
Inteligencia Artificial

Inferencia Aproximada en Redes Bayesianas

Jorge Luis Guevara Diaz

www.jorge.sistemasyservidores.com

Que veremos?

- Inferencia exacta por ennumeracion
- Inferencia exacta por eliminacion de variables
- Inferencia aproximada por simulación estocástica
- Inferencia aproximada por método de Monte Carlo y cadenas de Markov

Inferencia aproximada por simulación estocástica



■ Idea básica:

- Realizar N muestras de una distribución de muestras S
- Calcular la probabilidad a posteriori aproximada \bar{P}
- Mostrar su convergencia a la probabilidad verdadera P

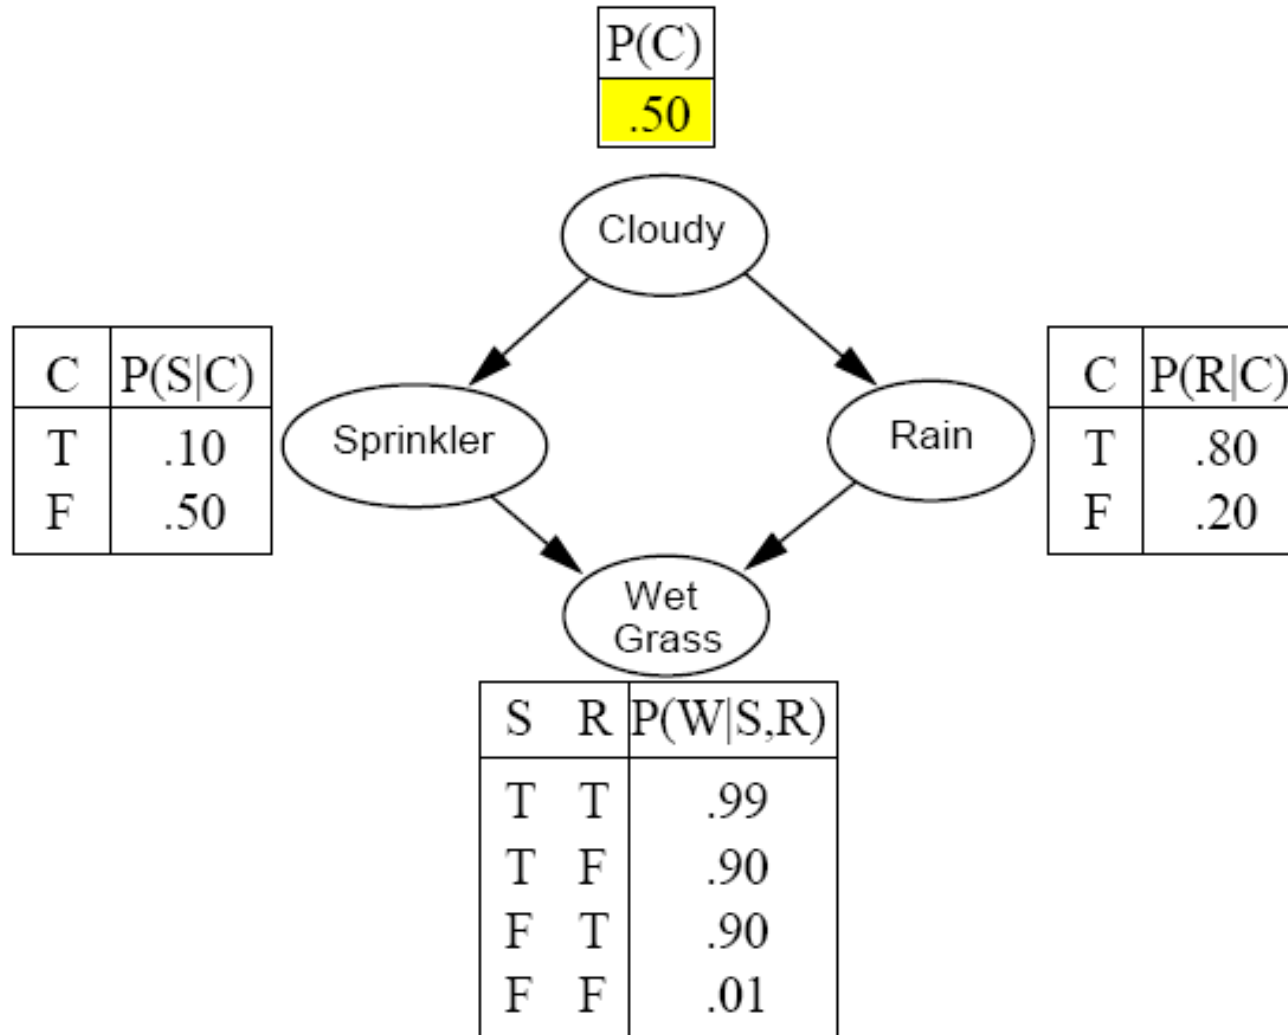
■ Algoritmos

- Muestreo de una red bayesiana
- **Rejection sampling (RS)** : rechazar las muestras que no están de acuerdo con la evidencia (rechazo de evidencia)
- **Likelihood weighting (LW)** : usa la evidencia para ponderar las muestras (Ponderación)
- **Markov chain Monte Carlo (MCMC)** : Método de Monte Carlo con Cadenas de Markov

