

Redes Neurais Artificiais Aplicada no Estudo e Previsão de Consumo de Carga Elétrica

R. B. Lehmann - USS e H. P. Amorim Jr. - CEPTEL

E-mail: rbrunow@uss.br

Palavras-Chave: Consumo de Carga Elétrica e Redes Neurais Artificiais (RNA).

Resumo: O trabalho tem como objetivo apresentar e empregar a técnica de redes neurais artificiais na previsão de consumo de carga elétrica. Para isso, fez-se uso de dados históricos de consumo de carga registrado ao longo de vários anos em uma das principais empresas de energia situada na região em que se encontra a Universidade, ou seja, no Vale do Rio Paraíba do Sul, no estado do Rio de Janeiro. Com posse destes resultados é possível se aventar um planejamento adequado que vise a expansão do sistema elétrico o que de certa forma minimiza as perdas causadas por eventuais queda no fornecimento e por conseqüência queda na receita e insatisfação do consumidor. A capacidade de aprendizado e generalização das redes neurais artificiais, inspiradas no mecanismo dos neurônios biológicos, oferece à ela uma grande área para aplicação. Uma delas, a previsão de consumo de carga elétrica baseado em dados históricos, será apresentado neste trabalho.

1. INTRODUÇÃO

A importância da previsão do consumo de carga elétrico cresce na medida que o sistema elétrico se amplia. Um dos principais motivos em aplicar metodologias para a previsão concentra-se em se estabelecer parâmetros de forma a auxiliar o planejamento afim de evitar que interrupções de fornecimento a consumidores ocorram em um intervalo de tempo estudado.

No entanto, algumas condições estabelecem o tipo de previsão a ser efetuada. Entre as mais importantes está a base de tempo em que se deseja trabalhar para alcançar previsão adequada. De uma forma geral, pode-se enumerar alguns tipos de previsões, tais como: a de curtíssimo prazo, a de curto prazo e a de médio prazo, cada qual apresentando peculiaridades que serão discutidas neste trabalho.

O tipo de previsão depende fundamentalmente do tratamento que se aplica aos dados históricos, em especial a diferença de tempo entre estes dados, que podem ser minutos, horas, dias, meses, ano, etc. Devido a predominância de geração hidrelétrica no país, fato que se associa com a inércia das turbinas hidráulicas, numa eventual variação brusca de carga, a previsão a curtíssimo prazo pode auxiliar de maneira eficaz na tomada de decisão de um possível redespacho de energia de energia elétrica. Essa previsão trabalha com a base de tempo em minutos e as vezes horas.

Extrapolando o intervalo de tempo, podem ser consideradas previsões de curto prazo, aquelas que atuam sob a base de dias ou semanas. Pode-se nestes casos separar as curvas de cargas dos dias e meses distintos, como por exemplo, nos dias da semana que apresentam curvas distintas entre si, como o caso entre domingo e segunda, por exemplo. Desta forma, é possível trabalhar com diversas curvas com a mesma base de tempo mas aplicando a previsão em dias diferentes. Este procedimento aumenta a performance da rede neural na previsão.

No caso de previsão a longo prazo, observa-se um tendência sazonal da curva de carga, em que a estação do ano em muito a influencia. O objetivo deste tipo de previsão é um planejamento eficaz direcionando os investimentos em infraestruturas, possibilitando uma ampliação adequada do sistema de energia elétrica.

Os resultados apresentados neste trabalho baseiam-se nos dados históricos disponibilizados com intervalo de tempo mensal, ou seja, a previsão pode ser caracterizada como de longo prazo. Uma previsão, chamada de multi-step, será realizada com doze meses a frente, em que o resultado obtido na previsão do mês anterior é apresentado de forma a se obter a nova previsão do mês subsequente.

O trabalho é sub-dividido em seções, onde seção 2 se faz um breve histórico sobre o surgimento e evolução da teoria de redes neurais artificiais, na seção 3 os fundamentos básicos da teoria são discutidos e na seção 4 os aspectos e os conceitos que envolvem a aplicação da técnica na previsão de carga são demonstrados. Após este processo introdutório a seção 5 realiza a aplicação e expõe os resultados obtidos. Em seguida, a seção 6 apresenta a conclusão e as propostas futuras a este trabalho.

2. HISTÓRICO

A área de Redes Neurais Artificiais (RNA) teve seu início na década de 40, através do 1º modelo computacional para o neurônio artificial proposto por McCulloch e Pitts em 1943. Em um primeiro instante este modelo era incapaz de executar uma das principais tarefas que hoje se espera dele, o aprendizado. O modelo proposto por Donald Hebb (1949), que recebeu o nome de Regra de Hebb (Hebbian Learning Rule), minimizava este problema onde as conexões entre os neurônios eram automaticamente adaptáveis.

