

Legge della Probabilità Totale

1. $P(A) = P(A | B)P(B) + P(A | B^c)P(B^c)$
2. $P(A) = \sum_j P(A | B_j)P(B_j)$
3. $f_X(x) = \int f_{X|Y}(x | y)f_Y(y) dy$

Regola di Bayes

1. $P(B | A) = \frac{P(A | B)P(B)}{P(A | B)P(B) + P(A | B^c)P(B^c)}$
2. $P(B_i | A) = \frac{P(A | B_i)P(B_i)}{\sum_j P(A | B_j)P(B_j)}$
3. $f_{Y|X}(y | x) = \frac{f_{X|Y}(x | y)f_Y(y)}{\int f_{X|Y}(x | y)f_Y(y) dy}$
4. $p(\theta | y) = \frac{p(y | \theta)p(\theta)}{\int_{\Theta} p(y | \bar{\theta})p(\bar{\theta}) d\bar{\theta}}$

Mixture Process

Siano $f_1(Y), f_2(Y), \dots, f_n(Y)$ delle pdf/pmf. Allora:

$$f(Y) = \sum_{h=1}^n c_h f_h(Y) \quad \text{con} \quad \sum_{h=1}^n c_h = 1$$

Sia $Y | \theta$ una famiglia di variabili casuali indicizzate da θ , e sia θ una variabile casuale con pdf/pmf $G(\theta)$. Allora:

$$f(Y) = \int_{-\infty}^{\infty} f_{\theta}(Y) dG(\theta)$$

Indipendenza Condizionata e Scambiabilità

1. Indipendenza Condizionata

Siano y_1, \dots, y_n delle osservazioni condizionatamente indipendenti dato θ . Allora:

$$p(y_1, \dots, y_n | \theta) = \prod_{i=1}^n p(y_i | \theta)$$

2. Scambiabilità (Exchangeability)

Siano y_1, \dots, y_{10} scambiabili. Allora:

$$p(y_1, \dots, y_{10}) = \int_0^1 p(y_1, \dots, y_{10} | \theta) p(\theta) d\theta$$

Nel caso Bernoulliano (ad esempio $y_i \in \{0, 1\}$), si può scrivere:

$$p(y_1, \dots, y_{10}) = \int_0^1 \theta^{\sum y_i} (1 - \theta)^{10 - \sum y_i} p(\theta) d\theta$$

Modelli a un parametro

1. Modello Binomiale

$$p(Y = y | \theta) = \binom{n}{y} \theta^y (1 - \theta)^{n-y}$$

2. Distribuzione Beta

$$p(x; a, b) = \frac{\Gamma(a+b)}{\Gamma(a)\Gamma(b)} x^{a-1} (1-x)^{b-1}$$

Proprietà:

$$\text{Mode}(x) = \frac{a-1}{(a-1)+(b-1)} = \frac{a-1}{a+b-2}$$

$$\mathbb{E}[x] = \frac{a}{a+b}$$

$$\mathbb{V}(x) = \frac{ab}{(a+b)^2(a+b+1)} = \mathbb{E}[x](1-\mathbb{E}[x]) \cdot \frac{1}{a+b+1}$$

3. Modello Beta-Binomiale

Una prior Beta e un modello binomiale portano a una posterior Beta:

$$p(\theta | y) = \text{Beta}(a+y, b+n-y)$$

Implica:

$$\mathbb{E}[\theta | y] = \frac{a+y}{a+b+n}$$

$$\text{Mode}[\theta | y] = \frac{a+y-1}{a+b+n-2}$$

$$\mathbb{V}(\theta | y) = \mathbb{E}[\theta | y](1-\mathbb{E}[\theta | y]) \cdot \frac{1}{a+b+n+1}$$

4. Previsione (Predizione)

$$\begin{aligned} P(\tilde{Y} = 1 | y_1, \dots, y_n) &= \int_{\Theta} P(\tilde{Y} = 1, \theta | y_1, \dots, y_n) d\theta = \mathbb{E}[\theta | y_1, \dots, y_n] \\ &= \frac{a + \sum_i y_i}{a + b + n} \end{aligned}$$

$$P(\tilde{Y} = 0 | y_1, \dots, y_n) = \frac{b + n - \sum_i y_i}{a + b + n}$$

5. Modello di Poisson

$$\begin{aligned} P(Y_1 = y_1, \dots, Y_n = y_n | \theta) &= \prod_{i=1}^n p(y_i | \theta) = \prod_{i=1}^n \frac{\theta^{y_i} e^{-\theta}}{y_i!} \\ &= \theta^{\sum_i y_i} e^{-n\theta} \prod_{i=1}^n \frac{1}{y_i!} \end{aligned}$$

