

LABIC

Redes Auto-organizáveis

SCE 5809 REDES NEURAIS

Profa. Roseli Romero
2o. Semestre de 2010

PARTE II

Redes Neurais – 2010

RAFR 1

LABIC

Aprendizado Competitivo

- As saídas dos neurônios competem entre si para ser aquele neurônios que será ativado.
- Na regra de Hebb vários neurônios podem simultaneamente ser ativados. Neste tipo de aprend. apenas um neurônio é ativado por vez.
- Propicia descobrir aquelas características estatísticas importantes que podem ser usadas para classificar um conjunto de dados.
- Durbin, 1989 - tem um papel importante na formação de mapas topográficos presentes nos circuitos interregionais do nosso cérebro.

Redes Neurais – 2010

RAFR 2

LABIC

Aprendizado Competitivo

Existem 3 elementos básicos:

- Um conjunto de neurônios (pesos aleator.)
- Um limite sobre o compr. de cada neurônio (=1)
- Um mecanismo que permite os neurônios competirem para responder a um dado conj. de entrada, tal que apenas um neurônio de saída seja ativado. O neurônio ganhador e chamado de **winner-takes-all**.
- Os neurônios individuais aprendem a se especializar sobre conj. de padrões similares - **detetores de características importantes**.

Redes Neurais – 2010

RAFR 3

LABIC

Aprendizado Competitivo

- $\Delta w_{kj}(n) = \eta (y_i - w_{kj})$, se o neurônio ganha a competiçao
- 0, se o neurônio perde a competiçao

onde η e o parâmetro de velocidade.

Efeito: mover o peso sináptico w_j em direcao a entrada x

Quando os pesos sinápticos sao propriamente escalonados, eles formam um conj. de vet. que caem na mesma esfera unitária n-dimensional.

Redes Neurais – 2010

RAFR 4

LABIC

Mapas Auto-organizáveis

- Os sistemas Self-Organizing Maps (SOM) tem sido muito utilizados para clusterização de dados e compressão de dados.
- Existem muitas aplicações interessantes que utilizaram tais sistemas, com sucesso:
 - ◆ Reconhecimento de voz
 - ◆ Classificação de padrões

Redes Neurais – 2010

RAFR 5

LABIC

Mapas Auto-organizáveis

- Vários modelos de SOM, cada um com caract. próprias.
- Arquitetura pré-definida
 - Modelo de Kohonen (1989)
 - Modelo ART(1988)
- SOMs Construtivos
 - ◆ GNG
 - ◆ Modelos Hierárquicos
 - ◆ SAM-SOM (Cuadros,2003)

Redes Neurais – 2010

RAFR 6

LABIC

Mapas Auto-organizáveis

- Todos esses modelos pertencem ao paradigma NÃO SUPERVIONADO.
- Não existe um agente externo avaliando as respostas da rede, ela deve extrair as caract. dos dados segundo algum critério, como por exemplo, a distância.
- Existem muitas aplicações onde não se conhece a informação desejada, para um dado padrão apresentado à rede.

Redes Neurais – 2010

RAFR 7

LABIC

Mapas Auto-organizáveis

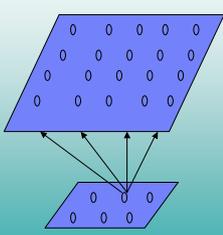
- Os SOM são baseados na idéia central do princípio de formação de mapas topográficos:
 - “a localização espacial de um neurônio de saída no mapa topográfico corresponde a um domínio particular ou característica do dado de entrada”.
- Um dos primeiros modelos de SOM foi proposto por Malsburg (73) que observou que um proc. Auto-org. envolvendo aprend. Sináptico pode ser responsável pela ordem local de células corticais “feature-sensitive”.

Redes Neurais – 2010

RAFR 8

LABIC

Mapas Auto-organizáveis



Modelo proposto Por Willshaw and von der Malsburg. para expl. o probl. do mapeamento retinotótipo da retina para o cortex visual. As dimensões entr/saída são = 2

Redes Neurais – 2010

RAFR 9

LABIC

Mapas Auto-organizáveis

- Os SOM são mais semelhantes as estruturas neurobiológicas que outras RNAs, tais como MLPs (Rumelhart,86).
- Sua estrutura padrão é formada por uma camada de entrada e uma camada de saída.
- No entanto, há modelos de SOM multicamadas (Fukushima, 1980).

