

LABIC

# SISTEMAS INTELIGENTES

Profa. Roseli Ap. Francelin Romero

RAFR Sistemas Inteligentes 1

LABIC

## Introdução

- **Conjuntos Nebulosos (FUZZY)**
  - Teoria conveniente para tratamento de incertezas, termos lingüísticos, redundâncias, imprecisão e de forma geral conceitos mal definidos.
  - Em meados de 1960, **Zadeh** introduziu a noção de **conjunto fuzzy** para permitir que esses conceitos fossem modelados.
  - Exemplo de conceitos (de quantidades) definidos de forma IMPRECISA: "poucos livros", "uma longa estória", "uma mulher bonita", "um homem alto".
  - A teoria clássica de conjunto é governada por uma lógica que dá à uma proposição um valor: **falso** ou **verdadeiro**.
  - Essa lógica não representa bem conceitos **VAGOS**.

RAFR Sistemas Inteligentes 2

LABIC

## Introdução

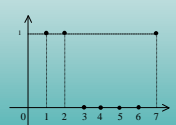
- Conjuntos fuzzy: A teoria de conjuntos fuzzy, vista como uma extensão da teoria de conjuntos clássicos, está associada aos conceitos básicos de funções de pertinência, operações com conjuntos fuzzy, números fuzzy, relações nebulosas, regras fuzzy, regra composicional de inferência, etc.
- Lógica fuzzy : extensão das lógicas bi-valores. Ao invés de considerar apenas dois valores-verdade (Verdadeiro=0 e Falso=1) como é o caso da lógica bi-valores, a lógica fuzzy pressupõe que os valores-verdade são conjuntos fuzzy definidos no intervalo [0, 1].

RAFR Sistemas Inteligentes 3

LABIC

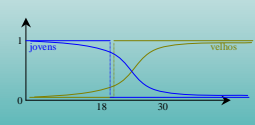
## Teoria clássica x fuzzy

**Teoria de conjuntos clássicos**

$$A : \begin{matrix} U \rightarrow \{1,0\} \\ x \in U \mapsto \{1,0\} \end{matrix}$$


Considere  $U = \{1,2,3,4,5,6,7\}$   
 $B = \{1,2,7\}$

**Teoria de conjuntos fuzzy**

$$A(x) : \begin{matrix} U \rightarrow [1,0] \\ x \in U \mapsto y = A(x) \end{matrix}$$


RAFR Sistemas Inteligentes 4

LABIC

## Conjuntos fuzzy

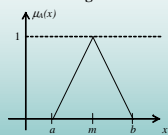
- **Idéia principal na teoria de conjunto fuzzy** é que um elemento tem um grau de pertinência num conjunto fuzzy.
- Então, uma proposição não precisa ser simplesmente **verdadeira** ou **falsa**, mas parcialmente verdadeira com um certo grau. Usualmente, assume-se que este grau é um número real pertencente ao intervalo [0,1].
- Por exemplo, consideremos o conjunto fuzzy "**VELHO**".
  - Claramente, alguém com 70 anos é velho  $\Rightarrow$  grau de pertinência ( ou relacionamento ) de uma idade 70 pode ser 1.
  - Alguém com 60 anos, não é tão certo que é um **velho** ou **não**  $\Rightarrow$  **parcialmente velho**  $\Rightarrow$  grau de pertinência da idade 60 como 0.7.
  - Portanto, a vagueza do termo "**VELHO**" pode ser capturada matematicamente.

RAFR Sistemas Inteligentes 5

LABIC

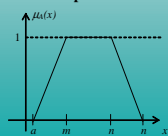
## Funções de pertinência

**triangular**



$$\mu_A(x) = \begin{cases} 0, & \text{se } x < a \\ \frac{x-a}{m-a}, & \text{se } a < x \leq m \\ \frac{b-x}{b-m}, & \text{se } m < x \leq b \\ 0, & \text{se } x \geq b \end{cases}$$

**trapezoidal**



$$\mu_A(x) = \begin{cases} 0, & \text{se } x < a \\ \frac{x-a}{m-a}, & \text{se } a < x \leq m \\ 1, & \text{se } m < x \leq n \\ \frac{b-x}{b-n}, & \text{se } n < x \leq b \\ 0, & \text{se } x \geq b \end{cases}$$

RAFR Sistemas Inteligentes 6

LABIC

## Funções de pertinência

**gaussiana**

$$\mu_A(x) = \exp^{-\sigma(x-m)^2}$$

**unitário**

$$\mu_A(x) = \begin{cases} 1, & \text{se } x = m \\ 0, & \text{caso contrário} \end{cases}$$

RAFR Sistemas Inteligentes 7

LABIC

## DEFINIÇÃO: Conjunto fuzzy

Considerando que  $X = \{x\}$  seja o universo de discurso contendo diversas características da variável  $x$ , a função de pertinência  $\mu(x)$  indica com que grau a variável  $x$  pertence ao conjunto  $A$  definido por um conjunto de pares ordenados.

$$A = \{ (x, \mu_A(x)), \quad x \in X \}$$

onde  $\mu_A(x)$  é chamado de **grau de pertinência** de  $x$  em  $A$  e  $\mu_A : X \rightarrow M$  é a função de  $X$  a um espaço  $M$  chamado de **espaço de pertinência**.

Quando  $M = \{0, 1\}$ ,  $A$  é **não-fuzzy** e  $\mu_A$  torna-se idêntica à função característica.

