

# INFERENZA IN RETI BAYESIANE

CORSO DI SISTEMI INTELLIGENTI, CAPITOLO 14.4–5

# Outline

- ◇ Inferenza esatta tramite enumerazione
- ◇ Inferenza esatta tramite eliminazione di variabile
- ◇ Inferenza approssimata tramite simulazione stocastica
- ◇ Inferenza approssimata tramite Markov chain Monte Carlo

## Compiti di inferenza

Query semplici: calcolare la probabilità a posteriori marginale  $\mathbf{P}(X_i|\mathbf{E} = \mathbf{e})$   
p.e.,  $P(\text{NoGas}|\text{Gauge} = \text{empty}, \text{Lights} = \text{on}, \text{Starts} = \text{false})$

Query congiuntive:  $\mathbf{P}(X_i, X_j|\mathbf{E} = \mathbf{e}) = \mathbf{P}(X_i|\mathbf{E} = \mathbf{e})\mathbf{P}(X_j|X_i, \mathbf{E} = \mathbf{e})$

Decisioni ottimali: reti di decisioni includono informazioni di utilità;  
inferenza probabilistica richiesta per  $P(\text{outcome}|\text{action}, \text{evidence})$

Recupero informazione: quale evidenza si deve cercare?

Analisi della sensitività: quali valori di probabilità sono i più critici?

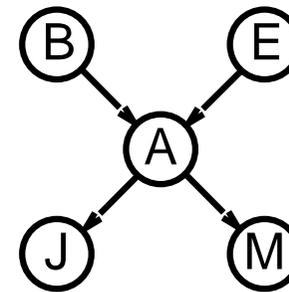
Spiegazione: perché ho bisogno di un nuovo motore di avviamento?

## Inferenza tramite enumerazione

Modo un pò più furbo per marginalizzare alcune variabili dalla distribuzione congiunta senza costruire esplicitamente la sua rappresentazione

Query semplice sulla rete dell'allarme:

$$\begin{aligned} & \mathbf{P}(B|j, m) \\ &= \mathbf{P}(B, j, m) / P(j, m) \\ &= \alpha \mathbf{P}(B, j, m) \\ &= \alpha \sum_e \sum_a \mathbf{P}(B, e, a, j, m) \end{aligned}$$



Riscrittura di entrate della distribuzione congiunta usando il prodotto di entrate di CPT:

$$\begin{aligned} & \mathbf{P}(B|j, m) \\ &= \alpha \sum_e \sum_a \mathbf{P}(B) P(e) \mathbf{P}(a|B, e) P(j|a) P(m|a) \\ &= \alpha \mathbf{P}(B) \sum_e P(e) \sum_a \mathbf{P}(a|B, e) P(j|a) P(m|a) \end{aligned}$$

Enumerazione ricorsiva depth-first:  $O(n)$  in spazio,  $O(d^n)$  in tempo

# Algoritmo di enumerazione

**function** ENUMERATION-ASK( $X, e, bn$ ) returns a distribution over  $X$

**inputs:**  $X$ , the query variable

$e$ , observed values for variables  $\mathbf{E}$

$bn$ , a Bayesian network with variables  $\{X\} \cup \mathbf{E} \cup \mathbf{Y}$

$Q(X) \leftarrow$  a distribution over  $X$ , initially empty

**for each** value  $x_i$  of  $X$  **do**

    extend  $e$  with value  $x_i$  for  $X$

$Q(x_i) \leftarrow$  ENUMERATE-ALL(VARS[ $bn$ ],  $e$ )

**return** NORMALIZE( $Q(X)$ )

---

**function** ENUMERATE-ALL( $vars, e$ ) returns a real number

**if** EMPTY?( $vars$ ) **then return** 1.0

$Y \leftarrow$  FIRST( $vars$ )

**if**  $Y$  has value  $y$  in  $e$

**then return**  $P(y \mid Pa(Y)) \times$  ENUMERATE-ALL(REST( $vars$ ),  $e$ )

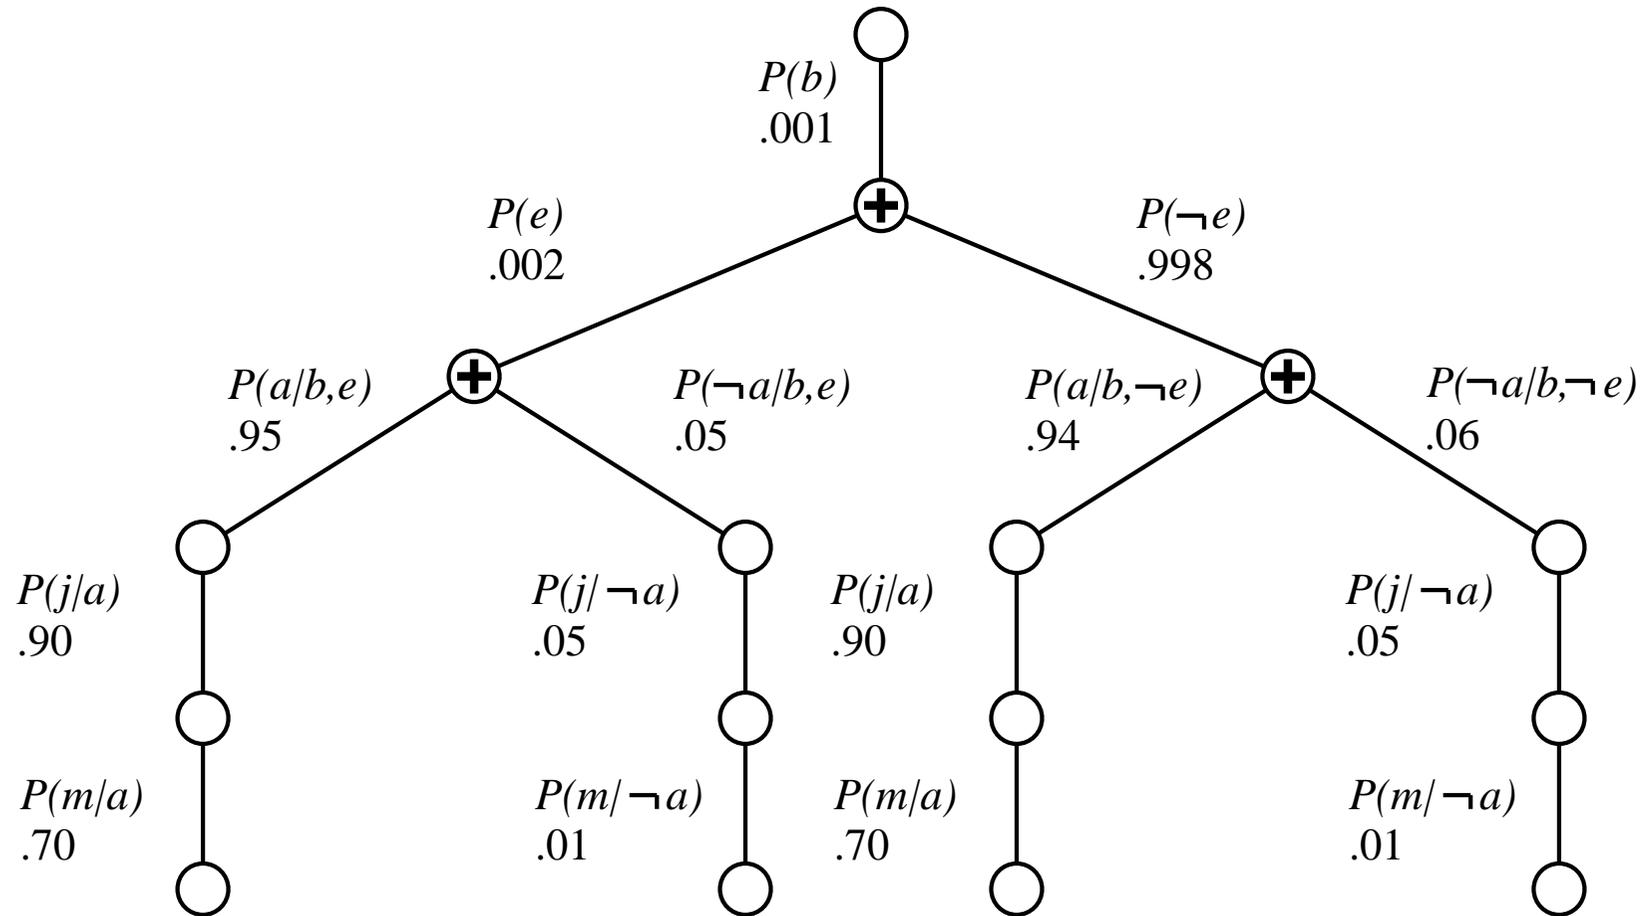
**else return**  $\sum_y P(y \mid Pa(Y)) \times$  ENUMERATE-ALL(REST( $vars$ ),  $e_y$ )

        where  $e_y$  is  $e$  extended with  $Y = y$

# Albero di valutazione

L'enumerazione è inefficiente: calcoli ripetuti

p.e., calcola  $P(j|a)P(m|a)$  per ogni valore di  $e$



## Inferenza tramite eliminazione di variabile

Eliminazione di variabile: effettuare le somme da destra a sinistra, memorizzare i risultati intermedi (**fattori**) per evitare di ricalcolarli

$$\begin{aligned} \mathbf{P}(B|j, m) &= \alpha \underbrace{\mathbf{P}(B)}_B \underbrace{\sum_e P(e)}_E \underbrace{\sum_a \mathbf{P}(a|B, e)}_A \underbrace{P(j|a)}_J \underbrace{P(m|a)}_M \\ &= \alpha \mathbf{P}(B) \sum_e P(e) \sum_a \mathbf{P}(a|B, e) P(j|a) f_M(a) \\ &= \alpha \mathbf{P}(B) \sum_e P(e) \sum_a \mathbf{P}(a|B, e) f_J(a) f_M(a) \\ &= \alpha \mathbf{P}(B) \sum_e P(e) \sum_a f_A(a, b, e) f_J(a) f_M(a) \\ &= \alpha \mathbf{P}(B) \sum_e P(e) f_{\bar{A}JM}(b, e) \text{ (elimina } A) \\ &= \alpha \mathbf{P}(B) f_{\bar{E}\bar{A}JM}(b) \text{ (elimina } E) \\ &= \alpha f_B(b) \times f_{\bar{E}\bar{A}JM}(b) \end{aligned}$$

## Eliminazione di variabile: operazioni base

Eliminare una variabile da un prodotto di fattori:

