

# GT-JeDi - Curso de Desenv. de Jogos

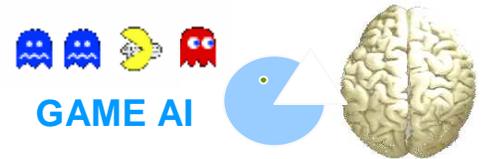
## *IA para Jogos*



Fernando Osório, com algumas alterações de intuito didático de G. Pessin

2007/1 - A07

# Representação e Manipulação de Conhecimentos



## ➤ Cronograma

### ➤ Introdução

#### ➤ IA Simbólica / Conexionista / Evolutiva

### ➤ CBR (Raciocínio baseado em casos)

### ➤ Sistemas inteligentes

#### ➤ SE (Sistemas especialistas)

##### ➤ Exemplo :: Clips (net3.clp, wine.clp)

#### ➤ RBS (Rule-Based Systems)

##### ➤ Exemplo :: Robocode, Robombeiros 0.5

#### ➤ CF (Fator de certeza)

#### ➤ Fuzzy

##### ➤ Exemplo :: CubiCalc, AIWisdom, LoadSway

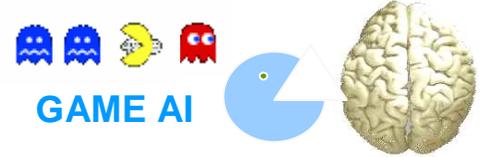
# Representação e Manipulação de Conhecimentos



## ➤ I.A. Simbólica

- Sistemas baseados na manipulação explícita de símbolos sob a aplicação de regras também explícitas.
- Inspira-se no modelo simbólico da mente, que parte do princípio de que a atividade cognitiva resume-se em manipulação de símbolos.
- Um símbolo [PEIRCE 1995] é um signo (marca, sinal) que referencia um objeto ou conceito, sem nenhuma relação causal com o mesmo, apenas devido a uma convenção social.
- **Um símbolo:**
  - **MAÇÃ** – cadeia de caracteres, representa o objeto ou conceito maçã.
  - **Arbitrário**, um mesmo símbolo pode inclusive referir-se a objetos diferentes em sistemas diferentes. Embora seja mais intuitivo usar o símbolo 'MAÇÃ' para representar o conceito maçã, poderíamos usar 'X', '011010' ou qualquer outra forma, sem nenhum prejuízo.
  - **Discreto**, não existindo relação de continuidade que possa ser semanticamente explorada. Dessa forma, entre os símbolos 'MAÇÃ' e 'PÊRA' – ou quaisquer outros pares de símbolos possíveis - não existe uma relação sistemática que ofereça possibilidade de uma transição contínua de um para outro.

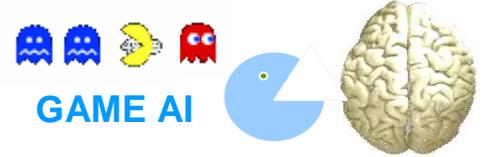
# Representação e Manipulação de Conhecimentos



## ➤ I.A. Simbólica

➤ A manipulação de símbolos através das regras é **baseada puramente na forma desses símbolos (e não de seu significado)**, isto é, é **puramente sintática**, e consiste na combinação e recombinação dos símbolos.

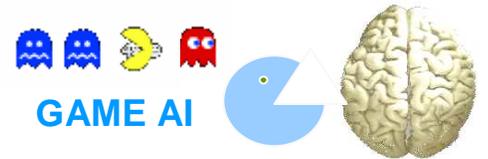
# Representação e Manipulação de Conhecimentos



## ➤ I.A. Simbólica

- A aprendizagem é um aspecto difícil de se lidar em sistemas simbólicos. Isso ocorre devido ao fato de tais sistemas serem focados em engenharia e representação do conhecimento em vez de aprendizagem.
- A aprendizagem em sistemas simbólicos, qualquer que seja a técnica, resume-se em modificação das estruturas de símbolos usadas para representar o conhecimento de forma a refletir o conhecimento adquirido pela experiência.

# Representação e Manipulação de Conhecimentos



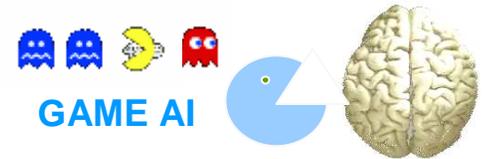
## ➤ I.A. Conexionista

- Sinônimo de rede neural artificial, inspirados na arquitetura e funcionamento do cérebro, são constituídos de um grande número de elementos de processamento muito simples, parecidos com neurônios, maciçamente interligados em forma de rede.
- Formalização matemática do funcionamento de neurônios
- Infância complicada (mas isso é coisa da aula 14...)

## ➤ I.A. Evolutiva

- Sinônimo de algoritmos/programação genética (aula 15)

# Representação e Manipulação de Conhecimentos



Inteligência Artificial:

- Representação e Manipulação de Conhecimentos
  - Analogia: CBR - Case Based Reasoning
  - Inferência: Sistemas Especialistas, KBS / RBS (Rule)
  - Incerteza e Possibilidade: Certainty Factor, Fuzzy Logic
  - Probabilidade: Bayesian Belief Networks
  - Linguagens: Lógica e Resolução de Problemas: Prolog
  - Representação de Conhecimentos de Alto Nível: Senso Comum, Redes Semânticas, Ontologias

## \* Ferramentas Usadas:

**Aquisição Manual de Conhecimentos**

**Representação de Conhecimentos**

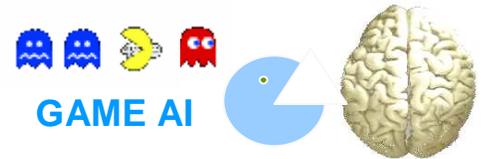
**Manipulação de Conhecimentos**

**Aquisição Automática de Conhecimentos**

**Validação de Conhecimentos**

**Transferência de Conhecimentos**

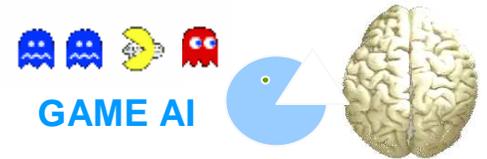
## TEMAS DE ESTUDO



### ***CBR - Case-Based Reasoning***

- **Conceitos Básicos**
- **Características**
- **Tipos de Aplicação**
- **Ciclo CBR**
- **Discussão sobre os Sistemas CBR**
- **Representação de Conhecimentos**
- **Métricas**
- **Exemplos de Sistemas CBR**
  
- **Temas de Pesquisa relacionados aos sistemas CBR**

## CONCEITOS BÁSICOS



Modelo Cognitivo Humano => Suporte ao CBR - **Case-Based Reasoning**

CBR => “A importância das lembranças no raciocínio humano”

**“Um método de resolução de problemas onde novos problemas são resolvidos adaptando-se soluções de antigos problemas similares”**

Memória de Casos Passados

Experiências Passadas / Casos Válidos

Recuperação de Casos Relevantes (Retrieval)

Raciocínio: Relembrar / Fazer Analogias (Reasoning by Analogy)

Associação de Idéias

Revisão de Conhecimentos Constante

Aquisição de Conhecimentos Constante (Revise / Retain)

Explorar: Sucessos passados / Fracassos passados

**Regras Básicas:**

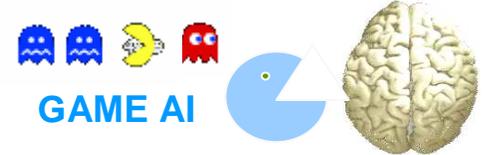
**“Problemas Similares tem Soluções Similares”**

**“Problemas tem a Tendência a se Repetir”**

**“Aprendizado a partir da Experiência Prática”**

**CBR: New solutions are generated by **retrieving** the most relevant cases from memory and **adapting** them to fit new situations**

## CONCEITOS BÁSICOS



### SISTEMAS

**CBR - *Case-Based Reasoning* e ES - *Expert Systems***

**CBR => Memória de Casos / Episódios Passados**

**Vantagens: Fácil obtenção de conhecimentos**

**Explicitação de conhecimentos bem aceita pelo usuário**

**Aquisição de Conhecimentos - simples, contínua**

**Tolerância as inconsistências / Fácil atualização**

**Generalização :^}**

**ES => Cadeia de Regras de Generalização**

**Problemas: Começa do “nada”**

**Explicitar regras (Knowledge Elicitation)**

**Gargalo da aquisição de conhecimento**

**(Knowledge Acquisition Bottleneck)**

**Contradições, conhecimento incompleto/inválido**

**Revisão e atualização de conhecimentos**

## CONCEITOS BÁSICOS



### **Exemplo:**

**Falha da Impressora:** *TimeOut*

**Painel/Luzes:** *Apagado*

**Resposta a comandos locais:** *Não*

**Tipo de Falha:** *Alimentação Interrompida / Falta de Luz*

**Solução:** *Aguardar o retorno da luz*

**Falha da Impressora:** *TimeOut*

**Painel/Luzes:** *Apagado*

**Resposta a comandos locais:** *Não*

**Tipo de Falha:** *Alimentação Interrompida / Impressora não conectada na tomada*

**Solução:** *Conectar a impressora na tomada*

**Falha da Impressora:** *TimeOut*

**Painel/Luzes:** *Apagado*

**Resposta a comandos locais:** *Sim*

**Tipo de Falha:** *Falha de Hardware*

**Solução:** *Resetar a impressora*

**Falha da Impressora:** *TimeOut*

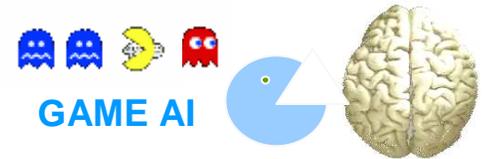
**Painel/Luzes:** *Aceso*

**Resposta a comandos locais:** *OK*

**Tipo de Falha:** *Conexão da porta paralela com problema*

**Solução:** *Testar a porta paralela com outra impressora que funcione*

# CARACTERÍSTICAS



## Vantagens...

### 1. Aquisição de Conhecimentos:

- ☹ Problema de explicitar os conhecimentos
- ☺ Torna-se apenas um problema de coletar casos

