

Redes *Bayesianas*: o que são, para que servem, algoritmos e exemplos de aplicações.

ROBERTO LIGEIRO MARQUES¹
INÊS DUTRA¹

¹Coppe Sistemas – UFRJ
{ligeiro,ines}@cos.ufrj.br

Resumo: Redes *bayesianas* são grafos acíclicos dirigidos que representam dependências entre variáveis em um modelo probabilístico. Esta abordagem representa uma boa estratégia para lidar com problemas que tratam incertezas, onde conclusões não podem ser construídas apenas do conhecimento prévio a respeito do problema. O presente trabalho aborda algumas questões básicas a respeito de modelos probabilísticos, teoria de grafos e sua representação em redes bayesianas.

Palavras Chaves: redes *bayesianas*, IA, DAG, probabilidade condicional.

1 Introdução

A inteligência tem sido matéria de estudo dos seres humanos por mais de 2000 anos¹. O sonho do desenvolvimento de uma máquina pensante tem sido fonte de pesquisa desde o desenvolvimento das primeiras máquinas computadas, em meados dos anos 40². A união destas duas áreas de pesquisa deu origem à disciplina chamada, Inteligência Artificial.

Atualmente, estudos em inteligência artificial podem ser divididos em duas grandes áreas: o desenvolvimento de sistemas que agem como humanos (robôs) e o desenvolvimento de sistemas que agem racionalmente.

Dentro do contexto dos sistemas que agem racionalmente, duas abordagens principais podem ser utilizadas: raciocínio lógico e raciocínio probabilístico. O raciocínio lógico pondera sobre o conhecimento prévio a respeito do problema e, sobre esta base de conhecimento retira suas conclusões. Esta abordagem, apesar de poderosa, pode não ser útil em situações onde não se conhece previamente todo o escopo do problema, para estes casos, o raciocínio probabilístico surge como uma boa opção.

Um sistema que possa atuar em situações de incerteza deve ser capaz de atribuir níveis de confiabilidade para todas as sentenças em sua base de conhecimento, e ainda, estabelecer relações entre as sentenças. Redes *bayesianas* oferecem uma abordagem para o raciocínio probabilístico que engloba teoria de grafos, para o estabelecimento das relações entre sentenças e ainda, teoria de probabilidades, para a atribuição de níveis de confiabilidade³.

A década de 90 marcou o início da maior parte das pesquisas realizadas a respeito das redes *Bayesianas*. Desde esta época, as redes *Bayseanas* vêm sendo utilizadas para a solução de vários

¹ Desde 463 BC, iniciando com os filósofos gregos Platão, Aristóteles e Sócrates.

² O primeiro trabalho de IA reconhecido foi: McCulloch e Pitts, 1943.

³ Uma alternativa a esta abordagem seria o uso de níveis de verdade de uma sentença (em contrapartida a níveis de confiabilidade) - lógica *fuzzy*.

tipos de problemas em diversas áreas, como por exemplo: diagnóstico médico (Heckerman 1990, Franklin 1989), aprendizado de mapas (Dean 1990), interpretação de linguagem (Goldman 1989), visão (Levitt, 1989).

O restante deste trabalho está organizado da seguinte forma: a próxima sessão apresenta algumas questões a respeito de probabilidades, a sessão 3 introduz algumas questões a respeito das redes *Bayesianas*, suas características e métodos para construção de redes. A sessão 4 demonstra um algoritmo para realização de inferências em redes *Bayesianas*, em seguida, as sessões 5 e 6 apresentam, respectivamente, alguns exemplos de aplicações e a conclusão do trabalho.

2 Raciocinando sob incertezas

“A principal vantagem de raciocínio probabilístico sobre raciocínio lógico é fato de que agentes podem tomar decisões racionais mesmo quando não existe informação suficiente para se provar que uma ação funcionará”[1].

Alguns fatores podem condicionar a falta de informação em uma base de conhecimento, os principais são:

- Impossibilidade: Em alguns casos, o trabalho exigido para a inserção de todos os antecedentes ou conseqüentes que configurem uma base de conhecimento onde quaisquer inferências a respeito do domínio do problema podem ser efetuadas, pode ser muito oneroso.
- Ignorância Teórica: Em alguns casos não se possui o conhecimento de todo domínio do problema.

Lidar com falta de informação significa lidar com incertezas. Nestes ambientes é necessário utilizar conectivos que manipulem níveis de certeza e não apenas valores booleanos, verdadeiro (1) e falso (0). Assim, seria possível, por exemplo, tratar uma expressão do tipo: “*Eu tenho probabilidade 0.8 fazer um bom trabalho de IA*” ou “*A probabilidade de um trabalho de IA ser bom é 0.5*” ou “*A probabilidade de um bom trabalho de IA tirar A é 0.9*”. Com isto, uma possível questão seria: “*Quais são as minhas chances tirar A?*”. Para responder a questão é necessário se estabelecer uma regra que combine as três probabilidades. Em outras palavras, é necessário uma função que retorne um valor dadas as probabilidades, 0.8, 0.5 e 0.9. Comparativamente poderíamos dizer que lógica probabilística estende lógica proposicional, no sentido que, *probabilidade 1* representa *verdadeiro* e *probabilidade 0* representa *falso*.

Para caracterização de situações de incerteza podemos utilizar grafos representando relações causais entre eventos. Como exemplo, considere o seguinte domínio:

“Pela manha meu carro não irá funcionar. Eu posso ouvir a ignição, mas nada acontece. Podem existir várias razões para o problema. O rádio funciona, então a bateria está boa. A causa mais provável é que a gasolina tenha sido roubada durante a noite ou que a mangueira esteja entupida. Também pode ser que seja o carburador sujo, um vazamento na ignição ou algo mais sério. Para descobrir primeiro eu verifico o medidor de gasolina. Ele indica ½ tanque, então eu decido limpar a mangueira da gasolina”.

A problema anterior pode ser representado, de forma simplificada, pelos seguintes eventos: $\{sim,não\}$ Gasolina?, $\{sim,não\}$ Mangueira limpa?, $\{cheio, \frac{1}{2}, vazio\}$ Medidor, $\{sim,não\}$ Funcionando. Em outras palavras, os eventos são agrupados em variáveis que podem assumir alguns estados. Nós sabemos que o estado *Gasolina?* e o estado *Mangueira entupida?* possuem impacto direto no estado *Funcionando*, assim como *Gasolina?* tem impacto em *Medidor*. Estas informações podem ser representadas como apresenta a *figura 1*. Na figura também estão

representadas as direções do impacto da variável. Neste caso, a maior certeza em uma causa, é movida na direção positiva.




Figura 1. Rede de causalidade.

O grafo da *figura 1* possibilita a realização de algumas conclusões. Obviamente, se eu sei que a mangueira está entupida (probabilidade 1), então a certeza do não funcionamento do carro aumenta. Entretanto, minha situação é oposta. Eu sei que o carro não funciona e desejo encontrar o motivo. A suspeita de que a gasolina pode ter sido roubada aumenta a expectativa de que o medidor esteja indicando *vazio*. Lendo a informação do *Medidor* = $\frac{1}{2}$, diminuí as expectativas de que o estado *Gasolina* seja a fonte do problema, guiando a aresta *Gasolina/Funcionamento* na direção negativa. Uma vez que a expectativa do problema ter sido causado pela falta de gasolina diminuí, cresce a expectativa sobre o estado *Mangueira limpa?*. Neste instante é possível se concluir o seguinte: “*O problema não parece ser a Gasolina, então muito provavelmente deve ser a Mangueira*”.

Para fazer estas escolhas, um agente deve inicialmente possuir *preferências* entre possíveis efeitos das ações a serem tomadas. Preferências são representadas por *utilidades* (*utility* – indicação do nível de *utilidade* que possui um estado) combinadas com probabilidades, resultando na chamada: *teoria de decisão*.

