

A Distribuição Normal Multivariada

Prof. Caio Azevedo

Introdução

- 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: $\boldsymbol{\Sigma} = \text{Cov}(\mathbf{Y}) = \mathcal{E}[(\mathbf{Y} - \boldsymbol{\mu})(\mathbf{Y} - \boldsymbol{\mu})'] =$

$$\mathcal{E}(\mathbf{Y}\mathbf{Y}') - \boldsymbol{\mu}\boldsymbol{\mu}' = \begin{bmatrix} \sigma_1^2 & \sigma_{12} & \dots & \sigma_{1p} \\ \sigma_{12} & \sigma_2^2 & \dots & \sigma_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{1p} & \sigma_{2p} & \dots & \sigma_p^2 \end{bmatrix}$$

- Função geradora de momentos:

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

- Função característica:

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

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

- $\mathcal{E}(\mathbf{A}\mathbf{Y}) = \mathbf{A}\mathcal{E}(\mathbf{Y})$.

- $\text{Cov}(\mathbf{A}\mathbf{Y}) = \mathbf{A}\text{Cov}(\mathbf{Y})\mathbf{A}'$.

- $\text{Cov}(\mathbf{A}\mathbf{Y}, \mathbf{B}\mathbf{X}) = \mathcal{E}((\mathbf{A}\mathbf{Y} - \mathbf{A}\boldsymbol{\mu})(\mathbf{B}\mathbf{X} - \mathbf{B}\boldsymbol{\mu})') = \mathbf{A}\text{Cov}(\mathbf{Y}, \mathbf{X})\mathbf{B}'$.

- Se $\mathbf{Y} = \mathbf{A}\mathbf{X} + \mathbf{B}$, então $M_{\mathbf{Y}}(\mathbf{t}) = e^{\mathbf{t}'\mathbf{B}}M_{\mathbf{X}}(\mathbf{t}'\mathbf{A})$.

Esperança de um vetor aleatório

$$\begin{aligned}\mathcal{E}(\mathbf{AY}) &= \mathcal{E} \left(\begin{bmatrix} A_{11} & A_{12} & \dots & A_{1p} \\ A_{21} & A_{22} & \dots & A_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ A_{q1} & A_{q2} & \dots & A_{qp} \end{bmatrix} \begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_p \end{bmatrix} \right) = \mathcal{E} \left(\begin{bmatrix} \sum_{i=1}^p A_{1i} Y_i \\ \sum_{i=1}^p A_{2i} Y_i \\ \vdots \\ \sum_{i=1}^p A_{qi} Y_i \end{bmatrix} \right) \\ &= \begin{bmatrix} \sum_{i=1}^p A_{1i} \mathcal{E}(Y_i) \\ \sum_{i=1}^p A_{2i} \mathcal{E}(Y_i) \\ \vdots \\ \sum_{i=1}^p A_{qi} \mathcal{E}(Y_i) \end{bmatrix} = \begin{bmatrix} \sum_{i=1}^p A_{1i} \mu_i \\ \sum_{i=1}^p A_{2i} \mu_i \\ \vdots \\ \sum_{i=1}^p A_{qi} \mu_i \end{bmatrix} = \mathbf{A} \mathcal{E}(\mathbf{Y}) = \mathbf{A} \boldsymbol{\mu}\end{aligned}$$

Matriz de covariâncias e fgm de um vetor aleatório

- Matriz de covariâncias.

$$\begin{aligned} \text{Cov}(\mathbf{AY}) &= \mathcal{E}[(\mathbf{AY} - \mathbf{A}\boldsymbol{\mu})(\mathbf{AY} - \mathbf{A}\boldsymbol{\mu})'] = \mathcal{E}[\mathbf{A}(\mathbf{Y} - \boldsymbol{\mu})(\mathbf{Y} - \boldsymbol{\mu})'\mathbf{A}'] \\ &= \mathbf{A}\mathcal{E}[(\mathbf{Y} - \boldsymbol{\mu})(\mathbf{Y} - \boldsymbol{\mu})']\mathbf{A} = \mathbf{A}\text{Cov}(\mathbf{Y})\mathbf{A}' \end{aligned}$$

