

INF623

2024/1



Inteligência Artificial



A7: Busca competitiva II

Plano de aula

- ▶ Oponentes e jogos estocásticos
- ▶ Revisão de probabilidades
- ▶ Algoritmo expectimax
- ▶ Modelos probabilísticos
- ▶ Expectimax com profundidade limitada
- ▶ Generalizações do minimax

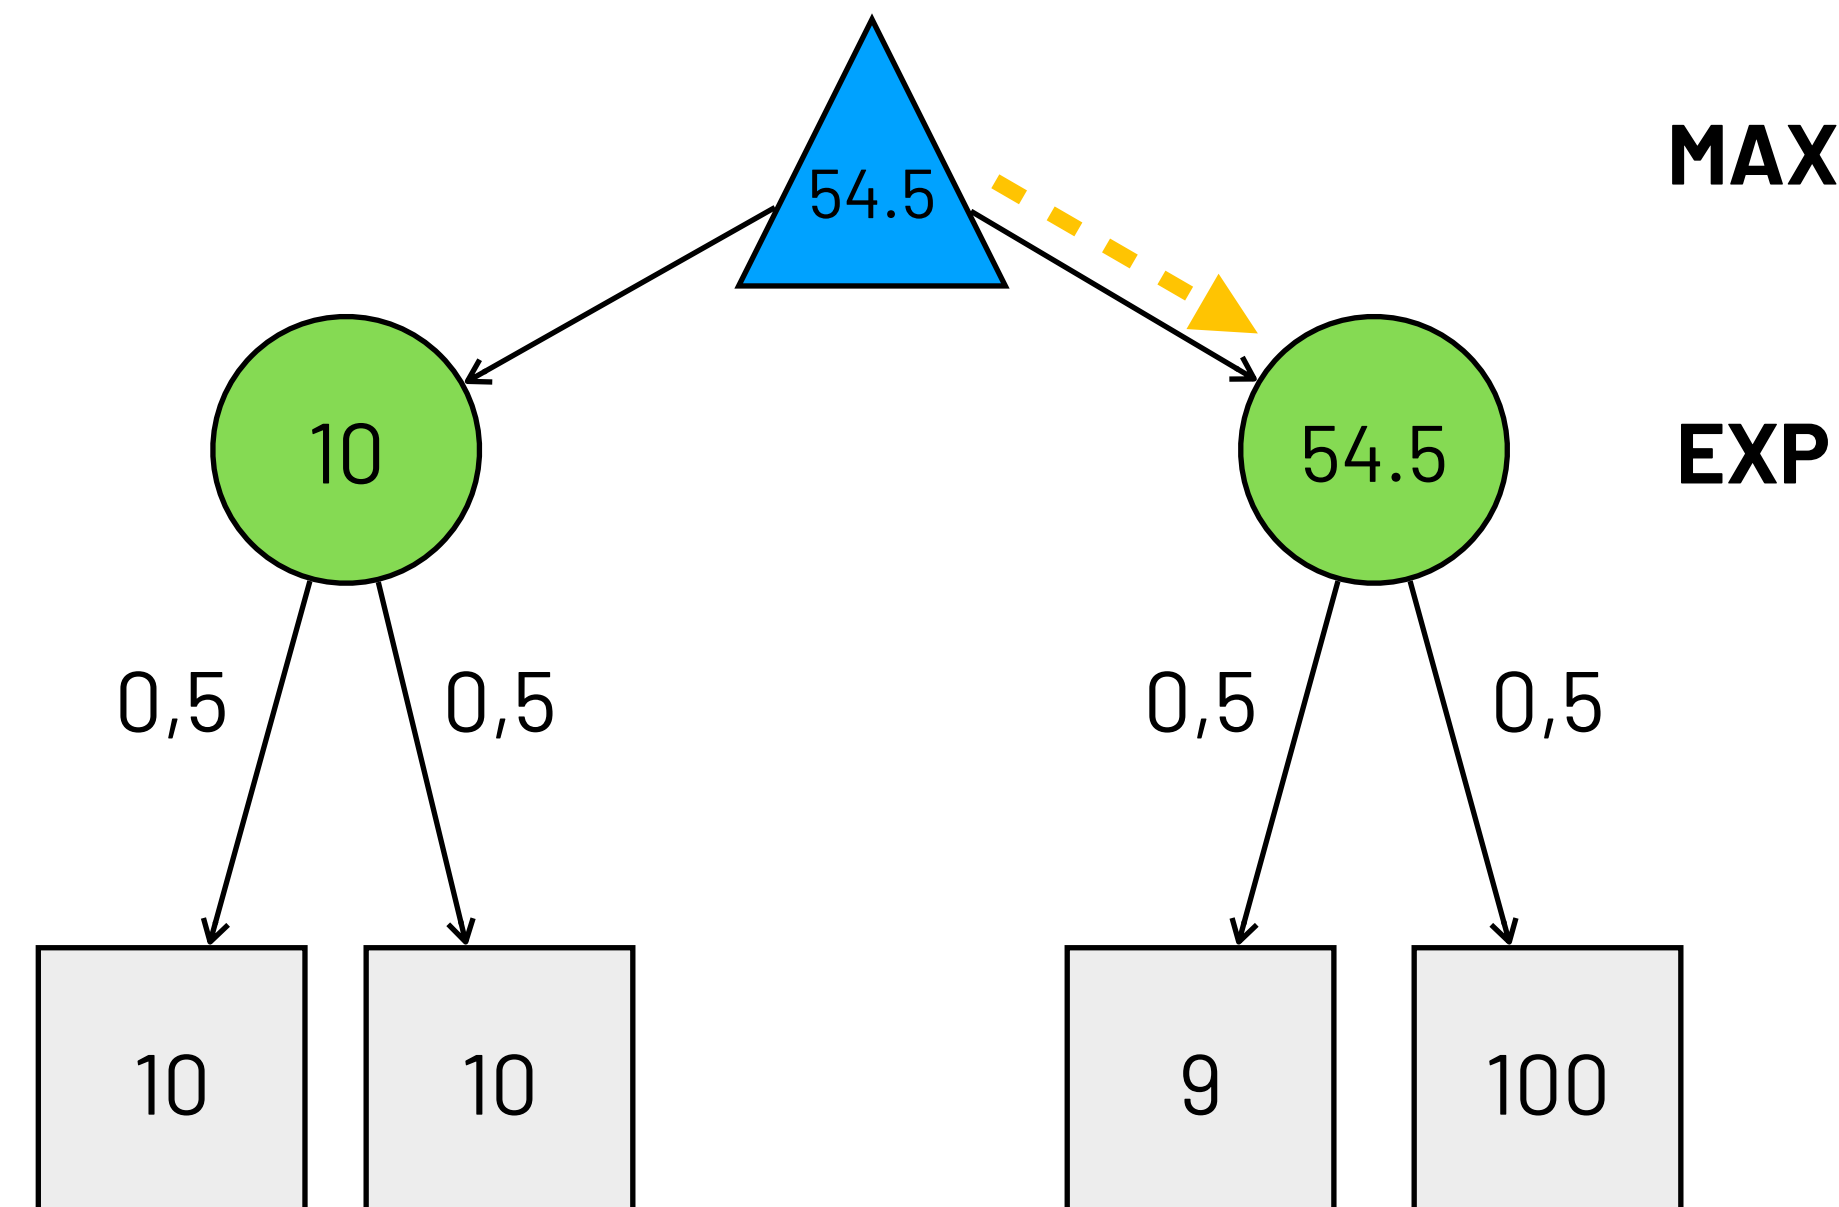

Exemplo 1: oponente racional

O algoritmo minimax calcula o valor $V(s)$ para cada estado s assumindo um **oponente racional (ótimo)**



Exemplo 2: oponente estocástico

Qual o problema de usar o minimax quando o oponente não é ótimo (e.g., estocástico)?



Quando o oponente é estocástico e usamos o minimax, jogamos de forma pessimista e perdemos oportunidades!

Outras situações estocásticas

Existem diversas situações onde o resultado de ações são incertos:

- ▶ Oponentes sub-ótimos:
 - ▶ Falta de habilidade/decisões aleatórias
 - ▶ Recursos computacionais limitados
- ▶ Jogos estocásticos (e.g., com rolagem de dados)
- ▶ Ações podem falhar (e.g., quando movemos um robô, as rodas podem escorregar)



Revisão de probabilidades

- ▶ Uma **variável aleatória** representa um evento no qual o resultado é incerto
- ▶ Uma **distribuição de probabilidades** é uma função que associa pesos a diferentes resultados
- ▶ Exemplo:

- ▶ Variável aleatória: $T \rightarrow$ trânsito na Av. P H Rolfs

- ▶ Resultados: $T \in \{\text{nenhum, pouco, muito}\}$

- ▶ Distribuição:

- ▶ $P(T=\text{nenhum}) = 0,25$

- ▶ $P(T=\text{pouco}) = 0,50$

- ▶ $P(T=\text{muito}) = 0,25$

- ▶ Algumas leis da probabilidade:


- ▶ Probabilidades são sempre não-negativas

- ▶ Probabilidades sobre todos os resultados possíveis somam um

- ▶ Ao obter mais evidências, as probabilidades podem mudar:

- ▶ $P(T=\text{muito}) = 0,25$


- ▶ $P(T=\text{muito} \mid \text{Hora}=18:00\text{h}) = 0,9$



P	0,25	0,50	0,25
---	------	------	------

Revisão de probabilidades

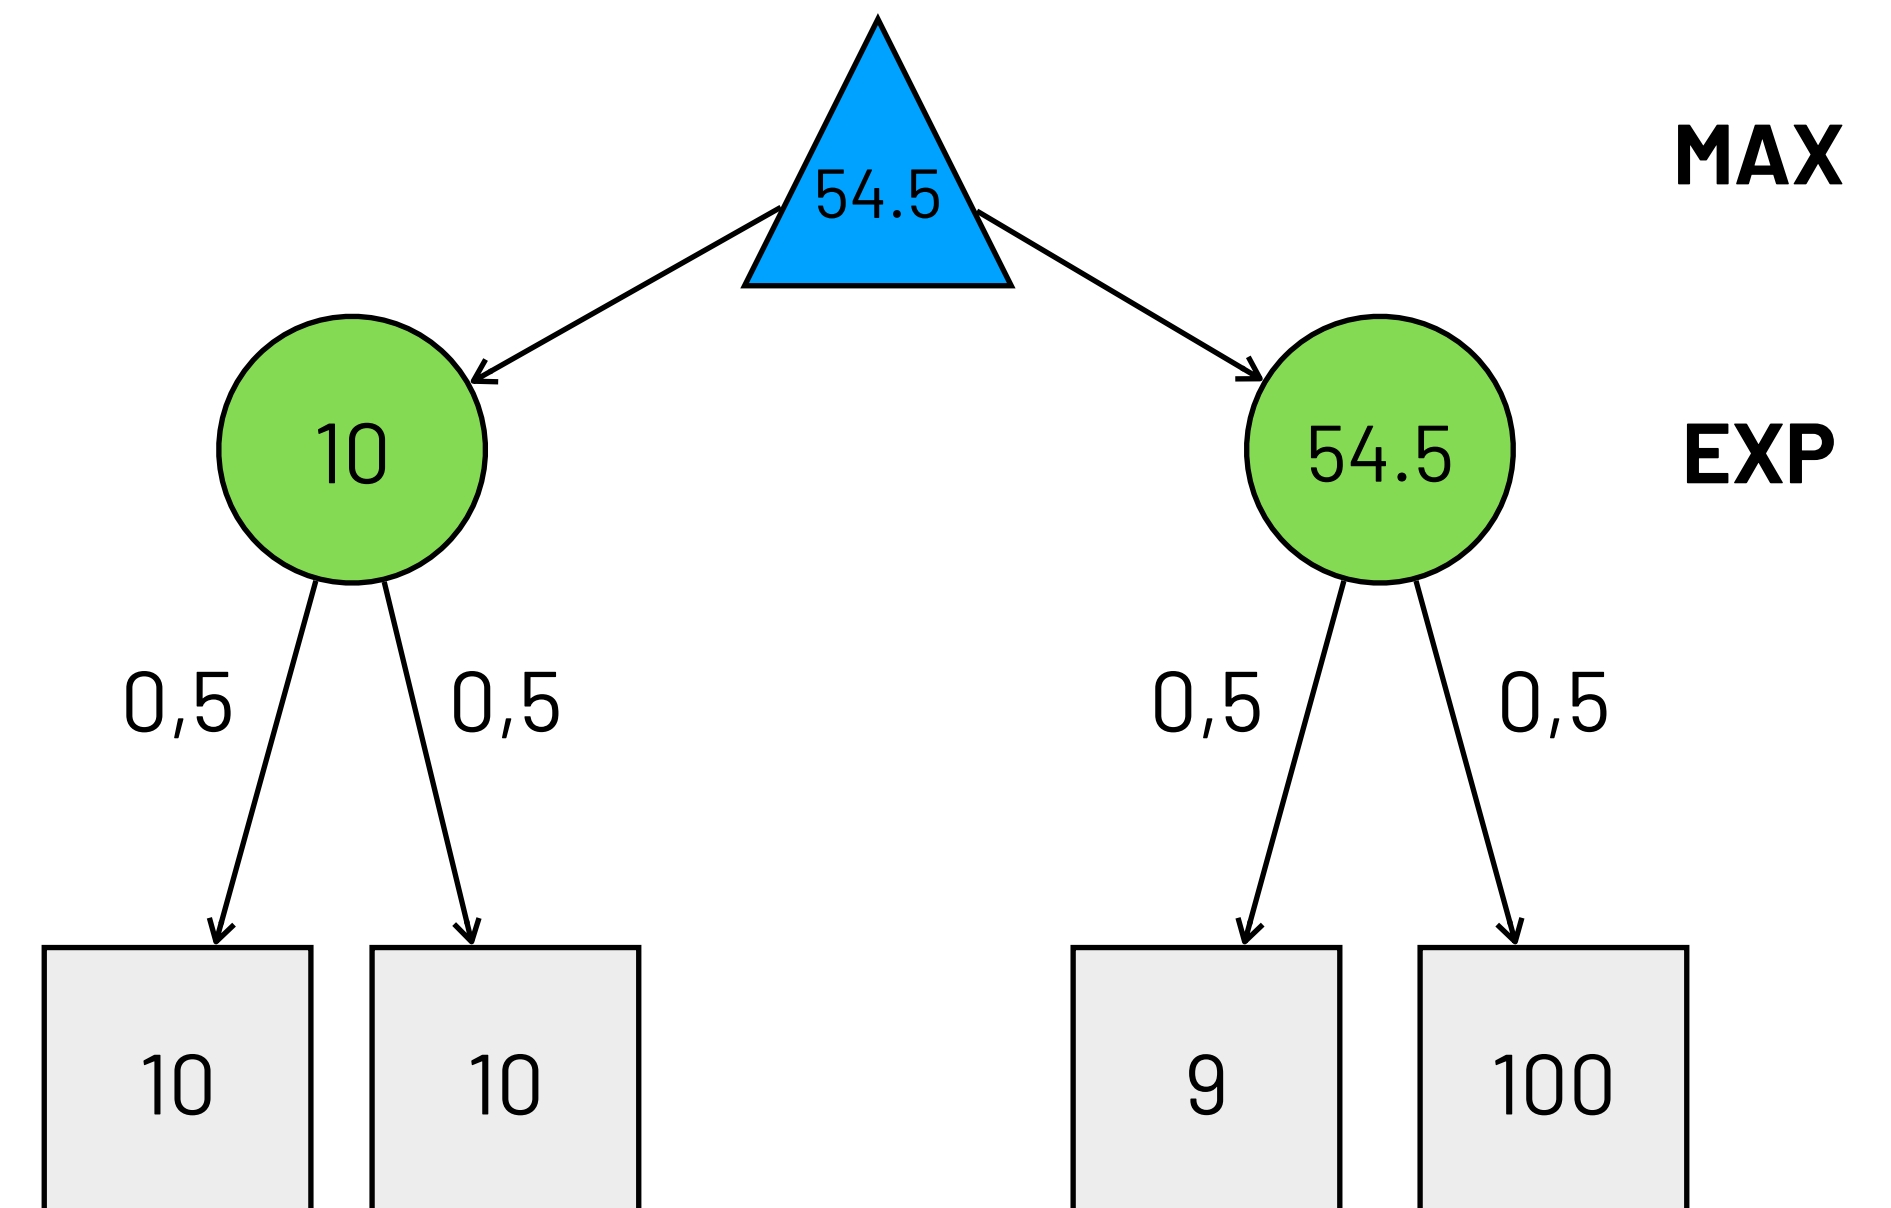
- ▶ O **valor esperado** de uma variável aleatória é a media dos resultados possíveis ponderada por suas probabilidades
- ▶ Exemplo: Qual o tempo esperado para chegar na rodoviária?



