

Bedingte Unabhängigkeit, Definition

Zwei Ereignisse a, b sind **bedingt unabhängig**, gegeben c , gdw.:

$$P(a, b \mid c) = P(a \mid c) P(b \mid c)$$

Zwei Variable A, B sind **bedingt unabhängig**, gegeben C , gdw.:

$$\mathbf{P}(A, B \mid C) = \mathbf{P}(A \mid C) \mathbf{P}(B \mid C)$$

Damit äquivalent sind die Formulierungen

$$\mathbf{P}(A \mid B, C) = \mathbf{P}(A \mid C) \text{ und } \mathbf{P}(B \mid A, C) = \mathbf{P}(B \mid C)$$

Bayes-Netze

... repräsentieren effizient gemeinsame W' Verteilungen und (bzw. unter Verwendung von) Aussagen zur bedingten Unabhängigkeit von Zufallsvariablen

Ein **Bayes-Netz** ist ein gerichteter azyklischer Graph, wobei

- Knoten entsprechen Zufallsvariablen (diskret, kontinuierlich)
- Kanten entsprechen *direkten* Abhängigkeiten zwischen Variablen; führt eine Kante von X nach Y , so heißt X ein Elternknoten von Y , die Menge aller Elternknoten ist $Parents(Y)$
- Jeder Knoten X trägt als Anschrift $\mathbf{P}(X | Parents(X))$

Interpretation: Sei $P(x_1, \dots, x_n) := P(X_1=x_1, \dots, X_n=x_n)$. Dann gilt:

$$P(x_1, \dots, x_n) = \prod_i P(x_i | Parents(X_i))$$

vgl. „naives“ Bayessches Modell

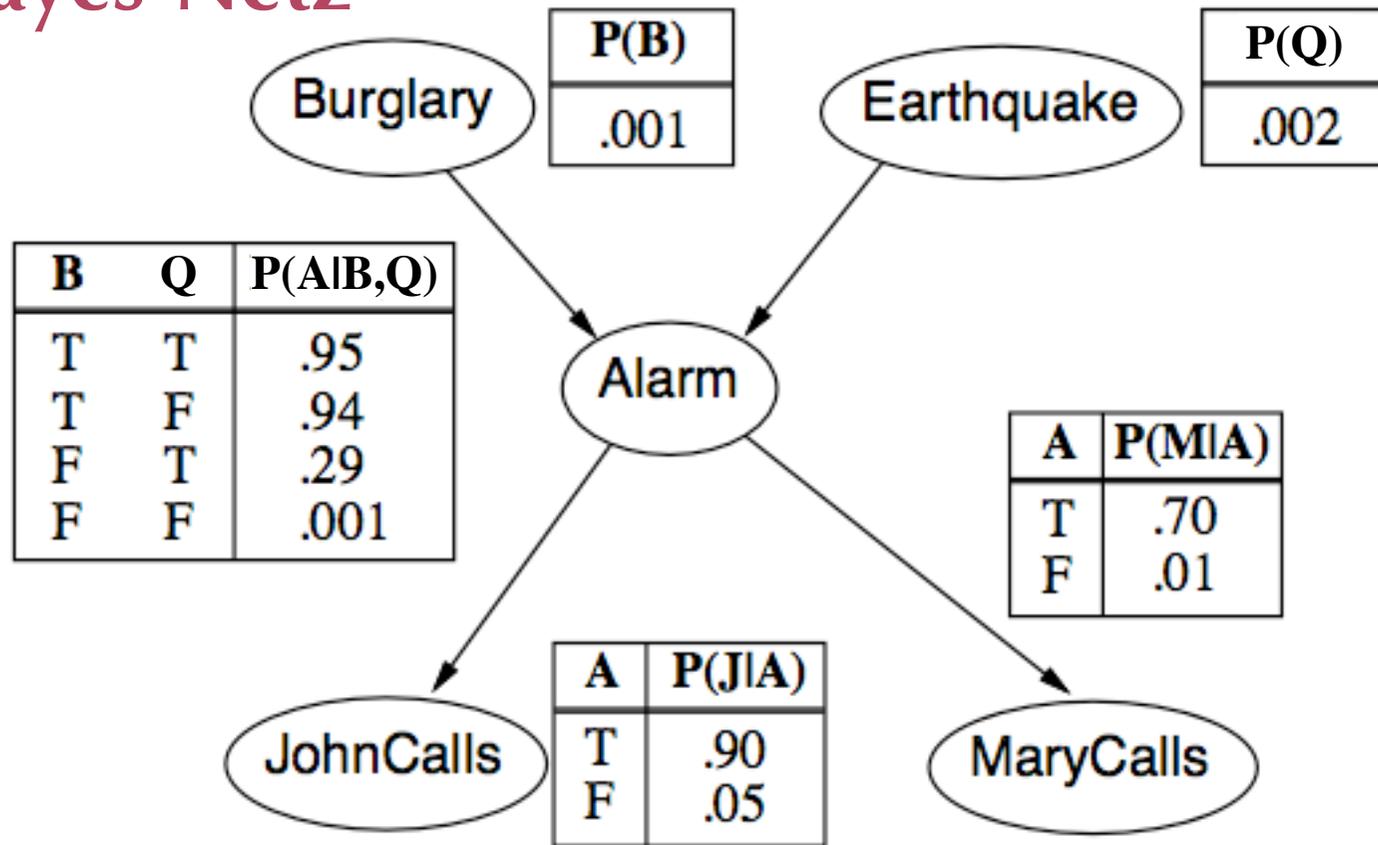
Beispiel für Kalifornische Wissenschaftende

