

Tópicos Especiais I - Jogos

IA para Jogos



Game AI
04

Fernando Osório

21/10/2003

IA para Jogos – Aula 04



Tópicos abordados... (continuação Aula 03)

- Aprendizado de máquinas em Jogos
“Machine Learning for Games”
 - Raciocínio baseado em Casos (RBC / CBR)
 - Redes Neurais Artificiais (RNA / ANN)
 - Redes Neurais: Reativo ao Híbrido (RNA-FSA)
 - Modelos Neurais: Cinemática, Dinâmica
 - Árvores de Decisão (AD / IDT)
 - Perfil de Usuários
 - Aprendizado por Reforço (RL)

**Bibliografia
em M.L.**

Machine Learning. Tom Mitchell, 1998.
Sistemas Inteligentes. Solange Rezende, 2003.
Redes Neurais. Simon Haykin, 2001.
C4.5: Programs for machine learning. Ross Quinlan, 1993
Raciocínio Baseado em Casos. Von Wangenheim, 2003.

Machine Learning / Aprendizado de Máquinas

- IDT (Indução de Árvores de Decisão)
- Levantamento do Perfil dos Usuários
- Aprendizado por Reforço (RL)

Tendências...

- AI Tools
- AI SDKs
- Team AI
- PLN
- ...

IDT – Induction of Decision Trees (Árvores de Decisão)

- Aprendizado Supervisionado

<i>Condição</i>					<i>Ação</i>	
Day	Outlook	Temp.	Humidity	Wind	Play	Tennis
D1	Sunny	Hot	High	Weak	No	
D2	Sunny	Hot	High	Strong	No	
D3	Overcast	Hot	High	Weak	Yes	
D4	Rain	Mild	High	Weak	Yes	
D5	Rain	Cool	Normal	Weak	Yes	
D6	Rain	Cool	Normal	Strong	No	
D7	Overcast	Cool	Normal	Strong	Yes	
D8	Sunny	Mild	High	Weak	No	
D9	Sunny	Cool	Normal	Weak	Yes	
D10	Rain	Mild	Normal	Weak	Yes	
D11	Sunny	Mild	Normal	Strong	Yes	
D12	Overcast	Mild	High	Strong	Yes	
D13	Overcast	Hot	Normal	Weak	Yes	
D14	Rain	Mild	High	Strong	No	

Tabela de Decisão

Indução

Conhecimento: Estruturação Generalização

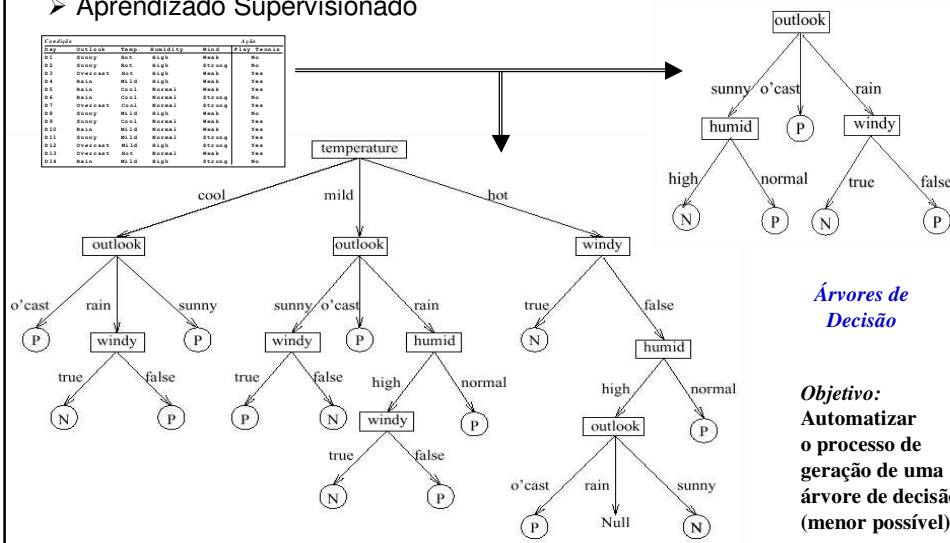
Inferência

Aplicação Prática

IDT – Induction of Decision Trees (Árvores de Decisão)

