

Ajuste Automático ao Histórico

Simulação de Reservatórios

Flavio Dickstein

IM/UFRJ

Paulo Goldfeld

IM/UFRJ

Renan V. Pinto


LabMAPetro/UFRJ

Novembro/2018



- 1 Preliminares
 - SVD
 - Condicionamento
 - Otimização
 - Probabilidade
- 2 Recuperação de Petróleo
 - Contexto geral
 - Modelagem
- 3 Ajuste ao Histórico
- 4 Resultados Numéricos

- Decomp. espectral: diagon. de matriz **quadrada**.
 $A = MDM^{-1}$, M é mudança de base.
Nem toda matriz quadrada é diagonalizável.
- SVD: diagonalização de **uma matriz qualquer**.
Mudanças de base **ortogonais**.



$$A = U\Sigma V^T$$

- $A_{m \times n}$ é qualquer;
- $U_{m \times m}$ é ortogonal, $U^T U = I$;
 $V_{n \times n}$ é ortogonal, $V^T V = I$;
- $\Sigma_{m \times n}$ diagonal, $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_n \geq 0$.

$$\Sigma = \begin{bmatrix} \sigma_1 & & & \\ & \ddots & & \\ & & \sigma_n & \\ & & & \end{bmatrix} \text{ ou } \begin{bmatrix} \sigma_1 & & & \\ & \ddots & & \\ & & \sigma_m & \\ & & & \end{bmatrix}.$$

$$A = U\Sigma V^T \Leftrightarrow AV = U\Sigma \Leftrightarrow Av_i = \sigma_i u_i, i \leq n$$

u_i 's e v_i 's são os vetores singulares à esquerda e à direita, σ_i são os valores singulares.

Aproximação de A

Seja $k < n$

$$\hat{\Sigma}_k = \left[\begin{array}{ccc|c} \sigma_1 & & & 0 \\ & \ddots & & \\ & & \sigma_k & \\ \hline & 0 & & 0 \end{array} \right] = \begin{bmatrix} \Sigma_k & 0 \\ 0 & 0 \end{bmatrix}$$

$$A_k = U \hat{\Sigma}_k V^T = \begin{bmatrix} U_k & \tilde{U} \end{bmatrix} \begin{bmatrix} \Sigma_k & 0 \\ 0 & 0 \end{bmatrix} \begin{bmatrix} V_k^T \\ \tilde{V}^T \end{bmatrix} = U_k \Sigma_k V_k^T$$

Se $\sigma_k > 0$, A_k é uma aproximação de A de posto k .

Aproximação de A

A_k é a matriz de posto k "mais próxima de A ". Defina

$$\|u\|_2 = \left(\sum_i |u_i|^2 \right)^{1/2}$$

$$\|A\|_2 = \max\{\|Au\|_2, \|u\|_2 = 1\} \quad (\text{norma 2})$$

$$\|A\|_F = \left(\sum_{i,j} A_{i,j}^2 \right)^{1/2} \quad (\text{norma de Frobenius})$$

Então, se $\text{rank}(B) \leq k$,

$$\|A - B\|_2 \geq \|A - A_k\|_2 = \sigma_{k+1}.$$

$$\text{Se } B \neq A_k, \|A - B\|_F > \|A - A_k\|_F = \left(\sum_{i>k} \sigma_i^2 \right)^{1/2}$$

Os valores e espaços singulares são únicos.

Número de condicionamento

Considere os sistemas lineares invertíveis

$$Ax = b \quad \text{e} \quad A(x + \delta x) = b + \delta b$$

de modo que

$$A\delta x = \delta b$$

Defina os erros relativos

$$e_b = \frac{\|\delta b\|}{\|b\|}, \quad e_x = \frac{\|\delta x\|}{\|x\|}$$

Então,

$$\frac{e_x}{e_b} = \frac{\|\delta x\|}{\|\delta b\|} \frac{\|b\|}{\|x\|} = \frac{\|A^{-1}\delta b\|}{\|\delta b\|} \frac{\|Ax\|}{\|x\|}$$

de modo que

$$\max_{x, \delta b} \frac{e_x}{e_b} = \|A\| \|A^{-1}\|$$

Número de condicionamento

Definimos o **número de condicionamento** $\kappa(A)$ como

$$\kappa(A) = \|A\| \|A^{-1}\|.$$

O condicionamento de A é o fator de amplificação do erro relativo introduzido na resolução de um sistema.

$\kappa(A)$ depende da norma considerada. No caso da norma 2,

$$\kappa_2(A) = \|A\|_2 \|A^{-1}\|_2 = \frac{\sigma_1}{\sigma_n}.$$

é o quociente entre o maior e o menor valor singular de A .

Número de condicionamento

Quando A é singular, consideramos o problema:
“encontrar o 'menor' x tal que $\|b - Ax\|$ seja mínima”.

Neste caso, se $\text{rank}(A) = k$, temos

$$\kappa_2(A) = \frac{\sigma_1}{\sigma_k}.$$

Se A tem posto n e aproximamos A por A_k , sua melhor representação de posto $k < n$, melhoramos o condicionamento do problema.

