

Departamento de Ciências Florestais
ESALQ - USP

**Elementos de Álgebra de Matrizes
Importantes para Regressão Linear**

João L. F. Batista

Piracicaba
– 2004 –

Sumário

1	Introdução	1
2	Definição de Matrizes	1
2.1	Algumas Matrizes Especiais	2
3	Manipulação Algébrica de Matrizes	4
3.1	Igualdade de Matrizes	4
3.2	Transposição de Matrizes	5
3.2.1	Implicações da Transposição	5
3.3	Adição e Subtração	6
3.3.1	Propriedades da Adição/Subtração	6
3.4	Multiplicação	7
3.4.1	Multiplicação de Matrix por Escalar	7
3.4.2	Produto Interno	7
3.4.3	Produto Externo	8
3.4.4	Multiplicação de Matrix por Vetor	8
3.4.5	Combinação Linear	10
3.4.6	Multiplicação Matrix por Matrix	10
3.4.7	Propriedades da Multiplicação de Matrizes	12
3.5	Representação Matricial do Somatório de Valores	13
4	Geometria Matricial	15
4.1	Espaços Vetoriais	16
4.2	Base de Espaços Vetoriais	17
4.3	Dependência Linear	19
4.4	Subespaços Vetoriais	20
4.5	Posto de uma Matrix	22
4.5.1	Propriedades do Posto de uma Matrix Importantes para Regressão	23

4.6	Determinante de uma Matrix	24
4.6.1	Alguns Aspectos Úteis do Determinante de uma Matrix	25
4.7	Norma e Ortogonalidade de Vetores	26
5	Solução de Sistemas Lineares	27
5.1	Sistemas de Equações Lineares	27
5.2	Matrix Inversa	28
5.2.1	Algumas Propriedades de Matrizes Inversas	29
5.3	Solução de Sistemas Lineares Não-Homogêneos	30
6	Auto-Valores e Auto-Vetores	31
6.1	Solução do Sistema	31
6.2	Resultados Úteis para Matrizes Simétricas	32
6.3	Posto de Matrizes	34
6.4	Número Condicional de uma Matriz	35
6.5	Determinante por Decomposição	35
6.6	Potências de uma Matrix	36
7	Vetores e Matrizes Aleatórios	37
7.1	Valor Esperado	38
7.2	Matrix de Variância-Covariância de um Vetor Aleatório	38
7.3	Algumas Propriedades envolvendo Vetores Aleatório	39
8	Exercícios	39

1 Introdução

- A importância da álgebra de matrizes na regressão linear múltipla se relaciona principalmente a dois aspectos dos problemas de regressão múltipla:
 - envolvem sistemas de equações extensos; e
 - envolvem grande conjuntos de dados.
- A álgebra de matrizes na regressão múltipla permite:
 - representação compacta dos sistemas;
 - operações eficientes independentemente do tamanho dos sistemas;
 - notação matemática clara e concisa.

2 Definição de Matrizes

Matrix é um conjunto retangular de elementos arranjados em *linhas* e *colunas*:

	Coluna 1	Coluna 2
Linha 1	34.090	2
Linha 2	125.001	9
Linha 3	5.671	5

A matrix acima é designada de matrix de *ordem* 3×2 por que possui 3 linhas por duas colunas.

Outro exemplos de matrizes são:

$$\text{Matrix } 2 \times 2 : \begin{bmatrix} 0 & 3 \\ 8 & 2 \end{bmatrix} \quad \text{Matrix } 2 \times 3 : \begin{bmatrix} 8 & 9 & 4 \\ 7 & 2 & 1 \end{bmatrix}$$

$$\text{Matrix } 4 \times 1 : \begin{bmatrix} 12 \\ 34 \\ 45 \\ 76 \end{bmatrix} \quad \text{Matrix } 1 \times 3 : [0.002 \quad 0.201 \quad 1.345]$$

Utilizamos índices para representar os elementos de uma matrix:

$$\begin{array}{l} i = 1 \\ i = 2 \end{array} \begin{array}{ccc} j = 1 & j = 2 & j = 3 \\ \left[\begin{array}{ccc} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \end{array} \right] \end{array}$$

sendo que o índice i representa as *linhas* e o índice j representa as *colunas*.

Para diferenciar matrizes de outros entes matemáticos, o nome das matrizes são geralmente indicados por letras em **negrito**, como **A**, **X**, **Z**. Assim a matrix acima pode ser definida como:

$$\mathbf{A} = \begin{bmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \end{bmatrix}$$

ou então pela expressão:

$$\mathbf{A} = [a_{ij}] \quad i = 1, 2; \quad j = 1, 2, 3.$$

Note que em ambas notações fica claro que **A** é uma matrix 2×3 .

Para representar resumidamente uma grande matrix com ordem $n \times p$, frequentemente utilizamos a expressão:

$$\mathbf{A} = \begin{bmatrix} a_{11} & a_{12} & \dots & a_{1j} & \dots & a_{1p} \\ a_{21} & a_{22} & \dots & a_{2j} & \dots & a_{2p} \\ \vdots & \vdots & & \vdots & & \vdots \\ a_{i1} & a_{i2} & \dots & a_{ij} & \dots & a_{ip} \\ \vdots & \vdots & & \vdots & & \vdots \\ a_{n1} & a_{n2} & \dots & a_{nj} & \dots & a_{np} \end{bmatrix}$$

ou na forma abreviada:

$$\mathbf{A} = [a_{ij}] \quad i = 1, \dots, n; \quad j = 1, \dots, p.$$

2.1 Algumas Matrizes Especiais

Matrix Quadrada é uma matrix com igual número de linhas e colunas, por exemplo:

$$\begin{array}{l} \text{Matrix } 1 \times 1 : \begin{bmatrix} 0.002 \end{bmatrix} \\ \text{Matrix } 2 \times 2 : \begin{bmatrix} 0 & 3 \\ 8 & 2 \end{bmatrix} \\ \text{Matrix } 3 \times 3 : \begin{bmatrix} 8 & 9 & 4 \\ 7 & 2 & 1 \\ 10 & -3 & -5 \end{bmatrix} \\ \text{Matrix } 4 \times 4 : \begin{bmatrix} 12 & 34 & 45 & 76 \\ 2 & 6 & -1 & 0 \\ -3 & 7 & 10 & 8 \\ 1 & -9 & 0 & 34 \end{bmatrix} \end{array}$$

Vetores: uma matrix é chamada de *vetor coluna* quando ela possui apenas uma coluna:

$$\mathbf{a} = \begin{bmatrix} 1 \\ 0 \\ 0 \\ 1 \end{bmatrix} \quad \mathbf{b} = \begin{bmatrix} c_1 \\ c_2 \\ c_3 \end{bmatrix} \quad \mathbf{c} = \begin{bmatrix} -1 \\ 0 \\ 1 \end{bmatrix}$$

Uma matrix é dita *vetor linha* quando formada por apenas uma linha:

$$\mathbf{b} = \begin{bmatrix} 3 & 8 & -2 \end{bmatrix} \quad \mathbf{x} = \begin{bmatrix} x_1 & x_2 & x_3 & x_4 \end{bmatrix}$$

Assumiremos que o formato padrão dos vetores é a forma de **vetor coluna**, assim, quando nos referirmos genericamente a um *vetor*, entenda-se *vetor coluna*.

Matrix Escalar ou (simplesmente) Escalar é uma matrix composta de apenas uma linha e uma coluna:

$$\mathbf{A} = [7].$$

Matrix Simétrica é uma *matrix quadrada* em que a permutação do número da linha pela coluna resulta em elementos de mesmo valor, i.e.,

$$a_{ij} = a_{ji}, \quad \text{para todo } i \text{ e } j.$$

Por exemplo, na matrix

$$\mathbf{A} = \begin{bmatrix} 1 & 0 & 2 \\ 0 & 7 & 3 \\ 2 & 3 & 6 \end{bmatrix},$$

temos que:

$$a_{12} = a_{21} = 0$$

$$a_{13} = a_{31} = 2$$

$$a_{23} = a_{32} = 3$$

Matrix Diagonal é uma *matrix quadrada* cujos únicos elementos não nulos estão na diagonal principal. Exemplos:

$$\mathbf{A} = \begin{bmatrix} 7 & 0 \\ 0 & 9 \end{bmatrix} \quad \mathbf{B} = \begin{bmatrix} -2 & 0 & 0 \\ 0 & 5 & 0 \\ 0 & 0 & 7 \end{bmatrix} \quad \mathbf{C} = \begin{bmatrix} c_1 & 0 & 0 & 0 \\ 0 & c_2 & 0 & 0 \\ 0 & 0 & c_3 & 0 \\ 0 & 0 & 0 & c_4 \end{bmatrix}$$

Note que toda matrix diagonal é necessariamente simétrica.

Matrix Identidade é uma *matrix diagonal* cujos os elementos da diagonal principal são todos unitários:

$$\mathbf{I}_2 = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \quad \mathbf{I}_3 = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad \mathbf{I}_4 = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}$$

Vetores e Matrizes Unitários são aqueles em que *todos os elementos* são unitários. Particularmente úteis à análise de regressão são os vetores colunas unitários:

$$\mathbf{i} = \begin{bmatrix} 1 \\ 1 \\ 1 \\ 1 \end{bmatrix}$$

e as matrizes quadradas unitárias:

$$\mathbf{J}_3 = \begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix} \quad \mathbf{J}_4 = \begin{bmatrix} 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 \end{bmatrix}$$

Matrix Triangular é uma matrix cujos elementos acima ou abaixo da diagonal principal são nulos.

Matrix Triangular Superior elementos *abaixo* da diagonal principal são *nulos*:

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

Matrix Triangular Inferior elementos *acima* da diagonal principal são *nulos*:

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

3 Manipulação Algébrica de Matrizes

3.1 Igualdade de Matrizes

Duas matrizes **A** e **B** são consideradas iguais quando *todos os seus elementos correspondentes são iguais*, i.e., quando

$$a_{ij} = b_{ij} \quad \text{para todo } i \text{ e } j.$$

A primeira exigência da igualdade é que **A** e **B** tenham a mesma ordem. Por exemplo, se **A** e **B** são:

$$\mathbf{A} = \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \\ a_{31} & a_{32} \end{bmatrix} \quad \mathbf{B} = \begin{bmatrix} -4 & 0 \\ 0 & 5 \\ 3 & 4 \end{bmatrix}$$

a expressão $\mathbf{A} = \mathbf{B}$ implica que:

$$a_{11} = -4, \quad a_{12} = 0, \quad a_{21} = 0, \quad a_{22} = 5, \quad a_{31} = 3, \quad a_{32} = 4.$$

3.2 Transposição de Matrizes

A matrix (ou vetor) transposta de uma matrix \mathbf{A} , denotada por \mathbf{A}' , é obtida criando-se uma matrix cuja a k ésima linha é a k ésima coluna da matrix original.

Ou seja, se a matrix original é

$$\mathbf{A} = [a_{ij}]$$

então a sua transposta será

$$\mathbf{B} = \mathbf{A}' \Leftrightarrow b_{ij} = a_{ji} \quad \text{para todo } i \text{ e } j.$$

Se a matrix \mathbf{A} tem ordem $n \times p$, a sua transposta \mathbf{A}' terá ordem $p \times n$.

