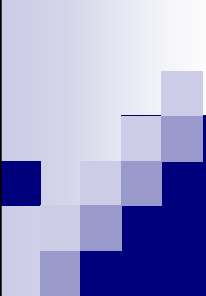


Sistemas de Apoio à Decisão – Outras redes neuronais

V 1.1, V.Lobo, EN/ISEGI, 2007



Redes Neuronais (outras redes)

Victor Lobo

LVQ – Linear vector quantization

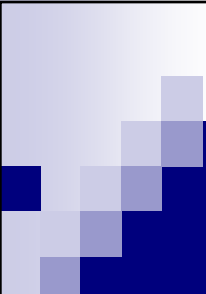
- Derivado do SOM, mas aplicado a aprendizagem supervisionada
- Neurónios recebem classes “à partida”
- Actualização do neurónio depende da classe do neurónio e da classe do novo exemplo
 - Se a classe é a mesma, o neurónio é atraído
 - Se a classe é diferente, o neurónio é repellido

Principais arquitecturas de redes

- Aprendizagem Supervisionada
 - MLP com BP
 - Multi-Layer Perceptron (perceptrão multicamada)
 - Treinado com Backpropagation (retropropagação do erro)
 - Variantes, vantagens, desvantagens, características...
- Aprendizagem Não Supervisionada
 - SOM
 - Self-Organizing Map (mapa auto-organizado)
 - Variantes, vantagens, desvantagens, características...

Algoritmo de treino do LVQ

- Para cada padrão de entrada:
 - 1) **Calcular** a distância entre o padrão de dados e todos os neurónios:
$$(d_{ij} = \|x_k - w_{ij}\|)$$
 - 2) **Escolher** o neurónio vencedor
$$w_{winner} (w_{ij} : d_{ij} = \min(d_{mn}))$$
 - 3) **Actualizar** cada neurónio de acordo com a regra
 - Para neurónis com a mesma classe do padrão
$$w_{ij} = w_{ij} + \alpha \cdot h(w_{winner}, w_{ij}) \cdot \|x_k - w_{ij}\|$$
 - Para neurónis com uma classe diferente
$$w_{ij} = w_{ij} - \alpha \cdot h(w_{winner}, w_{ij}) \cdot \|x_k - w_{ij}\|$$
 - 4) **Repetir** o processo até que um critério de paragem seja atingido.



LVQ Linear Vector Quantization

LVQ

- Inicialização do mapa
 - É comum fazer um SOM primeiro
- Aprendizagem para cada novo exemplo
 - Para neurónis com a mesma classe do padrão
$$w_{ij} = w_{ij} + \alpha \cdot h(w_{winner}, w_{ij}) \cdot \|x_k - w_{ij}\|$$
 - Para neurónis com uma classe diferente
$$w_{ij} = w_{ij} - \alpha \cdot h(w_{winner}, w_{ij}) \cdot \|x_k - w_{ij}\|$$
- Resultado final
 - Cada neurónio vai mapear uma só classe
 - Maior separação entre classes

Sistemas de Apoio à Decisão – Outras redes neuronais

V 1.1, V.Lobo, EN/ISEGI, 2007


RBF Radial Basis Function Networks

Comparação MLP/RBF

- RBF só tem 1 camada escondida
- Cada neurónio num RBF é um “detector”, que define um “círculo” no espaço de entrada. Cada neurónio num MLP define um plano de separação.
- MLP usa produtos internos, RBF usa distâncias.
- MLP generaliza mais facilmente para zonas do espaço de entrada onde não há dados de treino. (RBF é uma aprendizagem mais localizada)

RBF – Radial Basis Function Networks

- Radial Basis Functions – Funções de base radial
 - O valor da função depende da distância a uma referência, e assintoticamente decresce com esta
 - Também chamadas “kernel functions”
 - Parametrizadas pela posição central, largura, e eventualmente forma




Implementação das RBF em SAS

- Objecto comum às MLP
 - Escolher na opção “Architecture” RBF
 - Equal Width – Todos os neurónios têm a mesma função de activação, e só a colocação dos neurónios no espaço é aprendida
 - Unequal Width – O raio da cada RBF também é aprendido
 - Em opções avançadas
 - Escolher função de activação
 - Vários tipos de funções possíveis

Topologia de uma RBF

- Função implementada

$$\square f(x) = w_0 + \sum w_i K_i(d(n_i, x))$$




Redes para séries temporais

Sistemas de Apoio à Decisão– Outras redes neuronais

V 1.1, V.Lobo, EN/ISEGI, 2007

Tempo “embitido” (embedded)


- Dividir a série temporal em vetores de n valores (atributos) + 1 valor alvo



- Usar uma transformação para outro espaço (por exemplo, transformada de Fourier ou Wavelets)

Aprendizagem Hebbiana


- Se dois neurónios são activados ao mesmo tempo, as ligações entre eles deverão ser reforçadas



- Aprendizagem
 - Reforçar/enfraquecer ligações
- Utilização
 - Dar parte do padrão e associar o resto

Redes recorrentes

- Usam malhas de atraso na própria rede



- NARX – Non-linear Auto-Regressive with exogenous inputs

Redes de Hopfield

- Para treinar
 - Forçar um padrão, e minimizar erros
- Para “associar”
 - Dar parte de um padrão, e a rede converge para um estado onde o resto do padrão é definido
- Trajectórias no espaço de pesos

