

## Statistica descrittiva

### indici

#### indici (o misure) di posizione

media campionaria di  $n$  osservazioni  $x_1, x_2, \dots, x_n$

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$$

per  $k$  campioni  $x_i$  ripetuti ciascuno con frequenza  $f_i$

$$\bar{x} = \frac{1}{n} \sum_{i=1}^k x_i f_i$$

#### proprietà

Posto  $y_i = a x_i + b$  :  $\bar{y} = a \bar{x}$

#### mediana $m$ di $n$ osservazioni $x_1 \leq x_2 \leq \dots \leq x_n$

se  $n$  è dispari:  $m = x_{(n+1)/2}$

se  $n$  è pari:  $m = \frac{x_{n/2} + x_{(n/2)+1}}{2}$

#### moda

punto di massimo della distribuzione di frequenza  
una distribuzione con un solo punto di massimo è detta unimodale  
una distribuzione con più punti di massimo è detta plurimodale

### indici di dispersione

#### varianza di $n$ osservazioni $x_1, x_2, \dots, x_n$

$$\sigma^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$$

per  $k$  campioni  $x_i$  ripetuti ciascuno con frequenza  $f_i$

$$\sigma^2 = \frac{1}{n} \sum_{i=1}^k (x_i - \bar{x})^2 f_i = \left( \frac{1}{n} \sum_{i=1}^k x_i^2 f_i \right) - (\bar{x})^2$$

#### proprietà

posto  $y_i = a x_i + b$  :  $\sigma_y^2 = a^2 \sigma_x^2$

#### deviazione standard o scarto quadratico medio

$$\sigma = \sqrt{\sigma^2}$$

#### range di $n$ osservazioni $x_1 \leq x_2 \leq \dots \leq x_n$

differenza tra massima e minima osservazione

$$range = x_n - x_1$$

#### p-esimo quantile (o 100p-esimo percentile) di $n$ osservazioni $x_1 \leq x_2 \leq \dots \leq x_n$

$p \in \mathbb{R}(0,1)$ , si considera il numero  $np$

se  $np$  non è intero:  $k$  è l'intero successivo,  $Q_p = x_k$

se  $np$  è intero:  $k = np$ ,  $Q_p = \frac{x_k + x_{k+1}}{2}$

#### quartili

$Q_1$  primo quartile: quantile per  $p = 0.25$

$Q_2$  secondo quartile: quantile per  $p = 0.5$  (= mediana)

$Q_3$  terzo quartile: quantile per  $p = 0.75$

#### differenza interquartile (IQR – InterQuartile Range)

$$IQR = Q_3 - Q_1$$

### indici di forma

#### coefficiente di asimmetria (skewness)

$$sk = \frac{1}{n} \sum_{i=1}^n \left( \frac{x_i - \bar{x}}{\sigma} \right)^3$$

se vale zero indica che la distribuzione è simmetrica rispetto alla media  
se positivo denota una coda verso destra  
se negativo denota una coda verso sinistra

#### coefficiente di curtosi

$$curt = \frac{1}{n} \sum_{i=1}^n \left( \frac{x_i - \bar{x}}{\sigma} \right)^4$$

misura quanto la distribuzione è appuntita

### correlazioni

#### covarianza

di  $n$  osservazioni congiunte di 2 variabili  $\{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$ :

$$\sigma_{xy} = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) = \left( \frac{1}{n} \sum_{i=1}^n x_i y_i \right) - \bar{x} \bar{y}$$

se  $\sigma_{xy} > 0$   $x$  e  $y$  sono direttamente correlate: a valori grandi (piccoli) di  $x$  corrispondono valori grandi (piccoli) di  $y$ ;

se  $\sigma_{xy} < 0$   $x$  e  $y$  sono inversamente correlate: a valori grandi (piccoli) di  $x$  corrispondono valori piccoli (grandi) di  $y$ ;

se  $\sigma_{xy} = 0$   $x$  e  $y$  sono incorrelate;

#### coefficiente di correlazione

$$\rho_{xy} = \frac{\sigma_{xy}}{\sigma_x \sigma_y} ; -1 \leq \rho_{xy} \leq 1$$

indice normalizzato, adimensionale ed invariante per trasformazioni lineari delle variabili

#### regressione lineare

retta  $y = \hat{a}x + \hat{b}$  che meglio approssima la nuvola di punti  $(x_i, y_i)$

$$\hat{a} = \frac{\sigma_{xy}}{\sigma_x^2} ; \hat{b} = \bar{y} - \bar{x} \frac{\sigma_{xy}}{\sigma_x^2}$$

#### valori stimati

$$\hat{y}_i = \hat{a}x_i + \hat{b}$$

rappresentano i valori stimati di  $y$  a partire dalla retta di regressione lineare

#### residui

$$r_i = y_i - \hat{y}_i$$

differenza tra i valori reali e stimati

#### valore previsto

$$\hat{y}_0 = \hat{a}x_0 + \hat{b}$$

$x_0$  è un valore diverso dai valori  $x_i$  già osservati

#### cambiamento di scala

$$\log(y) = \hat{a} \log(x) + \hat{b}$$

$$y = e^{\hat{b}} x^{\hat{a}}$$

#### devianza totale

$$DEV_{TOT} = DEV_{REG} + DEV_{RES} = \sum_{i=1}^n (y_i - \bar{y})^2$$

$$DEV_{REG} = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 ; DEV_{RES} = \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

#### coefficiente di determinazione

$$R^2 = \frac{DEV_{REG}}{DEV_{TOT}} = 1 - \frac{DEV_{RES}}{DEV_{TOT}} = \frac{\sigma_{\hat{y}}^2}{\sigma_y^2} ; 0 \leq R^2 \leq 1$$

tanto più esso si avvicina ad uno tanto più la funzione di regressione trovata è buona.

## Probabilità

### definizioni

#### eventi elementari

tutti i possibili esiti di un esperimento aleatorio

#### evento

ogni sottoinsieme di uno spazio campionario discreto  $\Omega$

#### spazio campionario

insieme di tutti gli eventi elementari; può essere:

##### discreto

se gli elementi sono un numero finito o un'infinità numerabile

$$P(\{\omega_k\}) = p_k$$

##### continuo

se è più numeroso (ad esempio: tutti i numeri reali in un certo intervallo)

#### linguaggio

insiemi	eventi
$\Omega$ , intero spazio campionario	evento certo
$\emptyset$ , insieme vuoto	evento impossibile
insieme $A$	l'evento si verifica
insieme $\bar{A}$ complementare di $A$	l'evento non si verifica
$A \cup B$ , (unione)	si verifica almeno uno dei due eventi
$A \cap B$ , (intersezione)	gli eventi si verificano simultaneamente
$A \setminus B$ , (sottrazione = $A \cap \bar{B}$ )	si verifica $A$ e non si verifica $B$
$A \cap B = \emptyset$ , eventi disgiunti	gli eventi sono incompatibili
$B \subseteq A$ ( $B$ incluso in $A$ )	$B$ implica $A$

#### proprietà eventi A, B, C sottoinsiemi di $\Omega$

$$A \cup A = A$$

$$A \cap A = A$$

$$A \cup B = B \cup A$$

$$A \cap B = B \cap A$$

$$A \cup (B \cap C) = (A \cup B) \cap C$$

$$A \cap (B \cup C) = (A \cap B) \cup C$$

$$A \cup (B \cap C) = (A \cup B) \cap (A \cup C)$$

$$A \cap (B \cup C) = (A \cap B) \cup (A \cap C)$$

$$A \cup \emptyset = A$$

$$A \cap \emptyset = \emptyset$$

$$A \cup \Omega = \Omega$$

$$A \cap \Omega = A$$

$$A \cup \bar{A} = \Omega$$

$$A \cap \bar{A} = \emptyset$$

$$(A \cup B) \cap \bar{C} = \bar{C} \cap (A \cup B)$$

$$(A \cap B) \cup \bar{C} = \bar{C} \cup (A \cap B)$$

$$(\bar{A}) = A$$

#### probabilità su $\Omega$

$$P: P(\Omega) \rightarrow [0,1]$$

#### proprietà

$$P(\Omega) = 1$$

$$P(\emptyset) = 0$$

$$P(\bar{A}) = 1 - P(A)$$

$$P(A \cup B) = P(A) + P(B) - P(A \cap B)$$

$$P\left(\bigcup_{n=1}^{\infty} A_n\right) = \sum_{n=1}^{\infty} P(A_n), \text{ con } A_i \cap A_j = \emptyset \text{ se } i \neq j$$

