

Intelligenza Artificiale II

Ragionamento probabilistico: rappresentazione

Marco Piastra

Ragionamento probabilistico: rappresentazione

Mondi possibili, sottoinsiemi, eventi

Variabili aleatorie

Probabilità

Marginalizzazione

Condizionalizzazione

Indipendenza, indipendenza condizionale

Modelli grafici

Eventi come sottoinsiemi di mondi possibili

■ Fbf e insiemi di *mondi possibili*

Si consideri un linguaggio logico L (p.es. del primo ordine)


A ciascuna fbf (chiusa) φ di L corrisponde un sottoinsieme di tutte le possibili strutture semantiche che soddisfano φ

Vale a dire, a ciascuna fbf (chiusa) φ corrisponde $\{\langle U, v \rangle : \langle U, v \rangle \models \varphi\}$

(assumiamo per semplicità di mantenere fisso U)

Ciascuna struttura semantica $\langle U, v \rangle$ rappresenta un *mondo possibile*

Quindi a ciascuna a ciascuna fbf (chiusa) φ corrisponde un insieme di *mondi possibili*



Intuitivamente

Un **evento** può esser visto come un sottoinsieme di *mondi possibili*:

un evento si **verifica** quando il *mondo attuale* appartiene al corrispondente sottoinsieme

L'agente usa le *descrizioni* (fbf) degli *eventi* e non sa qual'è il mondo attuale

Possibilità

■ Conoscenze oggettive e fbf possibili

L'agente possiede un sistema di conoscenze oggettive

Detta Γ la teoria che rappresenta le conoscenze dell'agente,

l'insieme dei *mondi possibili* (per l'agente) è $W \equiv \{ \langle U, v \rangle : \langle U, v \rangle \models \Gamma \}$

P.es. l'agente sa che $\varphi \vee \psi$

quindi solo i mondi $\{ \langle U, v \rangle : \langle U, v \rangle \models \varphi \vee \psi \}$ sono *possibili* (per l'agente)


Vuol dire che l'evento $\varphi \vee \psi$ si è già *verificato*?

Viceversa il valore di verità di una fbf χ potrebbe non essere noto (all'agente):

$$\varphi \vee \psi \not\models \chi$$

$$\varphi \vee \psi \not\models \neg\chi$$

Conoscenze oggettive significa che l'agente è sicuro che il mondo attuale sia incluso in W



■ Una misura dei sottoinsiemi di W

$W \equiv \{ \langle U, v \rangle : \langle U, v \rangle \models \Gamma \}$ dove Γ sono le conoscenze dell'agente

$P(\cdot)$ è una *funzione* che assegna un numero reale agli elementi di una σ -algebra Σ formata da sottoinsiemi di W

σ -algebra


Una collezione di sottoinsiemi Σ di un insieme W per cui valgono le seguenti proprietà:

- 1) Σ non è vuota
- 2) Se $\varphi \in \Sigma$ allora $\neg\varphi \in \Sigma$
($\neg\varphi$ inteso come *complemento* rispetto a W)
- 3) Per qualsiasi collezione numerabile $\{\varphi_i\}$, $\varphi_i \in \Sigma$, si ha $\bigcup_i \varphi_i \in \Sigma$

Corollario:

Gli insiemi \emptyset e W appartengono a qualsiasi σ -algebra generata su W

Gli elementi della σ -algebra sono gli **eventi**



- Una misura dei sottoinsiemi di W

$W \equiv \{ \langle U, v \rangle : \langle U, v \rangle \models \Gamma \}$ dove Γ sono le conoscenze dell'agente


$P(\cdot)$ è una *funzione* che assegna un numero reale agli elementi di una σ -algebra Σ formata da sottoinsiemi di W

Caso particolare:

σ -algebra generata su W dalle fbf di L

I sottoinsiemi $\{ \langle U, v \rangle : \langle U, v \rangle \models \varphi \} \cap W$ che corrispondono alle fbf φ di L formano un'algebra di Boole su W tramite le operazioni di unione e complemento (vedi IA1)

Qualsiasi algebra di Boole è anche una σ -algebra



Gli **eventi** di questa σ -algebra sono insiemi di *mondi possibili*

Più precisamente, sono i sottoinsiemi di W che corrispondono alle fbf di L

■ Una misura dei sottoinsiemi di W

$W \equiv \{ \langle U, v \rangle : \langle U, v \rangle \models \Gamma \}$ dove Γ sono le conoscenze dell'agente


