

## MATRIZES E VETORES

### 1) CONCEITOS BÁSICOS

Os cálculos/operações assim como conceitos envolvendo matrizes e vetores constituem a base dos métodos numéricos que tratam da solução de sistemas lineares e não lineares de equações algébricas ou diferenciais. A representação destes sistemas em termos matriciais/vetoriais é extremamente mais compacta e é corrente na literatura técnica. Como visa-se neste curso apresentar os conceitos básicos deste assunto especialmente relacionados com aplicações em Engenharia Química, os elementos de matrizes e vetores serão em princípio números ou variáveis reais a não ser quando explicitamente especificados como complexos.

Uma matriz é um arranjo retangular de números em  $m$  linhas e  $n$  colunas,  $m \times n$ , sendo representada como  $\mathbf{A}$  (letras maiúsculas em negrito) pertencente a  $\mathfrak{R}^{m \times n}$ , isto é:  $\mathbf{A} \in \mathfrak{R}^{m \times n}$ . O elemento da linha  $i$  e coluna  $j$  de  $\mathbf{A}$  é representado por  $a_{ij}$  (correspondente letra minúscula com o sub-índice  $ij$ ) ou  $(\mathbf{A})_{ij}$ . A matriz completa é geralmente escrita na

$$\text{forma: } \mathbf{A} = \begin{pmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{m1} & a_{m2} & \cdots & a_{mn} \end{pmatrix} \text{ ou,}$$

em forma mais compacta, por:  $\mathbf{A} = (a_{ij})$  com  $i = 1, \dots, m$  e  $j = 1, \dots, n$ . Se duas matrizes  $\mathbf{A}$  e  $\mathbf{B}$  apresentam o mesmo número de linhas e o mesmo número de colunas são ditas do mesmo tipo.

Se  $\mathbf{A} = (a_{ij})$  é tal que  $a_{ij} = 0$  para todo  $i$  e  $j$  então a matriz  $\mathbf{A}$  é dita nula e é representada por  $\mathbf{0}$ .

Se  $n=m$  a matriz  $\mathbf{A}$  é dita quadrada.

Se  $n=m$  e  $a_{ij} = a_{ji}$  para  $i, j = 1, \dots, n$  a matriz quadrada  $\mathbf{A}$  é dita simétrica.

Se  $n=1$  tem-se um vetor coluna ou simplesmente vetor designado por  $\mathbf{v}$  (letra minúscula em

negrito) e representado por:  $\mathbf{v} = \begin{pmatrix} v_1 \\ v_2 \\ \vdots \\ v_m \end{pmatrix} \in \mathfrak{R}^m$

Se  $m=1$  tem-se um vetor linha designado por  $\mathbf{v}^T$  (letra minúscula em negrito com o sobre-índice T de transposto) e representada por:  $\mathbf{v}^T = (v_1 \ v_2 \ \cdots \ v_n) \in \mathfrak{R}^{1 \times n}$

Se  $m=n=1$  tem-se um escalar (real)  $\alpha$  (letra minúscula grega), ou seja:  $\alpha \in \mathfrak{R}$ .

A matriz  $\mathbf{A} \in \mathfrak{R}^{m \times n}$  pode ser particionada por:

a) Colunas na forma:

$$\mathbf{A} = (\mathbf{a}_1 \quad \mathbf{a}_2 \quad \vdots \quad \mathbf{a}_n) \text{ onde } \mathbf{a}_j = \begin{pmatrix} a_{1j} \\ a_{2j} \\ \vdots \\ a_{mj} \end{pmatrix} \in \mathfrak{R}^m \text{ para } j = 1, \dots, n \text{ são os } n \text{ vetores$$

colunas da matriz  $\mathbf{A}$ ;

b) Linhas na forma:

$$\mathbf{A} = \begin{pmatrix} \mathbf{a}_1^T \\ \mathbf{a}_2^T \\ \vdots \\ \mathbf{a}_m^T \end{pmatrix} \text{ onde } \mathbf{a}_i^T = (a_{i1} \quad a_{i2} \quad \dots \quad a_{in}) \in \mathfrak{R}^{1 \times n} \text{ para } i = 1, \dots, m \text{ são os } m \text{ vetores$$

linhas da matriz  $\mathbf{A}$ .

## 2) OPERAÇÕES ENTRE MATRIZES

As operações de adição ou subtração são definidas apenas para matrizes do mesmo tipo, assim se  $\mathbf{A}$  e  $\mathbf{B}$  são matrizes  $(m \times n)$  então a matriz  $\mathbf{C}$ , também  $(m \times n)$ , soma ou subtração de  $\mathbf{A}$  com  $\mathbf{B}$ , representada por  $\mathbf{C} = \mathbf{A} \pm \mathbf{B}$ , tem como termo geral :

$$c_{ij} = a_{ij} \pm b_{ij} \text{ para } i = 1, \dots, m \text{ e } j = 1, \dots, n.$$

Se  $\alpha$  é um escalar qualquer, a matriz  $\alpha \mathbf{A}$  é uma matriz cujo termo geral é  $\alpha a_{ij}$ .

A operação de multiplicação de matrizes está intimamente relacionada a transformações de coordenadas. Assim sejam as seguintes *transformações lineares*:

$$z_i = \sum_{j=1}^n a_{ij} y_j \text{ para } i = 1, \dots, m \text{ e } y_j = \sum_{k=1}^p b_{jk} x_k \text{ para } j = 1, \dots, m.,$$

expressando  $z_i$  em termos de  $x_k$ , por substituição tem-se:

$$z_i = \sum_{j=1}^n a_{ij} \left( \sum_{k=1}^p b_{jk} x_k \right) = \sum_{k=1}^p \left( \sum_{j=1}^n a_{ij} \cdot b_{jk} \right) \cdot x_k$$

definindo:  $c_{ik} = \sum_{j=1}^n a_{ij} \cdot b_{jk}$  tem-se:  $z_i = \sum_{k=1}^p c_{ik} \cdot x_k$ , o que induz à definição da matriz:

$\mathbf{C} = \mathbf{A} \cdot \mathbf{B}$  onde  $\mathbf{A}$  é  $(m, n)$ ,  $\mathbf{B}$  é  $(n, p)$  e  $\mathbf{C}$  é  $(m, p)$  que apresenta como termo geral:

$$c_{ik} = \sum_{j=1}^n a_{ij} \cdot b_{jk} \text{ para } i = 1, \dots, m \text{ e } k = 1, \dots, p. \text{ Verificando-se assim que a operação } \mathbf{A} \cdot \mathbf{B} \text{ só}$$

é definida se o número de colunas de  $\mathbf{A}$  (primeira parcela do produto) for igual ao número de linhas de  $\mathbf{B}$  (segunda parcela do produto). É importante ressaltar que a lei de comutatividade não é satisfeita pelo produto entre matrizes, mesmo que  $\mathbf{B} \cdot \mathbf{A}$  seja definida, isto é  $m=p$  e mesmo que  $\mathbf{B} \cdot \mathbf{A}$  seja do mesmo tipo que  $\mathbf{A} \cdot \mathbf{B}$ , o que só ocorrerá se  $m=p=n$  (isto é ambas as matrizes são quadradas e de mesma dimensão), assim de uma forma geral tem-se:  $\mathbf{A} \cdot \mathbf{B} \neq \mathbf{B} \cdot \mathbf{A}$ .

Se a primeira parcela do produto é um vetor linha  $\mathbf{u}^T (1,n)$  e a segunda parcela é um vetor coluna  $\mathbf{v} (n,1)$  então o produto  $\mathbf{u}^T \cdot \mathbf{v}$  é um escalar:  $\mathbf{u}^T \cdot \mathbf{v} = \sum_{j=1}^n u_j \cdot v_j$  que é comutável, isto é  $\mathbf{u}^T \cdot \mathbf{v} = \mathbf{v}^T \cdot \mathbf{u}$ . Este produto é chamado de produto escalar de dois vetores.

Se  $\mathbf{A}$  é uma matriz  $(m,n)$  e  $\mathbf{v}$  um vetor  $(n,1)$  então o produto  $\mathbf{A} \cdot \mathbf{v}$  é um vetor  $\mathbf{u} (m,1)$  cujo termo geral é:  $u_i = \sum_{j=1}^n a_{ij} v_j$  para  $i = 1, \dots, m$ . Este produto pode ser efetuado de duas formas distintas:

(a) por linhas (método **ij**) considerando a partição por linhas da matriz  $\mathbf{A}$ , isto é:  $\mathbf{A} = \begin{pmatrix} \mathbf{a}_1^T \\ \mathbf{a}_2^T \\ \vdots \\ \mathbf{a}_m^T \end{pmatrix}$ ,

então:  $\mathbf{A} \cdot \mathbf{v} = \begin{pmatrix} \mathbf{a}_1^T \cdot \mathbf{v} \\ \mathbf{a}_2^T \cdot \mathbf{v} \\ \vdots \\ \mathbf{a}_m^T \cdot \mathbf{v} \end{pmatrix}$ , isto é o elemento  $i$  de  $\mathbf{u}$  é dado por  $u_i = \mathbf{a}_i^T \cdot \mathbf{v}$  para  $i = 1, \dots, m$ , que é

o produto escalar do vetor composto pelos elementos da linha  $i$  da matriz  $\mathbf{A}$  com o vetor  $\mathbf{u}$ .

(b) por colunas (método **ji**): considerando a partição por colunas de  $\mathbf{A}$ , isto é:  $\mathbf{A} = (\mathbf{a}_1 \ \mathbf{a}_2 \ \vdots \ \mathbf{a}_n)$ , então:

$\mathbf{u} = \mathbf{A} \cdot \mathbf{v} = (\mathbf{a}_1 \ \mathbf{a}_2 \ \vdots \ \mathbf{a}_n) \cdot \begin{pmatrix} v_1 \\ v_2 \\ \vdots \\ v_n \end{pmatrix} = v_1 \cdot \mathbf{a}_1 + v_2 \cdot \mathbf{a}_2 + \dots + v_n \cdot \mathbf{a}_n = \sum_{i=1}^n v_i \cdot \mathbf{a}_i$ , isto é o vetor  $\mathbf{u}$  é

uma combinação linear dos vetores coluna de  $\mathbf{A}$  sendo os coeficientes desta combinação os elementos do vetor  $\mathbf{v}$ .

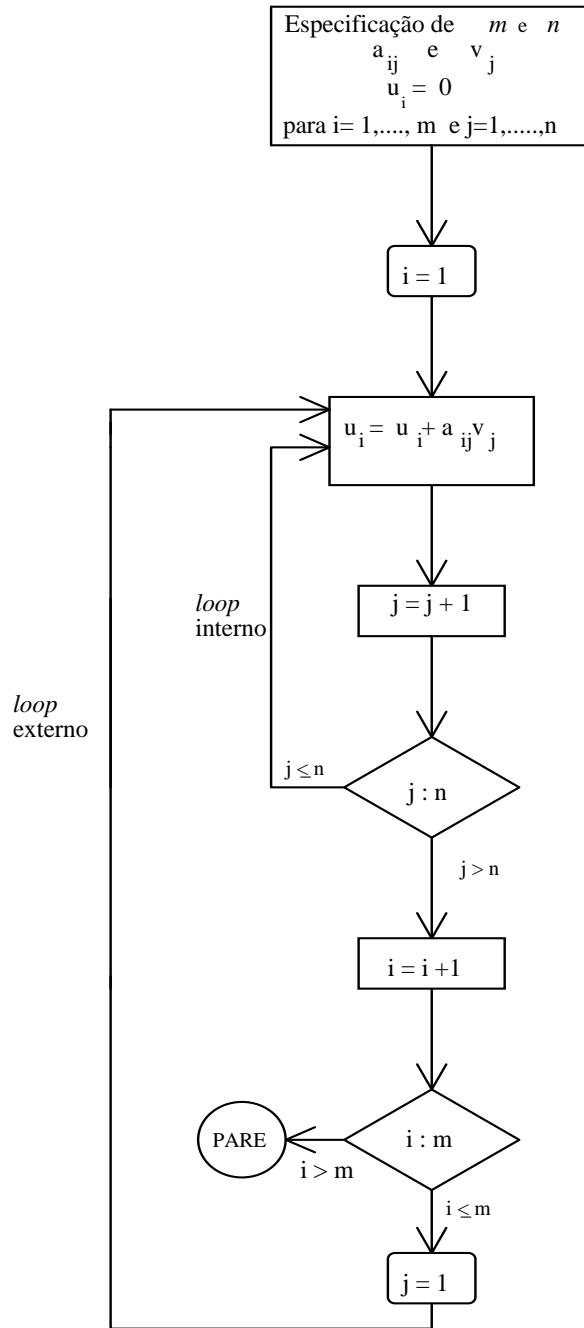
Exemplo Ilustrativo  $\mathbf{A} = \begin{pmatrix} 1 & 2 \\ 3 & 4 \\ 5 & 6 \end{pmatrix}$ ,  $\mathbf{v} = \begin{pmatrix} 7 \\ 8 \end{pmatrix}$

