

1.1 - Simulação de v.a.'s pelo método da transformação Inversa

1.1.1 - Geração de v.a.'s nos uniformes

Objectivo: usou nos pseudo-aleatórios ($n \sim U(0,1)$) para gerar observações de outras distribuições de uma forma rápida

1. Método da transformação Inversa (ou quantil) - 1ª vez para v.a.'s contínuas


teo. da transformação Inversa:

Seja X uma v.a. contínua com f. distribuições $F_X(x)$, então $F(X) \sim U(0,1)$

Dem: Seja $Y = F_X(X)$ com f. distribuições $F_Y(y)$

$$F_Y(y) = P(Y \leq y) = P(F_X(X) \leq y) = P(X \leq F_X^{-1}(y)) = F_X(F_X^{-1}(y)) = y$$

$x \in (0,1) \quad \therefore Y = F_X(X) \sim U(0,1)$ porque $F_Y(y) = \begin{cases} 0, & y < 0 \\ y, & 0 \leq y < 1 \\ 1, & y \geq 1 \end{cases}$



Exemplo: $Y = F_X(X) = 1 - e^{-\lambda X}$, $X \in \mathbb{R}^+$ ($X \sim \text{Exp}(\lambda)$); $R_Y = [0,1]$

$$F_Y(y) = P(Y \leq y) = P(1 - e^{-\lambda X} \leq y) = P(e^{-\lambda X} \geq 1 - y) = P(-\lambda X \geq \ln(1 - y)) = P(X \leq -\frac{\ln(1 - y)}{\lambda}) = 1 - e^{-\frac{\lambda}{\lambda} \ln(1 - y)} = 1 - (1 - y) = y$$

$$\therefore Y \sim U(0,1) \quad F_X\left(-\frac{\ln(1 - y)}{\lambda}\right)$$

Como usar este resultado para simular v.a.'s contínuas nos uniformes?

Seja $U \sim U(0,1)$, então $F(X) = U$ significa que a v.a. $F^{-1}(U)$ tem a mesma distribuição que a v.a. X

Método:

- 1) obter um valor u a partir de $U(0,1)$
- 2) Devolver $x = F^{-1}(u)$

Geracao de v.a's univariadas contínuas

• Exponencial (λ)

$$X \sim \text{Exp}(\lambda) ; f_x(x) = \begin{cases} \lambda e^{-\lambda x}, & x > 0, \lambda > 0 \\ 0, & \text{c.c.} \end{cases} ; F_x(x) = \begin{cases} 1 - e^{-\lambda x}, & x > 0 \\ 0, & \text{c.c.} \end{cases}$$

Assim tendo um n^e u da dist. $U(0,1)$, fazemos:

$$1 - e^{-\lambda x} = u \Leftrightarrow x = -\frac{1}{\lambda} \ln(1-u)$$

Isto ainda pode ser simplificado porque:

se $U \sim U(0,1)$ então $(1-U) \sim U(0,1)$

Dem: $Y = (1-U)$

$$\begin{aligned} F_Y(y) &= P(Y \leq y) = P(1-U \leq y) = P(-U \leq y-1) = P(U \geq 1-y) = \\ &= 1 - F_U(1-y) = 1 - (1-y) = y \quad \therefore (1-U) \sim U(0,1) \end{aligned}$$

Assim, $x = \frac{-\ln u}{\lambda}$ é um valor da dist. $\text{Exp}(\lambda)$

• Weibull (α, λ)

$$\begin{aligned} X \sim W(\alpha, \lambda) ; F_x(x) &= 1 - e^{-(\lambda x)^\alpha}, \quad x > 0, \lambda, \alpha > 0 \\ 1 - e^{-(\lambda x)^\alpha} &= u \Leftrightarrow e^{-(\lambda x)^\alpha} = 1 - u \Leftrightarrow -(\lambda x)^\alpha = \ln(1-u) \Leftrightarrow \\ \Leftrightarrow \lambda x &= (-\ln(1-u))^{1/\alpha} \Leftrightarrow x = \frac{(-\ln(1-u))^{1/\alpha}}{\lambda} \end{aligned}$$

que pode ser simplificado em $x = \frac{(-\ln u)^{1/\alpha}}{\lambda}$

• Gama (n, λ) = Erlang (n, λ)

$X \sim G(n, \lambda)$; $F_X(x) = \int_0^x \frac{\lambda^n y^{n-1} e^{-\lambda y}}{(n-1)!} dy$ a qual não tem uma forma explícita

Mas $X \sim G(n, \lambda) \Leftrightarrow X = \sum_{i=1}^n Y_i \sim \text{Exp}(\lambda)$ indep

temos que ter u_1, \dots, u_n

Assim $x = -\sum_{i=1}^n \frac{1}{\lambda} \ln(u_i) = -\frac{1}{\lambda} \ln\left(\prod_{i=1}^n u_i\right)$

• Qui-quadradado (2n)

$X \sim \chi^2_{(2n)} \Leftrightarrow (2\lambda Y) \sim \chi^2_{(2n)}$ se $Y \sim G(n, \lambda)$

Assim $x = -2 \ln \prod_{i=1}^n u_i$

$\chi^2_{(3)} = \chi^2_{(2)} + \chi^2_{(1)}$
 indep $\left(\frac{N(0,1)}{\sqrt{2}}\right)^2$

• Dist. Normal

Não tem uma forma explícita para a f. distribuição e a técnica da soma também não funciona (uma Normal só surge como a soma de Normais Indep.)

Métodos especiais para simulação da Normal

1) Simulação direta (usando o T.E.C.)

$u_i \sim U(0,1)$, $E(u_i) = \frac{1}{2}$ e $\text{var}(u_i) = \frac{1}{12}$
 i.i.d.

$Y = \sum_{i=1}^n u_i$ com $E(Y) = \frac{n}{2}$ e $\text{var}(Y) = \frac{n}{12}$, pelo t.e.c.