- Hausalarm geht an bei Einbruch und manchmal bei Erdbeben
- Nachbarn John und Mary sollen im Büro anrufen, wenn sie tagsüber Alarm hören
- John ruft im Büro an, aber nicht Mary. Wie wahrscheinlich ist es, dass gerade eingebrochen wird?

Modellierung

- Variablen *Burglary*, *Earthquake*, *Alarm*, *JohnCalls*, *MaryCalls*
- Gesucht also $\mathbf{P}(B \mid j, -m)$
- *Alarm* hängt direkt ab von *Burglary*, *Earthquake*; *JohnCalls* und *MaryCalls* hängen direkt je nur ab von *Alarm*
- W'keiten wie nachfolgend angegeben

Beispiel-Bayes-Netz



Beispiel

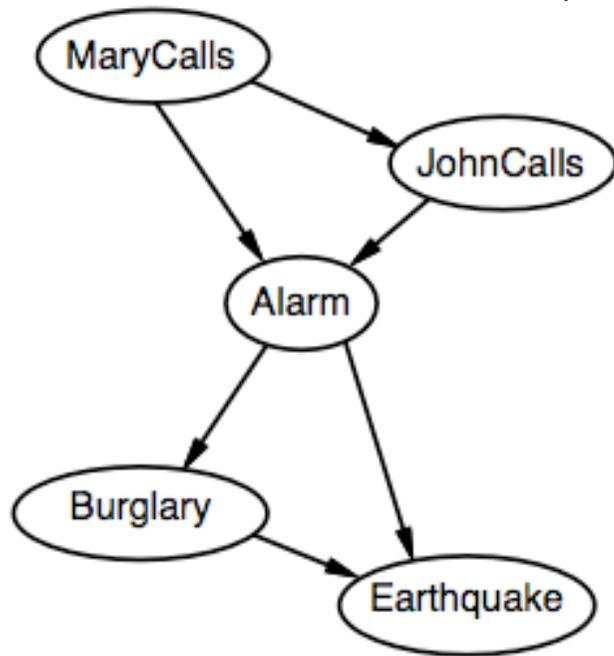
$$\begin{aligned}
 &P(j, -m, a, b, -q) \\
 &= P(j|a)P(-m|a)P(a|b, -q)P(b)P(-q) \\
 &= 0.9 \times 0.3 \times 0.94 \times 0.001 \times 0.998 \\
 &= 0.0002532924
 \end{aligned}$$

Doch eigentlich suchen wir ja $P(B | j, -m)$! (Fortsetzung folgt)

Konstruktion eines Bayes-Netzes

1. Wähle eine vollständige Ordnung X_1, \dots, X_n der Variablen
2. **for** $i=1$ **to** n
 füge X_i zum Netz hinzu;
 wähle X_i s direkte Vorgänger aus X_1, \dots, X_{i-1} so, dass

$$\mathbf{P}(X_i | Parents(X_i)) = \mathbf{P}(X_i | X_1, \dots, X_{i-1})$$



Bei ungeschickter Variablenordnung entstehen unnötig komplexe Netze!

Beispiel: Reihenfolge M, J, A, B, Q

$\mathbf{P}(J|M) \neq \mathbf{P}(J)$ ↪ $M \rightarrow J$

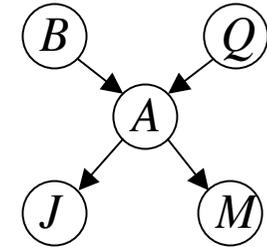
$\mathbf{P}(A|J,M) \neq \mathbf{P}(A|J)$ und $\mathbf{P}(A|J,M) \neq \mathbf{P}(A|M)$

↪ $M \rightarrow A, J \rightarrow A$

$\mathbf{P}(B|A,J,M) = \mathbf{P}(B|A)$ ↪ nicht $M \rightarrow B$ $J \rightarrow B$

...

