

# INF623

2024/1



# Inteligência Artificial

## A17: Raciocínio Probabilístico IV

# Plano de aula

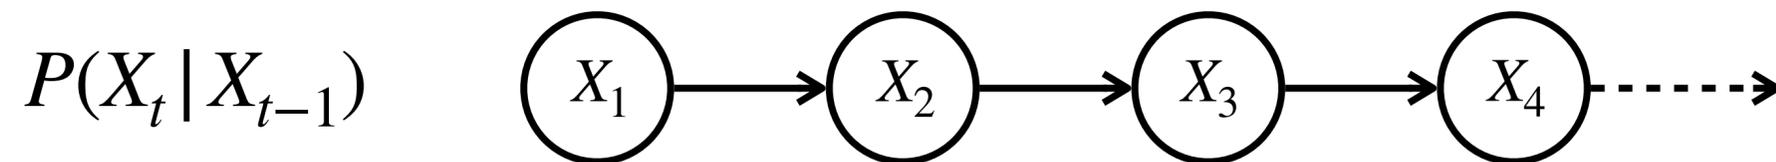
- ▶ Modelos Ocultos de Markov
- ▶ Inferência
  - ▶ Filtragem
  - ▶ Previsão
  - ▶ Suavização
  - ▶ Explicação mais provável

# Processos (ou cadeias) de Markov

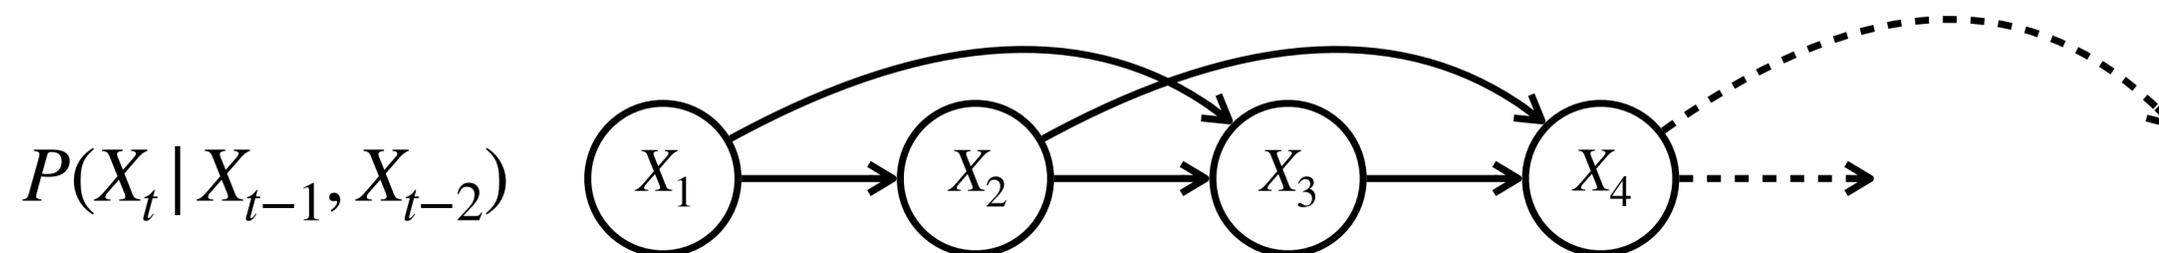
Um **processo de Markov** é uma sequência de variáveis aleatórias onde a distribuição de cada variável depende apenas de um número fixo  $k$  de variáveis anteriores  $X_{t-1}, X_{t-2}, \dots, X_{t-k}$ :

## Suposição de Markov

Para  $k = 1$ , dizemos que o modelo é de primeira ordem:



Para  $k = 2$ , dizemos que o modelo é de segunda ordem:



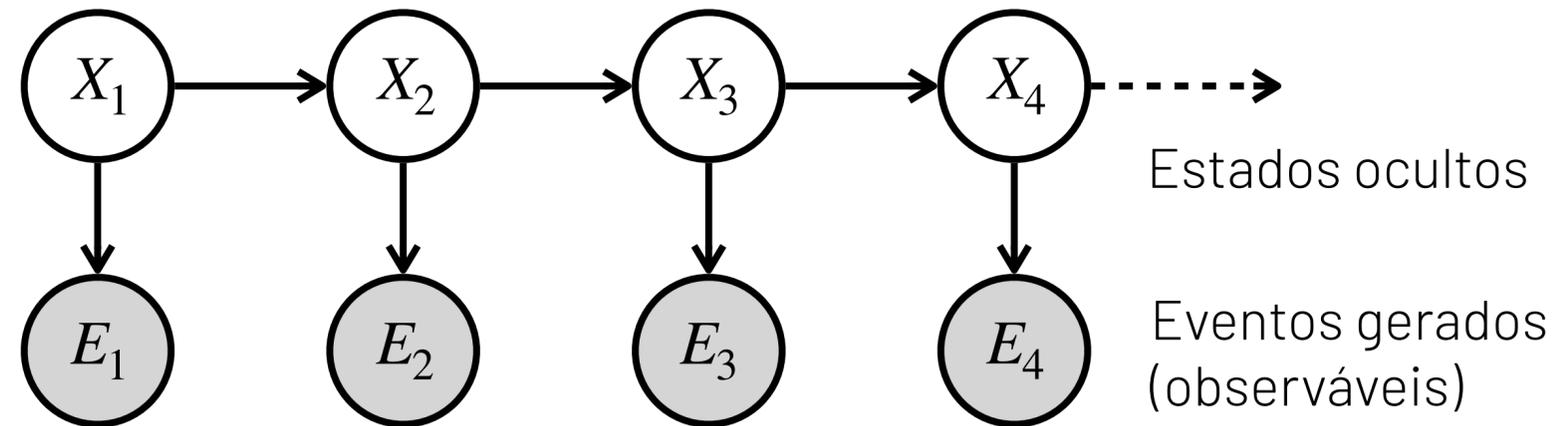
e assim por diante para  $k = 3, 4, \dots$

# Estados ocultos

- ▶ Processos de Markov são úteis em situações onde queremos prever estados futuros a partir de um estado inicial:
  - ▶  $P(X_2 = \text{☁️} \mid X_1 = \text{☀️})$
- ▶ No entanto, na prática, frequentemente não observamos os estados  $X_1 = \text{☀️}$  diretamente, mas temos um "sensor" que nos dá informações sobre eles:
  - ▶ Reconhecimento de voz
  - ▶ Rastreamento de robôs
  - ▶ Atenção do usuário

# Modelos ocultos de Markov (HMM)

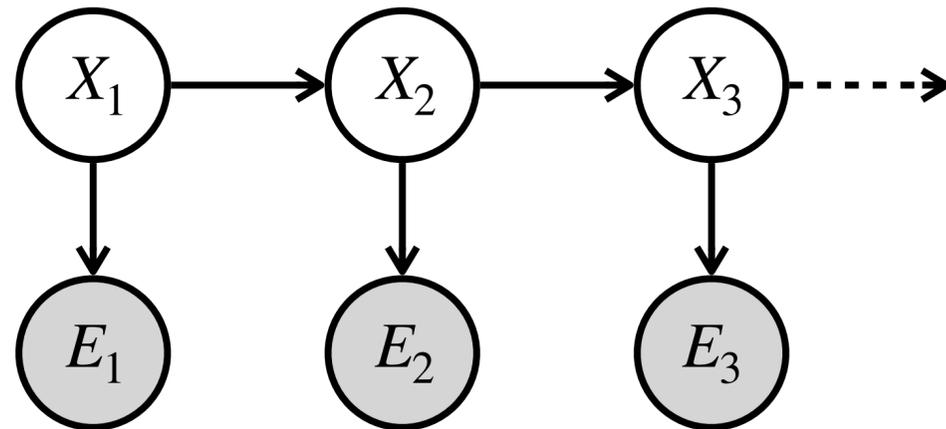
Modelos ocultos de Markov são processos de Markov com estados ocultos  $X_t$ , onde cada estado produz uma observação  $E_t$ .



