

A Distribuição Normal Multivariada

Prof. Caio Azevedo

Brevíssima revisão de cálculo de probabilidades

- Como usual, denotaremos por uma letra maiúscula, e.g. Y , uma variável aleatória (va) e por uma letra minúscula, y , um valor observado (realização de um experimento aleatório) desta va.
- Um vetor aleatório (vea) $\mathbf{Y} = (Y_1, \dots, Y_p)'$ é uma coleção (arranjo) de variáveis aleatórias.
- As va's que compõem um vea podem apresentar alguma estrutura de dependência e/ou serem de diferentes tipos (discretas, contínuas ou mistas).

- Função densidade de probabilidade ou função de probabilidade:

$$f_{\mathbf{Y}}(\mathbf{y})$$

- Função de distribuição acumulada $F_{\mathbf{Y}}(\mathbf{y}) = P(Y_1 \leq y_1, \dots, Y_p \leq y_p)$.

- Vetor de médias: $\boldsymbol{\mu} = \mathcal{E}(\mathbf{Y}) = \begin{bmatrix} \mathcal{E}(Y_1) \\ \mathcal{E}(Y_2) \\ \vdots \\ \mathcal{E}(Y_p) \end{bmatrix} = \begin{bmatrix} \mu_1 \\ \mu_2 \\ \vdots \\ \mu_p \end{bmatrix}$

- Matriz de covariâncias: $\boldsymbol{\Sigma} = Cov(\mathbf{Y}) = \begin{bmatrix} \sigma_1^2 & \sigma_{12} & \dots & \sigma_{1p} \\ \sigma_{12} & \sigma_2^2 & \dots & \sigma_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{1p} & \sigma_{2p} & \dots & \sigma_p^2 \end{bmatrix}$

- Função geradora de momentos:

$$M_{\mathbf{Y}}(\mathbf{t}) = \int \left(\dots \left(\int \left(\int e^{\mathbf{y}' \mathbf{t}} f_{\mathbf{Y}}(\mathbf{y}) dy_1 \right) dy_2 \right) \dots \right) dy_p$$

- Função característica:

$$\Phi_{\mathbf{Y}}(\mathbf{t}) = \int \left(\dots \left(\int \left(\int e^{i\mathbf{y}' \mathbf{t}} f_{\mathbf{Y}}(\mathbf{y}) dy_1 \right) dy_2 \right) \dots \right) dy_p$$

- Sejam \mathbf{A} e \mathbf{B} matrizes não aleatórias, então

- $\mathcal{E}(\mathbf{AY}) = \mathbf{A}\mathcal{E}(\mathbf{Y}).$
- $Cov(\mathbf{AY}) = \mathbf{ACov}(\mathbf{Y})\mathbf{A}'.$
- $Cov(\mathbf{AY}, \mathbf{BX}) = \mathbf{ACov}(\mathbf{Y}, \mathbf{X})\mathbf{B}'.$
- Se $\mathbf{Y} = \mathbf{AX} + \mathbf{B}$, então $M_{\mathbf{Y}}(\mathbf{t}) = e^{\mathbf{t}' \mathbf{B}} M_{\mathbf{X}}(\mathbf{t}' \mathbf{A}).$





Distribuição Normal multivariada

- Dizemos que $\mathbf{Y} = (Y_1, \dots, Y_p)' \sim N_p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ se sua fdp é dada por

$$f_{\mathbf{Y}}(\mathbf{y}) = |\boldsymbol{\Sigma}|^{-1/2} (2\pi)^{-p/2} \exp \left\{ -\frac{1}{2} (\mathbf{y} - \boldsymbol{\mu})' \boldsymbol{\Sigma}^{-1} (\mathbf{y} - \boldsymbol{\mu}) \right\} \mathbb{1}_{\mathcal{R}^p}(\mathbf{y})$$


