

Inteligência Artificial

Aula 6
 Prof^a Bianca Zadrozny
<http://www.ic.uff.br/~bianca/ia-pos>

Aula 6 - 05/10/2010

1

Tomada de decisões simples

Capítulo 16 – Russell & Norvig
 Seções 16.1 a 16.5

Aula 6 - 05/10/2010

2

Combinação de crenças e desejos sob incerteza

- *“Para julgar o que se deve fazer para obter um bem ou evitar um mal, é necessário considerar não apenas o bem ou o mal em si, mas também a probabilidade de ele acontecer, e ainda visualizar geometricamente a proporção que esses itens têm em conjunto”*
 (Port-Royal Logic, Arnauld, 1662)

Aula 6 - 05/10/2010

3

Combinação de crenças e desejos sob incerteza

- Função de Utilidade: Atribui um número para expressar a **desejabilidade** de um estado para o agente.
 - As utilidades são combinadas com probabilidades dos estados para tomada de decisão.
 - Notação: $U(S)$

Aula 6 - 05/10/2010

4

Utilidade Esperada

- Ação tem i resultados possíveis $Resultado_i(A)$
- Probabilidade de cada resultado:
 $P(Resultado_i(A)|Fazer(A),E)$, onde E resume a evidência disponível do agente sobre o mundo.
- A utilidade esperada da ação A dada a evidência atual E é:

$$EU(A|E) = \sum_i P(Resultado_i(A)|Fazer(A),E)U(Resultado_i(A))$$

Aula 6 - 05/10/2010

5

Princípio de Utilidade Máxima Esperada (UME)

- Um agente racional deve escolher uma ação que **maximize** a utilidade esperada do agente.
- Pode ser usado diretamente para tomada de decisões simples (i.e., escolher uma única ação).
- Para tomada de decisões complexas (sequências de ações), precisamos enumerar todas as sequências e escolher a sequência com máxima utilidade esperada.
 - Próximo capítulo, técnicas para fazer isso de forma eficiente.

Aula 6 - 05/10/2010

6

A Base da Teoria da Utilidade

- Por que maximizar a utilidade média é tão especial?
- Por que não tentar minimizar a pior perda possível?
- Como sabemos que existe uma função de utilidade que captura as preferências do agente?
- Podemos demonstrar que o princípio de UME pode ser derivado a partir de **restrições** sobre as **preferências** que um agente racional pode ter.

Aula 6 - 05/10/2010

7

Preferências

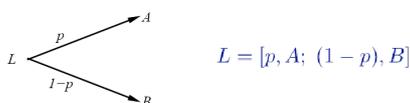
- **Notação**
 - $A \succ B$: A é preferível a B
 - $A \sim B$: o agente está indiferente entre A e B
 - $A \succeq B$: O agente prefere A a B ou está indiferente
- onde A e B são estados.

Aula 6 - 05/10/2010

8

Loterias

- **Loteria**: distribuição de probabilidade sobre um conjunto de resultados (prêmios)



- Cada resultado de uma loteria pode ser um estado ou outra loteria.

Aula 6 - 05/10/2010

9

Restrições para as Preferências Racionais: Axiomas da Utilidade

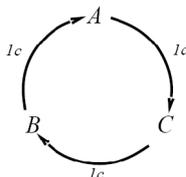
- **Ordenabilidade**: $(A \succ B) \vee (B \succ A) \vee (A \sim B)$
- **Transitividade**: $(A \succ B) \wedge (B \succ C) \implies (A \succ C)$
- **Continuidade**: $A \succ B \succ C \implies \exists p [p, A; 1-p, C] \sim B$
- **Substitutibilidade**:
 - $A \sim B \implies [p, A; 1-p, C] \sim [p, B; 1-p, C]$
- **Monotonicidade**:
 - $A \succ B \implies (p \geq q \iff [p, A; 1-p, B] \succeq [q, A; 1-q, B])$

Aula 6 - 05/10/2010

10

Violar restrições leva a irracionalidade

- Exemplo: se um agente viola a restrição de transitividade, seria possível induzi-lo a gastar todo o seu dinheiro.
 - Se $B \succ C$, então se ele tem C daria 1 centavo (por exemplo), para trocar C por B .
 - Se $A \succ B$, então ele daria 1 centavo (por exemplo), para trocar B por A .
 - Se $C \succ A$, então ele daria 1 centavo (por exemplo), para trocar A por C .
 - Volta ao estado inicial com 3 centavos a menos.



Aula 6 - 05/10/2010

11

Princípio de Utilidade e Princípio de Utilidade Máxima Esperada

- Teorema (Ramsey, 1931; von Neumann e Morgenstern, 1944): Dadas preferências satisfazendo as restrições, então existe uma função de valores reais U que opera sobre estados tal que

$$U(A) \geq U(B) \iff A \succeq B$$

$$U([p_1, S_1; \dots; p_n, S_n]) = \sum_i p_i U(S_i)$$

Aula 6 - 05/10/2010

12

Princípio de Utilidade e Princípio de Utilidade Máxima Esperada

- Teorema (Ramsey, 1931; von Neumann e Morgenstern, 1944): Dadas preferências satisfazendo as restrições, então existe uma função de valores reais U que opera sobre estados tal que

$$U(A) \geq U(B) \iff A \succeq B$$

$$U([p_1, S_1; \dots; p_n, S_n]) = \sum_i p_i U(S_i)$$

Aula 6 - 05/10/2010

13

Função de Utilidade

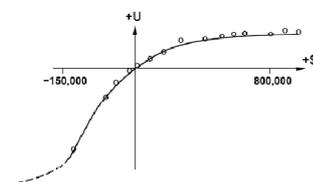
- Sabemos que existe uma função de utilidade mapeando estados a números reais, mas como encontrá-la?
- Uma maneira é usar uma “Loteria padrão”
 - Comparar o estado S com uma loteria L_p que tem probabilidade p de retornar a utilidade máxima possível \bar{u} e probabilidade $1 - p$ de retornar a utilidade mínima possível \underline{u} .
 - Ajustar p até que $S \sim L_p$
 - Aí teremos $U(S) = p(\bar{u} - \underline{u})$