(a) método **ij**:  $u_1 = (1 \ 2) \cdot \begin{pmatrix} 7 \\ 8 \end{pmatrix} = 1 \cdot 7 + 2 \cdot 8 = 23$ ;  $u_2 = (3 \ 4) \cdot \begin{pmatrix} 7 \\ 8 \end{pmatrix} = 3 \cdot 7 + 4 \cdot 8 = 53$  e

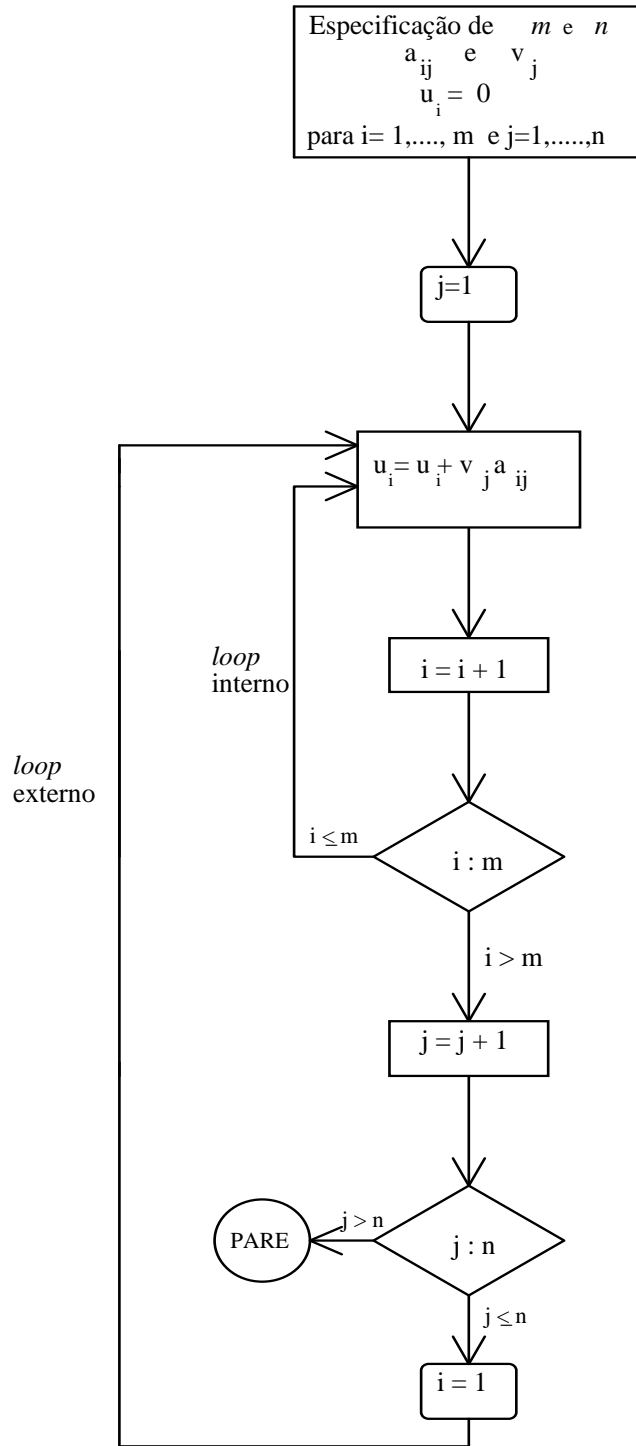
$u_3 = (5 \ 6) \cdot \begin{pmatrix} 7 \\ 8 \end{pmatrix} = 5 \cdot 7 + 6 \cdot 8 = 83$ , logo:  $\mathbf{u} = \begin{pmatrix} 23 \\ 53 \\ 83 \end{pmatrix}$

(b) método **ji**:  $\mathbf{u} = 7 \cdot \begin{pmatrix} 1 \\ 3 \\ 5 \end{pmatrix} + 8 \cdot \begin{pmatrix} 2 \\ 4 \\ 6 \end{pmatrix} = \begin{pmatrix} 23 \\ 53 \\ 83 \end{pmatrix}$ .

A designação dos métodos como **ij** e como **ji** deve-se à forma como os *loops* de programação são efetuados, assim no primeiro método tem-se o seguinte fluxograma:



Note que neste caso o *loop* externo é em **i** (linha) e o *loop* interno é em **j** (coluna).  
 O segundo método é descrito pelo fluxograma:



Note que neste caso o *loop* externo é em **j** (coluna) e o *loop* interno é em **i** (linha).

Estes métodos podem também ser ilustrados acompanhando passo a passo o Exemplo Ilustrativo anterior segundo cada um dos algoritmos.

<b>i</b>	1	1	2	2	3	3
<b>j</b>	1	2	1	2	1	2
<b>u<sub>1</sub></b>	7	23	23	23	23	23
<b>u<sub>2</sub></b>	0	0	21	53	53	53
<b>u<sub>3</sub></b>	0	0	0	0	35	83

<b>j</b>	1	1	1	2	2	2
<b>i</b>	1	2	3	1	2	3
<b>u<sub>1</sub></b>	7	7	7	23	23	23
<b>u<sub>2</sub></b>	0	21	21	21	53	53
<b>u<sub>3</sub></b>	0	0	35	35	35	83

A operação de *transposição* de uma matriz  $\mathbf{A}$  ( $m,n$ ) consiste em trocar as linhas pelas colunas de  $\mathbf{A}$ , esta nova matriz é chamada de matriz *transposta* de  $\mathbf{A}$ , representada por  $\mathbf{A}^T$ , e é uma matriz ( $n,m$ ) cujo termo da linha  $j$  e coluna  $i$  é  $a_{ji}^T = a_{ij}$  para  $j = 1, \dots, n$  e  $i = 1, \dots, m$ . Se a matriz  $\mathbf{A}$  é simétrica então:  $\mathbf{A} = \mathbf{A}^T$ .

As propriedades que serão descritas a seguir aplicam-se **exclusivamente** a matriz quadradas ( $n,n$ ) e a vetores coluna ( $n,1$ ) e a vetores linha ( $1,n$ ).

Define-se como matriz identidade a matriz  $\mathbf{I}$  cujo elemento geral é:  
 $(\mathbf{I})_{ij} = \delta_{ij} = \begin{cases} 1 \text{ apenas se } i=j \\ 0 \text{ sempre que } i \neq j \end{cases}$ , onde  $\delta_{ij}$  é chamado de *delta de Kronecker*, deste modo a matriz identidade é uma matriz diagonal cujos termos da diagonal são todos unitários,

assim:  $\mathbf{I} = \begin{pmatrix} 1 & 0 & \dots & 0 \\ 0 & 1 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & 1 \end{pmatrix}$ , entendendo-se como matriz diagonal uma matriz quadrada em

que apenas os elementos da diagonal (também chamada de *diagonal principal*) são não

nulos, geralmente uma matriz diagonal  $\mathbf{D} = \begin{pmatrix} d_1 & 0 & \dots & 0 \\ 0 & d_2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & d_n \end{pmatrix}$  é representada na forma

mais compacta:  $\mathbf{D} = \text{diag}(d_1 \ d_2 \ \dots \ d_n)$ .

Note que toda matriz diagonal é simétrica.

Uma propriedade muito importante da matriz identidade é:  $\mathbf{I} \cdot \mathbf{A} = \mathbf{A} \cdot \mathbf{I} = \mathbf{A}$ , isto é, a matriz identidade pré-multiplicada ou pós-multiplicada por qualquer matriz quadrada de mesma dimensão não altera o valor de elemento algum desta matriz.

Uma matriz diagonal é um caso particular de matrizes dita *esparsas*, que são matrizes que apresentam um grande número de elementos nulos, sendo os elementos não nulos mais a exceção do que a regra. Algumas destas matrizes são apresentadas abaixo:

1) matrizes *tridiagonais* são matrizes que apresentam apenas os elementos da diagonal, os elementos sobre a diagonal e os elementos sob a diagonal não nulos, sendo os demais nulos, assim se  $\mathbf{A}$  é uma matriz tridiagonal então:

$$a_{ij} = \begin{cases} \neq 0 & \text{se } i = j \text{ - diagonal} \\ \neq 0 & \text{se } i = j+1 \text{ (para } i=2,\dots,n\text{)-sob a diagonal} \\ \neq 0 & \text{se } i = j - 1 \text{ (para } i=1,\dots,n-1\text{)- sobre a diagonal} \\ =0 & \text{em qualquer outro caso} \end{cases}$$

2) matrizes *bidiagonais* são matrizes que apresentam apenas os elementos da diagonal e os elementos sobre a diagonal ou sob a diagonal não nulos, no primeiro caso diz-se que a matriz é *bidiagonal superior* e no segundo caso *bidiagonal inferior*.

3) matrizes *triangulares* são matrizes que apresentam todos os elementos sob (ou sobre) a diagonal nulos, sendo neste caso chamada de matriz *triangular superior* ou matriz  $\mathbf{U}$  (ou *triangular inferior* ou matriz  $\mathbf{L}$ ), assim:

$$(\mathbf{U})_{ij} = 0 \text{ se } i > j \text{ e } (\mathbf{L})_{ij} = 0 \text{ se } j > i .$$

Algumas vezes para evitar ambigüidades representa-se a matriz identidade de dimensão  $n$  por  $\mathbf{I}_n$ .

O *traço* de uma matriz quadrada  $\mathbf{A}$  é a soma dos elementos de sua diagonal, isto é:

$$tr(\mathbf{A}) = \sum_{i=1}^n a_{ii} .$$

Uma matriz quadrada  $\mathbf{A}$  é dita *positiva definida* se  $\mathbf{x}^T \cdot \mathbf{A} \cdot \mathbf{x} > 0$  para todo vetor  $\mathbf{x} \neq \mathbf{0}$  (isto é não nulo), caso  $\mathbf{x}^T \cdot \mathbf{A} \cdot \mathbf{x} \geq 0$  a matriz  $\mathbf{A}$  é dita *positiva semi-definida* e se  $\mathbf{x}^T \cdot \mathbf{A} \cdot \mathbf{x} \geq 0$  para alguns vetores  $\mathbf{x} \neq \mathbf{0}$  e se  $\mathbf{x}^T \cdot \mathbf{A} \cdot \mathbf{x} < 0$  para algum vetor  $\mathbf{x} \neq \mathbf{0}$  a matriz  $\mathbf{A}$  é dita *não-definida*. Além disto,  $\mathbf{A}$  é dita *negativa definida* se  $\mathbf{x}^T \cdot \mathbf{A} \cdot \mathbf{x} < 0$  para todo vetor  $\mathbf{x} \neq \mathbf{0}$  e é dita *negativa semi-definida* caso  $\mathbf{x}^T \cdot \mathbf{A} \cdot \mathbf{x} \leq 0$ .

O *determinante* de uma matriz  $\mathbf{A}$  é um escalar obtido através da soma de todos os produtos possíveis envolvendo um elemento de cada linha e cada coluna da matriz, com o sinal positivo ou negativo conforme o número de permutações dos índices seja par ou ímpar. Sua obtenção e sua representação, apesar de ser um dos conceitos mais preliminares envolvendo matrizes, não são tarefas triviais e o conceito de determinante será utilizado nestas notas apenas como base de outras propriedades de matrizes quadradas. Assim, o determinante de  $\mathbf{A}$  designado por  $\det(\mathbf{A})$  pode ser representado por:

$\det(\mathbf{A}) = \sum \pm a_{1,i_1} \cdot a_{2,i_2} \cdots a_{n,i_n}$ , ou então através do conceito de *cofator* do elemento  $ij$  da matriz  $\mathbf{A}$  (representado por  $A_{ij}$ ) que é o determinante da matriz obtida cancelando a linha  $i$  e a coluna  $j$  da matriz  $\mathbf{A}$  com o sinal mais ou menos conforme  $i+j$  seja par ou ímpar, assim:

$A_{ij} = (-1)^{i+j} \cdot \det(\Lambda_{ij})$  onde  $\Lambda_{ij}$  é matriz quadrada  $(n-1, n-1)$  obtida pela eliminação da linha  $i$  e a coluna  $j$  de  $\mathbf{A}$ . Tem-se então:

$$\det(\mathbf{A}) = \sum_{j=1}^n a_{ij} \cdot A_{ij}$$

(expansão do determinante pela linha  $i$ ),

$$\det(\mathbf{A}) = \sum_{i=1}^n a_{ij} \cdot A_{ij}$$

(expansão do determinante pela coluna  $j$ ).

Além disto:  $\sum_{j=1}^n a_{ij} \cdot A_{kj} \equiv 0$  se  $k \neq i$  (pois equivaleria a dizer que a matriz  $\mathbf{A}$  apresenta duas

linhas iguais, no caso as linhas  $i$  e  $k$ ); e  $\sum_{i=1}^n a_{ij} \cdot A_{ik} \equiv 0$  se  $k \neq j$  (pois equivaleria a dizer que a matriz  $\mathbf{A}$  apresenta duas colunas iguais, no caso as colunas  $j$  e  $k$ ).

