




Introdução à Lógica Fuzzy

Lógica Fuzzy

Albert Einstein, 1928

“À medida que as proposições matemáticas se referem à realidade, elas não são certas; e, à medida que são certas, elas não se referem à realidade.”



Lotfi Zadeh, 1973




“Dito informalmente, a essência do princípio da incompatibilidade é que, à medida que a complexidade de um sistema aumenta, nossa habilidade de fazer afirmações precisas e significativas sobre o seu comportamento diminui até um limite além do qual precisão e relevância se tornam características quase mutuamente exclusivas.”

- Lógica Fuzzy (Fuzzy Sets, Lógica Nebulosa) foi concebida e formalmente descrita por Lotfi Zadeh
- Generalização da Teoria Clássica dos Conjuntos
- Representa e trata “noções lingüísticas” → objetos com limites não definidos
- Lógica multi-valores x Lógica clássica binária


Conjuntos Clássicos e Conjuntos Fuzzy

- O conceito de **conjuntos clássicos (*crisp sets*)** introduz a noção intuitiva fundamental de aceitar ou rejeitar um objeto como pertencente a uma dada coleção (ou categoria).
- O processo de dicotomia impõe uma decisão binária: tudo ou nada, 0 ou 1, verdadeiro ou falso.
- O conceito de **conjuntos fuzzy (*fuzzy sets*)** consiste em relaxar este requerimento e admitir valores intermediários de classes de pertinência.
- Este conceito permite um cenário de interpretação mais rico e realístico, acomodando afirmações com quantificações parciais de pertinência.



Função de pertinência (=função característica= *membership function*)

- Fuzzy sets são caracterizados por funções de pertinência.
- O valor da função de pertinência descreve o grau de pertinência da variável linguística em questão, com relação ao conceito que ela descreve (o quão relacionada a variável é com o conceito).



O valor de $H(t)$ descreve o grau de pertinência de t em H .

t : variável linguística

T : **universo de discurso** de t , $T=[0,50]$ (= domínio de $H(t)$)

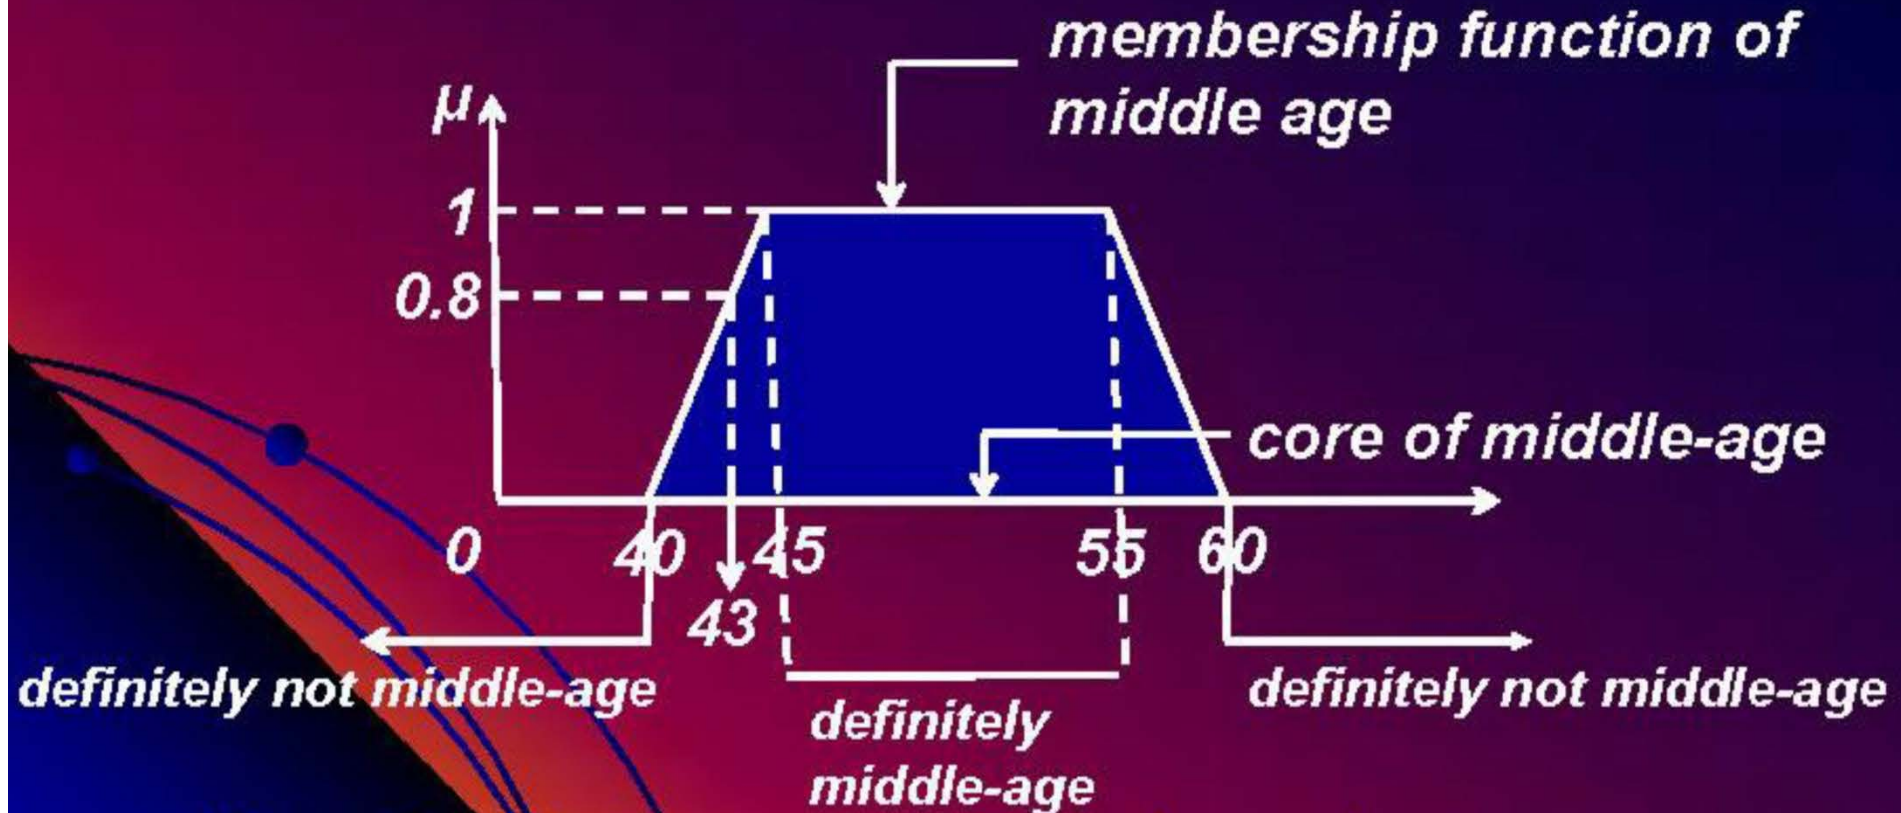
*Note que aqui consideramos o conceito de Alta Temperatura (HT) em um contexto ambiental, com temperaturas distribuídas no intervalo $[0, 50^\circ\text{C}]$.

Caracterização do FS H de “Alta Temperatura (HT)” no universo de discurso $T=[0,50]$

Temperatura em questão $t \in T$	Relação com o conceito “Alta Temperatura = HT”	Valor de $H(t)$ relacionado à compatibilidade de t com o conceito de HT
0°C	Não é entendido como HT	Grau de Pertinência = 0
$t \geq 30^\circ\text{C}$	Certamente é entendido como HT	Grau de Pertinência = 1
$30^\circ\text{C} < t \leq 50^\circ\text{C}$	Certamente é entendido como HT	Grau de Pertinência = 1
$12.5^\circ\text{C} \leq t < 30^\circ\text{C}$	≠s relações com o conceito	≠s valores em $[0,1]$


EXAMPLE—GRADUATION OF MIDDLE-AGE

- *Imprecision of meaning = fuzziness of meaning*
- *Computational model of middle-age (trapezoidal fuzzy set)*



- *Note: Parameters are context-dependent*

Função de pertinência p/ conjuntos clássicos




$$\underline{x_1 \in A}; \underline{x_2 \notin A}$$

CONSIDERANDO O CONJUNTO A MOSTRADO NA FIGURA AO LADO, NO UNIVERSO X, PODE-SE AFIRMAR CLARAMENTE QUE O OBJETO (PONTO) x_1 PERTENCE AO CONJUNTO A, ENQUANTO x_2 NÃO PERTENCE.

