

# GT-JeDi - Curso de Desenv. de Jogos

## IA para Jogos



Fernando Osório

2006/2 - A07

### Representação e Manipulação de Conhecimentos



- I.A. Simbólica
- I.A. Conexionista (sub-simbólica)

#### Inteligência Artificial:

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

## Representação e Manipulação de Conhecimentos



- I.A. Simbólica
- I.A. Conexionista (sub-simbólica)

### Inteligência Artificial:

- Busca em Espaço de Estados
- Heurísticas
- Representação e Manipulação
- Analogia: CBR - Case Based Reasoning
- Inferência: Sistemas Especialistas
- Incerteza e Possibilidade: Certainty Factors
- Probabilidade: Bayesian Belief Networks
- Linguagens: Lógica e Resolução
- 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

## Representação e Manipulação de Conhecimentos



- I.A. Simbólica

- CASOS - Case Based Reasoning (CBR)
- PREDICADOS LÓGICOS - Logic Systems / PROLOG
- REGRAS - Rule Based Systems / Knowledge Based Systems / Expert Systems

### • SISTEMAS ESPECIALISTAS:

Fatos + Regras + Motor de Inferência

## 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”

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

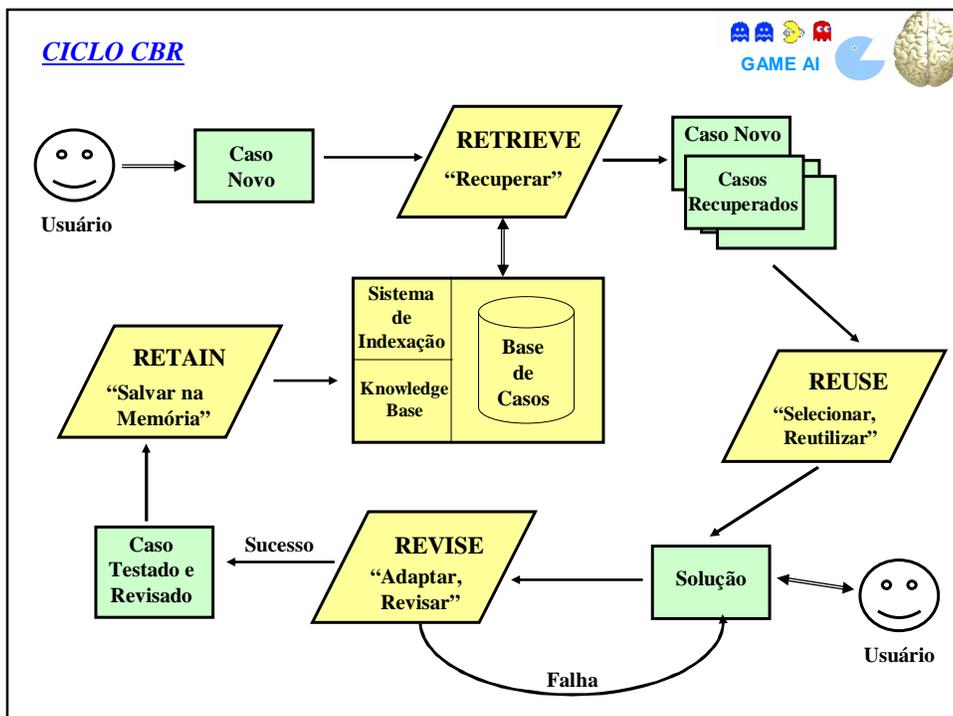
#### 5. Aceite pelo usuário:

