

Introdução a Sistemas Inteligentes

Tópicos em Redes Neurais III: Redes Neurais RBF – 2ª Parte

Prof. Ricardo J. G. B. Campello

ICMC / USP


Aula de Hoje

- Revisão de Modelos RBF
- Treinamento de Modelos RBF
 - Estimação dos Pesos
 - Mínimos Quadrados
 - Back-Propagation
 - Estimação das Funções de Base Radial
 - Exemplo em Regressão Não Linear

Modelo RBF (revisão)

- ◆ Função Radial para n Entradas (Gaussiana):

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



3

Modelo RBF (revisão)


- ◆ Função Radial para n Entradas (Gaussiana):

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

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

4


Modelo RBF (revisão)



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

5

Modelo RBF (revisão)



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

6

Treinamento de Redes RBF

◆ Problemas:

- Dadas as funções de base radial, como determinar o melhor vetor de pesos \mathbf{w} ?
- Como determinar bons parâmetros para as funções de base radial (centros e aberturas) ?
 - reduzir no. de funções para dada precisão, ou
 - aumentar precisão para dado no. de funções

7

Treinamento de Redes RBF

◆ Problemas:

- **Dadas as funções de base radial, como determinar o melhor vetor de pesos \mathbf{w} ?**
- Como determinar bons parâmetros para as funções de base radial (centros e aberturas) ?
 - reduzir no. de funções para dada precisão, ou
 - aumentar precisão para dado no. de funções

8

Determinação dos Pesos

- ◆ Queremos determinar os pesos de uma rede RBF com funções radiais conhecidas para aproximar a função (mapeamento) entre um conjunto de N padrões de entrada $\mathbf{x}_k = [x_{1k} \dots x_{nk}]^T$ e saída $y(\mathbf{x}_k)$ para $k=1, \dots, N$

- Por simplicidade, assume-se aqui que a saída é única

- ◆ Exemplo:

- ◆ para $N = 100$ clientes de um banco, descritos por $n = 5$ variáveis (salário, idade, tempo de relacionamento com o banco, sexo, estado civil), queremos obter uma rede que, dado um cliente \mathbf{x}_k , responda se este cliente possui maior risco de ser caloteiro ($y(\mathbf{x}_k) = 1$) ou não ($y(\mathbf{x}_k) = 0$)

9

Determinação dos Pesos

- ◆ Como as m funções radiais são conhecidas, podemos calcular o valor dessas funções para cada padrão \mathbf{x}_k

- ◆ Representando esses valores em uma matriz tem-se:

$$\mathbf{H} = \begin{bmatrix} h_1(\mathbf{x}_1) & \dots & h_m(\mathbf{x}_1) \\ \vdots & \ddots & \vdots \\ h_1(\mathbf{x}_N) & \dots & h_m(\mathbf{x}_N) \end{bmatrix}$$

- ◆ As saídas desejadas (conhecidas) também podem ser representadas em um vetor:

$$\mathbf{y} = [y(\mathbf{x}_1) \quad \dots \quad y(\mathbf{x}_N)]^T$$

10

Determinação dos Pesos

- ◆ Para uma representação ideal da saída, deseja-se que a rede RBF possua pesos \mathbf{w} tais que:

$$\begin{bmatrix} h_1(\mathbf{x}_1) & \dots & h_m(\mathbf{x}_1) \\ \vdots & \ddots & \vdots \\ h_1(\mathbf{x}_N) & \dots & h_m(\mathbf{x}_N) \end{bmatrix} \cdot \begin{bmatrix} w_1 \\ \vdots \\ w_m \end{bmatrix} = \begin{bmatrix} y(\mathbf{x}_1) \\ \vdots \\ y(\mathbf{x}_N) \end{bmatrix}$$

ou seja: $\mathbf{H} \cdot \mathbf{w} = \mathbf{y}$

- ◆ Se \mathbf{H} fosse quadrada, poderíamos multiplicar por \mathbf{H}^{-1} em ambos os lados e resolver o problema como:

$$\mathbf{w} = \mathbf{H}^{-1} \cdot \mathbf{y}$$

11

Determinação dos Pesos

- ◆ Podemos obter uma matriz quadrada multiplicando ambos os lados da equação por \mathbf{H}^T :

$$\mathbf{H}^T \cdot \mathbf{H} \cdot \mathbf{w} = \mathbf{H}^T \cdot \mathbf{y}$$

