

Teorema di Bayes

13 aprile 2017

Si introduce l'equazione di partizione o regola delle probabilità totali. Successivamente si discute il teorema di Bayes.

1 Regola delle probabilità totali

Uno dei prerequisiti per formulare il teorema di Bayes è la regola delle probabilità totali, conosciuta anche come equazione di partizione.

Teorema 1.1 (Equazione di partizione o regola delle probabilità totali)

Sia (S, \mathcal{F}, P) il nostro spazio di probabilità e sia (A_1, A_2, \dots, A_n) una successione finita o numerabile di eventi che partizionano S . Allora se $B \subseteq S$ con $B \in \mathcal{F}$:

$$P(B) = \sum_{i=1}^n P(A_i) \cdot P(B | A_i). \quad (1)$$

Dimostrazione Si ha che

$$B = B \cap S = B \cap (\cup_i A_i) = \cup_i (B \cap A_i).$$

Poiché per definizione di partizione $A_i \cap A_j = \emptyset$, $i \neq j$, allora

$$\begin{aligned} P(B) &= P(B \cap A_1) + P(B \cap A_2) + \dots + P(B \cap A_n) = \\ &= P(A_1) \cdot P(B | A_1) + P(A_2) \cdot P(B | A_2) + \dots + P(A_n) \cdot P(B | A_n) = \\ &= \sum_{i=1}^n P(A_i) \cdot P(B | A_i). \end{aligned}$$

Esempio 1.2 Consideriamo il caso elementare in cui S risulti diviso in due partizioni A e $\sim A$, con B sottoinsieme di S , come mostrato in Figura 1, dunque valgono le seguenti:

$$S = A \cup \sim A$$

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

Applicando ora la misura di probabilità otteniamo,

$$P(B) = P(B \cap A) + P(B \cap \sim A).$$

E per la regola del prodotto:

$$P(B) = P(A) \cdot P(B | A) + P(\sim A) \cdot P(B | \sim A).$$

Mostriamo in Figura 2, la regola delle probabilità totali (2) in forma di albero delle probabilità (chance tree) per chiarire ancora meglio questo semplice esempio.




Figura 1: Spazio campionario partizionato in due eventi




Figura 2: L'equazione di partizione esplicitata come albero di probabilità sullo spazio degli stati di Figura 1

Vediamo ora alcuni esempi di applicazione della regola (2).

Esempio 1.3 Abbiamo una moneta sbilanciata e due urne contenenti palline bianche e nere, lanciamo la moneta e sulla base dell'esito peschiamo da un'urna piuttosto che dall'altra, vogliamo predire la probabilità di pescare una pallina nera sulla base del seguente modello generativo (Tabella 1):

Moneta Sbilanciata	Urna 1	Urna 2
-	5 palline, 3 nere e 2 bianche	5 palline, 4 nere e 1 bianca
$P(T) = \frac{4}{10}$	$P(N) = \frac{3}{5}$	$P(N) = \frac{4}{5}$
$P(C) = \frac{6}{10}$	$P(B) = \frac{2}{5}$	$P(B) = \frac{1}{5}$

Tabella 1: Modello generativo

Dopo aver osservato che la probabilità di pescare dall'urna 1 equivale alla probabilità che esca testa sulla moneta e la probabilità di pescare dall'urna 2 equivale alla probabilità che esca croce ($P(U_1) = P(T)$ e $P(U_2) = P(C)$) costruiamo il seguente chance tree (Figura 3):

L'evento di nostro interesse è N , applichiamo quindi la regola delle probabilità totali (2) per trovare $P(N)$.




Figura 3: Chance tree per il problema delle monete nelle urne

$$\begin{aligned}
 P(N) &= P(U_1) \cdot P(N | U_1) + P(U_2) \cdot P(N | U_2) = \\
 &= \frac{4}{10} \cdot \frac{3}{5} + \frac{6}{10} \cdot \frac{4}{5} = \frac{12}{50} + \frac{24}{50} = \frac{36}{50} = \frac{18}{25}
 \end{aligned}
 \tag{2}$$

Esempio 1.4 Un esperimento prevede il lancio di una moneta, scelta fra un insieme di 3 monete con probabilità uniforme: $P(A) = P(B) = P(C) = \frac{1}{3}$. Ciascuna moneta genera testa o croce secondo il seguente modello

Moneta A	Moneta B	Moneta C
$P(T A) = 1$	$P(T B) = \frac{1}{2}$	$P(T C) = 0$

Tabella 2: Modello generativo delle tre monete

Dunque solo la moneta B è bilanciata.