**EXEMPLO: CONJUNTO FUZZY "ALTO"**  
Os elementos são homens e seus graus de pertinência dependem de suas alturas:  
**Homem com 1,50m. pode ter grau 0**  
**Homem com 2,00m. Pode ter grau 1**

RAFR Sistemas Inteligentes 8

LABIC

## Conjuntos fuzzy

**Notação: Conjunto Fuzzy A**

- Função de Pertinência:  
 $A : X \rightarrow [0,1] \quad A(x) = y$   
 $\mu_A : X \rightarrow [0,1] \quad \mu_A(x) = y$
- Conjunto Fuzzy com Universo Finito:  
 $A = \mu_A(x_1)/x_1 + \mu_A(x_2)/x_2 + \dots + \mu_A(x_n)/x_n$   
 $A = \sum_{i=1}^n \mu_A(x_i)/x_i$
- Conjunto Fuzzy com Universo Contínuo:  
 $A = \int_X \mu_A(x)/x$

RAFR Sistemas Inteligentes 9

LABIC

## Operações com conjuntos fuzzy

- União:**  $\mu_{(A \cup B)} = \max[\mu_A(x), \mu_B(x)] = \mu_A(x) \vee \mu_B(x)$
- Interseção:**  $\mu_{(A \cap B)} = \min[\mu_A(x), \mu_B(x)] = \mu_A(x) \wedge \mu_B(x)$
- Complemento:**  $\mu_{\bar{A}} = 1 - \mu_A(x)$

RAFR Sistemas Inteligentes 10

LABIC

## EXEMPLO

**CONJUNTO BASE  $X = \{0,1,2, \dots, 10\}$**

Ótimo = { 0.5/8 + 0.8/9 + 1/10 }  
 Bom = { 0.4/5 + 0.7/6 + 1/7 + 1/8 + 1/9 + 1/10 }  
 Regular = { 0.1/4 + 0.5/5 + 1/6 + 0.5/7 + 0.1/8 }  
 Ruim = { 0.3/2 + 0.7/3 + 1/4 + 0.7/5 }  
 Péssimo = { 1/0 + 1/1 + 1/2 + 0.7/3 + 0.3/4 }

**Complemento:**  
 não Bom = { 1/0 + 1/1 + 1/2 + 1/3 + 1/4 + 0.6/5 + 0.3/6 }

**União:**  
 Ótimo  $\vee$  Regular = { 0.1/4 + 0.5/5 + 1/6 + 0.5/7 + 0.5/8 + 0.8/9 + 1/10 }

**Interseção:**  
 Ruim  $\wedge$  Péssimo = { 0.3/2 + 0.7/3 + 0.3/4 }

**Negação  $\neq$  antônimo**  
**não bom  $\neq$  ruim**

RAFR Sistemas Inteligentes 11

LABIC

## EXEMPLO

Altura(m.)	Grau de pertinência
1.50	0.00
1.54	0.08
1.58	0.32
1.60	0.50
1.64	0.82
1.68	0.98
1.70	1.00

**CONJUNTO FUZZY: AVALIAÇÃO**  
 Alto : alturas [ 0,1 ]

domínio  $\rightarrow$  contra-domínio

RAFR Sistemas Inteligentes 12

LABIC

## A Álgebra de Subconjuntos fuzzy

1) UNIÃO  $\mu_{(\text{ALTO OR BAIXO})} = \max(\mu_{\text{ALTO}}, \mu_{\text{BAIXO}})$

ALTO	OR	BAIXO
1.50		1.00
1.54		0.92
1.58		0.68
1.60		0.50
1.64		0.82
1.68		0.98
1.70		1.00

- A UNIÃO significa dizer que um homem é ALTO ou BAIXO. Podemos imaginar que ele é NÃO-TAMANHO-MÉDIO. Logo, obtemos um novo conceito: NÃO-TAMANHO-MÉDIO dos conceitos ALTO e BAIXO

CONJUNTOS NÃO FUZZY SÃO CHAMADOS CONJUNTOS "CRISP"

RAFR Sistemas Inteligentes 13

LABIC

## A Álgebra de Subconjuntos fuzzy

2) INTERSEÇÃO  $\mu_{(\text{ALTO AND BAIXO})} = \min(\mu_{\text{ALTO}}, \mu_{\text{BAIXO}})$

ALTO	AND	BAIXO
1.50		0.00
1.54		0.08
1.58		0.32
1.60		0.50
1.64		0.18
1.68		0.02
1.70		0.00

- A INTERSEÇÃO significa pensar que um homem é ALTO e BAIXO ⇒ MÉDIO.

- Mas é mais razoável dizer que ele é NÃO-ALTO e NÃO-BAIXO. **VERIFICAR !!!**

- Do ponto de vista da Teoria Fuzzy as representações são equivalentes

RAFR Sistemas Inteligentes 14

LABIC

## A Álgebra de Subconjuntos fuzzy

3) COMPLEMENTO  $\mu_{(\text{NAO-ALTO})} = 1 - \mu_{\text{ALTO}}$

ALTO	NÃO-ALTO
1.50	0.00
1.54	0.08
1.58	0.32
1.60	0.50
1.64	0.82
1.68	0.98
1.70	1.00

- Novo LABEL para NÃO-ALTO: BAIXO

- Isto não significa que BAIXO tenha que ser um antônimo de "ALTO"

RAFR Sistemas Inteligentes 15

LABIC

## Propriedades dos operadores fuzzy

Condições de limite	$A \cup \emptyset = A, A \cup X = X$ $A \cap \emptyset = \emptyset, A \cap X = A$
Comutatividade	$A \cup B = B \cup A, A \cap B = B \cap A$
Associatividade	$(A \cup B) \cup C = A \cup (B \cup C)$ $(A \cap B) \cap C = A \cap (B \cap C)$
Distributividade	$A \cup (B \cap C) = (A \cup B) \cap (A \cup C)$ $A \cap (B \cup C) = (A \cap B) \cup (A \cap C)$

RAFR Sistemas Inteligentes 16

LABIC

## Propriedades dos operadores fuzzy

Idempotência	$A \cup A = A, A \cap A = A$
Involução	$\overline{\overline{A}} = A$
Lei da contradição	$A \cap \overline{A} = \emptyset$
Lei da exclusão do meio	$A \cup \overline{A} = X$
Lei de Morgan	$\overline{A \cup B} = \overline{A} \cap \overline{B}$ $\overline{A \cap B} = \overline{A} \cup \overline{B}$

RAFR Sistemas Inteligentes 17

LABIC

## Normas triangulares

- Classe geral de operadores (normas e co-normas) de união e interseção que satisfazem as propriedades de comutatividade, associatividade, monotonicidade e condições de limite.

- Operações baseadas em normas e co-normas triangulares podem operar conjuntos em universos distintos (diferente da união e interseção que trabalham com conjuntos definidos num mesmo universo).

