

# *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)  $\varphi$  di  $L$  corrisponde un sottoinsieme di tutte le possibili strutture semantiche che soddisfano  $\varphi$

Vale a dire, a ciascuna fbf (chiusa)  $\varphi$  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)  $\varphi$  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  $\Gamma$  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  $\chi$  potrebbe non essere noto (all'agente):

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

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



## ■ Una misura dei sottoinsiemi di $W$

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

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

### $\sigma$ -algebra


Una collezione di sottoinsiemi  $\Sigma$  di un insieme  $W$  per cui valgono le seguenti proprietà:

- 1)  $\Sigma$  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  $\sigma$ -algebra generata su  $W$

Gli elementi della  $\sigma$ -algebra sono gli **eventi**



- Una misura dei sottoinsiemi di  $W$

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


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

Caso particolare:

$\sigma$ -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  $\varphi$  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  $\sigma$ -algebra



Gli **eventi** di questa  $\sigma$ -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  $\Gamma$  sono le conoscenze dell'agente

$P(.)$  è una *funzione* che assegna un numero reale agli elementi di una  $\sigma$ -algebra  $\Sigma$  formata da sottoinsiemi di  $W$


$P(.)$  è una *misura* della  $\sigma$ -algebra  $\Sigma$

- 1) Per qualsiasi evento  $\varphi \in \Sigma$ ,  $P(\varphi) \geq 0$
- 2)  $P(W) = 1$
- 3) Per qualsiasi sequenza numerabile  $\varphi_i$  di eventi *disgiunti* di  $\Sigma$  (*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  $0 \leq P(\varphi) \leq 1$

(\*Vedi anche DutchBook.xls)




# Partizioni, variabile aleatoria\* (\* Nel caso di $W$ discreto

## ■ Partizione

Ciascuna fbf (chiusa)  $\varphi$  suddivide  $W$   
in due sottoinsiemi disgiunti,  $\varphi$  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  $\varphi$  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  $x$

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

$A$	$B$	$C$	$P(A, B, C)$
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 \$1.00

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, per vincere \$1.00 ?

b) Il gettone è rosso. Quanto scommettete, per una vincita \$1.00 ?

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

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

- **Indipendenza condizionale**

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

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

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

Questa è la proprietà più rilevante

**ATTENZIONE:** le due forme di indipendenza sono disgiunte!

$$\langle A \perp B \rangle \not\Rightarrow \langle A \perp B | C \rangle, \langle A \perp B | C \rangle \not\Rightarrow \langle A \perp B \rangle$$



# 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

P(C=F)	P(C=T)
0.5	0.5



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 *dependenti*:

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

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*

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