

Decomposições Matriciais

Prof. Caio Azevedo

- Reescrever uma matriz (que atenda certos requisitos) como produto (em geral) de outras matrizes com certas propriedades de interesse.
- Utilidade:
 - Demonstrações (obtenções) de resultados teóricos (propriedades).
 - Melhor desempenho de outros algoritmos computacionais (integração, maximização, simulação).
- Decomposições importantes:
 - Cholesky.
 - QR.
 - Valor singular (e espectral).

- Seja $\Sigma_{p \times p}$, simétrica e positiva definida (todos os seus auto-valores são positivos).
- Exemplo: Matriz de covariâncias e matriz de correlações.
- Definição: Dada uma matriz Σ existe uma matriz L , diagonal inferior com os valores da diagonal estritamente positivos, $\Sigma = LL'$.
- Tal decomposição é única. A demonstração pode ser feita via decomposição LU .
- Existem alguns algoritmos que possibilitam a obtenção de L .

Estrutura

- De um modo geral

$$\Sigma = \begin{bmatrix} \sigma_1^2 & \sigma_{12} & \dots & \sigma_{1p} \\ \sigma_{12} & \sigma_2^2 & \dots & \sigma_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{1p} & \sigma_{2p} & \dots & \sigma_p^2 \end{bmatrix} = \begin{bmatrix} l_{11} & 0 & \dots & 0 \\ l_{21} & l_{22} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ l_{p1} & l_{p2} & \dots & l_{pp} \end{bmatrix} \begin{bmatrix} l_{11} & l_{21} & \dots & l_{2p} \\ 0 & l_{22} & \dots & l_{p2} \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & 0 \end{bmatrix}$$

Exemplo

- Exemplo:

$$\Sigma = \begin{bmatrix} 3 & 1 & 0.5 \\ 1 & 2 & 0.8 \\ 0.5 & 0.8 & 4 \end{bmatrix}$$

$$\mathbf{L} \approx \begin{bmatrix} 1,732 & 0 & 0 \\ 0,577 & 1,291 & 0 \\ 0,289 & 0,491 & 1,917 \end{bmatrix}$$

Aplicações

- Métodos (algoritmos) de estimação:
 - Em geral, sempre que o método envolver inversão de matrizes positivas definidas. A inversão de \mathbf{LL}' é mais estável.
 - Mínimos quadrados generalizados (resolução de sistemas lineares).
 - Mínimos quadrados ponderados.
 - Máxima verossimilhança (utilização de algoritmos de maximização: Newton-Raphson, Escore de Fisher, BFGS).
- Análise de componentes principais.
- Simulação Estocástica.

Sistemas lineares

- Considere o sistema $\mathbf{Ax} = \mathbf{b}$.
- Caso \mathbf{A} seja inversível a solução é dada por $\mathbf{x} = \mathbf{A}^{-1}\mathbf{b}$.
- Inverter a matriz \mathbf{A} pode ser muito despendioso computacionalmente.

Por outro lado, se a matriz \mathbf{A} for diagonal superior ou inferior, a solução torna-se mais simples.

A diagonal inferior

- Considere

$$\begin{bmatrix} a_{11} & 0 & \dots & 0 \\ a_{21} & a_{22} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ a_{p1} & a_{p2} & \dots & a_{pp} \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_p \end{bmatrix} = \begin{bmatrix} b_1 \\ b_2 \\ \vdots \\ b_p \end{bmatrix}$$

- Solução $x_i = \frac{b_i - \sum_{j=1}^{i-1} a_{ij}x_j}{a_{ii}}$

A diagonal superior

- Considere

$$\begin{bmatrix} a_{11} & a_{21} & \dots & a_{2p} \\ 0 & a_{22} & \dots & a_{p2} \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & 0 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_p \end{bmatrix} = \begin{bmatrix} b_1 \\ b_2 \\ \vdots \\ b_p \end{bmatrix}$$

- Solução $x_i = \frac{b_i - \sum_{j=i+1}^p a_{ij}x_j}{a_{ii}}$

Aplicação da decomposição de Cholesky

- Ao invés de calcular $\mathbf{x} = \mathbf{A}^{-1}\mathbf{b}$ resolve-se o sistema em duas etapas.
- Primeiro $\mathbf{L}\mathbf{y} = \mathbf{b}$, depois $\mathbf{L}'\mathbf{x} = \mathbf{y}$. Multiplicando-se esta última por \mathbf{L} recupera-se $\mathbf{Ax} = \mathbf{b}$.
- Algoritmo
 - 1 Resolver $\mathbf{L}\mathbf{y} = \mathbf{b}$.
 - 2 Depois, resolver $\mathbf{L}'\mathbf{x} = \mathbf{y}$.