#### probabilità classica

la probabilità di un evento è il rapporto dei casi favorevoli ed il numero dei casi possibili

posto  $\Omega$  di  $N$  elementi  $\omega_k$  ( $k = 1, 2, \dots, N$ ) e

$$P(\{\omega_k\}) = p, \text{ (eventi elementari equiprobabili)}, A \text{ evento qualunque}$$

qualunque

$$P(A) = \sum_{\omega_k \in A} P(\{\omega_k\}) = p|A| = \frac{|A|}{N} = \frac{|A|}{|\Omega|}$$

$|A|$  è il numero di elementi di  $A$

#### permutazione di $n$ oggetti

è ogni allineamento di  $n$  oggetti distinti in  $n$  caselle

$$P_n = n! = n(n-1)(n-2) \dots 3 \cdot 2$$

#### proprietà di $n!$ (n fattoriale)

$$0! = 1$$

$$\frac{n!}{n} = (n-1)!$$

$$\frac{n!}{m!} = n(n-1)(n-2) \dots (m+1), \text{ con } m < n$$

#### disposizione di $n$ oggetti in $k$ posti

è ogni allineamento di  $k$  oggetti scelti tra  $n$  oggetti distinti in  $k$  posti

$$D_{n,k} = n(n-1)(n-2) \dots (n-k+1), \text{ con } 1 \leq k \leq n$$

$$D_{n,n} = P_n = n!$$

#### disposizione con ripetizione di $n$ oggetti in $k$ posti

è ogni allineamento di  $k$  oggetti scelti tra  $n$  oggetti e ripetibili, in  $k$  posti

$$D_{n,k}^* = n^k, \text{ con } k \geq 1$$

#### combinazione di $n$ oggetti di classe $k$

è ogni sottoinsieme di  $k$  elementi dell'insieme di  $n$  oggetti (modi per scegliere  $k$  oggetti tra  $n$ )

$$C_{n,k} = \frac{D_{n,k}}{P_k} = \binom{n}{k} = \frac{n(n-1)(n-2) \dots (n-k+1)}{k!}, \text{ con } n \geq 1; 0 \leq k \leq n$$

#### coefficiente Binomiale

$$\binom{n}{k} = \binom{n}{n-k} = C_{n,k}; \binom{n}{1} = n; \binom{n}{0} = \binom{n}{n} = 1$$

#### combinazione con ripetizione di $k$ oggetti scelti fra $n$

ogni gruppo formato di  $k$  oggetti scelti fra  $n$ , che possono essere ripetuti (modi per disporre  $k$  oggetti uguali in  $n$  posti)

$$C_{n,k}^* = \binom{n+k-1}{k} = \binom{n+k-1}{n-1}$$

#### permutazione con ripetizione di $n$ oggetti uguali fra loro a gruppi

(allineamento in  $n$  posti di  $n$  oggetti)

$$P_{k_1, k_2, \dots, k_r}^* = \frac{n!}{k_1! k_2! \dots k_r!}$$

## probabilità condizionata

### probabilità dell'evento A, condizionata a B

$$P(A|B) = \frac{P(A \cap B)}{P(B)}$$

#### proprietà

$$P(A \cap B) = P(B \cap A) = P(A|B)P(B) = P(B|A)P(A)$$

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)}$$

$$P(\bar{A}|B) = 1 - P(A|B)$$

#### probabilità totali

$$P(A) = \sum_{j=1}^n P(A|B_j) \cdot P(B_j),$$

con  $\cup_{j=1}^n B_j = \Omega$ ,  $B_i \cap B_j = \emptyset$  per  $i \neq j$ ,  $P(B_j) \neq 0$  per ogni  $j$   
caso notevole:

$$P(A) = P(A|B)P(B) + P(A|\bar{B})P(\bar{B}),$$

con  $\{B, \bar{B}\}$  partizione di  $\Omega$

#### formula di Bayes

$$P(B_k|A) = \frac{P(A|B_k)P(B_k)}{\sum_{j=1}^n P(A|B_j) \cdot P(B_j)}, \text{ per ogni } k$$

## indipendenza di eventi

### eventi A, B indipendenti

lo sono se soddisfano una delle seguenti condizioni

$$P(A \cap B) = P(A) \cdot P(B)$$

$$P(A|B) = P(A)$$

$$P(B|A) = P(B)$$

### famiglia di eventi indipendenti

$n$  eventi  $A_1, A_2, \dots, A_n$  costituiscono una famiglia di eventi indipendenti se per ogni sottofamiglia di  $r$  eventi ( $2 \leq r \leq n$ ), la probabilità di intersezione di questi  $r$  eventi è uguale al prodotto delle probabilità di ciascuno di essi:

$$P(A_i \cap A_j) = P(A_i)P(A_j), \text{ per ogni coppia di indici } i \neq j$$

$$P(A_i \cap A_j \cap \dots \cap A_n) = P(A_i)P(A_j) \dots P(A_n)$$

data una famiglia di eventi indipendenti, anche sostituendo alcuni  $A_i$  con i complementari  $\bar{A}_i$ , rimane una famiglia di eventi indipendenti.

## Affidabilità di un sistema

### componenti in serie

il sistema funziona se e solo se funzionano tutti i componenti

#### affidabilità (probabilità che il sistema funzioni)

$$a = a_1 \cdot a_2 \cdot \dots \cdot a_n$$

### componenti in parallelo

il sistema funziona se e solo se funziona almeno un componente

#### affidabilità (probabilità che il sistema funzioni)

$$a = 1 - (1 - a_1) \cdot (1 - a_2) \cdot \dots \cdot (1 - a_n)$$

## variabili aleatorie e modelli probabilistici

### variabili aleatorie

#### variabile aleatoria (v.a.) discreta

è una qualunque funzione:

$$X: \Omega \rightarrow \mathbb{R}$$

$(X \in I)$ , con  $I \subseteq \mathbb{R}$  è un'abbreviazione di  $\{\omega \in \Omega: X(\omega) \in I\}$

#### legge (o distribuzione) di una v.a.

applicazione che associa ad ogni intervallo  $I \subseteq \mathbb{R}$  il numero:

$$P(X \in I) = P\{\omega \in \Omega: X(\omega) \in I\}$$

#### densità discreta di X

funzione che ad ogni valore assunto da X associa la probabilità che X assuma quel valore

$$p_X(x_k) = P(X = x_k)$$

#### proprietà

probabilità dell'evento  $X \in I$ :

$$P(X \in I) = \sum_{x_k \in I} p_X(x_k), \text{ purché la serie converga}$$

#### v.a. indipendenti

se scelti  $n$  intervalli  $I_1, I_2, \dots, I_n \subseteq \mathbb{R}$  si ha

$$P(X_1 \in I_1, X_2 \in I_2, \dots, X_n \in I_n) = P(X_1 \in I_1) \cdot P(X_2 \in I_2) \cdot \dots \cdot P(X_n \in I_n)$$

#### valore atteso, o media, o speranza matematica

$$\mu_X = EX = \sum_k x_k p_X(x_k), \text{ per } X \text{ discreta}$$

$$\mu_X = EX = \int_{\mathbb{R}} t \cdot f_X(t) dt, \text{ per } X \text{ continua}$$

