

---

**Lista geral da disciplina**


---

## 1. Fazer em Octave/Matlab

- (a) Um programa que cria dois vetores randômicos e calcula o seu produto escalar.
- (b) Um programa que cria duas matrizes randômicas e calcula o seu produto.
- (c) Um programa que mede o tempo necessário para calcular o produto de duas matrizes randômicas de  $100 \times 100$ . Usar os comandos `tic` e `toc`.
- (d) Um programa para determinar se os vetores de  $\mathbb{R}^4$  na sequência são linearmente independentes

$$\mathbf{v}_1 = [0 \ 1 \ 0 \ 1]^T, \quad \mathbf{v}_2 = [1 \ 2 \ 3 \ 4]^T, \\ \mathbf{v}_3 = [1 \ 0 \ 1 \ 0]^T, \quad \mathbf{v}_4 = [0 \ 0 \ 1 \ 1]^T$$

(exercício 1.6 do livro de Quarteroni et al.)

- (e) Um programa que, para um valor dado de  $x$ , calcule numericamente a probabilidade  $P(x)$  de que uma matriz randômica de  $3 \times 3$  tenha determinante menor (em valor absoluto) que  $x$ . Desenhe a função  $P(x)$ .

## 2. A conectividade de uma rede é uma matriz em que cada linha corresponde a uma conexão (aresta) e tem duas colunas, uma para cada um dos vértices da conexão.

Considere as seguintes matrizes de conectividade:

`con1=[2,1;1,6;6,4;4,5;5,3;3,2;1,4;4,3;3,1];`


`con2=[2,1;1,6;3,4;1,3;6,4;4,5;2,3;3,5;1,4];`

`con3=[1,2;6,1;4,3;3,1;4,6;4,5;2,3;3,5;1,4];`

e a seguinte função:

```
function vec=f(nv,nb,con)
    vec=zeros(1,nv);
    for i=1:nb
        p = con(i,1);
        q = con(i,2);
        vec(p)=vec(p)+1;
        vec(q)=vec(q)+1;
    end
end
```

- (a) Considere a rede da figura e responda qual das matrizes de conectividade (`con1`, `con2`, `con3`) corresponde com ela (podem ser várias ou nenhuma).



- (b) Responda se verdadeiro ou falso:

```
> vec=f(6,9,con1)
vec =
4 2 4 4 2 2
```

- (c) Responda se verdadeiro ou falso: Em toda rede, se `nv` é o número de vértices, `nb` o número de arestas, e `con` a conectividade, então
- ```
> vec=f(nv,nb,con)
```
- dará um vetor cuja componente `i` será o número de arestas que tem o vértice `i` como um dos extremos.
- (d) Responda se verdadeiro ou falso: O resultado de `f(6,8,con1)` é o mesmo de `f(6,8,con2)`.

3. Considere a definição de  $F(\beta, t, m, M)$ .

- (a) Determine quantos números distintos há no conjunto.
- (b) Particularize a resposta do item anterior para o conjunto  $C = F(3, 5, -3, 3)$ .
- (c) Indique qual o número de  $C$  mais próximo de  $\sqrt{2}$ . Expressar o resultado em base 3 e em base 10. Quanto vale o erro de arredondamento relativo nesse caso?
- (d) Calcule  $\epsilon_M$ .
- (e) Calcule o maior e o menor número positivo representável no conjunto  $C$ , expressados em base 3 e em base 10.

## 4. Faça uma função em Octave

```
function kang = angulos(a,b,c)
```

que tome como dados três números reais que são os comprimentos dos três lados de um triângulo  $T$ . A função deve retornar os seguintes valores:

1  $\rightarrow$  se todos os ângulos de  $T$  são agudos.

2  $\rightarrow$  se algum dos ângulos é obtuso.

0  $\rightarrow$  se não existe triângulos com esses comprimentos de lados.