Vogliamo predire la probabilità complessiva associata all'evento "esce testa".

Utilizziamo l'equazione di partizione (2):

$$\begin{aligned}
 P(T) &= P(A) \cdot P(T | A) + P(B) \cdot P(T | B) + P(C) \cdot P(T | C) = \\
 &= \frac{1}{3} \cdot 1 + \frac{1}{3} \cdot \frac{1}{2} + \frac{1}{3} \cdot 0 = \frac{1}{3} + \frac{1}{6} = \frac{1}{2}
 \end{aligned}
 \tag{3}$$

Come ci aspettavamo, A e C si "annullano" nei loro esiti ed essendo sotto ipotesi di probabilità uniforme, la nostra $P(T)$ equivale alla $P(T)$ di qualunque moneta bilanciata.

Esempio 1.5 Vogliamo calcolare la probabilità di vittoria in un torneo di scacchi considerando che esistono tre tipologie di giocatori di diversa bravura iscritti al torneo.

Sulla base delle iscrizioni, la metà dei giocatori iscritti al torneo è di tipologia 1, 1/4 di tipologia 2, e i restanti di tipologia 3.

La Tabella 3 ci fornisce probabilità di vittoria contro ciascun tipo di giocatore

T_1	T_2	T_3
50%	25%	25%
$P(V T_1) = 0.3$	$P(V T_2) = 0.4$	$P(V T_3) = 0.5$

Tabella 3: Modello generativo per l'esempio 4

Possiamo effettuare una predizione sulla probabilità complessiva di vincere usando l'equazione di partizione (4).

$$\begin{aligned} P(V) &= P(T_1) \cdot P(V | T_1) + P(T_2) \cdot P(V | T_2) + P(T_3) \cdot P(V | T_3) = \\ &= 0.5 \cdot 0.3 + 0.25 \cdot 0.4 + 0.25 \cdot 0.5 = 0.375 \end{aligned} \quad (4)$$

Vediamo ora un esempio più complesso che illustra

- l'aspetto predittivo del teorema delle probabilità totali;
- una formulazione iterativa, che consente di considerare predizioni successive come il risultato dell'evoluzione (temporale) di un sistema dinamico.

Esempio 1.6 Consideriamo i due eventi complementari A_i e $\sim A_i = I_i$ che significano rispettivamente "sono avanti con la preparazione del corso di Statistica al tempo i " e "sono indietro con la preparazione del corso di Statistica al tempo i ".

Sia dato il seguente modello generativo (formulato, per esempio, dopo aver osservato nel tempo comportamenti e risultati di un gruppo di studenti frequentanti il corso) rappresentato con un chance tree in Figura 4):

Supponiamo ora di essere interessati a scoprire la probabilità di essere avanti con la preparazione in un tempo k , applichiamo quindi la (2):

$$\begin{aligned} P(A_{i+1}) &= P(A_i) \cdot P(A_{i+1} | A_i) + P(I_i) \cdot P(A_{i+1} | I_i) = \\ &= 0.8 \cdot P(A_i) + 0.4 \cdot P(I_i) = 0.4 \cdot (2 \cdot P(A_i) + P(I_i)) = \\ &= 0.4 \cdot (2 \cdot P(A_i) + P(\sim A_i)) = 0.4 \cdot (2 \cdot P(A_i) + 1 - P(A_i)) = \\ &= 0.4P(A_i) + 0.4. \end{aligned} \quad (5)$$

Quello che abbiamo appena ottenuto in (5) applicando (2) prende il nome di **definizione iterativa o ricorsiva del modello probabilistico generativo**. Per procedere verso un calcolo effettivo di $P(A_k)$ attraverso l'equazione (5) occorre fissare la base della ricorsione, ovvero $P(A_1)$.




Figura 4: Chance tree che formalizza l'evoluzione del livello di preparazione dell'esame di Statistica dal tempo i al tempo $i + 1$

Fissiamo, per esempio, $P(A_1) = 0.8$ e $k = 3$, qui sotto riportiamo i calcoli (6) che ci permettono di calcolare $P(A_3)$

$$\begin{aligned} P(A_3) &= 0.4 \cdot (1 + P(A_2)) = 0.4 \cdot (1 + 0.4 \cdot (1 + P(A_1))) = \\ &= 0.4 \cdot (1 + 0.4 \cdot (1 + 0.8)) = 0.688 \end{aligned} \quad (6)$$

Possiamo ora introdurre la regola di Bayes.

