

PCS 2428 / PCS 2059
Inteligência Artificial

Prof. Dr. Jaime Simão Sichman
Prof. Dra. Anna Helena Reali Costa

Aprendizagem Indutiva

Aprendendo pelas observações

- Idéia: percepção deve ser usada não somente para a atuação imediata, mas também para melhorar a habilidade do agente em agir no futuro! → aprendizado
- Aprendizado decorre das interações do agente com o mundo e pela observação do agente de seu próprio processo de decisão.

2


Aprendizado – por que?

- Capacidade de aprender é parte fundamental do conceito de inteligência.
- Um agente aprendiz é mais flexível → aprendizado permite lidar com situações novas (mundo é dinâmico). Dá **autonomia** ao agente.
- Aprendizado facilita tarefa do projetista → programar apenas o essencial

Como construir programas (agentes) que automaticamente melhoram com sua experiência?

3

Agente que aprende



- **Aprendizado**: processo de modificação dos parâmetros do agente, de modo a maximizar uma medida de desempenho.

Um Modelo Geral

- **Ambiente / Sensores / Atuadores**
- **Crítico**: comunica ao EA quão bem ou mal o agente está operando, de acordo com um critério fixo. Observações sensoriais nem sempre são boas indicadoras...
- **Elemento de Aprendizagem (EA)**: armazena informação sobre como a modificação dos parâmetros do EE deve ser feita (algoritmos, estruturas de dados, medida de desempenho, conhecimentos a priori, etc).
- **Gerador de Instâncias**: sugere ações alternativas que podem ser tomadas pelo agente, com o fim de adquirir informação adicional.
- **Elemento de Execução (EE)**: executa as ações de acordo com medida geral de desempenho.

5

Aprendizagem – paradigmas (I)

- **Aprendizado supervisionado**
 - Pares corretos de **entrada/saída** podem ser observados (ou demonstrados por um supervisor).
 - O crítico comunica ao EA o **erro** relativo entre a ação que deve ser tomada idealmente pelo EE (saída desejada) e a ação efetivamente escolhida pelo agente (saída executada).

6

Aprendizagem – paradigmas (II)

- **Aprendizado por reforço**
 - O crítico comunica apenas uma **indicação de desempenho** (geralmente, indicação de quão bom ou ruim é o estado resultante), normalmente de modo intermitente e apenas quando situações dramáticas são atingidas (*feedback* indireto, com retardo).

7

Aprendizagem – paradigmas (III)

- **Aprendizado não-supervisionado**
 - O crítico não envia nenhum tipo de informação ao EA, não há “pistas” sobre as saídas corretas.
 - Geralmente utilizam-se de regularidades, propriedades estatísticas dos dados sensoriais, etc.
 - Ex: Clustering (agrupamento).

8


Aprendizado Indutivo

- **Paradigma:** aprendizado **supervisionado**.
- **Funcionamento:** inferência de uma regra geral (**hipótese**) a partir de exemplos particulares → **generalização**
- Eficácia diretamente proporcional à quantidade de exemplos. Abordagem:
 - **incremental:** atualiza hipótese a cada novo exemplo
 - mais flexível, situada... Porém a ordem de apresentação é importante!
 - **não incremental:** gera hipótese a partir de todo conjunto de exemplos (mais eficiente e prática)
- **Métodos:** simbólicos (ex:ID3), não-simbólicos (ex:NN).

9

Aprendizado Indutivo


- x : entrada; $f(x)$: saída desejada
- Exemplo (par de treinamento) = $(x, f(x))$
- Objetivo: aprender uma função h (hipótese) que aproxime f .



10

Aprendizado Indutiva

Conhecimento em extensão
(exemplos percepção-ação, características-conceitos, etc.)



Conhecimento em intenção
(regras definições.)