$z = \frac{Y - E(Y)}{\sqrt{\text{var}(Y)}} = \frac{Y - \frac{n}{2}}{\sqrt{\frac{n}{12}}} \sim N(0,1)$
 para $n \geq 12$ já é válida a conv. se não para a $N(0,1)$

Escolhendo $n = 12$, vem $z = Y - 6 = \left(\sum_{i=1}^{12} u_i - 6\right) \sim N(0,1)$

Assim : 1) Geram-se 12 pseud-aleatórios indep. u_1, \dots, u_{12}

2) Efectuando a atribuição $z = \sum_{i=1}^{12} u_i - 6$

obtem-se uma observação de $z \sim N(0,1)$

De notar que $z \in (-6, 6)$ mas $P(|z| > 6) \approx 10^{-10}$

2) Método de Box-Müller (ver, por ex., Ross de P. 5. secc 15.6.1)

Baseia-se no resultado
se $U_i \sim U(0,1)$, $i=1,2$ então
i.i.d.

$$Z_1 = \sqrt{-2 \ln(U_1)} \cos(2\pi U_2) \sim N(0,1), \quad Z_1 \perp Z_2$$

$$Z_2 = \sqrt{-2 \ln(U_1)} \sin(2\pi U_2) \sim N(0,1)$$

utiliza-se uma das duas expressões para gerar 1 valor da $N(0,1)$

Geracão de v.a's multivariadas contínuas (só a normal multivariada)

- Distribuição Normal K-variada

$$\underset{\sim}{X} = \begin{bmatrix} X_1 \\ \vdots \\ X_K \end{bmatrix} \quad X \text{ (bold)}$$

$\underset{\sim}{X} = (X_1, \dots, X_K) \rightarrow$ vetor Aleatório em \mathbb{R}^K

$$E(\underset{\sim}{X}) = E \begin{bmatrix} X_1 \\ \vdots \\ X_K \end{bmatrix} = \begin{bmatrix} E(X_1) \\ \vdots \\ E(X_K) \end{bmatrix} = \begin{bmatrix} \mu_1 \\ \vdots \\ \mu_K \end{bmatrix} = \underset{\sim}{\mu} \quad (E(X_i) = \mu_i)$$

(vetor média)

$\text{VAR}(\underset{\sim}{X}) = \underset{\sim}{\Sigma}$ matriz de variâncias-covariâncias de $\underset{\sim}{X}$
de covariâncias

$$\underset{\sim}{\Sigma} = \begin{matrix} & \begin{matrix} X_1 & X_2 & \dots & X_K \end{matrix} \\ \begin{matrix} X_1 \\ \vdots \\ X_K \end{matrix} & \begin{bmatrix} \sigma_1^2 & \sigma_{12} & \dots & \sigma_{1K} \\ \sigma_{12} & \sigma_2^2 & \dots & \sigma_{2K} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{K1} & \dots & \dots & \sigma_K^2 \end{bmatrix} \end{matrix}$$

$$\text{cov}(X_1, X_1) = \text{var}(X_1) = \sigma_1^2 = \sigma_{11}$$

$$\text{cov}(X_1, X_2) = \sigma_{12} = \text{cov}(X_2, X_1)$$

$\underset{\sim}{\Sigma}$ é uma matriz simétrica e definida positiva (d.p.)

vamos partir da f.d.p. de Normal univariada e vamos ver como a generalizar para o caso K-variada

$X \sim N(\mu, \sigma^2)$; $f_X(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{1}{2\sigma^2}(x-\mu)^2}$, $x \in \mathbb{R}, \mu \in \mathbb{R}, \sigma \in \mathbb{R}^+$

No expoente o termo $(\frac{x-\mu}{\sigma})^2$

① $(x-\mu)(\sigma^2)^{-1}(x-\mu)$
 generalizando para \mathbb{R}^k ↓ $(\underline{x}-\underline{\mu})^T \underline{\Sigma}^{-1} (\underline{x}-\underline{\mu}) = \Delta^2$

$\Delta \rightarrow$ distância de Mahalanobis

$\mathbb{R} \rightarrow \mathbb{R}^k$
 $(2\pi)^{-1/2} \rightarrow (2\pi)^{-k/2}$ $|\underline{\Sigma}| \rightarrow$ variância generalizada
 $(\sigma^2)^{-1/2} \rightarrow |\underline{\Sigma}|^{-1/2}$ $tr(\underline{\Sigma}) \rightarrow$ variância total

Assim se $X \sim N_k(\underline{\mu}, \underline{\Sigma})$ a sua f.d.p. é:

$$f_X(\underline{x}) = \frac{1}{(2\pi)^{k/2} |\underline{\Sigma}|^{1/2}} e^{-\frac{1}{2} \Delta^2} = \frac{1}{(2\pi)^{k/2} |\underline{\Sigma}|^{1/2}} e^{-\frac{1}{2} (\underline{x}-\underline{\mu})^T \underline{\Sigma}^{-1} (\underline{x}-\underline{\mu})}$$

$\underline{x} \in \mathbb{R}^k, \underline{\mu} \in \mathbb{R}^k$
 $\underline{\Sigma} \in \mathbb{R}^k \times \mathbb{R}^k$ simétrica e definida positiva

• Caso Particular - Normal bivariada

$\underline{X} \sim N_2(\underline{\mu}, \underline{\Sigma})$

$X_1 \sim N(\mu_1, \sigma_1^2)$

$X_2 \sim N(\mu_2, \sigma_2^2)$

1) $X_1 \perp X_2$ $f_{X_1, X_2}(x_1, x_2) = f_{X_1}(x_1) f_{X_2}(x_2)$

$$f_{X_1, X_2}(x_1, x_2) = \frac{1}{\sqrt{2\pi}\sigma_1} e^{-\frac{1}{2\sigma_1^2}(x_1-\mu_1)^2} \times \frac{1}{\sqrt{2\pi}\sigma_2} e^{-\frac{1}{2\sigma_2^2}(x_2-\mu_2)^2}$$

$$= \frac{1}{(2\pi)^{1/2} (\sigma_1^2 \sigma_2^2)^{1/2}} e^{-\frac{(x_1-\mu_1)^2}{2\sigma_1^2} - \frac{(x_2-\mu_2)^2}{2\sigma_2^2}}$$

$\underline{\Sigma} = \begin{bmatrix} \sigma_1^2 & 0 \\ 0 & \sigma_2^2 \end{bmatrix}$ e $(\underline{x}-\underline{\mu})^T \underline{\Sigma}^{-1} (\underline{x}-\underline{\mu}) = \frac{(x_1-\mu_1)^2}{\sigma_1^2} + \frac{(x_2-\mu_2)^2}{\sigma_2^2}$

$\underline{\Sigma}^{-1/2} = \begin{bmatrix} 1/\sigma_1 & 0 \\ 0 & 1/\sigma_2 \end{bmatrix}$ $|\underline{\Sigma}| = \sigma_1^2 \sigma_2^2$

