

2005年5月18日(水)

数值解析講義 前期水曜3限
3年(2005)

青柳 睦

aoyagi@cc.kyushu-u.ac.jp

研究室:情報基盤センター5階502

講義内容

{括弧}の項目はSkipまたは参考程度

1. 超越方程式(非線形方程式)の解法

1.1 2分法 → 演習

1.2 {補間法}

1.3 ニュートン法 → 演習

2. 代数方程式の解法

2.1 グラフエの方法 → (~~演習~~)

2.2 {ベルヌーイの方法}

3. 連立一次方程式の解法

3.1 行列計算 → 演習

3.2 ガウスの消去法 → 演習

3.3 3重対角行列の場合の解法

3.4 LU分解法 → 演習

講義vs演習スケジュールに
余裕がある日を見つけて、
「数値解析」を必要とする
理学工学(社会学?)分野で
活用されている計算科学の
概論を紹介します(予定).

- 3. 5 {特異値分解法}
- 3. 6 共役勾配法
- 3. 7 反復法
- 4. 固有値と固有ベクトルの近似計算
 - 4. 1 レバリエールの方法
 - 4. 2 3重対角行列の固有値と固有ベクトルの計算
 - 4. 3 ランチョスの方法(3重対角行列への帰着)
 - 4. 4 ギブンスの方法(対称な3重対角行列への帰着)
 - 4. 5 ヤコビの方法(対角行列への帰着)
- 5. ラグランジュの未定乗数法
- 6. 勾配法
 - 6. 1 最急降下法
 - 6. 2 最急降下加速法
 - 6. 3 ステップ幅の決め方

4章「固有値・・・」以降は、
講義と演習の進捗状況によっ
ては項目を絞った内容にする
可能性があります・・・

成績評価, その他

- 出席点5割 + 前期末試験5割
- 講義ノートは, 毎回配りますが
もし欠席したら各自でDLしてください
server-500.cc.kyushu-u.ac.jp
(講義ノートはその週の金曜日17時までには公開)
- 次回から座席指定をお願いします
30分後には座席表から出欠を取ります
- 研究室の電話は 092-642-3838
- メールは, aoyagi@cc.kyushu-u.ac.jp
Subjectには, 「数値解析」と記入
してください

3. 4 LU 分解法 (先週の復習)

$$Ax = b$$

$$A = \begin{pmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ & & \cdots & \\ a_{n1} & a_{n2} & \cdots & a_{nn} \end{pmatrix}$$

$$b = {}^t(b_1, b_2, \dots, b_n)$$

$$A = LU$$

L : 下半三角行列

U : 上半三角行列

$$L = \begin{pmatrix} \alpha_{11} & 0 & \cdots & 0 \\ \alpha_{21} & \alpha_{22} & \cdots & 0 \\ & \cdots & & \\ \alpha_{n1} & \alpha_{n2} & \cdots & \alpha_{nn} \end{pmatrix}, \quad U = \begin{pmatrix} \beta_{11} & \beta_{12} & \cdots & \beta_{1n} \\ 0 & \beta_{22} & \cdots & \beta_{2n} \\ & \cdots & & \\ 0 & \cdots & & \beta_{nn} \end{pmatrix},$$

3行3列の場合を例に・・・($\alpha_{11}=1$) 未知要素が決まる順番, 緑→青→赤→水色→黄色

$$A = LU = \begin{pmatrix} \alpha_{11} & 0 & 0 \\ \alpha_{21} & \alpha_{22} & 0 \\ \alpha_{31} & \alpha_{32} & \alpha_{33} \end{pmatrix} \cdot \begin{pmatrix} \beta_{11} & \beta_{12} & \beta_{13} \\ 0 & \beta_{22} & \beta_{23} \\ 0 & 0 & \beta_{33} \end{pmatrix}$$