➤ Aprendizado Supervisionado

Outlook	Temp	Humidity	Wind	Play
Sunny	Hot	High	Weak	No
Sunny	Hot	High	Strong	No
Overcast	Hot	High	Weak	Yes
Rain	Mild	High	Weak	Yes
Rain	Cool	Normal	Weak	Yes
Sunny	Cool	Normal	Strong	No
Overcast	Cool	Normal	Strong	Yes
Sunny	Mild	High	Weak	No
Rain	Cool	Normal	Weak	Yes
Rain	Mild	Normal	Weak	Yes
Overcast	Mild	High	Strong	Yes
Sunny	Hot	Normal	Weak	Yes
Overcast	Hot	Normal	Weak	Yes
Rain	Mild	High	Strong	No



IDT – Induction of Decision Trees (Árvores de Decisão)

➤ Aprendizado Supervisionado

Algoritmos IDT:

- ID3 - Quinlan / 1986
- C4.5 - Quinlan / 1993
<http://www.cse.unsw.edu.au/~quinlan/> (Atualmente See5)
- ASSISTANT - Cestnik, Kononenko, Bratko / 1987
- CART (Classification and Regression Trees) Breitman et al / 1984
- CN2 - Clark, Niblett / 1987
<http://www.cs.utexas.edu/users/pclark/software.html>
- ID5R, ITI (Incremental DT induction) - Utgoff / 1989
<http://www.cs.umass.edu/~lrn/iti/>
- Métodos similares... Família AQ - Michalski
<http://www.mli.gmu.edu/msoftware.html>

Árvores de Decisão

Algoritmo Básico:

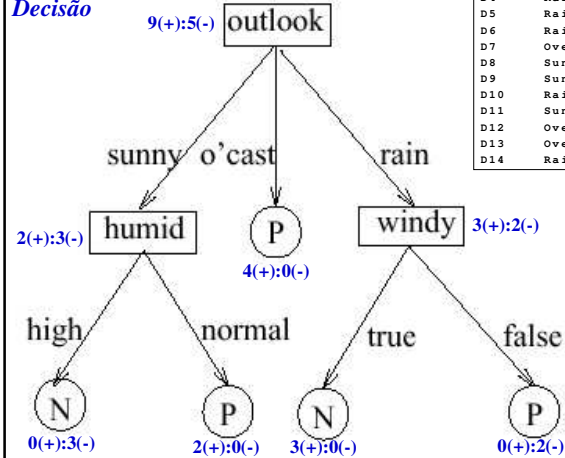
Selecionar o atributo que melhor discrimine os dados em relação as classes definidas.

C4.5: utiliza uma medida baseada na entropia (“grau de mistura dos dados”), obtendo para cada atributo o ganho (“redução da mistura”) caso este seja selecionado como atributo discriminante.

IDT – Induction of Decision Trees (Árvores de Decisão)

➤ Aprendizado Supervisionado

Árvores de Decisão



Condição	Outlook	Temp.	Humidity	Wind	Ação
D1	Sunny	Hot	High	Weak	No
D2	Sunny	Hot	High	Strong	No
D3	Overcast	Hot	High	Weak	Yes
D4	Rain	Mild	High	Weak	Yes
D5	Rain	Cool	Normal	Weak	Yes
D6	Rain	Cool	Normal	Strong	No
D7	Overcast	Cool	Normal	Strong	Yes
D8	Sunny	Mild	High	Weak	No
D9	Sunny	Cool	Normal	Weak	Yes
D10	Rain	Mild	Normal	Weak	Yes
D11	Sunny	Mild	Normal	Strong	Yes
D12	Overcast	Mild	High	Strong	Yes
D13	Overcast	Hot	Normal	Weak	Yes
D14	Rain	Mild	High	Strong	No

Nodo = Atributo testado
Aresta = Valor do atributo

Nodos: Está indicada a contagem total de YES (+) e de NO (-)

Regras obtidas: (exemplos)

