

ZAKLJUČIVANJE U BAYESOVIM MREŽAMA

POGLAVLJE 14.4–5

Prema slajdovima Stuarta Russella (hvala)!

Sadržaj

- ◇ Egzaktno zaključivanje enumeracijom (pobrojavanjem)
- ◇ Egzaktno zaključivanje eliminacijom varijabli
- ◇ Približno zaključivanje statističkom/stohastičkom simulacijom
- ◇ Približno zaključivanje metodom “Markov chain Monte Carlo”

Očita pitanja — problemi zaključivanja

Bayesova mreža je bazirana na **uvjetnim** vjerojatnostima i **uvjetnim** zavisnostima (nezavisnostima) pojedinih varijabli.

Prirodna pitanja — problemi zaključivanja:

- određivanje **međuzavisnosti** pojedinih čvorova,
- računanje **a priori** (početne) vjerojatnosti, a **ne** uvjetne,
- širenje (propagiranje) dokaza **unaprijed** kroz mrežu
= duž puta **u smjeru** strelica = kauzalni smjer,
- širenje (propagiranje) dokaza **unatrag** kroz mrežu
= duž puta **obrnuto** od smjera strelica = dijagnostički smjer,
- tzv. “skretanje” = **kombinacija** natrag–naprijed,
- širenje (propagiranje) dokaza s **višestrukim** putevima,
kad imamo **više** puteva između dva čvora (ovo je **teško**).

Oznake i standardni upit — ponavljanje

Oznake — kao i ranije (kod zaključivanja enumeracijom), neka je

\mathbf{X} = popis varijabli **upita**, tj. **traženih** varijabli,

\mathbf{E} = popis **dokaznih** varijabli i

\mathbf{e} = popis njihovih **opaženih** = **dokaznih** vrijednosti,

tj. $\mathbf{E} = \mathbf{e}$ je konkretni opaženi događaj,

\mathbf{Y} = popis svih preostalih, tzv. **skrivenih** varijabli.

Dakle, unija $\mathbf{X} \cup \mathbf{E} \cup \mathbf{Y}$ daje skup **svih** varijabli u problemu (mreži).

U **praksi** je interesantan **upit** oblika $\mathbf{P}(\mathbf{X} | \mathbf{e})$, tj. traži se

uvjetna združena distribucija varijabli \mathbf{X} , uz dane **dokaze** $\mathbf{E} = \mathbf{e}$.

Radi jednostavnosti, obično gledamo upite sa samo **jednom** varijablom, tj. $\mathbf{X} = \{X\}$ — odmah će biti jasno i zašto.

Ako je $\mathbf{E} = \emptyset$, tj. ako **nema** dokaza, onda, umjesto uvjetnih, dobivamo **bezuovjetne** ili **a priori** vjerojatnosti.

Zadaci zaključivanja — u Bayesovoj mreži

Jednostavni upiti:

izračunaj naknadnu (marginalnu) distribuciju $\mathbf{P}(X \mid \mathbf{E} = \mathbf{e})$,

na primjer, vjerojatnost da “nemam goriva u rezervoaru”

$$P(\text{noGas} \mid \text{Gauge} = \text{empty}, \text{Lights} = \text{on}, \text{Starts} = \text{false})$$

(engl. gauge = mjerač za gorivo).

Konjunktivni upiti (upiti s više varijabli): **svode** se na **jednostavne!**

Koristimo **produktno/lančano** pravilo — prirodno za Bayesove mreže

$$\mathbf{P}(X_i, X_j \mid \mathbf{E} = \mathbf{e}) = \mathbf{P}(X_i \mid \mathbf{E} = \mathbf{e}) \mathbf{P}(X_j \mid X_i, \mathbf{E} = \mathbf{e}).$$

Ovo vrijedi i **bez** uvjetne nezavisnosti X_i, X_j uz uvjete $\mathbf{E} = \mathbf{e}$.

Uvjetna nezavisnost \implies **pojednostavljenje** zadnjeg faktora (nema X_i).

Zadaci zaključivanja — općenito

Osnovni zadaci vjerojatnosnog zaključivanja u Bayesovoj mreži služe za donošenje **složenijih** zaključaka u problemu.

Optimalne odluke: mreže odlučivanja uključuju informacije o **korisnosti**; vjerojatnosno zaključivanje je potrebno za računanje/procjenu

$$P(\textit{outcome} \mid \textit{action}, \textit{evidence})$$

vjerojatnosti nekog **rezultata** (ishoda) za dane **akcije** i **dokaze**.

Vrijednost informacije: koji dokaz treba **prvo** pronaći ili ispitati?

Analiza osjetljivosti: koje vjerojatnosti su **najkritičnije**?

Objašnjenje (kad to nekog zanima): **zašto** trebam novi starter?

Najvjerojatnije objašnjenje $\arg \max_x P(X = x \mid \mathbf{E} = \mathbf{e})$,

Ovaj “zašto” nije samo pitanje osobne znatiželje, već **pokretač istraživanja** i **razvoja** u industriji, medicini, ...

Zaključivanje enumeracijom — ponavljanje

To je najjednostavnija metoda za **probabilističko** zaključivanje.

Bazira se na **potpunoj združenoj distribuciji** svih varijabli i svodi se na **pobrojavanje svih** mogućnosti iz upita i **zbrajanje** pripadnih vjerojatnosti, uz **normalizaciju** zbroja 1.

Za jednostavni upit $P(X | e)$, to znači

fiksiraj **dokaze** i **zbroji** preko svih ostalih = **skrivenih** varijabli iz **Y**.

Tražena distribucija $P(X | e)$ računa se “**marginalizacijom**”, kao **zbroj**

$$P(X | e) = \alpha P(X, e) = \alpha \sum_y P(X, e, y).$$

Suma ide po **svim** mogućim kombinacijama vrijednosti **Y = y** skrivenih varijabli **Y**, a α je **normalizacijska** konstanta da **konačni** zbroj bude 1.

Svrha **marginalizacije** je **eliminacija** skrivenih varijabli, a algoritam za to = **sumiranje** po njima.

Zaključivanje enumeracijom — Bayesove mreže

U **Bayesovoj** mreži, **potpuna združena distribucija** ima poseban prikaz, preko **produkta** tablica **uvjetnih vjerojatnosti (CPT)** u čvorovima mreže

$$\mathbf{P}(X_1, \dots, X_n) = \prod_{i=1}^n \mathbf{P}(X_i \mid \mathit{Parents}(X_i))$$

Ovo množenje je množenje vektora **po točkama, svaki sa svakim**.

Kroneckerov, direktni ili tenzorski produkt — standardna oznaka je \times .

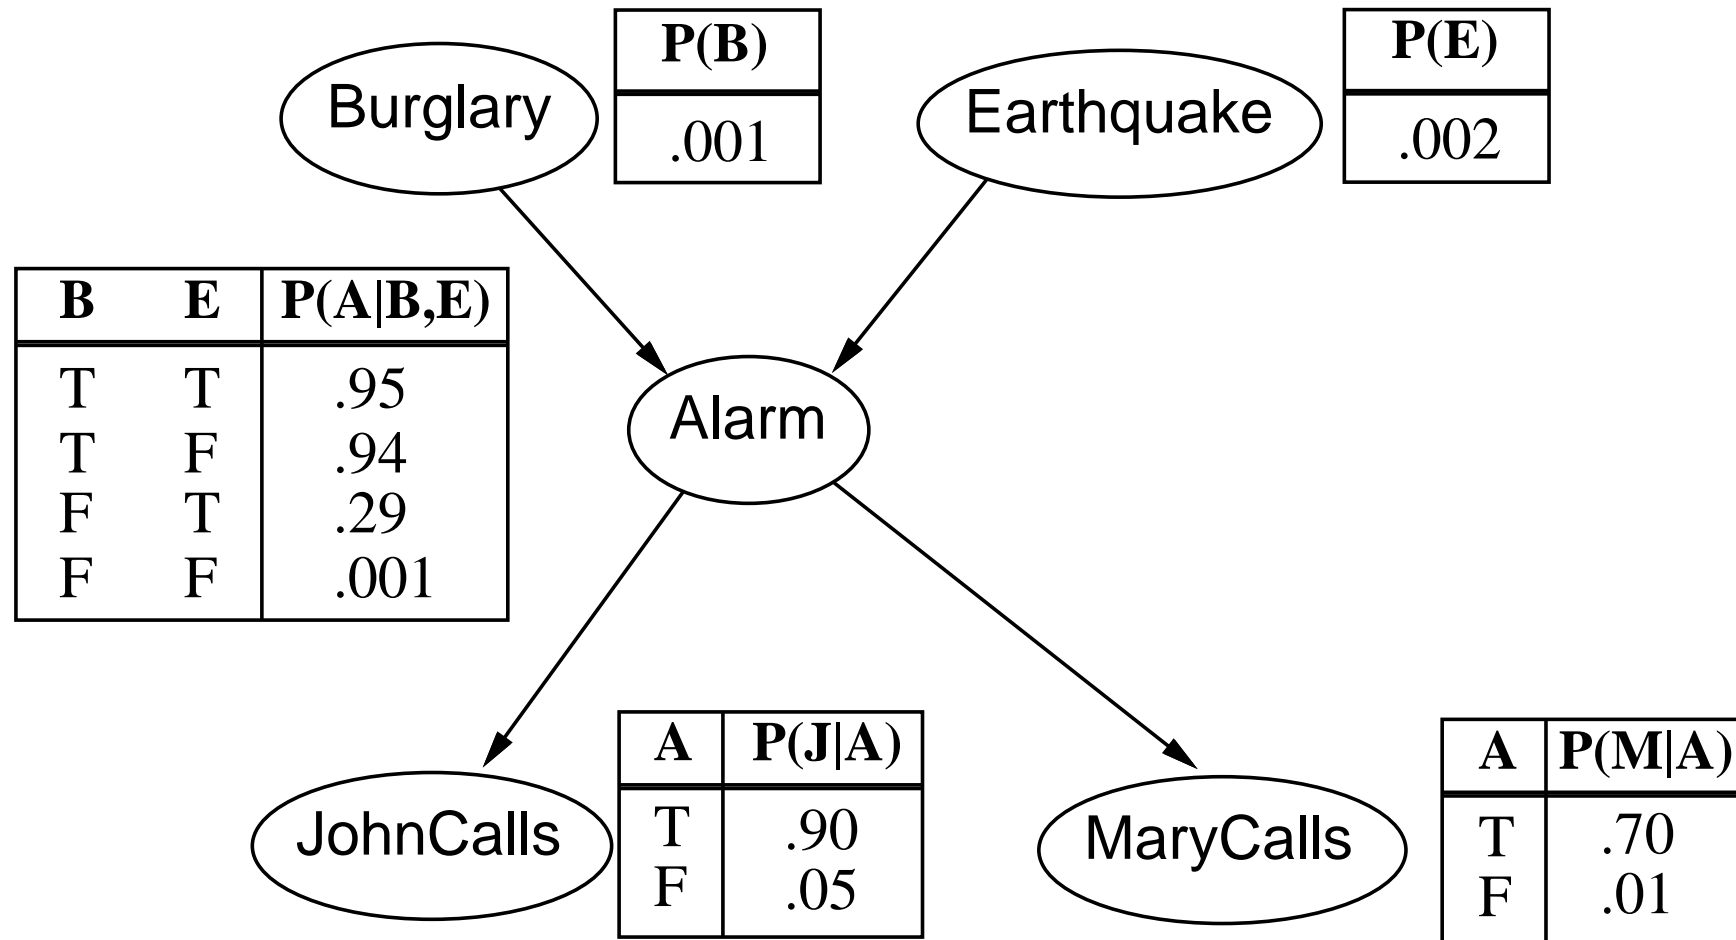
Napomena: X_1, \dots, X_n su **sve** varijable u problemu (mreži), tj. ako je X varijabla upita, a \mathbf{E} su dokazne varijable, onda su **skrivenne** varijable

$$\mathbf{Y} = \{X_1, \dots, X_n\} \setminus (\{X\} \cup \mathbf{E}).$$

Kod računanja upita $\mathbf{P}(X \mid \mathbf{e})$ u Bayesovoj mreži, gornja formula se može iskoristiti na **dva** načina:

- za “pametno” **zbrajanje** = **pobrojavanje** ili **enumeracija**,
- za izravnu **eliminaciju** skrivenih varijabli = **eliminacija** varijabli.

