

Capítulo 5 - Distribuições conjuntas de probabilidades e complementos

5.1 Duas variáveis aleatórias discretas. Distribuições conjuntas, marginais e condicionais. Independência

Em relação a uma mesma experiência podem ser consideradas várias variáveis aleatórias.

Exemplos:

a) Transmissão/recepção de sinais em que cada um é classificado como: alta, média ou baixa qualidade. Considerem-se as v.a.

X - nº de sinais de alta qualidade

Y - nº de sinais de baixa qualidade

Trata-se de duas variáveis discretas.

1

b) Fabrico de peças cilíndricas

X - comprimento da peça

Y - diâmetro da peça

Trata-se de duas variáveis contínuas.

Nos Capítulos 3 e 4 estudou-se a distribuição de probabilidade de v.a. (discretas ou contínuas), consideradas isoladamente.

Para duas ou mais v.a. o seu comportamento simultâneo é estudado usando as chamadas distribuições de probabilidade conjuntas.

Definição: Dadas duas variáveis aleatórias discretas, chama-se função de probabilidade conjunta a $f_{XY}(x, y) = P(X = x, Y = y)$, tal que

$$(1) f_{XY}(x, y) \geq 0, \forall_{(x,y)} \quad (2) \sum_x \sum_y f_{XY}(x, y) = 1$$

2

Exemplo: Lançamento de dois dados perfeitos. Seja

X - nº de vezes que sai a face 6 $x=0,1,2$

Y - nº de vezes que sai a face 5 $y=0,1,2$

$$P(X = 0, Y = 0) = \frac{4}{6} \times \frac{4}{6}$$

$$P(X = 1, Y = 0) = \frac{4}{6} \times \frac{1}{6} \times 2 = P(X = 0, Y = 1)$$

$$P(X = 1, Y = 1) = \frac{1}{6} \times \frac{1}{6} \times 2$$

$$P(X = 2, Y = 0) = \frac{1}{6} \times \frac{1}{6} = P(X = 0, Y = 2)$$

$$P(X = 1, Y = 2) = 0 = P(X = 2, Y = 1)$$

$$P(X = 2, Y = 2) = 0$$


$$\sum_{x=0}^2 \sum_{y=0}^2 P(X = x, Y = y) = 1$$

3

Organização da função de probabilidade conjunta em tabela:

Y \ X	0	1	2
0	16/36	8/36	1/36
1	8/36	2/36	0
2	1/36	0	0

Gráfico:



A partir da tabela podem calcular-se também as probabilidades (chamadas marginais) para X ou Y .
Por exemplo:

$$P(X = 0) = f_{XY}(0,0) + f_{XY}(0,1) + f_{XY}(0,2) = \sum_{y=0}^2 f_{XY}(0,y)$$

Estas probabilidades podem ser acrescentadas à tabela da função de probabilidade conjunta:

$Y \setminus X$	0	1	2	$P(Y = y)$
0	16/36	8/36	1/36	25/36
1	8/36	2/36	0	10/36
2	1/36	0	0	1/36
$P(X = x)$	25/36	10/36	1/36	1

Nota: verificar que $X \sim Bin\left(2, \frac{1}{6}\right)$ e $Y \sim Bin\left(2, \frac{1}{6}\right)$ (diz-se que X e Y são identicamente distribuídas)

Definição: Se X e Y forem v.a. discretas com função de probabilidade conjunta $f_{XY}(x,y)$, as funções de probabilidade marginais de X e Y são

$$f_X(x) = P(X = x) = \sum_y f_{XY}(x,y)$$

$$f_Y(y) = P(Y = y) = \sum_x f_{XY}(x,y)$$

Nota: dada uma função de probabilidade conjunta, $E(X)$, $V(X)$, $E(Y)$ e $V(Y)$ podem ser calculados usando a f.p. conjunta ou as f.p. marginais:

$$E(X) = \mu_X = \sum_x x f_X(x) = \sum_x x \left(\sum_y f_{XY}(x,y) \right) = \sum_x \sum_y x f_{XY}(x,y)$$

Definição: Dadas as v.a. discretas X e Y com f.p. conjunta $f_{XY}(x,y)$, a função de probabilidade condicionada de Y dado $X=x$ (tal que $f_X(x) > 0$) é

$$f_{Y|x}(y) = P(Y = y | X = x) = \frac{f_{XY}(x,y)}{f_X(x)}$$

e verifica

$$(1) f_{Y|x}(y) \geq 0, \forall_y \quad (2) \sum_y f_{Y|x}(y) = 1$$

(tem as propriedades de uma f.p.)