Redes Neurais – 2010

RAFR 10

LABIC

Rede de Kohonen

- Esta rede foi proposta por Teuvo Kohonen da Universidade de Helsinki, Finlândia, em 1982.
- Ela tem forte inspiração neurofisiológica.
- Apesar do cérebro humano ser uma estrutura muito complexa do ponto de vista microscópico, ele tem uma estrutura uniforme a escala macroscópica.

Redes Neurais – 2010

RAFR 11

LABIC

Rede de Kohonen

- Os centros responsáveis por atividades tais como: pensamento, visão, audição, sempre se encontram na mesma posição em todos os seres humanos. As áreas individuais, por sua vez, apresentam uma ordenação lógica em relação a sua funcionalidade.
- Ex. de ordenação e o mapa tonotópico das regiões auditivas (Wosley, 58) e (Celsia, 76).

Redes Neurais – 2010

RAFR 12

Rede de Kohonen

- Neste mapa neurônios próximos entre si respondem a frequências similares de sons.
- Mapa somatotópico (Amari, 83) que é o mapa dos nervos motores responsáveis por cada parte do corpo humano. Neste tipo de mapa regiões fisicamente próximas são responsáveis por membros do corpo fisicamente próximos.

Redes Neurais – 2010

Rede de Kohonen

- Utilizada para agrupamento ou clustering de dados
- Implementa em seu algoritmo de aprendizado o método k-means.
- Algoritmo de aprendizado é do tipo aprendizado competitivo
- Ela não é significativa para explicar os detalhes neurobiológicos. Mas, o modelo tenta capturar as caract. essenciais de mapas topográficos permanecendo ainda computac. tratável.

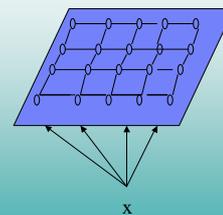
Redes Neurais – 2010

Rede de Kohonen

- Parece que o modelo de Kohonen é mais geral que o modelo de von der Malsburg no sentido que ele é capaz de realizar compressão de dados.

Redes Neurais – 2010

Rede de Kohonen



Redes Neurais – 2010

Modelo de Kohonen

- A Rede de Kohonen apresenta um exemplo de como Redes Neurais podem “aprender sozinhas” ou “auto-organizar-se”, sem que seja dado uma resposta correta para um dado padrão de entrada.
- O modelo de Kohonen nos oferece uma visão de como nosso cérebro pode realmente trabalhar, uma vez que forma “mapas de preservação da topologia”, que são também uma característica dos cérebros biológicos.
- A estrutura da rede proposta por Kohonen apresenta uma camada bidimensional de neurônios baseada nas camadas presentes no córtex cerebral, as quais apresentam características de auto-organização e memória associativa.

Redes Neurais – 2010

Modelo de Kohonen

- A Rede de Kohonen possui as seguintes características:
 1. *Estrutura não-hierárquica*: todos os neurônios da rede são do mesmo tipo, desempenham a mesma função e pertencem a uma única camada, chamada *Camada de Kohonen*.

Redes Neurais – 2010

LABIC

Modelo de Kohonen

- 2. *Aprendizado não supervisionado*: a rede possui auto-organização; podendo fornecer uma saída correta para uma dada amostra de entrada, sem que a saída esperada tenha sido fornecida.

Redes Neurais – 2010

RAFR 19

LABIC

Modelo de Kohonen

- A camada de Kohonen é um arranjo de neurônios em duas dimensões, onde todos os neurônios são conectados aos seus vizinhos mais próximos, respeitando sempre a estrutura da rede.

Redes Neurais – 2010

RAFR 20

LABIC

Rede de Kohonen

- Duas habilidades fundamentais:
 1. *Modelar a Distribuição das Entradas*: a rede modela a função distribuição de probabilidade dos vetores entrada usados durante o treinamento. Este modelo é representado através da separação dos vetores-peso em diferentes agrupamentos. Cada agrupamento (ou classe) representa entradas que são similares.

