

## 3. Campioni statistici

### 3.1 Introduzione

Scopo della statistica inferenziale è lo stabilire metodi rigorosi per ottenere – con un calcolabile *grado di certezza* proprietà generali di una popolazione a partire da una raccolta di dati sulla popolazione stessa.

Possiamo sintetizzare il modello matematico che applichiamo come segue

- Se rileviamo un carattere su una popolazione di  $n$  individui, consideriamo ciascun dato rilevato come il valore assunto da  $X_1, X_2, \dots, X_n$  variabili aleatorie aventi tutte la stessa distribuzione  $\mathbb{P}_X$  e che (molto spesso) si possono supporre indipendenti.
- La distribuzione  $\mathbb{P}_X$  è (parzialmente) incognita; si cercano informazioni su  $\mathbb{P}_X$  a partire dai dati rilevati. Le informazioni ricavate sulla distribuzione  $\mathbb{P}_X$  sono di natura probabilistica. Per esempio, non riusciremo ad ottenere informazioni del tipo *il valore atteso della distribuzione  $\mathbb{P}_X$  è 50* ma informazioni del tipo *il valore atteso della distribuzione  $\mathbb{P}_X$  è compresa tra 49.8 e 50.2 con probabilità del 90%*.

Comunemente si suppone di conoscere il *tipo* della distribuzione  $\mathbb{P}_X$ , ovvero si suppone di sapere se è gaussiana, esponenziale o binomiale o altro, ma di non conoscere i parametri che la caratterizzano.

**Definizione 3.1.1** (Campione statistico). Una famiglia di variabili aleatorie

$$X_1, \dots, X_n$$

si dice un *campione statistico di numerosità  $n$*  se le v.a.  $X_1, \dots, X_n$  sono indipendenti ed identicamente distribuite.

Se  $f: \mathbb{R} \rightarrow [0, +\infty]$  è la comune densità delle v.a.  $X_1, \dots, X_n$ , allora la v.a. vettoriale  $X := (X_1, \dots, X_n)$  ha densità congiunta

$$g_{X_1, \dots, X_n}(x_1, \dots, x_n) = f(x_1)f(x_2)\dots f(x_n).$$

La comune distribuzione delle  $X_i$  si dice *distribuzione campionaria di  $X_1, \dots, X_n$* .

**Osservazione 3.1.1.** Poiché le v.a.  $X_1, \dots, X_n$  seguono la stessa distribuzione, esse hanno anche lo stesso valore atteso e la stessa varianza (se queste quantità esistono).

**Definizione 3.1.2** (Statistica, stimatori). Sia  $X_1, \dots, X_n$  un campione statistico. Sia  $f: \mathbb{R}^n \rightarrow \mathbb{R}$  una funzione misurabile secondo Borel. Allora la v.a.  $Y := f(X_1, \dots, X_n)$  si dice una statistica del campione  $X_1, \dots, X_n$ .

Supponiamo ora di avere una successione  $(X_i)_{i \in \mathbb{N}}$  di v.a. i.i.d. e che per ogni  $n \in \mathbb{N}$  sia definita una statistica  $Y_n = f_n(X_1, \dots, X_n)$ . Se  $Y_n$  converge in probabilità ad una

v.a. costante con valore  $\lambda$ , dico che  $Y_n$  è uno *stimatore consistente in senso debole* di  $\lambda$ . Se  $Y_n$  converge quasi certamente ad una v.a. costante con valore  $\lambda$ , dico che  $Y_n$  è uno *stimatore consistente in senso forte* di  $\lambda$ .

Se  $Y_n$  è uno stimatore consistente di  $\lambda$  e se  $\mathbb{E}[Y_n] = \lambda$  per ogni  $n$ , dico che  $Y_n$  è uno *stimatore corretto* o uno *stimatore non distorto* di  $\lambda$ .

### 3.2 Media campionaria e varianza campionaria

**Definizione 3.2.1.** Sia  $X_1, \dots, X_n$  un campione statistico. Chiamiamo **media campionaria** di  $X_1, \dots, X_n$  la statistica

$$\bar{X} := \frac{1}{n} \sum_{i=1}^n X_i,$$

chiamiamo **varianza campionaria** di  $X_1, \dots, X_n$  la statistica

$$S^2 := \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2.$$

**Proposizione 3.2.1.** Sia  $X_1, \dots, X_n$  un campione statistico di numerosità  $n$  con valore atteso  $\mu$  e varianza  $\sigma^2$  finiti. Siano  $\bar{X}$  e  $S^2$  la media campionaria e la varianza campionaria. Allora

$$\mathbb{E}[\bar{X}] = \mu, \quad \text{Var}[\bar{X}] = \frac{\sigma^2}{n}, \quad \mathbb{E}[S^2] = \sigma^2.$$

*Dimostrazione.*

$$\begin{aligned} \mathbb{E}[\bar{X}] &= \mathbb{E}\left[\frac{1}{n} \sum_{i=1}^n X_i\right] = \frac{1}{n} \sum_{i=1}^n \mathbb{E}[X_i] = \frac{1}{n} n\mu = \mu \\ \text{Var}[\bar{X}] &= \text{Var}\left[\frac{1}{n} \sum_{i=1}^n X_i\right] = \frac{1}{n^2} \text{Var}\left[\sum_{i=1}^n X_i\right] = \frac{1}{n^2} \sum_{i=1}^n \text{Var}[X_i] = \frac{1}{n^2} n\sigma^2 = \frac{\sigma^2}{n}. \end{aligned}$$

Per calcolare il valore atteso di  $S^2$  osserviamo preliminarmente che

$$\begin{aligned} S^2 &= \frac{1}{n-1} \left( \sum_{i=1}^n X_i^2 - 2\bar{X} \sum_{i=1}^n X_i + \sum_{i=1}^n \bar{X}^2 \right) \\ &= \frac{1}{n-1} \left( \sum_{i=1}^n X_i^2 - 2\bar{X}n\bar{X} + n\bar{X}^2 \right) = \frac{1}{n-1} \left( \sum_{i=1}^n X_i^2 - n\bar{X}^2 \right). \end{aligned}$$

Dunque

$$\begin{aligned} (n-1)\mathbb{E}[S^2] &= \mathbb{E}\left[\sum_{i=1}^n X_i^2 - n\bar{X}^2\right] = \mathbb{E}\left[\sum_{i=1}^n (X_i - \mu + \mu)^2 - n(\bar{X} - \mu + \mu)^2\right] \\ &= \sum_{i=1}^n \mathbb{E}\left[(X_i - \mu + \mu)^2\right] - n\mathbb{E}\left[(\bar{X} - \mu + \mu)^2\right] \\ &= \sum_{i=1}^n \mathbb{E}\left[(X_i - \mu)^2 + \mu^2 + 2\mu(X_i - \mu)\right] - n\left(\mathbb{E}\left[(\bar{X} - \mu)^2\right] + \mu^2 + 2\mu\mathbb{E}[\bar{X} - \mu]\right) \end{aligned}$$

$$= \sum_{i=1}^n (\sigma^2 + \mu^2) - n \left( \frac{\sigma^2}{n} + \mu^2 \right) = (n-1) \sigma^2$$

e quindi  $\mathbb{E}[S^2] = \sigma^2$ . □

### 3.2.1 La disuguaglianza di Chebychev e la legge (debole) dei grandi numeri

Enunciamo alcuni importanti risultati asintotici che giustificano l'uso della media campionaria  $\bar{X}$  come stima del valore atteso  $\mu$  del campione.

**Teorema 3.2.1** (Disuguaglianza di Chebychev). *Se  $X$  è una variabile aleatoria con valore atteso  $\mu$  e varianza non superiore a  $\sigma^2$ , allora*

$$\mathbb{P}(|X - \mu| \geq t) \leq \frac{\sigma^2}{t^2} \quad \forall t > 0.$$

**Osservazione 3.2.1.** La disuguaglianza di Chebychev può anche essere formulata nel seguente modo: Se  $X$  è una variabile aleatoria con valore atteso  $\mu$  e varianza  $\sigma^2$  finite, allora

$$\mathbb{P}(|X - \mu| > \eta \sigma) \leq \frac{1}{\eta^2} \quad \forall \eta > 0.$$

Ovvero: la probabilità che  $X$  disti dal suo valore atteso  $\mu$  più di una frazione  $\eta$  della deviazione standard  $\sigma$  è inferiore a  $\frac{1}{\eta^2}$ .