### 2. Manutenção de Conhecimentos:

- ☹ Problema da revisão de conhecimentos/inconsistências
- ☺ Torna-se apenas um problema de adicionar mais casos

### 3. Aumento da Eficiência na Resolução de Problemas:

- ☹ Problemas complexos demais (tipo NP-Hard)
- ☺ Tornam-se simples - Boa heurística: usar experiência prévia de sucesso

### 4. Aumento da Qualidade das Soluções:

- ☹ Problema do conhecimento incompleto em sistemas baseados em regras
- ☺ Podemos adicionar novos exemplos para refinar os conhecimentos
- ☺ Podemos trabalhar com conhecimentos parciais sobre o problema

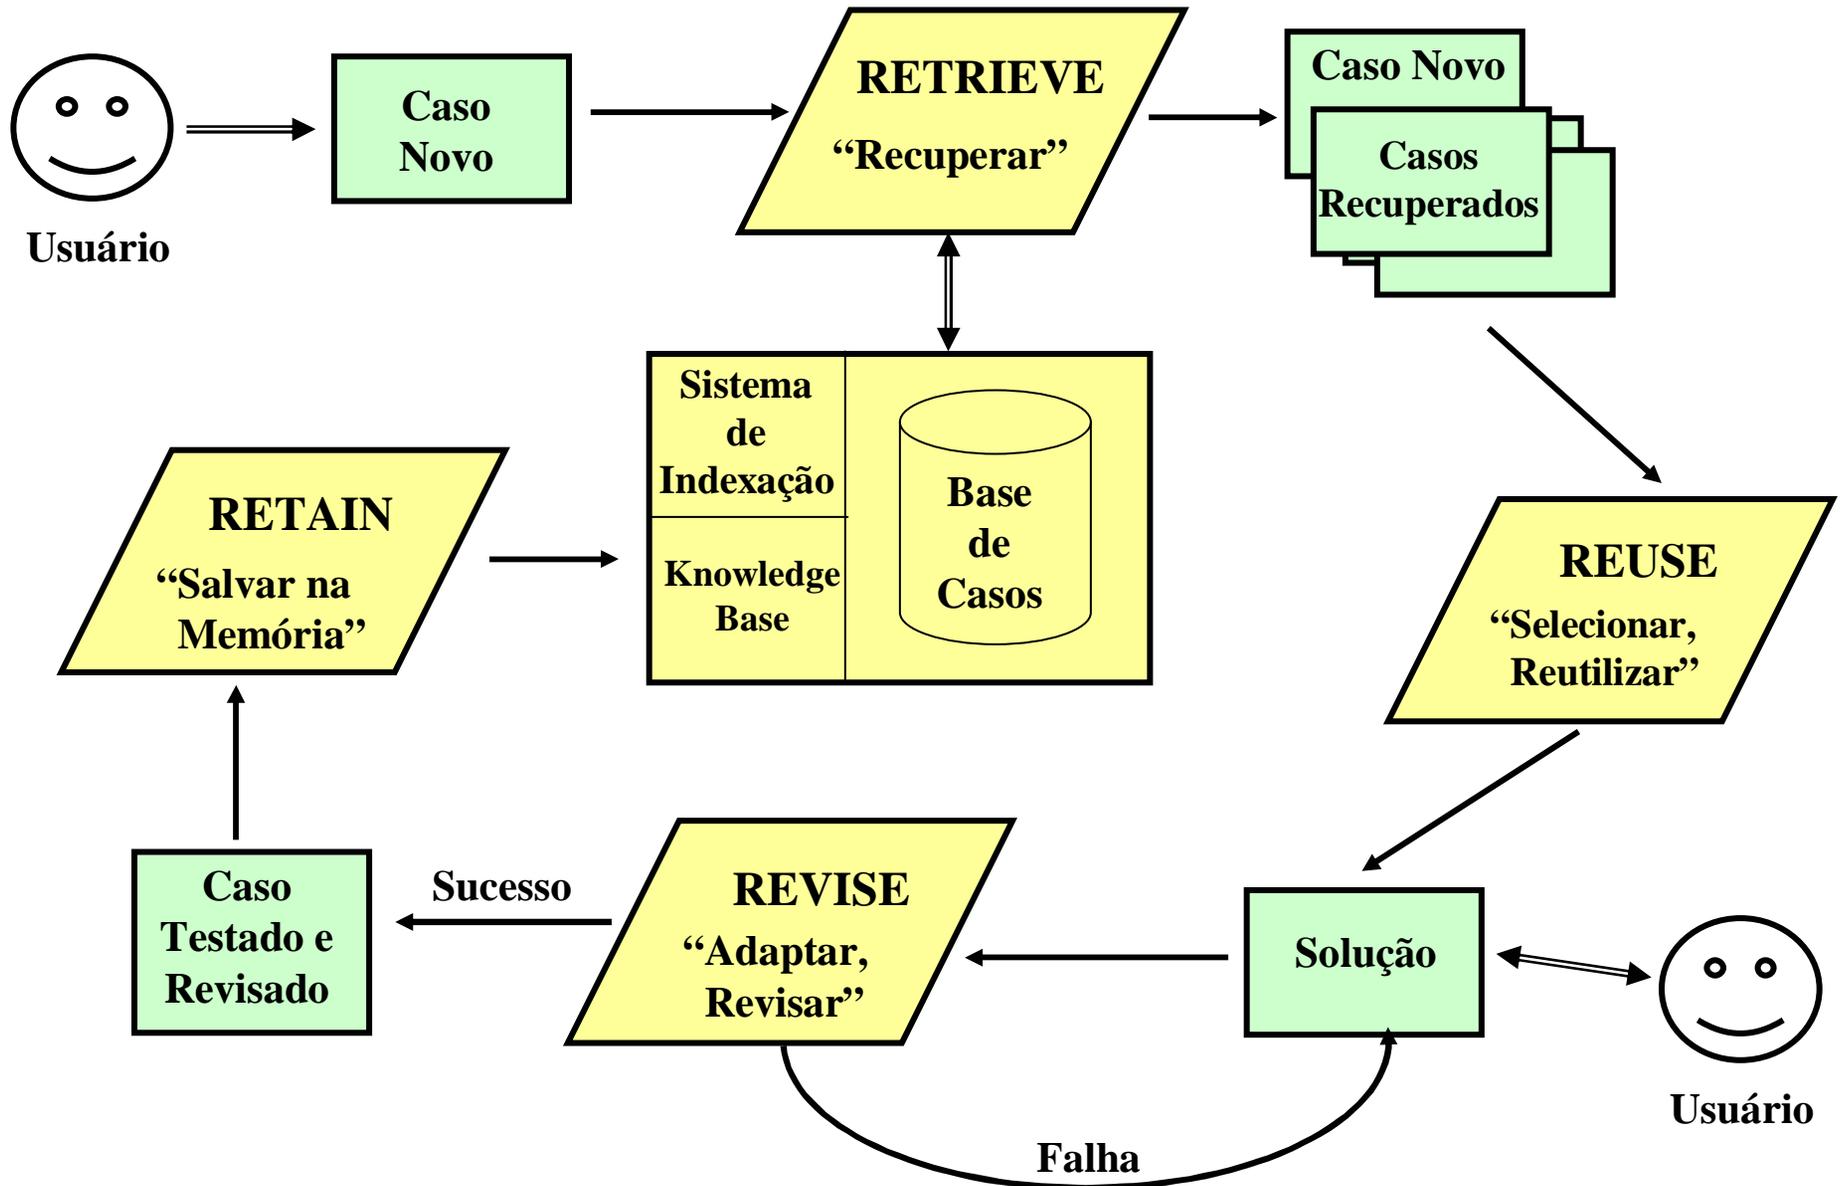
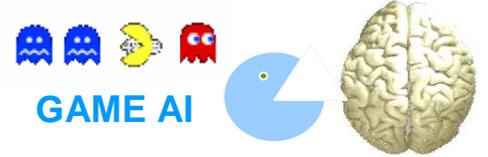
### 5. Aceite pelo usuário:

- ☺ Fácil de convencer os usuários em relação a...  
Inserção de conhecimentos / Consulta do Sistema / Explicação das Respostas

