

Mestrado em Engenharia Elétrica

Processamento de Imagem

Prof Dr Aristófanés Correa Silva (DEE)

Prof Dr Alexandre César Muniz de Oliveira (DEINF)

www.deinf.ufma.br/~acmo

1. **Objetivo:** Pesquisar técnicas heurísticas para segmentação de imagens. Aplicações em processamento de imagens compreendendo:
 - a. Lógica Fuzzy e Agrupamento
 - b. Redes neurais
 - c. Heurísticas de busca
 - d. Aplicações
2. **Bibliografia:**
 - a. The Image Processing Handbook – John Russ. IEEE Press
 - b. Artigos diversos
3. **Metodologia:** aulas expositivas e trabalhos de implementação

Introdução às Redes Neurais Artificiais

Jorge M. Barreto

Laboratório de Conexionismo e Ciências Cognitivas
UFSC -Departamento de Informática e de Estatística
88040-900 - Florianópolis - SC

Passado e futuro

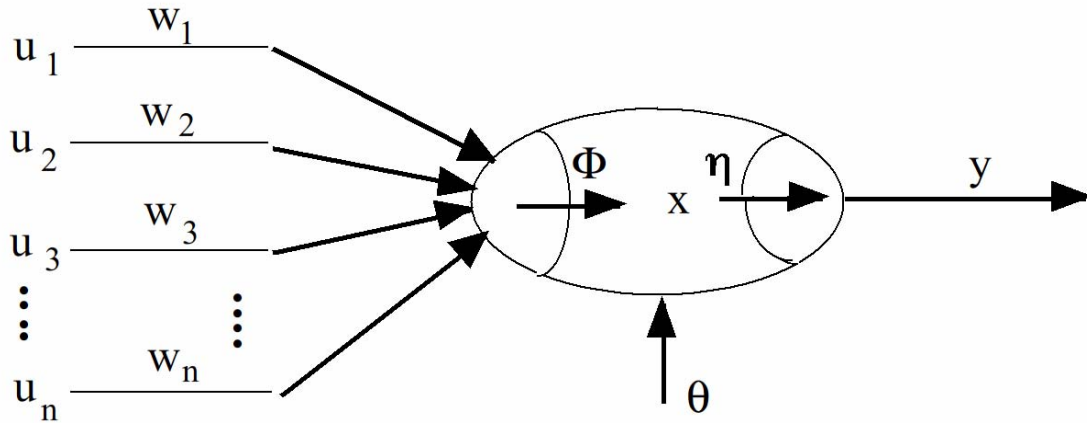
- A construção de redes neurais artificiais (RNAs) tem inspiração nos neurônios biológicos e nos sistemas nervosos.
- As RNAs estão muito distantes das redes neurais naturais (RNNs) e frequentemente as semelhanças são mínimas.
- Motivação para a pesquisa nos dias de hoje:
 - O primeiro é modelar o sistema nervoso com suficiente precisão de tal modo a poder observar um comportamento emergente que sendo semelhante ao comportamento do ser vivo modelado, possa servir de apoio às hipóteses usadas na modelagem.
 - O segundo é construir computadores com um alto grau de paralelismo.

O que as RNAs não são!


- A semelhança entre RNA e RNN é limitada. As RNAs são uma caricatura da realidade biológica.
 - **RNN não são circuitos digitais.** O modelo apresentado por McCulloch-Pitts usava sinais binários. O neurônio biológico expressa sua ativação pela frequência que emite pulsos e esta frequência tem uma variação contínua entre dois valores positivos.
 - **RNN não podem ter excitação negativa.** Alguns modelos usam valores de excitação negativa.
 - **RNN não são homogêneas.** As RNN não possuem todos os seus neurônios de mesmo tipo como nas RNA, apenas em algumas regiões existe uma certa uniformidade no tipo de neurônios existentes nas RNN.
 - **RNN não são circuitos síncronos ou assíncronos.** As RNN são sistemas a tempo contínuo, logo não cabe a classificação de síncrono ou assíncrono.
 - **Nem neurônios nem sinapses tem dois valores.** Logo a semelhança com o “spin” do elétron não é válida.
 - **Circuitos cerebrais não são capazes de cálculos recursivos.** Isto é consequência dos neurônios não serem sistemas discretos, levando a rede a não ser um autômato. Logo, equivalência com problemas solúveis por funções recursivas não tem sentido biológico. Entretanto, os neurônios das RNAs fazem das RNAs sistemas equivalentes à máquina de Turing e portanto capazes de resolver funções recursivas.

