

-
-
-
-
-

IF-705 – Automação Inteligente

Sistemas Nebulosos para Modelagem

Aluizio Fausto Ribeiro Araújo
Universidade Federal de Pernambuco
Centro de Informática - CIn
Departamento de Sistemas da Computação
aluizioa@cin.ufpe.br



-
-
-
-
-

Sumário

1. Introdução

2. Modelagem de sistemas nebulosos (*fuzzy systems*)

3. Abordagens para modelagem de sistemas nebulosos

- Modelagem Direta
- Modelagem baseada na identificação de sistemas clássica
- Modelagem de aprendizagem consecutiva
- Modelagem bio-inspirada
 - ✓ *Neuro-fuzzy*
 - ✓ Modelagem difusa evolucionária

4. Exemplo da modelagem Nebulosa



Introdução

O que é modelar?

É representar um sistema físico real, ou parte dele, em forma física ou simbólica, convenientemente preparada para predizer ou descrever o seu comportamento.

Modelagem: é a atividade de construir o modelo para representar o sistema físico real.

Porque é necessário modelar situações reais?

- Para se realizar ensaios e experimentos de uma forma real.
- Para reduzir custos.
- Solução direta de vários problemas pode ser arriscada e/ou difícil, a modelagem pode ampliar entendimento sobre soluções para, em seguida, colocá-los em operação.
- Necessidade de planejamento preliminar.



Introdução

Tipos de Modelagem:

1. Modelagem Matemática

Obtém-se um modelo idealizado do processo a ser controlado, geralmente na forma de equações diferenciais ou equações de diferenças.

2. Modelagem Experimental ou identificação de sistemas

Usa dados experimentais, entrada-saída da planta ou processo para determinar o modelo matemático (**planta desconhecida**).

3. Modelagem Heurística

Consiste em se realizar uma tarefa de acordo com a experiência prévia, com regras práticas ou “dicas” das estratégias utilizadas. **Identifica-se (modela-se) o comportamento do operador de controles (operador humano).**

Uma regra heurística pode ser uma implicação lógica do tipo:

If condição **Then** ação



Introdução

Vantagens da Modelagem Heurística:

- Possibilita usar expressões linguísticas em vez de numéricas.
- Inexistência de restrição a priori.
- Semelhança com o método experimental.
- Construção da função de transferência entrada saída não-matemática.
- Operação em plantas industriais não completamente compreendidas, processos mal definidos e sistemas com dinâmica não conhecida:
 - ✓ sistemas complexos que são difíceis ou impossíveis de modelar;
 - ✓ sistemas controlados por especialistas [humanos];
 - ✓ sistemas com entradas e saídas complexas e contínuas;
 - ✓ sistemas naturalmente “vagos”, como os que envolvem ciências sociais e comportamentais, cuja descrição é extremamente complexa.

Introdução

Desvantagens da Modelagem Heurística:

- Estacionaridade. Sistemas *fuzzy* são estáticos, não sendo capazes de se adaptar a contextos extremamente dinâmicos.
- Definir boas funções de pertinência e regras nebulosas não são tarefas fáceis. Questões como o porquê de um determinado sistema especialista nebuloso precisa de tantas regras, ou quando um desenvolvedor pode parar de adicionar mais regras não são facilmente respondidas.
- A verificação e validação de um sistema especialista nebuloso geralmente requer testes extensivos. Muitos desenvolvedores não conseguem fazer isso ou mesmo as circunstâncias não permitem vários testes.
- Falta de capacidade de aprendizagem. Pelo fato de serem estáticos, sistemas nebulosos muitas vezes são definidos sem aprendizagem.

Introdução

Pesquisas ligadas a hibridização com outras técnicas:

- Combinação (hibridização) de sistemas nebulosos com outras técnicas a fim de prover adaptabilidade:
 - ✓ redes neurais [artificiais] (*neuro-fuzzy systems*, em inglês);
 - ✓ algoritmos evolucionários;
- Redução da dependência do especialista;
- Aumento do poder do mecanismo de raciocínio para lidar com mudanças.

Modelagem de Sistemas Nebulosos

Necessidade de encontrar um *trade-off* entre acurácia e interpretabilidade.

✓ Prover uma alta precisão numérica juntamente com baixa perda do poder descritivo.

Os modelos difusos podem ser construídos basicamente de duas maneiras:

1. Como sistemas especialistas difusos, usando o conhecimento humano.
2. Usando dados numéricos e técnicas de identificação adequadas.