Durante a década de 50, Frank Roseblatt, outro importante nome na evolução da teoria, inventou o modelo neural Perceptron (1958). Era uma máquina capaz de treinar através do aprendizado e posteriormente classificar certos padrões por meio de modificações das conexões. Esta foi a primeira vez em que se observou uma arquitetura neural completa, com todos os seus elementos necessários.

Embora houvessem trabalhos interessantes surgidos na década de 60, a publicação do livro de Marvin Minsky e Seymour Papert (1969), em que eles provam matematicamente que, as redes do tipo Perceptron são incapazes de solucionar certos tipos de problemas, como o ou-exclusivo, impuseram uma estagnação nas pesquisas sobre a área das Redes Neurais.

Somente no início dos anos 80, com o surgimento de novos modelos, o estudo sobre RNA estabeleceu-se como uma promissora área de pesquisa. A publicação do artigo escrito por David Rumelhard, em 1986 [2], intitulado como: “processamento paralelo distribuído”, promoveu uma nova revolução na teoria de RNA. Se atribuiu a este novo modelo o nome de algoritmo de Retropropagação ou Back-Propagation, sendo até hoje o algoritmo utilizado na maioria das aplicações das RNA.


3. FUNDAMENTOS BÁSICOS

Por definição, RNA são sistemas inspirados nos neurônios biológicos e na estrutura massivamente paralela do cérebro, com capacidade de adquirir, armazenar e utilizar o conhecimento experimental. Assim, elas devem exibir características básicas similares ao comportamento humano, tais como: *Aprendizado*: a rede aprende por experiência, através de treinamento baseado na apresentação de exemplos; *Associação*: a rede é capaz de fazer associações entre padrões diferentes; *Generalização*: ela é capaz de generalizar por exemplos anteriores, ou seja, responder corretamente a uma entrada nunca vista antes por similaridade aos padrões já apresentados.

O aprendizado ou treinamento é baseado na apresentação de exemplos, e se configura como uma etapa fundamental tanto ao processo humano como computacional. Este treinamento tem como finalidade efetuar os ajustes necessários nos parâmetros da RNA, representados pelos pesos sinápticos. O objetivo desta etapa é capacitar a RNA a associar um dado de entrada com um grau de semelhança aos exemplos já apresentados. Entre os algoritmos que estabelecem como e quando as conexões devem ser atualizadas, o back-propagation é o mais difundido e será o algoritmo utilizado neste trabalho.

A teoria de RNA pode ser dividida em três tópicos básicos: *Elemento Processador (EP)*: Elemento básico, inspirado no neurônio biológico (fig. 1); *Topologia*: modo de conexão entre os diversos elementos processadores (EPs) que formam a RNA; e *Aprendizado*: processo pelo qual a RNA aprende, por meio da apresentação dos padrões desejados. Cada um destes tópicos apresenta suas peculiaridades que são as seguintes:

Elemento Processador: é um modelo simplificado do neurônio biológico e é constituído de três partes fundamentais: pesos sinápticos, que ponderam os valores das entradas do neurônio, regra de propagação, que define como as entradas serão combinadas no neurônio, em geral é um somatório ponderado e a função de ativação, que determina o efeito que o resultado da regra de propagação terá sobre o nível de ativação do neurônio. Um modelo é mostrado na figura 1.



onde:

$S_1, S_2, \dots, S_i \dots$ Valores de Entrada

$W_{1j}, W_{2j} \dots W_{ij}$

$S_j \dots$ neurônio de saída

Figura 1 – Elemento Processador

Topologia: o encadeamento de vários destes neurônios formando o que se chama de camadas, é denominado de topologia da RNA. Em geral, ela possui três ou mais camadas de elementos processadores, sendo que a primeira recebe o nome de camada de entrada, a última recebe o nome de camada de saída e a(s) camada(s) intermediária(s) de camada(s) escondida(s). Como exemplo imagine uma RNA com a seguinte topologia (2-4-4-1). Isto implica que ela possui a camada de entrada com 2 elementos processadores, duas camadas escondidas, cada qual com 4 elementos processadores e a camada de saída, com apenas 1 elemento processador. O fluxo dos dados é, conforme o algoritmo back-propagation, em dois sentidos, para frente e para trás.




