

## 3 Representação do conhecimento

### 3.1-Limitações dos grafos

Nos problemas vistos até aqui, tínhamos formas sofisticadas de busca em uma forma de representação simples (os grafos) quase sempre baseada em conceitos matemáticos. Entretanto, para muitos processos de decisão humanos (em finanças, engenharia, manutenção, sistemas tutoriais ou de diagnósticos e várias outras aplicações), é necessário armazenar uma grande massa de conhecimento e possuir mecanismos de busca mais ágeis. Para estes sistemas, os grafos não se mostram estruturas ideais, na medida em que há uma quantidade grande de estados possíveis.

Há que se descobrir, portanto, novas formas de representação do conhecimento. Como vimos no capítulo 1, o conhecimento é mais do que a simples informação. Ele embute os conceitos de informação e de propósito. Ou seja, ele alia informação com procedimento. Já a inteligência, à luz daquela classificação piramidal, pode ser definida como o uso sensato do conhecimento, dentro de um propósito moral ou ético e, neste sentido, alia o conhecimento à sensatez (eficiência).

As pesquisas em IA, em um certo período (a partir da década de 60) foram direcionadas para formas mais eficientes de representação do conhecimento e da interpretação (tomada de decisões) deste conhecimento. O problema é que o conhecimento humano é fortemente baseado na linguagem natural, a qual apresenta, como vimos no item 2.4, muitas fontes de ambigüidade e dependência do contexto.

De fato, nos problemas com representações de grafos, todo o conhecimento necessário à solução do problema está disponível, quer através da enumeração das ações possíveis (representadas pelos operadores), quer através dos estados possíveis (dedutíveis através da aplicação dos operadores), quer ainda pelo conhecimento de um estado inicial e do(s) estado(s) final(is) que se desejava alcançar.

Ocorre que, muitos problemas para os quais procuramos respostas, são incompletos. Para estes problemas, é necessário criar mecanismos de inferência, que gerem novos conhecimentos a partir de conhecimentos existentes ou considerem fontes exteriores de aquisição de conhecimento, tais como perguntas que se façam aos usuários, leituras de sensores disponíveis, consultas a bancos de dados existentes ou a incorporação de conhecimentos aprendidos de casos analisados no passado.

### 3.2-Outras formas de representação do conhecimento

Para representar o conhecimento, pelo que acabamos de ver, devemos possuir formas de representar tanto as informações, como os procedimentos (ações). Existem várias formas de representação do conhecimento. Algumas dão mais ênfase à representação da informação (são chamadas de fortemente declarativas) como os Grafos de Estados que vimos até agora, ou as Redes Semânticas ou ainda os Objetos Estruturados. Outras dão mais ênfase aos procedimentos (são chamadas de fortemente procedimentais), como a Lógica de Primeira Ordem ou os sistemas de Regras de Produção (como os Sistemas Especialistas). Destes, talvez os de maior emprego sejam os últimos (Sistemas de Regras de Produção). Entretanto, para que possamos compreendê-los, é necessário entender com quais entidades eles lidam. Fundamentalmente, podemos falar em duas entidades: os fatos (ou seja, as verdades ou informações que possuímos sobre um determinado contexto) e a representação dos fatos (formalismo simbólico que permite representar e manipular o conhecimento em um determinado contexto).

A forma de representação mais comum é a linguagem natural. Mas podemos empregar também lógica matemática como formalismo representacional. Considere, por exemplo, a frase:

*Thor é um cachorro* (1)

Este fato, pode ser representado em um formalismo lógico como:

*Cachorro (Thor)* (2)

Se tivermos um formalismo para representar que todos os cachorros tem rabo, poderíamos escrever:

$\forall x: \text{cachorro}(x) \rightarrow \text{tem-rabo}(x)$  (3)

Usando mecanismos de dedução lógica, poderíamos concluir:

*Tem-rabo(Thor)* (4)

Que em linguagem natural eqüivale a:

*Thor tem rabo* (5)

O que se fez (embora não esteja explicado como), foi criar novos fatos (4 ou 5, de acordo com a representação usada), a partir de um fato inicial (1 ou 2) e de um conhecimento que permite inferência de novos fatos (3). Este novo fato, pode agora ser considerado, juntamente com os demais conhecimentos existentes para produzir novas inferências, ou seja, gerar novos fatos. Se esta geração tiver uma orientação adequada, poderemos produzir fatos que sejam relevantes em um determinado contexto, ou seja, poderemos encontrar as respostas que objetivamos.