Algoritmo expectimax


O algoritmo **expectimax** produz uma estratégia que maximiza a utilidade média em **jogos de soma zero**:

- ▶ Aplicado em jogos ou oponentes estocásticos
- ▶ Os jogadores alternam suas jogadas em turnos
 - ▶ Um jogador maximiza o resultado (**MAX**)
 - ▶ O outro joga de forma estocástica (**EXP**)
- ▶ O algoritmo calcula o valor expectimax para cada estado: a utilidade esperada contra um **oponente estocástico**



Algoritmo expectimax


```
def valor-max(s, A, E, U, P):  
1. if E(s) == True:  
2.     return U(s, 'max')  
3. v = -∞  
4. for filho in A(s):  
5.     v = max(v, valor-exp(filho, A, E, U, P))  
6. return v  
  
def valor-exp(s, A, E, U, P):  
1. if E(s) == True:  
2.     return U(s, 'exp')  
3. v = 0  
4. for filho in A(s):  
5.     v += P(filho) * valor-max(filho, A, E, U, P)  
6. return v
```




Algoritmo expectimax

```
def valor-max(s, A, E, U, P):  
1. if E(s) == True:  
2.     return U(s, 'max')  
3. v = -∞  
4. for filho in A(s):  
5.     v = max(v, valor-exp(filho, A, E, U, P))  
6. return v  
  
def valor-exp(s, A, E, U, P):  
1. if E(s) == True:  
2.     return U(s, 'exp')  
3. v = 0  
4. for filho in A(s):  
5.     v += P(filho) * valor-max(filho, A, E, U, P)  
6. return v
```



