



SME0822 Análise Multivariada e Aprendizado Não-Supervisionado

Aula 3: **Vetores aleatórios**

Prof. Cibeles Russo

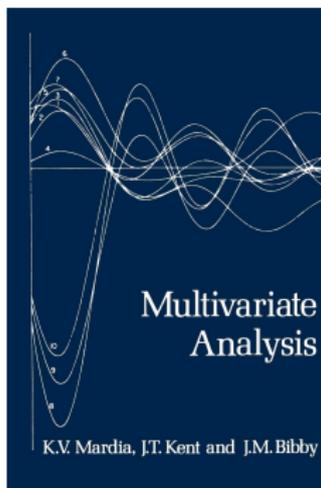
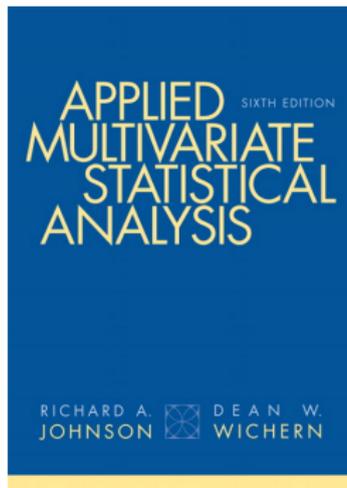
cibele@icmc.usp.br

<http://www.icmc.usp.br/~cibele>

Johnson, R. A., & Wichern, D. W. (2007) Applied Multivariate Statistical Analysis. Prentice Hall.

Mardia, K. V., Kent, J. T. & Bibby J. M. (1979) Multivariate analysis. Academic Press Inc.

Referências indicadas



Vetor aleatório

Def: \underline{X} é um **vetor aleatório** de dimensão $p \times 1$

$$\underline{X} = \begin{pmatrix} X_1 \\ X_2 \\ \vdots \\ X_p \end{pmatrix},$$

em que cada X_i é uma variável aleatória com **média** μ_i e **variância** $\sigma_i^2 = \sigma_{ii}$, para $i = 1, \dots, p$, em que

$$\mu_i = E(X_i) \quad (\text{média populacional})$$

$$\sigma_i^2 = \text{Var}(X_i) = E[(X_i - \mu_i)^2] \quad (\text{variância populacional})$$

Vetor aleatório

Mais especificamente,

$$\mu_i = \begin{cases} \int_{-\infty}^{\infty} x_i f_i(x_i) dx_i, & \text{se } X_i \text{ é v.a. contínua com f.d.p. } f_i(x_i) \\ \sum_{\text{todo } x_i} x_i p_i(x_i), & \text{se } X_i \text{ é v.a. discreta com f.p. } p_i(x_i) \end{cases}$$

$$\sigma_i^2 = \begin{cases} \int_{-\infty}^{\infty} (x_i - \mu_i)^2 f_i(x_i) dx_i, & \text{se } X_i \text{ é v.a. contínua com f.d.p. } f_i(x_i) \\ \sum_{\text{todo } x_i} (x_i - \mu_i)^2 p_i(x_i), & \text{se } X_i \text{ é v.a. discreta com f.p. } p_i(x_i) \end{cases}$$

Covariância e correlação (populacionais)

A **covariância** e a **correlação** (populacionais) entre duas variáveis X_i e X_k , com $i, k = 1, \dots, p$ e $i \neq k$ são dadas, respectivamente, por

$$\text{Cov}(X_i, X_k) = \sigma_{ik} = E[(X_i - \mu_i)(X_k - \mu_k)] \text{ e}$$

$$\text{Cor}(X_i, X_k) = \rho_{ik} = \frac{\sigma_{ik}}{\sqrt{\sigma_i^2} \sqrt{\sigma_k^2}}$$

Covariância e correlação (populacionais)