8

Passos para Modelagem de Sistemas Nebulosos

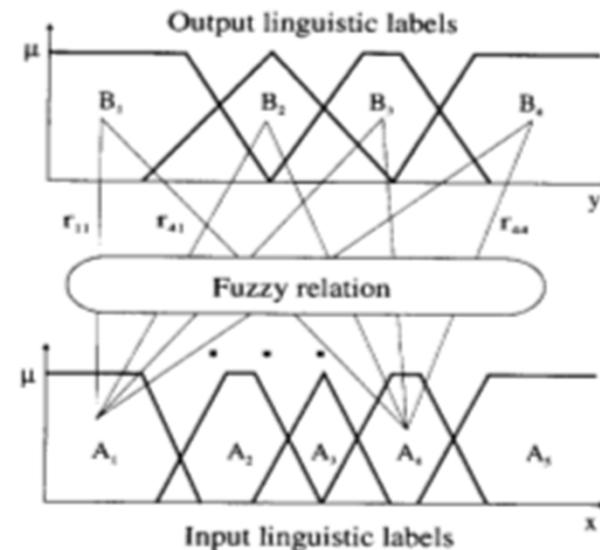
Considere o seguinte sistema não linear:

$$\begin{cases} \delta x(t) = f_1(x(t)) + g_1(x(t))u(t) + g_2(x(t))\omega(t) \\ y(t) = f_2(x(t)) + g_3(x(t))\omega(t) \\ z(t) = f_3(x(t)) + g_4(x(t))u(t) \end{cases}$$

Os passos para a modelagem de uma planta com a estrutura anterior:

1. Especificar o problema e definir as variáveis linguísticas;

✓ Especificação do problema em termos de conhecimento de engenharia, ou seja, definir as variáveis de entrada e de saída, assim como seus respectivos intervalos de valores.



Passos para Modelagem de Sistemas Nebulosos

2. Definir os conjuntos *fuzzy*;

✓ É preciso manter a interseção suficiente entre conjuntos adjacentes, de modo que a mudança entre os conceitos seja o mais suave possível.

✓ Os conjuntos *fuzzy* com forma triangular ou trapezoide frequentemente fornecem uma representação adequada do conhecimento especialista e, ao mesmo tempo, simplifica significativamente o processo de computação.

✓ Um número maior de conjuntos *fuzzy* torna o funcionamento do sistema mais preciso.

✓ Conjunto *Fuzzy*: $\mathfrak{F}_\varrho^l (\varrho = 1, 2, \dots, \varphi)$

Passos para Modelagem de Sistemas Nebulosos

3. Definir as funções de pertinência;

Reflete o conhecimento que se tem em relação a intensidade com que o objeto pertence ao conjunto *fuzzy*.

✓ Funções de pertinência normalizadas $\mu_l[x(t)]$:

$$\mu_l[x(t)] := \frac{\prod_{\phi=1}^{\varphi} \mu_{l\phi}[\theta_{\phi}(x(t))]}{\sum_{\zeta=1}^r \prod_{\phi=1}^{\varphi} \mu_{\zeta\phi}[\theta_{\phi}(x(t))]} \geq 0, \quad \sum_{l=1}^r \mu_l[x(t)] = 1$$

✓ onde: $\mu_{l\phi}[\theta_{\phi}(x(t))]$ é o grau de pertinência de $\theta_{\phi}(x(t))$ em \mathfrak{F}_{ϕ}^l .

Passos para Modelagem de Sistemas Nebulosos

4. Construir as regras nebulosas;

- ✓ Adquirir o conhecimento envolvido, através de entrevistas com especialistas, no intuito de descrever como o problema pode ser resolvido usando variáveis linguísticas, ou através de outras fontes de conhecimento.
- ✓ Representar as regras nebulosas em forma de matriz (memória associativa *fuzzy* – MAF), cada coordenada representando uma variável linguística de entrada e o valor de uma célula representando um valor da variável de saída.
- ✓ Com base na memória associativa que relaciona as variáveis linguísticas, é possível então definir as regras nebulosas.

Passos para Modelagem de Sistemas Nebulosos

4. Construir as regras *fuzzy*;

✓ Regras *fuzzy* da planta:

\mathcal{R}^l : IF $\theta_1(x(t))$ is \mathcal{F}_1^l and $\theta_2(x(t))$ is \mathcal{F}_2^l and \dots and $\theta_\varphi(x(t))$ is \mathcal{F}_φ^l , THEN

$$\begin{cases} \delta x(t) = A_l x(t) + B_l u(t) + D_l \omega(t) \\ y(t) = C_l x(t) + M_l \omega(t) \\ z(t) = L_l x(t) + N_l u(t), \quad l \in \{1, 2, \dots, r\} \end{cases}$$

- \mathcal{R}^l : l -ésima regra de inferência nebulosa;
- r : é o número de regras de inferências;
- \mathcal{F} : conjuntos nebulosos;
- θ : premissas;
- $(A^l, B^l, D^l, L^l, M^l, N^l)$: l -ésimo modelo local do sistema.

