

USTC

Chapter 14b

Inference in Bayesian Networks

王子磊 (Zilei Wang)

Email: zlwang@ustc.edu.cn

<http://vim.ustc.edu.cn>

提纲

❖ 精确推理 (exact inference)

- 通过枚举 (enumeration)
- 通过变量消元 (variable elimination)

❖ 近似推理 (approximate inference)

- 通过随机模拟 (stochastic simulation)
- 通过 Markov 链蒙特卡洛 (MCMC)

推理任务

- ❖ 简单查询：计算后验边缘概率 $P(X_i|\mathbf{E} = \mathbf{e})$
e.g., $P(\text{NoGas}|\text{Gauge} = \text{empty}, \text{Lights} = \text{on}, \text{Starts} = \text{false})$
- ❖ 合取查询： $P(X_i, X_j|\mathbf{E} = \mathbf{e}) = P(X_i|\mathbf{E} = \mathbf{e})P(X_j|X_i, \mathbf{E} = \mathbf{e})$
- ❖ 最优决策：决策网络包括效用信息，概率推理需要计算
 $P(\text{outcome}|\text{action}, \text{evidence})$
- ❖ 信息价值：哪些证据是需要下一步获取的？
- ❖ 灵敏度分析：哪些概率值是最重要的？
- ❖ 解释：我为什么需要一个启动马达？

通过枚举进行推理

- ❖ 稍微智能的方法：直接求和联合概率分布中的变量，而不进行实际概率的显式计算


- ❖ 在 Burglary 网络上的简单查询

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

- ❖ 采用 CPT 项的乘积表达完全联合项

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

- ❖ 递归深度优先枚举： $O(n)$ 空间复杂度， $O(d^n)$ 时间复杂度




枚举算法

```
function ENUMERATION-ASK( $X, e, bn$ ) returns a distribution over  $X$   
  inputs:  $X$ , the query variable  
          $e$ , observed values for variables  $E$   
          $bn$ , a Bayesian network with variables  $\{X\} \cup E \cup Y$  父节点到子节点的次序  
  
   $Q(X) \leftarrow$  a distribution over  $X$ , initially empty  
  for each value  $x_i$  of  $X$  do  
    extend  $e$  with value  $x_i$  for  $X$  } 针对查询变量的每个值进行  
     $Q(x_i) \leftarrow$  ENUMERATE-ALL(VARS[ $bn$ ],  $e$ ) } 计算 (加入到证据变量中)  
  return NORMALIZE(Q(X)) 归一化
```

```
function ENUMERATE-ALL( $vars, e$ ) returns a real number 递归算法  
  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( $vars$ ),  $e$ ) 观测到  
    else return  $\sum_y P(y \mid Pa(Y)) \times$  ENUMERATE-ALL(REST( $vars$ ),  $e_y$ ) 未观测到  
    where  $e_y$  is  $e$  extended with  $Y = y$ 
```

估算树




❖ 枚举是低效的：存在重复计算

- e.g., 对 e 的每个值，都计算了 $P(j|a)P(m|a)$

通过变量消元进行推理

- ❖ 变量消元 (variable elimination) : 从右向左进行求和操作
 - 存储中间结果 (factors) 以避免重复计算



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

变量消元：基本操作

- ❖ 求和：针对单个变量，累加乘法因子
 - 将所有约束因子移到求和项外部
 - 将其余因子逐点相乘的子矩阵进行累加

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

这里，假定 f_1, f_2, \dots, f_i 不依赖于 X

- ❖ 逐点相乘：考虑 f_1 和 f_2

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

$$\text{E.g., } f_1(a, b) \times f_2(b, c) = f(a, b, c)$$

变量消元算法


```
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  $P(X_1, \dots, X_n)$   
 $factors \leftarrow []$ ;  $vars \leftarrow$  REVERSE(VARS[ $bn$ ]) 子节点到父节点的次序  
for each  $var$  in  $vars$  do  
     $factors \leftarrow$  [MAKE-FACTOR( $var, e$ )| $factors$ ]  
    if  $var$  is a hidden variable then  $factors \leftarrow$  SUM-OUT( $var, factors$ ) 求和消除  
return NORMALIZE(POINTWISE-PRODUCT( $factors$ )) 显变量点乘
```

无关变量 (Irrelevant variables)

❖ 考虑查询: $P(\text{JohnCalls} | \text{Burglary} = \text{true})$

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

▪ 在 m 上求和为 1; M 是与查询无关的



❖ **定理1:** Y 是查询无关的, 除非 $Y \in \text{Ancestors}(\{X\} \cup \mathbf{E})$

❖ 在上例中, $X = \text{JohnCalls}$, $\mathbf{E} = \{\text{Burglary}\}$

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


因此 MaryCalls 是无关的

类比于 Horn 子句 KB 的后向链接算法

无关变量 (Irrelevant variables)

- ❖ 定义（贝叶斯网络的 moral 图）：连接父节点并消除箭头
- ❖ 定义（m-分离, m-separated）：A 通过 C 对 B 是 m-分离的，当且仅当它们在 moral 图中通过 C 是可分离的
- ❖ 定理2：Y 是无关的，如果它通过 E 对 X 是 m-分离的

For $P(\text{JohnCalls} | \text{Alarm} = \text{true})$, both *Burglary* and *Earthquake* are irrelevant



确定推理的复杂度 *


❖ 单连通网络 (多形树, polytrees):

- 任何两个节点之间最多只有一条 (无向) 路径
- 变量消元的时间和空间代价是 $O(d^k n)$

❖ 多连通网络:

- 能够转换为 3SAT 进行精确推理 \rightarrow NP-hard
- 等价于对 3SAT 模型的计数 \rightarrow #P-complete

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



通过随机模拟进行推理

❖ 基本思想：

- 从样本分布 S 中采用 N 个样本
- 计算一个近似的后验概率 \hat{P}
- 证明该概率收敛于真实概率 P



❖ 贝叶斯网络采样方法

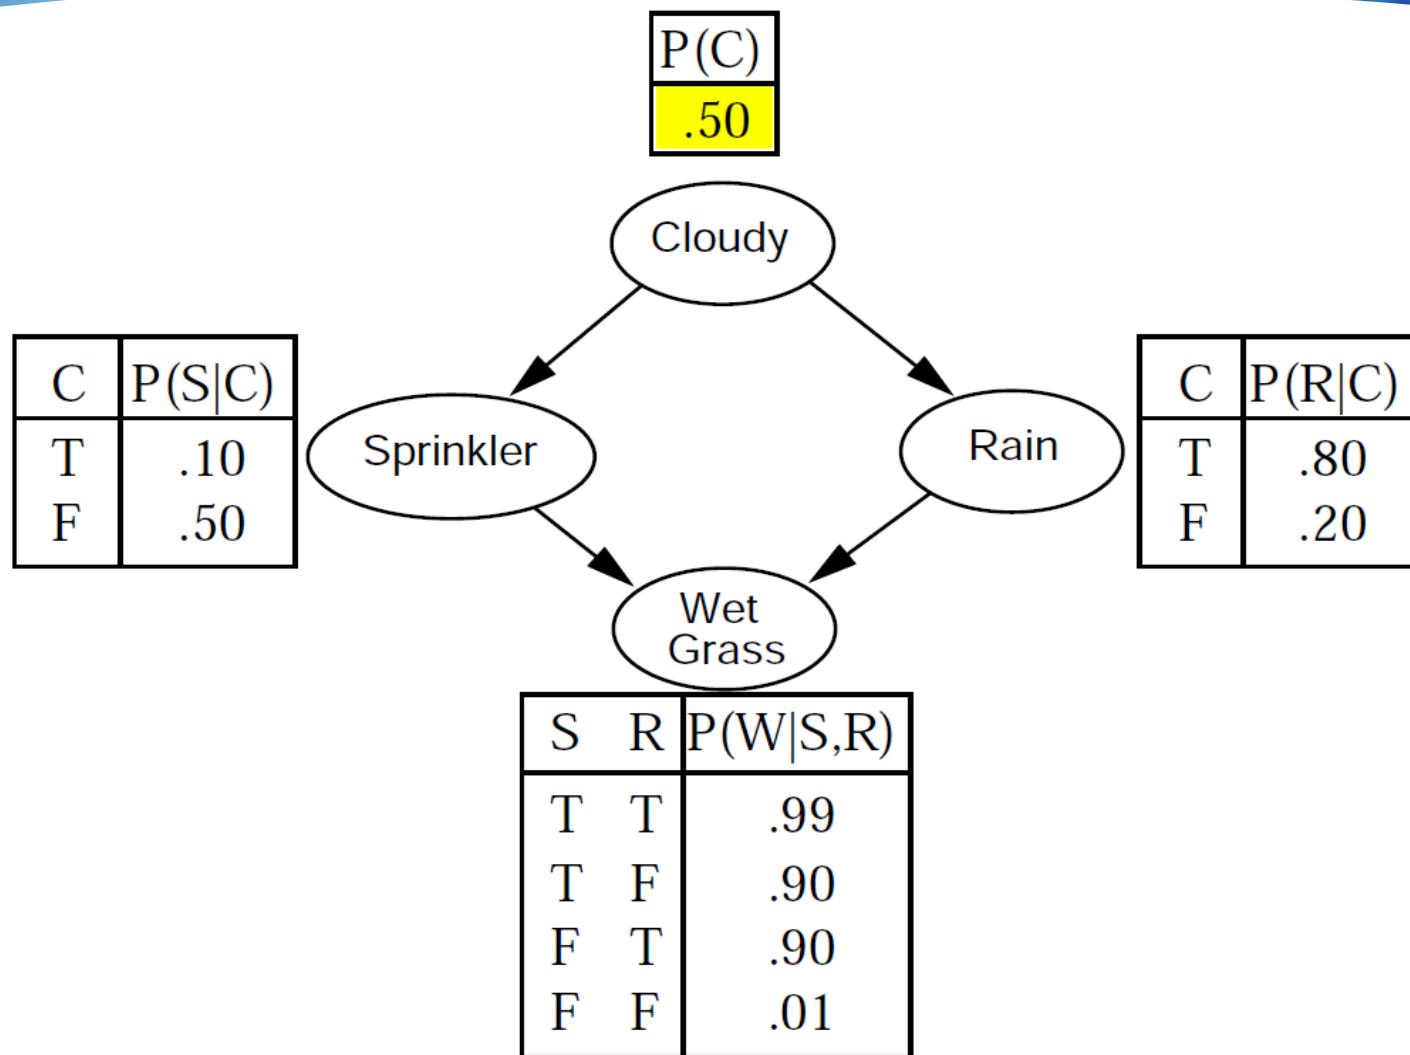
- 从一个空白网络中进行直接采样
- 拒绝采样：与证据不一致的拒绝样本
- 似然加权：根据证据对采样样本进行加权
- **马尔科夫链蒙特卡洛 (Markov chain Monte Carlo, MCMC)**：根据一个随机过程进行采样，它的稳态分布就是真实的后验概率