Um modelo oculto de Markov é definido por:

- ▶ Distribuição inicial –  $P(X_1)$
- ▶ Modelo de transições –  $P(X_t | X_{t-1})$
- ▶ Modelo de sensor –  $P(E_t | X_t)$

# Exemplos reais de HMMs



## ▶ Reconhecimento de voz

- ▶ Observações são sinais de áudio
- ▶ Estados são as palavras ditas em cada posição da frase

## ▶ Tradução de texto

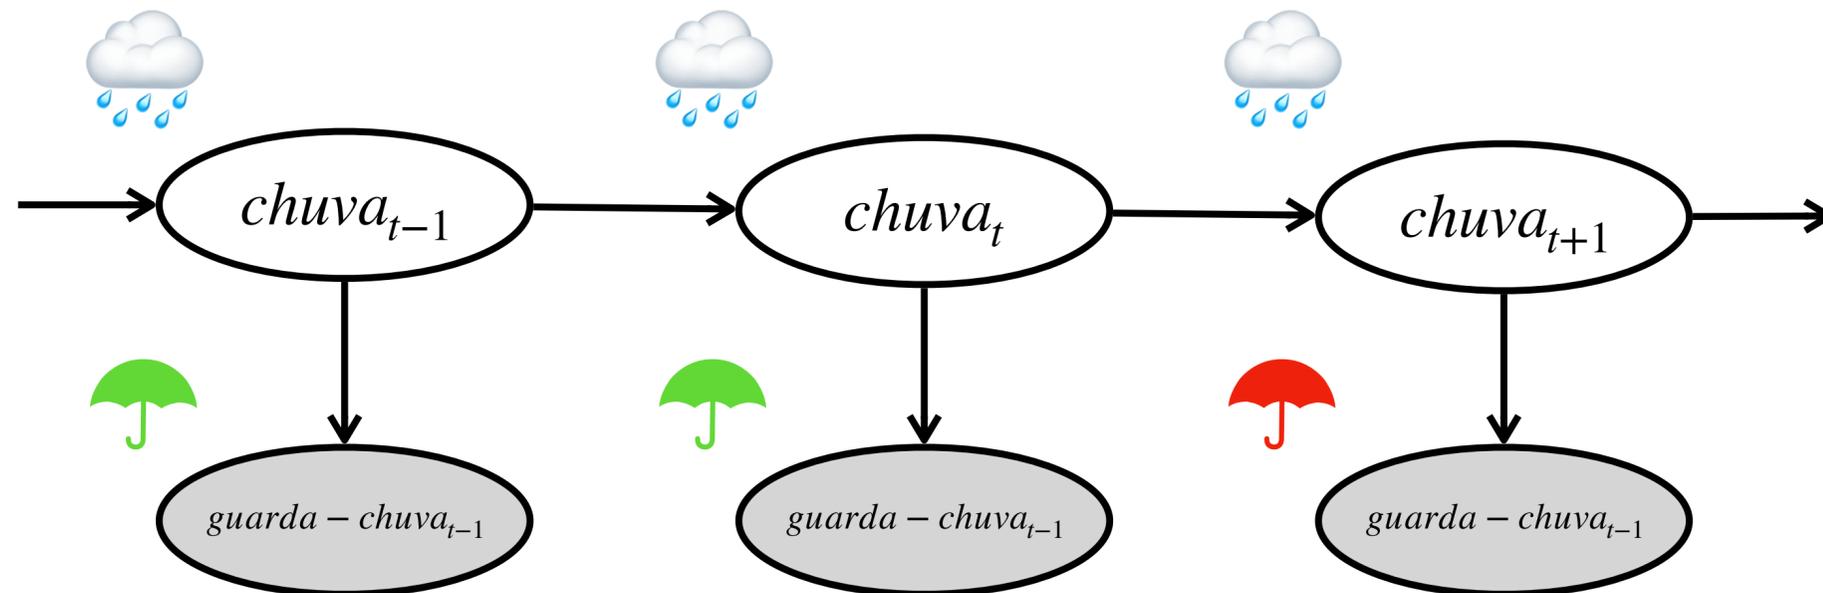
- ▶ Observações são palavras
- ▶ Estados são opções de tradução

## ▶ Rastreamento de robôs

- ▶ Observações são leituras de sensores de navegação
- ▶ Estados são as posições no mapa

# Modelo de sensor

Além do estado inicial e do modelo de transição, um HMM possui um **modelo de sensor**  $P(E_t | X_t)$  que especifica a distribuição de probabilidade do estado  $X_t$  produzir uma observação  $E_t$ .



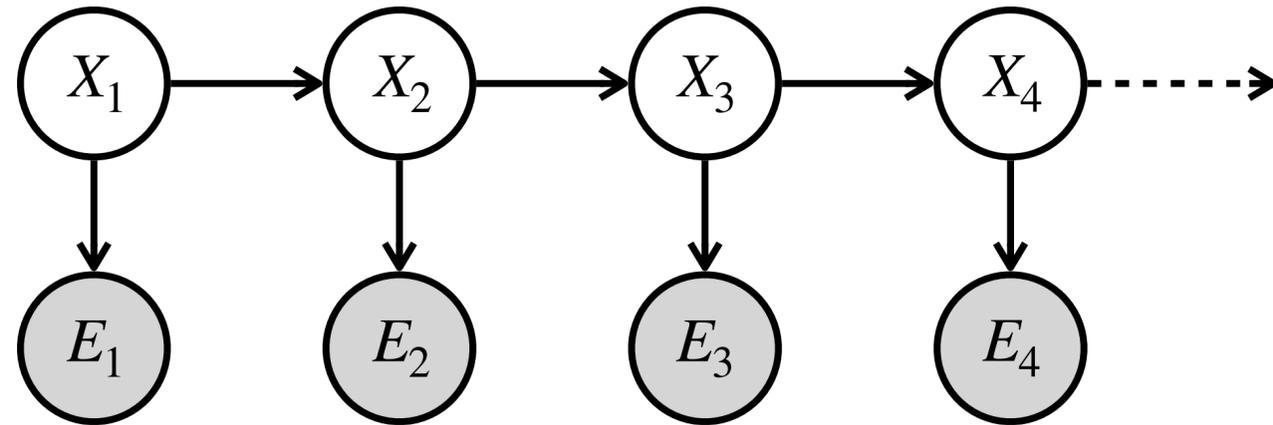
$X_{t-1}$	$X_t$	$P(X_t   X_{t-1})$
☀️	☀️	0,9
☀️	☁️	0,1
☁️	☀️	0,3
☁️	☁️	0,7

$X_t$	$E_t$	$P(E_t   X_t)$
☀️	☂️	0,2
☀️	☂️	0,8
☁️	☂️	0,9
☁️	☂️	0,1

## Suposição de sensores de Markov

A probabilidade do evento  $E_t$  depende apenas do estado  $X_t$

# Distribuição conjunta de HMMs



► Para 4 estados:

$$P(X_1, E_1, X_2, E_2, X_3, E_3, X_4, E_4) = P(X_1)P(E_1 | X_1)P(X_2 | X_1)P(E_2 | X_2)P(X_3 | X_2)P(E_3 | X_3)P(X_4 | X_3)P(E_4 | X_4)$$

► De uma maneira geral, para  $T$  estados:

$$P(X_1, E_1, X_2, E_2, \dots, X_T, E_T) = P(X_1)P(E_1 | X_1) \prod_{t=2}^T P(X_t | X_{t-1})P(E_t | X_t)$$

# Inferência

Um HMM pode ser utilizado para diferentes tarefas de inferência:

▶ **Filtragem:**  $P(X_t | e_1, \dots, e_t)$ ?

A probabilidade de chover hoje, dado todas as observações de guarda-chuva até o momento

▶ **Previsão:**  $P(X_{t+k} | e_1, \dots, e_t)$ ?

A probabilidade de chover depois de amanhã, dado todas as observações de guarda-chuva até o momento

▶ **Suavização:**  $P(X_k | e_1, \dots, e_t)$ ?