2 Teorema o regola di Bayes

La regola di Bayes ha trovato numerose applicazioni in campo diagnostico

Esempio 2.1 Sia B l'evento di interesse: una "macchia" sulla radiografia (*effetto*) osservabile dal radiologo. Il problema del radiologo è effettuare la diagnosi, ovvero inferire la possibile *causa* della macchia.

Lo spazio campionario relativo al problema della diagnosi (Figura 5) è partizionato nelle seguenti *cause*:

- A_1 = tumori maligni
- A_2 = tumori benigni
- A_3 = altre malattie

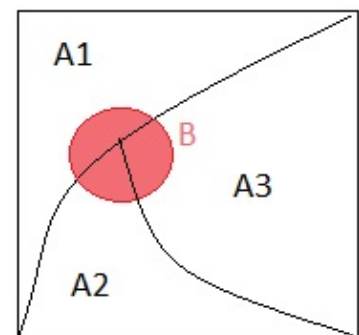


Figura 5: Spazio campionario relativo al problema della diagnosi

Allora il modello generativo (**cause** → **effetto**) mi consente di calcolare la probabilità di B ovvero di effettuare una **predizione**. Sostanzialmente, si considerano nel chance tree (Figura ??) solo i cammini che portano a B e non si considerano quelli che portano a $\sim B$ e si usa la probabilità totale:

$$P(B) = P(A1)P(B | A1) + P(A2)P(B | A2) + P(A3)P(B | A3)$$

Il problema della diagnosi é dunque quello di invertire il modello generativo per inferire la causa piú probabile (Figura 7): **cause** ← **effetto**



Figura 7: Inversione del modello generativo per inferire le cause

Consideriamo lo stesso problema (inferenza) nel caso semplice della selezione (cieca) di una moneta e della conoscenza dell'esito del risultato.

Esempio 2.2 (Lancio delle monete) *Date tre monete A, B, C in un'urna tali che:*

- $P(T | A) = 1$ (sbilanciata),
- $P(T | B) = \frac{1}{2}$ (bilanciata),
- $P(T | C) = 0$ (sbilanciata).

Una moneta viene estratta a caso con probabilità uniforme:

$$P(A) = P(B) = P(C) = \frac{1}{3}$$

Prima di lanciare la moneta e osservare l'esito del lancio, sulla base delle informazioni il modello generativo rappresentato in Figura 9 ci consente di predire che $P(T) = \frac{1}{2}$

L'esperimento viene effettuato: chi ha estratto la moneta la lancia e fornisce la seguente informazione: "É uscita testa".

Problema: osservato l'esito dell'esperimento, su quale moneta sareste disposti a scommettere?

Il problema é inferenziale (**moneta** ← **esito del lancio**: scommetterete sulla moneta che massimizza la seguente probabilità:

$$P(\text{moneta} | \text{esito lancio} = T)$$




Figura 8: Tre monete con diverso bilanciamento




Figura 9: Chance tree ridotto dopo l'osservazione dell'esito "testa"

Intuitivamente, per scommettere sulla moneta A , con riferimento all'albero di possibilità in Figura 9 pesiamo la probabilità di percorrere il ramo $A \rightarrow T$ rispetto a tutti i cammini possibili:

$$P(A \mid \text{esito lancio} = T) = \frac{\text{Prob}(A \rightarrow T)}{\text{Prob}(A \rightarrow T) + \text{Prob}(B \rightarrow T) + \text{Prob}(C \rightarrow T)} = \frac{\text{Prob}(A \rightarrow T)}{P(T)}$$

Chiameremo la $P(A \mid T)$, **probabilità a posteriori** di aver lanciato la moneta A dopo aver osservato l'esito T , ovvero:

$$P(A \mid T) = \frac{P(A) \cdot P(T \mid A)}{P(A) \cdot P(T \mid A) + P(B) \cdot P(T \mid B) + P(C) \cdot P(T \mid C)} = \frac{\frac{1}{3} \cdot 1}{\frac{1}{3} \cdot 1 + \frac{1}{3} \cdot \frac{1}{2} + \frac{1}{3} \cdot 0} = \frac{\frac{1}{3}}{\frac{1}{3} + \frac{1}{6}} = \frac{\frac{1}{3}}{\frac{1}{2}} = \frac{2}{3}$$