IF Outlook = Overcast
Then Yes
IF Outlook = rain AND Windy = True
Then No

IDT – Induction of Decision Trees (Árvores de Decisão)

➤ Aprendizado Supervisionado

Características das Árvores de Decisão:

- Aprendizado fácil e rápido
- Fácil integração em outras aplicações (obtenção de regras)
- Apesar de permitirem trabalhar com atributos quantitativos (discretizados de forma automática, sendo codificados como se fossem atributos nominais), as árvores de decisão são melhores na manipulação de **informações simbólicas**

SOFTWARES:

- C4.5 <http://www.cse.unsw.edu.au/~quinlan/>
- Dtree <http://fuzzy.cs.uni-magdeburg.de/~borgelt/>
- Weka <http://www.cs.waikato.ac.nz/ml/weka/>
- R <http://www.r-project.org/>
- CN2 <http://www.cs.utexas.edu/users/pclark/software.html>
- ITI <http://www.cs.umass.edu/~lrm/iti/>
- AQ Family <http://www.mli.gmu.edu/msoftware.html>
- See5 <http://www.rulequest.com/>
- CART <http://www.salford-systems.com/>
- Clementine <http://www.isl.co.uk/clementine.html>
<http://www.spss.com/clementine/>

IDT – Induction of Decision Trees (Árvores de Decisão)

➤ IDT em Jogos...

Árvores de Decisão – Usando o Conhecimento Adquirido

Decision Tree:

outlook = overcast: Yes (3.2)
 outlook = sunny:
 | humidity <= 75 : Yes (2.0)
 | | humidity > 75 :
 | | | windy = false: No (2.0)
 | | | windy = true:
 | | | | temperature <= 75 : Yes (0.4)
 | | | | temperature > 75 : No (1.0)
 outlook = rain:
 | windy = false: Yes (3.0)
 | windy = true:
 | | temperature <= 71 : No (2.0)
 | | temperature > 71 : Yes (0.4)


Atributo Numérico

Regras IF/THEN

IF Outlook = Overcast Then Yes
IF Outlook = Rain AND Windy = False Then Yes
IF Outlook = Sunny AND Humidity <= 75 Then Yes
 ...

Production Rule Classifier



Rule 1:
 outlook = sunny
 -> class Play [100.0%]
 Default class: Play



IDT – Induction of Decision Trees (Árvores de Decisão)

➤ IDT em Jogos...

Árvores de Decisão – Usando o Conhecimento Adquirido



IDT – Induction of Decision Trees (Árvores de Decisão)

➤ IDT em Jogos...

Aplicações possíveis - Exemplos...

- **Robocup - CMUnited RoboCup-98 Simulator**

Peter Stone and Manuela Veloso.

Using decision tree confidence factors for multiagent control.

In Proceedings of the First International Workshop on RoboCup, Nagoya, Japan, August 1997.

<http://www.cs.utexas.edu/users/pstone/papers.html>

- **Aquisição de Conhecimento para Agentes**

Yusuf Pisan

Building Characters: A Form of Knowledge Acquisition

AAAI Spring Symposium on AI and Interactive Entertainment. 2000.

<http://www.qrg.northwestern.edu/aigames.org/pastpapers.html>

- **Jogos de Tabuleiro**

- **Agentes baseados em Regras**

Ferramenta necessária: *Inference Engine / RBS (Rule Based System)*

Levantamento do Perfil de Usuários (“oponentes”)

➤ Aprendizado Não-Supervisionado

Determinando o comportamento de um agente humano...

- **Concepção de Um Ambiente Virtual Inteligente e Adaptativo**

Cássia Trojahn dos Santos, Fernando Osório

Revista Scientia – Unisinos (Artigo Submetido – V.14 N.2 – 2003)

Definição: Modelo de Usuário (Perfil) [Santos03 / SBIE]

Um modelo de usuário é uma representação explícita das características, preferências e necessidades de um usuário. Conforme Kobsa (1995), é uma coleção de informações e suposições sobre usuários individuais ou sobre grupos de usuários, necessárias para que o sistema adapte diversos aspectos de suas funcionalidades e interface. Compreende toda a informação sobre o usuário, extraída da sua interação com o sistema [Abbattista et al, 2002]. O termo perfil de usuário [Wasfi, 1999] também é utilizado com o propósito de representar o conhecimento sobre o usuário. Ao processo de aquisição e representação de um modelo dá-se o nome de modelagem de usuário.