从一个空白网络中直接采样

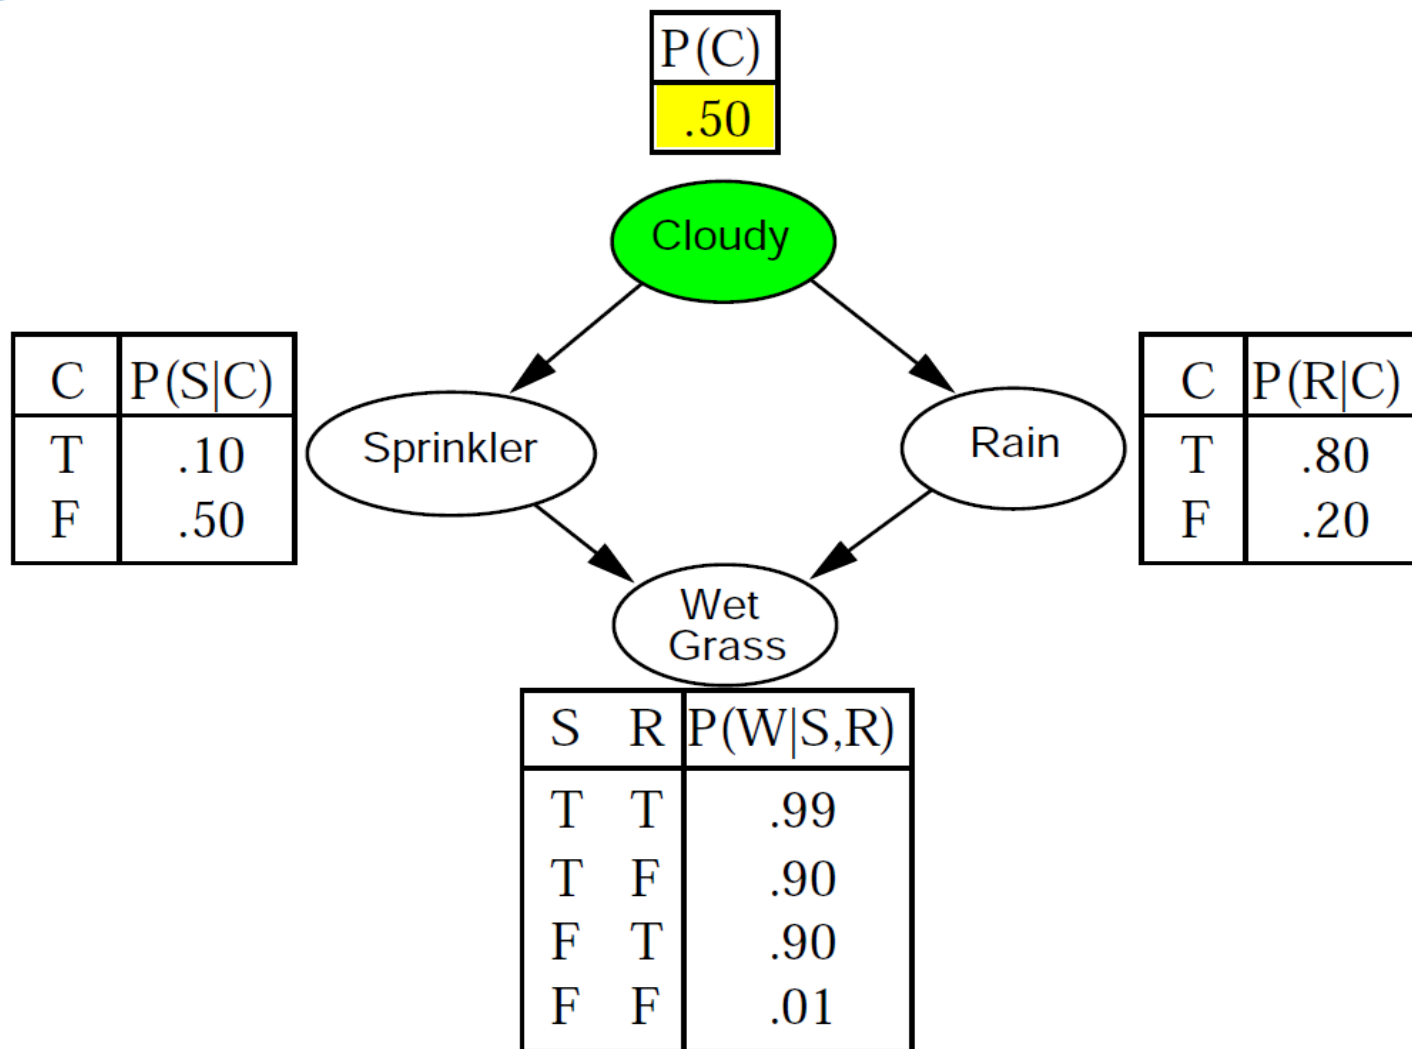
❖ 无证据变量，直接进行事件采样

```
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  $\mathbf{P}(X_i \mid \text{parents}(X_i))$   
    given the values of  $\text{Parents}(X_i)$  in  $\mathbf{x}$  依据条件概率进行采样  
  return  $\mathbf{x}$ 
```