La stessa probabilità può essere calcolata per B, C :

$$P(B \mid T) = \frac{P(B) \cdot P(T \mid B)}{P(A) \cdot P(T \mid A) + P(B) \cdot P(T \mid B) + P(C) \cdot P(T \mid C)} = \frac{\frac{1}{3} \cdot \frac{1}{2}}{\frac{1}{3} \cdot 1 + \frac{1}{3} \cdot \frac{1}{2} + \frac{1}{3} \cdot 0} = \frac{\frac{1}{6}}{\frac{1}{2}} = \frac{1}{3}$$

$$P(C \mid T) = \frac{P(C) \cdot P(T \mid C)}{P(A) \cdot P(T \mid A) + P(B) \cdot P(T \mid B) + P(C) \cdot P(T \mid C)} = \frac{\frac{1}{3} \cdot 0}{\frac{1}{3} \cdot 1 + \frac{1}{3} \cdot \frac{1}{2} + \frac{1}{3} \cdot 0} = \frac{0}{\frac{1}{2}} = 0$$

Notiamo il seguente fatto (cfr., Figura 10):

- Prima di osservare l'esito dell'esperimento (**probabilità a priori**):

$$P(A) = \frac{1}{3}, P(B) = \frac{1}{3}, P(C) = \frac{1}{3}$$

- Dopo aver lanciato (**probabilità a posteriori**):

$$P(A \mid T) = \frac{2}{3}, P(B \mid T) = \frac{1}{3}, P(C \mid T) = 0$$




Figura 10: Probabilità di aver utilizzato la moneta A, B, C prima e dopo l'osservazione dell'esito dell'esperimento. La linea rossa serve solo a "guidare lo sguardo".

In sintesi, abbiamo applicato per inferire dall'osservazione la moneta più probabile, il seguente

Teorema 2.3 (Regola di Bayes) Siano E_1, E_2, \dots, E_n eventi che partizionano S . Considerato l'evento $B \subseteq S$, e supposto $P(B) > 0$, allora:

$$P(E_i | B) = \frac{P(B | E_i)P(E_i)}{\sum_{i=1}^n P(B | E_i)P(E_i)} \quad (7)$$

Dimostrazione

Per la definizione di probabilità condizionata:

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

Per la regola del prodotto:

$$= \frac{P(E_i) \cdot P(B | E_i)}{P(B)}$$

Per la regola della probabilità totale:

$$= \frac{P(E_i)P(B | E_i)}{\sum_{i=1}^n P(B | E_i)P(E_i)}$$

2.1 Un'interpretazione piú generale della Regola di Bayes

La regola di Bayes ha una valenza piú generale se si assumono le seguenti:

- $\mathcal{H}_1, \mathcal{H}_2, \dots, \mathcal{H}_n$: ipotesi o teorie (in competizione fra di loro)
- \mathcal{D} : dati/osservazioni

La (7) si può pertanto riscrivere

$$P(\mathcal{H}_i | \mathcal{D}) = \frac{P(\mathcal{D} | \mathcal{H}_i)P(\mathcal{H}_i)}{\sum_{i=1}^n P(\mathcal{D} | \mathcal{H}_i)P(\mathcal{H}_i)} \quad (8)$$

dove si possono fattorizzare le seguenti componenti

- **PROBABILITÀ A POSTERIORI** (dell'ipotesi): $P(\mathcal{H}_i | \mathcal{D})$
- **FUNZIONE DI VEROSIMIGLIANZA** (dei dati, likelihood): $P(\mathcal{D} | \mathcal{H}_i)$, a volte anche scritta come $f(\mathcal{D}; \mathcal{H}_i)$, per evidenziare il fatto che può assumere valori al di fuori dell'intervallo $[0, 1]$
- **PROBABILITÀ A PRIORI** (sulle ipotesi): $P(\mathcal{H}_i)$;

- EVIDENZA (dei dati): $P(\mathcal{D})$, a volte detta funzione di partizione.

L'equazione (8) sintetizza in modo generale il processo di inferenza scientifica: considerato un'insieme di ipotesi o teorie $\{\mathcal{H}_i\}_{i=1}^n$ in competizione fra loro, con plausibilità $P(\mathcal{H}_i)$ sulla base di conoscenza a priori, dopo aver effettuato un esperimento che misura la verosimiglianza $P(\mathcal{D} | \mathcal{H}_i)$ dell'ipotesi \mathcal{H}_i nello spiegare i dati \mathcal{D} , ciascuna ipotesi assume, a posteriori, plausibilità $P(\mathcal{H}_i | \mathcal{D})$.