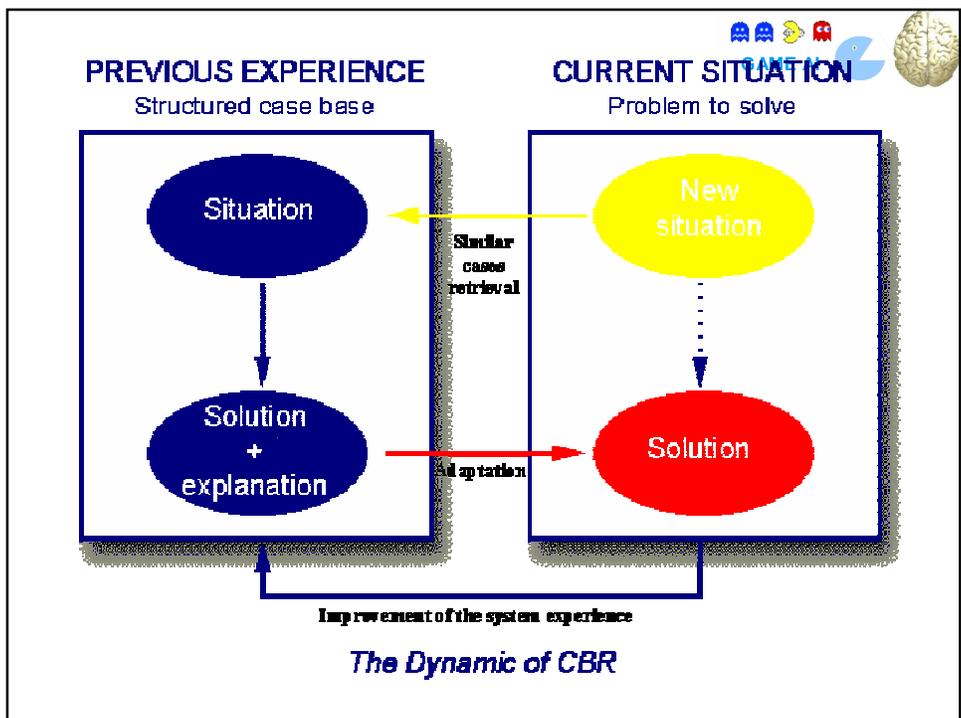
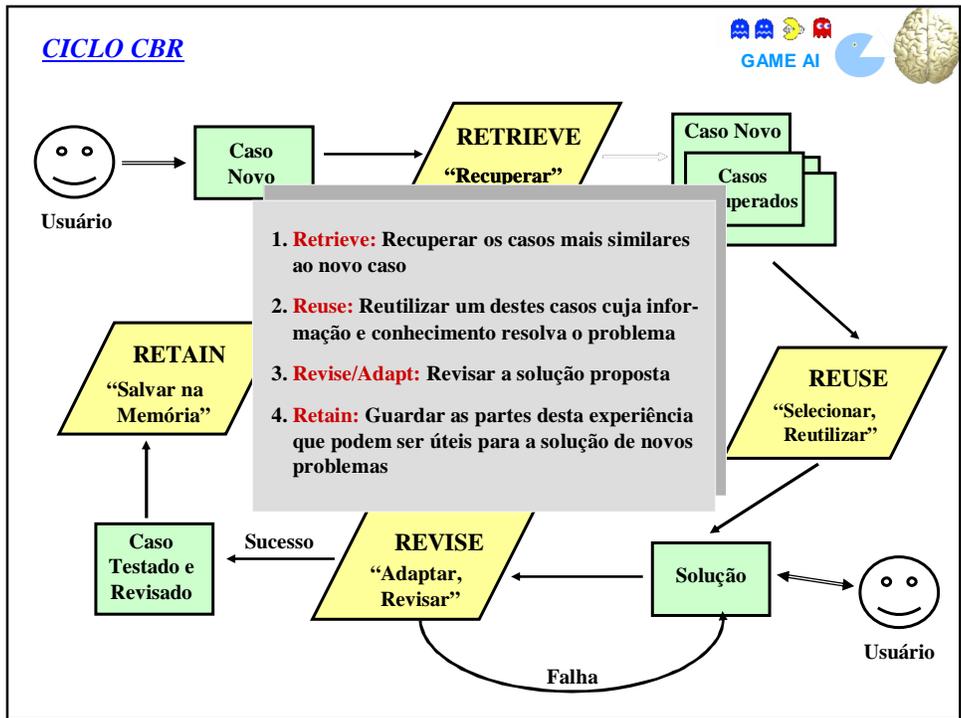
- ⊙ Fácil de convencer os usuários em relação a...  
Inserção de conhecimentos / Consulta do Sistema / Explicação das Respostas