Aula 6 - 05/10/2010

14

Utilidade do Dinheiro

- Não é uma função linear: conforme aumenta a quantidade de dinheiro, a taxa de crescimento da utilidade diminui.
 - Pessoas ficam mais avessas a risco conforme aumentam os valores
 - Preferimos ganhar R\$500.000 to que ter a chance de ganhar de R\$1.000.000 com probabilidade 0.6.
 - Do lado da dívida a tendência é ser favorável ao risco.



Aula 6 - 05/10/2010

15

Redes de Decisão

- Adicionar **nós de ação** (retângulos) e **nós de utilidade** (losangos) a redes bayesianas.
 - Nós de ação têm que ser pais e funcionam como evidências (variáveis observadas).
 - Nós de utilidade têm como pais todos os nós que afetam a utilidade do agente.



Aula 6 - 05/10/2010

16

Redes de Decisão

- Algoritmo:
 1. Para cada valor do nó de ação:
 - Calcular probabilidades dos pais do nó de utilidade dadas a ação e as outras variáveis de evidência (usar um algoritmo de inferência em redes bayesianas).
 - Calcular valor esperado da utilidade usando as probabilidades obtidas.
 2. Retornar ação com maior valor esperado de utilidade.

Aula 6 - 05/10/2010

17

Exemplo: Redes de Decisão

Umbrella = leave

$$EU(\text{leave}) = \sum_w P(w)U(\text{leave}, w) = 0.7 \cdot 100 + 0.3 \cdot 0 = 70$$

Umbrella = take

$$EU(\text{take}) = \sum_w P(w)U(\text{take}, w) = 0.7 \cdot 20 + 0.3 \cdot 70 = 35$$

Optimal = leave

$$MEU(\emptyset) = \max_a EU(a) = 70$$

	W	P(W)
sun		0.7
rain		0.3

A	W	U(A,W)
leave	sun	100
leave	rain	0
take	sun	20
take	rain	70

Slide 7
Hal Daume III

Aula 6 - 05/10/2010

CS 5300: Decisions + Information

18

Exemplo: Redes de Decisão

Umbrella = leave

$$EU(\text{leave}|\text{bad}) = \sum_w P(w|\text{bad})U(\text{bad}, w)$$

$$= 0.34 \cdot 100 + 0.66 \cdot 0 = 34$$

Umbrella = take

$$EU(\text{take}|\text{bad}) = \sum_w P(w|\text{bad})U(\text{take}, w)$$

$$= 0.34 \cdot 20 + 0.66 \cdot 70 = 53$$

Optimal = take

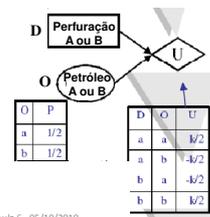
$$MEU(F = \text{bad}) = \max_a EU(a|\text{bad}) = 53$$

W	P(W F=bad)
sun	0.34
rain	0.66

A	W	U(A,W)
leave	sun	100
leave	rain	0
take	sun	20
take	rain	70

Valor da Informação

- Calcular valor de adquirir cada possível evidência
 - Pode ser feito diretamente a partir da rede de decisão
- Exemplo:



Exemplo: Valor da Informação

- Exemplo: comprar direito de perfuração de petróleo
 - Duas regiões A e B, uma tem petróleo, valendo k.
 - Probabilidade a priori em cada região é 0.5
 - Preço atual de cada região é k/2
 - UME = 0 (qualquer ação maximiza essa utilidade)
- Solução: calcular valor da informação = ganho esperado de UME para cada evidência obtida.
 - Suponha que podemos verificar com um teste O se a região A contém ou não óleo. Quando valeria à pena pagar por esse teste?
 - Depois da verificação o ganho esperado em utilidade é k/2.
 - Logo VPI(O) = k/2 (VPI = valor da informação perfeita)

Valor da Informação

- Valor esperado da ação de utilidade máxima dada a evidência atual

$$MEU(e) = \max_s \sum_s P(s|e) U(s, a)$$
- Valor esperado da ação de utilidade máxima da a evidência atual + nova evidência

$$MEU(e, e') = \max_s \sum_s P(s|e, e') U(s, a)$$
- Como E' é desconhecida, tenho que calcular ganho esperado considerando todos os valores E'=e'

$$VPI_e(E') = \sum_{e'} P(e'|e) (MEU(e, e') - MEU(e))$$

VPI Example

MEU with no evidence

$$MEU(\phi) = \max_a EU(a) = 70$$

MEU if forecast is bad

$$MEU(F = \text{bad}) = \max_a EU(a|\text{bad}) = 53$$

MEU if forecast is good

$$MEU(F = \text{good}) = \max_a EU(a|\text{good}) = 95$$

Forecast distribution

F	P(F)
good	0.59
bad	0.41

$$\Rightarrow 0.59 \cdot (95 - 70) + 0.41 \cdot (53 - 70)$$

$$0.59 \cdot (+25) + 0.41 \cdot (-17) = +22$$

$$VPI_e(E') = \sum_{e'} P(e'|e) (MEU(e, e') - MEU(e))$$