## Problemas... ☹ Seleção dos Casos: Métricas

- ☹ Casos não estruturados - Alto Nível / Linguagem Natural

# CICLO CBR



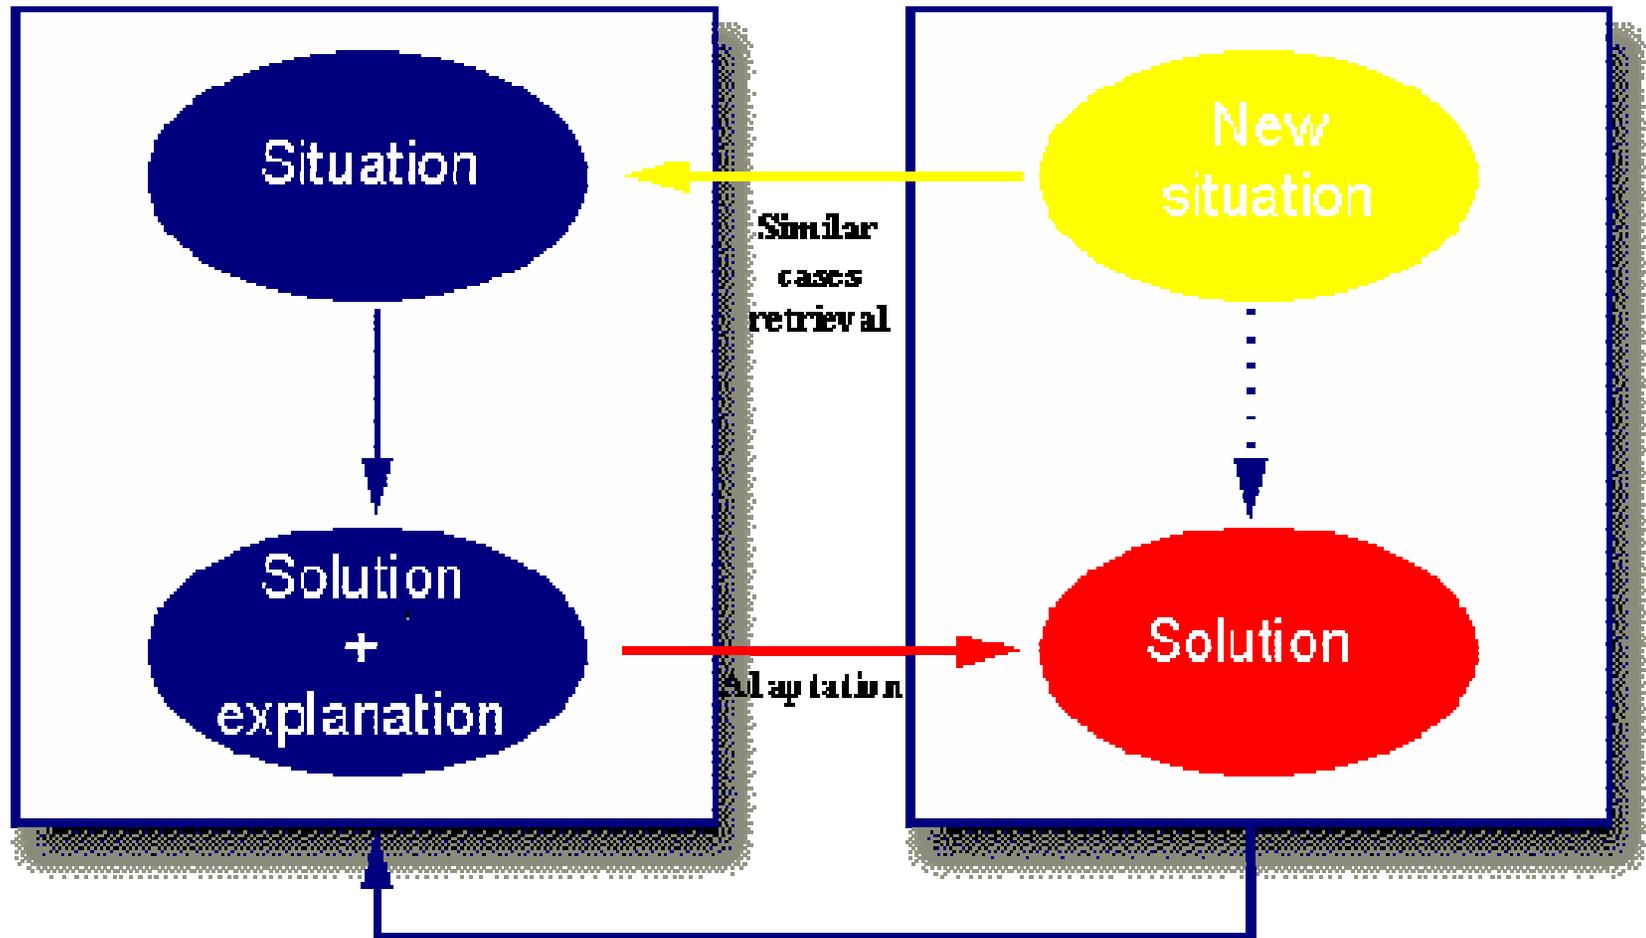


## PREVIOUS EXPERIENCE

Structured case base

## CURRENT SITUATION

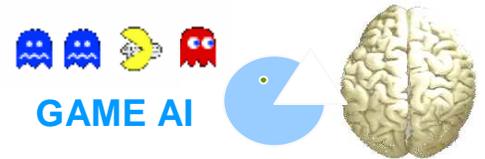
Problem to solve



Improvement of the system experience

*The Dynamic of CBR*

## SIMILARIDADE / MÉTRICAS DE COMPARAÇÃO:



### \* ATRIBUTOS NUMÉRICOS (Quantitativos)

Caso 1 - Atributo 1 (C1A1) = 10

Caso 2 - Atributo 1 (C2A1) = 20

Similaridade Euclidiana (C1A1A2, C2A1A2) =  $\text{SQRT} ( \text{SQR}(C2A1 - C1A1) + \text{SQR}(C2A2 - C1A2) )$

Similaridade Normalizada (C1A1, C2A1) =  $1 - | C2A1 - C1A1 | / ( \text{ValMax} - \text{ValMin} )$

Similaridade Ponderada (C1A1A2, C2A1A2) =  $\text{Peso\_A1} * \text{Distância} (C1A1, C2A1) + \text{Peso\_A2} * \text{Distância} (C1A2, C2A2)$

Métrica de Similaridade Não Linear...

### \* ATRIBUTOS TEXTUAIS (Qualitativos)

Cores = { Branco, Amarelo, Vermelho, Marrom, Preto }

Caso 1 - Atributo 1 (C1A1) = Branco

Caso 2 - Atributo 1 (C2A1) = Amarelo

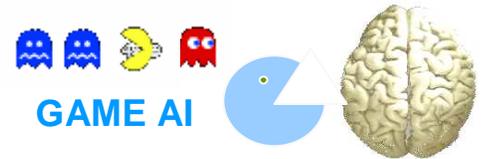
Opção 1: Similaridade binária

Opção 2: Similaridade dada uma ordem pré-definida

Opção 3: Similaridade dada uma tabela de relações

Opção 4: Similaridade entre textos (por aproximação)

Opção 5: ...



## SIMILARIDADE / MÉTRICAS DE COMPARAÇÃO:

### \* ATRIBUTOS TEXTUAIS (Qualitativos)

Cores = { Branco, Amarelo, Vermelho, Marrom, Preto }

Caso 1 - Atributo 1 (C1A1) = Branco

Caso 2 - Atributo 1 (C2A1) = Amarelo

#### Opção 1: Similaridade binária

SE C1A1 = C2A2 THEN Similaridade = 1  
ELSE Similaridade = 0

#### Opção 2: Similaridade dada uma ordem pré-definida

| Branco | Amarelo | Vermelho | Marrom | Preto |
|--------|---------|----------|--------|-------|
| 0      | 0.25    | 0.5      | 0.75   | 1     |

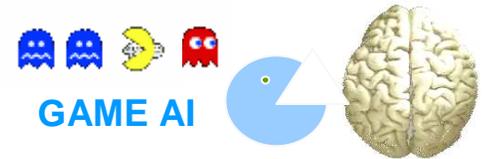
#### Opção 3: Similaridade dada uma tabela de relações

|          | Branco | Amarelo | Vermelho | Marrom | Preto |
|----------|--------|---------|----------|--------|-------|
| Branco   | 1      | 0.8     | 0.4      | 0.15   | 0     |
| Amarelo  |        | 1       | 0.5      | 0.2    | 0     |
| Vermelho |        |         | 1        | 0.7    | 0.6   |
| Marrom   |        |         |          | 1      | 0.85  |
| Preto    |        |         |          |        | 1     |

#### Opção 4: Similaridade entre textos (por aproximação) => Assassínio <=> Assassinato

#### Opção 5: ...

# DISCUSSÃO sobre os SISTEMAS CBR



NOMENCLATURA... [Aamodt, Plaza 94]

1. Exemplar-Based Reasoning (EBR)
2. Instance-Based Reasoning (IBR)
3. Memory-Based Reasoning (MBR)
4. Case-Based Reasoning (CBR)
5. Analogy-Based Reasoning (ABR)

APRENDIZADO... [David Leake 96]