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

- ⊗ Casos não estruturados - Alto Nível / Linguagem Natural

## CICLO CBR





## 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)

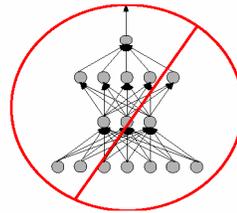
### Case-Based Reasoning

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!!!**

David W. Aha  
Navy Center  
Naval Research Laboratory

Page 2427

## 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
- Inferência:
  - *Forward Chaining*
  - *Backward Chaining*
  - *Rete Algorithm*
- Incerteza
  - *Certainty Factors (CF / Rule Confidence)*
  - *Fuzzy / Bayesian*
- Exemplos de ESS (Expert System Shells): ES e CLIPS
  
- Temas de Pesquisa relacionados aos Sistemas Especialistas



## SISTEMAS ESPECIALISTAS: *Conceitos Básicos*

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

- Sistemas especialistas usam conhecimento sobre um domínio específico para resolver problemas ligados a este domínio de aplicação.

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:

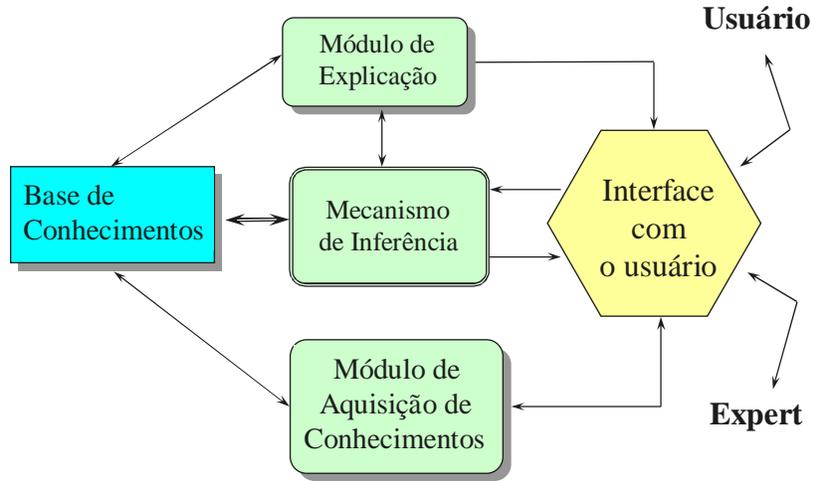
- Base de Conhecimentos
- Mecanismo de Inferência
- Módulo de Aquisição de Conhecimentos
- Módulo de Explicação das Respostas
- Interface com o Usuário

- Classificação dos Sistemas Especialistas:

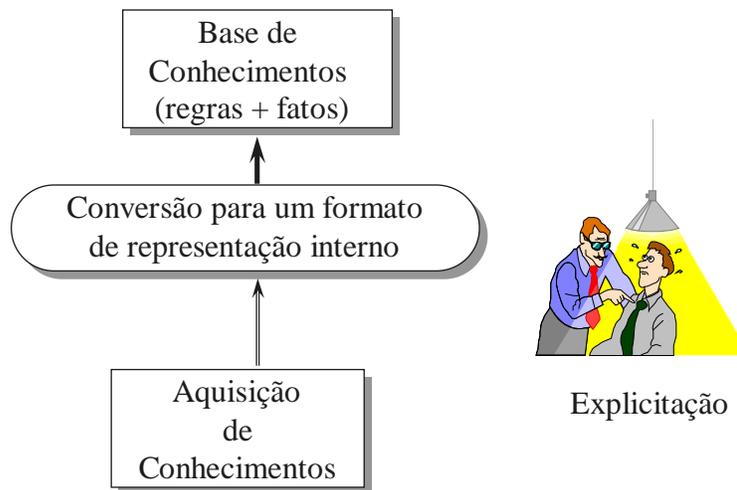
- SE de Primeira Geração
- SE de Segunda Geração

- Sistemas Especialistas famosos: MYCIN, DENDRAL, PROSPECTOR

Componentes de um Sistema Especialista



Aquisição de Conhecimentos



\* Problema: *Knowledge Acquisition Bottleneck* / *Symbolic x Sub-Symbolic*

## Representação de Conhecimentos



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

Sistemas Especialistas representam conhecimentos através Regras e Fatos

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 )

## Representação de Conhecimentos



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

Sistemas Especialistas representam conhecimentos através Regras e Fatos

IF - THEN Rules - Sistema de dedução  
FACTS - Verdades absolutas

#### Métodos de Raciocínio (Clássicos):

**ANALOGIA:** Estabelecer uma relação de semelhança de uma coisa com outra.  
*CBR* Baseada na semelhança.

**DEDUÇÃO:** Consequência tirada de um raciocínio.  
*RBS* Encadeamento de proposições conforme regras definidas, constituídas por axiomas e regras de inferência (Se isso Então aquilo).  
Baseada em conclusões e inferências.