Modelo Geral de Neurônio

- Generalização do modelo de McCulloch e Pitts.



- A função Φ pode ser:
 - A soma das entradas.
 - O produto das entradas.
 - Raramente uma outra função.
- A não linearidade do neurônio frequentemente é introduzida na função de ativação, θ que pode ser não-linear




Neurônio estático e dinâmico

- O neurônio é dito dinâmico se para o cálculo de y em um determinado instante é necessário o conhecimento de x em um instante anterior no caso do neurônio ser de tempo discreto.
- Um neurônio é estático quando o valor de x e de y se referem ao mesmo instante que as excitações ou seja, o retardo é nulo.

Redes diretas (Feedforward)

- Redes Diretas são aquelas cujo grafo não tem ciclos e são representadas em camadas (monocamada ou multicamada).
- Neurônios que recebem sinais de excitação são chamados da camada de entrada.
- Neurônios que têm sua saída como saída da rede pertencem a camada de saída.
- Neurônios que não pertencem nem a camada de entrada nem a de saída são neurônios internos à rede podendo se organizar em uma ou mais camadas internas (“hidden layers”).



Aprendizado

- Aprender é o ato que produz um comportamento diferente a um estímulo externo devido a excitações recebidas no passado e é, de certa forma, sinônimo de aquisição de conhecimento.
- Aprender pode ser considerado como atributo fundamental de um comportamento inteligente.
- Sistemas inteligentes apresentam algumas características são comuns a organismos inteligentes:
 - Adaptativos: percebem alterações no ambiente em que estão inseridos e se adaptam;
 - Autônomos: são conduzidos a um estado de equilíbrio sem a necessidade de intervenção humana;
 - Descentralizados: subsistemas podem interagir entre si de forma independente e paralela;
- **RNA possuem a capacidade de aprenderem por exemplos, e fazerem interpolações do que aprenderam.**
- **Os exemplos representam todo o conhecimento necessário para ela aprender algo.**
- **O processo gerador dos exemplos é totalmente desconhecido para a rede.**
- **No aprendizado conexionista não é necessário se conhecer as regras, como na abordagem simbólica da IA**
- **A intensidade de conexões entre neurônios representa regras que foram aprendidas através dos exemplos**
- **Como o conhecimento é armazenado nas conexões, o uso de RNA está intimamente ligado ao que se chama de conexionismo.**

Tipos de aprendizado

- Aprendizado Supervisionado
 - Neste caso o 'professor' indica explicitamente um comportamento bom ou ruim.
 - Escolhe-se uma rede direta, com dois neurônios na camada de saída, uma ou várias camadas internas e uma conjunto de neurônios na camada de entrada capaz de representar com a precisão desejada a letra em questão.
 - Apresentam-se pares de entrada-saída sucessivamente a uma retina artificial constituída por uma matriz de elementos fotossensíveis, cada um ligado a um neurônio de uma RNA direta (feedforward).
 - Observa-se qual dos neurônios de saída está mais excitado.
 - Se for o que se convencionou representar a saída desejada, nada deve ser corrigido.
 - Caso contrario modifica-se os valores das conexões sinápticas no sentido de fazer a saída se aproximar da desejada.
 - Para cada exemplo apresentado uma correção é introduzida.
 - Este tipo de treinamento tem atraído atenção de muitos pesquisadores, por poder ser encarado como um problema de otimização e usar ferramentas que já mostraram sua eficiência, tanto em programação linear e não linear.
 - Basta para isso, considerar o aprendizado com a minimização do erro entre a saída da rede e uma saída desejada.