- Se $\mathbf{Y} = \mathbf{AX} + \mathbf{B}$, então

$$\begin{aligned} M_{\mathbf{Y}}(\mathbf{t}) &= \mathcal{E}(e^{\mathbf{t}'(\mathbf{AX} + \mathbf{B})}) = \mathcal{E}(e^{\mathbf{t}'\mathbf{AX} + \mathbf{t}'\mathbf{B}}) = \mathcal{E}(e^{\mathbf{t}'\mathbf{AX}})\mathcal{E}(e^{\mathbf{t}'\mathbf{B}}) \\ &= M_{\mathbf{X}}(\mathbf{t}'\mathbf{A})e^{\mathbf{t}'\mathbf{B}} = M_{\mathbf{X}}(\mathbf{t}^*)e^{\mathbf{t}'\mathbf{B}}, \end{aligned}$$

em que $\mathbf{t}^* = \mathbf{t}'\mathbf{A}$

Matriz de correlações

- Seja $\mathbf{\Sigma} = \text{Cov}(\mathbf{Y})$ e defina $\mathbf{D} = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_p)$, em que $\sigma_i = \sqrt{\sigma_i^2}, i = 1, 2, \dots, p$.
- Assim, temos que $\boldsymbol{\rho} = \mathbf{D}^{-1}\mathbf{\Sigma}\mathbf{D}^{-1}$ é a matriz de correlações associada a \mathbf{Y} , pois

Matriz de correlações (cont.)

$$\rho = \begin{bmatrix} \sigma_1^{-1} & 0 & \dots & 0 \\ 0 & \sigma_2^{-1} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \sigma_p^{-1} \end{bmatrix} \begin{bmatrix} \sigma_1^2 & \sigma_{12} & \dots & \sigma_{1p} \\ \sigma_{12} & \sigma_2^2 & \dots & \sigma_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{1p} & \sigma_{2p} & \dots & \sigma_p^2 \end{bmatrix}$$
$$\times \begin{bmatrix} \sigma_1^{-1} & 0 & \dots & 0 \\ 0 & \sigma_2^{-1} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \sigma_p^{-1} \end{bmatrix} = \begin{bmatrix} 1 & \rho_{12} & \dots & \rho_{1p} \\ \rho_{12} & 1 & \dots & \rho_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ \rho_{1p} & \rho_{2p} & \dots & 1 \end{bmatrix}$$

em que $\rho_{ij} = \frac{\sigma_{ij}}{\sigma_i \sigma_j}$

Variância generalizada

- A variância generalizada (VG) é definida como o determinante da matriz de covariâncias, e procura resumir a variabilidade associada à dados multivariados (matriz de dados).
- Considere uma matriz de covariâncias 2×2 , ou seja:

$$\Sigma = \begin{bmatrix} \sigma_1^2 & \sigma_1\sigma_2\rho \\ \sigma_1\sigma_2\rho & \sigma_2^2 \end{bmatrix}$$

- Assim $VG = \sigma_1^2\sigma_2^2 - \sigma_1^2\sigma_2^2\rho^2 = \sigma_1^2\sigma_2^2(1 - \rho^2)$. Em geral, quanto maior/menor forem as variâncias de cada componente e/ou menores/maiores forem as correlações, maior/menor será a variância generalizada.