Teoria de Decisão = teoria de probabilidades + teoria de utilidade

A idéia fundamental em teoria de decisão é: *um agente é racional se e somente se ele escolhe a ação que permite a maior expectativa de utilidade, ponderada pelos efeitos de todas as possíveis ações*, ou princípio da Máxima expectativa de Utilidade (MEU). O algoritmo para um agente que utilize *Teoria de Decisão* seria:

```

Função RP-Agente(percepção) retorna ação
{
  Estático: conjunto de sentenças probabilísticas a respeito do problema.

  Calcula novas probabilidades para o estado atual baseado na evidência
  disponível incluindo a percepção atual e a ação anterior.

  Calcula as probabilidades para as possíveis ações, dado a descrição das
  ações e as probabilidades atuais.

  Seleciona a ação com a maior expectativa.

  Retorna ação.
}
  
```

A próxima sessão apresenta algumas questões a respeito do cálculo de probabilidades.

2.1 Cálculo de probabilidades

- Axioma base: (probabilidade incondicional)

A probabilidade $P(a)$ de um evento a é um número dentro do intervalo $[0,1]$.

- $P(a) = 1$ sss a é certo.
- Se a e b são mutuamente exclusivos, então: $P(a \vee b) = P(a) + P(b)$

Por exemplo, considerando que *Cárie* denota a proposição de que um paciente em particular tenha cárie, então: $P(\text{Cárie}) = 0.1$, significa dizer que, na ausência de outra informação, o sistema assinalará a probabilidade 0.1 ao evento ter cárie.

Proposições podem também incluir igualdades envolvendo variáveis aleatórias. Por exemplo, caso estejamos interessados em uma variável aleatória, *Tempo*, poderíamos considerar:

- $P(\text{Tempo} = \text{Ensolarado}) = 0.7$
- $P(\text{Tempo} = \text{Chuvoso}) = 0.2$
- $P(\text{Tempo} = \text{Nublado}) = 0.1$

Em alguns casos, podemos nos referir apenas a variável *Tempo*, como um vetor de probabilidades $P(\text{Tempo}) = \langle 0.7, 0.2, 0.1 \rangle^4$.

E ainda, proposições podem assumir o domínio booleano $\langle \text{verdadeiro}, \text{falso} \rangle$, neste caso, a expressão $P(\text{Cárie})$ pode ser vista como $P(\text{Cárie} = \text{verdadeiro})$ e, analogamente, $P(\neg \text{Cárie}) = P(\text{Cárie} = \text{falso})$.

Para expressar todas as combinações de valores de duas probabilidades podemos utilizar $P(\text{Tempo}, \text{Cárie})$, que pode ser vista como uma tabela de probabilidades conjunta (*joint probabilities*) de $\text{Tempo} \wedge \text{Cárie}$, de 3 x 2 posições.

- Probabilidade condicional:

Probabilidade condicional $P(a|b) = x$, pode ser interpretada como: “Dado o evento b , a probabilidade do evento a é x ”.

- Regra fundamental: $P(a|b) = P(a,b)/P(b)$, ou $P(a|b)P(b) = P(a,b)$. Onde $P(a,b)$ é a probabilidade do evento conjunto do evento $a \wedge b$.

Por exemplo, $P(\text{Cárie}|\text{Dor}) = 0.8$, indica que caso um paciente esteja com dor (de dente) e nenhuma outra informação esteja disponível, então, a probabilidade de o paciente ter uma cárie é de 0.8. É importante ressaltar que $P(A|B)$ pode ser utilizado apenas quando toda informação disponível é B . Uma vez que outra variável C é conhecida, deve-se reconsiderar para $P(A|B \wedge C)$.

- $P(a,b)=P(b,c)$, então de i , chegamos em $P(a|b)P(b) = P(b|a)P(a)$, que resulta em: $P(b|a) = P(a|b)P(b)/P(a)$, chamada Regra de Bayes.
- Em alguns casos podemos estar interessados em uma probabilidade segundo uma evidência e , neste caso, aplica-se: $P(a|b,e)P(b|e) = P(a,b|e)$

⁴ Variáveis vetor serão representadas por letras maiúsculas: $A, P(A)$, etc.

Em geral, se estamos interessados em uma proposição A , e temos o conhecimento da evidência B , devemos calcular $P(A|B)$. Em alguns casos este valor não está disponível na base de conhecimento e, portanto, devemos utilizar algum método de inferência para obtê-lo.

- **Conjunção de Probabilidades**

Seja X uma variável aleatória com n estados, x_1, \dots, x_n , e $P(X)$ a distribuição de probabilidades para estes estados,

$P(X) = (a_1, \dots, a_n)$; $a_i \geq 0$; $\sum a_i = 1$, onde a_i é a probabilidade de X estar no estado a_i , $P(X=a_i)$.

Se a variável Y possui os estados b_1, \dots, b_m , então $P(X|Y)$ representa uma tabela $n \times m$ contendo os valores $P(a_i|b_j)$. Por exemplo:

| | | | |
|-------|-------|-------|-------|
| | b_1 | b_2 | b_3 |
| a_1 | 0.4 | 0.3 | 0.6 |
| a_2 | 0.6 | 0.7 | 0.4 |

Tabela1. $P(X|Y)$

A conjunção de probabilidades para as variáveis A e B , ou $P(A,B)$, é também uma tabela $n \times m$, representada pela probabilidade de cada configuração (a_i, b_j) . Aplicando a regra $P(A|B) = P(A,B)/P(B)$, para as variáveis X e Y e a tabela1, teríamos: (considerando $P(Y) = \langle 0.4, 0.4, 0.2 \rangle$)

| | | | |
|-------|-------|-------|-------|
| | b_1 | b_2 | b_3 |
| a_1 | 0.16 | 0.12 | 0.12 |
| a_2 | 0.24 | 0.28 | 0.08 |

Tabela2. $P(X,Y)$

A probabilidade $P(X)$ pode ser então calculada a partir da tabela2, calculando-se: $P(a_i) = \sum P(a_i, b_j)$. Este cálculo é chamado *marginalização* de B em $P(A,B)$. O resultado para a tabela2 será: $P(X) = \langle 0.4, 0.6 \rangle$.

E ainda, aplicando a regra de *Bayes* sob a tabela1, obteríamos $P(Y|X)$.

| | | |
|-------|-------|-------|
| | a_1 | a_2 |
| B_1 | 0.4 | 0.4 |
| B_2 | 0.3 | 0.47 |
| B_3 | 0.3 | 0.13 |

Tabela3. $P(Y|X)$

Considerando uma situação real, podemos imaginar um problema contendo centenas ou milhares de variáveis. Considerando o uso apenas de variáveis que assumam valores booleanos, teríamos a necessidade do cálculo de 2^n entradas para a tabela de conjunção de probabilidades do sistema. Ou seja, um crescimento exponencial em relação ao número de variáveis. O que pode se

tornar algo infactível de se computar. Entretanto, sendo possível a computação de todos os valores, o sistema será capaz de obter qualquer probabilidade que se esteja interessado.

2.1.1 Aplicando a Regra de Bayes

Para aplicação da regra de *Bayes* precisamos de três termos: uma probabilidade condicional e duas incondicionais. Vamos considerar um exemplo de diagnóstico médico: “*um médico sabe que a meningite causa torcicolo em 50% dos casos. Porém, o médico também conhece algumas probabilidades incondicionais que dizem que, um caso de meningite atinge 1/50000 pessoas e, a probabilidade de alguém ter torcicolo é de 1/20.*”⁵

Considere T e M , respectivamente, como a probabilidade incondicional de um paciente ter torcicolo e a probabilidade incondicional de um paciente ter meningite. Assim:

$$P(T|M) = 0.5 \text{ (probabilidade de ter torcicolo tendo meningite)}$$

$$P(M) = 1/50000$$

$$P(T) = 1/20$$

Aplicando a regra de *Bayes*:

$$P(M|T) = (P(T|M)P(M))/P(T) = (0.5 \times 1/50000)/(1/20) = 0.0002$$

Ou seja, é esperado que apenas 1 em 5000 pacientes com torcicolo tenha meningite. Note que mesmo tendo torcicolo uma alta probabilidade nos casos de meningite (0.5), a probabilidade de um paciente ter meningite continua pequena, devido ao fato de a probabilidade incondicional de torcicolo ser muito maior que a probabilidade de meningite.

