

Introdução a Sistemas Inteligentes



Conceituação

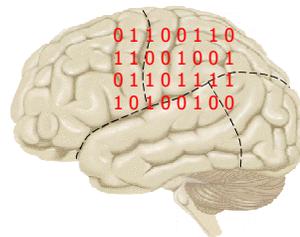
Prof. Ricardo J. G. B. Campello

ICMC / USP

Créditos



- Parte do material a seguir consiste de adaptações e extensões dos originais gentilmente cedidos pelo Prof. André C. P. L. F. de Carvalho





Aula de Hoje

- Motivação e Definições Básicas da Ementa
 - Sistemas Inteligentes
 - Sistemas Baseados em Conhecimento
 - Raciocínio Aproximado
 - Aprendizado de Máquina
 - Raciocínio Baseado em Casos
 - Análise Inteligente / Mineração de Dados

3



O que são Sistemas Inteligentes ?

- Sistemas que exibem algum comportamento que se possa caracterizar como "inteligente"
 - Problema é a interpretação de "inteligente"...
 - Muitas definições... Muita controvérsia...
- No contexto da disciplina / área de pesquisa:
 - capacidade de aprendizado, generalização, aproximação, adaptação, cooperação, evolução, dedução, indução, etc.

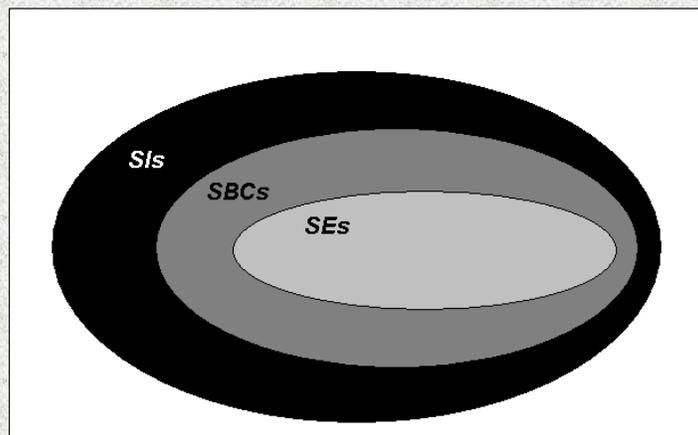
4

O que são Sistemas Baseados em Conhecimento (SBCs) ?

- **SBCs** ⇒ Classe de *Sistemas Inteligentes* (SIs) que tornam explícito o domínio do conhecimento, além de separá-lo do sistema. Exemplo: *Sistemas Especialistas* (SEs)
- **SEs** ⇒ SBCs que resolvem problemas ordinariamente resolvidos por especialistas humanos, utilizando conhecimento fornecido por um ou mais especialistas

5

Relação entre SIs e SBCs



6

Conhecimento

Compreensão ou Modelo de um determinado Domínio ou Área

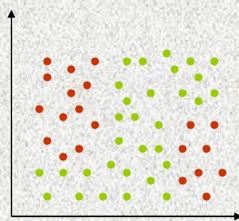
Dados – Informação – Conhecimento

- **Dados:**
 - quantificações de um determinado evento
- **Informação:**
 - dados contextualizados
- **Conhecimento:**
 - (modelo das) relações existentes entre as informações contidas nos dados e do seu significado

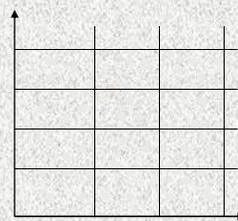
7

Exemplo

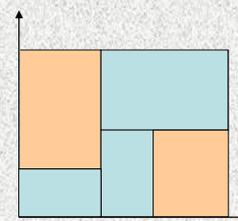
(Dados – Informação – Conhecimento)