Mais especificamente,

$$\sigma_{ik} = \left\{ \begin{array}{l} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} (x_i - \mu_i)(x_k - \mu_k) f_{ik}(x_i, x_k) dx_i dx_k, \\ \\ \sum_{\text{todo } x_i} \sum_{\text{todo } x_k} (x_i - \mu_i)(x_k - \mu_k) p_{ik}(x_i, x_k), \end{array} \right.$$

se X_i, X_k
são v.a.'s contínuas
com f.d.p. conjunta
 $f_{ik}(x_i, x_k)$

se X_i, X_k
são v.a.'s discretas
com f.p. conjunta
 $p_{ik}(x_i, x_k)$

Distribuição conjunta de X_1, \dots, X_p

A distribuição conjunta das p variáveis aleatórias (v.a.'s) X_1, \dots, X_p ou do vetor $\underline{X} = (X_1, \dots, X_p)^\top$ é descrito pela **função densidade de probabilidade conjunta** (ou função de probabilidade conjunta no caso discreto) de X_1, \dots, X_p , dada por

$$f(x_1, \dots, x_p) = f(\underline{x}),$$

com

$$\int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} f(u_1, \dots, u_p) du_1 \dots du_p = 1$$

(ou somatória no caso discreto).

Função distribuição acumulada

Se $\underline{X} = (X_1, \dots, X_p)^\top$ é um vetor aleatório e tem f.d.p.

$f(\underline{x}) = f(x_1, \dots, x_p)$, então a **função distribuição acumulada** de \underline{x} é dada por

$$F(\underline{x}) = P(\underline{X} \leq \underline{x}) = P(X_1 \leq x_1, \dots, X_p \leq x_p)$$

que pode ser calculada no nosso contexto como

$$F(\underline{x}) = \int_{-\infty}^{x_1} \dots \int_{-\infty}^{x_p} f(u_1, \dots, u_p) du_1 \dots du_p$$

(no caso discreto substituir por somatórias adequadas)

Função distribuição acumulada

Se $\underline{X} = (X_1, \dots, X_p)^\top$ é um vetor aleatório e tem f.d.p.

$f(\underline{x}) = f(x_1, \dots, x_p)$, então a **função distribuição acumulada** de \underline{x} é dada por

$$F(\underline{x}) = P(\underline{X} \leq \underline{x}) = P(X_1 \leq x_1, \dots, X_p \leq x_p)$$

que pode ser calculada no nosso contexto como

$$F(\underline{x}) = \int_{-\infty}^{x_1} \dots \int_{-\infty}^{x_p} f(u_1, \dots, u_p) du_1 \dots du_p$$

(no caso discreto substituir por somatórias adequadas)

F.d.a. e f.d.p. marginais de X_i

Sem perda de generalidade, suponha $i = 1$.

A função distribuição acumulada marginal de X_1 é dada por

$$F_1(x_1) = P(X_1 \leq x_1) = \int_{-\infty}^{x_1} \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} f(u_1, \dots, u_p) du_1 du_2 \dots du_p$$

A função densidade marginal de X_1 é dada por

$$f_1(x_1) = \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} f(u_1, \dots, u_p) du_2 \dots du_p$$

Note que na última equação temos $p - 1$ integrais somente.

Da mesma forma poderíamos obter outras f.d.a.'s e f.d.p.'s, e analogamente para o caso discreto.

F.d.a. e f.d.p. marginais de X_i

Sem perda de generalidade, suponha $i = 1$.

A função distribuição acumulada marginal de X_1 é dada por

$$F_1(x_1) = P(X_1 \leq x_1) = \int_{-\infty}^{x_1} \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} f(u_1, \dots, u_p) du_1 du_2 \dots du_p$$

A função densidade marginal de X_1 é dada por

$$f_1(x_1) = \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} f(u_1, \dots, u_p) du_2 \dots du_p$$

Note que na última equação temos $p - 1$ integrais somente.

Da mesma forma poderíamos obter outras f.d.a.'s e f.d.p.'s, e analogamente para o caso discreto.

Independência estatística

Dada a distribuição conjunta de X_i e X_k , se

$$P(X_i \leq x_i, X_k \leq x_k) = P(X_i \leq x_i)P(X_k \leq x_k)$$

para todos os pares possíveis (x_i, x_k) , então dizemos que X_i e X_k são estatisticamente independentes.

Quando X_i e X_k são variáveis aleatórias contínuas com f.d.p. $f_{ik}(x_i, x_k)$, a condição para a independência é

$$f_{ik}(x_i, x_k) = f_i(x_i)f_k(x_k)$$

para todo par (x_i, x_k) .

Independência estatística

Dada a distribuição conjunta de X_i e X_k , se

$$P(X_i \leq x_i, X_k \leq x_k) = P(X_i \leq x_i)P(X_k \leq x_k)$$

para todos os pares possíveis (x_i, x_k) , então dizemos que X_i e X_k são estatisticamente independentes.