Na prática, entretanto, é praticamente impossível calcular o determinante de matrizes através destas regras gerais por envolver um número muito grande de termos [na realidade  $n!$ , assim mesmo com matrizes relativamente pequenas como com  $n=10$  tem-se 3 milhões de termos]. Felizmente, para os nossos propósitos, apenas as regras a seguir serão suficientes:

① O determinante de uma matriz  $\mathbf{A}$  mantém-se inalterado se somarem-se a todos os elementos de qualquer linha (ou coluna) os correspondentes elementos de uma outra linha (ou coluna) multiplicados pela mesma constante  $\alpha$ ;

② se  $a_{ij}$  é o único elemento não nulo da linha  $i$  ou da coluna  $j$  então:  $\det(\mathbf{A}) = a_{ij} \cdot A_{ij}$ ;

③ se  $\mathbf{A} = \begin{pmatrix} a & b \\ c & d \end{pmatrix}$  então:  $\det(\mathbf{A}) = \begin{vmatrix} a & b \\ c & d \end{vmatrix} = a \cdot d - b \cdot c$ .

Da regra ① verifica-se que se  $\det(\mathbf{A}) = 0$  então  $\mathbf{A}$  apresenta duas linhas (ou colunas) proporcionais entre si, ou ainda, de uma forma mais geral, pode-se afirmar que uma linha (ou coluna) de  $\mathbf{A}$  pode ser escrita como combinação linear de alguma ou algumas linhas (ou colunas) da mesma matriz. Da regra ② demonstra-se que se  $\mathbf{A}$  for uma matriz triangular então  $\det(\mathbf{A})$  é simplesmente o produto dos elementos de sua diagonal (note que o mesmo vale para matrizes bidiagonais que são também matrizes triangulares).

Se  $\det(\mathbf{A}) = 0$  diz-se que a matriz  $\mathbf{A}$  é singular, e caso  $\det(\mathbf{A}) \neq 0$  então  $\mathbf{A}$  é dita regular.

Se  $\mathbf{C} = \mathbf{A} \cdot \mathbf{B}$  então  $\det(\mathbf{C}) = \det(\mathbf{A}) \cdot \det(\mathbf{B})$ .

Se  $\mathbf{B} = \mathbf{A}^T$  então  $\det(\mathbf{B}) = \det(\mathbf{A})$ , isto é  $\det(\mathbf{A}^T) = \det(\mathbf{A})$

A matriz adjunta de uma matriz  $\mathbf{A}$  é a matriz transposta da matriz obtida substituindo cada elemento da matriz  $\mathbf{A}$  pelo seu correspondente cofator, isto é se  $\tilde{\mathbf{A}}$  é a matriz adjunta de  $\mathbf{A}$  então o elemento da linha  $i$  e coluna  $j$  de  $\tilde{\mathbf{A}}$  é  $A_{ji}$ . A propriedade mais importante da matriz adjunta diz respeito aos produtos:  $\mathbf{P} = \mathbf{A} \tilde{\mathbf{A}}$  e  $\mathbf{Q} = \tilde{\mathbf{A}} \mathbf{A}$  o primeiro

produto tem com termo geral:  $p_{ij} = \sum_{k=1}^n a_{ik} \cdot \tilde{a}_{kj} = \sum_{k=1}^n a_{ik} \cdot A_{jk} = \det(\mathbf{A}) \delta_{ij}$



e o segundo produto:  $q_{ij} = \sum_{k=1}^n \tilde{a}_{ik} \cdot a_{kj} = \sum_{k=1}^n A_{ki} \cdot a_{kj} = \det(A) \delta_{ij}$ , assim:

$\mathbf{A} \cdot \tilde{\mathbf{A}} = \tilde{\mathbf{A}} \cdot \mathbf{A} = \det(\mathbf{A}) \mathbf{I}$ . Deste modo se  $\det(\mathbf{A}) \neq 0$  ( $\mathbf{A}$  é regular) define-se:

$\mathbf{A}^{-1} = \frac{1}{\det(\mathbf{A})} \cdot \tilde{\mathbf{A}}$  a chamada *inversa* de  $\mathbf{A}$  que tem como propriedade:

$\mathbf{A} \cdot \mathbf{A}^{-1} = \mathbf{A}^{-1} \cdot \mathbf{A} = \mathbf{I}$  que existe apenas se  $\det(\mathbf{A}) \neq 0$ . Note que  $\det(\mathbf{A}^{-1}) = \frac{1}{\det(\mathbf{A})}$

**Exemplo Ilustrativo:** Considere a seguinte matriz (2x2):

$$\mathbf{A} = \begin{pmatrix} a & b \\ c & d \end{pmatrix}, \text{ assim, seus cofatores são: } \begin{cases} A_{11} = d ; A_{12} = -c \\ A_{21} = -b ; A_{22} = a \end{cases}, \text{ permitindo determinar a}$$

matriz adjunta:  $\tilde{\mathbf{A}} = \begin{pmatrix} d & -b \\ -c & a \end{pmatrix}$ , note que:

$$\mathbf{A} \cdot \tilde{\mathbf{A}} = \tilde{\mathbf{A}} \cdot \mathbf{A} = (a \cdot d - b \cdot c) \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} = \det(\mathbf{A}) \cdot \mathbf{I} \Rightarrow \mathbf{A}^{-1} = \frac{1}{(a \cdot d - b \cdot c)} \cdot \begin{pmatrix} d & -b \\ -c & a \end{pmatrix}, \text{ isto é, para}$$

determinar a inversa de uma matriz (2x2) basta trocar os elementos da diagonal principal, trocar o sinal dos elementos da diagonal secundária e dividir a matriz resultante pelo determinante da matriz original.

Se  $\mathbf{A}^{-1} = \mathbf{A}^T$ , isto é a inversa da matriz é igual a sua transposta, então a matriz  $\mathbf{A}$  é chamada de *matriz ortogonal*., e neste caso o  $\det(\mathbf{A}) = +1$  ou  $-1$ .

**Exemplo Ilustrativo** - Considere a mudança de coordenadas em  $\mathfrak{R}^2$  resultante da simples rotação dos eixos, conforme mostrado abaixo:

vê-se da figura acima que no sistema original  $(x_1, x_2)$  :  $v_1 = r \cos(\alpha)$  e :  $v_2 = r \sin(\alpha)$ , o vetor **OP** faz um ângulo igual a  $\theta - \alpha$  com o eixo  $y_1$  e projeta-se na porção negativa do eixo  $y_2$ , assim:

$$\begin{cases} u_1 = r \cdot \cos(\theta - \alpha) = r \cdot \cos\theta \cdot \cos\alpha + r \cdot \sin\theta \cdot \sin\alpha \\ u_2 = -r \cdot \sin(\theta - \alpha) = -r \cdot \sin\theta \cdot \cos\alpha + r \cdot \cos\theta \cdot \sin\alpha \end{cases} \text{ ou seja:}$$

$$\begin{cases} u_1 = \cos \theta \cdot v_1 + \text{sen} \theta \cdot v_2 \\ u_2 = -\text{sen} \theta \cdot v_1 + \cos \theta \cdot v_2 \end{cases} \text{ ou, em termos matriciais: } \begin{pmatrix} u_1 \\ u_2 \end{pmatrix} = \begin{pmatrix} \cos \theta & \text{sen} \theta \\ -\text{sen} \theta & \cos \theta \end{pmatrix} \cdot \begin{pmatrix} v_1 \\ v_2 \end{pmatrix},$$

identificando a matriz da transformação :  $\mathbf{T} = \begin{pmatrix} \cos \theta & \text{sen} \theta \\ -\text{sen} \theta & \cos \theta \end{pmatrix} \Rightarrow \mathbf{T}^T = \begin{pmatrix} \cos \theta & -\text{sen} \theta \\ \text{sen} \theta & \cos \theta \end{pmatrix}$ ,

tem-se:

$$\mathbf{T} \cdot \mathbf{T}^T = \begin{pmatrix} \cos^2 \theta + \text{sen}^2 \theta & -\cos \theta \text{sen} \theta + \text{sen} \theta \cos \theta \\ -\text{sen} \theta \cos \theta + \cos \theta \text{sen} \theta & \text{sen}^2 \theta + \cos^2 \theta \end{pmatrix} = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} \quad e$$

$$\mathbf{T}^T \cdot \mathbf{T} = \begin{pmatrix} \cos^2 \theta + \text{sen}^2 \theta & \cos \theta \text{sen} \theta - \text{sen} \theta \cos \theta \\ \text{sen} \theta \cos \theta - \cos \theta \text{sen} \theta & \text{sen}^2 \theta + \cos^2 \theta \end{pmatrix} = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}.$$

Verificando-se assim que a matriz  $\mathbf{T}$  é uma matriz ortogonal.

É interessante verificar que os vetores coluna da matriz  $\mathbf{T}$  são exatamente os componentes dos vetores  $\mathbf{e}_1 = \begin{pmatrix} 1 \\ 0 \end{pmatrix}$  e  $\mathbf{e}_2 = \begin{pmatrix} 0 \\ 1 \end{pmatrix}$  no novo sistema de coordenadas, em acordo com a figura abaixo:

### 3) ALGUMAS PROPRIEDADES FUNDAMENTAIS DE OPERAÇÕES ENTRE MATRIZES

As leis de associação e de comutação são válidas para as operações de adição/subtração, assim:  $(\mathbf{A}+\mathbf{B})+\mathbf{C} = \mathbf{A}+(\mathbf{B}+\mathbf{C})$  e  $\mathbf{A}+\mathbf{B} = \mathbf{B}+\mathbf{A}$ .

São válidas também as leis de associação e de distribuição para a multiplicação, assim:  $(\mathbf{AB})\mathbf{C} = \mathbf{A}(\mathbf{BC})$  ;  $\mathbf{A}(\mathbf{B}+\mathbf{C}) = \mathbf{AB} + \mathbf{AC}$  e  $(\mathbf{A}+\mathbf{B})\mathbf{C} = \mathbf{AC} + \mathbf{BC}$

Para a matriz transposta tem-se as seguintes propriedades:  $(\mathbf{A}+\mathbf{B})^T = \mathbf{A}^T + \mathbf{B}^T$  e  $(\mathbf{AB})^T = \mathbf{B}^T \mathbf{A}^T$

e para a matriz inversa:  $(\mathbf{AB})^{-1} = \mathbf{B}^{-1} \mathbf{A}^{-1}$  e  $(\mathbf{A}^{-1})^T = (\mathbf{A}^T)^{-1}$  Um menor de ordem p de uma matriz  $\mathbf{A}$  ( $n,n$ ) é o valor do determinante da matriz obtida eliminando-se  $n-p$  linhas e  $n-p$  colunas da matriz  $\mathbf{A}$ . Se uma matriz  $\mathbf{A}$  apresenta a propriedade de todos os menores de ordem  $(r + 1)$  serem nulos e de pelo menos um menor de ordem  $r$  ser não nulo então diz-se

que a matriz  $\mathbf{A}$  é de posto (rank)  $r$ . Note que toda matriz quadrada  $(n,n)$  regular ( ou não singular) apresenta o posto igual a  $n$ .

Um conjunto de  $n$  vetores  $\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_n$  com  $n$  elementos é dito linearmente independente se os únicos valores de  $c_1, c_2, \dots, c_n$  tais que:  $c_1 \mathbf{u}_1 + c_2 \mathbf{u}_2 + \dots + c_n \mathbf{u}_n = \mathbf{0}$  são:  $c_1 = c_2 = \dots = c_n = 0$ . Neste caso os vetores  $\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_n$  formam uma base de  $\mathfrak{R}^n$  e todo vetor deste espaço de dimensão  $n$  (que é o número máximo de vetores linearmente independentes que pode existir neste espaço, que também é igual ao número de elementos destes vetores) pode ser expresso como uma combinação linear dos vetores da base, os coeficientes desta combinação linear são os componentes do vetor nesta base. Os componentes de um vetor qualquer do  $\mathfrak{R}^n$  apenas confundem-se com seus elementos quando adota-se a base canônica do  $\mathfrak{R}^n$ , que é a base composta pelos vetores unitários  $\mathbf{e}_i$  cujo único elemento não nulo é o  $i$ 'ésimo, isto é :  $e_{ij} = \delta_{ij}$ , desta forma os vetores coluna ou os vetores linha da matriz identidade  $\mathbf{I}$  são os vetores da base canônica do  $\mathfrak{R}^n$ .

Em uma matriz de posto  $r$  todos seus vetores linha (ou coluna) podem ser escritos como uma combinação linear de  $r$  vetores linha (ou coluna), desta forma o posto de uma matriz é também o número máximo de vetores linha (ou coluna) linearmente independentes.