SE DENOTARMOS A DECISÃO DE ACEITAÇÃO POR 1 E A DECISÃO DE REJEIÇÃO POR 0, PODE-SE EXPRESSAR A DECISÃO POR MEIO DE UMA FUNÇÃO CARACTERÍSTICA (OU FUNÇÃO DE PERTINÊNCIA) $A(x)$, $x \in X$, CONFORME:

$$A(x) = \begin{cases} 1, & \text{SE } x \in A \\ 0, & \text{SE } x \notin A \end{cases}$$

↑
FORMA ANALÍTICA DE $A(x)$



- O CONJUNTO VAZIO \emptyset TEM FUNÇÃO CARACTERÍSTICA NULA,
 $\phi(x) = 0$, $\forall x \in X$;

- O CONJUNTO UNIVERSO X TEM FUNÇÃO CARACTERÍSTICA UNITÁRIA,
 $X(x) = 1$, $\forall x \in X$;

- UM CONJUNTO QUE CONTENHA APENAS 1 ELEMENTO (a , POR EXEMPLO) $A = \{a\}$ TEM FUNÇÃO CARACTERÍSTICA:
$$A(x) = \begin{cases} 1, & \text{SE } x = a \\ 0, & \text{EM CASO CONTRÁRIO.} \end{cases}$$


A FUNÇÃO DE PERTINÊNCIA $A: X \rightarrow \{0,1\}$ INDUZ UMA RESTRIÇÃO COM LIMITES BEM DEFINIDOS SOBRE OS OBJETOS DO UNIVERSO X QUE PODEM SER ATRIBUÍDOS AO CONJUNTO A .

EXEMPLO 1 :

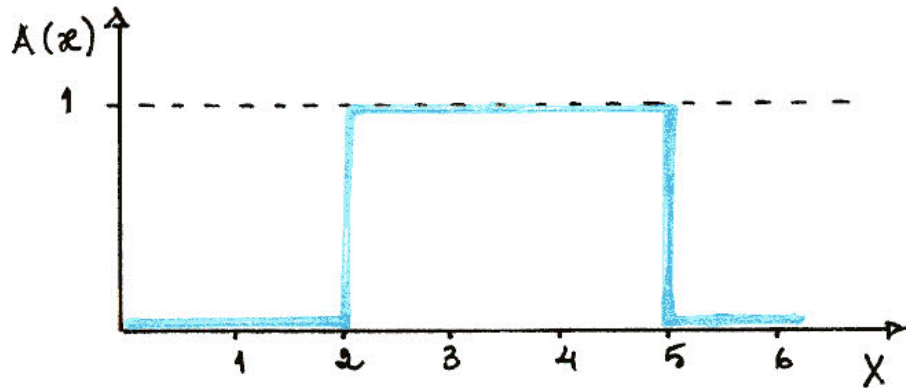

CONSIDERE OS CONJUNTOS $A = \{x \in \mathbb{R} \mid 2 \leq x \leq 5\}$ E $B = \{x \in \mathbb{R} \mid 3 \leq x \leq 6\}$, OS QUAIS MODELAM INTERVALOS SOBRE A RETA REAL \mathbb{R} .

* DETERMINE AS FUNÇÕES CARACTERÍSTICAS DE A E B.

* DETERMINE A UNIÃO, A INTERSECÇÃO E O COMPLEMENTO DOS CONJUNTOS A E B EM TERMOS DE SUAS FUNÇÕES CARACTERÍSTICAS.




* DETERMINE AS FUNÇÕES CARACTERÍSTICAS DE A E B.



$$A: X \rightarrow \{0, 1\}$$

$$A(x) = \begin{cases} 1, & \text{SE } x \in A \\ 0, & \text{SE } x \notin A \end{cases}$$

$$A = \{x \in \mathbb{R} \mid 2 \leq x \leq 5\}$$




$$B: X \rightarrow \{0, 1\}$$

$$B(x) = \begin{cases} 1, & \text{SE } x \in B \\ 0, & \text{SE } x \notin B \end{cases}$$

$$B = \{x \in \mathbb{R} \mid 3 \leq x \leq 6\}$$


* DETERMINE A UNIÃO E A INTERSECÇÃO DOS CONJUNTOS A E B EM TERMOS DE SUAS FUNÇÕES CARACTERÍSTICAS.



$$A \cup B : x \rightarrow \{0, 1\}$$

$$A \cup B = \{x \in \mathbb{R} \mid 2 \leq x \leq 6\}$$

$$(A \cup B)(x) = \begin{cases} 1, & \text{SE } x \in (A \cup B) \\ 0, & \text{CASO CONTRÁRIO} \end{cases}$$

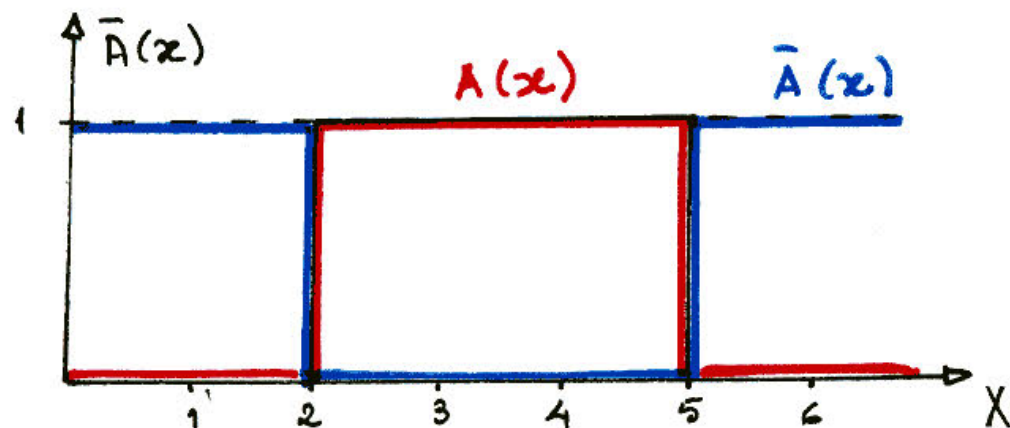


$$A \cap B : x \rightarrow \{0, 1\}$$

$$A \cap B = \{x \in \mathbb{R} \mid 3 \leq x \leq 5\}$$


$$(A \cap B)(x) = \begin{cases} 1, & \text{SE } x \in (A \cap B) \\ 0, & \text{CASO CONTRÁRIO} \end{cases}$$

* DETERMINE O COMPLEMENTO DOS CONJUNTOS A E B EM TERMOS DE SUAS FUNÇÕES CARACTERÍSTICAS.



$$\bar{A}(x) = 1 - A(x), \forall x \in X$$

$$A, \bar{A} : X \rightarrow \{0, 1\}$$



$$\bar{B}(x) = 1 - B(x), \forall x \in X$$

$$B, \bar{B} : X \rightarrow \{0, 1\}$$

EXEMPLO 2 :

PARA OS CONJUNTOS A E B DO EXEMPLO 1, COM FUNÇÕES DE PERTINÊNCIA DEFINIDAS POR :


$$A(x) = \begin{cases} 1, & \text{SE } x \in A \\ 0, & \text{CASO CONTRÁRIO} \end{cases}$$

$$E \quad B(x) = \begin{cases} 0.5, & \text{SE } x \in B \\ 0, & \text{CASO CONTRÁRIO,} \end{cases}$$

* DETERMINE A UNIÃO E A INTERSECÇÃO DOS DOIS CONJUNTOS EM TERMOS DE SUAS FUNÇÕES DE PERTINÊNCIA.


$$A = \{x \in \mathbb{R} \mid 2 \leq x \leq 5\}$$

$$A(x) : X \rightarrow \{0, 1\}$$




$$B = \{x \in \mathbb{R} \mid 3 \leq x \leq 6\}$$

$$B(x) : X \rightarrow \{0.5, 1\}$$




* DETERMINE A UNIÃO E A INTERSECÇÃO DOS DOIS CONJUNTOS EM TERMOS DE SUAS FUNÇÕES DE PERTINÊNCIA.

$$(A \cup B)(x) = \max \{ A(x), B(x) \}, \forall x \in X$$




$$(A \cup B)(x): X \rightarrow \{0, 0.5, 1\}$$

$$(A \cap B)(x) = \min \{ A(x), B(x) \}, \forall x \in X$$



$$(A \cap B)(x): X \rightarrow \{0, 0.5, 1\}$$


OBS:



Função de pertinência μ / conjuntos *fuzzy* (=fuzzy sets):

Noções como **alta** temperatura, **média** pressão, vizinhança **próxima**, **baixa** velocidade, etc., representam categorias usadas para descrever “objetos do mundo real” que não possuem limites bem definidos (as expressões em **vermelho** identificam as fontes de nebulosidade).

- Se um objeto pertence ou não a tal categoria é uma questão de grau (de pertinência), expresso, por exemplo, por um número real pertencente ao intervalo $[0,1]$.
- Quanto mais próximo de 1, maior o grau de pertinência do objeto à particular categoria.



Nota: Um *fuzzy set* é um conjunto cujos elementos possuem diferentes graus de pertinência, e não apenas a pertinência $\{0,1\}$ dos conjuntos clássicos. A função de pertinência é a representação do *fuzzy set*. Neste contexto, as denominações “função de pertinência” e “*fuzzy set*” são usadas de maneira equivalente.

Função de pertinência μ / *fuzzy sets*:


Definição: Coleção de objetos com valores de pertinência que variam entre a exclusão completa (0) e a inclusão completa (1).

Os valores de pertinência expressam os graus de compatibilidade do objeto com as propriedades ou características que distinguem a coleção (ou seja, o quanto o objeto tem a ver com o conceito).

Um *fuzzy set* é caracterizado por uma função de pertinência que mapeia os elementos de um domínio, espaço ou **universo de discurso X** ao intervalo unitário $[0,1]$, ou seja: $A : X \rightarrow [0,1]$. (Zadeh, 1965)

Um *fuzzy set* é uma generalização do conceito de um conjunto clássico cujas funções de pertinência assumem um de dois possíveis valores, $\{0,1\}$.

