

Introdução a Sistemas Inteligentes

Tópicos em Redes Neurais II: Redes Neurais RBF – 1ª Parte

Prof. Ricardo J. G. B. Campello

ICMC / USP

Aula de Hoje

- Neurônios de Resposta Radial
- Modelos Neurais RBF
 - Única Saída
 - Múltiplas Saídas
 - Representação Matricial
 - Exemplo em Classificação Não Linear


Redes RBF

- ◆ Redes RBF (*Radial Basis Functions*) são uma classe de redes com arquitetura *feedforward*
 - Assim como as MLPs, os valores das entradas se propagam na rede em um único sentido
- ◆ Essas redes diferem das MLPs especialmente no modelo de neurônio que utilizam
 - Neurônios com *resposta radial* a excitações
 - Modelam o conceito biológico de *campo receptivo*

3

Redes RBF

- ◆ Resposta Radial Típica:



4

Redes RBF

◆ Resposta Radial


- Presentes em alguns tipos de células nervosas:
 - Células auditivas: possuem maior sensibilidade a frequências *próximas* a um determinado tom
 - Células da retina: maior sensibilidade a excitações luminosas *próximas* ao centro do seu campo receptivo
- Modelo matemático:
 - **Função de Base Radial**

5

Função de Base Radial

◆ Diferentes Modelos Matemáticos Possíveis

- Gaussiana:
$$h(x) = \exp\left(-\frac{(x-c)^2}{\sigma^2}\right)$$




6

Função de Base Radial

◆ Diferentes Modelos Matemáticos Possíveis

- Multi-Quadrática Inversa:
$$h(x) = \frac{1}{\sqrt{(x-c)^2 + \sigma^2}}$$




7

Função de Base Radial

◆ Diferentes Modelos Matemáticos Possíveis

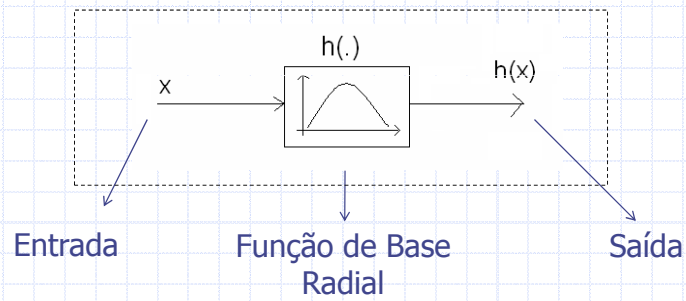
- Chapéu Mexicano:
$$h(x) = \begin{cases} \frac{\sin((x-c)/\sigma)}{((x-c)/\sigma)} & \text{se } x \neq c \\ 1 & \text{caso contrário} \end{cases}$$



8


Modelo do Neurônio RBF

◆ Modelo Básico do Neurônio:



9

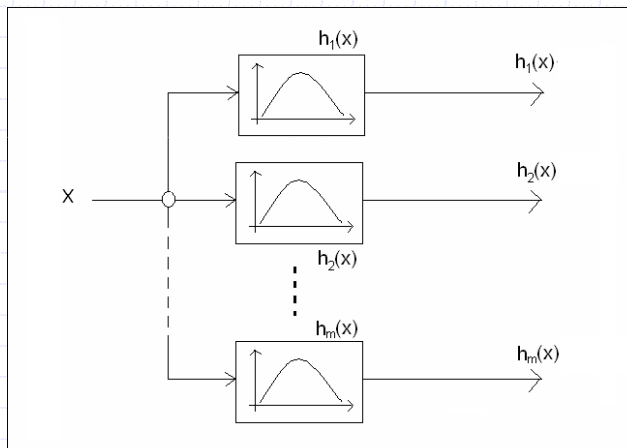
Campos Receptivos Distintos



10

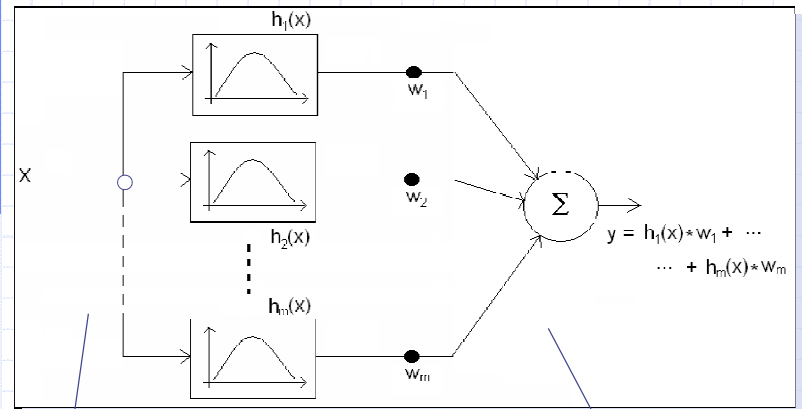
Múltiplos Neurônios

◆ Neurônios com campos receptivos distintos:



11

Modelo RBF (1 entrada)



"camada" entrada


camada intermediária

camada de saída
(neurônio linear)

12

Regressão Não Linear

◆ RBFs são **Aproximadores Universais** !