Primjer — Provalnička mreža



Zaključivanje enumeracijom (pobrojavanjem)

Algoritam enumeracije ili pobrojavanja: “ponešto pametan” način da “odsumiramo” skrivene varijable iz združene distribucije, bez da stvarno formiramo njezinu eksplicitnu reprezentaciju, već zbrajamo produkte uvjetnih vjerojatnosti iz mreže.


Primjer jednostavnog upita za provalničku mrežu

$$\mathbf{P}(Burglary \mid JohnCalls = true, MaryCalls = true).$$

Skrivene varijable za ovaj upit su *Earthquake* i *Alarm*.


U skraćenim oznakama (jedno slovo), enumeracija daje

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



Zaključivanje enumeracijom — zapis preko CPT

Vrijednosti $\mathbf{P}(B, e, a, j, m)$ iz potpune združene distribucije zapišemo kao **produkte** vrijednosti iz **CPT** u mreži — to je **osnovna** formula za provalničku Bayesovu mrežu:



$$\mathbf{P}(B, e, a, j, m) = \mathbf{P}(B) P(e) \mathbf{P}(a | B, e) P(j|a) P(m|a).$$

To uvrstimo u enumeracijsku sumu, pa dobijemo

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

U **ovom** obliku, za **svaku** vrijednost $B = b$, $B = \neg b$, treba izračunati **sumu** od 4 člana, po svim vrijednostima skrivenih varijabli $y = (e, a)$, svaki član je **produkt** od 5 faktora (ukupni broj čvorova).

Općenito, ako treba “odsumirati” **većinu** varijabli (skoro n), složenost u **najgorem** slučaju za mrežu s n Booleovih varijabli je $O(n2^n)$.

Zaključivanje enumeracijom — primjer

Pogledati: Eliminacija, str. 1.

Rezultat je $\mathbf{P}(B \mid j, m) = \langle 0.284172, 0.715818 \rangle$.


Zaključivanje enumeracijom — poboljšanje

Poboljšanje = izlučivanje faktora koji **ne ovise** o pojedinoj sumi.

Na primjer, $P(B)$ **ne ovisi** o e, a , jer je **na vrhu** mreže.

Slično, $P(e)$ **ne ovisi** o a , jer je **iznad** njega u mreži.

Onda dobijemo



$$P(B | j, m) = \alpha P(B) \sum_e P(e) \sum_a P(a | B, e) P(j|a) P(m|a).$$

Kad možemo **izlučiti** neki faktor **ispred** neke sume?

Svaki **faktor** = neka vrijednost iz **CPT** u danom čvoru,

a **CPT** u čvoru ovisi samo o **čvoru** i **roditeljima** čvora (ako ih ima)!

Dakle, faktor **smije ispred** svih suma koje **nisu** taj čvor ili njegovi roditelji.

Ostaje još pitanje dobrog “**globalnog poretka**” suma za izlučivanje.

Enumeracija — oblik izraza

Svaka **suma** = jedna **skrivena** varijabla ili čvor u mreži.

Sume **poredamo** (slijeva udesno) prema **standardnom** topološkom poretku čvorova u mreži — tako da **roditelji** dolaze **prije** djece.

Time dobivamo jedan **korektan** poredak suma za izlučivanje faktora.

Faktor iz danog čvora ide **ispred** svih onih suma koje idu po **skrivenim** varijablama (čvorovima) **iza** njega, po poretku čvorova u mreži.

$$\mathbf{P}(B | j, m) = \alpha \mathbf{P}(B) \sum_e P(e) \sum_a \mathbf{P}(a | B, e) P(j|a) P(m|a).$$

Čvor B je **prvi**, pa ide **ispred** svega (slučajno baš upit).

Prva **skrivena** varijable E je **druga** po redu. Pripadni faktor $P(e)$ **možemo** izlučiti iz svih naknadnih suma — ima još skrivenih varijabli!

Zadnja **skrivena** varijabla A je **treća** po redu, odmah iza prethodne — iz pripadne sume **ne možemo** ništa izlučiti.

Zaključivanje enumeracijom — skica algoritma

Računanje ovog izraza:

= petlja po **svim** čvorovima, prema poretku:

u svakom čvoru **množimo** odgovarajuću vrijednost iz pripadne **CPT**,
u **skrivenim** čvorovima još ide petlja za **zbrajanje** tih produkata,
po svim mogućim **vrijednostima** te varijable.

Normalizacijski faktor α se računa na kraju, zbrajanjem po dobivenom vektoru vrijednosti, a onda se distribucija normalizira.

Rekurzivno prebrojavanje u dubinu: $O(n)$ prostorno, $O(d^n)$ vremenski.

Enumeracijski algoritam

function ENUMERATION-ASK(X, \mathbf{e}, bn) **returns** a distribution over X

inputs: X , the query variable

\mathbf{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 \mathbf{e} with value x_i for X

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

return NORMALIZE($Q(X)$)

function ENUMERATE-ALL($vars, \mathbf{e}$) **returns** a real number

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

$Y \leftarrow$ FIRST($vars$)


if Y has value y in \mathbf{e}

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

else return $\sum_y P(y \mid Pa(Y)) \times$ ENUMERATE-ALL(REST($vars$), \mathbf{e}_y)

 where \mathbf{e}_y is \mathbf{e} extended with $Y = y$

Evaluacijsko stablo



Enumeracija je neefikasna: ponovljeno računanje
 na pr. računa $P(j|a)P(m|a)$ za svaku vrijednost e

Enumeracija — drugi oblik izraza

Ako prvo uzmemo čvor A , pa onda E , dobivamo izraz

$$\mathbf{P}(B | j, m) = \alpha \mathbf{P}(B) \sum_a P(j|a) P(m|a) \sum_e P(e) \mathbf{P}(a | B, e).$$

Optimalni poredak = NP-težak problem.

Zaključivanje eliminacijom varijabli


Eliminacija varijabli: treba napraviti sumacije zdesna nalijevo, spremite međurezultate (**faktore**) za izbjegavanje ponovljenog računanja

$$\mathbf{P}(B|j, m) = \alpha \underbrace{\mathbf{P}(B)}_{f_1(B)} \sum_e \underbrace{P(e)}_{f_2(E)} \sum_a \underbrace{\mathbf{P}(a|B, e)}_{f_3(A, B, E)} \underbrace{P(j|a)}_{f_4(A)} \underbrace{P(m|a)}_{f_5(A)}.$$


Primjer provalničke mreže i značenje faktora (na sljedećoj stranici).

Zaključivanje eliminacijom varijabli

B	P(B)
+b	0.001
-b	0.999



E	P(E)
+e	0.002
-e	0.998



A	J	P(J A)
+a	+j	0.9
+a	-j	0.1
-a	+j	0.05
-a	-j	0.95

A	M	P(M A)
+a	+m	0.7
+a	-m	0.3
-a	+m	0.01
-a	-m	0.99

B	E	A	P(A B,E)
+b	+e	+a	0.95
+b	+e	-a	0.05
+b	-e	+a	0.94
+b	-e	-a	0.06
-b	+e	+a	0.29
-b	+e	-a	0.71
-b	-e	+a	0.001
-b	-e	-a	0.999

Kad **uvrstimo** dokaze, u terminima faktora, izraz se može napisati kao

$$P(B|j, m) = \alpha f_1(B) \times \sum_e f_2(E) \times \sum_a f_3(A, B, E) \times f_4(A) \times f_5(A).$$

Koraci u eliminaciji varijabli

- Prvo, **odsumiramo** A iz produkta f_3 , f_4 i f_5 .
To daje novi faktor $f_6(B, E)$, kojemu indeksi prolaze samo po B i E :

$$\begin{aligned} f_6(B, E) &= \sum_a f_3(A, B, E) \times f_4(A) \times f_5(A) \\ &= (f_3(a, B, E) \times f_4(a) \times f_5(a)) \\ &\quad + (f_3(\neg a, B, E) \times f_4(\neg a) \times f_5(\neg a)). \end{aligned}$$

Sada ostajemo s izrazom:

$$\mathbf{P}(B|j, m) = \alpha f_1(B) \times \sum_e f_2(E) \times f_6(B, E).$$

(za računanje pogledati: Eliminacija, str. 2–3.)

Koraci u eliminaciji varijabli (nastavak)

- Nadalje, odsumiramo E iz produkta f_2 i f_6 :

$$\begin{aligned} f_7(B) &= \sum_e f_2(E) \times f_6(B, E) \\ &= f_2(e) \times f_6(B, e) + f_2(\neg e) \times f_6(B, \neg e) \end{aligned}$$

što daje

$$\mathbf{P}(B|j, m) = \alpha f_1(B) \times f_7(B).$$

Ovaj izraz izvrednjava se množenjem po točkama i normalizacijom rezultata.

Prethodni primjer pokazuje potrebu za samo dvije operacije:

- produkt po točkama para faktora
- zbrajanje po varijabli iz produkta faktora.

Stvarno, treba i treća operacija — za uvrštavanje vrijednosti varijable

- fikisiranje neke vrijednosti u faktoru = projekcija!

Eliminacija varijabli: osnovne operacije

Zbrajanje po varijabli iz produkta faktora:

konstante se izbace ispred sumacije

zbroje se podmatrice u produkt po točkama iz preostalih faktora

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

uz pretpostavku da f_1, \dots, f_i ne ovisi o X

Produkt po točkama faktora f_1 i f_2 :

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

Na primjer $f_1(a, b) \times f_2(b, c) = f(a, b, c)$

Algoritam eliminacije varijabli

```
function ELIMINATION-ASK( $X, \mathbf{e}, bn$ ) returns a distribution over  $X$   
  inputs:  $X$ , the query variable  
            $\mathbf{e}$ , 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  
     $factors \leftarrow [\text{MAKE-FACTOR}(var, \mathbf{e}) | factors]$   
    if  $var$  is a hidden variable then  $factors \leftarrow \text{SUM-OUT}(var, factors)$   
  return NORMALIZE( $\text{POINTWISE-PRODUCT}(factors)$ )
```

Za korektan algoritam, operacija **MAKE-FACTOR** mora generirati faktor s **uvrštenim** dokazima (za smanjenje veličine faktora).

Ovdje:

- pokazati slajdove Dana Kleina (CS 188, Lecture 15, str. 14–32)
- vrati se na računanje = Eliminacija, str. 2–3.

Eliminacija varijabli — drugi oblik izraza

Eliminaciju možemo napraviti i na drugi način — za izraz:

$$\mathbf{P}(B | j, m) = \alpha \mathbf{P}(B) \sum_a P(j|a) P(m|a) \sum_e P(e) \mathbf{P}(a | B, e).$$

Ovdje prvo eliminiramo varijablu E , pa onda A .

Pogledati: Eliminacija, str. 4.