$(i < j)$

$$\alpha_{11}\beta_{12} = a_{12}$$

$$\alpha_{11}\beta_{13} = a_{13}$$

$$\alpha_{21}\beta_{13} + \alpha_{22}\beta_{23} = a_{23}$$

$(i = j)$

$$\alpha_{11}\beta_{11} = a_{11}$$

$$\alpha_{31}\beta_{13} + \alpha_{32}\beta_{23} + \alpha_{33}\beta_{33} = a_{33}$$

$$\alpha_{21}\beta_{12} + \alpha_{22}\beta_{22} = a_{22}$$

$(i > j)$

$$\alpha_{21}\beta_{11} = a_{21}$$

$$\alpha_{31}\beta_{11} = a_{31}$$

$$\alpha_{31}\beta_{12} + \alpha_{32}\beta_{22} = a_{32}$$

$$A = LU = \begin{pmatrix} \alpha_{11} & & & & & 0 \\ \alpha_{21} & \alpha_{22} & & & \cdots & 0 \\ \alpha_{31} & \alpha_{32} & \alpha_{33} & & & 0 \\ \alpha_{41} & \alpha_{42} & \alpha_{43} & \alpha_{44} & & 0 \\ \vdots & \vdots & & & \ddots & \vdots \\ \alpha_{n1} & \alpha_{n2} & \alpha_{n3} & \alpha_{n4} & \cdots & \alpha_{nn} \end{pmatrix} \begin{pmatrix} \beta_{11} & \beta_{12} & \beta_{13} & \beta_{14} & \cdots & \beta_{1n} \\ & \beta_{22} & \beta_{23} & \beta_{24} & \cdots & \beta_{2n} \\ & & \beta_{33} & \beta_{34} & & \beta_{3n} \\ & & & \beta_{44} & & \beta_{4n} \\ & & & & \ddots & \vdots \\ 0 & 0 & 0 & 0 & \cdots & \beta_{nn} \end{pmatrix},$$

$$i < j \quad \alpha_{21}\beta_{14} + \alpha_{22}\beta_{24} = a_{24} \quad \Rightarrow \beta_{24}$$

$$i = j \quad \alpha_{31}\beta_{13} + \alpha_{32}\beta_{23} + \alpha_{33}\beta_{33} = a_{33} \quad \Rightarrow \beta_{33}$$

$$i > j \quad \alpha_{41}\beta_{12} + \alpha_{42}\beta_{22} = a_{42} \quad \Rightarrow \alpha_{42}$$

$i < j$ のとき、

$$\alpha_{i1}\beta_{1j} + \alpha_{i2}\beta_{2j} + \dots + \alpha_{ii}\beta_{ij} = a_{ij}$$

$i = j$ のとき、

$$\alpha_{i1}\beta_{1i} + \alpha_{i2}\beta_{2i} + \dots + \alpha_{ii}\beta_{ii} = a_{ii}$$

$i > j$ のとき、

$$\alpha_{i1}\beta_{1j} + \alpha_{i2}\beta_{2j} + \dots + \alpha_{ij}\beta_{jj} = a_{ij}$$

β_{ij} と α_{ij} を計算するアルゴリズム

(i) $\alpha_{ii} \equiv 1, \quad i = 1, 2, \dots, n$

(ii) $j = 1, 2, \dots, n$ のそれぞれに対して、

$$\beta_{ij} = a_{ij} - \sum_{k=1}^{i-1} \alpha_{ik} \beta_{kj}, \quad i = 1, 2, \dots, j$$

$$\alpha_{ij} = \frac{1}{\beta_{jj}} \left(a_{ij} - \sum_{k=1}^{j-1} \alpha_{ik} \beta_{kj} \right), \quad i = j+1, j+2, \dots, n$$

β_{ij} と α_{ij} の計算でのポイント

- (a) α_{ij} を求めるには $a_{ij}, \alpha_{ik} (k < i), \beta_{kj} (k = 1, \dots, j)$ が必要
- (b) β_{ij} を求めるには $a_{ij}, \beta_{kj} (k < j), \alpha_{ik} (k = 1, \dots, i)$ が必要
- (c) a_{ij} は α_{ij} または β_{ij} の計算以外では参照されない
- (d) $\alpha_{ii} = 1 (i = 1, 2, \dots, n)$ は配列に入れる必要なし

LU分解による解法手順

(1) α_{ij}, β_{ij} を求め配列 A を置き換える (LU 分解)