Quando X_i e X_k são variáveis aleatórias contínuas com f.d.p. $f_{ik}(x_i, x_k)$, a condição para a independência é

$$f_{ik}(x_i, x_k) = f_i(x_i)f_k(x_k)$$

para todo par (x_i, x_k) .

Independência estatística

Se tivermos p variáveis aleatórias contínuas X_1, \dots, X_p , elas são estatisticamente independentes se a sua f.d.p. conjunta pode ser fatorada como

$$f(\underline{x}) = f_1(x_1) \dots f_p(x_p), \forall (x_1, \dots, x_p).$$

A independência tem uma implicação importante:

Se X_i e X_k são independentes, então

$$\text{Cov}(X_i, X_k) = 0$$

A volta não vale necessariamente.

Independência estatística

Se tivermos p variáveis aleatórias contínuas X_1, \dots, X_p , elas são estatisticamente independentes se a sua f.d.p. conjunta pode ser fatorada como

$$f(\underline{x}) = f_1(x_1) \dots f_p(x_p), \forall (x_1, \dots, x_p).$$

A independência tem uma implicação importante:

Se X_i e X_k são independentes, então

$$\text{Cov}(X_i, X_k) = 0$$

A volta não vale necessariamente.

Momentos populacionais

Se $\underline{X}_{p \times 1}$ é um vetor aleatório com f.d.p. $f(\underline{x})$, o **valor esperado** de uma função escalar $g(\underline{x})$ é definido por

$$E(g(\underline{x})) = \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} g(\underline{u}) f(\underline{u}) du_1 \dots du_p.$$

Mais geralmente, o valor esperado de uma função vetorial de \underline{x} , $\underline{g}(\underline{x})$, é dado por

$$E(\underline{g}(\underline{x})) = (E(g_i(\underline{x}))),$$

ou seja, o valor esperado é calculado elemento a elemento da função vetorial $\underline{g}(\underline{x})$.

Momentos populacionais

Se $\underline{X}_{p \times 1}$ é um vetor aleatório com f.d.p. $f(\underline{x})$, o **valor esperado** de uma função escalar $g(\underline{x})$ é definido por

$$E(g(\underline{x})) = \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} g(\underline{u}) f(\underline{u}) du_1 \dots du_p.$$

Mais geralmente, o valor esperado de uma função vetorial de \underline{x} , $\underline{g}(\underline{x})$, é dado por

$$E(\underline{g}(\underline{x})) = (E(g_i(\underline{x}))),$$

ou seja, o valor esperado é calculado elemento a elemento da função vetorial $\underline{g}(\underline{x})$.

Vetor de médias e matriz de variâncias e covariâncias (populacionais)

O **vetor de médias** (populacionais) de \underline{X} é $\underline{\mu}_{p \times 1}$ e a **matriz de variâncias e covariâncias** (populacionais) de \underline{X} é $\Sigma_{p \times p}$, em que

$$\underline{\mu} = E(\underline{X}) = \begin{pmatrix} \mu_1 \\ \mu_2 \\ \vdots \\ \mu_p \end{pmatrix} = \begin{pmatrix} E(X_1) \\ E(X_2) \\ \vdots \\ E(X_p) \end{pmatrix} \text{ e } \Sigma = \begin{pmatrix} \sigma_1^2 & \sigma_{12} & \dots & \sigma_{1p} \\ & \sigma_2^2 & \dots & \sigma_{2p} \\ & & \ddots & \vdots \\ \text{sim.} & & & \sigma_p^2 \end{pmatrix}$$

Obs: Note que Σ é simétrica pois $\text{Cov}(X_i, X_k) = \text{Cov}(X_k, X_i)$, para $i, j = 1, \dots, p$.

Matriz de correlações (populacionais)

A **matriz de correlações** (populacionais) de \underline{X} é $P = P_{p \times p}$, em que

$$P = Cor(\underline{X}) = \begin{pmatrix} 1 & \rho_{12} & \dots & \rho_{1p} \\ & 1 & \dots & \rho_{2p} \\ & & \ddots & \vdots \\ \text{sim.} & & & 1 \end{pmatrix}$$

Obs 1: Pelo mesmo motivo que Σ é simétrica, P também é.