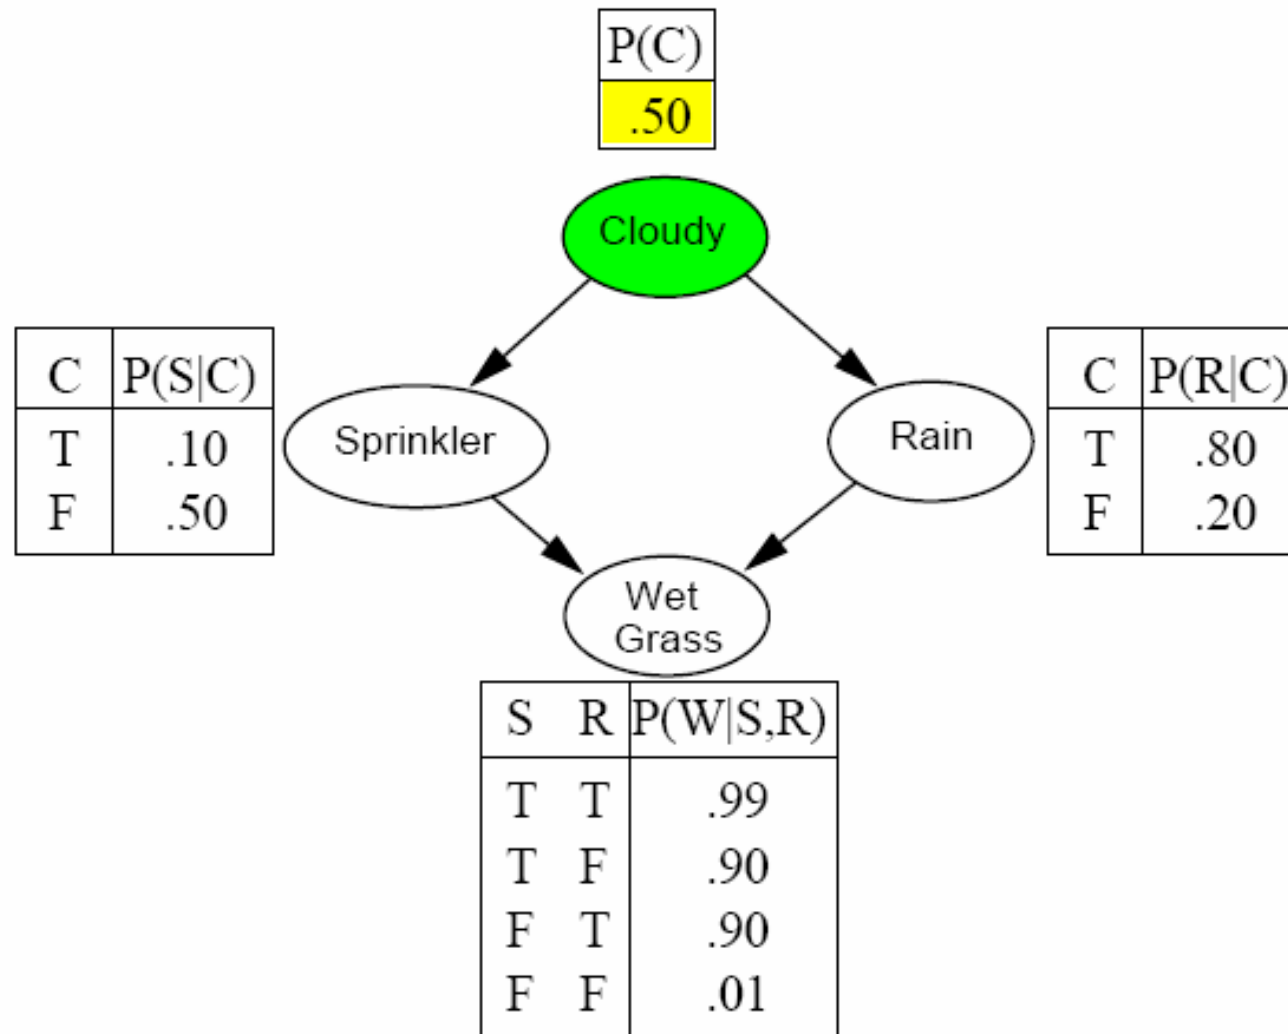
Muestreo de una red bayesiana

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

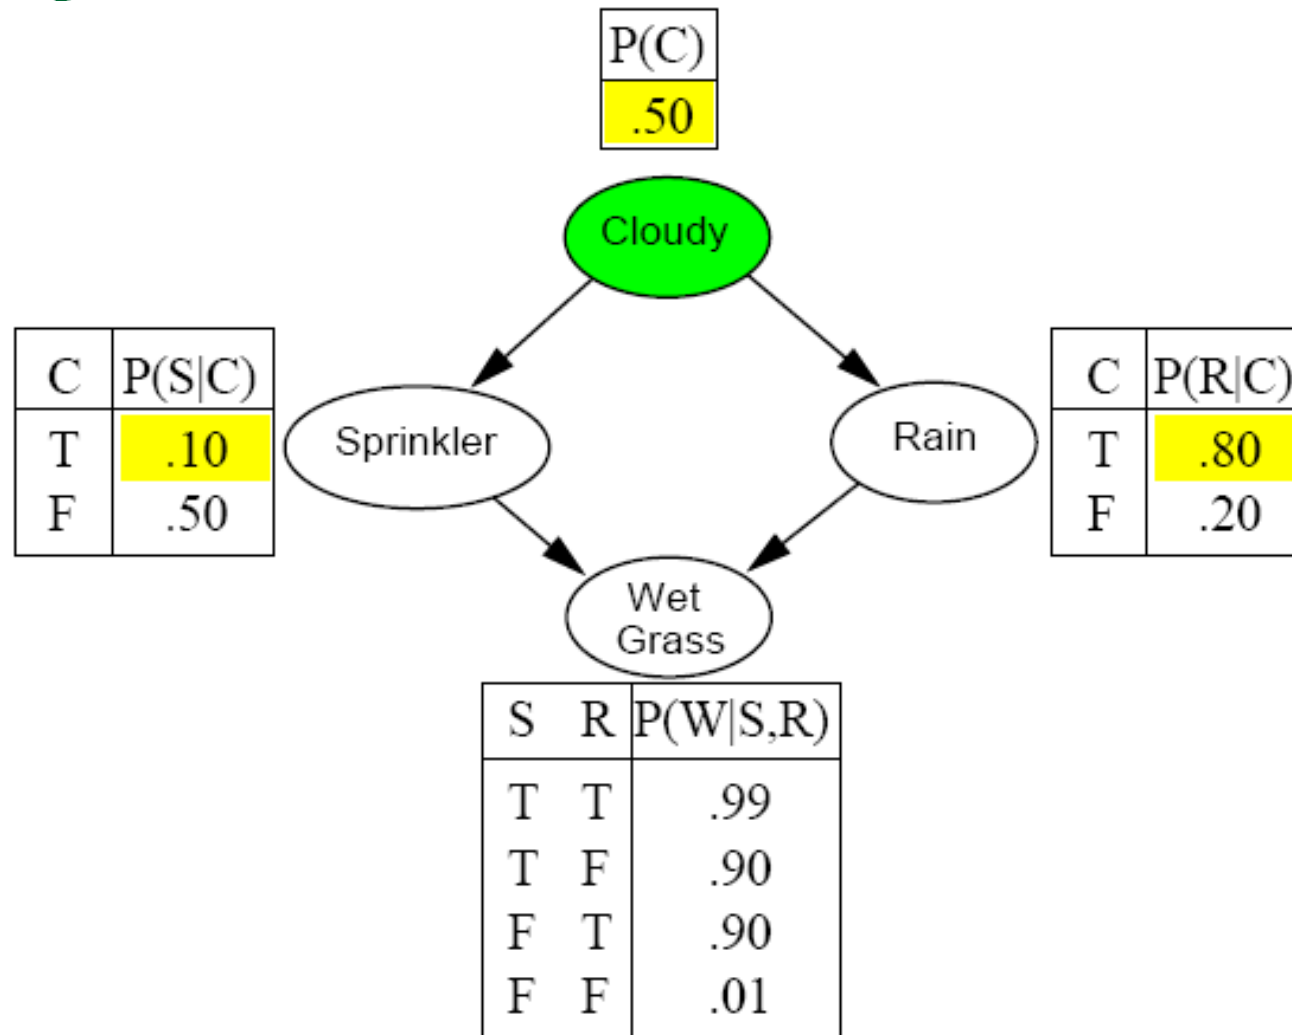
Ejemplo



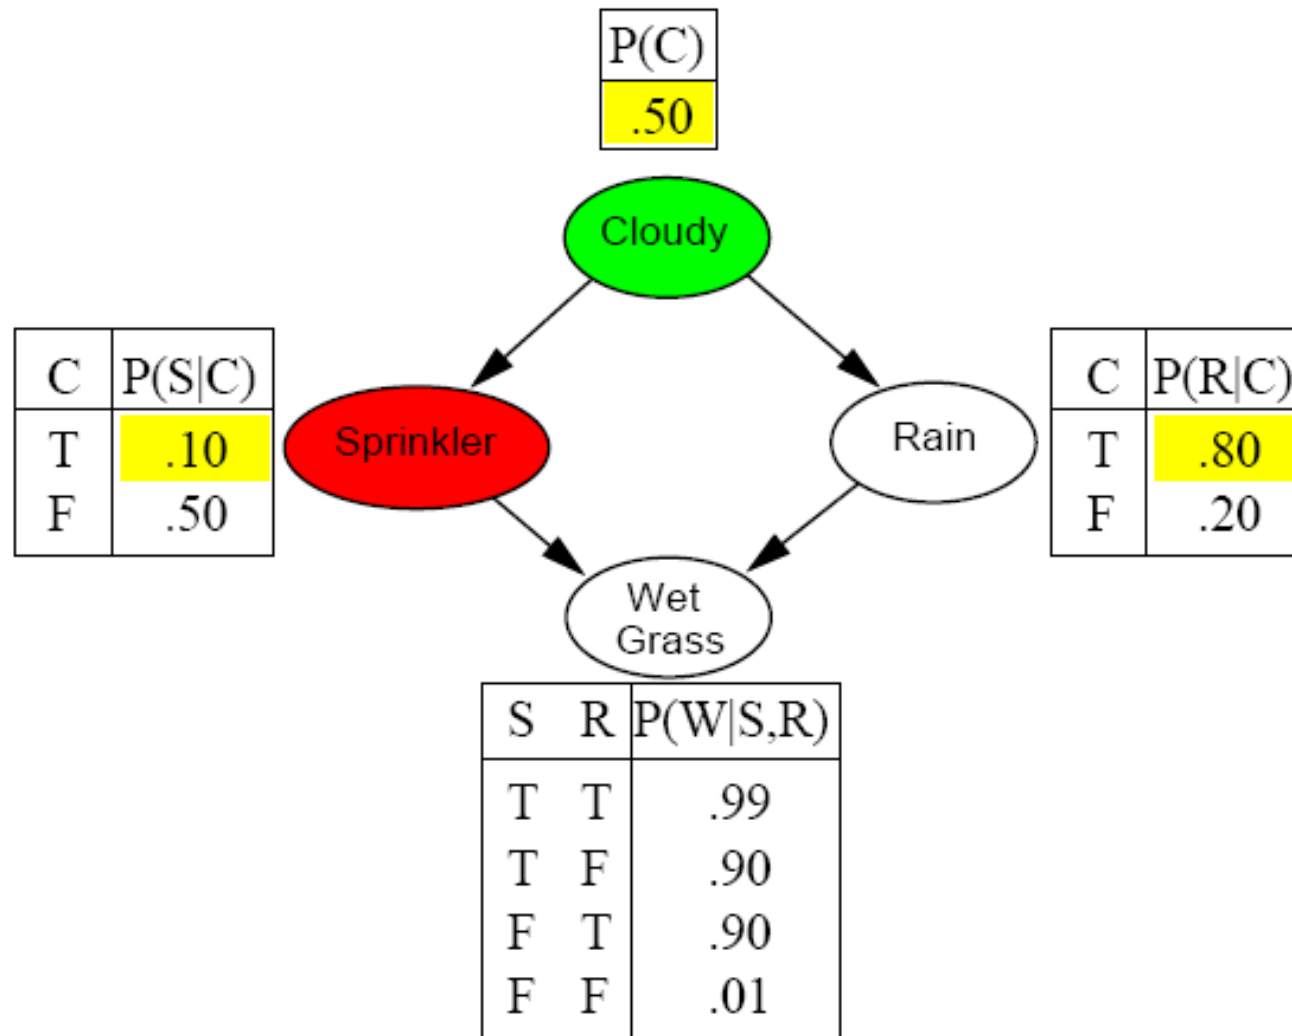
Ejemplo



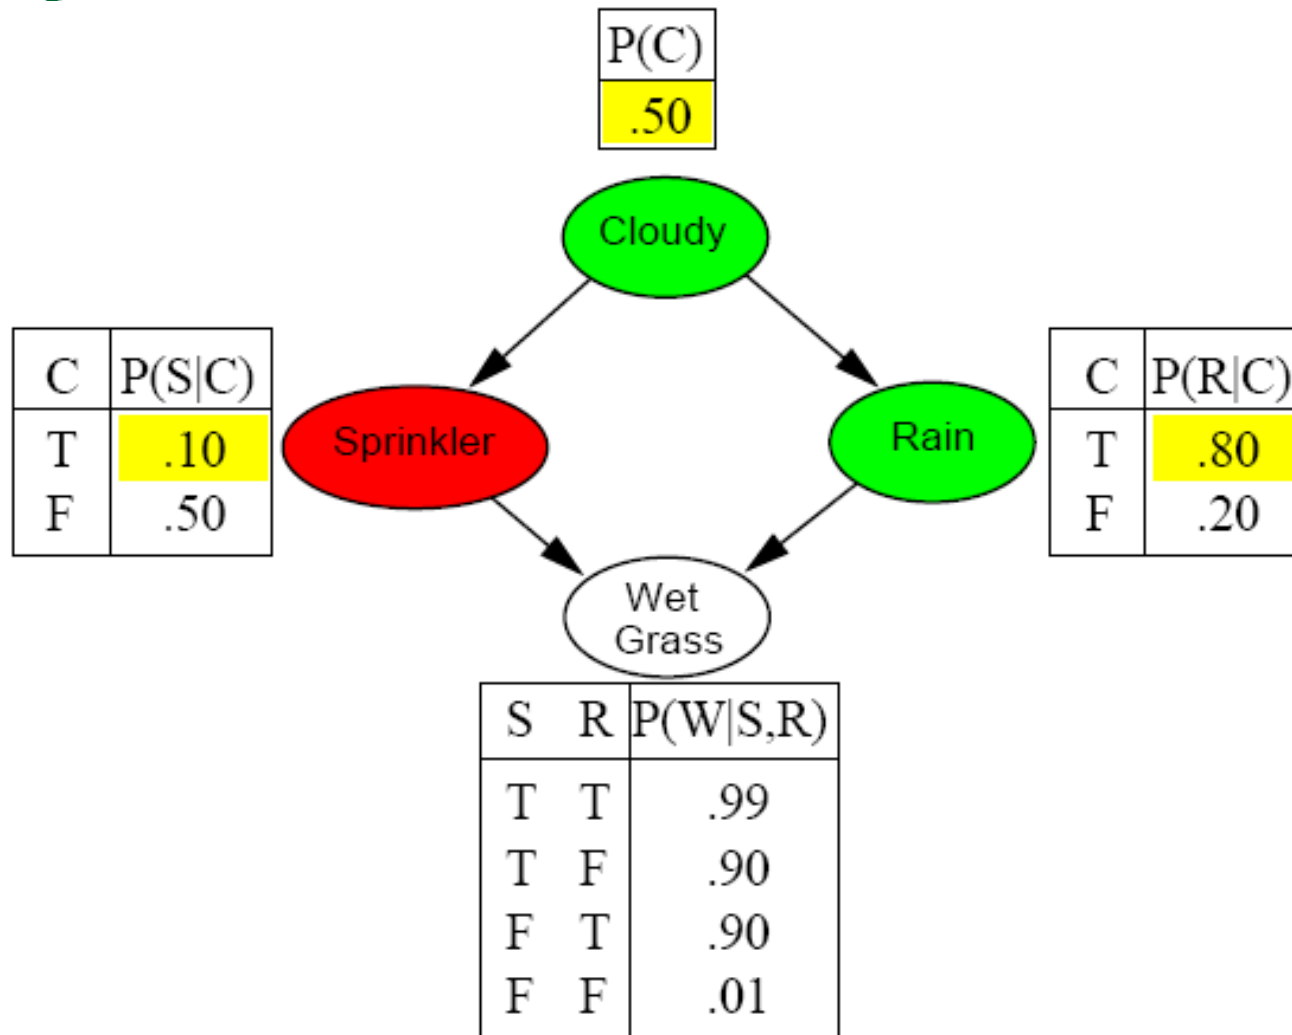
Ejemplo



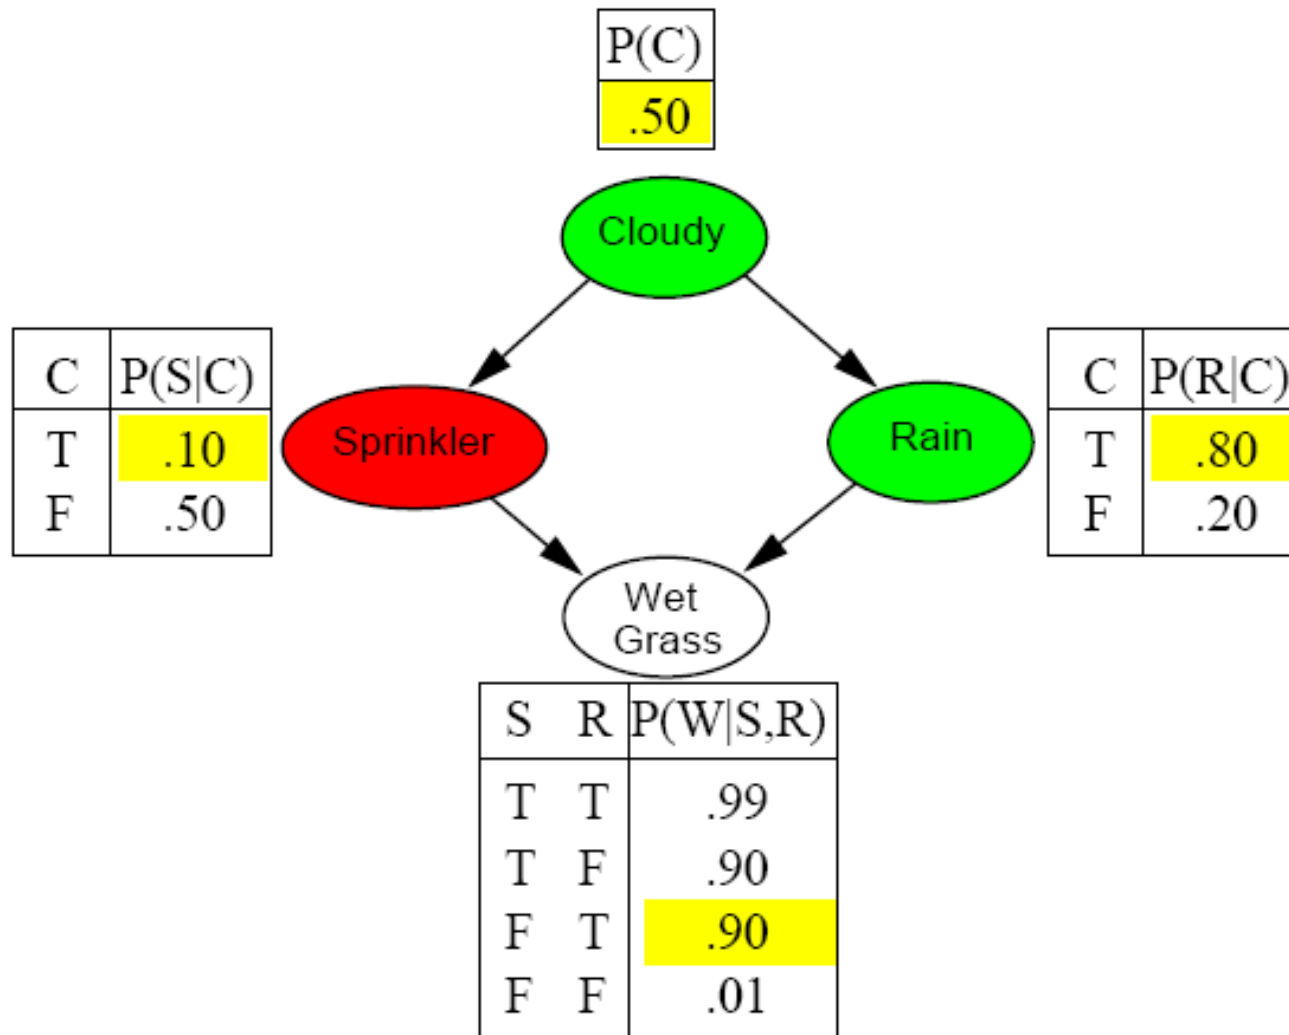
Ejemplo



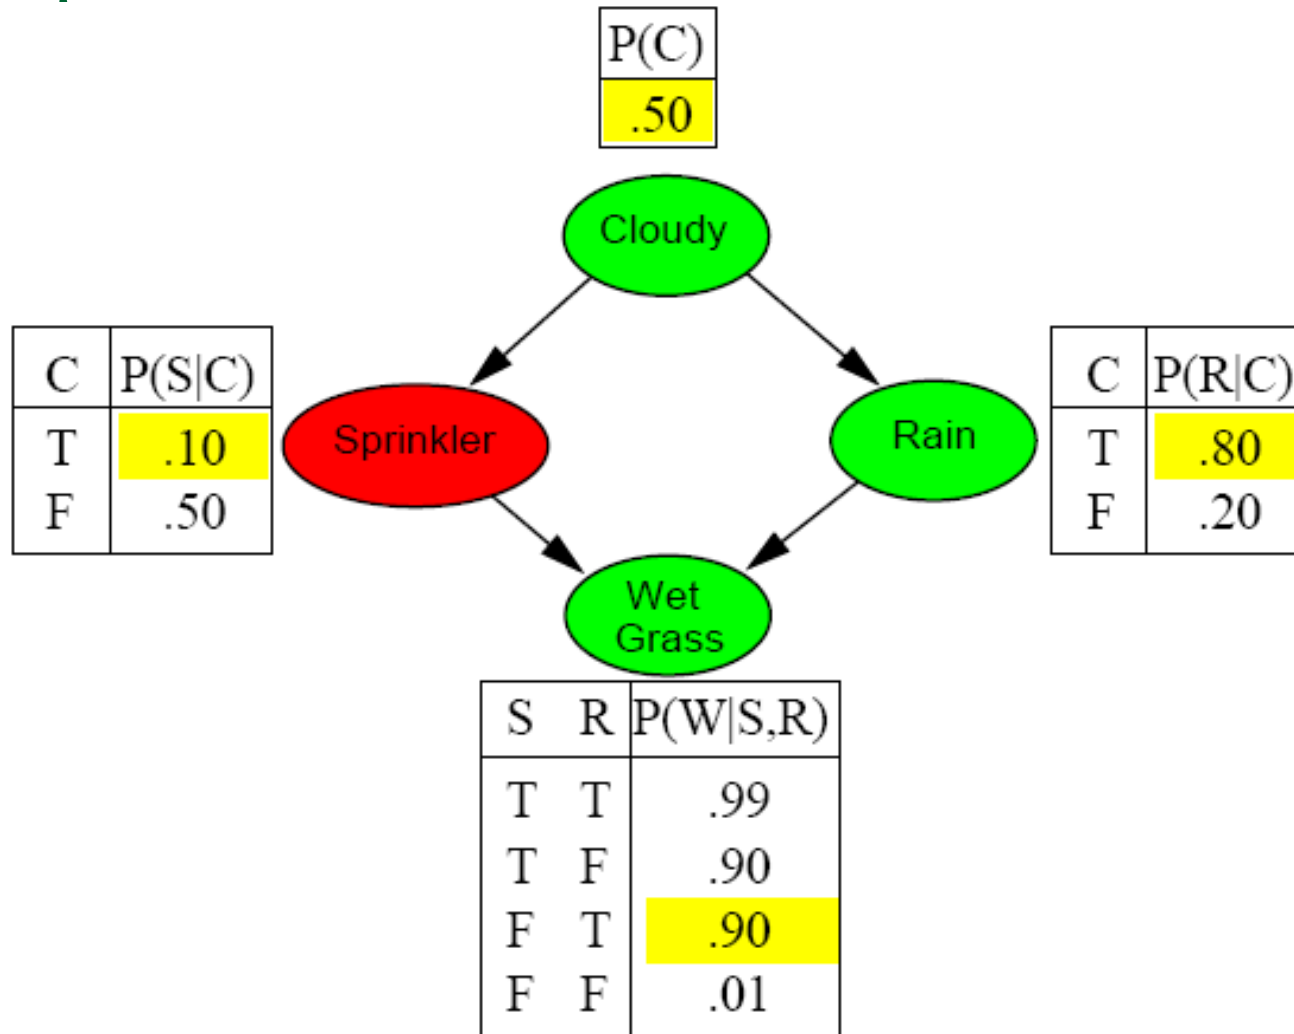
Ejemplo



Ejemplo



Ejemplo



Muestreo de una red bayesiana

