

Previsão de variáveis físicas através de Redes Neurais

Alexandre Pinhel Soares e André Pinhel Soares

Universidade do Estado do Rio de Janeiro - UERJ

Resumo

Os registros de variáveis físicas, desde que suficientemente longos e confiáveis, podem ser processados por métodos de reconhecimento de padrões direcionados à previsão. Este trabalho apresenta uma forma de implementar um sistema de previsão baseado em Redes Neurais Artificiais. Como exemplo serão mostrados os resultados obtidos com o registro horário de 1995 da temperatura do ar da Estação Meteorológica do Maracanã, situada na cidade do Rio de Janeiro.

INTRODUÇÃO

Uma Rede Neural Artificial (ANN) é uma estrutura computacional baseada em arquiteturas de processamento distribuído encontradas em seres vivos. É composta pela interligação de elementos processadores muito simples, chamados neurônios, e podem ser construídas em meios elétricos, óticos e híbridos ou simuladas em *software*.

Os tipos de redes existentes são caracterizadas pelo modelo do neurônio, pela topologia das interligações e pelo algoritmo de treinamento. Uma visão geral pode ser encontrada em [1] e [2]. Neste trabalho utilizou-se a *multilayered perceptron* (MLP) que é composta por neurônios que possuem n entradas com pesos variáveis (sinapses), uma saída (axônio) e três funções internas (entrada, ativação e saída) que diferem conforme a posição dentro da rede (figuras 1 e 2). Tipicamente a função de entrada calcula a soma ponderada dos sinais aplicados nas sinapses e a função de ativação recebe essa soma e fornece o nível de atividade do neurônio para a função de saída que o aplica ao axônio. A retenção do conhecimento se dá pela variação dos pesos das sinapses no decorrer do treinamento.

O potencial da MLP é conhecido há bastante tempo, porém a sua popularização só veio a ocorrer em 1986, com o trabalho de Humelhart, Hinton e Williams [3], pois até então era desconhecida qualquer estratégia de treinamento. Esses autores desenvolveram a *generalized delta rule*, conhecida também como *backpropagation error correction algorithm*. Essa técnica aplica um padrão na entrada, compara a saída encontrada com a esperada e recalcula os pesos das sinapses a partir da retropropagação do erro.

Em uma MLP a saída é função da entrada, de forma que os dados utilizados devem ter alguma correlação. No caso desse trabalho, a rede recebe em sua entrada os valores da variável de $t-1$ até $t-n$, onde t é o tempo futuro e n é a quantidade de dados passados que será utilizada, e fornece na saída o valor estimado para o tempo t , na grandeza da variável. Nota-se que a previsão é obtida somente a partir do passado.

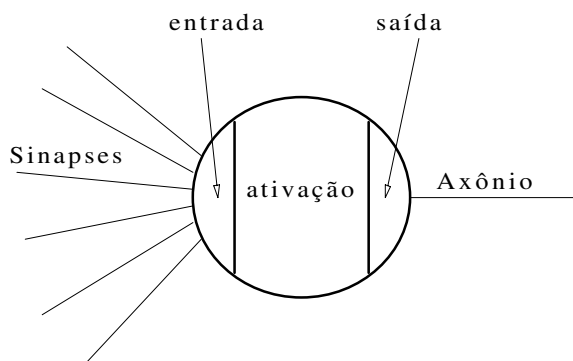


Figura. 1 : Neurônio de uma rede MLP

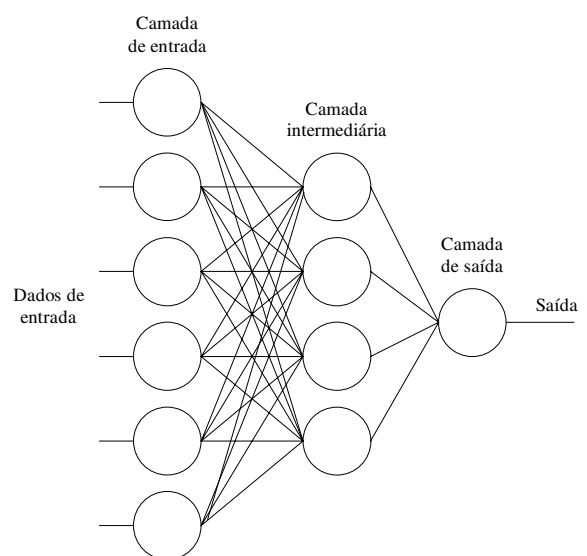


Figura 2 : Rede MLP

O SISTEMA NEURAL DE PREVISÃO

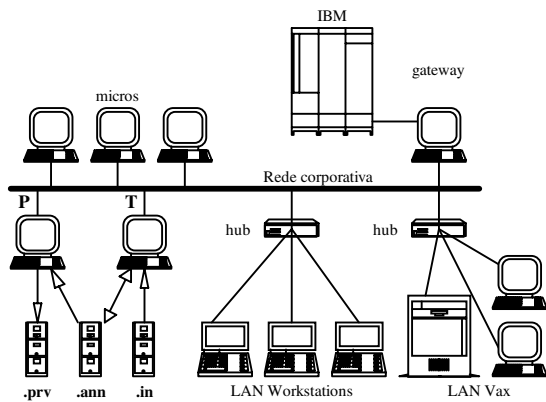
O Sistema Neural de Previsão (SNP) foi desenvolvido em Turbo Pascal e consiste de dois programas. Um será chamado de TREINADOR e é o responsável pelo treinamento da rede, e o outro será chamado de PREVISOR e se utiliza da rede treinada para efetuar a previsão em si.