## 5. Considere a simulação MC:

```
som = 0;
for i=1:N
    theta=rand(2,1);
    *****
    som = som + X;
end
x=som/N
```

Quando \*\*\*\*\* é substituído por

```
Y=theta'*theta;
X=Y*Y;
```

$x$  converge a:

- (a)  $12/25$
- (b) 1
- (c)  $16/9$
- (d)  $28/45$
- (e)  $26/35$
- (f) Nenhuma das anteriores

Quando \*\*\*\*\* é substituído por

```
Y=theta(1)+theta(2);
if (Y<0.5) X=1;
```

x converge a:

- (a) 1
- (b) 1/4
- (c) 2
- (d) 4
- (e) 1/8
- (f) Nenhuma das anteriores

6. As condutâncias  $C(1:nc)$  de uma rede hidráulica tomam tres valores possíveis,  $c1$ ,  $c2$  e  $c3$ , aleatoriamente. As probabilidades são 20%, 70% e 10%, respectivamente. O seguinte código gera amostras de  $C$ :

```
function C = geraC(nc,c1,c2,c3)
for k=1:nc
C(k)=c2;
aux=rand();
if (aux < *****) C(k)=c1; end
if (aux > |||) C(k)=c3; end
end
```

O que deve ser escrito em vez de **\*\*\*\*\*** e de **|||**?

7. A função anterior é utilizada na seguinte simulação MC:

```
som = 0;
for i=1:N
C=geraC(nc,c1,c2,c3);
P=ResolveRede(nv,conec,C);
X=1+min(min(sign(P-3),0));
som=som+X;
end
mu=som/N
```

Então, a média  $\mu$  converge para

- (a) o número esperado de nós da rede com pressão superior a 3 bar.
- (b) o número esperado de nós da rede com pressão inferior a 3 bar.
- (c) a probabilidade de haver algum nó da rede com pressão superior a 3 bar.
- (d) a probabilidade de não haver nenhum nó da rede com pressão superior a 3 bar.
- (e) duas das anteriores são verdadeiras.
- (f) todas as anteriores são falsas.

8. Na integração Monte Carlo de uma certa função se sabe que, para conseguir **dois dígitos significativos** confiáveis, são necessárias no mínimo **1500** amostras (ou iterações). Então, para conseguir **quatro dígitos** confiáveis, quantas serão necessárias?

9. Responder com verdadeiro ou falso:

- (a) Para um sistema de equações  $A\mathbf{x} = \mathbf{b}$ ,  $A \in \mathbb{R}^{n \times n}$  que admite solução única se verifica que as linhas de  $A$  são linearmente dependentes.
- (b) Para um sistema de equações  $A\mathbf{x} = \mathbf{b}$ ,  $A \in \mathbb{R}^{n \times n}$  que admite solução única se verifica que  $A\mathbf{x} = 0$  se e só se  $\mathbf{x} = 0$ .

- (c) Se premultiplicar (ou seja, multiplicar a esquerda) uma matriz  $A$  por uma matriz de permutação  $P$ , então o resultado será uma matriz com as mesmas linhas que  $A$ , mas numa ordem diferente.
- (d) Uma matriz de permutação, obtida trocando a ordem apenas de duas linhas da matriz identidade, é simétrica.
- (e) Conhecida a fatoração  $LU$  de  $A$ , podemos calcular o determinante dela como  $\det(A) = \det(L)$ .
- (f) Uma vez calculada a fatoração  $LU$  de uma matriz  $A \in \mathbb{R}^{n \times n}$ , o determinante dela pode ser calculado fazendo

```
for i=1:n
det=1;
det=det*U(i,i);
end
```

- (g) O custo computacional de calcular o produto escalar de dois vetores é de ordem  $\mathcal{O}(n^2)$ .
- (h) O custo computacional de calcular o produto de uma matriz por um vetor é de ordem  $\mathcal{O}(n^3)$ .
- (i) O custo computacional de calcular a fatoração  $LU$  de uma matriz,  $A \in \mathbb{R}^{n \times n}$  é proporcional  $n^3$ .
- (j) O custo computacional de aplicar o método de substituição progressiva (Forward substitution) para resolver um sistema triangular inferior de  $n \times n$  é proporcional a  $n$ .
- (k) Uma vez obtida a fatoração  $LU$  de uma matriz  $A \in \mathbb{R}^{n \times n}$ , para resolver qualquer sistema da forma

$$A\mathbf{x} = \mathbf{b}$$

são necessárias  $\mathcal{O}(n)$  operações.

