

情報数理工学・コンピュータサイエンス 実験第2 大規模連立1次方程式に対する 共役勾配法

緒方秀教 (ogata@im.uec.ac.jp)

2016年11月2日(水)

実験スケジュール

- 11月2日（水）
 - ガイダンス
 - 実験（計算機室，エリア1）
- 10月14日（水）～
 - 実験（計算機室，エリア1）
- 実験内容
 - 課題1～5を解く→レポート
 - 証明問題（課題1,2）…自宅学習
 - プログラミング（課題3,4,5）…計算機室
 - 課題6以降は発展課題
- レポート締め切り…最終日から3週間後くらい（掲示に注意）

1. 序：本実験の目的

大規模連立1次方程式の数値解法である共役勾配法を理解し、プログラミングする。

$$Ax = b, \quad \text{i.e.} \quad \begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1N} \\ a_{21} & a_{22} & \cdots & a_{2N} \\ \vdots & \vdots & & \vdots \\ a_{N1} & a_{N2} & \cdots & a_{NN} \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_N \end{bmatrix} = \begin{bmatrix} b_1 \\ b_2 \\ \vdots \\ b_N \end{bmatrix}.$$

(仮定) A は大規模対称疎行列である。

N 巨大, $a_{ij} = a_{ji}$, 大部分の $a_{ij} = 0$.

1. 序：問題の動機

科学技術計算（微分方程式の数値解法）

⇒ 連立1次方程式の解の計算に帰着されることが多い。

1. 序：問題の動機

科学技術計算（微分方程式の数値解法）

⇒ 連立1次方程式の解の計算に帰着されることが多い。

(例) 常微分方程式の2点境界値問題 → 差分法による近似解

$$\begin{cases} -\frac{d^2y}{dx^2} = f(x) & a < x < b, \\ y(a) = y(b) = 0. \end{cases}$$

1. 序：問題の動機

科学技術計算（微分方程式の数値解法）

⇒ 連立1次方程式の解の計算に帰着されることが多い。


(例) 常微分方程式の2点境界値問題 → 差分法による近似解

$$\begin{cases} -\frac{d^2y}{dx^2} = f(x) & a < x < b, \\ y(a) = y(b) = 0. \end{cases}$$

差分法：微分 → 差分近似

$$\frac{dy}{dx} \simeq \frac{f(x+h) - f(x)}{h}, \quad \frac{d^2y}{dx^2} \simeq \frac{f(x+h) - 2f(x) + f(x-h)}{h^2}.$$


1. 序：問題の動機（微分方程式の差分法による近似解）



$$\begin{bmatrix} 2 & -1 & & \\ -1 & 2 & -1 & \\ & \ddots & \ddots & \ddots \\ & & -1 & 2 \end{bmatrix} \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_{N-1} \end{bmatrix} = \begin{bmatrix} h^2 f(x_1) \\ h^2 f(x_2) \\ \vdots \\ h^2 f(x_{N-1}) \end{bmatrix},$$

$$\left. \begin{array}{l} x_k = a + kh \\ y_k \simeq y(x_k) \end{array} \right\} k = 0, 1, \dots, N; h = \frac{b - a}{N}.$$

1. 序：問題の動機（微分方程式の差分法による近似解）



$$\underbrace{\begin{bmatrix} 2 & -1 & & & \\ -1 & 2 & -1 & & \\ & \ddots & \ddots & \ddots & \\ & & & -1 & 2 \end{bmatrix}}_{\text{大規模疎行列}} \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_{N-1} \end{bmatrix} = \begin{bmatrix} h^2 f(x_1) \\ h^2 f(x_2) \\ \vdots \\ h^2 f(x_{N-1}) \end{bmatrix},$$

大規模疎行列

$$\left. \begin{array}{l} x_k = a + kh \\ y_k \simeq y(x_k) \end{array} \right\} k = 0, 1, \dots, N; h = \frac{b - a}{N}.$$

2. 理論

連立 1 次方程式 $A\mathbf{x} = \mathbf{b}$

係数行列 A に対する仮定

1. **対称** : $A^T = A$
2. **正定値** : $(\mathbf{x}, A\mathbf{x}) \geq 0$ ($\forall \mathbf{x} \in \mathbb{R}^N$), $(\mathbf{x}, A\mathbf{x}) = 0 \Rightarrow \mathbf{x} = \mathbf{0}$.
* $(\mathbf{x}, \mathbf{y}) = x_1y_1 + \cdots + x_Ny_N$ (ベクトルの内積)

2. 理論

連立1次方程式 $A\mathbf{x} = \mathbf{b}$

係数行列 A に対する仮定

1. **対称** : $A^T = A$
2. **正定値** : $(\mathbf{x}, A\mathbf{x}) \geq 0$ ($\forall \mathbf{x} \in \mathbb{R}^N$), $(\mathbf{x}, A\mathbf{x}) = 0 \Rightarrow \mathbf{x} = \mathbf{0}$.
* $(\mathbf{x}, \mathbf{y}) = x_1y_1 + \cdots + x_Ny_N$ (ベクトルの内積)