- Sejam A e B dois conjuntos fuzzy definidos nos universos X e Y, respectivamente, e a e b valores de pertinência dados por  $a = \mu_A(x)$  e  $b = \mu_B(y)$ . Então, as normas e co-normas triangulares podem ser definidas como:

RAFR Sistemas Inteligentes 18

LABIC

## Normas triangulares

**T-NORMA:**

- Função  $t$  de dois argumentos:

$t : [0,1]^2 \rightarrow [0,1]$ , que satisfaz as seguintes condições:

- 1) não decrescente ponto a ponto:  $atb \leq ctd$  para  $a \leq c$  e  $b \leq d$
- 2) comutatividade:  $atb = bta$
- 3) associatividade:  $(atb)tc = at(btc)$
- 4) condições de limite:  $at0 = 0$  e  $at1 = a$

**T-NORMA = OPERADOR DE INTERSEÇÃO**

RAFR Sistemas Inteligentes 19

LABIC

## Normas triangulares

**S-NORMA (CO-NORMA):**

- Função  $t$  de dois argumentos:

$t : [0,1]^2 \rightarrow [0,1]$ , que satisfaz as seguintes condições:

- 1) não decrescente ponto a ponto:  $asb \leq csd$  para  $a \leq c$  e  $b \leq d$
- 2) comutatividade:  $asb = bsa$
- 3) associatividade:  $(asb)sc = as(bsc)$
- 4) condições de limite:  $as0 = a$  e  $as1 = 1$

**S-NORMA = OPERADOR DE UNIÃO**

RAFR Sistemas Inteligentes 20

LABIC

## Operações Algébricas

- Sejam A, B e C conjuntos fuzzy, então define-se:

- Soma Algébrica:  $C = A + B$   
 $\mu_{(A+B)}(x) = \mu_A(x) + \mu_B(x) - \mu_A(x) \cdot \mu_B(x)$
- Soma Limitada:  $C = A \oplus B$   
 $\mu_{A \oplus B}(x) = \min\{1, \mu_A(x) + \mu_B(x)\}$
- Diferença Limitada:  $C = A (-) B$   
 $\mu_{A (-) B}(x) = \max\{0, \mu_A(x) + \mu_B(x) - 1\}$

RAFR Sistemas Inteligentes 21

LABIC

## Outras operações

- Sejam A e B conjuntos fuzzy no mesmo universo U
- A medida de **possibilidade** quantifica o grau de sobreposição entre dois conjuntos.  

$$Poss(A, B) = \sup_{x \in X} [\min(\mu_A(x), \mu_B(x))]$$
- A medida de **necessidade** quantifica o grau de inclusão de um conjunto em outro.  

$$Nec(A, B) = \inf_{x \in X} [\max(\mu_A(x), 1 - \mu_B(x))]$$

RAFR Sistemas Inteligentes 22

LABIC

## Relações fuzzy

- As relações fuzzy são generalizações das relações tradicionais. Nas relações fuzzy, cada elemento de um conjunto possui uma dependência (seja nula ou não) com cada elemento de outro conjunto.
- Sejam X e Y dois universos quaisquer. Uma relação fuzzy R é um conjunto fuzzy definido em X x Y que associa a cada elemento de X x Y um grau de pertinência definido no intervalo unitário, ou seja,  $R : X \times Y \rightarrow [0; 1]$ .

$$R = \{((x, y), \mu_R(x, y)) \mid (x, y) \in X \times Y\}$$

RAFR Sistemas Inteligentes 23

LABIC

## Relações fuzzy

- Exemplos:

- 1) Sejam os conjuntos universos  $X = \{a, b, c\}$  e  $Y = \{1, 2\}$ , uma relação R pode ser definida como:  
 $R = \{0.1 \mid (a,1) + 0.6 \mid (a,2) + 0.9 \mid (b,1) + 1 \mid (b,2) + 0 \mid (c,1) + 0.2 \mid (c,2)\}$
- 2) Sejam os conjuntos universos  $X = \{NY, Paris\}$  e  $Y = \{Beijing, NY, Londres\}$ , uma relação R pode ser definida na representação matricial como:

R → relação fuzzy representando muito longe.

		NY	Paris
Beijing		1	0.9
NY		0	0.7
Londres		0.6	0.3

RAFR Sistemas Inteligentes 24

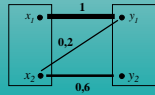
LABIC

## Relações fuzzy

- Para universos discretos, as relações podem representadas por grafos ou matrizes. Os nós destes grafos são elementos de  $X$  e  $Y$ , enquanto que as arestas correspondem aos graus de pertinência.

$X = \{x_1, x_2\}$   
 $Y = \{y_1, y_2\}$   
 $R = \{1 | (x_1, y_1) + 0 | (x_1, y_2) + 0.2 | (x_2, y_1) + 0.6 | (x_2, y_2)\}$

$$R = \begin{matrix} & y_1 & y_2 \\ x_1 & \begin{bmatrix} 1 & 0 \end{bmatrix} \\ x_2 & \begin{bmatrix} 0.2 & 0.6 \end{bmatrix} \end{matrix}$$



RAFR Sistemas Inteligentes 25

LABIC

## Operações com relações fuzzy

- Sejam  $R_1$  e  $R_2$  relações em  $X \times Y$ , então as operações são dadas por:

- União:**  $\mu_{(R_1 \cup R_2)}(x,y) = \mu_{(R_1)}(x,y) \vee \mu_{(R_2)}(x,y)$
- Interseção:**  $\mu_{(R_1 \cap R_2)}(x,y) = \mu_{(R_1)}(x,y) \wedge \mu_{(R_2)}(x,y)$
- Complemento:**  $\mu_{(\neg R_1)}(x,y) = 1 - \mu_{R_1}(x,y)$

RAFR Sistemas Inteligentes 26

LABIC

## Composição de relações fuzzy

- Uma relação composição ou simplesmente **composição de relações fuzzy** pode ser simplificada como:

$R_1(A,B) \quad R_2(B,C)$   
  
 $R(A,C)$

- A composição mais comum é: sup-t:  $R = G \circ W$

$$\mu_R(x, y) = \sup_{z \in Z} [\mu_G(x, z) \wedge \mu_W(z, y)]$$

RAFR Sistemas Inteligentes 27

LABIC

## Composição de relações fuzzy

- 1) Composição: sup-t:  $R = G \circ W$

$$\mu_R(x, y) = \sup_{z \in Z} [\mu_G(x, z) \wedge \mu_W(z, y)]$$

- As composições mais conhecidas são as que usam o *min* e o produto algébrico como normas-t, sendo denominadas de composição *max-min* e *max-prod*, respectivamente