Definição: O valor esperado condicionado de Y dado $X=x$ é

$$E(Y|x) = \mu_{Y|x} = \sum_y y f_{Y|x}(y)$$

e a respectiva variância condicionada é

$$V(Y|x) = \sum_y (y - \mu_{Y|x})^2 f_{Y|x}(y)$$

Nota: Definições semelhantes para X dado $Y=y$.

Exemplo (cont.): $Y|X=1$

$$P(Y = 0 | X = 1) = \frac{8/36}{10/36} = \frac{8}{10}$$

$$P(Y = 1 | X = 1) = \frac{2/36}{10/36} = \frac{2}{10}$$

$$P(Y = 2 | X = 1) = \frac{0}{10/36} = 0$$

$$E(Y|X = 1) = 0 \times \frac{8}{10} + 1 \times \frac{2}{10} = \frac{2}{10}$$

$Y|X=0$

$$P(Y = 0 | X = 0) = \frac{16/36}{25/36} = \frac{16}{25}$$

$$P(Y = 1 | X = 0) = \frac{8/36}{25/36} = \frac{8}{25}$$

$$P(Y = 2 | X = 0) = \frac{1/36}{25/36} = \frac{1}{25}$$

$$E(Y|X = 0) = 0 \times \frac{16}{25} + 1 \times \frac{8}{25} + 2 \times \frac{1}{25} = \frac{10}{25}$$

O conceito de independência de acontecimentos pode ser estendido a variáveis aleatórias.

Definição: Dadas duas v.a. discretas X e Y , se uma das seguintes condições se verificar então as outras também se verificam e as v.a. são independentes

- (1) $f_{XY}(x, y) = f_X(x)f_Y(y), \quad \forall_{x,y}$
- (2) $f_{Y|x}(y) = f_Y(y), \quad \forall_{x,y}$ com $f_X(x) > 0$
- (3) $f_{X|y}(x) = f_X(x), \quad \forall_{x,y}$ com $f_Y(y) > 0$

Exemplo (cont.): Serão X e Y independentes? Não, porque, por exemplo,

$$P(X = 2, Y = 2) = 0 \neq P(X = 2)P(Y = 2)$$

Consequência da definição de independência: Se X e Y são independentes, então

$$P(X \in A \text{ e } Y \in B) = P(X \in A) \times P(Y \in B)$$

5.2 Duas variáveis aleatórias contínuas. Distribuições conjuntas, marginais e condicionais. Independência

Do mesmo modo que para caracterizar uma v.a. contínua foi necessário introduzir o conceito de função de densidade de probabilidade, define-se para duas variáveis aleatórias contínuas a função de densidade de probabilidade conjunta.

Definição: A função de densidade de probabilidade conjunta para duas v.a. contínuas, X e Y , representada por $f_{XY}(x, y)$, satisfaz:

- (1) $f_{XY}(x, y) \geq 0 \quad \forall_{(x,y)}$
- (2) $\int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} f_{XY}(x, y) dx dy = 1$
- (3) $P((X, Y) \in R) = \iint_R f_{XY}(x, y) dx dy \quad \forall \text{ região } R$

Definição: Dadas duas v.a. contínuas, X e Y , com f.d.p. conjunta $f_{XY}(x, y)$, as funções de densidade de probabilidade marginais de X e Y são dadas por

$$f_X(x) = \int_{-\infty}^{+\infty} f_{XY}(x, y) dy$$

$$f_Y(y) = \int_{-\infty}^{+\infty} f_{XY}(x, y) dx$$

Definição: Dadas duas v.a. contínuas, X e Y , com f.d.p. conjunta $f_{XY}(x, y)$, a função de densidade de probabilidade condicionada de Y dado $X=x$ (tal que $f_X(x) > 0$) é

$$f_{Y|x}(y) = \frac{f_{XY}(x, y)}{f_X(x)}$$

e verifica:

- (1) $f_{Y|x}(y) \geq 0, \quad \forall_y$
- (2) $\int_{-\infty}^{+\infty} f_{Y|x}(y) dy = 1$
- (3) $P(Y \in B | X = x) = \int_B f_{Y|x}(y) dy$

Definição: O valor esperado condicionado de Y dado $X=x$ é

$$E(Y|x) = \mu_{Y|x} = \int_{-\infty}^{+\infty} y f_{Y|x}(y) dy$$

e a respectiva variância condicionada é

$$V(Y|x) = \int_{-\infty}^{+\infty} (y - \mu_{Y|x})^2 f_{Y|x}(y) dy$$

Nota: Definições semelhantes para X dado $Y=y$.