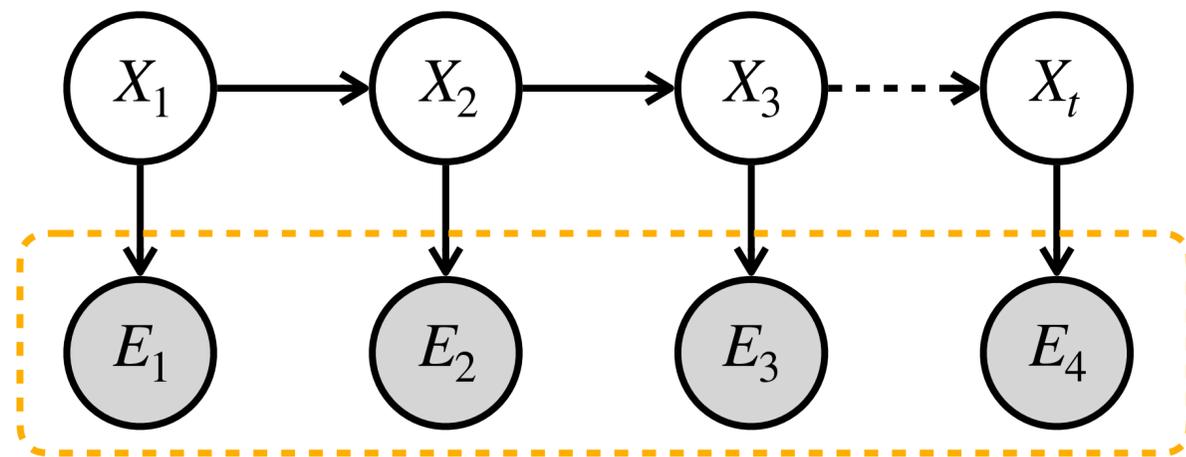
A probabilidade de que choveu na última quarta-feira, dado todas as observações de guarda-chuva até o momento

▶ **Explicação mais provável:**  $\operatorname{argmax}_{x_{1:t}} P(x_{1:t} | e_1, \dots, e_t)$

A sequência de estados mais provável de ter gerado as observações obtidas.

# Filtragem

Qual a probabilidade  $B_t(X) = P(X_t | e_1, \dots, e_t)$ , dado todas as observações até o momento?



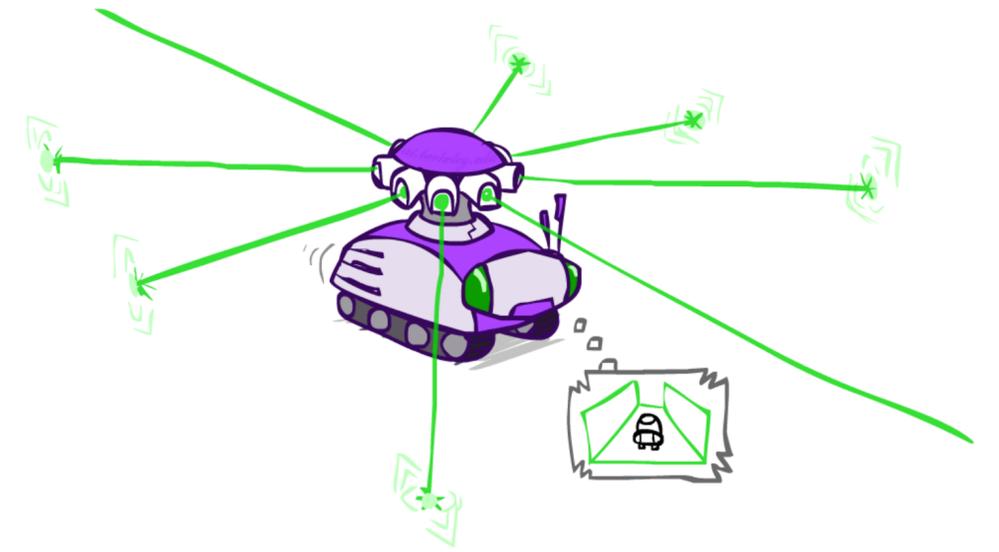
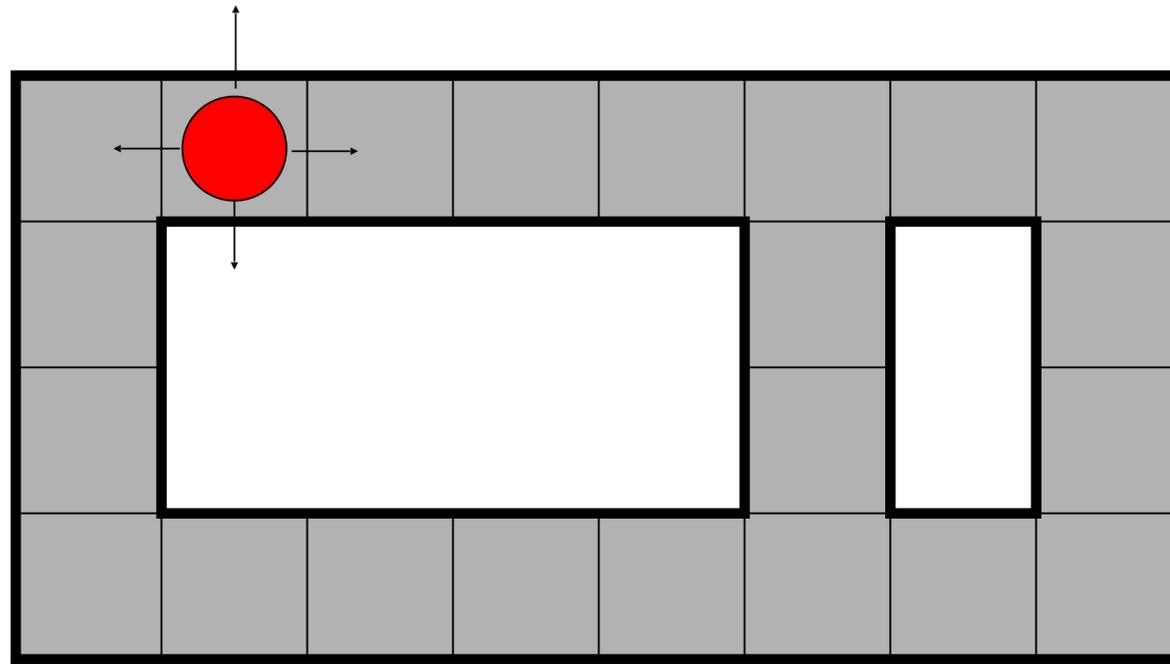
Queremos:  $P(X_t | e_1, \dots, e_t) = B_t(X)$

Observamos

- ▶ Começar  $B_1(X) = P(X_1 | e_1)$ , normalmente uniforme
- ▶ Atualizamos  $B_t(X)$  a cada nova evidência  $e_t$
- ▶ O **filtro de Kalman** foi inventado na década de 60 e implementado pela primeira vez como método de estimativa de trajetória para o programa Apollo.