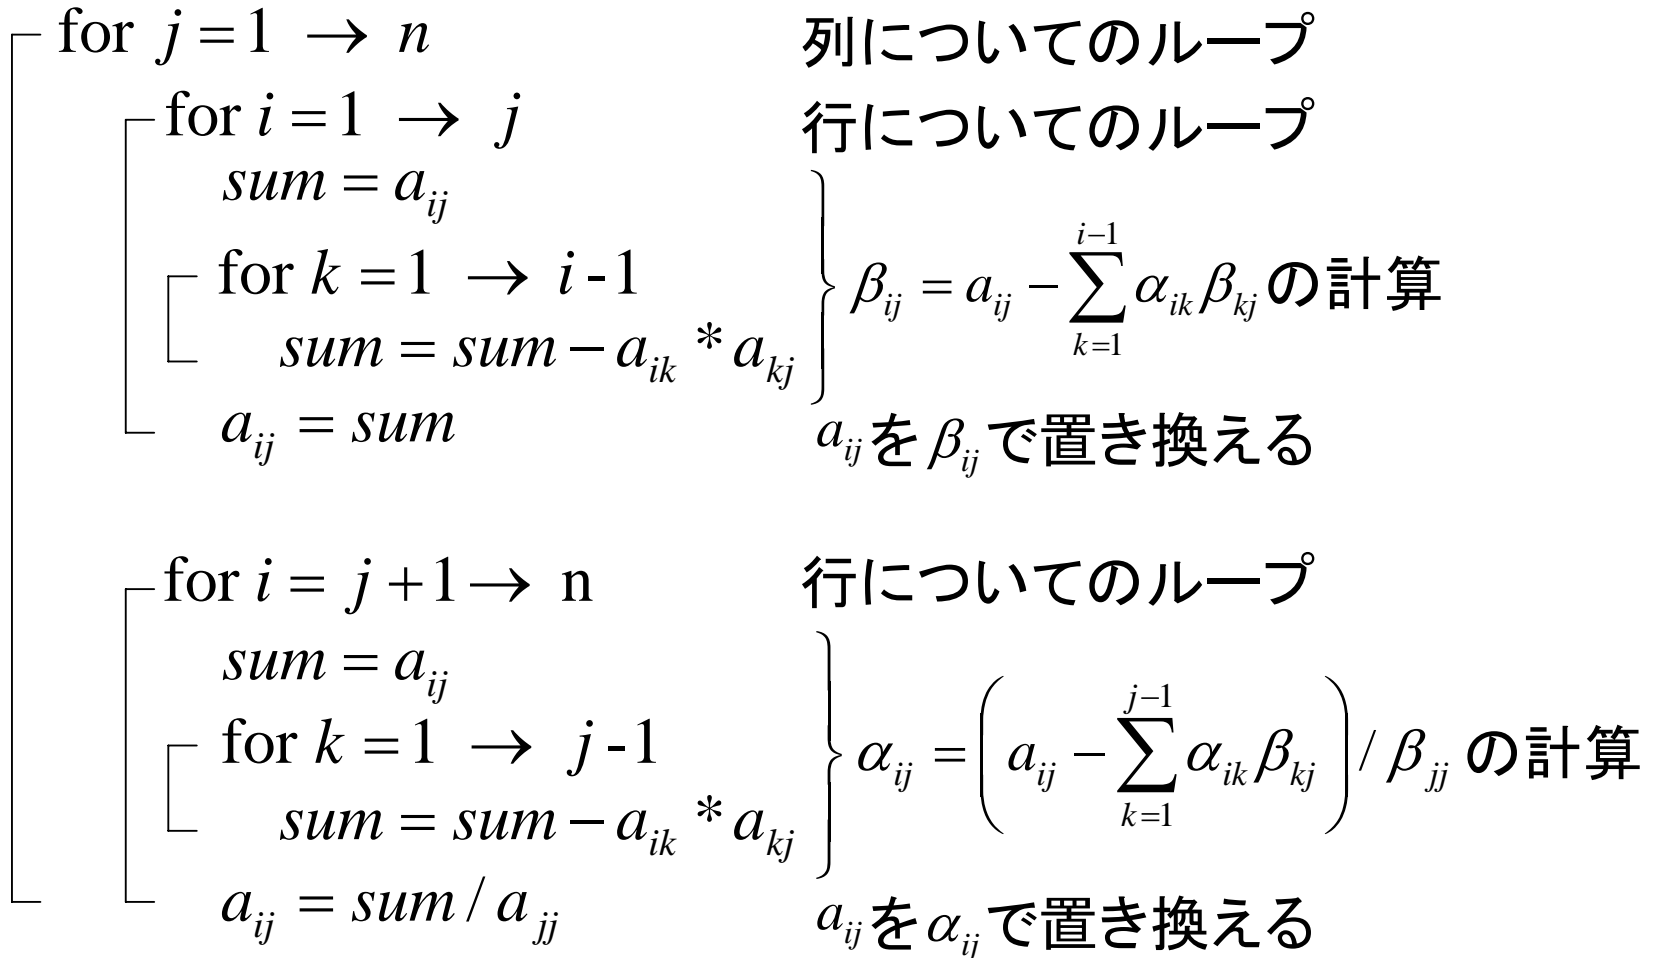
(2) $Ly = b$ から y を求める (前進代入)