A **definição de independência** coincide com a que foi dada para as variáveis discretas mas em que $f_{XY}(x, y)$, $f_X(x)$, $f_Y(y)$, $f_{Y|x}(y)$ e $f_{X|y}(x)$ são funções de densidade de probabilidade.

5.3 Covariância e correlação

Pretende-se uma medida que meça algum aspecto da variação conjunta de duas variáveis aleatórias.

Definição: a covariância entre duas v.a., X e Y , é dada por

$$\text{cov}(X, Y) = \sigma_{XY} = E[(X - \mu_X)(Y - \mu_Y)]$$

Se ambas as v.a. forem discretas tem-se


$$\sigma_{XY} = \sum_x \sum_y (x - \mu_X)(y - \mu_Y) f_{XY}(x, y)$$

Se ambas as v.a. forem contínuas tem-se

$$\sigma_{XY} = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} (x - \mu_X)(y - \mu_Y) f_{XY}(x, y) dx dy$$



Interpretação do sinal da covariância:

$\text{cov}(X, Y) > 0$:




Nota: pontos com iguais probabilidades.

$\text{cov}(X, Y) = 0$:



$\text{cov}(X, Y) < 0$:



Propriedades da covariância:

- 1) $\text{cov}(X, Y) = E(XY) - \mu_X \mu_Y$
- 2) $\text{cov}(X, Y) = \text{cov}(Y, X)$ 3) $\text{cov}(X, X) = V(X)$
- 4) $\text{cov}(aX, Y) = a \text{cov}(X, Y)$
- 5) $\text{cov}(X + Z, Y) = \text{cov}(X, Y) + \text{cov}(Z, Y)$
- 6) $\text{cov}\left(\sum_{i=1}^n X_i, \sum_{j=1}^n Y_j\right) = \sum_{i=1}^n \sum_{j=1}^n \text{cov}(X_i, Y_j)$

Exemplo (cont.): Calcular a covariância entre X e Y

$Y \backslash X$	0	1	2
0	16/36	8/36	1/36
1	8/36	2/36	0
2	1/36	0	0

$$E(XY) = 0 \times 0 \times \frac{16}{36} + \dots + 1 \times 1 \times \frac{2}{36} + \dots + 2 \times 2 \times 0 = \frac{2}{36}$$

$$X \text{ e } Y \sim \text{Bin}\left(2, \frac{1}{6}\right) \Rightarrow E(X) = E(Y) = 2 \times \frac{1}{6} = \frac{1}{3}$$

$$\text{logo } \text{cov}(X, Y) = \frac{2}{36} - \frac{1}{9} = -\frac{1}{18}$$

Significado: em média há uma tendência para y decrescer quando x cresce e vice-versa.

O valor absoluto da covariância não é interpretável porque esta pode ser arbitrariamente alterada por uma mudança de escala (propriedade 4).

17

Medida cujo sinal dá a mesma indicação mas que é adimensional e cujo valor absoluto já é interpretável:

Definição: A correlação ou coeficiente de correlação entre duas v.a. X e Y é

$$\rho_{XY} = \frac{\text{cov}(X, Y)}{\sqrt{V(X)V(Y)}} = \frac{\sigma_{XY}}{\sigma_X \sigma_Y}$$

Propriedades:

1) $-1 \leq \rho_{XY} \leq 1, \quad \forall_{X, Y}$

2) a) $\rho_{XY} = 1$ sse $Y = aX + b$ com $a > 0$

b) $\rho_{XY} = -1$ sse $Y = aX + b$ com $a < 0$

18

Demonstração: 1) a) $\rho_{XY} \geq -1$

Considere-se a v.a. auxiliar $\frac{X}{\sigma_X} + \frac{Y}{\sigma_Y}$, sabe-se que

$$V\left(\frac{X}{\sigma_X} + \frac{Y}{\sigma_Y}\right) \geq 0, \quad \forall_{X, Y}, \text{ por outro lado}$$