Métodos com derivada

Ideia básica: f_k aproximação quadrática de f em torno de m_k .

$$f_k(m_k + \delta m) = f(m_k) + \nabla f(m_k)^T \delta m + \frac{1}{2} \delta m^T \nabla^2 f(m_k) \delta m$$

Minimizando f_k :

$$\nabla f_k(m_k + \delta m_k)^T = 0 = \nabla f(m_k)^T + \nabla^2 f(m_k) \delta m_k.$$

Assim, $\delta m_k = -(\nabla^2 f(m_k))^{-1} \nabla f(m_k)^T$.

- Newton:
- + convergência quadrática;
 - não garante convergência (nem mesmo descida) e
 - exige o cálculo de $\nabla^2 f(m_k)$.

Otimização Não-Linear

Método de Newton: $\delta m_k = -(\nabla^2 f(m_k))^{-1} \nabla f(m_k)^T$

Métodos “tipo” Newton: $\delta m_k = -\alpha H_k^{-1} \nabla f(m_k)^T$.

- $H_k > 0 \Rightarrow$ direção de descida;
- escolha de $\alpha > 0$ é a busca linear;
- Newton: $\alpha = 1$, $H_k = \nabla^2 f(m_k)$;
- Máxima Descida: $H_k = I$ e
- Quasi-Newton: $H_k > 0$ aproxima $\nabla^2 f(m_k)$, usando $\nabla f(m_j)$, $j \leq k$.

Método de Gauss-Newton

O Método de Gauss-Newton se aplica a problemas de mínimos quadrados não-lineares

$$\min_m \frac{1}{2} \|r(m)\|^2$$

A cada iteração k aproximamos

$$r(m_k + \delta m) \approx r(m_k) + r'(m_k)\delta m = A\delta m - b$$

e resolvemos o problema de mínimos quadrados **linear**

$$\min_{\delta m} \frac{1}{2} \|A\delta m - b\|^2$$

cuja solução é dada pelas **equações normais**

$$A^T A \delta m_k = A^T b$$

Um espaço de medida (E, Σ, P) é dito um espaço de probabilidade se $P \geq 0$ e $P(E) = 1$.

Uma variável aleatória (v.a.) é uma função mensurável $X : E \rightarrow \mathbb{R}^n$.

No que segue $E = \mathbb{R}^m$, Σ é a σ -álgebra de Borel e μ é a medida de Lebesgue.

Seja X uma v.a. Então, $f_X : \mathbb{R} \rightarrow \mathbb{R}$ é uma densidade de probabilidade (dp) de X se

$$P(X(x) \in \Omega) = \int_{\Omega} f_X(x) dx.$$

Esperança e Variância

A **média** μ (ou **valor esperado** $E(X)$) de X é dada por

$$\mu = \int_{\mathbb{R}^m} xf_X(x) dx \in \mathbb{R}^n$$

Se X é escalar, a **variância** σ^2 de X é dada por

$$\sigma^2 = E((X - \mu)^2) = \int_{\mathbb{R}^m} (x - \mu)^2 f_X(x) dx$$

Se $X = (X_1, X_2, \dots, X_n)$, a **matriz de covariância** C de X é

$$C_{i,j} = E((X_i - \mu_i)(X_j - \mu_j))$$

Seja $X = (X_1, X_2)$. Então, X_1, X_2 são v.a. **independentes** se $f_X(x_1, x_2) = f_{X_1}(x_1)f_{X_2}(x_2)$, isto é,

$$P(X_1 \in \Omega_1 \wedge X_2 \in \Omega_2) = P(X_1 \in \Omega_1)P(X_2 \in \Omega_2)$$

Neste caso, $C(X)$ é diagonal.

Distribuição Normal

Se $\sigma \neq 0$, a densidade normal $\mathcal{N}_{\mu, \sigma^2}$ dada por

$$f(x) = \frac{1}{(2\pi\sigma^2)^{N/2}} e^{-\frac{\langle x-\mu, x-\mu \rangle}{2\sigma^2}} \propto e^{-\frac{\|x-\mu\|^2}{2\sigma^2}}$$

tem média μ e variância σ^2 . $\mathcal{N}_{0,1}$ é dita normal padrão.

Se $C_{n \times n}$ é SPD, então $\mathcal{N}_{\mu, C}$ dada por

$$f(x) \propto e^{-\frac{1}{2} \langle C^{-1}(x - \mu), x - \mu \rangle}$$

tem média $\mu \in \mathbb{R}^n$ e covariância C . $\mathcal{N}_{0, I}$ é dita normal padrão.

Se X tem distribuição $\mathcal{N}_{\mu, C}$, então X_i , $i \leq n$, são independentes se e só se C é diagonal.

Distribuição χ^2

Seja $C = C^{1/2}C^{1/2}$, $C^{1/2}$ SPD. Então,
 $\langle C^{-1}(x - \mu), x - \mu \rangle = \|C^{-1/2}(x - \mu)\|^2$.

Se X é uma v.a. de densidade $\mathcal{N}_{\mu, C}$, então $Y = C^{-1/2}(X - \mu)$ é normal padrão.

Sejam X_1, \dots, X_n v.a. independentes com distribuição normal padrão. Então,

$$\|X\|^2 = X_1^2 + X_2^2 + \dots + X_n^2$$

é dita uma v.a. χ_n^2 . $\|X\|^2$ tem média n e variância $\sigma^2 = 2n$.

Se X é $\mathcal{N}_{\mu, C}$, então,

$$\|C^{-1/2}(X - \mu)\|^2$$

tem distribuição χ_n^2 .