連立1次方程式 $A\mathbf{x} = \mathbf{b}$ の解を求めることは、次の2次関数を最小にする $\mathbf{x} = \mathbf{x}^*$ を求めることと同値である。

$$f(\mathbf{x}) = \frac{1}{2}(\mathbf{x}, A\mathbf{x}) - (\mathbf{b}, \mathbf{x}) = \frac{1}{2} \sum_{i,j=1}^N a_{ij}x_ix_j - \sum_{i=1}^N b_ix_i.$$

2. 理論

連立 1 次方程式 $A\mathbf{x} = \mathbf{b}$

係数行列 A に対する仮定

1. **対称** : $A^T = A$
2. **正定値** : $(\mathbf{x}, A\mathbf{x}) \geq 0$ ($\forall \mathbf{x} \in \mathbb{R}^N$), $(\mathbf{x}, A\mathbf{x}) = 0 \Rightarrow \mathbf{x} = \mathbf{0}$.
* $(\mathbf{x}, \mathbf{y}) = x_1y_1 + \cdots + x_Ny_N$ (ベクトルの内積)

連立 1 次方程式 $A\mathbf{x} = \mathbf{b}$ の解を求めることは、次の 2 次関数を最小にする $\mathbf{x} = \mathbf{x}^*$ を求めることと同値である。

$$f(\mathbf{x}) = \frac{1}{2}(\mathbf{x}, A\mathbf{x}) - (\mathbf{b}, \mathbf{x}) = \frac{1}{2} \sum_{i,j=1}^N a_{ij}x_ix_j - \sum_{i=1}^N b_ix_i.$$

2 次関数 $f(\mathbf{x})$ の最小化問題を考える。

2. 理論

$f(\mathbf{x})$ の最小化問題 \Rightarrow 反復法により解く.

$$\text{近似解列 } \mathbf{x}_0, \mathbf{x}_1, \dots, \mathbf{x}_k, \dots \rightarrow \mathbf{x}^*, \quad f(\mathbf{x}^*) = \min_{\mathbf{x} \in \mathbb{R}^N} f(\mathbf{x}).$$

近似解列 $\{\mathbf{x}_k\}$ … 次の算法により生成する.

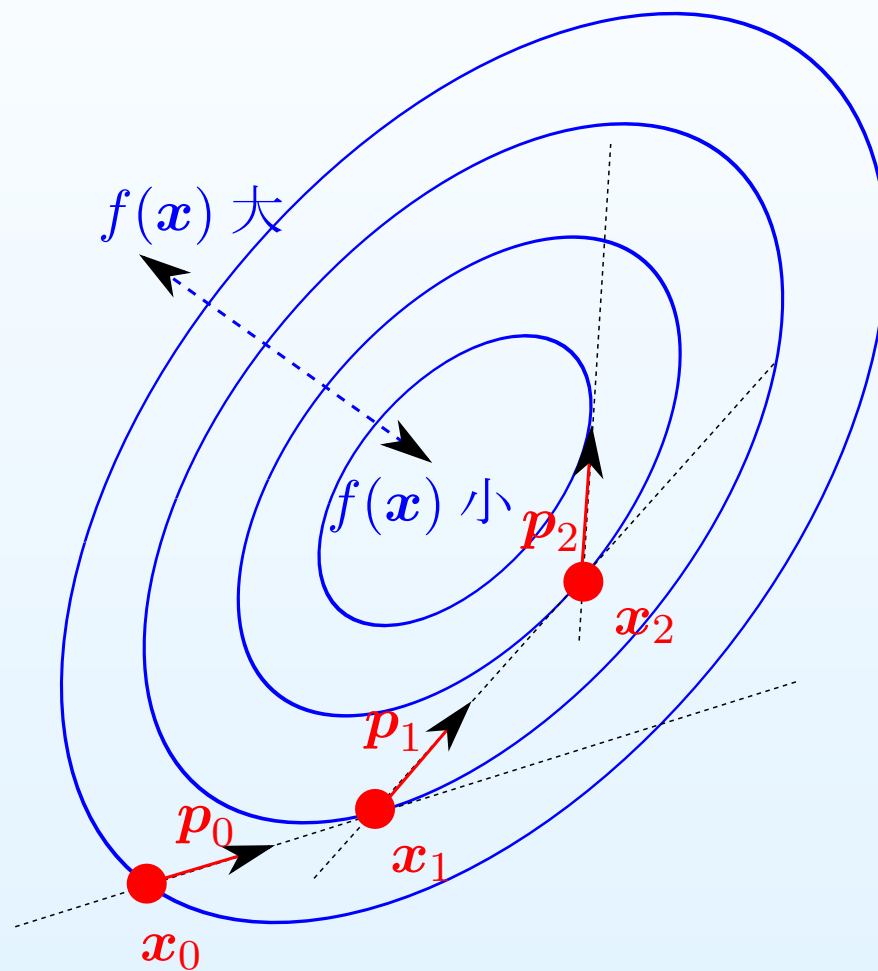
初期解 \mathbf{x}_0 を適当に定める ;