# Exemplo: Localização de robôs

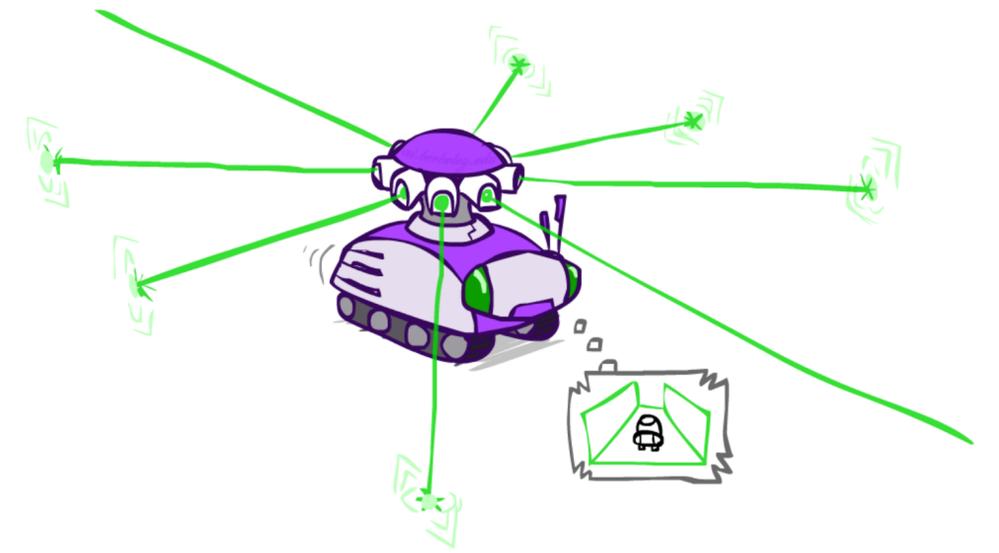
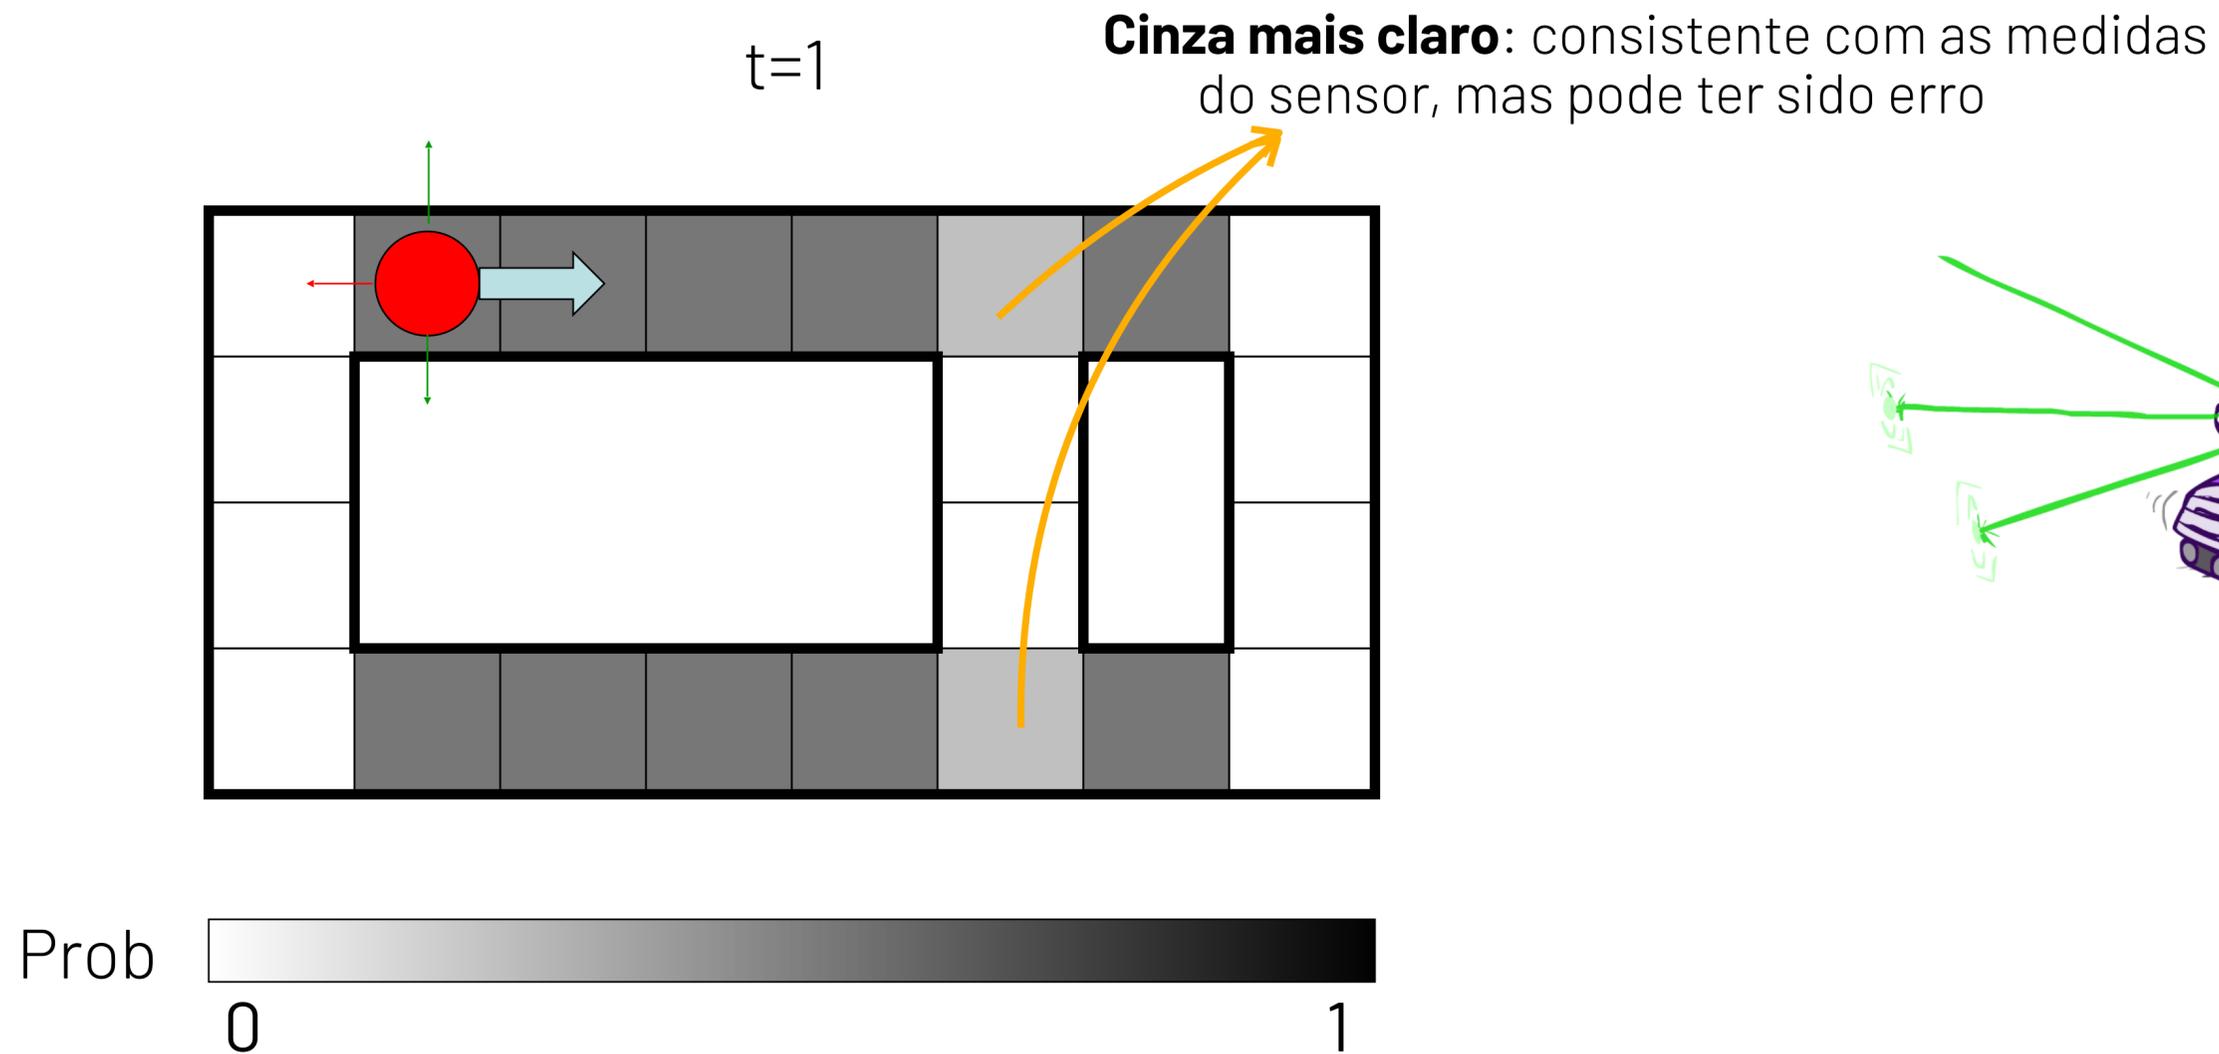
t=0