- (l) O pivotamento ajuda na precisão reduzindo o erro de arredondamento.
- (m) Sabemos que na fatoração  $LU$  com pivotamento, são calculadas matrizes  $P$ ,  $L$  e  $U$  tais que  $PA = LU$ . Ainda, a matriz de permutação  $P$  é sempre simétrica.
- (n) Sabemos que na fatoração  $LU$  com pivotamento, são calculadas matrizes  $P$ ,  $L$  e  $U$  tais que  $PA = LU$ . Ainda, os elementos da matriz de permutação  $P$  são 0 ou 1.
- (o) Se uma matriz tem determinante negativo, então ela não pode ser fatorada da forma

$$A = HH^T$$

- (p) O custo computacional de calcular a fatoração de Cholesky para uma matriz  $A \in \mathbb{R}^{n \times n}$  é proporcional a  $n^3$  (i.e.,  $\#flops \sim Cn^3$ ). Essa constante  $C$  é menor que no caso da fatoração  $LU$ .
- (q) A decomposição de Cholesky pode ser aplicada a qualquer matriz simétrica.

10. Seja  $D \in \mathbb{R}^{m \times N}$  uma matriz de dados ( $m \gg 1$ ). A quantidade representada numa coluna  $i$  qualquer será chamada de  $d_i$  (e.g., superfície, preço, etc.). Diga se é verdadeiro ou falso que cada um dos seguintes códigos Octave ajustam a coluna  $\mathbf{k}$  como um polinômio de segundo grau da coluna  $\mathbf{j}$  e calculam o valor do ajuste no

valor  $d_j = a$ . Os códigos podem ser errados por dar o resultado errado ou por conter erros de programação.

O ajuste desejado é por quadrados mínimos, com o produto escalar usual. Os dados de entrada são  $m$ ,  $D$ ,  $j$ ,  $k$ , e  $a$ . O valor do ajuste deve estar na variável de saída  $val$ .

```
A=[ones(m,1),D(:,j),D(:,j).*D(:,j)];
b=D(:,k);
x=A\b;
val=1+a*x+a^2*x^2;
```

```
A=[ones(m,1),D(:,j),D(:,j).*D(:,j)];
z=[1,a,a^2]';
b=D(:,k);
x=A\b;
val=z'*x;
```

```
A=[D(:,j)-1,D(:,j)+1,...
D(:,j).*D(:,j)];
z=[a-1,a+1,a^2]';
b=D(:,k);
x=A\b;
val=z'*x;
```

11. Se sabe que as colunas 1, 2 e 3 de  $D$  são ortonormais. Se deseja calcular a distância (euclidiana usual) da coluna  $k$  ao espaço gerado pelas colunas 1, 2 e 3.

Para isto, se desenvolveu o seguinte código:

```
A=D(:,1:3);
b=D(:,k);
v=A'*b;
p=A*v;
val=norm(*****);
```

Que deve ser programado em **\*\*\*\*\*** para que  $val$  tenha o valor desejado?

12. Indique se Verdadeiro ou Falso, sendo que  $A \in \mathbb{R}^{m \times n}$  com  $m \geq n$ :

- (a) Para que existam  $Q \in \mathbb{R}^{m \times m}$  ortogonal e  $R \in \mathbb{R}^{m \times n}$  triangular superior tais que

$$A = QR$$

é necessário que  $A$  seja de posto completo ( $\text{rank}(A) = n$ ).

- (b) É suficiente que  $A$  seja de posto completo para que as últimas  $m - n$  colunas de  $Q$  sejam base de  $\text{Im}(A)^\perp$ .
- (c) É suficiente que  $A$  seja de posto completo para que as últimas  $m - n$  colunas de  $Q$  sejam base de  $\text{Nu}(A^T)$ .
- (d) Se as colunas de  $A$  já são ortonormais, então  $Q = A$ , mesmo que  $\text{rank}(A) = k < n$ .