**Esempio 3.2.1.** Sia  $X_1, \dots, X_n$  un campione statistico di numerosità  $n$ . Supponiamo di conoscere la varianza  $\sigma^2 = 4$  del campione e che il valore atteso  $\mu$  sia ignoto. Quanto deve essere grande  $n$  per poter affermare che

$$\mathbb{P}(|\bar{X} - \mu| > 1) \leq \frac{1}{10}?$$

Sappiamo che

$$\mathbb{P}(|\bar{X} - \mu| > 1) \leq \frac{\sigma^2}{n 1^2} = \frac{4}{n}.$$

è allora sufficiente richiedere  $\frac{4}{n} \leq \frac{1}{10}$  cioè  $n \geq 40$ .

Dalla disuguaglianza di Chebychev segue facilmente il seguente

**Teorema 3.2.2** (Legge debole dei grandi numeri). *Sia  $\{X_i\}_{i=1}^\infty$  una successione di v.a. indipendenti, identicamente distribuite, con valore atteso  $\mu$  e varianza  $\sigma^2$  finiti.*

*Per ogni  $n \in \mathbb{N}$  sia  $\bar{X}_n := \frac{1}{n} \sum_{i=1}^n X_i$ . Allora*

$$\lim_{n \rightarrow \infty} \mathbb{P}(|\bar{X}_n - \mu| > t) = 0 \quad \forall t > 0.$$

**Corollario 3.2.3.** *La media campionaria è uno stimatore corretto del valore atteso della distribuzione campionaria.*

*Dimostrazione.* Sia  $(X_i)_{i \in \mathbb{N}}$  una successione di v.a. i.i.d. con valore atteso  $\mu$  e varianza  $\sigma^2$ , entrambi finiti. Abbiamo già dimostrato che per ogni  $n \in \mathbb{N}$  la media campionaria  $\bar{X}_n$  del campione statistico  $X_1, \dots, X_n$  soddisfa le proprietà

$$\mathbb{E} [\bar{X}_n] = \mu, \quad \text{Var} [\bar{X}_n] = \frac{\sigma^2}{n}.$$

Applicando la legge debole dei grandi numeri otteniamo

$$\mathbb{P} (|\bar{X}_n - \mu| > \varepsilon) \leq \frac{\sigma^2}{n\varepsilon^2} \quad \forall \varepsilon > 0,$$

da cui la tesi. □

La legge debole dei grandi numeri ci *autorizza* a usare il valore di  $\bar{X}_n$  come sostituto del valore atteso  $\mu$  della distribuzione e la disuguaglianza di Chebychev ci dice con precisione quanto è *probabilisticamente accettabile* questa sostituzione.

**Esempio 3.2.2.** Ho una monetina che potrebbe essere truccata. Voglio scoprire, con un'approssimazione di  $\pm 0.05$  e con un grado di certezza del 90% quanto vale la probabilità di ottenere testa in un singolo lancio. Posso formalizzare ogni singolo lancio della monetina con una variabile aleatoria di Bernoulli di parametro  $p$  dove  $p$  è la probabilità (incognita) di ottenere testa in un singolo lancio. Se lancio la monetina  $n$  volte ho allora un campione statistico  $X_1, \dots, X_n$  che segue la distribuzione  $B(p)$ . Sia  $\bar{X}_n$  la media campionaria di questo campione. Allora

$$\mathbb{E} [\bar{X}_n] = p, \quad \text{Var} [\bar{X}_n] = \frac{p(1-p)}{n}.$$

Per la disuguaglianza di Chebychev

$$\mathbb{P} (|\bar{X}_n - p| \geq 0.05) \leq \frac{p(1-p)}{n(0.05)^2} \leq \frac{400}{4n} = \frac{100}{n}$$

Voglio

$$\mathbb{P} (|\bar{X}_n - p| \leq 0.05) \geq \frac{90}{100}$$

cioè

$$\mathbb{P} (|\bar{X}_n - p| \geq 0.05) \leq 1 - \frac{90}{100} = \frac{1}{10}$$

Basta allora avere  $\frac{100}{n} \leq \frac{1}{10}$  cioè  $n \geq 1000$ . Dunque: tiro la monetina 1000 volte registrando il risultato ad ogni  $i$ -esimo lancio ( $x_i = 1$ ) o croce ( $x_i = 0$ ) vedendo questo numero come il valore assunto da una v.a. bernoulliana  $X_i$  di parametro  $p$ .

Calcolo  $\bar{x} = \frac{1}{1000} \sum_{i=1}^{1000} x_i$  e lo vedo come il valore assunto dalla v.a.  $\bar{X}$ . La probabilità che il valore  $\bar{x}$  differisca da  $p$  per meno di 0.05 è maggiore-uguale del 90%.

Più in generale

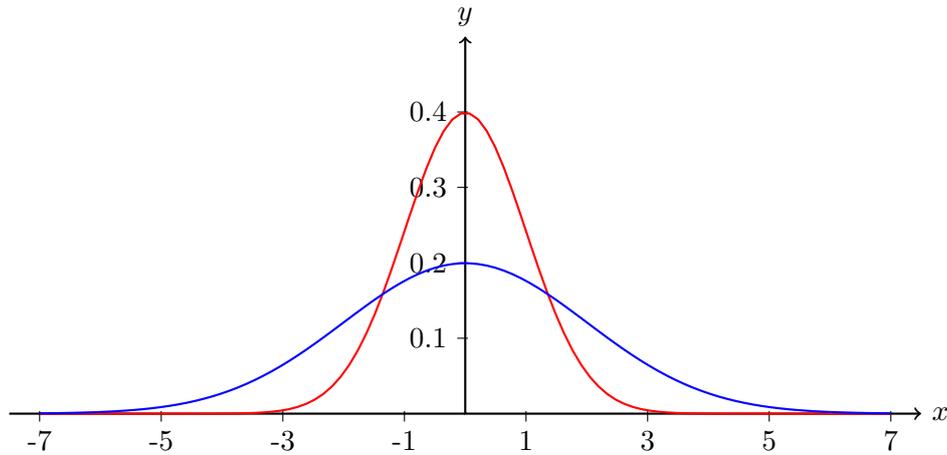


Figura 3.1: Densità associate alle distribuzioni  $N(0, 1)$  (in rosso) e  $N(0, 4)$  (in blu)

**Esempio 3.2.3.** Sia  $X_1, \dots, X_n$  un campione statistico di numerosità  $n$ , bernoulliano di parametro (incognito)  $p \in [0, 1]$ . Dunque

$$\begin{aligned} \mathbb{E}[X_i] &= p & \text{Var}[X_i] &= p(1-p) \\ \mathbb{E}[\bar{X}_n] &= p & \text{Var}[\bar{X}_n] &= \frac{p(1-p)}{n} \end{aligned}$$

Allora, per la disuguaglianza di Chebychev

$$\mathbb{P}(|\bar{X}_n - p| > \varepsilon) \leq \frac{p(1-p)}{n\varepsilon^2} \leq \frac{1}{4n\varepsilon^2} \quad \forall \varepsilon > 0.$$

poiché  $p(1-p) \leq \frac{1}{4} \quad \forall p \in [0, 1]$ .

### 3.2.2 La distribuzione gaussiana $N(\mu, \sigma^2)$ e il teorema del limite centrale

Ricordiamo che la distribuzione gaussiana di parametri  $\mu \in \mathbb{R}$  e  $\sigma^2 > 0$ ,  $N(\mu, \sigma^2)$ , è la distribuzione assolutamente continua associata alla densità

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right), \quad x \in \mathbb{R}.$$

Se una v.a.  $X$  segue la distribuzione  $N(\mu, \sigma^2)$ , allora

$$\mathbb{E}[X] = \mu, \quad \text{Var}[X] = \sigma^2.$$

Inoltre  $f(x) > 0$  per ogni  $x \in \mathbb{R}$ , quindi la funzione di ripartizione  $F_X(x) := \mathbb{P}(X \leq x)$  è strettamente monotona crescente. Dunque, per ogni  $\alpha \in (0, 1)$  esiste uno ed un solo  $x = x_\alpha \in \mathbb{R}$  tale  $F_X(x_\alpha) = \alpha$ .  $x_\alpha$  si dice **quantile** di  $X$  di livello  $\alpha$ . Inoltre, se  $\mu = 0$ , la densità è una funzione pari, e dunque  $F_X(t) + F_X(-t) = 1$  per ogni  $t \in \mathbb{R}$ ; in particolare  $x_{1-\alpha} = -x_\alpha$ .

