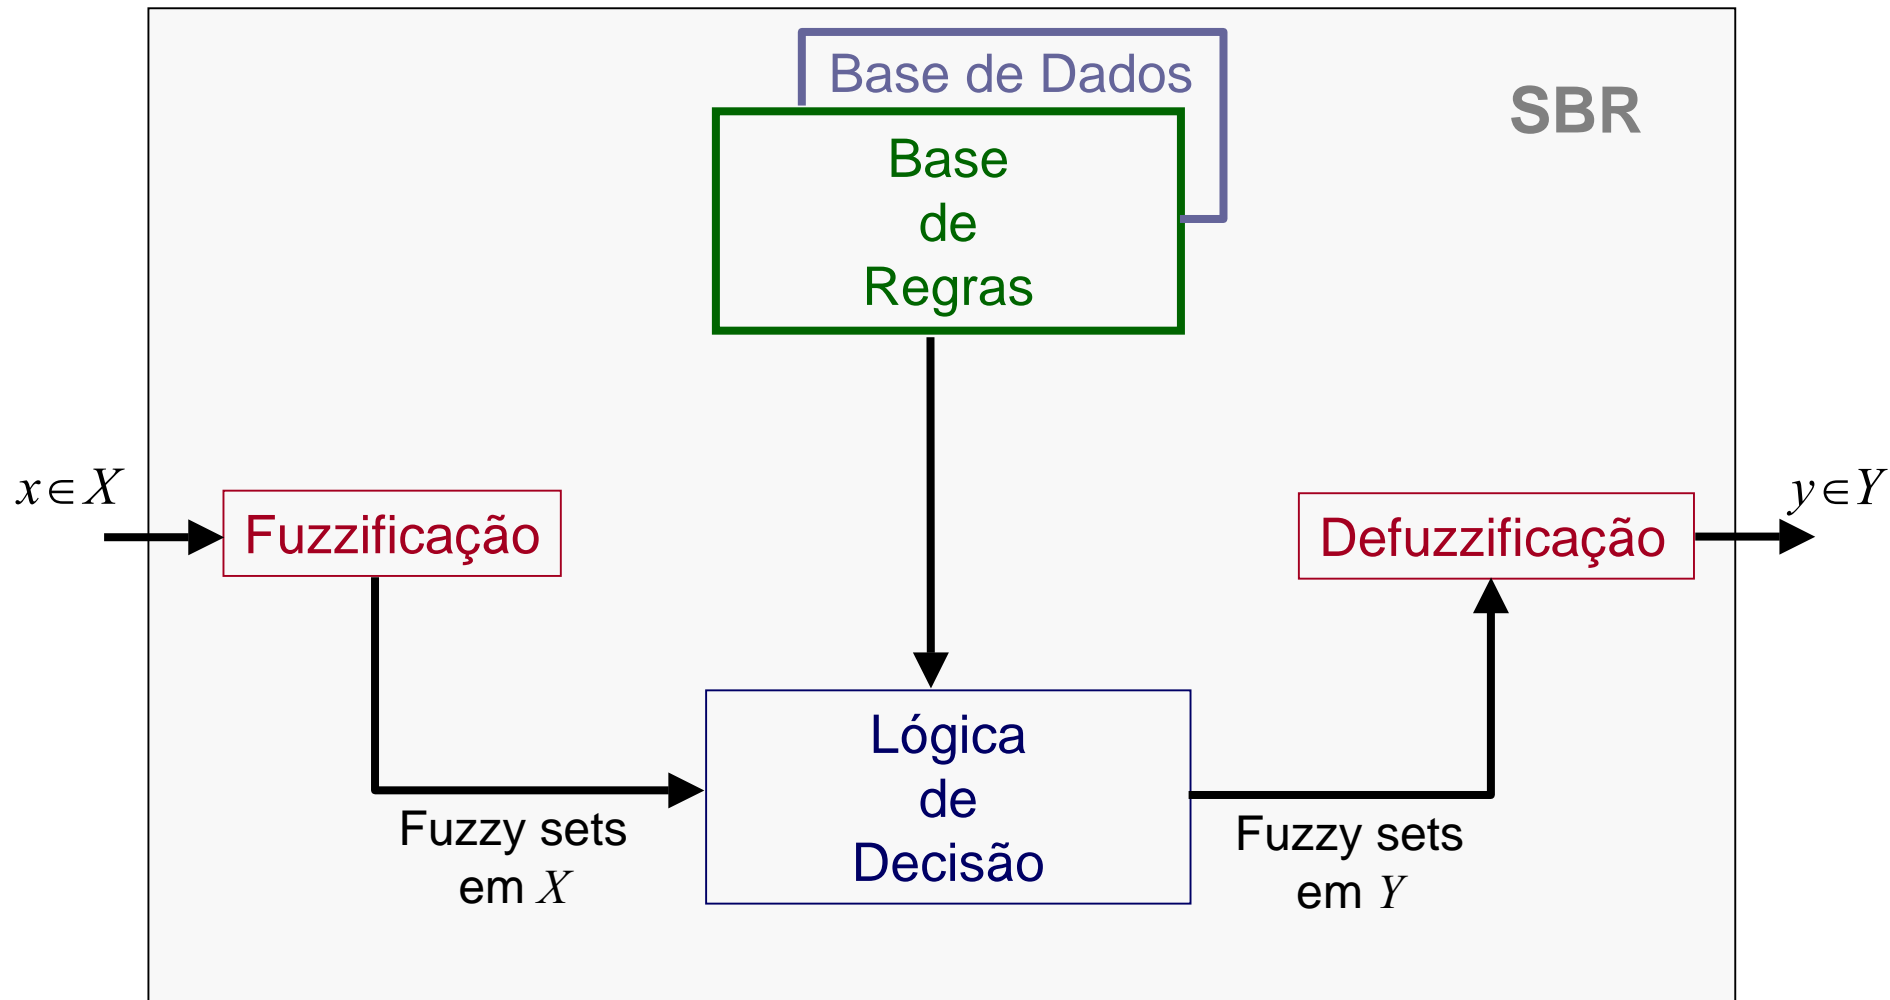


Sistema Baseado em Regras Nebulosas



Geração de Bases de Regras: Método Ingênuo

Dado: conjunto de pares entrada/saida

$$(x_1^1, x_2^1; y^1), (x_1^2, x_2^2; y^2), \dots, (x_1^i, x_2^i; y^i), \dots$$

x_1, x_2 entradas




y saída

Determinar: base Regras Se-Então tal que

$$f : (x_1, x_2) \rightarrow y$$

1-Granularizar espaços de entrada e saída

- determinar universos $[x_1^-, x_1^+]$, $[x_2^-, x_2^+]$, $[y^-, y^+]$
- particionar em $2N+1$ regiões: SN, .., S1, CE, B1, ..., BN



2-Gerar regras a partir dos dados

- determinar graus de ativação
- criar regras correspondentes aos graus mais altos

R1: Se x_1 é B1 e x_2 é S1 então y é CE

R2: Se x_1 é B1 e x_2 é CE então y é B1

3-Atribuir um grau a cada regra

- determinar grau de cada regra $Grau(Regra) = A(x_1).B(x_2).C(y)$
- resolver conflitos escolhendo regra de maior grau

Li-Xin Wang, Adaptive Fuzzy Systems and Control, Prentice Hall, 1994

Geração de Bases de Regras: Método Agrupamento

- Reconhecimento de padrão
 - Processo de busca de estruturas em dados e a classificação destas estruturas em categorias, classes.
 - Estruturas da mesma categoria tem alto grau de associação e estruturas de diferentes categorias tem baixo grau de associação.
- Classificação de objetos em categorias: análise de grupos (*cluster analysis*)
- Problemas principais em reconhecimento de padrões:
 - Sensoriamento (*sensing*) → padrão (*pattern vector*)
 - Extração de características (*feature extraction*)
 - Discriminação (*discrimination function*)

$$x = [x_1 \ x_2 \ \dots \ x_p]$$

Método Baseado em Agrupamento

Seja $X = \{x_1, x_2, \dots, x_n\}$ conjunto de dados

- c -partição fuzzy de X : família de conjuntos fuzzy $P = \{A_1, A_2, \dots, A_c\}$ tal que