1. muovere i fattori costanti al di fuori della somma
2. aggiungere le sottomatrici al prodotto “pointwise” dei fattori rimanenti

$$\sum_x f_1 \times \cdots \times f_k = f_1 \times \cdots \times f_i \sum_x f_{i+1} \times \cdots \times f_k = f_1 \times \cdots \times f_i \times f_{\bar{X}}$$

assumendo che  $f_1, \dots, f_i$  non dipendano da  $X$

Prodotto pointwise di fattori  $f_1$  e  $f_2$ :

$$\begin{aligned} f_1(x_1, \dots, x_j, y_1, \dots, y_k) \times f_2(y_1, \dots, y_k, z_1, \dots, z_l) \\ = f(x_1, \dots, x_j, y_1, \dots, y_k, z_1, \dots, z_l) \end{aligned}$$

P.e.,  $f_1(a, b) \times f_2(b, c) = f(a, b, c)$

## Algoritmo di eliminazione di variabile

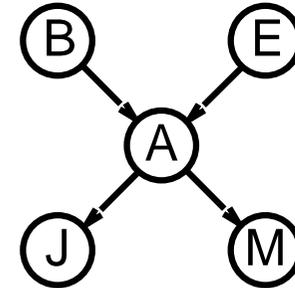
```
function ELIMINATION-ASK( $X, e, bn$ ) returns a distribution over  $X$   
  inputs:  $X$ , the query variable  
            $e$ , evidence specified as an event  
            $bn$ , a belief network specifying joint distribution  $\mathbf{P}(X_1, \dots, X_n)$   
  
   $factors \leftarrow []$ ;  $vars \leftarrow \text{REVERSE}(\text{VARS}[bn])$   
  for each  $var$  in  $vars$  do  
     $factors \leftarrow [\text{MAKE-FACTOR}(var, e) | factors]$   
    if  $var$  is a hidden variable then  $factors \leftarrow \text{SUM-OUT}(var, factors)$   
  return  $\text{NORMALIZE}(\text{POINTWISE-PRODUCT}(factors))$ 
```

## Variabili irrilevanti

Consideriamo la query  $P(\text{JohnCalls} | \text{Burglary} = \text{true})$

$$P(J|b) = \alpha P(b) \sum_e P(e) \sum_a P(a|b, e) P(J|a) \sum_m P(m|a)$$

La somma su  $m$  è uguale a 1;  $M$  è **irrilevante** per la query



Thm 1:  $Y$  è irrilevante a meno che  $Y \in \text{Ancestors}(\{X\} \cup \mathbf{E})$

Qui,  $X = \text{JohnCalls}$ ,  $\mathbf{E} = \{\text{Burglary}\}$ , e

$\text{Ancestors}(\{X\} \cup \mathbf{E}) = \{\text{Alarm}, \text{Earthquake}\}$

quindi  $M$  è irrilevante

(Confrontare con backward chaining a partire dalla query in KB con clausole di Horn)

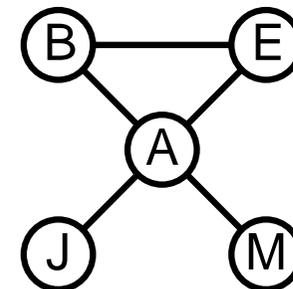
## Variabili irrilevanti

Defn: grafo moralizzato di una rete bayesiana: sposare tutti i genitori ed eliminare la direzione degli archi

Defn: **F** è m-separato da **G** tramite **H** sse è separato tramite **H** nel grafo moralizzato

Thm 2: **Y** è irrilevante se m-separato da **X** tramite **E**

Per  $P(\text{JohnCalls} | \text{Alarm} = \text{true})$ , sia *Burglary* che *Earthquake* sono irrilevanti



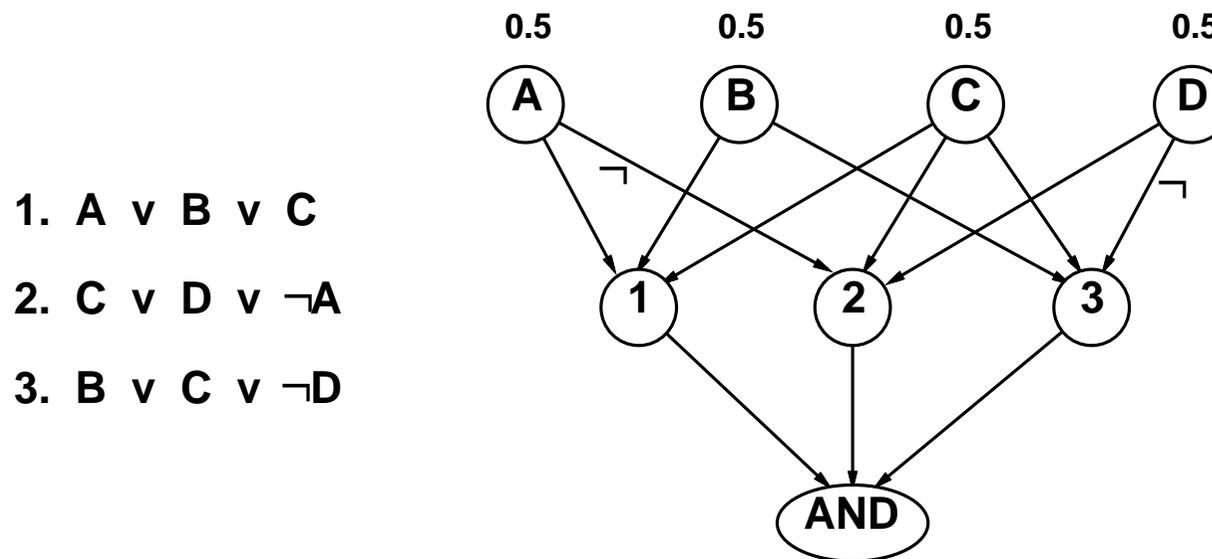
# Complessità dell'inferenza esatta

Reti **singolarmente connesse** (o **polytree**):

- ogni coppia di nodi è connessa da al più un cammino (non diretto)
- il costo in tempo e spazio della eliminazione di variabile è  $O(d^k n)$

Reti **connesse più che singolarmente**:

- possibile ridurre 3SAT alla inferenza esatta  $\Rightarrow$  NP-hard
  - equivalente a modelli 3SAT con **conteggio** (del numero di soluzioni)
- $\Rightarrow$  #P-complete



# Inferenza tramite simulazione stocastica

Idea base:

- 1) Estrarre  $N$  campioni da una distribuzione di campionamento  $S$
- 2) Calcolare la probabilità a posteriori approssimata  $\hat{P}$
- 3) Mostrare che converge alla vera probabilità  $P$

Outline:

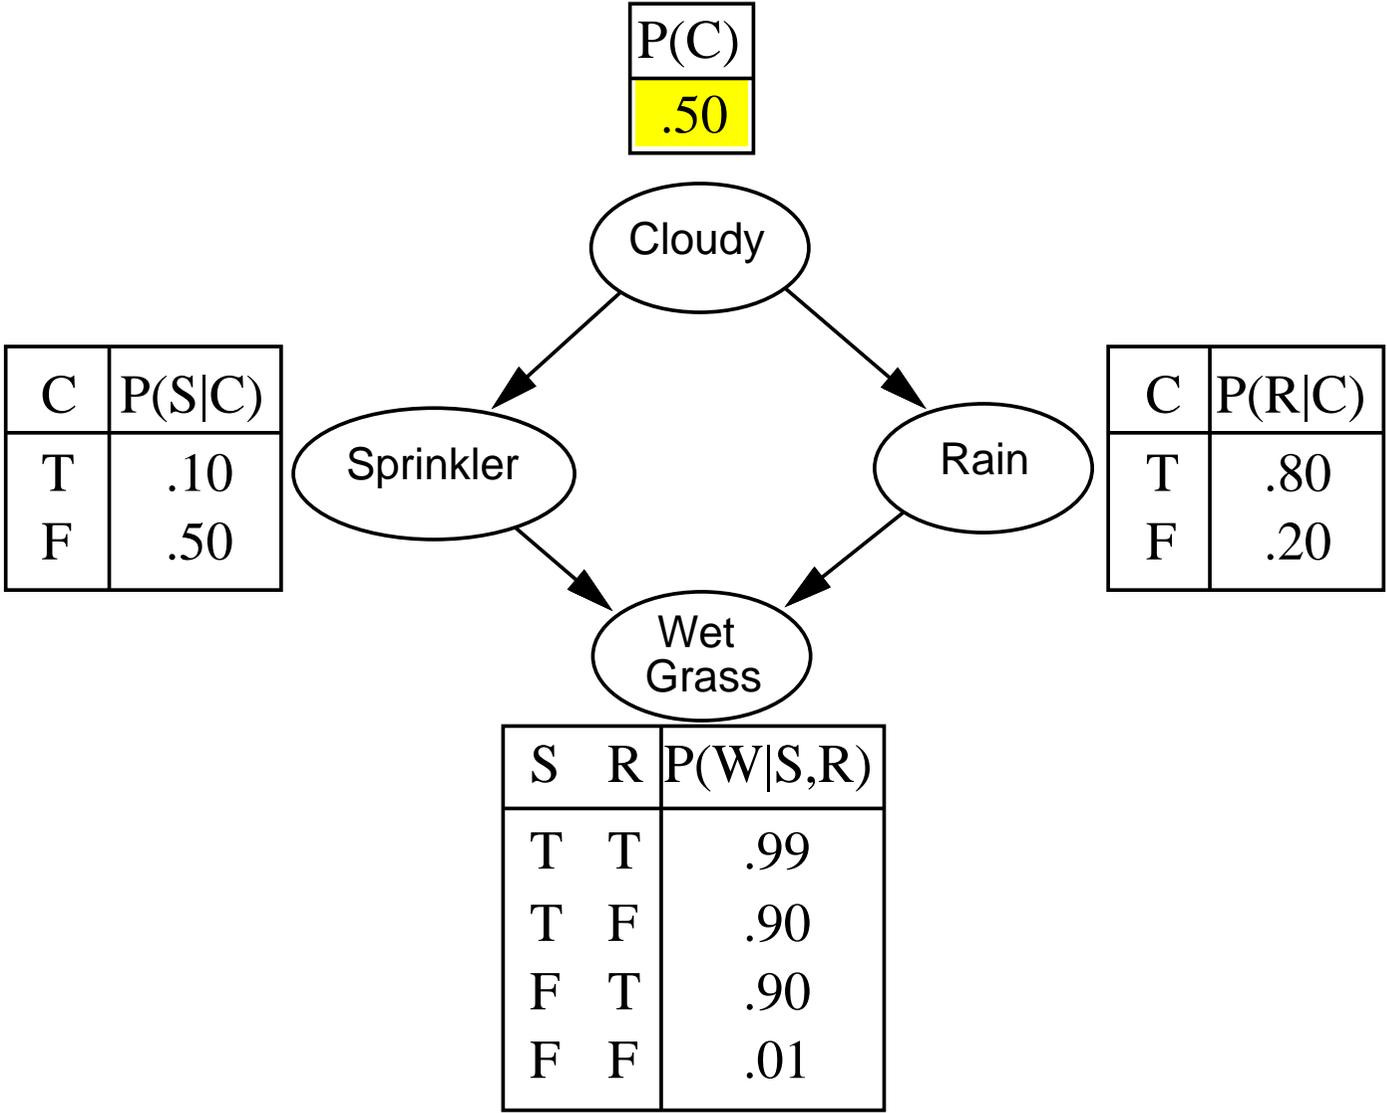
- Campionamento da una rete vuota
- Rejection sampling: rigettare i campioni in disaccordo con l'evidenza
- Likelihood weighting: usare l'evidenza per pesare i campioni
- Markov chain Monte Carlo (MCMC): campiona in accordo ad un processo stocastico la cui distribuzione stazionaria è la vera probabilità