Uma argumentação válida surge do fato de que o médico poderia também possuir a probabilidade incondicional $P(M|T)$, a partir de amostras de seu universo de pacientes, da mesma forma que $P(T|M)$, evitando o cálculo realizado anteriormente. Porém, imagine que um surto de meningite aflija o universo de pacientes do médico em questão, aumentando o valor de $P(M)$. Caso $P(M|T)$ tenha sido calculado estatisticamente a partir de observações em seus pacientes, o médico não terá nenhuma idéia de como este valor será atualizado (visto que $P(M)$ aumentou). Entretanto, caso tenha realizado o cálculo de $P(M|T)$ em relação aos outros três valores (como demonstrado) o médico verificará que $P(M|T)$ crescerá proporcionalmente em relação a $P(M)$.

Considere agora que um paciente pode estar com problema de coluna C , dado que está com torcicolo: $P(C|T) = (P(T|C)P(C))/P(T)$.

Utilizando $P(M|T)$ podemos calcular a probabilidade relativa de C em M dado T , ou, em outras palavras, a marginalização de M e C . Considerando que $P(T|C) = 0.8$ e $P(C) = 1/1000$. Então:

$$P(M|T)/P(C|T) = (P(T|M)P(M))/(P(T|C)P(C)) = (0.5 \times 1/50000)/(0.8 \times 1/1000) = 1/80$$

Isto é, Problema de coluna C é 80 vezes mais comum que meningite M , dado torcicolo.

3 Redes Bayesianas

⁵ Exemplo extraído de [6].

Matematicamente, uma Rede *Bayesiana* é uma representação compacta de uma tabela de conjunção de probabilidades do universo do problema. Por outro lado, do ponto de vista de um especialista, Redes Bayesianas constituem um modelo gráfico que representa de forma simples⁶ as relações de causalidade das variáveis de um sistema.

Uma Rede *Bayesiana* consiste do seguinte:

- Um conjunto de variáveis e um conjunto de arcos ligando as variáveis.
- Cada variável possui um conjunto limitado de estados mutuamente exclusivos.
- As variáveis e arcos formam um grafo dirigido sem ciclos (*DAG*).
- Para cada variável A que possui como pais B_1, \dots, B_n , existe uma tabela $P(A|B_1, \dots, B_n)$.

Repare que, caso A não possua um pai, a tabela de probabilidades é reduzida para uma probabilidade incondicional $P(A)$ ⁷. Uma vez definida a topologia da rede, basta especificar as probabilidades dos nós que participam em dependências diretas, e utilizar estas para computar as demais probabilidades que se deseje.

Considere o domínio¹ como exemplo⁸: “Você possui um novo alarme contra ladrões em casa. Este alarme é muito confiável na detecção de ladrões, entretanto, ele também pode disparar caso ocorra um terremoto. Você tem dois vizinhos, João e Maria, os quais prometeram telefonar-lhe no trabalho caso o alarme dispare. João sempre liga quando ouve o alarme, entretanto, algumas vezes confunde o alarme com o telefone e também liga nestes casos. Maria, por outro lado, gosta de ouvir música alta e às vezes não escuta o alarme.” Este domínio pode ser representado como apresenta a figura 2.




Figura2. Rede Bayesiana domínio 1.

Repare que a rede não possui nós indicando que Maria está ouvindo música, ou que o telefone está tocando e atrapalhando o entendimento de João. Estes fatos estão implícitos, associados à incerteza relacionada pelos arcos $Alarme \rightarrow JoãoLig$ e $Alarme \rightarrow MariaLig$, pois, poderia ser muito dispendioso (ou até mesmo impossível) se obter tais probabilidades, ou ainda, tais informações poderiam não ser relevantes. Assim, as probabilidades devem resumir as condições

⁶ O que não significa dizer que as relações sejam simples.

⁷ Ou, o caso particular $P(A|)$.

⁸ Exemplo extraído de [6].

em que o alarme pode falhar (falta de bateria, campainha estragada, etc) e ainda, as condições em que João e Maria podem falhar (não estava presente, não ouviu o alarme, estava de mau-humor, etc). Desta forma, o sistema pode lidar com uma vasta gama de possibilidades, ao menos de forma aproximada.

Uma vez definida a topologia, é necessário se definir a tabela de probabilidades condicionais (CPT) para cada nó. Cada linha na tabela contém a probabilidade condicional para cada *caso condicional* dos nós pais. Um *caso condicional* é uma possível combinação dos valores para os nós pais. Por exemplo, para a variável aleatória *Alarme* temos:

| Ladrão | Terremoto | $P(\text{Alarme} \text{Ladrão},\text{Terremoto})$ | |
|------------|------------|---|-------|
| | | Verdadeiro | Falso |
| Verdadeiro | Verdadeiro | 0.95 | 0.050 |
| Verdadeiro | Falso | 0.95 | 0.050 |
| Falso | Verdadeiro | 0.29 | 0.71 |
| Falso | Falso | 0.001 | 0.999 |

Tabela4. CPT Alarme.

A figura3 apresenta a Rede Bayesiana para o domínio1 e suas probabilidades condicionais.

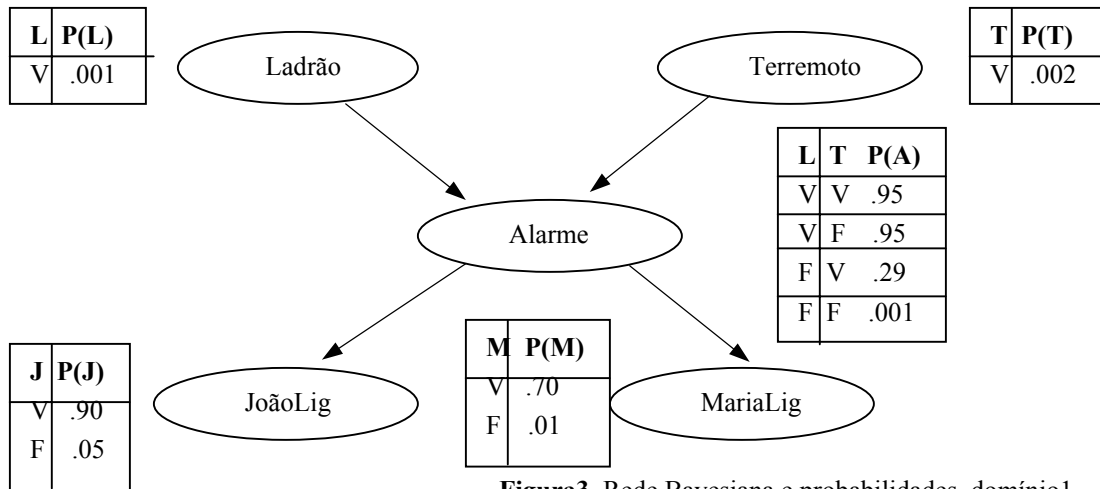


Figura3. Rede Bayesiana e probabilidades, domínio1.

3.1 Representando a distribuição da de conjunção de probabilidades

Todas as entradas da tabela de conjunção de probabilidades podem ser calculadas a partir das informações disponíveis em uma rede Bayesiana. Uma tabela de conjunção de probabilidades representa a descrição completa de um domínio. Cada entrada da tabela de conjunção de

probabilidades pode ser calculada a partir da conjunção das variáveis atribuídas aos devidos valores, $P(X_1=x_1 \wedge \dots \wedge X_n=x_n)$, ou $P(x_1, \dots, x_n)$. O valor de uma entrada é então dado por:

$$P(x_1, \dots, x_n) = \prod P(x_i | \text{Pais}(X_i)) \text{ para } 0 \leq i \leq n \quad (3.1)$$

Assim, cada entrada da tabela é representada pelo produto dos elementos apropriados das tabelas de probabilidades condicionais (CPT). As CPTs constituem então uma representação distribuída da tabela de conjunção de probabilidades do problema.