- $\boldsymbol{\mu}$ é o vetor de médias e $\boldsymbol{\Sigma}$ é a matriz de covariâncias.
- $M_{\mathbf{Y}}(\mathbf{t}) = \exp \left\{ \boldsymbol{\mu}' \mathbf{t} + \frac{1}{2} \mathbf{t}' \boldsymbol{\Sigma} \mathbf{t} \right\}$

$$\mu_1 = \mu_2 = 0, \sigma_1^2 = \sigma_2^2 = 1, \text{correlação} = \sigma_{11}$$




$$\mu_1 = \mu_2 = 0, \sigma_1^2 = \sigma_2^2 = 1, \text{correlação} = \sigma_{11}$$


correlação = 0




correlação = 0



correlação = -0.9



correlação = 0.9



Propiedades

- Fechada sob marginalização: $Y_i \sim N(\mu_i, \sigma_i^2)$.
- $Y_i \perp Y_j, \forall i \neq j \Leftrightarrow \text{Cov}(Y_i, Y_j) = \sigma_{ij} = 0$.
- Se $\mathbf{A}_{(q \times p)}$ e $\mathbf{B}_{(q \times 1)}$ forem matrizes não aleatórias, então
$$\mathbf{V} = \mathbf{AY} + \mathbf{B} \sim N_q(\mathbf{A}\boldsymbol{\mu} + \mathbf{B}, \mathbf{A}\boldsymbol{\Sigma}\mathbf{A}')$$
.
- Se $\mathbf{A}_{(p \times p)}$ for uma matriz não aleatória, simétrica e idempotente de $\text{rank} = p$, $\boldsymbol{\mu} = \mathbf{0}$ e $\boldsymbol{\Sigma} = \sigma^2 \mathbf{I}_{(p \times p)}$, então
$$V = \frac{1}{\sigma^2} \mathbf{Y}' \mathbf{AY} \sim \chi_r^2, r = \text{rank}(\mathbf{A})$$
. Em particular, se $\mathbf{A} = \mathbf{I}$, então
$$\frac{1}{\sigma^2} \mathbf{Y}' \mathbf{Y} \sim \chi_p^2$$
.
- Se $\mathbf{A}_{(p \times p)}$ for uma matriz não aleatória, então
$$\mathcal{E}(\mathbf{Y}' \mathbf{AY}) = \text{tr}(\mathbf{A}\boldsymbol{\Sigma}) + \boldsymbol{\mu}' \mathbf{A}\boldsymbol{\mu}$$
.

Derivadas matriciais úteis

- Sejam $\mathbf{A}_{(m \times n)}$ e $\mathbf{x}_{(n \times 1)}$ tais que

$$\mathbf{A} = \begin{bmatrix} a_{11} & a_{12} & \dots & a_{1n} \\ a_{21} & a_{22} & \dots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{m1} & a_{m2} & \dots & a_{mn} \end{bmatrix}; \mathbf{x} = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix}$$

Derivadas matriciais úteis

- Sejam $\mathbf{A}_{(m \times n)}$ e $\mathbf{x}_{(n \times 1)}$, e defina $\mathbf{y} = \mathbf{Ax}$ (\mathbf{A} não depende de \mathbf{x}).

Então:

$$\mathbf{y} = \begin{bmatrix} \sum_{k=1}^n a_{1k}x_k \\ \sum_{k=1}^n a_{2k}x_k \\ \vdots \\ \sum_{k=1}^n a_{mk}x_k \end{bmatrix}$$