$$y_1 = \frac{b_1}{\alpha_{11}}, \quad y_i = \frac{1}{\alpha_{ii}} \left(b_i - \sum_{j=1}^{i-1} \alpha_{ij} y_j \right), \quad i = 2, 3, \dots, n$$

(3) $Ux = y$ から x を求める (後進代入)

$$x_n = \frac{y_n}{\beta_{nn}}, \quad x_i = \frac{1}{\beta_{ii}} \left(y_i - \sum_{j=i+1}^n \beta_{ij} x_j \right), \quad i = n-1, n-2, \dots, 1$$

LU分解のプログラム



3.5 特異値分解法(参考まで)

まず一般理論は・・・

$A : m \times n (m \geq n)$ 行列

$U : m \times n$ 直交行列

$D : n \times n$ 対角行列

$V : n \times n$ 直交行列

$A = UD^tV$ と分解する。

$$U = (u_1 \ u_2 \ \cdots \ u_n),$$

$$u_j = {}^t (u_{1j}, u_{2j}, \dots, u_{mj})$$

$u_j, j = 1, 2, \dots, n$: 正規直交ベクトル

すなわち、 $(u_j, u_k) = \delta_{jk}$

$$D = \begin{pmatrix} d_1 & & & 0 \\ & d_2 & & \\ & & \cdot & \\ & & & \cdot \\ 0 & & & & d_n \end{pmatrix}$$

対角行列

(Wと記述することもある…)

$$V = (v_1 \ v_2 \ \cdots \ v_n),$$

$$v_j = {}^t (v_{1j}, v_{2j}, \dots, v_{nj})$$

$v_j, j = 1, 2, \dots, n :$ 正規直交ベクトル

すなわち、 $(v_j, v_k) = \delta_{jk}$

$${}^t U U = {}^t V V = I$$

特異値分解の一般論の補足(参考)

$A : m \times n$ ($m \geq n$) 行列
に対して

$B = {}^tAA : n \times n$ 対称行列
を考える。

$B = {}^tAA$ から任意の x に対して

$${}^t x B x = {}^t x {}^t A A x = \|Ax\|^2 \geq 0$$

であるがここでは簡単のため $x \neq 0$ に対して

${}^t x B x > 0$ 正定値
とする。

正定値2次
形式

対称行列に対する線形代数「固有値と固有ベクトル」
の考察から 次のi)、ii)が成り立つ (4章)

