

連立一次方程式に対する共役勾配法の導出

講義で割愛した，アルゴリズム導出の概略を説明する（参考：[1, 2] 等）．最適化（→今期講義『最適化手法』）と密接に関係し，面白い数理構造が表出するので，興味がある人は導出を追ってみるとよい．

以下の戦略に沿って導出する．

1. 行列 A が実対称正定値のとき， $Ax = b$ の解法が二次最適化に帰着できることを示す．
2. それに対する勾配降下法を構成する．ただしそこで最急降下は良い戦略にならない．
3. 最急降下方向を「 A 直交化」したとき，降下法が有限回で終わることを示す．
4. その降下法が資料で示した CG 法アルゴリズムと一致することを示す．

問題の次元を n とし，真の解を x^* で表す．記号 (\cdot, \cdot) ， $\|\cdot\|$ は通常の \mathbb{R}^n の内積とノルムとする．

1. 二次最適化への帰着

$\tilde{\phi}(x) = \frac{1}{2}(x - x^*, A(x - x^*))$ と置くと， A の正値性よりこの最適化は $Ax = b$ の求解と同値．さらに $\tilde{\phi}(x) = \frac{1}{2}(x, Ax) - (x, b) + \frac{1}{2}(x^*, b)$ であり，この最小化は $\phi(x) = \frac{1}{2}(x, Ax) - (x, b)$ の最小化と同値．以降，この問題を考える．

2. 降下法の構成

初期解 x_0 ，および各段の探索方向 p_k ($k = 0, 1, \dots$) が与えられているとする（探索方向が事前に分かっているとするのは現実的設定ではないが，どう取るかは後で考える）．このとき，第 k 段 ($k = 0, 1, \dots$) における最小化問題 $\min_{\alpha_k \in \mathbb{R}} \phi(x_k + \alpha_k p_k)$ の最適値を与えるステップ幅 α_k は $\alpha_0 = (r_k, p_k)/(p_k, Ap_k)$ ．これで降下法を構成したものをアルゴリズム原型（その 1）とする．

アルゴリズム原型（その 1）

```

 $x_0$ : given;  $p_0, p_1, \dots$ : given
for  $k := 0, 1, 2, \dots$  {
     $\alpha_k := (r_k, p_k)/(p_k, Ap_k)$ 
     $x_{k+1} := x_k + \alpha_k p_k$ 
}
    
```

探索方向 $\{p_k\}$ としては，素朴には最急降下方向が考えられる．これを計算すると $p_k = -\nabla\phi(x_k) = b - Ax_k =: r_k$ ．すなわち，この問題における最急降下方向は，その時点での残差 r_k で与えられる．しかし（最適化の講義で習っているように）これは一般には良い選択とはならない．

3. 「 A 直交」な探索方向列による降下法

定義 1 (A 直交) ベクトル列 $\{p_i\}_{i=0}^k$ が「 A 直交」するとは， $p_i \neq 0$ ($i = 0, \dots, k$) かつ $(p_i, Ap_j) = 0$ ($0 \leq i < j \leq k$) を満たすことを言う．

アルゴリズム原形（その 1）において，探索方向を原則的には最急降下方向にとるが，しかしながらそれらが A 直交列になるように直交化することを考える．これは以下のように Gram-Schmidt の直交化の変形で実現できる（数学的には A を計量とする内積空間における GS 直交化になる．興味がある人は本資料の

議論全体を計量を入れた内積 $(\cdot, \cdot)_A$, ノルム $\|\cdot\|_A$ で書き直してみよ).

$$\begin{aligned} p_0 &= r_0, & (\text{最急降下}) \\ p_1 &= r_1 - \frac{(r_1, Ap_0)}{(p_0, Ap_0)} p_0, \\ &\vdots \\ p_k &= r_k - \sum_{i=0}^{k-1} \frac{(r_k, Ap_i)}{(p_i, Ap_i)} p_i. \end{aligned}$$

探索方向を, このようにとる降下法をアルゴリズム原型 (その2) とする.

アルゴリズム原型 (その2)

```

 $x_0$ : given
 $r_0 := b - Ax_0$ ;  $p_0 := r_0$ 
for  $k := 0, 1, 2, \dots$  {
   $\alpha_k := (r_k, p_k) / (p_k, Ap_k)$ 
   $x_{k+1} := x_k + \alpha_k p_k$ ;  $r_{k+1} := b - Ax_{k+1} = r_k - \alpha_k Ap_k$ 
   $p_{k+1} := r_{k+1} - \sum_{i=0}^k \frac{(r_{k+1}, Ap_i)}{(p_i, Ap_i)} p_i$ 
}

```

この解析には, Krylov 部分空間の概念を入れると便利である.

定義 2 (Krylov 部分空間) ある $v \in \mathbb{R}^n$ に対し, $\mathcal{K}_k(A, v) := \text{span}(v, Av, \dots, A^{k-1}v)$ を (A により v から生成される) Krylov 部分空間と呼ぶ.

当然ながら $\mathcal{K}_k(A, v) \subseteq \mathcal{K}_{k+1}(A, v)$ かつ $\dim \mathcal{K}_k(A, v) \leq k \leq n$. ($\dim \mathcal{K}_n(A, v)$ は v に依存し決まる).

定理 1 行列 A が実対称正定値のとき, アルゴリズム原型 (その2) は破綻せず, その生成する $\{x_k\}$ は, (丸め誤差がない場合には) ある $k \leq n$ に対し $x_k = x^*$ を満たす.

(略証) アルゴリズム原形 (その2) において, 各段で $p_k \neq 0 \Leftrightarrow r_k \neq 0$ が示せる. ゆえにアルゴリズムは破綻しない. さらに $\text{span}(p_0, \dots, p_k) = \text{span}(r_0, \dots, r_k) = \mathcal{K}_{k+1}(A, r_0)$ が成り立ち, 主張はこれらより明らか. (なお数学的には, アルゴリズムが止まる k は $k = \dim \mathcal{K}_n(A, v)$ である.) ■

4. 降下法アルゴリズムの簡略化: CG 法の発見

前段で述べた内容により, 実は $(r_{k+1}, Ap_j) = 0$ ($0 \leq j \leq k-1$) が成り立つ. よって, アルゴリズム原型 (その2) の最終行の和を簡略化でき, 配付資料の CG 法アルゴリズムを得る.

参考文献

- [1] 杉原正顕, 室田一雄, 線形計算の数理, 岩波書店, 東京, 2009.
- [2] 櫻井鉄也, 松尾宇泰, 片桐孝洋 (編), 数値線型代数の数理と HPC, 共立出版, 東京, 2018.