Como exemplo, considere que se deseja calcular a probabilidade do alarme ter tocado, mas, nem um ladrão nem um terremoto aconteceram, e ambos, João e Maria ligaram, ou $P(J \wedge M \wedge A \wedge \neg L \wedge \neg T)$.

$$\begin{aligned} P(J \wedge M \wedge A \wedge \neg L \wedge \neg T) &= P(J|A)P(M|A)P(A|\neg L \wedge \neg T)P(\neg L)P(\neg T) \\ &= 0.9 \times 0.7 \times 0.001 \times 0.999 \times 0.998 = 0.00062 \end{aligned}$$

3.2 Método para construção de uma rede *Bayesiana*

A construção de uma rede *Bayesiana* exige que certos cuidados sejam tomados de forma a permitir que a tabela conjunção de probabilidades resultante seja uma boa representação do problema. Para sua construção utilizaremos como base a equação (3.1).

$P(x_1, \dots, x_n) = \prod P(x_i | \text{Pais}(X_i))$ para $0 \leq i \leq n$, será reescrita para:

$$P(x_1, \dots, x_n) = P(x_n | x_{n-1}, \dots, x_1) P(x_{n-1} | \dots, x_1)$$

Este processo será repetido, reduzindo cada conjunção de probabilidades em uma probabilidade condicional e uma conjunção menor.

$$P(x_1, \dots, x_n) = P(x_n | x_{n-1}, \dots, x_1) P(x_{n-1} | x_{n-2}, \dots, x_1) \dots P(x_2 | x_1) P(x_1) = \prod P(x_i | x_{i-1}, \dots, x_1) \text{ para } 0 \leq i \leq n$$

Comparando esta equação com (3.1), observamos que a especificação de uma tabela de conjunção de probabilidades é equivalente com a declaração geral:

$$P(X_i | X_{i-1}, \dots, X_1) = P(X_i | \text{Pais}(X_i)) \text{ para } \text{Pais}(X_i) \subseteq \{x_{i-1}, \dots, x_1\} \quad (3.2)$$

Esta equação expressa que, uma rede *Bayesiana* é a representação correta de um domínio se e somente se, cada nó é condicionalmente independente de seus predecessores, dado seu pai. Portanto, para se construir uma rede cuja estrutura represente devidamente o domínio do problema, é necessário que para todo nó da rede esta propriedade seja atendida. Intuitivamente, os pais de um nó X_i devem conter todos os nós X_1, \dots, X_{i-1} que influenciem diretamente X_i . Assim, é possível, por exemplo, determinar que a seguinte igualdade é verdadeira:

$$P(\text{MariaLig}|\text{JoaoLig}, \text{Alarme}, \text{Terremoto}, \text{Ladrão}) = P(\text{MariaLig}|\text{Alarme})$$

Então, um procedimento geral para construção de redes *Bayesianas* seria:

1. Escolha um conjunto de variáveis X_i que descrevam o domínio.
2. Escolha uma ordem para as variáveis.
3. Enquanto existir variáveis:
 - a. Escolha uma variável X_i e adicione um nó na rede.
 - b. Determine os nós $\text{Pais}(X_i)$ dentre os nós que já estejam na rede e que satisfaçam a equação (3.2).
 - c. Defina a tabela de probabilidades condicionais para X_i .

O fato de que cada nó é conectado aos nós mais antigos na rede garante que o grafo será sempre acíclico.

3.3 Compactação e ordenação de nós

As Redes *Bayesianas*, em geral, representam tabelas conjunção de probabilidades de um domínio de forma compacta. Esta característica decorre do fato de que as redes *Bayesianas* possuem uma propriedade geral chamada, localidade estrutural. Nos sistemas com localidade estrutural, cada subcomponente interage diretamente apenas com uma parte do restante do sistema (demais subcomponentes). No caso das redes *Bayesianas*, é razoável de se supor que, na maioria dos casos, cada variável aleatória é diretamente influenciada por no máximo k outras variáveis. Suponhamos, por questões de simplicidade, que as variáveis aleatórias possam assumir apenas valores booleanos, neste caso, a quantidade de informação necessária para se especificar uma determinada tabela de probabilidades condicionais será no máximo 2^k números, em contraste com uma tabela de conjunção de probabilidades, 2^n . Apenas como um exemplo do poder se compactação, suponhamos uma rede com 20 nós ($n = 20$), cada nó com no máximo 5 pais ($k = 5$), uma rede *Bayesiana* necessitaria de 640 números, enquanto uma tabela *joint* mais de 1 milhão.

Entretanto, existem domínios que requerem que cada nó seja influenciado por todos os outros – grafo fortemente conexo. Nestes casos, a especificação de uma tabela de conjunção de probabilidades requer a mesma quantidade de informação que uma rede *Bayesiana*. Porém, na prática, a maioria dos problemas podem ser simplificados de forma a se garantir que a rede não seja conexa, sem perda de informação útil. Por exemplo, para o problema proposto em *domínio1*, poder-se-ia imaginar que na ocorrência de um terremoto, João e Maria não telefonariam, mesmo ouvindo o alarme, visto que saberiam que a causa foi o próprio terremoto. Neste caso, duas arestas seriam inseridas ligando *Terremoto* a *JoãoLig* e *Terremoto* a *Maria*, aumentando o número de *CPTs*. Esta nova abordagem deveria então ser avaliada considerando-se o custo da informação adicional inserida em relação à relevância da mesma.

Mesmo em domínios localmente estruturados, construir uma rede localmente estruturada não é um trabalho trivial. Pois, cada variável deve ser diretamente influenciada por apenas k ($k \neq n$) outras e, a topologia deve realmente representar o domínio. Alguns métodos podem ser utilizados, porém, não garantem a construção correta da árvore, uma abordagem possível seria:

incluir inicialmente as raízes, em seguida os nós influenciados por nós do nível anterior, e assim sucessivamente até a inserção das folhas (não possuem influência sobre nenhum nó). Assim, a ordem de inserção dos nós pode influenciar no desempenho da rede. Considere o exemplo para o *domínio1*, a inserção poderia seguir a seguinte ordem:

- *MariaLig*: raiz.
- *JoãoLig*: Se Maria ligou, então, provavelmente, o alarme tocou. Neste caso, *MariaLig* influencia *JoãoLig*. Portanto, *MariaLig* é pai de *JoãoLig*.
- *Alarme*: Claramente, se ambos ligaram, provavelmente o alarme tocou. Portanto, *Alarme* é influenciado por *JoãoLig* e *MariaLig*.
- *Ladrão*: Influenciado apenas por *Alarme*.
- *Terremoto*: Se o alarme tocou, provavelmente, um terremoto pode ser acontecido. Entretanto, se existe um *Ladrão*, então as chances de um terremoto diminuem. Neste caso, *Terremoto* é influenciado por *Ladrão* e *Alarme*.

A rede resultante (*figura4*) possui mais arcos em relação à rede original, o que significa que mais tabelas devem ser especificadas. E ainda, pode-se notar que alguns arcos representam situações pouco naturais e, por conseqüência, de difícil especificação, como, por exemplo, a probabilidade de um *Terremoto* dado *Ladrão* e *Alarme*.

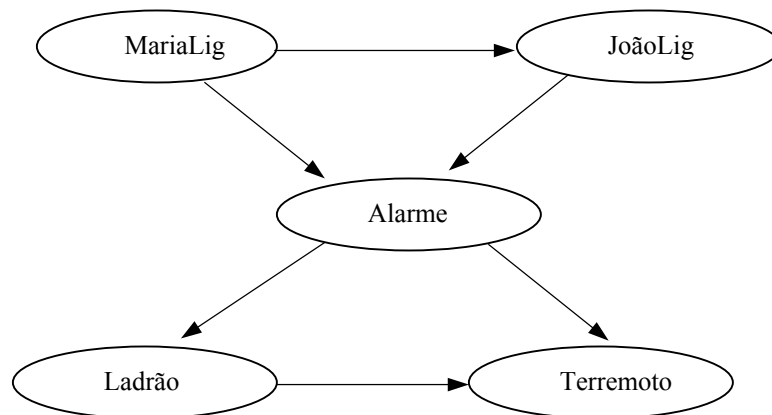


Figura4. Rede Bayesiana *domínio1*.