13



Passos para Modelagem de Sistemas Nebulosos

5. Especificar os procedimentos para realizar a inferência no sistema;

✓ Com base em uma inferência de produto, fuzzyficação única e defuzzyficação de média central, o modelo dinâmico pode ser descrito pelo seguinte modelo global:

$$\begin{cases} \delta x(t) = A(\mu)x(t) + B(\mu)u(t) + D(\mu)\omega(t) \\ y(t) = C(\mu)x(t) + M(\mu)\omega(t) \\ z(t) = L(\mu)x(t) + N(\mu)u(t) \end{cases}$$

onde:

$$\begin{cases} A(\mu) = \sum_{l=1}^r \mu_l A_l \\ B(\mu) = \sum_{l=1}^r \mu_l B_l & C(\mu) = \sum_{l=1}^r \mu_l C_l \\ D(\mu) = \sum_{l=1}^r \mu_l D_l & L(\mu) = \sum_{l=1}^r \mu_l L_l \\ M(\mu) = \sum_{l=1}^r \mu_l M_l & N(\mu) = \sum_{l=1}^r \mu_l N_l \end{cases}$$

✓ Conjunto *fuzzy* inferido: $\mathcal{F}^l := \prod_{\phi=1}^{\varphi} \mathcal{F}_{\phi}^l$

14



Passos para Modelagem de Sistemas Nebulosos

6. Codificar os conjuntos e regras nebulosas e os procedimentos para realizar a inferência no sistema;

✓ Implementar o sistema especialista utilizando:

- Uma linguagem de programação (C/C++, Java), opção preferida dos desenvolvedores experientes que provê uma maior flexibilidade, ou;
- Uma ferramenta de desenvolvimento para sistema nebuloso (como, por exemplo, o *Fuzzy Knowledge Builder™*), o que confere um rápido desenvolvimento e prototipagem de um sistema especialista.

7. Avaliar e melhorar o sistema.

✓ Verificar se o sistema atende aos requisitos especificados inicialmente no projeto, avaliando-se o mesmo e definindo-se possíveis melhorias (se for pertinente). ***A opinião do especialista é importante, pois ele pode estar ou não satisfeito com o sistema.***

15



Passos para Modelagem de Sistemas Nebulosos

7. Avaliar e melhorar o sistema.

✓ As melhorias que podem ser feitas no intuito de melhorar o desempenho de um sistema especialista nebuloso pode envolver um conjunto de ações:

1. Rever o modelo das variáveis de entrada e de saída e se é necessário redefinir seus intervalos;
2. Rever os conjuntos nebulosos e se é necessário definir conjuntos adicionais com relação ao domínio (universo do discurso);
3. Rever a forma dos conjuntos nebulosos, se é necessário alterá-la no intuito de prover uma maior precisão;
4. Fornecer sobreposição suficiente entre conjuntos nebulosos adjacentes (recomendado: 25% a 50% nas bases);

16

Passos para Modelagem de Sistemas Nebulosos

7. Avaliar e melhorar o sistema.

✓ As melhorias que podem ser feitas no intuito de aumentar o desempenho de um sistema especialista nebuloso pode envolver um conjunto de ações:

5. Verificar se a inclusão de modificadores nos conjuntos nebulosos pode melhorar o desempenho do sistema;
6. Rever as regras nebulosas e se é necessário adicionar novas regras à base de regras;
7. Ajustar o peso de execução das regras (a maioria das ferramentas para sistemas nebulosos permite o controle da importância das regras).

Abordagens para Modelagem de Sistemas Nebulosos

Existe um grande número de métodos para modelagem de sistemas nebulosos, que diferem quanto a:

1. Estratégia de busca utilizada e;
2. Quantidade/tipos de parâmetros que podem buscar.

Modelagem de sistemas nebulosos direta

- ✓ Nesta abordagem, primeiro o sistema é linguisticamente definido com base no conhecimento *a priori* oriundo do especialista.
- ✓ Posteriormente tal definição é transformada em uma estrutura formal de modelo nebuloso, seguindo os passos anteriormente mostrados.
- ✓ Considera mais intuição e experiência do que uma teoria precisa.

