

数値計算

京都大学大学院情報学研究科
大木 健太郎

連絡先: ohki@i.kyoto-u.ac.jp

第6回

- ・ 連立一次方程式の数値解法
- ・ 非線形方程式の数値解法

本日の内容

- ❖ 連立一次方程式の数値解法(3)
 - ❖ 共役勾配法
 - ❖ Krylov部分空間法
- ❖ 非線形方程式の数値解法
 - ❖ Newton法
 - ❖ 反復法と収束
 - ❖ 反復法の誤差解析

逐次最小化法と最急降下法

$$Ax_* = b, \quad A = A^\top > 0$$

$$\text{コスト関数: } S(\xi) := \frac{1}{2} (x_* - \xi)^\top A (x_* - \xi)$$

✓ 逐次最小化法

$$x^{(k+1)} = x^{(k)} + \alpha_k p^{(k)}, \quad \alpha_k \in \mathbb{R}, \quad p^{(k)} \in \mathbb{R}^n$$

$$\text{修正の方向: } p^{(k)} \quad \text{修正の大きさ: } \alpha_k = \frac{(p^{(k)})^\top (b - Ax^{(k)})}{(p^{(k)})^\top A p^{(k)}}$$

✓ 最急降下法

逐次最小化法で、修正の方向を次のルールで選んだもの

$$p^{(k)} = -\nabla S(x^{(k)})$$

デメリット: 数値誤差, 収束速度

共役勾配法

内積と直交性（共役性）

$A = A^\top > 0 \in \mathbb{R}^{n \times n}$ が与えられているものとする.

このとき、**内積**を次で定める:

$$\langle x, y \rangle_A := x^\top A y, \quad \forall x, y \in \mathbb{R}^n$$

$\langle x, y \rangle_A = 0$ を満たすベクトルの組があるとき, x, y は A に関して互いに**直交**, あるいは互いに**共役**であるという.

(参考: 内積の数学的定義)

X : 実ベクトル空間


$\langle \bullet, \bullet \rangle : X \times X \rightarrow \mathbb{R}$ が内積であるとは, 次の条件を満たすことをいう.

(i) $\langle x, x \rangle \geq 0$ かつ $\langle x, x \rangle = 0$ は $x = 0$ のときのみ

(ii) $\langle \alpha w + \beta x, \gamma y + \delta z \rangle = \alpha\gamma \langle w, y \rangle + \alpha\delta \langle w, z \rangle + \beta\gamma \langle x, y \rangle + \beta\delta \langle x, z \rangle, \quad \forall \alpha, \beta, \gamma, \delta \in \mathbb{R}, \forall w, x, y, z \in \mathbb{R}^n$

(iii) $\langle x, y \rangle = \langle y, x \rangle, \quad \forall x, y \in \mathbb{R}^n$

共役なベクトルの例



$$A = \begin{bmatrix} 2 & 0 \\ 0 & 1 \end{bmatrix} \quad \text{等高線が楕円になる}$$

$$x = \begin{bmatrix} 1 \\ 1 \end{bmatrix} \quad \longleftrightarrow \quad y = \begin{bmatrix} 1 \\ -2 \end{bmatrix}$$

互いに直交

共役勾配法 of 概念

解きたい問題: $Ax_* = b, A = A^\top > 0$

残差ベクトル: $r^{(k)} := b - Ax^{(k)}$

ノルムの同値性より

$$\|x_* - x^{(k)}\|_2 = 0 \Leftrightarrow \|x_* - x^{(k)}\|_A = 0 \Leftrightarrow \|r^{(k)}\|_2 = 0$$

・ $x_* - x^{(k)}$: 真値が不明なので計算できない(更新の方策が立てにくい)

・ $r^{(k)} = \underbrace{b}_{=Ax_*} - Ax^{(k)}$: 計算できる  これをゼロに近づけるアルゴリズムにすればよい

共役勾配法

✓ 修正方向の決め方: Gram-Schmidt の直交化法

$$p^{(k)} = r^{(k)} + \beta_{k-1} p^{(k-1)}, \quad k = 1, 2, \dots$$

$$p^{(0)} = b - Ax^{(0)}$$

$$\beta_{k-1} = -\frac{\langle p^{(k-1)}, r^{(k)} \rangle_A}{\langle p^{(k-1)}, p^{(k-1)} \rangle_A}$$