Uma forma de determinar o posto de uma matriz é através do processo de ortogonalização de Gram-Schmidt aplicado aos vetores linha ou aos vetores coluna da matriz, este processo pode ser resumido na forma, sejam:  $\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_n$  os vetores coluna (ou linha) de  $\mathbf{A}$ , então adota-se:

$$\mathbf{u}_1 = \mathbf{v}_1$$

$$\mathbf{u}_2 = \mathbf{v}_2 - \left( \frac{\mathbf{v}_2^T \cdot \mathbf{u}_1}{\|\mathbf{u}_1\|^2} \right) \cdot \mathbf{u}_1$$

$$\mathbf{u}_3 = \mathbf{v}_3 - \left( \frac{\mathbf{v}_3^T \cdot \mathbf{u}_1}{\|\mathbf{u}_1\|^2} \right) \cdot \mathbf{u}_1 - \left( \frac{\mathbf{v}_3^T \cdot \mathbf{u}_2}{\|\mathbf{u}_2\|^2} \right) \cdot \mathbf{u}_2$$

.....

$$\mathbf{u}_j = \mathbf{v}_j - \sum_{k=1}^{j-1} \left[ \left( \frac{\mathbf{v}_j^T \cdot \mathbf{u}_k}{\|\mathbf{u}_k\|^2} \right) \cdot \mathbf{u}_k \right] \text{ para } j = 2, \dots, n \text{ com } \mathbf{u}_1 = \mathbf{v}_1$$

onde  $\|\mathbf{p}\| = \sqrt{p_1^2 + p_2^2 + \dots + p_n^2}$  (módulo de  $\mathbf{p}$ )

Encontrando-se durante este processo algum vetor  $\mathbf{u}_k$  com módulo nulo ( ou menor que um valor pequeno preestabelecido) abandona-se este vetor e prossegue-se o procedimento renumerando-se os vetores subseqüentes, ao final do processo o número de vetores  $\mathbf{u}_k$  não nulos é igual ao posto da matriz. Este procedimento pode ser também aplicado a matrizes não-quadradas.

Exemplos Ilustrativos :Calcular através do processo de ortogonalização de Garm-Schmidt o posto de cada uma das matrizes abaixo:

$$(a) \begin{pmatrix} 2 & -3 & 7 \\ 4 & 6 & 2 \\ -4 & 0 & 1 \end{pmatrix}; (b) \begin{pmatrix} -1 & 2 & 3 \\ -2 & 4 & -1 \\ -1 & 2 & -4 \\ -5 & 10 & -6 \end{pmatrix}; (c) \begin{pmatrix} -1 & 2 & 3 & 1 \\ -2 & 4 & -1 & -3 \\ -1 & 2 & -4 & -4 \\ -5 & 10 & -6 & -10 \end{pmatrix}.$$

(a) utilizando os vetores coluna da matriz, isto é:  $\mathbf{v}_1 = \begin{pmatrix} 2 \\ 4 \\ -4 \end{pmatrix}$ ;  $\mathbf{v}_2 = \begin{pmatrix} -3 \\ 6 \\ 0 \end{pmatrix}$  e  $\mathbf{v}_3 = \begin{pmatrix} 7 \\ 2 \\ 1 \end{pmatrix}$ ,

tem-se:  $\mathbf{u}_1 = \mathbf{v}_1 = \begin{pmatrix} 2 \\ 4 \\ -4 \end{pmatrix} \Rightarrow \|\mathbf{u}_1\| = 6$ ;  $\mathbf{u}_1^T \cdot \mathbf{v}_2 = \mathbf{u}_1^T \cdot \mathbf{v}_3 = 18$

$$\mathbf{u}_2 = \mathbf{v}_2 - \left( \frac{\mathbf{v}_2^T \cdot \mathbf{u}_1}{\|\mathbf{u}_1\|^2} \right) \cdot \mathbf{u}_1 = \begin{pmatrix} -3 \\ 6 \\ 0 \end{pmatrix} - \frac{18}{6^2} \begin{pmatrix} 2 \\ 4 \\ -4 \end{pmatrix} = \begin{pmatrix} -4 \\ 4 \\ 2 \end{pmatrix} \Rightarrow \|\mathbf{u}_2\| = 6$$
;  $\mathbf{u}_2^T \cdot \mathbf{v}_3 = -18$

$$\mathbf{u}_3 = \mathbf{v}_3 - \left( \frac{\mathbf{v}_3^T \cdot \mathbf{u}_1}{\|\mathbf{u}_1\|^2} \right) \cdot \mathbf{u}_1 - \left( \frac{\mathbf{v}_3^T \cdot \mathbf{u}_2}{\|\mathbf{u}_2\|^2} \right) \cdot \mathbf{u}_2 = \begin{pmatrix} 7 \\ 2 \\ 1 \end{pmatrix} - \frac{18}{6^2} \begin{pmatrix} 2 \\ 4 \\ -4 \end{pmatrix} + \frac{18}{6^2} \begin{pmatrix} -4 \\ 4 \\ 2 \end{pmatrix} = \begin{pmatrix} 4 \\ 2 \\ 4 \end{pmatrix} \Rightarrow \|\mathbf{u}_3\| = 6$$

como os 3 vetores  $\mathbf{u}_1$ ,  $\mathbf{u}_2$  e  $\mathbf{u}_3$  são não nulos o posto da matriz é igual a 3.

utilizando os vetores linha da matriz, isto é:  $\mathbf{v}_1 = \begin{pmatrix} 2 \\ -3 \\ 7 \end{pmatrix}$ ;  $\mathbf{v}_2 = \begin{pmatrix} 4 \\ 6 \\ 2 \end{pmatrix}$  e  $\mathbf{v}_3 = \begin{pmatrix} -4 \\ 0 \\ 1 \end{pmatrix}$ ,

tem-se:  $\mathbf{u}_1 = \mathbf{v}_1 = \begin{pmatrix} 2 \\ -3 \\ 7 \end{pmatrix} \Rightarrow \|\mathbf{u}_1\| = \sqrt{62}$ ;  $\mathbf{u}_1^T \cdot \mathbf{v}_2 = 4$ ;  $\mathbf{u}_1^T \cdot \mathbf{v}_3 = -1$

$$\mathbf{u}_2 = \mathbf{v}_2 - \left( \frac{\mathbf{v}_2^T \cdot \mathbf{u}_1}{\|\mathbf{u}_1\|^2} \right) \cdot \mathbf{u}_1 = \begin{pmatrix} 4 \\ 6 \\ 2 \end{pmatrix} - \frac{4}{\sqrt{62}} \begin{pmatrix} 2 \\ -3 \\ 7 \end{pmatrix} = \begin{pmatrix} 3,871 \\ 6,194 \\ 1,548 \end{pmatrix} \Rightarrow \|\mathbf{u}_2\| = 7,466$$
;  $\mathbf{u}_2^T \cdot \mathbf{v}_3 = -13,935$

$$\mathbf{u}_3 = \mathbf{v}_3 - \left( \frac{\mathbf{v}_3^T \cdot \mathbf{u}_1}{\|\mathbf{u}_1\|^2} \right) \cdot \mathbf{u}_1 - \left( \frac{\mathbf{v}_3^T \cdot \mathbf{u}_2}{\|\mathbf{u}_2\|^2} \right) \cdot \mathbf{u}_2 = \begin{pmatrix} -4 \\ 0 \\ 1 \end{pmatrix} + \frac{1}{\sqrt{62}} \begin{pmatrix} 2 \\ -3 \\ 7 \end{pmatrix} + \frac{13,935}{7,466^2} \begin{pmatrix} 3,871 \\ 6,194 \\ 1,548 \end{pmatrix} =$$

$$= \begin{pmatrix} -3 \\ 1,5 \\ 1,5 \end{pmatrix} \Rightarrow \|\mathbf{u}_3\| = \sqrt{13,5}$$
, novamente tem-se os 3 vetores  $\mathbf{u}_1$ ,  $\mathbf{u}_2$  e  $\mathbf{u}_3$  não nulos e o posto da

matriz é igual a 3.

(b) utilizando os vetores coluna da matriz, isto é:  $\mathbf{v}_1 = \begin{pmatrix} -1 \\ -2 \\ -1 \\ -5 \end{pmatrix}$ ;  $\mathbf{v}_2 = \begin{pmatrix} 2 \\ 4 \\ 2 \\ 10 \end{pmatrix}$  e  $\mathbf{v}_3 = \begin{pmatrix} 3 \\ -1 \\ -4 \\ -6 \end{pmatrix}$ ,

$$\mathbf{u}_1 = \mathbf{v}_1 = \begin{pmatrix} -1 \\ -2 \\ -1 \\ -5 \end{pmatrix} \Rightarrow \|\mathbf{u}_1\| = \sqrt{31}$$
;  $\mathbf{u}_1^T \cdot \mathbf{v}_2 = -62$ ;  $\mathbf{u}_1^T \cdot \mathbf{v}_3 = 33$

$$\mathbf{u}_2 = \mathbf{v}_2 - \left( \frac{\mathbf{v}_2^T \cdot \mathbf{u}_1}{\|\mathbf{u}_1\|^2} \right) \cdot \mathbf{u}_1 = \begin{pmatrix} 2 \\ 4 \\ 2 \\ 10 \end{pmatrix} + \frac{62}{31} \begin{pmatrix} -1 \\ -2 \\ -1 \\ -5 \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \\ 0 \\ 0 \end{pmatrix} \Rightarrow \|\mathbf{u}_2\| = 0$$

novamente:  $\mathbf{u}_2 = \mathbf{v}_3 - \left( \frac{\mathbf{v}_3^T \cdot \mathbf{u}_1}{\|\mathbf{u}_1\|^2} \right) \cdot \mathbf{u}_1 = \begin{pmatrix} 3 \\ -1 \\ -4 \\ -6 \end{pmatrix} + \frac{33}{31} \begin{pmatrix} -1 \\ -2 \\ -1 \\ -5 \end{pmatrix} = \begin{pmatrix} 4,065 \\ 1,129 \\ -2,935 \\ -0,677 \end{pmatrix} \Rightarrow \|\mathbf{u}_2\| = 5,184$ , como há

apenas 2 vetores coluna linearmente independente o posto desta matriz é igual a 2; utilizando os vetores linha da matriz, isto é:

$$\mathbf{v}_1 = \begin{pmatrix} -1 \\ 2 \\ 3 \end{pmatrix}; \mathbf{v}_2 = \begin{pmatrix} -2 \\ 4 \\ -1 \end{pmatrix}; \mathbf{v}_3 = \begin{pmatrix} -1 \\ 2 \\ -4 \end{pmatrix} \text{ e } \mathbf{v}_4 = \begin{pmatrix} -5 \\ 10 \\ -6 \end{pmatrix}, \text{ tem-se:}$$

$$\mathbf{u}_1 = \mathbf{v}_1 = \begin{pmatrix} -1 \\ 2 \\ 3 \end{pmatrix} \Rightarrow \|\mathbf{u}_1\| = \sqrt{14}; \mathbf{u}_1^T \cdot \mathbf{v}_2 = \mathbf{u}_1^T \cdot \mathbf{v}_4 = 7 \text{ e } \mathbf{u}_1^T \cdot \mathbf{v}_3 = -7$$

$$\mathbf{u}_2 = \mathbf{v}_2 - \left( \frac{\mathbf{v}_2^T \cdot \mathbf{u}_1}{\|\mathbf{u}_1\|^2} \right) \cdot \mathbf{u}_1 = \begin{pmatrix} -2 \\ 4 \\ 1 \end{pmatrix} - \frac{7}{14} \begin{pmatrix} -1 \\ 2 \\ 3 \end{pmatrix} = \begin{pmatrix} -1,5 \\ 3 \\ -2,5 \end{pmatrix} \Rightarrow \|\mathbf{u}_2\| = \sqrt{17,5}; \mathbf{u}_2^T \cdot \mathbf{v}_3 = 17,5 \text{ e}$$

$$\mathbf{u}_2^T \cdot \mathbf{v}_4 = 52,5$$

$$\mathbf{u}_3 = \mathbf{v}_3 - \left( \frac{\mathbf{v}_3^T \cdot \mathbf{u}_1}{\|\mathbf{u}_1\|^2} \right) \cdot \mathbf{u}_1 - \left( \frac{\mathbf{v}_3^T \cdot \mathbf{u}_2}{\|\mathbf{u}_2\|^2} \right) \cdot \mathbf{u}_2 = \begin{pmatrix} -1 \\ 2 \\ -4 \end{pmatrix} + \frac{7}{14} \begin{pmatrix} -1 \\ 2 \\ 3 \end{pmatrix} - \frac{17,5}{17,5} \begin{pmatrix} -1,5 \\ 3 \\ -2,5 \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \\ 0 \end{pmatrix} \Rightarrow \|\mathbf{u}_3\| = 0$$

novamente:  $\mathbf{u}_3$ :

$$\mathbf{u}_3 = \mathbf{v}_4 - \left( \frac{\mathbf{v}_4^T \cdot \mathbf{u}_1}{\|\mathbf{u}_1\|^2} \right) \cdot \mathbf{u}_1 - \left( \frac{\mathbf{v}_4^T \cdot \mathbf{u}_2}{\|\mathbf{u}_2\|^2} \right) \cdot \mathbf{u}_2 = \begin{pmatrix} -5 \\ 10 \\ -6 \end{pmatrix} - \frac{7}{14} \begin{pmatrix} -1 \\ 2 \\ 3 \end{pmatrix} - \frac{52,5}{17,5} \begin{pmatrix} -1,5 \\ 3 \\ -2,5 \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \\ 0 \end{pmatrix} \Rightarrow \|\mathbf{u}_3\| = 0$$

desta forma a matriz apresenta apenas 2 vetores linha linearmente independentes reconfirmando que a matriz tem posto = 2;

