

Reti Bayesiane: Inferenza

Intelligenza Artificiale B
Prof. Alfonso E. Gerevini

Classi di Variabili

- Variabili di *query* (dato un *evento osservato*)
- Variabili di *prova/evidenza*: $\mathbf{E}: E_1 \dots E_m$
- Variabili non di prova (*nascoste*): $\mathbf{Y}: Y_1 \dots Y_k$
- Evento osservato \mathbf{e} : insieme di valori per \mathbf{E}
- Tipicamente ho una sola variabile di query (X) e un insieme di variabili prova
- Sono interessato a calcolare $P(X|\mathbf{e})$:
ad es. $P(\text{Furto}=\text{true}|\text{Tel-J}=\text{true}, \text{Tel-M}=\text{true})$

Inferenza

Calcolare la probabilità a posteriori di un insieme di variabili di query dato il valore esatto di alcune variabili prova (evidenza)

Quattro tipologie

- Inferenza *Diagnostica*, es. $P(\text{Furto} | \text{Allarme})$
- Inferenza *Causale*, es. $P(\text{Tel-Mary} | \text{Furto})$
- Inferenza *Intercausale*, es. $P(\text{Furto} | \text{Allarme}, \text{Terremoto})$
- Inferenza *Mista*
 - Diagnostico causale, es. $P(A | T-M, \text{Terremoto})$
 - Intercausale e diagnostica, es. $P(\text{Furto} | \text{Tel-Mary}, \text{Terr.})$

Inferenza per Enumerazione

- $P(X|\mathbf{e}) = P(X, \mathbf{e})/P(\mathbf{e}) = \alpha P(X, \mathbf{e})$
- $P(X|\mathbf{e}) + P(\neg X|\mathbf{e}) = 1 = P(X, \mathbf{e})/P(\mathbf{e}) + P(\neg X, \mathbf{e})/P(\mathbf{e})$
 $\Rightarrow \alpha (P(X, \mathbf{e}) + P(\neg X, \mathbf{e})) = 1$ con $\alpha = 1/P(\mathbf{e})$
 $\Rightarrow \alpha = 1 / (P(X, \mathbf{e}) + P(\neg X, \mathbf{e}))$
 \Rightarrow posso calcolare α dopo aver calcolato $P(X, \mathbf{e})$
e $P(\neg X, \mathbf{e})$
- $P(X|\mathbf{e}) = \alpha P(X, \mathbf{e}) = \alpha \sum_y P(X, \mathbf{e}, y)$
marginalizzazione di $P(X, \mathbf{e})$
con Y

Inferenza per Enumerazione

Esempio Furto/intrusione

Notazione: t-j: T-J=true, t-m: T-M=true, f: F=True, t: valore di Terremoto, a: valore di Allarme

$$P(F|t-j,t-m) = \alpha P(F,t-j,t-m) = \alpha \sum_t \sum_a P(F,t,a,t-j,t-m)$$

Sfruttando la semantica della (struttura) della rete:

$$P(f|t-j,t-m) = \alpha \sum_t \sum_a P(f) P(t) P(a|f,t) P(t-j|a) P(t-m|a)$$

Nel caso peggiore il numero di sommatorie è $O(n)$ e il numero dei termini è esponenziale!

