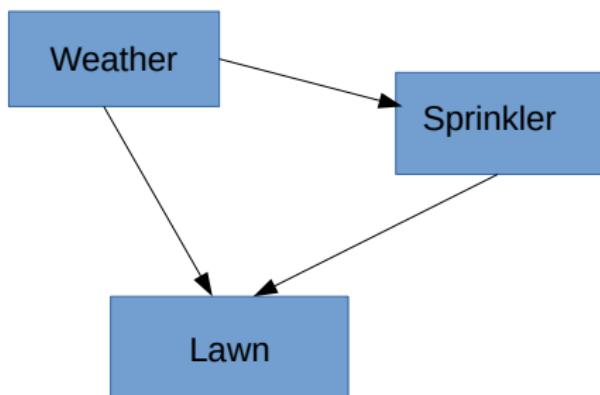


Probabilistic Knowledge Representation and Reasoning

based on Gilad Barkan's slides, slideshare

Redes de Crenças



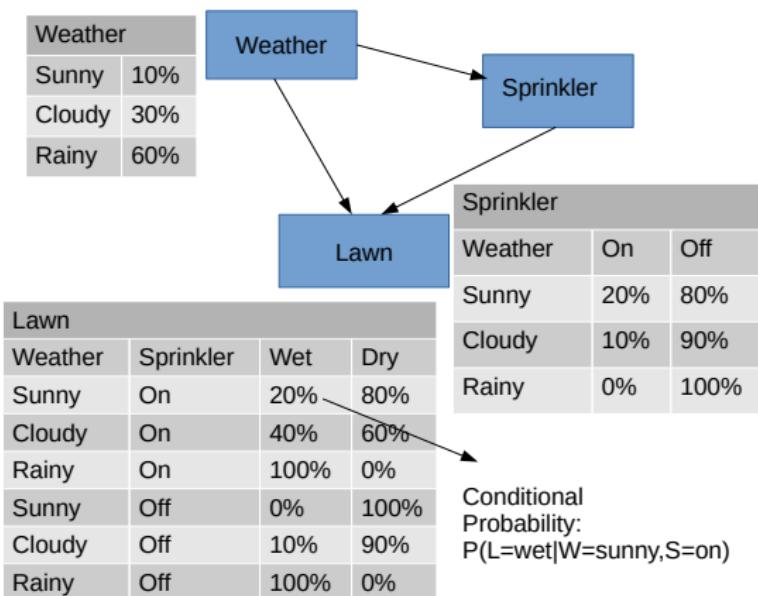
Redes de Crenças

- Probabilistic Graphical Model (PGM)
- Graphical (Directed Acyclic Graph) Model
- Nós são variáveis (features):
 - ▶ cada uma é uma variável aleatória com uma distribuição de probabilidade
 - ▶ Cada uma com um conjunto possível de parâmetros/valores/estados:
 - Weather = {sunny, cloudy, rainy}; Sprinkler={off,on}; Lawn={dry,wet}
 - Cenário possível: {Weather=rainy, Sprinkler=off, Lawn = wet}
- Arestas (links) representam relações entre as variáveis
- Arestas **podem** indicar causalidade (por exemplo, “rainy weather” ou “sprinkler” podem causar “wet lawn”).

Redes de Crenças

- Tabela de Probabilidades Condicionais: usada para armazenar todas as crenças relativas a todos os possíveis estados de um nó (variável)

Redes de Crenças



Inferência Bayesiana

- Após ter um modelo composto por **grafo** e **TPCs**, podemos responder questões do tipo:
 - ▶ Dado que choveu, será que a grama está molhada? (trivial)
 - ▶ Dado que a grama está molhada, qual pode ser a razão?
 - “rainy weather”?
 - “sprinkler on”?

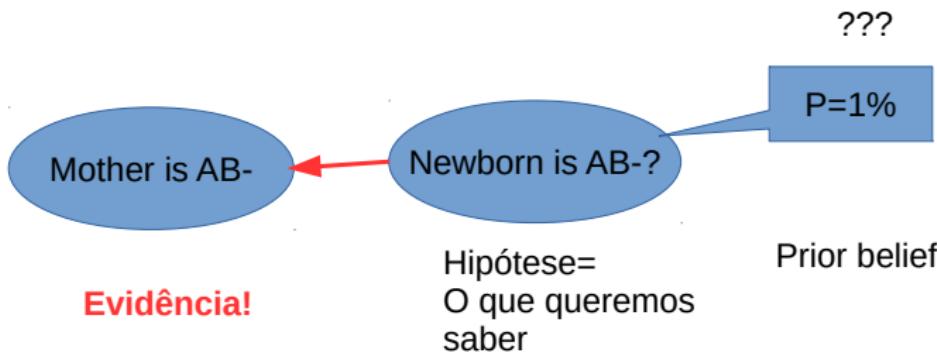
Teorema de Bayes em Ação!



Hipótese=
O que queremos
saber

Prior belief

Teorema de Bayes em Ação!



Sabendo a evidência, P pode deixar de ter valor 0.01
Nova probabilidade para P: **a posteriori update belief**

Inferência Bayesiana

- Do nosso exemplo, o que podemos prever usando o teorema de Bayes?
- Possível métrica (Regra de decisão Bayesiana): Maximum a Posteriori Probability (MAP)
 - ▶ $P(\text{Weather}=\text{rainy}|\text{Lawn}=\text{wet}) = 0.93;$
 - $P(\text{Sprinkler}=\text{on}|\text{Lawn}=\text{wet})=0.016$
- Neste caso, a resposta é: a grama está molhada porque choveu!