


GAUSS-JORDAN X DECOMPOSIÇÃO LU



PARTES 1

$$\sum_{k=1}^{n-1} \sum_{i=k+1}^n \left(1 + \sum_{j=k+1}^{m+1} 1 \right)$$

$$= \frac{1}{3} n^3 + \frac{1}{2} n^2 - \frac{1}{6} n$$

PARTES 2

para é preciso fazer em b!

$$\sum_{k=1}^{n-1} 2k = 2 \left(\frac{1}{2} n^2 - \frac{1}{2} n \right) = n^2 - n$$

DIVISÃO

colunas (da última até a segunda)

$$\text{TOTAL: } \frac{1}{3} n^3 + \frac{1}{2} n^2 - \frac{5}{6} n$$

$$+ 2 \left(\frac{1}{2} n^2 - \frac{1}{2} n \right) + n$$

$$= \frac{1}{3} n^3 + n^2 - \frac{1}{3} n$$

$$= \frac{1}{3} n^3 + \frac{2}{2} n^2 - \frac{5}{6} n$$

$A = LU \left(\frac{1}{3} n^3 - \frac{1}{3} n \right)$

$Lx = y = b \quad \frac{n^2 - n}{2}$
 $Ux = y \quad \frac{n^2 + n}{2}$

TOTAL: $\frac{1}{3} n^3$
 $-\frac{1}{3} n$
 $+ n^2$

$\left(\frac{1}{3} n^3 + n^2 - \frac{1}{3} n \right)$

$L y = b$

$y(i) = b(i)$

for $i = 2: n$

$s = 0$

for $k = 1: i-1$

$s = s + L(i,k) * y(k)$


end

$y(i) = b(i) - s$

end.

$\sum_{i=2}^n \sum_{k=1}^{i-1} 1 = \frac{n^2 - n}{2}$

INVERTIR UMA MATRIZ



PARTI 1

$$\sum_{k=1}^{m-1} \sum_{i=b+1}^m \left(1 + \sum_{j=b+1}^{2m} \right)$$

$$= \frac{5}{6} n^3 - \frac{1}{2} n^2 - \frac{1}{3} n$$

$$\frac{1}{3} n^3 - \frac{1}{3} n$$

$$+ n \left(2 \times \left(\frac{n^2}{2} \right) \right)$$

$$= \frac{1}{3} n^3 - \frac{1}{3} n$$

$$+ n^3$$

$$= \frac{4}{3} n^3 - \frac{1}{3} n$$

PARTI 2

$$\sum_{k=1}^{n-1} \left(\frac{n^2}{2} - \frac{n}{2} \right)$$

DIVISÃO

$$m \times n = n^2$$

total

$$\frac{5}{6} n^3 - \frac{1}{2} n^2 - \frac{1}{3} n + \frac{n^3}{2} + n^2$$

$$= \frac{4}{3} n^3 - \frac{1}{3} n$$

OBSERVAR QUE UMA DIFERENÇA ENTRE ESCALONAR

E DE COMPOSIÇÃO LU QUE L E U SÃO RESOLVIDAS. AO PRECISO ESCALONAR (RECALCULAR L e U) NOVAMENTE

ARMazenadas. Ax = L U x = b, NÃO É PRECISO ESCALONAR (RECALCULAR L e U) NOVAMENTE

FAZER UM ESCALONAMENTO COMPLETO
QUEBRARIA A ESTRUTURA LU

$$\begin{bmatrix} 1 & 2 \\ 0 & 1 \end{bmatrix} \xrightarrow{L_1 \leftarrow L_1 - 2L_2} \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}$$

Em termos matriciais

$$\begin{bmatrix} 1 & -2 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} 1 & 2 \\ 0 & 1 \end{bmatrix}$$

$F_2 \dots F_1$ $E_2 \dots E_1$, A
cisalhamentos horizontais cisalhamentos verticais

Só funciona multiplicando pela esquerda

~~$$\begin{bmatrix} 1 & 2 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} 1 & 2 \\ 0 & 1 \end{bmatrix} = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}$$~~

~~$$\begin{bmatrix} 1 & 4 & 5 \\ 0 & 2 & 6 \\ 0 & 0 & 3 \end{bmatrix}$$~~

~~$$L_2 \leftarrow L_2 \cdot \frac{1}{6} \quad L_1 \leftarrow L_1 - \frac{1}{6}L_2$$~~