- A. Instance-Based Learning (IBL)
- B. Explanation-Based Learning (EBL)

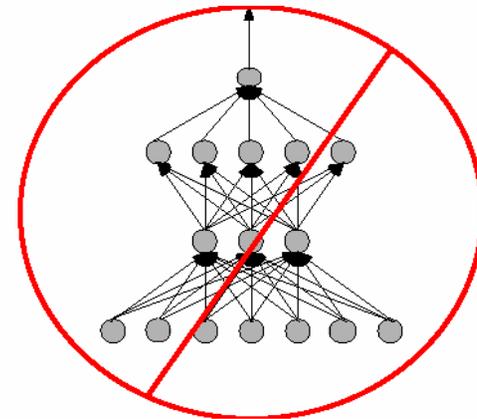
## Case-Based Reasoning

David W. Aha

Navy Center for Artificial Intelligence  
Naval Research Laboratory  
Washington, DC

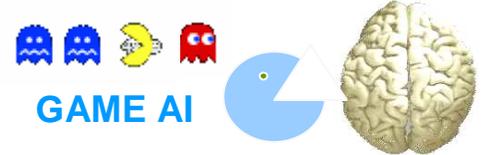
AIRIES '94 Workshop  
15 November 1994

**You're Not  
a Neural Net!!!**



**You're a  
Case-Based Reasoner!!!**

## TEMAS DE ESTUDO



### **Predicados Lógicos - PROLOG**

- **Conceitos Básicos**

**Predicados Lógicos** => pai(X, Y) - Define que X é pai de Y

**Fatos** => Asserções (conhecimentos a priori, crenças)

pai(carlos, pedro).

pai(pedro, joao).

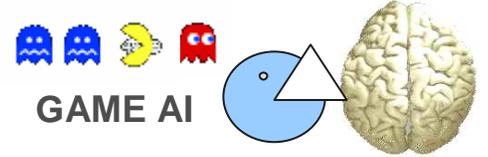
pai(joao, jose).

irmao(X,Y) :- pai(Z,X), pai(Z,Y).

avo(X,Y):- pai (X,Z), pai(Z,Y).

avo(X,Y):- pai (X,Z), mae(Z,Y).

## TEMAS DE ESTUDO: *SISTEMAS INTELIGENTES*

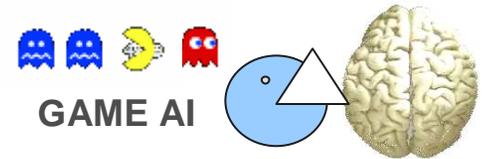


**ES** - *Expert Systems*

**RBS** - *Rule-Based Systems*

- **Conceitos Básicos**
- **Aquisição de Conhecimentos**
- **Representação do Conhecimento**
- **Incerteza**
  - *Certainty Factors (CF / Rule Confidence)*
  - *Fuzzy / Bayesian*
- **Exemplos de ESS (Expert System Shells): ES e CLIPS**

## SISTEMAS ESPECIALISTAS: *Conceitos Básicos*



### \* **Expert Systems** [Nikolopoulos, Cap. 1]

- Um sistema especialista é um programa projetado para modelar a habilidade de resolver problemas de um especialista.

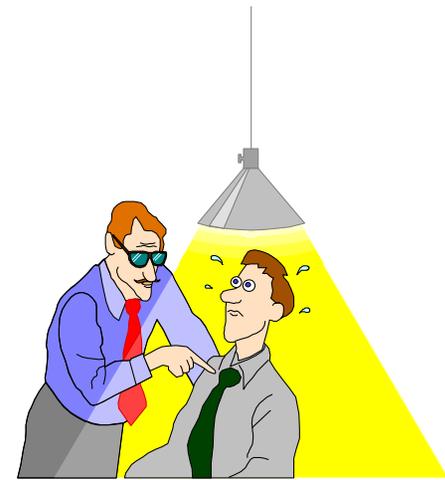
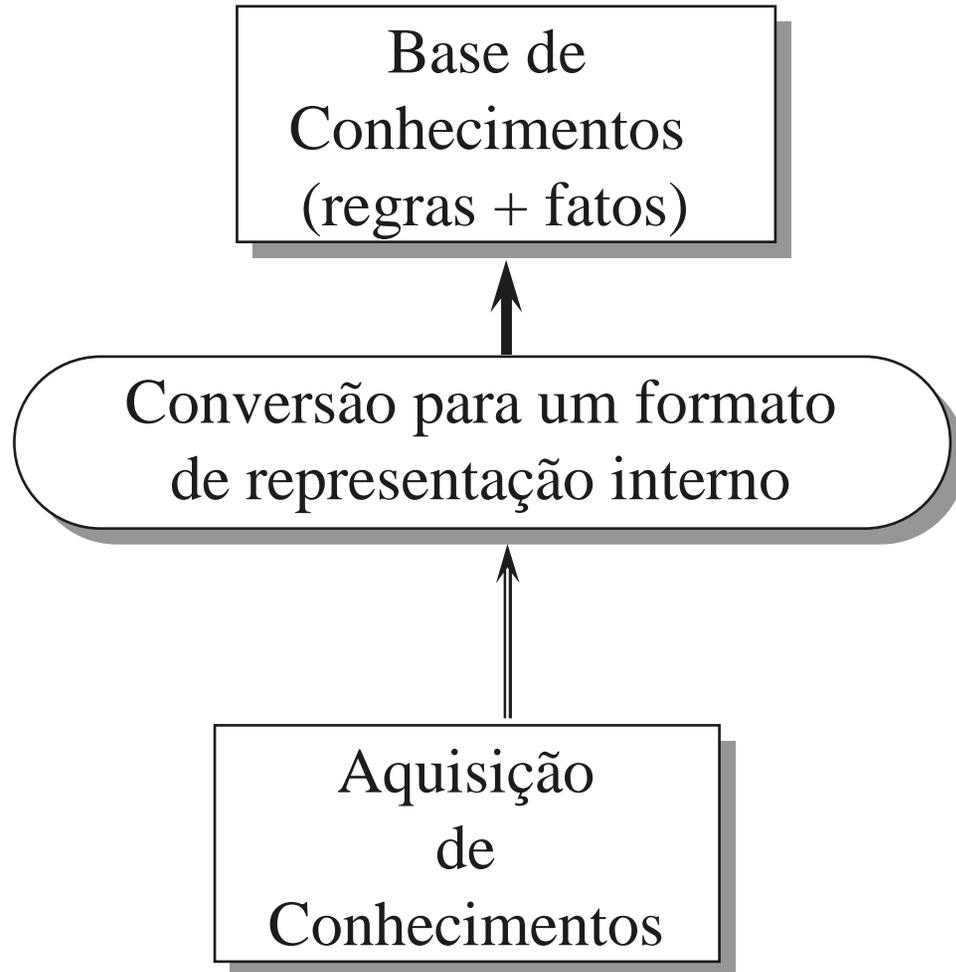
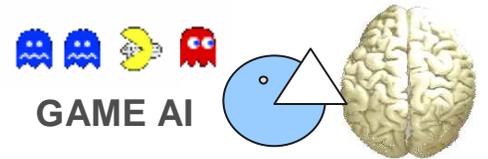
**Feigenbaum:** “An intelligent computer program that uses knowledge and inference procedures to solve problems that are difficult enough to require significant human expertise for their solution. The knowledge of an expert system consists of facts and heuristics.”

#### - **Componentes de um Sistema Especialista:**

- **Base de Conhecimento:** parte contendo o conhecimento do domínio, ou seja, as regras obtidas para o sistema;
- **Memória de Trabalho:** parte contendo os fatos sobre o problema que são descobertos, concluídos, em uma sessão de execução;
- **Máquina de Inferência:** processo que combina os fatos da memória com a base de conhecimento para chegar às conclusões sobre o problema.

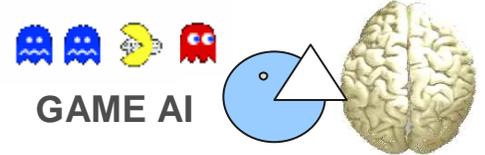
- **Sistemas Especialistas famosos: MYCIN, DENDRAL, PROSPECTOR**

# Aquisição de Conhecimentos



Explicitação

## Representação de Conhecimentos



### \* Rule-Based Systems (RBS)

Conjunto de regras no estilo *if-then* que são utilizadas para fazer inferências e decidir quais ações tomar

De certa forma, esse tipo de sistema imita a forma com que os humanos tendem a raciocinar sobre assuntos diversos usando conhecimento prévio e observação sobre o sistema

**IF - THEN Rules** - Sistema de dedução

**FACTS** - Verdades absolutas

**Asserts** - Suposições (statements) que não são necessariamente verdades absolutas

**Exemplos de Conhecimentos:**

- Regras:

**IF Temperatura é alta THEN Pressão é Alta**

**IF Pressão é Alta AND Receptivo é Frágil THEN Risco de Explosão**

**IF Temperatura maior que 100 graus THEN Abrir a válvula #1**

**IF <assertion> is True THEN <new\_assertion> => Rule-Based Deduction System**

**IF <assertion> is True THEN <add/delete, execute> => Rule-Based Reaction System**

- Fatos:

**Fact ( Temperatura Alta )**

**Fact ( Rex come Carne )**

**Fact ( Temperatura 120 )**

**Fact ( Rex possui Rabo )**

## Rule-Based Deduction Systems



**Definição de uma regra:**

**IF Antecedente  
THEN  
Consequente**

**IF assertion  
THEN  
new\_assertion**

**Ativação de uma regra:**

- Se todos os antecedentes satisfazem, a regra é ativada (fired) e então os consequentes são considerados como suposições válidas (new assertions)
- Coleção de assertions => Working memory
- Seleção de assertions => Search algorithm - Conflict Resolution (qual regra ativar primeiro)
- Agenda => Coleção de regras que estão prontas para serem ativadas

**Regras:**

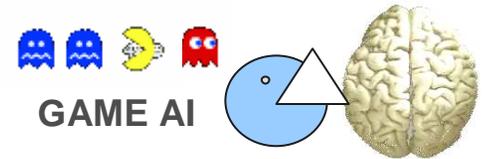
**R1 IF ?x tem cabelo  
THEN ?x é um mamífero**  
**R2 IF ?x produz leite  
THEN ?x é um mamífero**  
**R3 IF ?x tem penas  
THEN ?x é um pássaro**

**R4 IF ?x voa  
?x põem ovos  
THEN ?x é um pássaro**  
**R5 IF ?x é um mamífero  
?x come carne  
THEN ?x é um carnívoro**

**Fatos:**

**(F1 Rex tem cabelo)**  
**(F2 Rex come carne)**  
**(F3 Louro tem penas)**  
**(F4 Louro voa)**

## Mecanismo de Inferência: *Incerteza*



### *Certainty Factors - CF*

**IF**            **Pressure is high AND Temperature is high AND Escape-Valve is closed**  
**THEN**        **there is high evidence (0.90) that Recipient will explode**

### Conceitos: *Confidence = Medida de Crença em algo*

- Para cada regra/fato associamos um valor que reflita a certeza (confiança) desta regra ou fato
- Os valores de CF ficam na faixa de -1 à +1, sendo -1 indica que algo é definitivamente falso e +1 indica que algo é certamente verdadeiro (com 100% de certeza). Zero significa dúvida.
- Apesar da “associação” imediata com o conceito de valor probabilístico associado as regras, o CF não é uma representação formal de probabilidade. Sendo assim ao afirmar que uma regra tem um CF=0.7 isso não significa de modo algum que a sua negação deverá ter CF = 0.3 (não existe a imposição de obter uma soma de CFs relativas a uma regra/asserção igual a 1.0)

### Vantagens:

- Formalismo simples, fácil de entender, fácil de modelar, intuitivo

### Fatos:

A [CF = 0.8]  
C [CF = 0.9]  
D [CF = 0.7]  
E [CF = 0.5]

### Regras:

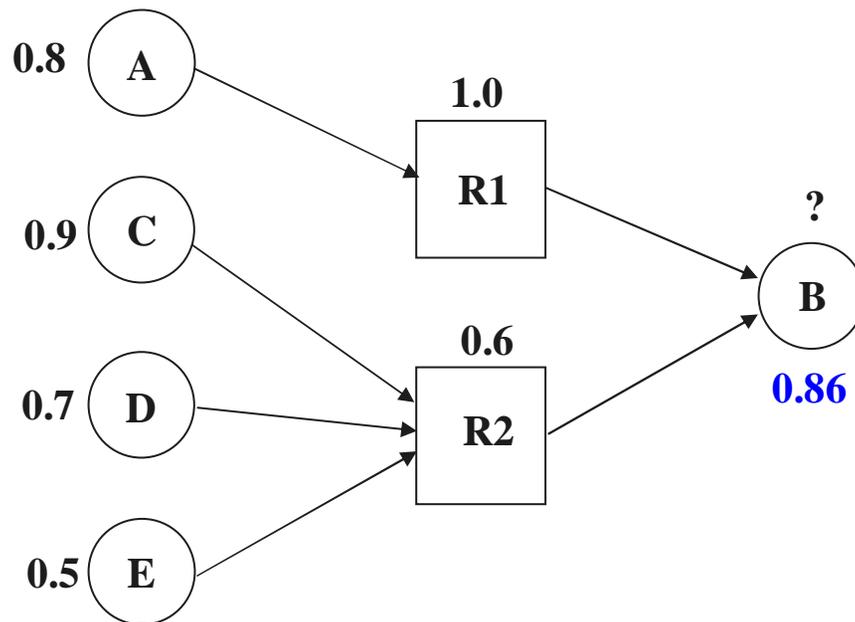
R1 IF A  
    THEN B with CF=1.0  
R2 IF C and D and E  
    THEN B with CF = 0.6

## Mecanismo de Inferência: *Certainty Factor / CF*



### Propagação de Incertezas:

| <i>Facts</i> | <i>Rules</i>         |
|--------------|----------------------|
| A [CF = 0.8] | R1 IF A              |
| C [CF = 0.9] | THEN B with CF=1.0   |
| D [CF = 0.7] | R2 IF C and D and E  |
| E [CF = 0.5] | THEN B with CF = 0.6 |



Via R1...

- Pegar o menor CF da esquerda da regra
  - Multiplicar pelo CF da própria regra
- CF de B via R1 =  $0.8 \times 1.0 = 0.8$

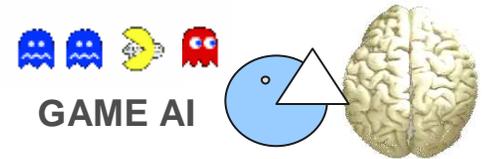
Via R2...

- Idem a R1
- CF de B via R2 =  $0.5 \times 0.6 = 0.3$

Combinando R1 e R2 em B...

- Ambos CF de R1 e R2 são positivos
- CF final de B =  $0.8 + 0.3 \times (1 - 0.8) = 0.86$   
 $= 0.3 + 0.8 \times (1 - 0.3) = 0.86$

## Mecanismo de Inferência: *Certainty Factor / CF*



### Propagação de Incertezas:

| <i>Facts</i> | <i>Rules</i>         |
|--------------|----------------------|
| A [CF = 0.8] | R1 IF A              |
| C [CF = 0.9] | THEN B with CF=1.0   |
| D [CF = 0.7] | R2 IF C and D and E  |
| E [CF = 0.5] | THEN B with CF = 0.6 |

\* **Combinando CFs:** Calculando  $CF_{new}$  supondo que temos  $CF1$  e  $CF2$

1. Se  $CF1$  e  $CF2$  são ambos positivos => Aumenta o CF final

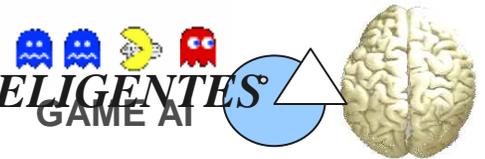
$$CF_{new} = CF1 + CF2 * (1 - CF1)$$

2. Se  $CF1$  e  $CF2$  são ambos negativos => Diminui ainda mais o CF final

$$CF_{new} = CF1 + CF2 * (1 + CF1)$$

3. Se  $CF1$  e  $CF2$  possuem sinais opostos => Um suporta e o outro vai contra...  
Fica entre  $CF1$  e  $CF2$

$$CF_{new} = (CF1 + CF2) / (1 - \text{Min}(|CF1|, |CF2|))$$



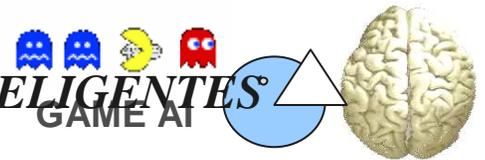
**TEMAS DE ESTUDO:** Uso da *INCERTEZA* nos *SISTEMAS INTELIGENTES*

*Fuzzy Sets*

*Fuzzy Logic / Lógica Nebulosa*

*Fuzzy Inference Systems -FIS*

- **Conceitos Básicos:**
  - > Lógica Booleana, Lógica Multi-Valorada, Lógica Fuzzy
- **Fuzzy Sets:** Membership Value, Membership Function
- **Representação Gráfica** da “Fuzzy Membership Function”
- **Variáveis Lingüísticas e Valores Lingüísticos**
- **Approximate Reasoning / Fuzzy inference:**
  - > Operadores - E / Interseção, OU / União, NOT / Complemento, Igualdade
  - > Métodos de Combinação e Propagação do Valor da Confiança (Confidence)
- **Métodos de “Defuzzification”**
  
- Temas de Pesquisa relacionados aos Sistemas de Lógica Nebulosa (Fuzzy)



**TEMAS DE ESTUDO: Uso da *INCERTEZA* nos *SISTEMAS INTELIGENTES***

Otimista diz: copo meio cheio, pessimista diz: meio vazio, fuzzy diz: ...

Usamos, no cotidiano, conceitos subjetivos para classificar ou considerar certas situações tais como :

- Siga em frente "alguns metros" .
- O dia está "parcialmente" nublado.
- Preciso perder "alguns" quilos para ficar "bem".
- Estamos com uma moeda "estável".

ou ainda :

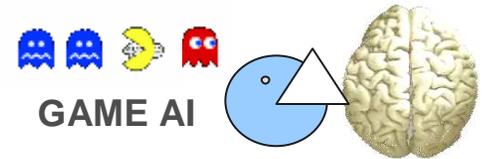
- A classificação de certos objetos como "largo", "sujo",..
- A classificação de pessoas pela idade tal como "velho", "jovem",..
- A descrição de características humanas como "saudável", "alto", ..