Redes Neurais – 2010

RAFR 21

LABIC

Rede de Kohonen

- 2. *Criar Mapas que Preservam a Topologia da Rede*: após o processo de aprendizagem da rede, a matriz que representa a sua topologia será vista como um subconjunto discreto do espaço . Assim, supondo que os vetores de entrada são de dimensão n (pertencem ao espaço R^n) e a rede é de dimensão 2 com r linhas e c colunas, a rede treinada é um mapeamento de $R^n \rightarrow [r,1] \times [1,c]$ Este mapeamento preserva a topologia natural dos dados, ou seja, caso dois vetores do conjunto de entrada estejam geometricamente próximos um do outro, então, eles serão mapeados em dois pontos também próximos um do outro (vizinhos) na matriz $[r,1] \times [1,c]$.

Redes Neurais – 2010

RAFR 22

LABIC

Modelo de Kohonen



Treinamento de vizinhança localizada

This effect of restricting the neighborhood in the learning process is illustrated in the diagram. The diagram shows a grid of neurons. A central neuron is highlighted, and its neighborhood is defined by a small region around it. The text explains that this process allows the network to learn the local structure of the input data, resulting in a map that preserves the topology of the input space.

2009/0202 Redes Neurais - André Poince de Leon F. de Carvalho - LABIC/USP

REDES NEURAIS - 2010

RAFR 23

LABIC

Algoritmo de Kohonen

- Para cada vetor de entrada , executa-se os seguintes passos:
 1. Identifica-se um neurônio z com a entrada apresentada, isto é, o neurônio cujo vetor-peso tiver a menor distância euclidiana em relação a entrada apresentada é escolhido.
 2. Atualizar gradualmente este neurônio e sua vizinhança . Isto é atualizar desde um raio inicial que é igual a largura da rede até um raio final igual a zero, que corresponde a atualizar somente o neurônio escolhido.

Redes Neurais – 2010

RAFR 24

LABIC

Algoritmo de Kohonen

A atualização do vetor-peso associado a um neurônio j ocorre na direção do vetor entrada x pela seguinte fórmula geral:

$$\Delta w_j = \begin{cases} \alpha(x - w_j), & j \in N_z \\ 0, & \text{c.c.} \end{cases}$$

onde α é uma função do tempo e determina o quanto deve caminhar na direção de x .

Redes Neurais – 2010

RAFR 25

LABIC

Algoritmo de Kohonen

- Os pesos são atualizados:

$$w_j(n+1) = \begin{cases} w_j(n) + \alpha(n)[x(n) - w_j(n)], & j \in N_z(n) \\ w_j(n), & \text{c.c.} \end{cases}$$

- onde n aumenta de uma unidade a cada variação de vizinhança e a cada nova entrada apresentada.

Redes Neurais – 2010

RAFR 26

LABIC

Algoritmo de Kohonen

- Critério de Convergência**

Para assegurar convergência dos vetores-peso, dois requisitos devem ser satisfeitos:

- α deve satisfazer os seguintes condições:

$$0 < \alpha(n) < 1 \rightarrow \forall n$$

$$\alpha(n) \text{ deve ser uma função decrescente}$$
 Quando α atinge um certo limite, diz-se que o aprendizado ocorreu.
- O tamanho da vizinhança N_z deve satisfazer duas condições:

$$1 < N_z(n) < \max(\text{linha}, \text{coluna}) \rightarrow \forall n$$

$$N_z(n) \text{ deve ser uma função decrescente}$$
 onde $\max(\text{linha}, \text{coluna})$ é considerado o diâmetro da rede.

Redes Neurais – 2010

RAFR 27

LABIC

Critério de Parada

Como $\alpha(n)$ deve ser decrescente durante o processo de aprendizado, esta função deve ser atualizada a cada novo padrão (entrada) apresentado à rede. Depois que todas as entradas foram apresentadas, verifica-se se um certo limite, que deve ser um valor bem próximo de zero, foi atingido pela função decrescente $\alpha(n)$. Em caso positivo, a etapa de treinamento está concluída; caso contrário, as entradas devem ser reapresentadas à rede, até o limite especificado seja alcançado.