Obs 2: $-1 \leq \rho_{ik} \leq 1$ para $i \neq k$ e $i, k = 1, \dots, p$.

Matriz de variâncias e covariâncias (populacionais)

Matricialmente,

$$\text{Var}(\underline{X}) = \Sigma = E[(\underline{X} - \underline{\mu})(\underline{X} - \underline{\mu})^T].$$

Além disso,

$$\text{Cor}(\underline{X}) = P = (V^{1/2})^{-1}\Sigma(V^{1/2})^{-1} = V^{-1/2}\Sigma V^{-1/2},$$

em que

$$V^{1/2} = \begin{pmatrix} \sqrt{\sigma_{11}} & 0 & \dots & 0 \\ 0 & \sqrt{\sigma_{22}} & \ddots & 0 \\ \vdots & \ddots & \ddots & 0 \\ 0 & \dots & 0 & \sqrt{\sigma_{pp}} \end{pmatrix}$$

Variância e covariância em forma matricial

Sejam \underline{X} e \underline{Y} vetores aleatórios p -dimensionais com

$$E(\underline{X}) = \underline{\mu}_X \text{ e } E(\underline{Y}) = \underline{\mu}_Y.$$

Define-se

- 1 $\text{Var}(\underline{X}) = E[(\underline{X} - \underline{\mu}_X)(\underline{X} - \underline{\mu}_X)^\top],$
- 2 $\text{Cov}(\underline{X}, \underline{Y}) = E[(\underline{X} - \underline{\mu}_X)(\underline{Y} - \underline{\mu}_Y)^\top]$

Variância e covariância em forma matricial

Propriedades.

Sejam \underline{X} , \underline{Y} , \underline{X}_1 e \underline{X}_2 vetores aleatórios p-dimensionais

- 1 $\text{Var}(\underline{X}) = E[\underline{X}\underline{X}^T] - \underline{\mu}_X \underline{\mu}_X^T$,
- 2 $\text{Cov}(\underline{X}, \underline{Y}) = E[\underline{X}\underline{Y}^T] - \underline{\mu}_X \underline{\mu}_Y^T$
- 3 $\text{Var}(A\underline{X} + \underline{b}) = A \text{Var}(\underline{X})A^T$
- 4 $\text{Cov}(A\underline{X} + \underline{b}, C\underline{Y} + \underline{d}) = A \text{Cov}(\underline{X}, \underline{Y})C^T$
- 5 $\text{Cov}(\underline{X}, \underline{X}) = \text{Var}(\underline{X})$
- 6 $\text{Cov}(\underline{X}_1 + \underline{X}_2, \underline{Y}) = \text{Cov}(\underline{X}_1, \underline{Y}) + \text{Cov}(\underline{X}_2, \underline{Y})$
- 7 $\text{Var}(\underline{X} + \underline{Y}) = \text{Var}(\underline{X}) + \text{Var}(\underline{Y}) + \text{Cov}(\underline{X}, \underline{Y}) + \text{Cov}(\underline{Y}, \underline{X})$
- 8 Se \underline{X} e \underline{Y} são independentes, então $\text{Cov}(\underline{X}, \underline{Y}) = 0$. A volta nem sempre vale.

Variância e covariância em forma matricial

Propriedades.

Sejam \underline{X} , \underline{Y} , \underline{X}_1 e \underline{X}_2 vetores aleatórios p-dimensionais

- 1 $\text{Var}(\underline{X}) = E[\underline{X}\underline{X}^T] - \underline{\mu}_X \underline{\mu}_X^T$,
- 2 $\text{Cov}(\underline{X}, \underline{Y}) = E[\underline{X}\underline{Y}^T] - \underline{\mu}_X \underline{\mu}_Y^T$
- 3 $\text{Var}(A\underline{X} + \underline{b}) = A \text{Var}(\underline{X})A^T$
- 4 $\text{Cov}(A\underline{X} + \underline{b}, C\underline{Y} + \underline{d}) = A \text{Cov}(\underline{X}, \underline{Y})C^T$
- 5 $\text{Cov}(\underline{X}, \underline{X}) = \text{Var}(\underline{X})$
- 6 $\text{Cov}(\underline{X}_1 + \underline{X}_2, \underline{Y}) = \text{Cov}(\underline{X}_1, \underline{Y}) + \text{Cov}(\underline{X}_2, \underline{Y})$
- 7 $\text{Var}(\underline{X} + \underline{Y}) = \text{Var}(\underline{X}) + \text{Var}(\underline{Y}) + \text{Cov}(\underline{X}, \underline{Y}) + \text{Cov}(\underline{Y}, \underline{X})$
- 8 Se \underline{X} e \underline{Y} são independentes, então $\text{Cov}(\underline{X}, \underline{Y}) = 0$. A volta nem sempre vale.