O conceito "fuzzy" pode ser entendido como uma situação onde não podemos responder simplesmente "Sim" ou "Não". Mesmo conhecendo as informações necessárias sobre a situação, dizer algo entre "sim" e "não" como por exemplo "talvez", "quase", ....se torna mais apropriado.

Considere, por exemplo, informações como "homens altos" , "dias quentes" ou "vento forte". Nada existe que determine exatamente qual a "altura" , "temperatura" ou "velocidade" que podemos considerar como limites para tais informações.

Se considerarmos como alto todos os homens com mais de 1,90m, então um homem com 1,88m não seria "alto" e sim "quase alto".

# FUZZY LOGIC / LÓGICA NEBULOSA: Conceitos Básicos

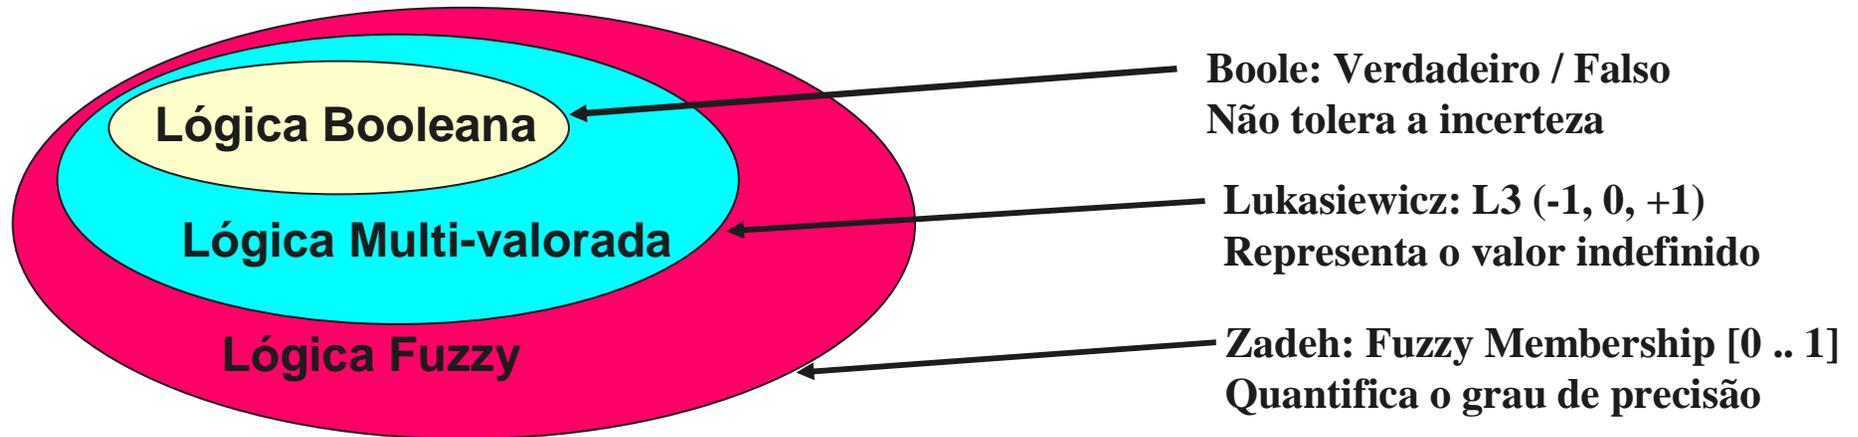


*Histórico:* Lofti Zadeh 1968 .. 1973

*Logic* = Science of the normative formal principles of reasoning

*Fuzzy Logic* = Formal principles of approximative reasoning

Representação do Conhecimento Especialista:



*Fuzzy Logic:* Usada para modelar processos de decisão

Usada para controle de máquinas e processos

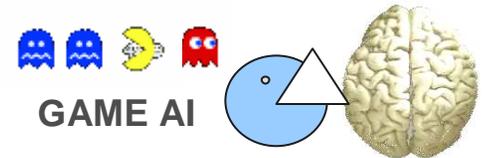
Descrever / Quantificar / Medir => Raciocínio Humano => L.N.

*Fuzzyness* = Defined as ... “a type of imprecision which is associated with...

classes in which there is no sharp transition from membership to non-membership”

( 0 ) não é <====> é ( 1 )

## FUZZY LOGIC / LÓGICA NEBULOSA: Conceitos Básicos



*Nebulosidade...*



*Nebulosidade não é Probabilidade [Eberhart]*

**Probabilidade:** Previsão futura, após ocorrido o fato, este deixa de ser uma probabilidade.

“Close World Model” = Modelo ser bem definido. Soma =  $P(X) + P(\neg X) = 1.0$

Uso da frequência estatística como modelo para previsão (Bayes).

Usualmente as variáveis tem que ser independentes.

“It doesn’t imply that probability is useless... Probability is appropriate for randomly-governed occurrences”

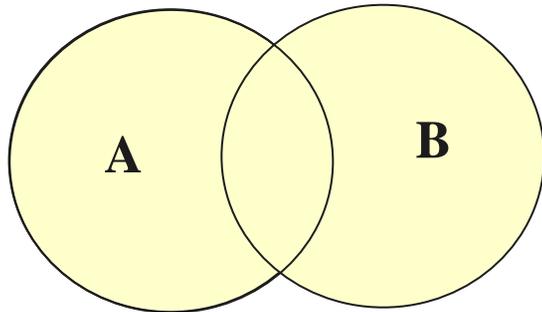
**Fuzzyness:** Medida de alguma coisa. Fato ocorrida ou previsão futura.

- Exemplos: O grau de força da chuva é independente da noção de previsão se vai chover...  
Pchuva(0.2) = Indica uma probabilidade de 20% de ocorrer chuva e 80% de não chover!  
Regra Fuzzy = Deve chover, com uma certeza de 0.2, uma chuva fraca (nível de chuva 0.1)



## FUZZY SETS:

- Definindo um Conjunto Nebuloso...

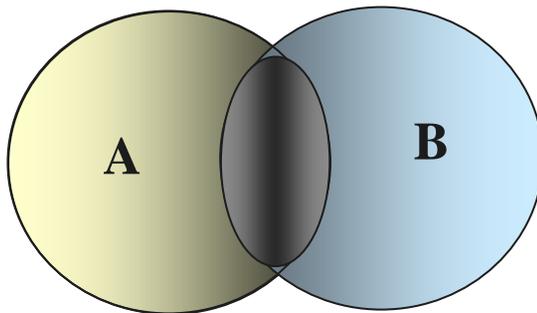


*Diagrama de Venn:*

**Conjunto A, Conjunto B**

**Operações:  $A \cup B$ ,  $A \cap B$ ,  $\neg A$ ,  $\neg B$**

**Fronteiras: bem definidas, inflexíveis!**



*Fuzzy Set:*

**Membership Value / Valor de Pertinência**

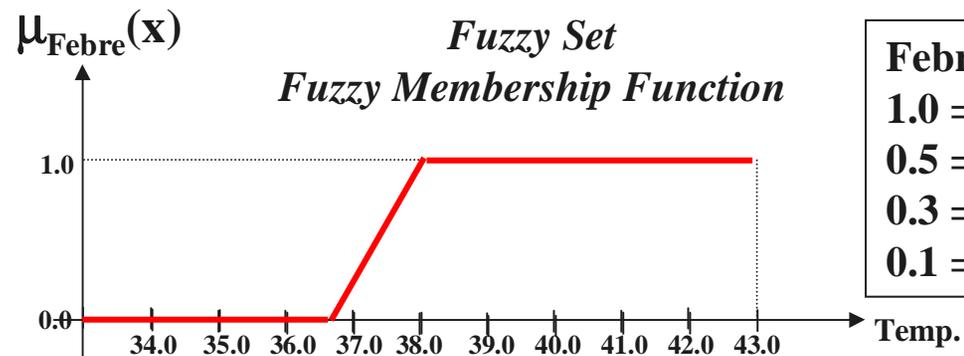
$$\mu_A(X) = m \quad \text{onde} \quad 0 \leq m \leq 1$$