6. Prior Coniugata: Distribuzione Gamma

$$p(\theta) = \frac{b^a}{\Gamma(a)} \theta^{a-1} e^{-b\theta}$$

Posterior:

$$\theta | y_1, \dots, y_n \sim \text{Gamma} \left(a + \sum_i y_i, b + n \right)$$

Valori attesi e varianze:

$$\mathbb{E}[\theta | y_1, \dots, y_n] = \frac{a + \sum_i y_i}{b + n} = \frac{b}{b+n} \cdot \frac{a}{b} + \frac{n}{b+n} \cdot \frac{\sum_i y_i}{n}$$

$$\mathbb{V}[\theta | y_1, \dots, y_n] = \frac{a + \sum_i y_i}{(b+n)^2} = \frac{\mathbb{E}[\theta | y]}{b+n}$$

Quando $n \gg b$:

$$\mathbb{E}[\theta | y] \approx \bar{y}, \quad \mathbb{V}[\theta | y] \approx \frac{\bar{y}}{n}$$

7. Valori Predittivi Attesi e Varianza

$$\mathbb{E}[\tilde{Y} | y_1, \dots, y_n] = \frac{a + \sum_i y_i}{b + n} = \mathbb{E}[\theta | y]$$

$$\mathbb{V}[\tilde{Y} | y_1, \dots, y_n] = \frac{a + \sum_i y_i}{b + n} \cdot \frac{b + n + 1}{b + n} = \mathbb{E}[\theta | y] \cdot \frac{b + n + 1}{b + n}$$

Modello Normale

Assumiamo di avere un campione $y = (y_1, \dots, y_n)$ di osservazioni indipendenti e identicamente distribuite, tali che

$$y_i \sim \mathcal{N}(\mu, \sigma_y^2), \quad i = 1, \dots, n,$$

dove μ è incognito e σ_y^2 è un parametro noto. Scegliamo una distribuzione a priori normale per μ :

$$\mu \sim \mathcal{N}(\mu_0, \sigma_0^2),$$

con μ_0 e σ_0^2 iperparametri fissati.

Distribuzione Posteriore

La distribuzione posteriore di μ risulta essere anch'essa normale:

$$\mu | \sigma_y^2, y \sim \mathcal{N}(\mu_n, \sigma_n^2),$$

con

$$\mu_n = \frac{\frac{n}{\sigma_y^2} \bar{y} + \frac{1}{\sigma_0^2} \mu_0}{\frac{n}{\sigma_y^2} + \frac{1}{\sigma_0^2}} \quad \text{e} \quad \sigma_n^2 = \frac{1}{\frac{n}{\sigma_y^2} + \frac{1}{\sigma_0^2}},$$

dove \bar{y} è la media campionaria.

Precisioni

Spesso si utilizza la precisione, definita come l'inverso della varianza:

$$\tau_0^2 = \frac{1}{\sigma_0^2} \quad (\text{precisione a priori}),$$

$$\tau_y^2 = \frac{1}{\sigma_y^2} \quad (\text{precisione del campionamento}),$$

$$\tau_n^2 = \frac{1}{\sigma_n^2} \quad (\text{precisione posteriore}).$$

Nel modello, la precisione posteriore risulta essere la somma della precisione a priori e della precisione derivante dai dati:

$$\tau_n^2 = \tau_0^2 + n \tau_y^2.$$

Di conseguenza, la media posteriore si esprime anche in termini di precisioni:

$$\mu_n = \frac{n \tau_y^2}{n \tau_y^2 + \tau_0^2} \bar{y} + \frac{\tau_0^2}{n \tau_y^2 + \tau_0^2} \mu_0.$$

Modello Normale con Parametri Incerti: Prior Normal–Gamma

Assumiamo di avere un campione

$$y_1, \dots, y_n \stackrel{\text{iid}}{\sim} \mathcal{N}(\mu, \sigma^2),$$

con μ e σ^2 incerti.

Dobbiamo definire un modello a priori per la coppia (μ, σ^2) . Utilizziamo la regola della moltiplicazione:

$$p(\mu, \sigma^2) = p(\mu | \sigma^2) p(\sigma^2).$$

Scegliamo:

- $\mu | \sigma^2 \sim \mathcal{N}\left(\mu_0, \frac{\sigma^2}{\kappa_0}\right)$, dove μ_0 è il valore a priori per la media e κ_0 rappresenta la forza (o affidabilità) del prior.
- Definiamo la precisione $\tau^2 = 1/\sigma^2$ e poniamo:

$$\tau^2 \sim \text{Gamma}\left(\frac{\nu_0}{2}, \frac{\nu_0 \sigma_0^2}{2}\right),$$

dove ν_0 e σ_0^2 sono iperparametri che esprimono la quantità di informazione a priori sulla varianza. Questa scelta porta ad un prior congiunto di tipo **Normal-Gamma**, indicato con:

$$\text{NG}(\mu_0, \kappa_0, \frac{\nu_0}{2}, \frac{\nu_0 \sigma_0^2}{2}).$$

Distribuzione Posteriore Coniugata

Il joint posterior di μ e σ^2 è dato da:

$$p(\mu, \sigma^2 | y_1, \dots, y_n) = p(\mu | \sigma^2, y_1, \dots, y_n) p(\sigma^2 | y_1, \dots, y_n).$$