Levantamento do Perfil de Usuários (“oponentes”)

➤ Aprendizado Não-Supervisionado

Aquisição do Modelo de Usuário [Santos03 / PIPCA]*

Os métodos para coleta dos dados podem ser agrupados em dois conjuntos:

- Explícitos
- Implícitos.

Os métodos explícitos coletam as informações diretamente do usuário, questionando-o sobre os seus interesses, preferências e necessidades. Este tipo de coleta, geralmente, é feita através do uso de formulários (identificação do perfil inicial do usuário).

Os métodos implícitos inferem informações dos usuários através do monitoramento do comportamento durante a interação com o sistema (atualização do perfil do usuário).

Exemplo:

Modelo de Usuário => Conservador (informado)

Modelo de Usuário => Agressivo (após adaptação ~ análise do comportamento)

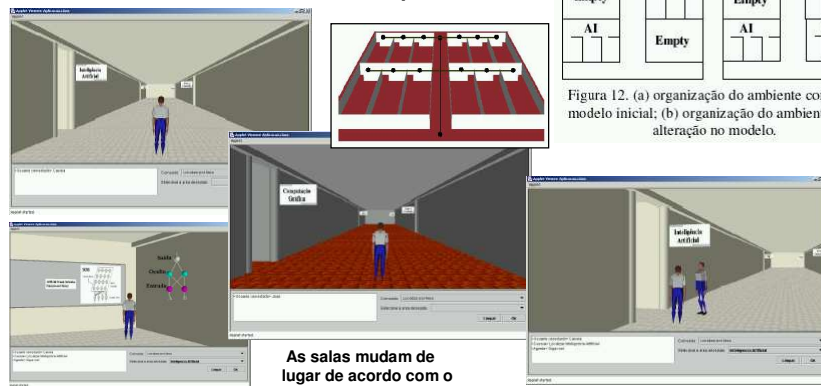
* Mais detalhes podem ser encontrados nos trabalhos relacionados a dissertação de mestrado de Cássia T. dos Santos

Levantamento do Perfil de Usuários (“oponentes”)

➤ Aprendizado Não-Supervisionado

Exemplo de Aplicação [Santos03 / PIPCA]

Ambiente Tridimensional Virtual e Adaptativo



As salas mudam de lugar de acordo com o perfil do usuário (interesses)




Figura 12. (a) organização do ambiente conforme modelo inicial; (b) organização do ambiente após alteração no modelo.

Levantamento do Perfil de Usuários (“opponentes”)

➤ Aprendizado Não-Supervisionado

Adaptação do Modelo de Usuário [Santos03 / PIPCA]

A atualização do modelo está baseada no uso de regras e fatores de certeza (CF):

SE Evidência(s)
ENTAO Hipótese com CF = x

Neste trabalho, as evidências correspondem às áreas do ambiente visitadas e aos conteúdos solicitados (a partir de um mecanismo de busca) e acessados (clikados) pelo usuário. O interesse inicial do usuário por determinada área (valor inicial de P(H)) é obtido a partir da coleta explícita de dados e pode ser alterado durante o processo de atualização do modelo, com base em limiares de aumento e diminuição.

Os CFs associam medidas de crença (MB) e descrença (MD) em uma hipótese (H), dada uma evidência (E). Um fator de certeza 1 indica crença total em uma hipótese, enquanto -1 corresponde a descrença total. O cálculo do fator de certeza é realizado a partir das seguintes fórmulas:

$$CF = \frac{MB - MD}{1 - \min(MB, MD)}$$

$$MB = \begin{cases} 1 & \text{if } P(H) = 1 \\ \frac{\max[P(H|E), P(H)] - P(H)}{1 - P(H)} & \text{otherwise} \end{cases}$$

$$MD = \begin{cases} 1 & \text{if } P(H) = 0 \\ \frac{\min[P(H|E), P(H)] - P(H)}{0 - P(H)} & \text{otherwise} \end{cases}$$