✓ 更新

$$x^{(k+1)} = x^{(k)} + \alpha_k p^{(k)}, \quad \alpha_k \in \mathbb{R}, \quad p^{(k)} \in \mathbb{R}^n$$

$$\alpha_k = \frac{\langle p^{(k)}, r^{(k)} \rangle_I}{\langle p^{(k)}, p^{(k)} \rangle_A} \quad (\text{逐次最小化法と同じ})$$


$$r^{(k+1)} = b - Ax^{(k+1)}$$

修正の方向

- ✓ 修正方向の決め方: Gram-Schmidt の直交化法

$$\left. \begin{aligned} p^{(k)} &= r^{(k)} + \beta_{k-1} p^{(k-1)}, \quad k = 1, 2, \dots \\ p^{(0)} &= b - Ax^{(0)} \\ \beta_{k-1} &= -\frac{\langle p^{(k-1)}, r^{(k)} \rangle_A}{\langle p^{(k-1)}, p^{(k-1)} \rangle_A} \end{aligned} \right\} \langle p^{(k)}, p^{(k-1)} \rangle_A = 0$$

(イメージ: $A = I$ の場合)



修正の方向と残差ベクトルの関係

途中のステップ ($k < n$)

$$p^{(k+1)} = r^{(k+1)} + \beta_k p^{(k)}, \quad k = 1, 2, \dots$$

$$r^{(k+1)} = b - Ax^{(k+1)} = r^{(k)} - \alpha_k Ap^{(k)} = r^{(0)} - \sum_{i=0}^k \alpha_i Ap^{(i)}$$
$$\alpha_k = \frac{\langle p^{(k)}, r^{(k)} \rangle_I}{\langle p^{(k)}, p^{(k)} \rangle_A}$$

修正ベクトルの作り方と係数から,

$$\langle p^{(k+1)}, p^{(k)} \rangle_A = 0, \quad \langle r^{(k+1)}, p^{(k)} \rangle_I = \langle r^{(k)}, p^{(k)} \rangle_I - \alpha_k \langle p^{(k)}, p^{(k)} \rangle_A = 0$$



$$\begin{aligned} \langle r^{(k+1)}, r^{(k)} \rangle_I &= \langle r^{(k)}, r^{(k)} \rangle_I - \alpha_k \langle p^{(k)}, r^{(k)} \rangle_A \\ &= \langle r^{(k)} - p^{(k)}, r^{(k)} \rangle_I = -\beta_{k-1} \langle p^{(k-1)}, r^{(k)} \rangle_I = 0 \end{aligned}$$

更新した残差が直交

一般化

補題1.5

逐次最小化において, 修正の方向 $p^{(i)} \in \mathbb{R}^n, i = 0, 1, \dots, k$ が A に関して互いに直交

➡ $\langle p^{(i)}, r^{(k+1)} \rangle_I = 0, i = 0, 1, \dots, k$

補題1.6

共役勾配法で生成した修正の方向と残差ベクトルに対し,

$$\langle r^{(i)}, r^{(j)} \rangle_I = 0, \langle p^{(i)}, p^{(j)} \rangle_A = 0, i \neq j, i, j = 0, 1, \dots, k < n$$

共役勾配法の性質

補題1.6

共役勾配法で生成した修正の方向と残差ベクトルに対し、

$$\langle r^{(i)}, r^{(j)} \rangle_I = 0, \quad \langle p^{(i)}, p^{(j)} \rangle_A = 0, \quad i \neq j, \quad i, j = 0, 1, \dots, k < n$$

探索を繰り返すと、 **n ステップ目**で生成される残差ベクトルがゼロ

※ \mathbb{R}^n の直交ベクトルは、 n 本しかとれないため

$$\Rightarrow r^{(n)} = 0 \quad \Rightarrow x^{(n)} = x_* \quad \text{真値に収束}$$

実際の問題では、丸め誤差の影響があるため、 n 回以上繰り返す

$$\Rightarrow \epsilon > 0 \text{ を設定し, } \|r^{(k+1)}\| \leq \epsilon \|b\| \text{ となったら反復を終える}$$

共役勾配法の前処理

- 共役勾配法は, A が単位行列の定数倍のとき, 逐次最小化法と同じ評価が可能

$$S(x^{(k+1)}) \leq \left(\frac{\kappa_2(A) - 1}{\kappa_2(A) + 1} \right)^2 S(x^{(k)})$$

$$\kappa_2(A) = 1 \quad \rightarrow \quad 1\text{ステップで到達可能}$$

- A 行列に前処理を行い, 単位行列に近い行列にする

$$C \in \mathbb{R}^{n \times n}, \det(C) \neq 0$$

$$\underline{C^{-1}AC^{-\top}C^{\top}x = C^{-1}b} \quad \rightarrow \quad \text{早く解が求まる}$$