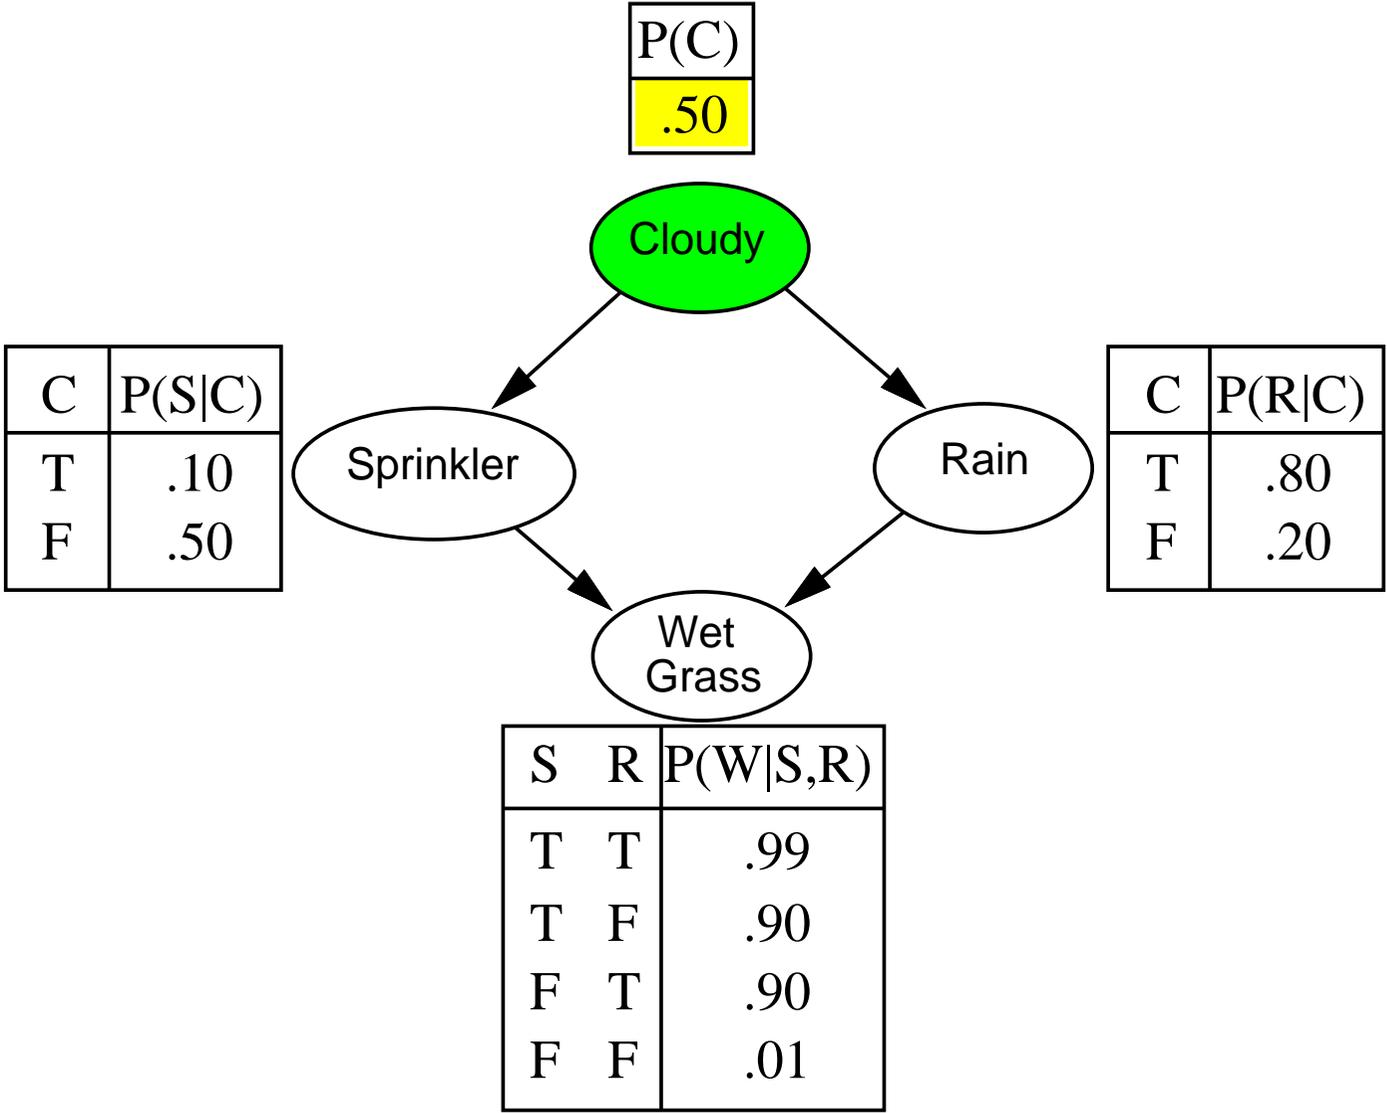
## Campionamento da una rete vuota

```
function PRIOR-SAMPLE(bn) returns an event sampled from bn  
  inputs: bn, a belief network specifying joint distribution  $\mathbf{P}(X_1, \dots, X_n)$   
  x  $\leftarrow$  an event with n elements  
  for i = 1 to n do  
     $x_i \leftarrow$  a random sample from  $\mathbf{P}(X_i \mid \text{Parents}(X_i))$   
  return x
```