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.
- $M_{\mathbf{Y}}(\mathbf{t}) = \exp \left\{ \boldsymbol{\mu}'\mathbf{t} + \frac{1}{2}\mathbf{t}'\boldsymbol{\Sigma}\mathbf{t} \right\}$.
- Se $p = 1$ então $f_Y(y) = (\sigma^2\pi)^{-1/2} \exp \left\{ -\frac{(y-\mu)^2}{2\sigma^2} \right\} \mathbb{1}_{\mathcal{R}}(y)$.
- Nos dois gráficos seguintes: $\mu_1 = \mu_2 = 0$, $\sigma_1^2 = \sigma_2^2 = 1$ ou (=9, no segundo gráfico), correlação = σ_{11} . VG, respectivamente (1;81;0,3429;0,3429).


correlação = 0




correlação = 0


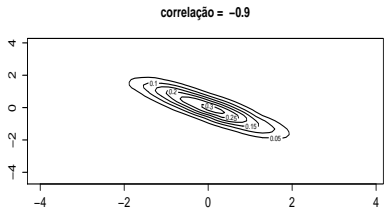




correlação = -0.9



correlação = 0.9





Propriedades

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

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

$$\frac{\partial \mathbf{y}}{\partial \mathbf{x}} = \frac{\partial \mathbf{A}\mathbf{x}}{\partial \mathbf{x}} = \begin{bmatrix} \frac{\partial \sum_{k=1}^n a_{1k}x_k}{\partial x_1} & \frac{\partial \sum_{k=1}^n a_{1k}x_k}{\partial x_2} & \cdots & \frac{\partial \sum_{k=1}^n a_{1k}x_k}{\partial x_n} \\ \frac{\partial \sum_{k=1}^n a_{2k}x_k}{\partial x_1} & \frac{\partial \sum_{k=1}^n a_{2k}x_k}{\partial x_2} & \cdots & \frac{\partial \sum_{k=1}^n a_{2k}x_k}{\partial x_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial \sum_{k=1}^n a_{mk}x_k}{\partial x_1} & \frac{\partial \sum_{k=1}^n a_{mk}x_k}{\partial x_2} & \cdots & \frac{\partial \sum_{k=1}^n a_{mk}x_k}{\partial x_n} \end{bmatrix}$$

$$\mathbf{A} = \begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{m1} & a_{m2} & \cdots & a_{mn} \end{bmatrix}$$

Derivadas matriciais úteis

- Alguns resultados:

$$\frac{\partial \mathbf{Ax}}{\partial \mathbf{x}} = \mathbf{A}, (\mathbf{A}'), \text{ se } \mathbf{A} \text{ for um vetor linha}$$

$$\frac{\partial \mathbf{x}'\mathbf{A}}{\partial \mathbf{x}} = \mathbf{A}', (\mathbf{A}), \text{ se } \mathbf{A} \text{ for um vetor linha}$$

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

$$\frac{\partial \mathbf{x}'\mathbf{Ax}}{\partial \mathbf{x}} = (\mathbf{A} + \mathbf{A}')\mathbf{x}, 2\mathbf{Ax}, \text{ se } \mathbf{A} \text{ for simétrica}$$

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 $\Sigma = \Psi\Psi'$ (decomposição de Cholesky), temos que:

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

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

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

- Matriz Jacobiana

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

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

- Além disso,

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

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

- Assim,

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

Obtenção da fgm

- Por simplicidade, suponha que $\boldsymbol{\mu} = \mathbf{0}$. Assim, temos que:

$$M_{\mathbf{Y}}(\mathbf{t}) = \int_{\mathcal{R}^p} |\boldsymbol{\Sigma}|^{-1/2} (2\pi)^{-p/2} \exp \left\{ -\frac{1}{2} (\mathbf{y}' \boldsymbol{\Sigma}^{-1} \mathbf{y} - 2\mathbf{t}' \mathbf{y}) \right\} d\mathbf{y}$$