Nel caso in cui  $\mu = 0$ ,  $\sigma^2 = 1$ , la distribuzione  $N(0, 1)$  si dice *distribuzione gaussiana standard*, la funzione di ripartizione associata si indica con la lettera  $\Phi$ ,

$$\Phi(x) := \int_{-\infty}^x \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{t^2}{2}\right) dt, \quad x \in \mathbb{R}.$$

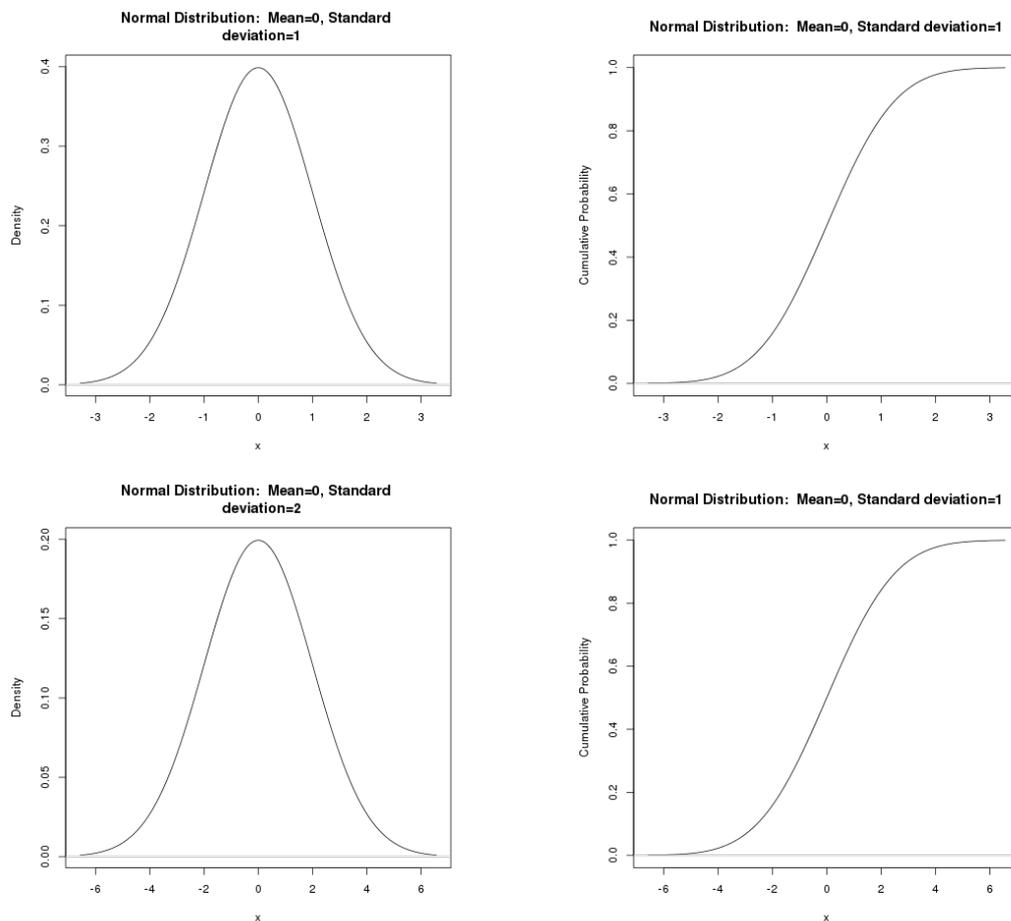


Figura 3.2:  $N(0, 1)$  e  $N(0, 4)$ , densità e funzione di ripartizione

e per ogni  $\alpha \in (0, 1)$  il quantile di livello  $\alpha$  si indica  $z_\alpha$ . Dunque

$$\Phi(x) + \Phi(-x) = 1 \quad \forall x \in \mathbb{R}, \quad z_{1-\alpha} = -z_\alpha \quad \forall \alpha \in (0, 1).$$

Ricordiamo alcune proprietà che abbiamo già visto:

**Proprietà 3.2.1.** 1. Se  $X$  è una v.a. gaussiana di valore atteso  $\mu$  e varianza  $\sigma^2$ :  $\mathbb{P}_X = N(\mu, \sigma^2)$  e  $\alpha, \beta$  sono due numeri reali,  $\alpha \neq 0$ , allora la v.a.  $\alpha X + \beta$  è gaussiana di valore atteso  $\alpha\mu + \beta$  e varianza  $\alpha^2\sigma^2$ :  $\mathbb{P}_{\alpha X + \beta} = N(\alpha\mu + \beta, \alpha^2\sigma^2)$ . In particolare  $Y := \frac{X - \mu}{\sigma}$  è una v.a. gaussiana standard:  $\mathbb{P}_Y = N(0, 1)$ .

2. Siano  $X_1, \dots, X_n$  v.a. indipendenti con  $X_i$  gaussiana di valore atteso  $\mu_i$  e varianza  $\sigma_i^2$ :  $\mathbb{P}_{X_i} = N(\mu_i, \sigma_i^2) \forall i = 1, \dots, n$ . Allora la v.a.  $S_n := X_1 + X_2 + \dots + X_n$  è gaussiana di valore atteso pari alla somma dei valori attesi e varianza pari alla somma delle varianze:

$$\mathbb{P}_{S_n} = N\left(\sum_{i=1}^n \mu_i, \sum_{i=1}^n \sigma_i^2\right)$$

**Teorema 3.2.4** (Teorema centrale del limite). *Sia  $(X_i)_{i=1}^{\infty}$  una successione di v.a. indipendenti, identicamente distribuite, con valore atteso  $\mu$  e varianza  $\sigma^2$  finiti. Sia  $\Phi(t)$  la legge associata alla distribuzione gaussiana standard  $N(0, 1)$ .*

*Per ogni  $n \in \mathbb{N}$  sia  $\bar{X}_n$  la media campionaria di  $X_1, \dots, X_n$  e sia  $\bar{Z}_n$  la sua standardizzazione:*

$$\bar{Z}_n := \frac{\bar{X}_n - \mu}{\frac{\sigma}{\sqrt{n}}}.$$

Allora

$$\lim_{n \rightarrow \infty} \mathbb{P}(\bar{Z}_n \leq t) = \Phi(t) \quad \forall t \in \mathbb{R}$$

ed il limite è uniforme in  $t \in \mathbb{R}$ .

**Osservazione 3.2.2.** Una formulazione equivalente della tesi del teorema del limite centrale è

$$\lim_{n \rightarrow \infty} \mathbb{P}\left(\frac{\sum_{i=1}^n X_i - n\mu}{\sigma\sqrt{n}} \leq t\right) = \Phi(t) \quad \forall t \in \mathbb{R}.$$

**Esempio 3.2.4.** Supponiamo di avere un campione statistico di numerosità 25 e deviazione standard 8. Qual è la probabilità che la media campionaria differisca dal valore atteso del campione per più di 4?

Devo calcolare

$$\mathbb{P}(|\bar{X} - \mu| > 4)$$

dove  $\mu = \mathbb{E}[X_i] \quad \forall i = 1, \dots, n$  e dunque è anche  $\mu = \mathbb{E}[\bar{X}]$ . Applicando la disuguaglianza di Chebychev otteniamo

$$\mathbb{P}(|\bar{X} - \mu| > 4) \leq \frac{\text{Var}[\bar{X}]}{4^2} = \frac{64}{25 \cdot 16} = \frac{4}{25} = 0.16$$

Proviamo ad applicare il teorema del limite centrale. Indico con  $\bar{Z}$  la standardizzazione della media campionaria. Si ha

$$\begin{aligned} \mathbb{P}(|\bar{X} - \mu| > 4) &= \mathbb{P}\left(\frac{|\bar{X} - \mu|}{\frac{\sigma}{\sqrt{n}}} > \frac{4}{\frac{\sigma}{\sqrt{n}}}\right) = \mathbb{P}\left(|\bar{Z}| > \frac{4}{\frac{8}{\sqrt{25}}}\right) = \\ &= \mathbb{P}\left(|\bar{Z}| > \frac{5}{2}\right) = \mathbb{P}\left(\bar{Z} > \frac{5}{2}\right) + \mathbb{P}\left(\bar{Z} < -\frac{5}{2}\right) \\ &\simeq 1 - \Phi(2.5) + \Phi(-2.5) = 2(1 - \Phi(2.5)) \\ &= 2(1 - \Phi(2.5)) \simeq 2(1 - 0.9938) = 0.0124 \end{aligned}$$

Perché questa stima *sembra* tanto migliore di quella ottenuta con la disuguaglianza di Chebychev? Perché non abbiamo un'indicazione sul significato del primo dei  $\simeq$ . In altre parole, il teorema del limite centrale è appunto un teorema di passaggio al limite e non fornisce una stima dell'errore che si compie sostituendo  $\mathbb{P}(Z_n \leq t)$  con  $\Phi(t)$ . A tal proposito vale il seguente

**Teorema 3.2.5** (Teorema di Berry–Esseen). *Sia  $\{X_i\}_{i=1}^{\infty}$  una successione di v.a. indipendenti, identicamente distribuite, con valore atteso  $\mu = 0$ , varianza  $\sigma^2$  e momento terzo*

$\gamma := \mathbb{E} [|X_i|^3]$  finiti. Sia  $\Phi(t)$  la funzione di ripartizione associata alla distribuzione gaussiana standard  $N(0, 1)$ .