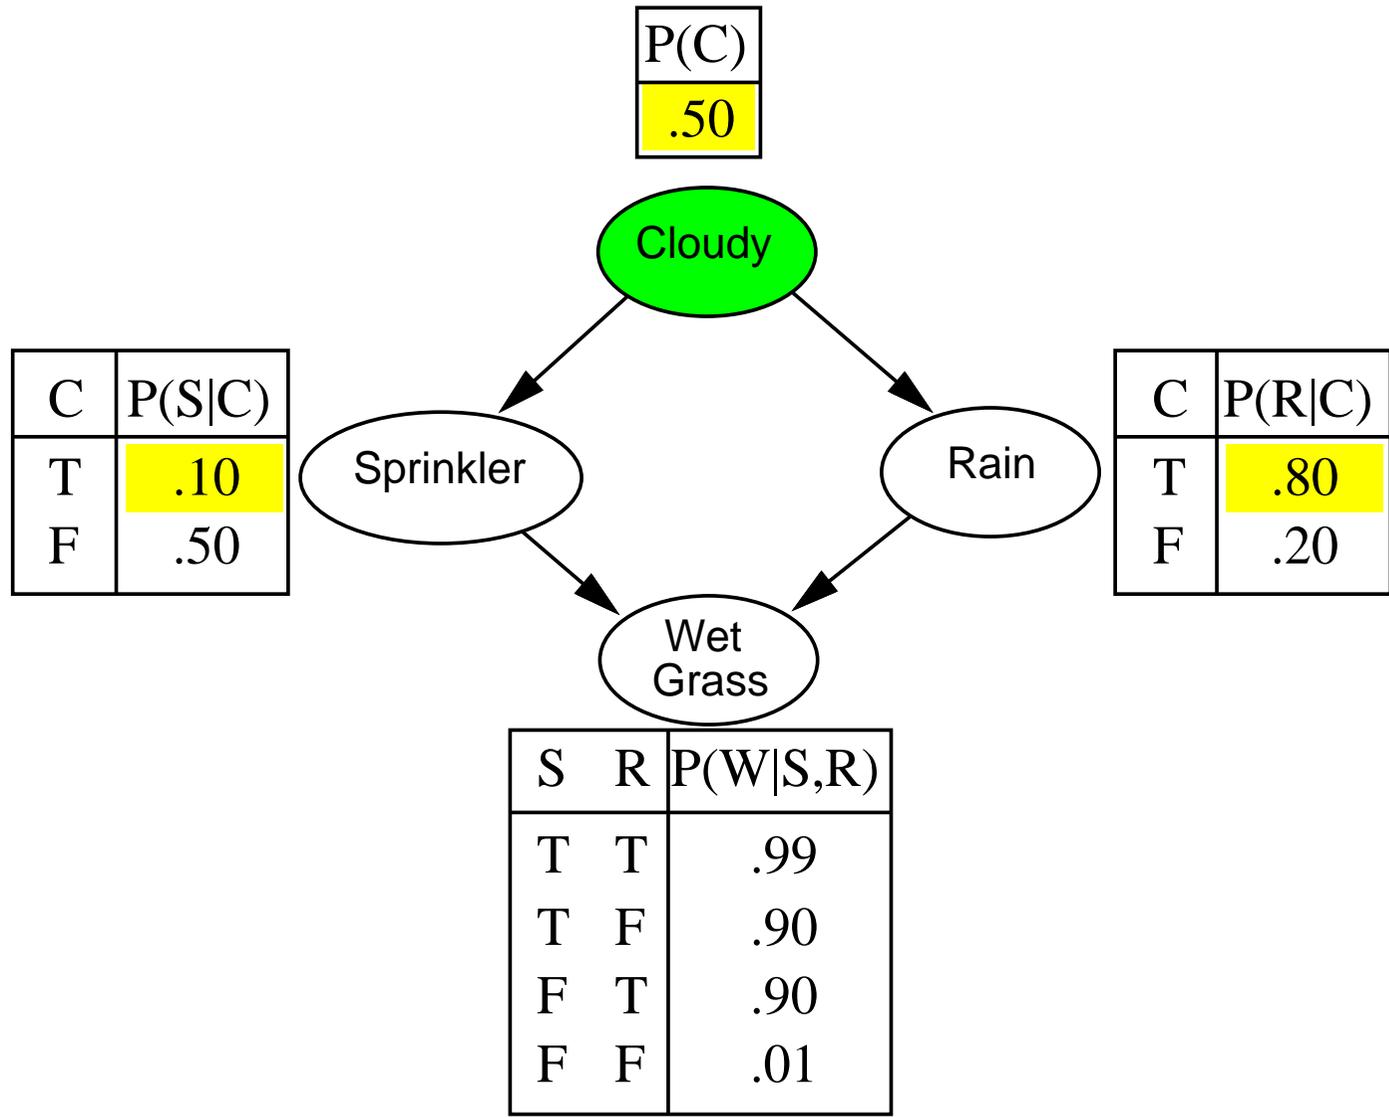
# Esempio



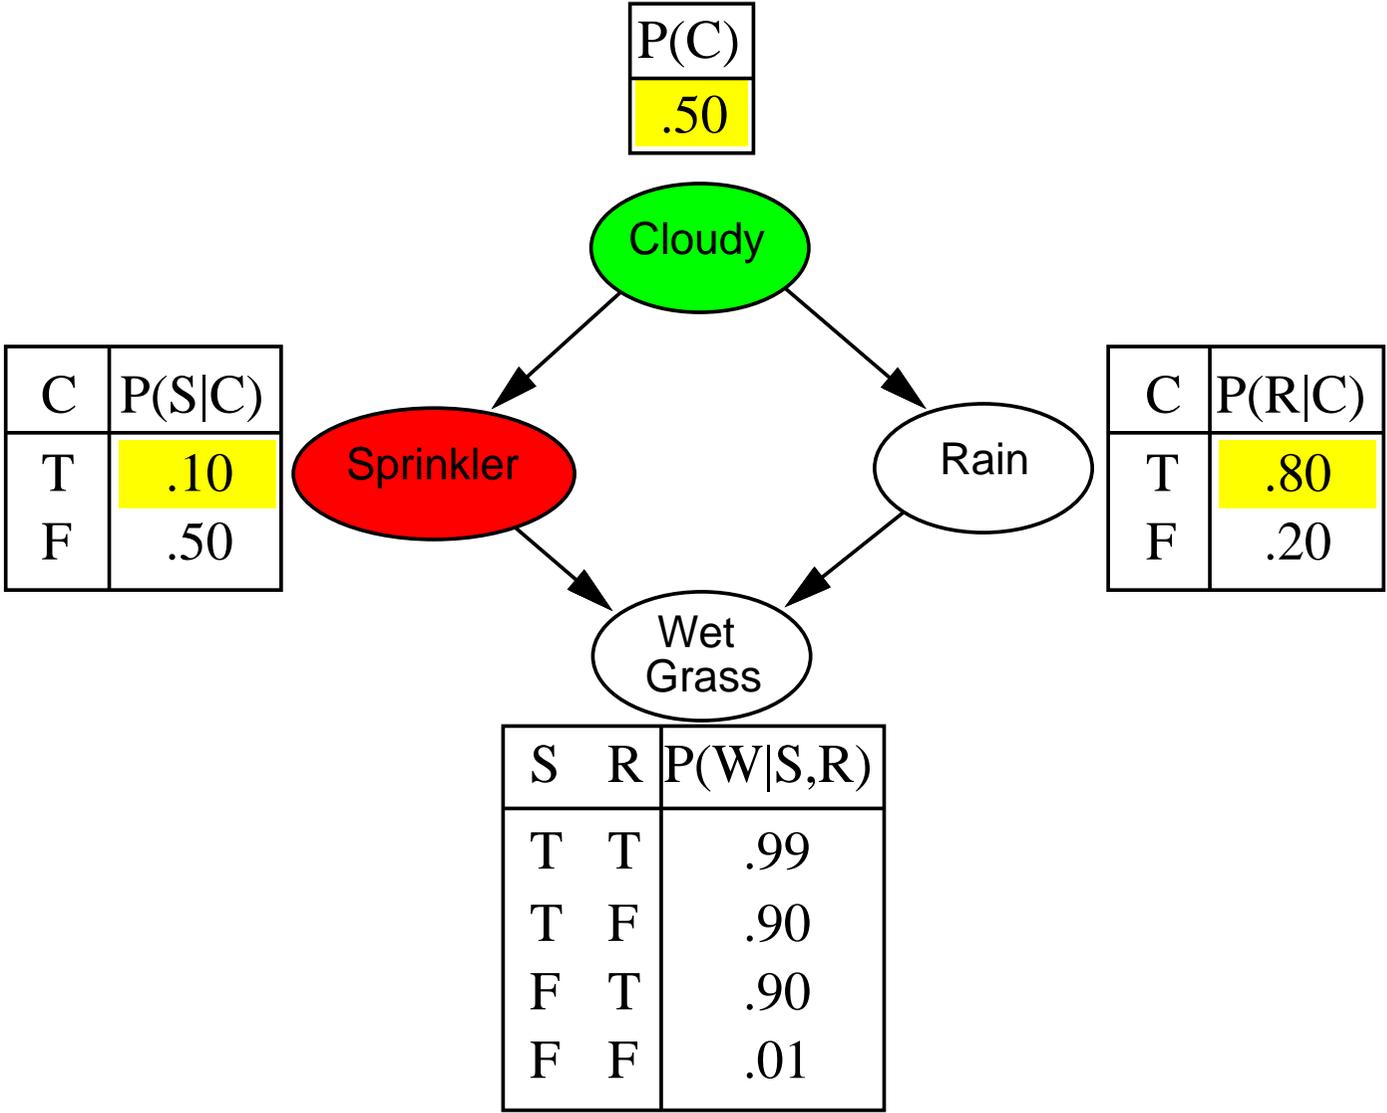
# Esempio



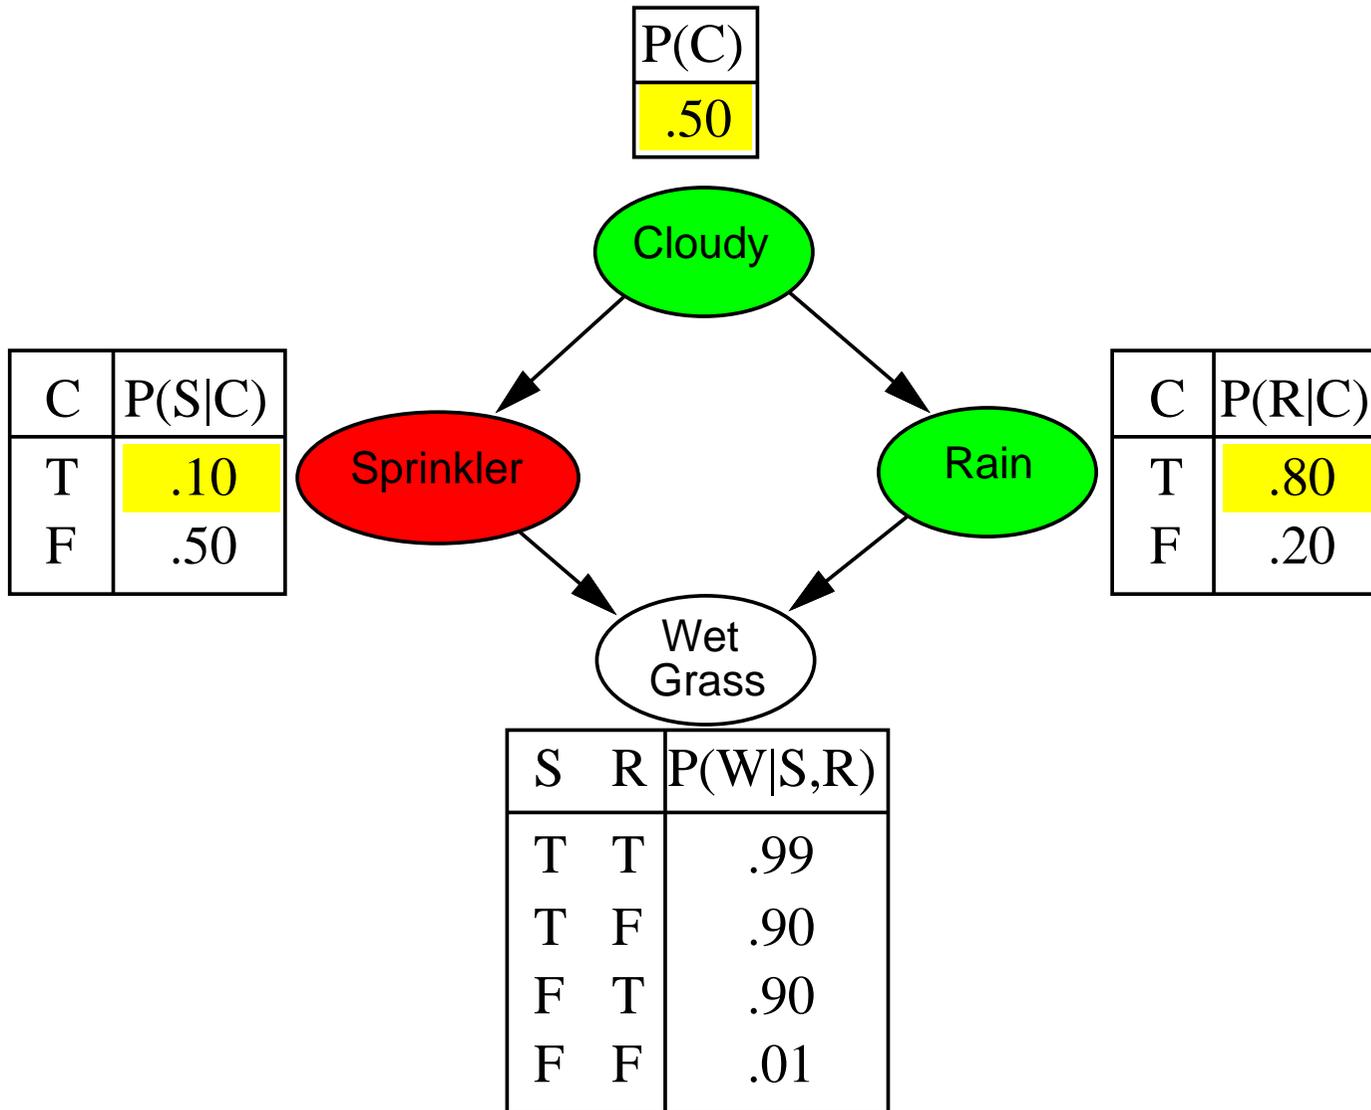
# Esempio



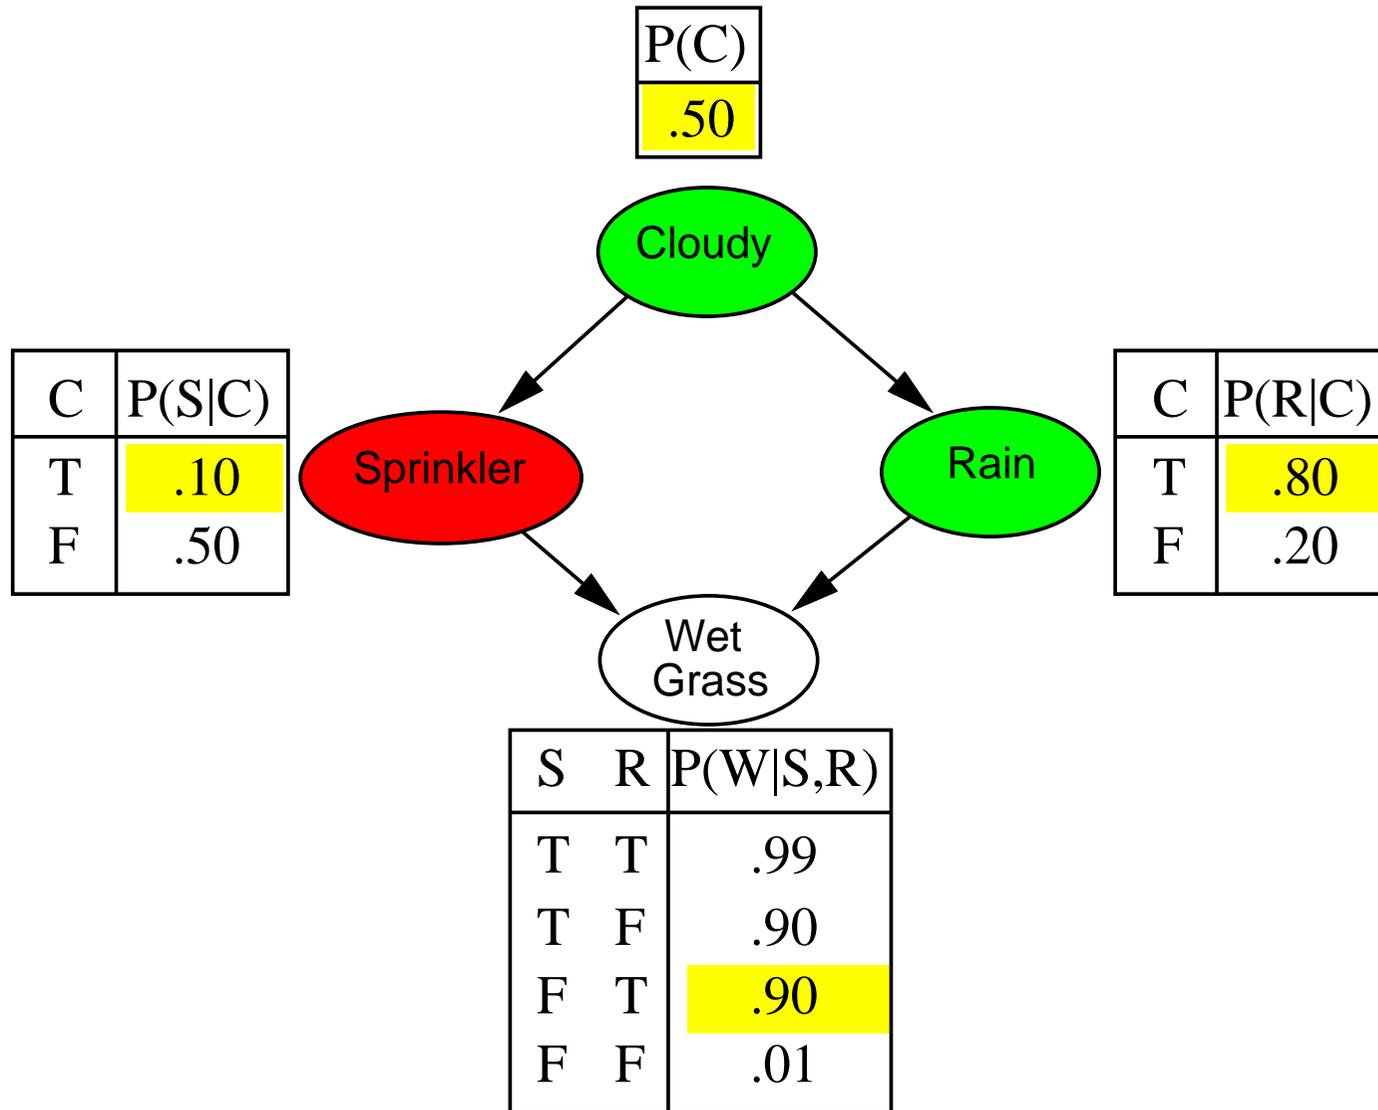
# Esempio



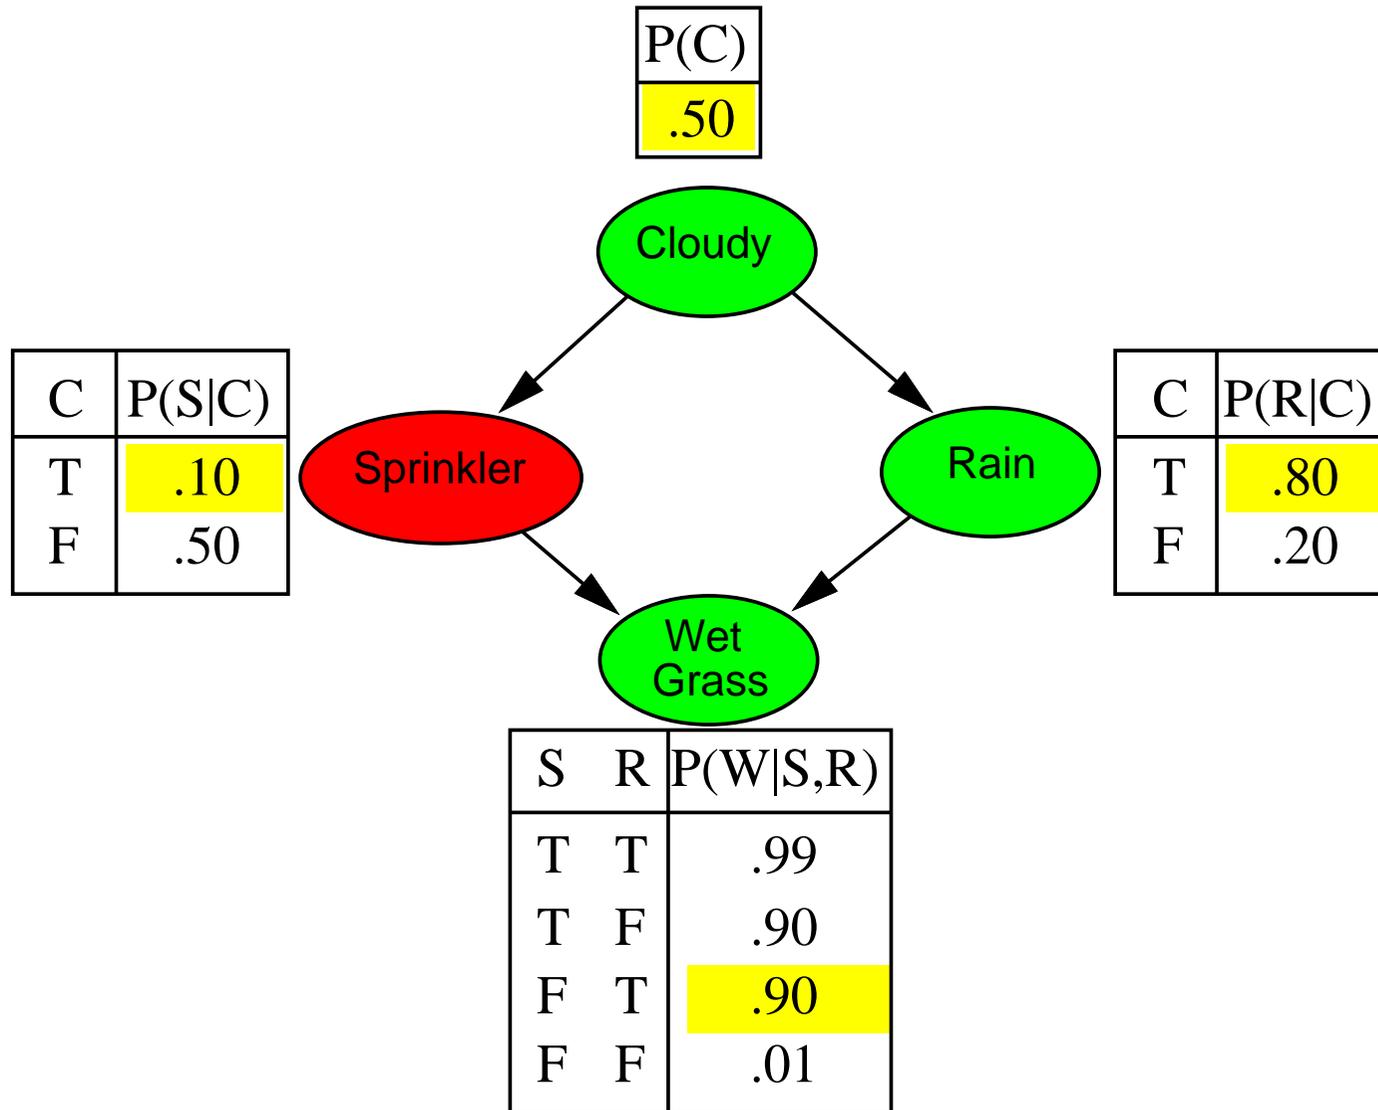
# Esempio



# Esempio



# Esempio



## Campionamento da una rete vuota

Probabilità che PRIORSAMPLE generi un evento particolare

$$S_{PS}(x_1 \dots x_n) = \prod_{i=1}^n P(x_i | Parents(X_i)) = P(x_1 \dots x_n)$$

cioè, la vera probabilità a priori

$$\text{P.e., } S_{PS}(t, f, t, t) = 0.5 \times 0.9 \times 0.8 \times 0.9 = 0.324 = P(t, f, t, t)$$

Posto  $N_{PS}(x_1 \dots x_n)$  essere il numero di campioni generati per l'evento  $x_1, \dots, x_n$

Allora abbiamo

$$\begin{aligned} \lim_{N \rightarrow \infty} \hat{P}(x_1, \dots, x_n) &= \lim_{N \rightarrow \infty} N_{PS}(x_1, \dots, x_n) / N \\ &= S_{PS}(x_1, \dots, x_n) \\ &= P(x_1 \dots x_n) \end{aligned}$$