- Contudo, note que $\mathbf{y}' \boldsymbol{\Sigma}^{-1} \mathbf{y} - 2\mathbf{t}' \mathbf{y} = (\mathbf{y} - \boldsymbol{\Sigma} \mathbf{t})' \boldsymbol{\Sigma}^{-1} (\mathbf{y} - \boldsymbol{\Sigma} \mathbf{t}) - \mathbf{t}' \boldsymbol{\Sigma} \mathbf{t}$.
Portanto,

$$\begin{aligned} M_{\mathbf{Y}}(\mathbf{t}) &= e^{\frac{1}{2} \mathbf{t}' \boldsymbol{\Sigma} \mathbf{t}} \underbrace{\int_{\mathcal{R}^p} |\boldsymbol{\Sigma}|^{-1/2} (2\pi)^{-p/2} \exp \left\{ -\frac{1}{2} (\mathbf{y} - \boldsymbol{\Sigma} \mathbf{t})' \boldsymbol{\Sigma}^{-1} (\mathbf{y} - \boldsymbol{\Sigma} \mathbf{t}) \right\} d\mathbf{y}}_1 \\ &= e^{\frac{1}{2} \mathbf{t}' \boldsymbol{\Sigma} \mathbf{t}} \end{aligned}$$

Obtenção da fgm

- Logo, se $\mathbf{X} \sim N(\mathbf{0}, \Sigma)$ e $Y = \mu + \mathbf{X}$, então

$$M_{\mathbf{Y}}(\mathbf{t}) = \mathcal{E}(e^{\mathbf{t}'\mu + \mathbf{t}'\mathbf{X}}) = e^{\mathbf{t}'\mu} M_{\mathbf{X}}(\mathbf{t}) = e^{\mathbf{t}'\mu + \frac{1}{2}\mathbf{t}'\Sigma\mathbf{t}}$$

Obtenção do vetor de médias

- Temos que $\mathcal{E}(\mathbf{Y}) = \left. \frac{\partial M_{\mathbf{Y}}(\mathbf{t})}{\partial \mathbf{t}} \right|_{\mathbf{t}=\mathbf{0}}$. Por outro lado, temos que:

$$\frac{\partial M_{\mathbf{Y}}(\mathbf{t})}{\partial \mathbf{t}} = \frac{\partial e^{\boldsymbol{\mu}'\mathbf{t} + \frac{1}{2}\mathbf{t}'\boldsymbol{\Sigma}\mathbf{t}}}{\partial \mathbf{t}} = M_{\mathbf{Y}}(\mathbf{t}) [\boldsymbol{\mu} + \boldsymbol{\Sigma}\mathbf{t}]$$

- Assim

$$\mathcal{E}(\mathbf{Y}) = \left. \frac{\partial M_{\mathbf{Y}}(\mathbf{t})}{\partial \mathbf{t}} \right|_{\mathbf{t}=\mathbf{0}} = M_{\mathbf{Y}}(\mathbf{0}) [\boldsymbol{\mu} + \boldsymbol{\Sigma}\mathbf{0}] = \boldsymbol{\mu}$$

Obtenção do matriz de covariâncias

- Temos que $\mathcal{E}(\mathbf{Y}\mathbf{Y}') = \left. \frac{\partial^2 M_{\mathbf{Y}}(\mathbf{t})}{\partial \mathbf{t} \partial \mathbf{t}'} \right|_{\mathbf{t}=\mathbf{0}}$. Por outro lado, temos que:

$$\begin{aligned} \frac{\partial^2 M_{\mathbf{Y}}(\mathbf{t})}{\partial \mathbf{t} \partial \mathbf{t}'} &= \frac{\partial}{\partial \mathbf{t}} \left[\frac{\partial M_{\mathbf{Y}}(\mathbf{t})}{\partial \mathbf{t}'} \right] = \frac{\partial}{\partial \mathbf{t}} \left[\frac{\partial M_{\mathbf{Y}}(\mathbf{t})}{\partial \mathbf{t}} \right]' = \frac{\partial}{\partial \mathbf{t}} [M_{\mathbf{Y}}(\mathbf{t}) (\boldsymbol{\mu}' + \mathbf{t}' \boldsymbol{\Sigma})] \\ &= \left(\frac{\partial M_{\mathbf{Y}}(\mathbf{t})}{\partial \mathbf{t}} \right) [\boldsymbol{\mu}' + \mathbf{t}' \boldsymbol{\Sigma}] + M_{\mathbf{Y}}(\mathbf{t}) \boldsymbol{\Sigma} \\ &= M_{\mathbf{Y}}(\mathbf{t}) [\boldsymbol{\mu} + \boldsymbol{\Sigma} \mathbf{t}] [\boldsymbol{\mu}' + \mathbf{t}' \boldsymbol{\Sigma}] + M_{\mathbf{Y}}(\mathbf{t}) \boldsymbol{\Sigma} \end{aligned}$$