- 2) Composição: inf-s:  $R = G \bullet W$

$$\mu_R(x, y) = \inf_{z \in Z} [\mu_G(x, z) \cdot \mu_W(z, y)]$$

RAFR Sistemas Inteligentes 28

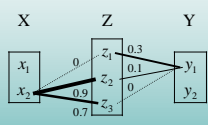
LABIC

## Exemplo de composição *max-min*

- Considere  $G(x,z)$  e  $W(z,y)$  relações fuzzy discretas

$$G = \begin{matrix} & z_1 & z_2 & z_3 \\ x_1 & \begin{bmatrix} 0.2 & 0.6 & 0 \end{bmatrix} \\ x_2 & \begin{bmatrix} 0 & 0.9 & 0.7 \end{bmatrix} \end{matrix}$$

$$W = \begin{matrix} & y_1 & y_2 \\ z_1 & \begin{bmatrix} 0.3 & 0.9 \end{bmatrix} \\ z_2 & \begin{bmatrix} 0.1 & 0.5 \end{bmatrix} \\ z_3 & \begin{bmatrix} 0 & 0.9 \end{bmatrix} \end{matrix}$$



- O resultado da composição  $R$ , considerando o *min* como t-norma (operador  $\wedge$ ), é dado por:

$$R = \begin{matrix} & y_1 & y_2 \\ x_1 & \begin{bmatrix} 0.2 & 0.5 \end{bmatrix} \\ x_2 & \begin{bmatrix} 0.1 & 0.7 \end{bmatrix} \end{matrix}$$

$$\mu_R(x_2, y_1) = \sup_z [0 \wedge 0.3, 0.9 \wedge 0.1, 0.7 \wedge 0];$$
  

$$\mu_R(x_2, y_2) = \sup_z [0, 0.1, 0] = 0.1.$$

RAFR Sistemas Inteligentes 29

LABIC

## Sistemas Fuzzy

Sistema Fuzzy

→ Variáveis de entr./saída

→ Regras Fuzzy

→ Métodos de Inferência Fuzzy

RAFR Sistemas Inteligentes 30

LABIC

## Raciocínio aproximado

- Em sistemas fuzzy, uma **conclusão** é derivada a partir de  **fatos e regras fuzzy**
- Regras fuzzy são interpretadas como relações fuzzy
- As regras modelam sentenças em linguagem natural (ou artificial) através do conceito de variáveis linguísticas.
- A composição de regras fuzzy (**inferência**) permite a derivação de um conclusão.
- Este processo é denominado de **raciocínio aproximado**

RAFR Sistemas Inteligentes 31

LABIC

## Variáveis linguísticas

- Uma **variável linguística** pode ser definida, de uma maneira informal, como uma variável cujos valores são palavras ou sentenças, ao invés de números (Pedrycz & Gomide, 1998).
- Exemplos de variáveis linguísticas que podem assumir os seguintes **valores linguísticos**:
  - Temperatura = {muito baixa, baixa, média, alta, muito alta}
  - Tamanho = {alto e gordo, mais ou menos magro e baixo, magro e baixo}

RAFR Sistemas Inteligentes 32

LABIC

## Variáveis linguísticas

- Cada **valor linguístico** de uma variável linguística é associado a um conjunto fuzzy em um mesmo universo de discurso.

Partição uniforme      Partição não-uniforme

RAFR Sistemas Inteligentes 33

LABIC

## Regras fuzzy

- As regras fuzzy armazenam o conhecimento do sistema nebuloso e da aplicação

lógica fuzzy

**Se <antecedente> então <consequente>**

**Se  $X$  é  $A$  então  $Y$  é  $B$**

Proposições fuzzy

- $X$  e  $Y$  são variáveis linguísticas nos universos  $X$  e  $Y$
- $A$  e  $B$  são conjuntos fuzzy representando valores linguísticos para as variáveis  $X$  e  $Y$ .

RAFR Sistemas Inteligentes 34

LABIC

## Regras fuzzy

**Se *velocidade* é *alta* então o *impacto* é *forte***

variável linguística      variável linguística

valor linguístico      valor linguístico

**Se *altitude* é *alta* então a *temperatura* é *baixa***

variável linguística      variável linguística

valor linguístico      valor linguístico

RAFR Sistemas Inteligentes 35

LABIC

## Regras fuzzy

- Uma regra do tipo “**Se  $X$  é  $A$  então  $Y$  é  $B$** ” é abreviada para  $A \rightarrow B$  e pode ser relação  $R$  no produto cartesiano  $X \times Y$

$$R: X \times Y \rightarrow \{0,1\}$$

$$R = \{(x, y), \mu_R(x, y)\} | (x, y) \in X \times Y\}$$

- A relação  $R$  é descrita através da função de pertinência definida no espaço bidimensional (i.e.  $R$  é um conjunto fuzzy)

$$\mu_R(x, y) = f(\mu_A(x), \mu_B(y)), \quad f: [0,1]^2 \rightarrow [0,1]$$

$$B'(y) = \max_{x \in X} (\min[A'(x), R(x, y)])$$

RAFR Sistemas Inteligentes 36

LABIC

## Regras fuzzy

- Sendo uma regra fuzzy uma relação, então é possível obter um valor de pertinência para as regras. O grau de pertinência indica quanto a regra é considerada verdadeira.
- As relações fuzzy (regras) vêm de 3 classes de funções através de t-normas (t) e s-normas (s):

1) **Conjunção fuzzy:**  $f_t(\mu_A(x), \mu_B(y)) = \mu_A(x) \mathbf{t} \mu_B(y)$


2) **Disjunção fuzzy:**  $f_s(\mu_A(x), \mu_B(y)) = \mu_A(x) \mathbf{s} \mu_B(y)$

RAFR Sistemas Inteligentes 37


LABIC

## Regras fuzzy

3) **Implicação fuzzy:** representa a relação  $R: A \rightarrow B = A \Rightarrow B$