Variância e covariância em forma matricial

Propriedades.

Sejam \underline{X} , \underline{Y} , \underline{X}_1 e \underline{X}_2 vetores aleatórios p-dimensionais

- 1 $\text{Var}(\underline{X}) = E[\underline{X}\underline{X}^T] - \underline{\mu}_X \underline{\mu}_X^T$,
- 2 $\text{Cov}(\underline{X}, \underline{Y}) = E[\underline{X}\underline{Y}^T] - \underline{\mu}_X \underline{\mu}_Y^T$
- 3 $\text{Var}(A\underline{X} + \underline{b}) = A \text{Var}(\underline{X})A^T$
- 4 $\text{Cov}(A\underline{X} + \underline{b}, C\underline{Y} + \underline{d}) = A \text{Cov}(\underline{X}, \underline{Y})C^T$
- 5 $\text{Cov}(\underline{X}, \underline{X}) = \text{Var}(\underline{X})$
- 6 $\text{Cov}(\underline{X}_1 + \underline{X}_2, \underline{Y}) = \text{Cov}(\underline{X}_1, \underline{Y}) + \text{Cov}(\underline{X}_2, \underline{Y})$
- 7 $\text{Var}(\underline{X} + \underline{Y}) = \text{Var}(\underline{X}) + \text{Var}(\underline{Y}) + \text{Cov}(\underline{X}, \underline{Y}) + \text{Cov}(\underline{Y}, \underline{X})$
- 8 Se \underline{X} e \underline{Y} são independentes, então $\text{Cov}(\underline{X}, \underline{Y}) = 0$. A volta nem sempre vale.

Variância e covariância em forma matricial

Propriedades.

Sejam \underline{X} , \underline{Y} , \underline{X}_1 e \underline{X}_2 vetores aleatórios p-dimensionais

- 1 $\text{Var}(\underline{X}) = E[\underline{X}\underline{X}^T] - \underline{\mu}_X \underline{\mu}_X^T$,
- 2 $\text{Cov}(\underline{X}, \underline{Y}) = E[\underline{X}\underline{Y}^T] - \underline{\mu}_X \underline{\mu}_Y^T$
- 3 $\text{Var}(A\underline{X} + \underline{b}) = A \text{Var}(\underline{X})A^T$
- 4 $\text{Cov}(A\underline{X} + \underline{b}, C\underline{Y} + \underline{d}) = A \text{Cov}(\underline{X}, \underline{Y})C^T$
- 5 $\text{Cov}(\underline{X}, \underline{X}) = \text{Var}(\underline{X})$
- 6 $\text{Cov}(\underline{X}_1 + \underline{X}_2, \underline{Y}) = \text{Cov}(\underline{X}_1, \underline{Y}) + \text{Cov}(\underline{X}_2, \underline{Y})$
- 7 $\text{Var}(\underline{X} + \underline{Y}) = \text{Var}(\underline{X}) + \text{Var}(\underline{Y}) + \text{Cov}(\underline{X}, \underline{Y}) + \text{Cov}(\underline{Y}, \underline{X})$
- 8 Se \underline{X} e \underline{Y} são independentes, então $\text{Cov}(\underline{X}, \underline{Y}) = 0$. A volta nem sempre vale.

Variância e covariância em forma matricial

Propriedades.