### 3.3-Regras de Produção

Uma outra forma de representar o conhecimento é através de regras. Sistemas baseados em regras são os mais populares, principalmente em aplicações especializadas em uma determinada área. Tais sistemas são conhecidos como Sistemas Especialistas. As regras são uma forma de representação do conhecimento bastante próxima da forma humana de expressá-lo. Por exemplo, conhecimentos como os abaixo expressos, podem ser fácil e naturalmente postos em formas de regras:

*Se a temperatura é maior que 38 graus, o paciente tem febre.*

*Se o paciente tem febre há mais de 3 dias, o paciente tem uma infecção.*

*Se há tensão na entrada da fonte e não há tensão na saída da fonte, então o transformador está queimado.*

Uma regra é formada por uma ou mais premissas, combinadas através de operadores lógicos e uma ou mais conclusões que são acionadas quando as premissas são verdadeiras. As premissas/conclusões são também chamadas de situação/ação ou ainda de antecedente/conseqüente.

Os sistemas baseados em regras usam a regra de inferência Modus Ponens. Assim, dado que o fato A é verdadeiro e a implicação  $A \rightarrow B$  é verdadeira, conclui-se que o fato B é verdadeiro. Os sistemas que usam esta técnica de representação, empregam técnicas de busca por regras e inferência de novos fatos, de forma a encontrar os fatos que tenham sido definidos como objetivos. A idéia é encontrar um caminho entre os fatos e conhecimentos que se tem e os fatos que se deseja descobrir.

Por exemplo, considere que temos os seguintes conhecimentos:

Regra 1: Se a temperatura ambiente está acima de 35 graus

Então o tempo está quente

Regra 2: Se a umidade relativa do ar é maior que 75%

Então a atmosfera está úmida

Regra 3: Se o tempo está quente e a atmosfera está úmida

Então é provável que se formem tempestades

Considere ainda que conhecemos os seguintes fatos:

Fato 1: A temperatura ambiente é de 37 graus

Fato 2: A umidade relativa do ar é de 81%

As regras 1 e 2 podem, a partir deste fatos, concluir novos fatos:

Fato 3: A atmosfera está úmida ( da regra 2)

Fato 4: O tempo está quente (da regra 1)

Os fatos 3 e 4 satisfazem as premissas da regra 3, levando a outro fato:

Fato 5: É provável que se formem tempestades.

A forma como percorremos as regras, produzindo as inferências, isto é, a escolha de quais regras examinar e ativar, pode obedecer a duas abordagens básicas:

Dirigida a dados (forward chain): aciona-se todas as regras que seja possível, a partir dos dados (fatos) conhecidos.

Dirigida a objetivos: aciona-se somente as regras que possuam na conclusão algum dos objetivos que procuramos. Caso as premissas da regra que desejamos acionar sejam desconhecidas, estabelecemos estas premissas como o novo objetivo e passamos a buscar regras que as contenham na parte da conclusão. Assim, o objetivo original é provisoriamente abandonado e será retomado (através do acionamento da regra abandonada) quando as premissas necessárias à obtenção do objetivo original tenham sido encontradas. O procedimento é recorrente, isto é, os objetivos são provisoriamente abandonados tantas vezes quantas se faça necessário, formando uma cadeia de busca para trás (*backward chain*).