$k = 0, 1, 2, \dots$ に対して

$$\left[\begin{array}{l} \text{探索方向ベクトル } \mathbf{p}_k \text{ を適当に定める ;} \\ f(\mathbf{x}_k + \alpha_k \mathbf{p}_k) = \min_{\alpha \in \mathbb{R}} f(\mathbf{x} + \alpha \mathbf{p}_k) \text{ なる } \alpha_k \text{ を定める ;} \\ \mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{p}_k; \end{array} \right.$$

2. 理論

$f(\boldsymbol{x})$ の等高線



2. 理論

$f(\mathbf{x})$ の最小化問題 \Rightarrow 反復法により解く.

$$\text{近似解列 } \mathbf{x}_0, \mathbf{x}_1, \dots, \mathbf{x}_k, \dots \rightarrow \mathbf{x}^*, \quad f(\mathbf{x}^*) = \min_{\mathbf{x} \in \mathbb{R}^N} f(\mathbf{x}).$$

近似解列 $\{\mathbf{x}_k\}$ … 次の算法により生成する.

初期解 \mathbf{x}_0 を適当に定める ;

$k = 0, 1, 2, \dots$ に対して

$$\left[\begin{array}{l} \text{探索方向ベクトル } \mathbf{p}_k \text{ を適当に定める ;} \\ f(\mathbf{x}_k + \alpha_k \mathbf{p}_k) = \min_{\alpha \in \mathbb{R}} f(\mathbf{x} + \alpha \mathbf{p}_k) \text{ なる } \alpha_k \text{ を定める ;} \\ \mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{p}_k; \end{array} \right.$$

2 次関数 $f(\mathbf{x})$ に対しては, α_k は厳密に求まる (課題 1).

$$\alpha_k = \frac{(\mathbf{p}_k, \mathbf{r}_k)}{(\mathbf{p}_k, A\mathbf{p}_k)}, \quad \mathbf{r}_k = \mathbf{b} - A\mathbf{x}_k \quad (\text{残差ベクトル})$$

2. 理論：最急降下法 (steepest descent method)

探索方向ベクトル \mathbf{p}_k のとり方

…最急降下方向にとる \Rightarrow **最急降下法**

$$\mathbf{p}_k = -\nabla f(\mathbf{x}_k) = \mathbf{r}_k = \mathbf{b} - A\mathbf{x}_k.$$

2. 理論：最急降下法 (steepest descent method)

探索方向ベクトル \mathbf{p}_k のとり方
…最急降下方向にとる \Rightarrow **最急降下法**

$$\mathbf{p}_k = -\nabla f(\mathbf{x}_k) = \mathbf{r}_k = \mathbf{b} - A\mathbf{x}_k.$$

問題点

同じ方向の探索方向ベクトル \mathbf{p}_k が
何度も現れることがある。




近似解を求める部分アフィン空間

$$\mathbf{x}_0 + \text{span}\{\mathbf{p}_0, \mathbf{p}_1, \dots, \mathbf{p}_k\}$$

が広がらない。



収束が遅くなる。



Stiefel の鳥かご

2. 理論：共役方向法 (conjugate direction method)

最急降下法の欠点を解消

$$A\text{-直交性 } (\mathbf{p}_j, A\mathbf{p}_k) = 0 \quad (j \neq k).$$

共役方向法…探索方向ベクトル \mathbf{p}_k が A -直交性を満たすようにとった反復法の総称.

2. 理論：共役方向法 (conjugate direction method)

最急降下法の欠点を解消

$$A\text{-直交性 } (\mathbf{p}_j, A\mathbf{p}_k) = 0 \quad (j \neq k).$$

共役方向法…探索方向ベクトル \mathbf{p}_k が A -直交性を満たすようにとった反復法の総称.

探索方向ベクトルの系 $\{\mathbf{p}_0, \mathbf{p}_1, \dots, \mathbf{p}_k\}$ は 1 次独立である
(課題 2) .

(同じ方向の探索方向ベクトルを繰り返すことはない)

2. 理論：共役方向法

探索方向ベクトル \mathbf{p}_k の A -直交性により

直線探索（局所的最小化）の繰り返し

$$f(\mathbf{x}_{k+1}) = f(\mathbf{x}_k + \alpha_k \mathbf{p}_k) = \min_{\alpha \in \mathbb{R}} f(\mathbf{x}_k + \alpha \mathbf{p}_k).$$

↓

大域的最適化の達成

$$\begin{aligned} f(\mathbf{x}_{k+1}) &= f(\mathbf{x}_0 + \alpha_0 \mathbf{p}_0 + \cdots + \alpha_k \mathbf{p}_k) \\ &= \min \{ f(\mathbf{x}_0 + c_0 \mathbf{p}_0 + \cdots + c_k \mathbf{p}_k) \mid c_0, c_1, \dots, c_k \in \mathbb{R} \}. \end{aligned}$$