✓ Ex. Modelagem no espaço de estado:

IF $\xi(k)$ is A_i and u_k is B_i

THEN
$$\begin{cases} \xi_i(k+1) = A_i \xi(k) + B_i u(k) \\ y_i(k) = C_i \xi(k) \end{cases}$$

18



Abordagens para Modelagem de Sistemas Nebulosos

Abordagem baseada na identificação de algoritmos clássica

- Um modelo nebuloso é um tipo especial de modelo não-linear;
- A modelagem difusa pode ser realizada através da aplicação de algum método de identificação clássico;

- Ex. Non-linear ARX (NARX):

$$\hat{y}(k+1) = F(y(k), \dots, y(k-n+1), u(k), \dots, u(k-m+1))$$

- Regras *Fuzzy*:

IF $y(k)$ is $A_{i,1}$ **and** ... $y(k-n+1)$ is $A_{i,n}$ **and** $u(k)$ is $B_{i,1}$ **and** ... $u(k-m+1)$ is $B_{i,m}$

$$\text{THEN } \hat{y}(k+1) = \sum_{j=1}^n a_{i,j} y(k-j+1) + \sum_{j=1}^m b_{i,j} u(k-j+1) + c_i$$

onde $a_{i,j}$, $b_{i,j}$ e c_i são os parâmetros do NARX.

19



Abordagens para Modelagem de Sistemas Nebulosos

Abordagem de aprendizagem construtiva

- O conhecimento *a priori* serve diretamente o processo de busca ao invés de ser utilizado diretamente na construção de parte, ou de todo, o sistema nebuloso;
- Após a definição guiada pelo especialista dos parâmetros lógicos e de alguns parâmetros estruturais (variáveis relevantes e universo de discurso), uma sequência de algoritmos de aprendizado é aplicada;
- Utilizam um determinado critério de performance para a construção de um sistema nebuloso;
 - ✓ Aplicação de técnicas de poda, que ajudam a reduzir o tamanho do sistema, não deixando de observar a obtenção de uma acurácia aceitável.

20



Abordagens para Modelagem de Sistemas Nebulosos

Abordagens bio-inspiradas

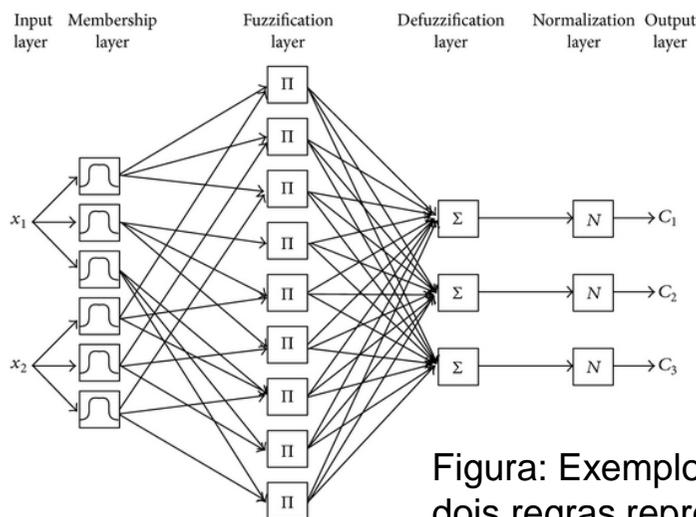
- Redes Neurais Artificiais, Algoritmos Evolucionários e Lógica difusa pertencem a mesma família de metodologias bio-inspiradas;
- Modelam diferentes extensões de processos naturais, como, aprendizado, evolução e raciocínio;
- A união dessas técnicas tem como objetivo utilizar seus pontos positivos e superar seus pontos negativos, originando as técnicas híbridas conhecidas como sistemas *neuro-fuzzy* e modelagem difusa evolucionária.

Abordagens para Modelagem de Sistemas Nebulosos

Abordagens bio-inspiradas: Sistemas *neuro-fuzzy* híbridos

Existem três linhas de pesquisa para desenvolvimento de sistemas *neuro-fuzzy*:

- Extração de regras difusas a partir de redes neurais: Nessa abordagem tenta-se a extração de regras, no formato nebuloso, do conhecimento embutido em uma rede neural treinada;
- Sistemas *neuro-fuzzy*: são implementações de sistemas de inferência nebulosos juntamente com redes neurais.



- Sistemas *neuro-fuzzy* orientados a interpretabilidade: são construídos respeitando certas restrições relacionadas a interpretabilidade, para que não haja degradação ou perda da capacidade explicativa.

22

Figura: Exemplo do modelo *fuzzy* de Takagi-Sugeno com duas regras representadas através de uma rede neural.