- ◆ Agora sim podemos multiplicar ambos os lados da equação pela inversa $(\mathbf{H}^T \mathbf{H})^{-1}$ e obter a solução como:

$$\mathbf{w} = (\mathbf{H}^T \cdot \mathbf{H})^{-1} \cdot \mathbf{H}^T \cdot \mathbf{y}$$

12

Determinação dos Pesos

- Se houver o termo aditivo w_0 na saída, é preciso somente redefinir \mathbf{H} e \mathbf{w} de tal forma que:

$$\underbrace{\begin{bmatrix} 1 & h_1(\mathbf{x}_1) & \dots & h_m(\mathbf{x}_1) \\ \vdots & \vdots & \ddots & \vdots \\ 1 & h_1(\mathbf{x}_N) & \dots & h_m(\mathbf{x}_N) \end{bmatrix}}_{\mathbf{H}} \cdot \underbrace{\begin{bmatrix} w_0 \\ w_1 \\ \vdots \\ w_m \end{bmatrix}}_{\mathbf{w}} = \underbrace{\begin{bmatrix} y(\mathbf{x}_1) \\ \vdots \\ y(\mathbf{x}_N) \end{bmatrix}}_{\mathbf{y}}$$

o que não afeta a solução:

$$\mathbf{w} = (\mathbf{H}^T \cdot \mathbf{H})^{-1} \cdot \mathbf{H}^T \cdot \mathbf{y}$$

13

Determinação dos Pesos

- Algoritmo:
 - Para um conjunto de $k = 1, \dots, N$ padrões de entrada e saída, $\{\mathbf{x}_k, y(\mathbf{x}_k)\}$, calcule a matriz \mathbf{H} , construa o vetor \mathbf{y} e calcule os pesos da rede segundo a equação:

$$\mathbf{w} = (\mathbf{H}^T \cdot \mathbf{H})^{-1} \cdot \mathbf{H}^T \cdot \mathbf{y}$$


- Nota: É possível demonstrar que, se a representação não for exata, a solução acima é aquela que minimiza o erro quadrático entre a saída da rede e a saída desejada (**Mínimos Quadrados**) !

14

Exercício (classificação)

- Sabemos que o problema XOR consiste em classificar $N = 4$ padrões (descritos por $n = 2$ variáveis) em 2 classes diferentes:

k	x_1	x_2	y (classe)
1	0	0	0
2	0	1	1
3	1	0	1
4	1	1	0




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

15

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 e w_2 , além do peso adicional w_0 (aditivo na saída), conforme abaixo:



- ◆ Obtenha os valores dos pesos w_0 , w_1 e w_2 para que a rede consiga indicar precisamente em sua saída a classe correta (0 ou 1) de cada um dos 4 padrões de entrada do problema XOR.
 - Apresente a solução passo a passo, em detalhes e de forma justificada !

17

Treinamento de Redes RBF

◆ Problemas:

- Dadas as funções de base radial, como determinar o melhor vetor de pesos w ?
- **Como determinar bons parâmetros para as funções de base radial (centros e aberturas) ?**
 - reduzir no. de funções para dada precisão, ou
 - aumentar precisão para dado no. de funções

18

Determinação das Funções Radiais

◆ Método 1 (Heurística Simples):

- Distribuir as funções de maneira homogênea sobre o domínio das variáveis de entrada
- Por exemplo, se a rede possui duas entradas, x_1 e x_2 , que assumem valores no intervalo $[-10, +10]$, então o domínio das funções são todos os pontos (x_1, x_2) tais que $x_1 \in [-10, +10]$ e $x_2 \in [-10, +10]$

19

Determinação das Funções Radiais


◆ Método 1 (cont.):

- Os centros das funções com relação a cada variável (dimensão) podem ser distribuídos uniformemente (equidistantes) ao longo do domínio daquela var.
- As aberturas das funções (desvios padrão) com relação a cada variável podem ser feitas iguais à distância entre dois centros consecutivos.