O valor de $A(x)$ descreve um grau de pertinência de x em A .



Função de pertinência $H: T \rightarrow [0,1]$, caracterizando o *fuzzy set* $H(t)$ de altas temperaturas, no universo $T = [0, 50]$

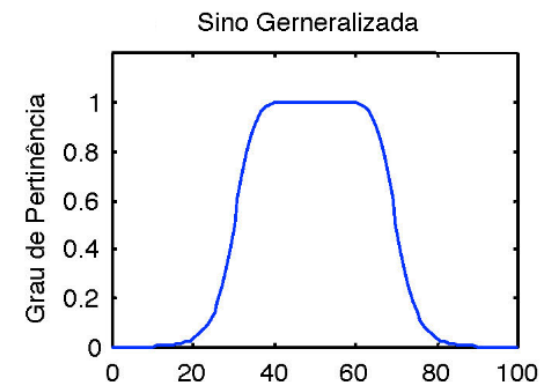
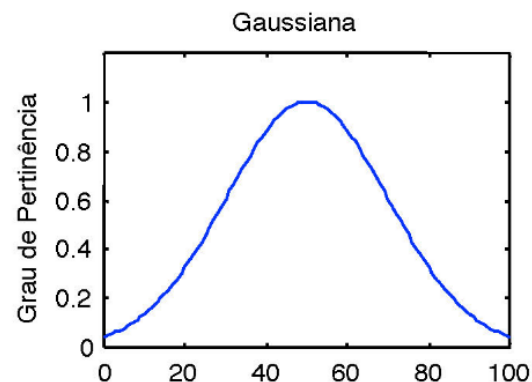
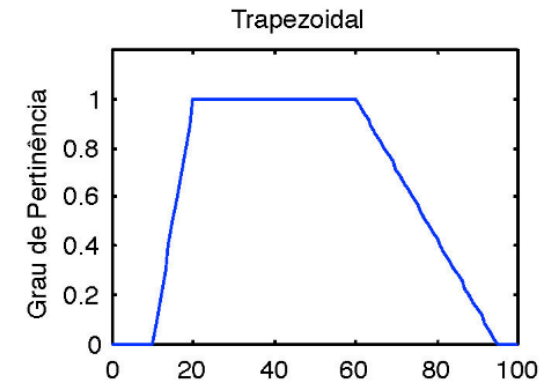

Temperatura \rightarrow Grau de compatibilidade com o conceito

$0^\circ \rightarrow$ Não é alta temperatura \rightarrow 0 (nulo)


$\geq 30^\circ \rightarrow$ São altas temperaturas \rightarrow 1 (máximo)

Tipos de função de pertinência μ / *fuzzy sets*:

- Qualquer função da forma $A : X \rightarrow [0,1]$ descreve uma função de pertinência associada com um *fuzzy set* A , que depende não apenas do conceito a ser representado, mas também do contexto no qual é usado.
- Em geral, funções simples são convenientes em consequência do baixo custo computacional.
- Em muitas aplicações práticas, *fuzzy sets* podem ser representados por funções parametrizadas, conforme figura ao lado.




Função de pertinência triangular:




$$A(x) = \begin{cases} 0 & \text{if } x \leq a \\ \frac{x - a}{m - a} & \text{if } x \in [a, m] \\ \frac{b - x}{b - m} & \text{if } x \in [m, b] \\ 0 & \text{if } x \geq b \end{cases}$$

Função de pertinência trapezoidal:



$$A(x) = \begin{cases} 0 & \text{if } x < a \\ \frac{x-a}{m-a} & \text{if } x \in [a, m) \\ 1 & \text{if } x \in [m, n) \\ \frac{b-x}{b-n} & \text{if } x \in [n, b] \\ 0 & \text{if } x > b \end{cases}$$

Função de pertinência gaussiana:




$$A(x) = \exp\left(-\frac{(x - m)^2}{\sigma^2}\right)$$

Caracterização de *fuzzy sets*:


A caracterização de *fuzzy sets* é baseada nas particularidades das funções de pertinência que os representam.

1. Um *fuzzy set* é **NORMAL** quando sua função de pertinência atinge 1, ou seja, $\text{Sup } A(x) = 1$ (supremo de $A = 1$) ou altura $\text{hgt}(A)$ de A é igual a 1:



Normal

$$\text{hgt}(A) = 1$$




Subnormal

$$\text{hgt}(A) < 1$$


$$\text{hgt}(A) = \sup_{x \in X} A(x)$$

2. **SUPORTE** de um *fuzzy set* A , denotado por $\text{Supp}(A)$, são todos os elementos do universo de discurso (domínio) X que pertencem ao fuzzy set A com um grau de pertinência não nulo:



$$\text{Supp}(A) = \{x \in X \mid A(x) > 0\}$$


3. **NÚCLEO (CORE)** de um *fuzzy set* A é o conjunto de todos os elementos do universo de discurso X que possuem pertinência 1 em A :




$$\text{Core}(A) = \{x \in X \mid A(x) = 1\}$$

α – corte da função de pertinência $A(x)$:

O α – corte de A , denotado por A_α , é um conjunto que consiste daqueles elementos do universo X cujos valores de pertinência excedem o limiar α , ou seja: $A_\alpha = \{x \in X \mid A(x) \geq \alpha\}$



$$A_\alpha = \{x \in X \mid A(x) \geq \alpha\}$$



$$A_\alpha^+ = \{x \in X \mid A(x) > \alpha\}$$

O maior limiar, $\alpha=1$, determina o conjunto de elementos de X que pertencem “totalmente” ao *fuzzy set* A .

Quanto menor o nível de α , maior o número de elementos de X que pertencem ao correspondente α – corte, ou seja:


Se $\alpha_1 > \alpha_2 \rightarrow A_{\alpha_1} \subset A_{\alpha_2}$.

Teorema da Representação

“Qualquer *fuzzy set* pode ser considerado como uma família de *fuzzy sets*.”

Qualquer *fuzzy set* A pode ser decomposto em uma série de α – cortes, de tal forma que $A = \bigcup \{A_\alpha\}$, $\alpha \in [0,1)$, ou, de forma equivalente, através da função de pertinência $A(x) = \sup (A_\alpha(x))$, $\alpha \in [0,1)$.

Quanto maior o número de níveis de quantização dos valores de pertinência (ou seja, quanto maior o número de α – cortes), mais detalhada a reconstrução.



Propriedades lógico-relacionais entre fuzzy sets:

1. INTERSECÇÃO $(A \cap B)(x) = \min(A(x), B(x)) = A(x) \wedge B(x)$

2. UNIÃO $(A \cup B)(x) = \max(A(x), B(x)) = A(x) \vee B(x)$

3. COMPLEMENTO $\bar{A}(x) = 1 - A(x)$

OBS:
 $\forall x \in X$

4. COMUTATIVIDADE $A(x) \cup B(x) = B(x) \cup A(x)$
 $A(x) \cap B(x) = B(x) \cap A(x)$

5. ASSOCIATIVIDADE $A(x) \cup (B(x) \cup C(x)) = (A(x) \cup B(x)) \cup C(x) =$
 $= A(x) \cup B(x) \cup C(x)$
 $A(x) \cap (B(x) \cap C(x)) = (A(x) \cap B(x)) \cap C(x) =$
 $= A(x) \cap B(x) \cap C(x)$

6. IDEMPOTÊNCIA $A(x) \cup A(x) = A(x)$
 $A(x) \cap A(x) = A(x)$

7. DISTRIBUTIVIDADE $A(x) \cap (B(x) \cup C(x)) = (A(x) \cap B(x)) \cup (A(x) \cap C(x))$
 $A(x) \cup (B(x) \cap C(x)) = (A(x) \cup B(x)) \cap (A(x) \cup C(x))$

8. CONDIÇÕES DE CONTORNO $A(x) \cup \phi(x) = A(x)$, $A(x) \cup X(x) = X(x)$
 $A(x) \cap \phi(x) = \phi(x)$, $A(x) \cap X(x) = A(x)$

9. INVOLUÇÃO $\bar{\bar{A}}(x) = A(x)$, OU SEJA:
 $\bar{\bar{A}}(x) = \overline{(\bar{A}(x))} = \overline{(1 - A(x))} = A(x)$

10. TRANSITIVIDADE $A(x) \subset B(x) \text{ E } B(x) \subset C(x) \Rightarrow A(x) \subset C(x)$


 O CONJUNTO UNIVERSO X TEM FUNÇÃO CARACTERÍSTICA UNITÁRIA,
 $X(x) = 1$, $\forall x \in X$;

Operações com *fuzzy sets* – normas triangulares

(operam 2 *fuzzy sets* resultando em um 3º *fuzzy set*):

Uma norma triangular **t-norma** é uma operação binária (no sentido de mapear 2 *fuzzy sets* em um 3º *fuzzy set*)

$$t : [0,1]^2 \rightarrow [0,1], \text{ ou seja } t : [0,1] \times [0,1] \rightarrow [0,1],$$