Sia  $C := \frac{0.8\gamma}{\sigma^3}$ . Allora

$$\left| \mathbb{P} \left( \frac{\bar{X}_n}{\frac{\sigma}{\sqrt{n}}} \leq t \right) - \Phi(t) \right| \leq \frac{C}{\sqrt{n}} \quad \forall t \in \mathbb{R}.$$

Dal Teorema di Berry–Esseen, teorema 3.2.5, otteniamo dunque

$$|\mathbb{P}(\bar{Z}_n \leq t) - \Phi(t)| \leq \frac{C}{\sqrt{n}} \quad \forall t \in \mathbb{R}.$$

### 3.3 Alcune distribuzioni legate alla distribuzione gaussiana

La prima distribuzione che incontreremo sarà la distribuzione di Pearson che è un caso particolare di distribuzione  $\Gamma$ . Ricordiamo dunque tali distribuzioni.

**Definizione 3.3.1.** Chiamo distribuzione Gamma di parametri  $\alpha$  e  $\lambda$  entrambi reali strettamente positivi e indico con il simbolo  $\Gamma(\alpha, \lambda)$ , la distribuzione assolutamente continua associata alla densità

$$f(x) = \begin{cases} \frac{\lambda^\alpha}{\Gamma(\alpha)} x^{\alpha-1} \exp(-\lambda x) & x > 0, \\ 0 & x \leq 0, \end{cases} \quad (3.1)$$

dove  $\Gamma(\alpha) := \int_0^{+\infty} x^{\alpha-1} e^{-x} dx$ ,  $\alpha > 0$ .

**Osservazione 3.3.1.** Verifichiamo che la funzione  $f$  definita in (3.1) è una densità di probabilità. Sicuramente  $f(x) \geq 0$  per ogni  $x \in \mathbb{R}$ . Inoltre

$$\begin{aligned} \int_{\mathbb{R}} f(x) dx &= \int_0^{+\infty} \frac{\lambda^\alpha}{\Gamma(\alpha)} x^{\alpha-1} \exp(-\lambda x) dx \quad (\text{con il cambio di variabile } x = \frac{y}{\lambda}) \\ &= \frac{\lambda^\alpha}{\Gamma(\alpha)} \int_0^{+\infty} \frac{1}{\lambda^\alpha} y^{\alpha-1} e^{-y} dy = \frac{1}{\Gamma(\alpha)} \Gamma(\alpha) = 1. \end{aligned}$$

**Osservazione 3.3.2.**  $f(x) > 0$  per ogni  $x \in (0, +\infty)$  dunque, se  $\mathbb{P}_X = \Gamma(\alpha, \lambda)$ , allora  $X$  è distribuita su tutta la semiretta  $(0, +\infty)$ .

**Osservazione 3.3.3.** Per  $\alpha = 1$  otteniamo  $\Gamma(1) = \int_0^{+\infty} e^{-x} dx = 1$ , dunque

$$f(x) = \begin{cases} \lambda \exp(-\lambda x) & x > 0, \\ 0 & x \leq 0, \end{cases}$$

ovvero  $\Gamma(1, \lambda) = \exp(-\lambda x)$  per ogni  $\lambda > 0$ .

**Osservazione 3.3.4.** Per ogni  $a > 0$  si ha  $\Gamma(a + 1) = a\Gamma(a)$ . Infatti

$$\Gamma(a + 1) = \int_0^{+\infty} x^a e^{-x} dx$$

per parti:  $f(x) = x^a$ ,  $g'(x) = e^{-x}$

$$= -x^a e^{-x} \Big|_{x=0}^{x \rightarrow +\infty} + \int_0^{+\infty} a x^{a-1} e^{-x} dx = 0 + a\Gamma(a).$$

Poiché  $\Gamma(1) = 1$  otteniamo, per induzione  $\Gamma(n) = (n - 1)!$

Inoltre  $\Gamma\left(\frac{1}{2}\right) = \sqrt{\pi}$ . Infatti (con la sostituzione  $x = y^2$ )

$$\Gamma\left(\frac{1}{2}\right) = \int_0^{+\infty} x^{-1/2} e^{-x} dx = \int_0^{+\infty} 2 e^{-y^2} dy = \int_{\mathbb{R}} e^{-y^2} dy = \sqrt{\pi}.$$

Quindi

$$\Gamma\left(\frac{3}{2}\right) = \frac{1}{2}\Gamma\left(\frac{1}{2}\right) = \frac{1}{2}\sqrt{\pi}, \quad \Gamma\left(\frac{5}{2}\right) = \frac{3}{2}\Gamma\left(\frac{3}{2}\right) = \frac{3 \cdot 1}{2 \cdot 2}\sqrt{\pi} = \frac{3!!}{2^2}\sqrt{\pi},$$

$$\dots \text{ per induzione } \dots \quad \Gamma\left(\frac{2n+1}{2}\right) = \frac{(2n-1)!!}{2^n}\sqrt{\pi} \quad \text{per ogni intero non-negativo } n.$$

Siamo dunque in grado di calcolare  $\Gamma\left(\frac{n}{2}\right)$  per ogni  $n \in \mathbb{N}$ .

**Proposizione 3.3.1.** *Se  $X$  è una v.a. con distribuzione  $\mathbb{P}_X = \Gamma(\alpha, \lambda)$ , allora*

$$\mathbb{E}[X] = \frac{\alpha}{\lambda}, \quad \text{Var}[X] = \frac{\alpha}{\lambda^2}.$$

*Dimostrazione.* Poiché  $X$  è distribuita solo sui reali positivi,  $\mathbb{E}[X]$  è ben definito e

$$\begin{aligned} \mathbb{E}[X] &= \int_{\mathbb{R}} x f(x) dx = \int_0^{+\infty} \frac{\lambda^\alpha}{\Gamma(\alpha)} x^\alpha \exp(-\lambda x) dx \\ &= \frac{\lambda^\alpha}{\Gamma(\alpha)} \frac{\Gamma(\alpha+1)}{\lambda^{\alpha+1}} \int_0^{+\infty} \frac{\lambda^{\alpha+1}}{\Gamma(\alpha+1)} x^{(\alpha+1)-1} \exp(-\lambda x) dx = \frac{1}{\Gamma(\alpha)} \frac{\alpha\Gamma(\alpha)}{\lambda} \cdot 1 = \frac{\alpha}{\lambda}. \end{aligned}$$

Analogamente

$$\begin{aligned} \mathbb{E}[X^2] &= \int_{\mathbb{R}} x^2 f(x) dx = \int_0^{+\infty} \frac{\lambda^\alpha}{\Gamma(\alpha)} x^{\alpha+1} \exp(-\lambda x) dx \\ &= \frac{\lambda^\alpha}{\Gamma(\alpha)} \frac{\Gamma(\alpha+2)}{\lambda^{\alpha+2}} \int_0^{+\infty} \frac{\lambda^{\alpha+2}}{\Gamma(\alpha+2)} x^{(\alpha+2)-1} \exp(-\lambda x) dx = \frac{1}{\Gamma(\alpha)} \frac{(\alpha+1)\alpha\Gamma(\alpha)}{\lambda^2} \cdot 1 = \frac{(\alpha+1)\alpha}{\lambda^2}. \end{aligned}$$

$$\text{Dunque } \text{Var}[X] = \frac{(\alpha+1)\alpha}{\lambda^2} - \left(\frac{\alpha}{\lambda}\right)^2 = \frac{\alpha}{\lambda^2}. \quad \square$$

**Lemma 3.3.1.** *Se  $X$  e  $Y$  sono due variabili aleatorie indipendenti, con distribuzioni  $\mathbb{P}_X = \Gamma(\alpha, \lambda)$ ,  $\mathbb{P}_Y = \Gamma(\beta, \lambda)$ , allora la v.a.  $X + Y$  ha distribuzione  $\Gamma(\alpha + \beta, \lambda)$ .*

*Dimostrazione.* Sappiamo che la distribuzione di  $X + Y$  è a.c. con densità  $h(x)$  data dal prodotto di convoluzione delle densità associate alle distribuzioni  $\Gamma(\alpha, \lambda)$  e  $\Gamma(\beta, \lambda)$ . Dunque  $h(x) = 0$  per  $x \leq 0$ . Per  $x > 0$  abbiamo invece

$$\begin{aligned} h(x) &= \int_0^x \frac{\lambda^\alpha}{\Gamma(\alpha)} y^{\alpha-1} e^{-\lambda y} \frac{\lambda^\beta}{\Gamma(\beta)} (x-y)^{\beta-1} e^{-\lambda(x-y)} dy \\ &= e^{-\lambda x} \frac{\lambda^{\alpha+\beta}}{\Gamma(\alpha)\Gamma(\beta)} \int_0^x y^{\alpha-1} (x-y)^{\beta-1} dy = \quad (\text{sostituisco } y = xt) \\ &= e^{-\lambda x} \frac{\lambda^{\alpha+\beta} x^{\alpha+\beta-1}}{\Gamma(\alpha)\Gamma(\beta)} \int_0^1 t^{\alpha-1} (1-t)^{\beta-1} dt = C x^{\alpha+\beta-1} e^{-\lambda x} \end{aligned}$$

dove  $C = \frac{\lambda^{\alpha+\beta}}{\Gamma(\alpha)\Gamma(\beta)} \int_0^1 t^{\alpha-1} (1-t)^{\beta-1} dt$ . Poiché  $h$  deve essere una densità di probabilità può solo essere  $C = \frac{\lambda^{\alpha+\beta}}{\Gamma(\alpha + \beta)}$ . □