$P(\cdot)$ è una *funzione* che assegna un numero reale agli elementi di una σ -algebra Σ formata da sottoinsiemi di W

$P(\cdot)$ è una *misura* della σ -algebra Σ

- 1) Per qualsiasi evento $\varphi \in \Sigma$, $P(\varphi) \geq 0$
- 2) $P(W) = 1$
- 3) Per qualsiasi sequenza numerabile φ_i di eventi *disgiunti* di Σ (*disgiunti* $\Leftrightarrow \varphi_i \cap \varphi_j \equiv \emptyset$ se $i \neq j$) si ha
$$P(\varphi_1 \vee \varphi_2 \vee \dots \vee \varphi_n) = \sum_i P(\varphi_i)$$

Corollario:

Per qualsiasi *evento* $\varphi \in \Sigma$, si ha $0 \leq P(\varphi) \leq 1$




Partizioni, variabile aleatoria* (* Nel caso di W discreto

■ Partizione

Ciascuna fbf (chiusa) φ suddivide W
in due sottoinsiemi disgiunti, φ e $\neg\varphi$

(Quindi $P(\varphi) + P(\neg\varphi) = P(W) = 1$, da cui $P(\neg\varphi) = 1 - P(\varphi)$)



■ Variabile aleatoria

Si consideri una variabile X che ha $\{x_1, x_2, \dots, x_n\}$ come *dominio*

In ciascun mondo possibile X assume un determinato valore x_i


I possibili valori $v(X) = x_1, v(X) = x_2, \dots, v(X) = x_n$ definiscono una *partizione* di W in base ad X

- X è una variabile aleatoria
- Ciascun $v(X) = x_i$ è un evento (un sottoinsieme di W)

(Anche φ può essere vista come una variabile aleatoria)

Le v.a. binarie o *binomiali* sono anche dette *bernoulliane*

Le v.a. a più valori sono dette *multinomiali*



(*) Nel caso di W discreto

Variabili aleatorie, distribuzione congiunta*

Essendo $X=x_i$ e $X=x_j$ eventi disgiunti: $P(X=x_i \vee X=x_j) = P(X=x_i) + P(X=x_j)$ se $i \neq j$

■ Variabili aleatorie multiple

Solitamente, in una rappresentazione probabilistica convivono più variabili aleatorie


Esempi:

X_i occorrenza in un'email di una parola i

Y classificazione della stessa email come spam

Ciascuna combinazione di valori delle v.a. è un *evento*

Un'insieme di v.a. definisce una partizione di V



■ Distribuzione di probabilità congiunta (*joint probability distribution*)

Per un determinato insieme di variabili aleatorie, p.es. X, Y, Z

È una funzione $P(X=x_i \wedge Y=y_j \wedge Z=z_k)$ che associa un numero reale a ciascuna combinazione di valori $\langle x_i, y_j, z_k \rangle$

Si indica anche con $P(X=x_i, Y=y_j, Z=z_k)$ oppure $P(X, Y, Z)$

Dato che X, Y e Z definiscono una partizione di V :
$$\sum_i \sum_j \sum_k P(X=x_i, Y=y_j, Z=z_k) = 1$$

Marginalizzazione

L'eliminazione di una variabile aleatoria da una probabilità congiunta

Data una probabilità congiunta

$$P(X=x_i, Y=y_j, Z=z_k)$$

La *probabilità marginale* $P(X=x_i, Y=y_j)$ si ottiene per sommatoria:

$$P(X=x_i, Y=y_j) = \sum_k P(X=x_i, Y=y_j, Z=z_k)$$


Data una probabilità congiunta su una partizione,

si può sempre ottenere una probabilità congiunta su una partizione contenuta nella prima

Probabilità condizionale

■ Definizione

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



■ Significato

È una forma di *inferenza*: si passa da un'insieme di mondi possibili ad un altro

Quindi, da una misura di probabilità ad un'altra

Si assuma un agente consideri W come insieme di mondi possibili


$P(A)$ è la probabilità che A si verifichi

Si supponga che l'agente venga a sapere che l'evento B si è verificato

L'evento complementare $\neg B$ è quindi *impossibile*

$W' \equiv B$ è il nuovo insieme dei mondi possibili

$P(A|B)$ è la nuova probabilità
che l'evento A si verifichi



Esempio: distribuzione congiunta

(*Vedi anche DutchBook.xls)