Aplicação no modelo de regressão normal linear

■ Modelo

$$\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\xi}$$

$$\mathbf{Y} = \begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix}, \mathbf{X} = \begin{bmatrix} 1 & X_{11} & \dots & X_{1p} \\ 1 & X_{21} & \dots & X_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ 1 & X_{n1} & \dots & X_{np} \end{bmatrix}, \boldsymbol{\xi} = \begin{bmatrix} \xi_1 \\ \xi_2 \\ \vdots \\ \xi_n \end{bmatrix}$$

- Suposição $\boldsymbol{\xi} \sim N_n(\mathbf{0}, \sigma^2 \mathbf{I}_n)$.
- Estimador de mínimos quadrados de $\boldsymbol{\beta}$, minimizar $(\mathbf{Y} - \mathbf{X}\boldsymbol{\beta})'(\mathbf{Y} - \mathbf{X}\boldsymbol{\beta})$, equivale a resolver $(\mathbf{X}'\mathbf{X})\boldsymbol{\beta} = \mathbf{X}'\mathbf{Y}$.

Cont.

- Solução natural $\beta = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y}$. Em geral $\mathbf{X}'\mathbf{X}$ é positiva definida.
- Seja \mathbf{L}_x a decomposição de Cholesky de $\mathbf{X}'\mathbf{X}$. Então, pode-se fazer:
 - 1 Resolver $\mathbf{L}_x\gamma = \mathbf{X}\mathbf{Y}$
 - 2 Depois, resolver $\mathbf{L}'_x\beta = \gamma$
- Pode ser bastante útil quando a dimensão de $\mathbf{X}'\mathbf{X}$ for grande e/ou for muito instável sua inversão.

Estimação por máxima verossimilhança

- Seja $X_1, \dots, X_n \stackrel{iid}{\sim} X, X \sim F_X(\cdot, \theta)$.
- Verossimilhança $L(\theta) = \prod_{i=1}^n f_X(x_i; \theta)$.
- Logverossimilhança $l(\theta) = \sum_{i=1}^n \ln f_X(x_i; \theta)$.
- Exemplo, $X \sim \text{gama}(r, \lambda), \mathcal{E}(X) = r\lambda$.
- Verossimilhança

$$L(\theta) = \frac{1}{\Gamma(r)^n} \lambda^{nr} e^{-n\bar{x}/\lambda} \prod_{i=1}^n x_i^{r-1}$$

Cont.

- Maximizar $l(\theta)$ em relação à θ .
- Resolver $\mathbf{S}(\hat{\theta}) = \mathbf{0}$.
- Em geral, não há solução analítica explícita.
- Algoritmo Escore de Fisher.
- Fazer, $m = 0, 1, 2, \dots$ até que algum critério de convergência seja satisfeito.

$$\theta^{(m+1)} = \theta^{(m)} + \mathbf{I}(\theta^{(m)})\mathbf{S}(\theta^{(m)})$$

- $\mathbf{I}(\theta) = -\mathcal{E}(\mathbf{H}(\theta))$, informação de Fisher.

Cont.

- Seja \mathbf{L} a decomposição de Cholesky de $\mathbf{I}(\boldsymbol{\theta})$.
- Temos que $\mathbf{I}(\boldsymbol{\theta})^{-1} = (\mathbf{L}')^{-1}\mathbf{L}^{-1}$.
- A inversão da informação de Fisher pode ser instável, principalmente em relação à \mathbf{L}
- A inversão de matrizes diagonais inferiores/superiores é menos dispendiosa computacionalmente.

Aplicação em modelos lineares generalizados

- Seja

$$y_i \sim \text{FE}(\mu_i, \phi)$$

$$\mu_i = g^{-1}(\mathbf{X}_i\boldsymbol{\beta})$$

\mathbf{X}_i é uma determinada linha de \mathbf{X} .

- Estimação por máxima verossimilhança: mínimos quadrados ponderados.

$$\boldsymbol{\beta}^{(m+1)} = (\mathbf{X}'\mathbf{W}^{(m)}\mathbf{X})^{-1}\mathbf{X}'\mathbf{W}^{(m)}\mathbf{z}^{(m)}$$

$m=1,2,\dots$ (até obter-se convergência).



Cont.

- Analogamente ao caso anterior, pode-se considerar a decomposição de Cholesky (\mathbf{L}) de $(\mathbf{X}'\mathbf{W}\mathbf{X})$, em cada passo do processo iterativo.
- A inversão de \mathbf{L} , em cada passo do algoritmo.
- Mais rapidez e estabilidade.
- Quando a matriz \mathbf{X} é composta de variáveis correlacionadas (Pearson), as matrizes $(\mathbf{X}'\mathbf{X})$ e $(\mathbf{X}'\mathbf{W}\mathbf{X})$ pode não ser inversíveis.

Simulação de uma Normal multivariada

- $\mathbf{X} \sim N_p(\boldsymbol{\mu}, \boldsymbol{\Sigma}), \boldsymbol{\mu} \in \mathcal{R}^p, \boldsymbol{\Sigma} > 0$.
- Sabemos que $\mathbf{X} = \boldsymbol{\Psi}\mathbf{Z} + \boldsymbol{\mu}, \boldsymbol{\Psi} = \text{Cholesky}(\boldsymbol{\Sigma}),$
 $\mathbf{Z} = (Z_1, \dots, Z_n), Z_i \stackrel{i.i.d.}{\sim} N(0, 1), i = 1, \dots, p$.
- $\mathbf{x} = \boldsymbol{\Psi}F_Z^{-1}(\mathbf{u}) + \boldsymbol{\mu}, \mathbf{u} = (u_1, \dots, u_p)$.