Exemplo numérico:

$$\mathbf{A} = \begin{bmatrix} 34 & 12 \\ 21 & 43 \\ 63 & -30 \end{bmatrix} \Rightarrow \mathbf{A}' = \begin{bmatrix} 34 & 21 & 63 \\ 12 & 43 & -30 \end{bmatrix}.$$

3.2.1 Implicações da Transposição

- Se a matrix \mathbf{A} é *simétrica* então $\mathbf{A}' = \mathbf{A}$.
- Para qualquer matrix \mathbf{A} , temos que $(\mathbf{A}')' = \mathbf{A}$.
- A transposta de um *vetor coluna* é um *vetor linha*:

$$\mathbf{a} = \begin{bmatrix} a_1 \\ a_2 \\ \vdots \\ a_n \end{bmatrix} \Rightarrow \mathbf{a}' = [a_1 \quad a_2 \quad \cdots \quad a_n]$$

Notação:

- utilizaremos a notação de **letra minúscula em negrito** para vetor coluna: \mathbf{a} ;
- os vetores linhas serão **sempre** representados como vetores transpostos: \mathbf{a}' .

3.3 Adição e Subtração

Adicionar ou **subtrair** duas matrizes requer que ambas tenham a mesma ordem. A adição/subtração é realizado somando-se ou adicionando-se os *elementos correspondentes*:

$$\mathbf{A} = \begin{bmatrix} 34 & 12 \\ 21 & 43 \\ 63 & -30 \end{bmatrix} \quad \mathbf{B} = \begin{bmatrix} -40 & 3 \\ 0 & 10 \\ 2 & 50 \end{bmatrix}$$

$$\mathbf{A} + \mathbf{B} = \begin{bmatrix} 34 + (-40) & 12 + 3 \\ 21 + 0 & 43 + 10 \\ 63 + 2 & -30 + 50 \end{bmatrix} = \begin{bmatrix} -6 & 15 \\ 21 & 53 \\ 65 & 20 \end{bmatrix}$$

$$\mathbf{A} - \mathbf{B} = \begin{bmatrix} 34 - (-40) & 12 - 3 \\ 21 - 0 & 43 - 10 \\ 63 - 2 & -30 - 50 \end{bmatrix} = \begin{bmatrix} 74 & 9 \\ 21 & 33 \\ 61 & -80 \end{bmatrix}$$

Portanto, dado as matrizes:

$$\mathbf{A} = [a_{ij}] \quad \text{e} \quad \mathbf{B} = [b_{ij}] \quad i = 1, \dots, n; \quad j = 1, \dots, p,$$

a adição/subtração corresponde a seguinte operação

$$\mathbf{A} + \mathbf{B} = [a_{ij} + b_{ij}] \quad \text{e} \quad \mathbf{A} - \mathbf{B} = [a_{ij} - b_{ij}]$$

A **matrix nula** na operação de adição/subtração é a matrix de zeros:

$$\mathbf{0} = [x_{ij} = 0] \quad i = 1, \dots, n; \quad j = 1, \dots, p,$$

$$\mathbf{A} + \mathbf{0} = [a_{ij} + 0] = [a_{ij}] = \mathbf{A}$$

3.3.1 Propriedades da Adição/Subtração

Comutativa: $\mathbf{A} + \mathbf{B} = \mathbf{B} + \mathbf{A}$.

Associativa: $(\mathbf{A} + \mathbf{B}) + \mathbf{C} = \mathbf{A} + (\mathbf{B} + \mathbf{C})$.

Matrix Nula: $\mathbf{A} + (-\mathbf{A}) = [a_{ij} - a_{ij}] = [0] = \mathbf{0}$.

Transposição: $(\mathbf{A} + \mathbf{B})' = \mathbf{A}' + \mathbf{B}'$.

3.4 Multiplicação

3.4.1 Multiplicação de Matrix por Escalar

A multiplicação de uma matrix por um escalar é realizada multiplicando-se cada elemento da matrix pelo escalar:

$$\mathbf{A} = \begin{bmatrix} 3 & -2 \\ 9 & 5 \end{bmatrix} \quad 4\mathbf{A} = \begin{bmatrix} 4(3) & 4(-2) \\ 4(9) & 4(5) \end{bmatrix} = \begin{bmatrix} 12 & -8 \\ 36 & 20 \end{bmatrix}$$

Ou seja, se \mathbf{A} é uma matrix e k um escalar, então:

$$k\mathbf{A} = \mathbf{A}k = [k \times a_{ij}]$$

Analogamente, a divisão de \mathbf{A} por k deve ser interpretada como a multiplicação de \mathbf{A} pelo inverso de k :

$$(1/k)\mathbf{A} = \mathbf{A}(1/k) = \left[\frac{a_{ij}}{k} \right]$$

Propriedades:

$$\begin{aligned} (p + q)\mathbf{A} &= p\mathbf{A} + q\mathbf{A} \\ p(\mathbf{A} + \mathbf{B}) &= p\mathbf{A} + p\mathbf{B} \\ p(q\mathbf{A}) &= (pq)\mathbf{A} \\ (-1)\mathbf{A} &= -\mathbf{A} \\ k\mathbf{0} &= \mathbf{0} \\ 0\mathbf{A} &= \mathbf{0} \end{aligned}$$

3.4.2 Produto Interno

O **produto interno** é gerado pela multiplicação de um vetor linha e um vetor coluna (*nessa ordem*). Para que o produto exista ambos vetores devem ter o mesmo número de elementos e o resultado será um *escalar*:

$$\begin{bmatrix} 2 & 7 & -1 \end{bmatrix} \begin{bmatrix} 3 \\ 4 \\ 9 \end{bmatrix} = (2)(3) + (7)(4) + (-1)(9) = 25$$

Note que, a multiplicação dos vetores inicia-se com a multiplicação de cada elemento do vetor linha pelo *respectivo* elemento do vetor coluna, e termina com a soma dos produtos obtidos.

Seja \mathbf{a}' um vetor $1 \times n$ e \mathbf{b} um vetor $n \times 1$, então:

$$\mathbf{a}'\mathbf{b} = a_1b_1 + a_2b_2 + \dots + a_nb_n = \sum_{i=1}^n a_ib_i$$

Propriedade: uma vez que a_ib_i é igual a b_ia_i , temos que $\mathbf{a}'\mathbf{b} = \mathbf{b}'\mathbf{a}$.

3.4.3 Produto Externo

O **produto externo** é gerado pela multiplicação de um vetor coluna e um vetor linha (*nessa ordem*). Para que o produto exista ambos vetores devem ter o mesmo número de elementos e o resultado será uma *matrix quadrada*:

$$\begin{bmatrix} 3 \\ 4 \\ 9 \end{bmatrix} \begin{bmatrix} 2 & 7 & -1 \end{bmatrix} = \begin{bmatrix} 3(2) & 3(7) & 3(-1) \\ 4(2) & 4(7) & 4(-1) \\ 9(2) & 9(7) & 9(-1) \end{bmatrix} = \begin{bmatrix} 6 & 21 & -3 \\ 8 & 28 & -4 \\ 18 & 63 & -9 \end{bmatrix}$$

Note que, a multiplicação dos vetores é realizada multiplicando-se *cada linha* do vetor **coluna** por *cada coluna* do vetor **linha**. Seja \mathbf{a} um vetor $m \times 1$ e \mathbf{b}' um vetor $1 \times n$, então:

$$\mathbf{a}\mathbf{b}' = \begin{bmatrix} a_1b_1 & a_1b_2 & a_1b_3 & \cdots & a_1b_n \\ a_2b_1 & a_2b_2 & a_2b_3 & \cdots & a_2b_n \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ a_nb_1 & a_nb_2 & a_nb_3 & \cdots & a_nb_n \end{bmatrix}.$$

Note que a matrix resultante tem ordem $n \times n$.

Propriedade: uma vez que a_ib_j é igual a b_ja_i , temos que $\mathbf{a}\mathbf{b}' = (\mathbf{b}\mathbf{a}')'$.

3.4.4 Multiplicação de Matrix por Vetor

Uma **matrix** pode ser multiplicada por um **vetor coluna** (*nessa ordem*) se o número de *elementos* no vetor for igual ao número de *colunas* da matrix.

A multiplicação é obtida realizando o **produto interno** de cada linha da matrix com o vetor, sendo que o resultado será um vetor com o mesmo número de linhas da matrix.

Por exemplo, tomemos uma matrix \mathbf{A} e identifiquemos as suas linhas:

$$\mathbf{A} = \begin{bmatrix} 4 & 1 & 5 \\ 2 & 3 & -4 \\ 6 & -3 & 0 \end{bmatrix} = \begin{bmatrix} \mathbf{a}'_1 \\ \mathbf{a}'_2 \\ \mathbf{a}'_3 \end{bmatrix} \quad \text{onde} \quad \begin{aligned} \mathbf{a}'_1 &= \begin{bmatrix} 4 & 1 & 5 \end{bmatrix} \\ \mathbf{a}'_2 &= \begin{bmatrix} 2 & 3 & -4 \end{bmatrix} \\ \mathbf{a}'_3 &= \begin{bmatrix} 6 & -3 & 0 \end{bmatrix} \end{aligned}$$

Agora tomemos um vetor:

$$\mathbf{b} = \begin{bmatrix} 1 \\ 3 \\ 2 \end{bmatrix}.$$

Calculemos o produto interno de cada linha de \mathbf{A} por \mathbf{b} :

$$\mathbf{a}'_1 \mathbf{b} = \begin{bmatrix} 4 & 1 & 5 \end{bmatrix} \begin{bmatrix} 1 \\ 3 \\ 2 \end{bmatrix} = 4(1) + 1(3) + 5(2) = 17$$

$$\mathbf{a}'_2 \mathbf{b} = \begin{bmatrix} 2 & 3 & -4 \end{bmatrix} \begin{bmatrix} 1 \\ 3 \\ 2 \end{bmatrix} = 2(1) + 3(3) + (-4)(2) = 3$$

$$\mathbf{a}'_3 \mathbf{b} = \begin{bmatrix} 6 & -3 & 0 \end{bmatrix} \begin{bmatrix} 1 \\ 3 \\ 2 \end{bmatrix} = 6(1) + (-3)(3) + 0(2) = -3$$

Os escalares resultantes compõe o **vetor coluna** que é o resultado da multiplicação:

$$\mathbf{c} = \mathbf{A}\mathbf{b} \Rightarrow \mathbf{c} = \begin{bmatrix} 17 \\ 3 \\ -3 \end{bmatrix}.$$

Para que a multiplicação de matrix por vetor seja possível há a necessidade de compatibilidade de ordem entre a matrix e o vetor:

$$\underbrace{(n \times p) \times (p \times 1)}_{(n \times 1)},$$

e o resultado será sempre um vetor com ordem $n \times 1$.

Utilizando uma notação algébrica mais detalhada, a multiplicação matrix-vetor pode ser apresentada na forma:

$$\mathbf{c} = \mathbf{A}\mathbf{b},$$

se temos

$$\mathbf{A} = [a_{ij}], \quad i = 1, \dots, n; \quad j = 1, \dots, p.$$

e também

$$\mathbf{b} = [b_j], \quad j = 1, \dots, p;$$

Então o produto é

$$\mathbf{c} = [c_i] \quad \text{onde} \quad c_i = \sum_{j=1}^p a_{ij} b_j \quad \text{e} \quad i = 1, 2, \dots, n.$$

3.4.5 Combinação Linear

A multiplicação matrix-vetor pode ser vista como uma representação de um sistema de equações de primeiro grau (sistema de equações lineares) onde o resultado é uma **combinação linear** das colunas da matrix.