- La probabilidad de que PRIORSAMPLE- genera un evento particular
 $S_{PS}(x_1 \dots x_n) = \prod_{i=1}^n P(x_i | \text{parents}(X_i)) = P(x_1 \dots x_n)$

Es la verdadera probabilidad a priori

Ejemplo:

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

Sea $N_{PS}(x_1 \dots x_n)$ el número de muestras generadas para el evento x_1, \dots, x_n

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

Las estimaciones derivadas de PRIOR-SAMPLE son consistentes

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

Muestreo de una red bayesiana

- En

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

- Se espera para un N “grande” que el 32.4% de las muestras pertenezcan a este evento

- Ejemplo si se generan 1000 muestras de la red anterior, y 511 tienen rain=true, entonces

$$P_{\text{aprox}}(\text{Rain=true}) = 0.511$$

Algoritmo RS (Rejection sampling) – Muestreo por rechazo de evidencia

- $\hat{P}(X|e)$ Se calcula a partir de las muestras que están de acuerdo con la evidencia

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

- Ejemplo: Estimar $P(\text{Rain} \setminus \text{Sprinkler} = \text{true})$ usando 100 muestras
27 tienen Sprinkler = true
8 tienen Rain = true y 19 tienen Rain = false
 $P(\text{Rain} \setminus \text{Sprinkler} = \text{true}) = \text{Normalizar} (\langle 8, 19 \rangle) = \langle 0.296, 0.704 \rangle$

Análisis del Algoritmo RS (Rejection sampling)

- Similar al procedimientos empíricos de estimación en el mundo real

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

- Retorna estimaciones posteriores consistentes
- Problema: Muy costoso si $\mathbf{P}(\mathbf{e})$ es muy pequeño
- $\mathbf{P}(\mathbf{e})$ decrece exponencialmente con el número de variables de evidencia

Algoritmo LW (Likelihood weighting)


