

Def. di probabilità

Combinatoria (Laplace): $P = \frac{M \text{ favorevoli}}{N \text{ tot. eventi}}$

Teoria frequentistica: $P = \lim_{N \rightarrow \infty} \frac{m \text{ favorevoli}}{N \text{ tot.}}$

Def. assiomatica (teoria matematica)

Dato l'insieme S degli eventi elementari, si definisce

"classe degli eventi" o "sigma algebra" una

collezione Σ di sottoinsiemi di S tali che:

- $S \in \Sigma$
- $A \in \Sigma \Rightarrow \bar{A} \in \Sigma$
- $\{A_m\} \in \Sigma \Rightarrow \bigcup_m A_m \in \Sigma \wedge \bigcap_m A_m \in \Sigma$

Definiamo probabilità una misura tale che:

- $\forall A \in \Sigma \quad 0 \leq P(A) \leq 1$
- $P(S) = 1$
- $\bigcap_m A_m = \emptyset \Rightarrow P(\bigcup_m A_m) = \sum_m P(A_m)$

È detta variabile casuale una funzione del set di sample S che associa ad ogni evento casuale $X_i \in \Sigma$ un numero reale x_i .

Densità di probabilità $P(X \in (x, x+dx)) = f(x) dx$

tale che $\int_{-\infty}^{+\infty} f(x) dx = 1$

Valore d'aspettazione di una variabile casuale: $E(x) = \int_{-\infty}^{+\infty} t f(t) dt$

Varianza $Var(x) = \int_{-\infty}^{+\infty} [t - E(x)]^2 f(t) dt$

Per variabili discrete:

$$E(x) = \sum_i x_i P(x_i) \quad Var(x) = \sum_i [x_i - E(x)]^2 P(x_i)$$

Probabilità condizionata

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

Se A e B sono eventi indipendenti:

$$P(A|B) = P(A) \quad \wedge \quad P(A \cap B) = P(A) \cdot P(B)$$

Teorema di Bayes

$$\{H_i\} : S = \bigcup_i H_i \quad \wedge \quad \forall i, j; H_i \cap H_j = \emptyset \quad \Rightarrow \quad \sum_i P(H_i) = 1$$

$$\text{Se } A \in \Sigma \text{ allora } A = A \cap \left(\bigcup_i H_i\right) = \bigcup_i (A \cap H_i)$$

$$\Rightarrow P(A) = \sum_i P(A \cap H_i) = \sum_i P(A|H_i) P(H_i)$$

Inoltre, dalla def. di probabilità condizionata,

$$P(H_i|A) = \frac{P(A|H_i) \cdot P(H_i)}{P(A)} \Rightarrow$$

$$P(H_i|A) = \frac{P(A|H_i) \cdot P(H_i)}{\sum_j P(A|H_j) \cdot P(H_j)}$$

Com: $P(H_i)$ \equiv probabilità a priori

$P(A|H_i)$ \equiv verosimiglianza

$P(H_i|A)$ \equiv probabilità a posteriori

Per applicare il teorema di Bayes dobbiamo conoscere le probabilità a priori.

Postulato di Bayes Se non c'è evidenza del contrario, allora la distribuzione di probabilità $P(H_i)$ si assume costante.

Principio di massima entropia. Dati dei vincoli conosciuti, si ricava la distribuzione di probabilità che fa minore utilizzo di informazioni esterne massimizzando l'entropia di Shannon: $S = - \int_{\Omega} f(x) \log[f(x)] dx$

DEFINIZIONI

Il risultato di un esperimento è detto evento. L'insieme di tutti i possibili risultati dell'esperimento è detto popolazione. Una collezione di risultati ottenuta ripetendo l'esperimento è detta sample: un sample si dice fiduciario se a partire da esso possiamo inferire le caratteristiche della popolazione. Se un esperimento

è privo di bias, qualsiasi sample ha la stessa probabilità di essere misurato. Un evento casuale è un membro della popolazione, il suo valore numerico è invece una variabile casuale.

Covarianza $Cov(x, y) = E[(x - \mu_x)(y - \mu_y)] = E(x \cdot y) - \mu_x \mu_y$

Momento n-esimo $\mu'_m = E(x^m)$ $\mu_m = E[(x - \mu_x)^m]$

Teorema Se due densità di probabilità f e g hanno gli stessi momenti e se $\forall x \quad f(x) - g(x) = \sum_m c_m x^m \Rightarrow f = g$.

Funzione generatrice dei momenti: $\Phi_x(t) = E(e^{xt}) = \int_{-\infty}^{+\infty} e^{xt} f(x) dx$

tale che $\Phi_x(t) \approx \sum_m \frac{E(x^m)}{m!} t^m = \sum_m \mu'_m \frac{t^m}{m!}$

E quindi $\mu'_m \equiv \frac{\partial^{(m)}}{\partial t^m} E(e^{xt}) \Big|_{t=0}$.

- $\Phi_{ax}(t) = \Phi_x(at)$
- $\Phi_{x+c}(t) = e^{ct} \Phi_x(t)$
- $\Phi_{\sum_i x_i}(t) = \prod_i \Phi_{x_i}(t)$ (x_i variabili casuali indipendenti)

Funzione caratteristica $\phi(t) = E(e^{itx}) = \int_{-\infty}^{+\infty} e^{itx} f(x) dx$

È la trasformata di Fourier della densità di probabilità.

- $\phi(0) = 1$
- $\mu'_m \equiv \frac{1}{i^m} \frac{\partial^{(m)} \phi(t)}{\partial t^m}$
- $f(x) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} \phi(t) e^{-itx} dt$

Funzione generatrice delle probabilità $\Pi(s) \equiv E(s^x) = \sum_i s^{x_i} p(x_i)$

Nel caso $\{x_i\} \in \mathbb{N}$: $\Pi(s) = p_0 + p_1 s + p_2 s^2 + \dots$ in cui

il coefficiente di s^m è la probabilità del risultato m-esimo.

- $\Pi(1) = 1$
- $\Pi'(1) = E(x)$
- $\Pi''(1) = E(x^2) - E(x)^2 \Rightarrow \text{Var}(x) = \Pi''(1) + \Pi'(1) - [\Pi'(1)]^2$

Se x_1, \dots, x_m sono m variabili indipendenti:

$$\bullet \Pi_{\sum x_i}(s) = \prod_i [\Pi_{x_i}(s)]$$

e se le x_i sono i.i.d.: $\Pi_{\sum x_i}(s) = [\Pi_x(s)]^m$

Nei processi di branching la Π è una funzione composta. Ad es.: $y = \sum_{i=1}^m x_i$; x_i , m variabili casuali

$$\Rightarrow \Pi_y(s) = \Pi_m[\Pi_x(s)]$$

$$\text{Coefficiente binomiale } \binom{a}{b} = \frac{a!}{b!(a-b)!}$$

Distribuzione binomiale probabilità di r successi in N prove di Bernoulli (solo 2 possibili risultati):

$$P(r|N) = \binom{N}{r} p^r (1-p)^{N-r} \quad \text{con } p = \text{probabilità del singolo successo.}$$

- $\mu = pN = E(r)$
- $\text{Var}(r) = Np(1-p)$
- $\Phi_r(t) = (pe^t + 1-p)^N$

Distribuzione geometrica Probabilità di ottenere un successo dopo N prove di Bernoulli sfavorevoli:

$$P(N|p) = (1-p)^{N-1} p$$

- $\mu = E(N) = \frac{1}{p}$
- $\text{Var}(N) = \frac{1-p}{p^2}$
- $\Phi_N(t) = \frac{p}{e^t - (1-p)}$
- $\Pi_{\text{geom}}(s) = \frac{ps}{1-s(1-p)}$

Distribuzione di Pascal È una binomiale inversa:

rappresenta la probabilità di dover ripetere una prova di Bernoulli N volte (N è la variabile aleatoria) per ottenere r successi.

$$P(N|r) = \binom{N-1}{r-1} p^r (1-p)^{N-r}$$

- $\Phi_N(t) = \left(\frac{p}{e^{-t} - (1-p)} \right)^r$
- $E(N) = r/p$
- $\text{Var}(N) = \frac{r(1-p)}{p^2}$
- $\Pi_{\text{pois}}(s) = \left(\frac{ps}{1-s(1-p)} \right)^r$

Distribuzione di Poisson $P(r|\mu) = \frac{\mu^r}{r!} e^{-\mu}$

- La probabilità di un evento è costante e indipendente dal tempo
- La probabilità che ci sia UN evento in un tempo dt è μdt
- La probabilità che al tempo t ci siano stati ZERO eventi è: $P(0|t) = e^{-\mu t}$
- La probabilità che al tempo t ci sia stato UN evento è: $P(1|t) = \mu t e^{-\mu t}$
- La probabilità di aver avuto r eventi al tempo t è: $P(r|t) = \frac{(\mu t)^r}{r!} e^{-\mu t}$ $\mu t = \mu$
- $E(r) = \mu$
- $\text{Var}(r) = \mu$
- $\Phi_r(t) = e^{\mu(e^t - 1)}$
- $\Pi_{\text{pois}}(s) = e^{\mu(s-1)}$
- La distribuzione di Poisson è additiva: se $r \sim \text{Poiss}(\mu_1)$, $t \sim \text{Poiss}(\mu_2)$, allora $s = r+t \sim \text{Poiss}(\mu_1 + \mu_2)$.