$$v = \frac{1}{2} 8 + \frac{1}{3} 24 + \frac{1}{6} 12 = 10$$



Exemplo 3: execução do expectimax



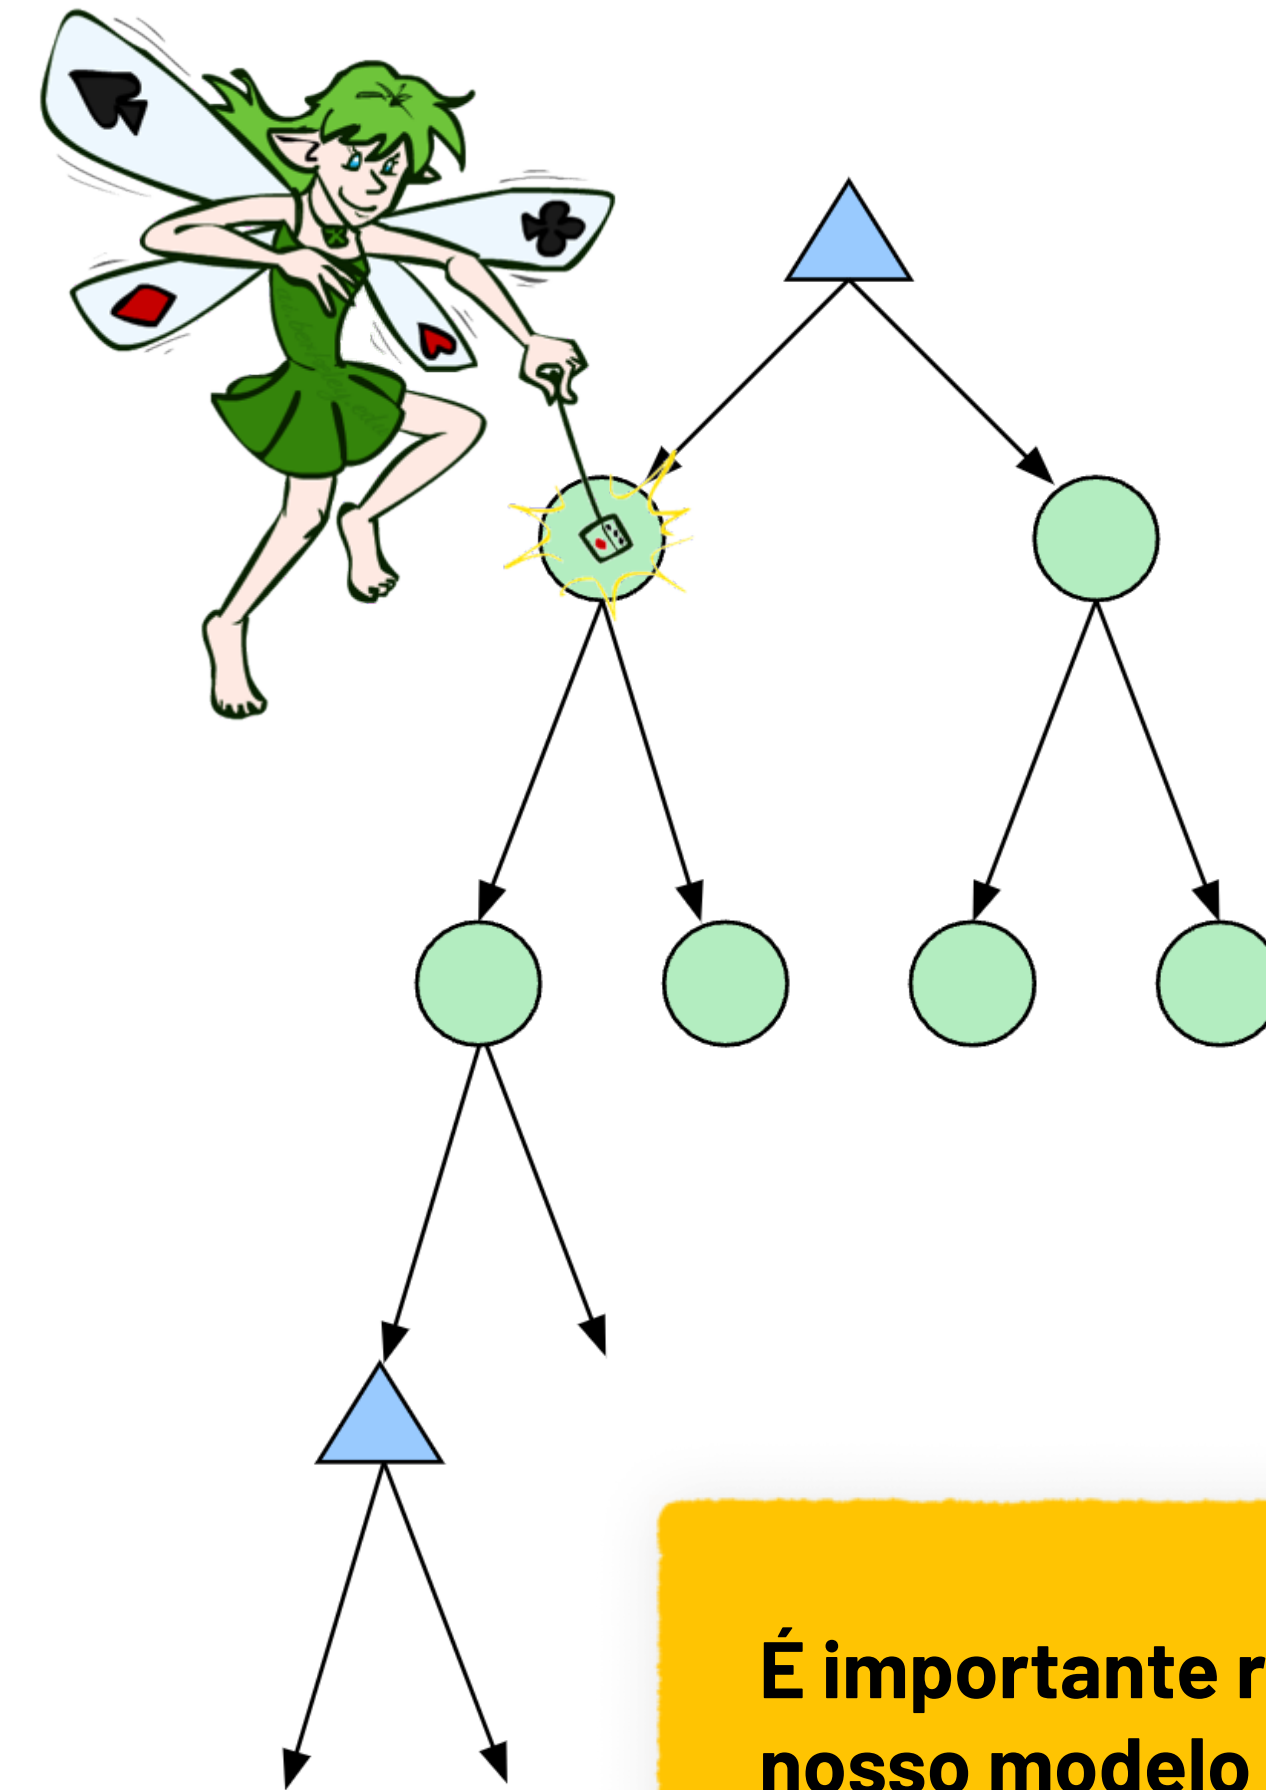
Poda de árvore no expectimax?