**INDUÇÃO:** Forma de raciocínio pela qual é possível, a partir de determinadas observações,  
*ML* formular as leis gerais que balizam certos fatos singulares.

**RACIOCÍNIO =>** Buscar a verdade com o auxílio da razão

## Representação de Conhecimentos



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

Sistemas Especialistas representam conhecimentos através Regras e Fatos

IF - THEN Rules - Sistema de dedução

FACTS - Verdades absolutas

#### Métodos de Raciocínio (Clássicos):

**ANALOGIA:** Estabelecer uma relação de semelhança de uma coisa com outra.  
Baseada na semelhança.

*CBR*

**DEDUÇÃO:** Conseqüência tirada de um raciocínio.

*RBS*

Encadeamento de proposições conforme regras definidas, constituídas por axiomas e regras de inferência (Se isso Então aquilo).  
Baseada em conclusões e inferências.

**INDUÇÃO:** Forma de raciocínio pela qual é possível, a partir de fatos específicos, formular as leis gerais que balizam certos fatos.

*ML*

**RACIOCÍNIO =>** Buscar a verdade com o auxílio da razão

#### Outras Palavras-Chave:

- Common Sense
- Beliefs
- Default Reasoning
- Uncertainty
- Redes Semânticas/Frames

## Representação de Conhecimentos



### \* Rule-Based Systems (RBS) - Regras de Produção

Sistemas Especialistas representam conhecimentos através Regras e Fatos

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



GAME AI

Definição de uma regra:

Antecedente (LHS)  
=>  
Consequente (RHS)

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



GAME AI

Forward Chaining: from Assertions  
Backward Chaining: from Hypotheses  
Otimizando.... Rete Algorithm

**FORWARD CHAINING:**

Rex tem cabelo (F1) => Rex é um mamífero (R1) => Rex é carnívoro  
Rex come carne (F1)

Forward Inference Net

**BACKWARD CHAINING:**

Rex é carnívoro? <= (R5)  
Rex come carne? (Perguntar)  
Rex é um mamífero? <= (R2)  
Rex produz leite? (P: Sem resposta)  
(R1)  
Rex tem cabelo? (Perguntar) <= Confirmado

**QUESTÃO:** Qual tipo de mecanismo de inferência utilizar?

- Depende do Fan In / Fan Out
- O problema pode determinar um tipo preferencial (iniciar: assertions/hypotheses ?)

## Mecanismo de Inferência



### RETE ALGORITHM

#### Regras:

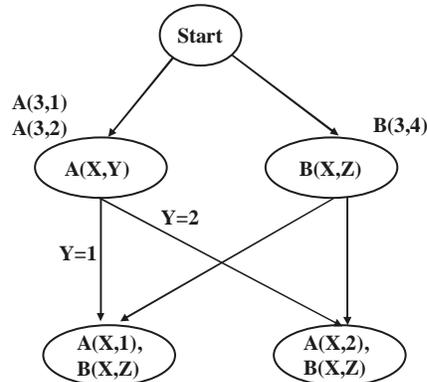
IF A(X,1) and B(X,Z) THEN G1 (X,Z)  
IF A(X,2) and B(X,Z) THEN G2(X,Z)

#### Fatos

A(3,1)  
A(3,2)  
B(3,4)

#### Working Memory:

Direciona asserções de acordo com o grafo. Evita busca exaustiva.



- Excesso de computação se tivermos que testar todos os possíveis “matches” das regras que constam na memória de trabalho.

