

# Aprendizado por Reforço Implementação

Valdinei Freire  
(EACH - USP)

# GYM AI

1. env = gym.make('CartPole-v0')
2. observation = env.reset()
3. while condição
  - (a) escolhe action
  - (b) observation, reward, done = env.step(action)

# Ambiente Discreto

observation, reward, done = env.step(action)

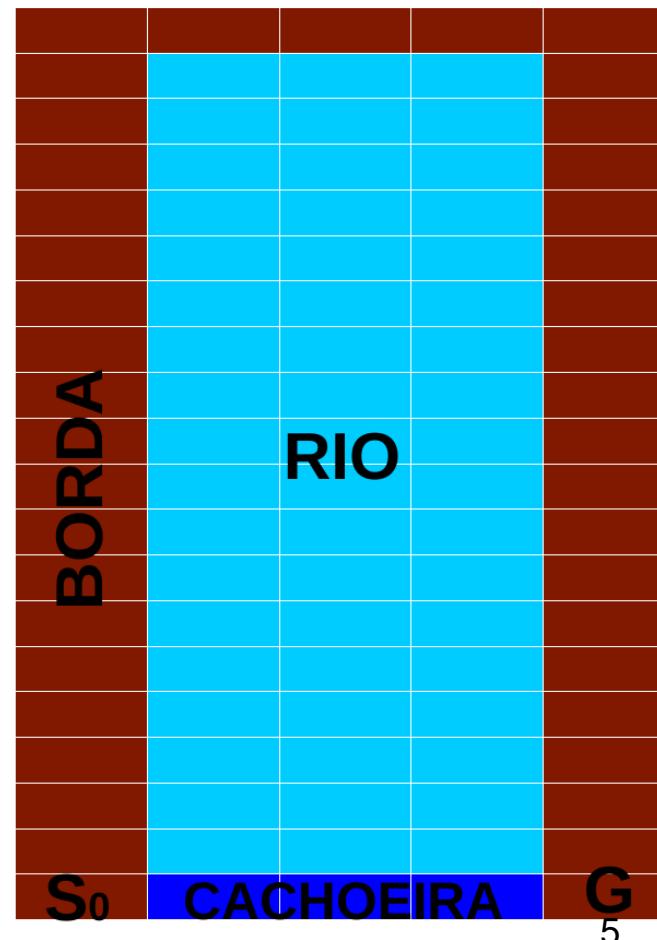
1.  $x \leftarrow \text{rand}()$
2.  $\text{sum} \leftarrow 0$
3.  $s_{\text{Next}} \leftarrow 0$
4. while  $\text{sum} < x$ 
  - (a)  $s_{\text{Next}} \leftarrow s_{\text{Next}} + 1$
  - (b)  $\text{sum} \leftarrow \text{sum} + T(\text{env}, s, \text{action}, s_{\text{Next}})$
5.  $\text{observation} \leftarrow \text{observe}(s_{\text{Next}})$
6.  $\text{reward} \leftarrow R(\text{env}, s, \text{action}, s_{\text{Next}})$
7.  $\text{env}.s \leftarrow s_{\text{Next}}$
8. if  $s_{\text{Next}} \in \mathcal{G}$ 
  - (a)  $\text{done} \leftarrow \text{true}$
9. else
  - (a)  $\text{done} \leftarrow \text{false}$

# Q-Learning com $\epsilon$ -greedy

1. Inicialize  $Q(s, a)$  arbitrariamente
2. `env = gym.make('FrozenLake8x8-v0')`
3. while condição
  - (a) `s = env.reset()`
  - (b) while  $d \neq \text{true}$ 
    - i. if  $rand > \epsilon$ 
      - A.  $a \leftarrow \arg \max_{a \in \mathcal{A}} Q(s, a)$
    - ii. else
      - A.  $a \leftarrow rand$
    - iii. `s, r, d = env.step(action)`
    - iv.  $\delta \leftarrow r + \gamma \max_{a' \in \mathcal{A}} Q(s, a') - Q(s, a)$
    - v.  $Q(s, a) \leftarrow Q(s, a) + \alpha \delta$