Abordagens para Modelagem de Sistemas Nebulosos

Abordagens bio-inspiradas: Modelagem difusa evolucionária

- Dada uma medida adequada de desempenho, Algoritmos Evolucionários (AE) são capazes de encontrar soluções quase-ótimas em espaços de busca grandes e complexos;
- São usados principalmente para ajustar o sistema de inferência nebuloso envolvido em tarefas de controle;
- Podem ser usados para o ajuste dos parâmetros relativos ao conhecimento, comportamento e estrutura do aprendizado, assim, são divididos em três categorias de modelagem difusas.

Abordagens para Modelagem de Sistemas Nebulosos

Abordagens bio-inspiradas: Modelagem difusa evolucionária

1. Ajuste do conhecimento (parâmetros operacionais)

- Um AE é usado para ajustar o conhecimento contido no sistema nebuloso através da busca por valores das funções de pertinência;
- Um sistema nebuloso inicial necessita ser definido por um especialista;
- Após, os valores das funções de pertinência são codificados em um gene;
- Um AE é utilizado para encontrar sistemas de alta performance;
- A evolução frequentemente supera problemas de mínimos locais presentes em métodos baseados nos gradiente.

Abordagens para Modelagem de Sistemas Nebulosos

Abordagens bio-inspiradas: Modelagem difusa evolucionária

2. Comportamento do aprendizado

- As funções de pertinência são definidas usando o conhecimento do especialista ou uma técnica de identificação (agrupamento nebuloso);
- Um AE é então usado para encontrar os consequentes das regras ou um subconjunto adequado de regras a serem incluídas na base de regras;
- O gene pode ser codificado diretamente com os consequentes de uma regra ou possuir um conjunto fixo de *templates* de regras definidas pelo usuário.