$f_i(\mu_A(x), \mu_B(y)) = \mu_A(x) \mathbf{t} \mu_B(y)$   lógica fuzzy

$p \Rightarrow q = \bar{p} \vee q$

$f_i(\mu_A(x), \mu_B(y)) = \min[1, 1 - \mu_A(x) + \mu_B(y)]$   lógica fuzzy

$p \Rightarrow q = 1 \wedge (1 - p + q)$

RAFR Sistemas Inteligentes 38

LABIC

## Regras fuzzy

- As regras fuzzy podem ter mais de uma variável no antecedente e no conseqüente

Se  $X_1 \in A_1$  E  $X_2 \in A_2$  E ... E  $X_n \in A_n$  então  $Y \in B$   
 Se  $X_1 \in A_1$  OU  $X_2 \in A_2$  OU ... OU  $X_n \in A_n$  então  $Y \in B$   
 Se  $X_1 \in A_1$  E ... E  $X_n \in A_n$  então  $Y_1 \in B_1$  E  $Y_2 \in B_2$  E ... E  $Y_n \in B_n$

- Em um sistema fuzzy o conhecimento é representado pelo conjunto de regras

Regra i: Se  $X_{i1} \in A_{i2}$  E ... E  $X_{im} \in A_{im}$  então  $Y_{i1} \in B_{i2}$  E ... E  $Y_{in} \in B_{in}$

RAFR Sistemas Inteligentes 39

LABIC

## Inferência Fuzzy

- Uma composição e uma implicação tornam possíveis Inferência FUZZY
- Lei de Inferência Composicional:  
 dada uma implicação  $R: A \Rightarrow B$  e uma composição  $\circ$ , **um valor fuzzy B'** pode ser inferido quando **um valor A'** é conhecido

**B' = A'  $\circ$  R**

RAFR Sistemas Inteligentes 40

LABIC

## Inferência Fuzzy

**R** relação fuzzy em  $X \times Y$   
**A'** conjunto fuzzy em  $X$   
**B'** conjunto fuzzy em  $Y$

$$B'(y) = \max_{x \in X} (\min[A'(x), R(x, y)])$$

**Proposições Condicionais:** Se  $V \in A$  então  $U \in B$   
 induz relação **R** sobre  $X \times Y$  determinada por:

$$R(x, y) = I[A(x), B(y)]$$

onde I denota a implicação fuzzy ( $\Rightarrow$ )

RAFR Sistemas Inteligentes 41

LABIC

## Inferência Clássica: Raciocínio exato

- Inferência : cadeia de *Matching*
- Sistemas de IA (sistemas de produção): Matching é EXATO
- Na lógica bi valores, o *modus ponens* (MP) é a regra básica de inferência utilizada

<i>MP</i>	premissa 1 (fato): $X \in A$ premissa 2 (regra): <b>se <math>X \in A</math> então <math>Y \in B</math></b>
	(conclusão): $Y \in B$

ou seja,  $X \rightarrow Y$  e  $X \in true \implies Y$  é inferido exatamente.

RAFR Sistemas Inteligentes 42

LABIC

## Inferência Clássica: Raciocínio exato

premissa 1 (fato): o tomate é vermelho  
 premissa 2 (regra): se o tomate é vermelho então ele está maduro  
 (conclusão): o tomate está maduro

- Se não ocorre o *matching* exato entre o fato e a regra, então nada pode ser concluído

RAFR Sistemas Inteligentes 43

LABIC

## Inferência Fuzzy: Raciocínio aproximado

- Na lógica fuzzy, as premissas e conclusão podem ser imprecisas e não apresentar valores exatos.
- A representação do conhecimento na lógica fuzzy se aproxima do raciocínio humano
- A regra mais utilizada para esta lógica é o *modus ponens* generalizado (MPG)
- Em MPG, não é necessário ocorrer o *matching* exato entre o fato e a regra
- Embora a premissa 1 apresente um fato diferente, porém muito semelhante ao conhecimento do antecedente da premissa 2, pode-se concluir alguma informação de  $Y$ .

RAFR Sistemas Inteligentes 44

LABIC

## Inferência Fuzzy: Modus Ponens Generalizado

MPG

premissa 1 (fato):  $X \text{ é } A'$   
 premissa 2 (regra): se  $X \text{ é } A$  então  $Y \text{ é } B$   
 (conclusão):  $Y \text{ é } B'$

premissa 1 (fato): o tomate é mais ou menos vermelho  
 premissa 2 (regra): se o tomate é vermelho então ele está maduro  
 (conclusão): o tomate está mais ou menos maduro

RAFR Sistemas Inteligentes 45

LABIC

## Leis de inferência fuzzy

### I) Modus Ponens Generalizada

Se  $x \text{ é } A$  então  $y \text{ é } B$   
 Sendo que o fato é ( $x \text{ é } A'$ ), então ( $y \text{ é } B'$ )

$B'$  pode ser inferido pela regra composicional:  
 $B' = A' \circ (A \Rightarrow B) = A' \circ R_{AB}$

$\circ$ : operador composicional  
 $R_{AB}$ : matriz relacional fuzzy representando a relação implicação  $A \Rightarrow B$

RAFR Sistemas Inteligentes 46

LABIC

## Leis de inferência fuzzy

### II) Modus Tolen Generalizada

Se  $x \text{ é } A$ , então  $y \text{ é } B$   
 Sabendo que  $y$  é inferido como  $B'$ , como encontrar o fato da regra (ou seja, como encontrar  $A'$ )?

$A'$  pode ser encontrado pela regra composicional:  
 $A' = (A \Rightarrow B) \circ B' = R_{AB} \circ B'$

### III) Lei Transitiva

$A \rightarrow B$  e  $B \rightarrow C$ , então  $A \rightarrow C$

RAFR Sistemas Inteligentes 47

LABIC

## Leis de Inferência Fuzzy

### IV) Leis de Morgan

$\neg(A \wedge B) = \neg A \vee \neg B$   
 $\neg(A \vee B) = \neg A \wedge \neg B$

Outras leis de inferencia fuzzy são dadas em

Yager and Zadeh, "An Introduction to Fuzzy Logic Applications in Intelligent Systems", Boston, Kluwer Academic, 1992.