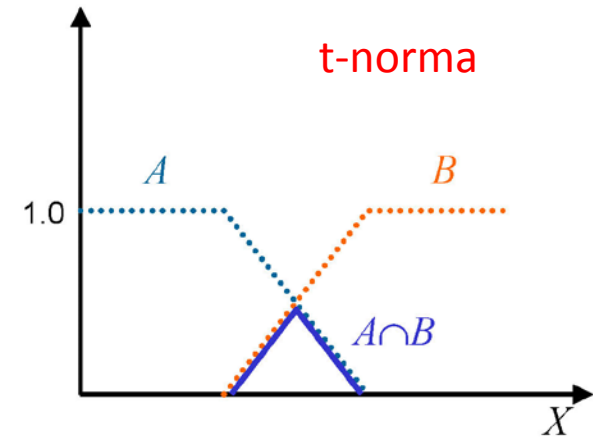
que satisfaça os seguintes requerimentos:

$$xty = ytx \quad \text{Comutativa}$$

$$xt(ytz) = (xty)tz \quad \text{Associativa}$$

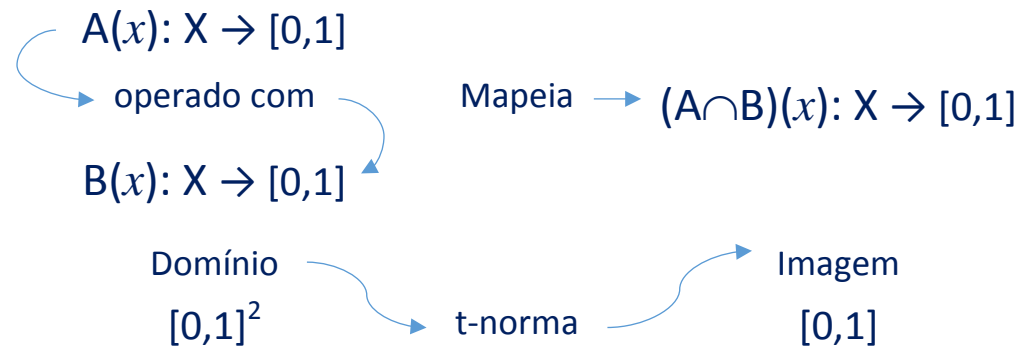
$$\text{Se } x \leq y \text{ e } w \leq z, \text{ então } xtw \leq ytz \quad \text{Monotônica}$$

$$xt1 = x \text{ e } 0tx = 0 \quad \text{Contorno}$$



$$(A \cap B)(x) = \min[A(x), B(x)] = A(x) \wedge B(x) \quad \forall x \in X$$

t-norma mín modela intersecção



Operações com *fuzzy sets* – normas triangulares:

Uma norma triangular **s-norma** é uma operação binária

$$s : [0,1]^2 \rightarrow [0,1], \text{ ou seja } s : [0,1] \times [0,1] \rightarrow [0,1],$$

$\underbrace{\hspace{10em}}_{\text{domínio}} \quad \underbrace{\hspace{2em}}_{\text{imagem}}$

que satisfaça os seguintes requerimentos:

$$xsy = ysx$$

Comutativa

$$xs(ysz) = (xsy)sz$$


Associativa

Se $x \leq y$ e $w \leq z$, então $xsw \leq ysz$

Monotônica

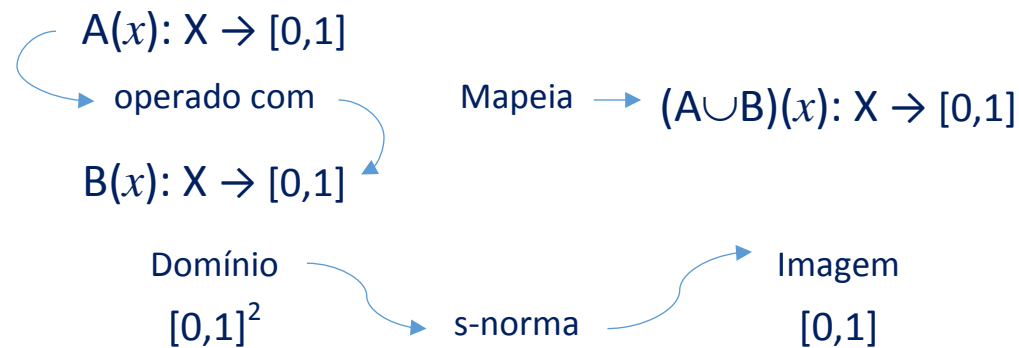
$$xs1 = 1 \text{ e } 0sx = x$$

Contorno



$$(A \cup B)(x) = \max[A(x), B(x)] = A(x) \vee B(x) \quad \forall x \in X$$

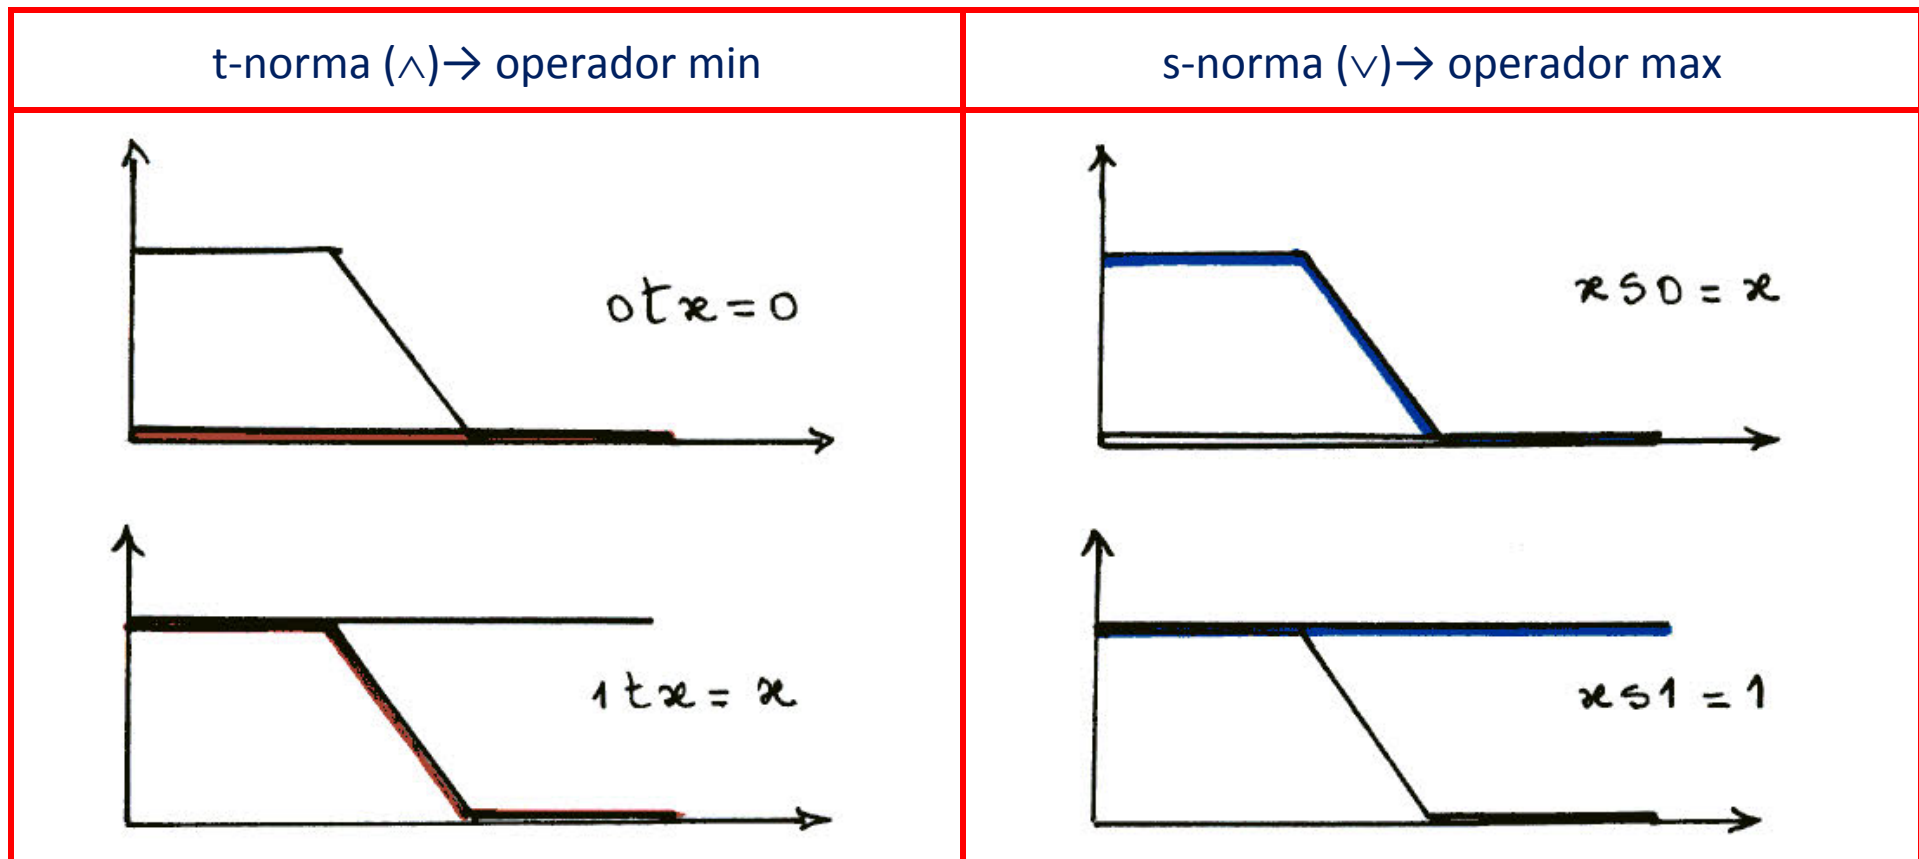
s-norma máx modela união



Operações com *fuzzy sets* – normas triangulares:

As propriedades comutatividade, associatividade e monotonicidade são idênticas para t-normas e s-normas.