### 3.3.1 Distribuzione di Pearson (o $\chi^2$ ) con $n$ gradi di libertà, $\chi_n^2$

Si tratta della distribuzione  $\Gamma(\alpha, \lambda)$  dove  $\alpha = \frac{n}{2}$ ,  $\lambda = \frac{1}{2}$ . È dunque la distribuzione assolutamente continua associata alla densità

$$f(x) := \begin{cases} \frac{1}{\Gamma(\frac{n}{2})} \left(\frac{1}{2}\right)^{\frac{n}{2}} x^{\frac{n}{2}-1} \exp\left(-\frac{x}{2}\right) & x > 0, \\ 0 & x \leq 0. \end{cases}$$

**Proprietà 3.3.1.** Se  $X$  è una v.a. con distribuzione  $\chi^2$  a  $n$  gradi di libertà,  $\mathbb{P}_X = \chi_n^2$ , allora

$$\mathbb{E}[X] = n, \quad \text{Var}[X] = 2n.$$

*Dimostrazione.* Poiché una v.a. con distribuzione  $\Gamma(\alpha, \lambda)$  ha valore atteso  $\alpha/\lambda$  e varianza  $\alpha/\lambda^2$ , in particolare per una v.a. con distribuzione di Pearson abbiamo

$$\mathbb{E}[X] = \frac{\frac{n}{2}}{\frac{1}{2}} = n, \quad \text{Var}[X] = \frac{\frac{n}{2}}{\left(\frac{1}{2}\right)^2} = 2n.$$

□

**Teorema 3.3.2.** Se  $X$  e  $Y$  sono due variabili di Pearson indipendenti,  $\mathbb{P}_X = \chi_n^2$ ,  $\mathbb{P}_Y = \chi_k^2$ , allora la v.a.  $X + Y$  segue la distribuzione di Pearson a  $n + k$  gradi di libertà:

$$\mathbb{P}_{X+Y} = \chi_{n+k}^2.$$

*Dimostrazione.* Scegliendo  $\alpha = \frac{n}{2}$ ,  $\beta = \frac{k}{2}$ ,  $\lambda = \frac{1}{2}$  nel Lemma 3.3.1, si ottiene la tesi. □

Il seguente teorema dà un legame tra la distribuzione gaussiana e le distribuzioni  $\chi^2$ :

**Teorema 3.3.3.** Se  $X$  è una v.a. gaussiana standard,  $\mathbb{P}_X = N(0, 1)$ , allora  $X^2$  segue la distribuzione di Pearson ad un grado di libertà,  $\mathbb{P}_{X^2} = \chi_1^2$ .

*Dimostrazione.* Sappiamo che  $\mathbb{P}_X = N(0, 1) = f(x)dx$  con  $f(x) = \frac{1}{\sqrt{2\pi}}e^{-x^2/2}$ . Dunque  $\mathbb{P}_{X^2} = g(x)dx$  con

$$g(x) = \begin{cases} 0 & x \leq 0, \\ \frac{1}{2\sqrt{x}}(f(\sqrt{x}) + f(-\sqrt{x})) & x > 0, \end{cases} = \begin{cases} 0 & x \leq 0, \\ \frac{1}{\sqrt{2\pi}}x^{-1/2}e^{-x/2} & x > 0, \end{cases}$$

cioè  $\mathbb{P}_{X^2} = \chi_1^2$ . □

**Teorema 3.3.4.** *Se  $X_1, \dots, X_n$  sono v.a. indipendenti e gaussiane, con  $X_i$  di valore atteso  $\mu_i$  e varianza  $\sigma_i^2, \forall i = 1, \dots, n$ , allora la v.a.  $\sum_{i=1}^n \left(\frac{X_i - \mu_i}{\sigma_i}\right)^2$  segue la distribuzione di Pearson a  $n$  gradi di libertà,  $\chi_n^2$ .*

*Dimostrazione.* Poiché la v.a.  $\frac{X_i - \mu_i}{\sigma_i}$  ha distribuzione gaussiana standard, applicando i teoremi 3.3.3 e 3.3.2 ed il principio di induzione si ottiene la tesi. □

**Corollario 3.3.5.** *Se  $X_1, \dots, X_n$  è un campione statistico gaussiano, con valore atteso  $\mu$  e varianza  $\sigma^2$ , allora la v.a.  $\sum_{i=1}^n \left(\frac{X_i - \mu}{\sigma}\right)^2$  segue una distribuzione  $\chi^2$  con  $n$  gradi di libertà.*

**Esempio 3.3.1.** Si vuole localizzare un oggetto puntiforme, misurandone le tre coordinate cartesiane rispetto ad un prefissato sistema di riferimento. L'errore sperimentale, misurato in millimetri per ciascuna delle tre coordinate è una v.a. gaussiana di valore atteso 0 e deviazione standard 2.

Supponendo che i tre errori siano v.a. indipendenti, calcolare la probabilità che la distanza tra la posizione misurata e la posizione reale sia inferiore a 1.2 mm.

*Soluzione.* Indico con  $X_1, X_2, X_3$ , gli errori commessi nella misurazione delle tre coordinate. Per il Teorema di Pitagora la distanza tra le due posizioni è

$$D = \sqrt{X_1^2 + X_2^2 + X_3^2}$$

Vogliamo calcolare  $\mathbb{P}(D < 1.2) = \mathbb{P}(D^2 < 1.44) = \mathbb{P}(X_1^2 + X_2^2 + X_3^2 < 1.44)$ .

Pongo  $Z_i := \frac{X_i}{\sigma} = \frac{X_i}{2}, i = 1, 2, 3$ , da cui  $X_i^2 = 4Z_i^2$  e dunque

$$\begin{aligned} \mathbb{P}(D < 1.2) &= \mathbb{P}(X_1^2 + X_2^2 + X_3^2 < 1.44) = \mathbb{P}(4(Z_1^2 + Z_2^2 + Z_3^2) < 1.44) \\ &= \mathbb{P}(Z_1^2 + Z_2^2 + Z_3^2 < .36). \end{aligned}$$

Basterà dunque controllare (vedi ultima riga del listato a seguire) il valore della funzione di ripartizione delle v.a. di distribuzione  $\chi_3^2$  nel punto 0.36 che è (circa) 0.052.

```
> setwd("/home/laura/Documents/didattica/2017-18_analisi_reale/alcuni_appunti")
> .x <- seq(0.015, 18.015, length.out=100)
> plot(.x, dchisq(.x, df=3), xlab="x", ylab="Density",
+ main=paste("ChiSquared Distribution: Degrees of freedom=3"), type="l")
> plot(.x, pchisq(.x, df=3), xlab="x", ylab="Density",
```