3.4 Tabelas de probabilidades condicionais

Tabelas de probabilidades condicionais tendem a ter um grande número de entradas, mesmo para nós com um número pequeno de pais. Preencher estes valores pode ser algo que requeira muita experiência, caso a relação entre nós pais e nós filhos seja completamente arbitrária. Entretanto, na maioria dos casos, esta relação pode ser bem adaptada a algum padrão, o que pode facilitar o trabalho. Estes casos são chamados *distribuições canônicas*.

O caso mais simples é o representado por *nós determinísticos*. Um nó determinístico tem o seu valor explicitamente determinado a partir dos pais, sem incerteza. Por exemplo, relação entre nós pais *Brasileiro*, *Peruano* e *Boliviano*, e o nó filho *SulAmericano* é determinado especificamente pela disjunção dos pais.

Relações com incerteza podem geralmente ser caracterizados como relações com *ruídos* (*noisy logical relationships*). A relação com *ruído* padrão é chamada *ruído-OU* (*noisy-OR*), uma generalização da relação lógica *OU*. Em lógica proposicional pode-se dizer que o estado *Febre* é verdadeiro se e somente se *Gripe*, *Resfriado* ou *Malaria* é verdadeiro. A relação *ruído-OU* adiciona um nível de incerteza à relação *OU*, considerando três suposições: (a) Cada causa possui uma chance independente de causar o efeito, (b) todas as possibilidades estão listadas, (c) a inibição de uma causa é independente da inibição das demais. Considere o exemplo, $P(\text{Febre}|\text{Gripe}) = 0,4$, $P(\text{Febre}|\text{Resfriado}) = 0.8$ e $P(\text{Febre}|\text{Malaria}) = 0.9$, para estes valores os parâmetros de *ruído* serão respectivamente 0.6, 0.2, 0.1. Se nenhum nó pai é verdadeiro, então o nó filho é falso com 100% de chance. Se apenas um (1) pai é verdadeiro, então a probabilidade do nó filho ser falso é igual ao *ruído* do nó pai verdadeiro (ou o produto do *ruído* dos pais, caso exista mais de um verdadeiro). A tabela abaixo apresenta o resultado para o exemplo.

| <i>Gripe</i> | <i>Resfriado</i> | <i>Malária</i> | $P(\text{Febre})$ | $P(\neg\text{Febre})$ |
|--------------|------------------|----------------|-------------------|-------------------------------------|
| F | F | F | 0.0 | 1.0 |
| F | F | V | 0.9 | 0.1 |
| F | V | F | 0.8 | 0.2 |
| F | V | V | 0.98 | $0.02 = 0.2 \times 0.1$ |
| V | F | F | 0.4 | 0.6 |
| V | F | V | 0.94 | $0.06 = 0.6 \times 0.1$ |
| V | V | F | 0.88 | $0.12 = 0.6 \times 0.2$ |
| V | V | V | 0.988 | $0.012 = 0.6 \times 0.2 \times 0.1$ |

Tabela5. *ruído-OU*.

3.5 Independência condicional em redes *Bayesianas*

Conforme demonstrado anteriormente, uma nó em uma rede *Bayesiana* possui independência condicional em relação a seus predecessores na rede dado o nó pai. Entretanto, para que possamos utilizar algum método de inferência em uma rede é necessário que possamos dizer mais a respeito das relações entre os nós de uma rede. Por exemplo, é necessário saber se um conjunto de nós X é independente de outro conjunto Y , dado que um conjunto de evidências E^9 , ou, em outras palavras, é preciso saber se X é *d-separado* de Y . Se todo caminho não dirigido entre um nó em X e um nó em Y é *d-separado* por E , então X e Y são condicionalmente independentes dada a evidência E .

Um conjunto de nós E *d-separa* dois conjuntos de nós X e Y , se todo o caminho não dirigido de um nó em X para um nó em Y é *bloqueado* dado E . Um caminho é bloqueado por um conjunto de nós E se existe um nó Z no que garante algumas das três condições:

1. Z está em E e Z possui um arco de entrada e um arco de saída no caminho.

⁹ Evidência em uma variável é uma declaração de uma certeza de seus estados. Se uma variável é instanciada, ela é chamada *hard evident*.

2. Z esta em E e Z possui dois arcos de saída no caminho não dirigido.
3. Z e nenhum de seus descendentes não estão em E e ambos os arcos no caminho não dirigido são de chegada em Z .

A figura5 demonstra os três casos.




Figura5. Casos gerais, nós X e Y d-separados.

A próxima sessão discute algumas questões a respeito de inferências em redes *Bayesianas*.

4 Inferência em Redes Bayesianas

A tarefa básica de uma inferência probabilística é computar a distribuição de probabilidades posterior para um conjunto de *variáveis de consulta* (*query variables*), dada uma *hard evidence*, ou seja, o sistema computa $P(Query|Evidence)$. Para o exemplo proposto em *dominio1*, *Ladrão* constitui uma boa variável de consulta e *JoãoLig*, *MariaLig* seriam boas variáveis de evidência (*hard evidence*).

O exemplo abaixo apresenta uma rede *Bayesiana* formada pelas seguintes variáveis *Cloudy* (*TempoNublado*), *Sprinklet* (*Regador*), *Rain* (*Chuva*) e *WetGrass* (*GramaMolhada*)¹⁰. Uma inferência possível seria: Dado que temos a evidência de que a grama está molhada, qual a probabilidade de ter chovido, ou do regador estar ligado?

¹⁰ Exemplo extraído de [4].

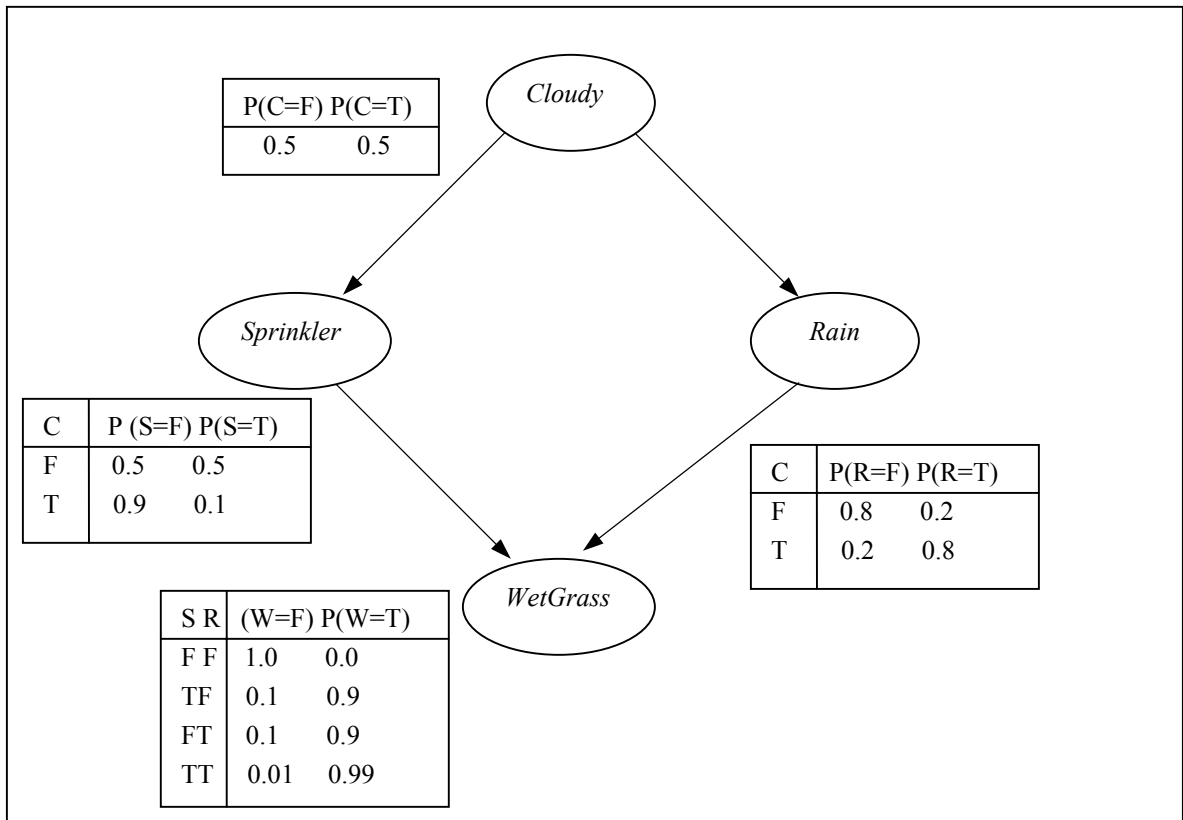


Figura6. Rede Bayesiana – Exemplo de inferência.