Exemplos
dia 29, a Marginal estava engarrafada
dia 30, a Marginal estava engarrafada
dia 01, a Marginal estava engarrafada
dia 03, a Marginal estava engarrafada

Hipótese indutiva
Todo dia, a Marginal está engarrafada

Aprendizado de Árvore de Decisão

- **Função aprendida:** representada por uma árvore de decisão (ou conjunto de regras IF-THEN)
 - **Entrada:** objeto ou situação (alvo) descrita por um conjunto de propriedades/atributos;
 - **Saída:** “decisão” sobre o alvo: SIM / NÃO
 - Árvore de decisão representa funções booleanas
- Idéia básica: testar primeiro o atributo “mais importante”.

12

Conceito a aprender: devo jogar tênis?

```

    graph TD
      céu[céu] -- ensolarado --> umidade[umidade]
      céu -- nublado --> SIM1[SIM]
      céu -- chuvoso --> vento[vento]
      umidade -- alta --> NÃO1[NÃO]
      umidade -- normal --> SIM2[SIM]
      vento -- forte --> NÃO2[NÃO]
      vento -- fraco --> SIM3[SIM]
  
```

Devo jogar tênis se: $(\text{céu} = \text{ensolarado} \wedge \text{umidade} = \text{normal}) \vee (\text{céu} = \text{nublado}) \vee (\text{céu} = \text{chuvoso} \wedge \text{vento} = \text{fraco})$

13

ID3: Algoritmo de aprendizagem

```

function APRENDIZAGEM_ID3(S,Atributos,Default) :árvore de decisão
  if (S = {}) then
    return Default;
  else if (todo s em S tem a mesma classificação) then
    return a classificação;
  else if (Atributos = {}) then
    return valor-da-maioria(S);
  else begin
    A <- ESCOLHA_MELHOR_ATRIBUTO(Atributos,S);
    árvore <- nova árvore com raiz "A";
    para cada valor possível v de A faça begin
      Sv <- subconjunto de S onde A = v;
      subárvore <- APRENDIZAGEM_ID3(Sv,Atributos-(melhor),
        valor-da-maioria(S));
      adicione a árvore uma subárvore com rótulo v;
    end
  end
  return árvore;
end
  
```

ID3 – exemplo

Exemplos S: p positivos e n negativos

“Melhor” atributo

$S = S1 \cup S2 \cup \dots \cup Sx$

15

Qual atributo é o melhor classificador?

- Medida baseada em **ganho de informação**, calculado pela **entropia**
- Entropia**: medida de “impureza” numa coleção de exemplos de treinamento S
 - Entropia = 0: todos membros da mesma classe
 - Entropia = 1: coleção com mesmo número de + e -

$$Entropia(S) = -(p+) \log_2(p+) - (p-) \log_2(p-)$$

16

Entropia: exemplo

$$Entropia(S) = -(p+) \log_2(p+) - (p-) \log_2(p-)$$

- Ex: se S tem 14 exemplos, sendo 9 positivos e 5 negativos, vem:

$$Entropia(S) = -(9/14) \log_2(9/14) - (5/14) \log_2(5/14) = 0.940$$
- Se atributo pode ter c-valores (não só + e -), então:

$$entropia(S) = \sum_{i=1}^c (-p_i \log_2 p_i)$$

OBS: $0 \log_2 0 = 0$

17

Ganho de Informação

- Mede a **redução esperada na entropia**, causada pela partição nos exemplos segundo um atributo.
- Ganho(S,A): ganho de informação de um atributo A, relativo à coleção de exemplos S.

$$Ganho(S,A) = entropia(S) - \sum_{v \in \text{valores}(A)} (|Sv| / |S|) entropia(Sv)$$