Dados
Números



Informação
Granularização



Conhecimento
Regras Se - Então

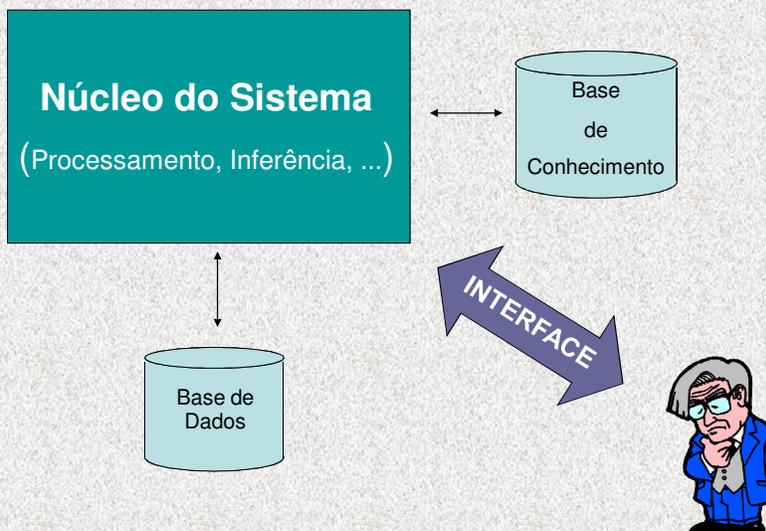
8

Sistemas Convencionais × SBCs (Características Típicas)

S. Convencionais	SBCs
Estruturas de Dados	Representação do Conhecimento
Dados e Relações entre Dados	Conceitos e Relações entre Conceitos
Conhecimento Embutido no Código	Conhecimento Representado Explicitamente e Separado do Código que o Manipula
Explicação do Raciocínio é Difícil	Podem e Devem explicar o Raciocínio

9

Estrutura Básica de um SBC



10

Base de Conhecimento

- **Alguns Tipos de Representação da BC:**

- 1. Lógica (Simbólica):**

- *Proposicional e Predicados*

- 2. Regras:**

- *Sistemas de Produção*

- *Sistemas Fuzzy*

- 3. Frames e Redes Semânticas**

Disciplina
de IA

11

Sistemas Fuzzy e Raciocínio Aproximado

- Modus Ponens Clássico e Condicional Exata:

$\frac{A}{A \rightarrow B} \Rightarrow$	<table border="0" style="width: 100%;"> <tr> <td style="padding-right: 20px;">Chuva</td> <td style="text-align: right;">$x = 10$</td> </tr> <tr> <td style="padding-right: 20px;">Chuva implica Estrada Perigosa</td> <td style="text-align: right;">$\text{If } x = 10 \text{ Then } y = y + 15$</td> </tr> <tr> <td style="border-top: 1px solid black; padding-top: 5px; padding-right: 20px;">Estrada Perigosa</td> <td style="border-top: 1px solid black; text-align: right; padding-top: 5px;">$y = y + 15$</td> </tr> </table>	Chuva	$x = 10$	Chuva implica Estrada Perigosa	$\text{If } x = 10 \text{ Then } y = y + 15$	Estrada Perigosa	$y = y + 15$
Chuva	$x = 10$						
Chuva implica Estrada Perigosa	$\text{If } x = 10 \text{ Then } y = y + 15$						
Estrada Perigosa	$y = y + 15$						

- Modus Ponens e Condicional **Aproximados**:

$\frac{A^*}{A \Rightarrow B} \Rightarrow$	<table border="0" style="width: 100%;"> <tr> <td style="padding-right: 20px;">Chuva Pesada</td> <td style="text-align: right;">$x = 9.856$</td> </tr> <tr> <td style="padding-right: 20px;">Chuva implica Estrada Perigosa</td> <td style="text-align: right;">$\text{If } x \approx 10 \text{ Then } y = y + (\approx 15)$</td> </tr> <tr> <td style="border-top: 1px solid black; padding-top: 5px; padding-right: 20px;">Estrada Muito Perigosa</td> <td style="border-top: 1px solid black; text-align: right; padding-top: 5px;">$y = \dots$</td> </tr> </table>	Chuva Pesada	$x = 9.856$	Chuva implica Estrada Perigosa	$\text{If } x \approx 10 \text{ Then } y = y + (\approx 15)$	Estrada Muito Perigosa	$y = \dots$
Chuva Pesada	$x = 9.856$						
Chuva implica Estrada Perigosa	$\text{If } x \approx 10 \text{ Then } y = y + (\approx 15)$						
Estrada Muito Perigosa	$y = \dots$						

