

Modelagem para previsão/estimação: uma aplicação Neuro-Fuzzy

Luiz Carlos Benini, José Gilberto Spasiani Rinaldi

Universidade Estadual Paulista - Departamento de Estatística

19060-900, Campus Presidente, SP

E-mail: benini@fct.unesp.br, gilberto@fct.unesp.br

Resumo: Neste trabalho utiliza-se de um sistema de inferência fuzzy que incorpora o aprendizado por meio de um conjunto de dados onde as variáveis de entrada estão relacionadas com suas respectivas variáveis de saídas. Takagi e Sugeno foram pioneiros em propor um modelo de sistema de inferência fuzzy, onde são utilizadas entradas e regras fuzzy mas com a saída do sistema sendo conjuntos não-fuzzy. Este modelo é uma excelente ferramenta para modelagem de problemas complexos e não lineares, quando combinado com a estrutura da rede de Sistema de Inferência Fuzzy Neuro Adaptativa (ANFIS). Sistemas de inferência fuzzy são utilizados com base em um conjunto regras, do tipo “se...então”, que representam as entradas e saídas do modelo, associando a capacidade de aprendizado das redes neurais artificiais com o poder de interpretação lingüístico dos sistemas de inferência fuzzy, as quais são capazes de tratar conhecimentos incompletos, incertos ou mesmo conflitantes. É apresentada uma aplicação onde os dados estimados pelo modelo se mostraram correlacionados, indicando boa exatidão para o modelo neuro-fuzzy obtido, onde pode ser verificada a capacidade e a eficiência dos sistemas de inferência fuzzy.

Introdução

As fases envolvidas com as variáveis que quantificam um processo de análise de um conjunto de dados são cercadas de imprecisões e incertezas inerentes aos próprios aspectos físicos e estruturais dos dados. Os sistemas de inferência fuzzy são usados nestes casos, pois os mesmos fazem o mapeamento de processos com entradas advindas de um conjunto de dados resultantes de observações, ou experimentações, em saídas precisas $y = f(x)$, sendo x a variável de entrada, possuindo diferentes graus de imprecisão e incerteza, y a saída do sistema de inferência fuzzy e f uma representação quantitativa do mapeamento.

A teoria dos conjuntos fuzzy, introduzida em [4], surgiu como um meio de representação e manipulação de dados imprecisos, e pelo fato de os conjuntos clássicos apresentarem limitações para lidar com problemas onde transições de uma classe para outra acontecem de forma lenta e gradual.

Zadeh [5] generalizou a função característica de maneira que esta pudesse assumir um número infinito de valores no intervalo $[0,1]$ sugerindo que alguns elementos são mais membros de um conjunto do que outros. Neste caso o grau de pertinência pode assumir qualquer valor no intervalo $[0,1]$. A função que define o grau de pertinência de um determinado elemento em um conjunto fuzzy, levando em consideração o seu universo de discurso, é definida como função de pertinência.

Neste trabalho utiliza-se de um sistema de inferência fuzzy que incorpora o aprendizado por meio de um conjunto de dados onde as variáveis de entrada estão relacionadas com suas respectivas variáveis de saídas. Takagi e Sugeno [3] estão entre os pesquisadores pioneiros a proporem estruturas de sistemas de inferência fuzzy baseadas em um conjunto de padrões de ajuste para a sua definição. Sistemas de inferência fuzzy têm sido utilizados para modelar processos complexos, não lineares e vagos, com base em um conjunto regras, do tipo “se...então”, que representam as entradas e saídas do modelo, e que combinadas com métodos de redes neurais artificiais, dão origem a um novo método classificado como híbrido, que associa a capacidade de aprendizado das redes neurais artificiais com o poder de interpretação lingüístico dos sistemas de inferência fuzzy.

Dentre as abordagens que usam métodos híbridos destaca-se o sistema de inferência fuzzy neuro adaptativo (ANFIS) proposto em [2], que suporta o sistema de Takagi-Sugeno de ordem zero ou um, permitindo várias variáveis de entrada com somente uma variável saída.