■ Logo

$$\frac{\partial \mathbf{y}}{\partial \mathbf{x}} = \frac{\partial \mathbf{Ax}}{\partial \mathbf{x}} = \begin{bmatrix} \frac{\partial \sum_{k=1}^n a_{1k}x_k}{\partial x_1} & \frac{\partial \sum_{k=1}^n a_{1k}x_k}{\partial x_2} & \cdots & \frac{\partial \sum_{k=1}^n a_{1k}x_k}{\partial x_n} \\ \frac{\partial \sum_{k=1}^n a_{2k}x_k}{\partial x_1} & \frac{\partial \sum_{k=1}^n a_{2k}x_k}{\partial x_2} & \cdots & \frac{\partial \sum_{k=1}^n a_{2k}x_k}{\partial x_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial \sum_{k=1}^n a_{mk}x_k}{\partial x_1} & \frac{\partial \sum_{k=1}^n a_{mk}x_k}{\partial x_2} & \cdots & \frac{\partial \sum_{k=1}^n a_{mk}x_k}{\partial x_n} \end{bmatrix}$$
$$\mathbf{A} = \begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{m1} & a_{m2} & \cdots & a_{mn} \end{bmatrix}$$

Derivadas matriciais úteis

- Alguns resultados:

$$\frac{\partial \mathbf{A}\mathbf{x}}{\partial \mathbf{x}} = \mathbf{A}$$

$$\frac{\partial \mathbf{x}'\mathbf{A}}{\partial \mathbf{x}} = \mathbf{A}'$$

$$\frac{\partial \mathbf{x}'\mathbf{x}}{\partial \mathbf{x}} = 2\mathbf{x}$$

$$\frac{\partial \mathbf{x}'\mathbf{A}\mathbf{x}}{\partial \mathbf{x}} = (\mathbf{A} + \mathbf{A}')\mathbf{x}$$

Dem. de que $f_{\mathbf{Y}}(\cdot)$ é uma fdp

- Queremos demonstrar que

$$I = \int_{\mathcal{R}^p} f_{\mathbf{Y}}(\mathbf{y}) d\mathbf{y} = \int_{\mathcal{R}} \int_{\mathcal{R}} \dots \int_{\mathcal{R}} f_{\mathbf{Y}}(\mathbf{y}) d\mathbf{y} = 1$$

Note que, se $\boldsymbol{\Sigma} = \boldsymbol{\Psi}\boldsymbol{\Psi}'$ (decomposição de Cholesky), temos que:

$$\begin{aligned} I &= \int_{\mathcal{R}^p} |\boldsymbol{\Sigma}|^{-1/2} (2\pi)^{-p/2} \exp \left\{ -\frac{1}{2} (\mathbf{y} - \boldsymbol{\mu})' (\boldsymbol{\Psi}\boldsymbol{\Psi}')^{-1} (\mathbf{y} - \boldsymbol{\mu}) \right\} d\mathbf{y} \\ &= \int_{\mathcal{R}^p} |\boldsymbol{\Sigma}|^{-1/2} (2\pi)^{-p/2} \exp \left\{ -\frac{1}{2} [\boldsymbol{\Psi}^{-1}(\mathbf{y} - \boldsymbol{\mu})]' (\boldsymbol{\Psi})^{-1} (\mathbf{y} - \boldsymbol{\mu}) \right\} d\mathbf{y} \end{aligned}$$

considere a transformação $\mathbf{z} = \boldsymbol{\Psi}^{-1}(\mathbf{y} - \boldsymbol{\mu}) \Leftrightarrow \mathbf{y} = \boldsymbol{\Psi}\mathbf{z} + \boldsymbol{\mu}.$

Dem. de que $f_{\mathbf{Y}}(\cdot)$ é uma fdp

- Matriz Jacobiana

$$\mathbf{J} = \frac{\partial \mathbf{y}}{\partial \mathbf{z}} = \begin{bmatrix} \frac{\partial y_1}{\partial z_1} & \frac{\partial y_1}{\partial z_2} & \cdots & \frac{\partial y_1}{\partial z_n} \\ \frac{\partial y_2}{\partial z_1} & \frac{\partial y_2}{\partial z_2} & \cdots & \frac{\partial y_2}{\partial z_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial y_n}{\partial z_1} & \frac{\partial y_n}{\partial z_2} & \cdots & \frac{\partial y_n}{\partial z_n} \end{bmatrix}$$

- Temos que $\frac{\partial \mathbf{y}}{\partial \mathbf{z}} = \frac{\partial \Psi \mathbf{z} + \boldsymbol{\mu}}{\partial \mathbf{z}} = \boldsymbol{\Psi}$.