Figura 2 – Rede Neural com duas Camadas Escondidas

Aprendizado: a forma com a qual os pesos das conexões são ajustados recebe o nome de aprendizado. Existem três tipos de treinamento: o sem treinamento, onde os pesos são ajustados em um único passo, o treinamento supervisionado, onde a RNA é alimentada por dados de entrada e seus respectivos valores de saída e as redes sem-supervisionamento, que não requer valores de saída, onde a RNA agrupa os valores de maior semelhança.

No trabalho apresentado foi empregado o algoritmo de treinamento supervisionado com duas topologias. A

primeira com duas camadas escondidas e a segunda com uma única camada escondida, possibilitando assim, a comparação das performances.

4. MÉTODOS DE PREVISÃO

Em virtude dos níveis de crescimento de consumo de carga elétrica na País e a visível falta de investimento no setor de geração, a área de planejamento tem alcançado lugar de destaque no setor elétrico. Logo, a possibilidade de previsão de consumo de carga possibilita um planejamento da expansão do sistema de energia.

Por outro lado, prever os níveis de consumo de energia elétrica é extremamente difícil. Esta dificuldade baseia-se principalmente nas muitas variáveis envolvidas, entre elas curva de consumo de carga elétrica nos períodos antecedentes à previsão, temperatura ambiente, dia da semana, hora do dia, estação do ano, entre outras.

Dois modelos estatísticos de previsão são habitualmente utilizados: séries temporais e modelos de regressão. O primeiro tipo é baseado em dados históricos de uma variável, onde o princípio é reconhecer um padrão na série histórica de dados e extrapolá-lo para o futuro, pelo método proposto por Box-Jenkins [3]. Modelos de regressão consideram que a variável a ser prevista tem um relacionamento causa e efeito com uma ou mais variáveis independentes. Seu princípio é descobrir esta forma de relacionamento ou correlação e usá-la na previsão da variável dependente, como exemplo citamos a regressão múltipla.

Através dos anos de atividades, as RNA tem provado serem capazes de identificar interdependências entre os dados. Em particular, elas tem o potencial de representar comportamentos não-lineares entre variáveis como por exemplo, valores de consumo de carga e informação de tempo. Esta característica, aliada com a simplicidade de construção e treinamento das RNA, reforçam a pesquisa e aplicação destas redes em previsão de consumo de carga elétrica.

5. RESULTADOS EXPERIMENTAIS E AVALIAÇÃO

Como já foi salientado, o algoritmo de treinamento empregado foi o algoritmo supervisionado back-propagation [1,3]. Sua funcionalidade está baseada no ajuste dos pesos sinápticos a partir do erro encontrado entre a saída desejada e o valor determinado pelo processamento da rede neural. O algoritmo tenta através do método gradiente descendente minimizar este erro, ou seja, é um processo iterativo que visa atingir um alvo estipulado.

Em geral dois processos são aplicados às RNA, são eles: treinamento e testes. No primeiro processo, o treinamento, o objetivo concentra-se na minimização do erro encontrado na saída da RNA. Este processo realiza-se através dos ajustes dos pesos sinápticos que interligam os elementos processadores das diversas camadas de neurônios existentes na RNA. O processo de treinamento deve ser interrompido somente por dois mecanismos, a

obtenção de um determinado nível de erro ou a extrapolação no número de iterações. O segundo item, ou seja, a definição do número máximo de iterações evita a condição em que a rede é super treinada, fato que pode causar problemas na generalização e diminuir a performance da RNA na previsão.

A segunda etapa visa, a partir da RNA já treinada e ajustada, avaliar a performance desta através da apresentação de valores de entrada nunca analisados pela rede. O resultado desta etapa é denominado de generalização e quanto melhor a generalização, mais eficiente é a rede neural.

Existe um compromisso entre o tempo de processamento e a performance da rede. Em geral, este fato está vinculado ao número de camadas escondidas adotado e a quantidade de elementos processadores em cada uma delas. Neste trabalho foram utilizados duas topologias que possibilitam visualizar este compromisso.

Trabalhar-se-á numa série histórica real mensal de consumo de carga elétrica do período compreendido entre 1982 e 1999. No entanto, observou-se através de testes que 3 anos de dados, ou seja, 36 amostras, eram necessárias para uma boa generalização da rede. Busca-se neste trabalho uma previsão com um ano de horizonte, que no caso de dados mensais representam 12 passos à frente. Sendo assim, a metodologia empregada é conhecida como multi-step, pois a partir de um dado previsto se realiza o processo de determinação do dado seguinte.

A topologia da rede neural foi considerada tomando como base o relacionamento entre o consumo de carga dos meses anteriores, no caso doze meses anteriores, com o mês a ser previsto. Duas topologias distintas foram testadas, dando margem a comparação de performance entre elas. A primeira topologia é definida com duas camadas escondidas (12-15-10-1) e a segunda rede apresenta somente uma camada escondida (12-25-1).