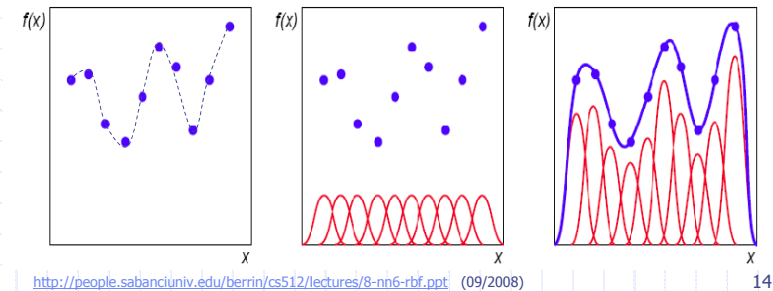


13

Regressão Não Linear

◆ Tais como MLPs, RBFs são **Aproximadores Universais**:

- Basta aumentar o número de neurônios (funções de base radial) para obter a capacidade de aproximação desejada.
- Tomando cuidado com super-treinamento (*overfitting*) !




14

Regressão Não Linear

◆ RBFs são **Aproximadores Universais**:

- Diversos problemas podem ser representados como problemas de aproximação de funções
 - Previsão, Tomada de decisão, Classificação*, etc
 - Por exemplo, operador humano de um processo complexo...




15

Modelo RBF (2 entradas)

◆ Função Radial para 2 Entradas (Gaussiana):

$$h(x_1, x_2) = \exp\left(-\frac{(x_1 - c_1)^2}{\sigma_1^2}\right) \times \exp\left(-\frac{(x_2 - c_2)^2}{\sigma_2^2}\right)$$




16

Modelo RBF (2 entradas)

- ◆ Função Radial para 2 Entradas (Gaussiana):


$$h(x_1, x_2) = \exp\left(-(\mathbf{x}-\mathbf{c})^T \cdot \begin{bmatrix} 1/\sigma_1^2 & 0 \\ 0 & 1/\sigma_2^2 \end{bmatrix} \cdot (\mathbf{x}-\mathbf{c})\right) \quad \begin{cases} \mathbf{x} = [x_1 & x_2]^T \\ \mathbf{c} = [c_1 & c_2]^T \end{cases}$$



17

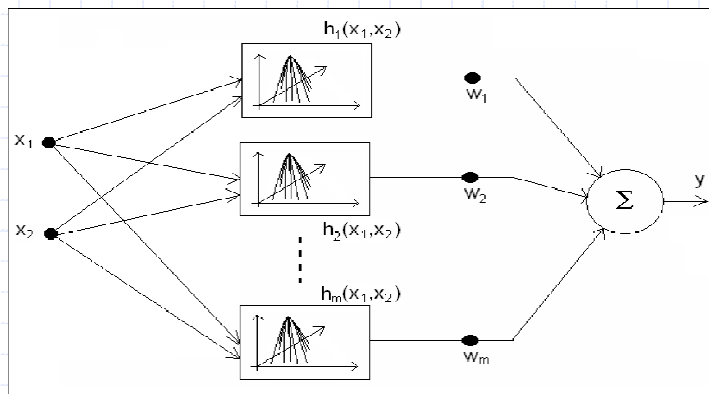
Modelo RBF (2 entradas)

- ◆ Função Radial para 2 Entradas (Chapéu Mexicano):



18

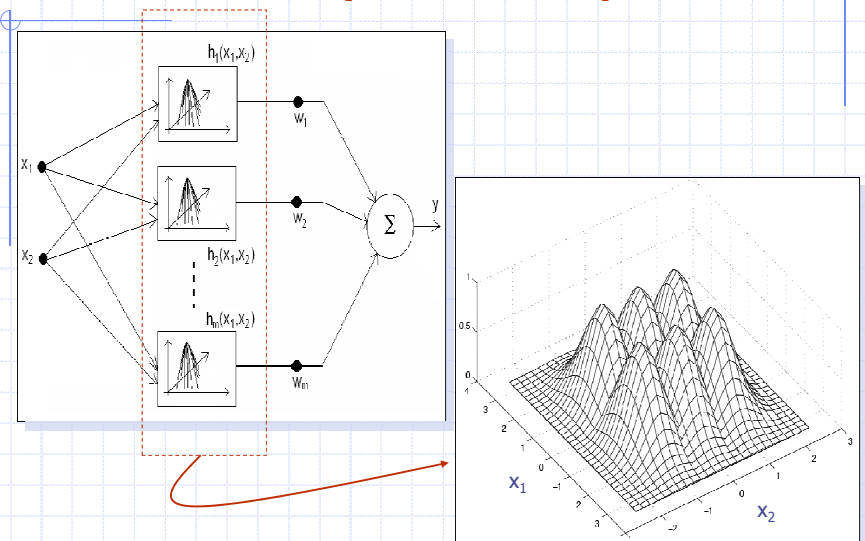
Modelo RBF (2 entradas)



$$y = \sum_{i=1}^m w_i \cdot h_i(x_1, x_2)$$

19


Modelo RBF (2 entradas)