Distribuzione di Poisson composta

$$r = \sum_{i=1}^m r_i \quad r_i \sim \text{Poiss}(\mu) \quad m \sim \text{Poiss}(\nu)$$

$$P(r|\mu, \nu) = \sum_{m=1}^{\infty} \left[\frac{1}{r!} (m\mu)^r e^{-m\mu} \right] \frac{1}{m!} \nu^m e^{-\nu}$$

- $E(r) = \mu \nu$
- $\text{Var}(r) = \nu \mu (\mu + 1)$
- $\Phi_r(t) = e^{\nu [e^{\mu(e^t - 1)} - 1]}$
- $\Pi_{\text{Poiss. comp.}}(s) = e^{\nu [e^{\mu(s-1)} - 1]}$

Distribuzione ipergeometrica

In una scatola ho N palle bianche ed M nere. Ne estraggo k . La probabilità di aver estratto r palle bianche è $P(r|N, M, k) = \frac{\binom{N}{r} \binom{M}{k-r}}{\binom{N+M}{k}}$

- $E(r) = k E(1) = \frac{kN}{N+M}$
- $Var(r) = \frac{kNM}{(N+M)^2} \left(1 - \frac{k-1}{N+M-1}\right)$

Le distribuzioni binomiale, geometrica, di Pascal, di Poisson, ed ipergeometrica sono distribuzioni discrete (\equiv la variabile aleatoria può assumere solo valori discreti).

Nel caso che la variabile possa assumere valori continui, definiamo la probabilità che x sia contenuta in un piccolo intervallo dx :

$dF = f(x) dx$ dove $f(x)$ è la densità di probabilità ed $F(x)$ è detta distribuzione cumulativa.

Distribuzione uniforme $f(x) = \begin{cases} 0 & \text{se } x < a \vee x > b \\ \frac{1}{b-a} & \text{se } a \leq x \leq b \end{cases}$

- $\Phi_x(t) = \frac{1}{b-a} \frac{e^{bt} - e^{at}}{t}$

- $E(x) = \frac{b+a}{2}$

- $Var(x) = \frac{(b-a)^2}{12}$

Distribuzione esponenziale $f(x) = \frac{1}{\tau} e^{-\frac{x}{\tau}}$

- $\Phi_x(t) = \frac{1}{1-t\tau}$

- $E(x) = \tau$

- $Var(x) = \tau^2$

La distribuzione esponenziale, come la distribuzione di Poisson, è memoryless:

$$P(X > a+b | X > a) = P(X > b) \quad \forall a, b \geq 0$$

Distribuzione normale $f(x|\mu, \sigma) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$

La distribuzione cumulativa è, per una normale standard,

$$F(x) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^x e^{-\frac{y^2}{2}} dy \quad \text{ed ha il significato}$$

di probabilità $F(x) = P(X < x | \mu=0, \sigma=1)$.

De Moivre scoprì la distribuzione normale come limite, per $N \rightarrow \infty$, della distribuzione della somma di N variabili poissoniane identicamente distribuite con media μ e varianza σ^2 .

- $\Phi_x(t) = e^{\mu t + \frac{(\sigma t)^2}{2}}$
- $E(x) = \mu$
- $\text{Var}(x) = \sigma^2$
- $\text{FWHM} = 2\sqrt{2 \log 2} \sigma$.

Distribuzione Gamma $f(x; \alpha, \beta) = \frac{1}{\Gamma(\alpha)\beta^\alpha} x^{\alpha-1} e^{-\frac{x}{\beta}}$

con: $\Gamma(\alpha) = \int_0^\infty y^{\alpha-1} e^{-y} dy$ (funzione gamma).

La funzione gamma gode delle proprietà:

- $\Gamma(\alpha) = (\alpha-1)\Gamma(\alpha-1)$
- $n \in \mathbb{N} \Rightarrow \Gamma(n) = (n-1)!$

La distribuzione esponenziale è una Gamma

con $\alpha \equiv 1$ ($\beta \equiv \tau$).

- $\Phi_x(t) = \frac{1}{(1-\beta t)^\alpha}$
- $E(x) = \alpha\beta$
- $\text{Var}(x) = \alpha\beta^2$

Distribuzione di Cauchy $f(x) = \frac{1}{\pi} \frac{1}{1+x^2}$

- $\text{Var}(x) = \infty$

Densità di probabilità di funzioni di variabili aleatorie

Se $\vec{x} \sim f(\vec{x})$ e $\vec{h} = \vec{h}(\vec{x})$, $f(\vec{x}) d\vec{x} = g(\vec{h}) d\vec{h}$

Segue che $g(\vec{h}) = \sum_{\vec{x}: \vec{h}(\vec{x}) = \vec{h}} f(\vec{x}) \left| \frac{\partial \vec{x}}{\partial \vec{h}} \right|_{\vec{x}}$

(dove l'ultimo fattore è il valore assoluto dello Jacobiano del cambio di variabile $\vec{x} = \vec{x}(\vec{h})$).

Approssimazione lineare

A volte è conveniente utilizzare quest' approssimazione per calcolare la varianza di funzioni di variabili aleatorie. Se $\vec{y} = \vec{y}(\vec{x})$, tronciamo al primo ordine uno sviluppo di Taylor attorno alla media:

$\vec{y}(\vec{x}) \approx \vec{y}(\vec{\mu}) + J \cdot (\vec{x} - \vec{\mu}) + \dots$ dove $\vec{\mu} = \mathbb{E}(\vec{x})$ e

J è la matrice Jacobiana $\frac{\partial y_i}{\partial x_j}$. In questa

approssimazione, $V(\vec{y}) \approx J V(\vec{x}) J^T$, dove $V(\vec{y})$ e

$V(\vec{x})$ sono le matrici di covarianza di \vec{y} ed \vec{x} .

Questa approssimazione è valida se, nel volume in cui varia \vec{x} , \vec{y} è ben approssimata dalla sua derivata prima.

Distribuzione del χ^2 $f(x) = \frac{1}{\Gamma(\frac{k}{2}) 2^{k/2}} x^{\frac{k}{2}-1} e^{-\frac{x}{2}} \equiv \chi_k^2$

Rappresenta la densità di probabilità della

somma di k variabili normali standard elevate al quadrato.

- $\Phi_x(t) = (1-2t)^{-\frac{k}{2}}$

- $E(x) = k$

- $\text{Var}(x) = 2k$

Se le k variabili normali sono invece distribuite come

$N(0, \sigma^2)$, $\chi_k^2 \rightarrow \sigma^2 \chi_k^2$.

Distribuzione di Student $f_{m-1}(x) = \frac{\Gamma(m/2)}{\sqrt{\pi(m-1)} \Gamma(\frac{m-1}{2})} \frac{1}{(1 + \frac{x^2}{m-1})^{m/2}}$

Per $m=2$ la Student si riduce

alla distribuzione di Cauchy. È usata nei test statistici per studiare la significanza della differenza di medie campionarie estratte da una popolazione normale, quando la deviazione standard della popolazione è sconosciuta. La variabile x rappresenta

$$x \equiv t = \frac{\bar{x} - \mu}{\sigma/\sqrt{n}} \cdot \left(\frac{s}{\sqrt{\sigma^2}}\right)^{-1} = \frac{\bar{x} - \mu}{s/\sqrt{n}} \quad \text{dove } s \equiv \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1}$$

ed è quindi il rapporto tra una $N(0,1)$ ed un χ_{m-1}^2 .

