

INFERENZA IN RETI BAYESIANE

CORSO DI INTELLIGENZA ARTIFICIALE, CAPITOLO 14.4–5

Inferenza approssimata tramite MCMC

“Stato” della rete = assegnamento corrente a tutte le variabili

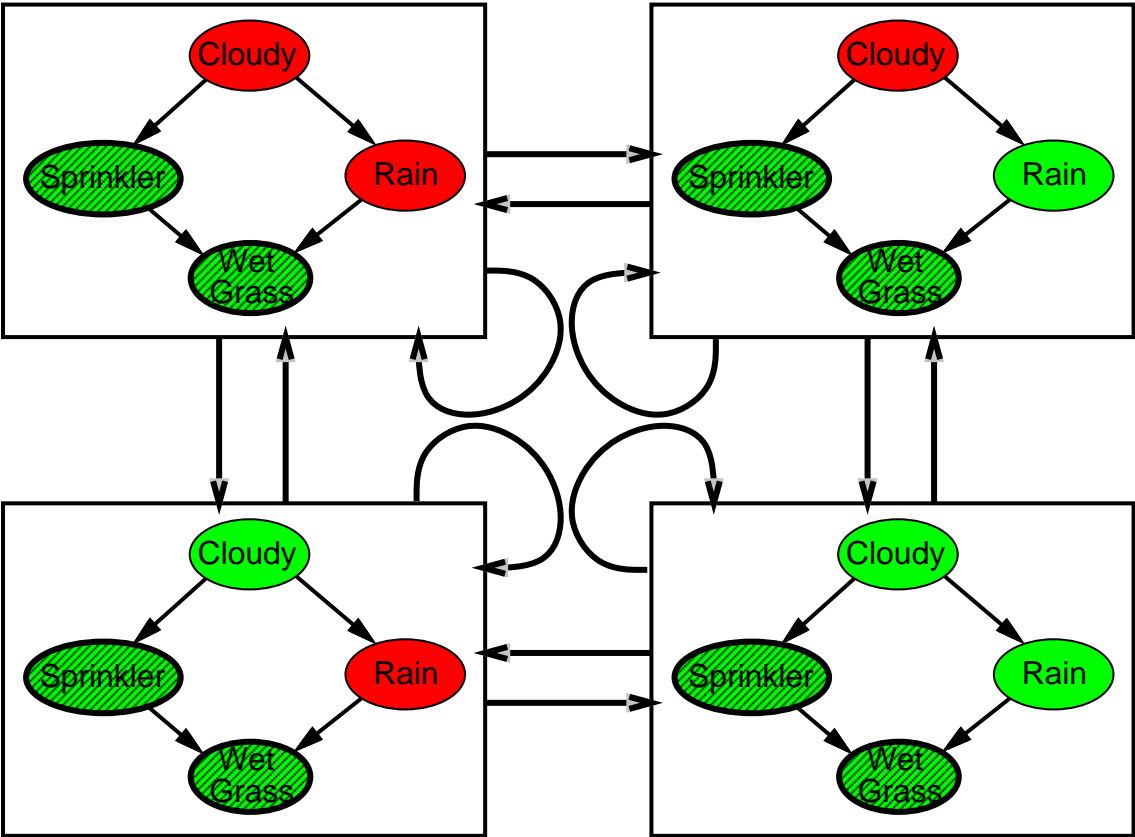
Genera lo stato successivo campionando una variabile dato il suo Markov blanket
Campiona ogni variabile a turno, mantenendo l'evidenza fissa

```
function MCMC-Ask( $X, \mathbf{e}, bn, N$ ) returns an estimate of  $P(X|\mathbf{e})$   
  local variables:  $\mathbf{N}[X]$ , a vector of counts over  $X$ , initially zero  
                    $\mathbf{Z}$ , the nonevidence variables in  $bn$   
                    $\mathbf{x}$ , the current state of the network, initially copied from  $\mathbf{e}$   
  
  initialize  $\mathbf{x}$  with random values for the variables in  $\mathbf{Y}$   
  for  $j = 1$  to  $N$  do  
     $\mathbf{N}[x] \leftarrow \mathbf{N}[x] + 1$  where  $x$  is the value of  $X$  in  $\mathbf{x}$   
    for each  $Z_i$  in  $\mathbf{Z}$  do  
      sample the value of  $Z_i$  in  $\mathbf{x}$  from  $\mathbf{P}(Z_i|MB(Z_i))$  given the values of  
       $MB(Z_i)$  in  $\mathbf{x}$   
  return NORMALIZE( $\mathbf{N}[X]$ )
```