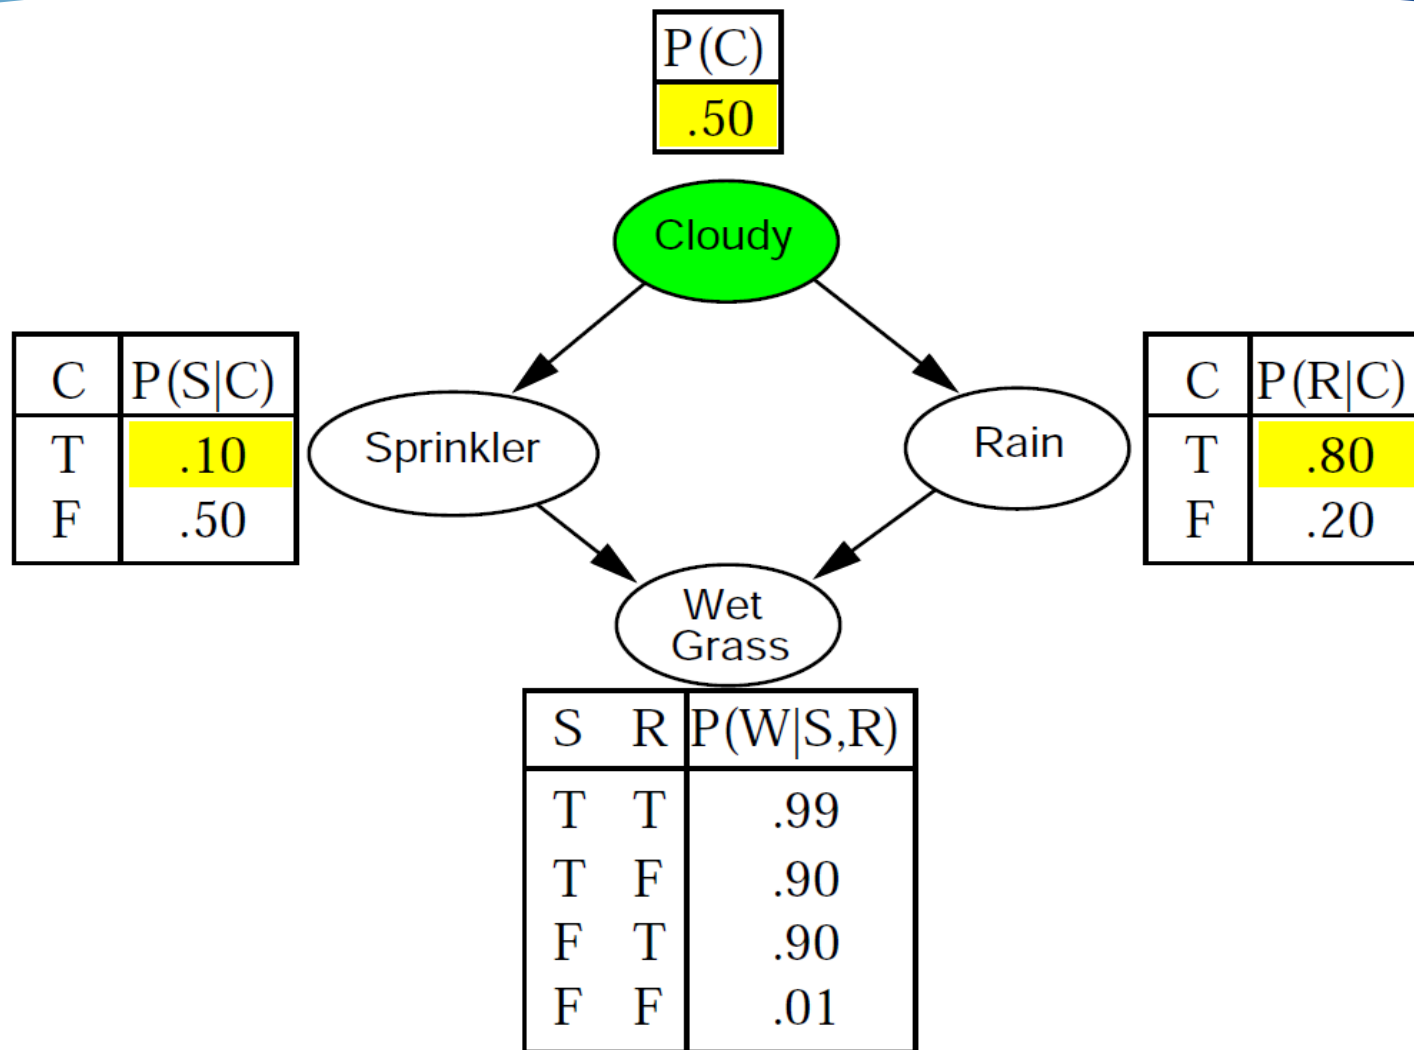
示例



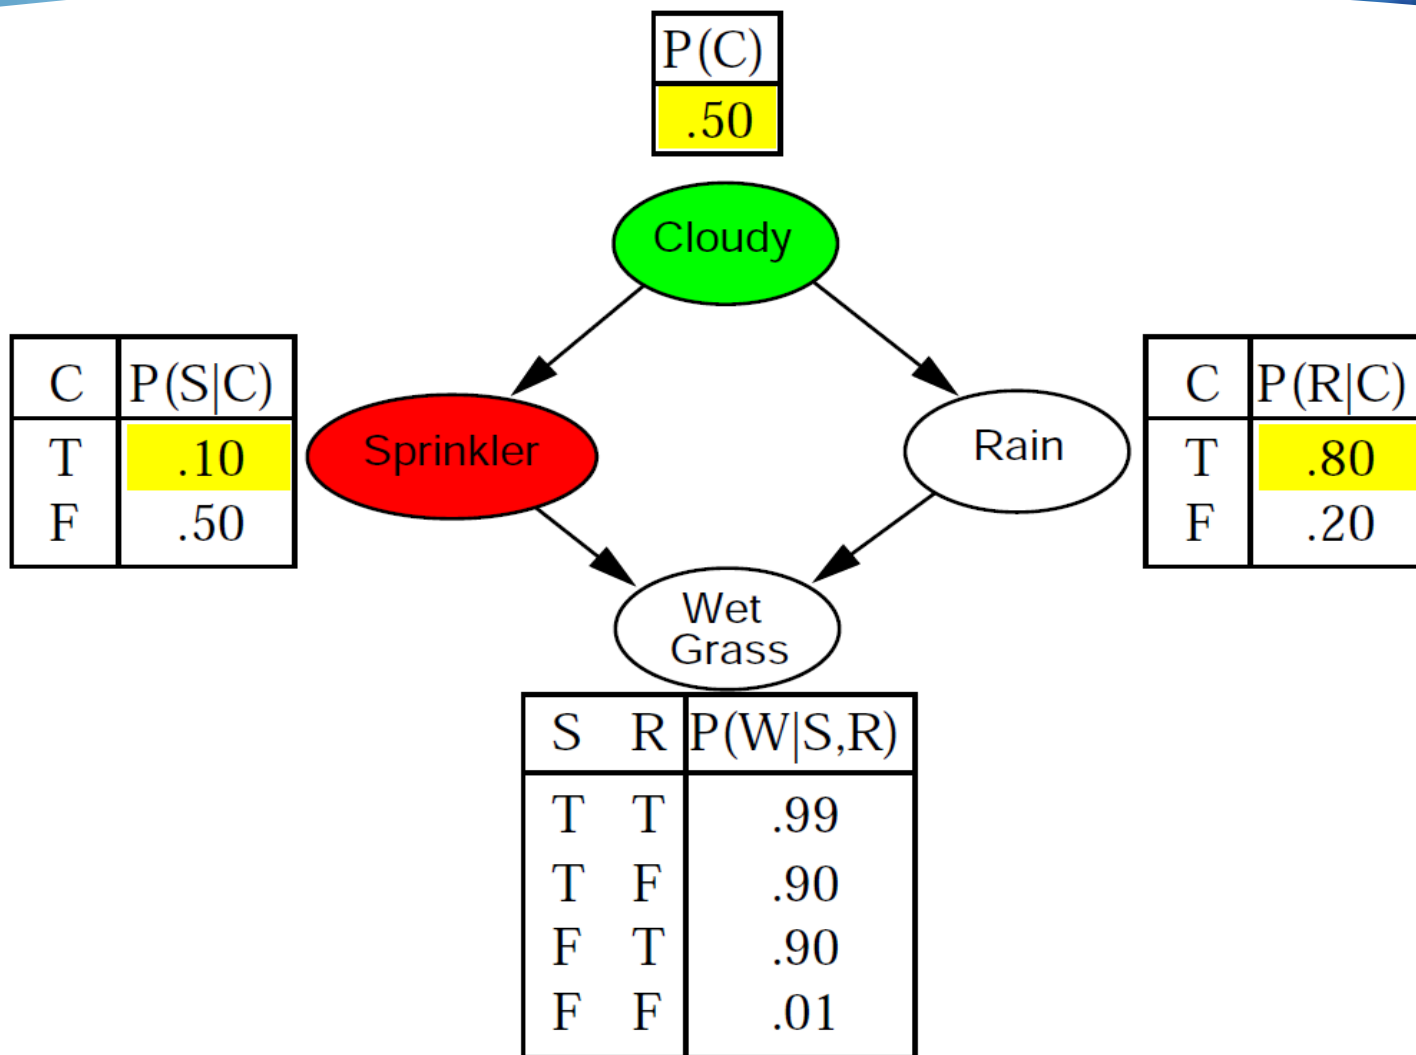
示例



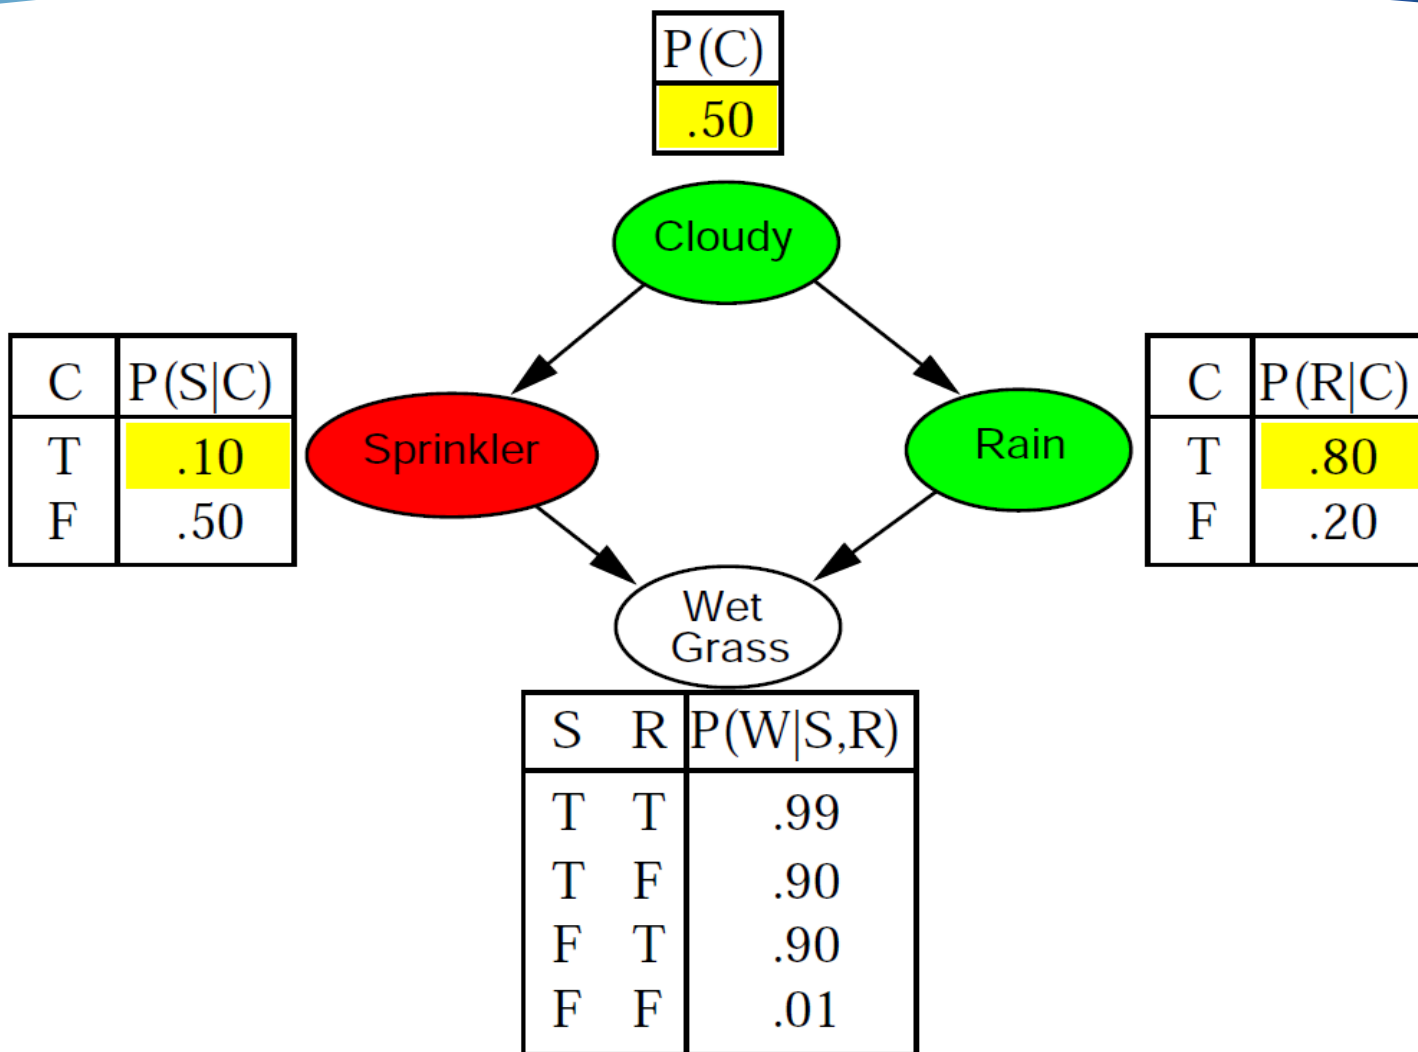
示例



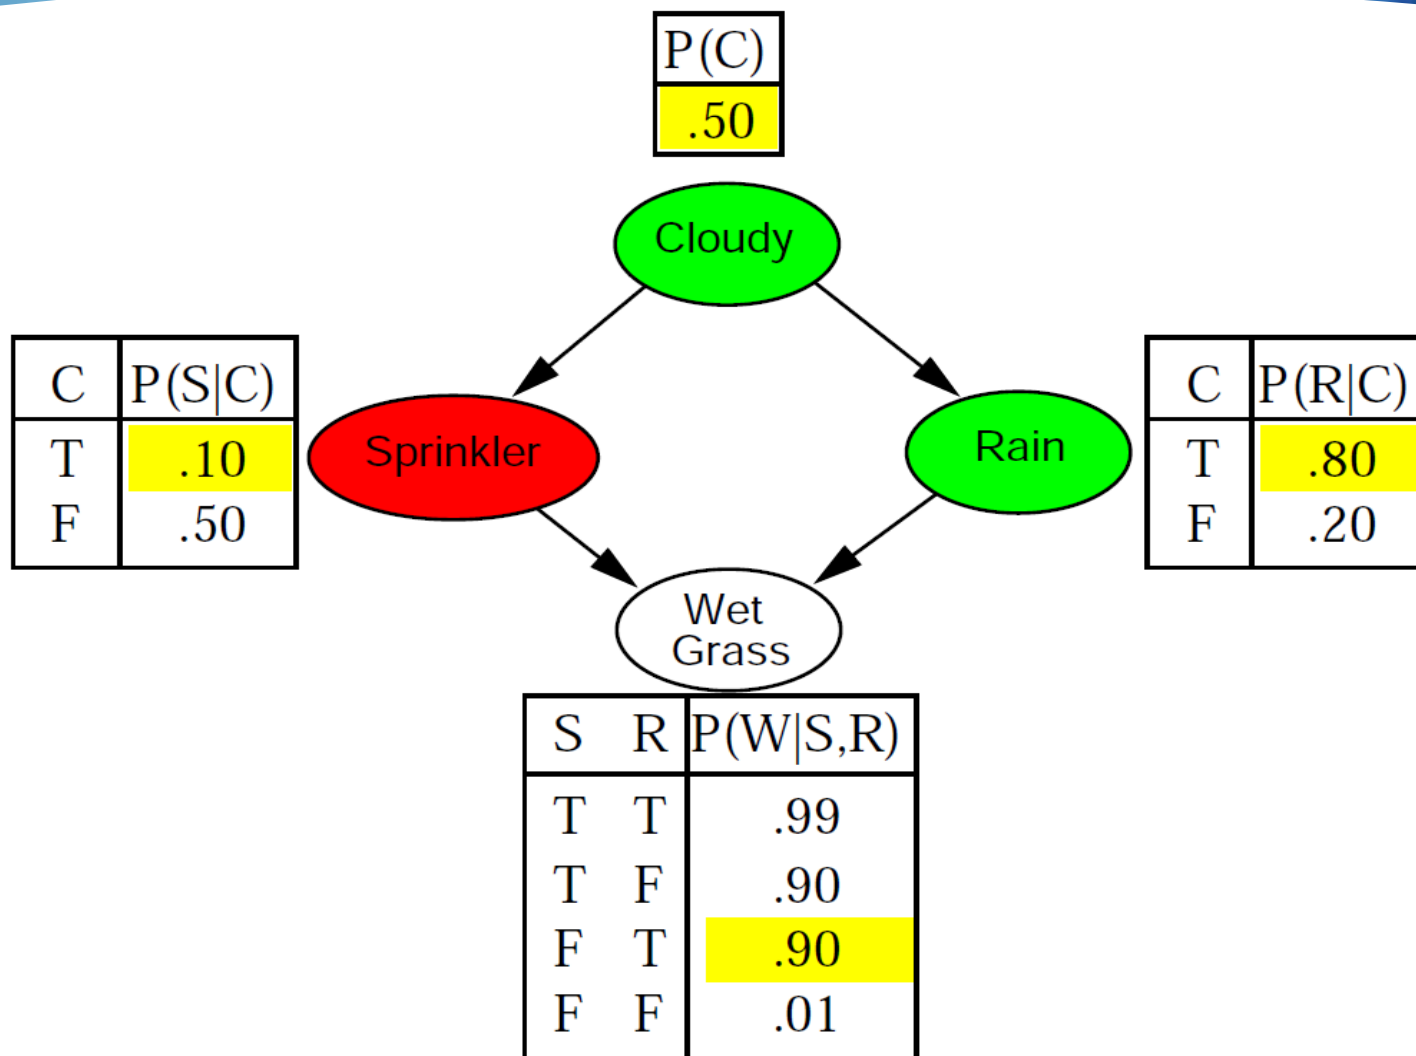
示例



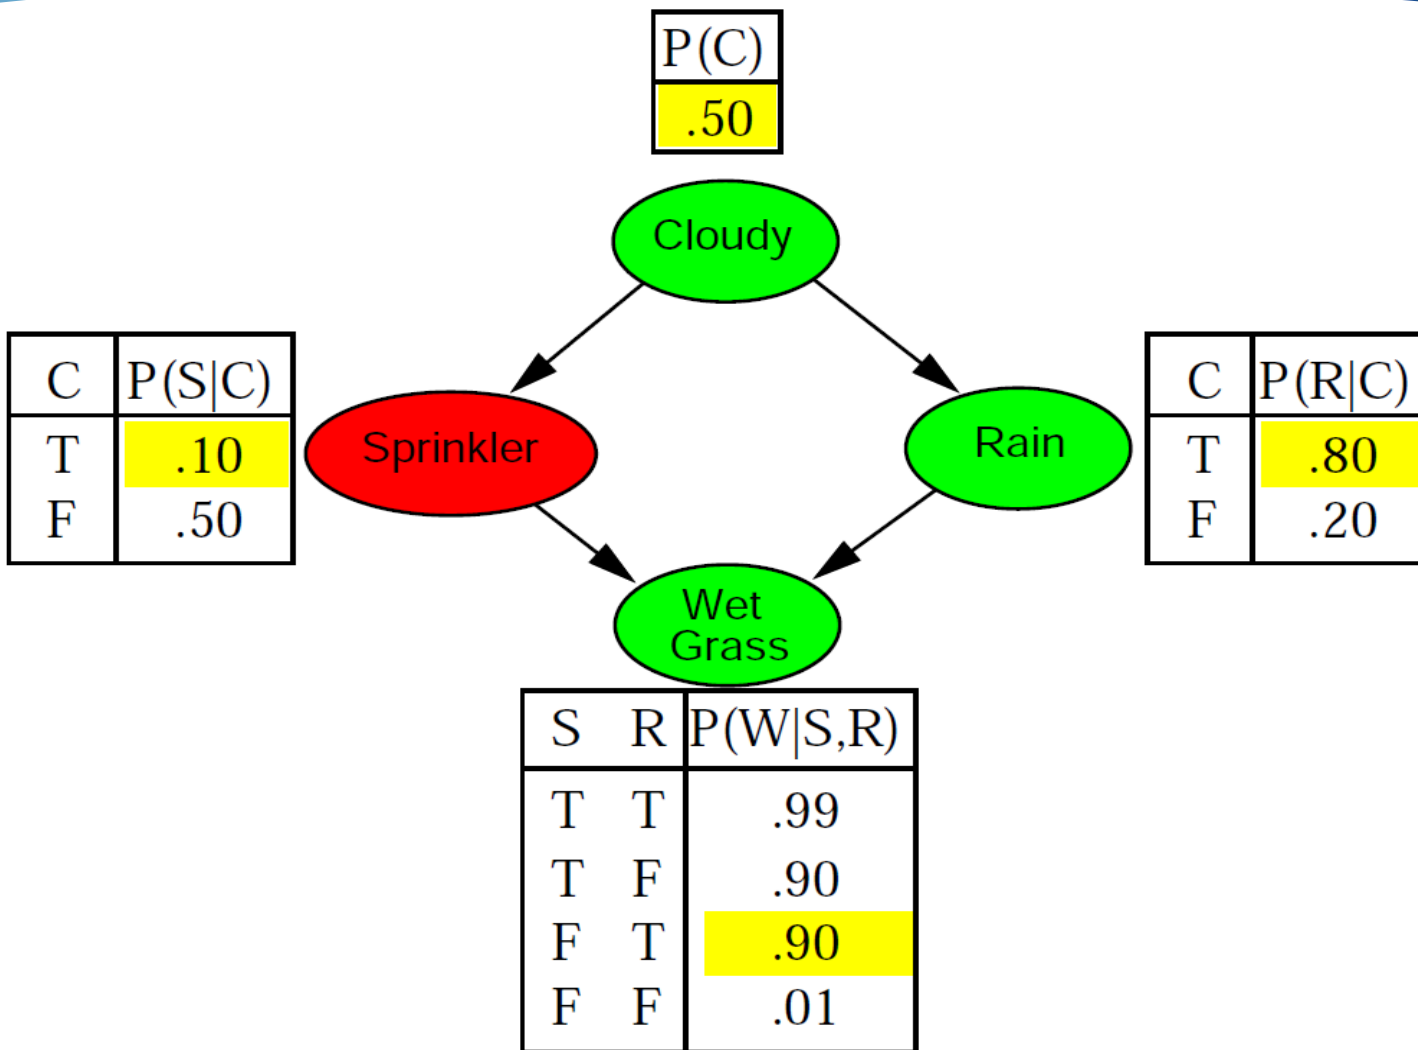
示例



示例



示例



从一个空白网络中直接采样

- ❖ 直接采样 (PriorSample) 产生一个特定事件的概率为：

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

i.e., 真实的先验概率

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

- ❖ $N_{PS}(x_1 \dots x_n)$ 表示事件 x_1, \dots, x_n 的采样样本数，则有：

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

即：直接采样的概率估计是一致的

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

拒绝采样 (Rejection sampling)