Diversos outros testes foram realizados, muito embora não exista uma regra estabelecida que determine o tamanho ótimo da rede, bem como o número exato de amostras para o treinamento. Desta forma, um total de 36 amostras com doze valores de entrada foram utilizadas para o processo de treinamento, que têm duração menor do que 1 minuto, num Pentium III, 700Mhz.

Após o treino e o ajuste da rede conforme padrões pré-estabelecidos, a etapa seguinte refere-se ao teste. Ele concentra-se na apresentação de amostras nunca antes vista pela rede neural, de forma que o resultado adquirido por esta pode ser comparado com o real, onde índices de performances podem ser calculados.

Os resultados obtidos na previsão são demonstrados através da tabela 1. Nesta tabela estão indicados os valores reais de consumo de carga elétrica no mês correspondente e seus respectivos valores previstos pela rede implementada. Esses resultados serão trabalhados mais adiante e produzirão índices de avaliação da RNA que serão alvo de discussão e conclusão do trabalho.

Tabela 1 – Resultado da Previsão

Real	RNA - 1	RNA - 2
0.9921	0.9665	0.9853
1.0000	0.9752	0.9920
0.9720	0.9772	0.9694
0.9141	0.9284	0.9109
0.8589	0.8673	0.8674
0.8563	0.8725	0.8596
0.8712	0.8871	0.8681
0.8528	0.8618	0.8613
0.8904	0.8742	0.8773
0.8642	0.8541	0.8637
0.8817	0.9113	0.8705
0.9308	0.9066	0.9369

O erro máximo admitido no treinamento foi de 0.0001 e uma taxa de aprendizado de 0.1. As curvas demonstrativas de previsão podem ser observadas graficamente na Figura 5 em anexo.

Na avaliação da performance das RNA aplicadas na previsão de carga elétrica algumas taxas foram pré-estabelecidas. Elas têm como fundamento criar parâmetros de modo a possibilitar a comparação ente os diversos outros métodos de previsão, bem como entre topologias de RNA distintas, como é o caso deste trabalho. Entre estas taxas estão:

MAPE – Mean Absolute Percentage Error – indica o valor médio do erro percentual das previsões sobre todo o conjunto de teste, e é calculado através da seguinte expressão:

$$MAPE = \frac{\sum_{k=1}^N \left| \frac{a_k - y_k}{a_k} \right|}{N} * 100$$

onde: N...Número de previsões realizadas;
 a_k ... saída desejada no índice k;
 y_k ... saída prevista no índice k.

RMSE – Root Mean Square Error – penaliza os erros maiores, desta forma se uma previsão apresenta bons resultados na maioria dos casos e alguns erros elevados em outras, o valor de RMSE será elevado. É calculado através da seguinte expressão:

$$RMSE = \sqrt{\frac{\sum_{k=1}^N \left| \frac{a_k - y_k}{a_k} \right|^2}{N}}$$

Coefficiente de U-Theil – essa métrica mede quanto os resultados são melhores do que uma previsão ingênua ou trivial, ou seja, aquela em que a melhor estimativa do próximo valor é próprio valor atual. Pode-se então analisar a qualidade da previsão da seguinte maneira:

- quando $U \geq 1$... erro do modelo é maior do que o ingênuo;

- quando $U < 1$... erro do modelo é melhor do que o ingênuo.

Desta foram, quanto mais U se aproximar de 0, melhor será a previsão. O valor de U-Theil é determinado pela seguinte expressão:

$$U - Theil = \frac{\sqrt{\sum_{k=1}^N (a_k - y_k)^2}}{\sqrt{\sum_{k=1}^N (a_k - a_{k-1})^2}}$$

Estas taxas foram então calculadas a partir dos valores de previsão da Tabela 1. O resultado da aplicação destas expressões para as duas topologias estão apresentados na Tabela 2.

Tabela 2 – Índices de de Perfomance na Previsão

	RNA 1	RNA 2
MAPE (%)	1,82	0,69
RMSE	13,64	8,34
U-Theil	0,5624	0,2227

6. CONCLUSÕES

Os resultados obtidos neste trabalho confirmam a aplicabilidade das RNA na previsão de consumo de carga elétrica carga. A não-linearidade dos dados comprova uma das habilidades fundamentais ao progresso desta técnica, a generalização. O algoritmo de aprendizado back-propagation foi utilizado para ajustar os pesos sinápticos, apresentando boa performance, conforme os resultados obtidos.