~~$$\begin{bmatrix} 1 & 4 & 5 \\ 0 & 2 & 6 \\ 0 & 0 & 3 \end{bmatrix}$$~~

NECESSIDADE DE PERMUTAR LINHAS

$$\begin{bmatrix} 1 & 1 & 1 \\ 2 & 2 & 5 \\ 4 & 6 & 8 \end{bmatrix} \xrightarrow{L_2 \leftarrow L_2 - 2L_1} \sim \begin{bmatrix} 1 & 1 & 1 \\ 0 & 0 & 3 \\ 4 & 6 & 8 \end{bmatrix}$$

$$\xrightarrow{L_3 \leftarrow L_3 - 4L_1} \sim \begin{bmatrix} 1 & 1 & 1 \\ 0 & 0 & 3 \\ 0 & 2 & 4 \end{bmatrix}$$

$$\xrightarrow{L_2 \leftrightarrow L_3} \sim \begin{bmatrix} 1 & 1 & 1 \\ 0 & 2 & 4 \\ 0 & 0 & 3 \end{bmatrix}$$

$$\underbrace{\begin{bmatrix} 1 & 0 & 0 \\ 0 & 0 & 1 \\ 0 & 1 & 0 \end{bmatrix}}_{P_1} \underbrace{\begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ -4 & 0 & 1 \end{bmatrix}}_{E_2} \underbrace{\begin{bmatrix} 1 & 0 & 0 \\ -2 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix}}_{E_1} \underbrace{\begin{bmatrix} 1 & 1 & 1 \\ 2 & 2 & 5 \\ 4 & 6 & 8 \end{bmatrix}}_A$$

↳ ~~matriz~~ matriz de permutação!

UM POUCO SOBRE MATRIZES DE PERMUTAÇÃO

- E_{rs} a matriz identidade com as linhas r e s permutadas.

$$r \leftrightarrow s \rightarrow \begin{bmatrix} 1 & & & \\ & \dots & & \\ & & 0 & 1 \\ & & 1 & 0 \\ & & & \dots & 1 \end{bmatrix}$$

$r \quad s$

(PERMUTAÇÃO ELEMENTAR)

Note que as colunas r e s também foram permutadas.

- $E_{r,s} A$ ~~troca~~ permuta as linhas r e s de A
- $A E_{r,s}$ permuta as colunas r , s e de.

$$\begin{bmatrix} 1 & 0 & 0 \\ 0 & 0 & 1 \\ 0 & 1 & 0 \end{bmatrix} \begin{bmatrix} 1 & 2 & 3 \\ 4 & 5 & 6 \\ 7 & 8 & 9 \end{bmatrix} = \begin{bmatrix} 1 & 2 & 3 \\ 7 & 8 & 9 \\ 4 & 5 & 6 \end{bmatrix}$$

E_{23}

$$\begin{bmatrix} 1 & 2 & 3 \\ 4 & 5 & 6 \\ 7 & 8 & 9 \end{bmatrix} \begin{bmatrix} 1 & 0 & 0 \\ 0 & 0 & 1 \\ 0 & 1 & 0 \end{bmatrix} = \begin{bmatrix} 1 & 3 & 2 \\ 4 & 6 & 5 \\ 7 & 9 & 8 \end{bmatrix}$$

↳ justificativa: multiplicação de matrizes e combinação de linhas para $r \neq s$.

- $E_{r,s}$ é invertível, $\det(E_{r,s}) = -1$

Mais ainda, $E_{r,s}^{-1} = E_{r,s}$.

$E_{r,s}^T = E_{r,s}$

• Mais geralmente, seja

$$P = E_{n_1 s_1} \cdots E_{n_2 s_2} E_{n_1 s_1}$$

~~Esta matriz~~ Cada linha de P tem apenas uma entrada igual a 1, ~~todas as outras~~ as outras são todas nulas.