**Modelo de sensor:** consegue ler em quais direções há uma parede, nunca mais do que 1 erro

**Modelo de movimento:** tem uma baixa probabilidade de falha.

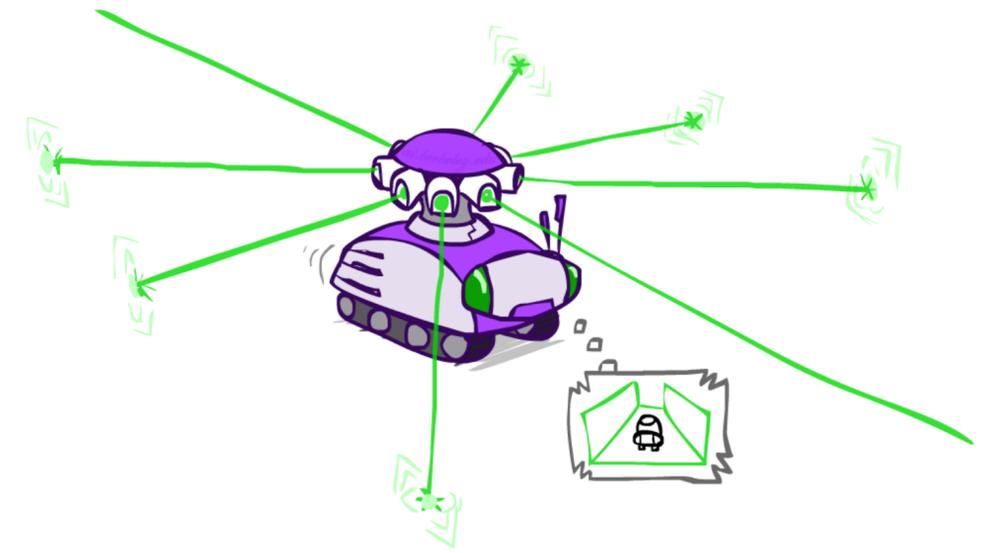
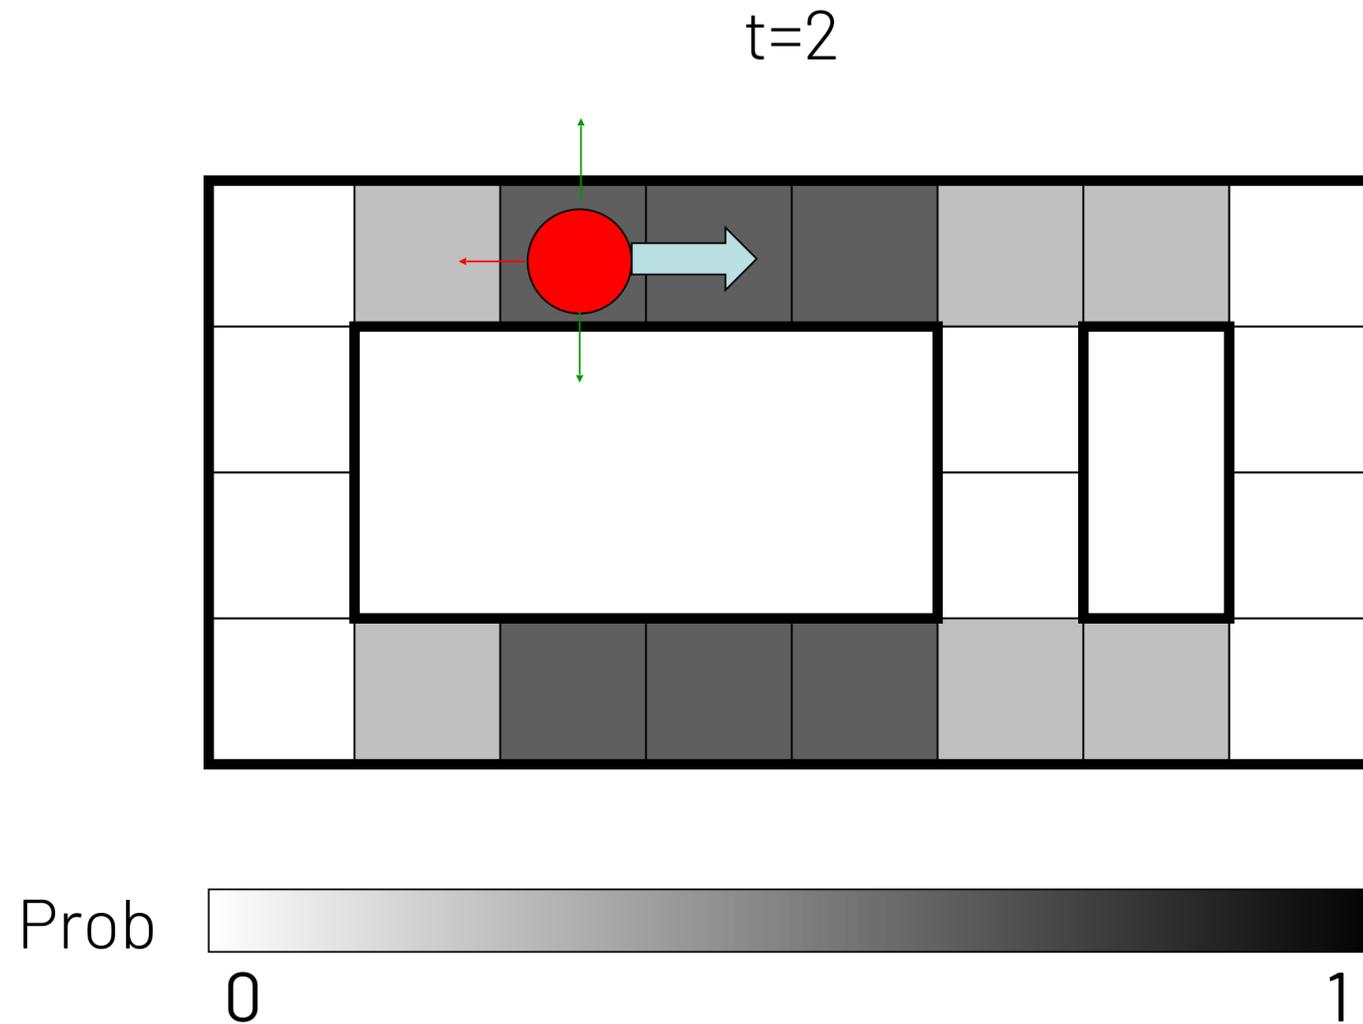
# Exemplo: Localização de robôs