13. Considere o algoritmo geral para resolver o sistema

$$A \mathbf{x} = \mathbf{b}$$

Dados  $\mathbf{x}^{(0)}$ ,  $TOL$ ,  $MAX\_IT$ ,  $k = 0$

Enquanto  $\|\mathbf{r}^{(k)}\| > TOL$  e  $k < MAX\_IT$

- (a) Resolver  $M \mathbf{d}^{(k+1)} = -\mathbf{r}^{(k)}$
- (b) Determinar o escalar  $\beta_{k+1}$
- (c) Avançar:  $\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} + \beta_{k+1} \mathbf{d}^{(k+1)}$
- (d) Calcular residual:  $\mathbf{r}^{(k+1)} = A \mathbf{x}^{(k+1)} - \mathbf{b}$
- (e) Incrementar  $k$

Fim

Responder com verdadeiro (V) ou Falso (F):

- (a) O algoritmo converge mais rapidamente quanto mais parecida seja a matriz  $M$  do método com a matriz  $A^{-1}$ .
- (b) O algoritmo converge mais rapidamente quanto mais parecida seja a matriz  $M$  do método com a matriz  $A$ .
- (c) Com a escolha de  $M = A$  e  $\beta_k = 1 \forall k$ , o algoritmo converge em uma iteração.
- (d) Dado um sistema linear e um método iterativo correspondente a uma certa escolha da matriz  $M$  e  $\beta_k = 1 \forall k$ , a convergência do método só depende de que o raio espectral da matriz  $S = \mathbb{I} - A M^{-1}$  seja menor do que 1.
- (e) Dado um sistema linear e um método iterativo correspondente a uma certa escolha da matriz  $M$  e  $\beta_k = 1 \forall k$ , a convergência do método depende de que o raio espectral da matriz  $S = \mathbb{I} - A M^{-1}$  seja menor do que 1 e da escolha para o chute inicial  $\mathbf{x}^{(0)}$ .
- (f) Considerando  $\beta_k = 1 \forall k$ , no passo  $(k + 1)$  do método podemos escrever  $\mathbf{x}^{(k+1)} = B \mathbf{x}^{(k)} + \mathbf{g}$ , sendo  $B = \mathbb{I} - M^{-1} A$  e  $\mathbf{g} = M^{-1} \mathbf{b}$ . A condição para a convergência é que o raio espectral de  $B$  seja menor do que 1.
- (g) O método de Jacobi converge para qualquer matriz simétrica que possui pelo menos um autovalor positivo.
- (h) Para o sistema

$$a_{11} x_1 + a_{12} x_2 + a_{13} x_3 = b_1$$

$$a_{21} x_1 + a_{22} x_2 + a_{23} x_3 = b_2$$

$$a_{31} x_1 + a_{32} x_2 + a_{33} x_3 = b_3$$

o método de Jacobi pode-se escrever como

$$x_1^{(k+1)} = \frac{1}{a_{11}} \left( b_1 - a_{12} x_2^{(k)} - a_{13} x_3^{(k)} \right)$$

$$x_2^{(k+1)} = \frac{1}{a_{22}} \left( b_2 - a_{21} x_1^{(k+1)} - a_{23} x_3^{(k)} \right)$$

$$x_3^{(k+1)} = \frac{1}{a_{33}} \left( b_3 - a_{31} x_1^{(k+1)} - a_{32} x_2^{(k+1)} \right)$$

- (i) Partindo do mesmo ponto inicial  $\mathbf{x}^{(0)}$ , o método de Jacobi vai calcular o mesmo segundo ponto  $\mathbf{x}^{(1)}$  para os dois sistemas seguintes,

$$\begin{cases} 2x_1 + x_2 = 3 \\ 3x_1 - x_2 = 5 \end{cases}, \quad \begin{cases} 3x_1 - x_2 = 5 \\ 2x_1 + x_2 = 3 \end{cases}$$

que são obviamente equivalentes.