- ❖ 考虑证据变量 e ，估计与其一致的概率，即条件概率 $\hat{P}(X|e)$

```
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( $N[X]$ )
```

正常采样，但只记录一致的样本

- ❖ 例如：用 100 个样本估计 $P(\text{Rain}|\text{Sprinkler} = \text{true})$
 - 27 个样本满足 $\text{Sprinkler} = \text{true}$
 - 其中，有 8 个 $\text{Rain} = \text{true}$ ，19 个是 $\text{Rain} = \text{false}$

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

拒绝采样分析

$$\begin{aligned}\hat{\mathbf{P}}(X|\mathbf{e}) &= \alpha \mathbf{N}_{PS}(X, \mathbf{e}) && \text{(algorithm defn.)} \\ &= \mathbf{N}_{PS}(X, \mathbf{e}) / N_{PS}(\mathbf{e}) && \text{(normalized by } N_{PS}(\mathbf{e})\text{)} \\ &\approx \mathbf{P}(X, \mathbf{e}) / P(\mathbf{e}) && \text{(property of PRIORSAMPLE)} \\ &= \mathbf{P}(X|\mathbf{e}) && \text{(defn. of conditional probability)}\end{aligned}$$

- ❖ 拒绝采样计算结果是一致的后验概率估计
- ❖ 问题：如果 $P(e)$ 比较小，则计算代价非常高
 - $P(e)$ 随着证据变量数目的增加呈指数级下降

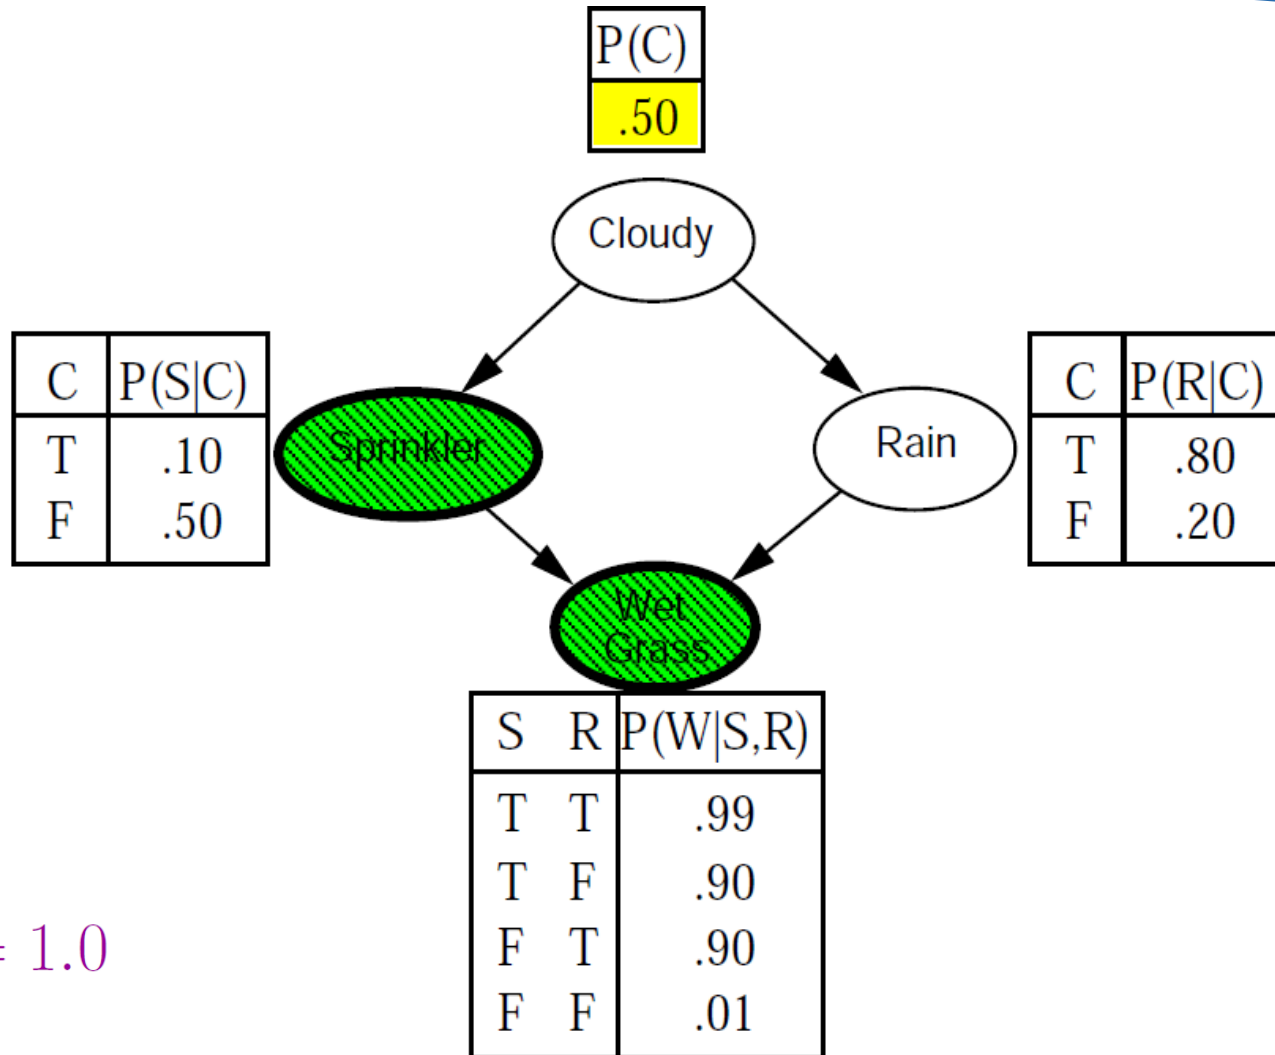
似然加权 (likelihood weighting, LW)

- ❖ 基本思想：固定证据变量，只采样非证据变量，同时对采样样本根据与证据的似然度进行加权

```
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( $\mathbf{W}[X]$ )
```