単位行列に近い行列にする

共役勾配法のアルゴリズムまとめ

※ 正定値対称行列 A の場合

$$p^{(0)} = r^{(0)} = b - Ax^{(0)}$$

解の更新 $x^{(k+1)} = x^{(k)} + \alpha_k p^{(k)}$

残差 $r^{(k+1)} = r^{(k)} - \alpha_k A p^{(k)} \left(= b - Ax^{(k+1)} \right)$

修正の方向 $p^{(k+1)} = r^{(k+1)} + \beta_k p^{(k)}$


$$\alpha_k = \frac{\langle r^{(k)}, r^{(k)} \rangle_I}{\langle p^{(k)}, p^{(k)} \rangle_A}, \quad \beta_k = \frac{\langle r^{(k+1)}, r^{(k+1)} \rangle_I}{\langle r^{(k)}, r^{(k)} \rangle_I}$$

修正の大きさ

修正の方向の更新

逐次最小化法の考え方


真の解がどこか分からない・・・ 写像した先で行くべき方向は分かる



逐次最小化の考え方: 最急降下法

“写像した先の残差方向”を直接用いるのが**最急降下法**

写像した先で行くべき方向は分かる



共役勾配法の考え方



写像した先の残差方向を1ステップ前の共役方向に修正して用いるのが共役勾配法

$$\beta_k; p^{(k+1)\top} A p^{(k)} = 0$$

$$p^{(k)} = r^{(k)} + \beta_{k-1} p^{(k-1)}$$

写像した先で行くべき方向は分かる

1つ前の解 $x^{(k-1)}$



本日の内容

- ❖ 連立一次方程式の数値解法(3)
 - ❖ 共役勾配法
 - ❖ Krylov部分空間法
- ❖ 非線形方程式の数値解法
 - ❖ Newton法
 - ❖ 反復法と収束
 - ❖ 反復法の誤差解析

非対称な行列Aの共役勾配法の例

- CGNR法: 正定値行列にする

$$Ax = b \Rightarrow A^T Ax = A^T b$$

【デメリット】条件数が悪くなる

- Krylov部分空間法

- Krylov部分空間を用いて残差ベクトルを処理する方法
- 固有値を求める際にも利用

Krylov部分空間

定義 (Krylov部分空間)

$u \in \mathbb{R}^n$, $A \in \mathbb{R}^{n \times n}$ が与えられており,

$u, Au, \dots, A^{k-1}u$ ($k \leq n$) が一次独立であるとき,

$$K_k(A; u) := \text{span}\{u, Au, \dots, A^{k-1}u\}$$

を A と u で生成される Krylov 部分空間という

※ A が正定値とも対称とも仮定されないことに注意

Krylov部分空間における直交基底生成法

$$u_j \in K_k(A; u), \quad j = 1, 2, \dots, k$$

□ Arnoldi過程

$$u_{k+1} = \mu_{k+1} \left\{ Au_k - \sum_{j=1}^k \frac{\langle u_j, Au_k \rangle_I}{\langle u_j, u_j \rangle_I} u_j \right\}, \quad u_1 = u$$
$$\mu_{k+1} \in \mathbb{R} \setminus \{0\}$$

□ Lanczos過程: $A = A^\top$ の場合, Arnoldi過程を整理して,

$$u_{k+1} = \mu_{k+1} \left\{ Au_k - \frac{\langle u_k, Au_k \rangle_I}{\langle u_k, u_k \rangle_I} u_k - \frac{\langle u_{k-1}, Au_k \rangle_I}{\langle u_{k-1}, u_{k-1} \rangle_I} u_{k-1} \right\}, \quad u_1 = u$$
$$\mu_{k+1} \in \mathbb{R} \setminus \{0\}$$

Krylov部分空間を利用した共役勾配法

- A が対称行列と仮定する(簡単のため)
- 残差ベクトルをLanczos過程で直交化

$$r^{(j)} \in K_k(A; r^{(0)}), \quad j = 0, 1, 2, \dots, k-1$$
$$r^{(k)} = -\alpha_{k-1} \left\{ Ar^{(k-1)} - \sum_{j=0}^{k-1} \frac{\langle r^{(j)}, Ar^{(k-1)} \rangle_I}{\langle r^{(j)}, r^{(j)} \rangle_I} r^{(j)} \right\}, \quad r_0 = b - Ax^{(0)}$$

□ 修正の方向: $p^{(k)} = r^{(k)} + \beta_{k-1}p^{(k-1)}, \quad \beta_{k-1} = \frac{\langle r^{(k)}, r^{(k)} \rangle_I}{\langle r^{(k-1)}, r^{(k-1)} \rangle_I}$