Neste caso, apesar de S e R serem independentes, tornam-se dependentes dado que W a evidência, é filho de ambos, ou seja, não S e R não são d-separados. Assim, para o calculo de $P(S|W)$ deve-se considerar $P(R)$ e vice-versa. A equação seria ($1 = T$ e $0 = F$):

$$P(S=1|W=1) = P(S=1, W=1)/P(W=1)$$

$$= \sum_{c,r} (P(C=c_i, S=1, R=r_i, W=1)/P(W=1)) = 0.2781/0.6471$$

$$P(R=1|W=1) = P(R=1, W=1)/P(W=1)$$

$$= \sum_{c,s} (P(C=c_i, S=s_i, R=1, W=1)/P(W=1)) = 0.4581/0.6471$$

Onde ($W = 1$):

$$P(W=1) = \sum_{c,r,s} P(C=c_i, S=s_i, R=r_i, W=1) = 0.6471$$

Repare que para o cálculo de $P(S=1|W=1)$, considera-se os estados possíveis de C e R (somatório). Assim, pode-se concluir que, dado que a grama está molhada, $W=1$, a probabilidade de ter chovido, $P(R=1|W=1) = 0.4581/0.6471 = 0.7079$ é maior que a probabilidade de o regador ter sido ligado $P(S=1|W=1) = 0.2781/0.6471 = 0.4297$.

Inferências podem ser realizadas sobre redes *Bayesianas* para:

- Diagnósticos: Dos efeitos para as causas. Dado *JoaoLig*, $P(\text{Ladrão}|\text{JoaoLig})$
- Causas: De causas para efeitos. Dado *Ladrão*, $P(\text{JoaoLig}|\text{Ladrão})$
- Intercausais: Entre causas de um efeito comum. Dado *Alarme*, $P(\text{Ladrão}|\text{Alarme})$ e dado *Terremoto*, $P(\text{Ladrão}|\text{Alarme}, \text{Terremoto})$.

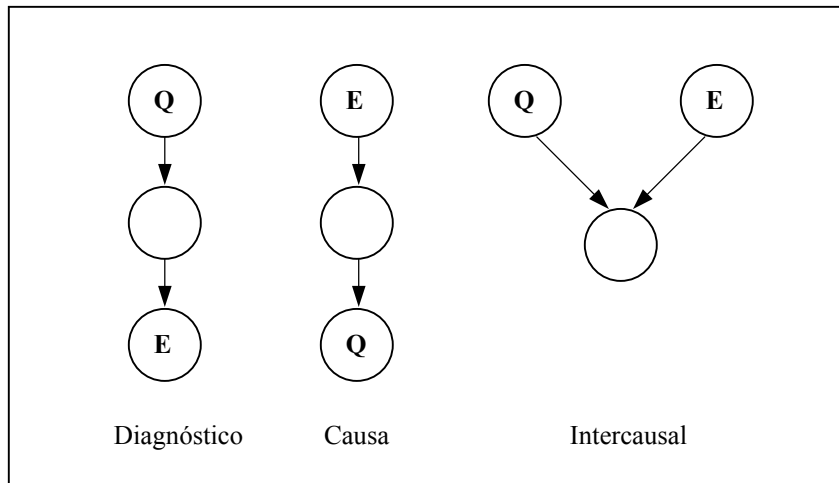


Figura7. Tipos de Inferências

E, além de consultas a partir de evidências, redes *Bayesianas* podem ser utilizadas para:

- Tomar decisões baseadas em probabilidades.
- Decidir quais evidências adicionais devem ser observadas a fim de se obter informações úteis do sistema.
- Analisar o sistema a fim de buscar os aspectos do modelo que possuem maior impacto sob as variáveis de consulta.
- Explicar os resultados de uma inferência probabilística ao usuário.

4.1 Algoritmo para resolução inferências

Conforme demonstrado, a computação básica de um método de inferência sobre uma rede *Bayesiana* requer o cálculo de todos os nós da rede (sua probabilidade condicional) dado que uma evidência foi observada. Isto implica dizer que, em geral, uma inferência probabilística realizada em uma rede *Bayesiana* será *NP-hard*. Este fato é diretamente proporcional a forma como o problema foi modelado, em outras palavras, em algumas situações, uma rede com apenas dezenas de nós pode necessitar de um tempo computacional muito grande (às vezes inviável), enquanto uma rede contendo milhares de nós pode levar apenas alguns instantes.

Entretanto, para uma classe restrita de redes, inferências probabilísticas podem ser realizadas em tempo linear. Esta classe é conhecida por: redes simplesmente conexas. Uma rede

simplesmente conexa é aquela onde, para qualquer dois nós i, j da rede existe apenas um caminho não dirigido entre i e j . A figura abaixo apresenta uma representação genérica de rede simplesmente conexa. Um nó X possui um conjunto U de pais, $U = U_1, \dots, U_m$, e filhos $Y = Y_1, \dots, Y_n$. Cada filho e cada pai está representado dentro de uma caixa contendo todos os seus nós descendentes e ancestrais, exceto em relação a X , ou seja, todas as caixas são disjuntas e não possuem nenhum arco ligando-as.

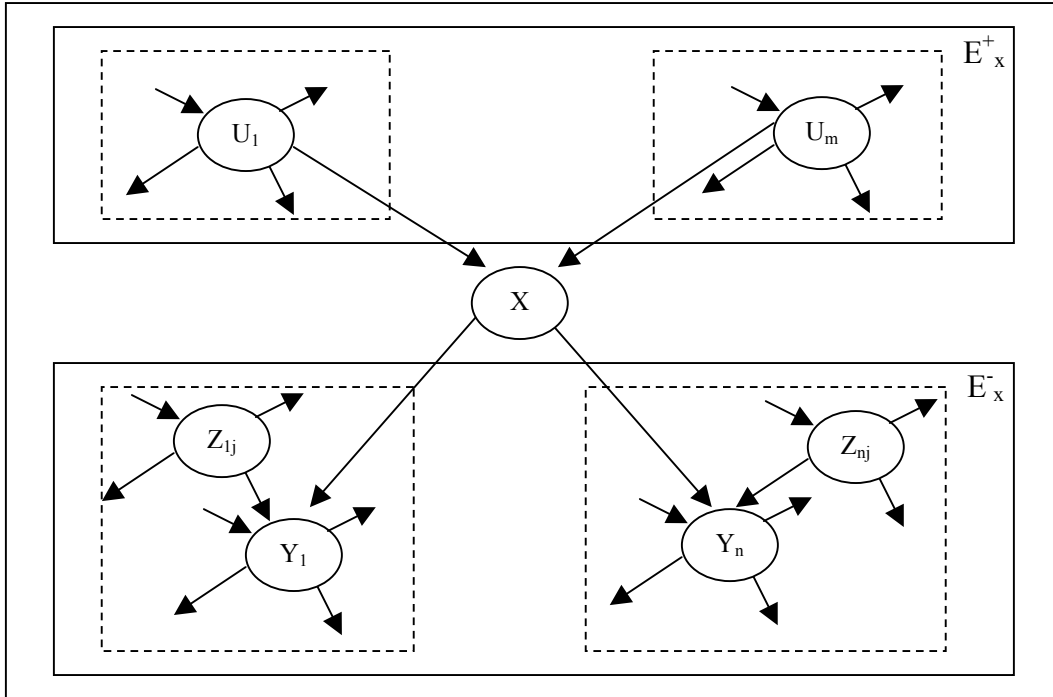


Figura8. Rede simplesmente conexa genérica

O algoritmo assume que X é a variável de consulta, e existe um conjunto de variáveis de evidência E ($X \notin E$). Para o funcionamento do algoritmo é necessário também que as disjunções E_x^-, E_x^+ , sejam definidas.