Nebitne varijable


Razmotrimo upit $P(\text{JohnCalls} \mid \text{Burglary} = \text{true})$

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

Suma po m je identički jednaka 1; M je **nebitan** za upit!

Teorem 1. Y je nebitna osim ako $Y \in \text{Ancestors}(\{X\} \cup \mathbf{E})$.

Ovdje je $X = \text{JohnCalls}$, $\mathbf{E} = \{\text{Burglary}\}$ i
 $\text{Ancestors}(\{X\} \cup \mathbf{E}) = \{\text{Alarm}, \text{Earthquake}\}$
pa je MaryCalls nebitno.



(Slično s ulančavanjem unatrag iz upita u KB s Hornovim klauzulama).


Nebitne varijable (nastavak)

Definicija. Moralni graf Bayesove mreže = **poženi** (spoji) sve roditelje i **ispusti** strelice.

Definicija. **A** je m -separiran od **B** s **C**, akko je separariran s **C** u moralnom grafu.

Teorem 2. **Y** je **nebitan**, ako je m -separiran od **X** s dokazima **E**.

Za upit $P(\text{JohnCalls} \mid \text{Alarm} = \text{true})$, oboje, *Burglary* i *Earthquake* je nebitno.



Složenost egzaktnog zaključivanja

Jednostruko povezane mreže (ili poli-stabla):

- svaka dva čvora povezana su najviše jednim (neusmjerenim) putem
- vremenska i prostorna složenost eliminacija varijabli su $O(d^k n)$
(d = br. vrij. varijable, k = br. roditelja, n = broj čvorova).


Drugim riječima, **linearno** u ukupnom broju elemenata u **CPT**.

Složenost egzaktnog zaključivanja (nastavak)

Višestruko povezane mreže:

- mogu reducirati 3SAT u egzaktno zaključivanje \Rightarrow NP-težak
- ekvivalentno **brojenju** 3SAT modela \Rightarrow #P-potpun (striktno **teži** od NP-potpunih problema).

1. $A \vee B \vee C$
2. $C \vee D \vee \neg A$
3. $B \vee C \vee \neg D$



Zaključivanje stohastičkom simulacijom

Osnovna ideja:

- 1) Uzmi N uzoraka iz uzoračke distribucije S
- 2) Izračunaj aproksimativnu a posteriori vjerojatnost \hat{P}
- 3) Pokaži da to konvergira prema pravoj vjerojatnosti P .

0.5

Coin

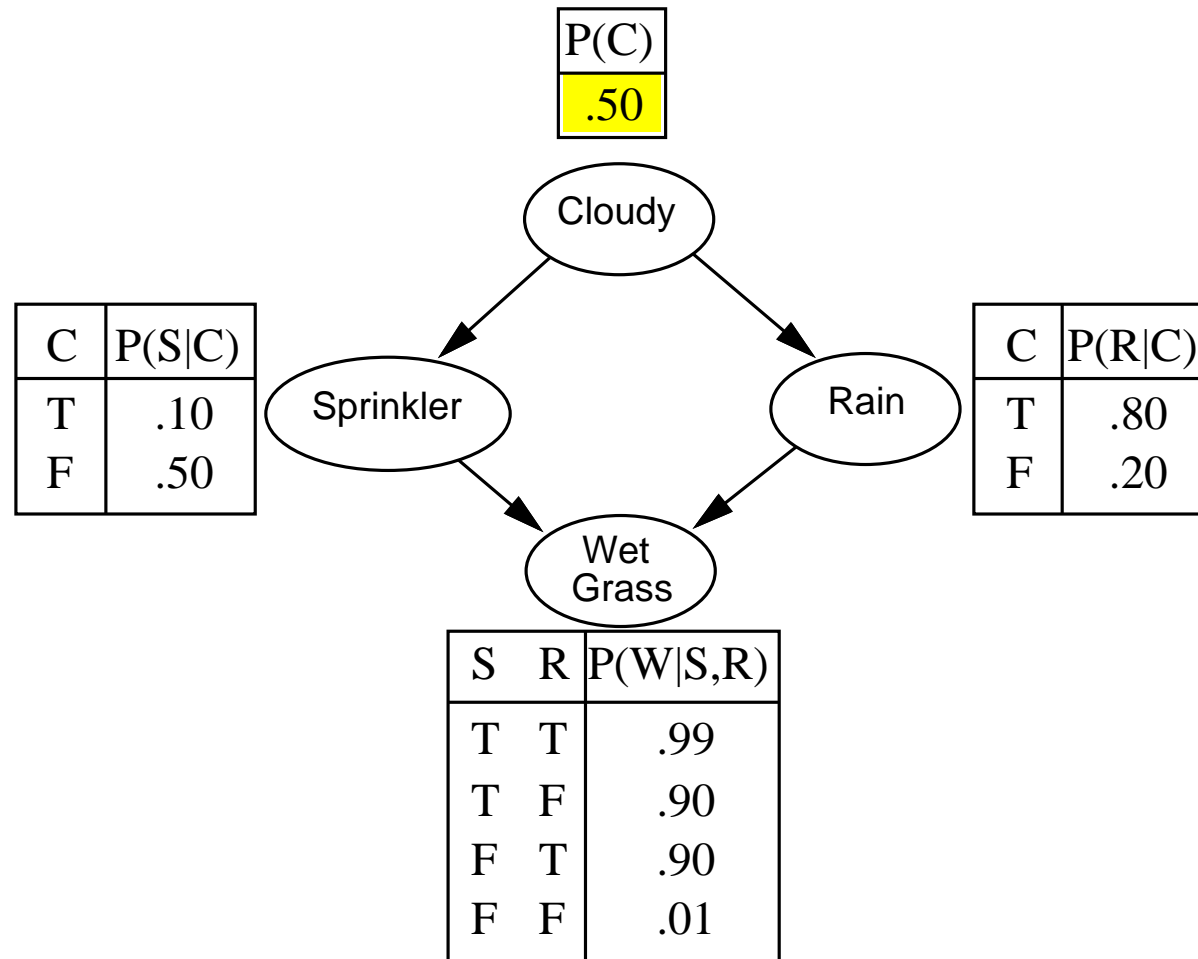
Sadržaj:

- Uzorkovanje iz prazne mreže
- Odbacivanje uzoraka: odbacuju se uzorci koji se ne slažu s dokazima
- Težinska izglednost/vjerodostojnost (engl. “likelihood weighting”): iskoriste se dokazi za stavljanje težina na uzorke
- Markov chain Monte Carlo (MCMC): uzme se uzorak iz stohastičkog procesa kojemu je stacionarna distribucija jednaka pravoj aposteriornoj distribuciji.