**Modelo de sensor:** consegue ler em quais direções há uma parede, nunca mais do que 1 erro

**Modelo de movimento:** tem uma baixa probabilidade de falha.

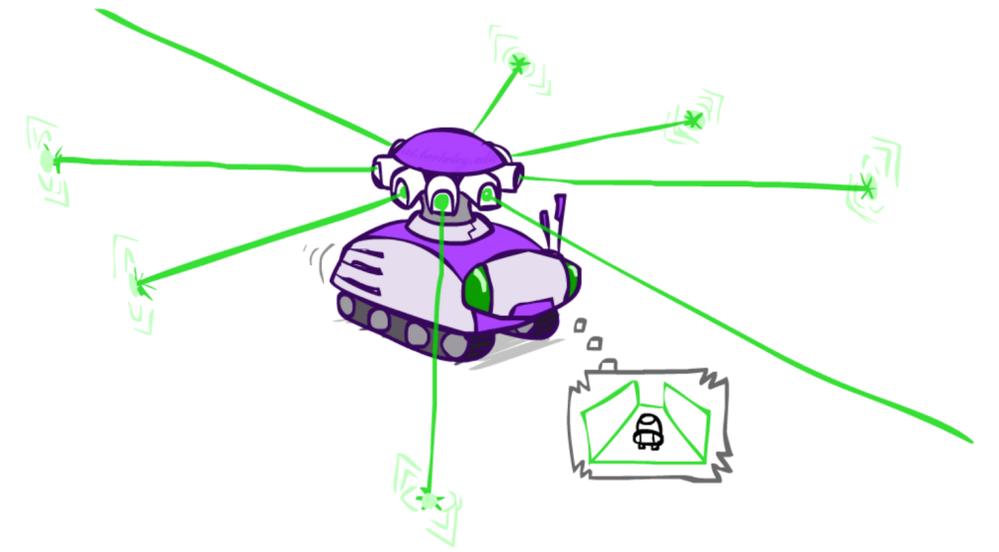
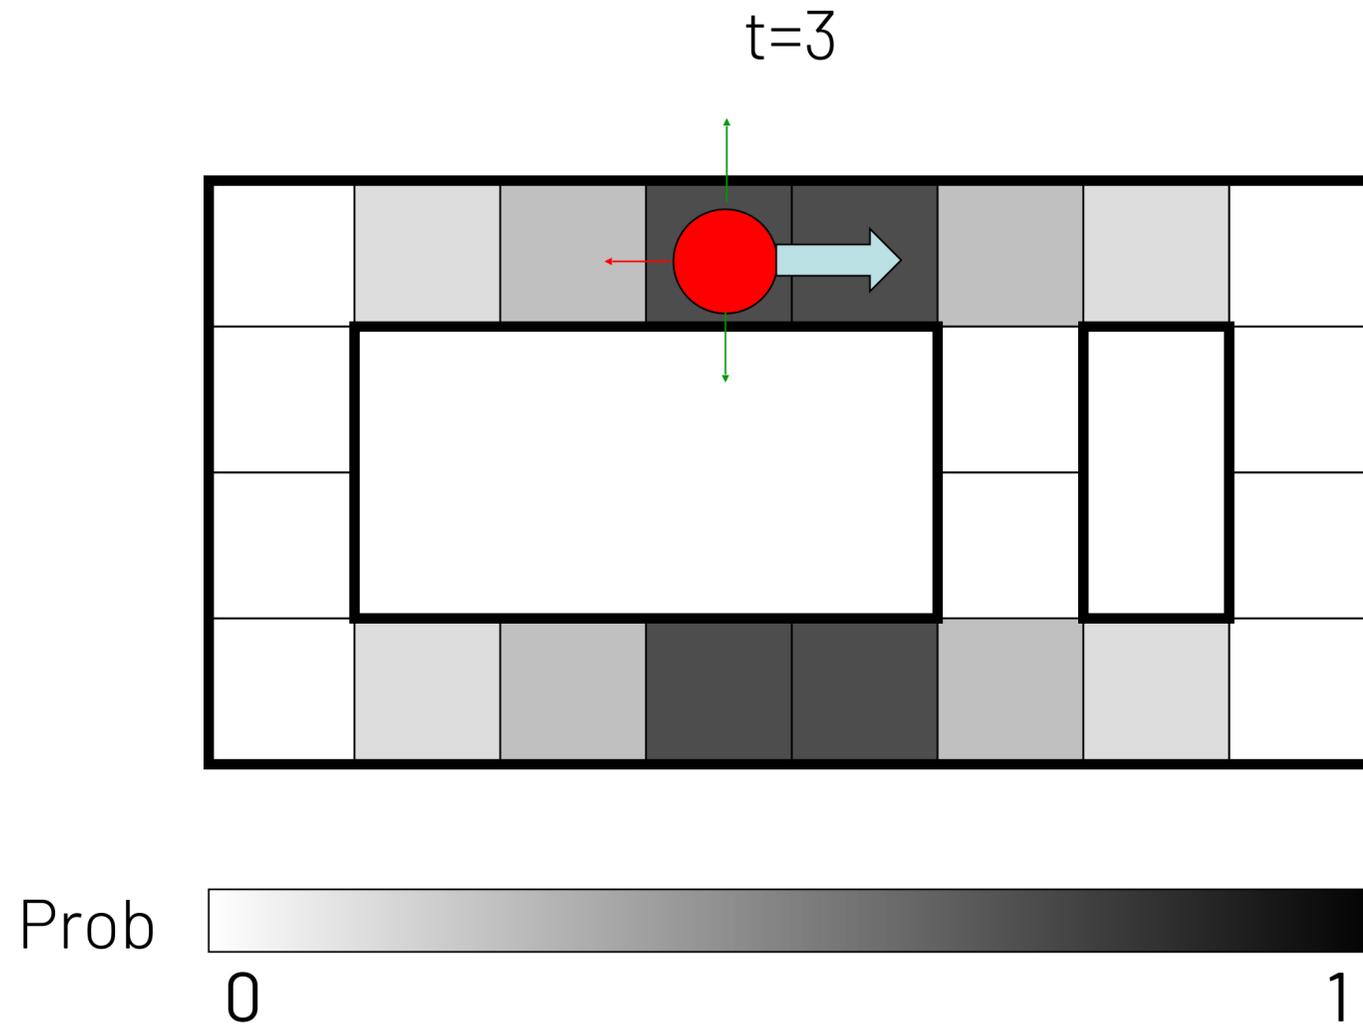
# Exemplo: Localização de robôs



**Modelo de sensor:** consegue ler em quais direções há uma parede, nunca mais do que 1 erro

**Modelo de movimento:** tem uma baixa probabilidade de falha.

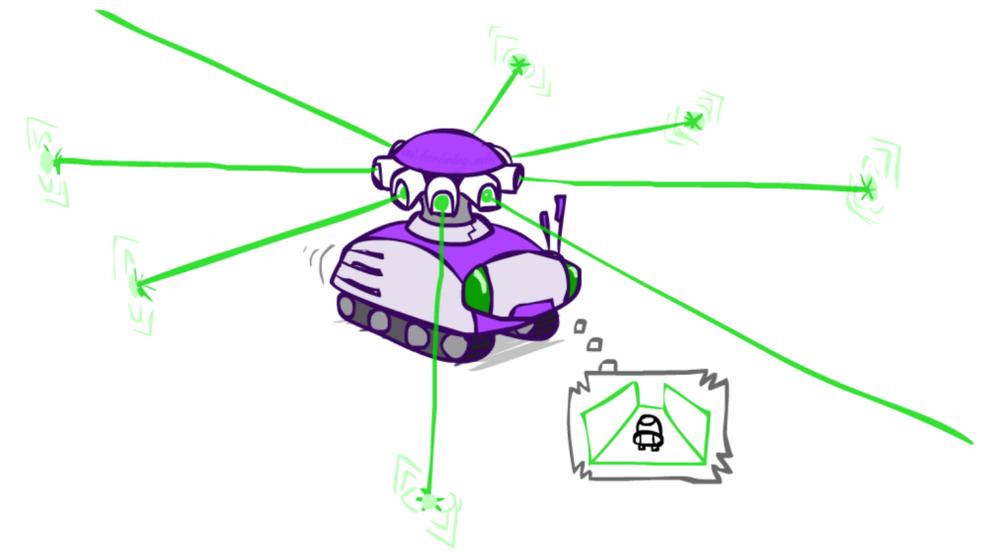
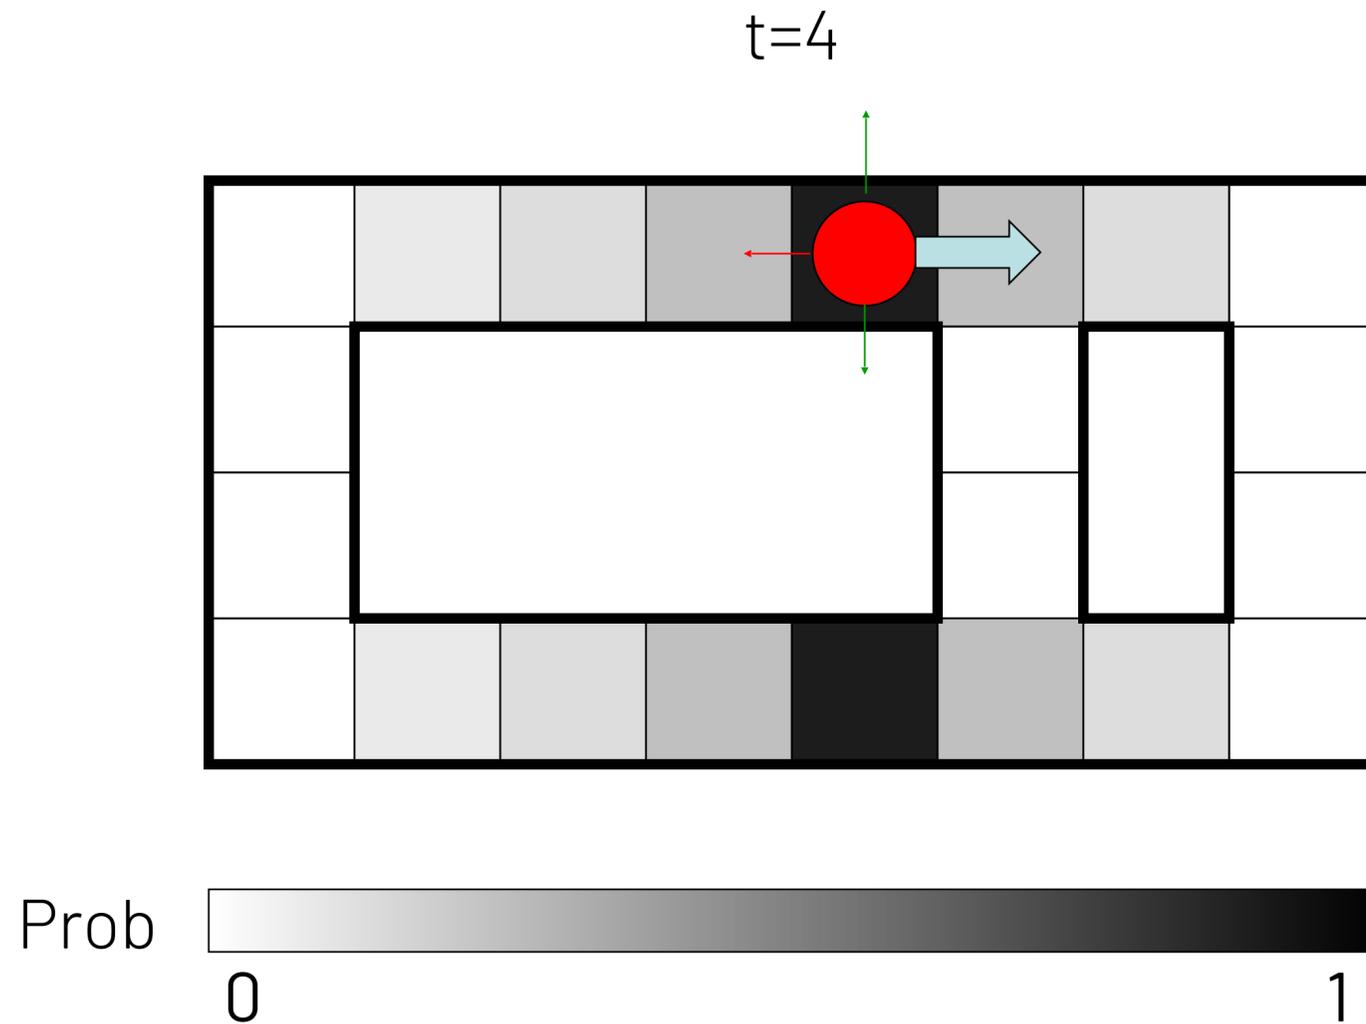
# Exemplo: Localização de robôs