Consideremos novamente o produto matrix-vetor:

$$\mathbf{c} = \mathbf{A}\mathbf{b},$$

mas tomemos o vetor \mathbf{b} como sendo composto de incógnitas

$$\begin{bmatrix} 7 \\ 3 \\ 2 \end{bmatrix} = \begin{bmatrix} 4 & 1 & 5 \\ 2 & 3 & 4 \\ 6 & 3 & 1 \end{bmatrix} \begin{bmatrix} b_1 \\ b_2 \\ b_3 \end{bmatrix}.$$

Essa multiplicação representa o sistema de equações

$$\begin{aligned} 7 &= 4b_1 + 1b_2 + 5b_3 \\ 3 &= 2b_1 + 3b_2 + 4b_3 \\ 2 &= 6b_1 + 3b_2 + 1b_3 \end{aligned}$$

o qual pode ser escrito na forma

$$\begin{bmatrix} 7 \\ 3 \\ 2 \end{bmatrix} = b_1 \begin{bmatrix} 4 \\ 2 \\ 6 \end{bmatrix} + b_2 \begin{bmatrix} 1 \\ 3 \\ 3 \end{bmatrix} + b_3 \begin{bmatrix} 5 \\ 4 \\ 1 \end{bmatrix}$$

mostrando que o resultado à esquerda do sinal de igualdade (\mathbf{c}) é uma **combinação linear** das colunas da matrix (\mathbf{A}), sendo os coeficientes os elementos do vetor (\mathbf{b}). O caso geral pode ser expresso como

$$\begin{aligned} \mathbf{c} &= \mathbf{A}\mathbf{b} \\ &= b_1\mathbf{a}_1 + b_2\mathbf{a}_2 + \cdots + b_p\mathbf{a}_p \end{aligned}$$

3.4.6 Multiplicação Matrix por Matrix

Considere uma matrix \mathbf{A} com ordem $n \times p$ e uma matrix \mathbf{B} com ordem $p \times k$.

A **pré**-multiplicação da matrix \mathbf{B} pela matrix \mathbf{A} , resultando no produto \mathbf{AB} , é obtida com os seguintes passos:

1. Decompondo a matrix \mathbf{A} em *linhas*:

$$\mathbf{A} = \begin{bmatrix} \mathbf{a}'_1 \\ \mathbf{a}'_2 \\ \vdots \\ \mathbf{a}'_n \end{bmatrix}.$$

2. Decompondo a matrix \mathbf{B} em *colunas*:

$$\mathbf{B} = \left[\mathbf{b}_1 \quad \mathbf{b}_2 \quad \cdots \quad \mathbf{b}_k \right].$$

3. Realizando os produtos internos de cada linha de \mathbf{A} por cada coluna de \mathbf{B} :

$$\mathbf{AB} = \begin{bmatrix} \mathbf{a}'_1 \\ \mathbf{a}'_2 \\ \vdots \\ \mathbf{a}'_n \end{bmatrix} \left[\mathbf{b}_1 \quad \mathbf{b}_2 \quad \cdots \quad \mathbf{b}_k \right] = \begin{bmatrix} \mathbf{a}'_1 \mathbf{b}_1 & \mathbf{a}'_1 \mathbf{b}_2 & \cdots & \mathbf{a}'_1 \mathbf{b}_k \\ \mathbf{a}'_2 \mathbf{b}_1 & \mathbf{a}'_2 \mathbf{b}_2 & \cdots & \mathbf{a}'_2 \mathbf{b}_k \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{a}'_n \mathbf{b}_1 & \mathbf{a}'_n \mathbf{b}_2 & \cdots & \mathbf{a}'_n \mathbf{b}_k \end{bmatrix}$$

Num exemplo numérico:

$$\begin{aligned} \mathbf{A} &= \begin{bmatrix} 34 & 12 \\ 21 & 43 \\ 63 & -30 \end{bmatrix} = \begin{bmatrix} \mathbf{a}'_1 \\ \mathbf{a}'_2 \\ \mathbf{a}'_3 \end{bmatrix} = \begin{bmatrix} \begin{bmatrix} 34 & 12 \end{bmatrix} \\ \begin{bmatrix} 21 & 43 \end{bmatrix} \\ \begin{bmatrix} 63 & -30 \end{bmatrix} \end{bmatrix} \\ \mathbf{B} &= \begin{bmatrix} 0 & 3 \\ 4 & -2 \end{bmatrix} = \left[\mathbf{b}_1 \quad \mathbf{b}_2 \right] = \left[\begin{bmatrix} 0 \\ 4 \end{bmatrix} \quad \begin{bmatrix} 3 \\ -2 \end{bmatrix} \right] \\ \mathbf{AB} &= \begin{bmatrix} \begin{bmatrix} 34 & 12 \\ 21 & 43 \\ 63 & -30 \end{bmatrix} \end{bmatrix} \left[\begin{bmatrix} 0 \\ 4 \end{bmatrix} \quad \begin{bmatrix} 3 \\ -2 \end{bmatrix} \right] \\ &= \begin{bmatrix} 34(0) + 12(4) & 34(3) + 12(-2) \\ 21(0) + 43(4) & 21(3) + 43(-2) \\ 63(0) + (-30)(4) & 63(3) + (-30)(-2) \end{bmatrix} \\ &= \begin{bmatrix} 48 & 78 \\ 172 & -23 \\ -120 & 249 \end{bmatrix} \end{aligned}$$

Note os seguintes aspectos importantes:

- Há necessidade de **compatibilidade** de ordem entre as matrizes para que a multiplicação seja possível:

$$\underbrace{(n \times p) \times (p \times k)}_{(n \times k)} \implies \underbrace{(3 \times 2) \times (2 \times 2)}_{(3 \times 2)}$$

- Nesse caso o produto \mathbf{AB} (**pré**-multiplicação de \mathbf{B} por \mathbf{A}) é possível, mas o produto \mathbf{BA} (**pós**-multiplicação de \mathbf{B} por \mathbf{A}) não existe, pois não há

compatibilidade de ordem.

$$\begin{array}{c} \neq \\ \underbrace{(2 \times 2) \times (3 \times 2)} \\ ? \end{array}$$

Apresentando a multiplicação de matrix com uma notação algébrica detalhada temos: o produto

$$\mathbf{C} = \mathbf{AB}$$

onde as matrizes são:

$$\begin{aligned} \mathbf{A} &= [a_{il}] \quad i = 1, 2, \dots, n; \quad l = 1, 2, \dots, k; \\ \mathbf{B} &= [b_{lj}] \quad l = 1, 2, \dots, k; \quad j = 1, 2, \dots, p \\ \mathbf{C} &= [c_{ij}] \quad i = 1, 2, \dots, n; \quad j = 1, 2, \dots, p; \end{aligned}$$

o produto resulta na matrix \mathbf{C} com elementos

$$c_{ij} = \sum_{l=1}^k a_{il} b_{lj}.$$

3.4.7 Propriedades da Multiplicação de Matrizes

Algumas propriedades da multiplicação de escalares não são válidas no caso da multiplicação de matrizes:

Comutativa: não é válida pois geralmente

$$\mathbf{AB} \neq \mathbf{BA}$$

mesmo que haja compatibilidade de ordem para a pré e pós-multiplicação.

Lei do Cancelamento: não é válida pois

$$\mathbf{AB} = \mathbf{0} \not\Rightarrow \mathbf{A} = \mathbf{0} \quad \text{ou} \quad \mathbf{B} = \mathbf{0}$$

e ainda temos que

$$\mathbf{AB} = \mathbf{AC} \not\Rightarrow \mathbf{B} = \mathbf{C}.$$

As *propriedade válidas* para multiplicação de matrizes são:

Lei Associativa:

$$(\mathbf{AB})\mathbf{C} = \mathbf{A}(\mathbf{BC})$$

Lei Distributiva:

$$(\mathbf{A} + \mathbf{B})\mathbf{C} = \mathbf{AC} + \mathbf{BC}$$

Transposta do Produto:

$$(\mathbf{ABC})' = \mathbf{C}'\mathbf{B}'\mathbf{A}'$$

Matrix Unitária na Multiplicação: seja \mathbf{A} uma matrix quadrada e \mathbf{I} uma matrix identidade, então

$$\mathbf{IA} = \mathbf{AI} = \mathbf{A}$$

3.5 Representação Matricial do Somatório de Valores

- Matrizes também são convenientes para representar a somatório de valores:

$$\sum_{i=1}^n x_i = x_1 + x_2 + \cdots + x_n = \mathbf{i}'\mathbf{x}.$$

- No caso do vetor ser composto de uma mesma constante: $\mathbf{x} = a\mathbf{i}$, temos:

$$\sum_{i=1}^n x_i = \mathbf{i}'\mathbf{x} = \mathbf{i}'(a\mathbf{i}) = a(\mathbf{i}\mathbf{i}') = na.$$

- Se tivermos uma constante a multiplicando cada elemento x_i temos:

$$\sum_{i=1}^n ax_i = a \sum_{i=1}^n x_i = a\mathbf{i}'\mathbf{x}.$$

- No caso de calcularmos a média amostra de n observações temos $a = 1/n$, logo:

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i = \frac{1}{n} \mathbf{i}'\mathbf{x}.$$

- O somatório do quadrado das observações e o somatório do produto de observações pareadas também pode ser obtida com o produto interno:

$$\begin{aligned} \sum_{i=1}^n x_i^2 &= x_1(x_1) + x_2(x_2) + \cdots + x_n(x_n) = \mathbf{x}'\mathbf{x}; \\ \sum_{i=1}^n x_i y_i &= x_1(y_1) + x_2(y_2) + \cdots + x_n(y_n) = \mathbf{x}'\mathbf{y}. \end{aligned}$$

- As matrizes também podem ser utilizadas para representar os desvios das observações em relação à média amostral e a soma do quadrado desses desvios (*soma de quadrados*).

Primeiro representamos um vetor com a média amostral:

$$\begin{bmatrix} \bar{x} \\ \bar{x} \\ \vdots \\ \bar{x} \end{bmatrix} = \mathbf{i}\bar{x} = \mathbf{i}\left(\frac{1}{n}\mathbf{i}'\mathbf{x}\right) = \frac{1}{n}\mathbf{ii}'\mathbf{x}$$

A matrix $(1/n)\mathbf{ii}'$ é uma matrix $n \times n$, onde todos os elementos são iguais a $1/n$.

Agora podemos representar o vetor de desvios em relação à média amostral:

$$\begin{bmatrix} x_1 - \bar{x} \\ x_2 - \bar{x} \\ \vdots \\ x_n - \bar{x} \end{bmatrix} = [\mathbf{x} - \mathbf{i}\bar{x}] = \left[\mathbf{x} - \frac{1}{n}\mathbf{ii}'\mathbf{x}\right]$$

como temos $\mathbf{x} = \mathbf{I}\mathbf{x}$, então

$$\left[\mathbf{x} - \frac{1}{n}\mathbf{ii}'\mathbf{x}\right] = \left[\mathbf{I}\mathbf{x} - \frac{1}{n}\mathbf{ii}'\mathbf{x}\right] = \left[\mathbf{I} - \frac{1}{n}\mathbf{ii}'\right]\mathbf{x} = \mathbf{M}^0\mathbf{x}$$

- A matrix \mathbf{M}^0 tem os elementos da diagonal todos igual a $(1 - 1/n)$ e os demais elementos $1/n$ e será sempre utilizada para gerar os desvios em relação à média amostral. Ela tem propriedades que facilitam a computação das somas de quadrados e de produtos:

Seu produto com vetor unitário é nula:

$$\mathbf{M}^0\mathbf{i} = \left[\mathbf{I} - \frac{1}{n}\mathbf{ii}'\right]\mathbf{i} = \mathbf{i} - \frac{1}{n}\mathbf{i}(\mathbf{i}'\mathbf{i}) = \mathbf{0}.$$

Isso também implica em $\mathbf{i}'\mathbf{M}^0 = \mathbf{0}$.

