



Uma Comparação entre as Redes Neurais Artificiais MLP e RBF na Classificação de Dados

Mikael Patrick Santos de Melo, Mariane Luyara Campos Magalhães, Michelly Martins Ferreira, Henrique Nunes Pereira Oliva, Nilton Alves Maia, Fabíola Thamusia Vieira Torchelsen, Diego Vinícius de Castro Pereira

Introdução

Atualmente diversas aplicações fazem uso de redes neurais artificiais, desde um leitor de digitais humanas a até previsão de acontecimentos no mercado econômico. O procedimento usual na solução de problemas com o uso de redes neurais artificiais passa inicialmente por uma fase de treinamento. Nesta fase, um conjunto de exemplos é apresentado para a rede, a qual extrai as características necessárias para representar as informações fornecidas. Essas características são utilizadas posteriormente para gerar respostas para o problema. A capacidade de aprender por meio de exemplos e de generalizar a informação aprendida é o principal atrativo da solução de problemas por meio de redes neurais artificiais [1].

Nesse trabalho, pretende-se comparar o desempenho das Redes Neurais Artificiais MLP e RBF na classificação de dados, levando em conta o tempo de treinamento e a taxa de acerto.

Material e Métodos

A. Redes Neurais Artificiais

De acordo com Braga, Carvalho e Ludemir [1] as Redes Neurais Artificiais (RNAs) podem ser entendidas como sistemas paralelos distribuídos e compostos por várias unidades de processamento simples que serão responsáveis por realizar cálculos de determinadas funções matemáticas. Essas unidades estarão posicionadas em uma ou várias camadas e interligadas por diversas conexões, que por sua vez, estão associadas a pesos que armazenam o conhecimento representado no modelo, além de ajustar a entrada que será recebida em cada neurônio da rede.

Uma das grandes vantagens das RNAs está na sua arquitetura e no desempenho para soluções de problemas. Braga, Carvalho e Ludemir [1] afirmam que “A solução de problemas através de RNAs é bastante atrativa, já que a forma como estes são representados internamente pela rede e o paralelismo natural inerente à arquitetura das RNAs criam a possibilidade de um desempenho superior ao dos modelos convencionais”.

O processo realizado pelas RNAs para a solução de um problema é iniciado na fase de aprendizagem, onde exemplos serão apresentados à rede e ela deve ser capaz de pegar as características que posteriormente vão gerar respostas para o problema, essa capacidade de aprendizagem é o principal atrativo na solução de problemas [1].

B. Redes Multilayer Perceptron - MLP

O primeiro modelo de rede neural proposto e implementado foi o chamado MCP, proposto por McCulloch e Pitts [2], que possuía entradas onde, com a aplicação de pesos fixos, produziam uma saída. O *perceptron*, proposto por Rosenblat (1958), foi uma evolução do modelo MCP, tendo pesos ajustáveis, e em consequência a possibilidade de aprendizado.

Contudo, o *perceptron* é limitado à resolução de problemas linearmente separáveis. Segundo Braga, Carvalho e Ludemir [1] as redes de múltiplas camadas (Redes Multilayer Perceptron – MLP) foram então desenvolvidas para resolver problemas não-linearmente separáveis. Uma Rede MLP consiste de uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída. É do tipo *feedforward*, ou seja, nenhuma saída de um neurônio de uma camada k será sinal de entrada para um neurônio de uma camada menor ou igual a k , e é completamente conectada, tal que cada neurônio fornece sua saída para cada unidade da camada seguinte [1].

C. Redes Radial Basis Function - RBF

Assim como as redes MLP as redes RBF (*Radial Basis Function*), são redes de múltiplas camadas. A Rede RBF consiste de uma camada de entrada, que conecta a RNA ao seu ambiente, apenas uma camada oculta, que aplica uma transformação não linear do espaço de entrada para um espaço oculto de alta dimensionalidade, e a camada de saída, que aplica uma transformação linear no espaço oculto fornecendo uma saída para a rede. Além disto, Redes RBF também são do tipo *feedforward* e são completamente conectadas [3].



D. Aplicação de Redes Neurais Artificiais na Classificação de Dados

Segundo Oliveira [4] a classificação é um processo onde dados coletados sobre determinado objeto de estudo são generalizados para que estes sejam reconhecidos. Assim, por exemplo, uma rede neural artificial pode ser capaz de classificar e identificar onde ocorreu uma falha em uma determinada rede elétrica, ou até conseguir classificar imagens como sendo de um determinado tipo de solo [5].

E. Neural Network Toolbox Matlab

Para a realização dos testes desse trabalho foi utilizado o toolbox de redes neurais artificiais do Matlab, que fornece toda interface para criação, treinamento, testes, gráficos, entre outras funcionalidades em relação às redes neurais artificiais [6].

Resultados e Discussão

A. Base de dados utilizada para a classificação

A base de dados utilizada para o treinamento e testes das redes neurais artificiais MLP e RBF contem quatro atributos e 358 instancias para cada atributo, sendo reservado para o treinamento 268 (75%) instancias e 89 (25%) para os testes. Os atributos representam respectivamente o valor de Atraso, *Jitter*, Perda e Vazão de um enlace de uma rede de computadores simulada como mostra a Figura 1.

B. Arquitetura e Desempenho da rede MLP

A rede MLP utilizada possui quatro entradas, duas camadas, sendo que a camada escondida é formada por três neurônios e a camada de saída por um neurônio. As funções de ativação utilizadas em todos os neurônios foram do tipo sigmoide. A rede MLP apresentou bons resultados. No treinamento, o melhor resultado obtido pela rede MLP foi de 765.16 segundos com uma taxa de acerto de 100% e o pior resultado foi de 778.23 segundos e taxa de acerto de 99.6%.