- Aprendizado não Supervisionado
 - Para que sejam feitas modificações nos valores das conexões sinápticas não se usa informações sobre se a resposta da rede está correta ou não
 - Os exemplos não possuem pares entrada-saída.
 - Para entradas semelhantes a rede deve responder de modo semelhante.
 - Este aprendizado pode ser considerado descobridor de regularidades
 - As redes que assim aprendem se auto-organizam para assumir o comportamento desejado

- Auto associador
 - Uma coleção de exemplos é apresentada à rede, a qual é suposta memorizar os exemplos.
 - Depois, quando um destes exemplos for novamente apresentado de modo deteriorado supõe-se que a rede restitua o original sem deterioração.
 - Neste caso aprende-se a funcionar como um filtro.
- Hetero-associador
 - Variante do auto-associador em que se memoriza um conjunto de pares.
 - O sistema aprende a reproduzir o segundo elemento do par mesmo que o primeiro seja apresentado de modo contendo pequenas alterações (ruídos).
 - Também conhecido como um reconhecedor de padrões, onde o primeiro elemento apresentado é elemento a reconhecer e o segundo um elemento do conjunto de padrões considerado.
- O detetor de regularidades
 - Variante do reconhecedor de padrões quando estes não são definidos a priori.
 - O sistema deve se auto-organizar, e criar os possíveis padrões.

Regras de Aprendizado Conexionistas

- Essencialmente o aprender de redes neurais consiste em colocar valores de conexões sinápticas.
- Em alguns casos estes valores são colocados representando um certo conhecimento, como no caso usado em sistemas especialistas.
- Em outros usa-se um algoritmo para encontrá-los. A este algoritmo chama-se algoritmo de aprendizagem.
- Regra Delta

- Ajuste a intensidade da conexão entre os neurônios A e B de uma quantidade proporcional ao valor da ativação simultânea dos dois neurônios.

- Se, no entanto, A tenta excitar B e não consegue a conexão é enfraquecida.

- Uma característica importantíssima da lei de Hebb é que ela goza da propriedade de localidade.

- Isto significa que para alterar o valor de uma conexão sináptica apenas informações locais à sinapse em jogo são usadas dando plausibilidade biológica ao algoritmo.

Regra Delta

- Tomando a regra de Hebb: $\Delta w_{ij} = \eta x_i o_j$

w_{ij} intensidade da conexão entre os neurônios i e j

Δw_{ij} acréscimo da intensidade da conexão entre os neurônios i e j

η parâmetro definindo a intensidade da correção chamado *taxa de aprendizado*

x_i estado de ativação do neurônio i

o_j saída do neurônio j

- Complementando: $\Delta w_{ij} = \Phi(x_i, d_i, w_{ij}, o_j, t)$

- Chega-se a Widrow-Hoff: (delta) $\Delta w_{ij} = \eta(d_i - x_i)o_j$

$$E_p = \frac{1}{2} \sum_j (d_{pj} - o_{pj})^2$$

- Pode-se calcular o erro:
- O erro é função do valor das conexões
- Para calcular seu mínimo deve-se encontrar os valores que anulam a primeira derivada:

$$\begin{aligned} \frac{\partial E_p}{\partial w_{ij}} &= \frac{\partial E_p}{\partial o_{ip}} \partial o_{ip} \partial w_{ij} \\ &= -(d_{pj} - o_{pj}) \frac{\partial o_{pj}}{\partial w_{ij}} \end{aligned}$$

$$\frac{\partial E_p}{\partial w_{ij}} = \eta(d_{pj} - o_{pj})$$

Aprendizado por Retropropagação (“Backpropagation”)