RAFR Sistemas Inteligentes 48



LABIC

## Exemplo - MPG

*R* induzida por proposição condicional

premissa 1 (fato):  $X \text{ é } A'$   
 premissa 2 (regra): **se  $X \text{ é } A$  então  $Y \text{ é } B$**   
 (conclusão):  $Y \text{ é } B'$

**Exemplo:**  
 $A = \{0.5/x_1 + 1/x_2 + 0.6/x_3\}$   
 $B = \{1/y_1 + 0.4/y_2\}$   
 $A' = \{0.6/x_1 + 0.9/x_2 + 0.7/x_3\}$

$$R = \begin{matrix} & \begin{matrix} y_1 & y_2 \end{matrix} \\ \begin{matrix} x_1 \\ x_2 \\ x_3 \end{matrix} & \begin{bmatrix} 1 & 0.9 \\ 1 & 0.4 \\ 1 & 0.8 \end{bmatrix} \end{matrix}$$

$$\begin{bmatrix} 0.6 & 0.9 & 0.7 \end{bmatrix} \circ \begin{bmatrix} 1 & 0.9 \\ 1 & 0.4 \\ 1 & 0.8 \end{bmatrix} = \begin{bmatrix} 0.9 \\ 0.7 \end{bmatrix} \quad \text{B}' = \{0.9/y_1 + 0.7/y_2\}$$

RAFR Sistemas Inteligentes 49

LABIC

## Métodos de Inferência

- **Representação Matricial**

$X = Y = \{ 1 + 2 + 3 + 4 \}$   
 $A = \{ 0.4/2 + 1/3 + 0.5/4 \}$   $B = \{ 1/2 + 0.6/3 + 0.2/4 \}$

$$D = A \oplus B \quad B' = A' \circ D$$

$$\mu_{A \oplus B}(x) = \min \{ 1, \mu_A(x) + \mu_B(x) \}$$

$$\begin{bmatrix} 0.5 & 0.7 & 0.2 & 0 \end{bmatrix} \circ \begin{bmatrix} 0 & 1 & 0.6 & 0.2 \\ 0.4 & 1 & 1 & 0.6 \\ 1 & 1 & 1 & 1 \\ 0.5 & 1 & 1 & 0.7 \end{bmatrix} = \begin{bmatrix} 0.5 \\ 0.7 \\ 0.7 \\ 0.6 \end{bmatrix}$$

RAFR Sistemas Inteligentes 50

LABIC

## Métodos de Inferência

1) Considera-se uma base de regras com uma única regra composta por uma variável no antecedente e uma no conseqüente

Sabendo que uma regra pode ser representada por uma relação, a conclusão pode ser inferida através de composição

premissa 1 (fato):  $X \text{ é } A'$   
 premissa 2 (regra):  $R$  (relação resultante da regra "se  $X \text{ é } A$  então  $Y \text{ é } B$ ")  
 (conclusão):  $Y \text{ é } B' = A' \circ R = A' \circ (A \Rightarrow B)$

RAFR Sistemas Inteligentes 51

LABIC

## Métodos de Inferência

2) Com uma base de mais de uma regra, cada regra  $R_i$  pode induzir uma relação fuzzy diferente

$R_i$ : se  $X \text{ é } A_i$  então  $Y \text{ é } B_i$ ,  $i = 1, \dots, k$  ( $k$  = número de regras)

O conjunto de regras, por sua vez, resulta numa relação fuzzy que é obtida pela agregação das relações (regras) individuais, como:

$$R = \bigcup_{i=1}^m R_i = \bigcup_{i=1}^m (A_i \Rightarrow B_i)$$

O operador de agregação  $A_R$  é normalmente representado por uma s-norma (mas t-normas podem ser usadas)

RAFR Sistemas Inteligentes 52

LABIC

## Métodos de Inferência

■ **Inferência Max-min**

- ◆ Se  $X \text{ é } A_1$  então  $U \text{ é } B_1$
- ◆ Se  $X \text{ é } A_2$  então  $U \text{ é } B_2$

RAFR Sistemas Inteligentes 53

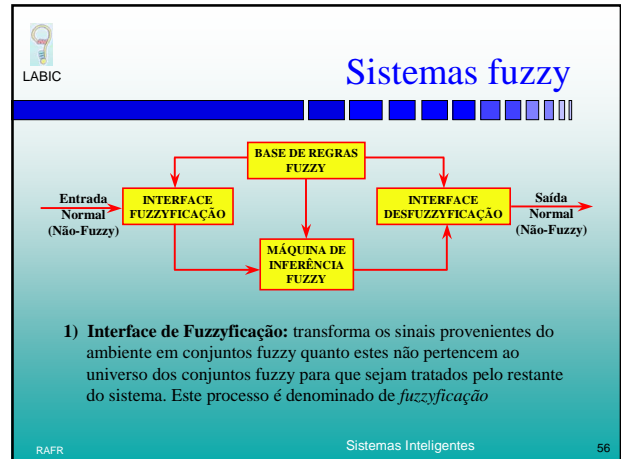
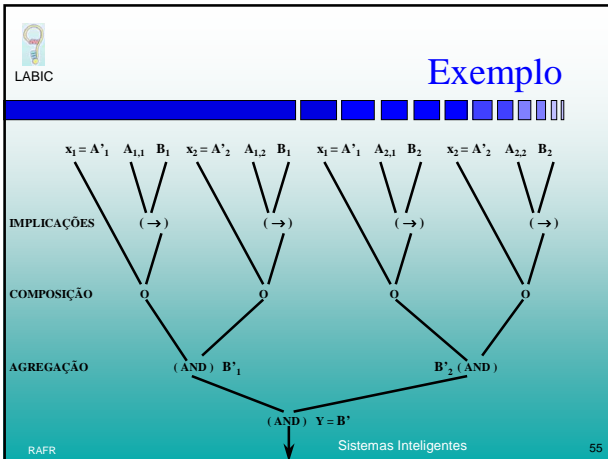
LABIC

## Métodos de Inferência

- Se entre as regras existe um **link-OR**  
Operação MAX pode ser aplicada.
- Se entre as regras existe um **link-AND**  
Operação MIN pode ser aplicada.
- Se entre as regras existe um **link-Additive**  
Operação  $\mu_B = \sum \mu_{B_i} w_i$ ,  $i = 1, 2, \dots, m$  é aplicada para inferir