- $E(x) = 0$
- $m > 3 \Rightarrow \text{Var}(x) = \frac{m-1}{m-3}$
- $m \rightarrow \infty \Rightarrow x \sim N(0,1)$

Distribuzione di Fisher-Snedecor

$$f_{m,m}(x) = \frac{\Gamma(\frac{m}{2} + \frac{m}{2})}{\Gamma(\frac{m}{2}) \Gamma(\frac{m}{2})} m^{\frac{m}{2}} m^{\frac{m}{2}} \cdot \frac{x^{\frac{m}{2}-1}}{(mx+m)^{\frac{m+m}{2}}}$$

È usata per stabilire la significanza della differenza delle varianze di due campioni indipendenti estratti da una popolazione normale. La variabile x rappresenta il rapporto tra gli estimatori s_m, s_m delle varianze dei due campioni di dimensioni, rispettivamente, $m+1$ ed $m+1$. I test sono condotti sull'ipotesi $\sigma_m^2 = \sigma_m^2 \equiv \sigma^2$

$$\Rightarrow x = \frac{s_m^2}{s_m^2} \sim \frac{\sigma_m^2 \chi_m^2}{m} \left(\frac{m}{\sigma_m^2 \chi_m^2} \right) \sim \frac{\chi_m^2}{m} \frac{m}{\chi_m^2}$$

- $m \geq 3 \Rightarrow E(x) = \frac{m}{m-2}$
- $m \geq 5 \Rightarrow \text{Var}(x) = \frac{2m^2(m+m-2)}{m(m-2)^2(m-4)}$
- $f_{m,m}(x) = f_{m,m}\left(\frac{1}{x}\right)$
- $G_{m,m}(x) \equiv \int_{-\infty}^x f_{m,m}(t) dt \Rightarrow G_{m,m}(x) = 1 - G_{m,m}\left(\frac{1}{x}\right)$

Media campionaria

Se $\{X_i\}_{i=1, \dots, n}$ è una collezione di variabili aleatorie i.i.d., si definisce media campionaria $\bar{X} \equiv \frac{\sum_i X_i}{n}$.

- È anch'essa una variabile aleatoria
- È un operatore lineare
- $\text{Var}(\bar{X}) = \frac{1}{n} \text{Var}(X_i)$
- legge dei grandi numeri: $\lim_{n \rightarrow \infty} P[|\bar{X} - E(X_i)| > \epsilon] = 0$
- teorema del limite centrale: $n \rightarrow \infty \Rightarrow \bar{X} \sim N\left(\mu, \frac{\sigma^2}{n}\right)$

Per n finito:

- $X_i \sim \text{Cauchy} \Rightarrow \bar{X} \sim \text{Cauchy}$
- $X_i \sim N(\mu, \sigma^2) \Rightarrow \bar{X} \sim N\left(\mu, \frac{\sigma^2}{n}\right)$
- $X_i \sim \text{Poisson}(\mu_i) \Rightarrow \bar{X} \sim \text{Poisson}\left(\frac{\sum_i \mu_i}{n}\right)$
- $X_i \sim \binom{N_i}{k} p^k (1-p)^{N_i-k} \Rightarrow \bar{X} \sim \binom{\sum_i N_i}{k} p^k (1-p)^{\sum_i N_i - k}$
- $X_i \sim \exp(\tau) \Rightarrow f(\bar{X} | \tau, n) = \frac{\tau^n}{\Gamma(n)} \bar{X}^{n-1} e^{-\tau \bar{X}}$

Somma dei quadrati rispetto alla media

Per un campione di dimensione n :

$$\sum_{i=1}^n \left(\frac{X_i - \mu}{\sigma}\right)^2 \sim \chi^2_n \quad \text{Ma se } \mu \text{ non è conosciuto:}$$

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

Il problema si è ridotto di un grado di libertà a causa del vincolo $\sum_{i=1}^n (X_i - \bar{X}) = 0$.

Varianza campionaria $s^2 \equiv \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$

- $E(s^2) = \sigma^2$
- $X_i \sim N(\mu, \sigma^2) \Rightarrow \text{Var}(s^2) = \frac{2\sigma^4}{n-1} \wedge s^2 \sim \frac{\sigma^2}{n-1} \chi^2_{n-1}$

DARIA

(potest. test
Z test)

Student
tL

parametri stimatori + Dim
(suff + eff)

VARIAZ + TOTALE

Prob. secondo Kolmogorov / stimatori decision making, ML, test

TANZI (dim)

Liar: cost / grandi numeri / dim: suff, eff, case-soo (+ dim), test d'ipotesi decision making, c-d.

Disuguaglianza di Bienaymé - Chebyshev

\forall densità di probabilità $f(x)$ t.c. $E(x) = \mu$ ed

$E(x - \mu)^2 = \sigma^2$ vale:

$$\forall k \in \mathbb{N} \quad P(|x - \mu| \geq k\sigma) \leq \frac{1}{k^2}$$

$$\begin{aligned} \bullet \text{ Infatti: } \sigma^2 &= \int_{-\infty}^{+\infty} (x - \mu)^2 f(x) dx \\ &\geq \int_{-\infty}^{\mu - k\sigma} (x - \mu)^2 f(x) dx + \int_{\mu + k\sigma}^{+\infty} (x - \mu)^2 f(x) dx \end{aligned}$$

$$\geq (k\sigma)^2 \cdot \left[\int_{-\infty}^{\mu - k\sigma} f(x) dx + \int_{\mu + k\sigma}^{+\infty} f(x) dx \right]$$

$$= (k\sigma)^2 P(|x - \mu| \geq k\sigma)$$

- è la disuguaglianza più "forte" che è possibile ottenere senza sapere nulla su $f(x)$.

Legge dei grandi numeri

Dato un insieme aleatorio di variabili aleatorie iid, di

dimensione n , tale che $\bar{x} \equiv \frac{\sum_{i=1}^n x_i}{n} \wedge \forall i \ E(x_i) = \mu$:

- forma debole: $\lim_{n \rightarrow \infty} P(|\bar{x} - \mu| > \varepsilon) = 0$
- forma forte: $P(\lim_{n \rightarrow \infty} |\bar{x} - \mu| > \varepsilon) = 0$
- dimostrazione per la forma debole per distribuzioni a varianza finita:

$$\text{Var}(\bar{x}) = \frac{\sigma^2}{n} \Rightarrow P(|\bar{x} - \mu| \geq k \frac{\sigma}{\sqrt{n}}) \leq \frac{1}{k^2}$$

$$\varepsilon \equiv k \frac{\sigma}{\sqrt{n}} \Rightarrow k^2 \equiv n \varepsilon^2 / \sigma^2$$

$$P(|\bar{x} - \mu| \geq \varepsilon) \leq \frac{\sigma^2}{n \varepsilon^2} \Rightarrow P(|\bar{x} - \mu| < \varepsilon) > 1 - \frac{\sigma^2}{n \varepsilon^2}$$

$$\Rightarrow \lim_{n \rightarrow \infty} P(|\bar{x} - \mu| < \varepsilon) = 1$$

- Si dice che \bar{x} tende in probabilità a μ .

Teorema del limite centrale

$\{x_i\}$ variabili aleatorie indipendenti t.c. $E(x_i) = \mu_i$
e $\text{Var}(x_i) = \sigma_i^2 < +\infty$, con almeno uno $\sigma_i^2 > 0$.

Definendo $S_m \equiv \sum_{i=1}^m x_i$ e $\sigma_m \equiv \sqrt{\text{Var}(S_m)} = \sqrt{\sum_{i=1}^m \sigma_i^2}$,

allora $Z_m \equiv \frac{S_m - E(S_m)}{\sigma_m}$ converge normalmente
(tende in distribuzione ad $N(0,1)$) per $m \rightarrow +\infty$.

• $\{x_i\}$ iid $\Rightarrow \frac{S_m/m - \mu}{\sigma/\sqrt{m}} \xrightarrow[m \rightarrow +\infty]{\text{Dist}} N(0,1)$

Infatti: \forall distribuzione con momenti $\neq 0$

si ha $\Phi_{X-\mu}(t) = E(e^{(X-\mu)t}) = 1 + 0 + \sigma^2 \frac{t^2}{2!} + \dots$

Se definiamo: $W \equiv \frac{X-\mu}{\sigma/\sqrt{n}} \Rightarrow \Phi_W(t) = \Phi_{X-\mu}\left(\frac{t}{\sigma/\sqrt{n}}\right) =$
 $= 1 + \frac{t^2}{2n}$

Definiamo: $Z \equiv \sum_{i=1}^m W_i = \sum_{i=1}^m \frac{x_i - \mu}{\sigma/\sqrt{m}} = \frac{\bar{X} - \mu}{\sigma/\sqrt{m}}$

Allora $\Phi_Z(t) = [\Phi_W(t)]^m = \left(1 + \frac{t^2}{2m}\right)^m \xrightarrow[m \rightarrow \infty]{} e^{t^2/2}$

che è la $\Phi_X(t)$ per $X \sim N(0,1)$

• $\bar{X} = \frac{\sigma}{\sqrt{m}} Z + \mu \Rightarrow \bar{X} \xrightarrow[m \rightarrow \infty]{\text{Dist}} N\left(\mu, \frac{\sigma^2}{m}\right)$

- Il teorema non vale per distribuzioni che non hanno momenti finiti (ad es. Cauchy).

P-value

Data una ipotesi nulla H_0 , esatta e che specifichi completamente la distribuzione di probabilità di una variabile aleatoria X , e dato un valore x_0 misurato, si definisce p-value la quantità

$$P(X > x_0 | H_0)$$

• H_0 vera $\Rightarrow P(X > x_0 | H_0) \sim U(0,1)$

Test d'ipotesi (test di significato)

H_0 definisce una distribuzione di probabilità per X .