Propriedade condições de contorno para t-normas e s-normas:



Exemplos de t-normas:

$$\bullet x \text{ t}_1 y = \frac{1}{1 + \sqrt[p]{((1-x)/x)^p + ((1-y)/y)^p}}, \quad p > 0$$

$$\bullet x \text{ t}_2 y = \max(0, (1+p)(x+y-1) - pxy), \quad p \geq -1$$

$$\bullet x \text{ t}_3 y = 1 - \min(1, \sqrt[p]{(1-x)^p + (1-y)^p}), \quad p > 0$$

$$\bullet x \text{ t}_4 y = xy$$

$$\bullet x \text{ t}_5 y = \frac{xy}{p + (1-p)(x+y-xy)}, \quad p \geq 0$$

$$\bullet x \text{ t}_6 y = \frac{1}{\sqrt[p]{1/x^p + 1/y^p - 1}}$$

$$\bullet x \text{ t}_7 y = \sqrt[p]{\max(0, x^p + y^p - 1)}, \quad p > 0$$

$$\bullet x \text{ t}_8 y = \frac{xy}{\max(x, y, p)}, \quad p \in [0, 1]$$

$$\bullet x \text{ t}_9 y = \log_p \left[1 + \frac{(p^x - 1)(p^y - 1)}{p - 1} \right], \quad p > 0, p \neq 1$$

$$\bullet x \text{ t}_{10} y = \frac{1}{1 + \sqrt[p]{((1-x)/x)^p + ((1-y)/y)^p}}, \quad p > 0$$

$$\bullet x \text{ t}_{11} y = \begin{cases} x, & \text{if } y = 1 \\ y, & \text{if } x = 1 \\ 0, & \text{otherwise} \end{cases}$$



Exemplos de s-normas:

- $x \text{ s}_1 y = \frac{1}{1 + \sqrt[p]{(x/1-x)^p + (y/1-y)^p}}, \quad p > 0$
- $x \text{ s}_2 y = \min(1, x + y + pxy), \quad p \geq 0$
- $x \text{ s}_2 y = \min(1, \sqrt[p]{x^p + y^p}), \quad p > 0$
- $x \text{ s}_4 y = x + y - xy$
- $x \text{ s}_5 y = \frac{x + y - xy - (1-p)xy}{1 - (1-p)xy}, \quad p \geq 0$
- $x \text{ s}_6 y = 1 - \frac{1}{\sqrt[p]{1/(1-x)^p + 1/(1-y)^p} - 1}$
- $x \text{ s}_7 y = 1 - \max(0, \sqrt[p]{((1-x)^p + (1-y)^p - 1)}), \quad p > 0$
- $x \text{ s}_8 y = 1 - \frac{(1-x)(1-y)}{\max((1-x), (1-y), p)}, \quad p \in [0, 1]$
- $x \text{ s}_9 y = \log_p \left[1 + \frac{(p^{1-x} - 1)(p^{1-y} - 1)}{p - 1} \right], \quad p > 0, p \neq 1$
- $x \text{ s}_{10} y = \frac{1}{1 - \sqrt[p]{(x/1-x)^p + (y/1-y)^p}}, \quad p > 0$
- $x \text{ s}_{11} y = \begin{cases} x, & \text{if } y = 0 \\ y, & \text{if } x = 0 \\ 1, & \text{otherwise} \end{cases}$

Leis da contradição:

Em geral, normas triangulares não satisfazem as leis da contradição, ou seja:

$$A(x) \cap \bar{A}(x) \neq 0 \quad \text{e} \quad A(x) \cup \bar{A}(x) \neq X$$



O $A(x)$ ao lado é o conjunto mais nebuloso dentre todos os *fuzzy sets* que podem ser definidos no universo de discurso X , pois tanto o **operador min** quanto o **operador max** retornam o mesmo valor para intersecção e união de A e \bar{A} :

$$\begin{aligned} \min [A(x), 1 - A(x)] &= \min (1/2, 1/2) = 1/2 \\ \max [A(x), 1 - A(x)] &= \max (1/2, 1/2) = 1/2, \quad \forall x \text{ em } X. \end{aligned}$$

O grau de falha de um conjunto em satisfazer as leis da contradição indica o grau de nebulosidade do conjunto.


Variáveis Linguísticas:

Uma variável linguística é uma variável cujos valores são palavras ou sentenças, ao invés de números.

Temperatura = {muito baixa, baixa, média, alta, não baixa e não muito alta, muito alta, ...}

↑
Variável
linguística

↑
Valores
linguísticos



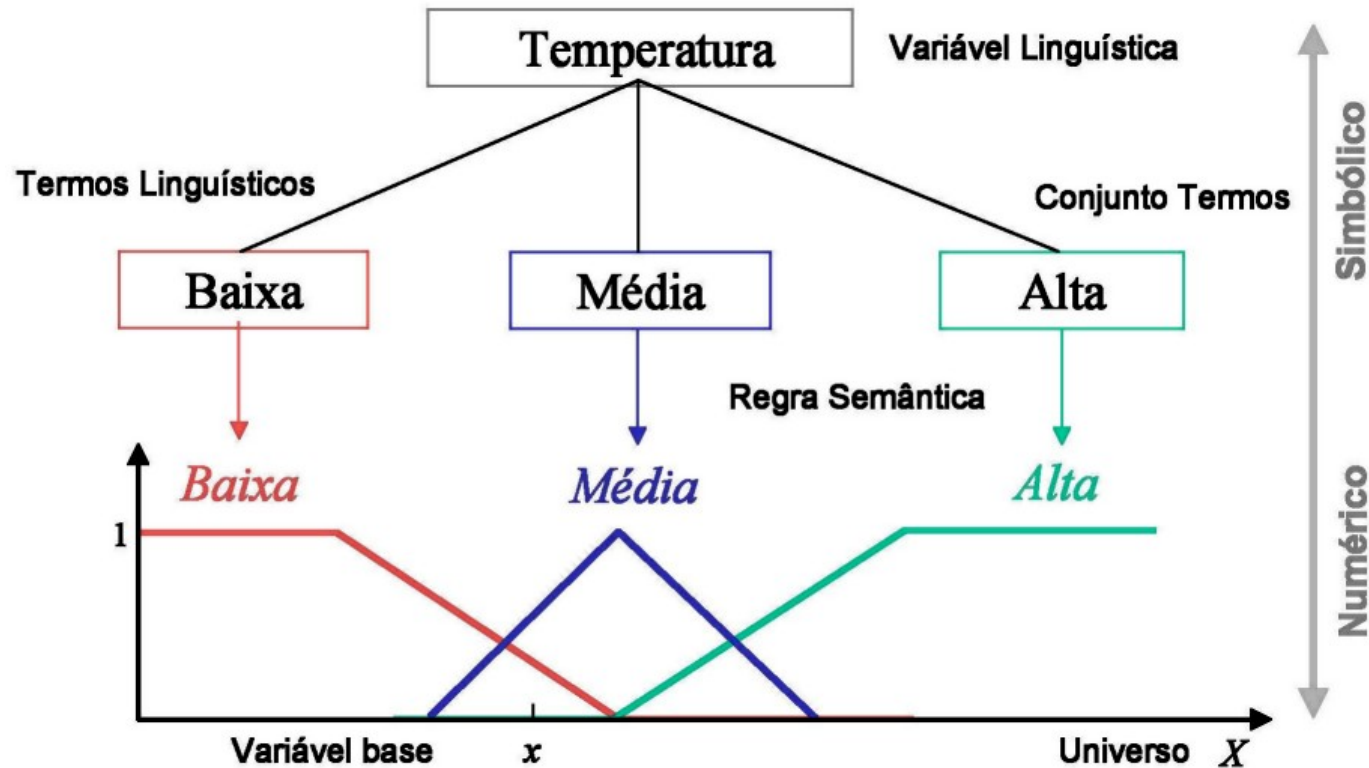
↑
Variável
linguística

↑
Valores
Linguísticos

Variável linguística representada por uma família de *fuzzy sets*:

Variável Linguística: **Temperatura**

Termos Linguísticos ou *Labels* (restrições impostas sobre a variável): **Baixa, Média, Alta**





Modificadores dos Termos Linguísticos: **conectivos** (AND, OR); **negação** (NOT); **hedges** (muito, mais ou menos, pouco, ...)

Frames de Cognição:

- Uma família de *fuzzy sets* (=família de funções de pertinência) geram o conceito de **Frame de Cognição**.
- Um Frame de Cognição granulariza a informação (**granularização = quantização nebulosa**)
- Um Frame de Cognição caracteriza uma variável linguística (pressão, temperatura, voltagem, etc...) representada pela família de *fuzzy sets*.

Um Frame de Cognição (ou moldura cognitiva) consiste de vários *fuzzy sets* normais (ver slide 20) usados como pontos de referência para o processamento de informação nebulosa.





Definição: Um Frame de Cognição $\mathbf{A} = \{A_1, A_2, \dots, A_n\}$ é uma coleção de todos os *fuzzy sets* definidos no mesmo universo de discurso X que satisfazem as seguintes condições:

1. Cobertura:


$$\forall x \in X \exists A_i(x) > \varepsilon \in [0,1], i=1, \dots, n$$

ε : nível de cobertura; $\varepsilon \in [0,1]$.