## Mecanismo de Inferência: Incerteza



### Certainty Factors - CF

#### Rule Confidence

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



**Conceitos:**

h = Hipótese            P(h) => Probabilidade da hipótese 'h' se verificar  
 e = Evidência           P(h/e) => Probabilidade da hipótese 'h' se verificar dada a evidência 'e'

$$CF(h, e) = \frac{MB(h/e) - MD(h/e)}{1 - \min[MB(h/e), MD(h/e)]} \quad CF \Rightarrow [-1 .. +1]$$

MB(h/e) = Medida de maior crença que 'h' é verdadeiro, dado que 'e' é verdadeiro (Measure of Belief)  
 MD(h/e) = Medida de maior descrença que 'h' é verdadeiro, dado que 'e' é verdadeiro (Disbelief)

$$MB(h/e) = \begin{cases} 1 & \text{se } P(h) = 1 \\ \{ \max[P(h/e), P(h)] - P(h) \} / [1 - P(h)] & \text{caso contrário} \end{cases}$$

$$MD(h/e) = \begin{cases} 1 & \text{se } P(h) = 0 \\ \{ P(h) - \min[P(h/e), P(h)] \} / P(h) & \text{caso contrário} \end{cases}$$

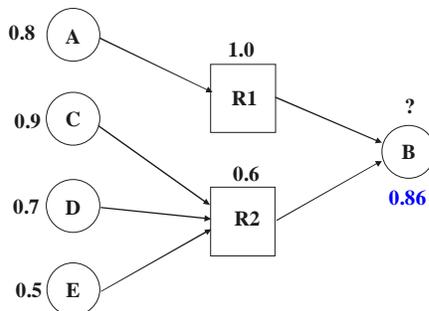
Sendo assim... Se a evidência 'e' suporta a hipótese 'h' então P(h/e) > P(h), e então MB é positivo  
 Se P(h/e) < P(h) então MD é positivo / Se P(h/e) = P(h) então MB=MD=0 !

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 x 1.0 = 0.8

Via R2...

- Idem a R1
- CF de B via R2 = 0.5 x 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 x (1 - 0.8) = 0.86
- = 0.3 + 0.8 x (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<sub>new</sub> 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

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

MYCIN



- > What is the patient's name?  
John Doe.
  - > Male or Female?  
Male.
  - > Age?  
He is 55.
  - > Have you obtained positive cultures indicating general type?  
Yes.
  - > What type of infection is it?  
Primary bacteremia.
  - > When did symptoms first appear?  
May 5.
  - > Let's call the most recent positive culture C1. From what site was C1 taken?  
From the blood.
  - > When?  
May 9.
  - > Let's call the first significant organism from this culture U1. Do you know the identity of U1?  
No.
  - > Is U1 a rod or a coccus or something else?  
Rod.
  - > What is the gram stain of U1?  
Gram-negative.
  - > Have there been positive cultures from sites that are not associated with the infections about which you are seeking advice?  
No.
- > ...

## MYCIN



### Diagnosis...

> My recommendations will be based on the opinion that the identity of U1 may be:

1. Pseudomonas-aeruginosa
2. Klebsiella-pneumoniae
3. E. coli
4. Bacteroides-fragilis
5. Enterobacter
6. Proteus-nommirabilis

### Some more questions...

> On a scale of 0 to 4, where higher numbers indicate greater severity, how would you rate the patient's degree of sickness?

3.

> Does the patient have a clinically significant allergic reaction to any antimicrobial agent?

No.

> How much does the patient weigh?

70 kg.

### First recommendation...

> My first recommendation is as follow: to cover for items 1,2,3,5 and 6, give gentamycin using a dose of 119 mg (1,7 mg/kg) q8h IV [or IM] for 10 days. Modify dose in renal failure. Also, to cover for item 4, give clindamycin using a dose of 595 mg (8.5 mg/kg) qh6 IV [or IM] for 14 days. If diarrhea or other gastrointestinal symptoms develop, check for pseudomembranous colitis.

## MYCIN



*Mycin - Buchanan & Shortliffe 76*

*Emycin - Expert System Shell*

### Typical Rule...

M88    IF        ?x type is primary bacteremia  
                 the suspected entry point of ?x is the gastrointestinal tract  
                 the site of the culture of ?x is one of the sterile sites  
         THEN    there is evidence that ?x is bacteroides

### Using Certainty Factors (CF)...

X111    IF        the stain of the organism is grain positive  
                 the morphology of the organism is coccus  
                 the growth conformation of the organism is chains  
         THEN    there is suggestive evidence (0.70)  
                 that the identity of the organism is streptococcus