Modelo RBF (n entradas)

- ◆ Função Radial para n Entradas (Gaussiana):

$$h(x_1, \dots, x_n) = \exp\left(-\frac{(x_1 - c_1)^2}{\sigma_1^2}\right) \times \dots \times \exp\left(-\frac{(x_n - c_n)^2}{\sigma_n^2}\right)$$



21

Modelo RBF (n entradas)


- ◆ Função Radial para n Entradas (Gaussiana):

$$h(x_1, \dots, x_n) = \exp\left(-(\mathbf{x} - \mathbf{c})^T \cdot \Phi^{-1} \cdot (\mathbf{x} - \mathbf{c})\right)$$

$$\begin{cases} \mathbf{x} = [x_1 & \dots & x_n]^T \\ \mathbf{c} = [c_1 & \dots & c_n]^T \\ \Phi = \text{diag}(\sigma_1^2, \dots, \sigma_n^2) \end{cases}$$

22


Modelo RBF (n entradas)



$$y = \sum_{i=1}^m w_i \cdot h_i(x_1, \dots, x_n) = \mathbf{w}^T \cdot \mathbf{h}$$

23

Modelo RBF (n entradas / r saídas)



$$y_j = \sum_{i=1}^m w_{ji} \cdot h_i(x_1, \dots, x_n) \quad \text{ou} \quad \mathbf{y} = \mathbf{W} \cdot \mathbf{h}$$

24


RBF vs. MLP

- Algumas diferenças e semelhanças entre RBFs e MLPs:

MLP	RBF
Aproximadores Universais	Aproximadores Universais
1 ou mais camadas intermediárias	Em geral 1 camada intermediária
Em geral demandam menos neurônios / parâmetros para uma mesma precisão	Em geral demandam mais neurônios / parâmetros para uma mesma precisão
Treinamento mais complexo	Treinamento mais simples
Difícil interpretação, senão impossível	Possível interpretação (se vista como sistema fuzzy)

25

Nota (Adição de Termo Constante)




$$y = w_0 + \sum_{i=1}^m w_i \cdot h_i(x_1, \dots, x_n)$$

26

Exercício (classificação)

- Sabemos que o problema XOR consiste em classificar 4 padrões (descritos por 2 variáveis) em 2 classes diferentes, ou seja:

x_1	x_2	Classe
0	0	1
0	1	2
1	0	2
1	1	1




Note que esse problema não é linearmente separável, ou seja, não existe uma função linear que separe as classes no espaço $x_1 \times x_2$

27

Exercício (cont.)

- No entanto, os padrões podem passar a ser linearmente separáveis após serem processados por funções de base radial, desde que essas sejam escolhidas de forma apropriada. P. ex., escolhendo 2 funções Gaussianas h_1 e h_2 com centros dados por $[0,0]$ e $[1,1]$, respectivamente, e desvios padrão unitários para ambas, tem-se:


x_1	x_2	$h_1(x_1, x_2)$	$h_2(x_1, x_2)$
0	0	1	0,1353
0	1	0,3679	0,3679
1	0	0,3679	0,3679
1	1	0,1353	1



$h_1(x_1, x_2)$

Exercício (cont.)

- ◆ Considere então a rede RBF com essas funções de base radial e pesos $w_1 = w_2 = -1$ e $w_0 = 1$ (aditivo na saída):



- ◆ Escreva analiticamente a expressão da saída da rede em função das entradas x_1 e x_2 e mostre que essa rede é capaz de classificar corretamente os padrões XOR assumindo que esses padrões pertencem à classe 1 se $y < 0$ e à classe 2 se $y > 0$

Referências

- Haykin, S., *Neural Networks: A Comprehensive Foundation*, Prentice Hall, 2nd Edition, 1999
- Braga, A. P., Carvalho, A. C. P. L. F., Ludemir, T. B., *Redes Neurais Artificiais: Teoria e Aplicações*, LTC, 2ª Edição, 2007
- Kovács, *Redes Neurais Artificiais: Fundamentos e Aplicações*, Collegium Cognitio, 2ª Edição, 1996