# Ambiente - TRAVESSIA DO RIO

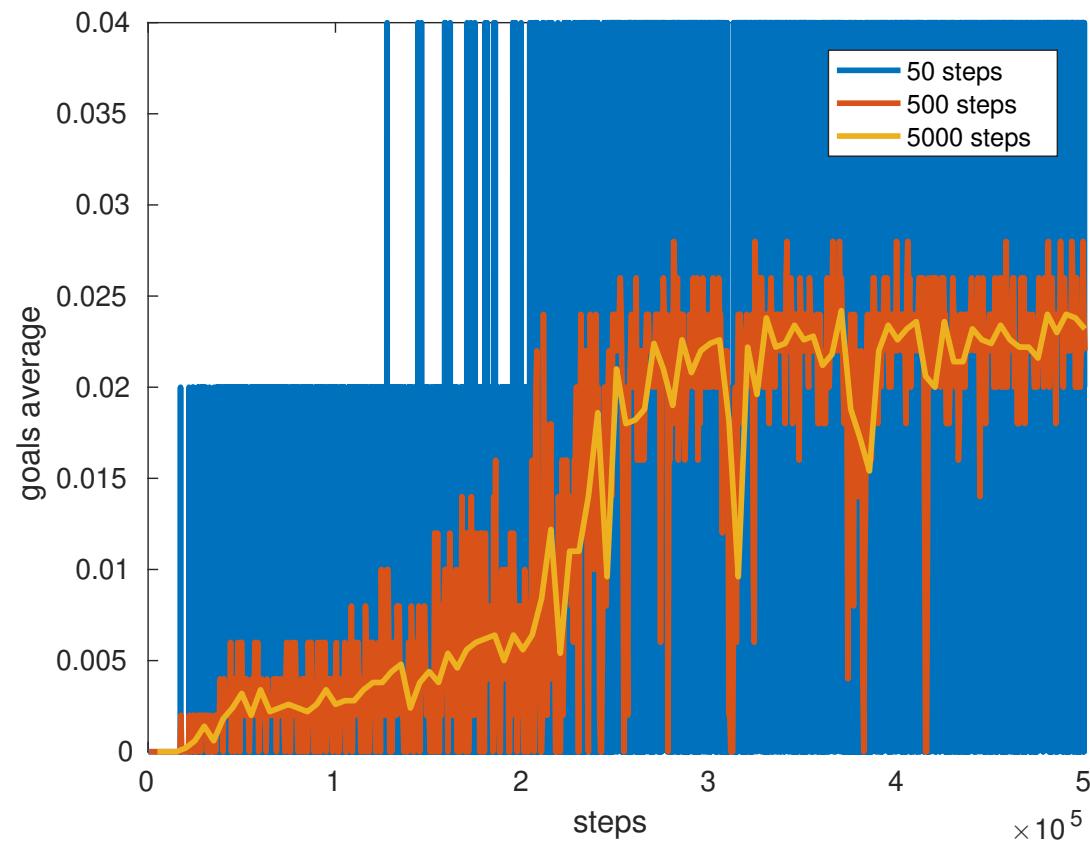
- Borda: resultados das ações são deterministas
- Rio: por causa da correnteza sempre há uma chance de ir na direção da cachoeira.
- Cachoeira: volta para o estado inicial
- Instância: 20x100