Material e Método

Para a construção do modelo foram consideradas sete variáveis de entrada, sendo elas: temperatura máxima, temperatura mínima, ponto de orvalho, pressão atmosférica, umidade relativa, vento velocidade, vento direção, e uma variável de saída representando a temperatura do ar.

Para o desenvolvimento do trabalho foi utilizado um conjunto de dados, com as observações advindas de uma estação meteorológica, dividido em dois grupos selecionados aleatoriamente: dados de treinamento e dados de testes para a validação do modelo, e então construídos um sistema de inferência fuzzy, do tipo Takagi-Sugeno [3], definido por um conjunto de regras da forma: se x é A e y é B então $z = f(x, y)$, sendo x e y variáveis fuzzy, A e B conjuntos fuzzy e f uma função de x e y que aproxima o valor de z .

O modelo neuro-fuzzy com base no modelo do tipo de Takagi-Sugeno de primeira ordem e no algoritmo ANFIS, considerando um sistema de inferência fuzzy de duas entradas, x_1 e x_2 , uma saída, f , e composto por duas regras fuzzy:

Regra 1: Se x_1 é A_1^1 e x_2 é A_2^1 , então $f_1 = p_1 x_1 + q_1 x_2 + r_1$

Regra 2: Se x_1 é A_1^2 e x_2 é A_2^2 , então $f_2 = p_2 x_1 + q_2 x_2 + r_2$.

pode ser representada como na Figura 1.

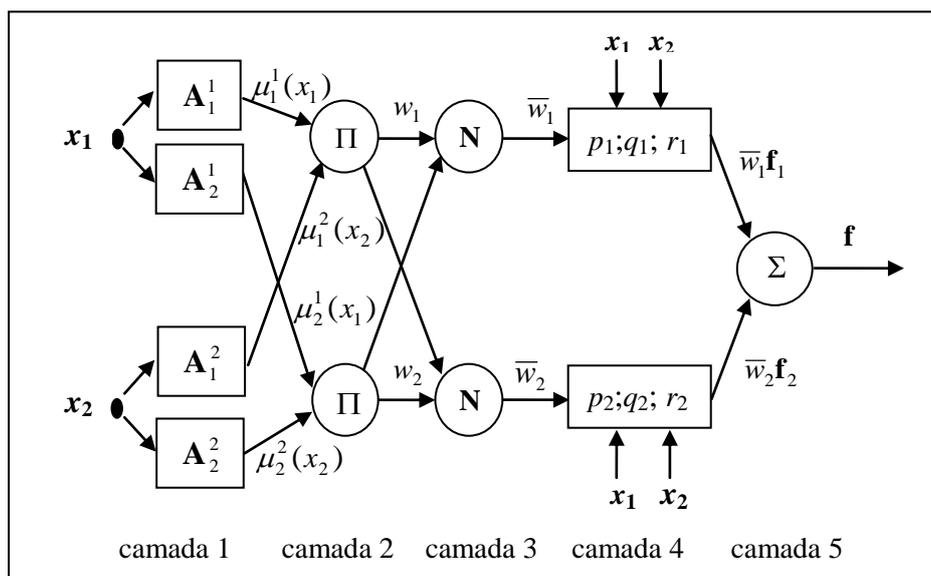


Figura 1 – Arquitetura típica de um modelo ANFIS.

Na estrutura do sistema de inferência fuzzy se pode, ainda, incorporar às regras um conhecimento proveniente de um especialista, dado por uma regra heurística, ao conhecimento intrínseco dos dados, obtidos a partir do processo de aprendizagem. Estas regras são ajustadas através de um processo de otimização buscando minimizar alguma medida de erro, sendo o vetor de variáveis independentes formado pelos parâmetros das funções de pertinências e os coeficientes dos consequentes das regras.

O modelo ANFIS ajusta por meio do algoritmo do gradiente descendente os parâmetros das funções de pertinências, os quais são neste trabalho do tipo gaussianas. O método dos mínimos quadrados é usado para encontrar os coeficientes da função de saída para o modelo.