#### proprietà

$$E(aX + b) = a(EX) + b, \text{ con } a, b \in \mathbb{R}$$

$$E(X_1 + X_2 + \dots + X_n) = EX_1 + EX_2 + \dots + EX_n$$

$$E(X_1 \cdot X_2 \cdot \dots \cdot X_n) = EX_1 \cdot EX_2 \cdot \dots \cdot EX_n,$$

con  $X_1, X_2, \dots, X_n$  v.a. indipendenti

$$Ef(X) = \sum_k f(x_k) p_X(x_k), \text{ purché la serie converga}$$

$$E(aX_1 + b) = aEX_1 + b, \text{ per ogni } a, b \in \mathbb{R} \text{ (per v.a. continue)}$$

$$E(g(X_1)) = \int_{\mathbb{R}} g(t) f_{X_1}(t) dt, \text{ per } g: \mathbb{R} \rightarrow \mathbb{R} \text{ (per v.a. continue)}$$

#### varianza

X v.a. discreta:

$$\sigma_X^2 = \text{Var}X = E((X - EX)^2) = E(X^2) - (EX)^2$$

X v.a. continua:

$$\sigma_X^2 = \text{Var}X = E(X^2) - (EX)^2 = \int_{\mathbb{R}} t^2 f_X(t) dt - \left( \int_{\mathbb{R}} t f_X(t) dt \right)^2$$

#### proprietà

$$\text{Var}X \geq 0$$

$$\text{Var}X = E(X^2) - (EX)^2$$

$$\text{Var}(c) = 0, \text{ per ogni costante } c$$

$$\text{Var}(aX + b) = a^2 \text{Var}X, \text{ per ogni } a, b \in \mathbb{R}$$

$$\text{Var}X = \sum_k (x_k - EX)^2 p_X(x_k) = \left( \sum_k x_k^2 p_X(x_k) \right) - (EX)^2$$

$$\text{Var}(X_1 + X_2 + \dots + X_n) = \text{Var}X_1 + \text{Var}X_2 + \dots + \text{Var}X_n, \\ \text{con } X_i \text{ indipendenti}$$

#### deviazione standard o scarto quadratico medio

$$\sigma_X = \sqrt{\sigma_X^2} = \sqrt{\text{Var}X}$$

#### covarianza

$$\text{Cov}(X, Y) = E((X - EX) \cdot (Y - EY)) = E(XY) - EX \cdot EY, \\ \text{con } X, Y \text{ v.a. con varianza finita}$$

**proprietà**

$$\text{Cov}(X, X) = \text{Var}X$$

$$\text{Cov}(X, c) = 0, \text{ per ogni costante } c$$

$$\text{Cov}(X, Y) = \text{Cov}(Y, X)$$

$$\text{Cov}(X+Y, Z) = \text{Cov}(X, Z) + \text{Cov}(Y, Z)$$

$$\text{Cov}(Y, Y+Z) = \text{Cov}(X, Y) + \text{Cov}(X, Z)$$

$$\text{Cov}(aX, Y) = a\text{Cov}(X, Y)$$

$$\text{Cov}(X, aY) = a\text{Cov}(X, Y)$$

$$\text{Var}(X+Y) = \text{Var}X + \text{Var}Y + 2\text{Cov}(X, Y)$$

$$|\text{Cov}(X, Y)| \leq \sqrt{\text{Var}X \cdot \text{Var}Y} \quad (\text{dis. Cauchy} - \text{Swartz})$$

**correlazione**

due v.a. con varianza finita si dicono **incorrelate** se:

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

in tal caso:

$$\text{Var}(X+Y) = \text{Var}(X) + \text{Var}(Y)$$

**coefficiente di correlazione di X, Y**

$$\rho_{XY} \equiv \frac{\sigma_{XY}}{\sigma_X \cdot \sigma_Y} \equiv \frac{\text{Cov}(X, Y)}{\sqrt{\text{Var}X \cdot \text{Var}Y}}, \text{ dove } -1 \leq \rho_{XY} \leq 1$$

se  $\rho_{XY}$  è vicino a zero: X e Y sono quasi indipendenti

se  $\rho_{XY}$  è positivo: ad X grande corrisponderà in genere una Y grande

se  $\rho_{XY}$  è negativo: ad X grande corrisponderà in genere una Y piccola

se  $\rho_{XY} = \pm 1$  le v.a. sono una funzione lineare dell'altra:  $Y = aX + b$

**standardizzata di X**

è una v.a. ottenuta da una v.a. X con media e varianza finite:

$$X^* = \frac{X - \mu_X}{\sigma_X}$$

$$EX^* = 0; \text{ Var } X^* = 1$$

**disuguaglianza di Cebicev**

sia X una v.a. di valore atteso  $\mu_X$  e varianza  $\sigma_X^2$  finite, allora per ogni  $\delta > 0$ :

$$P(|X - \mu_X| \geq \delta \sigma_X) \leq \frac{1}{\delta^2}, \text{ ovvero}$$

$$P(|X - \mu_X| < \delta \sigma_X) = P(\mu_X - \delta \sigma_X < X < \mu_X + \delta \sigma_X) \geq 1 - \frac{1}{\delta^2}$$

**processo di Bernoulli**

sequenza di esperimenti di Bernoulli indipendenti di uguale parametro p

**esperimento bernoulliano o prova di Bernoulli**

è un esperimento aleatorio che può avere solo due esiti possibili:

- successo : con probabilità p
- insuccesso : con probabilità (1-p)

p è il parametro della prova di Bernoulli

**processo di Bernoulli limitato**

il numero di prove è finito

**bernoulliana di parametro p**

$$X \sim B(n, p)$$

descrive l'esito di ogni prova di Bernoulli

$$p_X(1) = p; \quad p_X(0) = 1 - p$$

$$EX = p; \quad \text{Var}X = p(1-p)$$

la probabilità di ottenere, in n prove, una particolare sequenza di k successi e (n-k) insuccessi è:

$$p^k (1-p)^{n-k}$$

la probabilità di ottenere, in n prove, almeno un successo è:

$$1 - (1-p)^n$$

**Binomiale di parametri n e p**

$$X \sim B(n, p)$$

conta il numero complessivo di successi ottenuti in n prove (estrazione con reimmissione)

$$p_X(k) = \binom{n}{k} p^k (1-p)^{n-k}, \quad k=0,1,2,\dots,n$$

$$EX = np; \quad \text{Var}X = np(1-p)$$

$$sk(X) = \frac{1-2p}{\sqrt{np(1-p)}}; \quad \text{curt}(X) = 3 + \frac{1-6p(1-p)}{np(1-p)}$$

il numero di oggetti di tipo K che si trovano in un campione di n oggetti estratti con reimmissione da un insieme di N oggetti che contiene K oggetti di un tipo e (N-K) oggetti di un'altro è:

$$X \sim B\left(n, \frac{K}{N}\right)$$

**processo di Bernoulli illimitato**

sequenza infinita di prove

**Binomiale negativa di parametri -n e p**

$$X \sim B(-n, p)$$

conta il numero di insuccessi che si ottengono prima di ottenere n successi

$$p_X(k) = \binom{n+k-1}{k} p^n (1-p)^k, \quad k=0,1,2,\dots$$

$$EX = n \frac{1-p}{p}; \quad \text{Var}X = n \frac{1-p}{p^2}$$

il numero Y di prove necessarie per ottenere n successi:

$$P(Y=k) = P(X+n=k) = P(X=k-n) = \binom{k-1}{k-n} p^n (1-p)^{k-n},$$

$$\text{ per } k = n, n+1, n+2, \dots$$

**Geometrica di parametro p**

$$X \sim G(p)$$

conta il numero di prove necessarie per ottenere il primo successo

$$p_X(k) = p(1-p)^{k-1}, \quad \text{ per } k=1,2,3,\dots$$

$$EX = \frac{1}{p}; \quad \text{Var}X = \frac{1-p}{p^2}$$

**Geometrica traslata di parametro p**

$$X \sim G'(p)$$

conta il numero di insuccessi prima del primo successo

$$p_X(k) = p(1-p)^k, \quad \text{ per } k=0,1,2,\dots$$

$$EX = \frac{1-p}{p}; \quad \text{Var}X = \frac{1-p}{p^2}$$

**Ipergeometrica di parametri (N, K, n)**

$$X \sim G(N, K, n), \quad \text{ con } N \geq k; N \geq n$$

conta il numero di oggetti di tipo K che si trovano in un campione di n oggetti estratti senza reimmissione da un insieme di N oggetti che contiene K oggetti di un tipo e (N-K) oggetti di un altro.