Complessità Inferenza Esatta

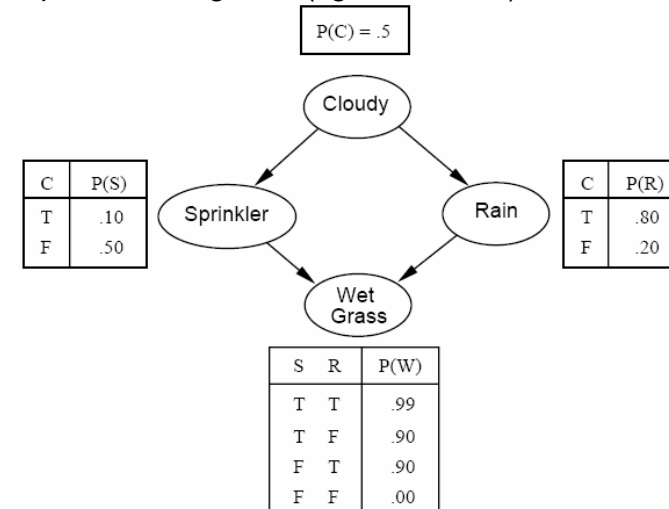
- **Eliminazione delle variabili:** è un algoritmo che consente di velocizzare i conti riducendo anche significativamente calcoli ripetuti
 - È una forma di programmazione dinamica
 - Porta vantaggi solo se la rete è un polialbero (o singolarmente connessa)
- **Reti singolarmente connesse:** per ogni coppia di nodi X e Y esiste al più un cammino orientato oppure NON-orientato che li collega
- **Complessità dell'inferenza esatta:**
 - Polinomiale (lineare) se la rete è singolarmente connessa
 - NP-hard nel caso generale

Inferenza nelle Reti *non* Singolarmente Connesse

- **Metodi di raggruppamento (clustering):** trasformano la rete in un polialbero equivalente accorpondo dei nodi.
- **Metodi approssimati basati su simulazione stocastica:** usando la rete generano un grosso numero di modelli.
- **Metodi di condizionamento:** trasformano la rete istanziando gruppi di variabili e valutando poi un polialbero per ogni istanziazione possibile.

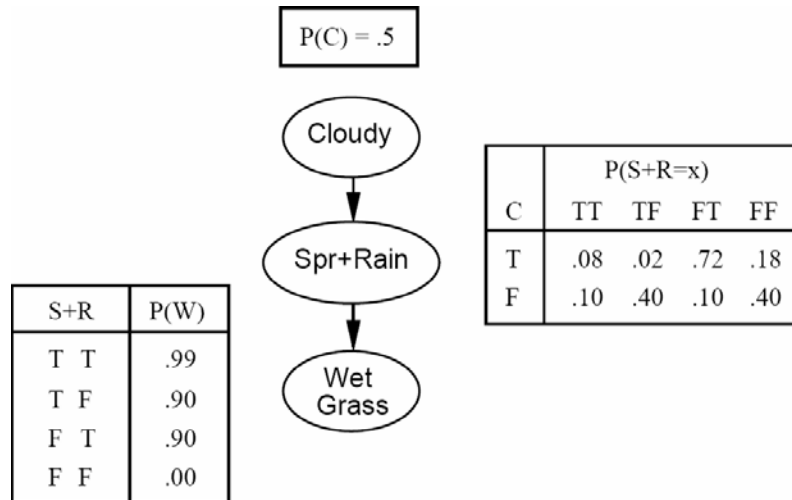
Algoritmi di Clustering

Esempio "Erba bagnata" (fig 14.11 R&N)



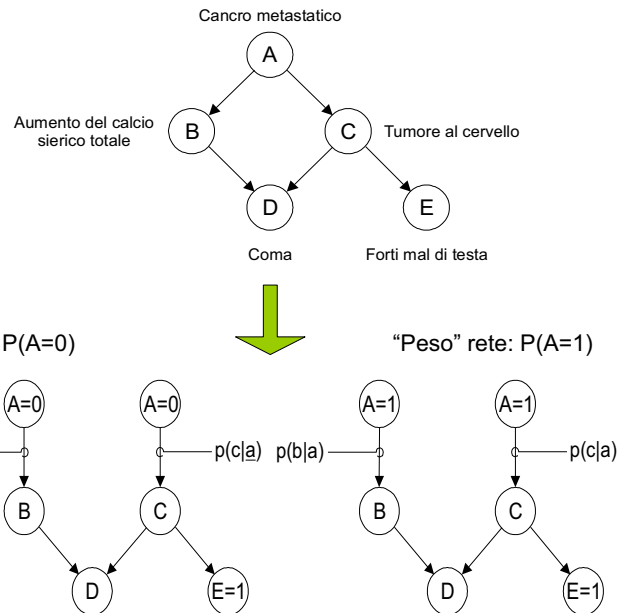
Algoritmi di Clustering

Esempio "Erba bagnata" (fig 14.11 R&N)