i) n 個のでない0でない(実の)固有ベクトル

$$v_i = {}^t (v_{1i}, \dots, v_{ni}) \quad (i = 1, \dots, n)$$

とその固有値 λ_i (実数)が存在して

$$Bv_i = \lambda_i v_i$$

ii) v_i は正規直交となるように選べる。すなわち

$${}^t v_i v_j = \delta_{ij}$$

ここで

$$V = (v_1, v_2, \dots, v_n) : n \times n \text{ 行列}$$

とすると

$${}^t VV = I : \text{直交行列}$$

B の正定値性を仮定したので

$$\lambda_i = \lambda_i {}^t v_i v_i = {}^t v_i B v_i > 0$$

となる。

そこで $w_i = \sqrt{\lambda_i}$ と書くことにし、 m 次元ベクトル

$$u_i = {}^t (u_{1i}, \dots, u_{mi})$$

を

$$A v_i = w_i u_i$$

で定義する。このとき

$${}^t A u_i = ({}^t A A v_i) / w_i = (\lambda_i v_i) / w_i = w_i v_i$$

$$A {}^t A u_i = w_i A v_i = w_i^2 u_i = \lambda_i u_i$$

だから u_i は $A {}^t A$ の固有ベクトルとなる

また、

$$\begin{aligned} {}^t u_i u_j &= ({}^t v_i {}^t A A v_j) / (w_i w_j) = (\lambda_j {}^t v_i v_j) / (w_i w_j) \\ &= (\lambda_j \delta_{ij}) / (w_i w_j) = \delta_{ij} \end{aligned}$$

だから u_i も正規直交ベクトルとなる

ここで

$$U = (u_1, u_2, \dots, u_n) : m \times n \text{ 行列}$$

とすると

$${}^t U U = I$$

次に、これらを用いると

$$A = \sum_{i=1}^n w_i u_i {}^t v_i = U W {}^t V$$

となることを示す。

n 個の n 次元ベクトル v_j ($j = 1, \dots, n$) は直交するから
任意の n 次元ベクトル x は v_j によって

$$x = \sum_{j=1}^n \xi_j v_j \quad (\xi_j = {}^t v_j x)$$

と展開できる。ここで

$$\begin{aligned}
\left(A - \sum_{i=1}^n w_i u_i^t v_i \right) x &= A \left(\sum_{j=1}^n \xi_j v_j \right) - \left(\sum_{i=1}^n w_i u_i^t v_i \right) \left(\sum_{j=1}^n \xi_j v_j \right) \\
&= \sum_{j=1}^n \xi_j A v_j - \sum_{i=1}^n \sum_{j=1}^n \xi_j w_i u_i^t v_i v_j \\
&= \sum_{j=1}^n \xi_j w_j u_j - \sum_{i=1}^n \sum_{j=1}^n \xi_j w_i u_i \delta_{ij} \\
&= 0
\end{aligned}$$

となる。ここで x は任意だから

$$A - \sum_{i=1}^n w_i u_i^t v_i = 0 \quad \therefore A = \sum_{i=1}^n w_i u_i^t v_i$$

行列を用いて書くと

$$A = \sum_{i=1}^n w_i u_i^t v_i$$

$$= \begin{matrix} \overbrace{\left(\begin{array}{ccc} u_{11} & \cdots & u_{1n} \\ u_{21} & \cdots & u_{2n} \\ \vdots & & \vdots \\ u_{m1} & \cdots & u_{mn} \end{array} \right)}^{m \times n} & \overbrace{\left(\begin{array}{ccc} w_1 & \cdots & 0 \\ & w_2 & \\ \vdots & \ddots & \vdots \\ 0 & \cdots & w_n \end{array} \right)}^{n \times n} & \overbrace{\left(\begin{array}{ccc} v_{11} & v_{21} & \cdots & v_{n1} \\ v_{12} & v_{22} & \cdots & v_{n2} \\ \vdots & \vdots & \ddots & \vdots \\ v_{1n} & v_{2n} & \cdots & v_{nn} \end{array} \right)}^{n \times n} \end{matrix}$$
$$= UW^tV$$

これらの表現を行列 A の特異値分解、 w_i を特異値という。

$m = n$ かつ A が対称行列の場合、

LU分解法との関係を考える

$$D = \begin{pmatrix} a_{11}^{(1)} & & & & \\ & a_{22}^{(2)} & & & \\ & & a_{33}^{(3)} & & \\ & & & \ddots & \\ & & & & a_{nn}^{(n)} \end{pmatrix} \quad \text{とおくと}\cdots$$