2. 理論：共役方向法

とくに $k = N - 1$ の場合,

$$\{ \mathbf{x}_0 + c_0 \mathbf{p}_0 + \cdots + c_{N-1} \mathbf{p}_{N-1} \mid c_0, \dots, c_{N-1} \in \mathbb{R} \} = \mathbb{R}^N.$$

↓

$$f(\mathbf{x}_N) = \min_{\mathbf{x} \in \mathbb{R}^N} f(\mathbf{x}).$$

$\therefore \mathbf{x}_N$ は $f(\mathbf{x})$ を最小にする, i.e., $A\mathbf{x} = \mathbf{b}$ の解である.

2. 理論：共役方向法

とくに $k = N - 1$ の場合,

$$\{ \mathbf{x}_0 + c_0 \mathbf{p}_0 + \cdots + c_{N-1} \mathbf{p}_{N-1} \mid c_0, \dots, c_{N-1} \in \mathbb{R} \} = \mathbb{R}^N.$$

↓

$$f(\mathbf{x}_N) = \min_{\mathbf{x} \in \mathbb{R}^N} f(\mathbf{x}).$$

∴ \mathbf{x}_N は $f(\mathbf{x})$ を最小にする, i.e., $A\mathbf{x} = \mathbf{b}$ の解である.

(理論上は) 有限回の反復で連立 1 次方程式 $A\mathbf{x} = \mathbf{b}$ の真の解 $\mathbf{x}^* = A^{-1}\mathbf{b}$ を得る.

2. 理論：共役方向法

$$\begin{aligned} f(\mathbf{x}_{k+1}) &= f(\mathbf{x}_0 + \alpha_0 \mathbf{p}_0 + \cdots + \alpha_k \mathbf{p}_k) \\ &= \min \{ \mathbf{x}_0 + c_0 \mathbf{p}_0 + \cdots + c_k \mathbf{p}_k \mid c_0, \dots, c_k \in \mathbb{R} \} \end{aligned}$$

の証明…下記のように「変数分離」できることから、証明できる。

$$\begin{aligned} & f(\mathbf{x}_0 + c_0 \mathbf{p}_0 + \cdots + c_k \mathbf{p}_k) \\ &= \frac{1}{2} \left(\mathbf{x}_0 + \sum_{j=0}^k c_j \mathbf{p}_j \right)^t A \left(\mathbf{x}_0 + \sum_{j=0}^k c_j \mathbf{p}_j \right) - \mathbf{b}^t \left(\mathbf{x}_0 + \sum_{j=0}^k c_j \mathbf{p}_j \right) \end{aligned}$$

($\{\mathbf{p}_k\}$ の A -直交性を用いて)

$$= \sum_{j=0}^k \psi(c_j \mathbf{p}_j) + f(\mathbf{x}_0) \quad \cdots \quad c_0, \dots, c_k \text{ について変数分離される}$$

$$\text{with } \psi(\mathbf{x}) = \frac{1}{2} \mathbf{x}^t A \mathbf{x} - \mathbf{r}_0^t \mathbf{x}.$$

2. 共役勾配法 (conjugate gradient method, CG 法)

A -直交性を満たす探索方向ベクトル \mathbf{p}_k をどうやって生成するか？

2. 共役勾配法 (conjugate gradient method, CG 法)

A-直交性を満たす探索方向ベクトル \mathbf{p}_k をどうやって生成するか？

最急降下方向ベクトル

$$-\nabla f(\mathbf{x}_k) = \mathbf{r}_k = \mathbf{b} - A\mathbf{x}_k$$

を Gram-Schmidt 直交化してつくる。

$$\mathbf{p}_0 = \mathbf{r}_0,$$

$$\mathbf{p}_{k+1} = \mathbf{r}_{k+1} - \sum_{j=0}^k \beta_j^{(k)} \mathbf{p}_j, \quad \beta_j^{(k)} = \frac{(\mathbf{r}_{k+1}, A\mathbf{p}_j)}{(\mathbf{p}_j, A\mathbf{p}_j)} \quad (k = 0, 1, \dots).$$

こうして得られるのが共役勾配法 (CG 法) である。

2. 理論：共役勾配法

実は次式が成立する.

$$\beta_j^{(k)} = \begin{cases} 0 & (j \leq k-1) \\ -\|\mathbf{r}_{k+1}\|^2 / \|\mathbf{r}_k\|^2 & (j = k) \end{cases}$$

↓

$$\mathbf{p}_{k+1} = \mathbf{r}_{k+1} + \beta_k \mathbf{p}_k, \quad \beta_k = \frac{\|\mathbf{r}_{k+1}\|^2}{\|\mathbf{r}_k\|^2}.$$

2. 理論：共役勾配法

実は次式が成立する.

$$\beta_j^{(k)} = \begin{cases} 0 & (j \leq k-1) \\ -\|\mathbf{r}_{k+1}\|^2 / \|\mathbf{r}_k\|^2 & (j = k) \end{cases}$$

↓

$$\mathbf{p}_{k+1} = \mathbf{r}_{k+1} + \beta_k \mathbf{p}_k, \quad \beta_k = \frac{\|\mathbf{r}_{k+1}\|^2}{\|\mathbf{r}_k\|^2}.$$

過去のステップの探索方向ベクトル $\mathbf{p}_0, \mathbf{p}_1, \dots, \mathbf{p}_{k-1}$ を記憶しなくてよい (メモリの節約).