Considere, por exemplo, que temos a seguinte base de conhecimentos:

Regra 1: Se a taxa de juros é baixa

Então a bolsa de valores está em alta

Regra 2: Se a taxa de juros é alta

Então a bolsa de valores está em baixa

Regra 3: Se a cotação do Dolar está baixa

Então a taxa de juros é alta

Regra 4: Se a cotação do Dolar está alta


Então a taxa de juros é baixa

Considere também que conhecemos o seguinte fato:

Fato 1: a cotação do Dolar está baixa.


O que desejamos saber é: "Qual a tendência da bolsa de valores?"

Se executarmos a busca com a abordagem orientada a dados, teremos a seguinte cadeia de investigação e acionamento de regras:



Onde as regras com círculos serão acionadas, porque as premissas assim o permitem, enquanto que as demais serão apenas investigadas.

Se a busca for com a abordagem orientada a objetivos, teremos:



Do primeiro para o segundo passo, o objetivo seria trocado de "bolsa de valores" para "taxa de juros" e iniciar-se-ia a busca por este novo objetivo. Quando ele fosse encontrado (após o acionamento da regra 3), retornar-se-ia à regra abandonada (regra 1) para buscar novamente pelo objetivo original, que seria encontrado após o acionamento da regra 2.

O que acontece quando não é mais possível encontrar regras que gerem o conhecimento objetivado, no esquema de *backward chain* ou não é mais possível gerar novos conhecimentos no esquema *forward chain*?

Bem, neste caso ocorre o mesmo que quando se vai a uma consulta médica e somente com as informações relatadas e o seu conhecimento, o médico não é capaz ainda de produzir um diagnóstico. Ele precisa de agregar novos conhecimentos vindos de fora do sistema. Em uma consulta isto pode representar outras perguntas ao paciente ou a requisição de exames complementares. Em um sistema especialista montado a partir de regras de produção, a agregação de novos conhecimentos que não sejam possíveis de deduzir a partir das regras existentes, geralmente se dá através de perguntas que se faz ao usuário sobre valores das variáveis que sejam importantes na cadeia de conhecimento necessária à resolução do problema que se objetiva.

A evolução na elaboração de sistemas especialistas com histórias de sucesso, levou os projetistas a separar os sistemas em três partes, de forma a facilitar a elaboração de novos sistemas:

1. Motor de inferências - responsável por estabelecer uma estratégia ou uma heurística de como proceder a busca do conhecimento a partir da base de conhecimentos (regras de produção) e dos fatos (base de dados) existentes;
2. Base de conhecimentos - responsável por armazenar de forma explícita em regras de produção o conhecimento de uma área específica de aplicação;
3. Base de dados - responsável pelo armazenamento dos fatos conhecidos.

Esta estratégia acabou gerando o aparecimento de ambientes de desenvolvimento de sistemas especialista em que há algum tipo de editor e sintaxe para se editar a base de conhecimentos e estabelecer os fatos, acoplado a um motor de inferências para realizar as buscas. Tais ambientes, denominados de Shells de Sistemas Especialistas, permitem que o usuário desenvolva sua própria base de conhecimentos, de uma forma mais fácil e rápida. Alguns destes sistemas possuem ainda tradutores de código para alguma linguagem procedimental (C, por

exemplo), permitindo que o sistema, após ter sido depurado, seja integrado com o restante do código que tenha sido desenvolvido de forma tradicional.

Vamos analisar como seriam geradas estas perguntas a partir um exemplo com a seguinte base de regras:

| regra | Se                                                                                  | Então                  |
|-------|-------------------------------------------------------------------------------------|------------------------|
| 1     | Formato = longa E<br>cor = verde OU amarela                                         | Fruta = banana         |
| 2     | Diâmetro > 10 cm E<br>Formato = redonda OU bojuda                                   | Origem = parreira      |
| 3     | Formato = redonda E<br>Diâmetro < 10 cm                                             | Origem = árvore        |
| 4     | Quantidade de sementes = 1                                                          | Classe = mono semente  |
| 5     | Quantidade de sementes > 1                                                          | Classe = multi semente |
| 6     | Origem = parreira E<br>Cor = verde                                                  | Fruta = melancia       |
| 7     | Origem = parreira E<br>Superfície = lisa E<br>Cor = amarela                         | Fruta = maracujá       |
| 8     | Origem = parreira E<br>Superfície = rugosa E<br>Cor = amarela                       | Fruta = melão          |
| 9     | Origem = árvore E<br>Cor = alaranjada E<br>Classe = mono semente                    | Fruta = abricó         |
| 10    | Origem = árvore E<br>Cor = alaranjada E<br>Classe = multi semente                   | Fruta = laranja        |
| 11    | Origem = árvore E<br>Cor = vermelha E<br>Classe = mono semente                      | Fruta = cereja         |
| 12    | Origem = árvore E<br>Cor = alaranjada E<br>Classe = mono semente                    | Fruta = pêssigo        |
| 13    | Origem = árvore E<br>Classe = multi semente E<br>Cor = vermelha OU amarela OU verde | Fruta = maçã           |
| 14    | Origem = árvore E<br>Classe = mono semente E<br>Cor = arroxeada                     | Fruta = ameixa         |

Suponha que inicialmente não conhecemos fato algum e que o objetivo é determinar qual é a fruta.

Seguindo a abordagem de busca retroativa (*backward chain*) teremos:

| Pilha de objetivos             | Regra avalia da | Efeito   | Pergunta : Qual o valor de... | Fato inferido ou resposta ou observação |
|--------------------------------|-----------------|----------|-------------------------------|-----------------------------------------|
| Fruta                          | 1               | suspensa |                               | Novo objetivo: forma                    |
| Forma, Fruta                   |                 |          |                               | Não há regras p/ forma                  |
| Forma, Fruta                   |                 |          | Forma ?                       | <b>Formato = redonda</b> (usuário)      |
| Fruta                          | 1               | falhou   |                               | Falhou na premissa 1                    |
| Fruta                          | 6               | suspensa |                               | Novo objetivo: origem                   |
| Origem, Fruta                  | 2               | suspensa |                               | Novo objetivo: diâmetro                 |
| Diâmetro, Origem, Fruta        |                 |          |                               | Não há regras p/ diâmetro               |
| Diâmetro, Origem, Fruta        |                 |          | Diâmetro ?                    | <b>Diâmetro = 3 cm</b> (usuário)        |
| Origem, Fruta                  | 2               | falhou   |                               | Falhou na premissa 1                    |
| Origem, Fruta                  | 3               | ativada  |                               | <b>Origem = árvore</b>                  |
| Fruta                          | 6               | falhou   |                               | Falhou na premissa 1                    |
| Fruta                          | 7               | falhou   |                               | Falhou na premissa 1                    |
| Fruta                          | 8               | falhou   |                               | Falhou na premissa 1                    |
| Fruta                          | 9               | suspensa |                               | Novo objetivo: cor                      |
| Cor, Fruta                     |                 |          |                               | Não há regras p/ cor                    |
| Cor, Fruta                     |                 |          | Cor ?                         | <b>Cor = vermelha</b> (usuário)         |
| Fruta                          | 9               | falhou   |                               | Falhou na premissa 2                    |
| Fruta                          | 10              | falhou   |                               | Falhou na premissa 2                    |
| Fruta                          | 11              | suspensa |                               | Novo objetivo: classe                   |
| Classe, Fruta                  | 4               | suspensa |                               | Novo objetivo: quant. sement.           |
| Quant. sementes, Classe, Fruta |                 |          |                               | Não há regras p/ quantidade de sementes |
| Quant. sementes, Classe, Fruta |                 |          | Quant. de sementes?           | <b>Quant. de sementes = 1</b> (usuário) |
| Classe, Fruta                  | 4               | ativada  |                               | <b>Classe = mono semente</b>            |
| Fruta                          | 11              | ativada  |                               | Fruta = cereja                          |
|                                |                 |          |                               | Pilha de objetivos vazia, fim!          |

Uma estratégia auxiliar de busca é usada por alguns sistemas especialista ou *shells* (Crisalys, VP-expert) visando diminuir o espaço de busca e facilitar a implementação de interfaces com o usuário. Este esquema consiste em ativar regras a partir de modificações em valores de variáveis, no que poderia ser chamado de uma busca dirigida a eventos. Nestes sistemas, a alteração de uma variável, a partir por exemplo de uma ação do usuário, produz a avaliação de todas as regras em que aquela variável apareça na parte das premissas. Assim, novos fatos podem ser automaticamente ativados a cada mudança do valor de uma variável.