Matrix Simétrica:

$$\mathbf{M}^{0'} = \left[\mathbf{I} - \frac{1}{n}\mathbf{ii}'\right]' = \left[\mathbf{I}' - \frac{1}{n}(\mathbf{i}')'\mathbf{i}'\right] = \left[\mathbf{I} - \frac{1}{n}\mathbf{ii}'\right] = \mathbf{M}^0$$

Matrix Idempotente: é uma matrix que é igual ao seu quadrado:

$$\begin{aligned} (\mathbf{M}^0)^2 = \mathbf{M}^0\mathbf{M}^0 &= \left[\mathbf{I} - \frac{1}{n}\mathbf{ii}'\right] \left[\mathbf{I} - \frac{1}{n}\mathbf{ii}'\right] \\ &= \mathbf{I} \left[\mathbf{I} - \frac{1}{n}\mathbf{ii}'\right] - \frac{1}{n}\mathbf{ii}' \left[\mathbf{I} - \frac{1}{n}\mathbf{ii}'\right] \end{aligned}$$

$$\begin{aligned}
&= \left[\mathbf{I} - \frac{1}{n} \mathbf{ii}' \right] - \left[\mathbf{I} \left(\frac{1}{n} \mathbf{ii}' \right) - \left(\frac{1}{n} \mathbf{ii}' \right) \left(\frac{1}{n} \mathbf{ii}' \right) \right] \\
&= \left[\mathbf{I} - \frac{1}{n} \mathbf{ii}' \right] - \left[\left(\frac{1}{n} \mathbf{ii}' \right) - \left(\frac{1}{n^2} \mathbf{i}(\mathbf{i}'\mathbf{i})\mathbf{i}' \right) \right] \\
&= \left[\mathbf{I} - \frac{1}{n} \mathbf{ii}' \right] - \left[\left(\frac{1}{n} \mathbf{ii}' \right) - \left(\frac{1}{n} \mathbf{ii}' \right) \right] \\
&= \left[\mathbf{I} - \frac{1}{n} \mathbf{ii}' \right] - \mathbf{0} \\
&= \mathbf{M}^0
\end{aligned}$$

- A matrix \mathbf{M}^0 pode ser utilizada para obter os somatórios associados aos desvios em relação à média amostral:

Soma dos desvios em relação à média:

$$\sum_{i=1}^n (x_i - \bar{x}) = \mathbf{i}'[\mathbf{M}^0 \mathbf{x}] = \mathbf{0}'\mathbf{x} = 0.$$

Soma de quadrados dos desvios em relação à média:

$$\begin{aligned}
\sum_{i=1}^n (x_i - \bar{x})^2 &= (\mathbf{x} - \bar{x}\mathbf{i})'(\mathbf{x} - \bar{x}\mathbf{i}) \\
&= (\mathbf{M}^0 \mathbf{x})'(\mathbf{M}^0 \mathbf{x}) \\
&= \mathbf{x}'\mathbf{M}^0'\mathbf{M}^0 \mathbf{x} \\
&= \mathbf{x}'\mathbf{M}^0 \mathbf{x}
\end{aligned}$$

Soma de produtos dos desvios em relação às médias:

$$\begin{aligned}
\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) &= (\mathbf{x} - \bar{x}\mathbf{i})'(\mathbf{y} - \bar{y}\mathbf{i}) \\
&= (\mathbf{M}^0 \mathbf{x})'(\mathbf{M}^0 \mathbf{y}) \\
&= \mathbf{x}'\mathbf{M}^0'\mathbf{M}^0 \mathbf{y} \\
&= \mathbf{x}'\mathbf{M}^0 \mathbf{y}
\end{aligned}$$

4 Geometria Matricial

Os vetores apresentados, sejam eles vetores colunas, sejam as colunas de uma matriz, podem ser interpretados geometricamente como grandezas vetoriais que definem espaços geométricos.

Essa interpretação é útil pois permite a compreensão mais aprofundada da álgebra, por meio da geometria, mas também nos permitirá a interpretação geométrica do modelo linear múltiplo e de seu ajuste.

4.1 Espaços Vetoriais

- Os n elementos de um vetor coluna

$$\mathbf{a} = \begin{bmatrix} a_1 \\ a_2 \\ \vdots \\ a_p \end{bmatrix}$$

podem ser vistos como definindo um ponto num *espaço com p dimensões*.

- A figura 1 ilustra os seguintes vetores num espaço *bi-dimensional*:

$$\mathbf{a} = \begin{bmatrix} 2 \\ 3 \end{bmatrix} \quad \mathbf{b} = \begin{bmatrix} 6 \\ 1 \end{bmatrix}$$




Figura 1: Figura ilustrativa do espaço vetorial *bi-dimensional* definido por *multiplicação por escalar e adição de vetores*.

- Duas operações básicas são definidas num espaço vetorial:

Multiplicação por escalar: que altera o *comprimento* ou o *sentido* do vetor, mas nunca altera a sua *direção*:

$$\mathbf{a} = \begin{bmatrix} 2 \\ 3 \end{bmatrix} \quad \mathbf{a}^* = 2\mathbf{a} = \begin{bmatrix} 4 \\ 6 \end{bmatrix} \quad \mathbf{a}^{**} = -\frac{1}{2}\mathbf{a} = \begin{bmatrix} -1 \\ -3/2 \end{bmatrix}$$

Adição de vetores: que pode gerar um terceiro vetor a partir da soma de dois vetores:

$$\mathbf{a} + \mathbf{b} = \begin{bmatrix} 2 \\ 3 \end{bmatrix} + \begin{bmatrix} 6 \\ 1 \end{bmatrix} = \begin{bmatrix} 8 \\ 4 \end{bmatrix}$$

DEFINIÇÃO: ESPAÇO VETORIAL

Espaço vetorial é o conjunto de todos os vetores que é fechado sob multiplicação por escalar e adição de vetores.

- Para vetores bi-dimensionais, o conjunto \mathfrak{R}^2 é um espaço vetorial.
- Para vetores p -dimensionais, o conjunto \mathfrak{R}^p é um espaço vetorial.

4.2 Base de Espaços Vetoriais

- Considere as matrizes

$$\mathbf{a} = \begin{bmatrix} 2 \\ 3 \end{bmatrix} \quad \mathbf{b} = \begin{bmatrix} 6 \\ 1 \end{bmatrix}$$

e as seguintes operações vetoriais:

$$\mathbf{a}^* = 2 \begin{bmatrix} 2 \\ 3 \end{bmatrix} + 0 \begin{bmatrix} 6 \\ 1 \end{bmatrix} = \begin{bmatrix} 4 \\ 6 \end{bmatrix} \quad \mathbf{b}^* = 0 \begin{bmatrix} 2 \\ 3 \end{bmatrix} + 1.5 \begin{bmatrix} 6 \\ 1 \end{bmatrix} = \begin{bmatrix} 9 \\ 1.5 \end{bmatrix}$$

$$\mathbf{c} = 1 \begin{bmatrix} 2 \\ 3 \end{bmatrix} + 1 \begin{bmatrix} 6 \\ 1 \end{bmatrix} = \begin{bmatrix} 8 \\ 4 \end{bmatrix} \quad \mathbf{d} = 2 \begin{bmatrix} 2 \\ 3 \end{bmatrix} + 1 \begin{bmatrix} 6 \\ 1 \end{bmatrix} = \begin{bmatrix} 10 \\ 7 \end{bmatrix}$$

$$\mathbf{e} = 2 \begin{bmatrix} 2 \\ 3 \end{bmatrix} + 1.5 \begin{bmatrix} 6 \\ 1 \end{bmatrix} = \begin{bmatrix} 13 \\ 7.5 \end{bmatrix} \quad \mathbf{f} = -1 \begin{bmatrix} 2 \\ 3 \end{bmatrix} + 1 \begin{bmatrix} 6 \\ 1 \end{bmatrix} = \begin{bmatrix} 2 \\ -2 \end{bmatrix}$$

- Todas essas operações vetoriais geram **combinações lineares** dos vetores \mathbf{a} e \mathbf{b} .
- A figura 2 ilustra essas combinações lineares e mostra que *qualquer vetor* em \mathfrak{R}^2 pode ser expresso como uma combinação linear dos vetores \mathbf{a} e \mathbf{b} .




Figura 2: Figura ilustrativa das combinações lineares de dois vetores num espaço vetorial bidimensional.

- Analisemos com mais detalhe as combinações lineares possíveis em \mathbb{R}^2

$$\mathbf{a} = \begin{bmatrix} a_1 \\ a_2 \end{bmatrix} \quad \mathbf{b} = \begin{bmatrix} b_1 \\ b_2 \end{bmatrix} \quad \mathbf{c} = \begin{bmatrix} c_1 \\ c_2 \end{bmatrix}.$$

- Qualquer vetor \mathbf{c} em \mathbb{R}^2 pode ser expresso como combinação linear dos vetores \mathbf{a} e \mathbf{b}

$$\mathbf{c} = \alpha_1 \mathbf{a} + \alpha_2 \mathbf{b}.$$

- A combinação linear implica num sistema de equações

$$\begin{aligned} c_1 &= \alpha_1 a_1 + \alpha_2 b_1 \\ c_2 &= \alpha_1 a_2 + \alpha_2 b_2. \end{aligned}$$

- A solução do sistema é dado por

$$\alpha_1 = \frac{b_2 c_1 - b_1 c_2}{a_1 b_2 - b_1 a_2} \quad \alpha_2 = \frac{a_1 c_2 - a_2 c_1}{a_1 b_2 - b_1 a_2}$$

- Essa solução só será **única** se $(a_1b_2 - b_1a_2) \neq 0$.
- A situação de igualdade implica em

$$a_1b_2 - b_1a_2 = 0 \quad \Rightarrow \quad \frac{a_1}{a_2} = \frac{b_1}{b_2}$$

ou seja, se o vetor \mathbf{b} for múltiplo do vetor \mathbf{a} o sistema **não terá** solução única.

- **Conclusão:** para que os vetores \mathbf{a} e \mathbf{b} sejam vetores-base para \mathfrak{R}^2 é necessário que eles tenham **direções diferentes** (apontem para direções diferentes).

Nesse caso, o denominador acima não será nulo e o sistema de equações terá solução única, o que implica que *qualquer* vetor \mathbf{c} em \mathfrak{R}^2 pode ser expresso como uma *combinação linear única* de \mathbf{a} e \mathbf{b} .

- A base de um espaço vetorial não é única pois ela pode ser representada por qualquer conjunto de vetores que satisfaçam a definição.

Entretanto, *para uma dada base*, apenas uma combinação linear dos vetores base produzirá um vetor particular no espaço vetorial.

4.3 Dependência Linear

- Os resultados da secção anterior *podem* dar a impressão de que qualquer conjunto de p vetores é uma base para \mathfrak{R}^p .
- Mas observando a figura 2 vemos que os vetores \mathbf{a} e \mathbf{b} são base para \mathfrak{R}^2 , mas os vetores \mathbf{a} e \mathbf{a}^* não são.
- A diferença está no fato de que os vetores \mathbf{a} e \mathbf{b} são **linearmente independentes** (apontam para direções diferentes), enquanto que os vetores \mathbf{a} e \mathbf{a}^* são **linearmente dependentes** (apontam para a mesma direção).