LU分解法における
上三角行列:

$$\begin{pmatrix} a_{11}^{(1)} & a_{12}^{(1)} & a_{13}^{(1)} & \cdots & a_{1n}^{(1)} \\ & a_{22}^{(2)} & a_{23}^{(2)} & \cdots & a_{2n}^{(2)} \\ & & a_{33}^{(3)} & \cdots & a_{3n}^{(3)} \\ & & & \ddots & \vdots \\ & & & & a_{nn}^{(n)} \end{pmatrix}$$

は...

$$V = \begin{pmatrix} 1 & v_{12} & v_{13} & \cdots & v_{1n} \\ & 1 & v_{23} & \cdots & v_{2n} \\ & & 1 & \cdots & v_{3n} \\ 0 & & & \ddots & \vdots \\ & & & & 1 \end{pmatrix} \quad v_{kj} = \frac{a_{kj}^{(k)}}{a_{kk}^{(k)}}, (k < j)$$

ここでAが**対称** ${}^t A = A$

かつ、**正則**な場合を考える。

$AX = XA = E$ (単位行列) を満たす行列Xが存在する時、Aを正則行列という。

正則な対称行列においては、Gaussの消去法でkステップ目に表れる、(いまだ消去されていない)k行以下の部分行列に関する「対称性」が保たれている。

(証明)

第kステップまで消去された状態で、いまだ消去されていないk行以下の部分に着目する...

$$\begin{pmatrix}
 a_{11}^{(1)} & a_{12}^{(1)} & \cdots & \cdots & \cdots & \cdots & a_{1n}^{(1)} \\
 & a_{22}^{(2)} & \cdots & \cdots & \cdots & \cdots & a_{2n}^{(2)} \\
 & & \ddots & & & & \\
 & & & \begin{array}{cccc}
 a_{kk}^{(k)} & a_{k,k+1}^{(k)} & \cdots & a_{k,n}^{(k)} \\
 a_{k+1,k}^{(k)} & a_{k+1,k+1}^{(k)} & \cdots & a_{k+1,n}^{(k)} \\
 \vdots & \vdots & \ddots & \vdots \\
 a_{nk}^{(k)} & a_{n,k+1}^{(k)} & \cdots & a_{nn}^{(k)}
 \end{array} & & & \\
 & 0 & & & & &
 \end{pmatrix}$$

$$A^{(k)} = \begin{pmatrix} a_{kk}^{(k)} & a_{k,k+1}^{(k)} & \cdots & a_{k,n}^{(k)} \\ a_{k+1,k}^{(k)} & a_{k+1,k+1}^{(k)} & \cdots & a_{k+1,n}^{(k)} \\ \vdots & \vdots & \ddots & \vdots \\ a_{nk}^{(k)} & a_{n,k+1}^{(k)} & \cdots & a_{nn}^{(k)} \end{pmatrix}$$

$$a_{ij}^{(k)} = a_{ij}^{(k-1)} - \frac{a_{i,k-1}^{(k-1)}}{a_{k-1,k-1}^{(k-1)}} a_{k-1,j}^{(k-1)} \text{ である、}$$

ここで $a_{ij}^{(k)} = a_{ji}^{(k)}$ を仮定すると、

$$a_{ji}^{(k+1)} = a_{ji}^{(k)} - \frac{a_{j,k}^{(k)}}{a_{k,k}^{(k)}} a_{k,i}^{(k)} = a_{ij}^{(k)} - \frac{a_{k,i}^{(k)}}{a_{k,k}^{(k)}} a_{j,k}^{(k)} = a_{ij}^{(k+1)}$$

よって、 $a_{ij}^{(k)} = a_{ji}^{(k)}$ ならば $a_{ij}^{(k+1)} = a_{ji}^{(k+1)}$ が成り立つ。

一方 $A^{(1)} (= A)$ は対称行列、 $a_{ij}^{(1)} = a_{ji}^{(1)}$ であるから

すべてのステップ (k) で対称性は保存される。

以上より、Aが対称行列のとき、LU分解法における上三角行列を対角行列Dで割ったV行列の各要素は・・

$$v_{kj} = \frac{a_{kj}^{(k)}}{a_{kk}^{(k)}} = \frac{a_{jk}^{(k)}}{a_{kk}^{(k)}} = m_{jk} \text{となる、したがって} \cdot \cdot$$