La conoscenza della distribuzione di probabilità congiunta permette di stabilire la probabilità di qualsiasi combinazione logica di eventi

Esempi:

$$P(A \vee C) = \sum_B P(A \vee C, B) = 0.55$$

($0.55 \cdot x$) dovrebbe essere la somma che siete disposti a scommettere per una vincita x

$$P(\neg A \wedge \neg B) = \sum_C P(\neg A \wedge \neg B, C) = 0.22$$

<i>A</i>	<i>B</i>	<i>C</i>	<i>P(A, B, C)</i>
0	0	0	0.10
0	0	1	0.12
0	1	0	0.35
0	1	1	0.08
1	0	0	0.01
1	0	1	0.02
1	1	0	0.23
1	1	1	0.09

Esempio: probabilità condizionale

La conoscenza della distribuzione di probabilità congiunta permette di stabilire qualsiasi probabilità condizionale

Esempio:

<i>A</i>	<i>B</i>	<i>C</i>	<i>P(A, B, C)</i>
0	0	0	0.10
0	0	1	0.12
0	1	0	0.35
0	1	1	0.08
1	0	0	0.01
1	0	1	0.02
1	1	0	0.23
1	1	1	0.09

$$P(A \vee C \mid B=1) = \frac{P(A \vee C, B=1)}{P(B=1)} = \frac{0.40}{0.75} = 0.53$$

$P(A \vee B)$ era 0.55:

la conoscenza $B=1$ diminuisce, in questo caso, il valore della scommessa al totalizzatore

Teorema di Bayes (T. Bayes, 1764)



■ Definizione

Una relazione tra probabilità condizionali e marginali

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

Nelle applicazioni pratiche, $P(B|A)$
viene anche detta verosimiglianza (*likelihood*) $L(A|B)$

$$P(A|B) \propto L(A|B) P(A)$$

Corollario della definizione di probabilità condizionale (*chain rule*)


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

Per la definizione di marginalizzazione: $P(B) = \sum_A P(A, B) = \sum_A P(B|A) P(A)$

Da cui (formulazione alternativa del teorema di Bayes):

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

Esercizio: informazioni e scommesse



- Due buste, una viene estratta

Una busta contiene due gettoni rossi e due neri, vale 1 euro

Una busta contiene un gettone rosso e due neri, non vale nulla

La busta è stata estratta.

Prima di scommettere, potete estrarre un gettone

a) Il gettone è nero. Quanto scommettete?

b) Il gettone è rosso. Quanto scommettete?

Obiettivo: mostrare che il teorema di Bayes semplifica la rappresentazione e i calcoli

Indipendenza, indipendenza condizionale

- **Indipendenza** (anche detta indipendenza *marginale*)

Due eventi sono indipendenti se la probabilità congiunta è uguale al prodotto delle probabilità marginali

$$\langle A \perp B \rangle \quad \Rightarrow \quad P(A, B) = P(A) P(B)$$

- **Indipendenza condizionale**

Due eventi sono condizionalmente indipendenti (dato un terzo evento) se la probabilità condizionale congiunta è uguale al prodotto delle probabilità condizionali marginali

$$\langle A \perp B \mid C \rangle \Rightarrow P(A, B \mid C) = P(A \mid C) P(B \mid C)$$

$$\Rightarrow P(A \mid B, C) = \frac{P(A, B \mid C)}{P(B \mid C)} = \frac{P(A \mid C) P(B \mid C)}{P(B \mid C)} = P(A \mid C)$$

Questa è la proprietà più rilevante

Modelli grafici (anche Bayesian Networks)

Struttura + numeri, invece di soli numeri


- Un modo per rappresentare una distribuzione di probabilità congiunta

I nodi sono variabili aleatorie

Gli archi (orientati) rappresentano dipendenza

Notare che la specifica di una distribuzione congiunta di quattro v.a. richiederebbe $2^4 = 16$ valori
In figura i valori sono solo 9

C	P(S=F)	P(S=T)
F	0.5	0.5
T	0.9	0.1



C	P(R=F)	P(R=T)
F	0.8	0.2
T	0.2	0.8

S	R	P(W=F)	P(W=T)
F	F	1.0	0.0
T	F	0.1	0.9
F	T	0.1	0.9
T	T	0.01	0.99


Da un modello grafico alla probabilità congiunta

■ Distribuzione congiunta

Può essere espressa come prodotto di probabilità condizionali

(estensione della *chain rule*)