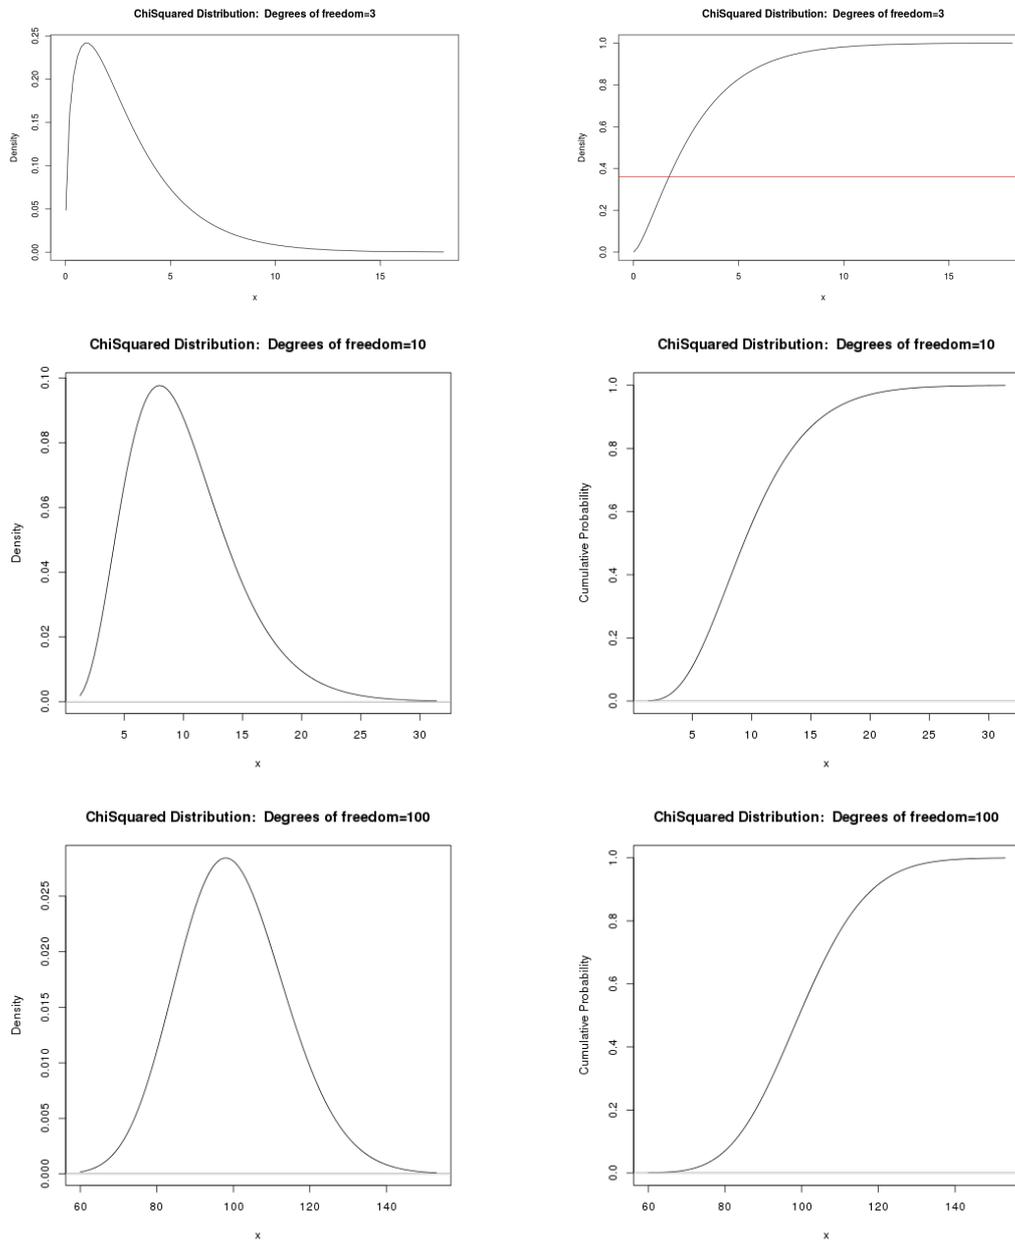


Figura 3.3:  $\chi_3^2$ ,  $\chi_{10}^2$  e  $\chi_{100}^2$ , densità e funzione di ripartizione

```
+ main=paste("ChiSquared Distribution: Degrees of freedom=3"), type="l")
> abline(h=0.36, col="red")
> pchisq(c(0.36), df=3, lower.tail=TRUE)
[1] 0.05162424
```

Il seguente teorema raccoglie alcune importanti proprietà dei campioni statistici gaussiani e delle loro media e varianza campionarie.

**Teorema 3.3.6.** *Sia  $X_1, \dots, X_n$  un campione statistico gaussiano di numerosità  $n$ , valore atteso  $\mu$  e varianza  $\sigma^2$ .*

*Allora, la media campionaria  $\bar{X}$  e la varianza campionaria  $S^2$  sono v.a. indipendenti.*

*Sia  $Z_1, Z_2, \dots, Z_n$  la standardizzazione del campione statistico  $X_1, \dots, X_n$  i.e.*

$$Z_i := \frac{X_i - \mu}{\sigma} \quad \forall i = 1, \dots, n$$

e sia  $\bar{Z}$  la media campionaria del campione normalizzato  $Z_1, \dots, Z_n$ .

Allora  $\bar{Z} = \frac{\bar{X} - \mu}{\sigma}$  e la v.a.  $\sum_{i=1}^n (Z_i - \bar{Z})^2$  sono indipendenti e quest'ultima segue una distribuzione  $\chi^2$  con  $n - 1$  gradi di libertà.

*Dimostrazione.* **1. n = 2.** Sappiamo che  $\mathbb{P}_{X_1+X_2} = N(2\mu, 2\sigma^2)$  e  $\mathbb{P}_{\bar{X}} = N(\mu, \sigma^2/2)$ . Inoltre

$$S^2 = (X_1 - \bar{X})^2 + (X_2 - \bar{X})^2 = \frac{1}{2}(X_1 - X_2)^2.$$

Dunque  $\bar{X}$  e  $S^2$  sono indipendenti se e solo se  $X_1 + X_2$  e  $X_1 - X_2$  sono indipendenti. Poiché  $\mathbb{P}_{-X_2} = N(-\mu, \sigma^2)$  abbiamo che  $\mathbb{P}_{X_1-X_2} = N(0, 2\sigma^2)$ .

Per provare che  $U := X_1 + X_2$  e  $V := X_1 - X_2$  sono indipendenti ne calcoliamo la densità congiunta e mostriamo che è uguale al prodotto delle densità marginali. Abbiamo già visto che  $\mathbb{P}_{X_1+X_2} = N(2\mu, 2\sigma^2)$ . Inoltre, poiché  $\mathbb{P}_{-X_2} = N(-\mu, \sigma^2)$  abbiamo che  $\mathbb{P}_{X_1-X_2} = N(0, 2\sigma^2)$ . Posto

$$\varphi: (x, y) \in \mathbb{R}^2 \mapsto (x + y, x - y) \in \mathbb{R}^2$$

abbiamo

$$(U, V) = \varphi \circ (X_1, X_2)$$

dunque, per ogni funzione boreliana non-negativa  $\psi: \mathbb{R}^2 \rightarrow \mathbb{R}$  abbiamo

$$\begin{aligned} \int_{\mathbb{R}^2} \psi(u, v) \mathbb{P}_{U, V}(dudv) &= \int_{\mathbb{R}^2} \psi(x + y, x - y) \mathbb{P}_{X_1, X_2}(dxdy) \\ &= \int_{\mathbb{R}^2} \psi(x + y, x - y) \frac{1}{2\pi\sigma^2} \exp\left(-\frac{(x - \mu)^2}{2\sigma^2}\right) \exp\left(-\frac{(y - \mu)^2}{2\sigma^2}\right) dx dy \end{aligned}$$

con il cambiamento di variabile  $u = x + y, v = x - y$

$$= \int_{\mathbb{R}^2} \psi(u, v) \frac{1}{2\pi(\sqrt{2}\sigma)^2} \exp\left(-\frac{(u - 2\mu)^2}{2(\sqrt{2}\sigma)^2}\right) \exp\left(-\frac{v^2}{2(\sqrt{2}\sigma)^2}\right) dudv$$

ovvero la densità congiunta è il prodotto delle densità marginali

$$f_{X_1+X_2}(u) = \frac{1}{\sqrt{2\pi(\sqrt{2}\sigma)^2}} \exp\left(-\frac{(u - 2\mu)^2}{2(\sqrt{2}\sigma)^2}\right), \quad f_{X_1-X_2}(v) = \frac{1}{\sqrt{2\pi(\sqrt{2}\sigma)^2}} \exp\left(-\frac{v^2}{2(\sqrt{2}\sigma)^2}\right).$$

Inoltre, se  $Z_1$  e  $Z_2$  sono gaussiane standard indipendenti abbiamo:

$$(Z_1 - \bar{Z})^2 + (Z_2 - \bar{Z})^2 = \frac{1}{2}(Z_1 - Z_2)^2 = \left( \frac{Z_1 - Z_2}{\sqrt{2}} \right)^2.$$

La v.a.  $Z_1 - Z_2$  ha distribuzione  $N(0, 2)$ , dunque  $\frac{Z_1 - Z_2}{\sqrt{2}}$  ha distribuzione  $N(0, 1)$ . Applicando il Teorema 3.3.3 otteniamo la tesi.