(c) utilizando os vetores coluna da matriz, isto é:

$$\mathbf{v}_1 = \begin{pmatrix} -1 \\ -2 \\ -1 \\ -5 \end{pmatrix}; \mathbf{v}_2 = \begin{pmatrix} 2 \\ 4 \\ 2 \\ 10 \end{pmatrix}; \mathbf{v}_3 = \begin{pmatrix} 3 \\ -1 \\ -4 \\ -6 \end{pmatrix} \text{ e } \mathbf{v}_4 = \begin{pmatrix} 1 \\ -3 \\ -4 \\ -10 \end{pmatrix},$$

$$\mathbf{u}_1 = \mathbf{v}_1 = \begin{pmatrix} -1 \\ -2 \\ -1 \\ -5 \end{pmatrix} \Rightarrow \|\mathbf{u}_1\| = \sqrt{31}; \mathbf{u}_1^T \cdot \mathbf{v}_2 = -62; \mathbf{u}_1^T \cdot \mathbf{v}_3 = 33 \text{ e } \mathbf{u}_1^T \cdot \mathbf{v}_4 = 59$$

$$\mathbf{u}_2 = \mathbf{v}_2 - \left( \frac{\mathbf{v}_2^T \cdot \mathbf{u}_1}{\|\mathbf{u}_1\|^2} \right) \cdot \mathbf{u}_1 = \begin{pmatrix} 2 \\ 4 \\ 2 \\ 10 \end{pmatrix} + \frac{62}{31} \begin{pmatrix} -1 \\ -2 \\ -1 \\ -5 \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \\ 0 \\ 0 \end{pmatrix} \Rightarrow \|\mathbf{u}_2\| = 0$$

$$\text{novoo: } \mathbf{u}_2 = \mathbf{v}_3 - \left( \frac{\mathbf{v}_3^T \cdot \mathbf{u}_1}{\|\mathbf{u}_1\|^2} \right) \cdot \mathbf{u}_1 = \begin{pmatrix} 3 \\ -1 \\ -4 \\ -6 \end{pmatrix} + \frac{33}{31} \begin{pmatrix} -1 \\ -2 \\ -1 \\ -5 \end{pmatrix} = \begin{pmatrix} 4,065 \\ 1,129 \\ -2,935 \\ -0,677 \end{pmatrix} \Rightarrow \|\mathbf{u}_2\| = 5,184,$$

$$\mathbf{u}_2^T \cdot \mathbf{v}_4 = 19,194$$

$$\mathbf{u}_3 = \mathbf{v}_4 - \left( \frac{\mathbf{v}_4^T \cdot \mathbf{u}_1}{\|\mathbf{u}_1\|^2} \right) \cdot \mathbf{u}_1 - \left( \frac{\mathbf{v}_4^T \cdot \mathbf{u}_2}{\|\mathbf{u}_2\|^2} \right) \cdot \mathbf{u}_2 = \begin{pmatrix} 1 \\ -3 \\ -4 \\ -10 \end{pmatrix} - \frac{59}{31} \begin{pmatrix} -1 \\ -2 \\ -1 \\ -5 \end{pmatrix} - \frac{19,194}{5,184^2} \begin{pmatrix} 4,065 \\ 1,129 \\ -2,935 \\ -0,677 \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \\ 0 \\ 0 \end{pmatrix}$$

$\Rightarrow \|\mathbf{u}_3\| = 0$ ; como há apenas 2 vetores coluna linearmente independente o posto desta matriz é igual a 2, isto pode ser reconfirmado com os vetores linha da matriz.

#### 4) FUNÇÕES DE MATRIZES

De forma análoga a funções analíticas de variáveis escalares que podem, em um certo domínio, ser expandidas em séries de potências da forma:

$$f(x) = \sum_{i=0}^{\infty} c_i \cdot x^i \quad \text{onde : } c_i = \frac{1}{i!} \left[ \frac{d^i f(x)}{dx^i} \right]_{x=0} \quad \text{tem-se as funções de matrizes que é um matriz}$$

da forma:  $f(\mathbf{A}) = \sum_{i=0}^{\infty} c_i \cdot \mathbf{A}^i$ . Como exemplo tem-se a função exponencial de uma matriz  $\mathbf{A}$

definida, em analogia à função  $e^x = \sum_{i=0}^{\infty} \frac{1}{i!} \cdot x^i$ , pela série:

$$\exp(\mathbf{A}) = e^{\mathbf{A}} = \sum_{i=0}^{\infty} \frac{1}{i!} \cdot \mathbf{A}^i, \quad \text{note que esta função apresenta as propriedades:}$$

i-)  $\exp(\mathbf{0}) = \mathbf{I}$  onde  $\mathbf{0}$  é a matriz nula;

ii-)  $\exp(\mathbf{A}t) = e^{\mathbf{A}t} = \sum_{i=0}^{\infty} \frac{t^i}{i!} \cdot \mathbf{A}^i$  onde  $t$  é um escalar, assim:

$$\frac{d \exp(\mathbf{A}t)}{dt} = \sum_{i=0}^{\infty} \frac{it^{i-1}}{i!} \cdot \mathbf{A}^i = \mathbf{A} \sum_{i=0}^{\infty} \frac{t^i}{i!} \cdot \mathbf{A}^i = \mathbf{A} \exp(\mathbf{A}t) \quad \text{ou seja se } \Phi(t) = \exp(\mathbf{A}t), \text{ tem-se:}$$

$$\Phi(0) = \mathbf{I} \quad \text{e} \quad \frac{d\Phi(t)}{dt} = \mathbf{A} \cdot \Phi(t), \quad \text{ou seja a matriz } \Phi(t) \text{ é solução da equação diferencial}$$

$$\text{ordinária matricial } \frac{d\Phi(t)}{dt} = \mathbf{A} \cdot \Phi(t), \quad \text{sujeita à condição inicial } \Phi(0) = \mathbf{I}.$$

Uma forma mais simples para determinar funções de matrizes pode ser desenvolvida através da aplicação do Teorema de Cayley-Hamilton que estabelece que toda a matriz quadrada  $\mathbf{A}$  é raiz de seu polinômio característico, isto é se

$$p(\lambda) = \lambda^n + c_1 \cdot \lambda^{n-1} + c_2 \cdot \lambda^{n-2} + \dots + c_{n-1} \cdot \lambda + c_n \quad \text{é o polinômio característico de } \mathbf{A}, \text{ então:}$$

$p(\mathbf{A}) = \mathbf{A}^n + c_1 \cdot \mathbf{A}^{n-1} + c_2 \cdot \mathbf{A}^{n-2} + \dots + c_{n-1} \cdot \mathbf{A} + c_n \cdot \mathbf{I} = \mathbf{0}$ . A demonstração deste teorema pode ser feita definindo-se a matriz adjunta da matriz  $\lambda\mathbf{I} - \mathbf{A}$ , isto é:  $\mathbf{C} = \text{adj}(\lambda\mathbf{I} - \mathbf{A})$  que pode ser expressa na forma:  $\mathbf{C} = \mathbf{C}_1\lambda^{n-1} + \mathbf{C}_2\lambda^{n-2} + \dots + \mathbf{C}_{n-1}\lambda + \mathbf{C}_n$ , onde  $\mathbf{C}_k$   $k = 1, 2, \dots, n$  são matrizes do mesmo tipo de  $\mathbf{A}$ , mas:  $(\lambda\mathbf{I} - \mathbf{A})[\text{adj}(\lambda\mathbf{I} - \mathbf{A})] = \det(\lambda\mathbf{I} - \mathbf{A})\mathbf{I} = p(\lambda)\mathbf{I}$ , ou seja:

$$(\lambda\mathbf{I} - \mathbf{A}) \cdot (\mathbf{C}_1\lambda^{n-1} + \mathbf{C}_2\lambda^{n-2} + \dots + \mathbf{C}_{n-1}\lambda + \mathbf{C}_n) = (\lambda^n + c_1\lambda^{n-1} + c_2\lambda^{n-2} + \dots + c_{n-1}\lambda + c_n) \cdot \mathbf{I}$$

igualando os termos equípotentes de  $\lambda$ , tem-se:

$$\begin{cases} \mathbf{C}_1 = \mathbf{I} \rightarrow \mathbf{A}^n \cdot \Rightarrow \mathbf{A}^n \cdot \mathbf{C}_1 = \mathbf{A}^n \\ \mathbf{C}_2 - \mathbf{A} \cdot \mathbf{C}_1 = c_1 \mathbf{I} \rightarrow \mathbf{A}^{n-1} \cdot \Rightarrow \mathbf{A}^{n-1} \cdot \mathbf{C}_2 - \mathbf{A}^n \cdot \mathbf{C}_1 = c_1 \mathbf{A}^{n-1} \\ \mathbf{C}_3 - \mathbf{A} \cdot \mathbf{C}_2 = c_2 \mathbf{I} \rightarrow \mathbf{A}^{n-2} \cdot \Rightarrow \mathbf{A}^{n-2} \cdot \mathbf{C}_3 - \mathbf{A}^{n-1} \cdot \mathbf{C}_2 = c_2 \mathbf{A}^{n-2} \\ \vdots \\ \mathbf{C}_n - \mathbf{A} \cdot \mathbf{C}_{n-1} = c_{n-1} \mathbf{I} \rightarrow \mathbf{A} \cdot \Rightarrow \mathbf{A} \cdot \mathbf{C}_n - \mathbf{A}^2 \cdot \mathbf{C}_{n-1} = c_{n-1} \mathbf{A} \\ -\mathbf{A} \cdot \mathbf{C}_n = c_n \mathbf{I} \rightarrow \mathbf{A}^0 = \mathbf{I} \cdot \Rightarrow -\mathbf{A} \cdot \mathbf{C}_n = c_n \mathbf{I} \end{cases} \quad \text{somando todos os termos}$$

após  $\Rightarrow$  tem-se:  $\mathbf{A}^n + c_1 \cdot \mathbf{A}^{n-1} + c_2 \cdot \mathbf{A}^{n-2} + \dots + c_{n-1} \cdot \mathbf{A} + c_n \cdot \mathbf{I} = p(\mathbf{A}) = \mathbf{0}$ .

Uma consequência do teorema de Cayley-Hamilton é que:

$$\mathbf{A}^n = -c_1 \cdot \mathbf{A}^{n-1} - c_2 \cdot \mathbf{A}^{n-2} - \dots - c_{n-1} \cdot \mathbf{A} - c_n \cdot \mathbf{I}, \text{ multiplicando membro a membro por } \mathbf{A}:$$

$$\mathbf{A}^{n+1} = -c_1 \cdot \mathbf{A}^n - c_2 \cdot \mathbf{A}^{n-1} - \dots - c_{n-1} \cdot \mathbf{A}^2 - c_n \cdot \mathbf{A} \text{ substituindo a expressão de } \mathbf{A}^n, \text{ tem-se:}$$

$$\mathbf{A}^{n+1} = (c_1^2 - c_2) \cdot \mathbf{A}^{n-1} + (c_1 c_2 - c_3) \cdot \mathbf{A}^{n-2} + \dots + (c_1 c_{n-1} - c_n) \cdot \mathbf{A} + c_1 c_n \cdot \mathbf{I}, \quad \text{e assim}$$

sucessivamente, o que permite concluir que :

$$\mathbf{A}^m = d_1 \cdot \mathbf{A}^{n-1} + d_2 \cdot \mathbf{A}^{n-2} + \dots + d_{n-1} \cdot \mathbf{A} + d_n \cdot \mathbf{I} \text{ para } m = 0, 1, 2, \dots. \text{ Além disto se } \mathbf{A} \text{ é regular, multiplica-se membro a membro de } p(\mathbf{A}) \text{ por } \mathbf{A}^{-1}, \text{ resultando em :}$$

$$\mathbf{A}^{n-1} + c_1 \cdot \mathbf{A}^{n-2} + c_2 \cdot \mathbf{A}^{n-3} + \dots + c_{n-1} \cdot \mathbf{I} + c_n \cdot \mathbf{A}^{-1} = \mathbf{0} \text{ ou seja:}$$

$$\mathbf{A}^{-1} = -\frac{1}{c_n} (\mathbf{A}^{n-1} + c_1 \cdot \mathbf{A}^{n-2} + c_2 \cdot \mathbf{A}^{n-3} + \dots + c_{n-1} \cdot \mathbf{I}) \quad \{ \text{note que } c_n = (-1)^n \det(\mathbf{A}) \neq 0 \text{ pois}$$