A seleção de qual link usar depende do contexto

RAFR Sistemas Inteligentes 54



LABIC

## Sistemas fuzzy

- Base de conhecimento:** composta por 2 componentes
  - Base de regras: contém as regras fuzzy que representam o conhecimento sistema
  - Base de dados: contém informações sobre os parâmetros das funções de pertinência (conjuntos fuzzy) e dos operadores de agregação e inferência
- Máquina de inferência:** realiza o processo de inferência (raciocínio fuzzy) para obter a saída ou a conclusão
- Interface de saída:** transforma a resposta normalizada pelo sistema fuzzy em sinais que sejam interpretados pelo ambiente do problema. Este processo é denominado de *desfuzzyficação*

RAFR

Sistemas Inteligentes 57

LABIC

## Modelo de inferência

- Um dos modelos de inferência mais utilizados para obter conclusões a partir de fatos e regras fuzzy é o modelo de **Mamdani** (Mamdani and Assilian, 1975)
- Para a descrição dos passos do modelo **Mamdani** considere uma base com  $k$  regras e  $m$  variáveis no antecedente e uma no consequente
 

premissa 1 (fato):  $X_1 \in A'_1$  e  $X_2 \in A'_2$  e ... e  $X_m \in A'_m$

premissa 2 (regra 1): se  $X_1 \in A_{1,1}$  e  $X_2 \in A_{1,2}$  e ... e  $X_m \in A_{1,m}$  então  $Y \in B_1$

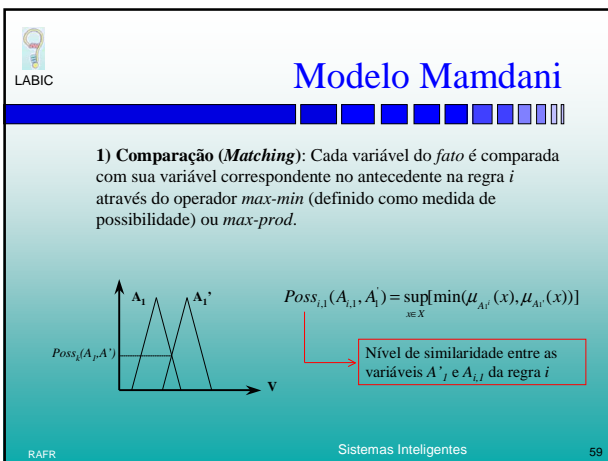
...

premissa k+1 (regra k): se  $X_1 \in A_{k,1}$  e  $X_2 \in A_{k,2}$  e ... e  $X_m \in A_{k,m}$  então  $Y \in B_k$

(conclusão):  $Y \in B$

RAFR

Sistemas Inteligentes 58



LABIC

## Modelo Mamdani

- Agregação dos antecedentes:** Os níveis de similaridades do antecedente de cada regra são agregados pelo operador norma-t se as variáveis são ligadas por E e pelo operador norma-s se as variáveis são ligadas por OU.

- Conjunção para regras  $i$  com  $m$  variáveis ligadas por E:
 
$$\mu_{A_i} = \mathbf{t} \prod_{v=1}^m Poss_{i,v}(A_{i,v}, A'_v)$$
- Disjunção para regras  $i$  com  $m$  variáveis ligadas por OU:
 
$$\mu_{A_i} = \mathbf{s} \max_{v=1}^m Poss_{i,v}(A_{i,v}, A'_v)$$

RAFR

Sistemas Inteligentes 60

LABIC

## Modelo Mamdani

3) **Derivação da conclusão individual:** Para cada regra, o valor obtido da agregação dos antecedentes é aplicado ao conjunto fuzzy da variável

$$B_i = \mu_{A_i} \text{ t } \mu_{C_i}$$

$B_i$ : conjunto fuzzy resultante da agregação dos antecedentes com o conseqüente da regra  $i$

$\mu_{A_i}$ : conjunto fuzzy resultante da agregação dos antecedentes da regra  $i$

$\mu_{C_i}$ : conjunto fuzzy do conseqüente da regra  $i$

RAFR Sistemas Inteligentes 61

LABIC

## Modelo Mamdani

4) **Derivação do resultado final:** Os conjuntos fuzzy obtidos na derivação da conclusão de cada regra são agregados através do operador norma-s (lembrando que  $k =$  número total de regras)

$$Q = \text{s}_{i=1}^k B_i$$

$Q$ : conjunto fuzzy resultante da agregação dos conseqüentes do conjunto completo de regras

$\mu_{A_i}$ : conjunto fuzzy resultante da agregação dos antecedentes com o conseqüente da regra  $i$

s: operador norma-s (o operador *max* é o mais utilizado)

RAFR Sistemas Inteligentes 62

LABIC

## Modelo Takagi-Sugeno

$X_1 \in A'_1$  e  $X_2 \in A'_2$  e ... e  $X_m \in A'_m$   
 se  $X_1 \in A_{1,1}$  e  $X_2 \in A_{1,2}$  e ... e  $X_m \in A_{1,m}$  então  $Y \in B_1 = f_1(\mathbf{W}_1, \mathbf{X})$   
 ...  
 se  $X_1 \in A_{k,1}$  e  $X_2 \in A_{k,2}$  e ... e  $X_m \in A_{k,m}$  então  $Y \in B_k = f_k(\mathbf{W}_k, \mathbf{X})$   
 Y é B

em que  $\mathbf{W}_i = [w_{i,1}, w_{i,2}, \dots, w_{i,m}] \rightarrow$  parâmetros do conseqüente (cada regra  $i$  possui  $\mathbf{W}_i$ )  
 $\mathbf{X} = [X_1, X_2, \dots, X_m] \rightarrow$  variáveis de entrada

- Modelo de inferência Takagi-Sugeno possui 4 passos:

- 1) **Comparação (Matching):** idêntico ao modelo de Mamdani
- 2) **Agregação dos antecedentes:** idêntico ao modelo de Mamdani