Cioè, stime derivate da PRIORSAMPLE sono **consistenti**

In breve:  $\hat{P}(x_1, \dots, x_n) \approx P(x_1 \dots x_n)$

## Rejection sampling

$\hat{\mathbf{P}}(X|\mathbf{e})$  stimate da campioni in accordo con  $\mathbf{e}$

```
function REJECTION-SAMPLING( $X, \mathbf{e}, bn, N$ ) returns an estimate of  $P(X|\mathbf{e})$ 
  local variables:  $\mathbf{N}$ , a vector of counts over  $X$ , initially zero
  for  $j = 1$  to  $N$  do
     $\mathbf{x} \leftarrow$  PRIOR-SAMPLE( $bn$ )
    if  $\mathbf{x}$  is consistent with  $\mathbf{e}$  then
       $\mathbf{N}[x] \leftarrow \mathbf{N}[x] + 1$  where  $x$  is the value of  $X$  in  $\mathbf{x}$ 
  return NORMALIZE( $\mathbf{N}[X]$ )
```

P.e., stimare  $\mathbf{P}(Rain|Sprinkler = true)$  usando 100 campioni

27 campioni hanno  $Sprinkler = true$

Di questi, 8 hanno  $Rain = true$  e 19 hanno  $Rain = false$ .