Sejam \underline{X} , \underline{Y} , \underline{X}_1 e \underline{X}_2 vetores aleatórios p-dimensionais

- 1 $\text{Var}(\underline{X}) = E[\underline{X}\underline{X}^T] - \underline{\mu}_X \underline{\mu}_X^T$,
- 2 $\text{Cov}(\underline{X}, \underline{Y}) = E[\underline{X}\underline{Y}^T] - \underline{\mu}_X \underline{\mu}_Y^T$
- 3 $\text{Var}(A\underline{X} + \underline{b}) = A \text{Var}(\underline{X})A^T$
- 4 $\text{Cov}(A\underline{X} + \underline{b}, C\underline{Y} + \underline{d}) = A \text{Cov}(\underline{X}, \underline{Y})C^T$
- 5 $\text{Cov}(\underline{X}, \underline{X}) = \text{Var}(\underline{X})$
- 6 $\text{Cov}(\underline{X}_1 + \underline{X}_2, \underline{Y}) = \text{Cov}(\underline{X}_1, \underline{Y}) + \text{Cov}(\underline{X}_2, \underline{Y})$
- 7 $\text{Var}(\underline{X} + \underline{Y}) = \text{Var}(\underline{X}) + \text{Var}(\underline{Y}) + \text{Cov}(\underline{X}, \underline{Y}) + \text{Cov}(\underline{Y}, \underline{X})$
- 8 Se \underline{X} e \underline{Y} são independentes, então $\text{Cov}(\underline{X}, \underline{Y}) = 0$. A volta nem sempre vale.

Variância e covariância em forma matricial

Propriedades.

Sejam \underline{X} , \underline{Y} , \underline{X}_1 e \underline{X}_2 vetores aleatórios p-dimensionais

- 1 $\text{Var}(\underline{X}) = E[\underline{X}\underline{X}^\top] - \underline{\mu}_X \underline{\mu}_X^\top,$
- 2 $\text{Cov}(\underline{X}, \underline{Y}) = E[\underline{X}\underline{Y}^\top] - \underline{\mu}_X \underline{\mu}_Y^\top$
- 3 $\text{Var}(A\underline{X} + \underline{b}) = A \text{Var}(\underline{X})A^\top$
- 4 $\text{Cov}(A\underline{X} + \underline{b}, C\underline{Y} + \underline{d}) = A \text{Cov}(\underline{X}, \underline{Y})C^\top$
- 5 $\text{Cov}(\underline{X}, \underline{X}) = \text{Var}(\underline{X})$
- 6 $\text{Cov}(\underline{X}_1 + \underline{X}_2, \underline{Y}) = \text{Cov}(\underline{X}_1, \underline{Y}) + \text{Cov}(\underline{X}_2, \underline{Y})$
- 7 $\text{Var}(\underline{X} + \underline{Y}) = \text{Var}(\underline{X}) + \text{Var}(\underline{Y}) + \text{Cov}(\underline{X}, \underline{Y}) + \text{Cov}(\underline{Y}, \underline{X})$
- 8 Se \underline{X} e \underline{Y} são independentes, então $\text{Cov}(\underline{X}, \underline{Y}) = 0$. A volta nem sempre vale.

Variância e covariância em forma matricial

Propriedades.

Sejam \underline{X} , \underline{Y} , \underline{X}_1 e \underline{X}_2 vetores aleatórios p-dimensionais

- 1 $\text{Var}(\underline{X}) = E[\underline{X}\underline{X}^\top] - \underline{\mu}_X \underline{\mu}_X^\top,$
- 2 $\text{Cov}(\underline{X}, \underline{Y}) = E[\underline{X}\underline{Y}^\top] - \underline{\mu}_X \underline{\mu}_Y^\top$
- 3 $\text{Var}(A\underline{X} + \underline{b}) = A \text{Var}(\underline{X})A^\top$
- 4 $\text{Cov}(A\underline{X} + \underline{b}, C\underline{Y} + \underline{d}) = A \text{Cov}(\underline{X}, \underline{Y})C^\top$
- 5 $\text{Cov}(\underline{X}, \underline{X}) = \text{Var}(\underline{X})$
- 6 $\text{Cov}(\underline{X}_1 + \underline{X}_2, \underline{Y}) = \text{Cov}(\underline{X}_1, \underline{Y}) + \text{Cov}(\underline{X}_2, \underline{Y})$
- 7 $\text{Var}(\underline{X} + \underline{Y}) = \text{Var}(\underline{X}) + \text{Var}(\underline{Y}) + \text{Cov}(\underline{X}, \underline{Y}) + \text{Cov}(\underline{Y}, \underline{X})$
- 8 Se \underline{X} e \underline{Y} são independentes, então $\text{Cov}(\underline{X}, \underline{Y}) = 0$. A volta nem sempre vale.

Variância e covariância em forma matricial

Propriedades.