- (j) O método de Jacobi é um caso particular do algoritmo geral, com  $M$  igual à parte diagonal de  $A$  e  $\beta_k = 1 \forall k$ .
- (k) O método de Jacobi converge para matrizes simétricas e definidas positivas de  $2 \times 2$ .
- (l) Para as matrizes estritamente diagonais dominantes por linha, o método de Gauss-Seidel nunca converge.

14. Considerar o sistema de equações

$$\begin{cases} 2x_1 + x_2 = 3 \\ \alpha x_1 + 3x_2 = 3 + \alpha \end{cases}$$

$\alpha \in \mathbb{R}$ , que será resolvido pelo método iterativo geral com  $M$  sendo a diagonal da matriz do sistema e  $\beta_k = 1 \forall k$ . O método é convergente se o só se:

- $\alpha < 10$
- $|\alpha| > 10$
- $\alpha < -6$
- $|\alpha| < 6$
- $\alpha = 6.1$
- Nenhum dos anteriores.



15. No diagrama da Figura se observam três massas ( $m_A$ ,  $m_B$ ,  $m_C$ ) e três molas (1, 2, 3) de constantes e comprimentos relaxados  $k_i$ ,  $\ell_i$ ,  $i = 1, 2, 3$ .

*Lembrete 1:* A energia elástica de uma mola é  $k \Delta \ell^2 / 2$ , onde  $\Delta \ell$  é a variação de comprimento respeito do estado relaxado. A tensão na mola é  $k \Delta \ell$ . A energia gravitacional de uma massa  $m$ , é  $m g (x_0 - x)$ , sendo  $x$  a coordenada vertical (positiva para baixo),  $x_0$  uma posição de referência arbitrária, e  $g$  a aceleração da gravidade.

*Lembrete 2:* Definindo

$$F(x) = (1/2)x^T A x - x^T b$$

e  $r(x) = Ax - b$ , de todos os pontos da forma  $y = x^{(k)} + \beta_k d^{(k)}$ , qualquer que seja a escolha de  $d^{(k)}$ , o valor de  $\beta_k$  que minimiza  $F(y)$  é

$$\beta_k = -\frac{d^{(k)T} r(x^{(k)})}{d^{(k)T} A d^{(k)}}.$$

Seja  $u = (u_A, u_B, u_C)^T$  o vetor de deslocamentos (verticais) das massas respeito da configuração de referência

(todas as molas com comprimento relaxado). Determinar uma matriz  $A$  tal que a energia elástica do sistema se escreva

$$E_{\text{elas}} = \frac{1}{2} u^T A u.$$

Determinar um vetor  $b \in \mathbb{R}^3$  tal que a energia gravitacional se escreva

$$E_{\text{grav}} = -u^T b.$$

Considerando  $m_A = 3$ ,  $m_B = 2$ ,  $m_C = 1$ ,  $g = 1$ ,  $k_1 = k_2 = k_3 = 10$ , calcule o gradiente (como vetor coluna) da energia total

$$E = E_{\text{elas}} + E_{\text{grav}}$$

na configuração  $\bar{u} = (1, 1, 0)$  (massas A e B deslocadas uma unidade para baixo, massa C na posição de referência).

16. Seja  $A$  uma matriz  $n \times n$  que tem  $n$  autovalores distintos,  $\lambda_1, \dots, \lambda_n$ , satisfazendo  $|\lambda_i| \neq |\lambda_j|$  sempre que  $i \neq j$ . Suponha os autovalores ordenados de maneira que  $|\lambda_1| > |\lambda_2| > \dots > |\lambda_n|$ . Os correspondentes autovetores são  $v^{(1)}, v^{(2)}$ , etc., são normalizados na norma euclidiana ( $\|z\| = \sqrt{z^T z}$ ). Dizer se verdadeiro ou falso:

- A matriz  $A$  é diagonalizável.
- A matriz  $A - \lambda_1 I$  é diagonalizável.
- O método das potências aplicado à matriz  $A^{-1}$  permite obter  $1/\lambda_n$ .
- O método das potências *inversas* aplicado à matriz  $A$  permite obter  $\lambda_n$ .
- O método das potências aplicado à matriz  $A$  convergirá mais rápido quanto menor seja o cociente  $|\lambda_2/\lambda_1|$ .
- O método das potências, com  $B = A$ , convergirá mais rapidamente que com  $B = A^2$ .
- A matriz  $A - \lambda_1 I$  tem autovalores  $0, \lambda_2 - \lambda_1, \lambda_3 - \lambda_1, \dots, \lambda_n - \lambda_1$ .