Cada coluna de P tem apenas uma entrada igual a 1, as outras são todas nulas.

$$P^{-1} = P^T$$

De fato:

$$P^T P = (E_{n_1 s_1} \cdots E_{n_2 s_2})^T (E_{n_1 s_1} \cdots E_{n_2 s_2})$$

P pode não ser simétrica!

$$P = \begin{bmatrix} 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}$$

$$P \begin{bmatrix} l_1 \\ l_2 \\ l_3 \\ l_4 \end{bmatrix} = \begin{bmatrix} l_2 \\ l_3 \\ l_1 \\ l_4 \end{bmatrix}$$

~~$$= E_{n_1 s_1}^T \cdots E_{n_2 s_2}^T E_{n_1 s_1} \cdots E_{n_2 s_2}$$

$$= E_{n_1 s_1} \cdots E_{n_2 s_2}$$

$$= E_{n_1 s_1} \cdots E_{n_2 s_2} E_{n_1 s_1} \cdots E_{n_2 s_1}$$~~

$$P = \begin{bmatrix} 0 & 1 & 0 \\ 0 & 0 & 1 \\ 1 & 0 & 0 \end{bmatrix} = \underbrace{\begin{bmatrix} 0 & 1 & 0 \\ 1 & 0 & 0 \end{bmatrix}}_{E_{1,2}} \underbrace{\begin{bmatrix} 0 & 0 & 1 \\ 0 & 1 & 0 \\ 1 & 0 & 0 \end{bmatrix}}_{E_{1,3}}$$

$$P^T = (E_{1,2} E_{1,3})^T = E_{1,3}^T E_{1,2}^T = E_{1,3} E_{1,2}$$

Troca 1 e 3 e depois troca 1 e 2 não é a mesma coisa que troca 1 e 2 e depois troca 1 e 3

~~$$= E_{1,2}$$

$$= E_{n_1 s_1} \cdots E_{n_2 s_2} E_{n_1 s_1} \cdots E_{n_2 s_1}$$

$$= I$$~~

$$= E_2 P_2 E_1 P_2^{-1} P_2 P_1 A$$

$$= E_2 E_1' P_2 P_1 A$$

Aqui P_i na verdade são matrizes elementares!

E_1 triangular inferior



E_1' triangular inferior

$$\begin{bmatrix} 1 & 0 & 0 \\ 2 & 1 & 0 \\ 3 & 0 & 1 \end{bmatrix}$$

é importante que E_1 tenha zeros aqui!

$$P_2 \begin{bmatrix} 1 & 0 & 0 \\ 2 & 1 & 0 \\ 3 & 0 & 1 \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 \\ 3 & 0 & 1 \\ 2 & 1 & 0 \end{bmatrix}$$

$$P_2 \begin{bmatrix} 1 & 0 & 0 \\ 2 & 1 & 0 \\ 3 & 0 & 1 \end{bmatrix} P_2^{-1} = \begin{bmatrix} 1 & 0 & 0 \\ 3 & 1 & 0 \\ 2 & 0 & 1 \end{bmatrix}$$

$$E_3 P_3 E_2 P_2 E_1 P_1 A$$

~~$$P_3 P_3^{-1} E_3 P_3 P_2 P_2^{-1} E_2 P_2 P_1 A$$~~

~~$$E_3 P_3^{-1} (P_3 P_2 E_1 P_2^{-1} P_3^{-1}) P_3 P_2 P_1 A$$~~

$$E_1 = \begin{bmatrix} 1 & & & \\ a & 1 & & \\ b & & 1 & \\ & & & 1 \end{bmatrix}$$

$$E_2 = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & a & 1 & 0 \\ 0 & b & 0 & 1 \end{bmatrix}$$

Reescrevendo

$$E_3 P_3 E_2 P_2 E_1 P_1 A = E_3 \underbrace{(P_3 E_2 P_3^{-1})}_{E_2'} \underbrace{(P_3 P_2 E_1 P_2^{-1} P_3^{-1})}_{E_1'} P_3 P_2 P_1 A$$

$$E_1 = \begin{bmatrix} 1 & 0 & 0 & 0 \\ a & 1 & 0 & 0 \\ b & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}$$

$$E_2 = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & a & 1 & 0 \\ 0 & b & 0 & 1 \end{bmatrix}$$