Cada elemento de x pertence a, no mínimo, um *fuzzy set*, com um grau maior do que ε .

2. Relevância Semântica:

Interpretabilidade linguística dos elementos de \mathbf{A} .



- Os A_i são unimodais (um único valor para o máximo da função A_i);
- Os A_i são normais (o máximo é unitário);
- Os A_i são suficientemente disjuntos para que os *fuzzy sets* sejam linguisticamente significativos;
- Usualmente a cardinalidade $\#\mathbf{A}$ é pequena ($5 \leq \#\mathbf{A} \leq 9$) – *rule of thumb*: número de A_i 's empiricamente adequado = 7

Codificação e Decodificação Nebulosa

Codificação \equiv Fuzzyficação

Representação de qualquer dado (numérico ou não) em termos de um “codebook” A ”.


Decodificação \equiv Defuzzyficação

Transformar o “codebook” A de volta a seu formato original.

Os mecanismos de codificação (F) e decodificação (F^{-1}) devem ser **univocamente reversíveis** (i.e., $F^{-1}(F(X)) = X$, onde X é o universo de discurso).

Codificação: A qualidade da codificação depende da granularidade imposta ao frame de cognição, a qual depende da natureza do problema tratado.

A figura abaixo apresenta duas codificações distintas Φ_1 e Φ_2 , resultando em dois frames de cognição de diferentes granularidades, sendo a granularidade da codificação Φ_2 maior do que a granularidade da codificação Φ_1 :



Decodificação: Há duas categorias de algoritmos para decodificação (ou defuzzyficação):


1. Decodificação baseada em **valores modais** do “codebook” (**valores modais** – valores em um intervalo do universo de discurso X para os quais os valores de pertinência são uma constante não nula que expressa o máximo da pertinência no intervalo).

Decodificação por Centro de Gravidade (com base nos valores modais):

$$F^{-1}(x) = \frac{\sum_{i=1}^n A(a_i)a_i}{\sum_{i=1}^n A(a_i)}$$

onde a_i denota o i -ésimo valor modal dentre os n valores valores modais de $A(x)$ no intervalo.

Esta abordagem produz um valor aproximado de x , cuja precisão é função do número n de valores modais considerados na expressão acima.




2. Decodificação baseada nas funções de pertinência do “codebook”.

Decodificação pelo método do Centro de Área (CoA)

O valor decodificado \hat{x} é tal que resulta na igualdade entre as áreas A_1 e A_2 na figura ao, ou seja:

$$\int_{-\infty}^{\hat{x}} A(x) dx = \int_{\hat{x}}^{\infty} A(x) dx$$



Operando com variáveis linguísticas:

Por meio de **Variáveis Linguísticas** e **Regras de inferência fuzzy**, afirmações do tipo “Se (IF) a temperatura é alta e (AND) a umidade é baixa, então (THEN) o conforto térmico é médio.” podem ser computadas.

As operações lógicas entre os conceitos linguísticos expressos por dois *fuzzy sets* A e B são definidas pelas relações lógicas AND, OR e NOT :

AND define a Intersecção $A \cap B$

OR define a União $A \cup B$

NOT define o Complemento \bar{A}

Lembrando dos slides 26 e 27 que:

t-norma (\wedge) \rightarrow operador min

$$A \cap B = A \mathbf{t} B = A \wedge B$$

s-norma (\vee) \rightarrow operador max

$$A \cup B = A \mathbf{s} B = A \vee B$$

Portanto, o significado semântico de um termo composto pode ser computado de forma direta:

Temperatura (variável linguística) = Não Baixa e Não Muito Alta (valor linguístico)

$$\text{Não Baixa e Não Muito Alta} = \overline{\text{Baixa}} \cap \overline{\text{Muito Alta}}$$

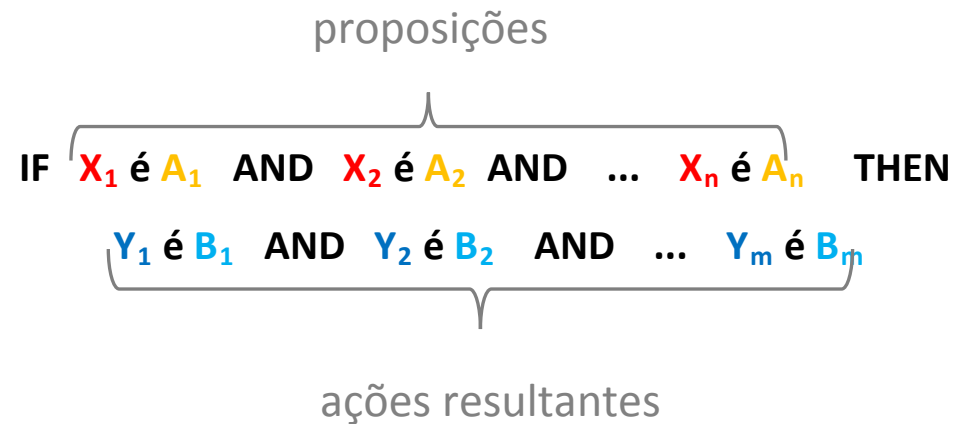
Temperatura (variável linguística) = Muito Alta ou Alta (valor linguístico)

$$\text{Muito Alta ou Alta} = \text{Muito Alta} \cup \text{Alta}$$

Operando com variáveis linguísticas – Regras de inferência fuzzy:

Dado um conjunto de dados de entrada (proposições), regras *fuzzy* proveem mecanismo para computar ações resultantes (afirmações, inferências) através de regras **IF-THEN** (se-então).

Uma regra *fuzzy* relaciona n **variáveis linguísticas antecedentes** X_1, X_2, \dots, X_n , a m **variáveis linguísticas consequentes** Y_1, Y_2, \dots, Y_m , e tem a forma:



onde X_i e Y_j são as variáveis linguísticas e A_i e B_j são seus respectivos valores linguísticos, sendo $i = 1, 2, \dots, n$ e $j = 1, 2, \dots, m$.

Exemplo:

IF **TemperaturaDoGas** é **MuitoAlta** AND **PressaoDoGas** é **Media** THEN
AberturaDaValvula é **QuaseTotal** AND **PotenciaCompressorRefrigeracao** é **Alta**

Computando com variáveis linguísticas e regras de inferência fuzzy:

Seja uma coleção de N regras fuzzy da forma:

IF X é A_i **AND** Y é B_i , **THEN** Z é C_i ,

onde $A_i, B_i, C_i, i = 1, \dots, N$ são *fuzzy sets* e X, Y, Z são os respectivos universos de discurso.

O valor de C inferido a partir da proposição “X é A **AND** Y é B” é obtido por uma Regra de Agregação (usualmente implementada pelo operador max) aplicado sobre uma Regra Composicional de Inferência, que usualmente é a t-norma min (Método de Mamdani) ou o produto algébrico (Método de Larsen), conforme:

$m_i = A_i(a) \wedge B_i(b)$, sendo a e b as variáveis de entrada, $a \in X$ e $b \in Y$.