$$\begin{aligned} V\left(\frac{X}{\sigma_X} + \frac{Y}{\sigma_Y}\right) &= E\left[\left(\frac{X}{\sigma_X} + \frac{Y}{\sigma_Y}\right)^2\right] - \left[E\left(\frac{X}{\sigma_X} + \frac{Y}{\sigma_Y}\right)\right]^2 = \\ &= \frac{E(X^2)}{\sigma_X^2} + \frac{E(Y^2)}{\sigma_Y^2} + 2\frac{E(XY)}{\sigma_X \sigma_Y} - \frac{\mu_X^2}{\sigma_X^2} - \frac{\mu_Y^2}{\sigma_Y^2} - 2\frac{\mu_X \mu_Y}{\sigma_X \sigma_Y} = \\ &= \frac{E(X^2) - \mu_X^2}{\sigma_X^2} + \frac{E(Y^2) - \mu_Y^2}{\sigma_Y^2} + 2\frac{E(XY) - \mu_X \mu_Y}{\sigma_X \sigma_Y} = \\ &= 1 + 1 + 2\rho_{XY} \geq 0 \Leftrightarrow \rho_{XY} \geq -1 \end{aligned}$$

b) $\rho_{XY} \leq 1$ Repetir a demonstração anterior com a v.a. auxiliar $\frac{X}{\sigma_X} - \frac{Y}{\sigma_Y}$

19

2) b) Pela demonstração anterior,

$$V\left(\frac{X}{\sigma_X} + \frac{Y}{\sigma_Y}\right) = 0 \Leftrightarrow \rho_{XY} = -1$$

mas $V\left(\frac{X}{\sigma_X} + \frac{Y}{\sigma_Y}\right) = 0 \Leftrightarrow \frac{X}{\sigma_X} + \frac{Y}{\sigma_Y} = \text{constante}$, o que demonstra o resultado.

Teorema: Se X e Y são independentes então

$$\sigma_{XY} = \rho_{XY} = 0$$

Demonstração: Vamos admitir que X e Y são ambas discretas (seria semelhante para ambas contínuas, substituindo os integrais por somatórios)

20

X e Y são independentes sse

$$f_{XY}(x, y) = f_X(x)f_Y(y), \quad \forall_{x, y}$$

logo

$$\begin{aligned} E(XY) &= \sum_x \sum_y xyf_{XY}(x, y) = \\ &= \sum_x \sum_y xyf_X(x)f_Y(y) = \\ &= \left(\sum_x xf_X(x) \right) \left(\sum_y yf_Y(y) \right) = E(X)E(Y) \end{aligned}$$

pelo que $\sigma_{XY} = 0$ e $\rho_{XY} = 0$

Muito importante: a proposição inversa não é verdadeira, isto é

$\rho_{XY} = \sigma_{XY} = 0$ não implica X e Y independentes

21

Exemplo:

$Y \setminus X$	-1	0	1	$P(Y = y)$
-1	0	1/6	0	1/6
0	1/12	1/2	1/12	2/3
1	0	1/6	0	1/6
$P(X = x)$	1/12	5/6	1/12	1

Tem-se $E(X) = E(Y) = 0$ e $E(XY) = 0$, pelo que $\sigma_{XY} = 0$, mas X e Y não são independentes.

5.4 Combinações lineares de variáveis aleatórias

Definição: dadas p v.a., X_1, X_2, \dots, X_p e p constantes c_1, c_2, \dots, c_p ,

$$Y = c_1X_1 + c_2X_2 + \dots + c_pX_p$$

é uma combinação linear de X_1, X_2, \dots, X_p .

22

Valor esperado duma combinação linear:

$$1) E(c_1X_1 + c_2X_2) = c_1E(X_1) + c_2E(X_2)$$

Demonstração:

$$\begin{aligned} E(c_1X_1 + c_2X_2) &= \sum_{x_1} \sum_{x_2} (c_1x_1 + c_2x_2)f(x_1, x_2) = \\ &= c_1 \sum_{x_1} \sum_{x_2} x_1f(x_1, x_2) + c_2 \sum_{x_1} \sum_{x_2} x_2f(x_1, x_2) = \\ &= c_1E(X_1) + c_2E(X_2) \end{aligned}$$

2) Generalização de (1)

$$\begin{aligned} E(c_1X_1 + c_2X_2 + \dots + c_pX_p) &= \\ &= c_1E(X_1) + c_2E(X_2) + \dots + c_pE(X_p) \end{aligned}$$