□ 修正の大きさ: $\alpha_k = \frac{\langle p^{(k)}, r^{(k)} \rangle_I}{\langle p^{(k)}, Ap^{(k)} \rangle_I}$

□ 解の更新: $x^{(k+1)} = x^{(k)} + \alpha_k p^{(k)}$

本日の内容

- ❖ 連立一次方程式の数値解法(3)
 - ❖ 共役勾配法
 - ❖ Krylov部分空間法
- ❖ 非線形方程式の数値解法
 - ❖ Newton法
 - ❖ 反復法と収束
 - ❖ 反復法の誤差解析

最適化問題と代数方程式のゼロ点

- 理学・工学や実社会において、**数理最適化**はよく用いられる。
 - (例) 適当な制約条件の下で、下の評価関数を最小化

$$S(x) = \frac{1}{2}(x - x_*)^\top A(x - x_*)$$

$$J(x) = \exp(\|x - x_*\|_2^2) - x^\top Ax$$

➡ **最適性の必要条件:** $\frac{\partial}{\partial x} S(x) = 0, \frac{\partial}{\partial x} J(x) = 0$

極値を精度よく求めることは、極めて重要

非線形方程式の数値解法


- 先ほどの極値を求める問題は,
 $f(x) = 0$ を満たす $x \in \mathbb{R}^n$ を求める問題
- 代表的な方法として, **Newton法**
 - 線形近似して解を逐次更新していく

(例) 1次元の場合

$$f(x) \simeq f(x^{(k)}) + f'(x^{(k)})(x^{(k+1)} - x^{(k)}) = 0$$
$$\Rightarrow x^{(k+1)} = x^{(k)} - \frac{f(x^{(k)})}{f'(x^{(k)})}$$

Newton法の幾何学的解釈

非線形の問題 \Rightarrow 線形の問題にして徐々に近づける



Newton法で扱える問題の例

- 平方根を求める問題: $f(x) = x^2 - a$
- n 乗根を求める問題: $f(x) = x^n - a$
- 指数を求める問題: $f(x) = \log x - a$

n 変数方程式のNewton法

- 最適化問題だと n 次元: $f : \mathbb{R}^n \rightarrow \mathbb{R}^n$

$$f(x) := \frac{\partial}{\partial x} S(x) \in \mathbb{R}^n$$

$$f(x) \simeq f(x^{(k)}) + J(x^{(k)})(x - x^{(k)}) = 0$$

$$J(x) := \left(\frac{\partial f_i(x)}{\partial x_j} \right)_{ij} = \frac{\partial^2}{\partial x \partial x^\top} S(x) \quad \det J(x) \neq 0, \quad \forall x \in \mathbb{R}^n \setminus \{x_*\}$$



$$x^{(k+1)} = x^{(k)} - J^{-1}(x^{(k)})f(x^{(k)})$$

Newton法の収束速度

- 前段の誤差の二乗に比例して小さくなる

$$x^{(k+1)} - x_* = J^{-1}(x^{(k)})O(\|x^{(k)} - x_*\|^2)$$

- J の正則性が成り立てば, 二次収束が保証されるので, 古くからよく使われている

反復法としてのNewton法

$\varphi(x) = \frac{1}{f'(x)}$ として, Newton 法は次の形で表せる

$$x^{(k+1)} = \phi(x^{(k)}), \quad \phi(x) = x - \varphi(x)f(x)$$

なぜこの形か？

$$x = \phi(x) \text{ ならば, } x = x - \underbrace{\varphi(x)f(x)}_{=0}$$

解が収束すれば, 方程式の根である

※ $\varphi(x) \neq 0$ は保証する必要がある

他の反復法による数値解法

$$x^{(k+1)} = \phi(x^{(k)}), \quad \phi(x) = x - \varphi(x)f(x)$$

- Newton 法

各ステップで線形近似 $\varphi(x) = \frac{1}{f'(x)}$

- 線形逆補間法


初期値のみでなく第一ステップの値も用いる $\varphi(x) = \frac{x - x_0}{f(x) - f(x_0)}$

- von Mises 法

初期値の傾きをずっと使う $\varphi(x) = \frac{1}{f'(x_0)}$


線形逆補間法の幾何学的解釈

$f(x_0)f(x_1) < 0$ となるペア $x_0, x_1 \in \mathbb{R}$ を見つけておく



von Mises 法の幾何学的解釈

初期値の傾きを使い続ける



本日の内容

- ❖ 連立一次方程式の数値解法(3)
 - ❖ 共役勾配法
 - ❖ Krylov部分空間法
- ❖ 非線形方程式の数値解法
 - ❖ Newton法
 - ❖ 反復法と収束
 - ❖ 反復法の誤差解析