$$V = {}^t L$$

$$A = LD {}^t L$$

Aが対称で正則な場合の、**特異値分解**となる

m_{jk} : 前節「(補足) Gaussの前進消去プロセスとLU分解の関係」を参照のこと。

3. 6 共役勾配法

仮定1 $A = {}^t A$ 対称行列

仮定2 ${}^t xAx > 0, x \neq 0$ 正定値行列

$$Ax = b$$

もし、 A が仮定を満たさなければ

$${}^t A Ax = {}^t A b$$

を考えればよい。

$Ax = b$ の解 ξ は次の最小化問題の解である:

$$F(\xi) = \min_x F(x), \quad F(x) = \frac{1}{2} {}^t xAx - {}^t xb$$

証明。 $x = \xi + \varepsilon$ とおくと、

$$\begin{aligned} F(x) &= F(\xi + \varepsilon) \\ &= \frac{1}{2} ({}^t \xi A \xi + {}^t \xi A \varepsilon + {}^t \varepsilon A \xi + {}^t \varepsilon A \varepsilon) - {}^t \xi b - {}^t \varepsilon b \\ &= F(\xi) + {}^t \varepsilon A \varepsilon / 2 \geq F(\xi) \end{aligned}$$

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

を $F(x)$ に代入すると、

$$F(x^{(k+1)}) = \frac{1}{2} {}^t U_k A U_k \lambda_k^2 - {}^t U_k R_k \lambda_k + F(x^{(k)})$$

ただし、 R_k は次で与えられる。

$$R_k = b - Ax^{(k)}$$

$F(x^{(k+1)})$ を最小にする λ_k は

$$\lambda_k = \frac{{}^tU_k R_k}{{}^tU_k A U_k} \quad \text{によって与えられる。}$$

ここで、次式が成り立つ。

$${}^tU_{k-1} R_k = 0 \quad \dots \textcircled{1}$$

【証明】

$$\begin{aligned} {}^tU_{k-1} R_k &= {}^tU_{k-1} (b - Ax^{(k)}) = {}^tU_{k-1} b - {}^tU_{k-1} Ax^{(k)} \\ &= {}^tU_{k-1} b - {}^tU_{k-1} A(x^{(k-1)} + \lambda_{k-1} U_{k-1}) \\ &= {}^tU_{k-1} (b - Ax^{(k-1)}) - \lambda_{k-1} {}^tU_{k-1} A U_{k-1} \\ &= {}^tU_{k-1} R_{k-1} - \lambda_{k-1} {}^tU_{k-1} A U_{k-1} \quad \lambda_{k-1} \text{ の定義より} \\ &= 0 \end{aligned}$$

適当な $x^{(0)}$ から出発し、順次修正を加える

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

↑ 大きさ
↓ 方向

$x^{(0)}, x^{(1)}, x^{(2)} \dots$ が $F(x)$ の最小値を与える解 ξ に収束

U_k が決まれば $F(x^{(k)} + \lambda_k U_k)$ を最小にする λ_k は

$$\frac{d}{d\lambda} [F(x^{(k)} + \lambda_k U_k)] = 0 \quad \text{から} \quad \lambda_k = \frac{{}^t U_k R_k}{{}^t U_k A U_k}$$

U_k として何が適当か？ 明確な回答はないが...

ひとつの(もっともらしい)方法

$$U_k = R_k = b - Ax^{(k)} \text{ (残差) とする}$$


R_k : 勾配の逆方向 ($F(x)$ が最も減少する方向)

$$R_k = b - Ax^{(k)} = \begin{pmatrix} -\frac{\partial}{\partial x_1^{(k)}} F(x^{(k)}) \\ \vdots \\ -\frac{\partial}{\partial x_N^{(k)}} F(x^{(k)}) \end{pmatrix} = -\nabla F(x^{(k)})$$

2次元の問題で $U_k = R_k$ とした場合 (最急降下法)

$F(x)$ の等高線

減少方向



実際には...