**$m = 1.0$  se  $X$  pertence ao conjunto A**

**Exemplo:**

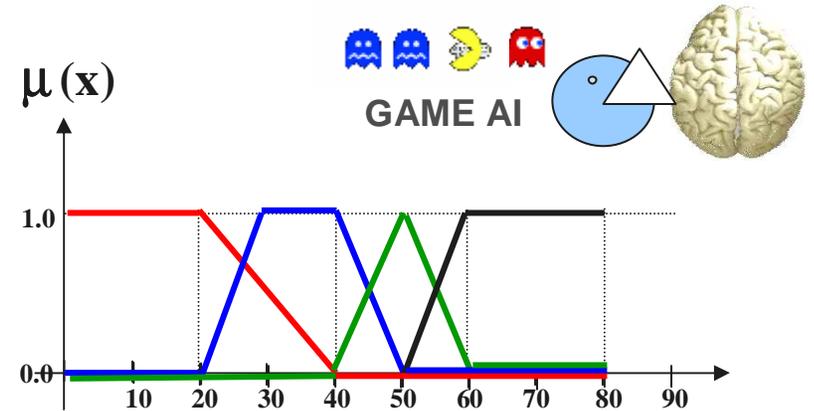
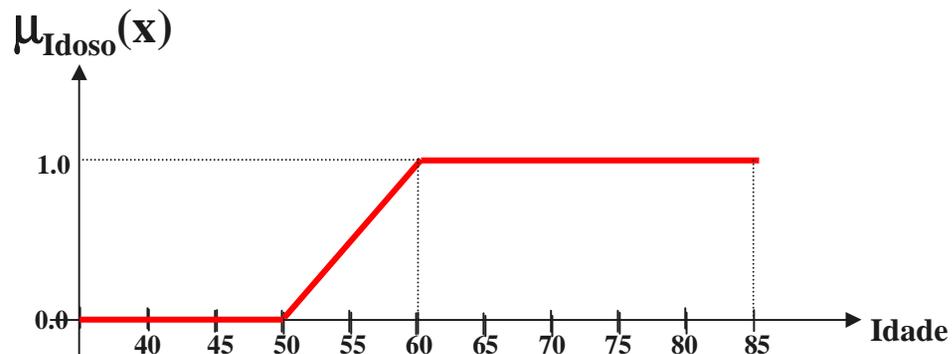
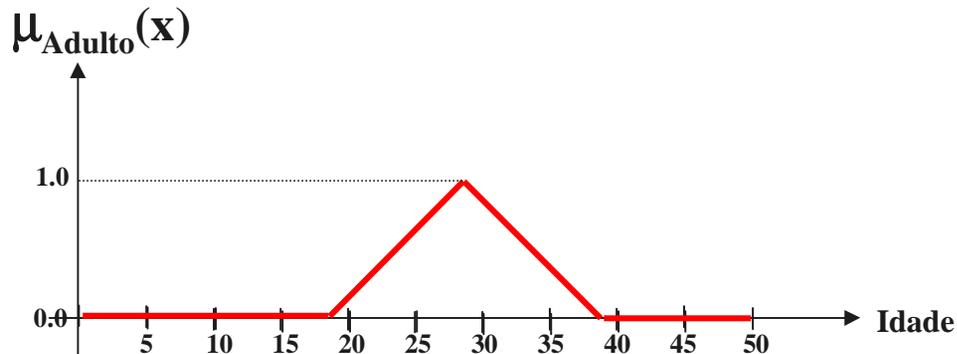
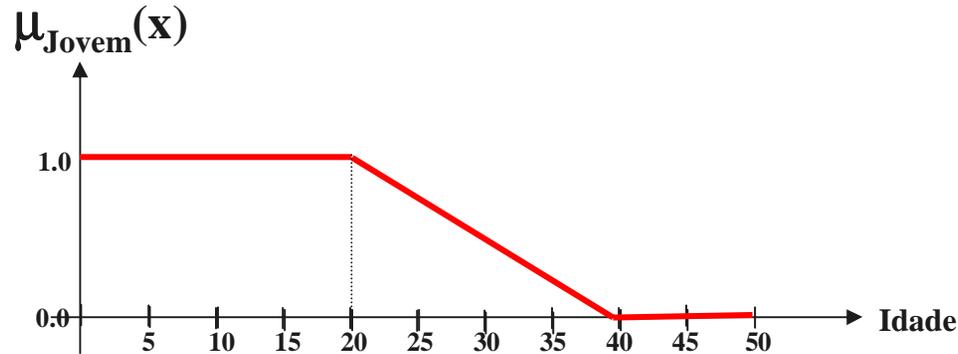
$$\mu_{\text{alto}}(\text{Objeto}) = 1.0 \dots 0.7 \dots 0.5 \dots 0.3 \dots 0.2$$

- Membership Value
- Membership Function



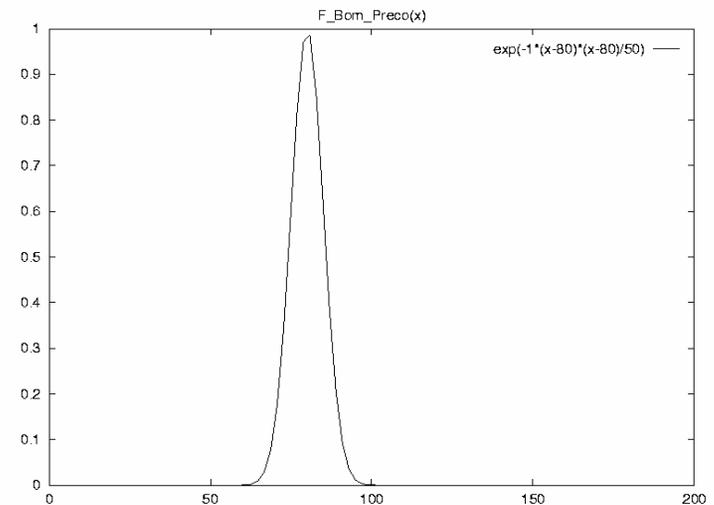
**Febre:**  
**1.0 = Muito Alta**  
**0.5 = Alta**  
**0.3 = Pouco Alta**  
**0.1 = Baixa**

# FUZZY SETS: *Membership Function* Representação Gráfica



## Membership Function:

- A função que define o conjunto nebuloso pode ser linear, não linear, normal, gaussiana, ascendente, descendente, forma de "S" (sigmoid), normalizada, definida por pontos, ...



## FUZZY SETS: Variáveis Lingüísticas - Valores Lingüísticos



**Linguistic Variables = “A variable whose value are words or sentences in a natural or artificial language”**

- Uma variável lingüística é uma variável que pode assumir um valor lingüístico
- Um valor lingüístico é um par VL(adjetivo, fuzzy\_set)

Exemplos: VL(jovem,  $\mu_{\text{Jovem}}$ )  
VL(adulto,  $\mu_{\text{Adulto}}$ )  
Associa nomes e conj. de valores

Adjetivos: um pouco quente  
muito quente  
extremamente quente

\* **Categorias de variáveis lingüísticas:**

- **Quantidade / Quantification terms :** all, most, many, about half, few, no
- **Frequência / Usuality terms :** always, frequently, often, occasionally, seldom, never
- **Probabilidade / Likelihood terms :** certain, likely, possible, uncertain, unlikely, certainly not

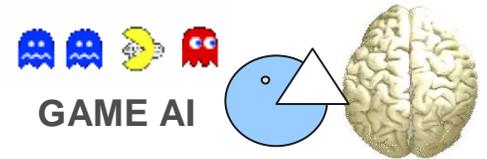
*Linguagem Natural / Senso Comum:* homem alto, homem baixo, homem muito alto

> **Possibilidade de fazer um mapeamento entre uma representação escrita e o seu significado numérico!**

---

*Senso Comum* => “Crenças sobrevivem justamente porque independem da estatística” [L.F.V. 06/08/00]  
;^)

## FUZZY SETS: Regras Fuzzy



*Fuzzy Rules => Expert System / Rule Based System:*

**IF temperature is low THEN oil viscosity is high**

**IF temperature is high AND pressure is normal THEN amount to add is high**

**IF input temperature > 70°C THEN input water is too hot**

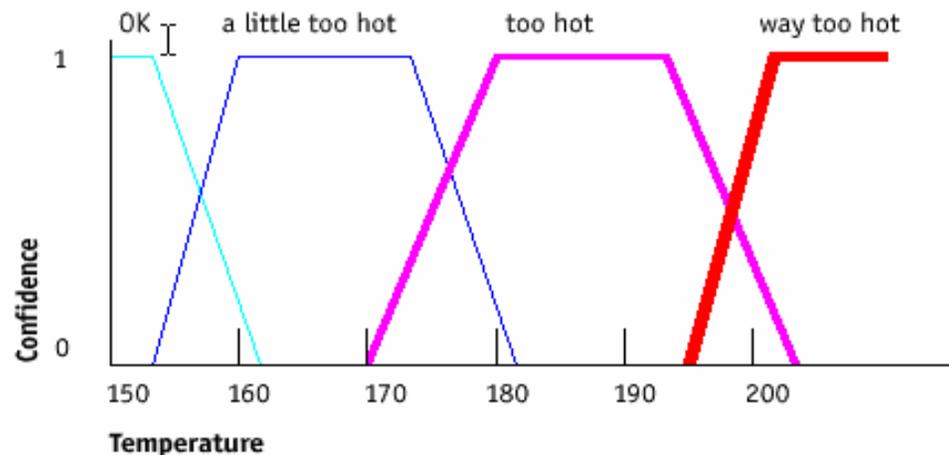
**IF input water is too hot THEN mix cold water with the input stream**

**IF input water is too hot THEN amount of cold water to add to the input is a medium**

**IF input water is a little too hot THEN amount of cold water to add to the input is a little**

**IF input water is a way too hot THEN amount of cold water to add to the input is a lot**

**IF input water is OK THEN amount of cold water to add to the input is none**



**Temp => OK [0..160]**

**Temp => little too hot [150..180]**

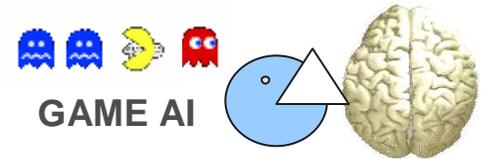
**Temp => too hot [170..210]**

**Temp => way too hot [195..End]**

**Too Hot : Fuzzy Set Definition**

**170=0 // 180=1 // 195=1 // 205=0**

## FUZZY SETS: Regras Fuzzy



Definição do conjunto

Considere que a variável  $V$  seja a temperatura do ar em algum lugar do planeta, e a função de pertinência apresentada na Tabela represente, em um dado contexto, o predicado “*alta*”.