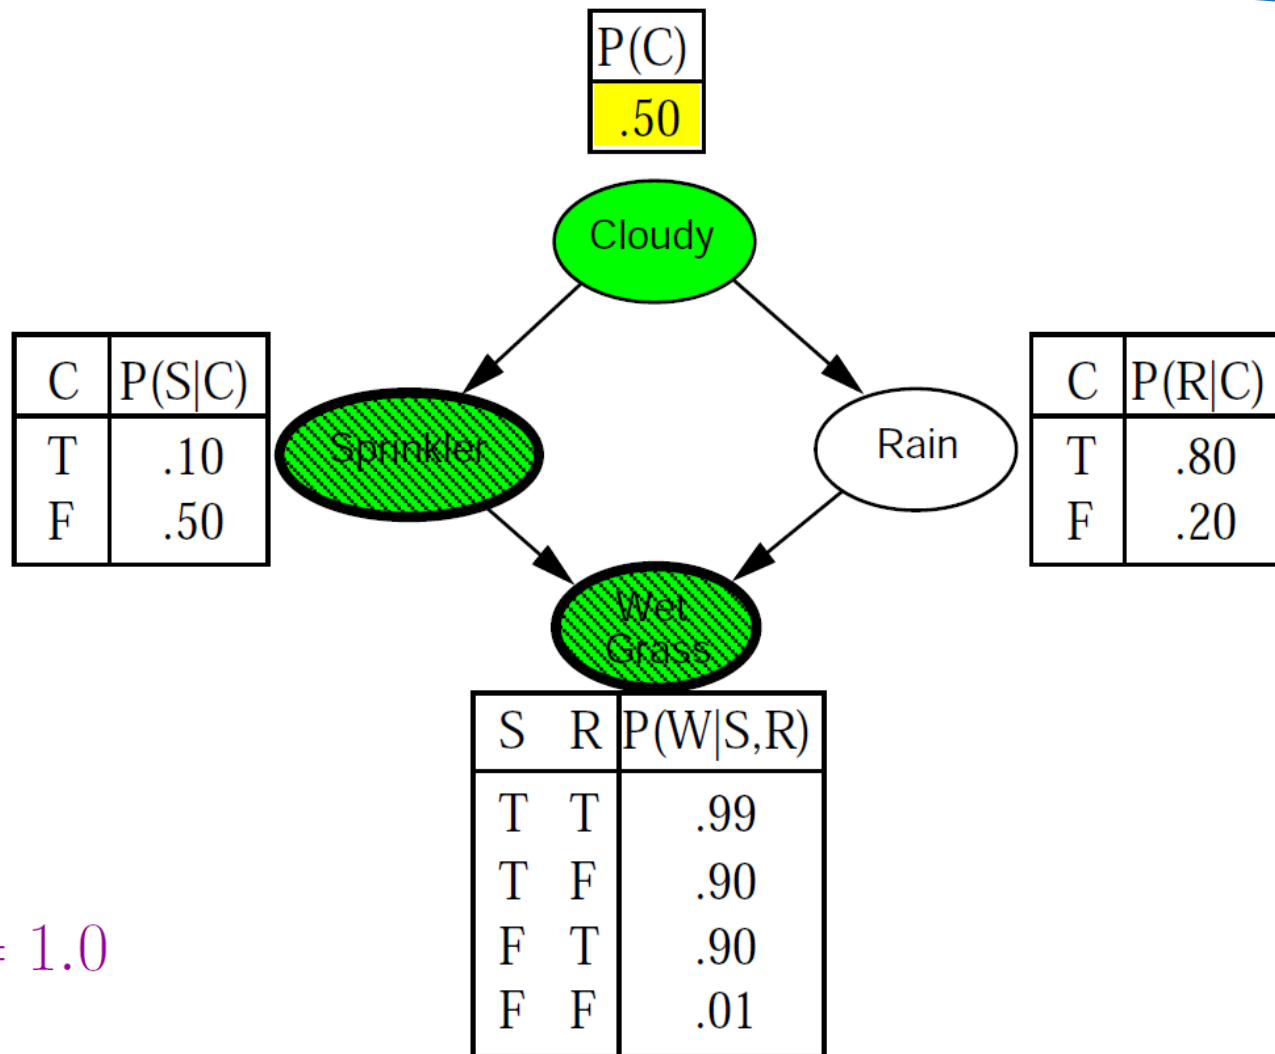
```
function WEIGHTED-SAMPLE( $bn, \mathbf{e}$ ) returns an event and a weight  
   $\mathbf{x} \leftarrow$  an event with  $n$  elements;  $w \leftarrow 1$  返回采样样本及其权重  
  for  $i = 1$  to  $n$  do  
    if  $X_i$  has a value  $x_i$  in  $\mathbf{e}$   
      then  $w \leftarrow w \times P(X_i = x_i \mid \text{parents}(X_i))$  对证据变量不采样  
      else  $x_i \leftarrow$  a random sample from  $\mathbf{P}(X_i \mid \text{parents}(X_i))$   
  return  $\mathbf{x}, w$ 
```