Metodi di Condizionamento

- Istanziamento di alcune variabili ad un valore definito (Insieme di taglio)
- Creazione di polialberi più semplici
- Calcolo delle probabilità che ci interessano su tutti i polialberi.
- Media pesata delle probabilità a posteriori (rispetto alla probabilità delle variabili condizionate)



Inferenza Approssimata: metodi di campionamento diretto

Algoritmi Monte Carlo: forniscono risposte *approssimate* la cui accuratezza dipende dal numero di campioni generati.

Campionamento casuale senza alcuna prova: campiono a turno ogni variabile, in *ordine topologico*, usando la distribuzione di probabilità condizionata ai valori già assegnati ai genitori della variabile.

- Campione $P(C) = \langle 0,5, 0,5 \rangle$...esce true
- Campione $P(S | C=true) = \langle 0,1, 0,9 \rangle$...esce false
- Campione $P(R | C = true) = \dots$...esce true
- Campione $P(W-G | I = false, P = true) = \dots$...esce true

C = coperto/cloudy **P**= piovuto **I**=incaffiato/sprinkler
E-B = erba-bagnata/wet grass

Evento generato dalla campionatura: **(true,false,true.false)**

Algoritmo Campiona-Priori (fig 14.12 R&N)

```
function PRIOR-SAMPLE(bn) returns an event sampled from the prior specified by bn
  inputs: bn, a Bayesian network specifying joint distribution  $P(X_1, \dots, X_n)$ 

  x ← an event with n elements
  for i = 1 to n do
     $x_i$  ← a random sample from  $P(X_i | \text{parents}(X_i))$ 
  return x
```

Metodo Campionamento: Calcolo delle Risposte (inferenza)

- Si calcolano *contando certi campioni generati*
 - *N*: numero campioni effettuati
 - $S(x_1, \dots, x_n)$ = probabilità che evento $x_1 \dots x_n$ sia generato dalla campionatura
 - $S(x_1, \dots, x_n) = \prod_{i:1-n} P(x_i | \text{genitori}(X_i)) = P(x_1, \dots, x_n)$
 - $Ns(x_1, \dots, x_n)$ = numero di eventi $x_1 \dots x_n$ generati
 - Al tendere di *N* a infinito ci aspettiamo che $Ns(x_1, \dots, x_n)/N = S(x_1, \dots, x_n) = P(x_1, \dots, x_n)$
- ⇒ Per un evento parziale x_1, \dots, x_m ($m < n$) possiamo *stimare*
 $P(x_1, \dots, x_m) = Ns(x_1, \dots, x_m)/N$
- Esempio:** se ho 1000 campioni per la rete ErbaBagnata, e in 511 $P=\text{true}$, allora $P(P=\text{true}) = 0,511$.

Campionamento di rigetto

Può essere utilizzato per calcolare/inferire una stima di $P(X|e)$

Metodo:

1. Genera campioni dalla distribuzione a priori specificata dalla rete
2. Rifiuta tutti i campioni che non corrispondono alla prova (*e*)
3. Calcola la stima di $P(X=x | e)$ contando quante volte vale $X=x$ nei campioni rimanenti

Esempio: query = $P(\text{Pioggia} | \text{Irrigatore} = \text{true})$

N = 100, 73 con $I=\text{false}$, 27 con $I=\text{true}$ di cui 8 con $P=\text{true}$ e 19 con $P = \text{false}$.