C. Arquitetura e Desempenho da rede RBF

Foi utilizada uma rede RBF para o conjunto de entrada, com três camadas, onde a camada escondida tinha o mesmo número de neurônios da camada de entrada e todos os nós da primeira camada estavam conectados com a da segunda camada, e a camada de saída formada por um neurônio.

As redes neurais RBF se mostraram extremamente rápidas e eficientes. No treinamento, o melhor resultado obtido pela rede RBF foi de 0.02 segundos com uma taxa de acerto de 100% e o pior resultado foi de 0.78 segundos e taxa de acerto de 91.3%.

Conclusão

As redes neurais artificiais MLP e RBF possuem pontos em comum, uma vez que, ambas são *feed-forward* não-lineares, são aproximadores universais e são utilizadas em aplicações semelhantes. De maneira geral a vantagem da utilização das redes neurais artificiais RBF está na sua rapidez no processo de treinamento comparado as redes neurais artificiais MLP, por outro lado há um uso maior de memória pelas redes RBF. Mesmo com um maior uso de memória, a rede RBF se saiu melhor, considerando a sua velocidade e taxa de acerto, mostrando-se uma alternativa rápida e eficiente na classificação de dados.

Referências

- [1] BRAGA, A. P.; CARVALHO, A. C. P. L. F.; LUDEMIR, T. B. **Redes Neurais Artificiais: Teoria e Aplicações**. Rio de Janeiro: LTC, 2000. p.1-73.
- [2] MCCULLOCH, W. e PITTS, W. **A Logical Calculus of the Ideas Immanent in Nervous Activity**, Bulletin of Mathematical Biology, pp. 115 – 133, 1943.
- [3] HAYKIN, Simon. **Redes Neurais: Princípios e Práticas**. 2ª edição. Editora Bookman, 2001.
- [4] OLIVEIRA, A. R. de (2005). **Redes Neurais Artificiais Aplicadas na Detecção, Classificação e Localização de defeitos em Linhas de Transmissão**. Dissertação (Mestrado em Engenharia Elétrica) – Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Juiz de Fora, Juiz de Fora, 2005. Disponível em: <<http://www.ufjf.br/ppee/files/2008/12/211047.pdf>>. Acesso em: out. de 2013.
- [5] NETO, L. B.; SIEIRA, A. C. C.; DANZIGER, B. R.; SILVA, J. G. S. **Neuro-CPT: Classificação de Solos Usando-se Redes Neurais Artificiais**. ENGEVISTA, v. 8, n. 1, p. 37-48, junho 2006. Disponível em: <http://www.ufjf.br/engevista/1_8Engevista4.pdf>. Acesso em: out. de 2013.
- [6] MATHWORKS (2014). **Neural Network Toolbox**. Disponível em: <<http://www.mathworks.com/products/neural-network/>>. Acesso em: jun. de 2014.

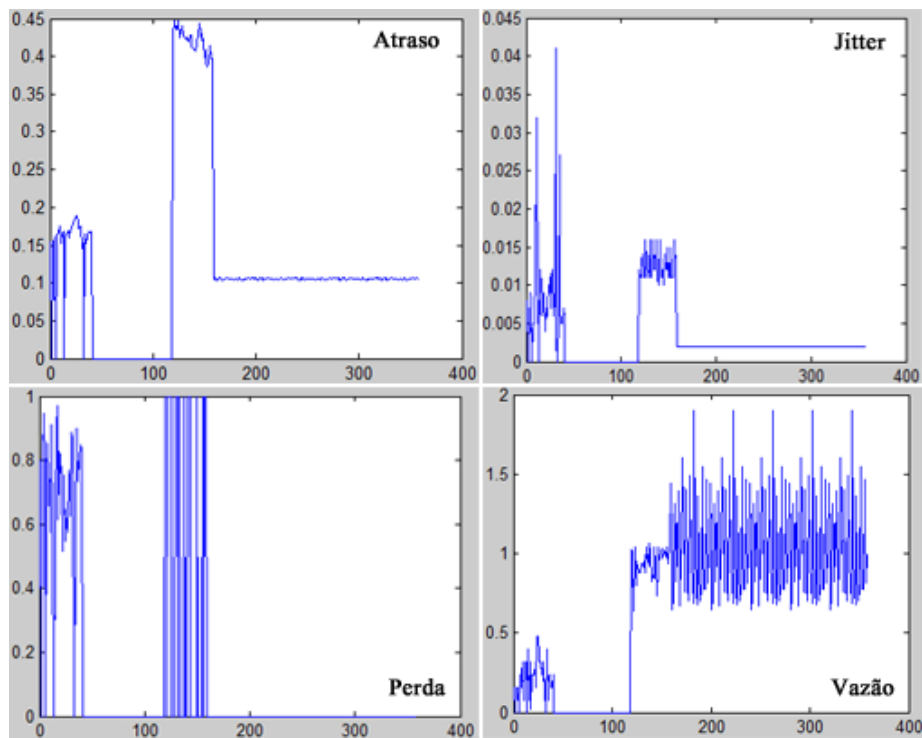


Figura 1. Base de dados formada por *Atraso*, *Jitter*, *Perda* e *Vazão* de um enlace utilizada para o treinamento das redes neurais artificiais.