

2. Redes Neurais Artificiais

Prof. Renato Tinós

Depto. de Computação e Matemática (FFCLRP/USP)

2.4. Outras Redes Neurais Artificiais

2.4.1. Redes RBF

2.4.2. Mapas Auto-Organizáveis de Kohonen

2.4.3. Processamento Temporal

2.4.3.1. Rede Alimentada Adiante Focada Atrasada no Tempo (TLFN Focada)

2.4.3.2. Arquiteturas Recorrentes

2.4.3.3. Modelo de Hopfield

2.4.4. Projeto de RNAs

2.4.4. Projeto de RNAs

- **Projeto de sistemas convencionais**
 - Formular modelo matemático a partir de observações do ambiente
 - Validar o modelo com dados reais
 - Construir o sistema utilizando o modelo
- **Projeto de Redes Neurais**
 - Baseado apenas nos dados
 - » Conhecimento pode ser inserido

2.4.4. Projeto de RNAs

- **Selecionar arquitetura adequada para a rede**
 - Modelo
 - Número de camadas
 - Número de neurônios por camada
 - Topologia
 - » Connectividade
 - » Sentido

2.4.4. Projeto de RNAs

- **Escolha do modelo**
 - Características dos dados e da aplicação direcionam a escolha do modelo
 - » Existência de saídas desejadas ou sinais de avaliação da qualidade da solução
 - » Necessidade de recorrência
 - Série temporal
 - » Tempo de resposta
 - » Taxas de erro/acerto

2.4.4. Projeto de RNAs

- **Camada de entrada**

- Número de elementos da camada de entrada igual ao de elementos do vetor de entrada
- Pré-processamento pode aumentar ou diminuir número de elementos do vetor de entrada
 - » Seleção de Atributos

- **Camada de saída**

- Um neurônio por classe, valor ou parâmetro

2.4.4. Projeto de RNAs

- **Conjuntos de dados**
 - Tamanho depende da complexidade dos dados
 - » Quanto maior a complexidade, maior a quantidade necessária
 - Devem ser representativos
 - » Pré-processamento dos dados
 - Dados numéricos
 - Presença de valores em todos os campos
 - Balanceamento entre classes

2.4.4. Projeto de RNAs

- **Pré-processamento de dados**
 - Conversão de valores simbólicos para valores numéricos
 - » Quando os valores apresentam ordenação
 - Codificar cada valor por um número inteiro ou real
 - » Quando os valores não apresentam ordenação
 - Vetores de valores binários, cada um com um elemento igual a 1 e os demais iguais a 0
 - Assim, a distância entre os dados fica igual
 - Tamanho do vetor igual ao número de valores diferentes

2.4.4. Projeto de RNAs

- **Pré-processamento de dados**
 - Estimativa de valores ausentes
 - » Média de todos os valores do mesmo campo
 - » Média entre anterior e posterior
 - » Criação de um novo valor
 - Normalização de valores numéricos
 - » Normalizar cada campo individualmente
 - » Assegurar que todos os valores de um dado campo estejam dentro de um intervalo (Ex. [0,0;...;1,0])

2.4.4. Projeto de RNAs

- **Conjuntos de dados**

- São geralmente divididos em

- » (Sub)conjunto de treinamento

- Dados para o treinamento da rede

- » (Sub)conjunto de teste

- Uma vez selecionados os parâmetros, resultados de teste fornecem um indicativo do desempenho da rede para novos dados

- generalização

- » (Sub)conjunto de validação

- Nem sempre é utilizado

- Os dados são divididos aleatoriamente entre os subconjuntos

- Balanceamento

2.4.4. Projeto de RNAs

- **Conjuntos de dados**
 - **Conjunto de validação**
 - » Resultados de validação devem ser utilizados para seleção dos parâmetros (durante o treinamento)
 - Envolve
 - Tempo de processamento
 - Taxas de erro, rejeição e acerto
 - Natureza dos erros

2.4.4. Projeto de RNAs

- **Conjuntos de dados**

- Funções de erro

- » Soma dos erros quadráticos ou SSE (do inglês, *Sum of Squared Error*)
 - » Erro quadrático médio ou MSE (do inglês, *Mean Squared Error*)
 - » Erro médio relativo ou MRE (do inglês *Mean Relative Error*)
 - » Raiz quadrada do erro médio ou RMS (do inglês *Root Mean Squared Error*)
 - » RMS normalizado, também conhecido por erro de previsão normalizado ou NPE (*Normalized Prediction Error*)

2.4.4. Projeto de RNAs

- **Conjuntos de dados**
 - Funções de erro para problemas de classificação
 - » As funções de erro anteriores geralmente não são medidas adequadas de desempenho em problemas de classificação
 - » Desempenho da rede deve ser medido pelo número de padrões corretamente / incorretamente classificados
 - Taxa de erro de um classificador ou taxa de erro
 - » Outras medidas, como especificidade, sensibilidade, curva ROC, podem ser também utilizadas, dependendo da aplicação

2.4.4. Projeto de RNAs

- **Inicialização dos parâmetros a serem otimizados**
 - Geralmente, é aleatória
 - » Necessidade de repetir o treinamento da RNA

2.4.4. Projeto de RNAs

- **Avaliação**

- Existem diversos métodos para a avaliação da RNA

- » *Holdout*

- Divide-se o conjunto de dados em subconjuntos com tamanhos dados por porcentagens do tamanho do conjunto original
 - Subconjunto de treinamento (Ex.: 50% dos dados)
 - Subconjunto de validação (Ex.: 25% dos dados) – nem sempre utilizado
 - Subconjunto de teste (Ex.: 25% dos dados)

2.4.4. Projeto de RNAs

- **Avaliação**

- Métodos para a avaliação da RNA

- » *Cross-Validation*

- No *r-fold cross-validation*, os exemplos são aleatoriamente divididos em r partições de tamanho aproximadamente igual a N/r padrões
- Os padrões em $(r-1)$ partições são utilizados para treinamento, enquanto que a partição restante é utilizada para teste
- O treinamento é repetido r vezes
 - cada vez considerando uma partição diferente para teste
- O erro é calculado como a média dos erros para cada treinamento

- » *Leave-one-out*

2.4.4. Projeto de RNAs

- Fases de um projeto
 - **Fase 1:** Análise dos requisitos
 - **Fase 2:** Escolha de um modelo de RNA
 - **Fase 3:** Escolha dos parâmetros do modelo de RNA
 - **Fase 4:** Pré-processamento dos dados
 - **Fase 5:** Treinamento
 - **Fase 6:** Testes
 - **Fase 7:** Análise dos resultados

- **Referências**

- **Haykin, S. S.. *Redes neurais: princípios e prática*. 2ª ed., Bookman, 2001.**

- » Capítulo 4