2) $X_1 \perp\!\!\!\perp X_2$

$$\Sigma = \begin{bmatrix} \sigma_1^2 & \sigma_{12} \\ \sigma_{12} & \sigma_2^2 \end{bmatrix} = \begin{bmatrix} \sigma_1^2 & \rho\sigma_1\sigma_2 \\ \rho\sigma_1\sigma_2 & \sigma_2^2 \end{bmatrix}$$

$$|\Sigma| = \sigma_1^2\sigma_2^2 - \rho^2\sigma_1^2\sigma_2^2 = \sigma_1^2\sigma_2^2(1-\rho^2)$$

$$\rho = \frac{\text{cov}(X_1, X_2)}{\sigma_1\sigma_2} = \frac{\sigma_{12}}{\sigma_1\sigma_2}$$

$$\Sigma^{-1} = \frac{1}{|\Sigma|} \begin{bmatrix} \sigma_2^2 & -\rho\sigma_1\sigma_2 \\ -\rho\sigma_1\sigma_2 & \sigma_1^2 \end{bmatrix} =$$

$$\sigma_{12} = \rho\sigma_1\sigma_2$$

$$= \frac{1}{(1-\rho^2)} \begin{bmatrix} 1/\sigma_1^2 & -\rho/\sigma_1\sigma_2 \\ -\rho/\sigma_1\sigma_2 & 1/\sigma_2^2 \end{bmatrix}$$

$$\Delta^2 = (\underline{x} - \underline{\mu})^T \Sigma^{-1} (\underline{x} - \underline{\mu}) = \dots$$

$$= \frac{1}{(1-\rho^2)} \left\{ \left(\frac{x_1 - \mu_1}{\sigma_1} \right)^2 - 2\rho \frac{(x_1 - \mu_1)(x_2 - \mu_2)}{\sigma_1\sigma_2} + \left(\frac{x_2 - \mu_2}{\sigma_2} \right)^2 \right\}$$

$$\underline{X} \sim N_2(\underline{\mu}, \Sigma)$$

$$f_{\underline{X}}(\underline{x}) = \frac{1}{2\pi\sigma_1\sigma_2\sqrt{1-\rho^2}} e^{-\frac{1}{2} \frac{1}{(1-\rho^2)} \left[\left(\frac{x_1 - \mu_1}{\sigma_1} \right)^2 - 2\rho \frac{(x_1 - \mu_1)(x_2 - \mu_2)}{\sigma_1\sigma_2} + \left(\frac{x_2 - \mu_2}{\sigma_2} \right)^2 \right]}$$

$$, \underline{x} \in \mathbb{R}^2, \underline{\mu} \in \mathbb{R}^2, \sigma_1 > 0, \sigma_2 > 0 \text{ e } |\rho| < 1$$

Propriedades: $\underline{X} \sim N_2(\underline{\mu}, \Sigma)$

1. $X_i \sim N(\mu_i, \sigma_i^2)$ $i=1,2$ (também é válido para a Normal k-variada)

2. $X_1 \perp\!\!\!\perp X_2 \iff \text{cov}(X_1, X_2) = 0$ ($\rho=0$)
 no caso de dist. Normal é equivalente

Se $X \perp\!\!\!\perp Y$ então $\text{cov}(X, Y) = 0$
 • $\text{cov}(X, Y) = 0 \not\Rightarrow X \perp\!\!\!\perp Y$

$$\Sigma = \text{Diagonal!} = \begin{bmatrix} \sigma_1^2 & 0 \\ 0 & \sigma_2^2 \end{bmatrix}$$

Prop.

$$\exists. \underline{X} \sim N_K(\underline{\mu}, \underline{\Sigma}) \quad \underline{X} \in \mathbb{R}^K$$

$\underline{\Sigma}$ matriz simétrica

$\gamma_1, \dots, \gamma_K \rightarrow$ vector próprios de $\underline{\Sigma}$

$\lambda_1, \dots, \lambda_K \rightarrow$ valores próprios de $\underline{\Sigma}$

ortogonal

$$\underline{\Gamma} = \begin{bmatrix} \gamma_1 & \gamma_2 & \dots & \gamma_K \\ \gamma_{11} & & & \gamma_{K1} \\ \vdots & & & \vdots \\ \gamma_{1K} & & & \gamma_{KK} \end{bmatrix}_{K \times K}$$

$$\begin{aligned} \underline{\Sigma} &= \underline{\Gamma} \underline{\Lambda} \underline{\Gamma}^T = \\ &= \underbrace{\underline{\Gamma} \underline{\Lambda}^{1/2}}_{\underline{C}} \underbrace{\underline{\Lambda}^{1/2} \underline{\Gamma}^T}_{\underline{C}^T} = \underline{C} \underline{C}^T = \end{aligned}$$

$$\underline{\Lambda} = \begin{bmatrix} \lambda_1 & & & \\ & \ddots & & \\ & & \lambda_K & \end{bmatrix} = \text{diag}(\lambda_1, \dots, \lambda_K)$$

$$\underline{X} \sim N_K(\underline{\mu}, \underline{\Sigma}) \quad \underline{Z} \sim N_K(\underline{0}, \underline{I})$$

$$\underline{X} \sim N_K(\underline{\mu}, \underline{\Sigma}) \Leftrightarrow \underline{X} = \underline{\mu} + \underline{C} \underline{Z} = \underline{\mu} + \underline{\Gamma} \underline{\Lambda}^{1/2} \underline{Z}$$

se $\underline{X} \sim N_K(\underline{\mu}, \underline{\Sigma})$ então $\underline{Z} = \left(\underline{\Sigma}^{-1/2} (\underline{X} - \underline{\mu}) \right) \sim N_K(\underline{0}, \underline{I})$

$$\underline{\Sigma}^{-1/2} = \underline{\Gamma} \underline{\Lambda}^{-1/2} \underline{\Gamma}^T = \underline{C} \underline{\Gamma}^T$$

4. $X \sim N_2(\mu, \Sigma)$

Para $|\rho| < 1$, $(X_1 | X_2 = x_2) \sim N(\mu_1 + \rho \frac{\sigma_1}{\sigma_2} (x_2 - \mu_2); \sigma_1^2 (1 - \rho^2))$