RAFR Sistemas Inteligentes 63

LABIC

## Modelo Takagi-Sugeno

3) **Derivação da conclusão individual:** Para cada regra, as variáveis de entrada (correspondente aos antecedentes) são aplicadas na função  $f_i(\mathbf{W}_i, \mathbf{X})$  que define o conseqüente juntamente com os parâmetros do vetor  $\mathbf{W}_i$

3) **Derivação do resultado final:** os valores resultantes da função  $f_i$  e da agregação dos antecedentes  $\mu_{A_i}$  são agregados para o cálculo da média ponderada  $Y$  que indica a saída final do sistema fuzzy.

$$Y = \frac{\sum_{i=1}^m \mu_{A_i} \times f_i}{\sum_{i=1}^m \mu_{A_i}}$$

Modelo Takagi-Sugeno não necessita de um método de desfuzzyficação para gerar a saída do sistema, uma vez que  $Y$  já é um valor não-fuzzy

RAFR Sistemas Inteligentes 64

LABIC

## Modelos de desfuzzyficação

- 1) **Média dos Máximos:** Os valores correspondentes ao máximo da função de pertinência do conjunto fuzzy  $Q$  resultante da agregação dos conseqüentes são identificados e a média define o valor não-fuzzy
- 2) **Centro de Massa:**  $\hat{q} = \frac{\int \mu_c(q) q dq}{\int \mu_c(q) dq}$   $w^0 = \frac{\sum_j w_j \mu_c(w_j)}{\sum_j \mu_c(w_j)}$
- 3) **Centro de Área:**  $\int_{-\infty}^{\hat{q}} \mu_c(q) dq = \int_{\hat{q}}^{\infty} \mu_c(q) dq$

em que  $Q$  é o conjunto resultante do Passo 4 no universo  $Q$  e  $\hat{q}$  resulta do balanço entre duas áreas de  $Q$  determinada por  $\hat{q}$

RAFR Sistemas Inteligentes 65

LABIC

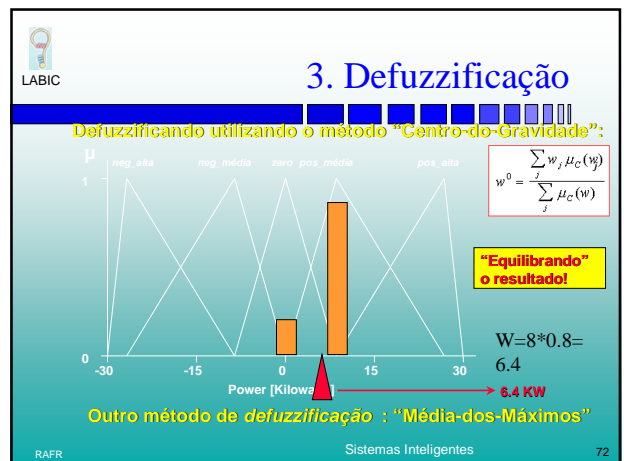

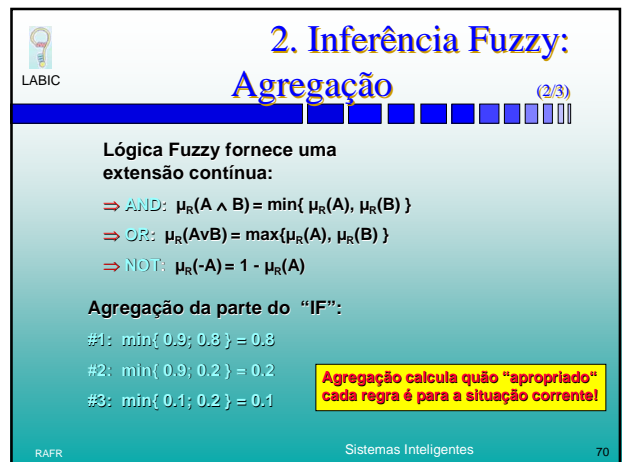

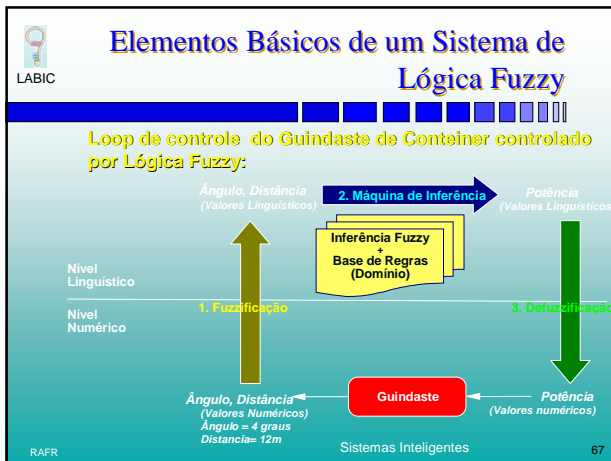
## Elementos Básicos de um Sistema de Lógica Fuzzy

Estudo do caso do Guindaste de Container:

Crane Head  
Container  
Ship  
Trailer

Dois variáveis de medida e uma variável de comando!

RAFR Sistemas Inteligentes 66





## Controle Nebuloso

### Vantagens:

- ⇒ Simplificação do modelo de processo;
- ⇒ Melhor Tratamento das imprecisões inerentes aos sensores utilizados;
- ⇒ Facilidade na especificação das regras de controle, em linguagem natural;
- ⇒ Satisfação de múltiplos objetivos de controle;
- ⇒ Facilidade de incorporação do conhecimento de especialistas



## Fuzzy em Aplicação Reais

### Exemplos de aplicação

#### Máquina de Lavar Roupas

- 159 regras
- diferença máxima de aproximadamente 350 mililitros do valor considerado como ideal
- capaz de economizar 20% de água e energia elétrica
- foi implementado em um controlador de 8 bits.

#### Interface Fuzzy para Consultas SQL

- permite consultas com “palavras vagas”
- Ex: Selecionar os funcionários que ganham bem*




## Fuzzy em Aplicação Reais

### Exemplos de aplicação (cont.)

#### Anti-Lock Break System (ABS)

- sem microcontroladores adicionais
- escorregamento determinado através da reação



## Softwares Fuzzy

- Nefclass
- np410 - {Neural Planner 4.1}
- Unfuzzy 1.1
- Fuzzytech
- LPA - FLINT {Fuzzy Logic Tool Kit}
- Toolbox do Matlab