2. 理論：共役勾配法

$$\beta_j^{(k)} = \begin{cases} 0 & (j \leq k-1) \\ -\|\mathbf{r}_{k+1}\|^2 / \|\mathbf{r}_k\|^2 & (j = k) \end{cases} \quad \text{の証明.}$$

Step 1/2 次の等式を証明する (プリント・命題 1).

$$(\mathbf{r}_{k+1}, \mathbf{p}_j) = 0 \quad (j = 0, 1, \dots, k).$$

$j = k$ の場合,

$$\begin{aligned} 0 &= \left. \frac{d}{d\alpha} f(\mathbf{x} + \alpha \mathbf{p}_k) \right|_{\alpha=\alpha_k} = (\mathbf{p}_k, \nabla f(\mathbf{x}_k + \alpha_k \mathbf{p}_k)) \\ &= (\mathbf{p}_k, A(\mathbf{x}_k + \alpha_k \mathbf{p}_k)) - \mathbf{b} = -(\mathbf{p}_k, \mathbf{r}_{k+1}), \end{aligned}$$

$j = 0, \dots, k-1$ の場合,

$$\begin{aligned} (\mathbf{r}_{k+1}, \mathbf{p}_j) &= (\mathbf{b} - A\mathbf{x}_{k+1}, \mathbf{p}_j) = (\mathbf{b} - A(\mathbf{x}_{j+1} + \alpha_{j+1}\mathbf{p}_{j+1} + \dots + \alpha_{k+1}\mathbf{p}_{k+1}), \mathbf{p}_j) \\ &= \underbrace{(\mathbf{r}_{j+1}, \mathbf{p}_j)}_{0 (\because j = k \text{ の場合の証明})} - \underbrace{\alpha_{j+1}(\mathbf{p}_{j+1}, A\mathbf{p}_j) - \dots - \alpha_{k+1}(\mathbf{p}_{k+1}, A\mathbf{p}_j)}_{0 (\because \mathbf{p}_k \text{ の } A\text{-直交性})} = 0. \end{aligned}$$

2. 理論：共役勾配法

Step 2/2 題意の等式の証明.

$$\begin{aligned}\beta_j^{(k)} &= \frac{(\mathbf{r}_{k+1}, A\mathbf{p}_j)}{(\mathbf{p}_j, A\mathbf{p}_j)} = \frac{1}{(\mathbf{p}_j, A\mathbf{p}_j)} \left(\mathbf{r}_{k+1}, A \frac{\mathbf{x}_{j+1} - \mathbf{x}_j}{\alpha_j} \right) \quad (\because \mathbf{x}_{j+1} = \mathbf{x}_j + \alpha_j \mathbf{p}_j) \\ &\quad \left(\alpha_j = \frac{(\mathbf{r}_j, \mathbf{p}_j)}{(\mathbf{p}_j, A\mathbf{p}_j)} = \frac{(\mathbf{r}_j, \mathbf{r}_j - \alpha_{j-1} \mathbf{p}_{j-1})}{(\mathbf{p}_j, A\mathbf{p}_j)} \quad (\because \text{Step 1/2}) \quad \frac{\|\mathbf{r}_j\|^2}{(\mathbf{p}_j, A\mathbf{p}_j)} \text{ を用いて} \right) \\ &= \frac{1}{(\mathbf{p}_j, A\mathbf{p}_j)} \frac{(\mathbf{p}_j, A\mathbf{p}_j)}{\|\mathbf{r}_j\|^2} (\mathbf{r}_{k+1}, \mathbf{r}_j - \mathbf{r}_{j+1}) = \frac{(\mathbf{r}_{k+1}, \mathbf{r}_j - \mathbf{r}_{j+1})}{\|\mathbf{r}_j\|^2}.\end{aligned}$$

ここで,

$$\mathbf{r}_j = \mathbf{p}_j + \sum_{i=0}^{j-1} \beta_i^{(j-1)} \mathbf{p}_i \in \text{span} \{ \mathbf{p}_0, \dots, \mathbf{p}_j \}, \quad (\mathbf{r}_{k+1}, \mathbf{p}_j) = 0 \quad (j = 0, \dots, k)$$

を用いると, $j+1 \leq k$ ($j \leq k-1$) の場合, $\beta_j^{(k)} = 0$.