A aprendizagem da estrutura ANFIS envolve a determinação do número de funções de pertinência por variável, a obtenção de um conjunto de regras fuzzy e de um conjunto de funções lineares, por valores atribuídos a parâmetros de ajustes, denominados raios de vizinhança dos centros dos agrupamentos, por meio da técnica de agrupamento subtrativo desenvolvida em [1], particionando o espaço de entrada e saída de um conjunto de dados.

Quando não se conhece “a priori” quantos agrupamentos deve haver para um determinado conjunto de dados, o agrupamento subtrativo é um algoritmo rápido e robusto para saber este número. Esta técnica permite a localização dos centros de agrupamentos de um conjunto de dados, que é o centro da função de pertinência e, a partir destas, obter as regras fuzzy.

Resultados e discussões

A partir do conjunto dos dados e com o uso das técnicas de otimização não linear do modelo ANFIS um sistema de previsão foi implementado utilizando o conjunto de variáveis de entrada como variáveis independentes e a variável de saída a variável dependente.

A identificação do modelo escolhido foi o que apresentou o menor erro quadrático para o conjunto de treinamento como para o conjunto de teste, e se obteve um número de funções de pertinência, e em função destas, também, um número de regras que satisfizeram ao critério do erro mínimo. Foi obtido o tipo de função de pertinência na forma gaussiana e o tipo de sistema fundamentado foi o modelo fuzzy de Takagi-Sugeno de primeira ordem.

Na determinação do modelo foram obtidas quatro funções de pertinências para cada uma das variáveis de entrada e deste modo o modelo identificado para estimar a temperatura do ar é constituído de sete variáveis de entrada, com quatro conjuntos fuzzy associados a cada uma das variáveis de entrada, quatro regras com os antecedentes de cada uma conectados pelo operador “e” e, portanto, quatro funções lineares, cada qual, representando a parte do consequente da regra fuzzy.

Variável de Entrada (x_i)	m	σ	m	σ	m	σ	m	σ
Temperatura Máxima (x_1)	22.26	1.148	16	6.43	22.13	1.36	19.84	4.392
Temperatura Mínima (x_2)	21.36	4.168	20.8	1.301	16.14	6.383	20.16	1.409
Ponto de Orvalho (x_3)	15.68	8.531	12.87	5.128	3.678	1.822	19.21	20.28
Pressão Atmosférica (x_4)	956.3	6.77	959.3	6.102	954.9	3.377	956.9	6.9
Umidade Relativa (x_5)	75.94	18.21	75.77	14.49	50.04	12.85	95.18	10.42
Vento Velocidade (x_6)	2.018	2.648	4.223	3.651	1.278	0.3847	0.97	2.62
Vento Direção (x_7)	103.6	75.08	102	76.86	77.96	71.7	56.35	75.48

Tabela 1 – Parâmetros das funções de pertinência (μ_i)

Na Tabela 1 são apresentados os parâmetros das funções de pertinência (μ), onde o parâmetro m denota o centro de um agrupamento (centro de uma função de pertinência) e σ a variação dos dados observados com relação à sua média.

Os parâmetros dos consequentes das regras fuzzy são apresentados na Tabela 2, onde os parâmetros c_i ($i = 1, \dots, 8$) são os coeficientes da função linear do consequente de cada uma das regras do modelo.

Regras	c_1	c_2	c_3	c_4	c_5	c_6	c_7	c_8
1	0.009	1.014	-0.020	-0.005	0.003	-0.047	-4.135	4.032
2	0.139	0.881	-0.017	0.003	0.008	-0.046	-0.0008	-0.669
3	1.570	-0.086	-0.502	-0.009	0.155	0.009	0.0005	-5.092
4	-0.137	0.516	0.624	-0.004	-0.081	0.007	-0.0004	12.290

Tabela 2. Parâmetros das funções lineares de saída dos consequente

Com os parâmetros da função de pertinência, as regras e as funções lineares que definem as saídas para os consequentes de cada regra, são as seguintes:

Regra 1: Se $x_1 \in [18.8, 25.7]$, $x_2 \in [8.9, 26.9]$, $x_3 \in [-2.2, 22.7]$, $x_4 \in [9941, 976.6]$,
 $x_5 \in [24.0, 95.0]$, $x_6 \in [0, 5.9]$, $x_7 \in [1, 328.8]$, então
 $y_1 = 0.01 x_1 + 1.01 x_2 - 0.02 x_3 - 0.01 x_4 + 0.01 x_5 - 0.05 x_6 - 4.14 x_7 + 4.03$

Regra2: Se $x_1 \in [4.2, 27.5]$, $x_2 \in [16.9, 24.7]$, $x_3 \in [-2.5, 22.7]$, $x_4 \in [941, 969.6]$,
 $x_5 \in [32.3, 95.0]$, $x_6 \in [0, 5.9]$, $x_7 \in [1, 332.6]$, então
 $y_2 = 0.14 x_1 + 0.88 x_2 - 0.02 x_3 + 0.01 x_4 + 0.01 x_5 - 0.05 x_6 - 0.001 x_7 - 0.67$

Regra 3: Se $x_1 \in [18.05, 26.21]$, $x_2 \in [0, 26.9]$, $x_3 \in [-1.8, 9.1]$, $x_4 \in [944.7, 965]$,
 $x_5 \in [11.5, 88.6]$, $x_6 \in [0.1, 2.4]$, $x_7 \in [1, 293.1]$, então
 $y_3 = 1.57 x_1 - 0.09 x_2 - 0.50 x_3 - 0.01 x_4 + 0.16 x_5 + 0.01 x_6 + 0.0005 x_7 - 5.09$

Regra 4: Se $x_1 \in [6.6, 27.5]$, $x_2 \in [15.9, 24.4]$, $x_3 \in [-2.2, 22.7]$, $x_4 \in [941.0, 969.6]$,
 $x_5 \in [63.92, 95.44]$, $x_6 \in [0.0, 5.9]$, $x_7 \in [1, 282.79]$, então
 $y_4 = -0.14 x_1 + 0.52 x_2 + 0.62 x_3 - 0.01 x_4 - 0.08 x_5 + 0.01 x_6 - 0.0004 x_7 + 12.29$

Na Tabela 3 são apresentados os dados observados da temperatura do ar e as estimativas obtidas pelo modelo neuro-fuzzy, juntamente com os erros relativos os quais são utilizados para medir a precisão entre estes valores.

	x_1	x_2	x_3	x_4	x_5	x_6	x_7	Temperatura Medida	Temperatura Estimada	Erro relativo (%)
1	25,2	24,2	13,3	956,9	47,0	3,6	84	24,2	24,3	0,1
2	15,5	15,3	12,0	959,4	80,0	4,1	98	15,3	15,3	0,0
3	19,3	18,5	8,4	960,6	50,0	2,5	79	19,1	18,6	0,5
4	25,7	25,2	9,9	952,6	37,0	4,2	352	25,2	25,3	0,1
5	21,1	20,8	19,1	959,8	87,0	1,8	121	20,8	20,9	0,1
6	17,6	17,3	13,9	959,5	79,0	1,3	127	17,5	17,4	0,1
7	22,3	21,9	20,7	951,4	92,0	0,1	2	22,0	21,8	0,2
8	16,8	16,2	7,5	962,7	55,0	1,5	111	16,3	16,3	0,0
9	26,4	26,0	15,3	955,7	50,0	2,6	82	26,0	26,1	0,1
10	23,5	23,3	18,0	953,8	71,0	2,2	84	23,3	23,4	0,1
11	10,2	9,3	7,4	961,8	83,0	0,0	183	9,80	9,52	0,3
12	12,9	12,7	11,1	958	88,0	1,8	107	12,8	12,9	0,1
13	17,5	17,2	15,9	958,6	91,0	2,2	53	17,4	17,3	0,1
14	14,9	14,6	11,5	955,6	80,0	2,2	111	14,6	14,7	0,1
15	24,5	23,9	14,9	954,0	55,0	2,5	88	24,0	24,0	0,0
16	21,5	21,4	19,5	952,1	88,0	1,2	90	21,5	21,5	0,0
17	17,3	17,1	15,7	958,5	92,0	0,8	107	17,1	17,1	0,0
18	23,7	23,1	20,5	943,3	82,0	2,1	32	23,7	23,2	0,5
19	23,0	22,6	19,9	956	79,0	1,7	35	22,6	22,7	0,1
20	23,9	23,4	17,9	949,2	69,0	1,7	97	23,4	23,5	0,1
	Erro relativo médio (ERM)									0,129
	Variância									0,021