Em expectimax não podemos podar a árvore, pois os valores dos filhos ainda não descobertos podem dominar o valor da média.

Que probabilidades usar?


- ▶ Na busca expectimax, temos um oponente (ou ambiente) probabilístico. Como modelar o comportamento desse oponente?
 - ▶ O modelo pode ser uma distribuição uniforme simples (lançar um dado)
 - ▶ O modelo pode ser sofisticado e exigir muita computação
 - ▶ O modelo tem um chance de agir de maneira ótima ou aleatória
 - ▶ etc..
- ▶ Por enquanto, suponha que as probabilidades de cada estado são dadas com o problema



É importante ressaltar que nosso modelo do oponente pode estar errado!

Expectimax com profundidade limitada

Assim como no minimax, também é possível realizar o expectimax com profundidade limitada.

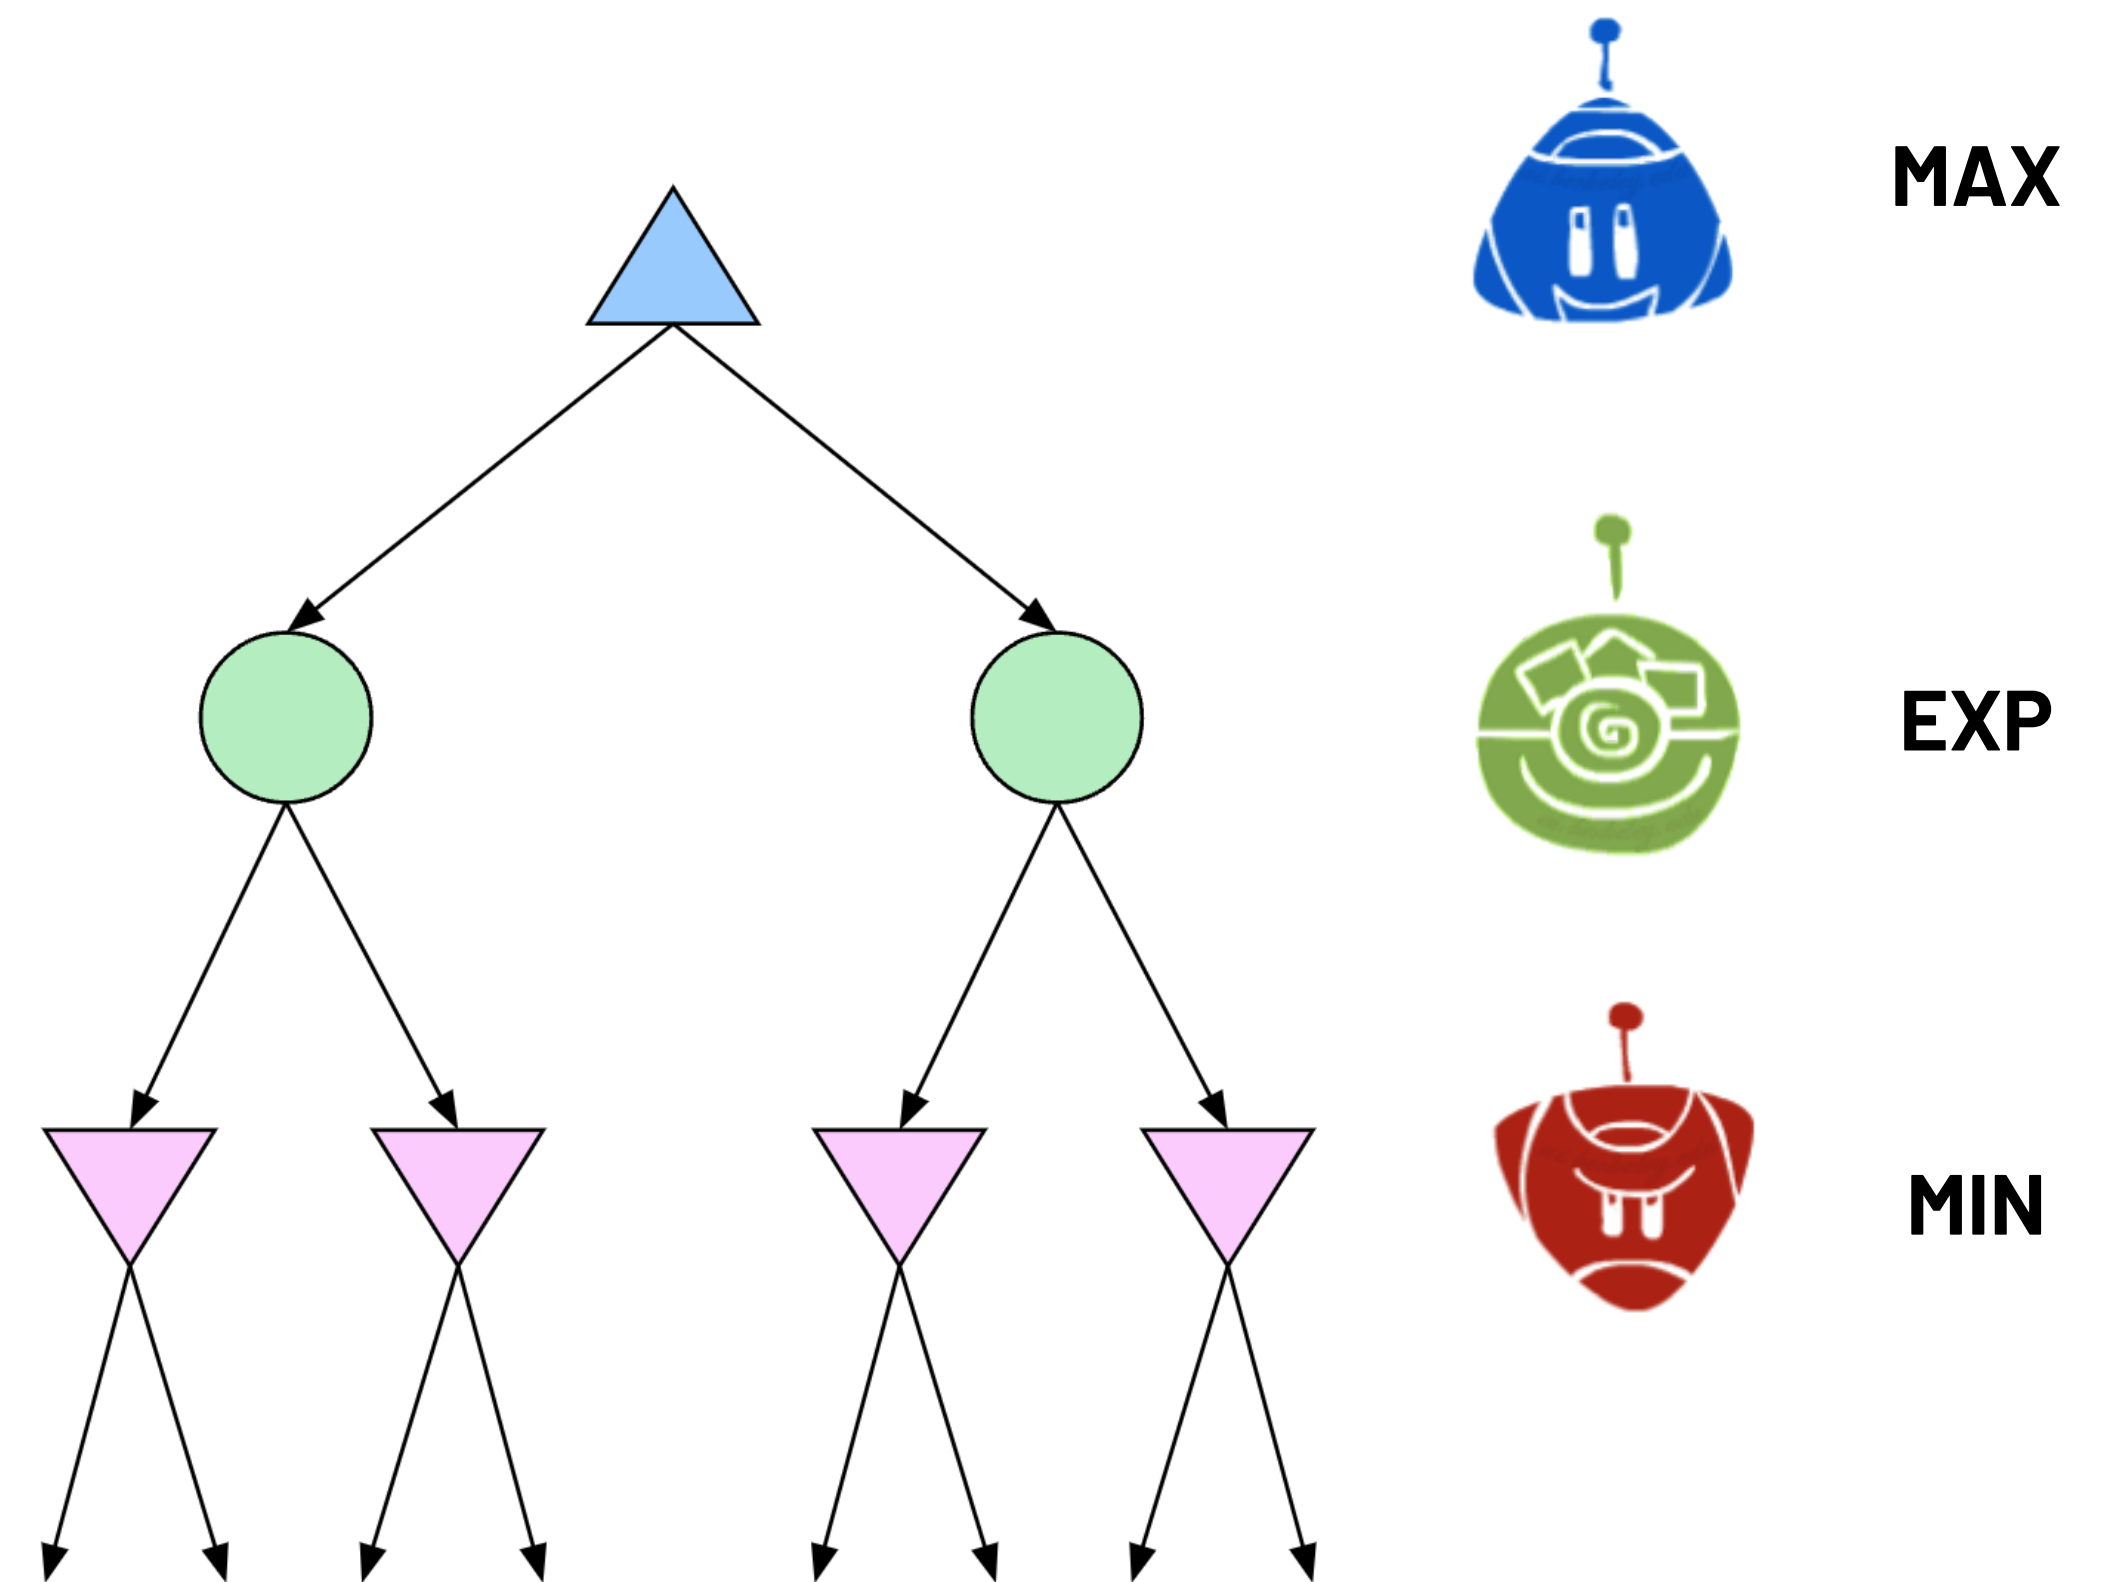


Estimar o valor expectimax

(que precisaria de muito recurso computacional para ser calculado de forma exata)



Expectiminimax

- ▶ Também existem árvores de jogo onde os níveis são alternados entre MAX, EXP e MIN.
- ▶ Nesse caso, podemos chamar o algoritmo de **expectminimax**.
- ▶ Exemplo: Gamão
 - ▶ O ambiente pode ser visto como um "agente **EXP** extra", que joga entre os **MAX** e **MIN**
 - ▶ Os estados MAX e MIN calculam seu valor usando o **expectmax** e **expectmin**, respectivamente



Utilidades multi-agente

- ▶ E se o jogo não for de soma zero, ou possuir múltiplos jogadores?
- ▶ Generalização do minimax:
 - ▶ Terminais possuem tuplas de utilidades
 - ▶ Valores dos estados também são tuplas
 - ▶ Cada jogador maximiza o seu próprio componente
 - ▶ Pode ocorrer cooperação and competição dinamicamente



Próxima aula

A8: Busca competitiva III

Busca em árvore monte carlo