Obtenção do matriz de covariâncias

- Assim

$$\begin{aligned}\mathcal{E}(\mathbf{Y}\mathbf{Y}') &= \left. \frac{\partial^2 M_{\mathbf{Y}}(\mathbf{t})}{\partial \mathbf{t} \partial \mathbf{t}'} \right|_{\mathbf{t}=\mathbf{0}} = M_{\mathbf{Y}}(\mathbf{0}) [\boldsymbol{\mu} + \boldsymbol{\Sigma} \mathbf{0}] [\boldsymbol{\mu}' + \mathbf{0}' \boldsymbol{\Sigma}] + M_{\mathbf{Y}}(\mathbf{0}) \boldsymbol{\Sigma} \\ &= \boldsymbol{\mu} \boldsymbol{\mu}' + \boldsymbol{\Sigma}\end{aligned}$$

- Portanto, $Cov(\mathbf{Y}) = \mathcal{E}(\mathbf{Y}\mathbf{Y}') - \boldsymbol{\mu} \boldsymbol{\mu}' = \boldsymbol{\Sigma}$.

Obtenção das Marginais

- Note que, para um dado j , $M_{Y_j}(t_j) = M_{\mathbf{Y}}(\mathbf{t}^*)$, em que

$$\mathbf{t}^* = [0 \ 0 \dots \underbrace{1}_{\text{posição } j} \dots 0 \ 0].$$

- Logo, temos que $M_{Y_j}(t_j) = \exp \left\{ \mu_j t_j + \frac{\sigma_j^2 t_j^2}{2} \right\}$.
- A fgm acima corresponde à fgm de uma va com distribuição $N(\mu_j, \sigma_j^2)$.

Observação sobre matrizes particionadas (em blocos)

- Seja $\mathbf{X} = \begin{bmatrix} \mathbf{X}_1 \\ \mathbf{X}_2 \end{bmatrix}$ e $\mathbf{A} = \begin{bmatrix} \mathbf{A}_1 & \mathbf{A}_2 \\ \mathbf{A}_3 & \mathbf{A}_4 \end{bmatrix}$
- Assim

$$\mathbf{X}'\mathbf{A} = \begin{bmatrix} \mathbf{X}'_1\mathbf{A}_1 + \mathbf{X}'_2\mathbf{A}_3 & \mathbf{X}'_1\mathbf{A}_2 + \mathbf{X}'_2\mathbf{A}_4 \end{bmatrix}$$

e

$$\mathbf{X}'\mathbf{A}\mathbf{X} = \begin{bmatrix} \mathbf{X}'_1\mathbf{A}_1\mathbf{X}_1 + \mathbf{X}'_2\mathbf{A}_3\mathbf{X}_1 + \mathbf{X}'_1\mathbf{A}_2\mathbf{X}_2 + \mathbf{X}'_2\mathbf{A}_4\mathbf{X}_2 \end{bmatrix}$$

Distribuições condicionais

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

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

- Para provar, basta usar a definição de distribuição condicional $\left(f_{\mathbf{Y}_1 | \mathbf{Y}_2}(\mathbf{y}_1 | \mathbf{y}_2) = \frac{f_{\mathbf{Y}}(\mathbf{y})}{f_{\mathbf{Y}_2}(\mathbf{y}_2)} \right)$ e resultados relativos à matrizes particionadas.

