (d), (e), (f) are independent of (c)) Use the definition of  $t_k$  and the equality  $b - Ax^{(k-1)} = b - Ax^{(0)} + Ax^{(0)} - \dots - Ax^{(k-2)} + Ax^{(k-2)} - Ax^{(k-1)}$  to show that

$$t_k \|v^{(k)}\|_A^2 = \langle v^{(k)}, b - Ax^{(0)} \rangle + \sum_{\ell=0}^{k-2} \langle v^{(k)}, A(x^{(\ell)} - x^{(\ell+1)}) \rangle.$$

- (e) Show that  $Ax^{(\ell)} - Ax^{(\ell+1)} = -t_{\ell+1} Av^{(\ell+1)}$ .
- (f) Deduce that  $t_k \|v^{(k)}\|_A^2 = \langle v^{(k)}, b - Ax^{(0)} \rangle - \sum_{\ell=0}^{k-2} t_{\ell+1} \langle v^{(k)}, v^{(\ell+1)} \rangle_A$ . And then that  $t_k \|v^{(k)}\|_A^2 = \langle v^{(k)}, b - Ax^{(0)} \rangle$ .
- (g) Conclude using Questions (c) and (f).