$$E P_3 \dots P_1 A = U$$

ainda triangulares inferiores com 1's na diagonal principal

No caso geral, obtemos a seguinte decomposição

$$E_k \dots E_1 P A = U$$

\Downarrow

$$P A = \underbrace{E_1^{-1} \dots E_k^{-1}}_L U$$

\Downarrow

$$P A = L U$$

GOLUB guarda a permutação através de um vetor $p(1:k-1)$

$$p = (4, 2, 3)$$

$$p(1) = 4 \text{ (trocar com } L_{1,4})$$

$$p(2) = 4 \text{ (trocar } L_{2,4})$$

$$p(3) = 4 \text{ (trocar } L_{3,4})$$

DO ALGORITMO DO SISTEMA PA=LU COM DECOMPOSIÇÃO LU PARA O CASO DO PIVOTAMENTO DO GOLUB, veja páginas 12 e 13

No MATLAB: $[L, U, P] = \text{lu}(A)$

$$A x = b$$

$$E_3 E_2 E_1 P A x = U x$$

$$E_3 E_2 E_1 P b = U x$$

OBSERVAÇÕES: Toda matriz A tem uma decomposição na forma $PA = LU$

Em geral, a escolha do ~~melhor~~ pivô é o maior elemento em módulo. Mesmo que não exista a necessidade de pivotamento, seu uso aumenta a estabilidade.

$1 - 10^{-20}$ é arredondado para -10^{-20} pela aritmética de ponto flutuante
 $1 - 10^{-20}$ é aproximado para um dos números que o computador pode aproximar

$$\begin{matrix} -1 \cdot 10^{20} \\ -1 \cdot 10^{20} \\ \vdots \\ -9.5 \cdot 10^{20} \\ -1 \cdot 10^{21} \end{matrix}$$

$$A = \begin{bmatrix} 10^{-20} & 1 \\ 1 & 1 \end{bmatrix}$$

Sem pivotamento

$$L = \begin{bmatrix} 1 & 0 \\ 10^{20} & 1 \end{bmatrix}, U = \begin{bmatrix} 10^{-20} & 1 \\ 0 & 1 - 10^{20} \end{bmatrix}$$

10^{20} muito maior do que 1

Com o arredondamento da máquina:

10

$$\tilde{L} = \begin{bmatrix} 1 & 0 \\ 10^{20} & 1 \end{bmatrix}, \quad \tilde{U} = \begin{bmatrix} 10^{-20} & 1 \\ 0 & -10^{20} \end{bmatrix}$$

$$\tilde{L}\tilde{U} = \begin{bmatrix} 10^{-20} & 1 \\ 1 & 0 \end{bmatrix}$$

Se resolvermos o sistema

$$Ax = b = \begin{pmatrix} 1 \\ 0 \end{pmatrix}$$

Resolvendo sem pivotação:

$$\begin{cases} y_1 = 1 \\ 10^{20} y_1 + y_2 = 0 \end{cases} \Rightarrow \begin{pmatrix} y_1 \\ y_2 \end{pmatrix} = \begin{pmatrix} 1 \\ -10^{20} \end{pmatrix}$$

$$\begin{cases} 10^{-20} x_1 + x_2 = 1 \\ -10^{20} x_2 = -10^{20} \end{cases} \Rightarrow \begin{matrix} x_2 = 1 \\ x_1 = 0 \end{matrix}$$

Enquanto que a solução correta é

~~$\tilde{x} = (-1, 1)$~~

$$\left(\frac{1}{10^{-20} - 1}, \frac{1}{1 - 10^{-20}} \right) \approx (-1, 1)$$

Com perturbamentos

$$L = \begin{bmatrix} 1 & 0 \\ 10^{-20} & 1 \end{bmatrix} \quad U = \begin{bmatrix} 1 & 1 \\ 0 & 1 \end{bmatrix}$$

$$A = \begin{bmatrix} 1 & 1 \\ 10^{-20} & 1 \end{bmatrix}$$

$$\begin{bmatrix} 1 & 0 \\ 10^{-20} & 1 \end{bmatrix} \begin{bmatrix} 1 & 1 \\ 10^{-20} & 1 \end{bmatrix} = \begin{bmatrix} 1 & 1 \\ 0 & 1+10^{-20} \end{bmatrix}$$

APPROXIMATION

$$P = \begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix}$$

NO MATLAB!
format long e

$$Ax = b \Rightarrow PAx = Pb$$

$$\Rightarrow LUX = Pb$$

$$Pb = \begin{pmatrix} 0 \\ 1 \end{pmatrix}$$

$$\begin{cases} y_1 + 0 = 0 & \Rightarrow y_1 = 0 \\ 10^{-20} y_1 + y_2 = 1 & \Rightarrow y_2 = 1 \end{cases}$$