Distribuições condicionais

- Temos que

$$\begin{aligned}\Sigma^{-1} &= \begin{bmatrix} \Sigma_{11} & \Sigma_{12} \\ \Sigma_{21} & \Sigma_{22} \end{bmatrix}^{-1} \\ &= \begin{bmatrix} \mathbf{I} & \mathbf{0} \\ -\Sigma_{22}^{-1}\Sigma_{21} & \mathbf{I} \end{bmatrix} \begin{bmatrix} (\Sigma_{11} - \Sigma_{12}\Sigma_{22}^{-1}\Sigma_{21})^{-1} & \mathbf{0} \\ \mathbf{0}' & \Sigma_{22}^{-1} \end{bmatrix} \\ &\times \begin{bmatrix} \mathbf{I} & -\Sigma_{22}^{-1}\Sigma_{21} \\ \mathbf{0}' & \mathbf{I} \end{bmatrix}\end{aligned}$$

pois Σ é simétrica.

Distribuições condicionais

- Pode-se provar, portanto, que

$$\begin{aligned}(\mathbf{y} - \boldsymbol{\mu})\boldsymbol{\Sigma}^{-1}(\mathbf{y} - \boldsymbol{\mu}) &= [\mathbf{y}_1 - \boldsymbol{\mu}_1 - \boldsymbol{\Sigma}_{12}\boldsymbol{\Sigma}_{22}^{-1}(\mathbf{y}_2 - \boldsymbol{\mu}_2)]' \\ &\times (\boldsymbol{\Sigma}_{11} - \boldsymbol{\Sigma}_{12}\boldsymbol{\Sigma}_{22}^{-1}\boldsymbol{\Sigma}_{21}) \\ &\times [\mathbf{y}_1 - \boldsymbol{\mu}_1 - \boldsymbol{\Sigma}_{12}\boldsymbol{\Sigma}_{22}^{-1}(\mathbf{y}_2 - \boldsymbol{\mu}_2)] \\ &+ (\mathbf{y}_2 - \boldsymbol{\mu}_2)' \boldsymbol{\Sigma}_{22}^{-1}(\mathbf{y}_2 - \boldsymbol{\mu}_2) \quad (1)\end{aligned}$$

Distribuições condicionais

- Pois

$$\begin{aligned}(\mathbf{y} - \boldsymbol{\mu})\boldsymbol{\Sigma}^{-1}(\mathbf{y} - \boldsymbol{\mu}) &= \begin{bmatrix} \mathbf{y}_1 - \boldsymbol{\mu}_1 \\ \mathbf{y}_2 - \boldsymbol{\mu}_2 \end{bmatrix}' \begin{bmatrix} \mathbf{I} & \mathbf{0} \\ -\boldsymbol{\Sigma}_{22}^{-1}\boldsymbol{\Sigma}_{21} & \mathbf{I} \end{bmatrix} \\ &\times \begin{bmatrix} (\boldsymbol{\Sigma}_{11} - \boldsymbol{\Sigma}_{12}\boldsymbol{\Sigma}_{22}^{-1}\boldsymbol{\Sigma}_{21})^{-1} & \mathbf{0} \\ \mathbf{0}' & \boldsymbol{\Sigma}_{22}^{-1} \end{bmatrix} \\ &\times \begin{bmatrix} \mathbf{I} & -\boldsymbol{\Sigma}_{22}^{-1}\boldsymbol{\Sigma}_{21} \\ \mathbf{0}' & \mathbf{I} \end{bmatrix} \begin{bmatrix} \mathbf{y}_1 - \boldsymbol{\mu}_1 & \mathbf{y}_2 - \boldsymbol{\mu}_2 \end{bmatrix}\end{aligned}$$

Distribuições condicionais

- Assim, basta usar (1) na definição $\left(f_{\mathbf{Y}_1|\mathbf{Y}_2}(\mathbf{y}_1|\mathbf{y}_2) = \frac{f_{\mathbf{Y}}(\mathbf{y})}{f_{\mathbf{Y}_2}(\mathbf{y}_2)} \right)$, e o resultado da distribuição condicional segue (com um pouco de álgebra...).