$\hat{\mathbf{P}}(Rain|Sprinkler = true) = \text{NORMALIZE}(\langle 8, 19 \rangle) = \langle 0.296, 0.704 \rangle$

## Analisi di rejection sampling

$$\begin{aligned}\hat{\mathbf{P}}(X|\mathbf{e}) &= \alpha \mathbf{N}_{PS}(X, \mathbf{e}) && \text{(def. algoritmo)} \\ &= \mathbf{N}_{PS}(X, \mathbf{e}) / N_{PS}(\mathbf{e}) && \text{(normalizzato tramite } N_{PS}(\mathbf{e})) \\ &\approx \mathbf{P}(X, \mathbf{e}) / P(\mathbf{e}) && \text{(proprietà di PRIORSAMPLE)} \\ &= \mathbf{P}(X|\mathbf{e}) && \text{(def. di probabilità condizionale)}\end{aligned}$$

Quindi rejection sampling restituisce stime consistenti della prob. a posteriori

Problemi: costosissimo se  $P(\mathbf{e})$  è piccola

La frazione di campioni consistente con  $\mathbf{e}$  decade esponenzialmente con il numero di variabili di evidenza!

## Likelihood weighting

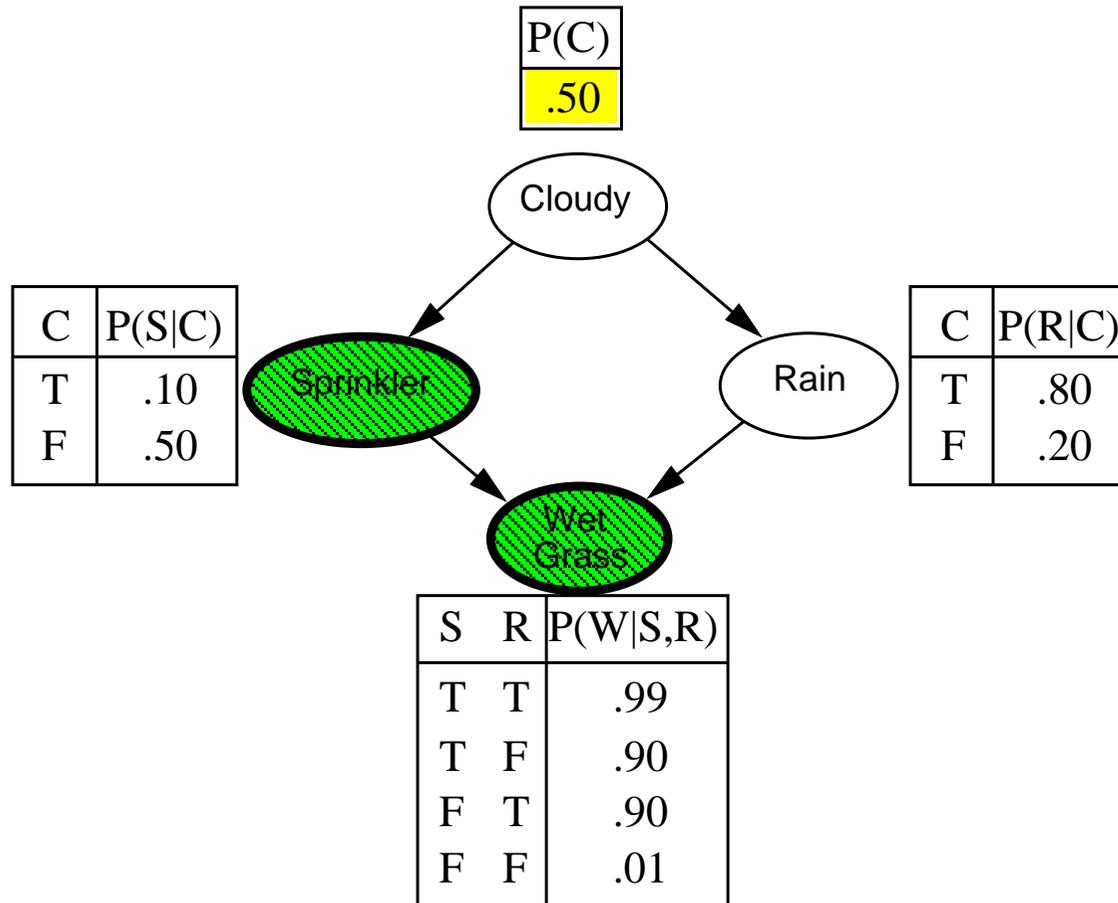
Idea: fissare le variabili di evidenza, campionare solo variabili non di evidenza, e pesare ogni campione con la likelihood accordata dall'evidenza

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

---

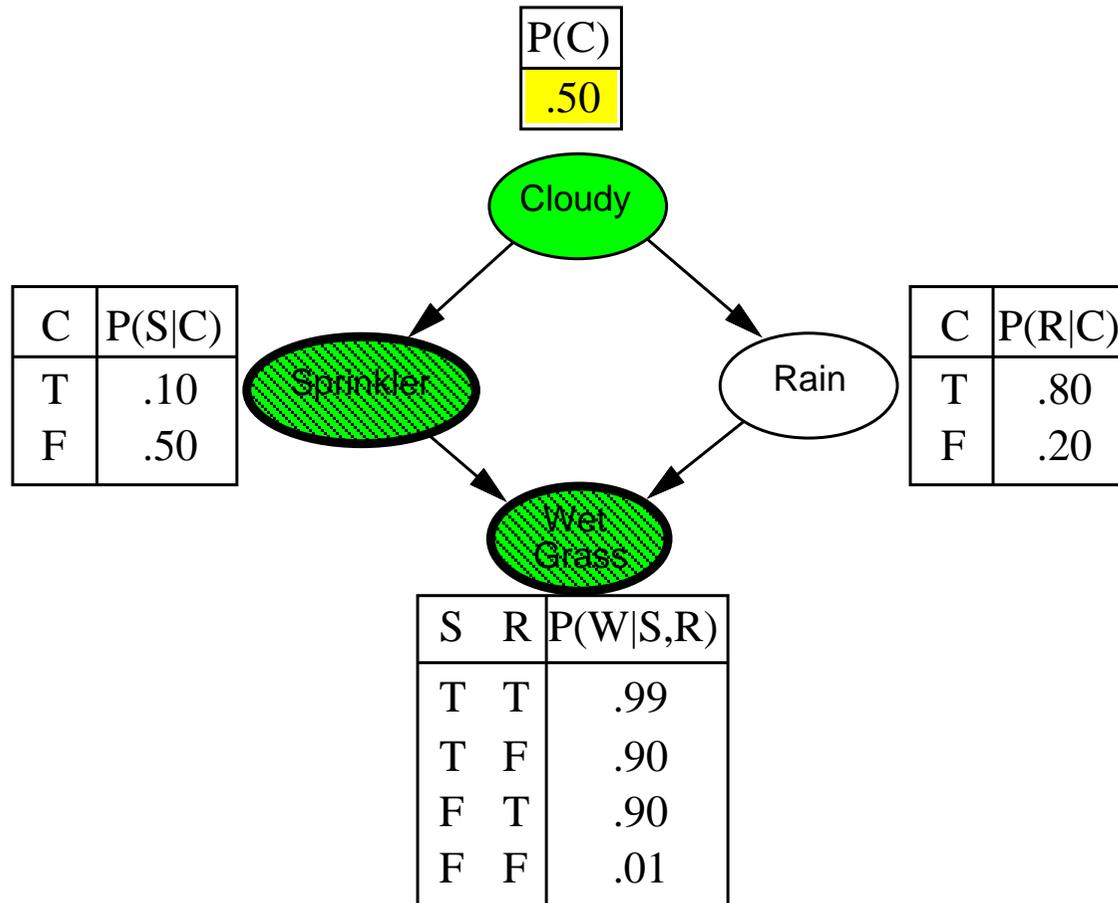
```
function WEIGHTED-SAMPLE( $bn, e$ ) returns an event and a weight  
  
   $x \leftarrow$  an event with  $n$  elements;  $w \leftarrow 1$   
  for  $i = 1$  to  $n$  do  
    if  $X_i$  has a value  $x_i$  in  $e$   
      then  $w \leftarrow w \times P(X_i = x_i \mid Parents(X_i))$   
      else  $x_i \leftarrow$  a random sample from  $\mathbf{P}(X_i \mid Parents(X_i))$   
  return  $x, w$ 
```