Dem: $f_{X_1, X_2}(x_1, x_2) = f_{X_1 | X_2 = x_2} \cdot f_{X_2}(x_2)$ Sabemos isto

$$f_{X_1, X_2}(x_1, x_2) = \frac{1}{2\pi \sigma_1 \sigma_2 \sqrt{1 - \rho^2}} e^{-\frac{1}{2} \Delta^2}$$

$$\Delta^2 = \frac{1}{(1 - \rho^2)} \left\{ \left(\frac{x_1 - \mu_1}{\sigma_1} \right)^2 - 2\rho \left(\frac{x_1 - \mu_1}{\sigma_1} \right) \left(\frac{x_2 - \mu_2}{\sigma_2} \right) + \left(\frac{x_2 - \mu_2}{\sigma_2} \right)^2 \right\}$$

reescrever Δ^2 de forma a tirar o termo da f.d.p. marginal de X_2 i.e., $\left(\frac{x_2 - \mu_2}{\sigma_2} \right)^2$

Somar e subtrair $\rho^2 \left(\frac{x_2 - \mu_2}{\sigma_2} \right)^2$

$$\Delta^2 = \frac{1}{(1 - \rho^2)} \left\{ \left(\left(\frac{x_1 - \mu_1}{\sigma_1} \right) - \rho \left(\frac{x_2 - \mu_2}{\sigma_2} \right) \right)^2 + (1 - \rho^2) \left(\frac{x_2 - \mu_2}{\sigma_2} \right)^2 \right\}$$

$$= \frac{1}{(1 - \rho^2)} \left\{ \left[\left(\frac{x_1 - \mu_1}{\sigma_1} \right) - \rho \left(\frac{x_2 - \mu_2}{\sigma_2} \right) \right]^2 + \left(\frac{x_2 - \mu_2}{\sigma_2} \right)^2 \right\}$$

$$f_{X_1, X_2}(x_1, x_2) = \frac{1}{2\pi \sigma_1 \sigma_2 \sqrt{1 - \rho^2}} e^{-\frac{1}{2} \left(\frac{x_2 - \mu_2}{\sigma_2} \right)^2} e^{-\frac{1}{2(1 - \rho^2)} \left\{ \left(\frac{x_1 - \mu_1}{\sigma_1} \right) - \rho \left(\frac{x_2 - \mu_2}{\sigma_2} \right) \right\}^2}$$

$$= \frac{1}{\sqrt{2\pi} \sigma_2} e^{-\frac{1}{2} \left(\frac{x_2 - \mu_2}{\sigma_2} \right)^2} \frac{1}{\sqrt{2\pi} \sigma_1 \sqrt{1 - \rho^2}} e^{-\frac{1}{2(1 - \rho^2) \sigma_1^2} \left[x_1 - \left[\mu_1 + \rho \frac{\sigma_1}{\sigma_2} (x_2 - \mu_2) \right] \right]^2}$$

$\underbrace{\frac{1}{\sqrt{2\pi} \sigma_2} e^{-\frac{1}{2} \left(\frac{x_2 - \mu_2}{\sigma_2} \right)^2}}_{\text{f.d.p. marginal de } X_2}$
 $N(\mu_2, \sigma_2^2)$

$\underbrace{\frac{1}{\sqrt{2\pi} \sigma_1 \sqrt{1 - \rho^2}} e^{-\frac{1}{2(1 - \rho^2) \sigma_1^2} \left[x_1 - \left[\mu_1 + \rho \frac{\sigma_1}{\sigma_2} (x_2 - \mu_2) \right] \right]^2}}_{\text{f.d.p. } X_1 | X_2 = x_2}$
 desvio padrão $X_1 | X_2 = x_2$
 $E[X_1 | X_2 = x_2] = \mu_1 + \rho \frac{\sigma_1}{\sigma_2} (x_2 - \mu_2)$
 (valor médio)

$\therefore (X_1 | X_2 = x_2) \sim N(\mu_1 + \rho \frac{\sigma_1}{\sigma_2} (x_2 - \mu_2); \sigma_1^2 (1 - \rho^2))$

• Função geradora de Momentos da Normal k-variada

Se $z_i \sim N(0,1)$ então $\underline{z} = (z_1, \dots, z_n) \sim N_k(0, \underline{I})$
 iid.

$$f_{\underline{z}}(\underline{z}) = \frac{1}{(2\pi)^{k/2} |\underline{I}|} e^{-\frac{1}{2} \Delta^2} \quad ; \quad \Delta^2 = (\underline{z} - 0)^T \underline{I} (\underline{z} - 0) = \underline{z}^T \underline{z}$$

$|\underline{I}|$

$$f_{\underline{z}}(\underline{z}) = \frac{1}{(2\pi)^{k/2}} e^{-\frac{1}{2} \underline{z}^T \underline{z}}$$

$$M_{\underline{z}}(\underline{t}) = E(e^{\underline{t}^T \underline{z}}) = E\left(\prod_{i=1}^k e^{t_i z_i}\right) = \prod_{i=1}^k E(e^{t_i z_i}) =$$

$z_i \neq z_j$
 $\forall i \neq j$

$$M_{z_i}(t_i) = E(e^{t_i z_i})$$

$t_i \in \mathbb{R}$ def

$$= \prod_{i=1}^k M_{z_i}(t_i)$$

$$M_{\underline{z}}(\underline{t}) = E(e^{\underline{t}^T \underline{z}}) = e^{\frac{1}{2} \underline{t}^T \underline{t}}$$

i.i.d. $\prod_{i=1}^k e^{\frac{1}{2} t_i^2} = e^{\frac{1}{2} \sum_{i=1}^k t_i^2}$

$$\sum_{i=1}^k t_i^2 = \underline{t}^T \underline{t}$$

$= e^{\frac{1}{2} \underline{t}^T \underline{t}}$
 nota esp vectorial

como obter a f.g.m. de $N_k(\underline{\mu}, \underline{\Sigma})$

$$\underline{X} = \underline{z} + \underline{\mu} \quad ; \quad \underline{\Sigma} = \underline{C} \underline{C}^T$$

$$M_{\underline{X}}(\underline{t}) = E(e^{\underline{t}^T \underline{X}}) = E(e^{\underline{t}^T (\underline{z} + \underline{\mu})}) = e^{\underline{t}^T \underline{\mu}} E(e^{\underline{t}^T \underline{z}}) = e^{\underline{t}^T \underline{\mu}} M_{\underline{z}}(\underline{t})$$

$$= E(e^{\underline{t}^T \underline{C} \underline{z} + \underline{t}^T \underline{\mu}}) = e^{\underline{t}^T \underline{\mu}} E(e^{\underline{t}^T \underline{C} \underline{z}})$$