1. Posterior per μ condizionato a σ^2 :

Dall'aggiornamento con i dati si ottiene:

$$\mu | \sigma^2, y \sim \mathcal{N}\left(\mu_n, \frac{\sigma^2}{\kappa_n}\right),$$

dove

$$\kappa_n = \kappa_0 + n, \quad \mu_n = \frac{\kappa_0 \mu_0 + n \bar{y}}{\kappa_0 + n}.$$

2. Posterior per σ^2 (o $\tau^2 = 1/\sigma^2$):

Utilizzando

$$p(\sigma^2 | y) \propto p(\sigma^2) p(y_1, \dots, y_n | \sigma^2) \frac{1}{\sigma^2},$$

si ottiene

$$\frac{1}{\sigma^2} | y \sim \text{Gamma}\left(\frac{\nu_n}{2}, \frac{\nu_n \sigma_n^2}{2}\right),$$

con

$$\nu_n = \nu_0 + n,$$

e

$$\sigma_n^2 = \frac{1}{\nu_n} \left[\nu_0 \sigma_0^2 + (n-1) s^2 + \frac{n \kappa_0}{\kappa_0 + n} (\bar{y} - \mu_0)^2 \right],$$

dove s^2 è la varianza campionaria e \bar{y} la media campionaria.

Pertanto, il joint posterior è un $\text{NG}(\mu_n, \kappa_n, \frac{\nu_n}{2}, \frac{\nu_n \sigma_n^2}{2})$.

Distribuzioni Marginali Post.

- $\mu | \sigma^2, y \sim \mathcal{N}\left(\mu_n, \frac{\sigma^2}{\kappa_n}\right)$.
- $\frac{1}{\sigma^2} | y \sim \text{Gamma}\left(\frac{\nu_n}{2}, \frac{\nu_n \sigma_n^2}{2}\right)$.
- Marginalizzando σ^2 , si ottiene la distribuzione a posteriori per μ che risulta essere una distribuzione t :

$$\mu | y \sim t_{\nu_n}\left(\mu_n, \frac{\sigma_n^2}{\kappa_n}\right).$$

Stima della Media e Confronto degli Stimatori

Un possibile stimatore della media è il *biasn*, definito come la media pesata:

$$\hat{\mu}_b = \frac{n \bar{y} + \kappa_0 \mu_0}{n + \kappa_0} = w \bar{y} + (1-w) \mu_0, \quad \text{con } w = \frac{n}{n + \kappa_0}.$$

Lo stimatore classico per la media, invece, è semplicemente:

$$\hat{\mu}_e = \bar{y}.$$

Le proprietà attese sono:

$$\mathbb{E}[\hat{\mu}_b | \mu = \mu^*] = w \mu^* + (1-w) \mu_0, \quad \mathbb{E}[\hat{\mu}_e | \mu = \mu^*] = \mu^*,$$

mentre i rispettivi errori quadratici medi (MSE) sono:

$$\text{MSE}(\hat{\mu}_e | \mu^*) = \sigma_n^2, \quad \text{MSE}(\hat{\mu}_b | \mu^*) = w^2 \sigma_n^2 + (1-w)^2 (\mu_0 - \mu^*)^2.$$

Prior Non-Informativi di Jeffreys

Sia una trasformazione del parametro data da

$$\eta = g(\theta),$$

con inversa

$$\theta = g^{-1}(\eta),$$

ammettendo che entrambe esistano. La densità corrispondente per η si ottiene tramite la formula di cambio variabile:

$$p(\eta) \propto p(g^{-1}(\eta)) \left| \frac{\partial g^{-1}(\eta)}{\partial \eta} \right|.$$

Per scegliere un prior non-informativo per θ si utilizza il criterio di Jeffreys, cioè:

$$p(\theta) \propto \sqrt{I(\theta)},$$

dove $I(\theta)$ è l'informazione di Fisher definita da

$$I(\theta) = -\mathbb{E} \left[\frac{\partial^2 \log l(y | \theta)}{\partial \theta^2} \middle| \theta \right].$$

Pertanto, anche per il parametro trasformato η si ha:

$$p(\eta) \propto \sqrt{I(\eta)}.$$