Handwritten note: $y_2 = 1$ (crossed out) $y_2 = 1$

$$\begin{cases} x_1 + x_2 = 0 & \Rightarrow x_1 = -1 \\ x_2 = 1 & \Rightarrow x_2 = 1 \end{cases}$$

SOLUÇÃO EXATA:

$$x_1 = \frac{1}{10^{-20} - 1}, \quad x_2 = \frac{1}{1 - 10^{-20}}$$

Se A é diagonal dominante (o maior elemento em módulo está na diagonal principal)

Dizemos que A é diagonal dominante se

$$|a_{xx}| > \sum_{\substack{j=1 \\ j \neq x}}^n |a_{xj}|$$


$\begin{bmatrix} 2 & 1 \\ 4 & 2 \end{bmatrix}$ ~~nao é diagonal dominante~~

PROPOSIÇÃO: Se A^T é diagonal dominante, então a decomposição LU de A pode ser calculada sem pivotamento de linhas.

Demonstração: (GOLUB e VAN LOAN, Matrix Computations, 3ed, página 6)



$$\begin{bmatrix} \alpha_{1x1} & w^T \\ v & C \end{bmatrix}$$



A.

$$\begin{bmatrix} 1 & 0 \\ -v/\alpha & I \end{bmatrix} \begin{bmatrix} \alpha_{1x1} & w^T \\ v & C \end{bmatrix} = \begin{bmatrix} \alpha & w^T \\ 0 & -\frac{v w^T}{\alpha} + C \end{bmatrix}$$

$$= \begin{bmatrix} 1 & 0 \\ 0 & C - \frac{v w^T}{\alpha} \end{bmatrix} \begin{bmatrix} \alpha & w^T \\ 0 & I \end{bmatrix}$$

Então

$$A = \begin{bmatrix} 1 & 0 \\ v/\alpha & I \end{bmatrix} \begin{bmatrix} 1 & 0 \\ 0 & C - \frac{v w^T}{\alpha} \end{bmatrix} \begin{bmatrix} \alpha & w^T \\ 0 & I \end{bmatrix}$$

B

Se A^T é diagonal dominante, α deve ser diferente de zero.

Fazta por indução!

caso $n=1$
 $\alpha_{11} \neq 0$
 passo indutivo

Se mostrarmos que B^T é diagonal dominante, por indução, teremos uma decomposição LU para A a partir da decomposição $B = L_B U_B$:

$$\begin{bmatrix} 1 & 0 \\ \alpha & I \end{bmatrix} \begin{bmatrix} \alpha & w^T \\ 0 & L_B U_B \end{bmatrix} = \begin{bmatrix} \alpha & w^T \\ v & L_B U_B \end{bmatrix}$$

$$\begin{bmatrix} 1 & 0 \\ v/\alpha & I \end{bmatrix} \begin{bmatrix} 1 & 0 \\ 0 & L_B U_B \end{bmatrix} \begin{bmatrix} \alpha & w^T \\ 0 & I \end{bmatrix}$$

$$\begin{bmatrix} 1 & 0 \\ v/\alpha & L_B \end{bmatrix} \begin{bmatrix} \alpha & w^T \\ 0 & U_B \end{bmatrix}$$

Para ver que B^T é diagonal dominante:

VARIÁVEIS ASCENDENTES!!!

$$\sum_{\substack{i=1 \\ i \neq j}}^{n-1} |b_{ij}| = \sum_{\substack{i=1 \\ i \neq j}}^{n-1} \left| c_{ij} - \frac{v_i w_j}{\alpha} \right|$$

nas dependem de i

$$\leq \sum_{\substack{i=1 \\ i \neq j}}^{n-1} |c_{ij}| + \frac{|w_j|}{|\alpha|} \sum_{\substack{i=1 \\ i \neq j}}^{n-1} |v_i|$$

$$\leq (|c_{jj}| - |w_j|) + \frac{|w_j|}{|\alpha|} (|\alpha| - |v_j|)$$

$$= |c_{jj}| - \left| \frac{w_j v_j}{\alpha} \right|$$

$$\neq |a| - |b| \leq |a - b|$$

$$\leq \left| c_{jj} - \frac{w_j v_j}{\alpha} \right| = |b_{jj}|$$



(A) $\sum_{\substack{i=1 \\ i \neq j}}^{n-1} |c_{ij}| + |w_j| |\alpha| < |c_{jj}|$

(B) $\sum_{\substack{i=1 \\ i \neq j}}^{n-1} (|v_i| + |v_j|) < |\alpha|$

VARIANTES:

→ Para matrizes invertíveis!