Uzorkovanje iz prazne mreže

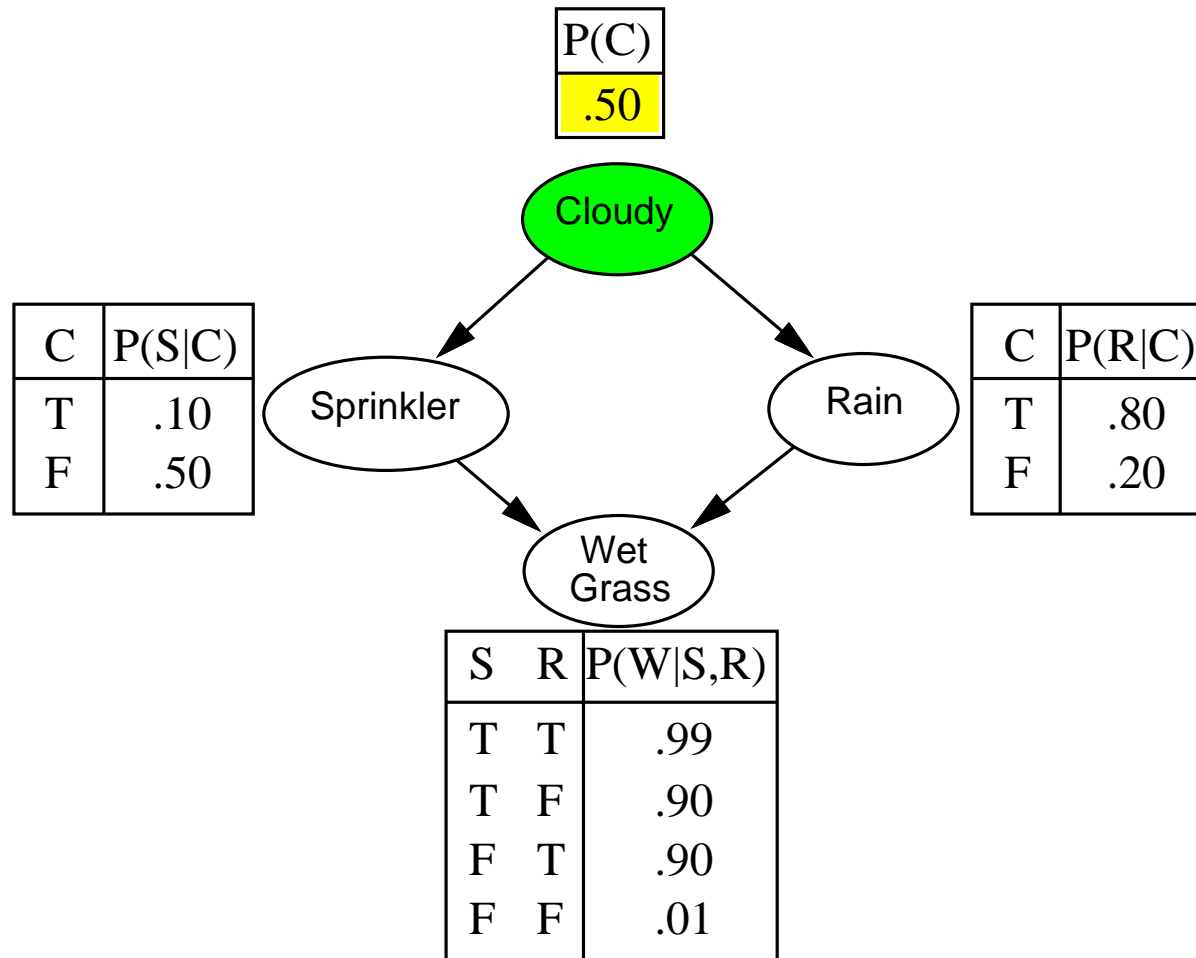
```
function PRIOR-SAMPLE(bn) returns an event sampled from bn  
inputs: bn, a belief network specifying joint distribution  $\mathbf{P}(X_1, \dots, X_n)$   
x  $\leftarrow$  an event with n elements  
for i = 1 to n do  
    xi  $\leftarrow$  a random sample from  $\mathbf{P}(X_i \mid \text{parents}(X_i))$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

Primjer



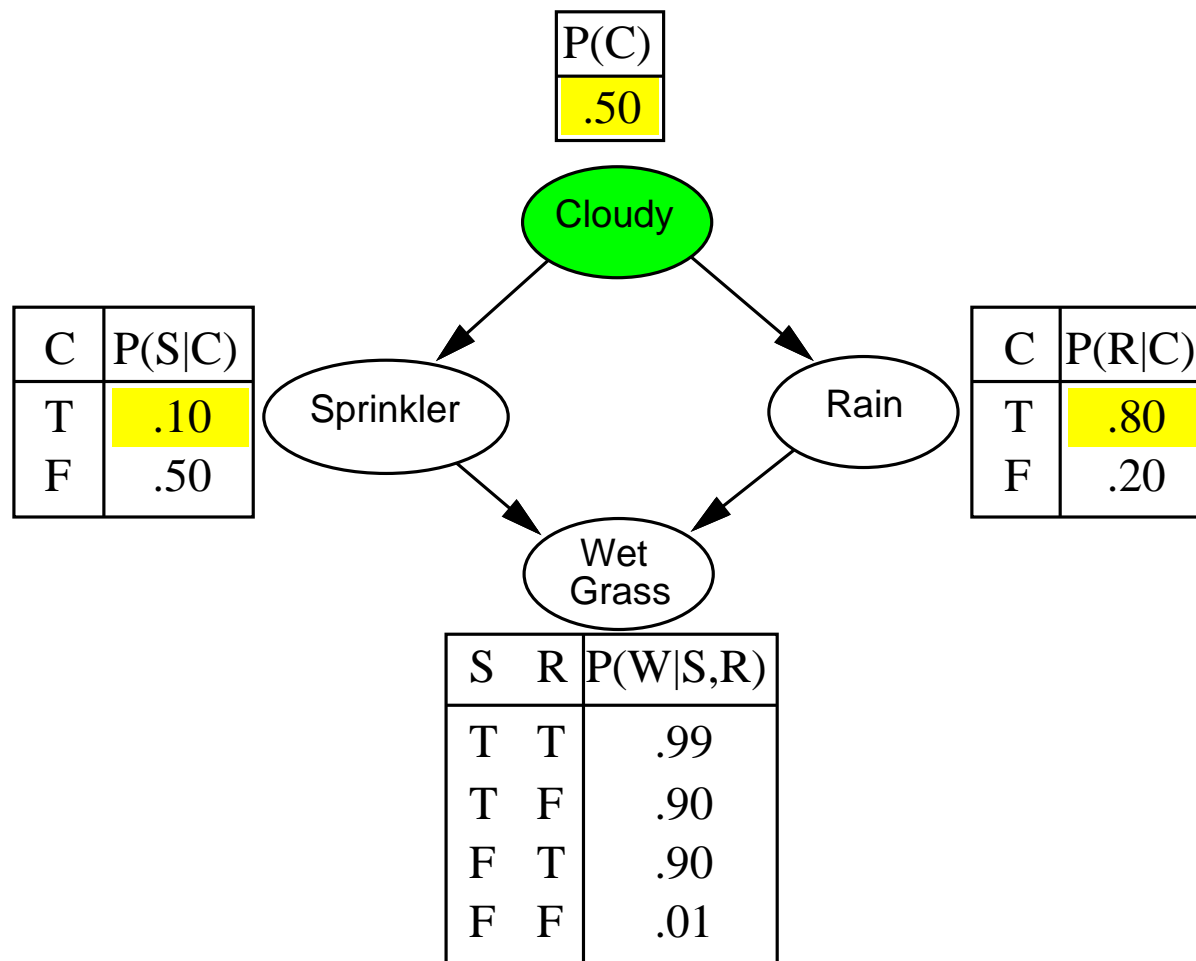
Uzorak iz $\mathbf{P}(Cloudy) = \langle 0.5, 0.5 \rangle$

Primjer



Uzorak iz $\mathbf{P}(Cloudy) = \langle 0.5, 0.5 \rangle$, neka je *true*.

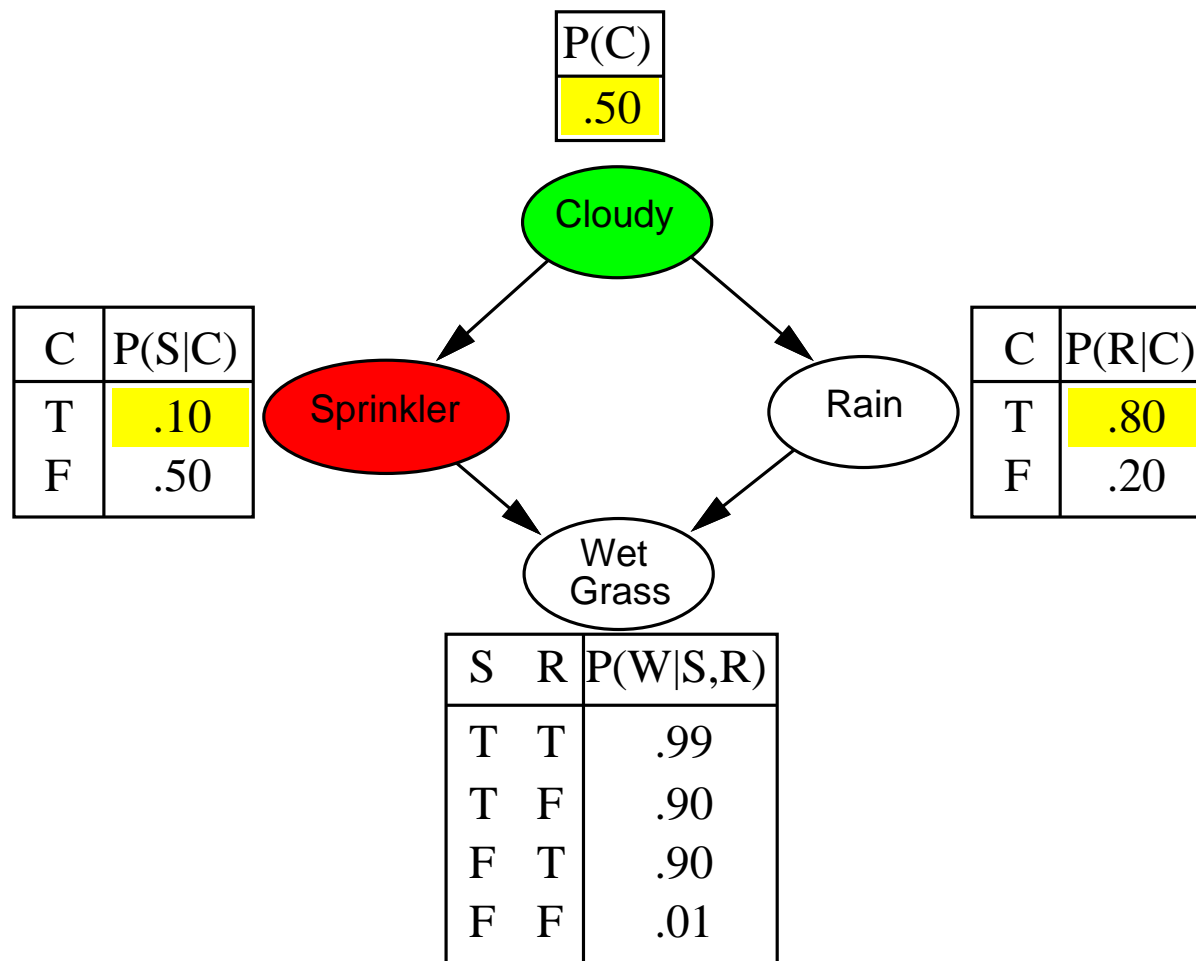
Primjer



Uzorak iz $\mathbf{P}(\textit{Sprinkler} \mid \textit{Cloudy} = \textit{true}) = \langle 0.1, 0.9 \rangle$

Uzorak iz $\mathbf{P}(\textit{Rain} \mid \textit{Cloudy} = \textit{true}) = \langle 0.8, 0.2 \rangle$

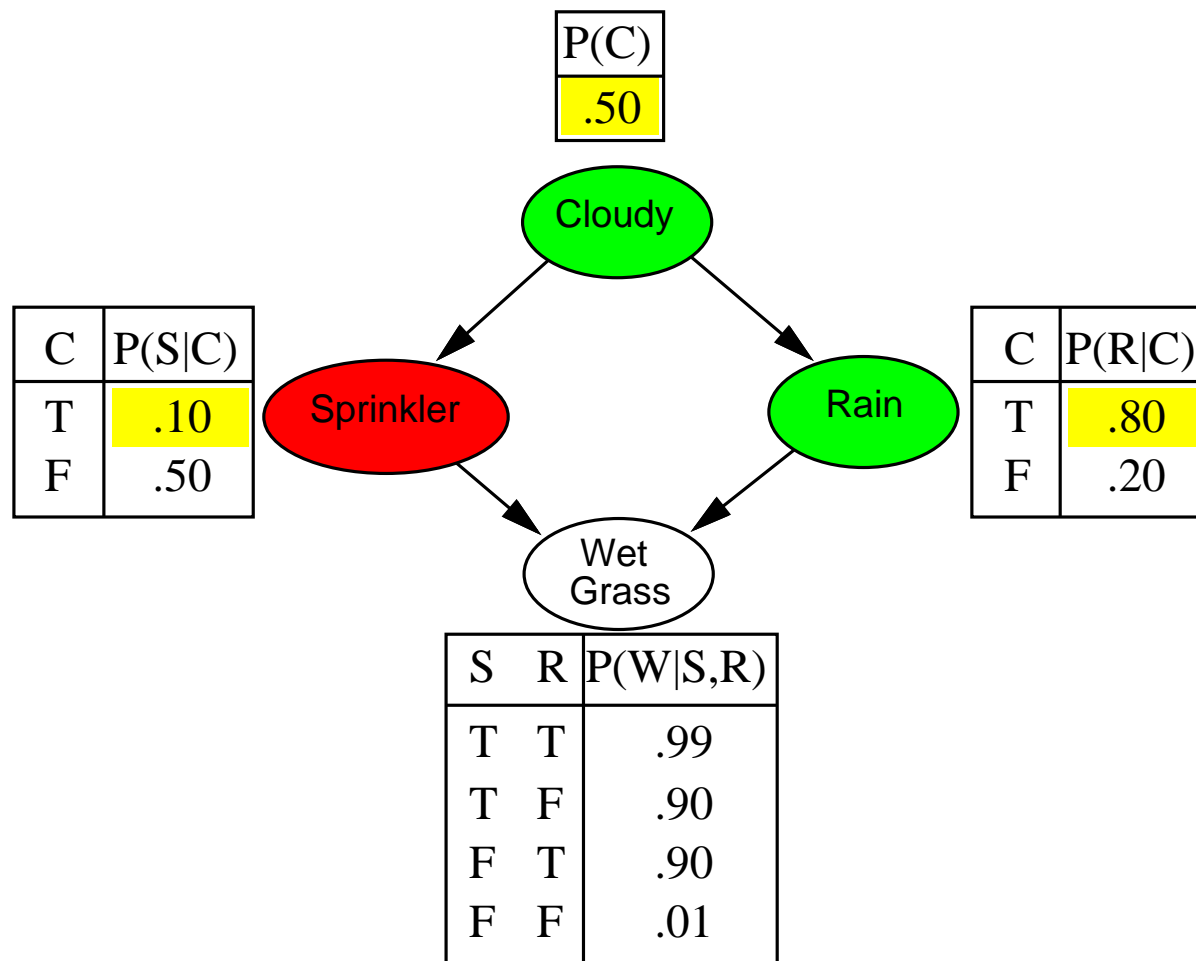
Primjer



Uzorak iz $\mathbf{P}(\textit{Sprinkler} \mid \textit{Cloudy} = \textit{true}) = \langle 0.1, 0.9 \rangle$ neka je *false*

Uzorak iz $\mathbf{P}(\textit{Rain} \mid \textit{Cloudy} = \textit{true}) = \langle 0.8, 0.2 \rangle$

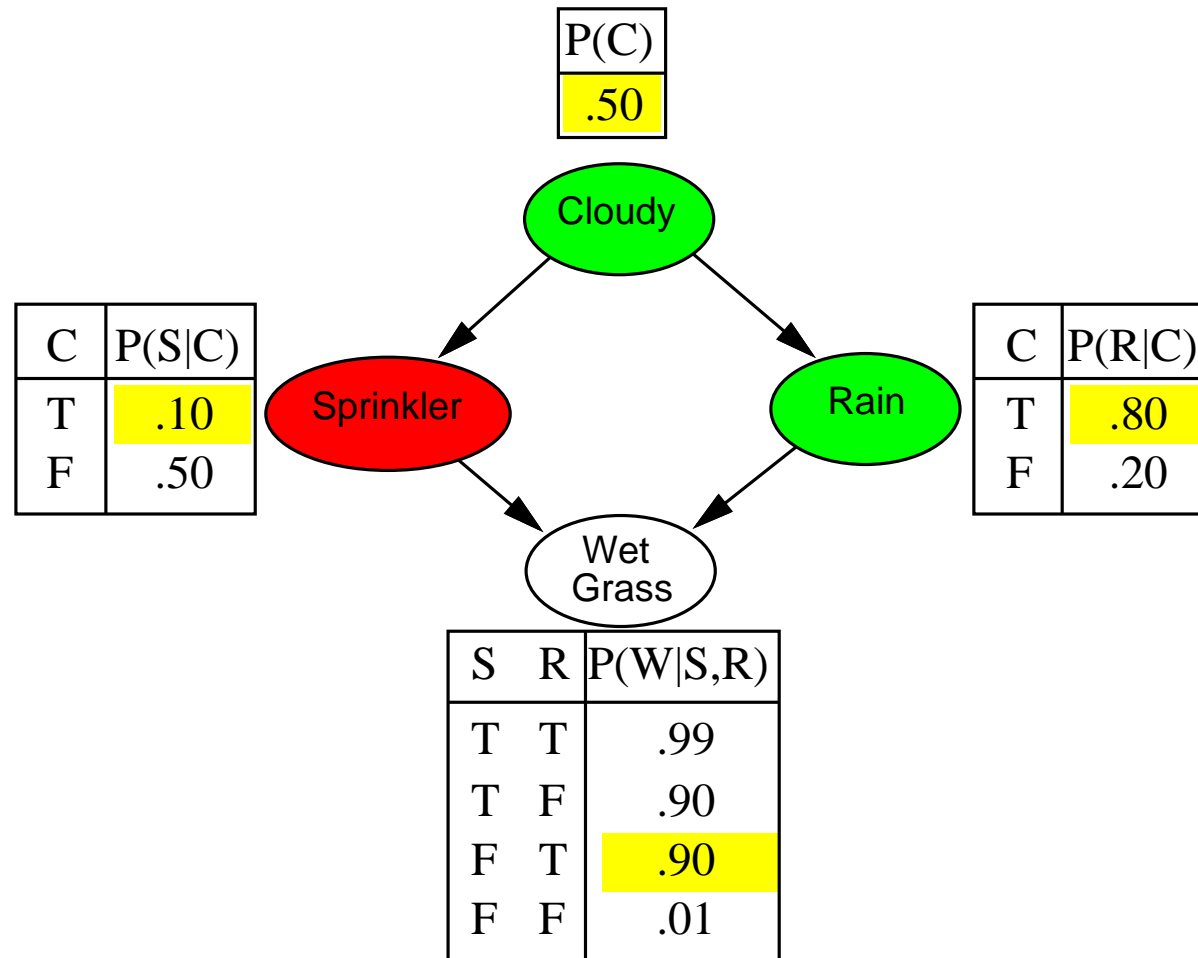
Primjer



Uzorak iz $\mathbf{P}(\textit{Sprinkler} \mid \textit{Cloudy} = \textit{true}) = \langle 0.1, 0.9 \rangle$ neka je *false*

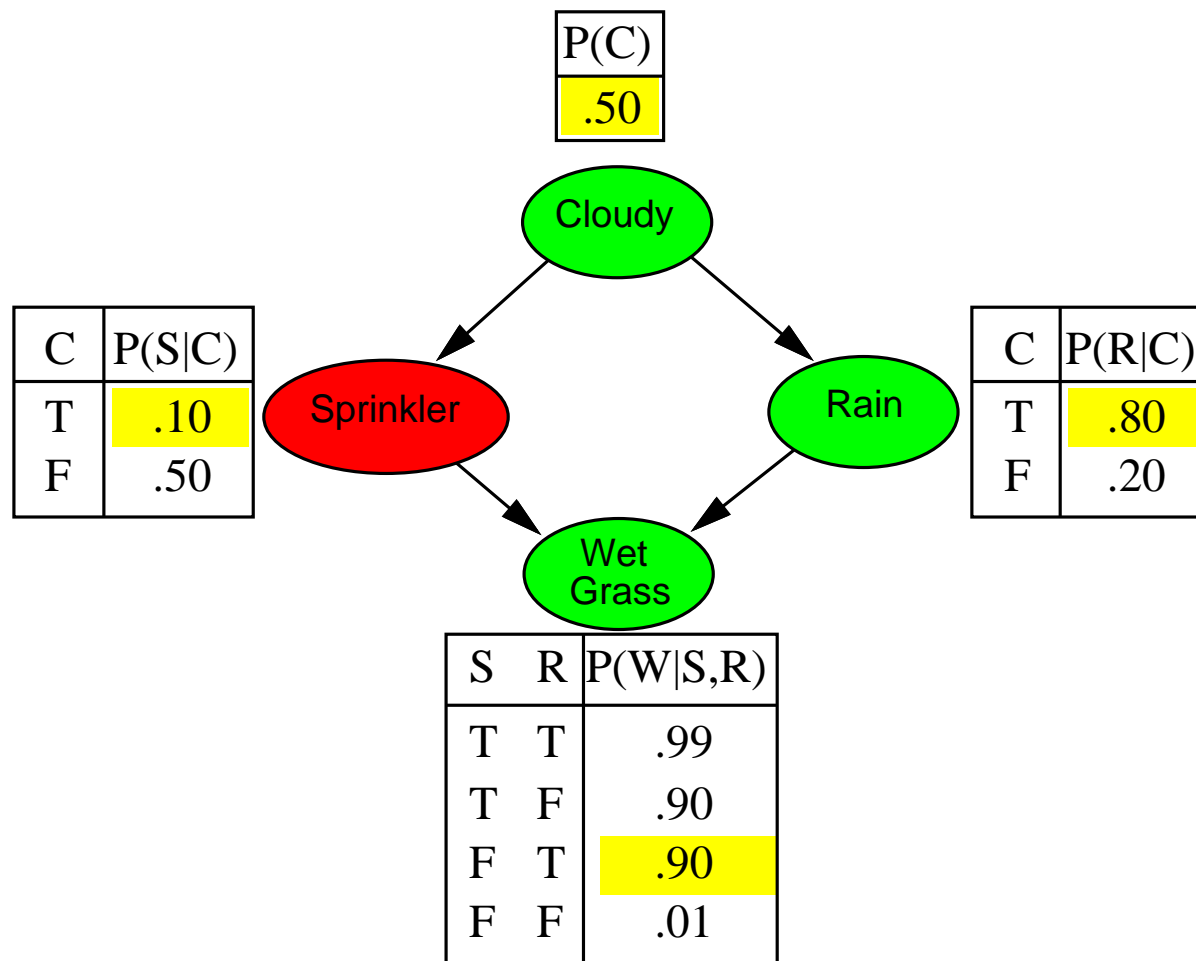
Uzorak iz $\mathbf{P}(\textit{Rain} \mid \textit{Cloudy} = \textit{true}) = \langle 0.8, 0.2 \rangle$ neka je *true*

Primjer



Uzorak iz $\mathbf{P}(WetGrass \mid Sprinkler = false, Rain = true) = \langle 0.9, 0.1 \rangle$

Primjer



Uzorak iz $\mathbf{P}(WetGrass \mid Sprinkler = false, Rain = true) = \langle 0.9, 0.1 \rangle$
neka je *true*

Uzorkovanje iz prazne mreže (nastavak)

Vjerojatnost da PRIORSAMPLE generira odgovarajući događaj

$$S_{PS}(x_1, \dots, x_n) = \prod_{i=1}^n P(x_i \mid \text{parents}(X_i)) = P(x_1, \dots, x_n)$$

tj., stvarna apriori vjerojatnost!

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

Neka je $N_{PS}(x_1, \dots, x_n)$ broj **povoljnih** uzoraka generiranih za događaj x_1, \dots, x_n . Tada imamo

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

To znači da su procjene izvedene iz PRIORSAMPLE **konzistentne**.

Pokrata: $\hat{P}(x_1, \dots, x_n) \approx P(x_1, \dots, x_n)$.

Odbacivanje uzoraka

$\hat{P}(X|e)$ procjene iz uzoraka slažu se s dokazima e :