12

SI's / SBCs podem Aprender ?

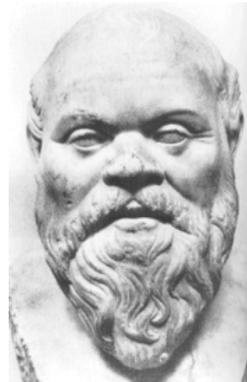
- Desde que os computadores foram inventados, é perguntado se eles poderiam aprender
- Se fosse possível entender como programá-los para aprender, o impacto seria enorme
 - Poderiam melhorar automaticamente seu desempenho com a experiência

13

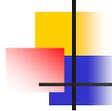
Definição de Aprendizado

Sócrates: Aprender é Recordar

(Diálogos de Platão)



14



Aprendizado de Máquina (AM)

- Algumas definições:
 - Uma máquina de aprendizado, definida de maneira ampla, é qualquer dispositivo cujas ações são influenciadas por **experiências anteriores** (Nilsson 1965)
 - Qualquer mudança em um sistema que o permita ter um melhor desempenho na segunda vez em que ele **repita** uma mesma tarefa ou outra retirada da mesma população (Simon 1983)
 - Modificação de uma tendência comportamental por meio de **experiência** (Webster 1984)
 - Uma melhoria na capacidade de processar informação a partir da **atividade** de processar informação (Tanimoto 1990)

15

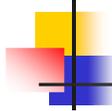


Aprendizado de Máquina

- Definição formal (Mitchell, 1997):

Um programa de computador é dito **aprender** a partir de uma experiência E com respeito a alguma classe de tarefas T e medida de desempenho P , se seu desempenho em tarefas de T , medido por P , melhora com a experiência E

16



Exemplo

- Problema de Filtrar SPAMs:
 - **Tarefa T**: categorizar mensagens de *email* como *spam* ou legítima
 - **Medida** de desempenho P: porcentagem de mensagens de *email* corretamente classificadas
 - **Experiência** de treinamento E: conjunto de *emails* rotulados por seres humanos

17



Por que AM é importante?

- Algumas tarefas não podem ser bem executadas sem que seja por meio de exemplos
 - Ex.: Reconhecer pessoas
- Ser humano não é capaz de explicar (e portanto de programar) sua habilidade para executar alguns tipos de tarefas
 - Ex.: Andar de bicicleta
- Quantidade de conhecimento disponível pode ser muito grande para ser descrito (e portanto programado) por humanos
 - Ex.: Diagnóstico médico

18



Por que AM é importante?

- Ser humano não é capaz de executar algumas tarefas que demandam quantidades grandes de cálculos complexos, passíveis apenas de execução em computador:
 - P. ex., detectar inter-relacionamentos / correlações escondidas em grandes quantidades de dados
- Ambientes (e perfis dos problemas) podem mudar com o tempo
 - Capacidade de adaptação automática é fundamental

19

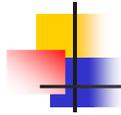


Aprendizado de Máquina

Na medida que os computadores se tornam mais sofisticados, parece inevitável que AM exercerá um papel central em Ciência da Computação e tecnologia de computadores

Tom Mitchell

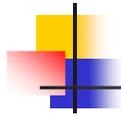
20



Paradigmas de Treinamento em AM

- Principais paradigmas de treinamento
 - **Supervisionado**
 - **Não supervisionado**
 - **Reforço**