$$= e^{\underline{t}^T \underline{\mu}} E(e^{(\underline{C}^T \underline{t})^T \underline{z}}) = e^{\underline{t}^T \underline{\mu}} M_{\underline{z}}(\underline{C}^T \underline{t})$$

$$= e^{\underline{t}^T \underline{\mu}} e^{\frac{1}{2} \underline{t}^T \underline{C} \underline{C}^T \underline{t}} = e^{\underline{t}^T \underline{\mu} + \frac{1}{2} \underline{t}^T \underline{\Sigma} \underline{t}}$$

$$M_{\underline{z}}(\underline{t}) = e^{\frac{1}{2} \underline{t}^T \underline{t}}$$

$$= e^{-\frac{t^T \mu}{\sigma} - \frac{1}{2} \frac{t^T \Sigma t}{\sigma^2}}$$

$$= \boxed{e^{-\frac{t^T \mu}{\sigma} - \frac{1}{2} \frac{t^T \Sigma t}{\sigma^2}}} \quad \text{f.g.m. } N_K(\mu, \Sigma)$$

f.g.m. Normal univariada

$$M_X(t) = e^{t\mu + \frac{1}{2} \sigma^2 t^2}$$

• Geracao de valores de Normal K-variada

$$Z_i \sim N(0,1) \quad i=1, \dots, K$$

iid.

$$\underline{z} \sim N_K(0, I_K)$$

$$\underline{x} = \underline{C} \underline{z} + \underline{\mu} \quad , \quad \text{com } \underline{C} \underline{C}^T = \underline{\Sigma}$$

$$\underline{\Sigma} = \underline{T} \underline{\Lambda} \underline{T}^T = \underline{T} \underline{\Lambda}^{1/2} \underline{\Lambda}^{1/2} \underline{T}^T$$

$\underline{\Sigma}$ simétrica de definida positiva

$$\underline{\Sigma} = \underline{T} \underline{\Lambda} \underline{T}^T$$

\underline{T} ortogonal (k-vetores próprios de $\underline{\Sigma}$)

$\underline{\Lambda} = \text{diag}(\lambda_1, \dots, \lambda_k)$
 $\lambda_i \rightarrow i$ -ésimo valor próprio de $\underline{\Sigma}$

1) gerar z_1, \dots, z_k com o método de Box-Müller, $i=1, \dots, k$ (indep)

$$\underline{z} = (z_1, \dots, z_k) \quad \text{observação de } N_K(0, I_K)$$

2) Fazer $\underline{x} = \underline{C} \underline{z} + \underline{\mu}$ com $\underline{C} = \underline{T} \underline{\Lambda}^{1/2}$


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

1. Método de transformação inversa para simulação de v.a's discretas

X v.a. discreta e $F_X(x)$ não é uma função contínua

Pode-se também aplicar o método de transformação inversa para simular v.a's discretas usando a "Alteração" (generalização)

$$x = F^{-1}(u) = \min \{x : F_X(x) \geq u\} \quad \text{com } u \text{ um valor de } U(0,1)$$



X v.a. discreta com f. dist. $F_X(x)$
e funç. de Prob. $P(X=x_j) = p_j, j=0,1, \dots$

$$X = \begin{cases} x_0 & \text{se } U < p_0 \\ x_1 & \text{se } p_0 \leq U < p_0 + p_1 \\ \vdots & \\ x_j & \text{se } \sum_{i=0}^{j-1} p_i \leq U < \sum_{i=0}^j p_i \end{cases}$$

Algoritmo:

- 1) Gerar u da $U(0,1)$
- 2) Devolver $x = x_j$ se $\sum_{i=0}^{j-1} p_i \leq u < \sum_{i=0}^j p_i$, i.e.

$$\text{se } F_X(x_{j-1}) \leq u < F_X(x_j)$$

Note-se que: $P(X=x_j) = P\left(\sum_{i=0}^{j-1} p_i \leq U < \sum_{i=0}^j p_i\right) = p_j$ como se pretendia!

Simulação de v.a.'s discretas usando o método da transformação inversa (quantil)

- Uniforme discreta em $\{1, \dots, n\}$

$$X \sim \text{Unif} \{1, 2, \dots, n\}$$

$$P(X=i) = \begin{cases} 1/n & , i \in \{1, 2, \dots, n\} \\ 0 & , \text{c.c.} \end{cases}$$

$$F_X(j-1) = \frac{j-1}{n} \quad ; \text{ Assim } X=j \text{ se } \frac{j-1}{n} \leq u < \frac{j}{n} \Leftrightarrow$$

$$F_X(j) = \frac{j}{n} \quad \Leftrightarrow j-1 \leq nu < j$$

$$\text{ie } x=j \Leftrightarrow x = [nu] + 1 = [nu]$$

\downarrow
 escrevendo à vista de u

$[\cdot] \rightarrow$ parte inteira
 $\lceil \cdot \rceil \rightarrow$ teto

Ex: $X \sim \text{Unif} \{1, 2, \dots, 6\}$

Gerar u ; $u = 0.7$ (supondo)

$$F_X(4) = \frac{4}{6} = 0.6 \quad F_X(4) \leq u = 0.7 < F_X(5)$$

$$F_X(5) = 5/6 = 0.8(3) \quad x = [6 \times 0.7] + 1 = [4.2] + 1 = 4 + 1 = 5$$

• Bernoulli (p)

$X \sim \text{Ber}(p)$; $R_X = \{0, 1\}$

$$x = 0 \text{ se } U < p_0 = (1-p)$$

$$U < (1-p)$$

$$\Leftrightarrow 1 - U > p \Leftrightarrow U > p$$

\downarrow
 $(1-U) \sim U(0,1)$

$$\therefore X = \begin{cases} 0 & \text{se } U > p \\ 1 & \text{se } U \leq p \end{cases}$$

• Binomial (n, p) ; $X \sim \text{Bin}(n, p)$

Método 1: Gerar n n.ºs pseudo-Aleatórios $\text{Ber}(p)$ e de seguida contabilizar o n.º de sucessos

1) Genere n n.ºs indep u_1, \dots, u_n da $U(0,1)$

2) Efectuar a atribuição

$$y_i = \begin{cases} 0, & \text{se } u_i > p \\ 1 & \text{se } u_i \leq p \end{cases} \quad i=1, \dots, n \text{ e}$$
$$x = \sum_{i=1}^n y_i$$

Método 2 (requer apenas a geração de um n.º u da $U(0,1)$)