Sejam \underline{X} , \underline{Y} , \underline{X}_1 e \underline{X}_2 vetores aleatórios p-dimensionais

- 1 $\text{Var}(\underline{X}) = E[\underline{X}\underline{X}^\top] - \underline{\mu}_X \underline{\mu}_X^\top,$
- 2 $\text{Cov}(\underline{X}, \underline{Y}) = E[\underline{X}\underline{Y}^\top] - \underline{\mu}_X \underline{\mu}_Y^\top$
- 3 $\text{Var}(A\underline{X} + \underline{b}) = A \text{Var}(\underline{X})A^\top$
- 4 $\text{Cov}(A\underline{X} + \underline{b}, C\underline{Y} + \underline{d}) = A \text{Cov}(\underline{X}, \underline{Y})C^\top$
- 5 $\text{Cov}(\underline{X}, \underline{X}) = \text{Var}(\underline{X})$
- 6 $\text{Cov}(\underline{X}_1 + \underline{X}_2, \underline{Y}) = \text{Cov}(\underline{X}_1, \underline{Y}) + \text{Cov}(\underline{X}_2, \underline{Y})$
- 7 $\text{Var}(\underline{X} + \underline{Y}) = \text{Var}(\underline{X}) + \text{Var}(\underline{Y}) + \text{Cov}(\underline{X}, \underline{Y}) + \text{Cov}(\underline{Y}, \underline{X})$
- 8 Se \underline{X} e \underline{Y} são independentes, então $\text{Cov}(\underline{X}, \underline{Y}) = 0$. A volta nem sempre vale.

Amostra aleatória

Suponha que \underline{X} tem uma **distribuição de probabilidade multivariada**, e que vamos observar uma **amostra aleatória** dessa distribuição, ou seja, n observações independentes e que vem todas da mesma distribuição:

amostra aleatória: $\underline{\tilde{X}}_1, \dots, \underline{\tilde{X}}_n$,

em que $\underline{\tilde{X}}_i^\top = (X_{i1}, X_{i2}, \dots, X_{ip})$.

Matriz aleatória

Suponha que $\underline{X}_1, \dots, \underline{X}_n$ ainda não foram observados, mas podemos organiza-las em uma **matriz aleatória**

$$X = \begin{pmatrix} X_{11} & X_{12} & \dots & X_{1p} \\ X_{21} & X_{22} & \dots & X_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ X_{n1} & X_{n2} & \dots & X_{np} \end{pmatrix}_{n \times p} = \begin{pmatrix} \underline{X}_1^T \\ \underline{X}_2^T \\ \vdots \\ \underline{X}_n^T \end{pmatrix}$$

Estimadores para $\underline{\mu}$ e Σ

Seja $\underline{X}_1, \dots, \underline{X}_n$ a.a. de uma distribuição com $E(\underline{X}) = \underline{\mu}$ e $\text{Var}(\underline{X}) = \Sigma$.

Então

- $\bar{\underline{X}}$ é um estimador não-viesado para $\underline{\mu}$, com $\text{Var}(\bar{\underline{X}}) = \frac{\Sigma}{n}$ e
- $\frac{n}{n-1}S$ é um estimador não-viesado para Σ , ou seja
 $E\left(\frac{n}{n-1}S\right) = \Sigma$.

Obs: Vimos na Aula 1 que os elementos de S são dados por

$$s_{ik} = \frac{1}{n} \sum_{j=1}^n (x_{ji} - \bar{x}_i)(x_{jk} - \bar{x}_k)$$

Estimadores para $\underline{\mu}$ e Σ

Seja $\underline{X}_1, \dots, \underline{X}_n$ a.a. de uma distribuição com $E(\underline{X}) = \underline{\mu}$ e $\text{Var}(\underline{X}) = \Sigma$.

Então

- $\bar{\underline{X}}$ é um estimador não-viesado para $\underline{\mu}$, com $\text{Var}(\bar{\underline{X}}) = \frac{\Sigma}{n}$ e
- $\frac{n}{n-1}S$ é um estimador não-viesado para Σ , ou seja
 $E\left(\frac{n}{n-1}S\right) = \Sigma$.

Obs: Vimos na Aula 1 que os elementos de S são dados por

$$s_{ik} = \frac{1}{n} \sum_{j=1}^n (x_{ji} - \bar{x}_i)(x_{jk} - \bar{x}_k)$$