Inferenz durch Ausrechnen



$$\mathbf{P}(B \mid j, -m)$$

$$= \mathbf{P}(B, j, -m) / P(j, -m)$$

$$= \alpha \mathbf{P}(B, j, -m)$$

$$= \alpha \sum_q \sum_a [\mathbf{P}(B, Q=q, A=a, j, -m)]$$

Produktregel

Normalisierung mit Konstante

Kolmogorow 3

Weiter mit $B=true$ (anderer Fall entsprechend)

$$= \alpha \sum_q \sum_a P(b)P(Q=q)P(A=a|b,q)P(j|a)P(-m|a) \text{ bed. Unabhängigkeit}$$

$$= \alpha P(b) \sum_q P(Q=q) [\sum_a P(A=a|b,q)P(j|a)P(-m|a)]$$

Durch Einsetzen der W'keiten gemäß Bayes-Netz:

$$\approx \alpha \langle 0.0002568, 0.0497979 \rangle$$

$$\alpha \approx 20$$

$$\approx \langle 0.00513, 0.99487 \rangle$$

→ Die W'keit für einen Einbruch ist von a priori 0,1% auf 0,513% gestiegen

Inferenz durch vollständiges Ausrechnen

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 $\{X\} \cup \mathbf{E} \cup \mathbf{Y}$

versteckte Variablen

$Q(X) \leftarrow$ 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 $P(y | Pa(Y)) \times$ ENUMERATE-ALL(REST($vars$), e)

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

 where e_y is e extended with $Y = y$

Parents, direkte Vorgänger von Y

Eigenschaften des vollständigen Ausrechnens

- ☺ Terminiert sicher mit korrektem Ergebnis
- ☺ Speicherbedarf: $O(n)$ („Tiefentraversierung“)
- ☹ Zeitbedarf: $O(m^n)$ für diskrete ZV max. m Werte (boolesche ZV: $m=2$)
- ☹ **Satz:** Exakte Inferenz in Bayes-Netzen ist NP-vollständig
Beweisidee: Abbildung propositionaler Inferenz in Bayes-Netz-Inferenz

Optimierungsmöglichkeiten (s. nächste Folien)

- *caching* von mehrfach auftauchenden Teilergebnissen
- Variablenelimination
- Überführung von Bayes-Netzen in Polybäume
- ↳ **Satz:** Inferenz in Bayes-Polybäumen ist linear in Speicher- und Zeitbedarf (hier ohne Beweis)

Wiederverwendung von Teilergebnissen

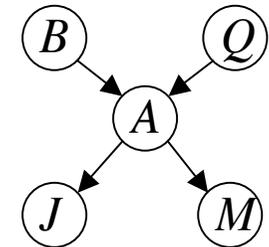
wir hatten vorher:

$$\mathbf{P}(B \mid j, -m)$$

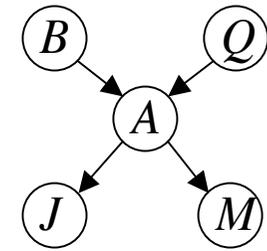
$$= \alpha P(b) \sum_q P(Q=q) \left[\sum_a P(A=a \mid b, q) P(j \mid a) P(-m \mid a) \right]$$

Die Terme $P(j \mid a) P(-m \mid a)$ (für alle Werte von a) tauchen in mehreren Summanden auf!

- ➔ Stell die Berechnung so um, dass die Verteilung „von innen nach außen“ berechnet wird
(Verfahren: Russell/Norvig S. 507ff)



Variablenelimination



Beispielanfrage: $\mathbf{P}(J \mid b)$

(wie wahrscheinlich ruft John an, wenn ein Einbruch vorliegt?)

$$\mathbf{P}(J \mid b) = \alpha P(b) \sum_q P(Q=q) \left[\sum_a P(A=a \mid b, q) P(J \mid a) \sum_m P(m \mid a) \right]$$

Beobachtung: $\sum_m P(m \mid a)$ ist immer =1!

M hängt nur ab von A , für das immer alle Werte untersucht werden:
 M ist **irrelevant** für die Anfrage: M -Terme können wegfallen

Satz:

Variable $Y \neq X$ ist irrelevant für die Anfrage $\mathbf{P}(X \mid \mathbf{E})$, falls
 $M \notin \text{Vorgänger}(\{X\} \cup \mathbf{E})$ (*Vorgänger* ist trans. Hülle von *Parents*)
(Beweis: Nach Konstruktion eines Bayes-Netzes)

