Inteligência Artificial

Aula 18

Profª Bianca Zadrozny
http://www.ic.uff.br/~bianca/ia

Tomada de decisões complexas

Capítulo 21 – Russell & Norvig

Seções 21.1 a 21.3

Aprendizagem por Reforço

- Ainda temos um Processo de Decisão de Markov:
  - Um conjunto de estados $s \in S$
  - Um conjunto de ações $a \in A$
  - Uma modelo de transição $T(s, a, s')$
  - Uma função de recompensa $R(s)$
- Ainda queremos encontrar uma política $\pi^*(s)$
- **Novidade:** o agente não conhece T e R.
  - Precisa executar ações e receber recompensas para **aprender**.

Aprendizagem Passiva

- Tarefa Simplificada
  - O agente não conhece $T(s, a, s')$ e $R(s)$
  - O agente tem uma política fixa $\pi(s)$
  - Quer aprender o quão boa é essa política = aprender a função de utilidade $U^{\pi}(s)$.
- Neste caso
  - Agente não escolhe as ações.
  - Apenas executa a política e aprende a partir da experiência se a política é boa ou não.
- Métodos
  - Estimativa direta da utilidade
  - Programação dinâmica adaptativa
  - Diferença temporal

Estimativa Direta da Utilidade

- O agente executa um conjunto de episódios e observa a sequência de estados e recompensas.

$(1,1)_{-.04} \rightarrow (1,2)_{-.04} \rightarrow (1,3)_{-.04} \rightarrow (1,2)_{-.04} \rightarrow (1,3)_{-.04} \rightarrow (2,3)_{-.04} \rightarrow (3,3)_{-.04} \rightarrow (4,3)_{+1}$
$(1,1)_{-.04} \rightarrow (1,2)_{-.04} \rightarrow (1,3)_{-.04} \rightarrow (2,3)_{-.04} \rightarrow (3,3)_{-.04} \rightarrow (3,2)_{-.04} \rightarrow (3,3)_{-.04} \rightarrow (4,3)_{+1}$
$(1,1)_{-.04} \rightarrow (2,1)_{-.04} \rightarrow (3,1)_{-.04} \rightarrow (3,2)_{-.04} \rightarrow (4,2)_{-1}$.

- A utilidade de um estado é calculada através da média da utilidade obtida em cada episódio a partir do estado em questão.
  - $U^{\pi}((1,1)) = (0.72 + 0.72 + (-1.16)) = 0.28$
- Converge devagar porque não utiliza as equações de Bellman.

Programação Dinâmica Adaptativa

- Ideia:
  - Aprender o modelo de transição e a função de reforço empiricamente (ao invés das utilidades).
  - Usar iteração de valor (programação dinâmica) simplificada (sem o max) para obter as utilidades.
- Algoritmo:
  - Contar quantas vezes o estado s' ocorre quando a ação a é executada no estado s.
  - Atualizar $R(s)$ na primeira vez em que s for visitado.

Programação Dinâmica Adaptativa

- A partir do conjunto de episódios:

$(1,1)_{\text{-.04}}\rightarrow(1,2)_{\text{-.04}}\rightarrow(1,3)_{\text{-.04}}\rightarrow(1,2)_{\text{-.04}}\rightarrow(1,3)_{\text{-.04}}\rightarrow(2,3)_{\text{-.04}}\rightarrow(3,3)_{\text{-.04}}\rightarrow(4,3)_{\text{+1}}$
$(1,1)_{\text{-.04}}\rightarrow(1,2)_{\text{-.04}}\rightarrow(1,3)_{\text{-.04}}\rightarrow(2,3)_{\text{-.04}}\rightarrow(3,3)_{\text{-.04}}\rightarrow(3,2)_{\text{-.04}}\rightarrow(3,3)_{\text{-.04}}\rightarrow(4,3)_{\text{+1}}$
$(1,1)_{\text{-.04}}\rightarrow(2,1)_{\text{-.04}}\rightarrow(3,1)_{\text{-.04}}\rightarrow(3,2)_{\text{-.04}}\rightarrow(4,2)_{\text{-1}}$.

pode-se calcular que

T((1,3),Direita,(2,3)) = 2/3

T((2,3),Direita,(3,3)) = 2/2 = 1

R((1,1)) = -0.04

R((4,3)) = +1

...

Diferenças Temporais

- Ao invés de aprender modelo, aprende-se a função de utilidade diretamente, mas usando a equação de Bellman.
- A cada transição de s para s' executada, faz-se a seguinte atualização do valor de $U^{\pi}(s)$:

$$U^{\pi}(s) \leftarrow U^{\pi}(s) + \alpha(R(s) + \gamma\, U^{\pi}(s') - U^{\pi}(s))$$

onde α é a taxa de aprendizagem.

Aprendizagem Ativa

- Agente pode escolher as ações que quiser.
- Objetivo é aprender a política ótima.
- Ideia:
  - Utilizar Programação Dinâmica Adaptativa + Iteração de Valor para encontrar política ótima usando o modelo atual.
  - Refinar modelo através da experiência e repetir.
  - Crucial: temos que dar um jeito de aprender o modelo para todos os estados e ações.

Exemplo: Programação Dinâmica Adaptativa Gulosa

- Imagine que o agente encontra primeiro o seguinte caminho:

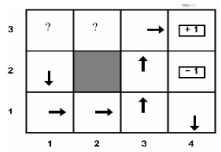

- Ele continuará sempre usando essa política e nunca visitará os outros estados.

O que deu errado?

- Problema com seguir a melhor política de acordo com o modelo atual:
  - Agente não aprenderá algo sobre as melhores regiões do ambiente se a política atual nunca visita essas regiões.
- Exploração vs. Aproveitamento
  - Exploração: escolher ações sub-ótimas de acordo com modelo atual para poder melhorar o modelo.
  - Aproveitamento: escolher as melhores ações.
  - Agentes devem explorar no começo e aproveitar no final.
- Solução: escolher algumas ações aleatórias
  - Com probabilidade fixa OU
  - Com probabilidade inversamente proporcional ao número de vezes em que a ação foi executada no estado.

Q-Learning

- Seja $Q(a,s)$ a utilidade de se executar a ação a no estado s, isto é:

$$U(s) = \max_a Q(a,s)$$

- A função $Q(a,s)$ é útil porque a partir dela podemos calcular diretamente a política, sem precisar de um modelo.
- Equação de atualização:
  - A cada transição se s para s' quando a ação a é executada:

$$Q(a,s) \leftarrow Q(a,s) + \alpha(R(s) + \gamma \max_{a'} Q(a',s') - Q(a,s))$$