- Regra de aprendizado supervisionado que considerada como a generalização da Regra Delta para redes diretas com mais de duas camadas.
- Neste caso, ao menos uma camada de neurônios não está envolvida com a entrada ou saída e é, portanto, interna à rede.
- Esta camada e suas conexões quando aprendem a efetuar uma função, agem como se houvesse uma representação interna da solução do problema.
- Algoritmo:

- Apresenta-se à rede um exemplo e verifica-se a saída da rede, saída esta que é comparada à saída esperada dando um erro.
- Calcula-se o gradiente deste erro com relação aos valores sinápticos da camada de saída
- Atualiza-se a camada de saída
- Calcula-se o erro da saída da penúltima camada
- Atualizam-se os pesos da penúltima camada
- E assim por diante retropropagando o erro por todas as camadas de conexões.
- A seguir apresenta-se mais um exemplo (pode ser o mesmo repetido) e continua-se o processo até que o erro seja menor que uma tolerância desejada.

- Estas redes são capazes de aproximar, com maior ou menor precisão, dependendo do número de neurônios da rede, qualquer função não-linear.
- Apesar de usarem neurônios dinâmicos (equação diferencial de primeira ordem ou a uma diferença finita), têm uma dinâmica muito limitada não podendo representar todos os sistemas dinâmicos.

Aprendizado Competitivo

- No aprendizado competitivo, usado nas redes popularizadas por Kohonen, neurônios são inibidos por outros neurônios de modo a que a competição entre eles leva a somente um se tornar excitado.
- Enquanto uma rede neural baseada em um aprendizado Hebbiano, vários neurônios de saída podem estar simultaneamente ativos, no caso do aprendizado competitivo, somente um neurônio de saída fica ativo de cada vez.
- Fundamentalmente existem três elementos que caracterizam o aprendizado competitivo:
 1. Existe um conjunto de neurônios idênticos, ligados por valores de conexões sinápticas de valores distribuídos de modo aleatório.
 2. Existe um valor máximo bem definido para a ativação dos neurônios.
 3. Existe um mecanismo que permite que os neurônios entrem em competição pelo direito de permanecerem excitados.



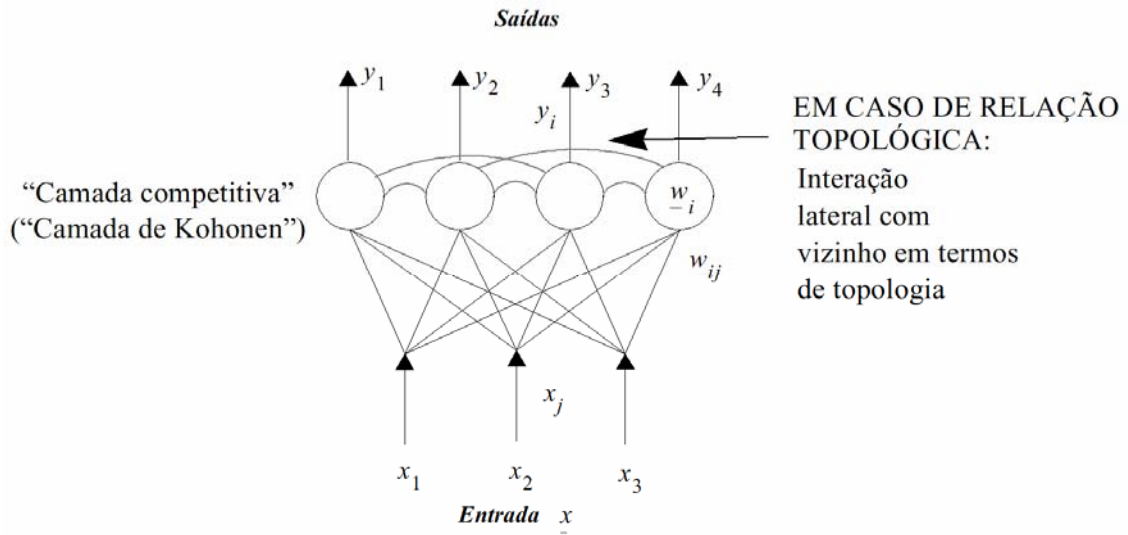
Aprendizado Competitivo

- No aprendizado competitivo entradas possuindo alguma semelhança tendem a excitar o mesmo neurônio na saída.
- Seja o conjunto de entrada