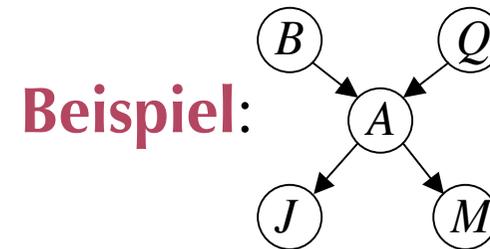
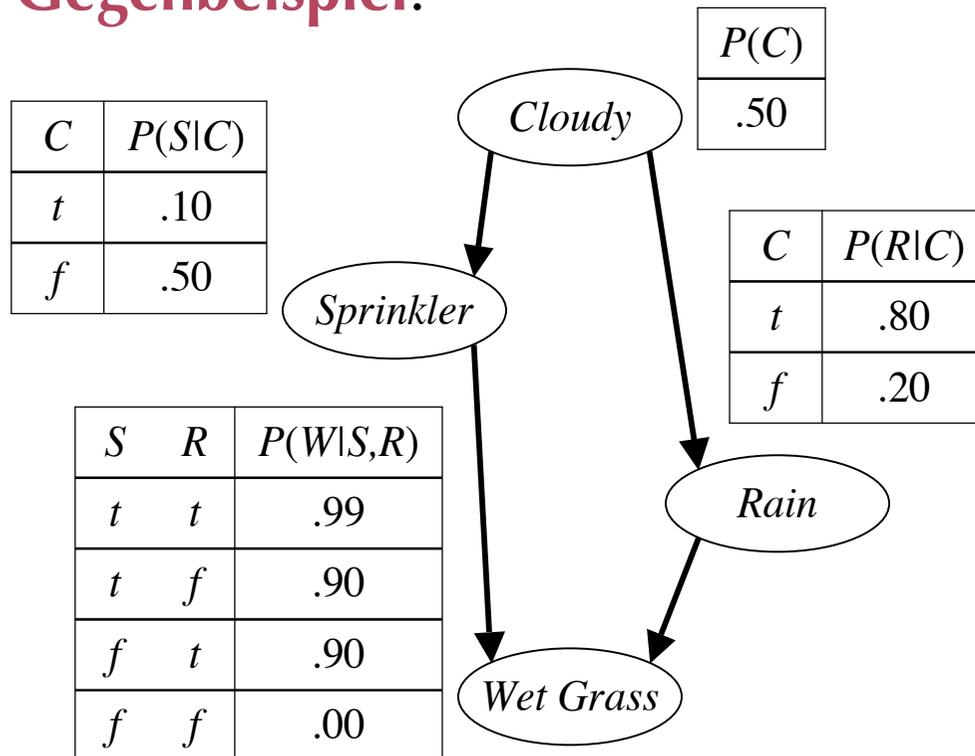
Im **Beispiel:** $X=J$, $\mathbf{E}=\{B\}$, $\text{Vorgänger}(\{X\} \cup \mathbf{E})=\{A, Q\}$

→ M ist irrelevant

Netze zu Polybäumen

Polybaum: Graph, in dem es zwischen zwei Knoten max. 1 Pfad gibt.