Levantamento do Perfil de Usuários (“opponentes”)

➤ Aprendizado Não-Supervisionado

Adaptação do Modelo de Usuário [Santos03 / PIPCA]

As evidências são usadas para inferir a hipótese de interesse do usuário em cada área do conhecimento, a partir das regras e dos fatores de certeza correspondentes. Para a atualização do modelo, as seguintes regras foram definidas:

SE solicitou ENTAO interesse em Y com CF = x
SE navegou ENTAO interesse em Y com CF = x
SE acessou ENTAO interesse em Y com CF = x

A cada N sessões, para cada área, são verificadas as evidências (navegação, solicitação e acesso) e feitas as inferências de interesse, com base nas regras apresentadas acima. A partir da ordenação dos fatores de certeza resultantes é estabelecido um ranking das áreas de interesse do usuário, através do qual é possível verificar as alterações no modelo inicial (obtido a partir da coleta explícita) e atualizar o modelo.

A partir dessa atualização (alterar perfil = alterar os fatores de certeza sobre o interesse em uma determinada área), é feita a re-organização do ambiente.

Levantamento do Perfil de Usuários (“oponentes”)

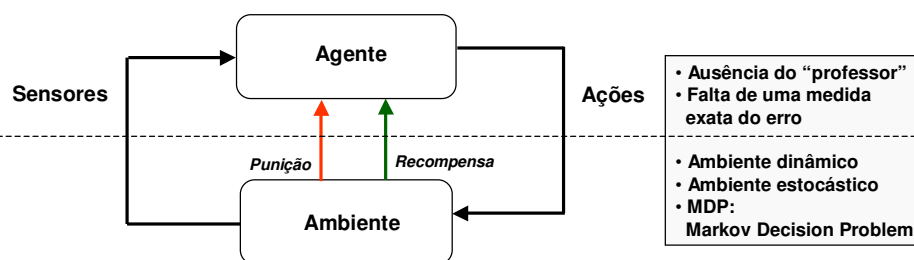
- Modelo de Usuário em Jogos... [Jogos de Ação](#)
 - Modelo de Comportamento...
 - Tipo de Usuário: Agressivo, Impulsivo, Conservador, ...
 - Comportamento no ambiente: Lugares que costuma visitar
 - Análise de ações do usuário: Ataque, Defesa
 - Baseado no comportamento...
 - Criar estratégias de jogo
 - Antecipar movimentos e ações
- Modelo de Usuário em Jogos... [Jogos de Estratégia e Simulação](#)
 - Modelo de Comportamento é Importante / Indispensável

Aprendizado por Reforço (Reinforcement Learning)

- Aprendizado Semi-Supervisionado

Referências:

- Artificial Intelligence: A Modern Approach. Russell & Norvig, 1995 (cap. 20).
- A Standart Interface for Reinforcement Learning Software in C++. Sutton & Samtamaría (Umass / 2003)
- Reinforcement Learning: A Survey. Kaelbling, Littman & Moore, Journal of Artificial Intelligence Research 4 (1996) 237-285



ML4Games

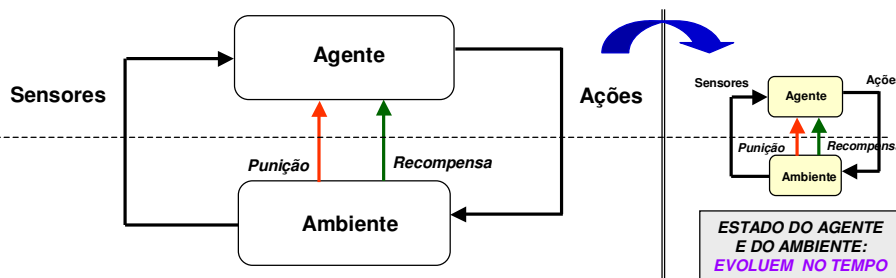


Aprendizado por Reforço (Reinforcement Learning)

➤ Aprendizado Semi-Supervisionado

Referências:

- Artificial Intelligence: A Modern Approach. Russell & Norvig, 1995 (cap. 20).
- A Standart Interface for Reinforcement Learning Software in C++.
- Sutton & Samtamarca (Umass / 2003)
- Reinforcement Learning: A Survey. Kaelbling, Littman & Moore, Journal of Artificial Intelligence Research 4 (1996) 237-285



ML4Games



Aprendizado por Reforço (Reinforcement Learning)

➤ Aprendizado Semi-Supervisionado

Conceitos Básicos:

• Aprendizado baseado no

Sucesso / Falha

Punição x Recompensa (*Punish x Reward*)

Estímulos: Pain / Pleasure - Food / Hunger

[Pavlov – 1849/1936]

• Aplicação em Jogos de Tabuleiro...

Xadrez: Aprendizado com professor => Imitar o professor!

Indica qual jogada faria...

Aprendizado sem professor => ?

Aprendizado por Reforço (Reinforcement Learning)

➤ Aprendizado Semi-Supervisionado

Conceitos Básicos:

- Aprendizado baseado no

Sucesso / Falha

Punição x Recompensa (*Punish x Reward*)

Estímulos: Pain / Pleasure - Food / Hunger [Pavlov – 1849/1936]

- Aplicação em Jogos de Tabuleiro...

Aprendizado sem professor => Random Moves

Status: End of the Game (Terminal State)

Retorno sobre desempenho: *Feed-Back*

Vitória: Sucesso / Perda: Fracasso

- Diferencial:

Não copia o professor

Tentativa de melhorar a performance (tentativa/erro)

Aprendizado por Reforço (Reinforcement Learning)

➤ Aprendizado Semi-Supervisionado

Tipos de Aprendizagem por Reforço... segundo:

- Ambiente:

Acessível (sensores) ou Inacessível (estado interno)

- Recompensa:

Em qualquer estado

Apenas no estado final

- Agente:

Aprendiz passivo (observa passivamente o resultado das ações)

Aprendiz ativo (sugere novas ações)

- Função:

Evaluation Utility function - U(i) ou *Action-Value function*

ADP

Adaptive Dynamic Programing

TD

Temporal Difference Learning

$$U(i) = R(i) + \sum_j M_{ij} U(j) \quad : M_{ij} = \text{Probabilidades de Transição}$$


$$U(i) \leftarrow U(i) + \alpha (R(i) + U(j) - U(i))$$

α = Learning Rate

Aprendizado por Reforço (Reinforcement Learning)

➤ Aprendizado Semi-Supervisionado

Artificial Intelligence: A Modern Approach. Russell & Norvig, 1995 (capit. 20)
Exemplo:



Seqüências de Treinamento:

- (1,1) > (1,2) > (1,3) > (1,2) > (1,3) > (1,2) > (1,1) > (2,1) > (3,1) > (4,1) > (4,2) > -1
- (1,1) > (1,2) > (1,3) > (2,3) > (3,3) > (4,3) > +1
- (1,1) > (1,2) > (1,1) > (1,2) > (1,1) > (2,1) > (3,1) > (3,2) > (4,2) > -1
- (1,1) > (1,2) > (1,1) > (1,2) > (1,3) > (2,3) > (1,3) > (2,3) > (3,3) > (4,3) > +1
- (1,1) > (2,1) > (3,1) > (2,1) > (1,1) > (1,2) > (1,3) > (2,3) > (3,3) > (4,3) > +1
- (1,1) > (2,1) > (1,1) > (1,2) > (1,3) > (2,3) > (3,3) > (3,2) > (4,2) > -1

Aprendizado por Reforço (Reinforcement Learning)

➤ Aprendizado Semi-Supervisionado

Q-Learning: Learning an Action-Value Function

“The agent learns an action-value function giving the “expected utility” of taking a given action in a given state – $Q(a,i)$ ”

$$U(i) = \text{Max}_a Q(a,i)$$

Q-Learning / ADP

Adaptive Dynamic Programming

$$Q(a,i) = R(i) + \sum_j M_{ij}^a \text{Max}_{a'} Q(a',j) \quad \therefore M_{ij}^a = \text{Probabilidade de Transição do estado "i" ao "j" para uma dada ação "a"}$$