反復法の収束

- 反復法によって生成される数列が、求めたい解に近づかなければ意味がない

$$x^{(k+1)} = \phi(x^{(k)})$$

- 収束の議論は**縮小写像の原理**

縮小写像の原理(復習)

仮定

$$\forall x, y \in \mathbb{R}^n, \|\phi(x) - \phi(y)\| \leq q\|x - y\|$$

かつ, q は $0 < q < 1$

 $x^{(k+1)} = \phi(x^{(k)})$ で更新される解は

$x = \phi(x)$ を満たす唯一解に収束

\mathbb{R}^n 全体で考えると, 多くの写像が縮小写像にならない

定義域を制限した縮小写像

- 非線形方程式の場合,
写像が縮小写像か否かは定義域にも依存する

$$x^{(k+1)} = \phi(x^{(k)}) \quad \phi(x) = x^2$$


$$x, y \in K = [0, 0.3], \quad |\phi(x) - \phi(y)| \leq q|x - y|$$

 ϕ は $K = [0, 0.3]$ 上で縮小写像

縮小写像の原理 (定理 2. 1)

仮定

- $K \subset \mathbb{R}^n$ は閉領域かつ $\phi : K \rightarrow K$
- $\forall x, y \in K \subset \mathbb{R}^n, \|\phi(x) - \phi(y)\| \leq q\|x - y\|$
かつ, q は $0 < q < 1$



$$x^{(k+1)} = \phi(x^{(k)}), \quad x^{(0)} \in K$$

で更新される解は

$x = \phi(x)$ を満たす唯一解に収束

本日の内容

- ❖ 連立一次方程式の数値解法(3)
 - ❖ 共役勾配法
 - ❖ Krylov部分空間法
- ❖ 非線形方程式の数値解法
 - ❖ Newton法
 - ❖ 反復法と収束
 - ❖ 反復法の誤差解析

反復法の誤差解析

丸め誤差なし $x^{(k+1)} = \phi(x^{(k)})$

丸め誤差あり $y^{(k+1)} = \phi(y^{(k)}) + \epsilon^{(k)}$

丸め誤差

仮定 $\|\epsilon^{(k)}\| \leq \epsilon, k = 1, 2, \dots$

 $\|y^{(N)} - x_*\| \leq \frac{1}{1-q} \left\{ q^N \|\phi(x^{(0)}) - x^{(0)}\| + \epsilon \right\}$

教科書の評価

これは分からない……

反復法の誤差解析: 修正版

$$y^{(1)} - x^{(0)} = \phi(x^{(0)}) - x^{(0)} + \epsilon^{(0)}$$
$$\Rightarrow y^{(1)} - x^{(0)} - \epsilon^{(0)} = \phi(x^{(0)}) - x^{(0)}$$


$$\|\phi(x^{(0)}) - x^{(0)}\| \leq \|y^{(1)} - x^{(0)}\| + \epsilon$$

$$\|y^{(N)} - x_*\| \leq \frac{1}{1-q} \left\{ q^N \left(\|y^{(1)} - x^{(0)}\| + \epsilon \right) + \epsilon \right\}$$

初期値, 事前情報(丸め誤差の大きさ), 第一ステップの値のみで評価可能

初期値の選択

- 反復法の収束は，適切な初期値の選択が重要

$$T_1 = \{y \mid \|y - x^{(0)}\| \leq \rho\}$$

仮定 $\|\phi(x^{(0)}) - x^{(0)}\| + \epsilon \leq (1 - q)\rho$

丸め誤差の大きさ

$q^N \leq 1$ より，

 $\|y^{(N)} - x_*\| \leq \frac{1}{1 - q} \left\{ \|\phi(x^{(0)}) - x^{(0)}\| + \epsilon \right\} \leq \rho$

初期値の選択: 修正版

$$T_1 = \{y \mid \|y - x^{(0)}\| \leq \rho\}$$

仮定 $\|y^{(1)} - x^{(0)}\| + 2\epsilon \leq (1 - q)\rho$

 $\|y^{(N)} - x_*\| \leq \frac{1}{1 - q} \left\{ \|y^{(1)} - x^{(0)}\| + 2\epsilon \right\} \leq \rho$

よって, $y^{(N)} \in T_1, N = 1, 2, \dots$

初期値を十分に真値に近くとる工夫が大事

次回の講義予定

- 代数方程式の数値解法