$$j+1 = k+1 \quad (j = k) \text{ の場合, } \beta_j^{(k)} = -\frac{(\mathbf{r}_{k+1}, \mathbf{r}_{k+1})}{\|\mathbf{r}_k\|^2} = -\frac{\|\mathbf{r}_{k+1}\|^2}{\|\mathbf{r}_k\|^2}. \quad \blacksquare$$

2. 理論：共役勾配法

共役勾配法のアルゴリズム

初期解 \mathbf{x}_0 を適当に定める； $\mathbf{r}_0 = \mathbf{b} - A\mathbf{x}_0$ ； $\mathbf{p}_0 = \mathbf{r}_0$ ；

$k = 0, 1, 2, \dots$ に対して

$$\alpha_k = \frac{\|\mathbf{r}_k\|^2}{(\mathbf{p}_k, A\mathbf{p}_k)};$$

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{p}_k;$$

$$\mathbf{r}_{k+1} = \mathbf{r}_k - \alpha_k A\mathbf{p}_k;$$

$\|\mathbf{r}_{k+1}\| \leq \epsilon \|\mathbf{b}\|$ ならば反復を終了する；

$$\beta_k = \frac{\|\mathbf{r}_{k+1}\|^2}{\|\mathbf{r}_k\|^2};$$

$$\mathbf{p}_{k+1} = \mathbf{r}_{k+1} + \beta_k \mathbf{p}_k;$$

3. ICCG 法：共役勾配法の歴史

1. 共役勾配法のはじまり

- M. R. Hestenes & E. Stiefel:
Methods of conjugate gradients for solving linear systems,
Journal of Research of the National Bureau of Standards,
49 (1952) 409–436.
- (欠点) **丸め誤差に弱い**→長い間忘れ去られていた.

2. 1980 年代, 再び日の目を見る.

- **前処理**との併用
- **Krylov** 部分空間法としての再定式化
- 非対称行列への拡張など (Bi-CG 法, etc.)

3. ICCG 法

前処理 (preconditioning)

もとの連立 1 次方程式の代わりに同値な別の連立 1 次方程式を解いて、共役勾配法の収束を速める。

3. ICCG 法

前処理 (preconditioning)

もとの連立 1 次方程式の代わりに同値な別の連立 1 次方程式を解いて、共役勾配法の収束を速める。

$$Ax = b$$

↓

$$(C^{-1}AC^{-t})(C^t x) = C^{-1}b$$

3. ICCG 法

前処理 (preconditioning)

もとの連立 1 次方程式の代わりに同値な別の連立 1 次方程式を解いて、共役勾配法の収束を速める。

$$Ax = b$$

↓

$$(C^{-1}AC^{-t})(C^t x) = C^{-1}b$$

$$\tilde{A} = C^{-1}AC^{-t}, \quad \tilde{x} = C^t x, \quad \tilde{b} = C^{-1}b \text{ とおくと,}$$

$$\tilde{A}\tilde{x} = \tilde{b} \quad \Leftarrow \text{これに共役勾配法を適用}$$

3. ICCG 法

前処理 (preconditioning)

もとの連立 1 次方程式の代わりに同値な別の連立 1 次方程式を解いて、共役勾配法の収束を速める。

$$Ax = b$$

↓

$$(C^{-1}AC^{-t})(C^t x) = C^{-1}b$$

$$\tilde{A} = C^{-1}AC^{-t}, \quad \tilde{x} = C^t x, \quad \tilde{b} = C^{-1}b \text{ とおくと,}$$

$$\tilde{A}\tilde{x} = \tilde{b} \quad \Leftarrow \text{これに共役勾配法を適用}$$

共役勾配法が速く収束するように行列 C を選ぶ。

3. ICCG 法 : 前処理

共役勾配法 : 係数行列が単位行列に近いほど速く収束する.

3. ICCG 法 : 前処理

共役勾配法 : 係数行列が単位行列に近いほど速く収束する.

定理 A の固有値を $\lambda_1, \lambda_2, \dots, \lambda_N$ ($\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_N > 0$) とすると,

$$f(\mathbf{x}_k) - f(\mathbf{x}^*) \leq \left(\frac{\sqrt{\kappa} - 1}{\sqrt{\kappa} + 1} \right)^{2k} \cdot 4(f(\mathbf{x}_0) - f(\mathbf{x}^*))$$
$$\left(\mathbf{x}^* = A^{-1}\mathbf{b}, \quad \kappa = \frac{\lambda_1}{\lambda_N} \quad (\text{条件数}). \right)$$

□

3. ICCG 法 : 前処理

共役勾配法 : 係数行列が単位行列に近いほど速く収束する.