Osservazione 2.4 *E' importante osservare la doppia valenza di $P(\mathcal{D} | \mathcal{H}_i)$:*

- fissata l'ipotesi \mathcal{H}_i può essere letta come la probabilità condizionata di osservare \mathcal{D} sotto l'ipotesi \mathcal{H}_i ;
- fissati i dati \mathcal{D} , ovvero avendo osservato gli esiti di un esperimento, è una funzione $f(\mathcal{D}; \mathcal{H}_i)$ che, al variare di \mathcal{H}_i , descrive la verosimiglianza (likelihood) delle ipotesi sulla base dei dati a disposizione.

Vediamo alcuni esempi di applicazione.

Esempio 2.5 (Canale binario) *Si consideri il canale binario rappresentato in Figura 11*

Definiamo la probabilità di emissione alla sorgente (trasmettitore t)

$$P(t \rightarrow 0) = p$$

$$P(t \rightarrow 1) = q = 1 - p$$

La probabilità di trasmissione corretta di un bit pari a 0 è formalizzata come:

$$P(r \leftarrow 0 | t \rightarrow 0)$$

e la probabilità di trasmissione corretta di un bit pari a 1

$$P(r \leftarrow 1 | t \rightarrow 1)$$

Ovviamente:

$$P(r \leftarrow 0 | t \rightarrow 1) = 1 - P(r \leftarrow 0 | t \rightarrow 0)$$

$$P(r \leftarrow 0 | t \rightarrow 1) = 1 - P(r \leftarrow 1 | t \rightarrow 1)$$

Per effettuare la predizione $P(r \leftarrow 1)$ si usa l'equazione di partizione:

$$P(r \leftarrow 1) = P(t \rightarrow 1) \cdot P(r \leftarrow 1 | t \rightarrow 1) + P(t \rightarrow 0) \cdot P(r \leftarrow 1 | t \rightarrow 0)$$

Supponiamo ora di osservare al ricevitore $r \leftarrow 1$




Figura 11: Un canale binario dove il trasmettitore o sorgente t può trasmettere 1 ($t \rightarrow 1$) o 0 ($t \rightarrow 0$) e il ricevitore r riceve 1 ($r \leftarrow 1$) o 0 ($r \leftarrow 0$). Il canale di trasmissione è soggetto a rumore che rende più o meno incerto l'esito della trasmissione, con possibilità del "flip" del simbolo trasmesso

Sappiamo statisticamente che 60% dei bit trasmessi dalla sorgente sono 1: questo é il modello del segnale.

Inoltre, l'errore statistico sul canale (commutazione di bit) é pari al 5% (probabilità di sbagliare 0.05). Questo rappresenta il modello del canale.

Dopo aver ricevuto il bit 1, qual é la probabilità che sia stato effettivamente emesso 1 alla sorgente?

Applicando Bayes:

$$P(t \rightarrow 1 | r \leftarrow 1) = \frac{P(r \leftarrow 1 | t \rightarrow 1) \cdot P(t \rightarrow 1)}{P(r \leftarrow 1)} = 0.97$$

Esempio 2.6 (Vasca dei pesci a.k.a. Sushi Delight) C'è una vasca contenente un pesce che può essere un piranha (p) o un pesce bandiera (b).

Viene aggiunto un pesce piranha e poi subito estratto uno dei due in modo casuale. Il risultato dell'estrazione é un piranha.

Qual é la probabilità che il primo pesce presente nella vasca fosse effettivamente un piranha?

Intuitivamente (considerando l'albero delle possibilità di Figura 12:

$$\frac{\text{path1}}{\text{path2} + \text{path1}} = \frac{\frac{1}{2}}{\frac{1}{4} + \frac{1}{2}} = \frac{2}{3}$$

Applicando formalmente Bayes:

$$\begin{aligned} P(P1 = p | E = p, P2 = p) &= \\ P(E = p, P2 = p | P1 = p) \cdot P(P1 = p) &= \\ P(E = p | P2 = p, P1 = p) \cdot P(P2 = p | P1 = p) \cdot P(P1 = p) &= \\ \frac{P(E = p | P2 = p, P1 = p) \cdot P(P2 = p) \cdot P(P1 = p)}{\sum_{i=[\text{"p"}, \text{"b"}]} P(E = p | P2 = p, P1 = i) \cdot P(P2 = p) \cdot P(P1 = i)} &= \\ \frac{P(E = p | P2 = p, P1 = p) \cdot P(P1 = p)}{\sum_{i=[\text{"p"}, \text{"b"}]} P(E = p | P2 = p, P1 = i) \cdot P(P1 = i)} & \end{aligned}$$

Per $i = \text{"p"}$: 1

Per $i = \text{"b"}$: $\frac{1}{2}$




Figura 12: Chance tree per il problema del Sushi Delight