17. Seja  $\underline{A}$  uma matriz  $4 \times 4$  cujos autovalores são 1, 2, 3 e 4. Então, começando com um vetor  $\underline{x}^{(0)}$  escolhido aleatoriamente, e aplicando o método das potências à matriz  $\underline{B} = (\underline{A} + 2 \underline{I})^{-1}$ , a sequência dos  $\lambda^{(k)}$  convergirá para que valor?

18. Seja  $A$  uma matriz  $n \times n$  conhecida. Começando com um vetor  $\underline{x}^{(0)}$  escolhido aleatoriamente, e aplicando o método das potências à matriz  $B = (A - 0.2 I)^{-1}$ , a sequência dos  $\lambda^{(k)}$  converge para 5. Então é possível concluir que:

- 5 é autovalor de  $A$ .
- 1/5 é autovalor de  $A$ .
- 2/5 é autovalor de  $A$ .
- 0 é autovalor de  $A$ .
- $A$  não tem autovalores positivos menores que 1/5.
- $A$  não tem autovalores positivos menores que 2/5.
- $A$  não tem autovalores positivos menores que 4/5.

19. O logaritmo de uma matriz  $A$  de  $n \times n$  simétrica e definida positiva se define da seguinte maneira: Se

$$A = S \Lambda S^{-1}$$

com  $\Lambda = \text{diag}(\lambda_1, \dots, \lambda_n)$ . Então

$$\log(A) = S \log(\Lambda) S^{-1},$$

onde  $\log(\Lambda) = \text{diag}(\log(\lambda_1), \dots, \log(\lambda_n))$ .

Os comandos de Octave relacionados são `eig` e `log`.

-- Built-in Function: `[V, LAMBDA] = eig(A)`  
 Compute the eigenvalues and eigenvectors of a matrix.

Eigenvectors: Columns of V  
 Eigenvalues: Diagonal elements of LAMBDA

-- Mapping Function: `log(X)`  
 Compute the natural logarithm, 'ln(X)', for each element of X.

Indicar quais dos seguintes programas Octave calculam  $B = \log(A)$  (podem ser zero, um ou vários):

- `B = log(A)`
- `[S D]=eig(A);`  
`B=log(S)*log(D);`
- `[S D]=eig(A);`  
`LD=log(D);`  
`B=S*LD*inv(S)`
- `[S D]=eig(A);`  
`B=inv(S)*log(D)*S`
- `[S D]=eig(A);`  
`lam=diag(D);`  
`eD=diag(log(lam));`  
`B=S*eD*S'`
- `[S D]=eig(A);`  
`lam=diag(D);`  
`eD=diag(log(lam));`  
`B=S*eD*inv(S)`

20. O quociente de Rayleigh  $r(v)$ , sendo  $v$  vetor (coluna) de  $\mathbb{R}^n$  e matrizes  $K$  simétrica e  $M$  simétrica definida positiva, se define como

$$r(v) = \frac{v^T K v}{v^T M v}.$$

Mantendo  $v$ ,  $K$  e  $M$  fixos, pode se provar que  $r(v)$  minimiza a função

$$J(\mu) = (Kv - \mu Mv)^T G (Kv - \mu Mv)$$

para uma certa matriz  $G$ . Quem é essa matriz  $G$ ?

- $G = M^{-1}$
- $G = M$
- $G = K$
- $G = KM$
- $G = K^{-1}$
- $G = I$  (identidade)
- $G = M^{-1}K$

(h)  $G = K^{-1}M$

(i) Nenhuma das anteriores

Comentário: Notar que

$$J(\mu) = \|Kv - \mu Mv\|_G^2$$

onde a norma  $\|\cdot\|_G$  vem do produto escalar  $\langle x, y \rangle = x^T G y$ . Nessa norma,  $r(v)$  é o valor de  $\mu$  que faz  $\mu Mv$  ser o mais próximo possível de  $Kv$ .