# Esempio di likelihood weighting



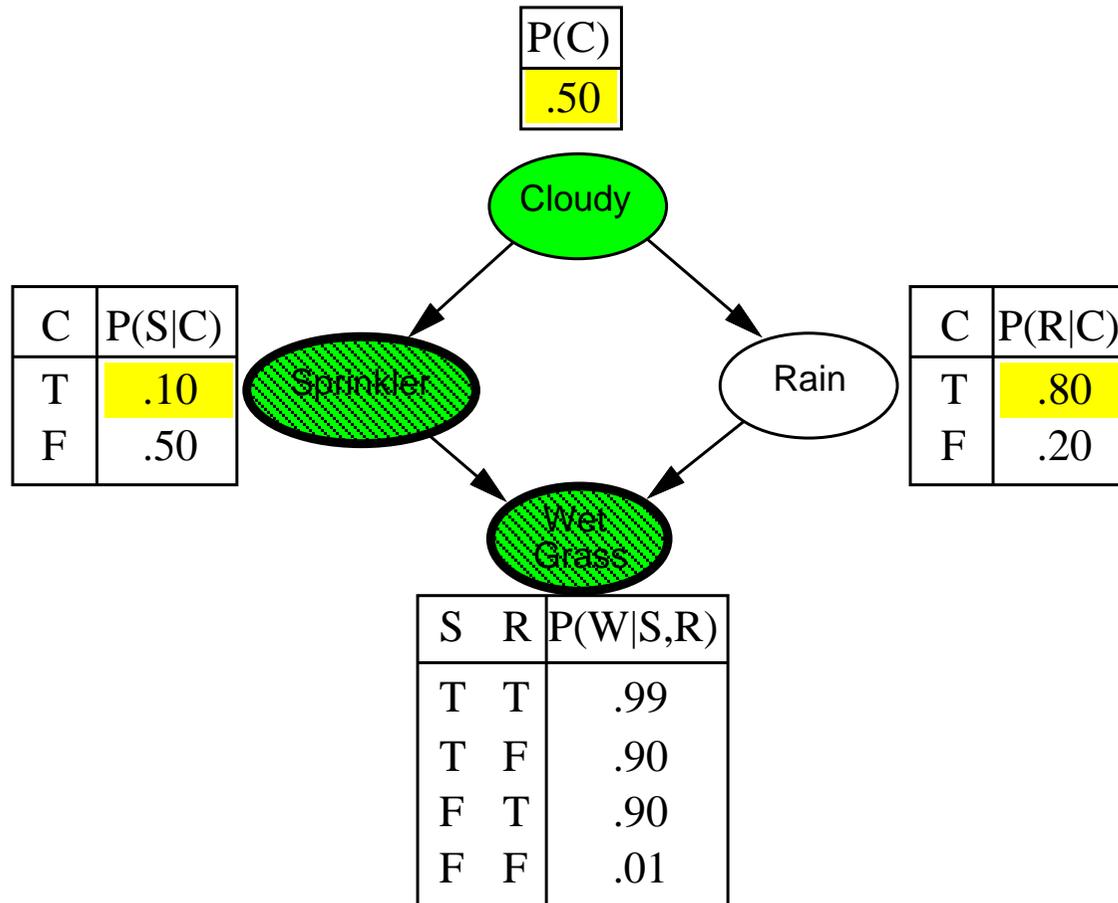
$$w = 1.0$$

# Esempio di likelihood weighting



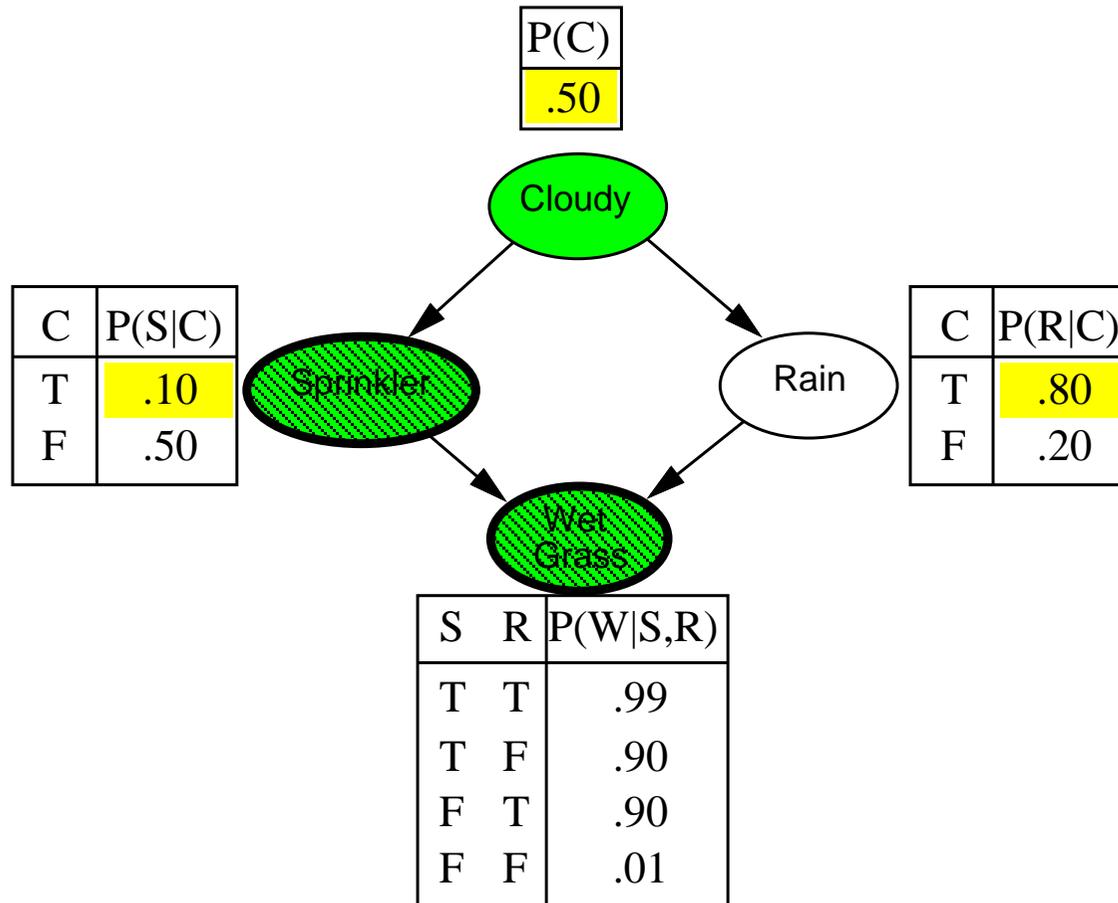
$w = 1.0$

# Esempio di likelihood weighting



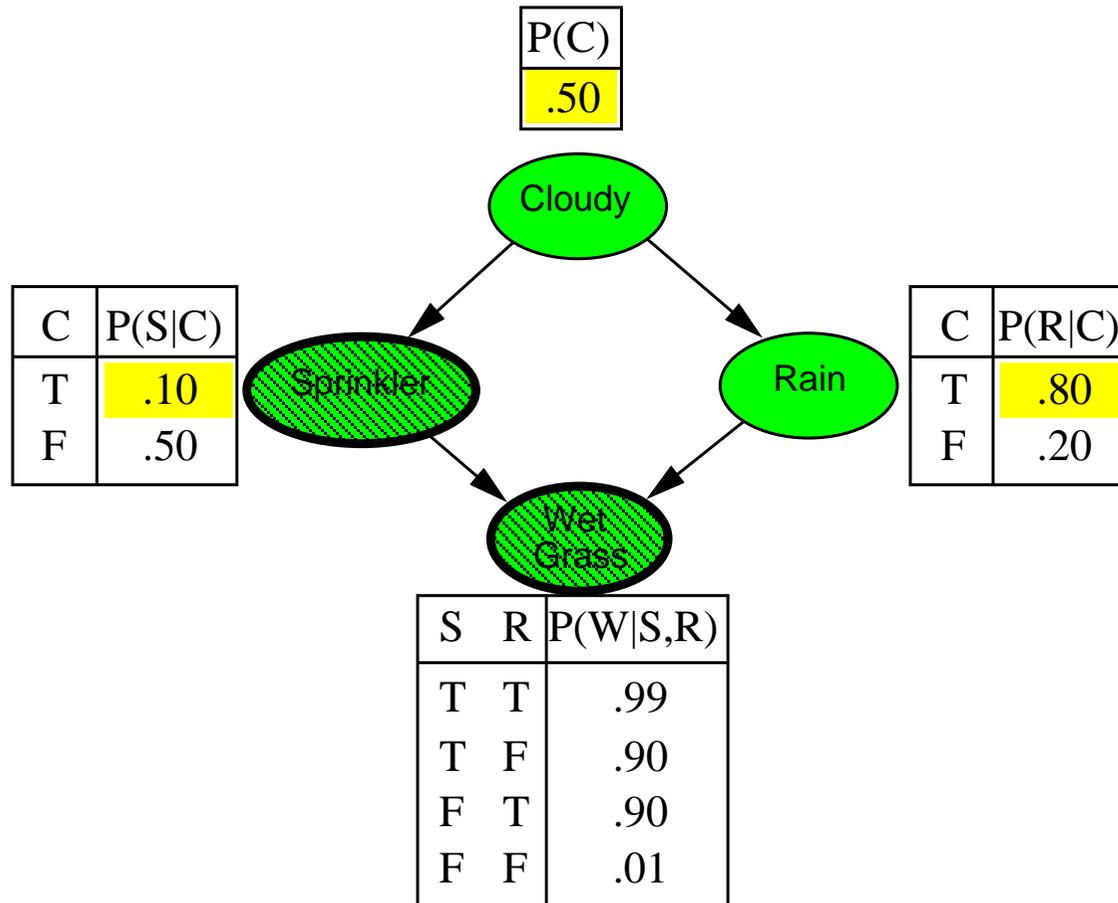
$w = 1.0$

# Esempio di likelihood weighting



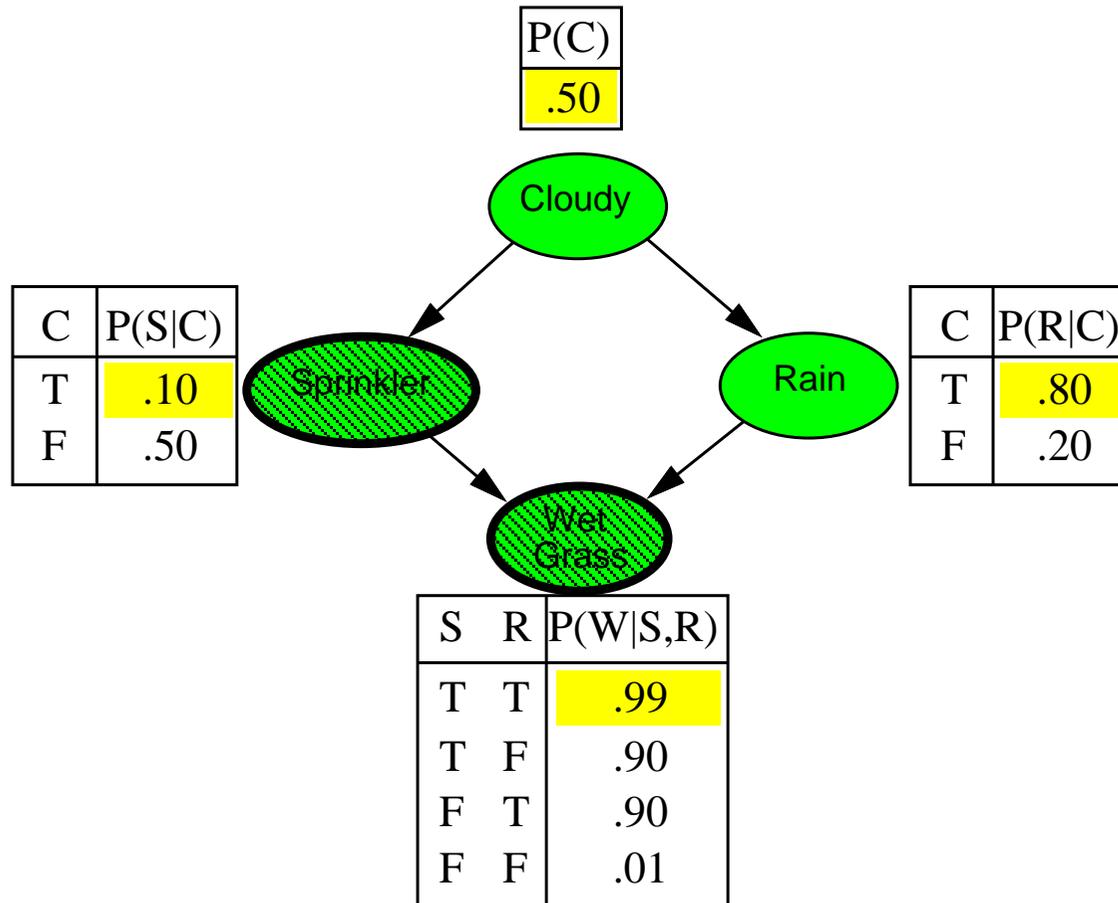
$$w = 1.0 \times 0.1$$

# Esempio di likelihood weighting



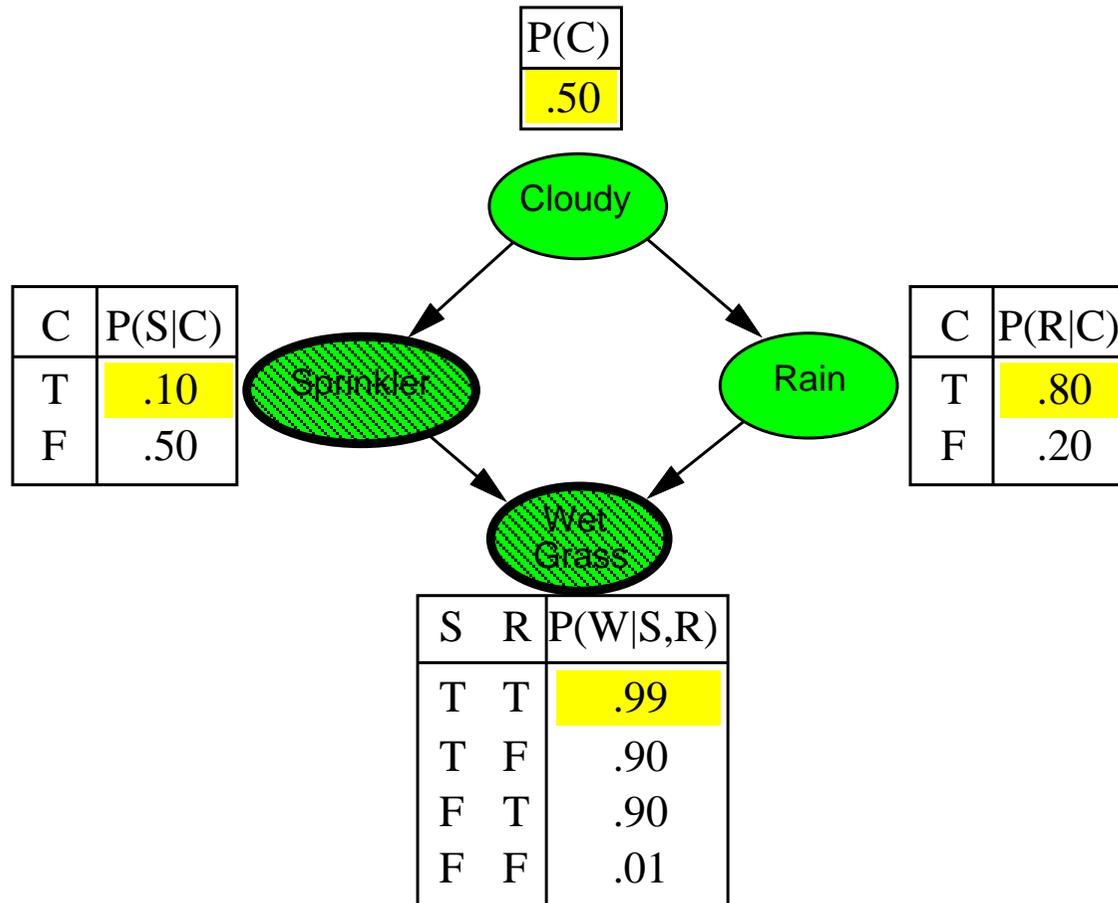
$$w = 1.0 \times 0.1$$

# Esempio di likelihood weighting



$$w = 1.0 \times 0.1$$

# Esempio di likelihood weighting



$$w = 1.0 \times 0.1 \times 0.99 = 0.099$$

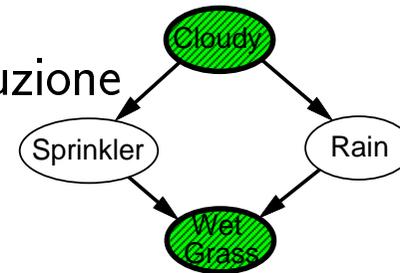
## Analisi di likelihood weighting

La probabilità di campionamento per WEIGHTEDSAMPLE è

$$S_{WS}(\mathbf{z}, \mathbf{e}) = \prod_{i=1}^l P(z_i | Parents(Z_i))$$

Nota: pone attenzione solo all'evidenza negli **antenati**

⇒ da qualche parte “nel mezzo” fra la distribuzione a priori e quella a posteriori



Il peso per un dato campione  $\mathbf{z}, \mathbf{e}$  è

$$w(\mathbf{z}, \mathbf{e}) = \prod_{i=1}^m P(e_i | Parents(E_i))$$

La probabilità di campionamento pesata è

$$\begin{aligned} & S_{WS}(\mathbf{z}, \mathbf{e}) w(\mathbf{z}, \mathbf{e}) \\ &= \prod_{i=1}^l P(z_i | Parents(Z_i)) \prod_{i=1}^m P(e_i | Parents(E_i)) \\ &= P(\mathbf{z}, \mathbf{e}) \text{ (per la semantica standard globale della rete)} \end{aligned}$$