O TREINADOR lê dois arquivos, um com as condições do treinamento e a configuração da rede e outro com os padrões de entrada e as saídas desejadas. Esses arquivos devem ser compatíveis entre si, i.e., a topologia descrita deve ser apropriada ao formato do arquivo de dados de treinamento.

A condição inicial da rede é dada pela inicialização randômica dos pesos das sinapses e o treinamento pode ser interrompido a qualquer momento para alteração de algum parâmetro.

Ao término do treinamento tem-se o arquivo de configuração da rede devidamente alterado. Esse arquivo é então utilizado pelo PREVISOR que gera um arquivo de saída com a previsão para as próximas *n* horas. A primeira hora é obtida através de dados reais aplicados à entrada da rede, porém da segunda hora em diante as previsões anteriores são usadas na composição do vetor de entrada que fornecerá o valor subsequente.

Todos os arquivos envolvidos são texto (ASCII), com isso consegue-se praticamente total independência da plataforma computacional a que o SNP for acoplado (figura 3). Pelo tempo gasto no treinamento, deve-se ter um micro dedicado ao TREINADOR e operando *off-line*. O arquivo de configuração obtido pode ser acessado, via rede local, pelo micro responsável pela previsão de forma que retreinamentos de rotina sejam transparentes ao operador do PREVISOR.


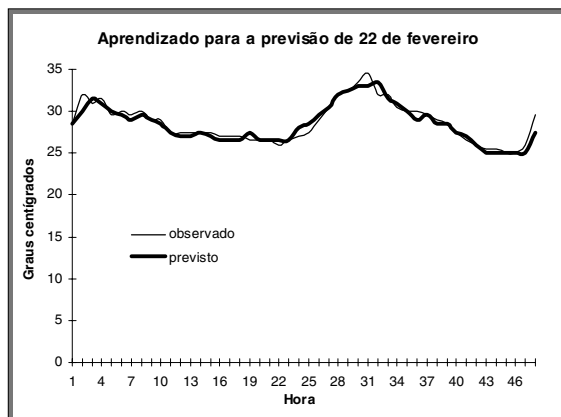


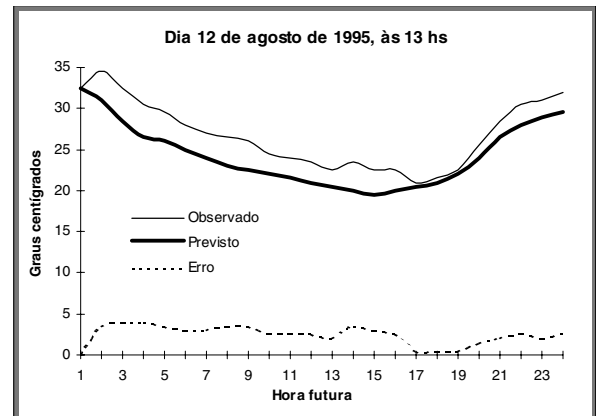






- .ann - arquivo de configuração da rede
- .in - arquivo de dados de treinamento
- .prv - arquivo de previsões
- P - micro on-line rodando o PREVISOR
- T - micro off-line rodando o TREINADOR

Figura 3 : O SNP em uma plataforma genérica

EXEMPLO

Para exemplificação dos resultados obtidos com esse tipo de abordagem escolheu-se como variável de estudo a temperatura do ar registrada na estação meteorológica do Maracanã, operada pelo Departamento de Climatologia e Meteorologia da Universidade do Estado do Rio de Janeiro. Foram definidos aleatoriamente 5 períodos do ano de 1995 e o SNP foi configurado para tentar encontrar a correlação do valor futuro com os últimos 24 valores passados. Os pares de gráficos a seguir apresentam o resultado do aprendizado da rede sobre o conjunto de treinamento (48 amostras aplicadas ao TREINADOR) e a previsão para 24 horas obtida pelo PREVISOR, utilizando a respectiva rede treinada.





CONCLUSÕES

Um sistema de previsão com as características apresentadas pode ser implementado com um baixo custo desde que a aquisição e o registro da variável a ser prevista já estejam sendo feitos. Dessa forma os últimos valores observados estarão disponíveis para o treinamento e a previsão em si.

O PREVISOR é vulnerável a propagação de erro devido a utilização de valores previstos como dados de entrada, portanto o SNP deve ser usado, sempre que possível, em conjunto com outras ferramentas, ficando a conclusão final com o profissional responsável pela previsão.

O modelo apresentado utiliza-se somente do passado da variável para estimar o seu futuro. Modelos que se utilizem de mais variáveis de entrada são mais complexos e mais caros, porém podem fornecer melhores resultados como, por exemplo, a utilização de variáveis meteorológicas (como a direção e velocidade do vento) na previsão do deslocamento de uma mancha de petróleo no mar ou de poluentes na atmosfera.

REFERÊNCIAS

[1] R. P. Lippman, "An Introduction to Computing with Neural Nets", *IEEE ASSP Magazine*, pp. 4-22, Abril 1989.

[2] Z. L. Kovács, "Redes Neurais Artificiais - Fundamentos e Aplicações", *Edição Acadêmica, Brasil*, 1996.

[3] D. Rumelhart, G. Hinton, R. Williams, "Learning Internal Representations by Error Propagation", in *Parallel Distributed Processing Explorations in Microstructures of Cognition*, vol. 1 : Foundations, pp. 318-362, MIT Press, 1986.

AGRADECIMENTOS

Agradecemos ao Departamento de Climatologia e Meteorologia da Universidade do Estado do Rio de Janeiro pelo fornecimento dos dados de temperatura.