$\mathbf{A}$  é regular ou não-singular), assim sendo se  $\mathbf{A}$  é regular:

$$\mathbf{A}^m = d_1 \cdot \mathbf{A}^{n-1} + d_2 \cdot \mathbf{A}^{n-2} + \dots + d_{n-1} \cdot \mathbf{A} + d_n \cdot \mathbf{I} \text{ para } m = 0, \pm 1, \pm 2, \dots$$

$$\text{A aplicação do Teorema de Cayley-Hamilton à série de potências } f(\mathbf{A}) = \sum_{i=0}^{\infty} c_i \cdot \mathbf{A}^i$$

permite reescrevê-la na forma:  $f(\mathbf{A}) = \sum_{i=0}^{n-1} \alpha_i \cdot \mathbf{A}^i$  pois potências superiores à  $(n-1)$  da

matriz  $\mathbf{A}$  pode, pelo teorema de Cayley-Hamilton, serem expressas em termos das  $(n-1)$  primeiras potências da matriz  $\mathbf{A}$ , além disto de acordo com a propriedade anteriormente apresentada de que se  $\lambda$  é um valor característico e  $\mathbf{v}$  o correspondente vetor característico de  $\mathbf{A}$ , então  $q(\lambda)$  é valor característico e  $\mathbf{v}$  o correspondente vetor característico de

$$q(\mathbf{A}) = \mathbf{A}^m + a_1 \mathbf{A}^{m-1} + a_2 \mathbf{A}^{m-2} + \dots + a_{m-1} \mathbf{A} + a_m \mathbf{I} \text{ tem-se que os valores característicos de}$$

$$f(\mathbf{A}) \text{ satisfazem a: } f(\lambda) = \sum_{i=0}^{n-1} \alpha_i \cdot \lambda^i, \text{ então para determinar os coeficientes } \alpha_i, \text{ assim}$$

procede-se:

(i) se os valores característicos de  $\mathbf{A}$  são todos distintos, resolve-se o sistema linear de equações:  $\sum_{i=0}^{n-1} \alpha_i \cdot \lambda_k^i = f(\lambda_k)$  para  $k = 1, 2, \dots, n$ ;

Se  $\mathbf{A}$  é uma matriz (2,2),  $\alpha_0, \alpha_1$  é solução de :

$$\begin{cases} \alpha_0 + \alpha_1 \lambda_1 = f(\lambda_1) \\ \alpha_0 + \alpha_1 \lambda_2 = f(\lambda_2) \end{cases} \Rightarrow \begin{cases} \alpha_0 = \frac{\lambda_2 f(\lambda_1) - \lambda_1 f(\lambda_2)}{\lambda_2 - \lambda_1} \\ \alpha_1 = \frac{f(\lambda_2) - f(\lambda_1)}{\lambda_2 - \lambda_1} \end{cases}$$

caso  $\lambda_1 = \lambda_2$  tem-se: 
$$\begin{cases} \alpha_0 = \lim_{\lambda_2 \rightarrow \lambda_1} \left[ \frac{\lambda_2 f(\lambda_1) - \lambda_1 f(\lambda_2)}{\lambda_2 - \lambda_1} \right] = f(\lambda_1) - \lambda_1 f'(\lambda_1) \\ \alpha_1 = \lim_{\lambda_2 \rightarrow \lambda_1} \left[ \frac{f(\lambda_2) - f(\lambda_1)}{\lambda_2 - \lambda_1} \right] = f'(\lambda_1) \end{cases}$$

o mesmo resultado poderia ser obtido derivando-se a segunda equação do sistema em relação a  $\lambda_2$  e, em seguida, fazer  $\lambda_2 \rightarrow \lambda_1$ , assim:

$$\begin{cases} \alpha_0 + \alpha_1 \lambda_1 = f(\lambda_1) \\ \alpha_1 = f'(\lambda_1) \end{cases} \Rightarrow \begin{cases} \alpha_0 = f(\lambda_1) - \lambda_1 f'(\lambda_1) \\ \alpha_1 = f'(\lambda_1) \end{cases}$$

Exemplos Ilustrativos: (a) para  $\mathbf{A} = \begin{pmatrix} 4 & 2 \\ 1 & 3 \end{pmatrix}$  calcule  $\mathbf{A}^{-3}$  e  $\ln(\mathbf{A})$ ;

(b) para  $\mathbf{A} = \begin{pmatrix} 5 & -3 \\ 2 & -2 \end{pmatrix}$  calcule  $\sqrt{\mathbf{A}}$ .

(a)  $p(\lambda) = \lambda^2 - 7\lambda + 10 = (\lambda - 2)(\lambda - 5) \Rightarrow \lambda_1 = 2$  e  $\lambda_2 = 5$ , assim:

$$\begin{cases} \alpha_0 = \frac{5f(2) - 2f(5)}{3} \\ \alpha_1 = \frac{f(5) - f(2)}{3} \end{cases}; \text{ para } f(x) = x^{-3} \text{ tem-se: } \begin{cases} \alpha_0 = \frac{5/8 - 2/125}{3} = 0,203 \\ \alpha_1 = \frac{1/125 - 1/8}{3} = -0,039 \end{cases} \text{ logo:}$$

$$\mathbf{A}^{-3} = 0,203 \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} - 0,039 \begin{pmatrix} 4 & 2 \\ 1 & 3 \end{pmatrix} = \begin{pmatrix} 0,047 & -0,078 \\ -0,039 & 0,086 \end{pmatrix} e$$

para  $f(x) = \ln(x)$ , tem-se 
$$\begin{cases} \alpha_0 = \frac{5 \ln(2) - 2 \ln(5)}{3} = 0,082287 \\ \alpha_1 = \frac{\ln(5) - \ln(2)}{3} = 0,30543 \end{cases} \text{ então:}$$

$$\mathbf{B} = \ln(\mathbf{A}) = 0,082287 \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} + 0,305430 \begin{pmatrix} 4 & 2 \\ 1 & 3 \end{pmatrix} = \begin{pmatrix} 1,304008 & 0,610860 \\ 0,30543 & 0,998577 \end{pmatrix}, \text{ esta última}$$

função matricial está correta se a função inversa também é verdadeira, isto é :  $\mathbf{A} = \exp(\mathbf{B})$ , para isto deve-se inicialmente determinar os valores característicos de  $\mathbf{B}$  que são



$$\eta_1=0,693147 \text{ e } \eta_2=1,609438 \text{ determina-se a seguir: } \begin{cases} \beta_0 = \frac{2\eta_2 - 5\eta_1}{\eta_2 - \eta_1} = -0,269412 \\ \beta_1 = \frac{5-2}{\eta_2 - \eta_1} = 3,27407 \end{cases} \text{ e então:}$$

$$\exp(\mathbf{B}) = -0,269412 \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} + 3,27407 \begin{pmatrix} 1,304008 & 0,610860 \\ 0,30543 & 0,998577 \end{pmatrix} = \begin{pmatrix} 4 & 2 \\ 1 & 3 \end{pmatrix} = \mathbf{A}$$

(b)  $p(\lambda) = \lambda^2 - 3\lambda - 4 = (\lambda + 1)(\lambda - 4) \Rightarrow \lambda_1 = -1$  e  $\lambda_2 = 4$  então como  $f(x) = \sqrt{x}$ , tem-se:  $f(\lambda_1) = \sqrt{-1} = \mathbf{i}$  e  $f(\lambda_2) = \sqrt{4} = 2$  logo:  $\begin{cases} \alpha_0 = \frac{4\mathbf{i} + 2}{5} = 0,4 + 0,8\mathbf{i} \\ \alpha_1 = \frac{2 - \mathbf{i}}{5} = 0,4 - 0,2\mathbf{i} \end{cases} e$

$$\sqrt{\mathbf{A}} = (0,4 + 0,8\mathbf{i}) \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} + (0,4 - 0,2\mathbf{i}) \begin{pmatrix} 5 & -3 \\ 2 & -2 \end{pmatrix} = \begin{pmatrix} 2,4 - 0,2\mathbf{i} & -1,2 + 0,6\mathbf{i} \\ 0,8 - 0,4\mathbf{i} & -0,4 + 1,2\mathbf{i} \end{pmatrix} \text{ note que:}$$

$$(\sqrt{\mathbf{A}})^2 = \begin{pmatrix} 2,4 - 0,2\mathbf{i} & -1,2 + 0,6\mathbf{i} \\ 0,8 - 0,4\mathbf{i} & -0,4 + 1,2\mathbf{i} \end{pmatrix} \cdot \begin{pmatrix} 2,4 - 0,2\mathbf{i} & -1,2 + 0,6\mathbf{i} \\ 0,8 - 0,4\mathbf{i} & -0,4 + 1,2\mathbf{i} \end{pmatrix} = \begin{pmatrix} 5 & -3 \\ 2 & -2 \end{pmatrix} = \mathbf{A}$$

(ii) se a matriz  $\mathbf{A}$  apresenta valores característicos múltiplos, por exemplo,  $\lambda_1 = \lambda_2 = \dots = \lambda_m \neq \lambda_{m+1} \neq \dots \neq \lambda_n$ , neste caso para levantar a indeterminação no cálculo dos coeficientes  $\alpha_i$ , deriva-se em relação a  $\lambda_1$   $m$  vezes a equação correspondente a  $\lambda_1$ , assim:  $\sum_{i=0}^{n-1} \alpha_i \cdot \lambda_1^i = f(\lambda_1)$ ;  $\sum_{i=1}^{n-1} i\alpha_i \cdot \lambda_1^{i-1} = f'(\lambda_1)$ ;  $\sum_{i=2}^{n-1} i(i-1)\alpha_i \cdot \lambda_1^{i-2} = f''(\lambda_1)$ ; ...;

$$\sum_{i=m}^{n-1} i(i-1)\dots(i-m+1)\alpha_i \cdot \lambda_1^{i-m} = \left. \frac{d^m f(\lambda)}{d\lambda^m} \right|_{\lambda_1} \text{ sendo as demais equações:}$$

$$\sum_{i=0}^{n-1} \alpha_i \cdot \lambda_k^i = f(\lambda_k) \text{ para } k = m+1, m+2, \dots, n.$$

Exemplo Ilustrativo: para  $\mathbf{A} = \begin{pmatrix} -1,750 & -2,000 & -0,250 \\ -0,125 & -2,000 & -0,375 \\ 0,250 & 2,000 & -0,250 \end{pmatrix}$  calcule  $\exp(\mathbf{A})$ ;

$$p(\lambda) = \det \begin{pmatrix} \lambda + 1,750 & 2,000 & 0,250 \\ 0,125 & \lambda + 2,000 & 0,375 \\ -0,250 & -2,000 & \lambda + 0,250 \end{pmatrix} = \lambda^3 + 4\lambda^2 + 5\lambda + 2 = 0 \Rightarrow \lambda_1 = \lambda_2 = -1$$

e  $\lambda_3 = -2$ , assim:

$$\begin{cases} \alpha_0 - \alpha_1 + \alpha_2 = \exp(-1) \\ \alpha_1 - 2\alpha_2 = \exp(-1) \text{ tem-se assim:} \\ \alpha_0 - 2\alpha_1 + 4\alpha_2 = \exp(-2) \end{cases} \begin{cases} \alpha_0 = 0,871094 \\ \alpha_1 = 0,638550 \text{ logo:} \\ \alpha_2 = 0,135335 \end{cases}$$

$$\exp(\mathbf{A}) = 0,871094 \begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{pmatrix} + 0,638550 \begin{pmatrix} -1,750 & -2,000 & -0,250 \\ -0,125 & -2,000 & -0,375 \\ 0,250 & 2,000 & -0,250 \end{pmatrix} + 0,135335 \begin{pmatrix} -1,750 & -2,000 & -0,250 \\ -0,125 & -2,000 & -0,375 \\ 0,250 & 2,000 & -0,250 \end{pmatrix}^2 =$$

$$= \begin{pmatrix} 0,193471 & -1,065512 & -0,358348 \\ -0,029068 & 0,435547 & 0,062902 \\ 0,058136 & -0,135335 & -0,242076 \end{pmatrix}$$

Caso desejar-se determinar uma série de potências  $f(\mathbf{A}t) = \sum_{i=0}^{\infty} c_i \cdot t^i \cdot \mathbf{A}^i = \Psi(t)$  onde a variável  $t$  é uma variável escalar real, esta função pode ser reescrita na forma:  $\Psi(t) = \sum_{i=0}^{n-1} [\alpha_i(t)] \cdot \mathbf{A}^i$  onde  $\alpha_i(t)$  é uma função escalar de  $t$  determinada através da solução de:

(i)  $\sum_{i=0}^{n-1} \alpha_i(t) \cdot \lambda_k^i = f(\lambda_k t)$  para  $k = 1, 2, \dots, n$  se os valores característicos de  $\mathbf{A}$  são todos distintos;

(ii)  $\sum_{i=0}^{n-1} \alpha_i(t) \cdot \lambda_1^i = f(\lambda_1 t)$  ;

$$\sum_{i=1}^{n-1} i \alpha_i(t) \cdot \lambda_1^{i-1} = t \left[ \frac{df(\xi)}{d\xi} \right]_{\xi=\lambda_1 t} ;$$

$$\sum_{i=2}^{n-1} i(i-1) \alpha_i(t) \cdot \lambda_1^{i-2} = t^2 \left[ \frac{d^2 f(\xi)}{d\xi^2} \right]_{\xi=\lambda_1 t} ;$$

$$\vdots$$

$$\sum_{i=m}^{n-1} i(i-1) \dots (i-m+1) \alpha_i(t) \cdot \lambda_1^{i-m} = t^m \left[ \frac{d^m f(\xi)}{d\xi^m} \right]_{\xi=\lambda_1 t}$$

sendo as demais equações:

$$\sum_{i=0}^{n-1} \alpha_i(t) \cdot \lambda_k^i = f(\lambda_k t) \quad \text{para } k = m+1, m+2, \dots, n. \text{ se}$$

$$\lambda_1 = \lambda_2 = \dots = \lambda_m \neq \lambda_{m+1} \neq \dots \neq \lambda_n$$

Exemplos Ilustrativos: (a) para  $\mathbf{A} = \begin{pmatrix} 4 & 2 \\ 1 & 3 \end{pmatrix}$  calcule  $\exp(\mathbf{A}t)$ ;

(b) para  $\mathbf{A} = \begin{pmatrix} -3 & -2 \\ 2 & 1 \end{pmatrix}$  calcule.  $\exp(\mathbf{A}t)$ .