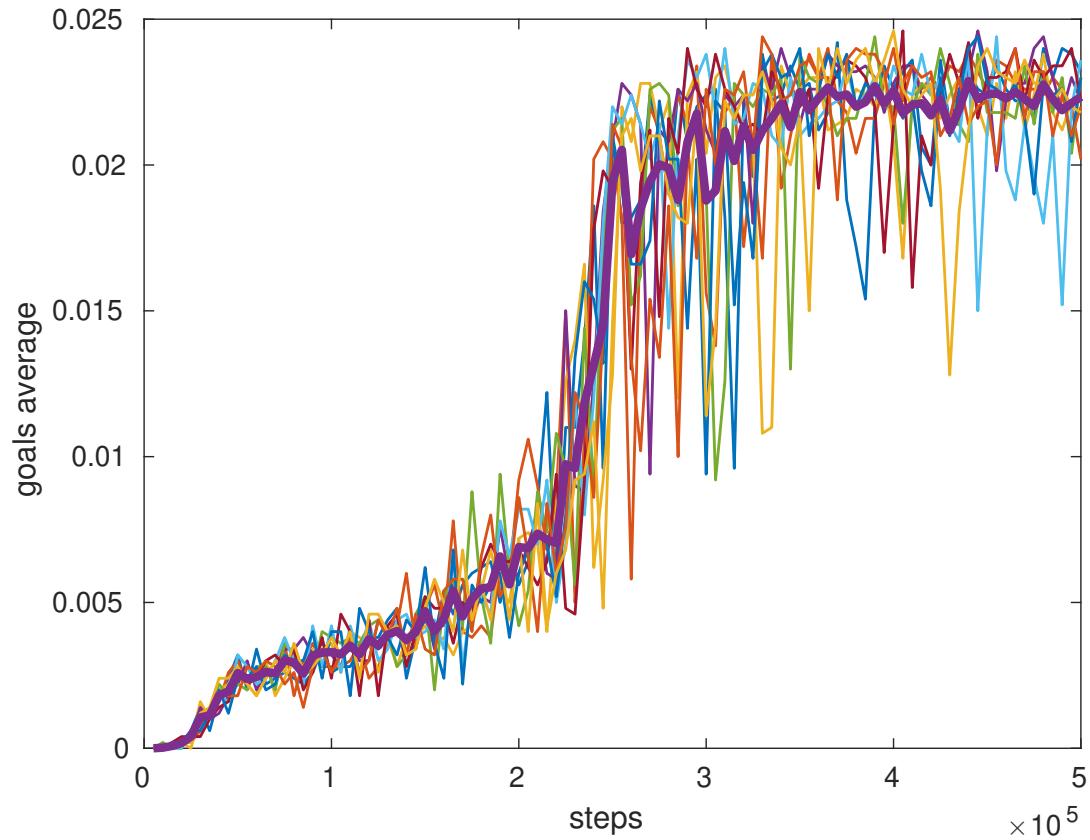
# Exibição de Resultados

- Média de várias execuções
- recompensa média por passos
- passos para chegar na meta
- recompensa acumulada

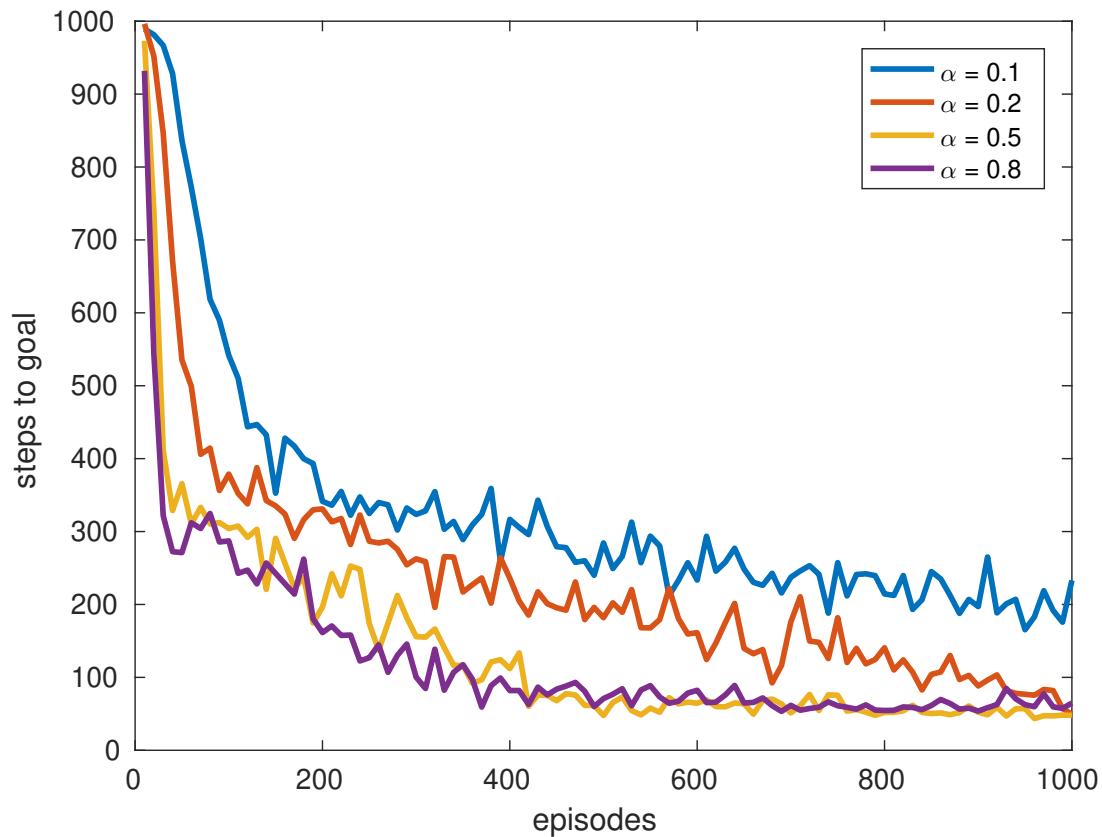
# Q-Learning: média de recompensa e resolução do gráfico