### 3.4-Trabalhando com probabilidades

Muitas das decisões que tomamos, são baseadas em algum cálculo da probabilidade de acerto, dadas as incertezas sobre os fatos conhecidos. Assim, um médico é capaz de diagnosticar mesmo ter certeza sobre os sintomas relatados pelo paciente, ou das taxas reportadas pelos exames. Da mesma forma, um analista financeiro é capaz de tomar decisões com boas perspectivas de acerto, mesmo diante das incertezas e conflitos dos indicadores do mercado financeiro. Esta capacidade inata do ser humano, está associada a algum tipo de cálculo de probabilidades.

Entretanto, implementar cálculos estatísticos a partir dos princípios Bayesianos de probabilidade, torna os sistemas especialistas difíceis de especificar, na medida em que tratamentos rigorosamente matemáticos de probabilidade utilizam informações nem sempre disponíveis ou simplificações que não são claramente justificáveis em aplicações práticas. Assim, foram construídas alternativas que também lidam com confiabilidade das afirmativas, embora em uma base menos rigorosa e ligada basicamente à teoria dos conjuntos. Na maioria dos sistemas, para cada afirmativa é possível usar um fator de confiança. Este fator é um número entre 0% e 100% que está relacionado à expectativa de que aquela afirmativa seja verdadeira. A partir destes valores, se estabelece um limite (em geral 50%, mas que freqüentemente pode ser mudado nas *shells*), para que as afirmativas sejam consideradas verdadeiras ou falsas. Assim se temos uma variável *Tempo* que possui o valor *Bom* com um grau de confiança 55%, a regra: Se *Tempo* = *Bom* então..., será ativada assim que seja examinada, dado que o fator de confiança do valor *Bom* é maior que 50%. Caso o fator de confiança fosse 43%, a regra não seria ativada pois o valor é menor que 50% e a premissa seria considerada Falsa.

Os cálculos com os fatores de confiança envolvem os operadores de implicação (ENTÃO), conjunção (E) e disjunção (OU), da seguinte forma:

1. Para operações de implicação - o grau de confiança da premissa é multiplicado pelo grau de confiança da conclusão;
2. Para operações de conjunção - o grau de confiança de todas as premissas é multiplicado para obter o grau de confiança da premissa composta;
3. Para operações de disjunção - o grau de confiança de todas as premissas é somado e o resultado é subtraído da multiplicação dos mesmos graus de confiança, para obter o grau de confiança da premissa composta.

Por exemplo, suponha que conhecemos os fatos A, C e E com confiabilidade de 90% e temos as seguintes regras:

Se A Então B (confiabilidade 70%)

Se B e C então D (confiabilidade 100%)

Se D ou E então F (confiabilidade 40%)

Se F então G (confiabilidade 100%)

A primeira regra leva a:  $CF(A) * CF(\text{conclusão}) = 0,9 * 0,7 = 0,63 = CF(B)$

A Segunda regra leva a:  $CF(B) * CF(C) = 0,63 * 0,9 = 0,567 * 1 = CF(D)$

A terceira regra leva a:  $CF(D) + CF(E) - CF(D) * CF(E) = 0,567 + 0,9 - 0,567 * 0,9 = 1,467 - 0,51 = 0,957 * 0,4 = 0,383 = CF(F)$

A quarta regra não será acionada porque  $CF(F) = 0,383 < 0,50$

Quando diferentes regras levam a diferentes graus de confiança para uma mesma variável, em geral é também aplicado o cálculo da disjunção para estes dois valores, como no caso do operador OU. Assim, para o exemplo acima, caso tivéssemos uma regra que fosse:

Se B então F (confiabilidade 90%)

Teríamos:  $CF(B) * 0,90 = 0,63 * 0,90 = 0,567 = CF(F)$

Como a  $CF(F)$  anterior era 0,383, a nova  $CF(F) = 0,567 + 0,383 - 0,567 * 0,383 = 0,95 - 0,217 = 0,733 = CF(F)$

Alguns sistemas tratam as operações com fatores de confiança de uma forma alternativa, utilizando funções de máximo e mínimo. Assim as operações de conjunção têm seu fator de confiança resultante calculado como o mínimo entre os valores de confiança das diversas premissas. Já a operação de disjunção leva a um fator de confiança igual ao máximo dos fatores das premissas envolvidas. A operação de implicação, nesta forma de cálculo, geralmente também é feita através do produto entre o fator de confiança resultante da premissa e o fator de confiança atribuído à implicação. Se fosse realizado este tipo de cálculo no exemplo acima, a regra 2 levaria a um grau de confiança para D de:  $CF(D) = \text{Min}(0,63, 0,9) * 1 = 0,63 = CF(D)$ . Já a regra 3 levaria a:  $CF(F) = \text{Max}(0,63, 0,9) * 0,4 = 0,9 * 0,4 = 0,36 = CF(F)$ .

Em qualquer caso, a atribuição dos fatores de confiança relativos às implicações é de responsabilidade do especialista que definiu a regra e, provavelmente, é oriundo da experiência na aplicação do conhecimento formal aprendido em casos de uso do passado.

Para analisar a aplicação dos cálculos dos fatores de confiança, vamos observar sua aplicação ao conjunto de regras do seguinte problema:

O carro de Odete Roitman foi furtado e os suspeitos são o mordomo e o genro da vítima.

Temos os seguintes conhecimentos sobre furto de carros:

| regra | Se                                                            | Então                                    |
|-------|---------------------------------------------------------------|------------------------------------------|
| 1     | O suspeito tinha um motivo E<br>O suspeito teve oportunidade  | O suspeito é culpado CF(0,6)             |
| 2     | O suspeito tem um alibi                                       | O suspeito não é culpado CF(0,8)         |
| 3     | As impressões digitais do suspeito foram encontradas no carro | O suspeito é culpado CF(0,4)             |
| 4     | As chaves foram deixadas no carro                             | O suspeito teve uma oportunidade CF(0,9) |
| 5     | O suspeito não gostava da vítima                              | O suspeito tinha um motivo CF(0,5)       |
| 6     | O suspeito precisava de um meio de transporte                 | O suspeito tinha um motivo CF(0,9)       |
| 7     | As impressões digitais do suspeito foram encontradas na chave | O suspeito é culpado CF(0,7)             |

Além do conhecimento acima, retirados das estatísticas criminais sobre roubos de carros, sabemos os seguintes fatos sobre o roubo do carro de Odete Roitman:

1. O carro do mordomo (um fusca 68) estava quebrado (portanto ele precisava de um meio de transporte) com CF(1,0)
2. O carro do genro de Odete Roitman (um gol 2.0) não estava quebrado (portanto ele não precisava de um meio de transporte) com CF(1,0)
3. As impressões digitais do mordomo estavam no carro de Odete Roitman com CF(1,0)
4. As impressões digitais do genro de Odete Roitman não estavam no carro de Odete Roitman com CF(1,0)
5. As impressões digitais do mordomo não estavam na chave do carro de Odete Roitman com CF(1,0)
6. As impressões digitais do genro de Odete Roitman estavam na chave do carro de Odete Roitman com CF(1,0)
7. As chaves do carro de Odete Roitman foram deixadas no carro com CF(1,0)
8. O mordomo não gostava de Odete Roitman com CF(0,6)
9. O genro gostava de Odete Roitman com CF(0,8)
10. O mordomo estava assistindo TV quando o crime ocorreu (portanto ele tinha um alibi) com CF(0,85)
11. O genro estava dormindo quando o crime ocorreu (portanto ele tinha um alibi, apesar de ninguém ter visto) com CF(0,2)

Desejamos computar a possibilidade do mordomo ser o culpado e a possibilidade do genro ser o culpado.