- Decomposição LDU → triangular superior com "1's na diagonal"
- ↓
- triangular inferior com "1's na diagonal principal"

Se A é invertível, então A possui no máximo uma única decomposição LDU.

Prova: ~~$(LDU) = (\tilde{L} \tilde{D} \tilde{U})$~~

~~$LD = \tilde{L} \tilde{D}$ e $DU = \tilde{D} \tilde{U}$ $U = \tilde{U}$~~

~~$D = \tilde{D}$ $L = \tilde{L}$, $D = \tilde{D}$, $U = \tilde{U}$~~

(TAMBÉM FAZ MAIS L

$LDU = \tilde{L} \tilde{D} \tilde{U}$
 \Downarrow
 $L(DU) = \tilde{L}(\tilde{D}\tilde{U})$
 \Downarrow resultados contendo
 $L = \tilde{L}$ e $DU = \tilde{D}\tilde{U}$
 \Downarrow na diagonal principal

• Decomposição de Cholesky: se A é e^U uma matriz simétrica: \Downarrow tom \Downarrow

~~$A = LDL^T$~~ LL^T na diagonal principal

Se A é simétrica invertível

$A = LDL^T \Rightarrow A^T = U^T D^T L^T = U^T D L^T$
 $L = U^T \Rightarrow U = L^T$

na diagonal principal com "1's na diagonal principal"

Logo

$A = LDL^T = \begin{bmatrix} 1 & & \\ & \ddots & \\ & & 1 \end{bmatrix} \begin{bmatrix} (d_1) & & \\ & \ddots & \\ & & (d_m) \end{bmatrix} \begin{bmatrix} 1 & & \\ & \ddots & \\ & & 1 \end{bmatrix}$


se $d_i > 0$,

$\begin{bmatrix} \sqrt{d_1} & & \\ & \sqrt{d_2} & \\ & & \ddots \\ & & & \sqrt{d_m} \end{bmatrix} \begin{bmatrix} \sqrt{d_1} & & \\ & \sqrt{d_2} & \\ & & \ddots \\ & & & \sqrt{d_m} \end{bmatrix}$
 $D = \sqrt{D}$

APLICAÇÃO: INTERPOLAÇÃO DE LAGRANGE

APLICAÇÃO: MÉTODO DE NEWTON

- Lembrar o caso $n=1$



- O caso geral:

$$y = F(p) + F'(p)(x-p)$$

$$\text{onde } F'(x) = \begin{bmatrix} \frac{\partial F_1(x)}{\partial x_1} & \dots & \frac{\partial F_1(x)}{\partial x_n} \\ \frac{\partial F_m(x)}{\partial x_1} & \dots & \frac{\partial F_m(x)}{\partial x_n} \end{bmatrix}$$

é a matriz jacobiana de F em x

$$y=0 \Rightarrow F'(p) \underbrace{(x-p)}_{\delta} = -F(p)$$

$$\Rightarrow \boxed{F'(p) \delta = -F(p)}$$

SISTEMA LINEAR

ALGORITMO:

(1) x_0 dado.

(2) Resolver

$$F'(x_0) \delta = -F(x_0)$$

$$x_1 = x_0 + \delta$$

(3) $F(x_0) \approx 0$ (ou $x_1 \approx x_0$)?

Se sim, pare!

Caso contrário! $x_0 = x_1$

Retorne ao passo 2.

EXEMPLO:

$$F_1(x_1, x_2) = x_1^2 + x_2^2 - 1$$

$$F_2(x_1, x_2) = \sin\left(\frac{\pi x_1}{2}\right) + x_2^3$$

$$DF = \begin{bmatrix} 2x_1 & 2x_2 \\ + \cos\left(\frac{\pi x_1}{2}\right) \frac{\pi}{2} & 3x_2^2 \end{bmatrix}$$

MATRIZES POSITIVAS DEFINIDAS

Seja $A_{n \times n}$ uma matriz simétrica.