$$\sum_{i=1}^c A_i(x_k) = 1 \quad \forall k \in \{1, 2, \dots, n\} = N_n$$

$$0 < \sum_{k=1}^n A_i(x_k) < n \quad \forall i \in \{1, 2, \dots, c\} = N_c$$

- Exemplo

$$X = \{x_1, x_2, x_3\}$$

$$A_1 = 0.6/x_1 + 1/x_2 + 0.1/x_3$$

$$A_2 = 0.4/x_1 + 0/x_2 + 0.9/x_3$$

$\{A_1, A_2\}$ é uma 2-partição de X

Algoritmo *Fuzzy c-Means*

$$\min J_m(P) = \sum_{k=1}^n \sum_{i=1}^c [A_i(x_k)]^m \|x_k - v_i\|^2$$

sa

$$\sum_{i=1}^c A_i(x_k) = 1 \quad \forall k \in N_n$$

$$0 < \sum_{k=1}^n A_i(x_k) < n \quad \forall i \in N_c$$

$$x_k \in R^p$$

$v_i \in R^p$ = centros dos grupos (*cluster centers*), $i = 1, \dots, c$

1 – Seja $t = 0$. Seleccionar uma partição inicial $P^{(0)}$.

2 – Calcular centros grupos $v_1^t, v_2^t, \dots, v_c^t$ para $P^{(t)}$ e valor escolhido de m .

$$v_i = \frac{\sum_{k=1}^n [A_i(x_k)]^m x_k}{\sum_{k=1}^n [A_i(x_k)]^m}, \quad m > 1$$

3 – Atualizar $P^{(t+1)}$: para cada $x_k \in X$, se $\|x_k - v_i^t\|^2 > 0 \forall i \in N_c$ então

$$A_i^{(t+1)}(x_k) = \left[\sum_{j=1}^c \left(\frac{\|x_k - v_i^t\|^2}{\|x_k - v_j^t\|^2} \right)^{\frac{1}{m-1}} \right]^{-1}$$

Se $\|x_k - v_i^t\|^2 = 0$ para algum $i \in I \subseteq N_c$, então definir $A_i^{t+1}(x_k)$ para $i \in I$ como qualquer número real não negativo que satisfaça

$$\sum_{i \in I} A_i^{(t+1)}(x_k) = 1 \text{ e definir } A_i^{(t+1)}(x_k) = 0 \text{ para } i \in N_c - I.$$

4 – Comparar $P^{(t)}$ e $P^{(t+1)}$. Se $|P^{(t+1)} - P^{(t)}| \leq \varepsilon$ então parar.

Senão $t = t + 1$, ir para o passo 2.

Nota: $|P^{(t+1)} - P^{(t)}|$ é uma distância em $R^{n \times c}$, como por exemplo

$$|P^{(t+1)} - P^{(t)}| = \max_{i \in N_c, k \in Nn} |A_i^{(t+1)}(x_k) - A_i^{(t)}(x_k)|$$

- *valor ótimo de m ainda desconhecido*
- *algoritmo converge para $m \in (0, \infty)$ (Bezdek, 1981)*

J. Bezdek and S. Pal, Fuzzy Models for Pattern Recognition, IEEE Press, 1992

Adaptação de Bases de Regras: Método do Gradiente

R^i : If x_1 is F_1^i and ...and x_n is F_n^i then y is G^i ($A^i \rightarrow G^i$)

F_j^i fuzzy set de X_j , G^i fuzzy set de Y

$x = (x_1 \ x_2 \ \dots \ x_n) \in X_1 \times X_2 \times \dots \times X_n = X$

$i = 1, 2, \dots, M \rightarrow M$ regras

Conjunção *and* : produto

Regra *If-then* : produto

Inferência : composição *sup-produto*

Entrada : ponto $x \in X \subseteq R^n$ *singleton* do R^n

Li-Xin Wang, Adaptive Fuzzy Systems and Control, Prentice Hall, 1994

Defuzzificação : média dos centros (*center average*)

$$y = \frac{\sum_{i=1}^M \bar{y}^i B^i(\bar{y}^i)}{\sum_{i=1}^M B^i(\bar{y}^i)} \quad \text{onde } \bar{y}^i \text{ é o valor modal de } G^i \text{ (normal e unimodal)}$$

$$B^i(y) = \sup_{x \in X} [R^i(x, y) \cdot A^i(x)] \quad (t = \text{produto})$$

$$R^i(x, y) = [\prod_{j=1}^n F_j^i(x)] \cdot G^i(y) = A^i(x) \cdot G^i(y)$$

$$A^i(x) = \prod_{j=1}^n F_j(x)$$

- Neste caso, o sistema baseado em regras tem a forma:

$$y = f(x) = \frac{\sum_{i=1}^M \bar{y}^i \left(\prod_{j=1}^n F_j^i(x_j) \right)}{\sum_{i=1}^M \left(\prod_{j=1}^n F_j^i(x_j) \right)}, \text{ supondo } G^i \text{ normal e unimodal } \forall i$$

$$f(x) = \frac{\sum_{i=1}^M \bar{y}^i B^i(\bar{y}^i)}{\sum_{i=1}^M B^i(\bar{y}^i)} \quad ; \quad B^i(\bar{y}^i) = \sup_{x' \in X} \left[\prod_{j=1}^n F_j^i(x'_j) \cdot G^i(\bar{y}^i) \cdot A'(x') \right]$$

$A'(x') = 1$ se $x' = x$ e $A'(x') = 0 \quad \forall x' \neq x \rightarrow$ supremo para $x' = x$

Logo

$$B^i(\bar{y}^i) = \prod_{j=1}^n F_j^i(x'_j) \cdot G^i(\bar{y}^i) \cdot A'(x') = \prod_{j=1}^n F_j^i(x'_j)$$

pois G^i é normal e unimodal $G^i(\bar{y}^i) = 1$.

- Funções de pertinência Gaussianas

$$F_j^i(x_i) = a_j^i \exp \left[- \left(\frac{x_i - \bar{x}_j^i}{\sigma_j^i} \right)^2 \right]$$

a_j^i , \bar{x}_j^i , σ_j^i são parâmetros ajustáveis

$$f(x) = \frac{\sum_{i=1}^M \bar{y}^i \left[\prod_{j=1}^n a_j^i \exp \left(- \left(\frac{x_j - \bar{x}_j^i}{\sigma_j^i} \right)^2 \right) \right]}{\sum_{i=1}^M \left[\prod_{j=1}^n a_j^i \exp \left(- \left(\frac{x_j - \bar{x}_j^i}{\sigma_j^i} \right)^2 \right) \right]}$$

Algoritmo de Adaptação via Gradiente

- dado (x^P, d^P) , $x^P \in X$, $d^P \in Y$ (supondo $a_j^i = 1$)

determinar \bar{y}^i , \bar{x}_j^i e σ_j^i , $i \in N_M$, $j \in N_n$ tal que

$$\min e^P = \min_{\bar{y}^i, \bar{x}_j^i, \sigma_j^i} \frac{1}{2} [f(x^P) - d^P]^2$$

- $\bar{y}^i(k+1) = \bar{y}^i(k) - \alpha \left. \frac{\partial e}{\partial \bar{y}^i} \right|_k$, $i \in N_M$

Fazendo $a = \sum_{i=1}^M \bar{y}^i z^i$, $b = \sum_{i=1}^M z^i$, $z^i = \prod_{j=1}^n \exp\left(-\left[(x_j - \bar{x}_j^i)/\sigma_j^i\right]^2\right)$

$$\frac{\partial e}{\partial \bar{y}^i} = (f - d) \frac{\partial f}{\partial a} \frac{\partial a}{\partial \bar{y}^i} = (f - d) \frac{1}{b} z^i$$

- $\bar{y}^i(k+1) = \bar{y}^i(k) - \alpha \frac{(f-d)}{b}, i \in N_M$

$$\bar{x}_j^i(k+1) = \bar{x}_j^i(k) - \beta \left. \frac{\partial e}{\partial \bar{x}_j^i} \right|_k$$

$$\frac{\partial e}{\partial \bar{x}_j^i} = (f-d) \frac{\partial f}{\partial z^i} \frac{\partial z^i}{\partial \bar{x}_j^i} = (f-d) \frac{\bar{y}^i - f}{b} z^i \frac{2(x_j^p - \bar{x}_j^i(k))}{[\sigma_j^i(k)]^2}$$

- $\bar{x}_j^i(k+1) = \bar{x}_j^i(k) - \beta (f-d) \frac{\bar{y}^i - f}{b} z^i \frac{2(x_j^p - \bar{x}_j^i(k))}{[\sigma_j^i(k)]^2}, j \in N_n, i \in N_M$