Viene misurato $X = x_0$. Lo sperimentatore deve definire un livello di significanza α tale che

$P(X \geq x_0 | H_0) \leq \alpha \Rightarrow$ lo sperimentatore decide di rigettare H_0 .

Il p-value è una misura di quanto i dati si accordano con H_0 . Se $P(X \geq x_0 | H_0) \leq \alpha$ si dice che il risultato è significativo.

Z-test

Si vuole verificare la media di una distribuzione Gaussiana.

$\forall i \ z_i \sim N(\mu, \sigma^2) \Rightarrow$ si prende la media campionaria

$\bar{z} = \frac{\sum_{i=1}^n z_i}{n}$. L'ipotesi H_0 è:

- $H_0: \mu = \mu_0$

Se H_0 è vera, $\bar{z} \sim N(\mu_0, \frac{\sigma^2}{n}) \Rightarrow z = \sqrt{n} \frac{\bar{z} - \mu_0}{\sigma} \sim N(0, 1)$

- P-value = $2 \int_{|z_{crit}|}^{+\infty} N(0, 1) dz$

T-test (test di Student)

Si vuole verificare la media di una distribuzione Gaussiana

a varianza sconosciuta. Si stima la varianza con

la varianza campionaria $s^2 = \frac{\sum_{i=1}^n (z_i - \bar{z})^2}{n-1}$, $z_i \sim N(\mu, \sigma^2) \forall i$.

- $H_0: \mu = \mu_0$

Se H_0 è vera, $t = \sqrt{n} \frac{\bar{z} - \mu_0}{s} \sim S_{n-1}$ (distribuzione di Student con $n-1$ gradi di libertà).

- P-value = $2 \int_{|t_{crit}|}^{+\infty} S_{n-1}(t) dt$

Distribuzione empirica

Se abbiamo un campione di eventi $\{x_i\}_{i=1, \dots, n}$, si definisce distribuzione empirica:

$$F_n(y) = \begin{cases} 0 & \text{se } y < x_1 \\ i/n & \text{se } x_i < y < x_{i+1} \\ 1 & \text{se } y > x_n \end{cases}$$

(si assume il campione ordinato in ordine di x_i crescente)

Se la distribuzione cumulativa di probabilità della popolazione da cui è estratto il campione è $F(x)$, allora $n \cdot F_n(y) \sim \text{Bin}(F(y), n)$.

- $E(F_n(x_i)) = F(x_i)$
- $\text{Var}(F_n(x)) = \frac{1}{n} F(x) [1 - F(x)]$

Test di Pearson

- H_0 : il campione $\sim f(x)$

Dividiamo gli n elementi del campione in k classi (costruiamo un istogramma), di occupazione $r_1 \dots r_k$. Chiamiamo $m_i = p_i \cdot n$ la predizione di occupazione della classe i -esima se H_0 è vera.

Ciascun r_i ha probabilità binomiale, ma per

il T.L.C., per $n \cdot p_i \geq 5$, $r_i \sim N(m_i, m_i)$.

Se H_0 è vera, $u = \sum_{i=1}^k \frac{(r_i - m_i)^2}{m_i} \sim \chi_{k-1}^2$.

- P-value = $\int_{u_n}^{+\infty} \chi_{k-1}^2(u) du$

Test w^2 di Smirnov, Cramer, Von Mises

Dato un campione $\{x_i\}_{i=1, \dots, n}$ ordinato in ordine crescente, ne costruiamo la distribuzione empirica $F_n(x)$.

• H_0 : la cumulativa della popolazione è $F(x)$.

$w^2 \equiv \int_0^1 [F_n(x) - F(x)]^2 dF = \frac{1}{12n^2} + \frac{1}{n} \sum_{i=1}^n \left[F(x_i) - \frac{2i-1}{2n} \right]^2$ rappresenta la varianza di $F_n(x)$.

Se H_0 è vera, la densità di w^2 non dipende dalla distribuzione di x .

• $E(w^2) = \frac{1}{6n}$

• $\text{Var}(w^2) = \frac{4n-3}{180n^3}$

• $P(n \cdot w^2 > x | H_0) = \frac{1}{\sqrt{16x}} \sum_{k=0}^{\infty} \left[\frac{\Gamma(k+1/2)}{k! \sqrt{\pi}} \sqrt{4k+1} e^{-\frac{(4k+1)^2}{16x}} \cdot K_{1/4} \left(\frac{(4k+1)^2}{16x} \right) \right]$

Test di Kolmogorov - Smirnov

• H_0 : la cumulativa del campione è $F(x)$.

Usiamo come statistica la distanza tra F e la distribuzione empirica. Se H_0 è vera, la distribuzione

di $d_n \equiv \sup_{-\infty < x < \infty} |F_n(x) - F(x)|$ non dipende dalla

forma di H_0 . Si ricava: $(t \equiv \sqrt{n} \cdot d_n)$

• P-value = $P(t \geq t_{n, \alpha} | H_0) = 2 \sum_{k=1}^{\infty} (-1)^{k+1} e^{-2k^2 \frac{t^2}{n}}$

Run-test (test di Wald-Wolfowitz)

• H_0 : una sequenza di eventi è casuale (non presenta trend).

Mescoliamo due serie di dati mettendoli in ordine crescente. Chiamiamo r il numero di run (passaggi da una serie all'altra). Se n, m sono le dimensioni delle serie:

• $E(r) = \frac{2nm}{n+m} + 1$

• $\text{Var}(r) = \frac{2nm(2nm - n - m)}{(n+m)^2(n+m-1)}$

Per $nm > 10$, $r \sim$ gaussiana e si effettua uno z-test

su $z \equiv \frac{r - E(r)}{\sqrt{\text{Var}(r)}} \sim N(0, 1)$.

Normal probability plot

Prendiamo un campione ordinato in modo crescente. Se

$$\forall i \quad x_i \sim N(\mu, \sigma), \text{ ovvero } F(x) = \int_{-\infty}^x \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(t-\mu)^2}{2\sigma^2}} dt,$$

costruiamo una nuova variabile y tale che:

$$F_n(x_i) = \frac{i}{n} = \int_{-\infty}^{y_i(F_n)} \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(t-\mu)^2}{2\sigma^2}} dt \Rightarrow y_i(F_n) \equiv F^{-1}(F_n(x_i))$$

Si chiama "normal probability plot" il plot dei punti

$(x_i, y_i(F_n))$. Se $x_i \sim N(\mu, \sigma)$, i punti si

allineano lungo la retta $y = \frac{x - \mu}{\sigma}$.

Combinazione di k test indipendenti sulla stessa H_0

Supponiamo di avere ottenuto k p-value $\{p_i\}_{i=1, \dots, k}$.

Definiamo $y_i \equiv -\ln p_i$. Ogni $p_i \sim U(0, 1)$ se H_0

è vera, quindi:

$$g(y_i) dy_i = f(p_i) \left| \frac{dp_i}{dy_i} \right| dy_i = e^{-y_i} dy_i$$

$$\Phi_{y_i}(t) = \frac{1}{1-t}$$

$$\text{Definiamo: } u \equiv -2 \sum_{i=1}^k y_i \Rightarrow \Phi_u(t) = \left(\frac{1}{1-2t} \right)^k$$

$\Rightarrow u \sim \chi_{2k}^2$. Il p-value globale sarà allora:

$$\text{P-value} = P(\chi_{2k}^2 \geq -\sum_{i=1}^k \ln p_i) = \int_{u_{\text{crit}}}^{+\infty} \chi_{2k}^2(t) dt$$

Test decisionale

Vogliamo scegliere tra due ipotesi H_0 ed H_1 . Definiamo

una regione critica w_α per H_0 (w_α = regione di accettazione

per H_1). Si dice:

• probabilità di falso rigetto $\alpha = \int_{w_\alpha} f(x|H_0) dx$ = "dimensione" del test

• probabilità di falsa accettazione $\beta = \int_{w_\alpha} f(x|H_1) dx$

• potenza del test $P = 1 - \beta = \int_{w_\alpha} f(x|H_1) dx$

Costruiamo il test fissando α e massimizzando

P (cioè minimizzando β).

Lemma di Neyman - Pearson

Supponiamo: $H_0: x \sim f_0(x)$; $H_1: x \sim f_1(x)$ con f_0 ed f_1 completamente specificate. Date le verosimiglianze $L(x|H_0)$ ed $L(x|H_1)$, fissati α e $t_\alpha: P(t \geq t_\alpha | H_0) = \alpha$, usiamo come statistica di test $t \equiv \frac{L(x|H_1)}{L(x|H_0)}$.

Il test piú potente si costruisce scegliendo w_α , con il vincolo $P(x \in w_\alpha | H_0) = \alpha$, in modo da massimizzare $E_{w_\alpha} \left(\frac{f_1}{f_0} | H_0 \right)$, cioè massimizzando $P(t(x \in w_\alpha) | H_0)$.