23

Variância duma combinação linear:

1)

$$\begin{aligned} V(c_1X_1 + c_2X_2) &= \\ &= c_1^2V(X_1) + c_2^2V(X_2) + 2c_1c_2 \text{cov}(X_1, X_2) \end{aligned}$$

Demonstração:

$$\begin{aligned} V(c_1X_1 + c_2X_2) &= \\ &= E[(c_1X_1 + c_2X_2)^2] - [E(c_1X_1 + c_2X_2)]^2 = \\ &= E(c_1^2X_1^2 + c_2^2X_2^2 + 2c_1c_2X_1X_2) - (c_1\mu_1 + c_2\mu_2)^2 = \\ &= c_1^2E(X_1^2) + c_2^2E(X_2^2) + 2c_1c_2E(X_1X_2) - \\ &\quad - c_1^2\mu_1^2 - c_2^2\mu_2^2 - 2c_1c_2\mu_1\mu_2 = \\ &= c_1^2[E(X_1^2) - \mu_1^2] + c_2^2[E(X_2^2) - \mu_2^2] + \\ &\quad + 2c_1c_2[E(X_1X_2) - \mu_1\mu_2] \end{aligned}$$

c.q.d.

24

2) Generalização de (1)

$$V(c_1X_1 + \dots + c_pX_p) = \sum_{i=1}^p c_i^2 V(X_i) + 2 \sum_{i=1}^p \sum_{j=i+1}^p c_i c_j \text{cov}(X_i, X_j)$$

3) Caso particular de 2)

Se $\text{cov}(X_i, X_j) = 0, \forall_{i \neq j}$, ou seja, se as v.a. forem não correlacionadas duas a duas tem-se

$$V(c_1X_1 + \dots + c_pX_p) = \sum_{i=1}^p c_i^2 V(X_i)$$

Nota: o mesmo acontece se as v.a. forem independentes duas a duas, uma vez que, como já se viu, nesse caso as covariâncias duas a duas são nulas.

Casos especiais de somas de variáveis aleatórias:**I) Propriedade reprodutiva da distribuição binomial**

a) Se $X_1 \sim \text{Bin}(n_1, p)$, $X_2 \sim \text{Bin}(n_2, p)$ e X_1 e X_2 forem independentes, então

$$X_1 + X_2 \sim \text{Bin}(n_1 + n_2, p)$$

($X_1 + X_2$ representa o número de sucessos em $n_1 + n_2$ provas de Bernoulli independentes com $P(\text{sucesso})$ constante e igual a p)

b) (Generalização) Se $X_i \sim \text{Bin}(n_i, p)$, $i = 1, \dots, k$, independentes, então

$$X_1 + \dots + X_k \sim \text{Bin}\left(\sum_{i=1}^k n_i, p\right)$$

Caso particular: $X_i \sim \text{Ber}(p) = \text{Bin}(1, p)$, $i = 1, \dots, n$ independentes, então $X_1 + \dots + X_n \sim \text{Bin}(n, p)$

II) Propriedade reprodutiva da distribuição de Poisson

a) Se $X_1 \sim \text{Poisson}(\lambda_1)$, $X_2 \sim \text{Poisson}(\lambda_2)$ e X_1 e X_2 forem independentes, então

$$X_1 + X_2 \sim \text{Poisson}(\lambda_1 + \lambda_2)$$

(Este caso pode ser visto como um limite do caso

I)a)

b) (Generalização) Se $X_i \sim \text{Poisson}(\lambda_i)$, $i = 1, \dots, k$, independentes, então

$$X_1 + \dots + X_k \sim \text{Poisson}\left(\sum_{i=1}^k \lambda_i\right)$$

III) Propriedade reprodutiva da distribuição Normal

Se $X_1 \sim N(\mu_1, \sigma_1^2)$, $X_2 \sim N(\mu_2, \sigma_2^2)$ e X_1 e X_2 forem independentes, então

$$c_1X_1 + c_2X_2 \sim N(c_1\mu_1 + c_2\mu_2, c_1^2\sigma_1^2 + c_2^2\sigma_2^2)$$

IV) Mudança de escala na distribuição exponencial

Se $X \sim \text{Exp}(\lambda)$ e $c > 0$, então $Y = cX \sim \text{Exp}\left(\frac{\lambda}{c}\right)$