Quindi likelihood weighting restituisce stime consistenti  
però le prestazioni degradano con la presenza di tante variabili di evidenza  
poiché pochi esempi hanno quasi tutto il peso totale

# 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

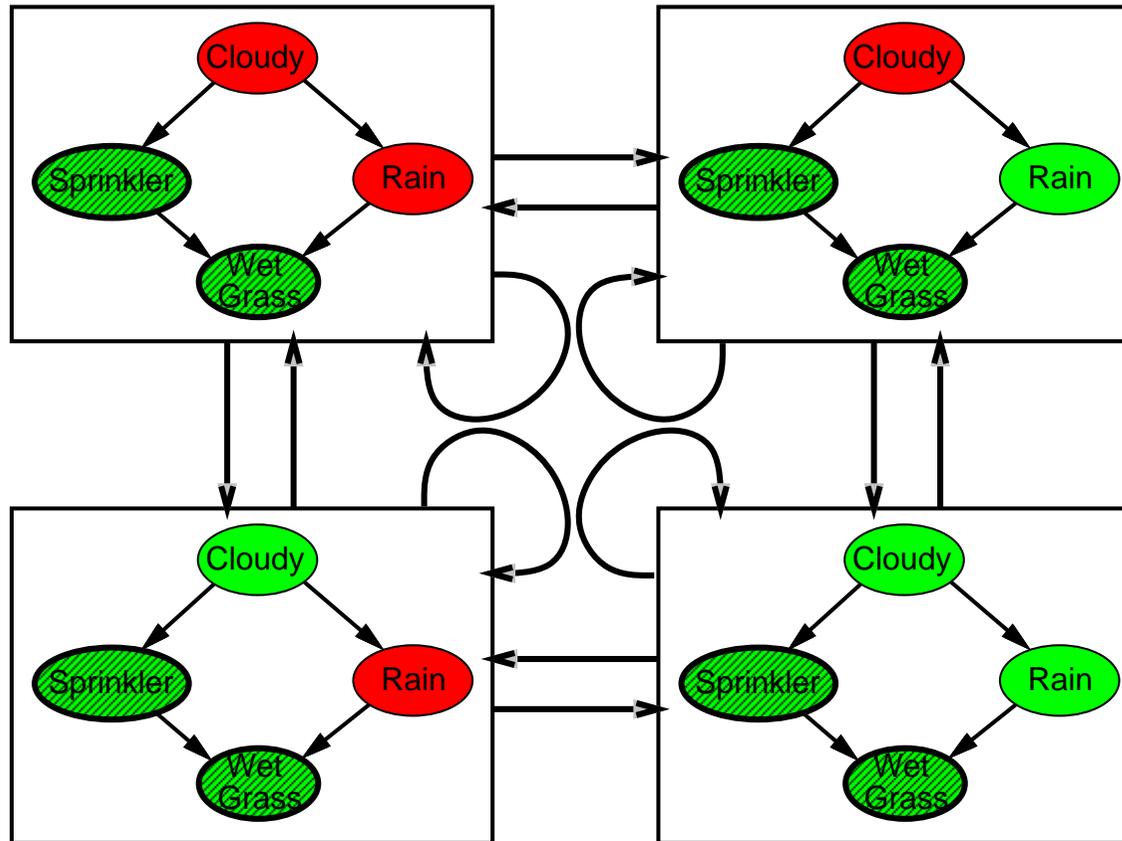
```
function MCMC-ASK( $X, e, bn, N$ ) returns an estimate of  $P(X|e)$ 
  local variables:  $\mathbf{N}[X]$ , a vector of counts over  $X$ , initially zero
                     $\mathbf{Z}$ , the nonevidence variables in  $bn$ 
                     $\mathbf{x}$ , the current state of the network, initially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

  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

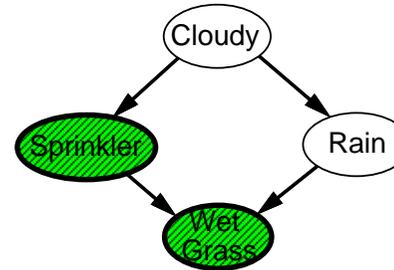
## Markov blanket: campionamento

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  $\pi_t$  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

⇒ 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  $t + 1$

$\pi_{t+1}$  definibile in termini di  $\pi_t$  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  $\pi$  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  $\pi$

# 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