Può anche scegliere una variabile da campionare a caso ogni volta

La catena di Markov (Markov chain)

Con *Sprinkler = true*, *WetGrass = true*, ci sono quattro stati:



“gironzolare” per un pò, fare la media di quello che si osserva

MCMC: esempio

Stimare $\mathbf{P}(Rain|Sprinkler = true, WetGrass = true)$

Campionare *Cloudy* o *Rain* dato il suo Markov blanket, ripetere.
Contare il numero di volte in cui *Rain* è true e false nei campioni.

P.e., visita 100 stati

31 hanno *Rain = true*, 69 hanno *Rain = false*

$$\hat{\mathbf{P}}(Rain|Sprinkler = true, WetGrass = true) \\ = \text{NORMALIZE}(\langle 31, 69 \rangle) = \langle 0.31, 0.69 \rangle$$

Teorema: la catena raggiunge la **distribuzione stazionaria**:
la frazione di tempo speso in ogni stato è esattamente
proporzionale alla sua probabilità a posteriori


Markov blanket: campionamento

Il Markov blanket di *Cloudy* è

Sprinkler e *Rain*

Il Markov blanket di *Rain* è

Cloudy, *Sprinkler*, e *WetGrass*



La probabilità dato il Markov blanket è calcolata come segue:

$$P(x'_i | MB(X_i)) = P(x'_i | Parents(X_i)) \prod_{Z_j \in Children(X_i)} P(z_j | Parents(Z_j))$$

Facilmente implementabile in un sistema parallelo a scambio di messaggi

Principali problemi computazionali:

- 1) Difficoltà a riconoscere se la convergenza è avvenuta
- 2) Molto costoso se il Markov blanket è grande:

$P(X_i | MB(X_i))$ non cambierà molto (legge dei grandi numeri)

Analisi di MCMC: passi principali

Probabilità di transizione $q(\mathbf{x} \rightarrow \mathbf{x}')$

Probabilità di stazionamento $\pi_t(\mathbf{x})$ al tempo t

Condizione di equilibrio su π_t implica distribuzione stazionaria $\pi(\mathbf{x})$

Nota: la distribuzione stazionaria dipende dalla scelta di $q(\mathbf{x} \rightarrow \mathbf{x}')$

Equilibrio garantito dal **detailed balance** (condizione di equilibrio) su coppie di stati

Probabilità di transizione calcolata secondo **Gibbs sampling**:

campiona ogni variabile dati i valori correnti di tutte le altre

\Rightarrow detailed balance con la vera probabilità a posteriori

Per reti Bayesiane, Gibbs sampling si riduce a campionare condizionatamente alla Markov blanket di ogni variabile

Distribuzione stazionaria

$\pi_t(\mathbf{x})$ = probabilità di trovarsi nello stato \mathbf{x} al tempo t

$\pi_{t+1}(\mathbf{x}')$ = probabilità di trovarsi nello stato \mathbf{x}' al tempo $t + 1$

π_{t+1} definibile in termini di π_t e $q(\mathbf{x} \rightarrow \mathbf{x}')$

$$\pi_{t+1}(\mathbf{x}') = \sum_{\mathbf{x}} \pi_t(\mathbf{x}) q(\mathbf{x} \rightarrow \mathbf{x}')$$