$$T = \{ (x_p) \}_{p=1}^n.$$

- Todos os neurônios recebem o mesmo estímulo \underline{x} .
- Entre a entrada \underline{x} e o neurônio \underline{y} existe um peso \underline{w}
- Todos os neurônios formam a camada competitiva
- Determina-se um vencedor dentro dessa camada competitiva.
- O neurônio vencedor é o único que tem o direito de emitir um sinal de saída que seja 1 (“winner takes all”).
- Todos os demais neurônio ficam inativos

Aprendizado Competitivo



- Adaptação dos Pesos

- Usando o método iterativo de adaptação de pesos, os pesos da rede se modificam exclusivamente baseado na estrutura dos dados de treinamento.

○ A expectativa do comportamento dessa rede é que estímulos semelhantes provoquem a resposta do mesmo vencedor.

- Assim os pesos sinápticos w do neurônio j devem se movimentar em direção aos estímulos:

$$w_{ij}^{(l+1)} = w_{ij}^{(l)} + \eta y_{pi} (x_{pj} - w_{ij}^{(l)})$$

x_{pj} : p -ésimo padrão de entrada

w_{ij} : i -ésimo vetor peso ($i < p$)

y_{pi} : neurônio de saída considerado vencedor (1 ou 0)

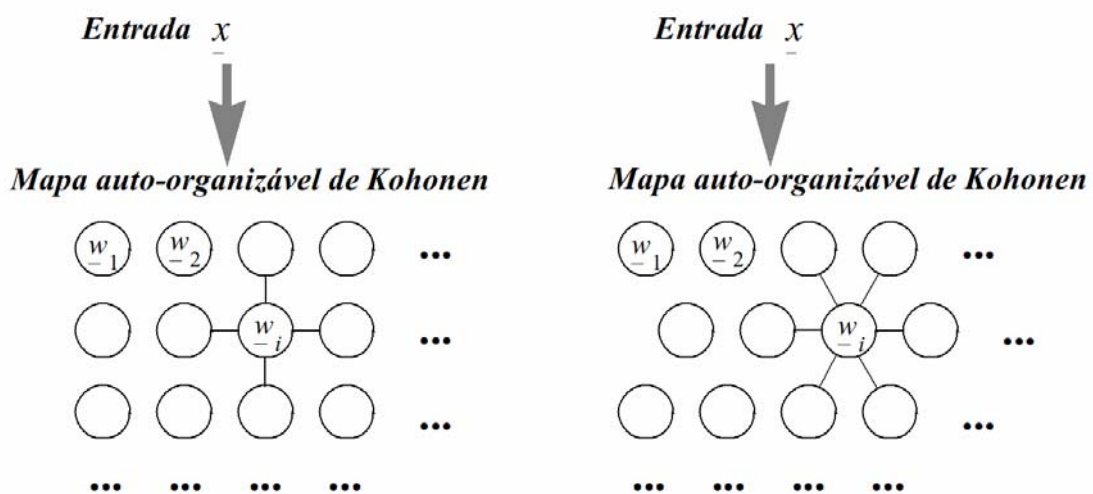
- Cada entrada x_p vai se ativar um neurônio correspondente, de acordo com o w_i mais próximo.

- Após a ativação, o peso correspondente é atualizado, se aproximando ainda mais da entrada que o ativou na próxima iteração

- Um neurônio de saída termina por se especializar em um grupo de padrões de entrada com características similares, considerando que, em geral, existem mais padrões de entrada que neurônios a serem ativados..