*Inferência... Backward Chaining*

*Explicação... Trace of the inference steps*

## EXEMPLOS DE “EXPERT SYSTEM SHELLS”:



\* SISTEMAS FAMOSOS / DISPONÍVEIS:

- NASA / CLIPS - C Language Integrated Production System (Disponível)  
<http://www.ghg.net/clips/CLIPS.html>  
<http://www.cs.cmu.edu/afs/cs/project/ai-repository/ai/areas/expert/systems/clips/0.htm>  
<http://web.ukonline.co.uk/julian.smart/wxclips/> (WxClips - Linux/Win)  
[http://ai.iit.nrc.ca/IR\\_public/fuzzy/fuzzyClips/fuzzyCLIPSIndex.html](http://ai.iit.nrc.ca/IR_public/fuzzy/fuzzyClips/fuzzyCLIPSIndex.html) (FuzzyClips)  
<http://herzberg.ca.sandia.gov/jess/> (JESS - Java)  
<http://www.haley.com/> (Eclipse)
- MIT AI Repository - Expert Systems  
<http://www.cs.cmu.edu/afs/cs/project/ai-repository/ai/areas/expert/systems/0.html>
- Summers / ES (Disponível)  
ES Software - Educacional - MIT AI Repository
- OPS5 (Disponível)
- Attar / XperRule (Disponível)
- LPA / Flex (Documentação)
- Huggin / Huggin (Disponível - HugginLite / Solaris)
- MDBS / Guru (Documentação)
- Cubicalc, MSBN, Netica, ... [Fuzzy, Bayes Net]
- ExSINTA

## 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”**
- **Controle Fuzzy:** Regras de Mandami, Regras de Sugeno
- Exemplos de FIS (Fuzzy Inference Systems):  
ES (?), FuzzyCLIPS, Cubicalc /HyperLogic, ExSys / MultiLogic
- Temas de Pesquisa relacionados aos Sistemas de Lógica Nebulosa (Fuzzy)

**FUZZY LOGIC / LÓGICA NEBULOSA: Conceitos Básicos**

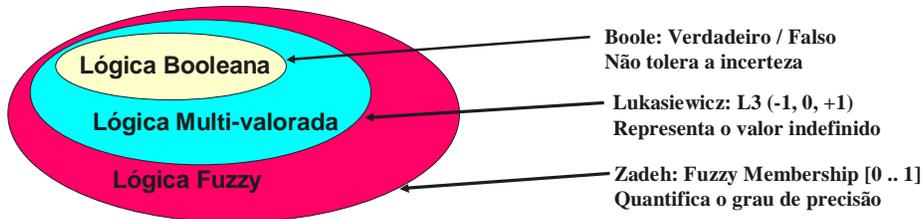


**Histórico:** Lofti Zadeh 1968 .. 1973

**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

Descrver / 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.

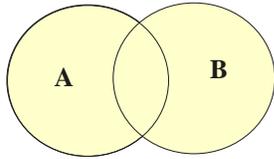
- Exemplos: O grau de força da chuva é independente da noção de previsão se vai chover...

Pchuva(0.2) = Indica uma probabilidade de 20% de ocorrer chuva e **80% de não chover!**

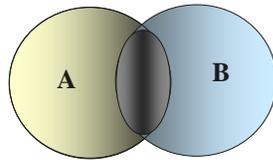
Regra Fuzzy = Deve chover, com uma certeza de 0.2, uma chuva fraca (nível de chuva 0.1)

**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!

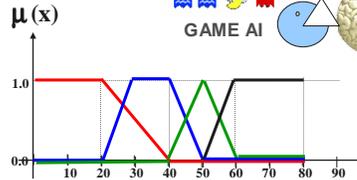
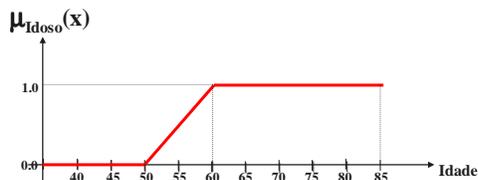
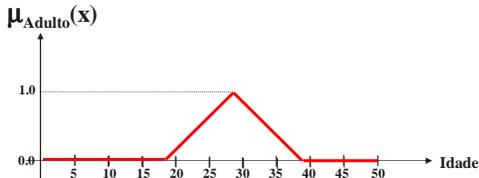
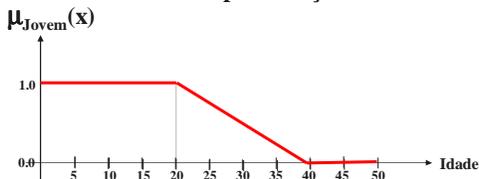