Dizemos que A é positiva definida se

$$x^T A x > 0, \forall x \in \mathbb{R}^n, x \neq 0.$$

Matrizes positivas definidas ~~aparecem~~ aparecem, por exemplo, na classificação de pontos críticos.

$$f(x) \approx f(p) + f'(p)(x-p) + \frac{1}{2}(x-p)^T f''(p)(x-p)$$

$$\text{onde } f''(p) = \begin{bmatrix} \frac{\partial^2 f}{\partial x_1^2}(p) & \frac{\partial^2 f}{\partial x_2 \partial x_1}(p) & \dots & \frac{\partial^2 f}{\partial x_n \partial x_1}(p) \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2 f}{\partial x_1 \partial x_n}(p) & \frac{\partial^2 f}{\partial x_2 \partial x_n}(p) & \dots & \frac{\partial^2 f}{\partial x_n^2}(p) \end{bmatrix} \text{ e } a$$

matriz Hessiana de f em p .

17

Se p é extremo local de $f: \mathbb{R}^n \rightarrow \mathbb{R}$, então p é ponto crítico de f (Regra de Fermat). Assim

$$f(x) \approx f(p) + \frac{1}{2} (x-p)^T f''(p) (x-p)$$

Se $f''(p)$ é positiva definida, então p é um ponto de mínimo local de f .

Como saber se uma matriz A é positiva definida?

(1) A é positiva definida \Leftrightarrow todos os menores $n \times n$ principais líderes > 0

(2) A é positiva \Leftrightarrow todos os autovalores de A são > 0 .

(3) A é positiva definida \Leftrightarrow existe a decomposição $A = LL^T$ de Cholesky, onde L tem todos os elementos da diagonal principal > 0 .

Observe que se $A = LDU$ e A é simétrica, então

$$A = \begin{bmatrix} 1 & 0 & 0 \\ 3 & 1 & 0 \\ 1 & 2 & 1 \end{bmatrix} \begin{bmatrix} 2 & 1 & 1 \\ 0 & 4 & 1 \\ 0 & 0 & 5 \end{bmatrix}$$

$$A^T = A = LDU$$

$$U^T D L^T$$

$$= \begin{bmatrix} 1 & 0 & 0 \\ 3 & 1 & 0 \\ 1 & 2 & 1 \end{bmatrix} \begin{bmatrix} 2 & 0 & 0 \\ 0 & 4 & 0 \\ 0 & 0 & 5 \end{bmatrix}$$

Pela unicidade da decomposição LDU de uma ~~matriz~~ matriz invertível, $U = L^T$.

$$\begin{bmatrix} 1 & 4/2 & 1/2 \\ 0 & 1 & 1/4 \\ 0 & 0 & 5/8 \end{bmatrix}$$

Logo $A = LDL^T$. Se todos os elementos da diagonal principal de D são > 0 , então

$$A = L \begin{bmatrix} \sqrt{d_{11}} & & \\ & \ddots & \\ & & \sqrt{d_{nn}} \end{bmatrix} \begin{bmatrix} \sqrt{d_{11}} & & \\ & \ddots & \\ & & \sqrt{d_{nn}} \end{bmatrix} L^T$$

$$= \tilde{L} \tilde{L}^T$$

onde $\tilde{L} = L \begin{bmatrix} \sqrt{d_{11}} & & \\ & \ddots & \\ & & \sqrt{d_{nn}} \end{bmatrix}$

$$\begin{bmatrix} 1 & 0 \\ 1 & -1 \end{bmatrix} \begin{bmatrix} 2 & 1 \\ 0 & -1 \end{bmatrix}$$

$$\begin{bmatrix} 1 & 0 \\ 1 & -1 \end{bmatrix} \begin{bmatrix} 1 & 1 \\ 1 & -1 \end{bmatrix} \begin{bmatrix} 1 & 1 \\ 0 & -1 \end{bmatrix}$$

$$\begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} 1 & 1 \\ 0 & 1 \end{bmatrix}$$

~~De fato: se $A = LU$~~

Note que \hookrightarrow normalizada

$$x^T A x = x^T L^T L x = \|Lx\|^2$$

Como L é ~~uma~~ invertível, $Lx \neq 0$ para $x \neq 0$. Assim, $x^T A x > 0$ para todo $x \neq 0$.