$P(P | I = \text{true}) = \text{Normalizza}(<8, 19>) = <0,296, 0,704>$ (anziché $<0,3, 0,7>$)

Algoritmo Campionamento di rigetto

```
function REJECTION-SAMPLING(X, e, bn, N) returns an estimate of  $P(X|e)$ 
  inputs: X, the query variable
         e, evidence specified as an event
         bn, a Bayesian network
         N, the total number of samples to be generated
  local variables: N, a vector of counts over X, initially zero

  for j = 1 to N do
    x ← PRIOR-SAMPLE(bn)
    if x is consistent with e then
       $N[x] \leftarrow N[x] + 1$  where x is the value of X in x
  return NORMALIZE(N[X])
```

Campionamento di rigetto

- Più campioni => migliore approssimazione (la stima converge alla probabilità reale)
- **Errore:** la deviazione standard dell'errore con n campioni in ogni probabilità è proporzionale a $1/\sqrt{n}$
- **Problema del metodo:** servono molti campioni, che non sono facili da ottenere (molti sono rigettati!)
- La parte dei campioni generati consistente con e *diminuisce esponenzialmente* al crescere del numero di variabili di prova
- => il metodo non è applicabile a problemi complessi di grandi dimensioni.

Pesatura di verosimiglianza

- Evita problema campionamento di rigetto: *vengono generati solo campioni consistenti con le prove*
- I valori (osservati) delle variabili di prova E sono tenuti fissi e si campiona le restanti variabili X e Y
- Prima di contare i campioni per ogni valore possibile della variabile di query X , ogni evento è *pesato dalla sua verosimiglianza date le prove*
- **Idea intuitiva:** *gli eventi in cui è improbabile che le prove siano verificate devono pesare di meno nel conteggio*
- La verosimiglianza si calcola moltiplicando le probabilità condizionate di ogni variabile di prova, dati i suoi genitori

Pesatura di verosimiglianza

Esempio rete ErbaBagnata:

Query $P(\text{Pioggia} \mid \text{Irrigatore}=\text{true}, \text{ErbaBagnata}=\text{true})$

1. $w = 1,0$
2. Campiono $P(\text{Coperto}) = \langle 0,5, 0,5 \rangle \dots$ esce *true*
3. $w = w * P(\text{Irrigatore}=\text{true} \mid \text{Coperto}=\text{true}) = 0,1$
4. Campiono $P(\text{Pioggia} \mid \text{Coperto}=\text{true}) = \langle 0,8, 0,2 \rangle \dots$ esce *true*
5. $w = w * P(\text{ErbaBagnata}=\text{true} \mid \text{Irrigatore}=\text{true}, \text{Pioggia}=\text{true}) = 0,099$

=> Ho generato il campione (true,true,true,true) con peso 0,099 che viene conteggiato per *Pioggia = true usando 0,099 al posto di 1. Ma perché ho ottenuto un valore così basso?*

Algoritmo Pesatura-Verosimiglianza

function LIKELIHOOD-WEIGHTING(X, e, bn, N) returns an estimate of $P(X|e)$

inputs: X , the query variable

e , evidence specified as an event

bn , a Bayesian network

N , the total number of samples to be generated

local variables: W , a vector of weighted counts over X , initially zero

for $j = 1$ to N **do**

$x, w \leftarrow$ WEIGHTED-SAMPLE(bn)

$W[x] \leftarrow W[x] + w$ where x is the value of X in x

return NORMALIZE($W[X]$)

function WEIGHTED-SAMPLE(bn, e) returns an event and a weight

$x \leftarrow$ an event with n elements; $w \leftarrow 1$

for $i = 1$ to n **do**

if X_i has a value x_i in e

then $w \leftarrow w \times P(X_i = x_i \mid \text{parents}(X_i))$


else $x_i \leftarrow$ a random sample from $P(X_i \mid \text{parents}(X_i))$

return x, w

Simulazione con catene di Markov

- **Algoritmo MCMC:** *Monte Carlo for Markov Chains*
- Ogni evento è generato attraverso una modifica di quello precedente
- La rete ha uno **stato corrente** (valore di tutte le variabili)
- **Stato successivo:** campiono casualmente una delle variabili NON di prova X_i
- La campionatura usa la probabilità di X_i condizionata ai valori correnti di tutte le variabili nella coperta di Markov di X_i
- **Coperta di Markov di X_i :** *genitori di X_i + figli di X_i + genitori figli di X_i*
- MCMC fa una “random walk” nello spazio degli stati possibili