$x^{(0)}$ によっては収束が遅い → あまり得策ではない

$U_k = R_k$ を少し変更して

$U_k = R_k + \mu_k U_{k-1}$ とする

μ_k を共役関係 ${}^t U_{k-1} A U_k = 0$ から指定すると,

$$\mu_k = \frac{{}^t R_k R_k}{{}^t R_{k-1} R_{k-1}} \quad \text{となる(ことを後で示す)}$$

このように U_k を順次, 改良してゆくスキームを
共役勾配法と呼ぶ.

まず後で使う式・・ $R_{k+1} = R_k - \lambda_k AU_k$ を示す.

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

両辺にAを掛けて、bから引くと

$$R_k = b - Ax^{(k)} \quad \text{より} \cdot \cdot$$

$$R_{k+1} = R_k - \lambda_k AU_k \quad \dots \textcircled{2}$$

U_k を次の反復式で決める。

$$U_k = R_k + \mu_k U_{k-1}$$

μ_k を決めるために、**共役関係**

$${}^t U_{k-1} A U_k = 0$$

を課す。この関係より、

$$0 = -{}^t U_{k-1} \lambda_{k-1} A U_k$$

$$= -{}^t (A \lambda_{k-1} U_{k-1}) U_k$$

②により

$$= {}^t (R_k - R_{k-1})(R_k + \mu_k U_{k-1})$$

これより、

$$\mu_k = \frac{{}^t(R_k - R_{k-1})R_k}{{}^tR_{k-1}U_{k-1}} \quad (\because \textcircled{1} \text{より } {}^tR_k U_{k-1} = 0)$$

ここで、次の二つのことを示す。

$${}^tR_{k-1}U_{k-1} = {}^tR_{k-1}R_{k-1},$$

$${}^tR_{k-1}R_k = 0$$

まず

$$\begin{aligned} {}^tR_{k-1}U_{k-1} &= {}^tR_{k-1}(R_{k-1} + \mu_{k-1}U_{k-2}) \\ &= {}^tR_{k-1}R_{k-1} \end{aligned}$$

$$\begin{aligned}
{}^t R_{k-1} R_k &= {}^t (U_{k-1} - \mu_{k-1} U_{k-2}) R_k \\
&= -\mu_{k-1} {}^t U_{k-2} R_k \quad \text{②より} \\
&= -\mu_{k-1} {}^t U_{k-2} (R_{k-1} - \lambda_{k-1} A U_{k-1}) \\
&= 0 \quad \text{第1項は①より,}
\end{aligned}$$

2項目は共役条件よりゼロ

これより、

$$\mu_k = \frac{{}^t R_k R_k}{{}^t R_{k-1} R_{k-1}}$$

アルゴリズムをまとめると、

適当な初期ベクトル $x^{(0)}$ を選び
 $R_0 = b - Ax^{(0)}$, $U_0 = R_0$ とする

例えば
 $x^{(0)} = 0$,
 $U_0 = R_0 = b$

$$\lambda_k = \frac{{}^t U_k R_k}{{}^t U_k A U_k}$$

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

$$R^{(k+1)} = R^{(k)} - \lambda_k A U_k$$

$\|R^{(k+1)}\| \leq \varepsilon \|b\|$ ならば終了

$$\mu_k = \frac{{}^t R_k R_k}{{}^t R_{k-1} R_{k-1}}$$

$$U_k = R_k + \mu_k U_{k-1}$$

$k = 0, 1, 2, \dots$

について繰り返す

ε : 解の精度に応じて
適当に定める

次式が成り立つ ${}^tU_iAU_k = 0 \quad (i = 0, 1, \dots, k-2, k-1)$

全ての U_k は線形独立

更に次式が成り立つ ${}^tR_iR_j = 0 \quad (i \neq j)$

R_0, R_1, R_2, \dots は互いに直交

$R_j = {}^t(R_{1j}, R_{2j}, \dots, R_{Nj}) : N$ 次元ベクトル

直交するベクトルは N 個以下


$R_N = b - Ax^{(N)} = 0 \longrightarrow N$ 回以下の反復で解に収束

しかし、現実の計算ではまるめ誤差により N 回以上の反復となる場合が多い

$$U_k = R_k + \mu_k U_{k-1} \text{ とした場合 (共役勾配法)}$$

$F(x)$ の等高線

減少方向



(2次元では)2回の反復で解に辿り着く