Demonstração: Seja para $y > 0$

$$\begin{aligned} F_Y(y) &= P(Y \leq y) = P(cX \leq y) = P\left(X \leq \frac{y}{c}\right) = \\ &= F_X\left(\frac{y}{c}\right) = 1 - e^{-\frac{\lambda}{c}y} \end{aligned}$$

uma vez que para $X \sim \text{Exp}(\lambda)$,

$$F_X(x) = 1 - e^{-\lambda x}, x > 0$$

5.5 Desigualdade de Chebychev*

Esta desigualdade permite relacionar probabilidades, relativas a uma qualquer v.a., discreta ou contínua, com os parâmetros μ e σ :

Proposição: Para qualquer v.a. X , com valor esperado μ e desvio padrão σ , verifica-se

$$P(|X - \mu| \geq c\sigma) \leq \frac{1}{c^2}$$

(só é útil para $c > 1$).

Exemplo:

c	$P(X - \mu \geq c\sigma)$ (qq v.a. X)
1.5	≤ 0.444
2	≤ 0.25
3	≤ 0.111
4	≤ 0.063

* Excepto para Probabilidades, Erros e Estatística

Estes valores são úteis se não conhecermos a distribuição da variável, mas podem ser muito pessimistas. Por exemplo para $X \sim N(\mu, \sigma^2)$, podem ser determinados exactamente e comparados com aqueles:

c	$P(X - \mu \geq c\sigma)$ $X \sim N(\mu, \sigma^2)$	$P(X - \mu \geq c\sigma)$ (qq v.a. X)
1.5	$= 0.1336$	≤ 0.444
2	$= 0.0456$	≤ 0.25
3	$= 0.0027$	≤ 0.111
4	$= 0.0001$	≤ 0.063

Demonstração: Considere-se a v.a. auxiliar Y , definida da seguinte forma

$$Y = \begin{cases} 1, & \text{se } |X - \mu| \geq c\sigma \\ 0, & \text{caso contrário} \end{cases}$$

Tem-se $E(Y) = 1 \times P(Y = 1) = P(|X - \mu| \geq c\sigma)$,

por outro lado como $y = 0$ ou $y = 1$, e pela definição de Y ,

$$(X - \mu)^2 \geq (X - \mu)^2 Y \text{ e } (X - \mu)^2 Y \geq c^2 \sigma^2 Y$$

Logo

$$\begin{aligned} E(X - \mu)^2 &\geq c^2 \sigma^2 E(Y) \Leftrightarrow \\ \Leftrightarrow \sigma^2 &\geq c^2 \sigma^2 P(|X - \mu| \geq c\sigma) \Leftrightarrow \\ \Leftrightarrow P(|X - \mu| &\geq c\sigma) \leq \frac{1}{c^2} \end{aligned}$$

5.6 Teorema do Limite Central

Este teorema justifica a grande utilidade e importância da distribuição normal.

T.L.C.: Se para todo o inteiro positivo n , X_1, \dots, X_n forem v.a. independentes e identicamente distribuídas com valor esperado μ e variância σ^2 , então para cada z , real, tem-se

$$\lim_{n \rightarrow \infty} P\left(\frac{\sum_{i=1}^n X_i - n\mu}{\sigma\sqrt{n}} \leq z\right) = \Phi(z)$$

Consequência: Para X_1, \dots, X_n nas mesmas condições e n grande verifica-se

$$P\left(a < \sum_{i=1}^n X_i < b\right) \cong \Phi\left(\frac{b - n\mu}{\sigma\sqrt{n}}\right) - \Phi\left(\frac{a - n\mu}{\sigma\sqrt{n}}\right)$$

Observações:

- A demonstração do teorema exige algumas ferramentas matemáticas avançadas.
- Como $E(X_i) = \mu$, $V(X_i) = \sigma^2$ e X_1, \dots, X_n são v.a. independentes tem-se

$$E\left(\sum_{i=1}^n X_i\right) = n\mu \quad \text{e} \quad V\left(\sum_{i=1}^n X_i\right) = n\sigma^2$$

pelo que

$$E\left(\frac{\sum_{i=1}^n X_i - n\mu}{\sigma\sqrt{n}}\right) = 0 \quad V\left(\frac{\sum_{i=1}^n X_i - n\mu}{\sigma\sqrt{n}}\right) = 1 \quad \forall_n$$

- As v.a. X_1, \dots, X_n podem ser discretas ou contínuas.
- A aproximação das distribuições Binomial e Poisson à distribuição normal (ver Capítulo 4), pode ser justificada por este teorema.
- Geralmente considera-se n grande se $n \geq 30$.