Na verdade, é possível saber se A é positiva definida já com a decomposição LU: 19

$$A = \begin{bmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{bmatrix} = \begin{bmatrix} L_{11} & U_{11} \\ & & & & \end{bmatrix} = LU$$

$$= \begin{bmatrix} L_{11} & 0 \\ L_{12} & L_{22} \end{bmatrix} \begin{bmatrix} U_{11} & U_{12} \\ 0 & U_{22} \end{bmatrix}$$

$$= \begin{bmatrix} L_{11}U_{11} & L_{11}U_{12} \\ L_{12}U_{11} & L_{12}U_{12} + L_{22}U_{22} \end{bmatrix}$$

$$A_{11} = L_{11}U_{11}$$

$$\det(A_{11}) = \det(U_{11}) = \prod_{i=1}^k u_{ii}$$

Assim, se todos os elementos da diagonal de U são > 0 , então A é positiva definida.

Este resultado não é válido para a decomposição ~~LU~~
 $PA=LU$

A é positiva definida $\Rightarrow A$ é invertível e aplicando os autovalores

for the quantities u_{sk} with $1 \leq s \leq k-1$. These elements lie in the k th column of U . Since U_{k-1} is nonsingular, we can solve the system

$$\sum_{s=1}^{k-1} \ell_{ks} u_{sj} = a_{kj} \quad (1 \leq j \leq k-1)$$

for ℓ_{ks} with $1 \leq s \leq k-1$. These elements lie in the k th row of L . From the requirement

$$a_{kk} = \sum_{s=1}^k \ell_{ks} u_{sk} = \sum_{s=1}^{k-1} \ell_{ks} u_{sk} + \ell_{kk} u_{kk}$$

we can obtain u_{kk} since ℓ_{kk} has been specified as unity. Thus, all the new elements necessary to form L_k and U_k have been defined. The induction is completed by noting that $\ell_{11} u_{11} = a_{11}$ and, therefore, $\ell_{11} = 1$ and $u_{11} = a_{11}$. ■

Cholesky Factorization

As mentioned earlier in this section, a matrix factorization that is useful in some situations has been given the name of the mathematician André Louis Cholesky, who proved the following result:

THEOREM 2 *If A is a real, symmetric, and positive definite matrix, then it has a unique factorization, $A = LL^T$, in which L is lower triangular with a positive diagonal.*

Proof Recall that a matrix A is symmetric and positive definite if $A = A^T$ and $x^T A x > 0$ for every nonzero vector x . It follows at once that A is nonsingular, for A obviously cannot map any nonzero vector into zero. Moreover, by considering special vectors of the form $x = (x_1, x_2, \dots, x_k, 0, 0, \dots, 0)^T$, we see that the leading principal minors of A are also positive definite. Theorem 1 implies that A has an LU decomposition. By the symmetry of A , we then have

$$LU = A = A^T = U^T L^T$$

This implies that

$$U(L^T)^{-1} = L^{-1}U^T$$

The left member of this equation is upper triangular, while the right member is lower triangular. (See Problem 1.) Consequently, there is a diagonal matrix D such that $U(L^T)^{-1} = D$. Hence, $U = DL^T$ and $A = LDL^T$. By Problem 27, D is positive definite, and thus its elements d_{ii} are positive. Denoting by $D^{1/2}$ the diagonal matrix whose diagonal elements are $\sqrt{d_{ii}}$, we have $A = \tilde{L}\tilde{L}^T$ where $\tilde{L} \equiv LD^{1/2}$, which is the Cholesky factorization. The proof of uniqueness is left as a problem. ■

The algorithm for the Cholesky factorization is a special case of the general LU -factorization algorithm. If A is real, symmetric, and positive definite then by Theorem 2 it has a unique factorization of the form $A = LL^T$, in which L is lower triangular and has positive diagonal. Thus, in Equation (8), $U = L^T$. In the k th step of the general algorithm, the diagonal entry is computed by

$$\ell_{kk} = \left(a_{kk} - \sum_{s=1}^{k-1} \ell_{ks}^2 \right)^{1/2} \quad (13)$$