```
function REJECTION-SAMPLING( $X, e, bn, N$ ) returns an estimate of  $P(X|e)$ 
  local variables:  $N$ , a vector of counts over  $X$ , initially zero
  for  $j = 1$  to  $N$  do
     $x \leftarrow$  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( $N[X]$ )
```

Na primjer, procjena $P(\text{Rain} \mid \text{Sprinkler} = \text{true})$ iz 100 uzoraka
27 uzoraka ima $\text{Sprinkler} = \text{true}$
od čega, 8 ima $\text{Rain} = \text{true}$ i 19 ima $\text{Rain} = \text{false}$.

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

Slično osnovnim empirijskim procedurama procjene u realnom svijetu!

Analiza odbacivanja uzoraka

Provjera korektnosti (**konzistentnosti**) uzorkovanja:

$$\begin{aligned}\hat{\mathbf{P}}(X|\mathbf{e}) &= \alpha \mathbf{N}_{PS}(X, \mathbf{e}) && \text{(definicija algoritma)} \\ &= \mathbf{N}_{PS}(X, \mathbf{e}) / N_{PS}(\mathbf{e}) && \text{(normalizirano s } N_{PS}(\mathbf{e})) \\ &\approx \mathbf{P}(X, \mathbf{e}) / P(\mathbf{e}) && \text{(svojstvo PRIORSAMPLE)} \\ &= \mathbf{P}(X|\mathbf{e}) && \text{(definicija uvjetne vjerojatnosti)}\end{aligned}$$

Odbacivanje uzoraka vraća konzistentnu a posteriori procjenu!

Problem: nevjerojatno skupo ako $P(\mathbf{e})$ je malen

$P(\mathbf{e})$ pada eksponencijalno s brojem dokaznih varijabli!

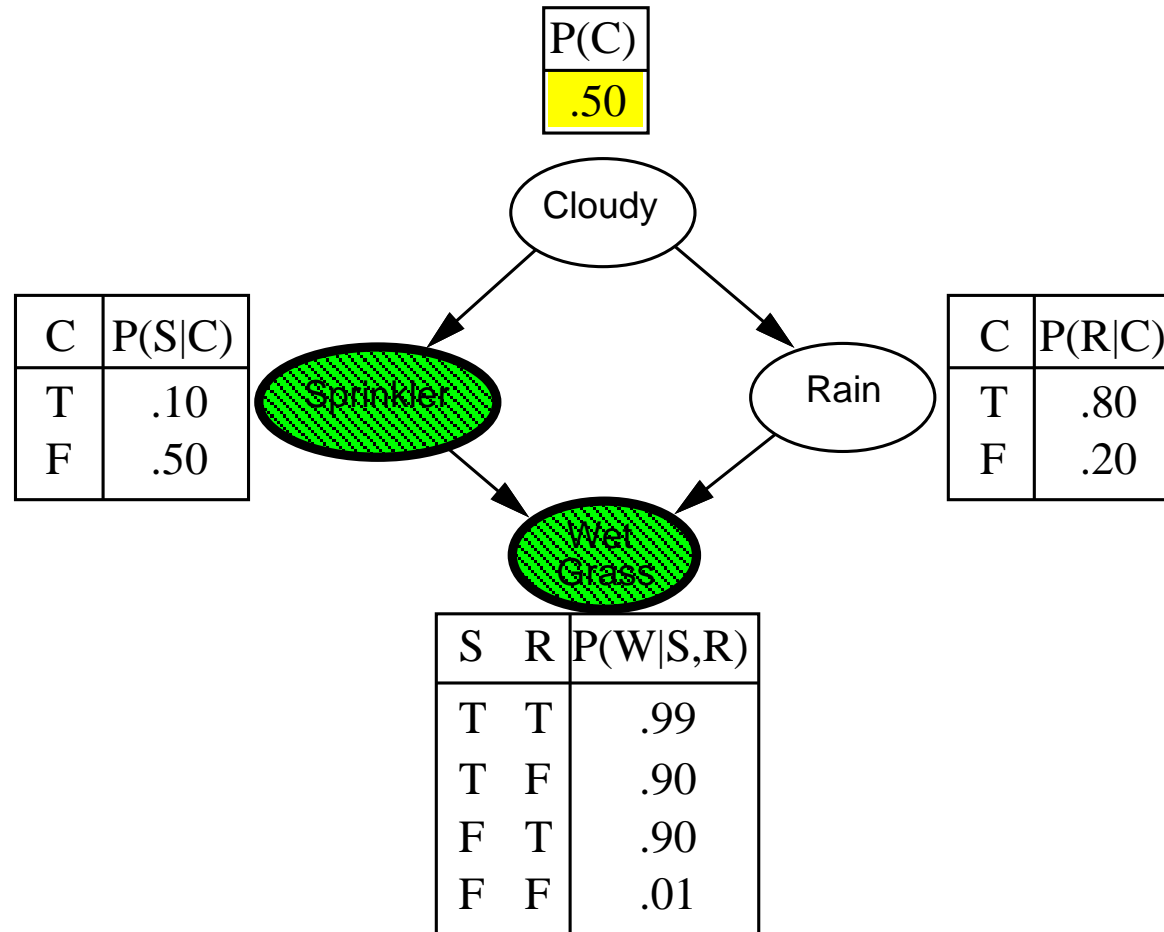
Težinska vjerodostojnost

Ideja: fiksiraj dokazne varijable, uzorkuj samo iz ne-dokaznih varijabli, stavi težinu na svaki uzorak prema vjerodostojnosti slaganja s dokazima