- **Idea:** Mantener fijas las variables e evidencia y ponderar cada muestra de acuerdo al likelihood de acuerdo a la evidencia

```
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  $w \leftarrow w \times P(X_i = x_i \mid \text{parents}(X_i))$   
      else  $x_i \leftarrow$  a random sample from  $P(X_i \mid \text{parents}(X_i))$   
  
  return  $x, w$ 
```

Algoritmo LW (Likelihood weighting)


- $P(\text{Rain} \setminus \text{Sprinkler} = \text{true}, \text{Wet Grass} = \text{true})$
 - Muestrear $P(\text{Cloudy})$ suponer true
 - Sprinkler es evidencia
 - $w = w \times P(\text{Sprinkler} = \text{true} \setminus \text{Cloudy} = \text{true}) = 0.1$
 - Muestrear $P(\text{Rain} \setminus \text{cloudy} = \text{true})$ suponer retorna true
 - Wet Grass es evidencia
 - $w = w \times P(\text{Wet Grass} = \text{true} \setminus \text{Sprinkler} = \text{true}, \text{Rain} = \text{true}) = 0.099$




$$w = 1.0$$



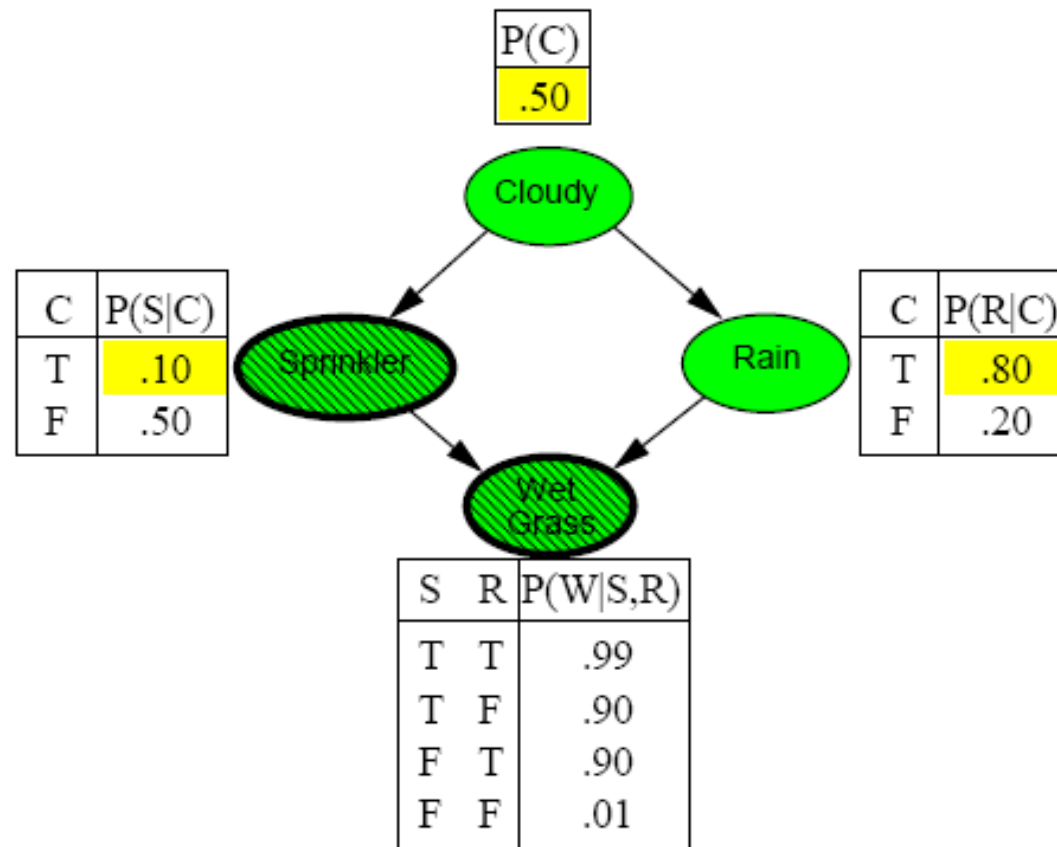
$w = 1.0$



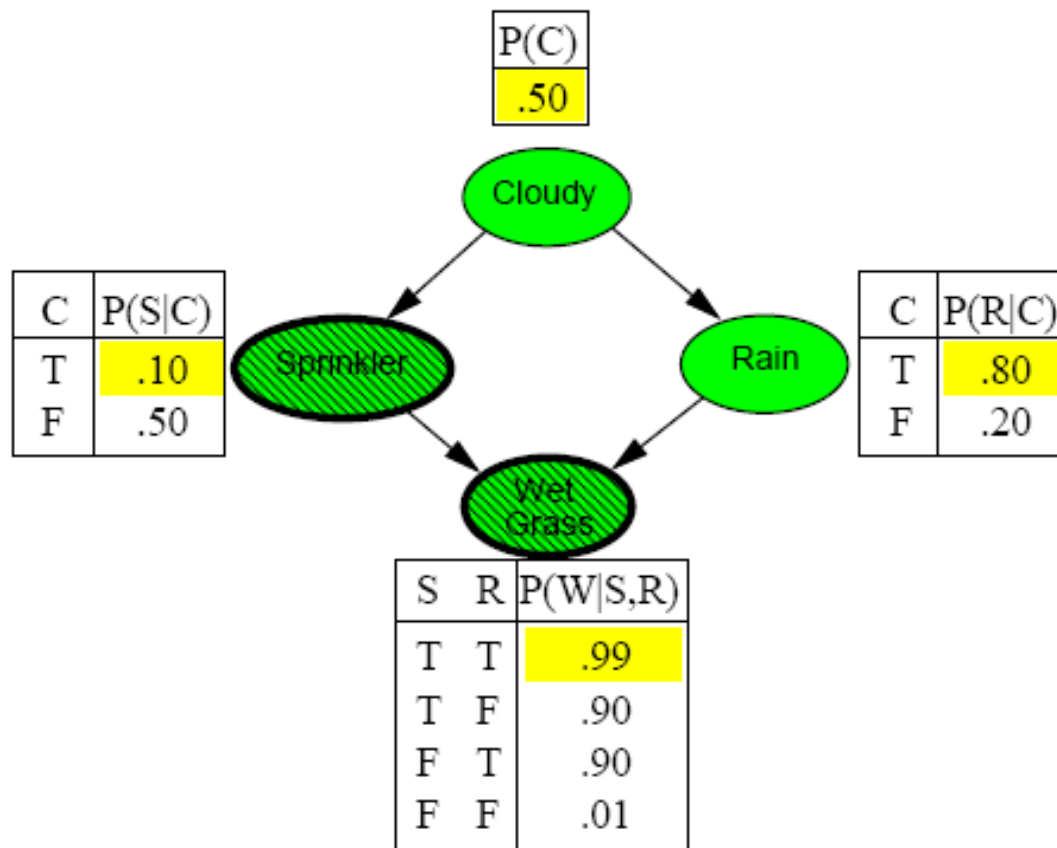
$w = 1.0$



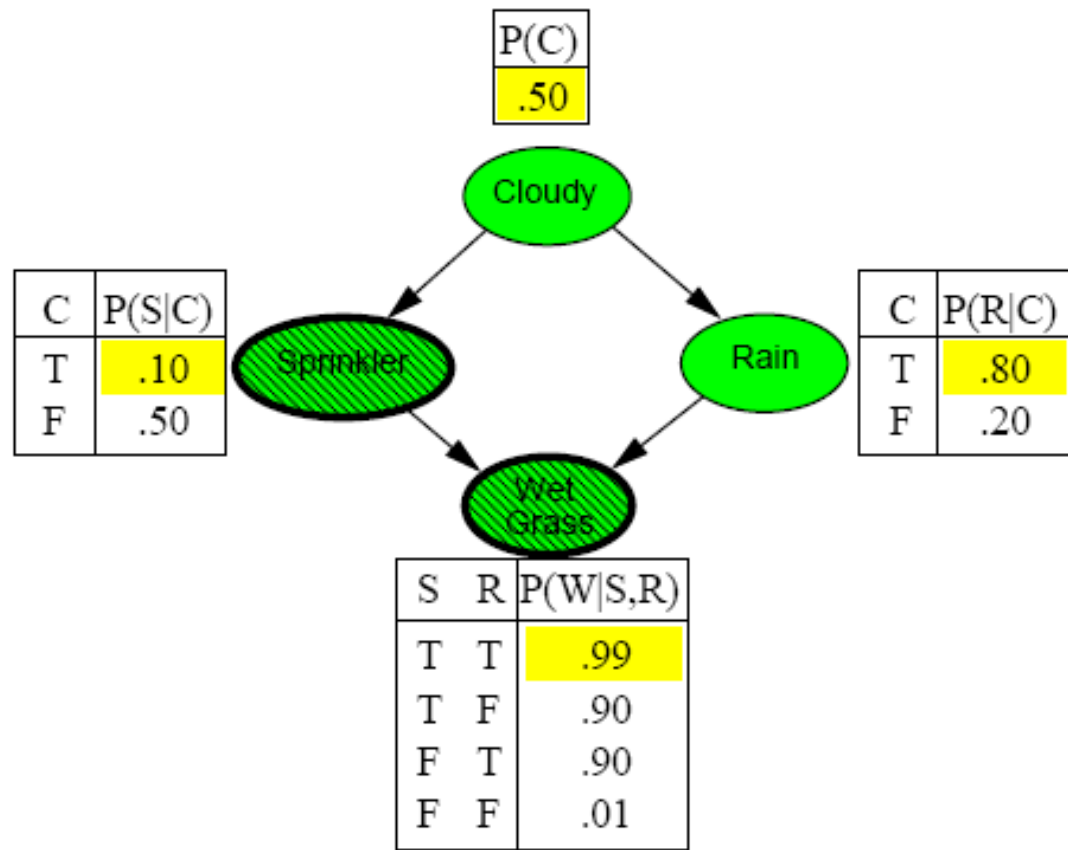
$$w = 1.0 \times 0.1$$



$$w = 1.0 \times 0.1$$



$$w = 1.0 \times 0.1$$



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

$$\begin{aligned}\hat{P}(x|\mathbf{e}) &= \alpha \sum_{\mathbf{y}} N_{WS}(x, \mathbf{y}, \mathbf{e}) w(x, \mathbf{y}, \mathbf{e}) \\ &\approx \alpha' \sum_{\mathbf{y}} S_{WS}(x, \mathbf{y}, \mathbf{e}) w(x, \mathbf{y}, \mathbf{e}) \\ &= \alpha' \sum_{\mathbf{y}} P(x, \mathbf{y}, \mathbf{e}) \\ &= \alpha' P(x, \mathbf{e}) = P(x|\mathbf{e})\end{aligned}$$

Referencias Bibliográficas

- Capitulo 14 Artificial Intelligence: A Modern Approach, Russell and Norvig
- <http://www.cs.iastate.edu/~cs572/studyguide.html>
- <http://www.aaai.org/AITopics/pmwiki/pmwiki.php/AITopics/Uncertainty>