**Modelo de sensor:** consegue ler em quais direções há uma parede, nunca mais do que 1 erro

**Modelo de movimento:** tem uma baixa probabilidade de falha.

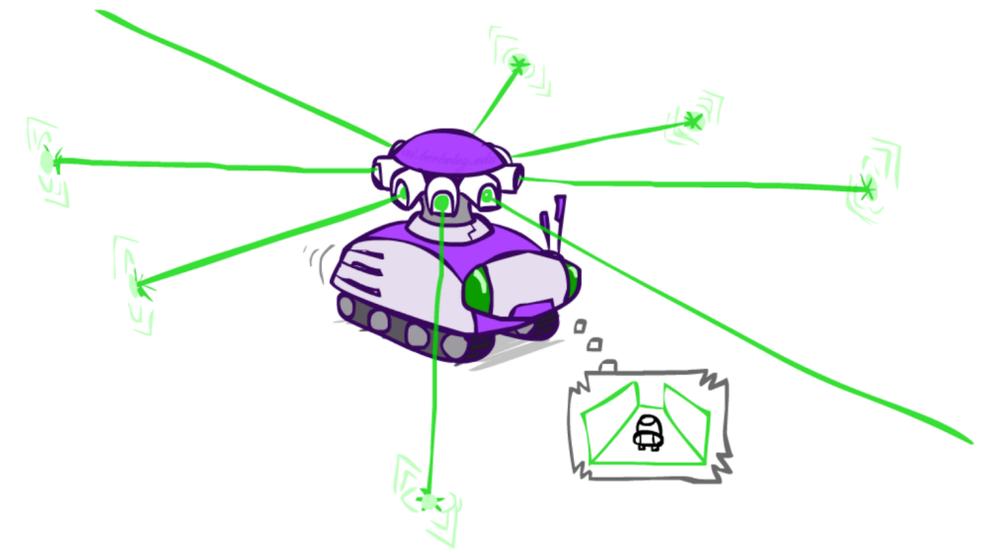
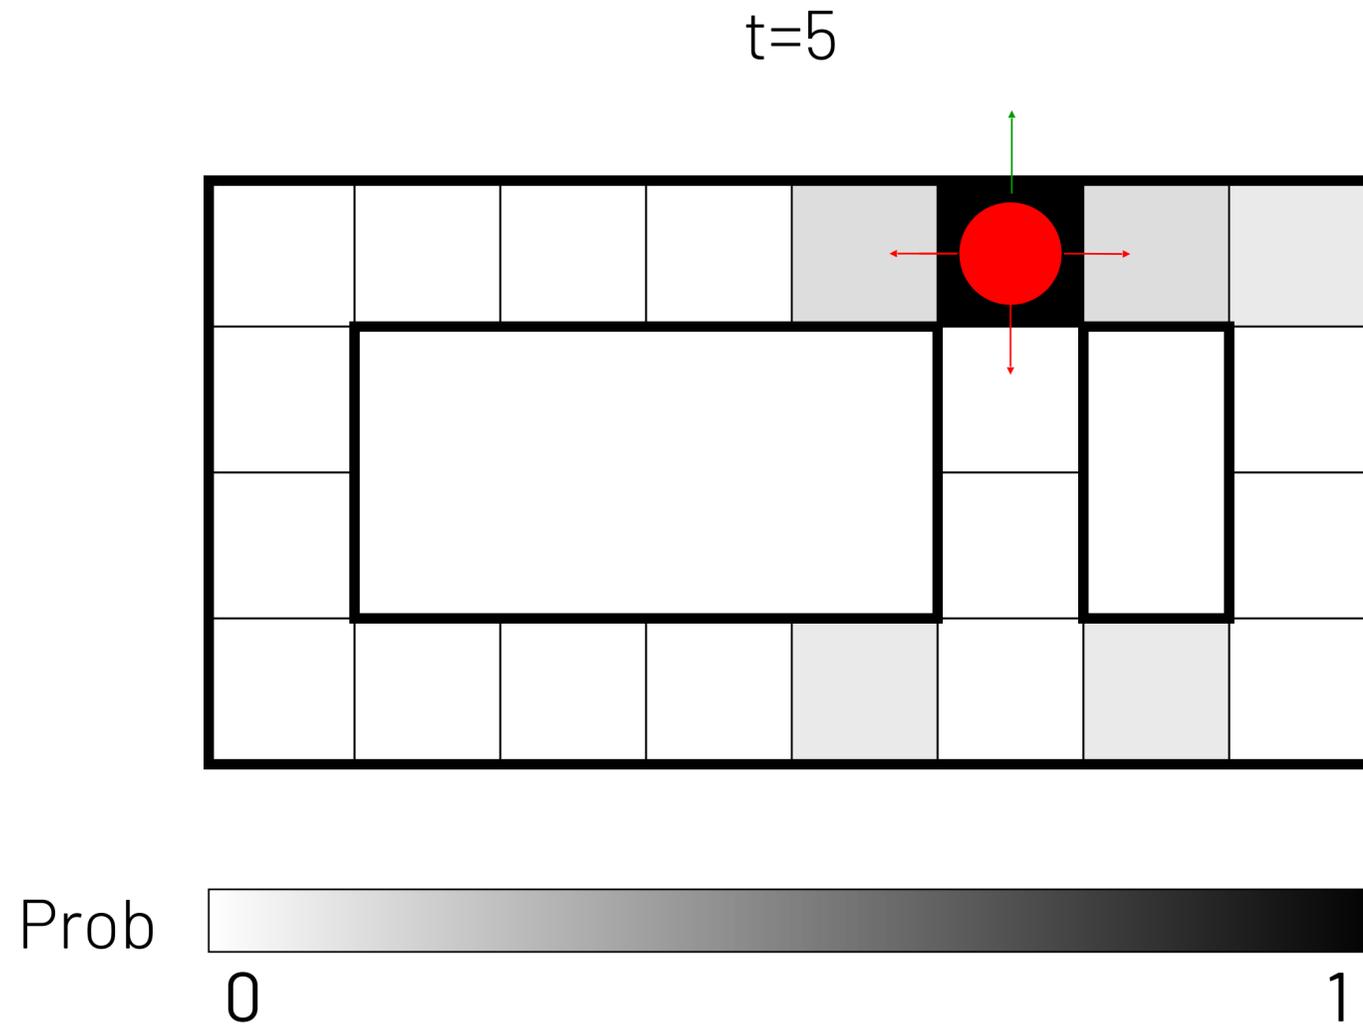
# Exemplo: Localização de robôs