**Fuzzy Set:**  
 Membership Value / Valor de Pertinência  
 $\mu_A(X) = m$  onde  $0 \leq m \leq 1$   
 $m = 1.0$  se X pertence ao conjunto A  
 Exemplo:  
 $\mu_{\text{alto}}(\text{Objeto}) = 1.0 \dots 0.7 \dots 0.5 \dots 0.3 \dots 0.2$

• Membership Value  
 • Membership Function

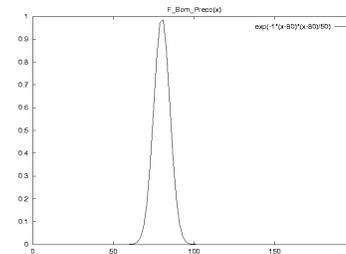


**FUZZY SETS: Membership Function**  
 Representação Gráfica



**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 Linguísticas - Valores Linguísticos



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

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

**Exemplos:** VL(jovem,  $\mu_{\text{Jovem}}$ )      **Adjetivos:** um pouco quente  
 VL(adulto,  $\mu_{\text{Adulto}}$ )                      muito quente  
 Associa nomes e conj. de valores                      extremamente quente

\* Categorias de variáveis linguísticas:

- 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:** Variáveis Linguísticas - HEDGES



Hedges = “Limitantes” - Possibilidade de modificar ou qualificar as variáveis linguísticas

- Intensify: very, extremely
- Dilute: about, somewhat, sort of, generally
- Probability: probably, not very likely
- Approximate a number: exactly
- Express quantities: many, most, seldom

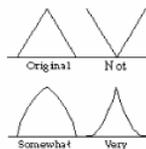
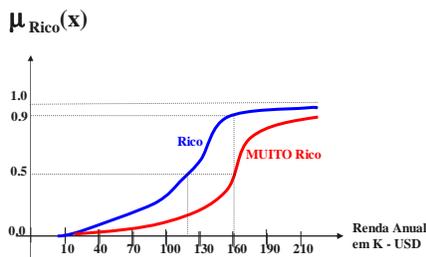


Figure 3. Adverbs



- \* Alteram a interpretação da Fuzzy Membership Function
  - Deslocar
  - Ampliar a área de SUPORTE
  - Reduzir

\* Suporte de um conjunto fuzzy:  
 SUP(A) = Zona na qual  $\mu_A(x) > 0$   
 Intervalo: [min, max]

\* Envelope: Região interna definida pelos limites da função de pertinência

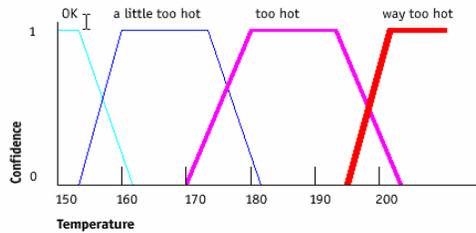
**FUZZY SETS:** Regras Fuzzy



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 LOGIC:** Fuzzy Inference



\* *Raciocínio Nebuloso - Approximate Reasoning:*

- Operadores Fuzzy: As operações com conjuntos fuzzy muitas vezes podem ser realizadas de diferentes modos.
- O importante é que estas operações respeitem algumas restrições básicas: satisfazer t-norms, t-conorm, extensão das operações Booleanas [Cechin]

• E / Interseção

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

*Diferenciável*

$$\mu_{A \cap B}(x) = \text{SoftMin}(x,y) = \frac{X \cdot \text{Exp}(-K \cdot X) + Y \cdot \text{Exp}(-K \cdot Y)}{\text{Exp}(-K \cdot X) + \text{Exp}(-K \cdot Y)}$$

K = Conste. > 0

• OU / União

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

$$\mu_{A \cup B}(x) = \text{SoftMax}(x,y) = \frac{X \cdot \text{Exp}(K \cdot X) + Y \cdot \text{Exp}(K \cdot Y)}{\text{Exp}(K \cdot X) + \text{Exp}(K \cdot Y)}$$

• NEGAÇÃO / Complemento

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

A	B	A OR B max(A,B)	A AND B min(A,B)
0	0	0	0
0	1	1	0
1	0	1	0
1	1	1	1
0.9	0.1	0.9	0.1

- Igualdade, Conjunto Contido, Implicação, Combinação Fuzzy...