定理 A の固有値を $\lambda_1, \lambda_2, \dots, \lambda_N$ ($\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_N > 0$) とすると,

$$f(\mathbf{x}_k) - f(\mathbf{x}^*) \leq \left(\frac{\sqrt{\kappa} - 1}{\sqrt{\kappa} + 1} \right)^{2k} \cdot 4(f(\mathbf{x}_0) - f(\mathbf{x}^*))$$
$$\left(\mathbf{x}^* = A^{-1}\mathbf{b}, \quad \kappa = \frac{\lambda_1}{\lambda_N} \quad (\text{条件数}). \right)$$

□

$\kappa \simeq 1$ である (A が単位行列に近い) ほど速く収束する.

3. ICCG 法 : 前処理

共役勾配法 : 係数行列が単位行列に近いほど速く収束する.

定理 A の固有値を $\lambda_1, \lambda_2, \dots, \lambda_N$ ($\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_N > 0$) とすると,

$$f(\mathbf{x}_k) - f(\mathbf{x}^*) \leq \left(\frac{\sqrt{\kappa} - 1}{\sqrt{\kappa} + 1} \right)^{2k} \cdot 4(f(\mathbf{x}_0) - f(\mathbf{x}^*))$$
$$\left(\mathbf{x}^* = A^{-1}\mathbf{b}, \quad \kappa = \frac{\lambda_1}{\lambda_N} \quad (\text{条件数}). \right)$$

□

$\kappa \simeq 1$ である (A が単位行列に近い) ほど速く収束する.

$$\text{前処理 } C^{-1}AC^{-t}(C^t\mathbf{x}) = C^{-1}\mathbf{b}.$$

$$\Rightarrow C^{-1}AC^{-t} \simeq I \quad \text{となるように行列 } C \text{ を選ぶ.}$$

3. ICCG 法 : Cholesky 分解

よく使われる前処理 : 不完全 Cholesky 分解

対称行列 A に対する Cholesky 分解 (LU 分解)

$$A = LDL^t = \begin{bmatrix} 1 & 0 & \cdots & 0 \\ l_{21} & 1 & & \\ \vdots & & \ddots & 0 \\ l_{N1} & l_{N2} & \cdots & 1 \end{bmatrix} \begin{bmatrix} d_1 & & & \\ & d_2 & & \\ & & \ddots & \\ & & & d_N \end{bmatrix} \begin{bmatrix} 1 & l_{21} & \cdots & l_{N1} \\ 0 & 1 & & l_{N2} \\ \vdots & & \ddots & \vdots \\ 0 & \cdots & 0 & 1 \end{bmatrix}.$$

3. ICCG 法 : Cholesky 分解

よく使われる前処理 : 不完全 Cholesky 分解

対称行列 A に対する Cholesky 分解 (LU 分解)

$$A = LDL^t = \begin{bmatrix} 1 & 0 & \cdots & 0 \\ l_{21} & 1 & & \\ \vdots & & \ddots & 0 \\ l_{N1} & l_{N2} & \cdots & 1 \end{bmatrix} \begin{bmatrix} d_1 & & & \\ & d_2 & & \\ & & \ddots & \\ & & & d_N \end{bmatrix} \begin{bmatrix} 1 & l_{21} & \cdots & l_{N1} \\ 0 & 1 & & l_{N2} \\ \vdots & & \ddots & \vdots \\ 0 & \cdots & 0 & 1 \end{bmatrix}.$$

$$\Downarrow$$
$$A = (LD^{1/2})(LD^{1/2})^t \left(D^{1/2} = \begin{bmatrix} d_1^{1/2} & & \\ & \ddots & \\ & & d_N^{1/2} \end{bmatrix} \right),$$

$$\therefore (LD^{1/2})^{-1} A (LD^{1/2})^{-t} = I.$$

3. ICCG 法 : 不完全 Cholesky 分解

不完全 Cholesky 分解 (Incomplete Cholesky decomposition)

$$a_{ij} = 0 \Rightarrow l_{ij} = 0$$

となるように, Cholesky 分解を省力化して行う.

3. ICCG 法 : 不完全 Cholesky 分解

不完全 Cholesky 分解 (Incomplete Cholesky decomposition)

$$a_{ij} = 0 \Rightarrow l_{ij} = 0$$

となるように, Cholesky 分解を省力化して行う.

$$A \simeq LDL^t = (LD^{1/2})(LD^{1/2})^t$$

↓

$$(LD^{1/2})^{-1}A(LD^{1/2})^{-t} \simeq I.$$

3. ICCG 法 : 不完全 Cholesky 分解

不完全 Cholesky 分解 (Incomplete Cholesky decomposition)

$$a_{ij} = 0 \Rightarrow l_{ij} = 0$$

となるように, Cholesky 分解を省力化して行う.

$$A \simeq LDL^t = (LD^{1/2})(LD^{1/2})^t$$

⇓

$$(LD^{1/2})^{-1}A(LD^{1/2})^{-t} \simeq I.$$

$$A\mathbf{x} = \mathbf{b}$$

⇓

$$\underbrace{(LD^{1/2})^{-1}A(LD^{1/2})^{-t}}_{\text{単位行列に近い}}(LD^{1/2})^t\mathbf{x} = (LD^{1/2})^{-1}\mathbf{b}.$$