$$p_X(k) = \frac{\binom{K}{k} \binom{N-K}{n-k}}{\binom{N}{n}}, \quad \text{ con } 0 \leq k \leq n; k \leq K; (n-k) \leq (N-K)$$

$$EX = n \frac{K}{N}; \quad \text{Var}X = n \frac{K}{N} \left(1 - \frac{K}{N}\right) \left(\frac{N-n}{N-1}\right)$$

**approssimazione Binomiale**

per N (e quindi K) molto grandi ( $N > 10n$ ) è come se estraessimo con reimmissione:

$$X \sim G(N, K, n) \rightarrow X \sim B\left(n, \frac{K}{N}\right), \quad \text{ per } N \rightarrow \infty$$

$$p_X(k) \rightarrow \binom{n}{k} p^k (1-p)^{n-k}, \text{ per } N \rightarrow \infty, p = \frac{K}{N}$$

$$EX = np; \text{ Var}X = np(1-p) \left( \frac{N-n}{N-1} \right)$$

$$\left( \frac{N-n}{N-1} \right) \text{ (fattore di correzione per la popolazione finita } (< 1))$$

### Poisson di parametro $\lambda > 0$

$$Y \sim P_0(\lambda), \text{ con } \lambda > 0$$

permette di descrivere quantitativamente situazioni in cui non abbiamo accesso ai valori di N e p, ma possediamo una unica informazione numerica: il parametro  $\lambda$  (numero medio di arrivi)

$$p_Y(k) = e^{-\lambda} \frac{\lambda^k}{k!}, \text{ per } k = 0, 1, 2, \dots$$

$$EY = \lambda; \text{ Var}Y = \lambda$$

$$sk(X) = \frac{1}{\sqrt{\lambda}}; \text{ curt}(X) = 3 + \frac{1}{\lambda}$$

### proprietà

se  $X_i \sim P_0(\lambda_i)$  allora:

$$X_1 + X_2 + \dots + X_n \sim P_0(\lambda_1 + \lambda_2 + \dots + \lambda_n)$$

### approssimazione della Binomiale

per N molto grande e p molto piccolo:

$$X \sim B(N, p) \rightarrow Y \sim P_0(Np), P(X=k) \rightarrow P(Y=k)$$

### processo Poisson di intensità $\nu$

permette di calcolare probabilità di eventi che accadono in un certo intervallo di tempo diverso da quello su cui abbiamo informazioni di partenza;

posto  $\lambda = \nu t$  con  $\nu$  numero medio di arrivi nell'unità di tempo, il numero  $X_t$  di arrivi nell'intervallo di tempo  $[0, t]$  è dato da

$$X_t \sim P_0(\nu t)$$

$$p_{X_t}(k) = e^{-\nu t} \frac{(\nu t)^k}{k!}, \text{ per } k = 0, 1, 2, \dots$$

$$EX_t = \nu t; \text{ Var}X_t = \nu t$$

### variabili aleatorie continue

#### densità continua $f_x$

determina la legge della v.a. continua X;  
è una densità di probabilità

$$P(X \in I) \equiv \int_I f_x(t) dt, \text{ con } I \subseteq \mathbb{R}$$

$$f_x: \mathbb{R} \rightarrow \mathbb{R}; f_x(t) \geq 0, \text{ per ogni } t \in \mathbb{R}; \int_{\mathbb{R}} f_x(t) dt = 1$$

#### proprietà

$P(X=t) = 0$ , per ogni  $t \in \mathbb{R}$  (la probabilità che assuma un valore fissato è nulla (integrale di un punto))

$$P(X \leq a) = P(X < a)$$

$$P(a \leq X < b) = P(a < X < b)$$

#### esempi di densità continue

##### densità uniforme

$$f_x(t) = \frac{1}{b-a} I_{(a,b)}(t), a, b \in \mathbb{R}, a < b$$

$$\text{con } I_{(a,b)}(t) = 1, \text{ per } t \in (a, b) \\ I_{(a,b)}(t) = 0, \text{ per } t \notin (a, b) \text{ (funzione indicatrice)}$$

$$P(X \in J) = \int_J \frac{1}{b-a} I_{(a,b)}(t) dt = \frac{1}{b-a} |(a, b) \cap J|$$

### densità di Cauchy

$$f_x(t) = \frac{1}{\pi(1+t^2)}$$

$$P(a < X < b) = \int_a^b \frac{1}{\pi(1+t^2)} dt = 1/\pi (\arctan(b) - \arctan(a))$$

### densità Normale Standard

“curva a campana” di Gauss, o curva degli errori

$$f_x(t) = \frac{1}{\sqrt{2\pi}} e^{-t^2/2}$$

$$P(a < X < b) = \int_a^b \frac{1}{\sqrt{2\pi}} e^{-t^2/2} dt$$

### funzione di ripartizione di X (f.d.r.)

equivale alla densità discreta nel caso continuo

$$F_x(t): \mathbb{R} \rightarrow [0, 1]$$

$$F_x(t) = P(X \leq t), \text{ per ogni } t \in \mathbb{R}$$

$$F_x(t) = \int_{-\infty}^t f_x(y) dy, \text{ per } X \text{ continua}$$

$$F_x(t) = \sum_{x_k \leq t} p_X(x_k), \text{ per } X \text{ discreta}$$

#### proprietà

se  $t_1 < t_2$ ,  $(X \leq t_1) \subseteq (X \leq t_2)$ ,  $P(X \leq t_1) \leq P(X \leq t_2)$ ,  
( $F_x(t)$  è monotona crescente)

$$F_x(t) \rightarrow 1 \text{ per } t \rightarrow +\infty$$

$$F_x(t) \rightarrow 0 \text{ per } t \rightarrow -\infty$$

$$F_x(b) - F_x(a) = P(X \leq b) - P(X \leq a) = P(a < X \leq b), \text{ con } a, b \in \mathbb{R}, a < b$$

la f.d.r. di una v.a. continua è sempre una funzione continua nei punti in cui la densità è continua; in questi punti è derivabile:

$$F'_x(t) = f_x(t)$$

#### quantile $\alpha$ -esimo ( $q_\alpha$ )

$$P(X \leq q_\alpha) = \alpha, \text{ con } q_\alpha \in (a, b) \subseteq \mathbb{R}, \alpha \in (0, 1)$$

### variabili aleatorie legate al processo di Poisson

#### legge Esponenziale di parametro $\nu$

$$Y \sim \text{Esp}(\nu), \text{ con } \nu > 0$$

misura l'istante del primo arrivo in un processo di Poisson  $X_t$  di intensità  $\nu$ , o il tempo di attesa tra due arrivi successivi; è l'unico modello adeguato a rappresentare il tempo di vita di un apparecchio non soggetto ad usura

$$F_Y(t) = 1 - e^{-\nu t}, \text{ per } t > 0$$

$$F_Y(t) = 0, \text{ per } t \leq 0$$

$$f_Y(t) = \nu e^{-\nu t}, \text{ per } t > 0$$

$$f_Y(t) = 0, \text{ per } t < 0$$

$$E(Y) = \frac{1}{\nu}; \text{ Var}Y = \frac{1}{\nu^2}$$

$$sk(X) = 2; \text{ curt}(X) = 9$$

#### stimatore non distorto per legge Esponenziale

$$U = T \frac{n-1}{n} = \frac{n-1}{n} \sum_{i=1}^n X_i$$

$$\hat{v} = \frac{n-1}{\sum_{i=1}^n X_i} = \frac{n-1}{n} \frac{1}{\bar{X}_n}, \quad (\text{stima di } v)$$