**2.  $n \geq 3$ .** Procediamo per induzione, supponendo che  $\bar{X}_{n-1}$  e  $S_{n-1}^2$  siano indipendenti. Osserviamo che

$$\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i = \frac{1}{n} ((n-1)\bar{X}_{n-1} + X_n) = \frac{n-1}{n} \bar{X}_{n-1} + \frac{1}{n} X_n \quad (3.2)$$

e dunque

$$\bar{X}_n - \bar{X}_{n-1} = \frac{1}{n} (X_n - \bar{X}_{n-1}).$$

Abbiamo dunque

$$\begin{aligned} S_n^2 &= \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_{n-1} + \bar{X}_{n-1} - \bar{X}_n)^2 \\ &= \frac{1}{n-1} \left( \sum_{i=1}^n (X_i - \bar{X}_{n-1})^2 + 2 \sum_{i=1}^n (\bar{X}_{n-1} - \bar{X}_n) (X_i - \bar{X}_{n-1}) + \sum_{i=1}^n (\bar{X}_{n-1} - \bar{X}_n)^2 \right) \\ &= \frac{1}{n-1} \left( (n-2)S_{n-1}^2 + (X_n - \bar{X}_{n-1})^2 + 2(\bar{X}_{n-1} - \bar{X}_n) n (\bar{X}_n - \bar{X}_{n-1}) + n(\bar{X}_{n-1} - \bar{X}_n)^2 \right) \\ &= \frac{1}{n-1} \left( (n-2)S_{n-1}^2 + (X_n - \bar{X}_{n-1})^2 - \frac{2}{n} (X_n - \bar{X}_{n-1}) (X_n - \bar{X}_{n-1}) + \frac{1}{n} (X_n - \bar{X}_{n-1})^2 \right) \\ &= \frac{1}{n-1} \left( (n-2)S_{n-1}^2 + \frac{n-1}{n} (X_n - \bar{X}_{n-1})^2 \right) \quad (3.3) \end{aligned}$$

Per la (3.2) e l'ipotesi di induzione  $\bar{X}_n$  è indipendente da  $S_{n-1}^2$ . Avremo dunque che  $S_n^2$  e  $\bar{X}_n$  sono indipendenti se e solo se  $\bar{X}_n$  e  $X_n - \bar{X}_{n-1}$  sono indipendenti.

Sappiamo che  $\mathbb{P}_{X_n} = N\left(\mu, \frac{\sigma^2}{n}\right)$ , dunque

$$\mathbb{P}_{\bar{X}_n} = N\left(\mu, \frac{\sigma^2}{n}\right), \quad \mathbb{P}_{\bar{X}_{n-1}} = N\left(\mu, \frac{\sigma^2}{n-1}\right), \quad \mathbb{P}_{X_n - \bar{X}_{n-1}} = N\left(0, \sigma^2 \frac{n}{n-1}\right),$$

Devo provare che  $U := \frac{n-1}{n} \bar{X}_{n-1} + \frac{1}{n} X_n$  e  $V = X_n - \bar{X}_{n-1}$  sono indipendenti. Osserviamo che

$$(U, V) = \varphi \circ (\bar{X}_{n-1}, X_n), \quad \varphi(x, y) = \left( \frac{n-1}{n}x + \frac{1}{n}y, y - x \right).$$

Sia dunque  $\psi: \mathbb{R}^2 \rightarrow \mathbb{R}$  una funzione di Borel non negativa. Abbiamo

$$\begin{aligned} \int_{\mathbb{R}^2} \psi(u, v) \mathbb{P}_{U, V}(dudv) &= \int_{\mathbb{R}^2} \psi\left(\frac{n-1}{n}x + \frac{1}{n}y, y - x\right) \mathbb{P}_{\bar{X}_{n-1}, X_n} dx dy \\ &= \int_{\mathbb{R}^2} \psi\left(\frac{n-1}{n}x + \frac{1}{n}y, y - x\right) \frac{\sqrt{n-1}}{2\pi\sigma^2} \exp\left(\frac{-(n-1)(x-\mu)^2 - (y-\mu)^2}{2\sigma^2}\right) dx dy \end{aligned}$$

con il cambiamento di variabile  $u = \frac{n-1}{n}x + \frac{1}{n}y$ ,  $v = y - x$

$$\begin{aligned} &= \int_{\mathbb{R}^2} \psi(u, v) \frac{\sqrt{n-1}}{2\pi\sigma^2} \exp\left(\frac{-(u-\mu)^2(\sqrt{n})^2}{2\sigma^2}\right) \exp\left(\frac{-v^2\left(\sqrt{\frac{n-1}{n}}\right)^2}{2\sigma^2}\right) dudv \\ &= \int_{\mathbb{R}^2} \psi(u, v) \frac{1}{\sqrt{2\pi\frac{\sigma^2}{n}}} \exp\left(\frac{-(u-\mu)^2}{2\left(\frac{\sigma}{\sqrt{n}}\right)^2}\right) \frac{1}{\sqrt{2\pi\sigma^2\frac{n}{n-1}}} \exp\left(\frac{-v^2}{2\left(\sigma\sqrt{\frac{n-1}{n}}\right)^2}\right) dudv \end{aligned}$$

ovvero la densità congiunta è il prodotto delle densità marginali. Questo prova l'indipendenza di  $U$  e  $V$  e dunque la prima parte della tesi.

Per dimostrare la seconda parte della tesi, osserviamo che essa è sicuramente vera per  $n-1$ , grazie al Teorema 3.3.3. Procediamo per induzione e riconsideriamo ora la formula (3.3) e supponiamo che essa non sia relativa al campione  $X_1, \dots, X_n$  ma alla sua versione standardizzata  $Z_1, \dots, Z_n$ :

$$\sum_{i=1}^n (Z_i - \bar{Z}_n)^2 = (n-1)S_n^2 = (n-2)S_{n-1}^2 + \left(\sqrt{\frac{n-1}{n}}(Z_n - \bar{Z}_{n-1})\right)^2.$$

Poiché il campione  $Z_1, \dots, Z_n$  è gaussiano standard,  $\mathbb{P}_{Z_n - \bar{Z}_{n-1}} = N\left(0, \frac{n}{n-1}\right)$  dunque la

v.a.  $\sqrt{\frac{n-1}{n}}(Z_n - \bar{Z}_{n-1})$  è gaussiana standard e quindi il suo quadrato segue una distribuzione di Pearson con un grado di libertà. D'altra parte, per induzione,  $\sum_{i=1}^{n-1} (Z_i - \bar{Z}_{n-1})^2 = (n-2)S_{n-1}^2(Z)$  segue una distribuzione di Pearson a  $n-2$  gradi di libertà. Per il Teorema 3.3.2 otteniamo la tesi.  $\square$

**Corollario 3.3.7.** *Sia  $X_1, \dots, X_n$  un campione statistico gaussiano di numerosità  $n$ , valore atteso  $\mu$  e varianza  $\sigma^2$  e sia  $S^2$  la sua varianza campionaria. Allora la v.a.  $V := (n-1)\frac{S^2}{\sigma^2}$  segue una distribuzione  $\chi^2$  con  $n-1$  gradi di libertà.*

*Dimostrazione.* Si ha infatti

$$V = (n-1)\frac{S^2}{\sigma^2} = \frac{1}{\sigma^2} \sum_{i=1}^n (X_i - \bar{X})^2 = \frac{1}{\sigma^2} \sum_{i=1}^n ((\mu + \sigma Z_i) - (\mu + \sigma \bar{Z}))^2 = \sum_{i=1}^n (Z_i - \bar{Z})^2$$

$\square$

### 3.3.2 Distribuzione $t$ di Student con $n$ gradi di libertà, $t(n)$

Si chiama così la distribuzione associata alla densità

$$\tau_n(x) = \frac{\Gamma\left(\frac{n+1}{2}\right)}{\Gamma\left(\frac{n}{2}\right)\sqrt{n\pi}} \left(1 + \frac{x^2}{n}\right)^{-\frac{(n+1)}{2}} \quad x \in \mathbb{R}.$$

**Proprietà 3.3.2.** Se  $X$  è una v.a. con distribuzione  $t$  di Student a  $n$  gradi di libertà, allora

$$\mathbb{E}[X] = 0, \quad \text{Var}[X] = \begin{cases} \frac{n}{n-2} & \text{se } n \geq 3, \\ +\infty & \text{se } n = 1, 2. \end{cases}$$

**Osservazione 3.3.5.** Il quantile di livello  $\alpha \in (0, 1)$  associato alla distribuzione  $t(n)$  si indica  $t_{n,\alpha}$ . Poiché la densità  $\tau_n$  è una funzione pari, se  $\mathbb{P}_X = t(n)$ , allora  $F_X(x) + F_X(-x) = 1$ . Dunque per i quantili della distribuzione  $t(n)$  si ha  $t_{n,\alpha} = -t_{n,1-\alpha}$  per ogni  $\alpha \in (0, 1)$ .

**Teorema 3.3.8.** Se  $Z$  è una v.a. gaussiana standard,  $\mathbb{P}_Z = N(0, 1)$ , se  $Y$  segue la distribuzione  $\chi^2$  con  $n$  gradi di libertà,  $\mathbb{P}_Y = \chi_n^2$  e se  $Z$  e  $Y$  sono indipendenti, allora la v.a.  $T := \frac{Z\sqrt{n}}{\sqrt{Y}}$  segue la distribuzione  $t$  di Student a  $n$  gradi di libertà:  $\mathbb{P}_T = t(n)$ .