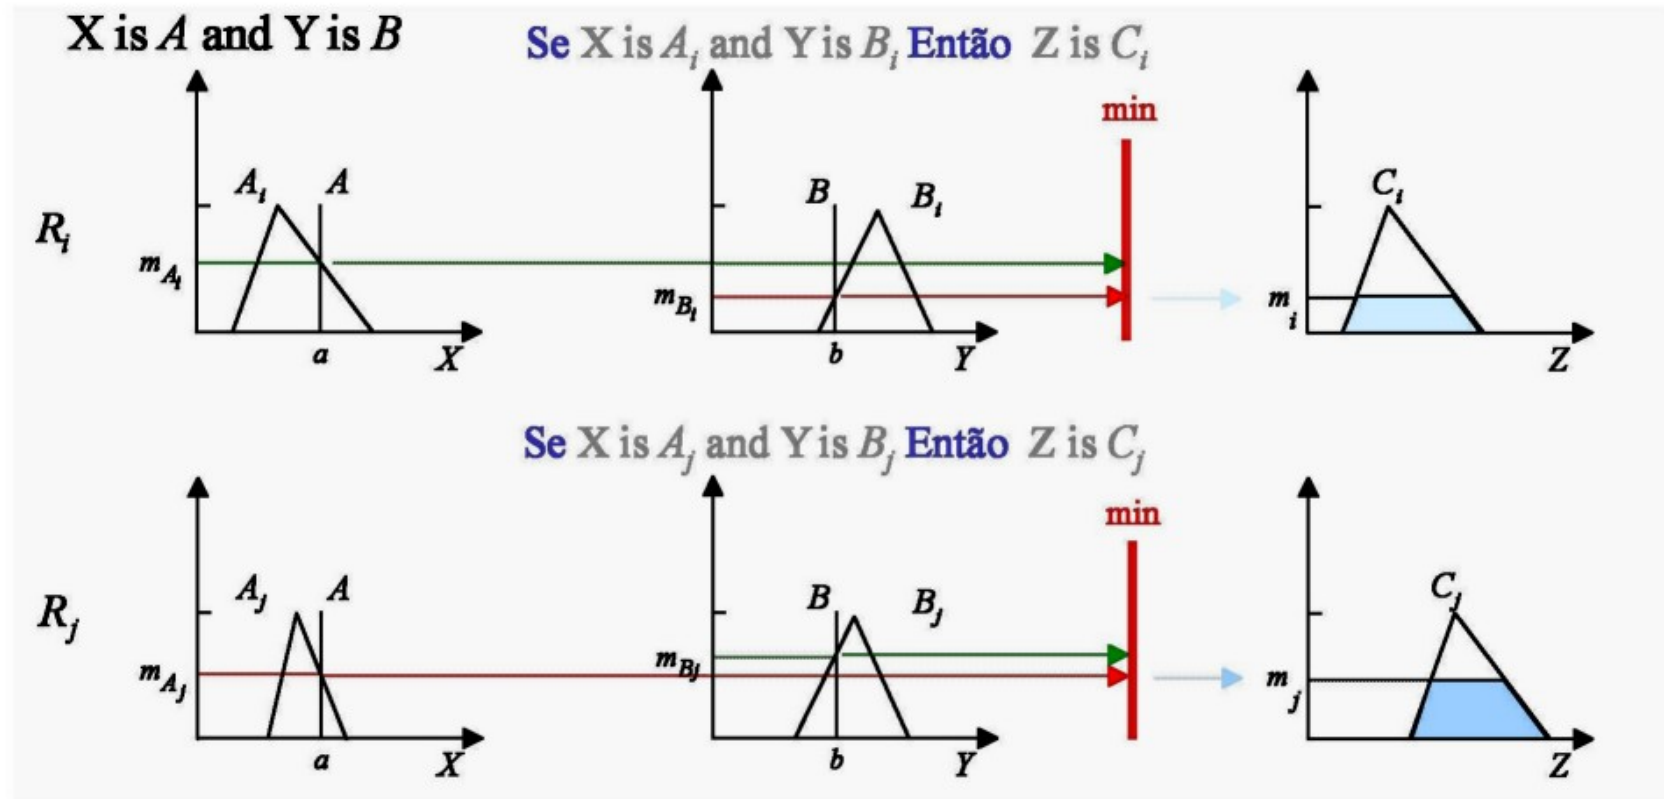
Mamdani (sup-min): $C(z) = \max [m_i \wedge C_i(z), i = 1, \dots, N], \forall z \in Z$

Larsen: $C(z) = \max [m_i \cdot C_i(z), i = 1, \dots, N], \forall z \in Z$

Método de Mamdani

O valor de entrada "a" determina dois *fuzzy sets* adjacentes A_i e A_j no frame de cognição A, aos quais "a" tem pertinência não nula.



O valor de entrada "b" determina dois *fuzzy sets* adjacentes B_i e B_j no frame de cognição B, aos quais "b" tem pertinência não nula.




O valor de entrada "a" determina dois *fuzzy sets* adjacentes A_i e A_j no frame de cognição A, aos quais "a" tem pertinência não nula.

O valor de entrada "b" determina dois *fuzzy sets* adjacentes B_i e B_j no frame de cognição B, aos quais "b" tem pertinência não nula.

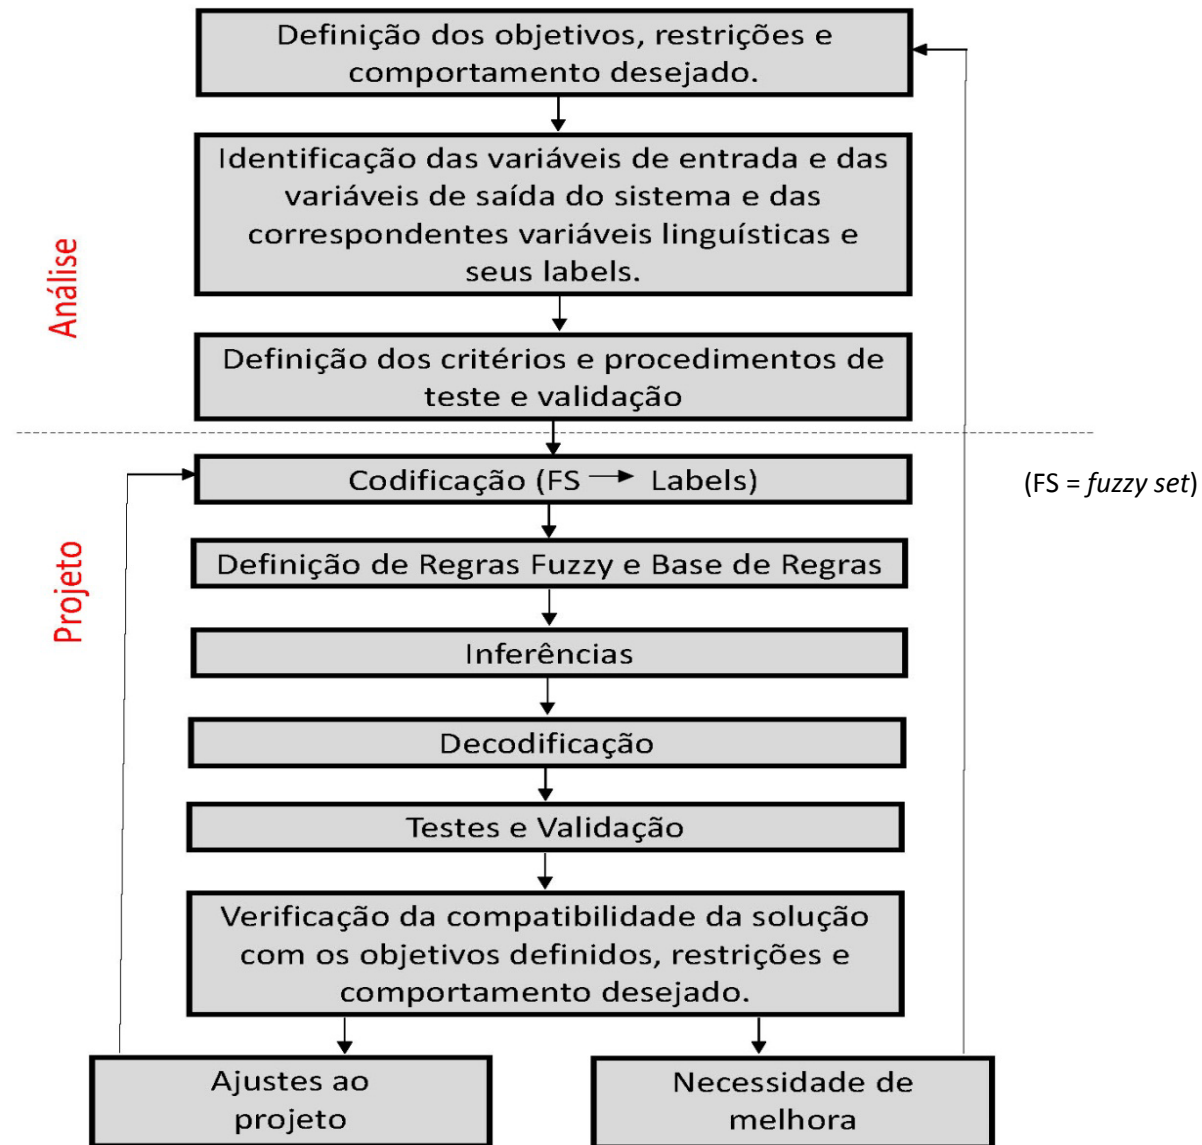
Método de Larsen



$$C_i \cup C_j = C$$



Metodologia p/ projeto e análise de controladores fuzzy:



Estudo de Caso - Controlador *fuzzy* p/ semáforo:



Labels das variáveis de entrada e de saída:

Variáveis de entrada:

Ocupação do Buffer (Alça = Acesso Crítico 1) → **B**

Tamanho da Fila na Av. Ipiranga (Acesso Crítico 2) → **F**

Variáveis de saída:

Tempo de Permanência no Verde → **TV**

Labels das variáveis linguísticas:


B = {Cheio, Parcialmente Cheio, Médio, Parcialmente Vazio, Vazio} = {**C, PC, MB, PV, V**}

F = {Absurdamente Grande, Grande, Média, Pequena, Inacreditavelmente Pequena} = {**A, G, MF, P, I**}

TV = {Máximo, Médio Grande (>Médio), Médio, Médio Pequeno (<Médio), Mínimo} = {**Max, MG, MTV, MP, Min**}

Crítérios de Teste e Validação:

- Verificação no local das condições de tráfego, com e sem o uso do Controlador Fuzzy;
- Medida do tempo médio de espera/veículo/horário/...