Q-Learning / TD

Temporal Difference Learning

$$Q(a,i) \leftarrow Q(a,i) + \alpha (R(i) + \text{Max}_{a'} Q(a',j) - Q(a,i)) \quad \therefore \alpha = \text{Learning Rate}$$

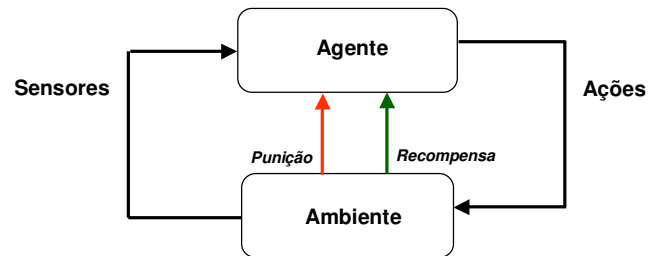
ML4Games



Aprendizado por Reforço (Reinforcement Learning)

➤ Reinforcement Learning em Jogos...

Aprendizado de Agentes baseado na punição e recompensa



Vantagens:

- Não precisa de um professor
- Possibilidade de realizar um aprendizado contínuo

Demo: <http://reinforcementlearning.ai-depot.com/Programs.html>



ML4Games



Aprendizado:

➤ Aprendizado de Máquinas para Jogos...

Outras técnicas possíveis de serem usadas:

- Algoritmos Genéticos (custo computacional muito alto)
- Modelos probabilistas / Redes Bayesianas
- Lógica Nebulosa
- Sistemas Híbridos
- Entre outros...

AI4Games



TENDÊNCIAS na área de GameAI

- AI TOOLS – AI Engine
- AI SKDs – AI Software Development Kits
- Team AI – Sistemas Multi-Agentes (interação, cooperação)
- PLN – Processamento de Linguagem Natural

AI4Games



TENDÊNCIAS na área de GameAI

- AI TOOLS – AI Engine
 - A* - Algoritmo A Star
 - Simulação de Autômatos (FSA, HFSA)
 - RBS – Inference Engine
 - CBR – Case Based Reasoning Tool
 - ANN – Rede Neural Artificial para o Controle de Agentes
 - ANN – Rede Neural Artificial para Simulação de Comportamentos Físicos (dinâmica)
 - Aprendizado de Agentes: Adaptação de Perfil, Aprendizado por Reforço, ...

Ideal: Ferramentas que possam ser facilmente integradas em um Game Engine...

TENDÊNCIAS na área de GameAI

➤ AI TOOLS – AI Engine

- A* - Algoritmo A Star
- Simulação de Autômatos (FSA, HFSA)
- RBS – Inference Engine (incluindo aspectos Real Time!)
- CBR – Case Based Reasoning Tool
- ANN – Rede Neural Artificial para o Controle de Agentes
- ANN – Rede Neural Artificial para Simulação de Comportamentos Físicos (dinâmica)
- Aprendizado de Agentes: Adaptação de Perfil, Aprendizado por Reforço, ...

Ideal: Ferramentas que possam ser facilmente integradas em um Game Engine...

- ### ➤ AI SKDs – AI Software Development Kits
- FreeAIDKit (Proposta Edital Fapergs – SL, 2002)

TENDÊNCIAS na área de GameAI

➤ Team AI – Sistemas Multi-Agentes

- Desenvolvimento de Sistemas Multi-Agente
- Focos de pesquisa:
 - Interação entre os agentes
 - Comunicação entre os agentes
 - Cooperação entre agentes

➤ PLN – Processamento de Linguagem Natural

- Possibilidade de interagir através de comandos de Linguagem Natural...
- Pesquisa: Síntese e Reconhecimento de Fala


AI4Games



FUTURO da área de GameAI

Desafios:

- Criatividade
- AI + CG + Redes
- Tempo Real



Tendências:

- Mercado em plena expansão
- Investimento => Retorno \$\$
- Possibilidade de Inovação
- Empresas:

Para os mais criativos..."Um Lugar ao Sol"