**Modelo de sensor:** consegue ler em quais direções há uma parede, nunca mais do que 1 erro

**Modelo de movimento:** tem uma baixa probabilidade de falha.

# Exemplo: Localização de robôs

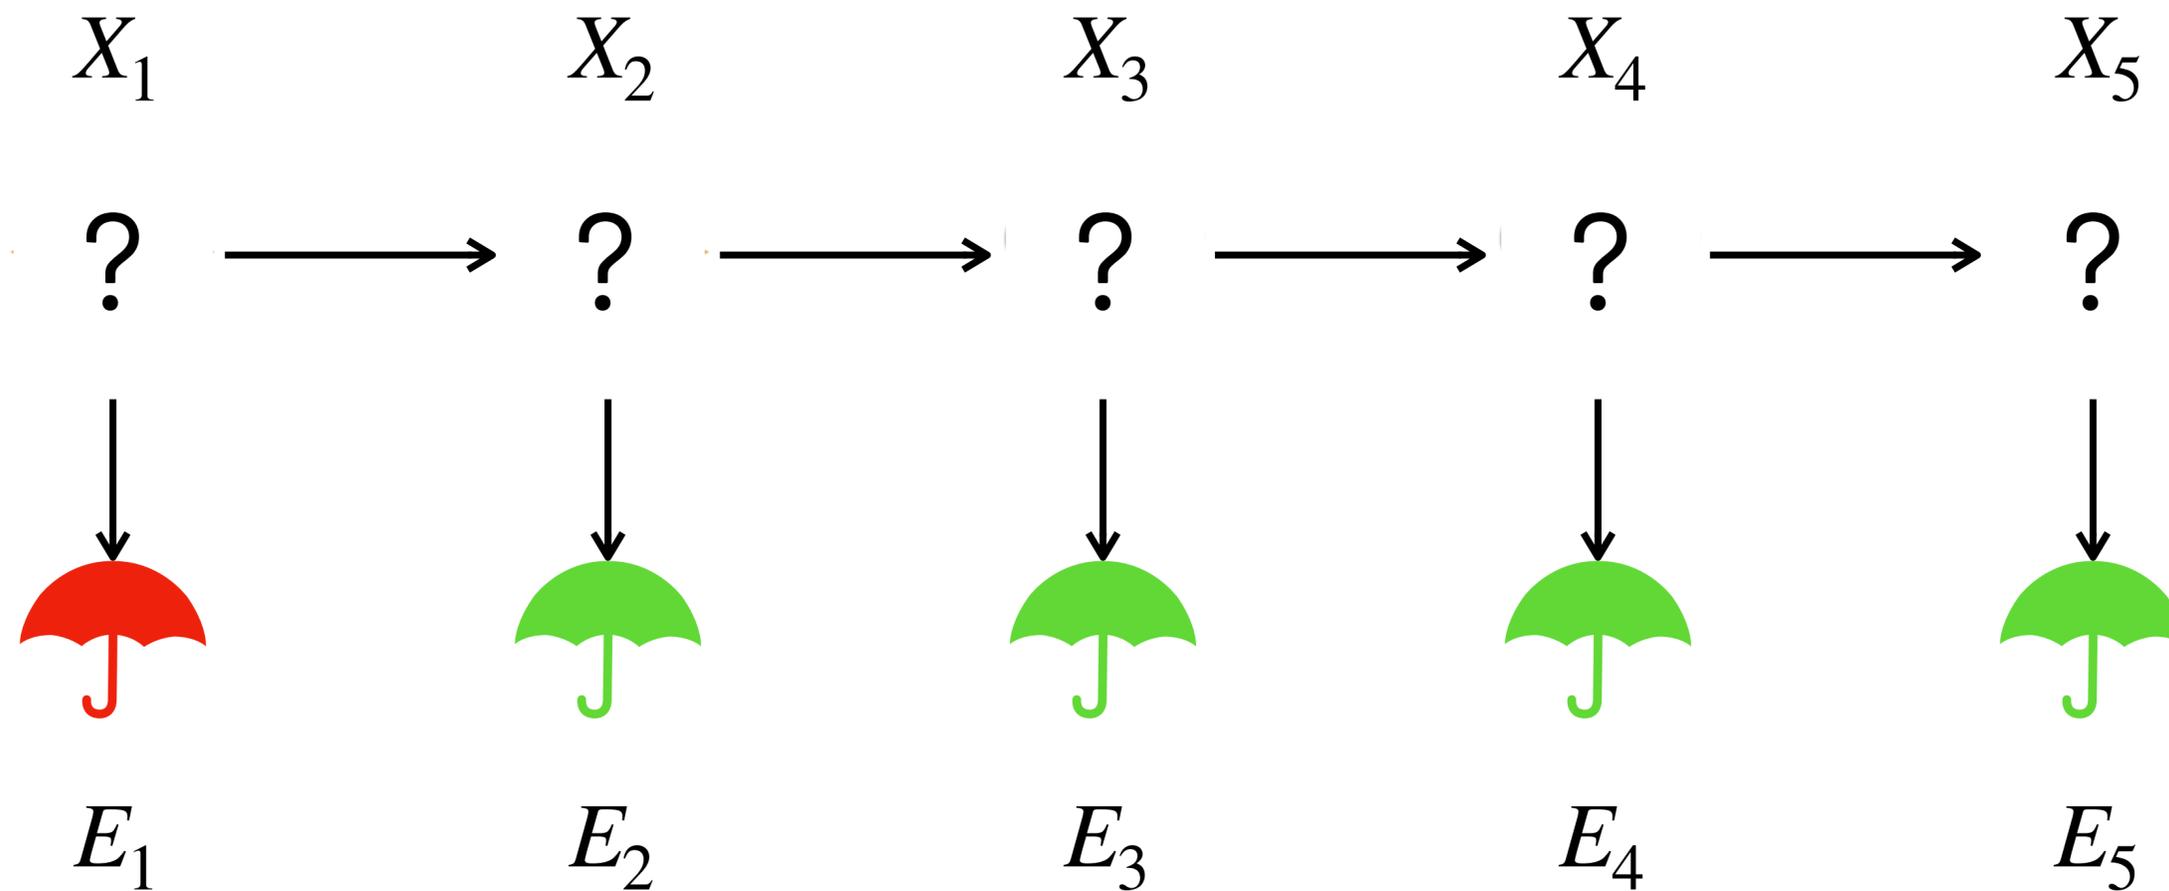


**Modelo de sensor:** consegue ler em quais direções há uma parede, nunca mais do que 1 erro

**Modelo de movimento:** tem uma baixa probabilidade de falha.

# Explicação mais provável

Qual é a sequência de estados mais provável de ter gerado as observações obtidas?



# Próxima aula

## **A18: Processos de decisão de Markov I**

Formalização matemática, exemplos, política, utilidade, descontos