Distribuzione stazionaria: $\pi_t = \pi_{t+1} = \pi$

$$\pi(\mathbf{x}') = \sum_{\mathbf{x}} \pi(\mathbf{x}) q(\mathbf{x} \rightarrow \mathbf{x}') \quad \text{per tutti gli stati } \mathbf{x}'$$

Se π esiste, essa è unica (e specifica per $q(\mathbf{x} \rightarrow \mathbf{x}')$)

All'equilibrio, “flusso in uscita” atteso = “flusso in entrata” atteso

Detailed balance

“flusso in uscita” = “flusso in entrata” per ogni coppia di stati

$$\pi(\mathbf{x})q(\mathbf{x} \rightarrow \mathbf{x}') = \pi(\mathbf{x}')q(\mathbf{x}' \rightarrow \mathbf{x}) \quad \text{per tutte le coppie } \mathbf{x}, \mathbf{x}'$$

Detailed balance \Rightarrow stazionarietà:

$$\begin{aligned} \sum_{\mathbf{x}} \pi(\mathbf{x})q(\mathbf{x} \rightarrow \mathbf{x}') &= \sum_{\mathbf{x}} \pi(\mathbf{x}')q(\mathbf{x}' \rightarrow \mathbf{x}) \\ &= \pi(\mathbf{x}') \sum_{\mathbf{x}} q(\mathbf{x}' \rightarrow \mathbf{x}) \\ &= \pi(\mathbf{x}') \end{aligned}$$

L'algoritmo MCMC è costruito in modo che la probabilità di transizione q sia in detailed balance con la probabilità desiderata π

Gibbs sampling

Campiona ogni variabile a turno, date **tutte le altre variabili**

Campionando X_i , denotiamo con $\bar{\mathbf{X}}_i$ tutte le altre variabili non di evidenza

Siano x_i e $\bar{\mathbf{x}}_i$ i valori correnti, e \mathbf{e} l'evidenza fissata

La probabilità di transizione è data da

$$q(\mathbf{x} \rightarrow \mathbf{x}') = q(x_i, \bar{\mathbf{x}}_i \rightarrow x'_i, \bar{\mathbf{x}}_i) = P(x'_i | \bar{\mathbf{x}}_i, \mathbf{e})$$

Questo conduce al detailed balance con la vera probabilità a posteriori $P(\mathbf{x} | \mathbf{e})$:

$$\begin{aligned} \pi(\mathbf{x})q(\mathbf{x} \rightarrow \mathbf{x}') &= P(\mathbf{x} | \mathbf{e})P(x'_i | \bar{\mathbf{x}}_i, \mathbf{e}) = P(x_i, \bar{\mathbf{x}}_i | \mathbf{e})P(x'_i | \bar{\mathbf{x}}_i, \mathbf{e}) \\ &= P(x_i | \bar{\mathbf{x}}_i, \mathbf{e})P(\bar{\mathbf{x}}_i | \mathbf{e})P(x'_i | \bar{\mathbf{x}}_i, \mathbf{e}) \quad (\text{chain rule}) \\ &= P(x_i | \bar{\mathbf{x}}_i, \mathbf{e})P(x'_i, \bar{\mathbf{x}}_i | \mathbf{e}) \quad (\text{chain rule invertita}) \\ &= q(\mathbf{x}' \rightarrow \mathbf{x})\pi(\mathbf{x}') = \pi(\mathbf{x}')q(\mathbf{x}' \rightarrow \mathbf{x}) \end{aligned}$$

Riassunto

Inferenza esatta tramite l'eliminazione di variabile:

- polinomiale su polialberi, NP-hard in generale
- spazio = tempo, dipendente dalla topologia

Inferenza approssimata tramite LW e MCMC:

- LW si comporta male quando c'è molta evidenza (soprattutto a “valle”)
- LW, MCMC in genere indipendenti dalla topologia
- La convergenza può essere molto lenta per probabilità vicine a 1 o 0
- Possono trattare combinazioni arbitrarie di variabili discrete e continue