*Dimostrazione.* Possiamo scrivere  $T = \varphi \circ (Y, Z)$  dove  $\varphi: (y, z) \in \mathbb{R}^2 \mapsto \begin{cases} \frac{z\sqrt{n}}{y} & y > 0 \\ 0 & y \leq 0 \end{cases} \in \mathbb{R}$ .

Sia dunque  $\psi: \mathbb{R} \rightarrow \mathbb{R}$  una funzione di Borel non negativa.

$$\begin{aligned} \int_{\mathbb{R}} \psi(t) \mathbb{P}_T(dt) &= \int_{y>0, z \in \mathbb{R}} \psi\left(\frac{z\sqrt{n}}{\sqrt{y}}\right) \mathbb{P}_{Y,Z}(dydz) \\ &= \int_{y>0, z \in \mathbb{R}} \psi\left(\frac{z\sqrt{n}}{\sqrt{y}}\right) \frac{1}{\sqrt{2n\pi}} \frac{1}{\Gamma\left(\frac{n}{2}\right)} \left(\frac{1}{2}\right)^{\frac{n}{2}} y^{\frac{n}{2}-1} \exp\left(\frac{-y}{2}\right) \exp\left(\frac{-z^2}{2}\right) dydz \end{aligned}$$

con il cambio di variabile  $t = \frac{z\sqrt{n}}{\sqrt{y}}$ ,  $z = \frac{t\sqrt{y}}{\sqrt{n}}$ ,  $dz = \frac{\sqrt{y}}{\sqrt{n}} dt$ ,

$$= \int_{\mathbb{R}} \psi(t) \frac{1}{\sqrt{2n\pi}} \frac{1}{\Gamma\left(\frac{n}{2}\right)} \left(\frac{1}{2}\right)^{\frac{n}{2}} \left(\int_0^{+\infty} y^{\frac{1}{2}} y^{\frac{n}{2}-1} \exp\left(\frac{-y}{2}\right) \exp\left(\frac{-yt^2}{2n}\right) dy\right) dt$$

con il cambio di variabile  $u = \frac{y}{2} \left(1 + \frac{t^2}{n}\right)$ ,  $y = 2u \left(1 + \frac{t^2}{n}\right)^{-1}$ ,  $dy = 2 \left(1 + \frac{t^2}{n}\right)^{-1} du$ ,

$$\begin{aligned} &= \int_{\mathbb{R}} \psi(t) \frac{1}{\sqrt{2n\pi}} \frac{1}{\Gamma\left(\frac{n}{2}\right)} \left(\frac{1}{2}\right)^{\frac{n}{2}} \left(\int_0^{+\infty} (2u)^{\frac{n+1}{2}-1} \exp(-u) \left(1 + \frac{t^2}{n}\right)^{\frac{-(n+1)}{2}} du\right) dt \\ &= \int_{\mathbb{R}} \psi(t) \frac{1}{\sqrt{2n\pi}} \frac{1}{\Gamma\left(\frac{n}{2}\right)} \left(\frac{1}{2}\right)^{\frac{n}{2}} \left(1 + \frac{t^2}{n}\right)^{\frac{-(n+1)}{2}} \Gamma\left(\frac{n+1}{2}\right) dt \end{aligned}$$

da cui la tesi. □

**Corollario 3.3.9.** Se  $X_1, \dots, X_n$  è un campione statistico gaussiano di numerosità  $n$ , valore atteso  $\mu$  e varianza  $\sigma^2$ , allora

$$T := \frac{(\bar{X} - \mu) \sqrt{n}}{S}$$

segue la distribuzione  $t$  di Student con  $n - 1$  gradi di libertà:  $\mathbb{P}_T = t(n - 1)$ .

*Dimostrazione.* Basta applicare il teorema 3.3.8 con  $Z = \frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}}$  e  $Y = V = (n - 1) \frac{S^2}{\sigma^2}$ . □

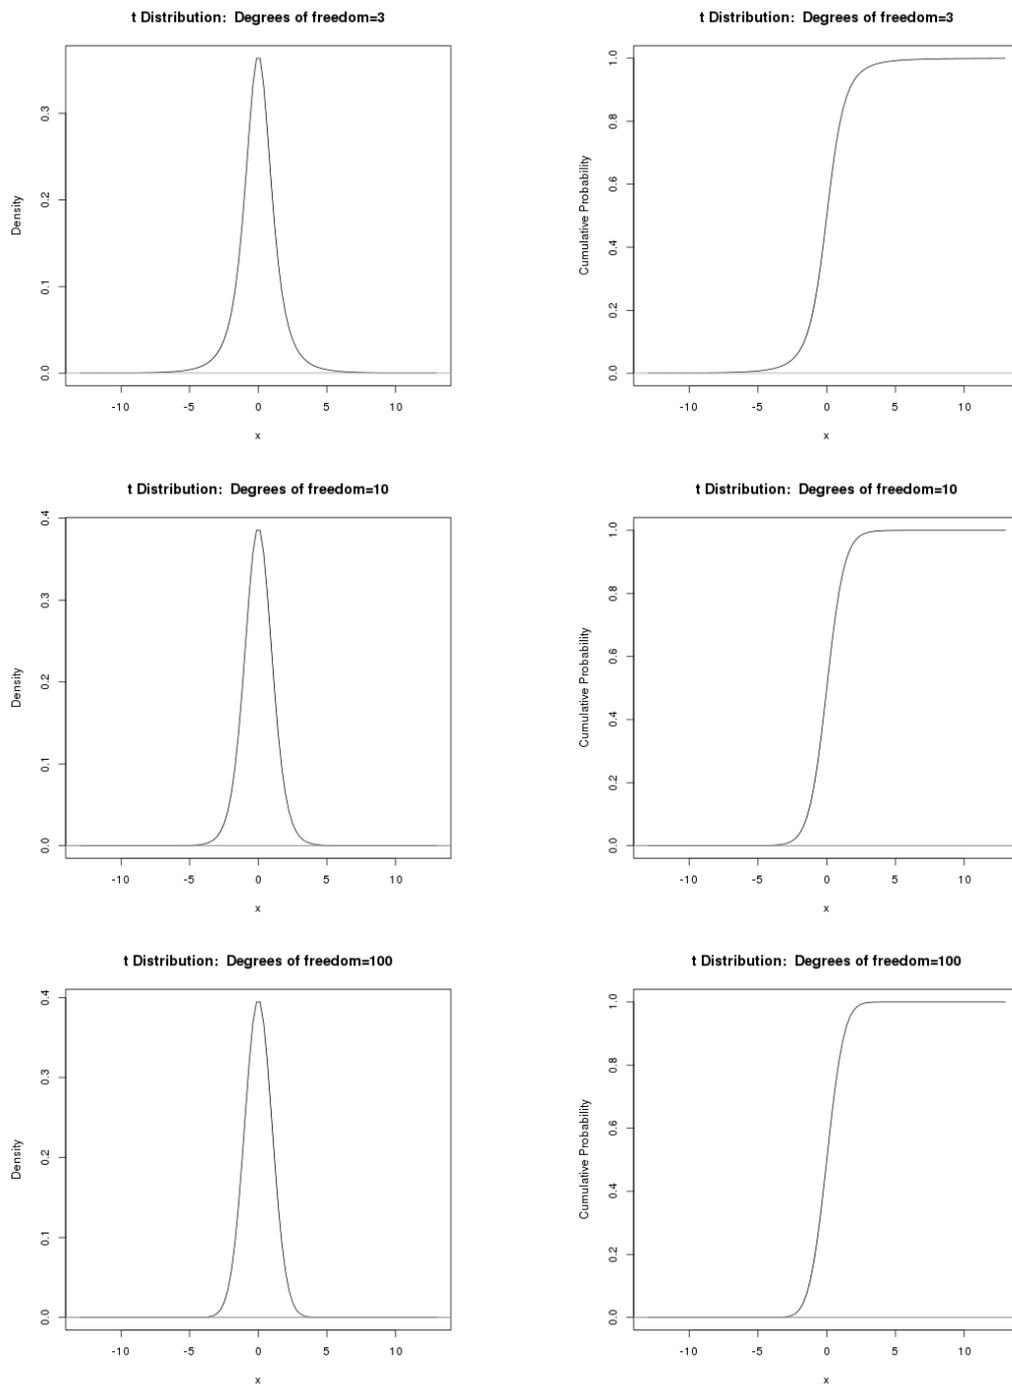


Figura 3.4:  $t(3)$ ,  $t(10)$ ,  $t(100)$ , densità e funzione di ripartizione