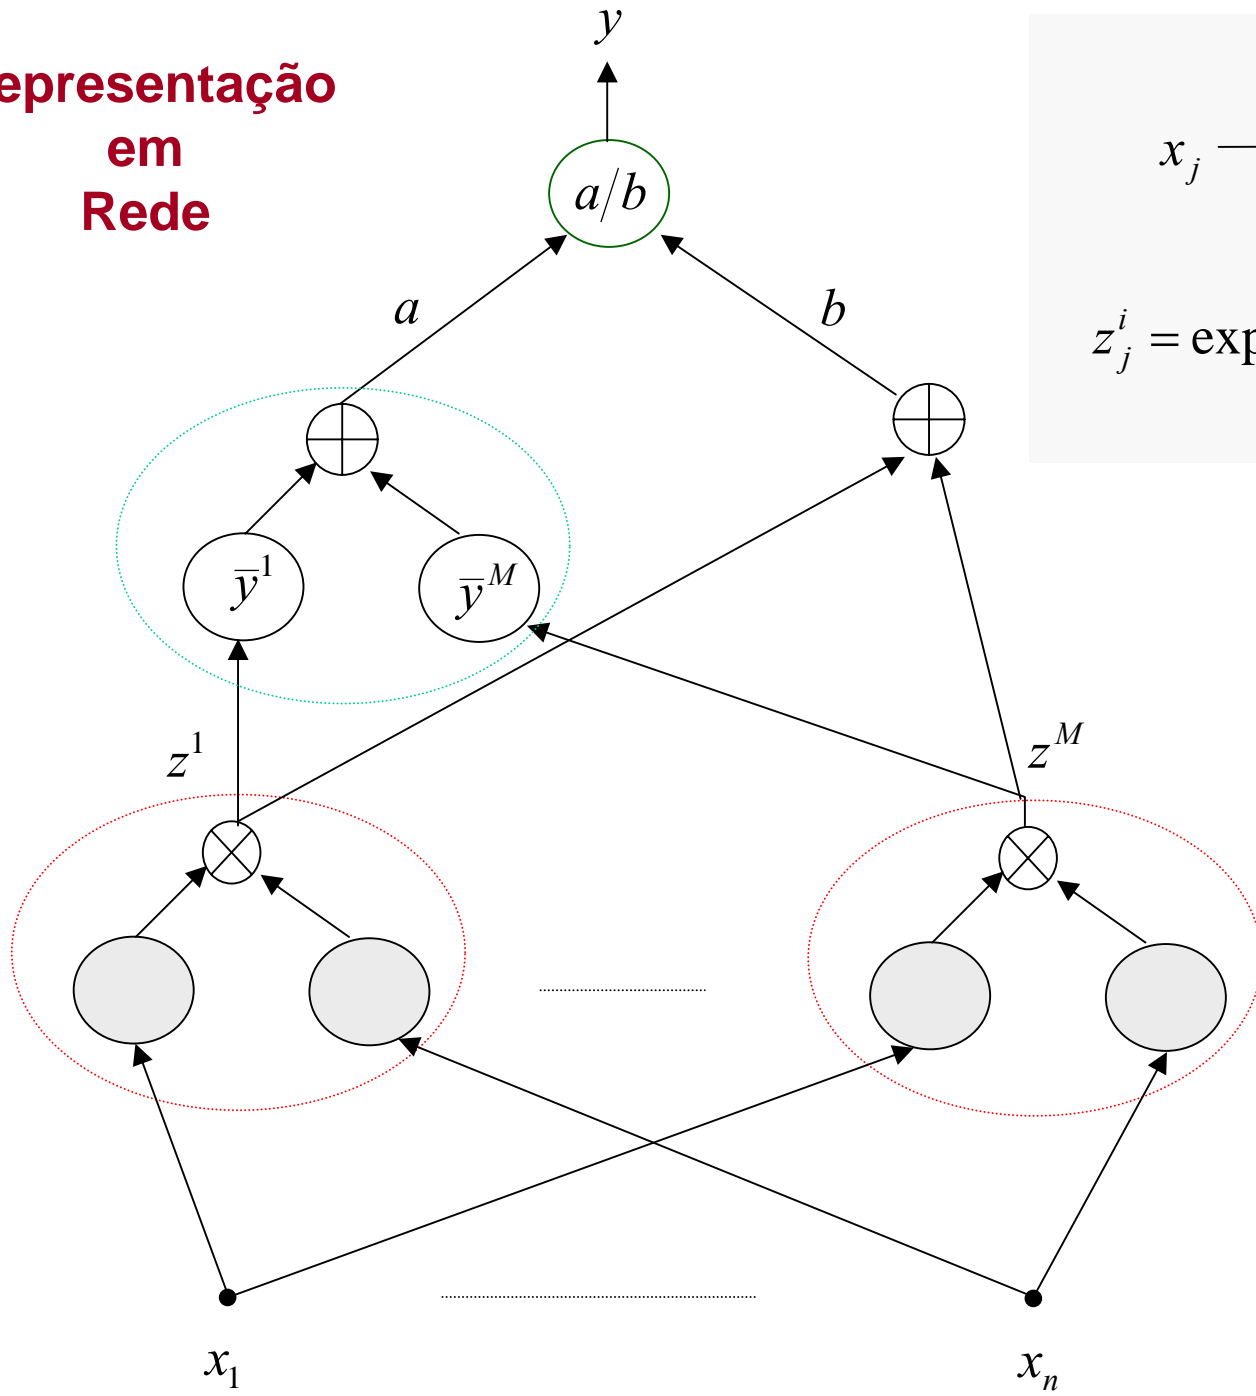
- $\sigma_j^i(k+1) = \sigma_j^i(k) - \gamma (f-d) \frac{\bar{y}^i - f}{b} z^i \frac{2[x_j^p - \bar{x}_j^i(k)]^2}{[\sigma_j^i(k)]^3}, j \in N_n, i \in N_M$