```
function LIKELIHOOD-WEIGHTING( $X, \mathbf{e}, bn, N$ ) returns an estimate of  $P(X|\mathbf{e})$   
  local variables:  $\mathbf{W}$ , a vector of weighted counts over  $X$ , initially zero  
  for  $j = 1$  to  $N$  do  
     $\mathbf{x}, w \leftarrow$  WEIGHTED-SAMPLE( $bn$ )  
     $\mathbf{W}[x] \leftarrow \mathbf{W}[x] + w$  where  $x$  is the value of  $X$  in  $\mathbf{x}$   
  return NORMALIZE( $\mathbf{W}[X]$ )
```

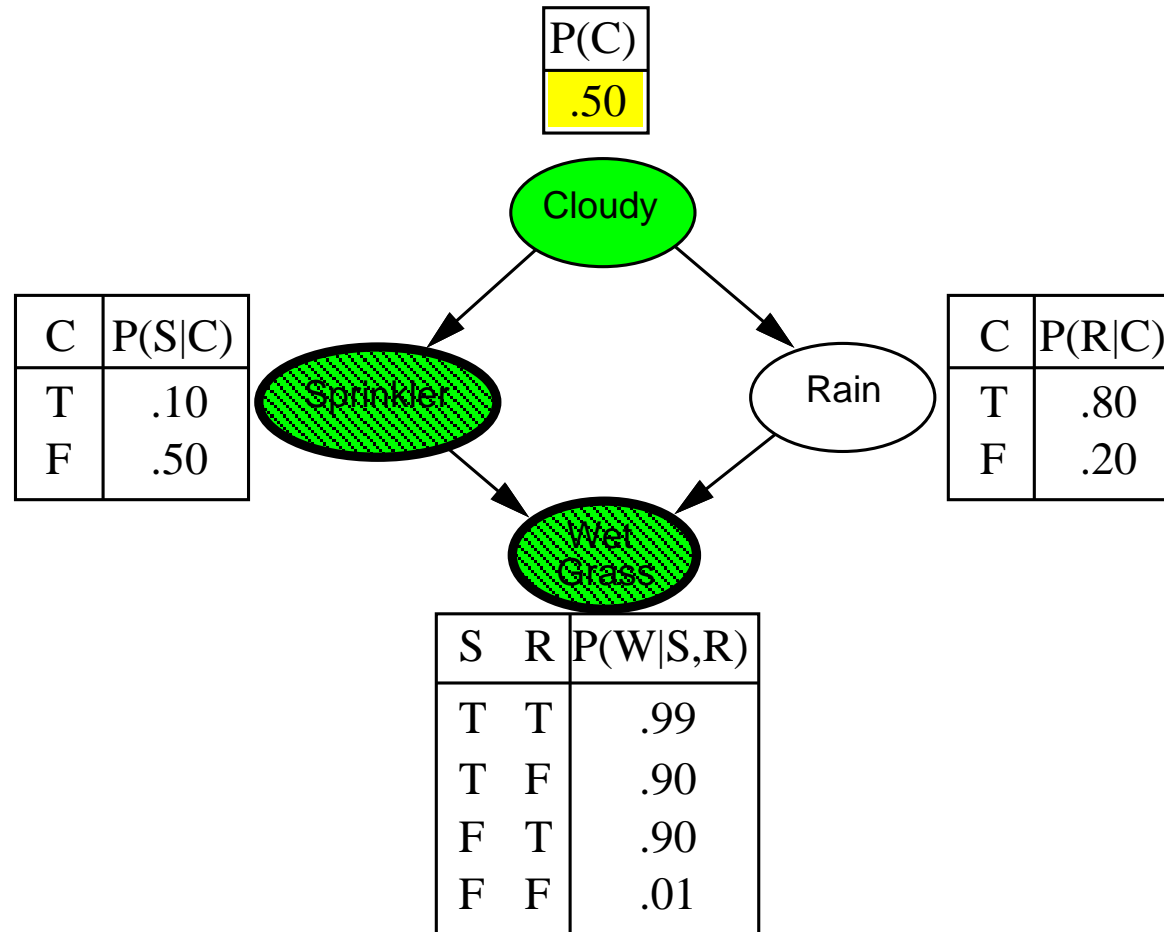
```
function WEIGHTED-SAMPLE( $bn, \mathbf{e}$ ) returns an event and a weight  
   $\mathbf{x} \leftarrow$  an event with  $n$  elements;  $w \leftarrow 1$   
  for  $i = 1$  to  $n$  do  
    if  $X_i$  has a value  $x_i$  in  $\mathbf{e}$   
      then  $w \leftarrow w \times P(X_i = x_i \mid \text{parents}(X_i))$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

Primjer težinske vjerodostojnosti



$w = 1.0$ (početak), *Cloudy* nije dokazna varijabla
 Uzorak iz $\mathbf{P}(Cloudy) = \langle 0.5, 0.5 \rangle$