C	P(S=F)	P(S=T)
F	0.5	0.5
T	0.9	0.1



C	P(R=F)	P(R=T)
F	0.8	0.2
T	0.2	0.8

Esempio:

$$P(C, S, R, W) = P(C)P(S|C)P(R|S,C)P(W|R,S,C)$$

In un modello grafico, la distribuzione congiunta è un prodotto delle probabilità condizionali dei nodi

$$P(X_1, X_2, \dots, X_n) = \prod_i P(X_i | \text{parents}(X_i))$$

Dove $\text{parents}(X_i)$ sono i nodi afferenti (diretti) del grafo orientato

Nell'esempio:

$$P(C, S, R, W) = P(C)P(S|C)P(R|C)P(W|R,S)$$

Assunzioni implicite: $\langle R \perp S | C \rangle, \langle W \perp C | R, S \rangle$

S	R	P(W=F)	P(W=T)
F	F	1.0	0.0
T	F	0.1	0.9
F	T	0.1	0.9
T	T	0.01	0.99

Modello grafico e indipendenze condizionali

■ *D-separation (Dependency-separation)*

Come si 'legge' l'indipendenza condizionale in un modello grafico


In un modello grafico

Due nodi X e Y sono condizionalmente indipendenti dato un insieme di nodi $\{Z_k\}$ se tutti i percorsi tra X e Y sono bloccati


Nel determinare i possibili percorsi tra due nodi, si ignora il verso degli archi

Un percorso tra X e Y è bloccato se:


- 1) Il percorso contiene una sequenza $X \rightarrow Z_i \rightarrow Y$ oppure una diramazione (*fork*) $X \leftarrow Z_i \rightarrow Y$ ($Z_i \in \{Z_k\}$)
- 2) Il percorso contiene una confluenza (*join*) $X \rightarrow N \leftarrow Y$ in cui N e tutti i discendenti di N non appartengono a $\{Z_k\}$



$\langle \text{WetGrass} \perp \text{Cloudy} \mid \text{Sprinkler} \rangle$



$\langle \text{Sprinkler} \perp \text{Rain} \mid \text{Cloudy} \rangle$



$\langle \text{Sprinkler} \perp \text{Rain} \rangle$
se WetGrass non è noto

Explaining Away

Ulteriori osservazioni sulla condizione 2) della *D-separation*

Modello grafico con un *join*

Probabilità congiunta, dal grafo:

$$P(X, Y, Z) = P(X)P(Y)P(Z|X, Y)$$

Probabilità marginale rispetto a X e Y (valore di Z incognito):

$$P(X, Y) = P(X)P(Y) \sum_Z P(Z|X, Y) = P(X)P(Y)$$

Quindi X e Y sono *marginamente indipendenti*


Ma se il valore di Z è noto, allora X e Y sono *dipendenti*:

$$P(X, Y | Z=v) = \frac{P(X, Y, Z=v)}{P(Z=v)} = \frac{P(X)P(Y)P(Z=v|X, Y)}{\sum_{X, Y} P(X)P(Y)P(Z=v|X, Y)}$$

Non è un paradosso.


Esempio:

X e Y sono due lanci della stessa moneta, $Z=1$ se il risultato è lo stesso, $Z=0$ altrimenti.




Esempi di modelli grafici

■ Dipendenza completa




$$P(X_1, X_2, X_3, X_4) = P(X_1)P(X_2 | X_1)P(X_3 | X_1, X_2)P(X_4 | X_1, X_2, X_3)$$

■ Modello di Markov



$$P(X_1, X_2, X_3, X_4) = P(X_1)P(X_2 | X_1)P(X_3 | X_2)P(X_4 | X_3) = P(X_1) \prod_{i=2}^n P(X_i | X_{i-1})$$

■ Modello 'Hidden Markov'



In genere, i nodi X_i sono *hidden*, nel senso di *non-osservabili*

$$\begin{aligned} P(X_1, X_2, X_3, X_4, Y_1, Y_2, Y_3, Y_4) &= P(X_1)P(Y_1 | X_1)P(X_2 | X_1)P(Y_2 | X_2)P(X_3 | X_2)P(Y_3 | X_3)P(X_4 | X_3)P(Y_4 | X_4) \\ &= P(X_1)P(Y_1 | X_1) \prod_{i=2}^n P(X_i | X_{i-1})P(Y_i | X_i) \end{aligned}$$