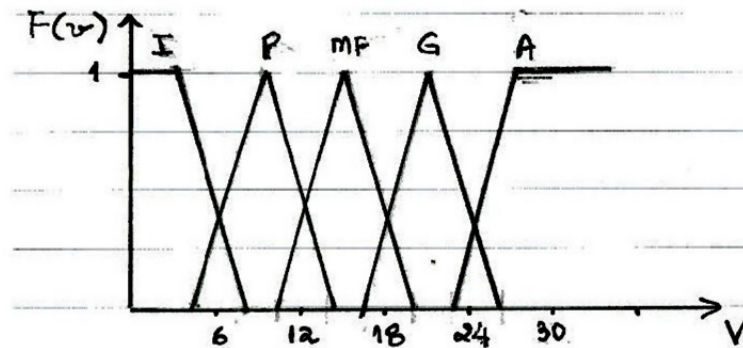
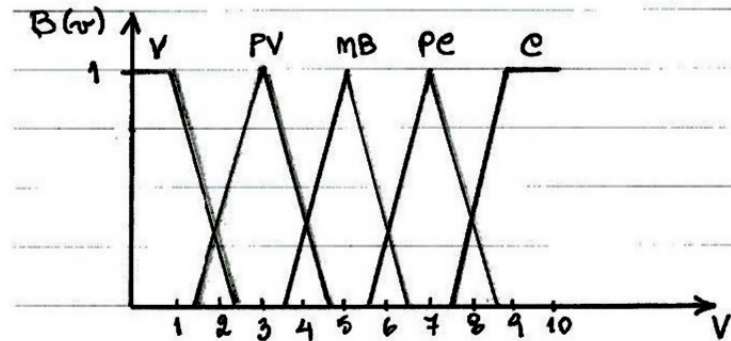


Codificação (resultante da observação dos valores numéricos do problema):

B = {Cheio, Parcialmente Cheio, Médio, Parcialmente Vazio, Vazio} = {C, PC, MB, PV, V}

F = {Absurdamente Grande, Grande, Média, Pequena, Inacreditavelmente Pequena} = {A, G, MF, P, I}

TV = {Máximo, Médio Grande (>Médio), Médio, Médio Pequeno (<Médio), Mínimo} = {Max, MG, MTV, MP, Min}



OBS: OS UNIVERSOS DE DISCURSO DE B E F PODEM CONTER N.ºS NÃO INTEIROS (P.EXPLD, O ESPAÇO DE VISUALIZAÇÃO DE UM CONTADOR PODE CONTER 1,7 VEÍCULOS)

Definição das regras e Base de regras *fuzzy*:

Regra 1	→	“Se o Buffer é Cheio e a Fila é Absurdamente Grande , então o Tempo de Permanência no Verde é Máximo ” “Se B é C e F é A , então TV é Max ”
Regra 2	→	“Se o Buffer é Médio e a Fila é Média , então o Tempo de Permanência no Verde é Médio ” “Se B é MB e F é MF , então TV é MTV ”
Regra 3	→	“Se o Buffer é Parcialmente Cheio e a Fila é Pequena , então o Tempo de Permanência no Verde é Médio Pequeno ” “Se B é PC e F é P , então TV é MP ”
...		
Regra n	→	...

Base de regras *fuzzy* resultante:

B \ F	A	G	MF	P	I
C	Max	Max	MG	MTV	MTV
PC	Max	Max	MG	MP	MP
MB	MG	MG	MTV	MP	MP
PV	MG	MG	MP	Min	Min
V	MTV	MTV	MP	Min	Min



Inferência do valor da variável de saída TV (Tempo de Permanência no Verde) sendo dado os valores para variáveis de entrada B (Ocupação do Buffer) e F (Tamanho da Fila na Av. Ipiranga):

Por exemplo, se $B=4.3$ e $F=16.5$ qual valor resulta para TV?

Regra Fuzzy:



Se B é 4.3 e F é 16.5, então TV é ?

Procedimento a ser adotado:

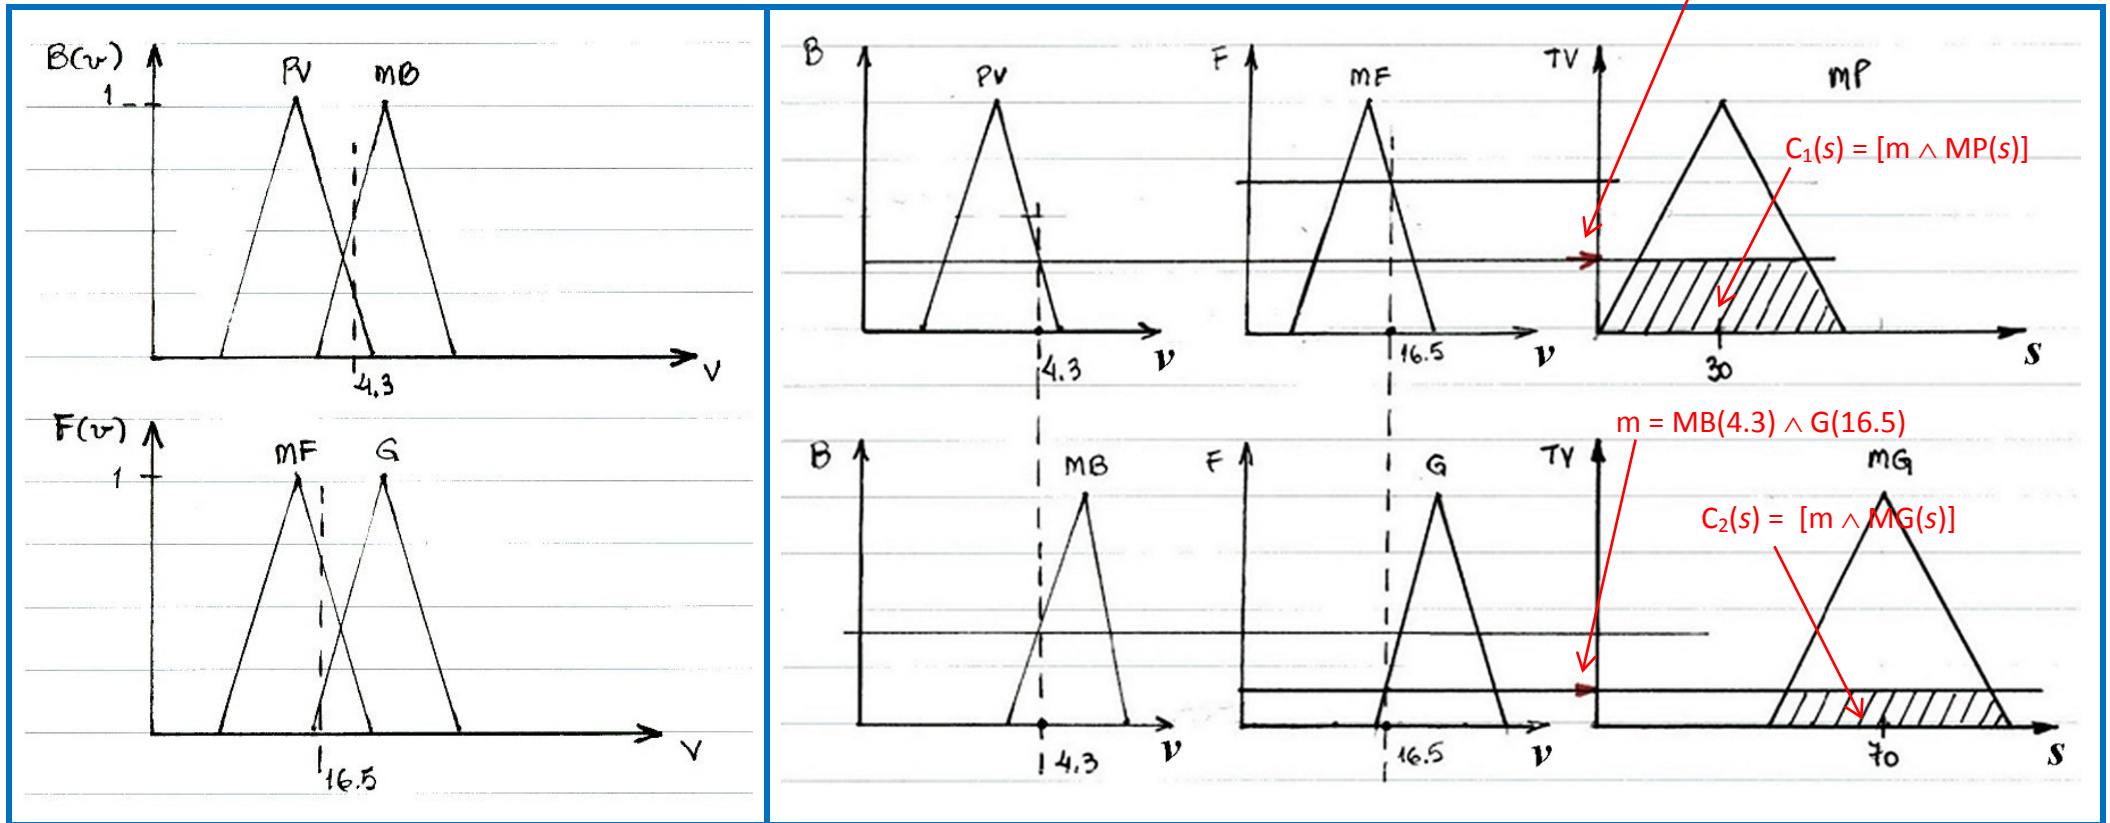
Conjunção: Mamdani

Agregação: Operador Max


Defuzzyficação: Centro de Gravidade



Conjunção (Mamdani):



Agregação max [C1(s), C2(s)] e Decodificação por Centro de Gravidade:



$$\hat{s} = F^{-1}(x) = \frac{\sum_{i=1}^n A(a_i)a_i}{\sum_{i=1}^n A(a_i)}$$

(ver slide 37)

$$\hat{s} = [0.29 (10+20+30+40+50) + 0.13 (60+70+80+90)] / [5 (0.29) + 4 (0.13)]$$

$$\hat{s} = 41.88 \approx 42$$

Se B é 4.3 e F é 16.5, então TV é 42.