(a)  $p(\lambda) = \lambda^2 - 7\lambda + 10 = (\lambda - 2)(\lambda - 5) \Rightarrow \lambda_1 = 2$  e  $\lambda_2 = 5$  , assim:

$$\begin{cases} \alpha_0 = \frac{5e^{2t} - 2e^{5t}}{3} \\ \alpha_1 = \frac{e^{5t} - e^{2t}}{3} \end{cases}; \text{ logo: } \exp(\mathbf{A}t) = \left( \frac{5e^{2t} - 2e^{5t}}{3} \right) \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} + \left( \frac{e^{5t} - e^{2t}}{3} \right) \begin{pmatrix} 4 & 2 \\ 1 & 3 \end{pmatrix} \text{ então:}$$

$$\frac{d[\exp(\mathbf{A}t)]}{dt} = 10 \left( \frac{e^{2t} - e^{5t}}{3} \right) \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} + \left( \frac{5e^{5t} - 2e^{2t}}{3} \right) \begin{pmatrix} 4 & 2 \\ 1 & 3 \end{pmatrix} e$$

$$\begin{aligned} \mathbf{A}[\exp(\mathbf{A}t)] &= \left( \frac{5e^{2t} - 2e^{5t}}{3} \right) \begin{pmatrix} 4 & 2 \\ 1 & 3 \end{pmatrix} + \left( \frac{e^{5t} - e^{2t}}{3} \right) \left\{ 7 \begin{pmatrix} 4 & 2 \\ 1 & 3 \end{pmatrix} - 10 \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} \right\} = \\ &= 10 \left( \frac{e^{2t} - e^{5t}}{3} \right) \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} + \left( \frac{5e^{5t} - 2e^{2t}}{3} \right) \begin{pmatrix} 4 & 2 \\ 1 & 3 \end{pmatrix} = \frac{d[\exp(\mathbf{A}t)]}{dt} e \end{aligned}$$

$\exp(\mathbf{A}0) = \mathbf{I}$ , comprovando que esta matriz exponencial está correta.

(b)  $p(\lambda) = \lambda^2 + 2\lambda + 1 = (\lambda + 1)^2 \Rightarrow \lambda_1 = \lambda_2 = -1$  deve-se assim resolver o sistema:

$$\begin{cases} \alpha_0 + \alpha_1 \lambda_1 = e^{\lambda_1 t} \\ \alpha_1 = t e^{\lambda_1 t} \end{cases} \Rightarrow \begin{cases} \alpha_0 - \alpha_1 = e^{-t} \\ \alpha_1 = t e^{-t} \end{cases} \Rightarrow \begin{cases} \alpha_0 = (1+t)e^{-t} \\ \alpha_1 = t e^{-t} \end{cases} \Rightarrow \begin{cases} \frac{d\alpha_0}{dt} = -t e^{-t} \\ \frac{d\alpha_1}{dt} = (1-t)e^{-t} \end{cases} \text{ assim:}$$

$$\exp(\mathbf{A}t) = (1+t)e^{-t} \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} + t e^{-t} \begin{pmatrix} -3 & -2 \\ 2 & 3 \end{pmatrix}; \exp(\mathbf{A}t)|_{t=0} = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} e$$

$$\frac{d[\exp(\mathbf{A}t)]}{dt} = -t e^{-t} \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} + (1-t)e^{-t} \begin{pmatrix} -3 & -2 \\ 2 & 3 \end{pmatrix} e$$

$$\mathbf{A}[\exp(\mathbf{A}t)] = (1+t)e^{-t} \begin{pmatrix} -3 & -2 \\ 2 & 3 \end{pmatrix} - t e^{-t} \left\{ 2 \begin{pmatrix} -3 & -2 \\ 2 & 3 \end{pmatrix} + \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} \right\} = \frac{d[\exp(\mathbf{A}t)]}{dt} e,$$

comprovando que a matriz exponencial está correta.

### 5) FORMAS QUADRÁTICAS

Em  $\mathfrak{R}^2$  a expressão geral das formas quadráticas é:

$$f(x_1, x_2) = c + b_1 \cdot x_1 + b_2 \cdot x_2 + \frac{a_{11}}{2} \cdot x_1^2 + a_{12} \cdot x_1 \cdot x_2 + \frac{a_{22}}{2} \cdot x_2^2,$$

cujas derivadas parciais são:

$$\frac{\partial f(x_1, x_2)}{\partial x_1} = b_1 + a_{11} \cdot x_1 + a_{12} \cdot x_2 \quad e \quad \frac{\partial f(x_1, x_2)}{\partial x_2} = b_2 + a_{22} \cdot x_2 + a_{12} \cdot x_1$$

$$\frac{\partial^2 f(x_1, x_2)}{\partial x_1^2} = a_{11}; \quad \frac{\partial f(x_1, x_2)}{\partial x_1 \partial x_2} = \frac{\partial f(x_1, x_2)}{\partial x_2 \partial x_1} = a_{12} \quad e \quad \frac{\partial^2 f(x_1, x_2)}{\partial x_2^2} = a_{22}.$$

Esta forma quadrada pode ser rescrita em forma matricial, segundo:

$$f(x_1, x_2) = c + (b_1 \ b_2) \cdot \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} + \frac{1}{2} \cdot (x_1 \ x_2) \cdot \begin{pmatrix} a_{11} & a_{12} \\ a_{12} & a_{22} \end{pmatrix} \cdot \begin{pmatrix} x_1 \\ x_2 \end{pmatrix}, \text{ ou seja, definindo:}$$

$$\mathbf{x} = \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} \in \mathfrak{R}^2, \mathbf{b} = \begin{pmatrix} b_1 \\ b_2 \end{pmatrix} \in \mathfrak{R}^2 \text{ e } \mathbf{A} = \begin{pmatrix} a_{11} & a_{12} \\ a_{12} & a_{22} \end{pmatrix} \in \mathfrak{R}^{2 \times 2} \text{ [ matriz simétrica], tem-se:}$$

$$f(\mathbf{x}) = c + \mathbf{b}^T \cdot \mathbf{x} + \frac{1}{2} \cdot \mathbf{x}^T \cdot \mathbf{A} \cdot \mathbf{x}$$

definindo o operador diferencial vetorial :  $\nabla = \begin{pmatrix} \frac{\partial}{\partial x_1} \\ \frac{\partial}{\partial x_2} \end{pmatrix}$  (operador *gradiente*), tem-se:

$$\nabla f(\mathbf{x}) = \begin{pmatrix} \frac{\partial f(x_1, x_2)}{\partial x_1} \\ \frac{\partial f(x_1, x_2)}{\partial x_2} \end{pmatrix} = \mathbf{b} + \mathbf{A} \cdot \mathbf{x} \text{ (vetor gradiente de uma função escalar } f) \text{ e}$$

$$\nabla^2 f(\mathbf{x}) = \begin{pmatrix} \frac{\partial}{\partial x_1} & \frac{\partial}{\partial x_2} \end{pmatrix} \cdot \begin{pmatrix} \frac{\partial f(x_1, x_2)}{\partial x_1} \\ \frac{\partial f(x_1, x_2)}{\partial x_2} \end{pmatrix} = \frac{\partial^2 f(x_1, x_2)}{\partial^2 x_1} + \frac{\partial^2 f(x_1, x_2)}{\partial^2 x_2} = a_{11} + a_{22} = \text{tr}(\mathbf{A})$$

(Laplaciano de uma função escalar).

Define-se também a *matriz Hessiana* por:

$$\mathbf{H}(\mathbf{x}) = \begin{pmatrix} \frac{\partial}{\partial x_1} \\ \frac{\partial}{\partial x_2} \end{pmatrix} \cdot \begin{pmatrix} \frac{\partial f(x_1, x_2)}{\partial x_1} & \frac{\partial f(x_1, x_2)}{\partial x_2} \end{pmatrix} = \begin{pmatrix} \frac{\partial^2 f(x_1, x_2)}{\partial^2 x_1} & \frac{\partial^2 f(x_1, x_2)}{\partial x_1 \partial x_2} \\ \frac{\partial^2 f(x_1, x_2)}{\partial x_2 \partial x_1} & \frac{\partial^2 f(x_1, x_2)}{\partial^2 x_2} \end{pmatrix} = \mathbf{A}.$$

Estas definições podem ser generalizadas para  $\mathfrak{R}^n$ , segundo:

$$\mathbf{x} = \begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{pmatrix} \in \mathfrak{R}^n, \mathbf{b} = \begin{pmatrix} b_1 \\ b_2 \\ \vdots \\ b_n \end{pmatrix} \in \mathfrak{R}^n \text{ e } \mathbf{A} = \begin{pmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ a_{12} & a_{22} & \cdots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{1n} & a_{2n} & \cdots & a_{nn} \end{pmatrix} \in \mathfrak{R}^{n \times n} \text{ [ matriz simétrica],}$$

$$\text{tem-se: } f(\mathbf{x}) = c + \mathbf{b}^T \cdot \mathbf{x} + \frac{1}{2} \cdot \mathbf{x}^T \cdot \mathbf{A} \cdot \mathbf{x} = c + \sum_{i=1}^n b_i \cdot x_i + \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n a_{ij} \cdot x_i \cdot x_j,$$

$$\nabla f(\mathbf{x}) = \begin{pmatrix} \frac{\partial f(\mathbf{x})}{\partial x_1} \\ \frac{\partial f(\mathbf{x})}{\partial x_2} \\ \vdots \\ \frac{\partial f(\mathbf{x})}{\partial x_n} \end{pmatrix} = \mathbf{b} + \mathbf{A} \cdot \mathbf{x},$$

$$\nabla^2 f(\mathbf{x}) = \begin{pmatrix} \frac{\partial}{\partial x_1} & \frac{\partial}{\partial x_2} & \cdots & \frac{\partial}{\partial x_n} \end{pmatrix} \cdot \begin{pmatrix} \frac{\partial f(\mathbf{x})}{\partial x_1} \\ \frac{\partial f(\mathbf{x})}{\partial x_2} \\ \vdots \\ \frac{\partial f(\mathbf{x})}{\partial x_n} \end{pmatrix} = a_{11} + a_{22} + \cdots + a_{nn} = \text{tr}(\mathbf{A})$$

$$\mathbf{H}(\mathbf{x}) = \begin{pmatrix} \frac{\partial}{\partial x_1} \\ \frac{\partial}{\partial x_2} \\ \vdots \\ \frac{\partial}{\partial x_n} \end{pmatrix} \cdot \begin{pmatrix} \frac{\partial f(\mathbf{x})}{\partial x_1} & \frac{\partial f(\mathbf{x})}{\partial x_2} & \cdots & \frac{\partial f(\mathbf{x})}{\partial x_n} \end{pmatrix} = \begin{pmatrix} \frac{\partial^2 f(\mathbf{x})}{\partial x_1^2} & \frac{\partial^2 f(\mathbf{x})}{\partial x_1 \partial x_2} & \cdots & \frac{\partial^2 f(\mathbf{x})}{\partial x_1 \partial x_n} \\ \frac{\partial^2 f(\mathbf{x})}{\partial x_2 \partial x_1} & \frac{\partial^2 f(\mathbf{x})}{\partial x_2^2} & \cdots & \frac{\partial^2 f(\mathbf{x})}{\partial x_2 \partial x_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2 f(\mathbf{x})}{\partial x_n \partial x_1} & \frac{\partial^2 f(\mathbf{x})}{\partial x_n \partial x_2} & \cdots & \frac{\partial^2 f(\mathbf{x})}{\partial x_n^2} \end{pmatrix} = \mathbf{A}$$

$$H_{ij}(\mathbf{x}) = \frac{\partial^2 f(\mathbf{x})}{\partial x_i \partial x_j} = \frac{\partial^2 f(\mathbf{x})}{\partial x_j \partial x_i} = H_{ji}(\mathbf{x}) \text{ [matriz simétrica]}. \text{ Note que caso a matriz } \mathbf{A} \text{ não seja}$$

simétrica redefinam-se seus elementos na forma:

$$a_{ij, \text{velha}} = \left( \frac{a_{ij, \text{velha}} + a_{ji, \text{velha}}}{2} \right) \text{ ou, em termos matriciais, } \mathbf{A}_{\text{nova}} = \frac{1}{2} \cdot (\mathbf{A}_{\text{velha}} + \mathbf{A}_{\text{velha}}^T)$$