21. Sejam as matrizes  $K$  simétrica e  $M$  simétrica e definida positiva. Sejam  $v^i$  e  $\lambda_i$  os autovalores e autovetores generalizados satisfazendo

$$K v^i = \lambda_i M v^i.$$

Os autovetores estão normalizados para satisfazer

$$(v^j)^T M v^i = \begin{cases} 1 & \text{se } i = j \\ 0 & \text{se } i \neq j \end{cases}$$

Com eles formamos as seguintes matrizes:

- $\Lambda = \text{diag}(\lambda_1, \dots, \lambda_n)$ .
- $V =$  matriz cujas colunas são os autovetores  $\{v^i\}$ .

Essas matrizes permitem estabelecer a decomposição generalizada seguinte (notar a semelhança com a decomposição usual  $A = SDS^{-1}$ ):

$$K = MV\Lambda V^{-1} \quad (1)$$

Indicar as seguintes afirmações são Verdadeiras ou Falsas:

- $KV = MV\Lambda$ .
- $KV = \Lambda MV$ .
- $K = \Lambda M$ .
- $V^T V = I$ .
- $V^T M V = I$ .
- $V^T M V = \Lambda$ .
- $V^T K V = \Lambda$ .
- $V^T K V = I$ .
- $M^{-1}K = V\Lambda V^{-1}$ .
- $\det(K - \lambda_i M) = 0 \quad \forall i = 1, \dots, n$ .
- $\det(M^{-1}K - \lambda_i I) = 0 \quad \forall i = 1, \dots, n$ .
- $\det(V) = 1$ .

22. Dizer se verdadeiro ou falso:

- As linhas de  $V$  são vetores singulares esquerda de  $A$ .
- As colunas de  $V$  são vetores singulares direita de  $A$ .
- As colunas de  $U$  são vetores singulares esquerda de  $A$ .
- As colunas de  $U$  são vetores singulares direita de  $A$ .
- As linhas de  $U$  são vetores singulares esquerda de  $A$ .
- As linhas de  $U$  são vetores singulares direita de  $A$ .

(g) As colunas de  $V$  são vetores singulares esquerda de  $A$ .

(h) As linhas de  $V$  são vetores singulares direita de  $A$ .

---

23. Denotemos por  $u_i$  a coluna número  $i$  de  $U$ , e por  $v_i$  a coluna número  $i$  de  $V$ . Dizer se verdadeiro ou falso:

(a)  $u_i^T v_j = 0$  if  $i \neq j$ .

(b)  $v_i^T v_j = 0$  if  $i \neq j$ .

(c)  $u_i^T u_j = 0$  if  $i \neq j$ .

(d)  $u_i^T A v_j = 0$  if  $i \neq j$ .

(e)  $v_i^T A u_j = 0$  if  $i \neq j$ .

(f)  $v_i^T A^T u_j = 0$  if  $i \neq j$ .

(g)  $u_i^T A^T v_j = 0$  if  $i \neq j$ .

---

24. Denotamos por  $A^\dagger$  a pseudoinversa de  $A$ , cuja decomposição SVD é  $A = U\Sigma V^T$ . Dizer se verdadeiro ou falso:

(a)  $AA^\dagger A = A$

(b)  $A^\dagger A = AA^\dagger$

(c)  $A^\dagger AA^\dagger = A^\dagger$

(d)  $A^\dagger AA^\dagger = A$

(e)  $(AA^\dagger)^T = AA^\dagger$

(f)  $A^T A^\dagger = A^\dagger A$

(g)  $(A^\dagger A)^T = A^\dagger A$

(h)  $A^\dagger A^T = (A^\dagger)^T A$

(i)  $A^T A = V\Sigma^2 V^T$

(j)  $A^T A = U\Sigma^2 U^T$

(k)  $AA^T = U\Sigma^2 U^T$

(l)  $AA^T = U\Sigma^2 U^T$

---

Boa prática, boa prova, e **boas férias !!**