Allora rigettiamo H_0 se $t \geq t_\alpha$.

Test decisionale, nel caso di ipotesi complesse, di verosimiglianza

Si usano per testare teorie i cui parametri devono essere stimati a partire dai dati. Si definisce, per una distribuzione $f(x, \vec{\theta})$, la FUNZIONE DI VEROSIMIGLIANZA $L = \prod_{i=1}^n f(x_i, \vec{\theta})$.

Supponiamo che l'ipotesi H_0 ponga restrizioni su alcuni parametri: detto Ω lo spazio dei parametri,

- $H_0: \vec{\theta} \in \omega \subset \Omega$

- $H_1: \vec{\theta} \in \Omega$

Definiamo il RAPPORTO DI MASSIMA VEROSIMIGLIANZA

$$\lambda \equiv \frac{\sup_{\vec{\theta} \in \omega} L(\vec{x} | \vec{\theta})}{\sup_{\vec{\theta} \in \Omega} L(\vec{x} | \vec{\theta})}$$

La densità $\lambda(H_0)$ non è sempre calcolabile, ma Wilks dimostrò che:

- $n \rightarrow \infty \Rightarrow -2 \ln(\lambda) \sim \chi_r^2$

con r = numero di parametri fissati da H_0 . In questo

limite il test diventa:

- $k_\alpha: P(\chi_r^2 > k_\alpha) = \alpha$

- $-2 \ln \lambda \geq k_\alpha \Rightarrow$ rigettare H_0

Estimatori

Un estimatore è una statistica, funzione delle osservazioni, usata per stimare un parametro sconosciuto.

Una statistica non dipende in alcun modo dai parametri della distribuzione.

CONSISTENZA: la stima tende al valore vero del parametro all'aumentare del numero di osservazioni.

NON DISTORSIONE: per campioni finiti, $E(\hat{\theta}) = \theta$, avendo chiamato $\hat{\theta}$ l'estimatore del parametro θ .

SUFFICIENZA: $\hat{\theta}$ è sufficiente quando nessuna altra funzione dei dati aggiunge informazioni su θ .

EFFICIENZA: si dice efficiente l'estimatore a varianza minima.

Disuguaglianza di Cramer - Rao

Dato un estimatore distorto t di una funzione τ del parametro θ : $E(t) = \tau(\theta) + b(\theta)$

$$\text{Var}(t) \geq \frac{\left(\frac{\partial \tau}{\partial \theta} + \frac{\partial b}{\partial \theta}\right)^2}{E\left(\left(\frac{\partial \ln L}{\partial \theta}\right)^2\right)}$$

$$\text{Se } \tau(\theta) = \theta: \text{Var}(t) \geq \frac{1}{E\left(\left(\frac{\partial \ln L}{\partial \theta}\right)^2\right)} \quad (\text{se } b=0)$$

Se vale l'uguaglianza, l'estimatore t è efficiente.

Teorema di fattorizzazione di Neyman - Fisher

Se la verosimiglianza $L = \prod_{i=1}^n f(x_i, \theta)$ è fattorizzabile nella forma

$$L = g(\hat{\theta}, \theta) h(x)$$

allora $\hat{\theta}$ è un estimatore sufficiente per θ .

Rapporto tra sufficienza ed efficienza di un estimatore

Sufficienza \Leftarrow efficienza.

Teorema di Darmois

Se esiste una statistica sufficiente, allora la densità di probabilità appartiene alla famiglia degli esponenziali.

Informazione di Fisher

Si definisce informazione di Fisher: $I_x(\theta) = -E\left(\frac{\partial^2 \ln L}{\partial \theta^2}\right)$.

Si dimostra che: $I_x(\theta) = E\left(\left(\frac{\partial \ln L}{\partial \theta}\right)^2\right)$.

- $I_x(\theta)$ è additiva per misure indipendenti.
- In generale, se $\hat{\theta}$ è un estimatore di θ : $I_x(\theta) \geq I_{\hat{\theta}}(\theta)$
L'informazione si conserva se $\hat{\theta}$ è sufficiente. Infatti:

$$\hat{\theta} \text{ suff.} \Leftrightarrow L(x, \theta) = g(\hat{\theta}, \theta) h(x) \Leftrightarrow$$

$$I_x(\theta) = -E\left(\frac{\partial^2 \ln L}{\partial \theta^2}\right) = -E\left(\frac{\partial^2 \ln g}{\partial \theta^2}\right) = I_{\hat{\theta}}(\theta)$$

- In caso si abbiano più parametri, I ha una forma matriciale: $(I_x(\theta))_{ij} = -E\left(\frac{\partial \ln L}{\partial \theta_i} \cdot \frac{\partial \ln L}{\partial \theta_j}\right)$
- In alcuni casi "regolari": $(I_x(\theta))_{ij} = -E\left(\frac{\partial^2 \ln L}{\partial \theta_i \partial \theta_j}\right)$
- Per variabili normali $X \sim N(\mu, \sigma^2)$:

$$I_x(\mu, \sigma^2) = \begin{pmatrix} 1/\sigma^2 & 0 \\ 0 & 1/2\sigma^4 \end{pmatrix}$$

- Il metodo della massima verosimiglianza fornisce estimatori asintoticamente consistenti, efficienti e distribuiti normalmente. In questo caso la matrice di covarianza $V(\theta)$ è approssimata da $I_x^{-1}(\theta)$.

$$J_n(\theta) = \sum_{i=1}^n \frac{\partial^2}{\partial \theta^2} \ln[f(x_i, \theta)]$$

Dalla legge dei grandi numeri e dalla consistenza di $\hat{\theta}$:

$$\hat{\theta} \xrightarrow{p} \theta \Rightarrow \frac{J_n(\hat{\theta})}{n} \xrightarrow{p} I_x(\theta) \sim n \cdot V^{-1}(\theta)$$

Per la normalità asintotica di $\hat{\theta}$: $(\hat{\theta} - \theta) \sqrt{J_n(\hat{\theta})} \xrightarrow{p} N(0, 1)$

Errore quadratico minimo

Per uno stimatore $\hat{\theta}$ di θ tale che $E(\hat{\theta}) = \theta + b(\theta)$, si definisce:

$$\begin{aligned} \text{mse}(\hat{\theta}) &= E[(T - \theta)^2] = E[(T - E(T) + E(T) - \theta)^2] = \\ &= [E(T) - \theta]^2 + E(T^2) - E^2(T) = b^2(\theta) + \text{Var}(T) \end{aligned}$$

Si dice efficiente lo stimatore a mse minimo.

• Se S è un generico stimatore di θ , e $\hat{\theta}$ uno stimatore efficiente di θ , allora, definendo $\hat{S} = E(S | \hat{\theta})$:

$$\text{mse}(\hat{S}) \leq \text{mse}(S) \quad (\text{teorema di Rao-Blackwell})$$

e l'uguaglianza vale sse $S = \hat{S}$.

TEST DI SIGNIFICATO

1) z-test verificare la media di una distrib. Gaussiana:

$x_i \sim N(\mu, \sigma^2) \forall i$ con σ^2 nota

$H_0: \mu = \mu_0$

$z \equiv \frac{\sqrt{n}}{\sigma} (\bar{x} - \mu_0) \sim N(0, 1)$ se H_0 è vero.

. test a due code.

2) t-test (test di Student)

$x_i \sim N(\mu, \sigma^2) \forall i$ con σ^2 sconosciuta

$H_0: \mu = \mu_0$

Si stima la varianza: $\hat{\sigma}^2 = s^2 \equiv \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1} \sim \chi_{n-1}^2$

$t \equiv \frac{\sqrt{n}}{s} (\bar{x} - \mu_0) \sim S_{n-1}$ se H_0 è vero.

. test a due code.

3) Test di Pearson, verificare la densità di probabilità (o la distribuzione) della popolazione da cui è estratto il campione.

• Dividiamo il campione in k classi. Chiamiamo r_1, \dots, r_k il numero di elementi in ogni classe.

$H_0: x \sim f(x)$

• Chiamiamo: $n_i \equiv \int_{\text{classe}} f(x) dx \cdot n$ (n = dimensione campione)

Per $n_i > 5$, $r_i \sim N(n_i, n_i)$.

$u \equiv \sum_{i=1}^k \frac{(r_i - n_i)^2}{n_i} \sim \chi_{k-1}^2$ se H_0 è vero.

4) w^2 -test (test di Smirnov, Cramer, Von Mises)

$H_0: x \sim f(x)$

• Costruiamo la cumulativa $F(x|H_0) = \int_{-\infty}^x f(t) dt$ e l'empirica $F_n(x)$.

$w^2 \equiv \int_0^1 [F_n(x) - F(x)]^2 dF = \frac{1}{12n^2} + \frac{1}{n} \sum_{i=1}^n \left[F(x_i) - \frac{2i-1}{n} \right]^2 = \text{Var}(F_n(x))$.