- Além disso,

$$|\mathbf{J}| = |\boldsymbol{\Psi}| = |\boldsymbol{\Psi}|^{1/2} |\boldsymbol{\Psi}|^{1/2} = |\boldsymbol{\Psi}|^{1/2} |\boldsymbol{\Psi}'|^{1/2} = |\boldsymbol{\Psi} \boldsymbol{\Psi}'|^{1/2} = |\boldsymbol{\Sigma}|^{1/2}$$

- Lembrando que $\int_{\mathcal{R}^p} f_Y(\mathbf{y}) d\mathbf{y} = \int_{\mathcal{R}^p} f_Y(\boldsymbol{\Psi}\mathbf{z} + \boldsymbol{\mu}) |\mathbf{J}| d\mathbf{z}$
- Assim,

$$\begin{aligned} I &= \int_{\mathcal{R}^p} |\boldsymbol{\Sigma}|^{-1/2} |\boldsymbol{\Sigma}|^{1/2} (2\pi)^{-p/2} \exp \left\{ -\frac{1}{2} \mathbf{z}' \mathbf{z} \right\} d\mathbf{z} \\ &= \prod_{i=1}^p \underbrace{\int_{\mathcal{R}} \frac{1}{\sqrt{2\pi}} \exp \left\{ -\frac{1}{2} z_i^2 \right\} dz_i}_1 = 1 \end{aligned}$$

Obtenção das Marginais

- Note que, para um dado j , $M_{Y_j}(t_j) = M_Y(\mathbf{t}^*)$, em que $\mathbf{t}^* = [0 \ 0 \dots \underbrace{1}_{\text{posição } j} \ \dots \ 0 \ 0]$.
- Logo, temos que $M_{Y_j}(t_j) = \exp \left\{ \mu_j t_j + \frac{\sigma_j^2 t_j}{2} \right\}$.
- A fgm acima corresponde à fgm de uma va com distribuição $N(\mu_j, \sigma_j^2)$.

Distribuições condicionais

- Seja $\mathbf{Y} = (\mathbf{Y}_1, \mathbf{Y}_2)'$, $\boldsymbol{\mu} = (\mu_1, \mu_2)'$ e

$$\boldsymbol{\Sigma} = \begin{bmatrix} \boldsymbol{\Sigma}_{11} & \boldsymbol{\Sigma}_{12} \\ \boldsymbol{\Sigma}_{21} & \boldsymbol{\Sigma}_{22} \end{bmatrix}$$

em que $\boldsymbol{\Sigma}_{21} = \boldsymbol{\Sigma}'_{12}$.

- Então $\mathbf{Y}_1 | \mathbf{Y}_2 = \mathbf{y}_2 \sim N(\bar{\boldsymbol{\mu}}, \bar{\boldsymbol{\Sigma}})$, em que

$$\bar{\boldsymbol{\mu}} = \boldsymbol{\mu}_1 + \boldsymbol{\Sigma}_{12}\boldsymbol{\Sigma}_{22}^{-1}(\mathbf{y}_2 - \boldsymbol{\mu}_2); \bar{\boldsymbol{\Sigma}} = \boldsymbol{\Sigma}_{11} - \boldsymbol{\Sigma}_{12}\boldsymbol{\Sigma}_{22}^{-1}\boldsymbol{\Sigma}_{21}$$

- Estimadores de máxima verossimilhança (dada uma amostra

aleatória) $\hat{\boldsymbol{\mu}} = \bar{\mathbf{Y}} = \frac{1}{n} \sum_{i=1}^n \mathbf{Y}_i$ e $\hat{\boldsymbol{\Sigma}} = \frac{1}{n} \sum_{i=1}^n (\mathbf{Y}_i - \bar{\mathbf{Y}})' (\mathbf{Y}_i - \bar{\mathbf{Y}})$.