Baseia-se no facto de se $U \sim U(0,1)$ então

1) Dado $U \leq p$ tem-se $(U | U \leq p) \sim U(0,p)$

2) Dado $U > p$ tem-se $(U | U > p) \sim U(p,1)$

Dem 1): $0 < u \leq p$

$$P(U \leq u | U \leq p) = \frac{P(U \leq u, U \leq p)}{P(U \leq p)} = \frac{P(U \leq u)}{P(U \leq p)} = \frac{u}{p} \quad \therefore$$

$(U | U \leq p) \sim U(0,p)$

Algoritmo:

1. Genere um n.º u da $U(0,1)$

2. Inicialize $k = 0$

3. $k = k + 1$

4. Se $u \leq p \Rightarrow \left. \begin{array}{l} y_k = 1 \\ \text{substitua } u \text{ por } \frac{u}{p} \end{array} \right\} \text{ obs: } \left(\frac{U}{p} | U \leq p \right) \sim U(0,1)$

5. Se $u > p \Rightarrow \left. \begin{array}{l} y_k = 0 \\ \text{substitua } u \text{ por } \frac{u-p}{1-p} \end{array} \right\} \text{ obs: } \left(\frac{U-p}{1-p} | U > p \right) \sim U(0,1)$

6. Se $k = n$ saia de $x = \sum_{i=1}^n y_k$ e pare

7. $\pm n$ para passo 3.

- Geométrica : $X \sim \text{Geo}(p)$

$$p_j = P(X=j) = p(1-p)^{j-1} \quad j=1,2,\dots$$

$$\begin{aligned} F_X(j-1) &= P(X \leq j-1) = 1 - P(X > j-1) \\ &= 1 - P(\text{'1's (j-1) para sem êxito'}) \\ &= 1 - (1-p)^{j-1} \quad j \in \{1,2,\dots\} \end{aligned}$$

$$F_X(j) = 1 - (1-p)^j$$

$$\begin{aligned} F_X(j-1) \leq U < F_X(j) &\Leftrightarrow 1 - (1-p)^{j-1} \leq U < 1 - (1-p)^j \\ &\Leftrightarrow (1-p)^j < 1-U \leq (1-p)^{j-1} \end{aligned}$$

$$X \text{ é o } 1^{\circ} j : (1-p)^j < 1-U$$

$$\text{ie } X = \min \{ j : (1-p)^j < 1-U \}$$

Aplicando Logaritmo, tem-se

$$\begin{aligned} X &= \min \{ j : \underbrace{j \ln(1-p)}_{< 0} < \ln(1-U) \} \\ &= \min \left\{ j : j > \frac{\ln(1-U)}{\ln(1-p)} \right\} \quad (1-U) \sim U(0,1) \end{aligned}$$

$$\text{Assim } X = \left\lceil \frac{\ln(U)}{\ln(1-p)} \right\rceil + 1$$

- Binomial Negativa - Generalização da Dist. Geométrica

Condições da Exp^ç Aleatória : $\left\{ \begin{array}{l} \bullet \text{ Sucessos de trials de Bernoulli Indep} \\ \bullet P(\text{'sucesso'}) = p; \text{ constante} : p = P(A_i) \end{array} \right.$

$X =$ 'v.a. n.º de provas até obter r sucessos'

$P(X=x) = P(\text{'na prova } x \text{ ocorreu sucesso e nas } (x-1) \text{ provas anteriores ocorreram } (r-1) \text{ sucessos'})$

$A_i =$ 'i-ésima prova é sucesso' $P(A_i) = p, \forall i$

Uma possibilidade (sem contar com a ordem)

$$B = A_1 A_2 \dots A_{r-1} \bar{A}_r \dots \bar{A}_{x-1} \boxed{A_x} \quad \leftarrow \text{fixo}$$

$$P(B) = \underbrace{p \times p \times \dots \times p}_{r-1} \times \underbrace{(1-p) \times \dots \times (1-p)}_{x-r} \times p$$

$$P(X=x) = \binom{x-1}{r-1} (1-p)^{x-r} p^r, \quad x = r, r+1, \dots$$

$$X \sim \text{BN}(r, p)$$

Esta v.a. tem esta designação porque:

Binomial

- * fixo o n.º de provas
- * conta-se o n.º de sucessos

Binomial Negativa

- * fixo o n.º de sucessos
- * conta-se o n.º de provas

Esta v.a. não tem f. dist. tabelada. No entanto, existe relação com a dist. Binomial.

$W =$ 'v.a. n.º de sucessos em $(x-1)$ provas'

$$W \sim \text{Bin}(x-1, p)$$

$$\begin{aligned}
 P(X=x) &= P(W=x-1) \cdot p = \\
 &= \binom{x-1}{r-1} p^{r-1} (1-p)^{x-1-(r-1)} \cdot p = \\
 &= \binom{x-1}{r-1} p^r (1-p)^{x-r}, \quad x=r, r+1, \dots
 \end{aligned}$$

Além disso se $X \sim \text{BN}(r, p)$

$$P(X \leq n) = P(Y \geq r) \quad Y \sim \text{BN}(n, p)$$

$\underbrace{\hspace{10em}}$
 São necessárias n ou menos
 provas para obter r sucessos
 \rightarrow n é de sucessos em n provas e
 no mínimo r

observações:

1) $r=1$, ie $X \sim \text{BN}(1, p) (=) X \sim \text{Geo}(p)$

2) $W_i \sim \text{Geo}(p)$, $i=1, \dots, r$ então $X = \sum_{i=1}^r W_i \sim \text{BN}(r, p)$
i.i.d.