### legge Gamma di parametri $n$ (intero positivo) e $v$ (intero positivo)

$$Y \sim \Gamma(n, v)$$

misura l'istante dell' $n$ -esimo arrivo in un processo di Poisson  $X_t$  di intensità  $v$

$$F_Y(t) = 1 - \sum_{k=0}^{n-1} \frac{e^{-vt} (vt)^k}{k!}, \quad \text{per } t > 0$$

$$F_Y(t) = 0, \quad \text{per } t \leq 0$$

$$f_Y(t) = v e^{-vt} \frac{(vt)^{n-1}}{(n-1)!} = C_{n,v} t^{n-1} e^{-vt}, \quad \text{per } t > 0,$$

$$f_Y(t) = 0, \quad \text{per } t < 0$$

$$C_{n,v} = \frac{v^n}{(n-1)!}$$

$$E(Y) = \frac{n}{v}; \quad \text{Var } Y = \frac{n}{v^2}$$

### legge Gamma di parametri $r$ e $v$ (reali positivi)

$$Y \sim \Gamma(r, v)$$

descrive il tempo di vita di un apparecchio la cui propensione al guasto cresce col tempo, fino al limite  $v$

$$f_Y(t) = C_{r,v} t^{r-1} e^{-vt}, \quad \text{per } t > 0$$

$$f_Y(t) = 0, \quad \text{per } t < 0$$

$$E(Y) = \frac{r}{v}; \quad \text{Var } Y = \frac{r}{v^2}$$

### assenza di memoria

$$P(Y \geq T-t | Y \geq T) = P(Y \geq T)$$

$$P(Y \geq T+t) = P(Y \geq T) \cdot P(Y \geq T)$$

se una v.a. continua soddisfa questa proprietà, allora ha legge

Esponenziale se è continua e legge Geometrica traslata se discreta

### istantaneous failure rate (propensione istantanea al guasto)

$$Z(t) = \frac{f_Y(t)}{1 - F_Y(t)}$$

#### per la legge Esponenziale:

$$Z(t) = v, \quad \text{per } t > 0$$

#### per la legge Gamma:

$$Z(t) = C_{n,v} \frac{t^{n-1}}{\sum_{k=0}^{n-1} \frac{(vt)^k}{k!}} = \frac{v^n}{(n-1)!} \frac{t^{n-1}}{\sum_{k=0}^{n-1} \frac{(vt)^k}{k!}}$$

### densità di Weibull

utile a rappresentare il tempo di vita di un apparecchio

posto  $Z(t) = c t^\beta$  si trova:

$$F_Y(t) = 1 - e^{-\frac{c t^{\beta+1}}{\beta+1}}, \quad \text{con } \beta > -1$$

$$f_Y(t) = c t^\beta e^{-\frac{c t^{\beta+1}}{\beta+1}}$$

se  $\beta > 0$  l'apparecchio invecchia

se  $-1 < \beta < 0$  l'apparecchio migliora col tempo

se  $\beta = 0$  si ritrova la legge Esponenziale

## modello Normale

### legge Normale standard

$$Z \sim N(0,1)$$

$$F_Z(t) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^t e^{-\frac{y^2}{2}} dy \equiv \Phi(t)$$

$$f_Z(t) = \frac{1}{\sqrt{2\pi}} e^{-\frac{t^2}{2}} \equiv \varphi(t)$$

$$E(Z) = 0; \quad \text{Var } Z = 1$$

#### proprietà

$$\Phi(-t) = 1 - \Phi(t), \quad (\text{simmetria})$$

#### calcoli con i quantili

posto  $z_\alpha$  quantile  $\alpha$ -esimo della legge Normale standard:

$$z_\alpha = -z_{1-\alpha}$$

$$P(Z < z_\alpha) = \alpha$$

$$P(Z > z_{1-\alpha}) = \alpha$$

$$P(|Z| > z_{1-\alpha/2}) = \alpha$$

$$P(|Z| < z_{(1+\alpha)/2}) = \alpha$$

### legge Normale (o gaussiana) di media $\mu$ e varianza $\sigma^2$

$$X \sim N(\mu, \sigma^2)$$

rappresenta bene gli errori di approssimazione

$$F_X(t) = \Phi\left(\frac{t-\mu}{\sigma}\right)$$

$$f_X(t) = \frac{1}{\sigma} \varphi\left(\frac{t-\mu}{\sigma}\right) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(t-\mu)^2}{2\sigma^2}}$$

$$EX = \mu; \quad \text{Var } X = \sigma^2$$

$$sk(X) = 0; \quad \text{curt}(X) = 3$$

la v.a.  $Z = \frac{X-\mu}{\sigma}$  ha legge Normale standard

#### proprietà

posto  $X_1 \sim N(\mu_1, \sigma_1^2)$ ,  $X_2 \sim N(\mu_2, \sigma_2^2)$  indipendenti:

$$X_1 + X_2 \sim N(\mu_1 + \mu_2, \sigma_1^2 + \sigma_2^2)$$

posto  $a, b \in \mathbb{R}$ :

$$aX_1 + b \sim N(a\mu_1 + b, a^2\sigma_1^2)$$

#### relazione tra legge Normale e legge Normale standard

$$Z \sim N(0,1) \Rightarrow \sigma Z + \mu \sim N(\mu, \sigma^2)$$

$$X \sim N(\mu, \sigma^2) \Rightarrow \frac{X-\mu}{\sigma} \sim N(0,1)$$

#### errori

$Y$  = misura di una grandezza fisica

$v$  = valore vero

$X$  = errore di misura

$\mu$  = errore sistematico

$E_c$  = errore casuale

$\sigma^2$  = inaccuratezza della misura

$$X \sim N(\mu, \sigma^2), \quad X = \mu + E_c$$

$$E_c \sim N(0, \sigma^2)$$

$$E(E_c) = 0$$

$$EY = v + \mu$$

#### media campionaria

se  $X_i \sim N(\mu, \sigma^2)$  sono v.a. indipendenti ed identicamente

distribuite (i.i.d.):

$$\bar{X}_n \sim N\left(\mu, \frac{\sigma^2}{n}\right)$$

$$E \bar{X}_n = \mu ; \text{Var } \bar{X}_n = \frac{\sigma^2}{n}$$

**media campionaria standardizzata**

$$S_n^* = \frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}}, \quad n=1,2,3,\dots$$

**teorema del limite centrale**

$$P(S_n^* \leq t) \rightarrow \Phi(t) \quad \text{per } n \rightarrow \infty, \quad t \in \mathbb{R}$$

**approssimazione Normale**

Date  $X_i$  v.a. i.i.d.,  $EX_i = \mu$ ,  $\text{Var} X_i = \sigma^2$  con  $n$  abbastanza grande:

$$\bar{X}_n \approx N\left(\mu, \frac{\sigma^2}{n}\right) \quad \text{ossia} \quad P(\bar{X}_n < t) \approx \Phi\left(\sqrt{n}\left(\frac{t-\mu}{\sigma}\right)\right)$$

$$\sum_{i=1}^n X_i \approx N(n\mu, n\sigma^2) \quad \text{ossia} \quad P\left(\sum_{i=1}^n X_i < t\right) \approx \Phi\left(\frac{t-n\mu}{\sqrt{n}\sigma}\right)$$

**approssimazione Normale di Gamma per  $n$  grande:**

$$Y \sim \Gamma(n, \lambda)$$

$$Y \approx N\left(\frac{n}{\lambda}, \frac{n}{\lambda^2}\right)$$

$$F_Y(t) = P(Y < t) \approx \Phi\left(\frac{\lambda t - n}{\sqrt{n}}\right)$$

**approssimazione Normale della Binomiale:**

approssimazione utile in problemi di campionamento

NOTA: vale se:  $np > 5$  ;  $n(1-p) > 5$

$$Y \sim B(n, p)$$

$$Y \approx N(np, np(1-p))$$

$$F_Y(t) = P(Y \leq t) \approx \Phi\left(\frac{t - np}{\sqrt{np(1-p)}}\right), \quad (\text{per v.a. continua})$$

$$F_Y(k) = P(Y \leq k) \approx \Phi\left(\frac{k + 0.5 - np}{\sqrt{np(1-p)}}\right),$$

$$k = 0, 1, 2, \dots, n, \quad (\text{per v.a. discreta})$$

**momenti ed indici di forma per v.a.**

**momento r-esimo di X**

$$\mu_r' = E(X^r)$$

$$\mu_r' = \sum_k x_k^r p_X(x_k), \quad \text{per } X \text{ discreta}$$

$$\mu_r' = \int_{\mathbb{R}} x^r f_X(x) dx, \quad \text{per } X \text{ continua}$$