DEFINIÇÃO: DEPENDÊNCIA LINEAR

Um conjunto de vetores é dito *linearmente dependente* se qualquer vetor no conjunto é uma combinação linear dos demais vetores do conjunto.

Exemplo de conjunto de vetores linearmente dependentes: considere os vetores

$$\mathbf{a} = \begin{bmatrix} 3 \\ 5 \end{bmatrix} \quad \mathbf{b} = \begin{bmatrix} 1 \\ 2 \end{bmatrix} \quad \mathbf{c} = \begin{bmatrix} 1 \\ 4 \end{bmatrix}.$$

Eles formam um conjunto linearmente dependente pois

$$-2\mathbf{a} + 7\mathbf{b} - \mathbf{c} = \mathbf{0}.$$

DEFINIÇÃO: INDEPENDÊNCIA LINEAR

Um conjunto de vetores é *linearmente independente* se, e somente se, a solução para qualquer combinação linear deles:

$$\alpha_1\mathbf{a}_1 + \alpha_2\mathbf{a}_2 + \cdots + \alpha_p\mathbf{a}_p$$

são escalares nulos:

$$\alpha_1 = \alpha_2 = \cdots = \alpha_p = 0.$$

Essa definição nos permite re-definir a *base* de um espaço vetorial:

DEFINIÇÃO: BASE DE UM ESPAÇO VETORIAL

A *base* de um espaço vetorial p -dimensional é qualquer conjunto de p vetores linearmente independentes naquele espaço vetorial.

4.4 Subespaços Vetoriais

DEFINIÇÃO: SUBESPAÇO VETORIAL

O conjunto de todas as combinações lineares de um conjunto de vetores é o *subespaço gerado* por esse conjunto de vetores.

- Pela definição acima, o *subespaço* gerado por uma base de \mathbb{R}^p é o próprio espaço vetorial \mathbb{R}^p .
- Nos exemplos acima os vetores \mathbf{a} , \mathbf{b} e \mathbf{c} formam uma base que gera o espaço vetorial \mathbb{R}^2 .

Logicamente que \mathbf{c} é desnecessário, pois os vetores \mathbf{a} e \mathbf{b} já são uma base para \mathbb{R}^2 .

- A consequência é que um dado vetor \mathbf{d} poderá ser expresso por *infinitas* combinações lineares de \mathbf{a} , \mathbf{b} e \mathbf{c} , mas por apenas *uma única* combinação linear de \mathbf{a} e \mathbf{b} .

A título de exemplo, considere os vetores

$$\mathbf{a} = \begin{bmatrix} 3 \\ 5 \end{bmatrix} \quad \mathbf{b} = \begin{bmatrix} 1 \\ 2 \end{bmatrix} \quad \mathbf{c} = \begin{bmatrix} 1 \\ 4 \end{bmatrix} \quad \mathbf{d} = \begin{bmatrix} 2 \\ 8 \end{bmatrix}.$$

O vetor \mathbf{d} é expresso por uma única combinação linear dos vetores \mathbf{a} e \mathbf{b}

$$\mathbf{d} = -4\mathbf{a} + 14\mathbf{b}.$$

Entretanto, como temos $\mathbf{d} = -2\mathbf{c}$, as combinações lineares de \mathbf{a} , \mathbf{b} e \mathbf{c} para expressar \mathbf{d} são

$$\mathbf{d} = k(-4\mathbf{a} + 14\mathbf{b}) + (k-1)(-2\mathbf{c}), \quad \text{para } k = 1, 2, 3, \dots$$

- Consideremos agora os seguintes vetores tridimensionais

$$\mathbf{a}' = \begin{bmatrix} a_1 & a_2 & 0 \end{bmatrix} \quad \text{e} \quad \mathbf{b}' = \begin{bmatrix} b_1 & b_2 & 0 \end{bmatrix}.$$

Esses vetores não geram o espaço tridimensional de \mathfrak{R}^3 , pois, por exemplo, o vetor $\mathbf{c}' = \begin{bmatrix} 1 & 2 & 3 \end{bmatrix}$ não pode ser expresso como uma combinação linear deles.

Entretanto, esses vetores podem representar qualquer vetor tridimensional *cujo terceiro elemento seja zero*, por isso, eles geram um **subespaço** de \mathfrak{R}^3 .

- O subespaço gerado pelos vetores tridimensionais \mathbf{a} e \mathbf{b} acima **não é** o espaço \mathfrak{R}^2 , mas apenas **um plano** no espaço \mathfrak{R}^3 : o plano que contém todos os vetores em \mathfrak{R}^3 cujo terceiro elemento é nulo.
- Qualquer plano em \mathfrak{R}^3 , independentemente de sua orientação, forma um subespaço bidimensional em \mathfrak{R}^3 que pode ser gerado por qualquer par de vetores independentes que estejam nesse subespaço.
- O espaço gerado por um conjunto de vetores em \mathfrak{R}^p tem **no máximo** p dimensões. Se o espaço gerado tem **menos** que p dimensões ele é um *subespaço*, designado de *hiperplano*.
- A idéia central é que *qualquer conjunto de vetores gera algum espaço vetorial*, o qual pode ser o espaço completo onde os vetores residem ou um subespaço dele.

4.5 Posto de uma Matrix

- Uma matrix deve ser vista como um conjunto de vetores coluna.
 - O número de colunas na matrix é igual o número de vetores.
 - O número de linhas na matrix é igual o número de coordenadas em cada vetor.

DEFINIÇÃO: ESPAÇO COLUNA

O *espaço coluna* de uma matrix é o espaço vetorial gerado por seus vetores coluna.

- Considere a matrix

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

ela possui três vetores de \mathbb{R}^3 , mas o terceiro vetor é a soma dos dois primeiros, por isso o espaço coluna dessa matrix não tem três dimensões, mas apenas duas, pois os seus os seus vetores colunas geram um subespaço bidimensional em \mathbb{R}^3 .

- Assim a matrix \mathbf{A} tem *posto coluna* igual a 2.

DEFINIÇÃO: POSTO COLUNA

O *posto coluna* de uma matrix é a dimensão do espaço vetorial gerado por seus vetores coluna.

- Considere a matrix

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

Essa matrix tem posto coluna igual a 3 e, portanto, seu espaço coluna é um subespaço em \mathbb{R}^4 .

- Considere agora a matrix transposta de \mathbf{B}

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

A matrix C é composta de quatro vetores coluna em \mathbb{R}^3 , conseqüentemente, seu espaço coluna é no máximo \mathbb{R}^3 e seus vetores coluna devem ser linearmente dependentes.

O espaço coluna de C é \mathbb{R}^3 e embora ele não seja o mesmo espaço coluna de B eles tem a mesma dimensão (3).

- O posto coluna de C é igual ao posto coluna de B , mas as colunas de C são as *linhas* de B , logo o posto coluna de C é igual o **posto linha** de B .

IGUALDADE DE POSTO COLUNA E POSTO LINHA

O *posto coluna* e o *posto linha* de uma matrix são iguais, i.e., o *espaço linha* e o *espaço coluna* de uma matrix têm a mesma dimensão.

- A igualdade de posto coluna e posto linha nos permite abandonar a distinção e trabalhar sempre com **posto** de uma matrix:

$$\text{posto}(\mathbf{A}) = \text{posto}(\mathbf{A}') \leq \min(\text{número de linhas, número de colunas})$$

DEFINIÇÃO: POSTO COMPLETO

Se o posto de uma matrix é igual ao número de colunas dela, a matrix tem *posto completo*.

4.5.1 Propriedades do Posto de uma Matrix Importantes para Regressão

- Considere o produto matricial $C = AB$.
 - As colunas da matrix C são combinações lineares das colunas da matrix A , portanto, cada coluna de C está no espaço coluna da matrix A , portanto

$$\text{posto}(\mathbf{C}) \leq \text{posto}(\mathbf{A}).$$

- As linhas da matrix C são combinações lineares das linhas da matrix B e, conseqüentemente,

$$\text{posto}(\mathbf{C}) \leq \text{posto}(\mathbf{B}).$$

- Uma vez que o posto coluna e posto linha de uma matrix é sempre igual, a conclusão é

$$\text{posto}(\mathbf{AB}) \leq \min(\text{posto}(\mathbf{A}), \text{posto}(\mathbf{B})).$$

- Uma propriedade que tem um papel central na aplicação da álgebra de matrizes na regressão linear é:

$$\text{posto}(\mathbf{A}) = \text{posto}(\mathbf{A}'\mathbf{A}) = \text{posto}(\mathbf{A}\mathbf{A}').$$

4.6 Determinante de uma Matrix

- Considere a matrix

$$\begin{aligned} \mathbf{A} &= [\mathbf{a}\mathbf{b}] \\ &= \begin{bmatrix} 2 & 6 \\ 3 & 1 \end{bmatrix} \end{aligned}$$

que é mostrada na figura 3.

- A área do paralelogramo formada pelas colunas de \mathbf{A} é o valor absoluto (sem sinal) do **determinante** de \mathbf{A} . Nesse exemplo, o valor absoluto do determinante é obtido por

$$|a_1b_2 - b_1a_2| = |2(1) - 6(3)| = |-16| = 16.$$

- O determinante só é definido para *matrizes quadradas*.

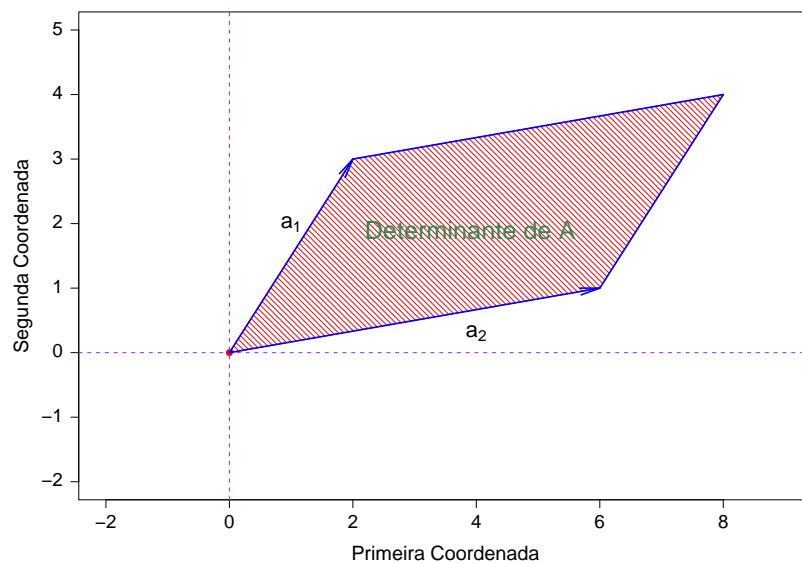


Figura 3: Figura ilustrativa do *determinante* de uma matrix a partir do *paralelogramo* formado pelo seus vetores coluna.

- Se as colunas de \mathbf{A} fossem linearmente dependentes, i.e., uma coluna fosse um múltiplo escalar da outra, então ambos vetores estariam sobre a mesma linha e o paralelogramo colapsaria para uma linha e teria área nula.
- Esse conceito implica que *se as colunas de uma matrix são linearmente dependentes, então seu determinante é zero.*
- Já foi apresentado que para um par de vetores num espaço bidimensional, a dependência linear entre os vetores implica em:

$$|a_1b_2 - b_1a_2| = 0$$

(o determinante de \mathbf{A} é $a_1b_2 - b_1a_2$).