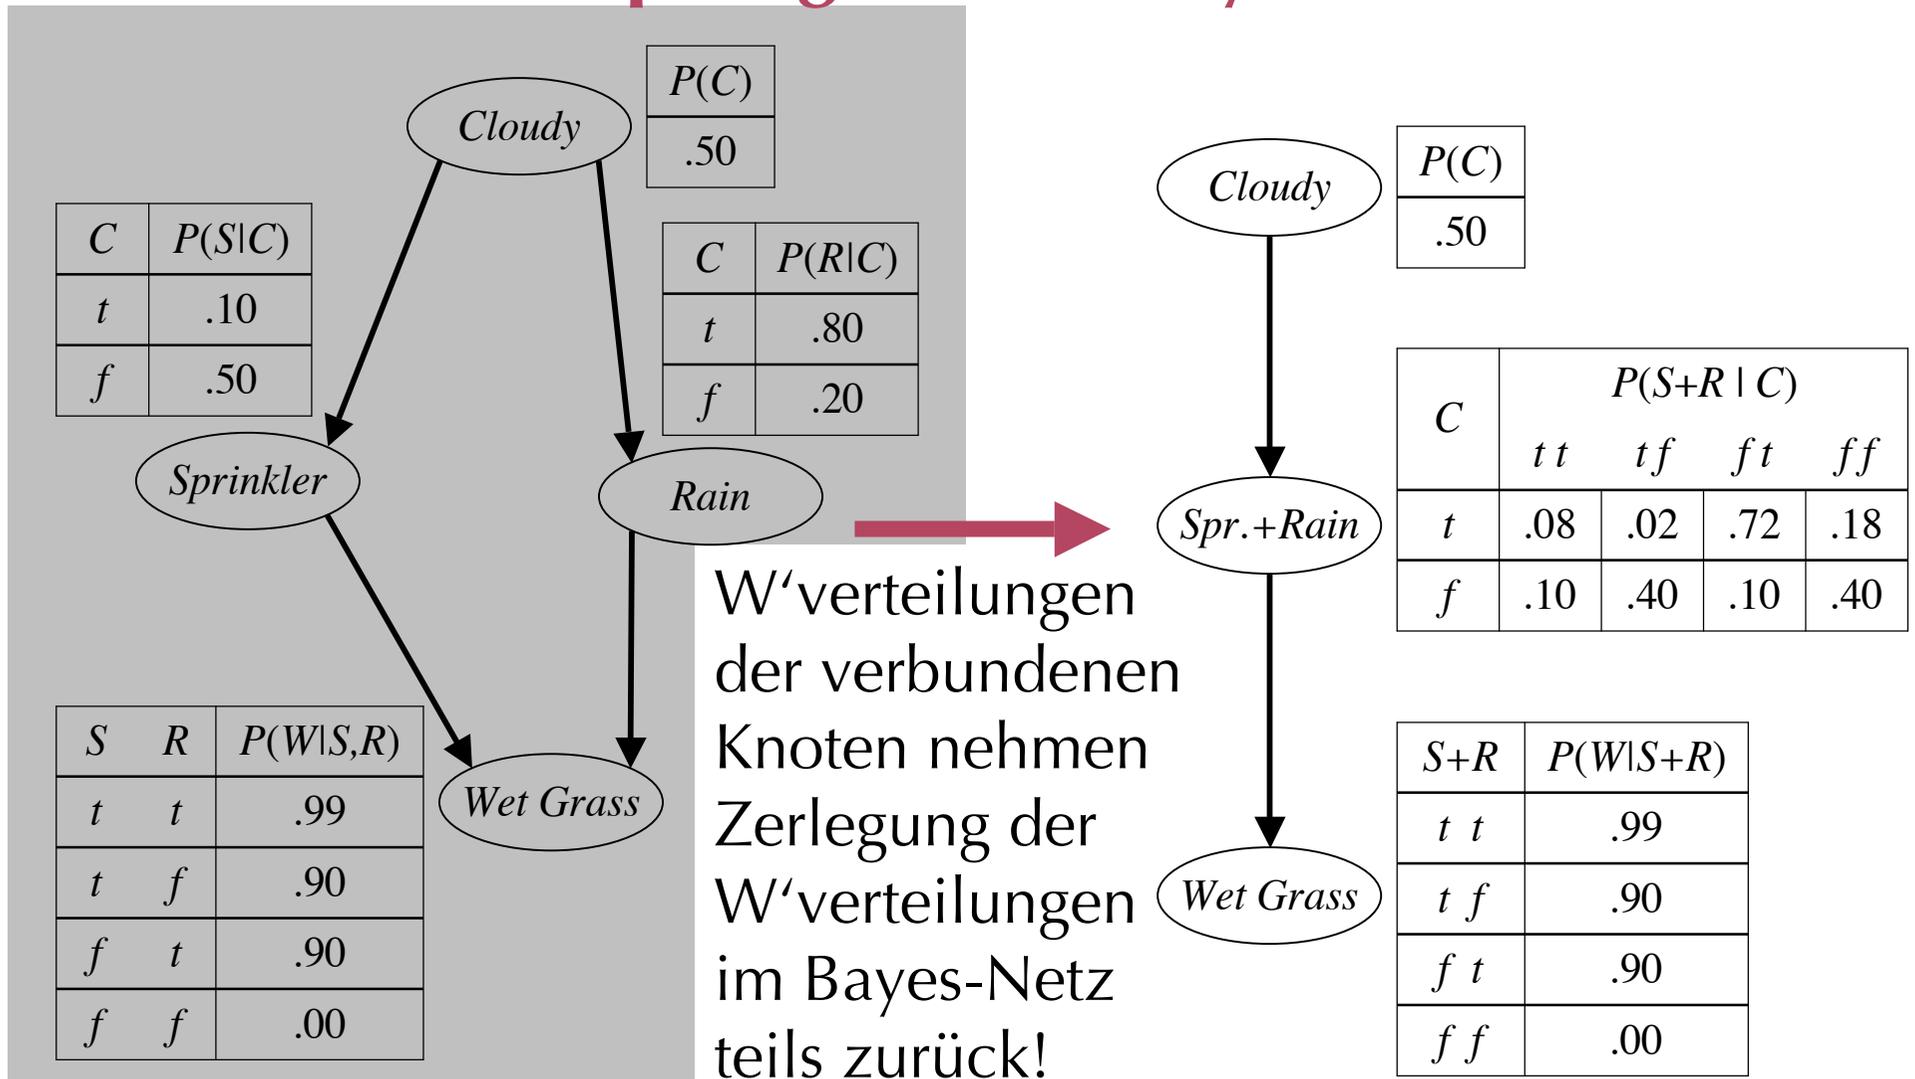
Gegenbeispiel:



Umformungsansatz:

- Verbinde Knoten, bis das Resultat ein Polybaum ist!
- Errechne Verteilungen der verbundenen Knoten aus Verteilungen der Einzelknoten

Rasensprengen mit Polybäumen



Bayes-Netz-Inferenz durch Approximation

Rechne (bedingte) Verteilungen nicht aus,
sondern ermittle sie durch Stichproben aus dem Netz!

```
function PRIOR-SAMPLE(bn) returns an event sampled from bn
  inputs: bn, a belief network specifying joint distribution  $\mathbf{P}(X_1, \dots, X_n)$ 

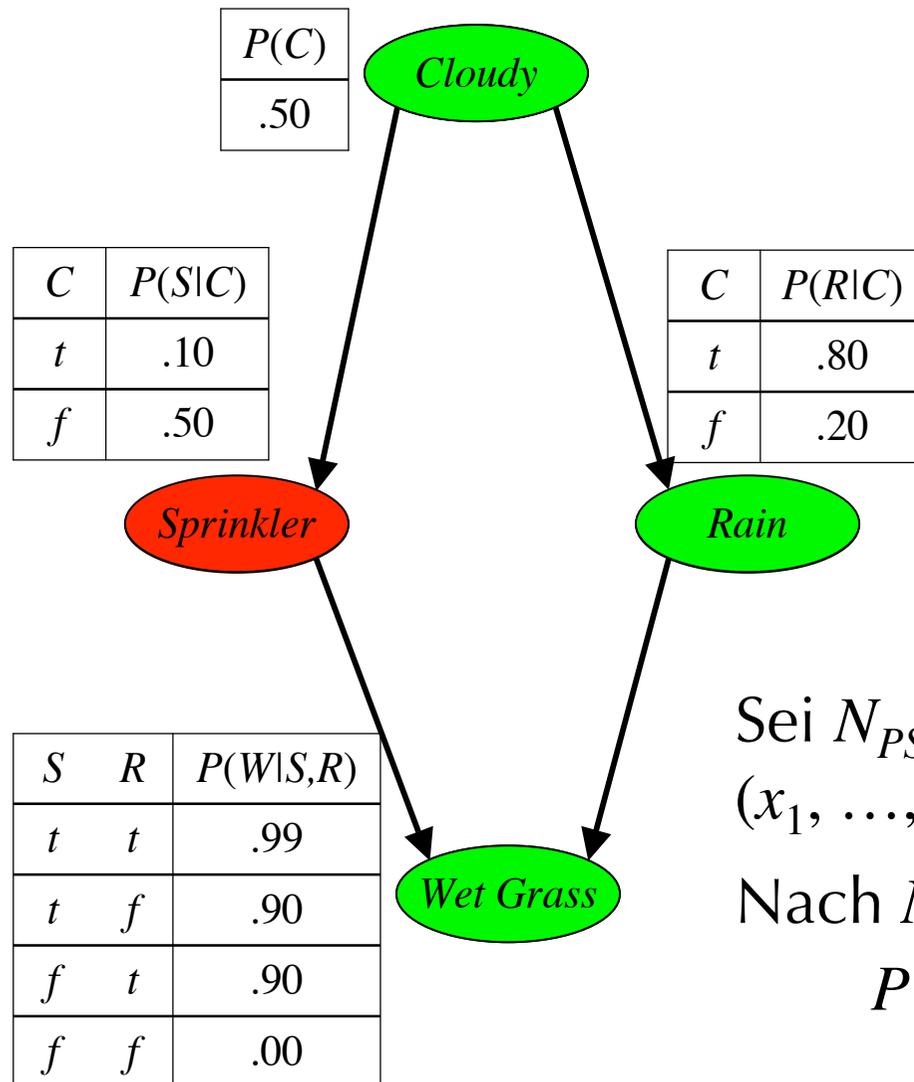
   $\mathbf{x} \leftarrow$  an event with n elements
  for i = 1 to n do
     $x_i \leftarrow$  a random sample from  $\mathbf{P}(X_i \mid \text{Parents}(X_i))$ 
  return  $\mathbf{x}$ 
```

W'keit, dass Funktion die Stichprobe (x_1, \dots, x_n) erzeugt:

$$S_{PS}(x_1, \dots, x_n) = \prod_i P(x_i \mid \text{Parents}(X_i)) = P(x_1, \dots, x_n)$$

d.h.: hinreichend viele Stichproben approximieren Verteilung!