- E_x^+ é o suporte de causa de X . Variáveis de evidência “acima” de X estão conectadas a X por estes pais.
- E_x^- é o suporte de evidência de X . Variáveis de evidência “abaixo” de X estão conectadas a X por estes filhos.

A estratégia geral é a seguinte:

1. Expressar $P(X|E)$ em relação a E_x^-, E_x^+ .
2. Computar a contribuição de E_x^+ através de seus efeitos em $Pais(X)$, e então transportar tais efeitos para X .

3. Computar a contribuição de E_x^- através de seus efeitos em $Filhos(X)$, e então transportar tais efeitos para X . Note que computar os efeitos nos filhos de X é uma recursão do problema de computar os efeitos em X .

A execução do algoritmo envolve chamadas recursivas a partir de X por todos seus arcos. A recursão termina em nós de evidência, raízes e folhas da árvore. Cada chamada recursiva exclui o nó que a chamou, desta forma, a árvore é coberta apenas uma vez. Portanto o algoritmo é linear no número de nós da rede. O algoritmo está representado abaixo¹¹.

Função Belif-Net-Ask(X) **retorna**(distribuição de probabilidades sobre X)
 { Entrada: X , a variável aleatória
 Suport-Except(X , NULL) }

Função Suport-Except(X , V) **retorna**($P(X|E)$)
 { **se** Evidencia(X) **retorna** ponto de distribuição observado para X
senão
 Calcula $P(E_x^-|X) = \text{Evidence-Except}(X, V)$
 $U = \text{Pais}(X)$
se $U == \text{vazio}$
 retorna $P(E_x^-|X)P(X)$
senão
 para cada U_i em U
 Calcule e armazene $P(U_i|E_{u_i}) = \text{Suport-Except}(U_i, X)$
 retorna $P(E_x^-|X) \sum P(X|u) \prod P(U_i|E_{u_i})$
 }

Função Evidence-Except(X , V) **retorna** $P(E_x^-|X)$
 { $Y = \text{Filhos}[X] - V$
se $Y == \text{vazio}$ **retorna** uma distribuição uniforme
senão
 para cada Y_i em Y
 Calcula $P(E_{y_i}^-|Y_i) = \text{Evidence-Except}(Y_i, \text{NULL})$
 $Z_i = \text{Pais}[Y_i] - X$
 para cada Z_{ij} em Z_i
 Calcule e armazene $P(Z_{ij}|E_{z_{ij}}) = \text{Suport-Except}(Z_{ij}, Y_i)$
 retorna $\prod \sum P(E_{y_i}^-|Y_i) \sum P(Y_i|X, z_i) \prod P(z_{ij}|E_{z_{ij}})$
 }

Vale lembrar que o algoritmo apenas funciona devido à característica da árvore de ser simplesmente conexa, caso contrário, ou uma mesma evidência seria contada mais de uma vez, ou o algoritmo poderia não terminar.

¹¹ Algoritmo extraído de [6].

Para demonstração matemática¹² do algoritmo, considere a árvore simplesmente conexa definida abaixo.




Figura9. Rede Bayesiana. Inferência $P(e|a,b,c,d)$.

Suponha que desejamos calcular a probabilidade de e dadas as evidências a,b,c,d . Es evidências são inicialmente divididas em dois conjuntos, $[a,b]$, nós que estão acima de e e $[c,d]$, nós que estão abaixo de e . O objetivo é se quebrar o problema $P(e|a,b,c,d)$, em dois subproblemas. Inicialmente aplicamos a rede de Bayes:

$$P(e|a,b,c,d) = P(e)P(a,b,c,d|e)/P(a,b,c,d)$$

O segundo termo do numerador pode ser quebrado;

$$P(e|a,b,c,d) = P(e) P(a,b|e)P(c,d|a,b,e)/P(a,b,c,d)$$

Note que $P(c,d|a,b,e) = P(c,d|e)$, pois e separa a e b de c e d . Substituindo este termo no ultimo termo do numerador e condicionando o denominador em a e b , teremos:

$$P(e|a,b,c,d) = P(e) P(a,b|e) P(c,d|e)/P(a,b) P(c,d|a,b)$$

Os fatores podem ser alterados para:

$$P(e|a,b,c,d) = (P(e) P(a,b|e) /P(a,b)) P(c,d|e) P(c,d|a,b)$$

Aplicando a regra de Bayes de forma reversa sobre o primeiro termo, teremos:

$$P(e|a,b,c,d) = (P(e|a,b) P(c,d|e))(1/P(c,d|ab))$$

¹² Extraído de [1].

Com esta equação obtemos o resultado desejado, o primeiro termo possui apenas variáveis que estão “acima” de e e o segundo, apenas variáveis que estão “abaixo”. O último termo envolve ambas as variáveis, mas, na realidade não precisa ser calculado. Basta, resolver esta equação para todos os valores de e , o último termo permanece inalterado, e pode ser marginalizado¹³.

4.2 Inferência em Redes Bayesianas Multiconectadas

Um grafo multiconectado é aquele para o qual dois nós são ligados por mais de um caminho não dirigido, ou, um nó possui duas ou mais causas, e estas causas compartilham um ancestral comum (*figura6*). Conforme já mencionado, o cálculo de inferências sob redes multiconectadas é um problema *NP-hard*, entretanto, algumas abordagens são propostas de forma se possibilitar estes cálculos em tempo polinomial.

Existem três classes de algoritmos para inferência em redes multiconectadas, cada um com uma área de aplicação definida:

- *Clustering* – Este método transforma probabilisticamente (não topologicamente) a rede em uma rede simplesmente conexa.
- *Conditioning* – Este método faz uma transformação na rede instanciando variáveis em valores definidos, e então, e então produz uma rede simplesmente conexa para cada variável instanciada.
- *Stochastic simulation* – Este método usa a rede para gerar um grande número de modelos concretos de um domínio. A partir destes modelos o algoritmo calcula uma aproximação de uma inferência.

Métodos de Clustering

Considere o exemplo da *figura6*. Uma forma de obter desta rede em uma rede simplesmente conexa seria a combinação das variáveis *Sprinkler* e *Rain*, em um mega nó chamado *Sprinkler+Rain*, conforme mostra a *figura10*. Repare que duas variáveis booleanas são substituídas por um nó que possui as quatro probabilidades, *TT*, *TF*, *FT* e *FF* (a probabilidade dos demais nós da rede permanecem inalteradas). O mega nó obtido possui apenas um pai, a variável booleana *Cloudy*. Uma vez que a rede foi convertida para uma rede simplesmente conexa, o algoritmo apresentado anteriormente pode ser aplicado.

Apesar da técnica permitir a aplicação de um algoritmo de inferência de tempo linear, a característica *NP-hard* não deixa de existir. No pior caso, o tamanho da rede pode crescer exponencialmente, tendo em vista que o método envolve o produto de tabelas de probabilidade incondicional. O problema passa então a depender da escolha de um bom método para junção de nós.

¹³ Ver sessão 2.1.1.