Abordagens para Modelagem de Sistemas Nebulosos

Abordagens bio-inspiradas: Modelagem difusa evolucionária

3. Estrutura do aprendizado (parâmetros estruturais)

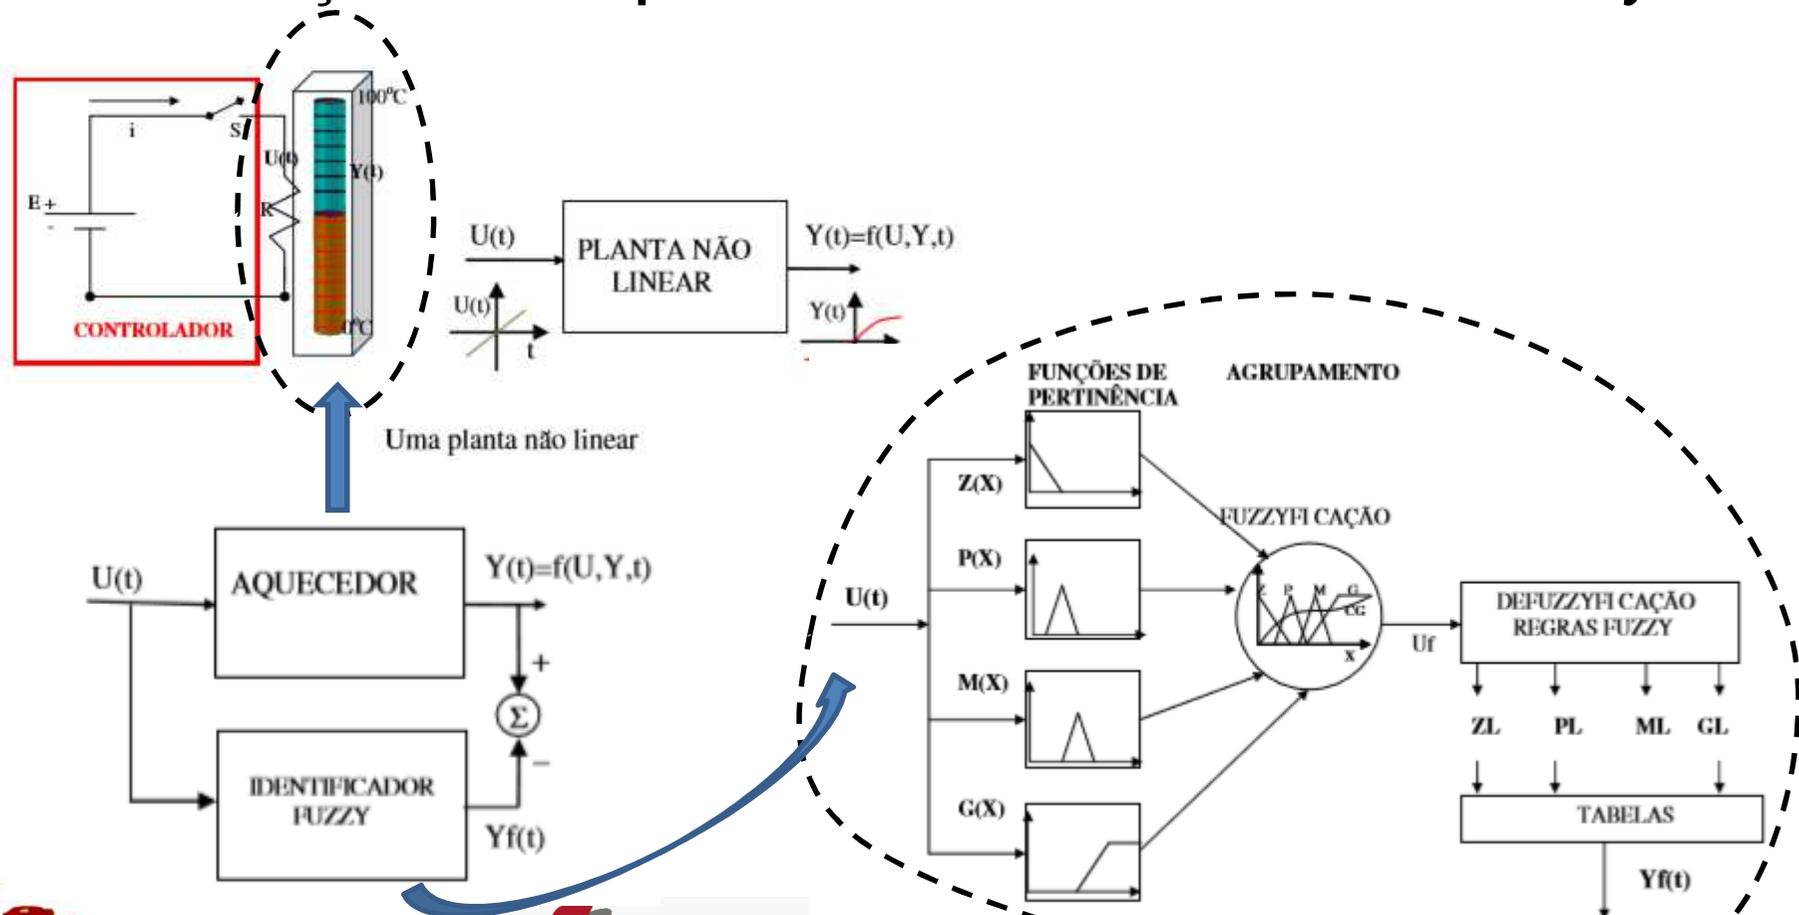
- Normalmente a informação disponível sobre o sistema é composta por dados entrada-saída e o conhecimento específico sobre a estrutura do sistema é escasso;
- Neste caso, AE são usados para o desenvolvimento simultâneo de regras, funções de pertinência e parâmetros estruturais;
- A alta interdependência entre os parâmetros envolvidos nessa forma de aprendizagem pode reduzir, ou até mesmo impedir por completo, a convergência do AE.
- Utilização de algoritmos co-evolucionários cooperativos
 - ✓ Existência de duas ou mais espécies e com restrições de acasalamento;
 - ✓ possuem uma relação cooperativa para o cálculo da aptidão.

26



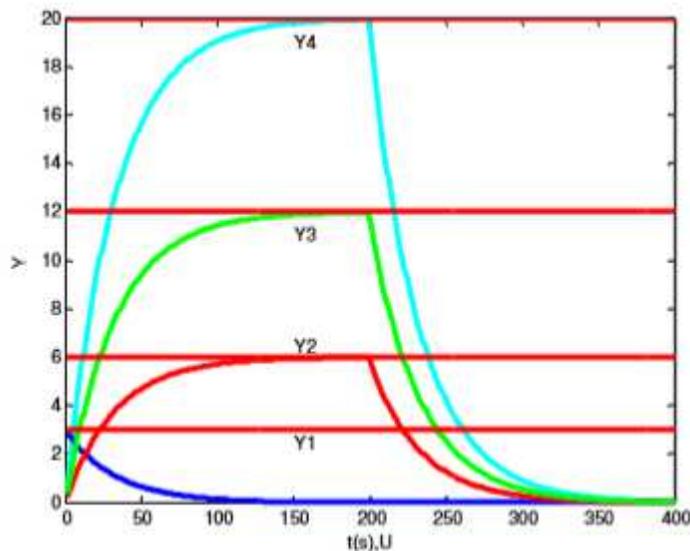
Exemplo da Modelagem Nebulosa

Identificação de um aquecedor usando um identificador *Fuzzy*.