Beispiel: Approximatives Rasenwässern



1. Ziehe C nach $\mathbf{P}(C)=\langle 0.5, 0.5 \rangle$
↪ Ergebnis sei $Cloudy=true$
2. Ziehe S nach $\mathbf{P}(S|c)=\langle 0.1, 0.9 \rangle$
↪ Ergebnis sei $Sprinkler=false$
3. Ziehe S nach $\mathbf{P}(R|c)=\langle 0.8, 0.2 \rangle$
↪ Ergebnis sei $Rain=true$
4. Ziehe S nach $\mathbf{P}(W|s, r)=\langle 0.9, 0.1 \rangle$
↪ Ergebnis sei $Wet_Grass=true$

Sei $N_{PS}(x_1, \dots, x_n)$ die Häufigkeit, mit der (x_1, \dots, x_n) gezogen wurde.

Nach N (hinreichend groß) Stichproben:

$$P(x_1, \dots, x_n) = N_{PS}(x_1, \dots, x_n) / N$$

Grenzen von PRIOR-SAMPLE

- Vorhandene Evidenz wird nicht verwendet:
 $\mathbf{P}(X)$ wird approximiert, aber nicht ohne Weiteres $\mathbf{P}(X|e)$
- Bei vielen Variablen oder unwahrscheinlicher Evidenz e (kleinem $P(e)$) werden viele „Nieten“ gezogen
 - ↳ N muss groß sein
- Je mehr Evidenzvariable, desto kleiner $P(e)$
 - ↳ Algorithmus wird relativ schlechter bei mehr Information!

Lösung: **Gewichtete Stichproben** (WEIGHTED-SAMPLE)

- Belege Evidenz-Variable wie durch e vorgegeben
- Wichte X nach $\mathbf{P}(e|X-e)$

Gewichtete Stichproben

```
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  $w \leftarrow w \times P(X_i = x_i | Parents(X_i))$ 
      else  $x_i \leftarrow$  a random sample from  $P(X_i | Parents(X_i))$ 
  return  $x, w$ 
```

Korrektheit von LIKELIHOOD-WEIGHTING

- Stichprobenw'keit in WEIGHTED-SAMPLE:

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

- Gewicht für Stichprobe (\mathbf{z}, \mathbf{e}) :

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

- Gewichtete Stichprobenw'keit:

$$S_{WS}(\mathbf{z}, \mathbf{e})w(\mathbf{z}, \mathbf{e}) = \prod_i^l P(z_i | Parents(Z_i)) \prod_i^m P(e_i | Parents(E_i)) = P(\mathbf{z}, \mathbf{e})$$

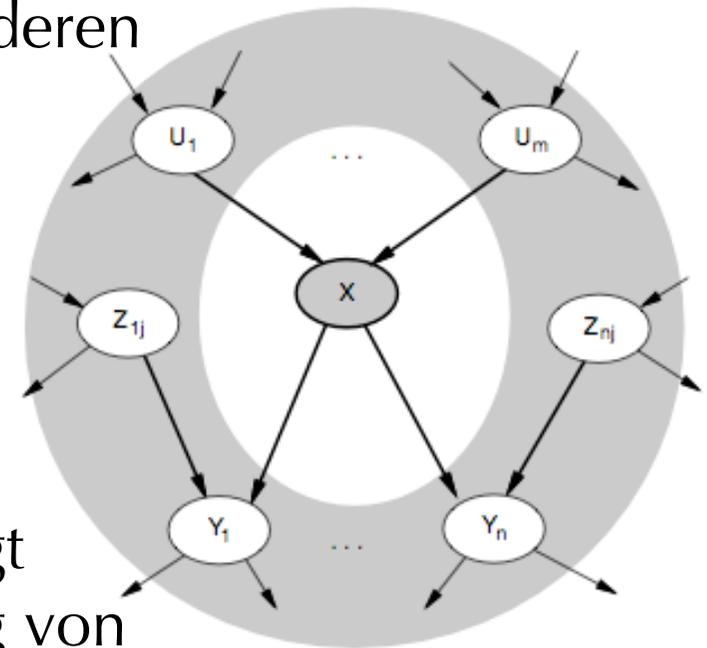
Es bleibt das Problem, dass bei kleinem $P(\mathbf{e})$ (geringe W'keit des Evidenzereignisses, viele Evidenzvariablen) große Stichproben erforderlich sind!