Redes Neurais – 2010

RAFR 28

LABIC

Rede de Kohonen

- Terminado o treinamento, à cada nova entrada é associado o neurônio que melhor a represente de acordo com o critério da menor distância euclidiana. Cada neurônio no mapa topológico deve representar apenas uma entrada.
- Assim, o resultado obtido na rede pode ser visualizado na matriz escolhida para representar a topologia da rede

Redes Neurais – 2010

RAFR 29

LABIC

Exercício

Utilizar o Modelo de Rede de Kohonen para agrupar o conjunto iris.dat em 3 classes.

Redes Neurais – 2010

RAFR 30

LABIC

Restrições do Modelo de Kohonen

- Topologia fixa;
- Comparação sequencial para encontrar a unidade ganhadora (Cuadros-Vargas 2002, 2003);
- Tempo de treinamento elevado. i.e WEBSOM (Kohonen, 98);
- Falta de prova de convergência
- Determinação da taxa de aprendizado é de forma heurística

Redes Neurais – 2010

RAFR 31

LABIC

Modelos construtivos

- *Grid-Growing Algorithm* apresentado por Blackmore (Blackmore and Miikkulainen, 1993).
- *Neural Gas plus Competitive Hebbian Learning* (Martinetz and Schulten, 1991, 1994)
- *Growing Neural Gas - GNG* (Fritzke, 1994a, 1995)
 - ♦ Demo: http://www.neuroinformatik.ruhr-uni-bochum.de/ini/VDM/research/gsn/DemoGNG/NG_2.html

Redes Neurais – 2010

RAFR 32

LABIC

Bibliografia

- **Redes Neurais Artificiais: Teoria e Aplicações**, Antônio Braga, André de Carvalho e Teresa Ludermir, LTC, 2007.
- **Material didático disponível no site do Labic (Laboratório de Inteligência Computacional) – ICMC / USP.**
 - ♦ <http://labic.icmc.usp.br>
- **Redes Neurais Artificiais para Extração de Características**, Patrícia Rufino Oliveira, Dissertação de Mestrado, ICMC / USP, 1997.
- Haykin, S., “Introduction to Neural Networks”, 1999

Redes Neurais – 2010

RAFR 33

LABIC

Referências

- Blackmore, J. and Miikkulainen, R. (1993). Incremental grid growing: Encoding high-dimensional structure into a two-dimensional feature map. In *Proc. ICNN'93, International Conference on Neural Networks*, volume I, pages 450–455, Piscataway, NJ. IEEE Service Center.
- Martinetz, T. M. and Schulten, K. J. (1991). Network learns topologies. In T. Kohonen, K. Makisara, O. Simula and J. Kangas (Eds.): *Artificial Neural Networks*.
- Fritzke, B. (1994a). Fast learning with incremental rbf networks. *Neural Processing Letters*, 1(1):2–5.
- Kohonen, T. (1998). Self-organization of very large document collections: State of the art. In Niklasson, L., Bod' en, M., and Ziemke, T., editors, *Proceedings of ICANN98, the 8th International Conference on Artificial Neural Networks*, volume 1, pages 65–74, London. Springer.

Redes Neurais – 2010

RAFR 34

LABIC

Referências

- Fritzke, B. (1995). A growing neural gas networks learns topologies. *Advances in Neural Information Processing Systems*, 7:625–632.
- E. Cuadros-Vargas and R. Francelin Romero and Klaus Obermayer. Speeding up algorithms of SOM Family for Large and High Dimensional Databases. In [Workshop on Self Organizing Maps](#), Kitakyushu Japan, September 2003.
- E. Cuadros-Vargas and R. Francelin Romero. A SAM-SOM Family: Incorporating Spatial Access Methods into Constructive Self-Organizing Maps. In *Proc. IJCNN'02, International Joint Conference on Neural Networks*, pages 1172-1177. Hawaii, HI. 2002. IEEE Press.

Redes Neurais – 2010

RAFR 35