Exemplo: Suponha-se que ao adicionar números reais cada número é arredondado previamente para o inteiro mais próximo. Admita-se que os erros de arredondamento são v.a. independentes e identicamente distribuídas com distribuição uniforme contínua no intervalo $[-0.5; 0.5]$ (esta suposição é razoável se desconhecermos à partida tudo sobre os referidos números reais e admitirmos que também eles se distribuem uniformemente e independentemente nalgum intervalo)

a) Qual é a probabilidade de que, ao adicionar 1500 números, o valor absoluto do erro seja superior a 15?

Pode afirmar-se que o valor absoluto do erro está certamente compreendido entre 0 e 750, mas este valor é muito pessimista.

Considerem-se as v.a.

E_i - erro na parcela i

T - erro total $T = \sum_{i=1}^{1500} E_i$

Tem-se $E(E_i) = 0$ e $V(E_i) = \frac{(0.5 - (-0.5))^2}{12} = \frac{1}{12}$

$E(T) = 1500 \times 0 = 0$ $V(T) = \frac{1500}{12} = 125$

Pelo T.L.C. conclui-se que $T = \sum_{i=1}^{1500} E_i \overset{a}{\sim} N(0, 125)$

Logo

$$\begin{aligned} P(|T| > 15) &= 1 - P(|T| \leq 15) = 1 - P(-15 \leq T \leq 15) = \\ &= 1 - P\left(-\frac{15}{\sqrt{125}} \leq \frac{T}{\sqrt{125}} \leq \frac{15}{\sqrt{125}}\right) = \\ &= 1 - P\left(-1.34 \leq \frac{T}{\sqrt{125}} \leq 1.34\right) \cong \\ &\cong 1 - (\Phi(1.34) - \Phi(-1.34)) = \\ &= 1 - (0.9099 - 0.0901) = 0.1802 \end{aligned}$$

b) Quantos números podem ser somados (n) para que

$$P\left(\left|\sum_{i=1}^n E_i\right| < 10\right) \cong 0.9$$

$$T_n = \sum_{i=1}^n E_i \quad E(T_n) = 0 \quad V(T_n) = \frac{n}{12}$$

Pelo T.L.C. conclui-se que $T_n \overset{a}{\sim} N\left(0, \frac{n}{12}\right)$

$$P(-10 < T_n < 10) \cong \Phi\left(\frac{10}{\sqrt{n/12}}\right) - \Phi\left(\frac{-10}{\sqrt{n/12}}\right)$$

Como $\Phi(-x) = 1 - \Phi(x)$

$$\Phi\left(\frac{10}{\sqrt{n/12}}\right) - \left(1 - \Phi\left(\frac{10}{\sqrt{n/12}}\right)\right) = 0.9 \Leftrightarrow$$

$$\Leftrightarrow \Phi\left(\frac{10}{\sqrt{n/12}}\right) = 0.95 \Leftrightarrow \frac{10}{\sqrt{n/12}} = \Phi^{-1}(0.95) = 1.645$$

$$\Leftrightarrow \sqrt{n/12} = 6.079 \Leftrightarrow n = 12 \times 6.079^2 = 443.45$$

Resposta: $n \cong 443$

Pode-se "observar" o T.L.C. em "acção":

Exemplo: Vamos realizar a experiência do exercício anterior. Para isso seleccionamos totalmente ao acaso e de modo independente n números reais num dado intervalo e fazemos a diferença para o inteiro mais próximo (isto é equivalente a seleccionar aleatoriamente n "erros" ao acaso no intervalo $[-0.5;0.5]$), em seguida somam-se os n erros. Temos então uma observação de T_n .

Repetimos este processo 1000 vezes (isto pode ser feito em computador).