# Q-Learning: 10 execuções



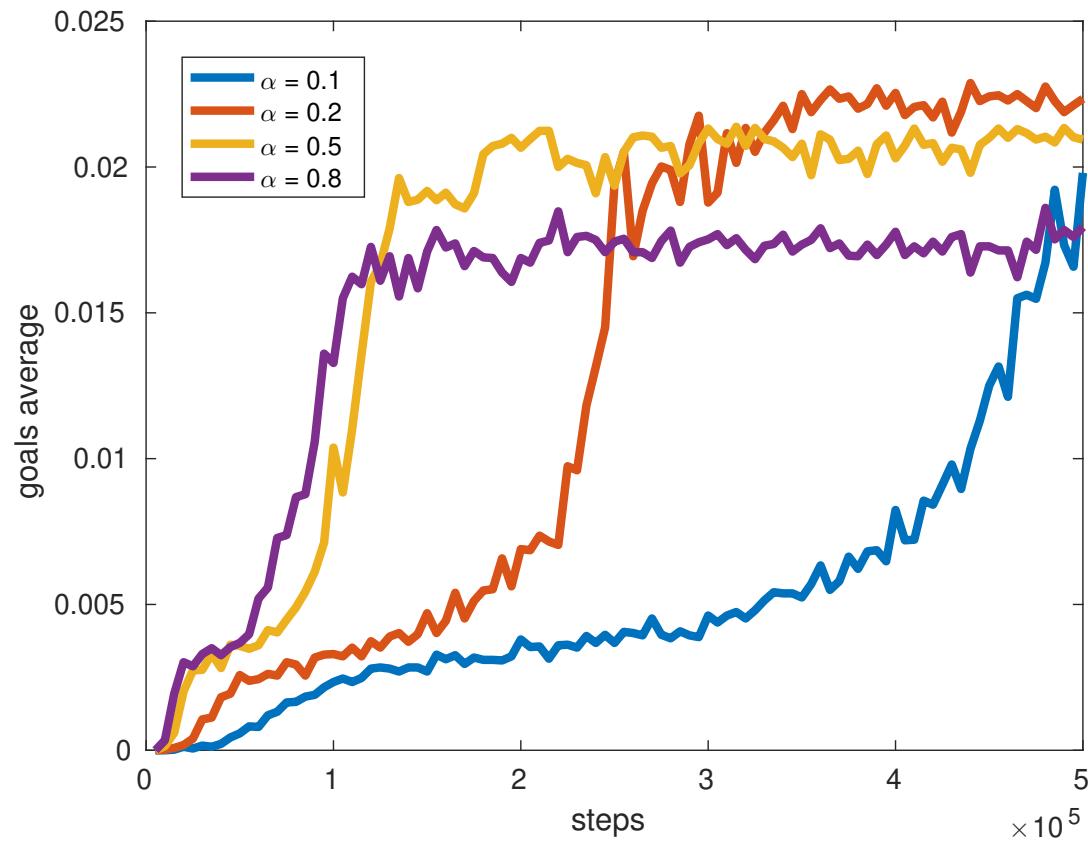
# Q-Learning: média de passos para a meta