単位行列に近い

3. ICCG 法

$$\tilde{A} = (LD^{1/2})^{-1}(LD^{1/2})^{-t}, \quad \tilde{\mathbf{x}} = (LD^{1/2})^t \mathbf{x}, \quad \tilde{\mathbf{b}} = (LD^{1/2})^{-1} \mathbf{b}.$$

↓

$$\tilde{A}\tilde{\mathbf{x}} = \tilde{\mathbf{b}}, \quad \tilde{A} \text{ は正行列に近い行列.}$$

3. ICCG 法

$$\tilde{A} = (LD^{1/2})^{-1}(LD^{1/2})^{-t}, \quad \tilde{x} = (LD^{1/2})^t x, \quad \tilde{b} = (LD^{1/2})^{-1} b.$$

↓

$$\tilde{A}\tilde{x} = \tilde{b}, \quad \tilde{A} \text{ は正方向列に近い行列.}$$

$Ax = b$ の代わりに $\tilde{A}\tilde{x} = \tilde{b}$ に共役勾配法 (CG 法) を適用すれば、より速く収束すると期待される。

…**ICCG 法** = IC 分解 + CG 法

3. ICCG 法

ICCG 法のアルゴリズム

初期解 \mathbf{x}_0 を適当に定める ; $\mathbf{r}_0 = \mathbf{b} - A\mathbf{x}_0$; $\mathbf{p}_0 = (LDL^t)^{-1}\mathbf{r}_0$;

$k = 0, 1, 2, \dots$ に対して

$$\left[\begin{array}{l} \alpha_k = \frac{(\mathbf{r}_k, (LDL^t)^{-1}\mathbf{r}_k)}{(\mathbf{p}_k, A\mathbf{p}_k)}; \\ \mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k\mathbf{p}_k; \\ \mathbf{r}_{k+1} = \mathbf{r}_k - \alpha_k A\mathbf{p}_k; \\ \|\mathbf{r}_{k+1}\| \leq \epsilon\|\mathbf{b}\| \text{ ならば反復を終了する ;} \\ \beta_k = \frac{(\mathbf{r}_{k+1}, (LDL^t)^{-1}\mathbf{r}_{k+1})}{(\mathbf{r}_k, (LDL^t)^{-1}\mathbf{r}_k)}; \\ \mathbf{p}_{k+1} = (LDL^t)^{-1}\mathbf{r}_{k+1} + \beta\mathbf{p}_k; \end{array} \right.$$

3. ICCG 法

ICCG 法のアルゴリズム

初期解 \mathbf{x}_0 を適当に定める ; $\mathbf{r}_0 = \mathbf{b} - A\mathbf{x}_0$; $\mathbf{p}_0 = (LDL^t)^{-1}\mathbf{r}_0$;

$k = 0, 1, 2, \dots$ に対して

$$\left[\begin{array}{l} \alpha_k = \frac{(\mathbf{r}_k, (LDL^t)^{-1}\mathbf{r}_k)}{(\mathbf{p}_k, A\mathbf{p}_k)}; \\ \mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k\mathbf{p}_k; \\ \mathbf{r}_{k+1} = \mathbf{r}_k - \alpha_k A\mathbf{p}_k; \\ \|\mathbf{r}_{k+1}\| \leq \epsilon\|\mathbf{b}\| \text{ ならば反復を終了する ;} \\ \beta_k = \frac{(\mathbf{r}_{k+1}, (LDL^t)^{-1}\mathbf{r}_{k+1})}{(\mathbf{r}_k, (LDL^t)^{-1}\mathbf{r}_k)}; \\ \mathbf{p}_{k+1} = (LDL^t)^{-1}\mathbf{r}_{k+1} + \beta\mathbf{p}_k; \end{array} \right.$$

(注意) $\mathbf{y} = (LDL^t)^{-1}\mathbf{x}$ の計算は、次の \mathbf{y}, \mathbf{z} に対する連立方程式を解いて行う (逆行列の計算をしない) .

$$\begin{cases} L\mathbf{z} = \mathbf{x} \\ L^t\mathbf{y} = D^{-1}\mathbf{z}. \end{cases}$$

まとめ

- 連立 1 次方程式 $A\mathbf{x} = \mathbf{b}$ に対する共役勾配法
 - 2 次関数 $f(\mathbf{x}) = (1/2)(\mathbf{x}, A\mathbf{x}) - (\mathbf{b}, \mathbf{x})$ の最小化問題に反復法を適用.
 - 探索方向ベクトル… A -直交性.
 - A -直交性を満たす探索方向ベクトルを, 最急降下方向ベクトルの Gram-Schmidt 直交化によりつくる.
- ICCG 法…不完全 Cholesky 分解による前処理.
- 参考文献
 - 杉原正顯, 室田一雄:【岩波数学叢書】線形計算の数理, 岩波書店, 2009 年 (6000 円+税).