- O mesmo conceito pode ser expandido para espaços de maiores dimensão. Considerando \mathbb{R}^3 , os vetores de uma matrix 3×3 definirão um sólido e o valor absoluto do determinante será o *volume* desse sólido.
- Se as colunas dessa matrix forem linearmente dependentes, então o sólido colapsará para uma figura plana cujo volume é nulo, e o determinante será zero.
- Generalizando o conceito para p dimensões temos a seguinte proposição:

PROPOSIÇÃO

O determinante de uma matrix é **não-nulo** se, e somente se, a matrix tiver **posto completo**.

4.6.1 Alguns Aspectos Úteis do Determinante de uma Matrix

- Utilizaremos a notação $|\mathbf{X}|$ para designar o determinante de uma matrix \mathbf{X} (e não seu valor absoluto).
- O determinante de uma matrix 2×2 pode ser facilmente encontrado por:

$$\begin{vmatrix} a & c \\ b & d \end{vmatrix} = ad - bc$$

- No caso de uma matrix $n \times n$, o determinante é encontrado usando a **expansão por cofatores**:

$$|\mathbf{A}| = \sum_{j=1}^n a_{ij}(-1)^{i+j}|\mathbf{A}_{ij}|, \quad i = 1, 2, \dots, n$$

onde A_{ij} é a matrix obtida a partir de A eliminando-se a linha i e a coluna j .

Exemplo com uma matrix 3×3 :

$$\mathbf{B} = \begin{bmatrix} 2 & 0 & 1 \\ 3 & 5 & 2 \\ 1 & 4 & 6 \end{bmatrix}$$

$$\begin{aligned} |\mathbf{B}| &= 2(-1)^{1+1} \begin{vmatrix} 5 & 2 \\ 4 & 6 \end{vmatrix} + 0(-1)^{1+2} \begin{vmatrix} 3 & 2 \\ 1 & 6 \end{vmatrix} + 1(-1)^{1+3} \begin{vmatrix} 3 & 5 \\ 1 & 4 \end{vmatrix} \\ &= 2(22) + 0 + 1(7) \\ |\mathbf{B}| &= 51 \end{aligned}$$

- No caso de matrix transposta, temos: $|\mathbf{A}| = |\mathbf{A}'|$.
- No caso de matrix diagonal, temos

$$\mathbf{D} = \begin{bmatrix} d_1 & 0 & \cdots & 0 \\ 0 & d_2 & \cdots & 0 \\ \vdots & \vdots & \cdots & \vdots \\ 0 & 0 & \cdots & d_n \end{bmatrix} \Rightarrow |\mathbf{D}| = d_1 d_2 \cdots d_n = \prod_{i=1}^n d_i.$$

- Sendo a matrix identidade uma matrix diagonal especial temos que $|\mathbf{I}_n| = 1$.
- Determinante de matrix diagonal multiplicada por escalar: $|c\mathbf{D}| = c^n |\mathbf{D}|$.
- Determinante do produto de duas matrizes diagonais: $|\mathbf{DC}| = |\mathbf{D}| \cdot |\mathbf{C}|$.

4.7 Norma e Ortogonalidade de Vetores

DEFINIÇÃO: COMPRIMENTO DE VETOR

O comprimento, ou **norma**, de um vetor é a raiz quadrada do produto interno do vetor por ele mesmo:

$$\|\mathbf{x}\| = \sqrt{\mathbf{x}'\mathbf{x}} = \sqrt{\sum_{i=1}^n x_i^2}.$$

DEFINIÇÃO: VETORES ORTOGONAIS

Dois vetores \mathbf{a} e \mathbf{b} são **ortogonais**, denotando por $\mathbf{a} \perp \mathbf{b}$, se, e somente se, o produto interno deles for nulo:

$$\mathbf{a}'\mathbf{b} = \mathbf{b}'\mathbf{a} = 0.$$

5 Solução de Sistemas Lineares

- A expressão matricial:

$$\mathbf{Ax} = \mathbf{b}$$

representa um **Sistema de Equações Lineares**, pois o seu desdobramento gera

$$\begin{aligned} a_{11}x_1 + a_{12}x_2 + \cdots + a_{1p}x_p &= b_1 \\ a_{21}x_1 + a_{22}x_2 + \cdots + a_{2p}x_p &= b_2 \\ &\vdots \\ a_{n1}x_1 + a_{n2}x_2 + \cdots + a_{np}x_p &= b_n \end{aligned}$$

- Para aplicação em regressão linear, consideraremos apenas sistemas *quadrados*, i.e., aqueles em que a matrix \mathbf{A} é $p \times p$.

5.1 Sistemas de Equações Lineares

Há dois tipos de sistemas de equações lineares:

Sistemas Homogêneos: são aqueles que têm a forma

$$\mathbf{Ax} = \mathbf{0}.$$

Por definição, uma solução não nula para o sistema ($\mathbf{x} \neq \mathbf{0}$) existe se, e somente se, as colunas de \mathbf{A} forem *linearmente dependentes*.

Isso implica que o determinante de \mathbf{A} é nulo: $|\mathbf{A}| = 0$.

Sistemas Não-Homogêneos: são aqueles que têm a forma

$$\mathbf{Ax} = \mathbf{b}$$

onde $\mathbf{b} \neq \mathbf{0}$, i.e., \mathbf{b} é num vetor não-nulo.

O vetor \mathbf{b} é escolhido arbitrariamente e expressa as combinações lineares das colunas da matrix \mathbf{A} .

Se \mathbf{b} tem p elementos, isso só será possível se as colunas de \mathbf{A} gerarem todo o espaço p -dimensional \mathfrak{R}^p .

Isso é equivalente a dizer que as colunas de \mathbf{A} são *linearmente independentes* e que o seu determinante não é nulo: $|\mathbf{A}| \neq 0$.

5.2 Matrix Inversa

- Para encontramos a solução do sistema (quadrado) $\mathbf{Ax} = \mathbf{b}$, necessitamos de uma operação matricial análoga à divisão entre escalares.
- Suponha que pudéssemos encontrar uma matrix \mathbf{B} tal que $\mathbf{BA} = \mathbf{I}$.
Nesse caso, a solução do sistema seria pré-multiplicando o sistema por ela:

$$\begin{aligned}\mathbf{BAx} &= \mathbf{Bb} \\ \mathbf{Ix} &= \mathbf{Bb} \\ \mathbf{x} &= \mathbf{Bb}.\end{aligned}$$

- Se a matrix \mathbf{B} *existe*, então ela é a **matrix inversa** de \mathbf{A} :

$$\mathbf{B} = \mathbf{A}^{-1}.$$

- Pela definição temos $\mathbf{A}^{-1}\mathbf{A} = \mathbf{I}$.
- Mas a relação também é válida para pós-multiplicação: $\mathbf{AA}^{-1} = \mathbf{I}$.
- Se a matrix inversa existe, então ela é única:

Suponha que existam duas matrizes tal que $\mathbf{B} = \mathbf{A}^{-1}$ e $\mathbf{C} = \mathbf{A}^{-1}$, então temos que

$$\begin{aligned}\mathbf{CAB} &= \mathbf{CAB} \\ (\mathbf{CA})\mathbf{B} &= \mathbf{C}(\mathbf{AB}) \\ \mathbf{IB} &= \mathbf{CI} \\ \mathbf{B} &= \mathbf{C}\end{aligned}$$

DEFINIÇÃO: MATRIX NÃO-SINGULAR

Se a inversa de uma matrix existe, essa matrix é dita **não-singular**.

5.2.1 Algumas Propriedades de Matrizes Inversas

- Matriz inversa de uma matrix 2×2 :

$$\mathbf{AB} = \mathbf{I}$$

$$\Rightarrow \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix} \begin{bmatrix} b_{11} & b_{12} \\ b_{21} & b_{22} \end{bmatrix} = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}$$

$$\Rightarrow \begin{cases} a_{11}b_{11} + a_{12}b_{21} = 1 \\ a_{11}b_{12} + a_{12}b_{22} = 0 \\ a_{21}b_{11} + a_{22}b_{21} = 0 \\ a_{21}b_{12} + a_{22}b_{22} = 1 \end{cases}$$

$$\Rightarrow \begin{bmatrix} b_{11} & b_{12} \\ b_{21} & b_{22} \end{bmatrix} = \frac{1}{a_{11}a_{22} - a_{12}a_{21}} \begin{bmatrix} a_{22} & -a_{12} \\ -a_{21} & a_{11} \end{bmatrix}$$

$$\Rightarrow \mathbf{A}^{-1} = \frac{1}{|\mathbf{A}|} \begin{bmatrix} a_{22} & -a_{12} \\ -a_{21} & a_{11} \end{bmatrix}$$

- Matriz inversa de uma matrix $n \times n$: utilizando a notação a^{ij} para indicar o (ij) ésimo elemento de \mathbf{A}^{-1} , então

$$a^{ij} = \frac{|\mathbf{C}_{ij}|}{|\mathbf{A}|}$$

onde $|\mathbf{C}_{ij}|$ é o (ji) ésimo co-fator de \mathbf{A} :

$$|\mathbf{C}_{ij}| = (-1)^{i+j} |\mathbf{A}_{ij}|$$

Exemplo numérico:

$$\mathbf{B} = \begin{bmatrix} 2 & 0 & 1 \\ 3 & 5 & 2 \\ 1 & 4 & 6 \end{bmatrix} \quad |\mathbf{B}| = 51$$

$$a^{11} = \frac{(-1)^{1+1}}{51} \begin{vmatrix} 5 & 2 \\ 4 & 6 \end{vmatrix} = \frac{22}{51} \quad a^{21} = \frac{(-1)^{1+2}}{51} \begin{vmatrix} 3 & 2 \\ 1 & 6 \end{vmatrix} = \frac{-16}{51} \quad a^{31} = \frac{(-1)^{1+3}}{51} \begin{vmatrix} 3 & 5 \\ 1 & 4 \end{vmatrix} = \frac{7}{51}$$

$$a^{12} = \frac{(-1)^{2+1}}{51} \begin{vmatrix} 0 & 1 \\ 4 & 6 \end{vmatrix} = \frac{4}{51} \quad a^{22} = \frac{(-1)^{2+2}}{51} \begin{vmatrix} 2 & 1 \\ 1 & 6 \end{vmatrix} = \frac{11}{51} \quad a^{32} = \frac{(-1)^{2+3}}{51} \begin{vmatrix} 2 & 0 \\ 1 & 4 \end{vmatrix} = \frac{-8}{51}$$

$$a^{13} = \frac{(-1)^{3+1}}{51} \begin{vmatrix} 0 & 1 \\ 5 & 2 \end{vmatrix} = \frac{-5}{51} \quad a^{23} = \frac{(-1)^{3+2}}{51} \begin{vmatrix} 2 & 1 \\ 3 & 2 \end{vmatrix} = \frac{-1}{51} \quad a^{33} = \frac{(-1)^{3+3}}{51} \begin{vmatrix} 2 & 0 \\ 3 & 5 \end{vmatrix} = \frac{10}{51}$$

$$\mathbf{B}^{-1} = \frac{1}{51} \begin{bmatrix} 22 & 4 & -5 \\ -16 & 11 & -1 \\ 7 & -8 & 10 \end{bmatrix}$$

- Matrix inversa de matrix diagonal:

$$\mathbf{D} = \begin{bmatrix} d_1 & 0 & \cdots & 0 \\ 0 & d_2 & \cdots & 0 \\ \vdots & \vdots & \cdots & \vdots \\ 0 & 0 & \cdots & d_n \end{bmatrix} \Rightarrow \mathbf{D}^{-1} = \begin{bmatrix} 1/d_1 & 0 & \cdots & 0 \\ 0 & 1/d_2 & \cdots & 0 \\ \vdots & \vdots & \cdots & \vdots \\ 0 & 0 & \cdots & 1/d_n \end{bmatrix}$$

- Sendo a matrix identidade uma matrix diagonal especial, temos: $\mathbf{I}^{-1} = \mathbf{I}$.
- Se a matrix \mathbf{A} é simétrica, então \mathbf{A}^{-1} também é simétrica.
- Alguns resultados computacionais:

$$\begin{aligned} |\mathbf{A}^{-1}| &= \frac{1}{|\mathbf{A}|} \\ (\mathbf{A}^{-1})^{-1} &= \mathbf{A} \\ (\mathbf{A}^{-1})' &= (\mathbf{A}')^{-1} \end{aligned}$$

- No caso de matrizes \mathbf{A} , \mathbf{B} e \mathbf{C} , todas elas quadradas e não-singulares:

$$(\mathbf{ABC})^{-1} = \mathbf{C}^{-1}\mathbf{B}^{-1}\mathbf{A}^{-1}$$

- Note que é possível que exista a matrix $(\mathbf{AB})^{-1}$, mesmo no caso em que as matrizes \mathbf{A} e \mathbf{B} não sejam nem mesmo quadradas.