Stichprobenziehen per *random walk*

Idee:

- Starte mit zufälligem Ereignis, das die Evidenz spiegelt
- Erzeuge neue Ereignisse durch „lokale Änderung“ in Nicht-Evidenz-Variablen
- Die lokalen Änderungen entsprechen W' -verteilung abhängig von den unveränderten Variablen

Markow-Hülle von X : die Eltern von X , die direkten Nachfolger von X und deren (andere) Eltern



Satz:

X ist bedingt unabhängig von allen anderen Knoten, gegeben seine Markow-Hülle

Markov Chain Monte Carlo Sampling

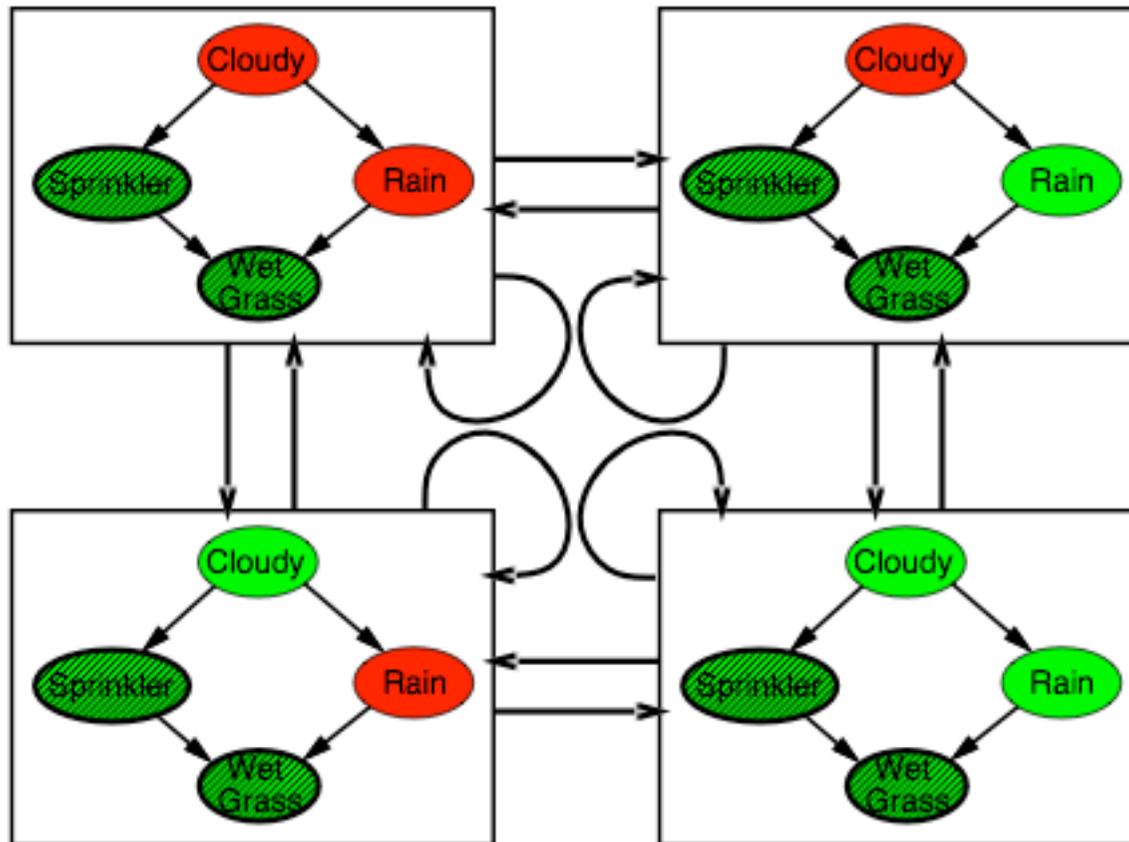
```
function MCMC-ASK( $X, e, bn, N$ ) returns an estimate of  $P(X|e)$ 
  local variables:  $N[X]$ , a vector of counts over  $X$ , initially zero
                   $Z$ , the nonevidence variables in  $bn$ 
                   $x$ , the current state of the network, initially copied from  $e$ 

  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  $P(Z_i | MB(Z_i))$  given the values of
         $MB(Z_i)$  in  $x$ 
  return NORMALIZE( $N[X]$ )
```

Markov-Hülle (*Markov blanket*)

Qualitatives Verhalten von MCMC (Beispiel)

Sei $\mathbf{e} = \{\text{Sprinkler} = \text{true}, \text{Wet_Grass} = \text{true}\}$, $\mathbf{Z} = \{\text{Cloudy}, \text{Rain}\}$



Stichproben entsprechen einer **Markov-Kette**

- Für $\mathbf{P}(r|e)$ setze z.B. $N=100$
- Zähle Stichproben aus nach $r, \neg r$; haben z.B. 31 r , 69 $\neg r$
- $\mathbf{P}(r|e)$
= $\text{NORMALIZE}(\langle 31, 69 \rangle)$
= $\langle 0.31, 0.69 \rangle$

Eigenschaften von MCMC

- ☺ **Satz:** Die Markow-Kette approximiert eine stationäre Verteilung: Im Limes ist sie in einer Häufigkeit in jedem Zustand, die der bedingten W'keit des entsprechenden Ereignisses entspricht.
- ☹ N muss man raten – wann ist Markow-Kette konvergiert?
- ☹ Bei sehr großen Markow-Hüllen lange Zeit bis Konvergenz