Dem: f.g.p.

$$E(X) = E\left(\sum_{i=1}^r W_i\right) \underset{\text{op. linear}}{=} \sum_{i=1}^r E(W_i) \underset{\text{i.i.d.}}{=} \sum_{i=1}^r E(W) = \frac{r}{p}$$

$$\text{Var}(X) = \dots \underset{\text{i.i.d.}}{=} \sum_{i=1}^r \text{var}(W) = \frac{r(1-p)}{p^2}$$

$$P_W(s) = \frac{ps}{1-(1-p)s}$$

$$P_X(s) = \left(\frac{ps}{1-(1-p)s}\right)^r$$

3) $X \sim \text{BN}(r, p)$ e $Y \sim \text{BN}(s, p)$ com $X \perp Y$

$$(X+Y) \sim \text{BN}(r+s; p)$$

Definição Alternativa

$Y =$ v.a. n.º de insucessos até obter r sucessos

$$X = Y + r$$

↗ n.º de sucessos
↓ n.º de insucessos

$$R_Y = \{0, 1, \dots\}$$

n.º de provas

Assim $Y = X - r$

$$\begin{aligned} P(Y=y) &= P(X = \underbrace{Y+r}_r) = \binom{y+r-1}{r-1} p^r (1-p)^{y+r-r} \\ &= \binom{y+r-1}{r-1} p^r (1-p)^y, \quad y \in \mathbb{N}_0 \end{aligned}$$

$$E(Y) = E(X-r) = E(X) - r = \frac{r}{p} - r = \frac{r(1-p)}{p}$$

$$\text{var}(Y) = \text{var}(X-r) = \text{var}(X) = \frac{r(1-p)}{p^2}$$

Algoritmo: usando 2) cria um algoritmo semelhante ao da Binomial (Método 1).

• Poisson: $X \sim \text{Poi}(\lambda)$

$$p_i = P(X=i) = \frac{e^{-\lambda} \lambda^i}{i!}, \quad i=0, 1, \dots, \lambda > 0$$

$$\frac{p_{i+1}}{p_i} = \frac{\frac{\lambda^{i+1}}{(i+1)!}}{\frac{\lambda^i}{i!}} = \frac{\lambda}{i+1} \therefore p_{i+1} = \frac{\lambda}{i+1} p_i \quad i \in \{0, 1, \dots\}$$

$$p_0 = P(X=0) = e^{-\lambda}$$

$$p_1 = P(X=1) = \lambda e^{-\lambda} = p_0 \lambda$$

$$p_2 = P(X=2) = \frac{e^{-\lambda} \lambda \cdot \lambda}{2!} = p_1 \frac{\lambda}{2!}$$

Algoritmo:

1. Gere u da $U(0,1)$
2. $x_i = 0$, $p = e^{-\lambda}$, $F = p$
3. se $u < F$ atribua $x = i$ e Pare
4. $p = \frac{\lambda p}{(i+1)}$; $F = F + p$; $i = i + 1$;
5. Ir para o passo 3.

Generação de v.a's discretas multivariadas (só a dist. Multinomial)

Multinomial

Generalização de dist. Binomial para mais do que duas categorias. Admite-se que se realizem n provas de Bernoulli indep. e que em cada prova há k resultados possíveis A_1, \dots, A_k com prob. constantes ao longo das n provas, ie

$$P(A_i) = p_i, \quad \sum_{i=1}^k p_i = 1 \quad \text{e} \quad n = \sum_{i=1}^k x_i \quad \text{onde}$$

$x_i =$ v.a. n.º de ocorrências de A_i nas n provas $i=1, \dots, k$

Qual é a dist. conjunta (função de prob. conjunta) do vetor $\underline{X} = (X_1, \dots, X_k)$?

Vamos ver um exemplo:

Num processo de controle de qualidade onde os elementos podem ter \exists tipo de defeito (indep):

Leves (A_1), médio (A_2) ou grave (A_3). ←

Qual é a prob. de nos próximos \exists elementos \exists defeitos haver exactamente $\underline{1}$ com defeito grave?

Sejam: $P(A_1) = 0.7$; $P(A_2) = 0.2$;
 $P(A_3) = 0.1$

$X_1 =$ v.a. n.º de elementos e/ def. A_1 em \exists elementos

$X_2 =$ " " " " A_2 em " " "

$X_3 =$ " " " " A_3 em " " "

Os defeitos possíveis nos \exists elementos, sem ter em conta a ordem, s.s:

$A_1 A_1 A_3$; $A_1 A_2 A_3$; $A_2 A_2 A_3$

$$P(A_1 A_1 A_3) = 0.7^2 \times 0.1$$

n.º de maneiras \neq s que pode surgir: $\binom{3}{2} \binom{1}{1}$

$$\binom{3}{2} \binom{1}{1} = \frac{3!}{2! 2!} \frac{1!}{1! 0!} = \frac{3!}{2! 1! 0!}$$

Assim:

$$P(X_1=2, X_2=0, X_3=1) = \frac{3!}{2! 0! 1!} 0.7^2 \times 0.2^0 \times 0.1^1$$

$$P(X_1=0, X_2=2, X_3=1) = \frac{3!}{0! 2! 1!} 0.7^0 \times 0.2^2 \times 0.1^1$$

⋮

$$P(X_1=x_1, X_2=x_2, X_3=x_3) = \frac{3!}{x_1! x_2! x_3!} 0.7^{x_1} 0.2^{x_2} 0.1^{x_3}$$

$$\text{Se } x_i = 0, \dots, 3; \sum_{i=1}^3 x_i = 3$$

Caso geral: Função de prob. do vetor $\underline{X} = (X_1, \dots, X_k)$

$$P(\underline{X} = \underline{x}) = \begin{cases} \frac{n!}{x_1! \dots x_k!} p_1^{x_1} \dots p_k^{x_k}, & \sum_{i=1}^k x_i = n, \sum_{i=1}^k p_i = 1 \\ 0, & \text{c.c.} \end{cases}$$

$$\underline{X} \sim \text{Mult}(n; \underline{p}) \quad \underline{p} = (p_1, \dots, p_k)$$

tal como acontece com a Binomial uma destas variáveis é redundante

Pode-se escrever a f. p. conjunta na forma

$$P(X_1 = x_1, \dots, X_{k-1} = x_{k-1}) = \frac{n!}{x_1! x_2! \dots x_{k-1}! (n - \sum_{i=1}^{k-1} x_i)!} \times$$

$$\times p_1^{x_1} \dots p_{k-1}^{x_{k-1}} (1 - \sum_{i=1}^{k-1} p_i)^{n - \sum_{i=1}^{k-1} x_i}$$

Propriedades

1. As dist. marginais univariadas são Binomiais
 $X_i \sim \text{Bin}(n, p_i) \quad E(X_i) = n p_i; \text{var}(X_i) = n p_i (1 - p_i)$
2. As dist. marginais multivariadas (2 ou + componentes)

$$P(X_i = x_i, X_j = x_j) = \frac{n!}{x_i! x_j! (n - x_i - x_j)!} p_i^{x_i} p_j^{x_j} (1 - p_i - p_j)^{n - x_i - x_j}$$

$$3. \text{Cov}(X_i, X_j) = -n p_i p_j \quad i \neq j$$

(Aula prática)

Passo para a Dem.