Representação em Rede

3

2

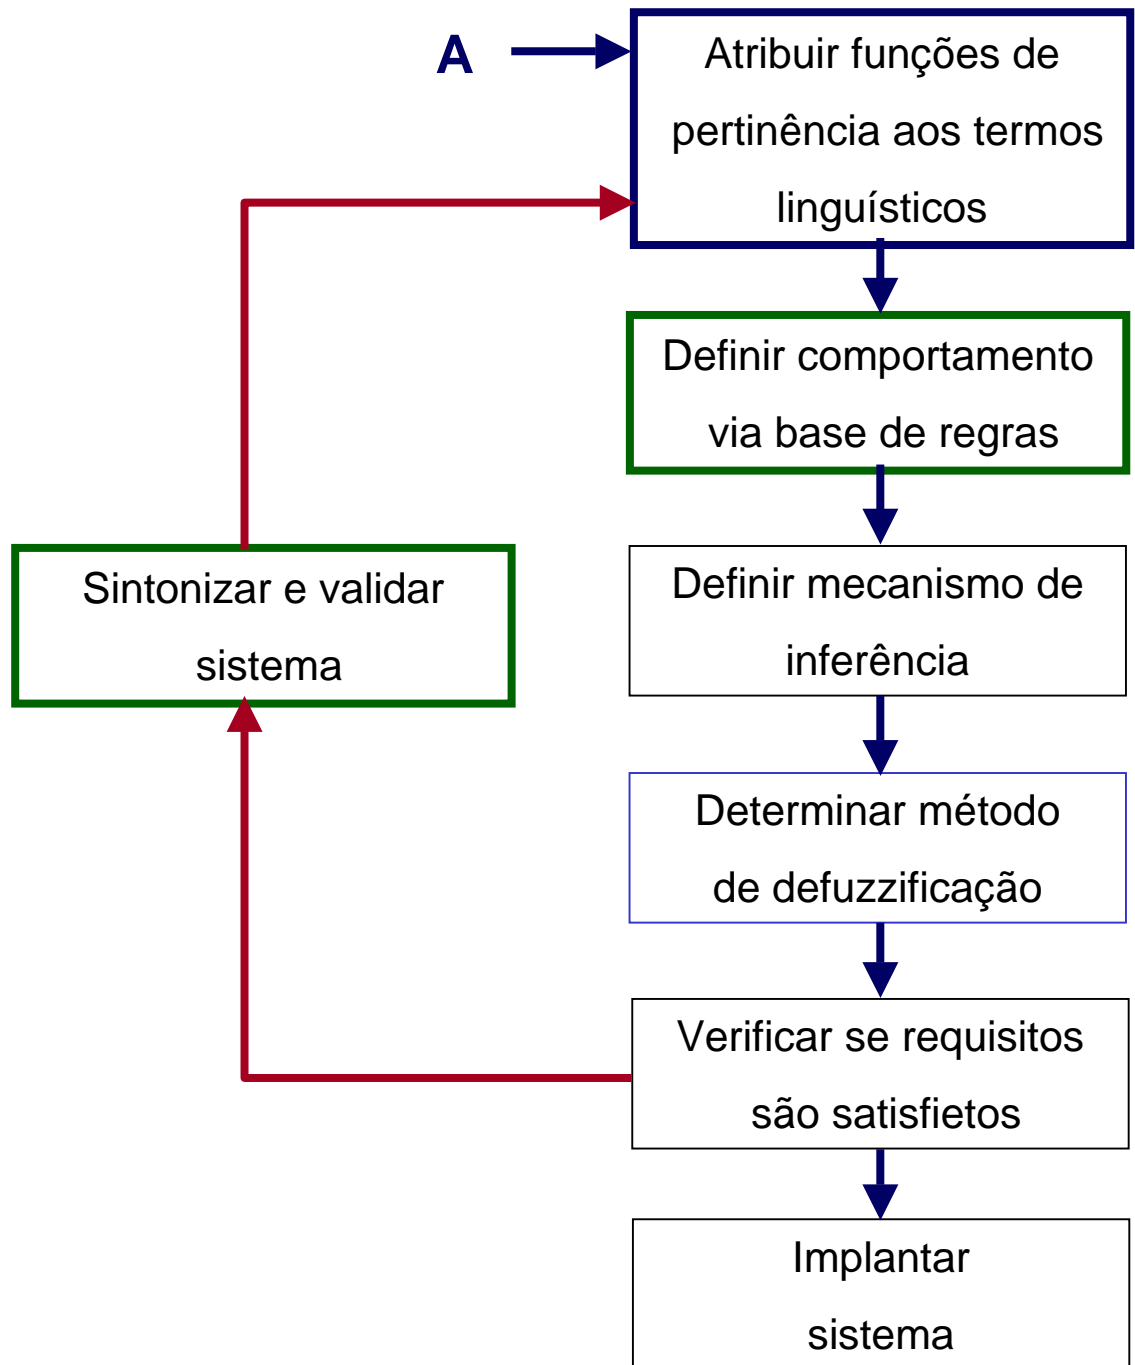
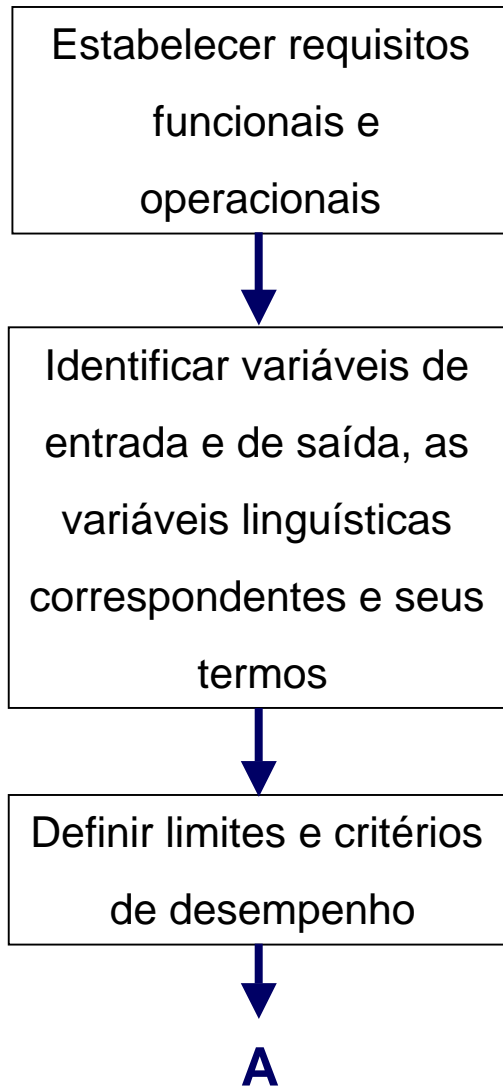
1



$x_j \rightarrow \text{circle} \rightarrow z_j^i$

$$z_j^i = \exp[-(x_i - \bar{x}_j^i)^2 / (\sigma_j^i)^2]$$

Projeto SBR



Este material não pode ser reproduzido sem autorização prévia dos autores. Quando autorizado, seu uso é exclusivo para atividades de ensino e pesquisa em instituições sem fins lucrativos.