似然加权示例



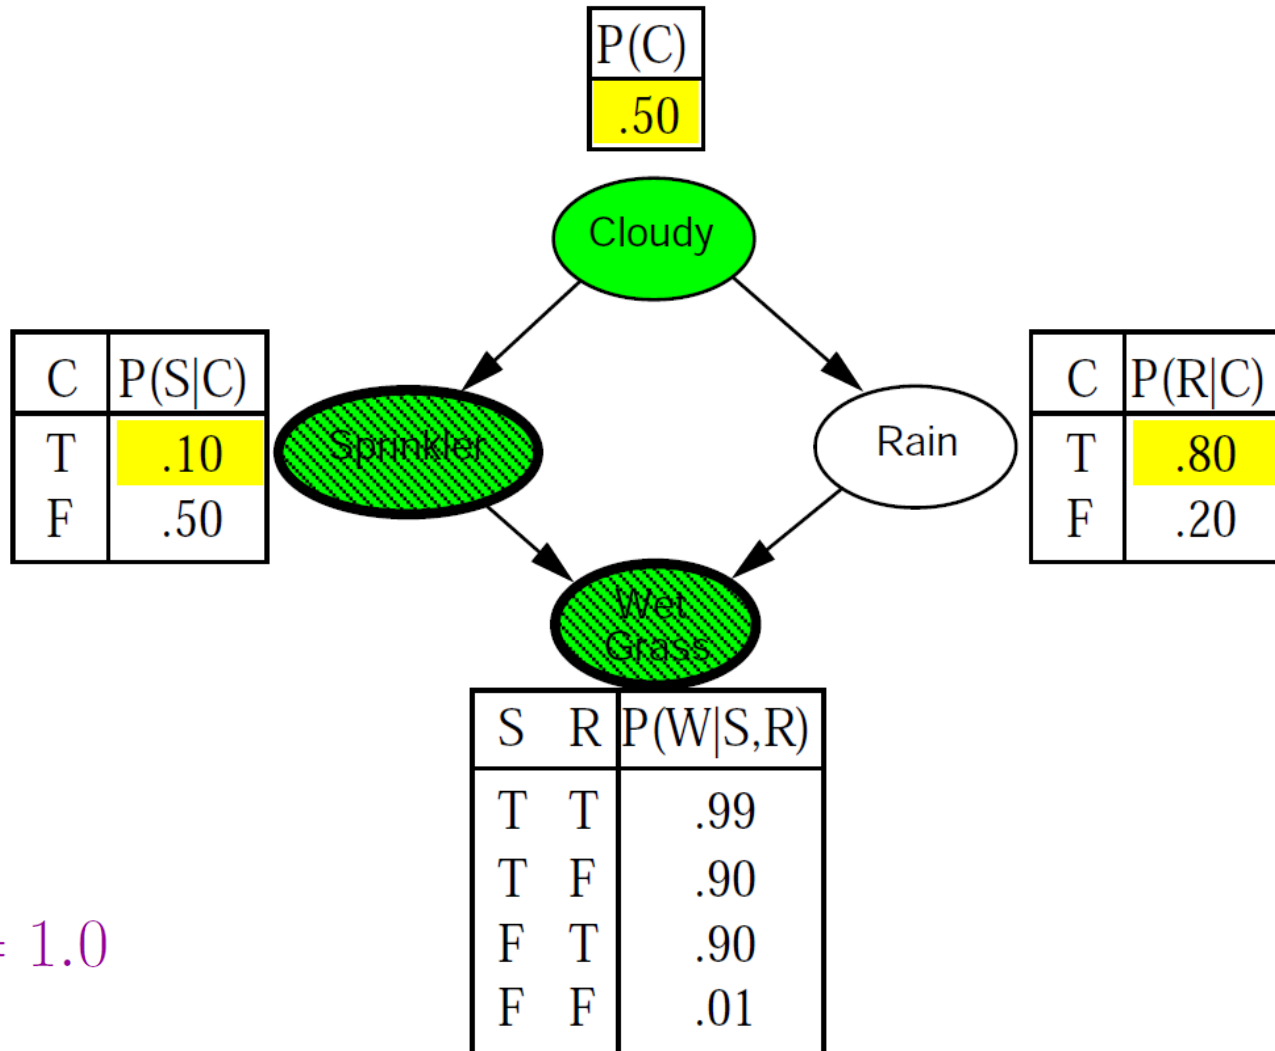
$$w = 1.0$$

似然加权示例



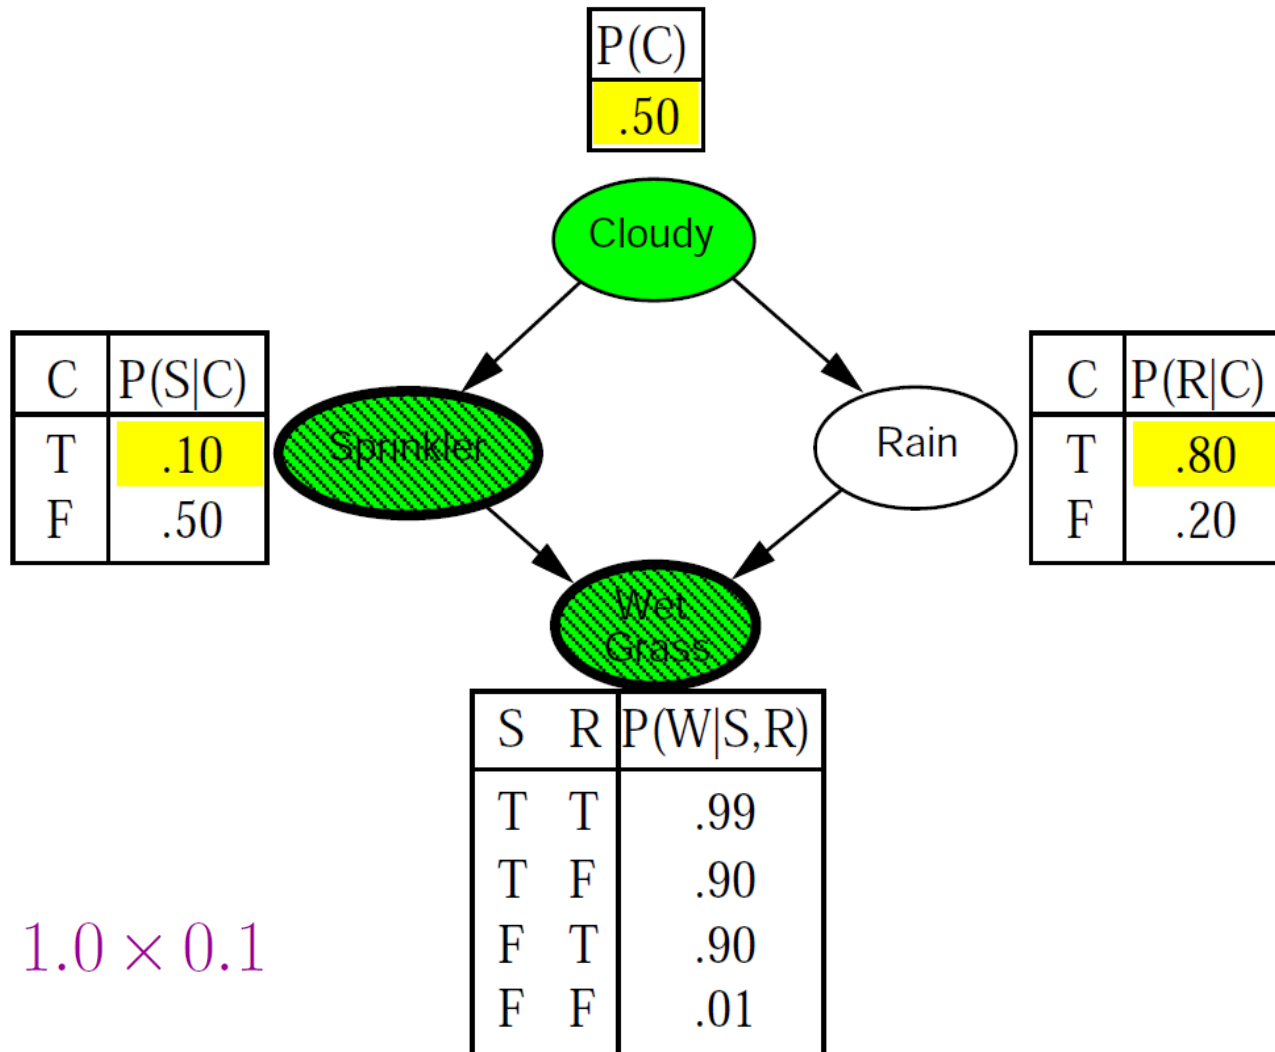
$$w = 1.0$$

似然加权示例



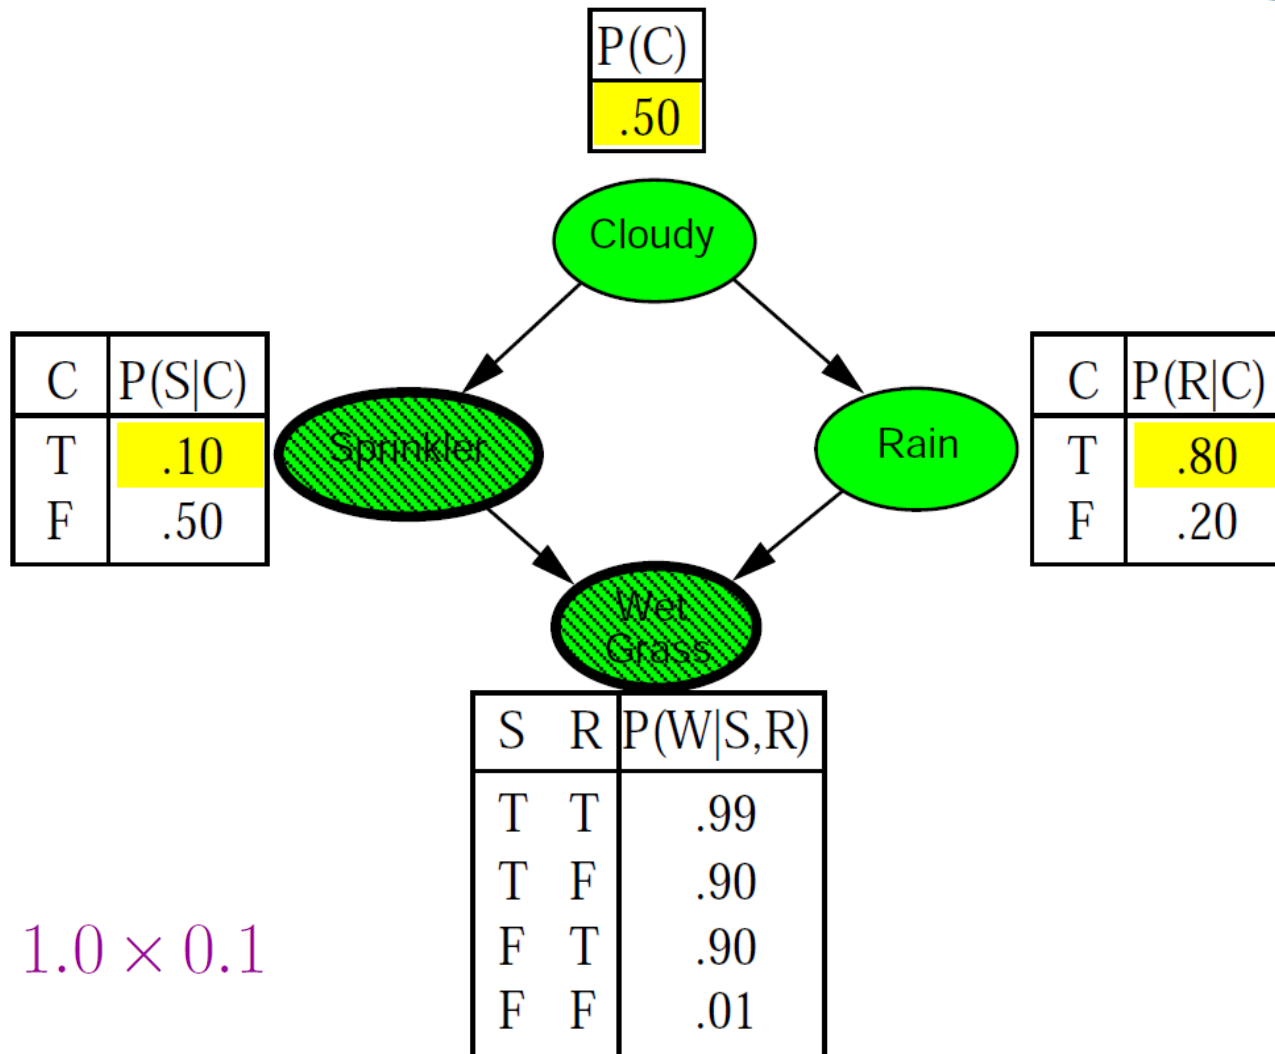
$$w = 1.0$$

似然加权示例



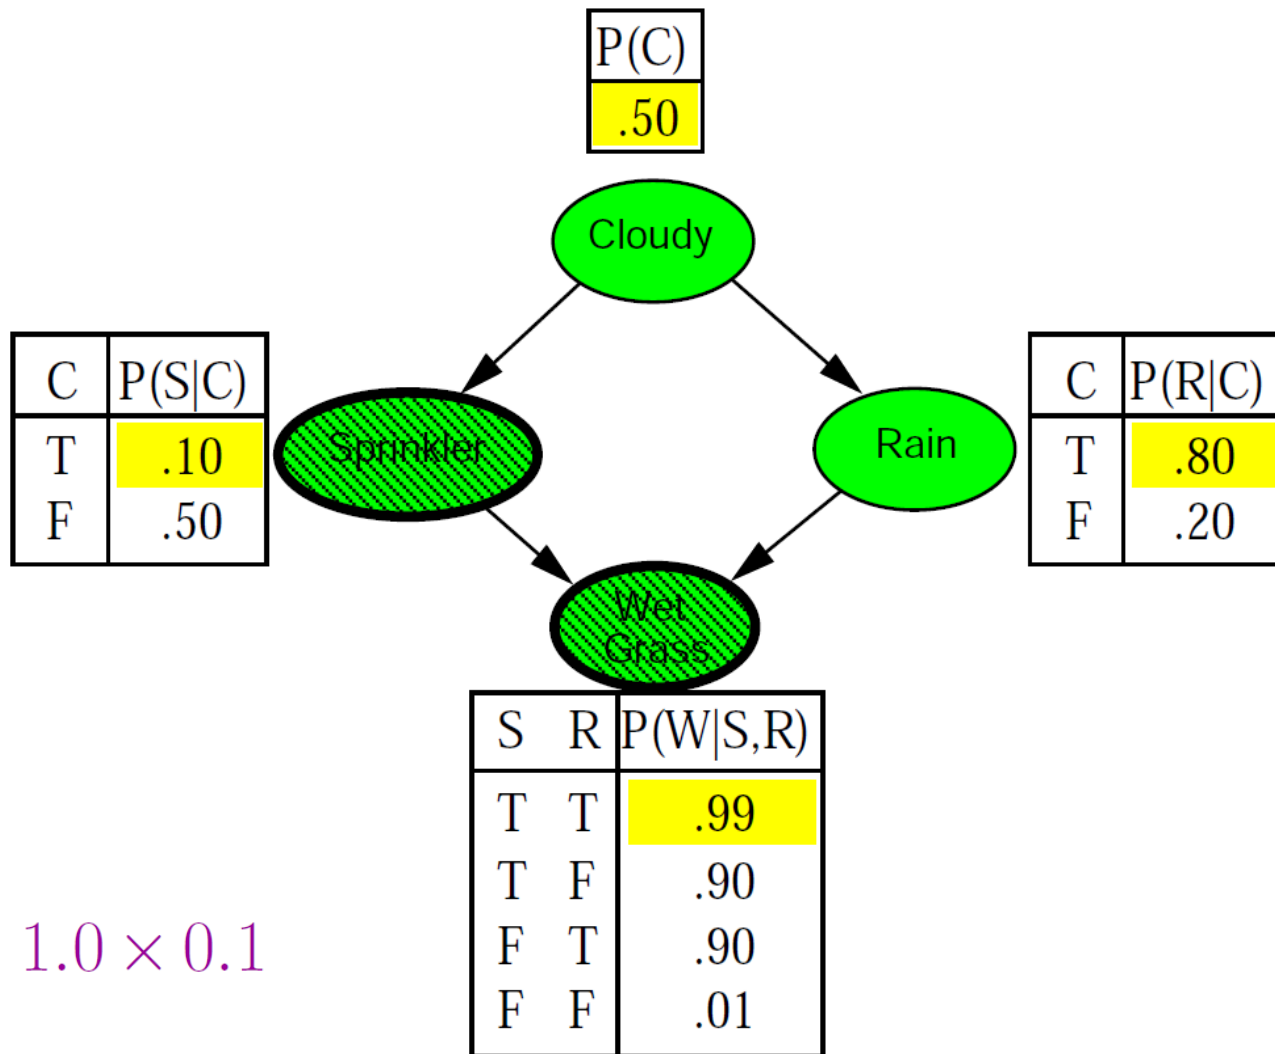
$$w = 1.0 \times 0.1$$

似然加权示例

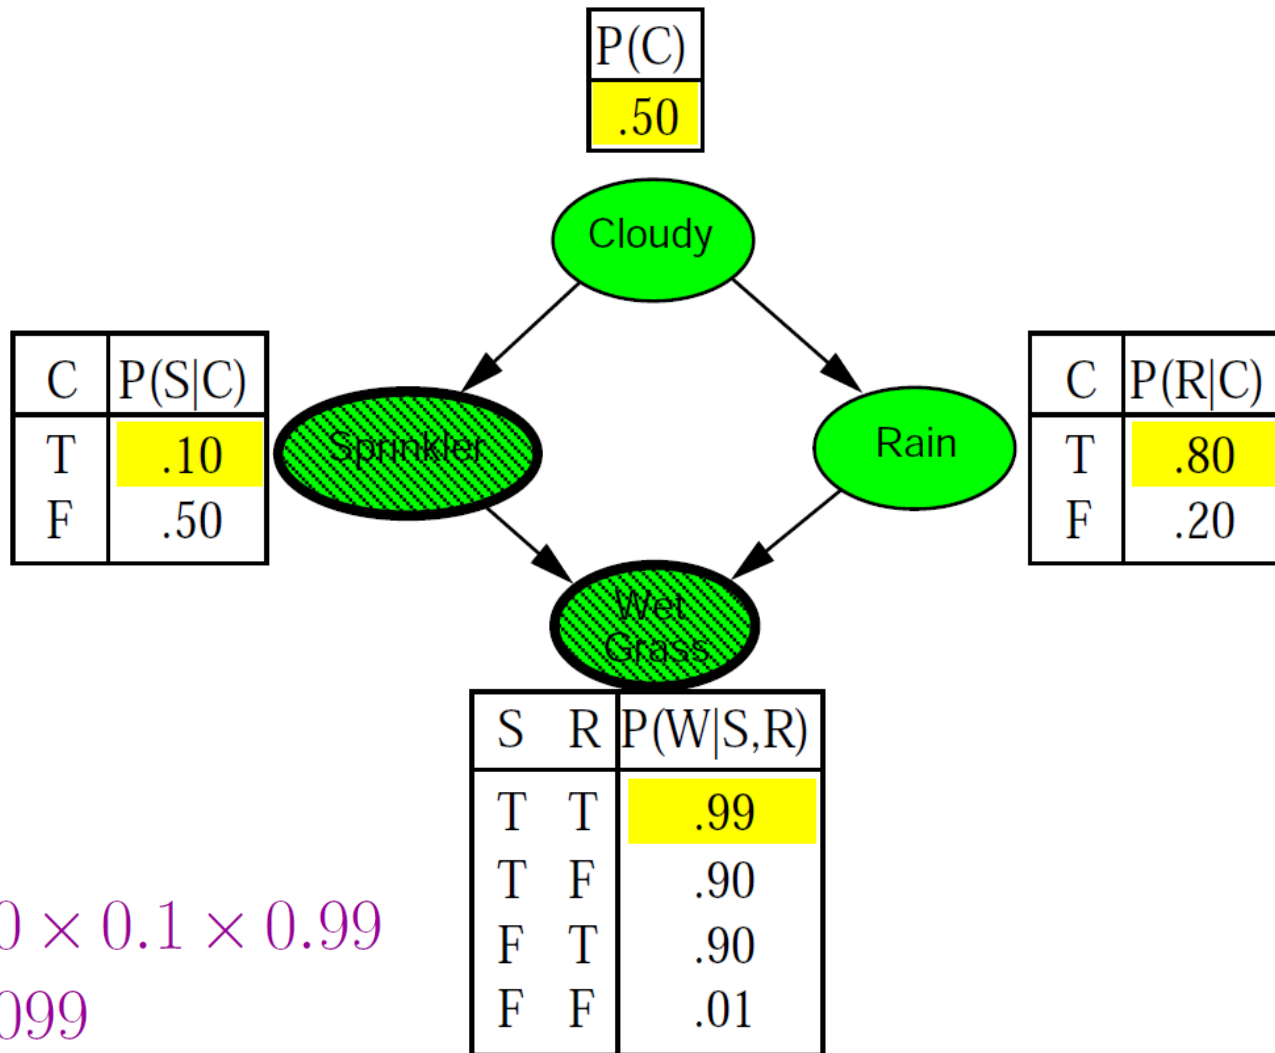


$$w = 1.0 \times 0.1$$

似然加权示例



似然加权示例



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

似然加权分析

- ❖ WeightedSample 的采样概率为

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

注意：这里只关注了 **ancestors** 中的证据变量

→ 存在先验和后验分布之间的情况

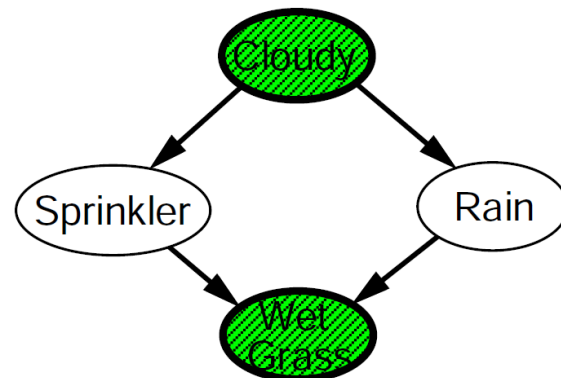
- ❖ 给定样本 \mathbf{z}, \mathbf{e} 的权重为：

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

- ❖ 加权的采样概率是

$$\begin{aligned} & S_{WS}(\mathbf{z}, \mathbf{e}) w(\mathbf{z}, \mathbf{e}) \\ &= \prod_{i=1}^l P(z_i | \text{parents}(Z_i)) \prod_{i=1}^m P(e_i | \text{parents}(E_i)) \\ &= P(\mathbf{z}, \mathbf{e}) \text{ (by standard global semantics of network)} \end{aligned}$$

- ❖ 似然加权采样获得了一致的概率估计，但随着证据变量的增多其性能仍会急剧下降
 - 只有很少的样本具有近似完整的权重



通过 MCMC 进行近似推理

❖ 网络状态 = 对所有变量的当前赋值

- 给定 Markov 覆盖，通过采样一个变量来产生下一个状态——Gibbs采样
- 证据变量保持不变，轮流采样其他的每个变量

```