Os modelos fazem uso de dados históricos de consumo de carga mensais. Entre os índices que caracterizam a performance na previsão, pode-se destacar o U-Theil, que representa quão melhor é a previsão com relação a método mais ingênuo possível. Quanto mais próximo este valor for de zero, melhor a performance. Desta feita, as duas topologias apresentaram, respectivamente, 0,5624 e 0,2227, índices bem abaixo do valor limite, indicando a obtenção de bons resultados.

De forma comparativa, RNA 2, com topologia 12-25-1, apresentou melhores resultados do que a RNA 1, com tologia 12-15-10-1. Indicando que a RNA 2 é a mais adequada a realizar a previsão com essa base de dados.

7. BIBLIOGRAFIA

- [1] Haykin, S., “Neural Networks – A Comprehensive Foudation”, Prentice Hall, 1994.
- [2] Rumelhard, D.E. and Hinton, G.E.and Willians, R.J., “Learning Internal Representation by Error Propagation”, Parallel Distributed Processing, vol.1, Cambridge, 1986
- [3] Box, G.E.P. and Jenkins, G.M. “Time Series Analysis Forecasting and Control”, Holden-Day, 1976.
- [4] Lee, K.Y, Cha, Y.T. and Park, J.K., “Short Term Load Forecasting Using an Artificial Neural Networks”, IEEE Trans. On Power System, vol.7, n°1, pp.124-132, Fev.1992

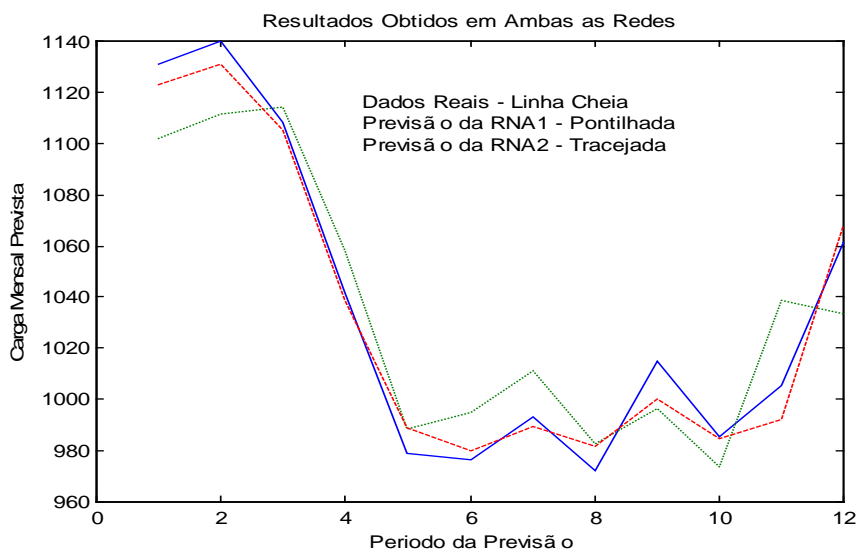

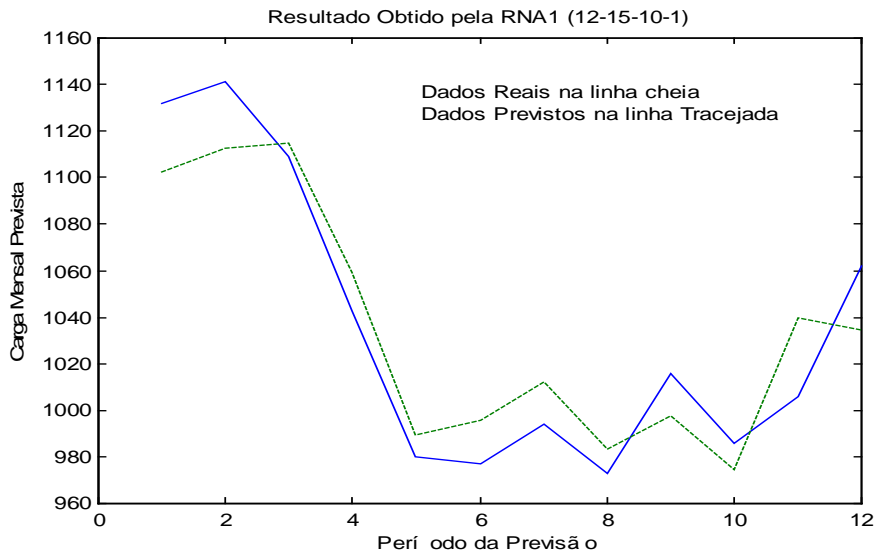


Figura 3 – Curvas Características da Previsão de Consumo de Carga Elétrica num Horizonte de 12 Meses