Se H_0 è vera, la densità di w^2 è indipendente dalla

densità di x :

$E(w^2) = \frac{1}{6n}$ } se H_0 è vera.

$\text{Var}(w^2) = \frac{4n-3}{180n^3}$

5) Test di Kolmogorov-Smirnov

$H_0: X \sim f(x)$

Costruiamo l'empirica $F_n(x)$ e la cumulativa $F(x)$.
 $T \equiv \sqrt{n} \cdot \sup_{-\infty < x < \infty} |F_n(x) - F(x)|$ è indipendente dalla densità di x , se H_0 è vera.

$P(T \geq t_n | H_0) = 2 \sum_{i=1}^{\infty} (-1)^{i+1} e^{-2i^2 t_n^2}$ se H_0 è vera.

6) Run test (test di Wald, Wolfowitz) verifica l'omogeneità di due campioni di dimensioni m, m (provenienza dalla medesima popolazione).

H_0 : i due campioni sono estratti dalla stessa popolazione.

Uniamo i due campioni e li rimescoliamo ordinando i dati in ordine crescente.

r = numero di volte che, nella sequenza, si passa da un elemento di un campione ad un elemento dell'altro campione (numero di run).

$E(r) = \frac{2mm}{m+m} + 1$
 $Var(r) = \frac{2mm(2mm - m - m)}{(m+m)^2(m+m-1)}$ } se H_0 è vera.

Per $m \cdot m \geq 10$ r ha una distribuzione normale:

$Z \equiv \frac{r - E(r)}{\sqrt{Var(r)}} \sim N(0,1)$ (z-test) se H_0 è vera.

7) TEST ANOVA (analysis of variance) verifica l'omogeneità di più campioni di dati.

(a) $S = \sum_{i=1}^k \sum_{j=1}^{n_i} (x_{ij} - \bar{x}_{..})^2 = \sum_{i=1}^k \sum_{j=1}^{n_i} (x_{ij} - \bar{x}_{i.})^2 + \sum_{i=1}^k n_i (\bar{x}_{i.} - \bar{x}_{..})^2$
 $S = S_A + S_B$
 $S_A = \sum_{i=1}^k \sum_{j=1}^{n_i} (x_{ij} - \bar{x}_{i.})^2$
 $S_B = \sum_{i=1}^k n_i (\bar{x}_{i.} - \bar{x}_{..})^2$
 $S_B = \sum_{i=1}^k n_i \bar{x}_{i.}^2 - 2 \bar{x}_{..} \sum_{i=1}^k n_i \bar{x}_{i.} + \bar{x}_{..}^2 \sum_{i=1}^k n_i$
 $S_B = \sum_{i=1}^k n_i \bar{x}_{i.}^2 - \frac{(\sum_{i=1}^k n_i \bar{x}_{i.})^2}{\sum_{i=1}^k n_i} + \bar{x}_{..}^2 \sum_{i=1}^k n_i$
 $S_B = \sum_{i=1}^k n_i \bar{x}_{i.}^2 - \frac{(\sum_{i=1}^k n_i \bar{x}_{i.})^2}{n} + \bar{x}_{..}^2 n$

• limite centrale

• legge grandi numeri

• estimatori

} DIMOSTR.

• Dimostrazione disuguaglianza di Cramer - Rao

- n osserv. di $x \sim f(x, \theta)$
- L derivabile 2 volte in θ
- t estimatore per $\tau(\theta)$

$$E(t) = \int t(x_i) L(x, \theta) dx_1 \cdot dx_n \equiv \tau(\theta) + b(\theta)$$

Derivando una volta:

$$\int t \frac{\partial}{\partial \theta} L(x, \theta) d\vec{x} = \frac{\partial \tau}{\partial \theta} + \frac{\partial b}{\partial \theta}$$

Usando la derivata logaritmica:

$$\frac{\partial}{\partial \theta} L = L \frac{\partial}{\partial \theta} \ln L \Rightarrow \int t \frac{\partial}{\partial \theta} \ln L L d\vec{x} = \frac{\partial \tau}{\partial \theta} + \frac{\partial b}{\partial \theta} \quad (1)$$

Usando le condiz. di normalizz. della p.d.f.:

$$\int L(x, \theta) d\vec{x} = 1 \quad \text{Derivando a } d\vec{x} \text{ e } d\theta:$$
$$\int \frac{\partial}{\partial \theta} \ln L L d\vec{x} = 0 \Rightarrow 0 = (\tau(\theta) + b(\theta)) \cdot \int \frac{\partial}{\partial \theta} \ln L L d\vec{x} \quad (2)$$

Sottraggo la (2) dalla (1) (sto sottraendo 0):

$$\int (t - \tau - b) \frac{\partial}{\partial \theta} \ln L L d\vec{x} = \frac{\partial \tau}{\partial \theta} + \frac{\partial b}{\partial \theta}$$

Fattorizzando: $[\int (t - \tau - b) L d\vec{x}] \cdot [\int \frac{\partial}{\partial \theta} \ln L L d\vec{x}] = \frac{\partial \tau}{\partial \theta} + \frac{\partial b}{\partial \theta}$

Posso applicare la disug. di Schwartz: $\|a\| \cdot \|b\| \geq \|ab\|$

la applico al quadrato: $\|a\|^2 \|b\|^2 \geq \|ab\|^2$ (considerando come misura $L \cdot d\vec{x}$):

$$[\int (t - \tau - b)^2 L d\vec{x}] \cdot [\int (\frac{\partial}{\partial \theta} \ln L)^2 L d\vec{x}] \geq (\frac{\partial \tau}{\partial \theta} + \frac{\partial b}{\partial \theta})^2$$

Dato che $E(t) = \tau + b$, $\int (t - \tau - b)^2 f(x, \theta) d\vec{x} = \text{Var}(t)$.

Quindi:

$$\text{Var}(t) \geq \frac{(\frac{\partial \tau}{\partial \theta} + \frac{\partial b}{\partial \theta})^2}{E((\frac{\partial}{\partial \theta} \ln L)^2)} \quad \text{c.v.d.}$$

• Dimostrazione equivalenza definizioni di sufficienza

$$(A) \quad P(\vec{X} = \vec{x} | \hat{\theta}(\vec{X}) = \hat{\theta}(\vec{x})) = h(\vec{x}) \quad (h \text{ non dip. da } \theta)$$

$$(B) \quad P(\vec{X} = \vec{x} | \theta) = L(\vec{x}, \theta) = h(\vec{x}) \cdot g(\hat{\theta}(\vec{x}), \theta)$$

(B) \Rightarrow (A)

$A = \{\vec{x}^* \in S : \hat{\theta}(\vec{x}^*) = \hat{\theta}(\vec{x})\}$ (è un evento!)

Allora, $P(\hat{\theta}(\vec{X}) = \hat{\theta}(\vec{x})) = \sum_{\vec{x}^* \in A} P(\vec{X} = \vec{x}^*)$

Avendo supposto:

$$P(\vec{X} = \vec{x}) = h(\vec{x}) g(\hat{\theta}(\vec{x}), \theta) \Rightarrow P(\vec{X} = \vec{x}) = h(\vec{x}) g(\hat{\theta}(\vec{x}))$$

Per cui:

$$P(\hat{\theta}(\vec{X}) = \hat{\theta}(\vec{x})) = \sum_{\vec{x}^* \in A} h(\vec{x}^*) g(\hat{\theta}(\vec{x}^*))$$

$$P(\hat{\theta}(\vec{X}) = \hat{\theta}(\vec{x})) = g(\hat{\theta}(\vec{x})) \cdot \sum_{\vec{x}^* \in A} h(\vec{x}^*)$$

E quindi:

$$P(\vec{X} = \vec{x} | \hat{\theta}(\vec{X}) = \hat{\theta}(\vec{x})) = \frac{P(\vec{X} = \vec{x})}{P(\hat{\theta}(\vec{X}) = \hat{\theta}(\vec{x}))} = \frac{g(\hat{\theta}(\vec{x})) h(\vec{x})}{g(\hat{\theta}(\vec{x})) \sum_{\vec{x}^* \in A} h(\vec{x}^*)} \quad \text{che non dip. da } \theta \text{ c.v.d.}$$

$$(A) \Rightarrow (B) \quad h(\vec{x}) = P(\vec{X} = \vec{x} | \hat{\theta}(\vec{X}) = \hat{\theta}(\vec{x})) = \frac{P(\vec{X} = \vec{x})}{P(\hat{\theta}(\vec{X}) = \hat{\theta}(\vec{x}))} = P(\vec{X} = \vec{x}) / g(\hat{\theta}(\vec{x}), \theta)$$

Dato che $P(\hat{\theta}(\vec{X}) = \hat{\theta}(\vec{x})) = \sum_{\vec{x}^* \in A} P(\vec{X} = \vec{x}^*) = g(\hat{\theta}(\vec{x}), \theta)$ c.v.d.