valores(A): todos possíveis valores do atributo A

Sv: subconjunto de S no qual A tem valor v

$$Sv = \{s \in S \mid A(s) = v\}$$

18

Exemplos de treinamento para o alvo JogarTênis

Ex	Céu	Temperatura	Umidade	Vento	JogarTênis
X1	Ensolarado	Quente	Alta	Fraco	NÃO
X2	Ensolarado	Quente	Alta	Forte	NÃO
X3	Nublado	Quente	Alta	Fraco	SIM
X4	Chuvoso	Boa	Alta	Fraco	SIM
X5	Chuvoso	Fria	Normal	Fraco	SIM
X6	Chuvoso	Fria	Normal	Forte	NÃO
X7	Nublado	Fria	Normal	Forte	SIM
X8	Ensolarado	Boa	Alta	Fraco	NÃO
X9	Ensolarado	Fria	Normal	Fraco	SIM
X10	Chuvoso	Boa	Normal	Fraco	SIM
X11	Ensolarado	Boa	Normal	Forte	SIM
X12	Nublado	Boa	Alta	Forte	SIM
X13	Nublado	Quente	Normal	Fraco	SIM
X14	Chuvoso	Boa	Alta	Forte	NÃO

Ex: qual melhor atributo classificador?

S: [9+, 5-]
E=0.940

umidade

Alta: [3+, 4-] E=0.985
Normal: [6+, 1-] E=0.592

Ganho(S,umidade) =
=0.940 - (7/14)*0.985 - (7/14)*0.592
=0.151

S: [9+, 5-]
E=0.940

vento

Fraco: [6+, 2-] E=0.811
Forte: [3+, 3-] E=1.0

Ganho(S,vento) =
=0.940 - (8/14)*0.811 - (6/14)*1.0
=0.048

ID3: aprendizado não-incremental
 • analisa todos os exemplos para decidir atributo classificador

Construção da árvore de decisão com ID3

Ganho(S,céu) = 0.246; Ganho(S,umidade) = 0.151
 Ganho(S,vento) = 0.048; Ganho(S,temperatura) = 0.029
 → Para S, céu é melhor (maior ganho)!

[X1, X2, ..., X14]
[9+, 5-]
céu

ensolarado: [X1, X2, X8, X9, X11] [2+, 3-] ?
 nublado: [X3, X7, X12, X13] [4+, 0-] **SIM**
 chuvoso: [X4, X5, X6, X10, X14] [3+, 2-] ?

Construção da árvore de decisão com ID3

Repete passo para Sv1 = {X1, X2, X8, X9, X11} e Sv2 = {X4, X5, X6, X10, X14}
 E assim por diante até chegar às folhas da árvore de decisão.

céu

ensolarado: **umidade**
 normal: **SIM**
 alta: **NÃO**

nublado: **SIM**

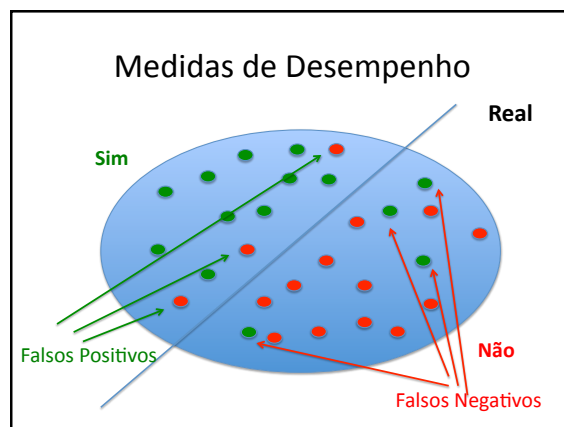
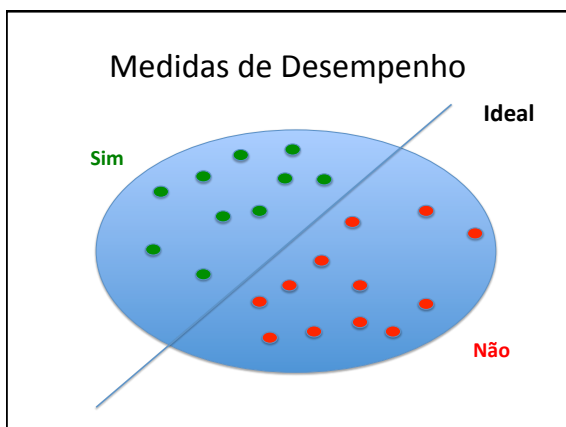
chuvoso: **vento**
 fraco: **SIM**
 forte: **NÃO**

Características do ID3

- Preferência por árvores pequenas:
 - sua busca no espaço de hipóteses aumenta a árvore somente até o tamanho necessário para classificar o conjunto de exemplos de treinamento disponível.
- Coloca mais perto da raiz aqueles atributos que oferecem o maior ganho de informação.