Tabela 3 – Resultados do modelo para os dados da temperatura do ar (°C)

Na Figura 2 são mostrados os gráficos dos dados medidos (observados) e os valores estimados pela modelagem fuzzy, onde se pode verificar o comportamento do modelo neuro-fuzzy para os valores dos dados estimados.

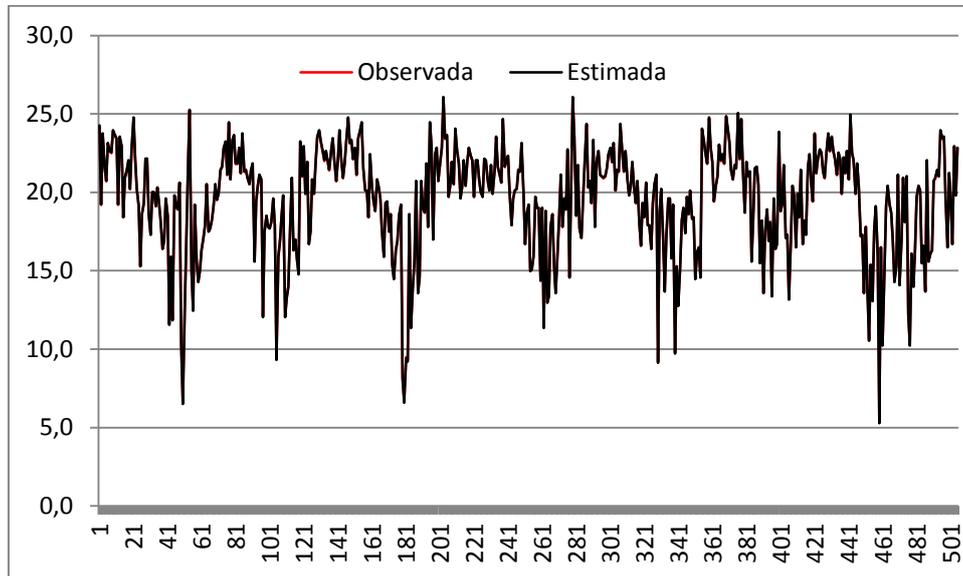


Figura 2: Gráfico dos valores observados e estimados pelo modelo neuro-fuzzy para o conjunto de dados analisado

Conclusões

A metodologia gerou modelos neuro-fuzzy simples com boa capacidade de generalização; os modelos obtidos podem ser utilizados para a estimativa da temperatura do ar com boa eficiência; os valores obtidos pelo modelo neuro-fuzzy e os valores observados estão bem correlacionados ($r = 0.999$).

Referências

- [1] Chiu, S.L. Selecting input variables for fuzzy models. *Journal of Intelligent and Fuzzy Systems*, vol.4, n.4, pp. 243-256, (1996).
- [2] Jang, J-R.R., Adaptive-network based fuzzy inference systems. *IEEE Transactions on Systems, Man and Cybernetics*, vol.23, n.3: pp. 665-685, (1993).
- [3] Takagi, T. ; Sugeno, M. , Fuzzy identification of systems and its applications to modelling and control. *IEEE Transactions on Systems, Man and Cybernetics*, vol.15, n.1, pp. 116-132, (1985).
- [4] Zadeh, L.A., Fuzzy sets. *Information and control*, vol. 8:29-44, (1965).
- [5] Zadeh, L.A., Outline of a new approach to the analysis of complex systems and decision processes. *IEEE Transactions on Systems, Man, and Cybernetics*, vol.3, n.1: pp. 28-44, (1973).