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( $\mathbf{N}[X]$ )
```

使用 markov 覆盖
计算采样概率

❖ 也可以每次随机选择一个变量进行采样（均匀分布）

Markov 链

❖ 针对 $Sprinkler = true, WetGrass = true$ ，有四种状态



MCMC 示例

- ❖ 估计 $P(\text{Rain}|\text{Sprinkler} = \text{true}, \text{WetGrass} = \text{true})$
 - 给定 *Cloudy* 和 *Rain* 的 Markov 覆盖，重复采样
 - 统计 *Rain* 为 *true* 和 *false* 的次数
- ❖ E.g., 总共访问了 100 个状态
 - 31 个是 *Rain = true* 的，69 个是 *Rain = false* 的
$$\hat{P}(\text{Rain}|\text{Sprinkler} = \text{true}, \text{WetGrass} = \text{true}) = \text{NORMALIZE}(\langle 31, 69 \rangle) = \langle 0.31, 0.69 \rangle$$
- ❖ 定理（链稳态分布）：长期来看，在每个状态上所消耗时间与其后验概率成正比

Markov 覆盖采样

❖ *Cloudy* 的 Markov 覆盖是

Sprinkler 和 *Rain*

❖ *Rain* 的 Markov 覆盖是

Cloudy, *Sprinkler* 和 *WetGrass*

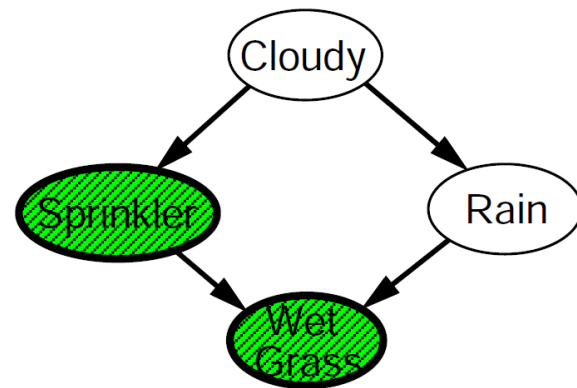
❖ 给定 Markov 覆盖下，概率计算公式为：

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

- 在消息并行传递系统中是容易实现的

❖ 主要计算问题：

- 判断是否已经收敛是困难的
- 如果 Markov 覆盖较大，计算可能是浪费的，因为 $P(X_i | mb(X_i))$ 不会变化太大



总结

❖ 通过变量消元进行精确推理

- 在多形树上是多项式时间的，在一般图上是 NP-hard
- 空间复杂度与时间复杂度相当，对拓扑很敏感

❖ 通过 LW, MCMC 进行近似推理

- 当存在大量下游证据变量时，LW 是低效的
- LW, MCMC 通常对拓扑是不敏感的
- 当概率接近于 1 或 0 时，收敛速度将很慢
- 能够处理离散变量和连续变量的任意组合

谢谢聆听！

