Redes Neuronais (outras redes)

Victor Lobo

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...

LVQ
Linear Vector Quantization

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 repelido

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

$$w_{ij} = w_{ij} + \alpha \; h(w_{winner}, w_{ij}) \; || x_k - w_{ij} ||$$

Para neurónis com uma classe diferente

$$w_{ij} = w_{ij} - \alpha \; h(w_{winner}, w_{ij}) \; || x_k - w_{ij} ||$$

4)Repetir o processo até que um critério de paragem seja atingido.

LVQ

- Inicialização do mapa
  - É comum fazer um SOM primeiro
- Aprendizagem para cada novo exemplo

Para neurónios com a mesma classe do padrão

$$w_{ij} = w_{ij} + \alpha \; h(w_{winner}, w_{ij}) \; || x_k - w_{ij} ||$$

Para neurónios com uma classe diferente

$$w_{ij} = w_{ij} - \alpha \; h(w_{winner}, w_{ij}) \; || x_k - w_{ij} ||$$

- Resultado final
  - Cada neurónio vai mapear uma só classe
  - Maior separação entre classes

RBF
Radial Basis Function Networks

RBF – Radial Basis Function Networks

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

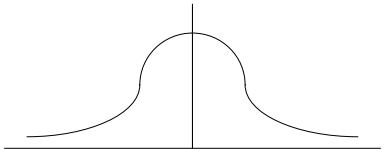

Topologia de uma RBF

- Função implementada
  - $f(\boldsymbol{x})=w_0+\sum w_i K_i(d(\boldsymbol{n_i},\boldsymbol{x}))$

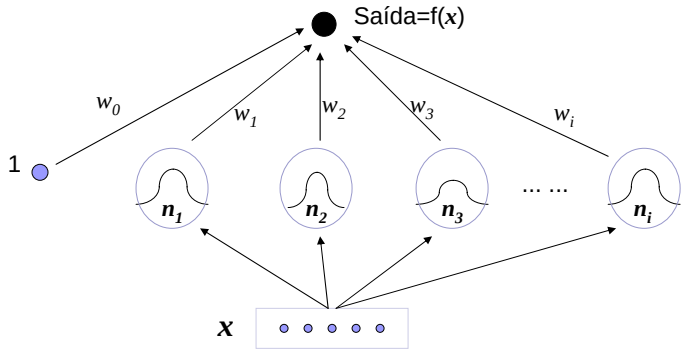

Comparação MLP/RBF

- RBF só tem 1 camada escondida
- Cada neurónio num RBF é um "detector", que define um "circulo" 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)

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

Redes para séries temporais

Tempo “embitido” (embedded)

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

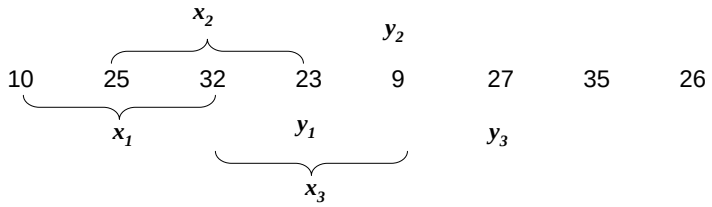

- Usar uma transformação para outro espaço (por exemplo, transformada de Fourier ou Wavelets)

Redes recorrentes

- Usam malhas de atraso na própria rede

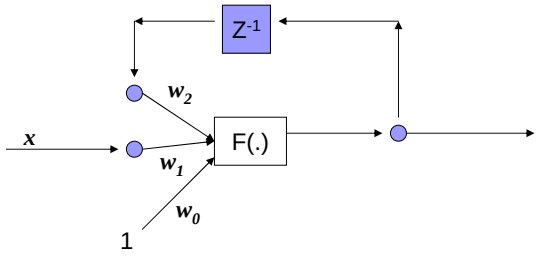

- NARX – Non-linear Auto-Regressive with eXogenous inputs

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

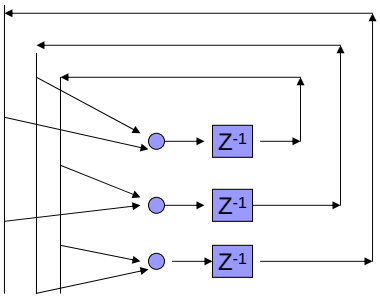

Aprendizagem Hebbiana

- 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