**momento r-esimo centrato di X**

$$\mu_r = E((X - EX)^r)$$

$$\mu_r = \sum_k (x_k - \mu)^r p_X(x_k), \quad \text{con } \mu = EX, \quad \text{per } X \text{ discreta}$$

$$\mu_r = \int_{\mathbb{R}} (x - \mu)^r f_X(x) dx, \quad \text{per } X \text{ continua}$$

**coefficiente di asimmetria (skewness) di una v.a.**

**X con  $\mu_3'$  finito**

misura l'asimmetria di X rispetto al valore atteso

$$sk(X) = \frac{\mu_3'}{\mu_2'^{3/2}} = E\left[\left(\frac{X-\mu}{\sigma}\right)^3\right]$$

**coefficiente di curtosi di una v.a. X con  $\mu_4'$  finito**

misura quanto la densità di X sia appuntita

$$curt(X) = \frac{\mu_4'}{\mu_2'^2} = E\left[\left(\frac{X-\mu}{\sigma}\right)^4\right], \quad \mu = EX, \quad \sigma^2 = \text{Var } X$$

**statistica inferenziale**

**campionamento e stime**

**definizioni**

**modello statistico**

famiglia di leggi di v.a., dipendenti da uno o più parametri incogniti:

$$\{p_X(x; \vartheta) : \vartheta \in I\}$$

$\vartheta$  è un vettore di parametri

**campione casuale di ampiezza n**

estratto da una popolazione di densità  $p_X(x; \vartheta)$  è una ennupla di v.a. indipendenti e identicamente distribuite (i.i.d)  $(X_1, X_2, \dots, X_n)$ , ciascuna avente legge  $p_X(x; \vartheta)$ .

**stima di parametri e stimatori**

**stima puntuale dei parametri**

stimare il valore vero del parametro (o dei parametri) a partire dal campione casuale

**stima del parametro p della popolazione bernulliana**

$$\hat{p} = \bar{x}_n, \quad \text{con } x_i \text{ valori effettivamente osservati}$$

**statistica T**

è una qualsiasi v.a. T funzione del campione casuale  $(X_1, X_2, \dots, X_n)$  di ampiezza n estratto da una popolazione di legge  $p_X(x; \vartheta)$ :

$$T = f(X_1, X_2, \dots, X_n), \quad \text{con } f: \mathbb{R}^n \rightarrow \mathbb{R}$$

**stimatore del parametro  $\vartheta$**

statistica che viene usata per stimare il valore del parametro  $\vartheta$  è **corretto (non distorto)** se  $ET = \vartheta$  altrimenti è detto **distorto**

**stima del parametro  $\vartheta$**

$$\hat{\vartheta} = f(x_1, x_2, \dots, x_n), \quad \text{calcolato a campionamento eseguito}$$

**stimatore consistente**

$$\text{var } T_n \rightarrow 0 \quad \text{per } n \rightarrow \infty, \quad \text{con } T_n \text{ stimatore corretto di } \vartheta$$

**valore atteso della media campionaria**

$$E \bar{X}_n = \mu$$

**varianza della media campionaria**

$$\text{Var } \bar{X}_n = \frac{\sigma^2}{n}$$

**legge dei grandi numeri**

$$P\{|\bar{X}_n - \mu| > \epsilon\} \rightarrow 0, \quad \text{per } n \rightarrow \infty$$

**stime**

$$\text{stima di } \sigma^2 = h(\vartheta)$$

$$S_n^2 \equiv \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2, \quad (\text{varianza campionaria})$$

a campionamento effettuato:

$$s_n^2 \equiv \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x}_n)^2 = \frac{1}{n-1} \sum_{i=1}^n x_i^2 - \frac{n}{n-1} (\bar{x}_n)^2$$

### stima popolazione Normale

$$\hat{\mu} = \bar{x}_n$$

$$\hat{\sigma}^2 = s_n^2$$

se  $\mu$  è nota:

$$\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \mu)^2$$

### stima popolazione Gamma

$$\hat{\lambda} = \frac{\bar{x}_n}{s_n^2} ; \hat{\hat{r}} = \frac{\bar{x}_n^2}{s_n^2}$$

### leggi

#### legge Chi quadro con n gradi di libertà

$$Y \sim X^2(n) \equiv Y \sim \Gamma\left(\frac{n}{2}, \frac{1}{2}\right)$$

$X_i$  sono v.a. indipendenti, ciascuna di legge  $N(0,1)$

$$f_Y(t) = c_n t^{\frac{n}{2}-1} e^{-\frac{t}{2}}, \text{ per } t > 0$$

$$f_Y(t) = 0, \text{ per } t < 0$$

$$EY = n ; \text{Var } Y = 2n$$

#### proprietà

posto  $Y_1 \sim X^2(n_1)$ ,  $Y_2 \sim X^2(n_2)$  indipendenti:

$$Y_1 + Y_2 \sim X^2(n_1 + n_2)$$

intervallo a cui una v.a. di legge Chi quadro appartiene con probabilità  $\alpha$ :

$$P\left(X^2_{\frac{1-\alpha}{2}}(n) < Y < X^2_{\frac{1+\alpha}{2}}(n)\right) = \alpha$$

#### approssimazione Normale di Chi quadro per n grande

$$X^2(n) \simeq N(n, 2n), \text{ per } n \text{ grande}$$

$$P(Y < t) \simeq \Phi\left(\frac{t-n}{\sqrt{2n}}\right)$$

$$X^2_\alpha(n) \simeq z_\alpha \sqrt{2n} + n$$

#### approssimazioni

Sia  $X_1, X_2, \dots, X_n$  un campione casuale estratto da una popolazione di legge  $N(\mu, \sigma^2)$ , allora:

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

$$\sum_{i=1}^n \left(\frac{X_i - \bar{X}_n}{\sigma}\right) \sim X^2(n-1)$$

$$\frac{(n-1)S_n^2}{\sigma^2} \sim X^2(n-1)$$

$S_n^2$  e  $\bar{X}_n$  sono tra loro indipendenti

#### legge t di student a n gradi di libertà

$$T \sim t(n) ; \text{ con } T = \frac{Z}{\sqrt{Y/n}}, \text{ } Z \sim N(0,1), \text{ } Y \sim X^2(n)$$

$$f_T(t) = c_n \left(1 + \frac{t^2}{n}\right)^{-\frac{(n+1)}{2}}, \text{ per } t \in \mathbb{R}$$

$$ET = 0, \text{ (tranne per } n=1 \text{ per cui non esiste finito)}$$

per  $t \rightarrow \infty$  la t di student tende alla Normale standard

#### approssimazioni

Sia  $X_1, X_2, \dots, X_n$  un campione casuale estratto da una popolazione

di legge  $N(\mu, \sigma^2)$ , allora:

$$\frac{\bar{X}_n - \mu}{\sqrt{S_n^2/n}} \sim t(n-1)$$

#### calcoli con i quantili

posto  $t_\alpha(n)$  quantile  $\alpha$ -esimo della legge  $t(n)$ :

$$P(T < t_\alpha(n)) = \alpha$$

$$P(T > t_{1-\alpha}(n)) = \alpha$$

$$P(|T| > t_{1-\alpha/2}(n)) = \alpha$$

$$P(|T| < t_{(1+\alpha)/2}(n)) = \alpha$$

$$t_{\frac{1-\alpha}{2}}(n-1) \simeq z_{\frac{1+\alpha}{2}}, \text{ approssimazione per } n > 120$$