Cercare dim. teor. di Darmois

• Efficienza \Rightarrow Sufficienza

Nella disug. di Schwartz vale l' "=" quando i due vettori (nel nostro caso: $\hat{\theta} - \tau(\theta) - b(\theta)$ e $\partial_{\theta} \ln L$) sono proporzionali.

Quindi:

condizione di efficienza (minimo varianza): $\partial_{\theta} \ln L = A(\theta) \cdot (\hat{\theta} - \tau(\theta) - b(\theta))$

La condizione di sufficienza è:

$L(x, \theta) = g(\hat{\theta}, \theta) h(x) \Rightarrow \partial_{\theta} \ln L = \partial_{\theta} \ln g(\hat{\theta}, \theta)$ (generica funzione di θ e dello stimatore).

$A(\theta) \cdot (\hat{\theta} - \tau(\theta) - b(\theta))$ è una generica funzione di $\hat{\theta}, \theta$
 \Rightarrow la cond. di efficienza implica quella di sufficienza.

• Dimostrazione TLC nel caso x_i iid

Ipotesi: x_i iid, $\sigma^2 \neq 0$, $\sigma^2 < +\infty$
 $S_n \equiv \sum_{i=1}^n x_i$ $s_n^2 \equiv \sum_{i=1}^n \sigma_i^2 = n\sigma^2$ $\Rightarrow z_n \equiv \frac{S_n - E(S_n)}{\sigma_n} \xrightarrow{nn} N(0,1)$

Dim.: $w_i \equiv \frac{x_i - \mu}{\sqrt{n}\sigma}$ detti μ e σ media e varianza di x .

La f. gen. dei momenti:
 $\Phi_x(t) = E(e^{tx}) \Rightarrow \Phi_{x-\mu}(t) = E(e^{t(x-\mu)}) = 1 + E(x-\mu)t + E(x-\mu)^2 \frac{t^2}{2} + \dots$
 $= 1 + 0 + \sigma^2 \frac{t^2}{2} + \dots$

Quindi: $\Phi_w(t) = \Phi_{x-\mu}(t/\sigma\sqrt{n}) = 1 + 0 + \frac{\sigma^2 t^2}{2\sigma^2 n} + O(n^{-3/2})$

Per $n \rightarrow \infty$ il termine $O(n^{-3/2})$ è trascurabile rispetto al resto.

$z_n \equiv \sum_{i=1}^n w_i = \sum_{i=1}^n \frac{x_i - \mu}{\sigma/\sqrt{n}} = \frac{\bar{x} - \mu}{\sigma/\sqrt{n}}$

$\Phi_{z_n}(t) = [\Phi_{w_i}(t)]^n = \left(1 + \frac{t^2}{2n}\right)^n \xrightarrow{n \rightarrow \infty} e^{t^2/2} = \Phi_{N(0,1)}(t)$

• Teorema di Darwais

Se T una statistica sufficiente la densità di probabilità è della famiglia degli esponenti.

Dim.: T statistica suff. $\hat{\theta} \Rightarrow L(x, \theta) \equiv h(x) g(\hat{\theta}, \theta)$

$\Rightarrow \log L = \log h(x) + \log g(\hat{\theta}, \theta) \Rightarrow \partial_x \partial_{\theta} \ln L = \partial_x \partial_{\theta} \ln g(\hat{\theta}(x), \theta)$

$= (\partial_{\hat{\theta}} \partial_{\theta} g)(\partial_x \hat{\theta})$
 Se $n > 1$ ($\exists x_j$): $\frac{\partial x_j \partial_{\theta} \ln L}{\partial x_j \partial_{\theta} \ln L} = \frac{\partial_{\hat{\theta}} \partial_{\theta} g}{\partial_{\hat{\theta}} \partial_{\theta} g} \frac{\partial x_j \hat{\theta}}{\partial x_j \hat{\theta}} = a(x)$ (indip. da θ)

$\Rightarrow \partial_x \partial_{\theta} \ln L \equiv a(x, \hat{\theta}(x)) b(\theta)$

Integrando: $\ln L = \ln f(x|\theta) = c_1(x) c_2(\theta) + k_1(x) + k_2(\theta)$

Si dimostra anche che la statistica sufficiente è $c_1(x)$.

LEGGE DEI GRANDI NUMERI IN FORMA DEBOLE

n variabili aleatorie X_i i.i.d. se $\exists \mu: E(X_i) = \mu, \Rightarrow$
 $\lim_{n \rightarrow \infty} P\left(\left|\frac{1}{n} \sum_{i=1}^n X_i - \mu\right| > \varepsilon\right) = 0$

Dimostrazione

1 - se le X_i hanno varianza finita:

$\text{Var}(\bar{X}) = \frac{\sigma^2}{n}$ si applica la disug. di Chebyshev:

$$P(|\bar{X} - \mu| \geq k \frac{\sigma}{\sqrt{n}}) \leq \frac{1}{k^2} \quad \text{chiamiamo: } \varepsilon \equiv k \frac{\sigma}{\sqrt{n}} \Rightarrow k^2 = n \frac{\varepsilon^2}{\sigma^2}$$

$$\Rightarrow P(|\bar{X} - \mu| \geq \varepsilon) < \frac{\sigma^2}{n \varepsilon^2} \quad \text{che tende a 0 per } n \rightarrow \infty, \text{ c.v.d.}$$

2 - se \exists o non è finita $\text{Var}(X_i)$:

Trasliamo le variabili per avere $\mu \equiv 0$.

Dalle n misure costruiamo due serie di dati:

$$\forall k = 1 \dots n, \begin{cases} U_k \equiv X_k & \text{se } |X_k| \leq mc \\ U_k \equiv 0 & \text{se } |X_k| > mc \end{cases} \quad \wedge \quad \begin{cases} V_k \equiv 0 & \text{se } |X_k| \leq mc \\ V_k \equiv X_k & \text{se } |X_k| > mc \end{cases}$$

con c costante arbitraria.

Se vale la LLN, $\lim_{n \rightarrow \infty} P\left(\left|\sum_{i=1}^n U_i\right| > \frac{n\varepsilon}{2}\right) = \lim_{n \rightarrow \infty} P\left(\left|\sum_{i=1}^n V_i\right| > \frac{n\varepsilon}{2}\right) = 0.$

$$E(|X_k|) \equiv a \Rightarrow E(U_i^2) = \sum_{|x_i| < mc} x_i^2 f(x_i) \leq mc \sum_{|x_i| < mc} |x_i| f(x_i) \leq mca$$

$$X_i \text{ i.i.d.} \Rightarrow U_i \text{ i.i.d.} \Rightarrow \text{Var}\left(\sum_{i=1}^n U_i\right) = n \text{Var}(U_i)$$

Inoltre: $\text{Var}(U_i) = E(U_i^2) - [E(U_i)]^2$ ma $E(U_i) \xrightarrow{n \rightarrow \infty} E(X_i) = 0$

$$\Rightarrow \text{Var}\left(\sum_{i=1}^n U_i\right) \xrightarrow{n \rightarrow \infty} n E(U_i^2) \leq n^2 ca$$

Applichiamo la disug. di Chebyshev a $\sum U_i$: $P(|y - E(y)| \geq b) \leq \frac{\text{Var}(y)}{b^2}$

$$\Rightarrow P\left(\left|\sum_{i=1}^n U_i\right| > \frac{n\varepsilon}{2}\right) \leq \frac{n^2 ca}{\frac{n^2 \varepsilon^2}{4}}$$

Questo vale $\forall c \Rightarrow$ possiamo anche scegliere $c \rightarrow 0$, dimostrando la prima disuguaglianza.

$$P\left(\sum_{i=1}^n V_i > 0\right) \leq \sum_{i=1}^n P(V_i > 0) = n P(V_i > 0) = n P(|X_i| > mc) =$$

$$= n \sum_{|x_i| > mc} f(x_i) \leq n \sum_{|x_i| > mc} \frac{|x_i|}{mc} f(x_i) = \frac{1}{c} \sum_{|x_i| > mc} |x_i| f(x_i) \xrightarrow{n \rightarrow \infty} 0$$

purché il valore di aspettazione di $|x_i|$ è finito, c.v.d.