Problemas gerais

- Estratégia de aumentar a árvore o mínimo necessário pode trazer **problemas** quando:
 1. Há ruído nos dados;
 2. Atributos são insuficientes;
 3. Número de exemplos de treinamento é pequeno (não representativo da função buscada)
- **Ambigüidade!!**
 - Ex: dois ou mais exemplos com mesma descrição (em termos dos atributos), mas classificação diferente.
- Soluções possíveis:
 - Cada folha é rotulada com a classificação **majoritária**;
 - Folhas indicam **probabilidade** de ocorrência de cada classificação (relativo à frequência da classificação).



Medidas de Desempenho

TP: true positives (ex: 10)
 TN: true negatives (ex: 12)
 FP: false positives (ex: 3)
 FN: false negatives (ex: 4)


Accuracy : $(TP + TN) / (TP + FP + TN + FN)$
 Error rate: $(FP + FN) / (TP + FP + TN + FN)$
 Sensitivity, Recall: $TP / (TP + FN)$
 Specificity: $TN / (TN + FP)$

Overfitting = hiperespecialização

→ problema de **todos** algoritmos de aprendizado!

Definição: dado um espaço de hipóteses H , uma hipótese $h \in H$ **overfits** os dados de treinamento se existir uma outra hipótese $h' \in H$, tal que **h tem menor erro que h' no conjunto de treinamento, mas h' tem menor erro que h sobre a distribuição total de instâncias (incluindo instâncias fora do conjunto de treinamento).**

→ Como detectar atributos irrelevantes?
 → Quão grande deve ser o ganho de informação para que o correspondente atributo seja um nó na árvore?




Overfitting – Uma Solução

- **Solução 1:** Parar de crescer a árvore antes de alcançar o ponto de classificação perfeita dos exemplos de treinamento.
 - mas, quando parar?

Validação cruzada: tenta estimar quão bem a hipótese corrente irá prever dados ainda não recebidos (“vistos”).


Validação Cruzada



- Algoritmo:
 - 1) Divide o conjunto de exemplos em dois sub-conjuntos: conjuntos de treinamento (CT) e de validação (CV);
 - 2) Usa indução (ID3) para gerar hipótese H sobre CT;
 - 3) Mede percentagem de erro de H aplicada à CV;
 - 4) Quando erro de H em CV aumentar, pára construção de H.
 - Repete passos 1-3 com diferentes tamanhos de CV e CT, e tendo elementos escolhidos aleatoriamente
- **Tamanho do conjunto de treinamento:** pode-se calcular a média da percentagem de acerto da hipótese atual em CV e determinar a **curva de aprendizagem** para o domínio em questão.
 - Espera-se que a qualidade da predição cresça com o crescimento do tamanho do conjunto de treinamento.

31

Curva de Aprendizagem



32

Overfitting – Outra Solução

- **Solução 2:** Abordagens que provocuem o *overfitting* e **depois poda a árvore (post-pruning)**
 - **Método do Erro Reduzido:**
 - considera cada nó como candidato a folha (elimina sub-árvore abaixo dele), com classificação a ele associada como a mais comum;
 - o nó se torna folha (nova árvore, menor) sempre que a acurácia da classificação não diminuir em relação à árvore original, usando o conjunto de validação.

33

Aplicações

- GASOIL
 - Sistema de separação de gás-óleo em plataformas de petróleo
 - Construção do sistema especialista para tal projeto usaria 10 pessoas-ano (aproximadamente 2500 regras!)
 - Desenvolvido em 100 pessoas-dia, usando aprendizado de árvore de decisão.
- Piloto automático de um *Cessna*
 - Treinado por três pilotos, obteve um desempenho melhor que os três
- Outros: Mineração de dados, Recuperação de Informação, Classificação de imagens, etc.

34