#### approssimazione di quantili tramite interpolazione lineare

$$y = mx + q,$$

equazione della retta che passa per i punti  $\{q_1, t_\alpha(q_1)\}, \{q_2, t_\alpha(q_2)\}$

$$t_\alpha(x) = t_\alpha(q_1) - \frac{t_\alpha(q_2) - t_\alpha(q_1)}{q_2 - q_1} (x - q_1), \text{ con } q_1 < x < q_2$$

#### legge di fisher con m e n gradi di libertà

$$X \sim F(m, n) ; \text{ con } X = \frac{U/m}{V/n}, \text{ } U \sim X^2(m), \text{ } V \sim X^2(n)$$

#### proprietà

$$\frac{1}{X} \sim F(n, m)$$

$$P(X < F_\alpha(m, n)) = \alpha$$

$$P\left(\frac{1}{X} < \frac{1}{F_\alpha(m, n)}\right) = 1 - \alpha$$

$$\frac{1}{F_\alpha(m, n)} = F_{1-\alpha}(n, m)$$

$$\frac{S_1^2}{S_2^2} = F(m-1, n-1)$$

#### intervallo di confidenza al livello del 100 $\alpha$ % per $h(\theta)$

Sia  $(X_1, X_2, \dots, X_n)$  un campione casuale estratto da una popolazione di densità  $f(x; \theta)$ ; siano  $T_1 = t_1(X_1, X_2, \dots, X_n)$ ,  $T_2 = t_2(X_1, X_2, \dots, X_n)$  due statistiche, e sia  $h(\theta)$  una funzione del parametro che si vuole stimare; fissato un numero  $\alpha \in (0, 1)$ , l'intervallo aleatorio  $(T_1, T_2)$  si dice intervallo di confidenza al 100 $\alpha$ % per  $h(\theta)$  se:

$$P^\theta(T_1 < h(\theta) < T_2) = \alpha$$

a campionamento eseguito l'intervallo  $(t_1, t_2)$  si dice "calcolato al campione";

$h(\theta)$  appartiene all'intervallo  $(t_1, t_2)$  con una confidenza del 100 $\alpha$ %;  $t_1$  e  $t_2$  sono detti **limiti di confidenza**

#### intervallo di confidenza per la media

(di una popolazione Normale o popolazione qualsiasi con n grande ( $n \geq 30$ ))

$$\hat{\mu} = \bar{X}_n \pm z_{(1+\alpha)/2} \frac{\sigma}{\sqrt{n}} = \bar{X}_n \pm E, \text{ (con varianza nota)}$$

$$\hat{\mu} = \bar{X}_n \pm t_{\frac{(1+\alpha)}{2}}(n-1) \sqrt{\frac{S_n^2}{n}}, \text{ (con varianza incognita)}$$

**stima dell'ampiezza per limitare l'errore  $E_0$**

$$n = t_{(1+\alpha)/2}^2 (n-1) \frac{\sigma^2}{E_0^2}, \text{ (con varianza nota)}$$

**intervallo di confidenza per la frequenza p**

valido per una popolazione bernoulliana e per grandi campioni ( $n \geq 30$ )

$$\hat{p} = \bar{X}_n \pm z_{(1+\alpha)/2} \sqrt{\frac{\bar{X}_n(1-\bar{X}_n)}{n}}; \text{ se: } n\bar{x}_n > 5, n(1-\bar{x}_n) > 5$$

**stima dell'ampiezza per limitare l'errore  $E_0$**

$$n = \left( \frac{z_{(1+\alpha)/2}}{2E_0} \right)^2$$

$E_0$  corrisponde a metà dell'intervallo di confidenza.

**test di ipotesi**

**ipotesi statistica**

è un'asserzione sul valore vero di un parametro incognito; si dice **semplice** se specifica completamente il valore del parametro, altrimenti si dice **composta**

**ipotesi nulla  $H_0$**

$$H_0: \vartheta \in \Theta_0$$

ipotesi che si ritiene vera "fino a prova contraria"; rifiuteremo  $H_0$  solo se i dati campionari forniranno una forte evidenza statistica contro di essa

**ipotesi alternativa  $H_1$**

$$H_1: \vartheta \notin \Theta_0$$

ipotesi vera solo se  $H_0$  è falsa

**errore di tipo I**

rifiutiamo  $H_0$  quando è vera; questo è considerato l'errore più grave

**errore di tipo II**

accettiamo  $H_0$  quando è falsa

**regione critica o regione di rifiuto**

è l'insieme R dei possibili risultati campionari che portano a rifiutare  $H_0$  data la **regola di decisione**: si rifiuti  $H_0$  se  $T(X_1, X_2, \dots, X_n) \in I$ :

$$R = \{(x_1, x_2, \dots, x_n) : T(x_1, x_2, \dots, x_n) \in I\}$$

la probabilità di rifiutare  $H_0$  prima del campionamento:

$$P^{\vartheta}(T(X_1, X_2, \dots, X_n) \in I)$$

**ampiezza del test (o livello di significatività)**

$$\alpha = \sup_{\vartheta \in \Theta_0} P^{\vartheta}(T(X_1, X_2, \dots, X_n) \in I)$$

rappresenta la massima probabilità di rifiutare l'ipotesi nulla quando questa è vera;

va stabilito piccolo a priori prima di eseguire il campionamento

**p-value**

numero pari al minimo livello di significatività a cui i dati campionari consentono di rifiutare l'ipotesi nulla; se p-value = 0 siamo praticamente certi di non sbagliare

**varianza campionaria pesata**

media pesata delle varianze campionarie di due campioni n, m

$$S^2 = \frac{(n-1)S_X^2 + (m-1)S_Y^2}{n+m-2} = \frac{\sum_{i=1}^n (X_i - \bar{X}_n)^2 + \sum_{i=1}^m (Y_i - \bar{Y}_m)^2}{n+m-2}$$

**test sulla media di una popolazione Normale di varianza nota**

$$z = \frac{\bar{x}_n - \mu_0}{\sigma / \sqrt{n}}$$

$H_0$	$H_1$	rifiutare $H_0$ se
$\mu = \mu_0$	$\mu \neq \mu_0$	$ z  > z_{1-\alpha/2}$
$\mu \leq \mu_0$	$\mu > \mu_0$	$z > z_{1-\alpha}$
$\mu \geq \mu_0$	$\mu < \mu_0$	$z < -z_{1-\alpha}$

**test sulla media di una popolazione Normale di varianza incognita**

$$t = \frac{\bar{x}_n - \mu_0}{s_n / \sqrt{n}}$$

$H_0$	$H_1$	rifiutare $H_0$ se
$\mu = \mu_0$	$\mu \neq \mu_0$	$ t  > t_{1-\alpha/2}(n-1)$
$\mu \leq \mu_0$	$\mu > \mu_0$	$t > t_{1-\alpha}(n-1)$
$\mu \geq \mu_0$	$\mu < \mu_0$	$t < -t_{1-\alpha}(n-1)$

**test sulla frequenza p di una popolazione bernoulliana**

$$z = \frac{\bar{x}_n - p_0}{\sqrt{p_0(1-p_0)/n}}$$

$H_0$	$H_1$	rifiutare $H_0$ se
$p = p_0$	$p \neq p_0$	$ z  > z_{1-\alpha/2}$
$p \leq p_0$	$p > p_0$	$z > z_{1-\alpha}$
$p \geq p_0$	$p < p_0$	$z < -z_{1-\alpha}$

**test sulla differenza di due medie con varianze note**

estriamo due campioni n,m da due popolazioni normali indipendenti con varianze note; questo test non va usato quando una varianza è almeno 4 volte l'altra

$$z = \frac{\bar{X}_n - \bar{Y}_m - \delta}{\sqrt{\frac{\sigma_X^2}{n} + \frac{\sigma_Y^2}{m}}}$$

$H_0$	$H_1$	rifiutare $H_0$ se
$\mu_X = \mu_Y + \delta$	$\mu_X \neq \mu_Y + \delta$	$ z  > z_{1-\alpha/2}$
$\mu_X \leq \mu_Y + \delta$	$\mu_X > \mu_Y + \delta$	$z > z_{1-\alpha}$
$\mu_X \geq \mu_Y + \delta$	$\mu_X < \mu_Y + \delta$	$z < -z_{1-\alpha}$