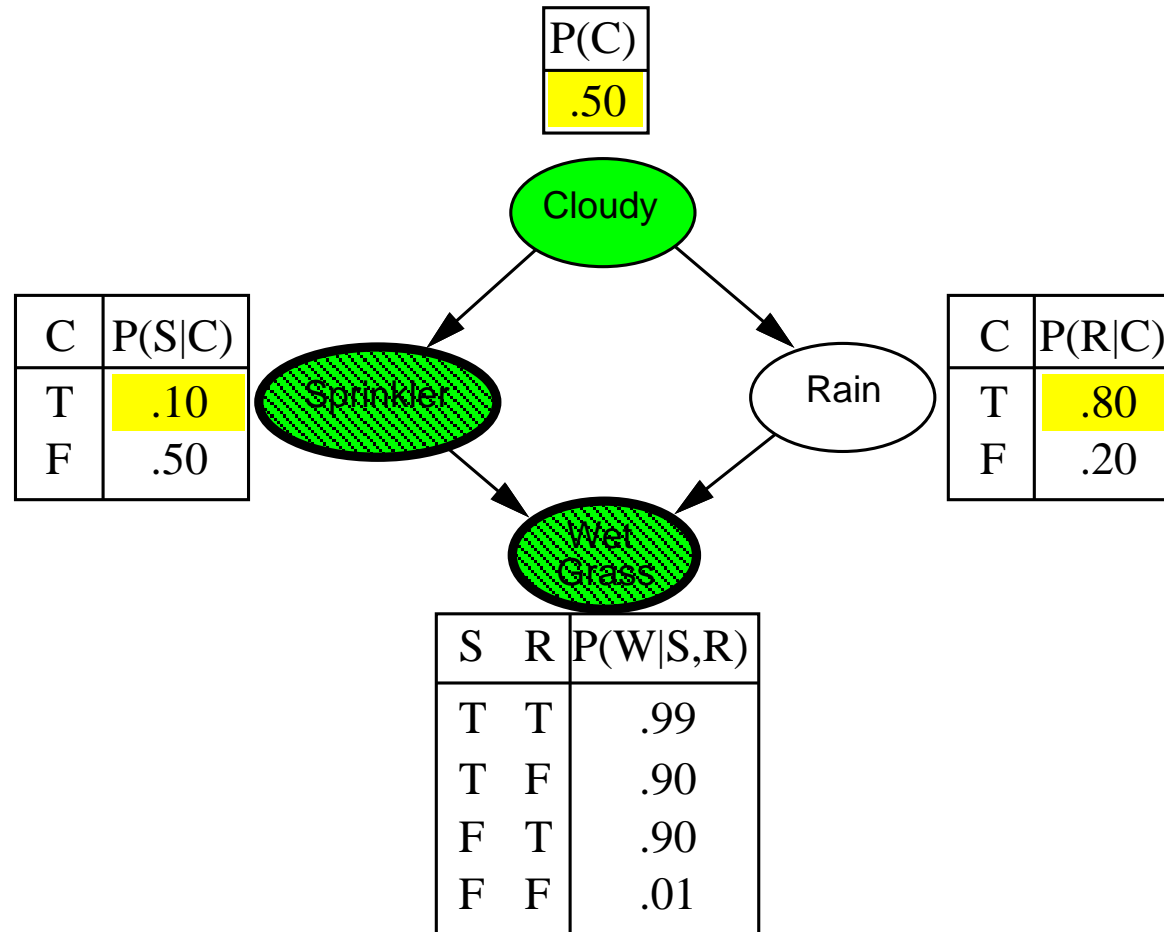
Primjer težinske vjerodostojnosti



$w = 1.0,$

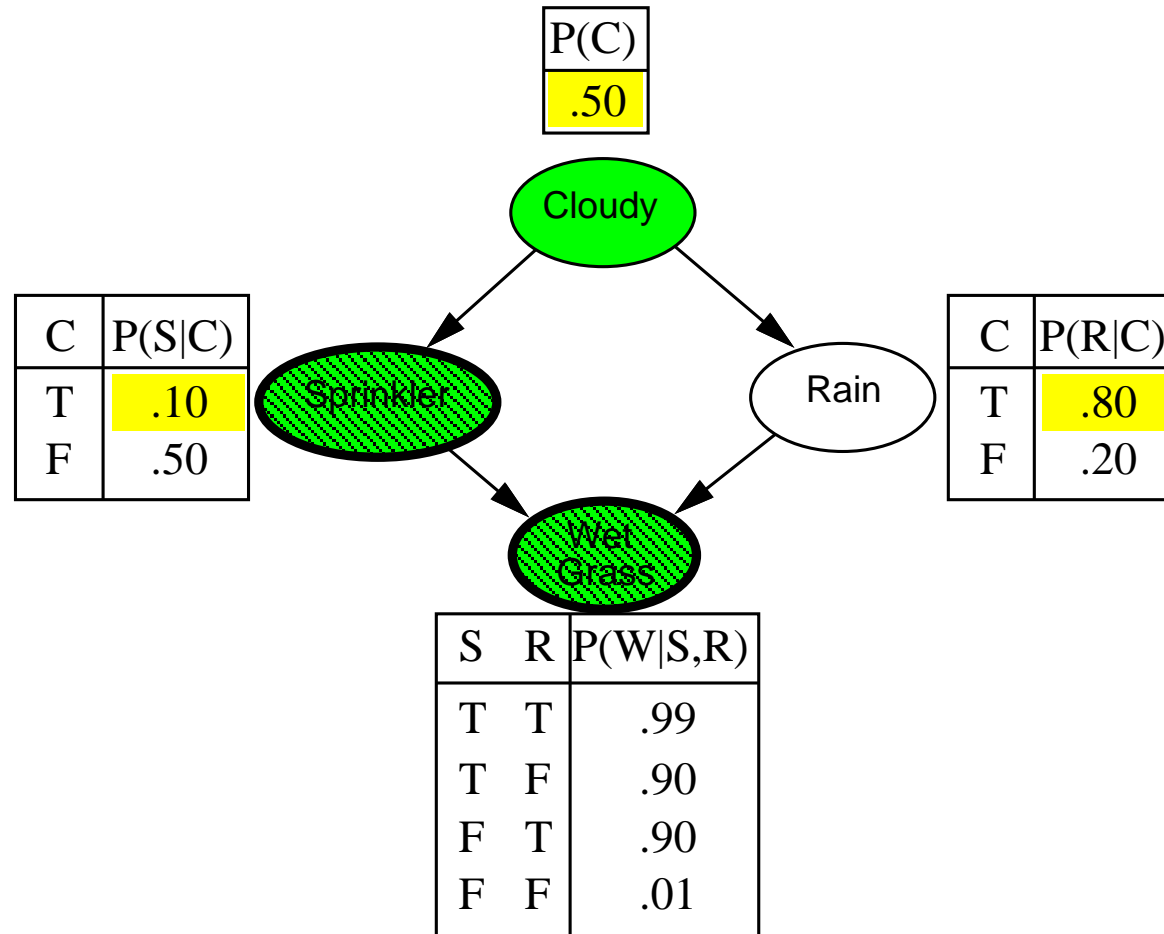
Uzorak iz $\mathbf{P}(Cloudy) = \langle 0.5, 0.5 \rangle,$ neka je *true*.