20

Determinação das Funções Radiais

◆ Método 1 (exemplo):



21

Determinação das Funções Radiais

◆ Método 2 (back-propagation):

- Análogo ao treinamento de MLPs
- A cada iteração ajusta-se o conjunto de parâmetros (centros e aberturas das funções) no sentido de minimizar o erro entre a saída da rede e a saída desejada para um conjunto de padrões
- Usualmente tenta-se minimizar: $J = \frac{1}{N} \sum_{k=1}^N (y(\mathbf{x}_k) - y_{\text{RBF}}(\mathbf{x}_k))^2$
- Demanda o cálculo do gradiente (derivadas) de J com relação aos parâmetros...
- Usualmente aplica-se para refinar o resultado inicial obtido com o método 1 ou método 3 (visto depois)

22

Exemplo (regressão)

◆ Problema:

- Aproximar a função $f(x) = \text{sen}(2x) / \exp(x/5)$

◆ N = 21 padrões de entrada e saída (k = 1, ..., 21):


Padrão E/S	x	f(x)
1	0	0
2	0.5	0.7614
3	1.0	0.7445
4	1.5	0.1045
5	2.0	-0.5073
6	2.5	-0.5816
7	3.0	-0.1533
8	3.5	0.3262
9	4.0	0.4445
10	4.5	0.1676

11	5.0	-0.2001
12	5.5	-0.3329
13	6.0	-0.1616
14	6.5	0.1145
15	7.0	0.2443
16	7.5	0.1451
17	8.0	-0.0581
18	8.5	-0.1756
19	9.0	-0.1241
20	9.5	0.0224
21	10.0	0.1236

23

Exemplo (cont.)

◆ Problema: Aproximar a função $f(x) = \text{sen}(2x) / \exp(x/5)$



24

Exemplo (cont.)


◆ Solução 1 (Método 1):

- Rede RBF com 6 neurônios (funções Gaussianas)
- Centros distribuídos de maneira uniforme
 - $c_1 = 0, c_2 = 2, c_3 = 4, c_4 = 6, c_5 = 8, c_6 = 10$
- Desvios padrão iguais à distância entre dois centros consecutivos
 - $\sigma_1 = \sigma_2 = \sigma_3 = \sigma_4 = \sigma_5 = \sigma_6 = 2$
- Apenas os pesos otimizados via Mínimos Quadrados (MQ):
 - 7 pesos ($w_0 \dots w_6$) obtidos via MQ: $\mathbf{w} = (\mathbf{H}^T \mathbf{H})^{-1} \mathbf{H}^T \mathbf{y}$

25

Exemplo (cont.)

◆ Resultado Solução 1:



26

Exemplo (cont.)


◆ Solução 2 (Método 1):

- Rede RBF com 11 neurônios
- Centros distribuídos de maneira uniforme
 - $c_1 = 0, c_2 = 1, c_3 = 2, \dots, c_{11} = 10$
- Desvios padrão iguais à distância entre dois centros consecutivos
 - $\sigma_1 = \sigma_2 = \dots = \sigma_{11} = 1$
- Apenas os pesos otimizados via Mínimos Quadrados (MQ):
 - 12 pesos ($w_0 \dots w_{11}$) obtidos via MQ: $\mathbf{w} = (\mathbf{H}^T \mathbf{H})^{-1} \mathbf{H}^T \mathbf{y}$

27

Exemplo (cont.)

◆ Resultado Solução 2:



28

Exemplo (cont.)


◆ Solução 3 (Método 1 + 2):

- Rede RBF com 6 neurônios
- Rede inicialmente configurada conforme Solução 1
- Sintonia fina realizada com **back-propagation**

29

Exemplo (cont.)

◆ Resultado Solução 3:



30

Exemplo (cont.)


◆ Solução 4 (Método 1 + 2):

- Rede RBF com 8 neurônios
- Rede inicialmente configurada de forma análoga à Solução 1
 - Porém com 8 neurônios (Gaussianas)
- Sintonia fina realizada com **back-propagation**

31


Exemplo (cont.)

◆ Resultado Solução 4:



32

Exemplo (cont.)



Exemplo (cont.)