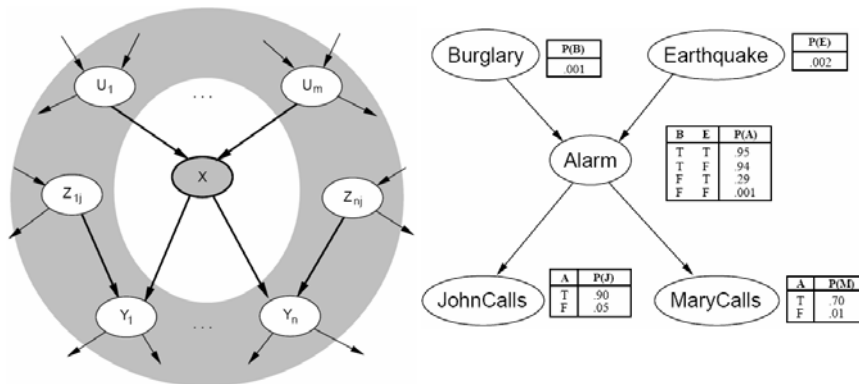
Markov Blanket (MB) per X



MB per X:

padri di X (nodi U_i) + figli di X (nodi Y_j) + padri figli di X (nodi Z_k)

MB e Indipendenza condizionale



Un nodo è condizionalmente indipendente da tutti gli altri nodi nella rete dati i nodi nella sua MB

Esempio: Burglary indipendente da JohnCalls e MaryCalls dati Earthquake e Alarm (la MB di Burglary)

Esempio MCMC

- Query $P(\text{Pioggia} | \text{Irrigatore}=\text{true}, \text{ErbaBagnata}=\text{true})$
- Coperto e Pioggia sono inizializzate casualmente (true e false)
- Stato iniziale: **(true, true, false, true)** (= primo campione)
- Ripeti
 - Campiona Coperto con $P(\text{Coperto} | \text{Irr.}=\text{true}, \text{Pioggia}=\text{false})$
 NB: $P(x | \text{mb}(X)) = \alpha P(x | \text{genitori}(X)) * \prod_{K_i} P(k | \text{genitori}(K_i))$
 K_i sono i nodi figli di X; k è il valore di K_i
 ... esce *false*
 => il nuovo stato è **(false, true, false, true)**
 - Campiona Pioggia usando
 $P(\text{Pioggia} | \text{coperto}=\text{false}, \text{Irr.}=\text{true}, \text{ErbaBagnata}=\text{true})$
 ... esce *true*
 => il nuovo stato è **(false, true, true, true)**
- Risposte calcolate attraverso il conteggio dei campioni

Algoritmo MCMC

```
function MCMC-ASK( $X, e, bn, N$ ) returns an estimate of  $P(X|e)$ 
  local variables:  $N[X]$ , a vector of counts over  $X$ , initially zero
                   $Z$ , the nonevidence variables in  $bn$ 
                   $x$ , the current state of the network, initially copied from  $e$ 

  initialize  $x$  with random values for the variables in  $Z$ 
  for  $j = 1$  to  $N$  do
     $N[x] \leftarrow N[x] + 1$  where  $x$  is the value of  $X$  in  $x$ 
    for each  $Z_i$  in  $Z$  do
      sample the value of  $Z_i$  in  $x$  from  $\mathbf{P}(Z_i|mb(Z_i))$  given the values of  $MB(Z_i)$  in  $x$ 
  return NORMALIZE( $N[X]$ )
```

ESERCIZIO

- Estendere la rete con variabili booleane *Acquagelata* e *MotorinoAvviamento*
- Fornire ragionevoli tabelle di prob. condizionate
- La distribuzione di prob. condizionata per la var *parte rumoroso* potrebbe essere descritta da una distribuzione di *AND rumoroso*. Definire questa famiglia in generale e metterla in relazione alla distribuzione di *OR-rumoroso*