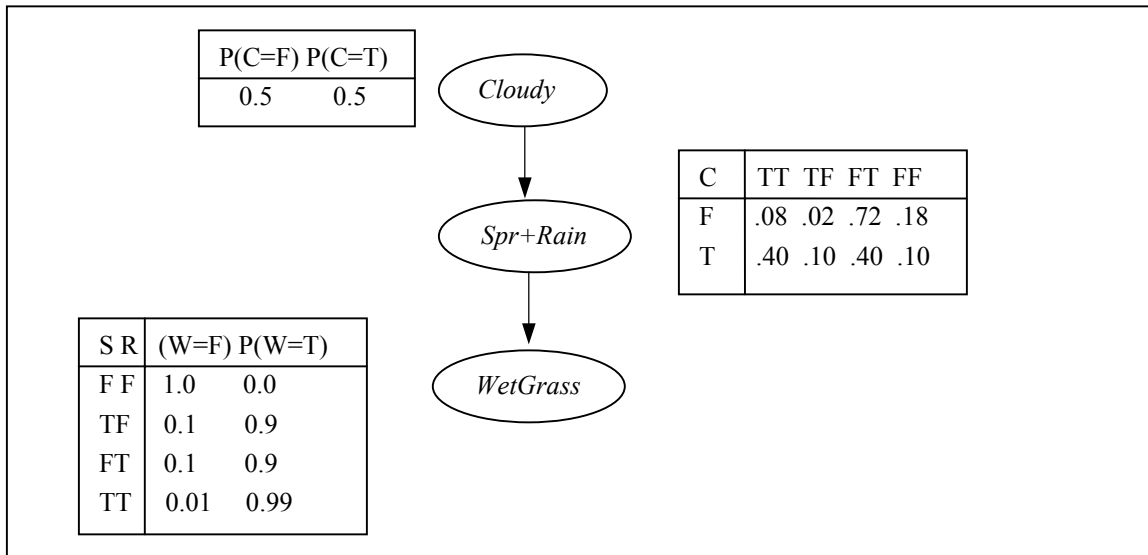


Figura10. Clustering de nós.

Métodos de *Cutset conditioning*

O método *Cutset conditioning* utiliza uma idéia oposta em relação a anterior. Seu propósito é transformar uma rede em diversas redes mais simples. Cada uma destas redes possui uma ou mais variáveis instanciadas em um valor definido. Assim, $P(X|E)$ é computado como uma média ponderada sobre os valores extraídos de cada uma das redes.

O conjunto de variáveis que podem ser instanciadas para permitir que uma rede simplesmente conexa seja obtida é chamado *cutset*. Para o exemplo anterior, o *cutset* seria apenas a variável *Cloudy*, como seu valor é booleano, apenas duas árvores são geradas, conforme mostra a figura abaixo.

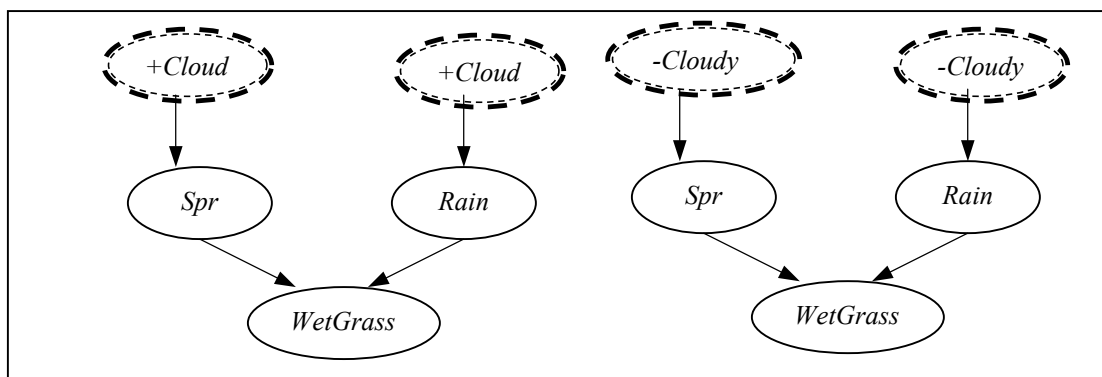


Figura1. Cut set conditioning.

De forma geral, o número resultante de novas árvores é exponencial em relação ao número de nós, o que significa dizer que, uma boa estratégia para definição de *cutsets* deve ser utilizada.

Métodos *Stochastic simulation*

Neste método, simulações sobre a rede são repetidamente executadas permitindo que informações estatísticas sejam extraídas para as probabilidades que se deseja. Em cada rodada da simulação, um valor aleatório é atribuído a cada nó raiz da rede, a escolha é ponderada pela probabilidade incondicional do nó. Para $P(Cloudy) = 0.5$, do exemplo anterior, $Cloudy = True$ deve ser escolhido metade das vezes, e $Cloudy = False$, a outra metade. Uma vez escolhido o valor de $Cloudy$, os valores de $Sprinkler$ e $Rain$ podem também ser escolhidos aleatoriamente. Finalmente, o mesmo pode ser realizado para $WetGrass$, e a primeira rodada termina.

Para se estimar o valor de $P(WetGrass|Cloudy)$, ou uma probabilidade qualquer $P(X|E)$, o procedimento anterior deve ser repetido várias vezes, e então se calcula a razão do número de vezes em que $P(Cloudy)$ e $P(WetGrass)$ foram verdadeiros, pelo número de vezes que apenas $Cloudy$ foi verdadeiro. Este valor tende a se aproximar do valor exato, na medida em que o número de simulações aumenta.

5 Aplicações

Redes *Bayesianas* têm sido utilizadas em diversos tipos de aplicações, entretanto, seu principal foco tem sido a área de diagnósticos, principalmente, diagnósticos médicos. A seguir serão apresentados alguns projetos.

- *Pathfinder*, Heckerman 1990. Stanford – Sistema para diagnósticos de problemas nas glândulas linfáticas. O sistema trata mais de 60 enfermidades sob as probabilidades de mais de 100 causas (sintomas e resultados de testes médicos).
- *Map Learning*, Ken Basye 1990. Brown University – Este projeto combina problemas de diagnóstico e teoria de decisão. Um robô deve percorrer um “labirinto”, procurando aprender os caminhos percorridos e, ao mesmo tempo, explorar caminhos desconhecidos. O robô deve ponderar entre seguir um caminho conhecido até seu objetivo e a tentativa de se descobrir um novo caminho.
- *AutoClass*, NASA’s Ames Research Center, 1998 - Sistema de exploração e aquisição de conhecimento espacial. Este projeto está desenvolvendo uma rede *bayesiana* que permita a interpolação automática de dados espaciais oriundos de diferentes observatórios e planetários espalhados pelo mundo.
- *Lumiere*, Microsoft Research, 1998 – O projeto pretende criar um sistema que possa automaticamente e inteligentemente interagir com outros sistemas, antecipando os objetivos e necessidades dos usuários.

6 Conclusões

Redes *bayesianas* constituem uma forma natural para representação de informações condicionalmente independentes. E ainda, possibilitam a representação compacta de uma tabela de conjunção de probabilidades. Em outras palavras, redes *bayesianas*, oferecem uma boa solução a problemas onde conclusões não podem ser obtidas apenas do domínio do problema, onde, o uso de probabilidades é exigido.

Inferências sobre redes *bayesianas* podem ser executadas em tempo linear, porém, para a maioria das topologias de rede, inferências possuem complexidade *NP-hard*. Algumas técnicas podem ser aplicadas para se obter tempo linear, mesmo em topologias que impossibilitariam este fato, entretanto, este ainda é um dos grandes desafios ao se desenvolver uma rede.

7 Referências Bibliográficas

- [1] Charniak, Eugene. “Bayesian Networks without Tears”. *IA Magazine*, 1991.
- [2] Darwiche, Adnan & Huang, Cecil. “Inference in Belief Networks: A procedural guide”. *International Journal of Approximate Reasoning*, 1994.
- [3] Jensen, V. Finn. “Bayesian Networks and Decision Graphs”. Springer-Verlag, 2001.
- [4] Murphy, P. Kevin. “A Brief Introduction to Graphical Models and Bayesian Networks”. <http://www.cs.berkeley.edu/~murphyk/Bayes/bayes.html>
- [5] Niedermayer, Daryle. “An Introduction to Bayesian Networks and their Contemporary Applications”. 1998.
- [6] Russell, J. Stuart & Norvig, Peter. “Artificial Intelligence: A modern Approach”. Prentice Hall 415-429, 436-457, 1995.