Exemplo da Modelagem Nebulosa

Identificação de um aquecedor usando um identificador *Fuzzy*.



Curvas $Y(t)$ para:

- $0 < t \leq 200s$

Entrada: $U_4=1$, $U_3=0.6$, $U_2=0.3$, $U_1=0.15$

- $200s < t < 400s$

Entrada: $U_4=0$, $U_3=0.$, $U_2=0.$ e $U_1=0.$

Figura: Entradas e saídas da planta, regime transitório.

1. Especificar o problema e definir as variáveis linguísticas;

✓ Entrada: $U(t)$

✓ Saída: $Y(t)$

28

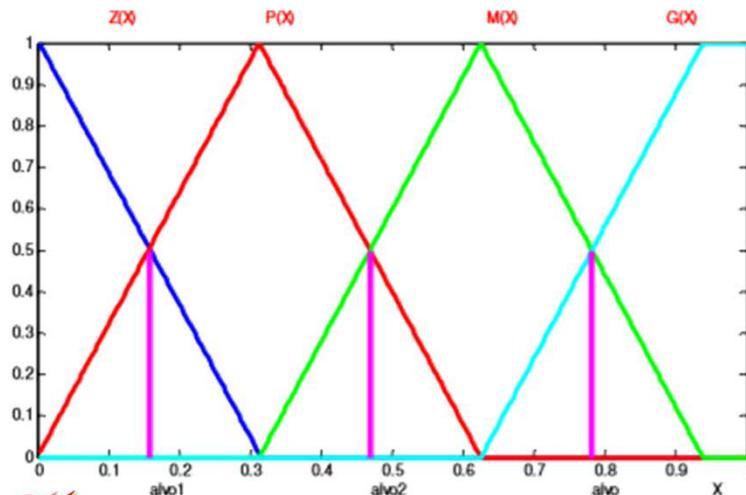
Exemplo da Modelagem Nebulosa

2. Definir os conjuntos *fuzzy*;

Conjuntos *Fuzzy*: $Z(X) \rightarrow Y1(t)$, $P(X) \rightarrow Y2(t)$, $M(X) \rightarrow Y3(t)$ e $G(X) \rightarrow Y4(t)$.

Os pontos máximos das funções de pertinência ($Y1$, $Y2$, $Y3$ e $Y4$) foram escolhidos para igualarem os valores finais de $Y(t)$ nas abscissas $U1=0.15$, $U2=0.3$ e $U1=0.6$, e $U4=1$.

3. Definir as funções de pertinência;



Intersecções entre as funções de pertinências (cor rosa) foram denominadas alvo1, alvo2 e alvo3.

Os pontos denominados alvo são usados na “defuzzyficação” lógica como pontos de mudança dos valores lógicos das funções de pertinências.

Exemplo da Modelagem Nebulosa

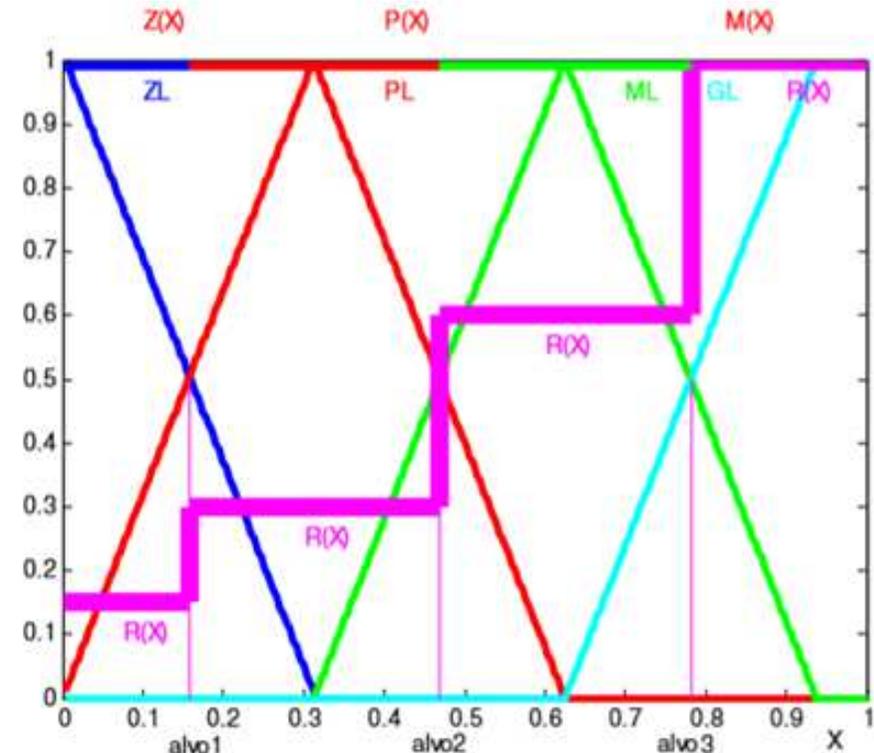
4. Especificar os procedimentos para realizar a inferência no sistema;
Defuzzyficação lógica baseada na operação *Fuzzy* UNIÃO :