Definição

- Seja $\mathbf{X}_{n \times p}$, com as colunas linearmente independentes.
- Exemplo: matriz de planejamento num modelo de regressão (sem multicolineariedade).
- Definição: dada uma matriz \mathbf{X} existem duas matrizes, \mathbf{Q} e \mathbf{R} , tais que as colunas de \mathbf{Q} são vetores ortonormais e \mathbf{R} é uma matriz triangular superior.
- Algoritmo básico:
 - 1 Gera-se \mathbf{Q} através das colunas de \mathbf{X} através do processo de ortnormalização de Gram-Schmidt.
 - 2 Calcula-se $\mathbf{R} = \mathbf{Q}'\mathbf{X} \Rightarrow \mathbf{Q}'\mathbf{X} = \mathbf{Q}'\mathbf{Q}\mathbf{R} \Rightarrow \mathbf{R} = \mathbf{Q}'\mathbf{X}$.

Cont.

- Seja

$$\mathbf{X} = \begin{bmatrix} 1 & -1 \\ 3 & 4 \\ 4 & 5 \end{bmatrix}$$

$$\mathbf{Q} \approx \begin{bmatrix} -0,196 & 0,977 \\ -0,588 & -0,188 \\ -0,784 & -0,102 \end{bmatrix}; \mathbf{R} \approx \begin{bmatrix} -5,100 & -6,079 \\ 0 & -2,224 \end{bmatrix}$$

Aplicações

- Métodos (algoritmos) de estimação:
 - Mínimos quadrados generalizados (resolução de sistemas lineares).
 - Mínimos quadrados ponderados.
 - Máxima verossimilhança (utilização de algoritmos de maximização: Newton-Raphson, Escore de Fisher, BFGS).
- Análise de componentes principais.
- Simulação MCMC.

Mínimos quadrados

- Do modelo linear normal, temos que o EMQ pode ser reescrito como

$$\begin{aligned}(\mathbf{X}'\mathbf{X})\boldsymbol{\beta} &= \mathbf{X}'\mathbf{Y} \Rightarrow ((\mathbf{QR})'\mathbf{QR})\boldsymbol{\beta} = \mathbf{X}'\mathbf{Y} \Rightarrow (\mathbf{R}'\mathbf{R})\boldsymbol{\beta} = \mathbf{R}'\mathbf{Q}'\mathbf{Y} \\ \boldsymbol{\beta} &= \mathbf{R}^{-1}\mathbf{Q}'\mathbf{Y}\end{aligned}$$

Mínimos quadrados reponderados

- A expressão, dado $\mathbf{W} = \mathbf{L}\mathbf{L}'$ é pode ser reescrita como

$$\begin{aligned}\hat{\beta} &= (\mathbf{X}'\mathbf{L}\mathbf{L}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{L}\mathbf{L}'\mathbf{z} = ((\mathbf{X}^*)'\mathbf{X}^*)^{-1}(\mathbf{X}^*)'\mathbf{L}'\mathbf{z} \\ &= (\mathbf{R}'\mathbf{Q}'\mathbf{Q}\mathbf{R})^{-1}\mathbf{R}'\mathbf{Q}'\mathbf{L}'\mathbf{z} = (\mathbf{R}')^{-1}\mathbf{Q}'\mathbf{L}'\mathbf{z}\end{aligned}$$

Simulação de Monte Carlo via Cadeias de Markov

■ Simular iterativamente

1 $Z_i \sim N_{[a,b]}(\beta' \beta, \sigma_i^2).$

2 $\beta \sim N_p((\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Z}, \Sigma).$

Simulação de Monte Carlo via Cadeias de Markov

■ Simular iterativamente

1 $Z_i \sim N_{[a,b]}(\beta' \beta, \sigma_i^2).$

2 $\beta \sim N_p((\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Z}, \Sigma).$

Definição

- Seja $\mathbf{A}_{(I \times J)}$, então podemos escrever :

$$\mathbf{A} = \mathbf{U}\mathbf{\Lambda}\mathbf{V}'$$

em que

\mathbf{U} : colunas formadas pelos autovetores (ortonormalizados) de $\mathbf{A}\mathbf{A}'$.

\mathbf{V} : coluna formadas pelos autovetores (ortonormalizados) de $\mathbf{A}'\mathbf{A}$.

$\mathbf{\Lambda}$: matriz diagonal com sua diagonal dada por $(\lambda_1, \lambda_2, \dots, \lambda_{\min(I, J)})'$, que são as raízes quadradas positivas dos autovalores maiores que zero, obtidos a partir das matrizes $\mathbf{A}\mathbf{A}'$ ou $\mathbf{A}'\mathbf{A}$ (os autovalores maiores que zero são iguais).

Aplicações

- Redução de dados (variáveis e observações) (ACP, AF).
- Mínimos quadrados.
- Mínimos quadrados reponderados.
- Análise de correspondência.
- Processamento e compressão de imagens
- Detecção de outliers.