A forma quadrática acima pode ser simplificada, através de um translação do eixo, tal que o termo  $\mathbf{b}^T \mathbf{x}$  desapareçam, assim sejam as novas coordenadas  $(y_1, y_2, \dots, y_n)$  tais que:  $\mathbf{x} = \mathbf{y} + \mathbf{d}$  assim:  $\mathbf{b}^T \cdot \mathbf{x} = \mathbf{b}^T \cdot \mathbf{y} + \mathbf{b}^T \cdot \mathbf{d}$  e

$$\mathbf{x}^T \cdot \mathbf{A} \cdot \mathbf{x} = (\mathbf{y}^T + \mathbf{d}^T) \cdot (\mathbf{A} \cdot \mathbf{y} + \mathbf{A} \cdot \mathbf{d}) = \mathbf{y}^T \cdot \mathbf{A} \cdot \mathbf{y} + \mathbf{y}^T \cdot \mathbf{A} \cdot \mathbf{d} + \mathbf{d}^T \cdot \mathbf{A} \cdot \mathbf{y} + \mathbf{d}^T \cdot \mathbf{A} \cdot \mathbf{d} =$$

$$= \mathbf{y}^T \cdot \mathbf{A} \cdot \mathbf{y} + 2\mathbf{d}^T \cdot \mathbf{A} \cdot \mathbf{y} + \mathbf{d}^T \cdot \mathbf{A} \cdot \mathbf{d} \text{ pois: } \mathbf{y}^T \cdot \mathbf{A} \cdot \mathbf{d} = \mathbf{d}^T \cdot \mathbf{A} \cdot \mathbf{y} \text{ [ } \mathbf{A} \text{ é simétrica]}, \text{ logo:}$$

$$f(\mathbf{y}) = c + \mathbf{b}^T \cdot \mathbf{y} + \mathbf{b}^T \cdot \mathbf{d} + \frac{1}{2} \mathbf{y}^T \cdot \mathbf{A} \cdot \mathbf{y} + \mathbf{d}^T \cdot \mathbf{A} \cdot \mathbf{y} + \frac{1}{2} \mathbf{d}^T \cdot \mathbf{A} \cdot \mathbf{d}$$

$$\text{identificando: } f(\mathbf{d}) = c + \mathbf{b}^T \cdot \mathbf{d} + \frac{1}{2} \mathbf{d}^T \cdot \mathbf{A} \cdot \mathbf{d} = \hat{c} \text{ e definindo } \hat{\mathbf{b}} = \mathbf{b} + \mathbf{A} \cdot \mathbf{d}$$

$f(\mathbf{y}) = \hat{c} + \hat{\mathbf{b}}^T \cdot \mathbf{y} + \frac{1}{2} \cdot \mathbf{y}^T \cdot \mathbf{A} \cdot \mathbf{y}$ , adotando  $\mathbf{d}$  tal que :  $\hat{\mathbf{b}} = \mathbf{b} + \mathbf{A} \cdot \mathbf{d} = \mathbf{0} \Rightarrow \mathbf{d} = \mathbf{A}^{-1} \cdot \mathbf{b}$  o que só será possível se  $\mathbf{A}$  for regular, assim chega-se a:

$$f(\mathbf{y}) = \hat{c} + \frac{1}{2} \cdot \mathbf{y}^T \cdot \mathbf{A} \cdot \mathbf{y} \text{ onde : } \mathbf{x} = \mathbf{y} + \mathbf{d} \text{ , } \mathbf{d} = \mathbf{A}^{-1} \cdot \mathbf{b} \text{ e } \hat{c} = f(\mathbf{d}) = c + \mathbf{b}^T \cdot \mathbf{d} + \frac{1}{2} \cdot \mathbf{d}^T \cdot \mathbf{A} \cdot \mathbf{d} \text{ ,}$$

neste novo sistema de coordenadas tem-se:

$$\nabla f(\mathbf{y}) = \begin{pmatrix} \frac{\partial f(\mathbf{y})}{\partial y_1} \\ \frac{\partial f(\mathbf{y})}{\partial y_2} \\ \vdots \\ \frac{\partial f(\mathbf{y})}{\partial y_n} \end{pmatrix} = \mathbf{A} \cdot \mathbf{y} \text{ , neste novo sistema de coordenadas o valor da variável}$$

independente  $\mathbf{y}$  que anula o vetor gradiente é o valor nulo, isto é a origem :  $\mathbf{y} = \mathbf{0}$  e neste ponto o valor da função  $f(\mathbf{y})$  é igual a :  $\hat{c}$ . Esta condição,  $\nabla f(\mathbf{y}) = \mathbf{0}$  é uma condição necessária para o ponto ser um extremo da função (máximo ou mínimo) e é chamado de ponto crítico, este ponto será um ponto de mínimo se para qualquer vizinhança de  $\mathbf{y} = \mathbf{0}$  , isto é :  $\|\mathbf{y}\| \leq \delta$ , a função é  $f(\mathbf{y}) > f(\mathbf{0}) = \hat{c}$ , ou seja :  $\mathbf{y}^T \cdot \mathbf{A} \cdot \mathbf{y} > 0$  e, neste caso, a matriz  $\mathbf{A}$  é chamada de positiva definida e caso em toda vizinhança de  $\mathbf{y} = \mathbf{0}$  a é  $f(\mathbf{y}) < f(\mathbf{0}) = \hat{c}$ , ou seja :  $\mathbf{y}^T \cdot \mathbf{A} \cdot \mathbf{y} < 0$  e, neste caso, a matriz  $\mathbf{A}$  é chamada de negativa definida e o ponto é um ponto de máximo. Em qualquer outra situação o ponto não é nem de máximo nem de mínimo, e no caso da matriz ser não definida tem-se o chamado ponto de sela.

A forma quadrática pode também ser rescrita em sua forma canônica, de forma análoga à apresentada no processo de diagonalização de matrizes, assim considerando  $\mathbf{y} = \mathbf{P} \cdot \mathbf{z}$ , onde  $\mathbf{P}$  é a matriz cujos vetores coluna são os vetores característicos normalizados de  $\mathbf{A}$  (por enquanto considerados  $n$  vetores característicos linearmente independentes e ortogonais entre si, isto é os valores característicos são todos reais e distintos - matriz  $\mathbf{A}$  é simétrica ), tem-se assim:

$$f(\mathbf{z}) = \hat{c} + \frac{1}{2} \mathbf{z}^T \cdot (\mathbf{P}^T \cdot \mathbf{A} \cdot \mathbf{P}) \cdot \mathbf{z} = \hat{c} + \frac{1}{2} \mathbf{z}^T \cdot \mathbf{D} \cdot \mathbf{z} = \hat{c} + \frac{1}{2} \cdot \sum_{i=1}^n \lambda_i \cdot z_i^2 \text{ , como à origem } \mathbf{y} = \mathbf{0}$$

correspondente também a  $\mathbf{z} = \mathbf{0}$ , tem-se  $\mathbf{z} = \mathbf{0}$  como ponto de mínimo se  $\sum_{i=1}^n \lambda_i \cdot z_i^2 > 0$  para

todo o domínio em que  $\mathbf{z} \neq \mathbf{0}$  se  $\lambda_i > 0$  para todo  $i = 1, \dots, n$  ,  $\mathbf{z} = \mathbf{0}$  é um ponto de

máximo se  $\sum_{i=1}^n \lambda_i \cdot z_i^2 < 0$  para todo o domínio em que  $\mathbf{z} \neq \mathbf{0}$  se

$\lambda_i < 0$  para todo  $i = 1, \dots, n$  e  $\mathbf{z} = \mathbf{0}$  é um ponto de sela se não há vizinhança de  $\mathbf{z} = \mathbf{0}$  na


qual  $\sum_{i=1}^n \lambda_i \cdot z_i^2$  não muda de sinal o que ocorre se alguns  $\lambda_i < 0$  e os demais são  $\lambda_i > 0$ .

No  $\mathfrak{R}^2$  a forma canônica assume a forma:


$f(z_1, z_2) = \hat{c} + \frac{1}{2}(\lambda_1 \cdot z_1^2 + \lambda_2 \cdot z_2^2)$ , neste caso a forma das curvas de nível caracterizam as seguinte cônicas, de acordo com o sinal de  $\Delta = \det(\mathbf{A}) = a_{11} \cdot a_{22} - a_{12}^2 = \lambda_1 \cdot \lambda_2$ , assim com  $\Delta > 0$  : elipse;  $\Delta < 0$  : hipérbole e  $\Delta = 0$  : parábola .

(a) Elipse: neste caso os valores característicos têm o mesmo sinal, sendo  $\mathbf{z}=\mathbf{0}$  um ponto de mínimo se ambos forem positivos e um ponto de máximo se ambos forem negativos. O tamanho do eixo  $z_1$  é  $\frac{2}{\lambda_1}[K-\hat{c}]$  e do eixo  $z_2$  é  $\frac{2}{\lambda_2}[K-\hat{c}]$ , onde  $K=f(z_1, z_2)$  [ verificando que se  $\mathbf{z}=\mathbf{0}$  é um ponto de mínimo  $K > \hat{c}$ ,  $\lambda_1 > 0$  e  $\lambda_2 > 0$  e se  $\mathbf{z}=\mathbf{0}$  é um ponto de máximo  $K < \hat{c}$ ,  $\lambda_1 < 0$  e  $\lambda_2 < 0$ , deste modo em ambos os casos:  $\frac{2}{\lambda_1}[K-\hat{c}] > 0$  e  $\frac{2}{\lambda_2}[K-\hat{c}] > 0$ ].

A seguir representam-se a superfície  $f(z_1, z_2)$  e as correspondentes curvas de contorno:




M




M

$$f(z_1, z_2) = z_1^2 + (5 \cdot z_2)^2$$

(b) Hipérbole: neste caso os valores característicos têm os sinais distintos, sendo  $\mathbf{z}=\mathbf{0}$  um ponto de sela. Abaixo representam-se a superfície  $f(z_1, z_2)$  e as correspondentes curvas de contorno



M



M

$$f(z_1, z_2) = z_1^2 - (5 \cdot z_2)^2$$

(c) Parábola: neste caso um dos valores característicos é nulo e portanto a matriz  $\mathbf{A}$  é singular, desta forma não é possível fazer a translação de eixo que elimina o termo  $\mathbf{b}^T \mathbf{x}$ . Então neste caso a rotação dos eixos é aplicada diretamente às variáveis  $(x_1, x_2)$ , isto é :  $\mathbf{x} = \mathbf{P} \cdot \mathbf{z}$ , obtendo-se :

$$f(z_1, z_2) = c + \tilde{b}_1 \cdot z_1 + \tilde{b}_2 \cdot z_2 + \frac{\lambda_1}{2} \cdot z_1^2 \text{ se } \lambda_2 = 0 \text{ ou:}$$




$f(z_1, z_2) = c + \tilde{b}_1 \cdot z_1 + \tilde{b}_2 \cdot z_2 + \frac{\lambda_2}{2} \cdot z_2^2$  se  $\lambda_1 = 0$ , onde  $\mathbf{b} = \mathbf{P} \cdot \tilde{\mathbf{b}} \Leftrightarrow \tilde{\mathbf{b}} = \mathbf{P} \cdot \mathbf{b}$ . Verifica-se assim que a condição necessária não é obtida em nenhum dos casos, pois no primeiro caso

tem-se:  $\nabla f(\mathbf{z}) = \begin{pmatrix} \frac{\partial f(z_1, z_2)}{\partial z_1} \\ \frac{\partial f(z_1, z_2)}{\partial z_2} \end{pmatrix} = \begin{pmatrix} \tilde{b}_1 + \lambda_1 \cdot z_1 \\ \tilde{b}_2 \end{pmatrix}$  segundo componente não nulo,


e no segundo caso tem-se:  $\nabla f(\mathbf{z}) = \begin{pmatrix} \frac{\partial f(z_1, z_2)}{\partial z_1} \\ \frac{\partial f(z_1, z_2)}{\partial z_2} \end{pmatrix} = \begin{pmatrix} \tilde{b}_1 \\ \tilde{b}_2 + \lambda_2 \cdot z_2 \end{pmatrix}$  primeiro componente não

nulo. Deste modo em ambos os casos um dos componentes do vetor gradiente é constante não podendo ser anulado através da escolha de  $z_1$  ou  $z_2$ , neste caso não se tem nem máximo nem mínimo. Abaixo, representa-se curvas de nível para cada um dos casos.



M  
curvas de nível (um dos val. caract. =0)

$$f(z_1, z_2) := z_1 + 2 \cdot z_2 + 5 \cdot (z_2)^2$$



M  
curvas de nível (um dos val. caract. =0)

$$f(z_1, z_2) := z_2 + 2 \cdot z_1 + 5 \cdot (z_1)^2$$

### Lista de Exercícios

1) Mostre que toda matriz ortogonal apresenta o determinante +1 ou -1. *Sugestão:* parta dos princípios que  $\det(\mathbf{A}) = \det(\mathbf{A}^T)$  e que  $\det(\mathbf{A}^{-1}) = 1/\det(\mathbf{A})$ .

2) Mostre que  $(\mathbf{A} \cdot \mathbf{B})^T = \mathbf{B}^T \cdot \mathbf{A}^T$

3) Mostre que  $(\mathbf{A} \cdot \mathbf{B})^{-1} = \mathbf{B}^{-1} \cdot \mathbf{A}^{-1}$

4) Mostre que  $(\mathbf{A}^{-1})^T = (\mathbf{A}^T)^{-1}$