Unicità estimatori ML

- Se \exists uno stimatore efficiente, la soluzione ottenuta col metodo della massima verosimiglianza è unica.
- dimostrazione

$$\hat{\theta} \text{ efficiente} \Rightarrow \frac{\partial \ln L}{\partial \theta} = A(\theta) (\hat{\theta} - \tau(\theta) - b(\theta))$$

$$\frac{\partial^2 \ln L}{\partial \theta^2} = (\hat{\theta} - \tau(\theta) - b(\theta)) \frac{\partial A(\theta)}{\partial \theta} + A(\theta) (-1) \left(\frac{\partial \tau(\theta)}{\partial \theta} + \frac{\partial b(\theta)}{\partial \theta} \right)$$

$$\frac{\partial \tau(\theta)}{\partial \theta} + \frac{\partial b(\theta)}{\partial \theta} = A(\theta) \cdot \text{Var}(\hat{\theta}) \text{ se } \hat{\theta} \text{ è efficiente,}$$

quindi:

$$\frac{\partial^2 \ln L}{\partial \theta^2} \Big|_{\theta=\hat{\theta}} = 0 - A^2(\theta) \text{Var}(\hat{\theta}) \leq 0$$

$\ln L$ è una funzione convessa o concavità negativa, ed ha un solo massimo (almeno nelle vicinanze di θ).

$$\Rightarrow \exists! \max(L) \Rightarrow \exists! \hat{\theta}.$$

$$\underline{E\left(\left(\frac{\partial \ln L}{\partial \theta}\right)^2\right) = -E\left(\frac{\partial^2 \ln L}{\partial \theta^2}\right)}$$

- dimostrazione

$$\int d\bar{x} f(\bar{x}, \theta) = 1 \Leftrightarrow \int d\bar{x} L(\theta|x) = 1 \quad \text{Derivo:}$$

$$0 = \int d\bar{x} \frac{\partial L}{\partial \theta} = \int d\bar{x} \frac{\partial \ln L}{\partial \theta} L \quad \text{Derivo ancora:}$$

$$0 = \int d\bar{x} \frac{\partial^2 L}{\partial \theta^2} = \int d\bar{x} \left[L \frac{\partial^2 \ln L}{\partial \theta^2} + \frac{\partial \ln L}{\partial \theta} \frac{\partial L}{\partial \theta} \right] \quad \text{quindi:}$$

$$\int d\bar{x} L \left(\frac{\partial^2 \ln L}{\partial \theta^2} \right) = - \int d\bar{x} \left(\frac{\partial \ln L}{\partial \theta} \right) \left(L \frac{\partial \ln L}{\partial \theta} \right) = - \int d\bar{x} L \left(\frac{\partial \ln L}{\partial \theta} \right)^2$$

$$\Rightarrow E\left(\frac{\partial^2 \ln L}{\partial \theta^2}\right) = -E\left(\left(\frac{\partial \ln L}{\partial \theta}\right)^2\right)$$

Normalità asintotica stimatori ML

Se $\hat{\theta}$ è uno stimatore ML di θ , allora $\hat{\theta} \sim N(\theta, \sigma_{\hat{\theta}}^2)$

$$\text{con } \sigma_{\hat{\theta}}^2 = \frac{1}{E\left(-\frac{\partial^2 \ln L}{\partial \theta^2}\right)}$$

• dimostrazione

$$\int L dx = 1 \Rightarrow \int L \frac{\partial \ln L}{\partial \theta} dx = 0 \Rightarrow E\left(\frac{\partial \ln L}{\partial \theta}\right) = 0$$

Esponiamo con Taylor $\frac{\partial \ln L}{\partial \theta}$ attorno a 0 (attorno al max della verosim.):

$$0 = \frac{\partial \ln L}{\partial \theta} \Big|_{\hat{\theta}} = \frac{\partial \ln L}{\partial \theta} \Big|_{\theta} + (\hat{\theta} - \theta) \frac{\partial^2 \ln L}{\partial \theta^2} \Big|_{\theta' \in (\theta, \hat{\theta})} \Rightarrow \frac{\partial \ln L}{\partial \theta} \Big|_{\theta} = (\hat{\theta} - \theta) \left(-\frac{\partial^2 \ln L}{\partial \theta^2} \Big|_{\theta'} \right)$$

Calcoliamo la varianza di $\frac{\partial \ln L}{\partial \theta}$:

$$\text{Var}\left(\frac{\partial \ln L}{\partial \theta}\right) = E\left(\left(\frac{\partial \ln L}{\partial \theta}\right)^2\right) - \left(E\left(\frac{\partial \ln L}{\partial \theta}\right)\right)^2 = E\left(\left(\frac{\partial \ln L}{\partial \theta}\right)^2\right) = E\left(-\frac{\partial^2 \ln L}{\partial \theta^2}\right)$$

Per il teorema del limite centrale, dato che $\ln L$ è additivo al crescere del numero delle misure,

$$\frac{\frac{\partial \ln L}{\partial \theta} - E\left(\frac{\partial \ln L}{\partial \theta}\right)}{\sqrt{\text{Var}\left(\frac{\partial \ln L}{\partial \theta}\right)}} \xrightarrow{\text{Distribuzione}} N(0, 1) \xleftarrow{\text{dist.}} \frac{\frac{\partial \ln L}{\partial \theta}}{\sqrt{\text{Var}\left(\frac{\partial \ln L}{\partial \theta}\right)}} \quad (E=0)$$

Gli stimatori ML sono consistenti $\Rightarrow \hat{\theta}, \theta' \rightarrow \theta$

$$\text{quindi } \frac{\partial^2 \ln L}{\partial \theta^2} \Big|_{\theta'} \rightarrow E\left(\frac{\partial^2 \ln L}{\partial \theta^2}\right)$$

$$\Rightarrow \text{Dall'espansione con Taylor } \frac{\partial \ln L}{\partial \theta} = (\hat{\theta} - \theta) E\left(-\frac{\partial^2 \ln L}{\partial \theta^2}\right)$$

Quindi:

$$\frac{\frac{\partial \ln L}{\partial \theta}}{\sqrt{E\left(-\frac{\partial^2 \ln L}{\partial \theta^2}\right)}} = \frac{(\hat{\theta} - \theta) E\left(-\frac{\partial^2 \ln L}{\partial \theta^2}\right)}{\sqrt{E\left(-\frac{\partial^2 \ln L}{\partial \theta^2}\right)}} = (\hat{\theta} - \theta) \sqrt{E\left(-\frac{\partial^2 \ln L}{\partial \theta^2}\right)} \sim N(0, 1)$$

$$\Rightarrow \hat{\theta} \sim N\left(\theta, \frac{1}{E\left(-\frac{\partial^2 \ln L}{\partial \theta^2}\right)}\right)$$

$$x^2 \equiv (y - A\theta)^T \frac{1}{\sigma^2} (y - A\theta)$$

$$\begin{aligned} y - A\theta &\equiv y - A\hat{\theta} + A\hat{\theta} - A\hat{\theta} \\ &= y - A\hat{\theta} + A(\hat{\theta} - \theta) \end{aligned}$$

$$x^2 = \frac{1}{\sigma^2} [(y - A\hat{\theta}) + A(\hat{\theta} - \theta)]^T [(y - A\hat{\theta}) + A(\hat{\theta} - \theta)] =$$

$$= \frac{1}{\sigma^2} \left\{ (y - A\hat{\theta})^T (y - A\hat{\theta}) + \cancel{(\theta - \hat{\theta})^T A^T (y - A\hat{\theta})} + \cancel{(y - A\hat{\theta})^T A (\theta - \hat{\theta})} + (\theta - \hat{\theta})^T A^T A (\theta - \hat{\theta}) \right\}$$

I termini misti:

$$(\theta - \hat{\theta})^T A^T (y - A\hat{\theta}) = (y - A\hat{\theta})^T A (\theta - \hat{\theta}) \quad \hat{\theta} = (A^T A)^{-1} A^T y$$

$$= \cancel{y^T A (\theta - \hat{\theta})} - \cancel{\hat{\theta}^T A^T A (\theta - \hat{\theta})} =$$

$$= \cancel{y^T A [\theta - (A^T A)^{-1} A^T y]} - \cancel{y^T A (A^T A)^{-1} A^T [\theta - (A^T A)^{-1} A^T y]} =$$

$$= \cancel{y^T A \theta} - \cancel{y^T A (A^T A)^{-1} A^T y} - \cancel{y^T A (A^T A)^{-1} A^T \theta} + \cancel{y^T A (A^T A)^{-1} A^T (A^T A)^{-1} A^T y}$$

$$= (y - \underbrace{A (A^T A)^{-1} A^T}_{\text{circled}} y) A (\theta - \hat{\theta}) = (y - A A^{-1} A^T^{-1} A^T y) A (\theta - \hat{\theta}) = 0$$

Rimane:

$$x^2 = \frac{1}{\sigma^2} \left[\underbrace{(y - A\hat{\theta})^T (y - A\hat{\theta})}_{\equiv X_{\text{MIN}}^2} + \underbrace{(\theta - \hat{\theta})^T A^T A (\theta - \hat{\theta})}_{\equiv X_{\theta}^2} \right]$$

↑
indipendente da θ

- caratteristiche stimatori
- " " " " ML
- dimostr. unicità
- min x^2 (e ML)
- costruzione int. conf