Primjer težinske vjerodostojnosti



$w = 1.0$, *Sprinkler = true* je dokaz
 modificiraj težinu prema dokazu

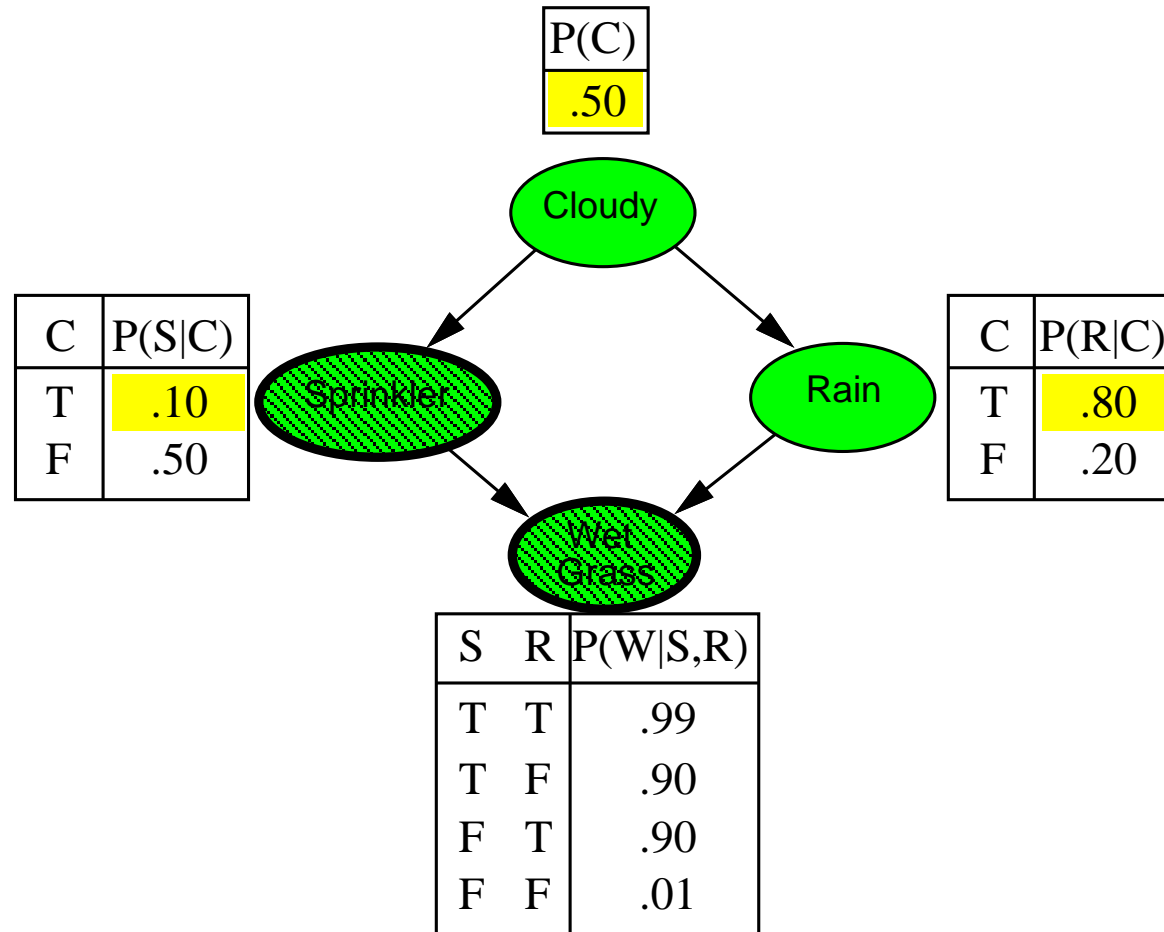
Primjer težinske vjerodostojnosti



$w = 1.0 \times 0.1$, *Rain* nije dokazna varijabla

Uzorak iz $\mathbf{P}(Rain \mid Cloudy = true) = \langle 0.8, 0.2 \rangle$

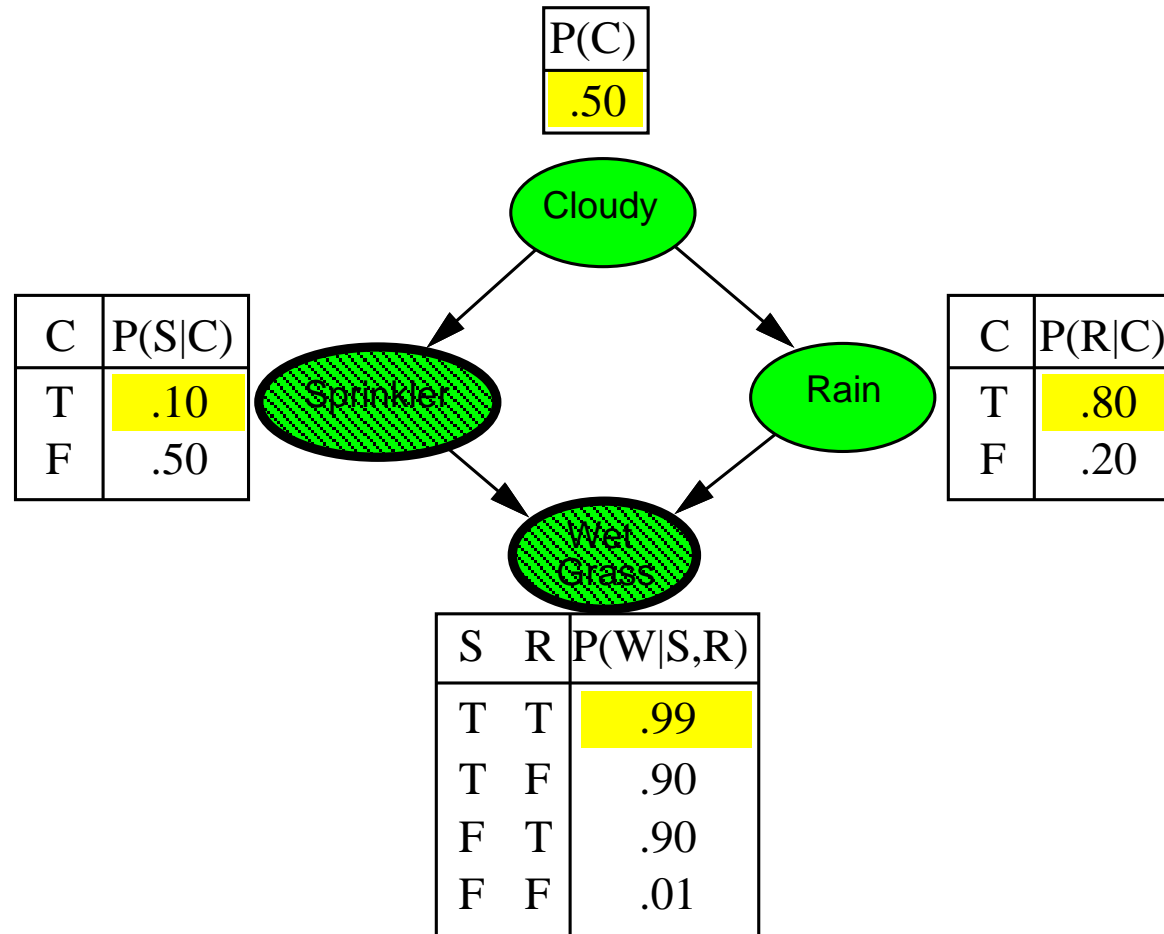
Primjer težinske vjerodostojnosti



$$w = 1.0 \times 0.1,$$

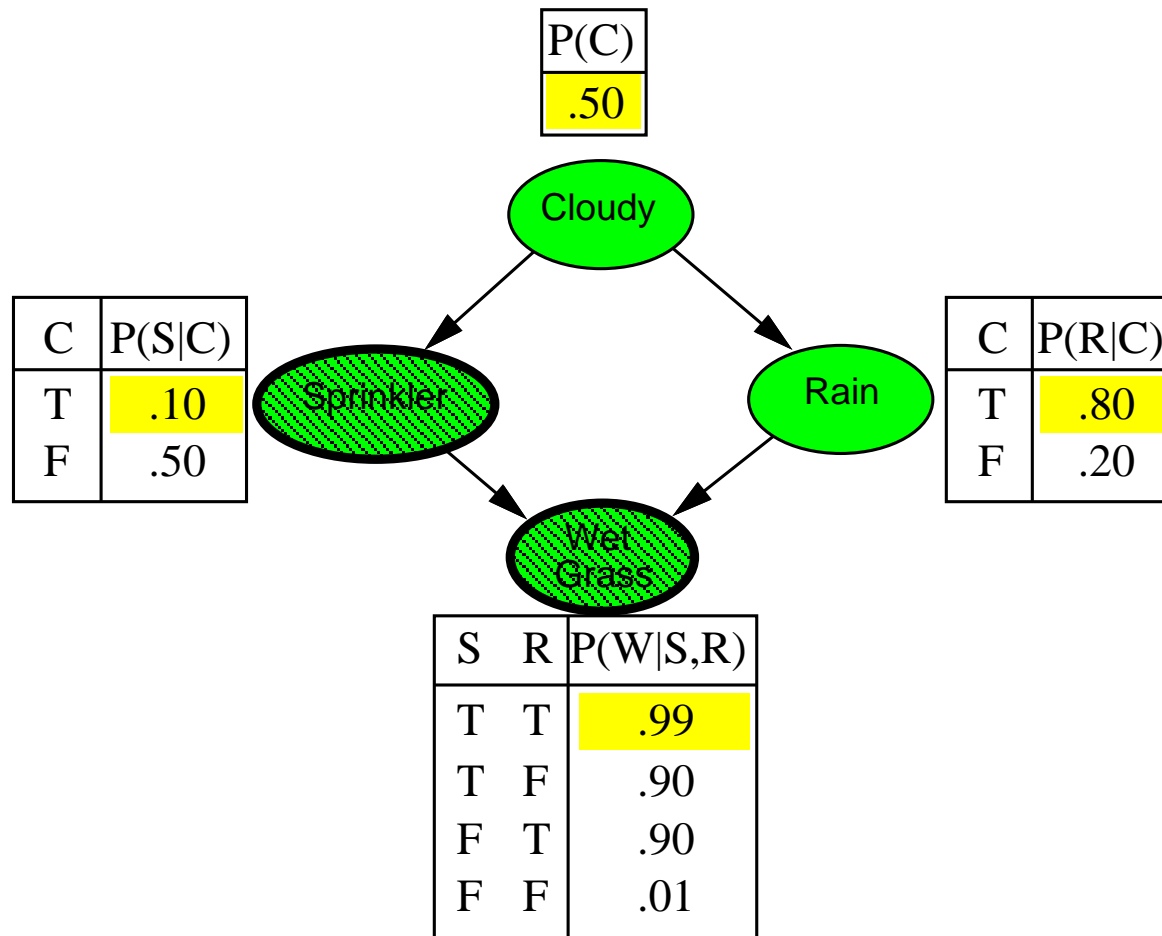
Uzorak iz $\mathbf{P}(Rain \mid Cloudy = true) = \langle 0.8, 0.2 \rangle$, neka je *true*

Primjer težinske vjerodostojnosti



$w = 1.0 \times 0.1$ *WetGrass = true* je dokaz
 modificiraj težinu prema dokazu

Primjer težinske vjerodostojnosti




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

Analiza težinske vjerodostojnosti

Uzoračka vjerojatnost za WEIGHTEDSAMPLE je

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



gdje \mathbf{Z} označava **nedokazne** varijable, uključivo i upit X .

Uočiti: uzima u obzir samo dokaze u **pretcima** (bez djece)

⇒ negdje “**između**” apriorne i aposteriorne distribucije!

Bez težina — procjene **nisu** konzistentne!

Moraju dobiti “**težinu**” za dokaze — prema danim roditeljima.

Analiza težinske vjerodostojnosti (nastavak)

Težina za dani uzorak \mathbf{z}, \mathbf{e} je

$$w(\mathbf{z}, \mathbf{e}) = \prod_{i=1}^m P(e_i \mid \text{parents}(E_i)).$$

Težinska uzoračka vjerojatnost

$$\begin{aligned} S_{WS}(\mathbf{z}, \mathbf{e})w(\mathbf{z}, \mathbf{e}) &= \prod_{i=1}^l P(z_i \mid \text{parents}(Z_i)) \prod_{i=1}^m P(e_i \mid \text{parents}(E_i)) \\ &= P(\mathbf{z}, \mathbf{e}) \quad (\text{std. globalna semantika mreže}). \end{aligned}$$

Težinska vjerodostojnost vraća **konzistentne** procjene, jer \mathbf{Z} i \mathbf{e} pokrivaju **sve varijable** u mreži.

Performansa LW ipak **pada** s mnogo dokaznih varijabli, jer samo **nekoliko** uzoraka ima skoro cijelu ukupno težinu.

Aproksimativno zaključivanje korištenjem MCMC

“Stanje” mreže = trenutne dodijeljene vrijednosti za **sve** varijable.

Novo stanje generira se uzorkovanjem **jedne** varijable za dani Markovljev pokrivač. Na primjer, u petlji, uzorkuj redom **sve**, **osim** dokaza (fiksni)!

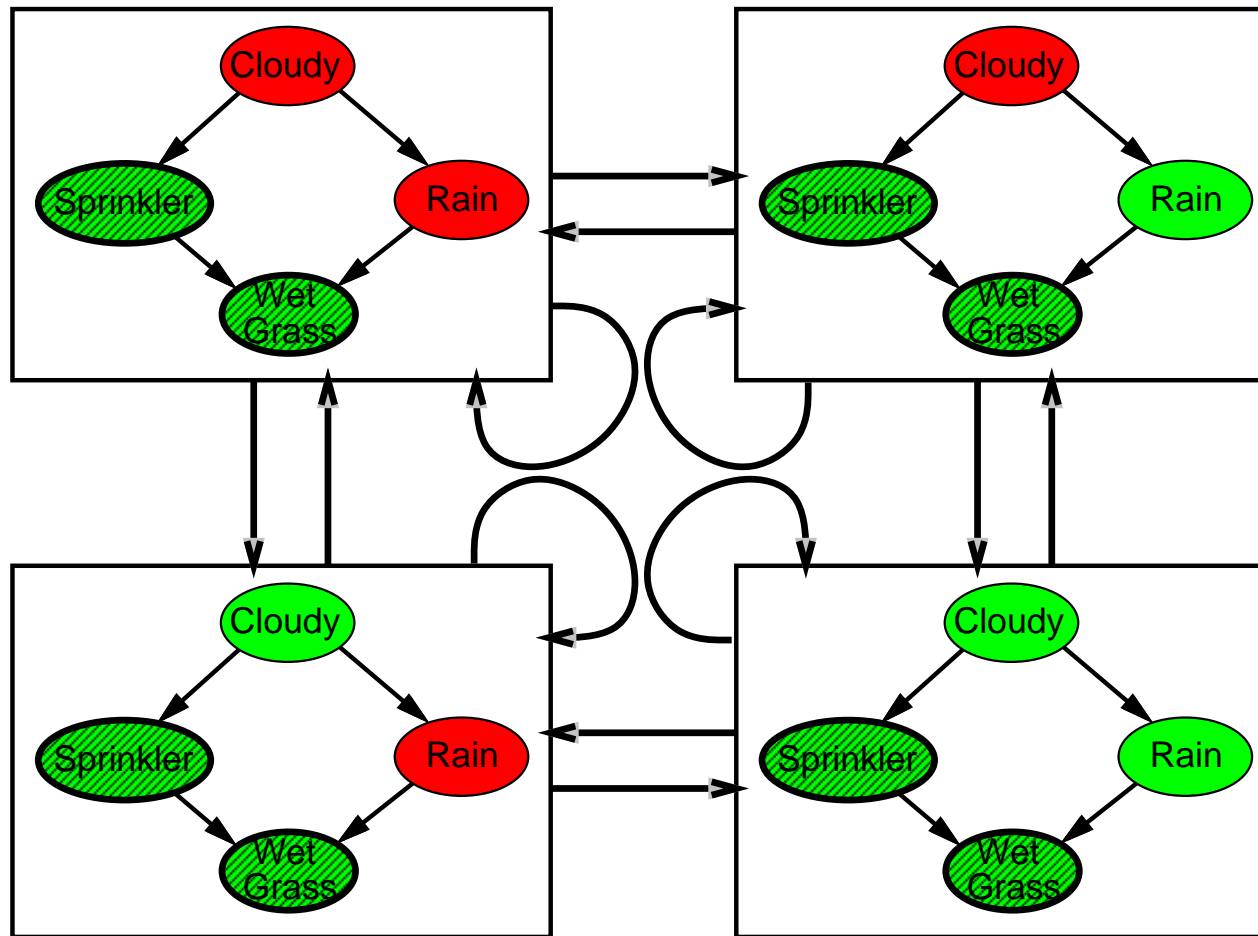
```
function MCMC-ASK( $X, \mathbf{e}, bn, N$ ) returns an estimate of  $P(X|\mathbf{e})$ 
  local variables:  $\mathbf{N}[X]$ , a vector of counts over  $X$ , initially zero
                   $\mathbf{Z}$ , the nonevidence variables in  $bn$ 
                   $\mathbf{x}$ , the current state of the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

  initialize  $\mathbf{x}$  with random values for the variables in  $\mathbf{Y}$ 
  for  $j = 1$  to  $N$  do
    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  $\mathbf{x}$ 
       $\mathbf{N}[x] \leftarrow \mathbf{N}[x] + 1$  where  $x$  is the value of  $X$  in  $\mathbf{x}$ 
  return NORMALIZE( $\mathbf{N}[X]$ )
```

Napomena: Može se i **slučajno** izabrati varijabla koja se uzorkuje.

Markovljev lanac

Sprinkler = true, WetGrass = true, ima četiri stanja:



Putujte neko vrijeme, uzmite prosjek onog što vidite!

MCMC primjer (nastavak)

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

Ponovljeno uzorkuj *Cloudy* ili *Rain* za njihov Markovljev pokrivač. Izbroji koliko puta je *Rain* istinito ili lažno u uzorcima.

Na primjer, u 100 stanja

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

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

Teorem: ulančani pristup **stacionarnoj distribuciji**:


uz dugotrajno ponavljanje, proporcija vremena u svakom stanju proporcionalna je a posteriori vjerojatnosti

Markovljev pokrivač — ponavljanje

Markovljev pokrivač od X — oznaka $MB(X)$, (označen sivo na slici)
= njegovi roditelji + djeca + roditelji djece.

Svaki čvor X je **uvjetno nezavisan** od **svih** ostalih čvorova u mreži, ako su **dane** (kao uvjet/dokaz) vrijednosti varijabli iz $MB(X)$.

Oznaka za dane vrijednosti tih varijabli je $mb(X)$.




Uzorkovanje Markovljevog pokrivača

Markovljev pokrivač za *Cloudy* je

Sprinkler i *Rain*

Markovljev pokrivač za *Rain* je

Cloudy, *Sprinkler* i *WetGrass*



Za Markovljeve pokrivače vjerojatnosti se računaju ovako:

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

Dakle, za **promjenu** vrijednosti neke varijable X_i , broj množenja u gornjoj formuli je jednak broju **djece** od X_i .

Glavni problemi u računanju:

- 1) Teško je reći da li je došlo do konvergencije
- 2) Može biti rasipno ako je Markovljev pokrivač velik:

$P(X_i | mb(X_i))$ se neće jako promijeniti (zakon velikih brojeva)

Sažetak

Egzaktno zaključivanje eliminacijom varijabli:

- polinomno vrijeme na poli-stablama, NP-teško na općim grafovima
- prostor = vrijeme, vrlo osjetljivo na topologiju

Aproksimativno zaključivanje korištenjem LW, MCMC:

- LW je loše ako ima mnogo (engl. downstream) dokaza
- LW, MCMC općenito neosjetljivi na topologiju
- Konvergencija može biti vrlo spora s vjerojatnostima blizu 1 ili 0
- Rade za proizvoljnu kombinaciju diskretnih i neprekidnih varijabli