Por exemplo, se \mathbf{A} matrix de ordem $(n \times p)$, é possível que exista a matrix $(\mathbf{A}'\mathbf{A})^{-1}$ que é simétrica $(p \times p)$.

5.3 Solução de Sistemas Lineares Não-Homogêneos

Dado um sistema linear não-homogêneo

$$\mathbf{Ax} = \mathbf{b},$$

se a matrix \mathbf{A} é não-singular, a **solução única** para o sistema é

$$\mathbf{x} = \mathbf{A}^{-1}\mathbf{b}.$$

6 Auto-Valores e Auto-Vetores

- Para se analisar uma matrix quadrada \mathbf{A} é útil utilizarmos a solução para o seguinte sistema de equações:

$$\mathbf{A}\mathbf{c} = \lambda\mathbf{c},$$

onde

\mathbf{c} é chamado de **auto-vetor** e

λ é o **auto-valor** associado a ele.

- Entretanto, há uma indeterminação nesse sistema, pois se \mathbf{c} é uma solução para o sistema, então o vetor $k\mathbf{c}$ também será uma solução.
- Consideraremos então os **vetores normalizados**, i.e., aqueles que possuem norma unitária

$$\mathbf{c}'\mathbf{c} = 1,$$

como solução do sistema.

- Assim a solução, consiste em λ e os $n - 1$ elementos de \mathbf{c} .

6.1 Solução do Sistema

- Apresentaremos aqui apenas a idéia da solução do sistema.
- Transformando o sistema original para um sistema homogêneo temos

$$\mathbf{A}\mathbf{c} = \lambda\mathbf{I}\mathbf{c} \quad \Rightarrow \quad (\mathbf{A} - \lambda\mathbf{I})\mathbf{c} = \mathbf{0}.$$

- Esse sistema só tem solução se a matrix $(\mathbf{A} - \lambda\mathbf{I})$ for singular, i.e., tiver determinante nulo.
- Logo, para encontrarmos os auto-valores devemos solucionar

$$|\mathbf{A} - \lambda\mathbf{I}| = 0,$$

que gera uma **equação polinômial em** λ chamada de equação característica.

- Por exemplo, considere a matrix (2×2) :

$$\begin{aligned} \mathbf{A} = \begin{bmatrix} 3 & 4 \\ 8 & 7 \end{bmatrix} & \Rightarrow |\mathbf{A} - \lambda\mathbf{I}| = \begin{vmatrix} 3 - \lambda & 4 \\ 8 & 7 - \lambda \end{vmatrix} \\ & = (3 - \lambda)(7 - \lambda) - 4(8) \\ & = \lambda^2 - 10\lambda - 11 \end{aligned}$$

As raízes dessa equação característica são $\lambda = 11$ e $\lambda = -1$.

- Aplicando-se os auto-valores ao sistema homogêneo obtêm-se os auto-vetores.
- No exemplo acima teremos

$$(\mathbf{A} - \lambda \mathbf{I})\mathbf{c} = 0$$

$$\begin{bmatrix} 3 - \lambda & 4 \\ 8 & 7 - \lambda \end{bmatrix} \begin{bmatrix} c_1 \\ c_2 \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \end{bmatrix}.$$

Para $\lambda = -1$ temos:

$$4c_1 + 4c_2 = 0 \quad \text{e} \quad 8c_1 + 8c_2 = 0 \quad \Rightarrow \quad c_1 = -c_2.$$

Para $\lambda = 11$ temos:

$$-8c_1 + 4c_2 = 0 \quad \text{e} \quad 8c_1 - 4c_2 = 0 \quad \Rightarrow \quad c_1 = \frac{1}{2}c_2.$$

Para obtermos a solução devemos considerar que $\mathbf{c}'\mathbf{c} = 1$, assim se obtem:

$$\text{Para } \lambda = 11 \quad \Rightarrow \quad \mathbf{c} = \begin{bmatrix} -1/\sqrt{5} \\ -2/\sqrt{5} \end{bmatrix}$$

$$\text{Para } \lambda = -1 \quad \Rightarrow \quad \mathbf{c} = \begin{bmatrix} -1/\sqrt{2} \\ 1/\sqrt{2} \end{bmatrix}$$

6.2 Resultados Úteis para Matrizes Simétricas

- Se \mathbf{A} é uma matrix $p \times p$ simétrica, então

1. \mathbf{A} tem p auto-vetores *distintos*

$$\mathbf{c}_1, \mathbf{c}_2, \mathbf{c}_3, \dots, \mathbf{c}_p.$$

2. \mathbf{A} tem p auto-valores *reais* não necessariamente distintos

$$\lambda_1, \lambda_2, \lambda_3, \dots, \lambda_p.$$

- Os auto-vetores de \mathbf{A} são **orto-normais**:

$$\begin{aligned} \mathbf{c}_i' \mathbf{c}_j &= 1 & \text{se } i = j; \\ \mathbf{c}_i' \mathbf{c}_j &= 0 & \text{se } i \neq j. \end{aligned}$$

- Os auto-vetores de \mathbf{A} podem ser organizados numa matrix orto-normal

$$\mathbf{C} = [\mathbf{c}_1 \ \mathbf{c}_2 \ \mathbf{c}_3 \ \dots \ \mathbf{c}_p]$$

enquanto que os auto-valores podem ser organizados numa matrix diagonal

$$\mathbf{\Lambda} = \begin{bmatrix} \lambda_1 & 0 & 0 & \dots & 0 \\ 0 & \lambda_2 & 0 & \dots & 0 \\ 0 & 0 & \lambda_3 & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \dots & \lambda_p \end{bmatrix}$$

- Utilizando essas matrizes, o todas as equações do sistema homogêneo

$$\mathbf{A}\mathbf{c}_i = \lambda_i\mathbf{c}_i$$

pode ser representado numa única expressão

$$\mathbf{A}\mathbf{C} = \mathbf{C}\mathbf{\Lambda}$$

- Como a matrix de auto-vetores é orto-normal, ela tem as seguintes propriedades:

$$\begin{aligned} \mathbf{C}'\mathbf{C} &= \mathbf{C}\mathbf{C}' = \mathbf{I} \\ \mathbf{C}' &= \mathbf{C}^{-1} \end{aligned}$$

DEFINIÇÃO: DIAGONALIZAÇÃO DE UMA MATRIX SIMÉTRICA

A *diagonalização* de uma matrix simétrica \mathbf{A} é

$$\mathbf{C}'\mathbf{A}\mathbf{C} = \mathbf{C}'\mathbf{C}\mathbf{\Lambda} = \mathbf{I}\mathbf{\Lambda} = \mathbf{\Lambda}.$$

DEFINIÇÃO: DECOMPOSIÇÃO ESPECTRAL DE UMA MATRIX SIMÉTRICA

A *decomposição espectral* de uma matrix simétrica \mathbf{A} é

$$\mathbf{A} = \mathbf{C}\mathbf{\Lambda}\mathbf{C}' = \sum_{i=1}^p \lambda_i \mathbf{c}_i \mathbf{c}_i'.$$

Uma vez que o produto externo $\mathbf{c}_i \mathbf{c}_i'$ gera uma matrix $(p \times p)$, na decomposição espectral, a matrix \mathbf{A} é expressa como o somatório de p matrizes de posto 1.

6.3 Posto de Matrizes

- Para qualquer matrix A e duas matrizes *não-singulares* B e C , o posto do produto BAC é igual ao posto de A .

$$\begin{aligned}\text{posto}(BCA) &= \text{posto}((BA)C) = \min(\text{posto}(BA), \text{posto}(C)) \\ &= \text{posto}(BA) \quad [\text{pois } C \text{ tem posto completo}]\end{aligned}$$

$$\begin{aligned}\text{posto}(BA) &= \text{posto}(A'B') = \min(\text{posto}(A'), \text{posto}(B')) \\ &= \text{posto}(A') \quad [\text{pois } B' \text{ tem posto completo}]\end{aligned}$$

$$\text{posto}(A') = \text{posto}(A)$$

$$\text{posto}(BCA) = \text{posto}(A)$$

- No caso de uma matrix *simétrica* A , usando a decomposição espectral temos

$$\text{posto}(A) = \text{posto}(CAC') = \text{posto}(\Lambda)$$

O posto de Λ é simplesmente o número de elementos não nulos na sua diagonal principal, pois Λ é uma matrix diagonal.

TEOREMA: POSTO DE MATRIX SIMÉTRICA

O posto de uma matrix simétrica é o número de auto-valores não nulos que ela contem.

- Esse teorema pode ser generalizado se lembrarmos que toda matrix pode gerar uma matrix simétrica se for pré-multiplicada ou pela sua transposta e que

$$\text{posto}(A) = \text{posto}(A'A) = \text{posto}(AA').$$

TEOREMA: POSTO DE UMA MATRIX

O posto de *qualquer* matrix A é igual ao número de auto-valores não nulos presentes na matrix $A'A$.

TEOREMA: AUTO-VALORES DO PRODUTO EXTERNO DE UMA MATRIX

Os auto-valores não-nulos da matrix AA' são os mesmo da matrix $A'A$.

6.4 Número Condicional de uma Matrix

- Como foi visto, o posto de uma matrix é um número discreto e, portanto, o fato de uma matrix ter ou não ter posto completo também é.
- Entretanto, freqüentemente na regressão linear lidados com matrizes que têm posto completo, pois todos os seus auto-valores são não-nulos, mas elas estão muito próximo de serem singulares, pois algumas colunas estão muito próximas de serem uma combinação linear das demais.
- O **número condicional** de uma matrix é uma forma de detectarmos esse problema:

$$\gamma = \left[\frac{\max(\text{auto-valores})}{\min(\text{auto-valores})} \right]^{1/2}$$

- Para uma matrix *não-quadrada* X , utilizaremos a matrix transformada $X'X$ e como os auto-valores dependem da escala das observações, devemos *re-escalonar* a matrix X para que suas colunas tenham comprimento 1.

Isso é obtido, dividindo os elementos da coluna por sua norma.