Distribuição de formas quadráticas normais

- Seja $\mathbf{Z} \sim N_p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$. Dizemos, então, que $Y = \mathbf{Z}'\mathbf{A}\mathbf{Z}$ é uma forma quadrática normal. Em geral, \mathbf{A} é uma matriz não aleatória simétrica e real.
- Pode-se provar, por exemplo, que:

$$Y = (\mathbf{Z} - \boldsymbol{\mu})'\boldsymbol{\Sigma}^{-1}(\mathbf{Z} - \boldsymbol{\mu}) \sim \chi_{(p)}^2 \quad (2)$$

- Vamos demonstrar a validade do resultado dado pela equação (2).
- Por simplicidade, admita que $\boldsymbol{\mu} = \mathbf{0}$.

- Assim, temos que :

$$\begin{aligned}
 M_Y(t) &= \mathcal{E}(e^{Yt}) = \int_{\mathcal{R}^p} e^{t'y} f_Z(\mathbf{z}) dz \\
 &= \int_{\mathcal{R}} \int_{\mathcal{R}} \dots \int_{\mathcal{R}} e^{tz' \Sigma^{-1} \mathbf{z}} |\Sigma|^{-1/2} (2\pi)^{-p/2} \exp \left\{ -\frac{1}{2} \mathbf{z}' \Sigma^{-1} \mathbf{z} \right\} dz \\
 &= \int_{\mathcal{R}} \int_{\mathcal{R}} \dots \int_{\mathcal{R}} |\Sigma|^{-1/2} (2\pi)^{-p/2} \exp \left\{ -\frac{1}{2} \mathbf{z}' \Sigma^{-1} \mathbf{z} (1 - 2t) \right\} dz
 \end{aligned}$$

- Considerando a mesma transformação anteriormente utilizada ($\mathbf{w} = \Psi^{-1} \mathbf{z}$), em que $\Sigma = \Psi \Psi'$, temos que:

$$\begin{aligned}
 M_Y(t) &= \prod_{i=1}^p \int_{\mathcal{R}} \underbrace{\frac{1}{\sqrt{2\pi}} \exp \left\{ -\frac{1}{2} w_i^2 (1 - 2t) \right\}}_{N(0, (1-2t)^{-1})} dw_i \\
 &= (1 - 2t)^{-p/2}
 \end{aligned}$$

- A qual corresponde à fgm de uma distribuição χ_p^2 .

Distribuição t de Student não-central

- Defina $T = \frac{Z+\mu}{\sqrt{V/\nu}}$, em que $Z \perp V$, $Z \sim N(0, 1)$ e $V \sim \chi_\nu^2$. Dizemos que T tem distribuição t de student não central, com ν graus de liberdade e parâmetro de não centralidade μ .
- Uma forma de se apresentar a densidade é:

$$f_T(t) = \frac{\nu^\nu/2 e^{-\frac{\nu\mu^2}{2(t^2+\nu)}}}{\sqrt{\pi}\Gamma(\nu/2)2^{\frac{\nu-1}{2}}(t^2 + \nu)^{(\nu+1)/2}} \times \int_0^\infty y^\nu \exp\left\{-\frac{1}{2}\left(y - \frac{\mu t}{\sqrt{t^2 + \nu}}\right)^2\right\} dy$$

Distribuição qui-quadrado não central

- Sejam $X_1, X_2, \dots, X_n \stackrel{ind}{\sim} N(\mu_i, \sigma_i^2)$.
- Defina $Y = \sum_{i=1}^n \left(\frac{X_i}{\sigma_i}\right)^2$. Dizemos então que Y tem distribuição qui-quadrado não central com n graus de liberdade e parâmetro de não-centralidade $\delta = \sum_{i=1}^n \left(\frac{\mu_i}{\sigma_i}\right)^2$
- Notação $Y \sim \chi_{(n,\delta)}^2$, cuja fdp é dada por

$$f_Y(y) = \sum_{i=0}^{\infty} \frac{e^{-\delta/2} (\delta/2)^i}{i!} f_{W_{n+2i}}(y) \mathbb{1}_{(0,\infty)}(y),$$

em que $W_{n+2i} \sim \chi_{(n+2i)}^2$

- Se $\delta = 0$, então $Y \sim \chi_{(n)}^2$.