$X_i =$ 'v.a. n.º de ocorrências de A_i nas n provas'

$X_j =$ ' " " " A_j " " " '

$d \rightarrow$ d -ésima prova e $I_{d_i} = \begin{cases} 1, & \text{se } d\text{-ésima prova} \\ & \text{ocorre } A_i \\ 0, & \text{c.c.} \end{cases}$

$I_{d_j} = \begin{cases} 1, & \text{se } d\text{-ésima prova} \\ & \text{ocorre } A_j \\ 0, & \text{c.c.} \end{cases}$

$$X_i = \sum_{d=1}^n I_{d_i}$$

$$; \quad X_j = \sum_{\beta=1}^n I_{\beta_j}$$

$\text{Cov}(I_{d_i}, I_{d_j})$ obter este valor

$\text{Cov}(X_i, X_j)$

4. As dist. condicionadas de qualquer subconjunto de variáveis por qualquer subconjunto de variáveis são também multinomiais (Binomiais)

Por exemplo:

$$\begin{aligned}
 P(X_i = x_i | X_j = x_j) &= \frac{P(X_i = x_i, X_j = x_j)}{P(X_j = x_j)} = \\
 &= \frac{\cancel{n!} p_i^{x_i} p_j^{x_j} (1 - p_i - p_j)^{n - x_i - x_j}}{\cancel{x_j!} (n - x_j)! p_j^{x_j} (1 - p_j)^{n - x_j}} = \\
 &= \frac{(n - x_j)!}{x_i! (n - x_i - x_j)!} \left(\frac{p_i}{1 - p_j} \right)^{x_i} \left(\frac{1 - p_i - p_j}{1 - p_j} \right)^{n - x_i - x_j} \\
 &= \frac{(n - x_j)!}{x_i! (n - x_i - x_j)!} \left(\frac{p_i}{1 - p_j} \right)^{x_i} \left(\frac{1 - p_i}{1 - p_j} \right)^{n - x_i - x_j} \\
 &\therefore (X_i | X_j = x_j) \sim \text{Bin} \left(n - x_j, \frac{p_i}{1 - p_j} \right)
 \end{aligned}$$

Função geradora de Probabilidades

$$P_X(s) = E(s^X)$$

def

1. teo Binomial

$$\forall x, y \text{ e } n \geq 1$$

$$(x+y)^n = \sum_{k=0}^n \binom{n}{k} x^k y^{n-k}$$

2. teo. multinomial

$$\forall x_1, \dots, x_k \text{ e } n \geq 1$$

$$(x_1 + x_2 + \dots + x_k)^n = \sum_{\substack{(n_1, \dots, n_k) \\ n_1 + \dots + n_k = n}} \binom{n}{n_1, \dots, n_k} x_1^{n_1} \dots x_k^{n_k},$$

$$\text{onde } \binom{n}{n_1, \dots, n_k} = \frac{n!}{n_1! \dots n_k!} = \binom{n}{\underline{n}}$$

Função Geradora de Probabilidades (caso multivariado)

$$\underline{X} = (X_1, \dots, X_k) \quad ; \quad \underline{\Delta} = (\Delta_1, \dots, \Delta_k)$$

$$P_{\underline{X}}(\underline{\Delta}) = E(\Delta_1^{X_1} \cdot \Delta_2^{X_2} \cdot \dots \cdot \Delta_k^{X_k})$$

def

$\underline{X} \sim MN(n, \underline{p})$, qual a f.g.p. de \underline{X} ?

$$\begin{aligned} P_{\underline{X}}(\underline{\Delta}) &= E(\Delta_1^{X_1} \cdot \dots \cdot \Delta_k^{X_k}) \\ &= \sum_{\substack{x_1 + \dots + x_k = n \\ \underline{x}}} \binom{n}{\underline{x}} \Delta_1^{x_1} \cdot \dots \cdot \Delta_k^{x_k} p_1^{x_1} \cdot \dots \cdot p_k^{x_k} \\ &= \sum_{x_1 + \dots + x_k = n} \binom{n}{\underline{x}} (\Delta_1 p_1)^{x_1} (\Delta_2 p_2)^{x_2} \cdot \dots \cdot (\Delta_k p_k)^{x_k} \end{aligned}$$

$$\sum_{\underline{x}} (p_1^{x_1} p_2^{x_2} + \dots + p_k^{x_k})^n$$

teo. multinomial

como simular um valor de \underline{x} de dist. Multinomial?

$$P(\underline{X} = \underline{x}) = \binom{n}{\underline{x}} p_1^{x_1} \dots p_k^{x_k}, \quad \sum_{i=1}^k x_i = n, \quad \sum_{i=1}^k p_i = 1$$

(x_1, \dots, x_k) ?

Sabemos que: $X_1 \sim \text{Bin}(n, p_1)$

$$(X_2 | X_1 = x_1) \sim \text{Bin}(n - x_1, \frac{p_2}{1 - p_1})$$

O valor do vetor \underline{x} pode ser obtido com uma simulação sequencial. Inicialmente gera-se x_1 (valor de Binomial), de seguida x_2 a partir da dist. condicional de $X_2 | X_1 = x_1$, depois x_3 a partir da dist. condicional de $(X_3 | X_1 = x_1, X_2 = x_2)$

Passos do Algoritmo:

1) Gerar $X_1 \sim \text{Bin}(n, p_1)$, por exemplo, usando a soma de n Bernoulli's indep. com parâmetros p_1 .

2) De seguida, dado x_1 , nas n provas A_1 ocorreu x_1 vezes e nas restantes $(n - x_1)$ provas A_2 pode ocorrer (independente/)

com prob. :
$$P(A_2 | \bar{A}_1) = \frac{p_2}{1 - p_1}$$

Assim $(X_2 | X_1 = x_1) \sim \text{Bin}(n - x_1, \frac{p_2}{1 - p_1})$ e x_2 pode ser simulado a partir desta Binomial

3) Nas restantes $(n - x_1 - x_2)$ provas A_3 pode ocorrer (indep.) com prob.:

$$P(A_3 | \bar{A}_1 \cap \bar{A}_2) = \frac{p_3}{1 - p_1 - p_2} \text{ e}$$

$$(X_3 | X_1 = x_1, X_2 = x_2) \sim \text{Bin}(n - x_1 - x_2, \frac{p_3}{1 - p_1 - p_2})$$

e assim sucessivamente até $k-1$

$$x_k = n - \sum_{i=1}^{k-1} x_i$$