$$Z(x) \cup P(x) \cup M(x) \cup G(x) = \max(Z(X), P(X), M(x), G(x)) \quad \forall x \in X.$$

```
ZL="0"; PL="0"; ML="0"; GL="0";  
if(X<alvo1)ZL="1"; %A função vencedora é a Z(X);end  
if(alvo1<=X<alvo2)PL="1"; %A função vencedora é a P(X);end  
if(alvo2<=X<alvo3)ML="1"; %A função vencedora é a M(X);end  
if(X>=alvo3)GL="1"; %A função vencedora é a G(X);end
```

Cálculo de $R(X)=W$

```
for X=0:1  
if(ZL==1) R(X)=0.15; %A função vencedora é a Z(X);end  
if(PL==1) R(X)=0.30; %A função vencedora é a P(X);end  
if(ML==1) R(X)=0.60; %A função vencedora é a M(X);end  
if(GL==1) R(X)=1.00; %A função vencedora é a G(X);end  
end
```



Exemplo da Modelagem Nebulosa

5. Construir as regras *fuzzy*;

Fuzzyficação:

Tabela Fuzzy da planta

VARIÁVEIS FUZZY	Z(X)	P(X)	M(X)	G(X)
Uf	ZL	PL	ML	GL
Yf	ZL	PL	ML	GL

Regras *Fuzzy* da Planta.

```
if (Uf==ZL)Yf=ZL;end
if (Uf==PL)Yf=PL;end
if (Uf==ML)Yf=ML;end
if (Uf==GL) Yf=GL;end
```

Defuzzyficação:

Defuzzyficação na forma numérica

	ZL	PL	ML	GL
U(t)	U1=0.15	U2=0.3	U3=0.6	U4=1.
Y(t)	Y1=3.	Y2=6.	Y3=12.	Y4=20.

Regras *Fuzzy* da defuzzyficação

```
if (Uf==ZL)U1=0.15; end
if (Uf==PL)U2=0.3; end
if (Uf==ML)U3=0.6; end
if (Uf==GL)U4=1.0; end

if (Yf==ZL)Y1=3.; end
if (Yf==PL)Y1=6.;end
if (Yf==ML)Y1=12.;end
if (Yf==GL)Y4=20.;end
```

31



Referências

1. Takagi, T., & Sugeno, M. (1985). Fuzzy identification of systems and its applications to modeling and control. IEEE transactions on systems, man, and cybernetics, (1), 116-132.
2. Babuška, R., & Verbruggen, H. B. (1996). An overview of fuzzy modeling for control. Control Engineering Practice, 4(11), 1593-1606.
3. Jang, J. S. (1993). ANFIS: adaptive-network-based fuzzy inference system. IEEE transactions on systems, man, and cybernetics, 23(3), 665-685.
4. Lee, C. H., & Teng, C. C. (2000). Identification and control of dynamic systems using recurrent fuzzy neural networks. IEEE Transactions on fuzzy systems, 8(4), 349-366.
5. Hojati, M., & Gazor, S. (2002). Hybrid adaptive fuzzy identification and control of nonlinear systems. IEEE Transactions on Fuzzy Systems, 10(2), 198-210.
6. Piegat, A. (2013). Fuzzy modeling and control (Vol. 69). Physica.
7. Al-Dabbagh, R. D., Kinsheel, A., Mekhilef, S., Baba, M. S., & Shamshirband, S. (2014). System identification and control of robot manipulator based on fuzzy adaptive differential evolution algorithm. Advances in Engineering Software, 78, 60-66.
8. Qiu, Jianbin, Huijun Gao, and Steven X. Ding. (2016). Recent advances on fuzzy-model-based nonlinear networked control systems: A survey. IEEE Transactions on Industrial Electronics 63.2: 1207-1217.