21



Treinamento Supervisionado

- Guiado por um "professor" externo
 - "Professor" possui conhecimento sobre o ambiente
 - Representado por conjunto de pares (\mathbf{x} , \mathbf{d})
 - Exemplo: \mathbf{x} = conjunto de sintomas, \mathbf{d} = diagnóstico
 - Parâmetros do modelo são ajustados por apresentações sucessivas de pares (\mathbf{x} , \mathbf{d})
 - Modelo procura reproduzir comportamento do "professor"

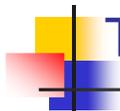
22



Treinamento por Reforço

- Guiado por um “crítico” externo
 - Processo de tentativa e erro
 - Procura maximizar sinal de reforço
- Se ação tomada por sistema é seguida por estado satisfatório, sistema é fortalecido, caso contrário, sistema é enfraquecido
- Tipos de reforço
 - Positivo (recompensa), Negativo (punição), Nulo

23



Treinamento Não Supervisionado

- Não tem crítico ou professor externo
 - Extração de propriedades estatisticamente relevantes
 - Exemplo:
 - Descobrir grupos de indivíduos com perfis de compra diferenciados em grandes bases de dados de consumidores, utilizando apenas os próprios dados

24

Modelos de Representação do Conhecimento Aprendido

- Modelos Simbólicos (paradigma **simbólico** de AM)

- Linguagem lógica proposicional ou de 1ª ordem,
- Regras,
- Árvores de decisão,
- Redes semânticas, ...

→ Disciplina de IA

- Modelos Matemáticos

- Regressão linear,
- Redes neurais (paradigma **conexionista** de AM),
- Máquinas de vetores de suporte, ...

25

Modelos de Representação do Conhecimento Aprendido

- Modelos Baseados em Instâncias (paradigma **baseado em casos**)

- K-NN,
- Raciocínio Baseado em Casos (CBR), ...

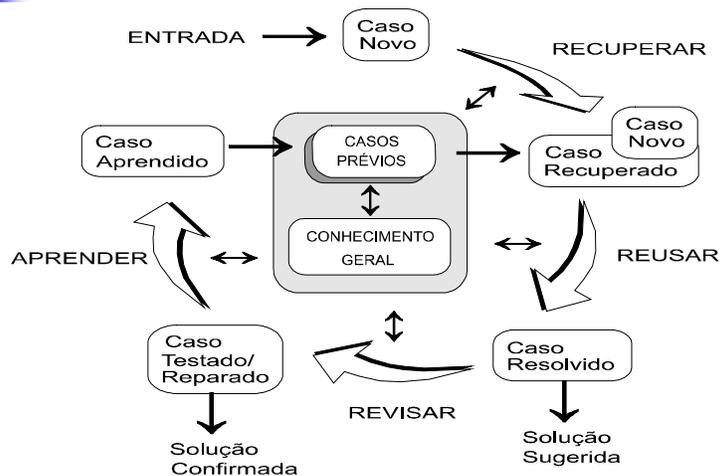
- Modelos Probabilísticos (paradigma **probabilístico**)

- Naive Bayes,
- Redes Bayesianas,
- Misturas de Gaussianas,
- Modelos de Markov Escondidos (HMMs), ...

→ Disciplina de IA

26

Exemplo de Modelo: Sistema Baseado em Casos



27

Técnicas de Aprendizado em AM

- Dado um tipo de modelo, um conceito / tarefa a ser aprendido e um conjunto de dados / exemplos, é preciso algum mecanismo para obter, a partir dos dados, um modelo específico que represente o conceito / tarefa
 - Esse mecanismo, denominado mecanismo de aprendizado, consiste fundamentalmente de uma **técnica de busca**
 - Busca-se no espaço dos modelos plausíveis por aquele modelo específico que melhor represente o conceito ou realize a tarefa
 - Exemplo: melhor conjunto de parâmetros de uma rede neural para que ela guie da melhor forma possível um veículo autônomo

28



Técnicas de Aprendizado

- Algoritmos Baseados em Otimização Matemática
 - Regressão Linear
 - Redes Neurais
 - Algoritmos de Agrupamento
 - ...
- Computação Evolutiva (paradigma **evolucionário**)
 - Aplicável a vários modelos...