◆ Comparação:

- A heurística de distribuição homogênea das funções radiais (método 1) foi muito eficaz nesse exemplo agindo sozinha, mas não necessariamente é sempre assim
- Embora a rede com 8 neurônios refinados com back-propagation tenha uma quantidade de parâmetros maior durante a fase de **treinamento**, é um modelo mais simples e compacto do que aquele com 11 neurônios (para **utilização**).
- A rede com 11 neurônios poderia ficar ainda mais precisa se seus parâmetros também fossem refinados com back-propagation

34

Dicas Básicas

- ◆ Usualmente utiliza-se apenas uma parcela dos padrões disponíveis para treinar a rede e reserva-se uma outra parcela para teste ou **validação**
- ◆ Uma boa heurística para saber quando interromper o treinamento (sintonia fina) dos parâmetros via back-propagation é observar os erros de ambas as parcelas:




➔ **Early Stop**

35

Dicas Básicas

- ◆ A mesma idéia pode ser usada para determinar quando parar de acrescentar neurônios à rede...



- ◆ Uma outra boa dica é normalizar os padrões de E/S de forma que cada variável tenha valores entre -1 e $+1$
 - Isso minimiza problemas numéricos durante o treinamento

36

Determinação das Funções Radiais

◆ Método 3 (Clustering):


- Agrupar os padrões em grupos (clusters) de padrões mais similares entre si do que aos demais padrões
- Associar um neurônio (função radial) para cada grupo de padrões, otimizando a representatividade de cada neurônio / função
- Idéia é que cada neurônio responda de forma apropriada e similar a um determinado conjunto de padrões similares
 - Tipicamente (sub)classes em **problemas de classificação**

37

Determinação das Funções Radiais

◆ Método 3 (cont.):

- Idéia intuitiva (1 var. de entrada):




38

Determinação das Funções Radiais

◆ Método 3 (cont.):

- Idéia intuitiva (2 vars. de entrada):



<http://people.sabanciuniv.edu/berrin/cs512/lectures/8-nn6-rbf.ppt> (09/2008)

39

Determinação das Funções Radiais

◆ Método 3 (cont.):

- Um dos algoritmos de agrupamento mais populares é o **K-means**, que agrupa N padrões em K grupos
 - fornece K protótipos (centróides) dos grupos
- K-means agrupa os N padrões em K grupos com o objetivo de minimizar as distâncias entre os padrões pertencentes a um mesmo grupo e seu protótipo
- Mas como aplicar K-means para determinação das funções radiais...?

40

Determinação das Funções Radiais


◆ Método 3 (cont.):

- Executa-se K-means com **K** igual ao número **m** de neurônios (funções radiais) desejado na rede RBF
- Toma-se o protótipo (centróide) de cada grupo resultante como centro de uma função radial
 - cada componente do centróide é o centro da função radial correspondente na respectiva variável
- Toma-se os desvios padrão de cada grupo, em cada variável, como o desvio padrão da função radial correspondente na respectiva variável

41

Método 3 (Exemplo)

padrão (entrada)	x_1	x_2
1	1	2
2	2	1
3	1	1
4	2	2
5	8	9
6	9	8
7	9	9
8	8	8
9	1	15
10	2	15
11	1	14
12	2	14



Slide cedido pelo Prof. Eduardo Raul Hruschka

Método 3 (Exemplo)

- ◆ K-means com $K = 3$ produziria tipicamente os protótipos $(1.5, 1.5)$, $(8.5, 8.5)$, $(1.5, 14.5)$
- ◆ O terceiro grupo, por exemplo, possui desvios padrão em x_1 e em x_2 respectivamente iguais a:

$$\sigma_1 = \sqrt{\frac{(1-1.5)^2 + (2-1.5)^2 + (1-1.5)^2 + (2-1.5)^2}{4}} = 0.5$$

$$\sigma_2 = \sqrt{\frac{(15-14.5)^2 + (15-1.5)^2 + (14-14.5)^2 + (14-14.5)^2}{4}} = 0.5$$

- ◆ Logo, a função radial (Gaussiana) correspondente pode ser definida como:

$$h_3(x_1, x_2) = \exp\left(-\frac{(x_1 - 1.5)^2}{0.5^2}\right) \times \exp\left(-\frac{(x_2 - 14.5)^2}{0.5^2}\right)$$

Exercícios

- ◆ Complete o exemplo anterior, ou seja, apresente as funções de base radial h_1 e h_2 correspondentes aos dois primeiros grupos encontrados pelo algoritmo K-means
- ◆ Obtenha 9 funções (h_1, \dots, h_9), mas agora utilizando o método 1 (heurística simples)
 - Avalie a máxima ativação de cada uma das 9 funções para os dados em mãos e discuta a representatividade delas frente a este cenário



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