$\rho: V \text{ é } F$

| Temperatura (V) | Grau de Pertinência (F) |
|-----------------|-------------------------|
| 0               | 0                       |
| 40              | 0                       |
| 80              | 0.4                     |
| 85              | 0.75                    |
| 90              | 0.90                    |
| 100             | 1                       |
| 110             | 1                       |

## FUZZY LOGIC: Fuzzy Inference



\* *Raciocínio Nebuloso - Approximate Reasoning:*

- **Operadores Fuzzy:** As operações com conjuntos fuzzy muitas vezes podem ser realizadas de diferentes modos.

• **E / Interseção**

$$\mu_{A \cap B}(x) = \text{Min} ( \mu_A(x), \mu_B(x) )$$

• **OU / União**

$$\mu_{A \cup B}(x) = \text{Max} ( \mu_A(x), \mu_B(x) )$$

---

---

• **NEGAÇÃO / Complemento**

$$\mu_{\text{Not-A}}(x) = 1 - \mu_A(x)$$

• **Igualdade, Conjunto Contido, Implicação, Combinação Fuzzy...**

## FUZZY LOGIC: Fuzzy Inference



### - Atribuição da confiança em uma questão - IF

**Se a questão é respondida diretamente pelo usuário ou o valor é setado externamente**

**Então Confidence = 1.0**

- **Se a questão é definida por uma função de pertinência fuzzy e uma variável associada a esta**

**Então Confidence =  $\mu_A(x)$**

- **Se a questão é define uma escolha na parte THEN da regra**

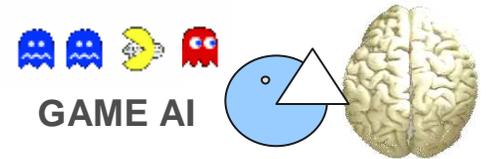
**Então Confidence = propaga a parte IF da regra combinada com Confidence da parte THEN**

**Exemplo: Supondo *Red* =0.8, *Blue* = 0.6 e a regra *IF color is red OR color is blue ...***

$$\text{Combined\_Conf} = 0.0 + 0.8 * (1-0) = 0.8$$

$$\text{Combined\_Conf} = 0.8 + 0.6*(1-0.8) = 0.92$$

## FUZZY LOGIC: Fuzzy Inference



*\* Exemplo:*

**IF**  $[X] > [Y]$  and The color is red or blue or Temperature is high or Today is Monday and  $[Z] > 0.5$

*Supondo:* Red = 0.8 / Blue = 0.6 /  $[X] = 0.7$  /  $[Y] = 0.8$  / Temp High = 0.85 / Today is Friday /  $[Z] = 0.9$

*Default:*

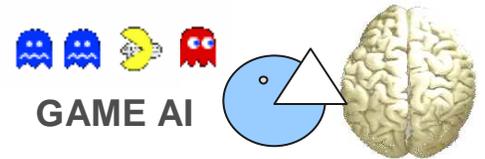
The color is red or blue OR Temperature is high OR Today is Monday  $\Rightarrow 0.988 (0.92 / 0.85 / 0)$

$[X] > [Y] = 0.7 * 0.8 = 0.56$

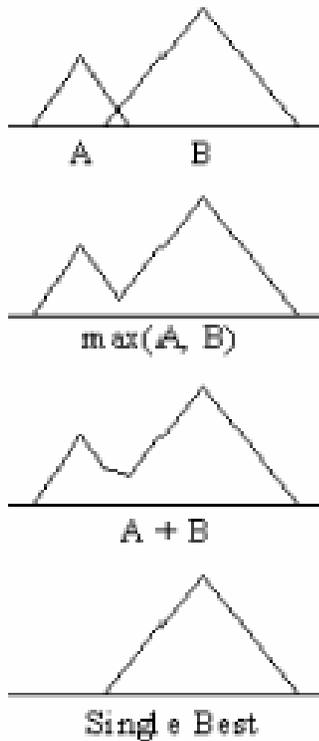
$[Z] = 0.9$

**FINAL =  $0.988 * 0.56 * 0.9 = 0.498$**

# FUZZY LOGIC: Fuzzy Inference



- Combinação de conseqüentes => Cálculo da Combinação das Regras / Escalar - THEN



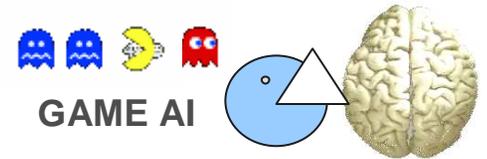
Regras com Combinação de conseqüentes:

**IF A is Large THEN C is Small**

**IF B is Small THEN C is Small**

Figure 7. Consequent Combination

## FUZZY LOGIC: Defuzzification



\* A defuzzyficação consiste em realizar um mapeamento do espaço do conjunto fuzzy para um valor preciso (*crisp value* = valor numérico).

O processo de defuzzyficação pode ser feito segundo diferentes métodos: [Cechin]

- Máximo
- Média dos Máximos (MOM)
- Média local dos Máximos
- Centro de Gravidade (Centroide)
- Centro da Área
- Centro da Média

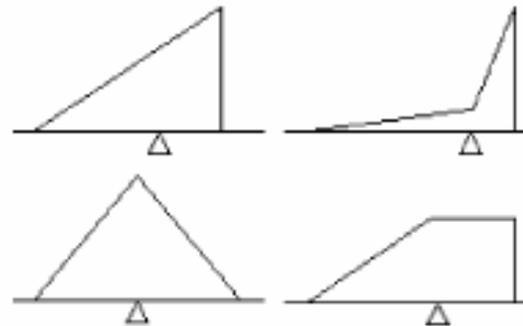


Figure 8. Centroids

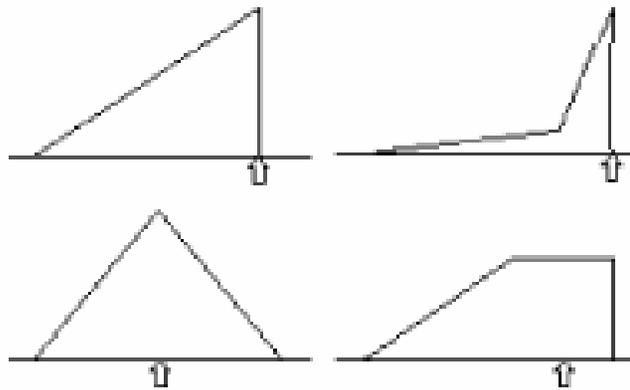


Figure 9. Midpoint of Maximum

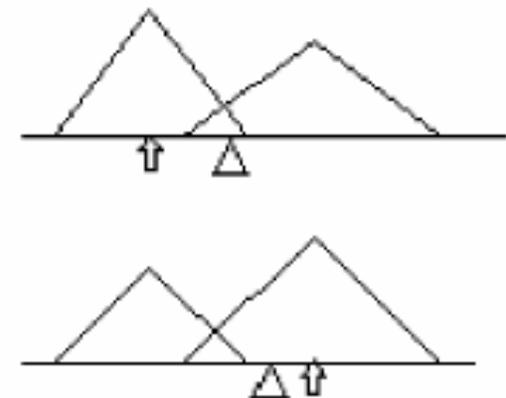
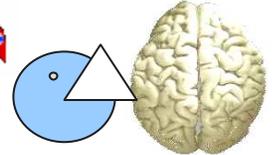


Figure 10. Max-height vs. Centroid

## TEMAS DE PESQUISA SOBRE SISTEMAS ESPECIALISTAS:



GAME AI



### \* PAPERS / DOCUMENTAÇÃO:

- **FAQ:** <http://www.faqs.org/faqs/fuzzy-logic/>  
<http://www.faqs.org/faqs/fuzzy-logic/part1/>  
<http://www.cs.cmu.edu/Web/Groups/AI/html/faqs/ai/fuzzy/part1/faq.html>
- **Computational Intelligence Tools / Russ Eberhart, Pat Simpson, Roy Dobbins**
- **Expert Systems / Chris Nikolopoulos**
- **The Extraction of Fuzzy Rules form Neural Networks / Adelmo Cechin**
- **Web: HyperLogic - Cubicalc / MultiLogic - ExSys**

### \* ASSOCIAÇÃO:

Association for Uncertainty in Artificial Intelligence - <http://www.auai.org/>

### \* TEMAS IMPORTANTES:

- **Definição dos fuzzy sets / fuzzy membership function (ajuste fino)**
- **Manipulação de regras fuzzy: Inferência Fuzzy, Defuzzification**
- **Aprendizado de regras fuzzy**
- **Integração da lógica fuzzy aos sistemas convencionais**