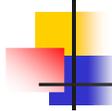
29



Técnicas de Aprendizado

- Dividir para Conquistar
 - Indução de regras e árvores de decisão
- Estimação de Probabilidades (paradigma **probabilístico**)
 - Naive Bayes, Redes Bayesianas, ...
- ...

30



Aplicações de AM

- Algoritmos de AM têm sido bem sucedidos, p. ex., para:
 - Identificar genes associados a determinadas doenças
 - Discriminar tecidos (saudáveis e doentes), objetos celestiais, ...
 - Identificar nichos de mercado
 - Prever a vazão de rios e nível de represas
 - Detectar uso fraudulento de cartões de crédito
 - Otimizar ações de controle em processos de produção
 - Reconhecimento de faces, de voz, de assinaturas ...
 - e tantas outras...

31



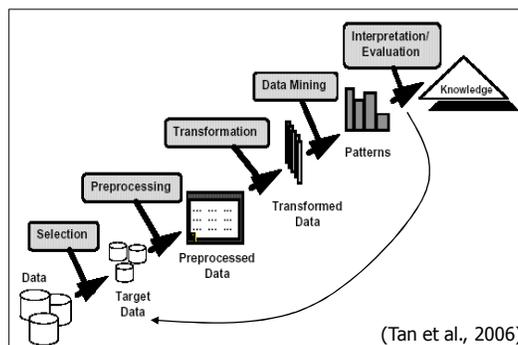
AM, KDD e DM

- Uma das áreas de aplicação mais importantes de AM têm sido a **Descoberta de Conhecimento em Bases de Dados (KDD)**
 - Extração de **conhecimento** a partir de:
 - Registros de compras em grandes supermercados
 - Registros de empréstimos financeiros
 - Registros de transações financeiras
 - Registros médicos
 - Sequências de expressão-gênica
 - ...
 - Engloba a **Mineração de Dados** (Data Mining – DM)

32

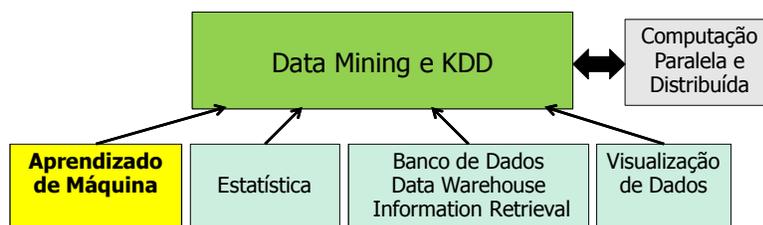
AM, KDD e DM

- KDD é usualmente definido como um **ciclo** que envolve DM:
 - Formalmente, é o processo *não trivial* de identificar padrões **válidos, novos, potencialmente úteis e compreensíveis** em dados



AM, KDD e DM

- Muitos utilizam os termos Aprendizado de Máquina e Data Mining de maneira indiscriminada, mas tais termos se referem a conceitos bem diferentes:



- DM é usualmente feito utilizando AM, mas nem sempre
 - Muitas vezes refere-se a DM via AM por **Análise Inteligente de Dados**



Referências

- Mitchell, T. M., *Machine Learning*, McGraw-Hill, 1997
- P.-N. Tan, Steinbach, M., and Kumar, V., *Introduction to Data Mining*, Addison-Wesley, 2006
- Rezende, S. O. (Ed.), *Sistemas Inteligentes: Fundamentos e Aplicações*, Editora Manole, 2003