- Mapa de preservação topológica

- No cérebro pode-se observar que estímulos sensoriais externos parecidos muitas vezes excitam as mesmas áreas do cérebro
- A área excitada corresponde a um grande número de neurônios “vizinhos”
- Mapa auto-organizável de Kohonen em duas dimensões:
 - Topologias retangular e hexagonal:




- Com esta proposta, os pesos exercem um efeito colateral sobre os vizinhos na camada competitiva.

- Função h(...) de vizinhança

- Ativa vários neurônios com diferentes graus em torno do neurônio vencedor
- Deve ter um valor máximo no centro, i.e. no neurônio vencedor e ter um comportamento decrescente com distância crescente do centro:

$$w_{ij}^{(l+1)} = w_{ij}^{(l)} + \eta h(i^*, i) (x_{pj} - w_{ij}^{(l)})$$

- Pode-se definir ligações inibitórias na vizinhança, afastando os neurônios vizinhos do estímulo, em vez de atraí-los, através de h(...) com valores menores que zero na vizinhança.
- Decremento linear de η permite uma adaptação rápida e “grossa” no início e lenta e “fina” no final.



- Algoritmo básico

Inicializar pesos e parâmetros

Repetir (até o mapa de características não mudar)

Para cada padrão de treinamento x faça

Definir nodo vencedor

Atualizar os pesos deste nodo e de seus vizinhos

Se número do ciclo for múltiplo de n então

Reduzir taxa de aprendizagem e vizinhança


Fim

Fim

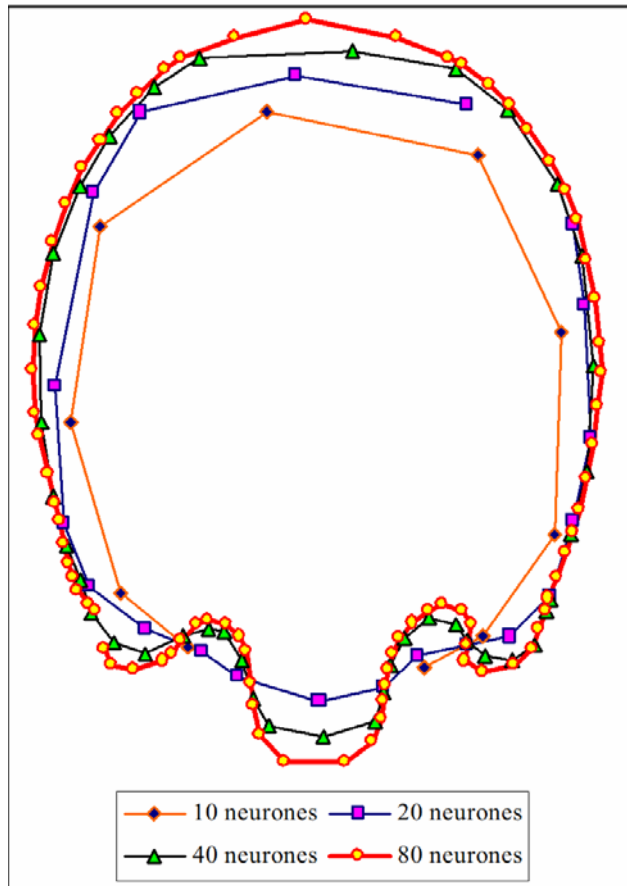

Fim

Aplicação do Mapa de Kohonen


Reyes-Aldasoro, C. C., and Aldeco A. L., Image Segmentation and Compression using Neural Networks, Advances in Artificial Perception and Robotics CIMAT, Guanajuato, México October 23-25, 2000, Guanajuato, Mexico.



. Adaptation of an 8*8 network to square input region



- Número de neurônios é decisivo para o processo:
 - Reduz a distância entre neurônios
 - Aumenta a qualidade da segmentação



- A adaptação da rede se aproxima do sinal de entrada
- A distância entre neurônios adjacentes pode ser uma medida de qualidade na segmentação da imagem:

$$\bar{d}_{\max}^{adj} = \max_i \|m_i(t) - m_{i+1}(t)\|$$