**FUZZY LOGIC:** Fuzzy Inference



\* *Raciocínio Nebuloso - Approximate Reasoning:* Múltiplos Métodos podem ser usados!  
 Descrição dos métodos usados junto ao Sistema ExSys (CF default / Fuzzy)

- 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  
Então Confidence =  $\mu_A(x)$
  - Se a questão é definida por uma escolha na parte THEN da regra  
Então Confidence = propaga a parte IF da regra combinada com Confidence da parte

- Avaliação dos antecedentes => Cálculo do Confidence Value (combinar) - IF  
 Fórmula de combinação:

$$\text{Combined\_Conf} = \text{Combined\_Conf} + (\text{Confidence} * (1 - \text{Combined\_Conf}))$$

Combined\_Conf começa com 0.0 *Default Method*

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

$\text{Combined\_Conf} = 0.0 + 0.8 * (1-0) = 0.8$	Alternativa:
$\text{Combined\_Conf} = 0.8 + 0.6 * (1-0.8) = 0.92$	<u>Fuzzy MinMax</u> = 0.8

**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 => 0.988 (0.92 / 0.85 / 0.9)  
 [X] > [Y] = 0.7 \* 0.8 = 0.56  
 [Z] = 0.9 FINAL = 0.988 \* 0.56 \* 0.9 = 0.498

*Fuzzy MinMax:*

The color is red or blue OR Temperature is high OR Today is Monday => 0.8 (0.8 / 0.85 / 0.9)  
 [X] > [Y] = 0.7 (0.7 / 0.8)  
 [Z] = 0.9 FINAL = 0.8 / 0.7 / 0.9 = 0.7

Reliability is good	Reliability is okay	Warranty is long	Warranty is very long	Reliability is okay and Warranty is very long	Reliability is good or (Reliability is okay and Warranty is very long)
0.5	0.5	0.5	0.25	0.25	0.5
0.75	0.5	0.5	0.25	0.25	0.75
0.5	.9	0.9	0.81	0.81	0.81
0.5	0.9	1.0	1.0	0.9	0.9

Figure 5. Evaluating Antecedents

**FUZZY LOGIC:** Fuzzy Inference



\* *Raciocínio Nebuloso - Approximate Reasoning: **Múltiplos Métodos podem ser usados!***  
 Descrição dos métodos usados junto ao Sistema CubiCalc (ExSys - Vide CF)

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

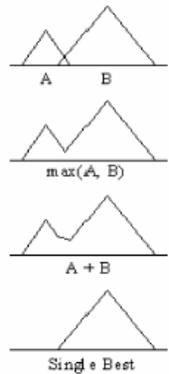


Figure 7. Consequent Combination

Regras com Combinação de conseqüentes:

IF A is Large THEN C is Small  
 IF B is Small THEN C is Small

Escalar os Conseqüentes:

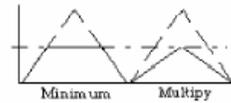


Figure 6. Scaling Consequents

**FUZZY LOGIC:** Defuzzification



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

O processo de defuzzificação 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

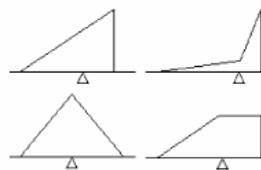


Figure 8. Centroids

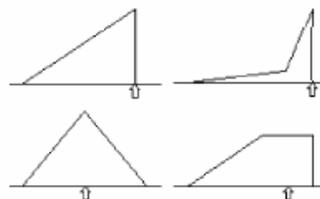


Figure 9. Midpoint of Maximum

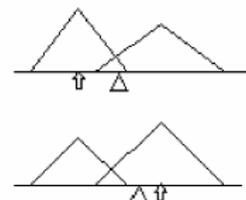


Figure 10. Max-height vs. Centroid

**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, Defuzzyfication**
- **Aprendizado de regras fuzzy**
- **Integração da lógica fuzzy aos sistemas convencionais**