**test sulla differenza di due medie con varianze incognite**

estriamo due campioni n, m da due popolazioni normali indipendenti con varianze incognite; questo test non va usato quando una varianza è almeno 4 volte l'altra

$$t = \frac{\bar{X}_n - \bar{Y}_m - \delta}{\sqrt{\frac{1}{n} + \frac{1}{m}} \sqrt{\frac{(n-1)S_X^2 + (m-1)S_Y^2}{n+m-2}}}$$

$H_0$	$H_1$	rifiutare $H_0$ se
$\mu_X = \mu_Y + \delta$	$\mu_X \neq \mu_Y + \delta$	$ t  > t_{1-\alpha/2}(n+m-2)$
$\mu_X \leq \mu_Y + \delta$	$\mu_X > \mu_Y + \delta$	$t > t_{1-\alpha}(n+m-2)$
$\mu_X \geq \mu_Y + \delta$	$\mu_X < \mu_Y + \delta$	$t < -t_{1-\alpha}(n+m-2)$

nel caso di campioni osservazioni accoppiate si considerano le differenze delle medie

**test su due frequenze di due popolazioni bernoulliane indipendenti**

estriamo due campioni n, m da due popolazioni bernoulliane indipendenti  $X \sim B(p_1)$ ,  $Y \sim B(p_2)$ ;

questa procedura è valida se  $\sum_{i=1}^n x_i > 5$ ;  $\sum_{i=1}^m y_i > 5$

$$z = \frac{\bar{x}_n - \bar{y}_m}{\sqrt{\hat{p}(1-\hat{p})(\frac{1}{n} + \frac{1}{m})}} \text{ con } \hat{p} = \frac{n\bar{x}_n + m\bar{y}_m}{n+m}$$

$H_0$	$H_1$	rifiutare $H_0$ se
$p_1 = p_2$	$p_1 \neq p_2$	$ z  > z_{1-\alpha/2}$
$p_1 \leq p_2$	$p_1 > p_2$	$z > z_{1-\alpha}$
$p_1 \geq p_2$	$p_1 < p_2$	$z < -z_{1-\alpha}$

**inferenze su una varianza**

$$X^2 = \frac{(n-1)s_n^2}{\sigma_0^2}$$

$H_0$	$H_1$	rifiutare $H_0$ se
$\sigma^2 = \sigma_0^2$	$\sigma^2 \neq \sigma_0^2$	$X^2 > X_{1-\alpha/2}^2(n-1)$ o $X^2 < X_{\alpha/2}^2(n-1)$
$\sigma^2 \leq \sigma_0^2$	$\sigma^2 > \sigma_0^2$	$X^2 > X_{1-\alpha}^2(n-1)$
$\sigma^2 \geq \sigma_0^2$	$\sigma^2 < \sigma_0^2$	$X^2 < X_{\alpha}^2(n-1)$

**intervallo di confidenza**

$$\left( \frac{(n-1)s_n^2}{X_{1+\alpha/2}^2(n-1)}, \frac{(n-1)s_n^2}{X_{1-\alpha/2}^2(n-1)} \right)$$

**inferenze su due varianze**

estriamo due campioni n, m da due popolazioni normali indipendenti con medie incognite;

$$F = \frac{s_X^2}{s_Y^2}$$

$H_0$	$H_1$	rifiutare $H_0$ se
$\sigma_X^2 = \sigma_Y^2$	$\sigma_X^2 \neq \sigma_Y^2$	$F > F_{1-\alpha/2}(n-1, m-1)$ $F < F_{\alpha/2}(n-1, m-1)$
$\sigma_X^2 \leq \sigma_Y^2$	$\sigma_X^2 > \sigma_Y^2$	$F > F_{1-\alpha}(n-1, m-1)$
$\sigma_X^2 \geq \sigma_Y^2$	$\sigma_X^2 \leq \sigma_Y^2$	$F < F_{1-\alpha}(n-1, m-1)$

**intervallo di confidenza**

$$\left( \frac{1}{F_{1+\alpha/2}(n-1, m-1)} \frac{s_X^2}{s_Y^2}, \frac{1}{F_{1-\alpha/2}(n-1, m-1)} \frac{s_X^2}{s_Y^2} \right)$$

**test Chi quadro di adattamento**

ha lo scopo di verificare se certi dati empirici si adattano bene ad una distribuzione teorica assegnata; si costruisce la seguente tabella:

classi	$A_1$	$A_2$	...	$A_k$	$\sum_{i=1}^k$
freq. rel. attese	$p_1$	$p_2$	...	$p_k$	1
freq. ass. attese	$np_1$	$np_2$	...	$np_k$	n
freq. ass. osservate	$N_1$	$N_2$	...	$N_k$	n
scarti quad. pesati	$\frac{(np_1 - N_1)^2}{np_1}$	$\frac{(np_2 - N_2)^2}{np_2}$	...	$\frac{(np_k - N_k)^2}{np_k}$	Q

le classi andranno accorpate in maniera tale che le frequenze assolute attese siano tutte maggiori o uguali a 5;

Chi quadro calcolato dalla campione:

$$Q = \sum_{i=1}^k \frac{(np_i - N_i)^2}{np_i}$$

$Q \rightarrow X^2(k-1)$  per  $n \rightarrow \infty$ , con  $p_i$  assegnate a priori

$Q \rightarrow X^2(k-1-r)$  per  $n \rightarrow \infty$ , con  $p_i$  calcolate dopo aver stimato r parametri incogniti

fissato  $\alpha$ , si stabilisce la regola di decisione:

si rifiuti  $H_0$  se  $Q > X_{1-\alpha}^2(k-1-r)$  (si calcola tramite tabelle)

il p-value corrispondente al valore Q è:

$$\alpha = P(X > Q), \text{ con } X \sim X^2(k-1-r)$$

**test Chi quadro di indipendenza**

verifica l'indipendenza o meno di due variabili;

si costruisce una tabella di contingenza di rs classi:

	$A_1$	$A_2$	...	$A_r$	Tot.
$B_1$	$n_{11}$	$n_{21}$	...	$n_{r1}$	$n_{.1}$
$B_2$	$n_{12}$	$n_{22}$	...	$n_{r2}$	$n_{.2}$
...	...	...	...	...	...
$B_s$	$n_{1s}$	$n_{2s}$	...	$n_{rs}$	$n_{.s}$
Tot.	$n_{.1}$	$n_{.2}$	...	$n_{.r}$	n

si costruisce una tabella di rs classi:

	$A_1$	$A_2$	...	$A_r$
$B_1$	$\frac{n_{1.} \cdot n_{.1}}{n}$	$\frac{n_{2.} \cdot n_{.1}}{n}$	...	$\frac{n_{r.} \cdot n_{.1}}{n}$
$B_2$	$\frac{n_{1.} \cdot n_{.2}}{n}$	$\frac{n_{2.} \cdot n_{.2}}{n}$	...	$\frac{n_{r.} \cdot n_{.2}}{n}$
...	...	...	...	...
$B_s$	$\frac{n_{1.} \cdot n_{.s}}{n}$	$\frac{n_{2.} \cdot n_{.s}}{n}$	...	$\frac{n_{r.} \cdot n_{.s}}{n}$

ciascuna delle frequenze attese deve essere:  $\frac{n_{i.} \cdot n_{.j}}{n} \geq 5$

si calcola il chi-quadro:

$$Q = \sum_{i=1}^r \sum_{j=1}^s \frac{(n_{ij} - \frac{n_{i.} \cdot n_{.j}}{n})^2}{\frac{n_{i.} \cdot n_{.j}}{n}}$$

fissato  $\alpha$ , si stabilisce la regola di decisione:

si rifiuti  $H_0$  se  $Q > X_{1-\alpha}^2((r-1)(s-1))$

(si calcola tramite tabelle)

il p-value corrispondente al valore Q è:

$$\alpha = P(X > Q), \text{ con } X \sim X^2((r-1)(s-1))$$