6.5 Determinante por Decomposição

- Para uma matrix simétrica A , a diagonalização dela implica em

$$C'AC = \Lambda \quad \Rightarrow \quad |C'AC| = |\Lambda|$$

- Desenvolvendo o determinante da diagonalização temos:

$$\begin{aligned} |C'AC| &= |C'| \cdot |A| \cdot |C| \\ &= |C'| \cdot |C| \cdot |A| \\ &= |C'C| \cdot |A| \\ &= |I| \cdot |A| \\ &= 1 \cdot |A| \\ &= |A| \\ &= |\Lambda| \end{aligned}$$

- Como Λ é uma matrix diagonal, o seu determinante é igual ao produto dos elementos da diagonal principal.

TEOREMA: DETERMINANTE DE MATRIX SIMÉTRICA

O determinante de uma matrix simétrica é igual ao produto de seus auto-valores.

6.6 Potências de uma Matrix

TEOREMA: POTÊNCIA DE MATRIX SIMÉTRICA

Para toda matrix simétrica *não-singular* temos

$$\mathbf{A}^K = \mathbf{C}' \Lambda^K \mathbf{C},$$

para $K = \dots, -2, -1, 0, 1, 2, \dots$

Alguns exemplos:

- Para $K = 2$:

$$\begin{aligned} \mathbf{A}^2 &= \mathbf{C} \Lambda \mathbf{C}'^2 = (\mathbf{C}' \Lambda \mathbf{C})(\mathbf{C} \Lambda \mathbf{C}') \\ &= \mathbf{C} \Lambda \mathbf{C}' \mathbf{C} \Lambda \mathbf{C}' \\ &= \mathbf{C} \Lambda \mathbf{I} \Lambda \mathbf{C}' \\ &= \mathbf{C} \Lambda^2 \mathbf{C}' \end{aligned}$$

- Para $K = -1$:

$$\begin{aligned} \mathbf{A}^{-1} &= \mathbf{C} \Lambda \mathbf{C}'^{-1} \\ &= (\mathbf{C}')^{-1} (\Lambda)^{-1} (\mathbf{C})^{-1} \\ &= \mathbf{C}' \Lambda^{-1} \mathbf{C} \end{aligned}$$

DEFINIÇÃO: MATRIX DEFINIDA POSITIVA

Uma matrix é dita **definida positiva** quando todos os seus auto-valores são positivos.

TEOREMA: POTÊNCIA DE MATRIX DEFINIDA POSITIVA

Para toda matrix definida positiva temos

$$\mathbf{A}^r = \mathbf{C}' \mathbf{\Lambda}^r \mathbf{C},$$

para qualquer número real r .

- Por exemplo para $r = 1/2$ temos:

$$\begin{aligned} \mathbf{A}^{1/2} &= \mathbf{C} \mathbf{\Lambda}^{1/2} \mathbf{C}' \\ &= \mathbf{C} \begin{bmatrix} \sqrt{\lambda_1} & 0 & \cdots & 0 \\ 0 & \sqrt{\lambda_2} & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & \cdots & 0 & \sqrt{\lambda_n} \end{bmatrix} \mathbf{C}' \end{aligned}$$

- Essa equação satisfaz a exigência de raiz quadrada, pois

$$\begin{aligned} \mathbf{A}^{1/2} \mathbf{A}^{1/2} &= (\mathbf{C} \mathbf{\Lambda}^{1/2} \mathbf{C}') (\mathbf{C} \mathbf{\Lambda}^{1/2} \mathbf{C}') \\ &= \mathbf{C} \mathbf{\Lambda}^{1/2} \mathbf{C}' \mathbf{C} \mathbf{\Lambda}^{1/2} \mathbf{C}' \\ &= \mathbf{C} \mathbf{\Lambda}^{1/2} \mathbf{\Lambda}^{1/2} \mathbf{C}' \\ &= \mathbf{C} \mathbf{\Lambda} \mathbf{C}' \\ &= \mathbf{A} \end{aligned}$$

7 Vetores e Matrizes Aleatórios

A única diferença de vetor ou matrix aleatórios das matrizes comuns é que os seus elementos são *variáveis aleatórias*. Por exemplo, o vetor

$$\mathbf{Y} = \begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix}$$

é um vetor aleatório se os elementos Y_1, Y_2, \dots, Y_n forem todas variáveis aleatórias.

7.1 Valor Esperado

O valor esperado de um vetor aleatório e o vetor dos valores esperados de cada elemento:

$$\mathbf{E}\{\mathbf{Y}\} = \begin{bmatrix} \mathbf{E}\{Y_1\} \\ \mathbf{E}\{Y_2\} \\ \vdots \\ \mathbf{E}\{Y_n\} \end{bmatrix}$$

Na regressão linear, geralmente temos a pressuposição para o termo dos os erros que $\varepsilon_i \sim N(0, \sigma^2)$ Se o termo do erro for representado como um vetor aleatório temos:

$$\varepsilon = \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_n \end{bmatrix} \Rightarrow \mathbf{E}\{\varepsilon\} = \begin{bmatrix} \mathbf{E}\{\varepsilon_1\} \\ \mathbf{E}\{\varepsilon_2\} \\ \vdots \\ \mathbf{E}\{\varepsilon_n\} \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \\ \vdots \\ 0 \end{bmatrix} = \mathbf{0}$$

7.2 Matrix de Variância-Covariância de um Vetor Aleatório

Se \mathbf{Y} é um vetor aleatório ($n \times 1$), a sua matrix de variância-covariância é definida como:

$$\mathbf{Var}\{\mathbf{Y}\}_{(n \times n)} = \begin{bmatrix} \mathbf{Var}\{Y_1\} & \mathbf{Cov}\{Y_1, Y_2\} & \dots & \mathbf{Cov}\{Y_1, Y_n\} \\ \mathbf{Cov}\{Y_2, Y_1\} & \mathbf{Var}\{Y_2\} & \dots & \mathbf{Cov}\{Y_2, Y_n\} \\ \vdots & \vdots & \dots & \vdots \\ \mathbf{Cov}\{Y_n, Y_1\} & \mathbf{Cov}\{Y_n, Y_2\} & \dots & \mathbf{Var}\{Y_n\} \end{bmatrix}$$

Algumas característica desta matrix:

- Os elementos da diagonal principal ($i = j$) são a variância de cada variável aleatória: $\mathbf{Var}\{Y_1\}, \mathbf{Var}\{Y_2\}, \dots, \mathbf{Var}\{Y_n\}$.
- Os elementos fora da diagonal principal ($i \neq j$) são as covariância entre as variáveis aleatórias: $\mathbf{Cov}\{Y_1, Y_2\}, \mathbf{Cov}\{Y_1, Y_n\}, \dots, \mathbf{Cov}\{Y_i, Y_j\} \dots$
- Como $\mathbf{Cov}\{Y_i, Y_j\} = \mathbf{Cov}\{Y_j, Y_i\}$ a matrix é *simétrica*.
- A definição tradicional de variância-covariância pode ser generalizada para um vetor de variáveis aleatórias, portanto:

$$\mathbf{Var}\{\mathbf{Y}\} = \mathbf{E}\{[\mathbf{Y} - \mathbf{E}\{\mathbf{Y}\}][\mathbf{Y} - \mathbf{E}\{\mathbf{Y}\}]'\}$$

Uma das pressuposições da regressão linear é que os erros se comportam como $\varepsilon_i \stackrel{iid}{\sim} N(0, \sigma^2)$. Neste caso, a matrix de variância-covariância dos erros é:

$$\mathbf{Var}\{\varepsilon\}_{(n \times n)} = \begin{bmatrix} \sigma^2 & 0 & \dots & 0 \\ 0 & \sigma^2 & \dots & 0 \\ \vdots & \vdots & \dots & \vdots \\ 0 & 0 & \dots & \sigma^2 \end{bmatrix} = \sigma^2 \begin{bmatrix} 1 & 0 & \dots & 0 \\ 0 & 1 & \dots & 0 \\ \vdots & \vdots & \dots & \vdots \\ 0 & 0 & \dots & 1 \end{bmatrix} = \sigma^2 \mathbf{I}_n$$

Portanto, em notação matricial, esta pressuposição fica:

$$\varepsilon \sim N(\mathbf{0}, \sigma^2 \mathbf{I}_n).$$

7.3 Algumas Propriedades envolvendo Vetores Aleatório

Já foi visto que uma variável aleatória W pode ser definida como uma combinação linear de uma série de variáveis aleatórias Y_i ($i = 1, \dots, n$), na forma:

$$W = a_1 Y_1 + a_2 Y_2 + \dots + a_n Y_n = \sum_{i=1}^n a_i Y_i,$$

onde a_i ($i = 1, \dots, n$) são constantes.

Generalizando a idéia de *função linear de variáveis aleatórias*, podemos dizer que um vetor aleatório \mathbf{W} é uma combinação linear do vetor aleatório \mathbf{Y} na forma

$$\mathbf{W} = \mathbf{A}\mathbf{Y}$$

onde \mathbf{A} é uma matrix de constantes (não aleatória).

Neste caso, são válidas as seguintes propriedades:

$$\begin{aligned} \mathbf{E}\{\mathbf{A}\} &= \mathbf{A} \\ \mathbf{E}\{\mathbf{W}\} &= \mathbf{E}\{\mathbf{A}\mathbf{Y}\} = \mathbf{A}\mathbf{E}\{\mathbf{Y}\} \\ \mathbf{Var}\{\mathbf{W}\} &= \mathbf{Var}\{\mathbf{A}\mathbf{Y}\} = \mathbf{A}\mathbf{Var}\{\mathbf{Y}\}\mathbf{A}' \end{aligned}$$

Nota: em algebra de matrizes o equivalente a $(ab)^2 = a^2b^2$ é a forma quadrática: $(\mathbf{A}\mathbf{B})^2 = \mathbf{A}\mathbf{B}\mathbf{B}'\mathbf{A}'$.

8 Exercícios

1. Para as matrizes

$$\mathbf{A} = \begin{bmatrix} 1 & 5 & 3 \\ -4 & 8 & 2 \end{bmatrix} \quad \mathbf{B} = \begin{bmatrix} 7 & 2 \\ 4 & -1 \\ 2 & -3 \end{bmatrix}$$

calcule: \mathbf{AB} , $\mathbf{A}'\mathbf{B}'$ e \mathbf{BA} .

2. Expanda o produto matricial

$$\mathbf{X} = \{[\mathbf{AB} + (\mathbf{CD})'] [(\mathbf{EF})^{-1} + \mathbf{GH}]\}'$$

tomando todas as matrizes como quadradas e \mathbf{E} e \mathbf{F} como não-singulares.

3. Seja \mathbf{A} uma matrix quadrada cujas colunas são $[\mathbf{a}_1 \ \mathbf{a}_2 \ \dots \ \mathbf{a}_m]$ e seja \mathbf{B} qualquer *re-arranjanento das colunas* da matrix identidade $m \times m$.

Qual operação é realizada ao se calcular o produto matricial \mathbf{AB} ? E o produto matricial \mathbf{BA} ?

4. Considere a matrix

$$\mathbf{X}' = \begin{bmatrix} 1 & 1 & 1 & 1 \\ -3 & 7 & -5 & 1 \end{bmatrix}.$$

- (a) Compute $\mathbf{P} = \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'$.
- (b) Compute $\mathbf{H} = \mathbf{I} - \mathbf{P}$.
- (c) Verifique que $\mathbf{PH} = \mathbf{0}$.
- (d) Demonstre que \mathbf{P} e \mathbf{H} são idempotentes.

5. Uma matrix \mathbf{A} é chamada de *nilpotente* se

$$\lim_{K \rightarrow \infty} \mathbf{A}^K = \mathbf{0}.$$

Demonstre que a condição necessária e suficiente para uma matrix simétrica ser nilpotente é que o valor absoluto de todos seus auto-valores é menor que um.