Usando as regras de operação de teoria dos conjuntos, temos:

Para o suspeito mordomo, usando busca retroativa:

| Pilha de objetivos    | Regra avaliada | Efeito   | Fato inferido com calculo do grau de confiabilidade ou observação                                                                     |
|-----------------------|----------------|----------|---------------------------------------------------------------------------------------------------------------------------------------|
| Culpado               | 1              | Suspensa | Novo objetivo: Motivo                                                                                                                 |
| Motivo, Culpado       | 5              | Ativada  | <b>Motivo = sim CF = <math>0,6 * 0,5 = 0,3</math></b>                                                                                 |
| Oportunidade, Culpado | 1              | Suspensa | Novo objetivo: Oportunidade                                                                                                           |
| Oportunidade, Culpado | 4              | Ativada  | <b>Oportunidade = sim CF = <math>1 * 0,9 = 0,9</math></b>                                                                             |
| Culpado               | 1              | Falhou   | $CF = 0,3 * 0,9 = 0,27 < 0,5$                                                                                                         |
| Culpado               | 2              | Ativada  | $CF(\text{álibi}) * CF(\text{não culpado}) = 0,85 * 0,8 = 0,68 \rightarrow$<br><b>Culpado = sim CF = <math>1 - 0,68 = 0,32</math></b> |
| Culpado               | 3              | Ativada  | <b>Culpado = sim CF = <math>1 * 0,4 = 0,4 \rightarrow</math></b><br>nova <b>CF = <math>0,4 + 0,32 - 0,4 * 0,32 = 0,592</math></b>     |
| Culpado               | 7              | Falhou   | $CF(\text{não estavam}) = 1 \rightarrow CF(\text{estavam}) = 0 < 0,5$                                                                 |

Não havendo mais regras que tenham como conclusão um culpado, conclui-se que o mordomo é culpado com 59,2% de confiabilidade.

Para o suspeito genro, usando busca retroativa:

| Pilha de objetivos | Regra avaliada | Efeito      | Fato inferido com calculo do grau de confiabilidade ou observação                                            |
|--------------------|----------------|-------------|--------------------------------------------------------------------------------------------------------------|
| Culpado            | 1              | Suspensa    | Novo objetivo: Motivo                                                                                        |
| Motivo, Culpado    | 5              | Falhou      | $CF(\text{gostava}) = 0,8 \rightarrow$<br>$CF(\text{não gostava}) = (1 - 0,8) = 0,2 < 0,5$                   |
| Motivo, Culpado    | 6              | Falhou      | $CF(\text{não precisava}) = 1,0 \rightarrow$<br>$CF(\text{precisava}) = (1 - 1) = 0 < 0,5$                   |
| Motivo, Culpado    | 1              | Abandona da | Retira objetivo: Motivo (não há mais regras para motivo e ainda há para culpado)                             |
| Culpado            | 2              | Falhou      | $CF(\text{álibi}) = 0,2 < 0,5$                                                                               |
| Culpado            | 3              | Falhou      | $CF(\text{sem impressões no carro}) = 1 \rightarrow$<br>$CF(\text{impressões no carro}) = (1 - 1) = 0 < 0,5$ |
| Culpado            | 7              | Ativada     | <b>Culpado = sim CF = <math>CF(\text{impressões na chave}) * 0,7 = 0,7 * 1 = 0,7</math></b>                  |

Não havendo mais regras que tenham como conclusão um culpado, conclui-se que o genro é culpado com 70,0% de confiabilidade.

Usando estes mesmos critérios para o resultado das operações, calcule:

1. O grau de confiança de que o crime foi cometido por um dos dois;
2. O grau de confiança de que o crime foi cometido por ambos.

Refaça os cálculos usando as funções de máximo e mínimo para os operadores de conjunção e disjunção.