Distribuição F não central

- Seja V uma outra v.a., independente de Y , $V \sim \chi^2_{(m)}$.
- Defina $F = \frac{Y/n}{V/m}$. Então, F tem distribuição F não central com graus de liberdade, n e m e parâmetro de não centralidade δ .
- Notação $F \sim \chi^2_{(n,m,\delta)}$, cuja fdp é dada por

$$f_F(f) = \sum_{i=0}^{\infty} \frac{e^{-\delta/2}(\delta/2)^i}{\beta(m/2, n/2 + i)i!} \left(\frac{n}{m}\right)^{n/2+i} \left(\frac{m}{m+nf}\right)^{(n+m)/2+i} \\ \times f^{n/2-1+i} \mathbb{1}_{(0,\infty)}(f)$$

em que $\beta(a, b) = \int_0^1 x^{a-1}(1-x)^{b-1} dx$

Principais teoremas de formas quadráticas normais

- Seja $\mathbf{Y} \sim N_p(\mathbf{0}, \mathbf{I})$ e \mathbf{A} uma matriz simétrica. Então

$$\mathbf{Y}'\mathbf{A}\mathbf{Y} \sim \chi^2_{[r(\mathbf{A})]}$$

se, e somente se \mathbf{A} for idempotente.

- Seja $\mathbf{Y} \sim N_p(\mathbf{0}, \mathbf{\Sigma})$ e \mathbf{A} uma matriz simétrica. Então

$$\mathbf{Y}'\mathbf{A}\mathbf{Y} \sim \chi^2_{[r(\mathbf{A})]}$$

se, e somente se $\mathbf{A}\mathbf{\Sigma}$ for idempotente.

Cont.

- Seja $\mathbf{Y} \sim N_p(\boldsymbol{\mu}, \mathbf{I})$ e \mathbf{A} uma matriz simétrica. Então

$$\mathbf{Y}'\mathbf{A}\mathbf{Y} \sim \chi^2_{[r(\mathbf{A}), \delta = \boldsymbol{\mu}'\mathbf{A}\boldsymbol{\mu}]}$$

se, e somente se \mathbf{A} for idempotente.

- Seja $\mathbf{Y} \sim N_p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ e \mathbf{A} uma matriz simétrica. Então

$$\mathbf{Y}'\mathbf{A}\mathbf{Y} \sim \chi^2_{[r(\mathbf{A}), \delta = \boldsymbol{\mu}'\mathbf{A}\boldsymbol{\mu}]}$$

se, e somente se $\mathbf{A}\boldsymbol{\Sigma}$ for idempotente.

- Naturalmente, se $\delta = \boldsymbol{\mu}'\mathbf{A}\boldsymbol{\mu} = 0$, as distribuições passam a ser qui-quadrados centrais.

Cont.

- Seja $\mathbf{Y} \sim N_p(\mathbf{0}, \mathbf{\Sigma})$, \mathbf{A} uma matriz simétrica e \mathbf{B} uma matriz qualquer. Então $\mathbf{Y}'\mathbf{A}\mathbf{Y}$ e $\mathbf{B}\mathbf{Y}$ são independentes se, e somente se $\mathbf{B}\mathbf{\Sigma}\mathbf{A} = \mathbf{0}$.
- Seja $\mathbf{Y} \sim N_p(\mathbf{0}, \mathbf{\Sigma})$, \mathbf{A} e \mathbf{B} matrizes simétricas. Então $\mathbf{Y}'\mathbf{A}\mathbf{Y}$ e $\mathbf{Y}'\mathbf{B}\mathbf{Y}$ são independentes se, e somente se $\mathbf{B}\mathbf{\Sigma}\mathbf{A} = \mathbf{A}\mathbf{\Sigma}\mathbf{B} = \mathbf{0}$.
- Demonstrações: pesquisar nas referências.