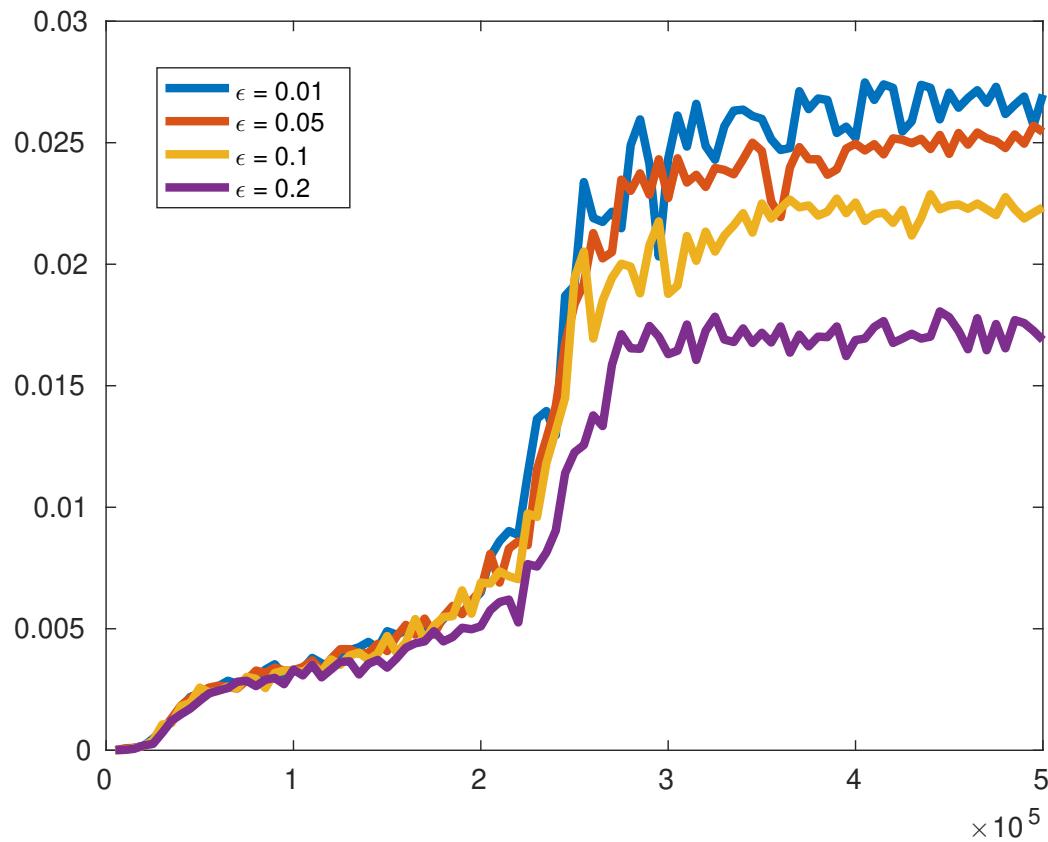
## Q-Learning: parâmetros

- taxa de aprendizado:  $\alpha$
- taxa de exploração:  $\epsilon$
- objetivo: recompensa vs custo
- valor inicial de Q: mínimo ou máximo

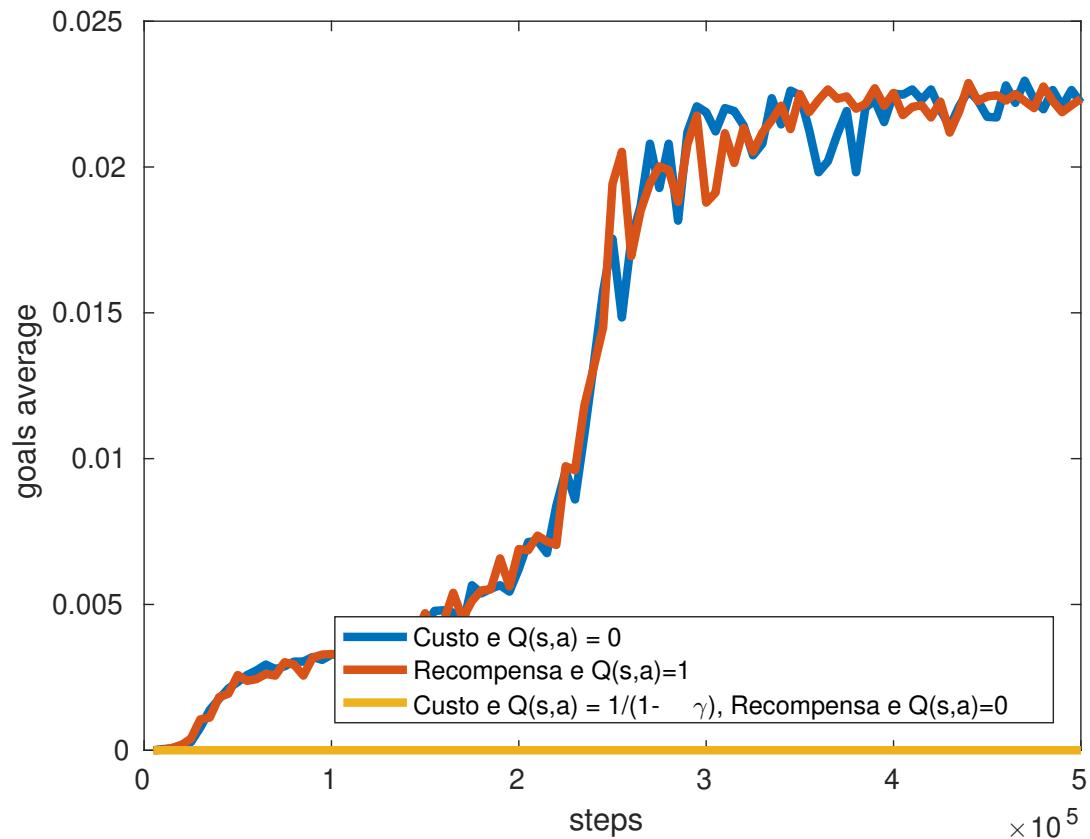
# Q-Learning: taxa de aprendizado



# Q-Learning: taxa de exploração



# Q-Learning: inicialização



## SARSA( $\lambda$ )