Em seguida construímos o histograma das frequências relativas das 1000 observações de

$$S_n = \frac{T_n - n\mu}{\sigma\sqrt{n}} = \frac{T_n}{\sqrt{n/12}}$$


e sobreposmo-lhe a densidade da distribuição $N(0,1)$

Resultados:

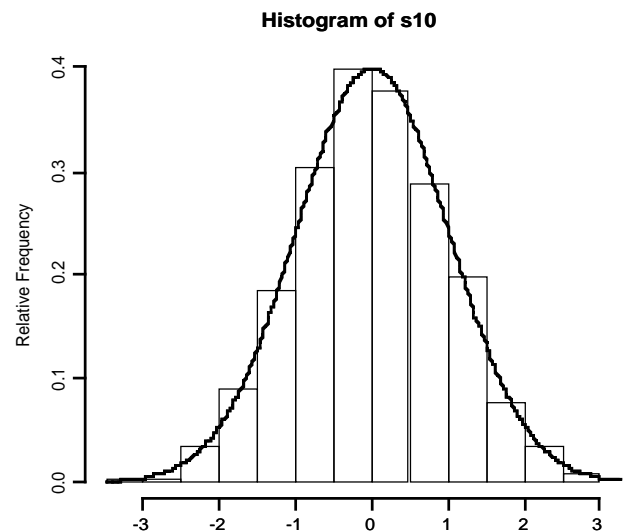
$n = 1$



$n = 5$



$n = 10$



A aproximação parece boa mesmo só com $n = 10$. (Uma explicação é que a distribuição de partida é simétrica e contínua)

Experimentemos com outra distribuição:

Exemplo: Seja $X_i \sim Exp(1)$, por exemplo, intervalo de tempo entre chegadas num processo de Poisson com taxa $\lambda = 1$. A v.a. $T_n = \sum_{i=1}^n X_i$ representa o intervalo de tempo até à n -ésima chegada. Vamos repetir o procedimento descrito no exemplo anterior. Ou seja, para cada n , obtemos 1000 observações de

$$S_n = \frac{T_n - n\mu}{\sigma\sqrt{n}} = \frac{T_n - n}{\sqrt{n}}$$


$$(\mu = E(X_i) = 1 \quad \sigma^2 = V(X_i) = 1)$$

Em seguida construímos o histograma das frequências relativas das 1000 observações de S_n e sobreposmo-lhe a densidade da distribuição $N(0,1)$.

Resultados:


$$n = 1$$

Histogram of se1




$$n = 5$$

Histogram of se5

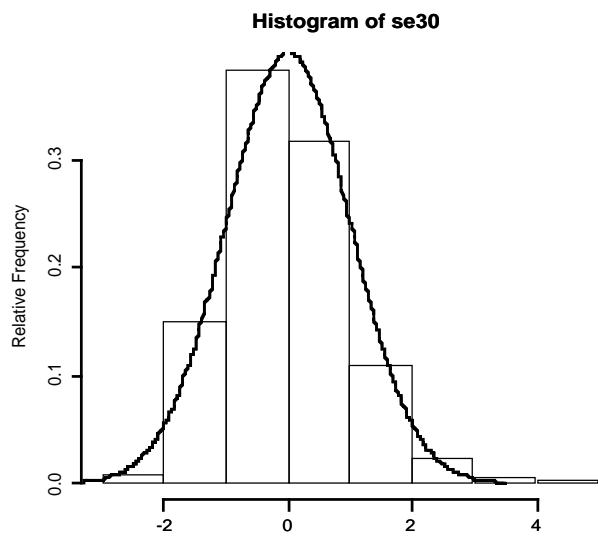


$$n = 20$$

Histogram of se20

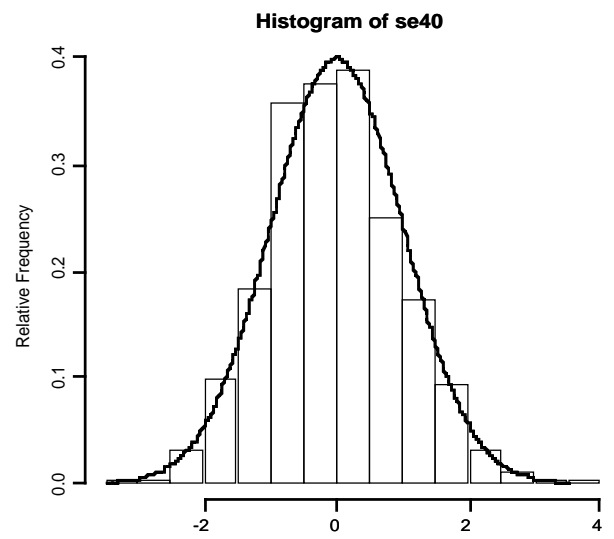


$n = 30$



45

$n = 40$



Aqui temos de ter n maior para que a aproximação comece a ser razoável.

46