

# Previsão de Carga Horária em Médio Prazo Utilizando Redes Neurais com Foco na Previsão dos Feriados

R. R. B. de Aquino, A. A. Ferreira, G. B. Silva, O. Nóbrega Neto, M. M. S. Lira, J. B. Oliveira

*Departamento de Engenharia Elétrica e Sistemas de Potência - DEESP/UFPE*

*rrba@ufpe.br, aaf@cin.ufpe.br, geane@hotmail.com, otoninobrega@hotmail.com, milde@ufpe.br, josinaldo.bezerra@gmail.com*

## Resumo

Uma das dificuldades encontradas frequentemente no problema de previsão de carga horária é a estimação adequada da carga dos dias feriados. Isto ocorre devido ao comportamento anômalo destes dias e a quantidade insuficiente de padrões disponíveis para treinamento. Este artigo é uma continuação das recentes pesquisas publicadas em [1],[2] nas quais é proposto um sistema que utiliza Redes Neurais Artificiais (RNAs) para realizar previsão de carga horária em médio prazo (30 dias), e tem por foco a redução do erro de previsão dos dias feriados. O estudo foi baseado no modelo de consumo de energia elétrica da Companhia Energética de Pernambuco (CELPE). As RNA utilizadas são do tipo Multilayer Perceptrons (MLP), treinada com o algoritmo RPROP. O trabalho está dividido em três etapas: a) criação da base de dados; b) busca da melhor arquitetura para criação do sistema; c) realização da previsão e análise dos resultados. Os resultados obtidos indicam a potencialidade do sistema de previsão de carga horária em médio prazo desenvolvido, destacando-se a redução do erro dos dias feriados.

## 1. Introdução

Atualmente, o sistema elétrico brasileiro está passando por modificações, tanto na parte administrativa quanto no planejamento, tornando-se cada vez mais complexo. A alteração do mercado de energia elétrica teve como consequência uma maior competitividade que foi imposta pela descentralização da distribuição de energia e pela demanda crescente de qualidade exigida pelo mercado consumidor, implicando numa busca permanente por melhorias no planejamento do sistema.

As atividades diárias de operação e planejamento de uma companhia energética necessitam da previsão

de demanda de seus consumidores. Várias pesquisas têm sido desenvolvidas com o objetivo de melhorar o planejamento e a operação desses sistemas. Especificamente no caso de previsão de carga, essas pesquisas se dividem em previsão de carga em curto, médio e longo prazo. Este trabalho trata de previsão de carga horária em médio prazo (horizonte de previsão de 30 dias).

Tradicionalmente, previsões de carga são feitas utilizando-se métodos estatísticos de análise de série temporais como regressão linear, amortecimento exponencial e Box Jenkins [7]. Ultimamente, técnicas de inteligência computacional como RNAs têm sido utilizadas, obtendo resultados promissores [3, 5],[6, [8, [11].

O procedimento atualmente adotado pela CELPE para previsão de carga horária é um misto de utilização de técnicas estatísticas e de aplicação de conhecimento de especialistas. Dessa forma, faz-se necessário automatizar o processo e diminuir a margem de erro. O presente trabalho tem o objetivo de melhorar a tarefa de previsão de carga horária, tornando-a automática e incorporando o conhecimento implícito do especialista ao sistema. A idéia principal é utilizar as RNAs para extrair o conhecimento que está embutido nos dados históricos de consumo horário da CELPE.

## 2. Descrição do problema e a modelagem da base de dados

O problema abordado neste trabalho consiste na previsão da carga por hora, em horizonte mensal (trinta dias de antecedência). Os dados utilizados neste trabalho foram disponibilizados pela CELPE e correspondem ao consumo horário do período de Janeiro de 2000 à Dezembro de 2003.

Todos os dados foram unificados em um único arquivo, onde cada padrão passou a ser formado pela informação do ano, dia, mês, a carga horária do dia (24

horas) e o dia da semana a ser previsto (Dom, Seg, ..., Sab). Os dados referentes aos meses de Maio a Julho de 2001, período mais crítico do racionamento ocorrido no sistema elétrico brasileiro no ano de 2001, foram expurgados do arquivo. O valor da carga horária foi normalizado ( $L_N$ ) para o intervalo [0 1], utilizando a fórmula descrita na equação (1):

$$L_N = \frac{L - L_{\min}}{L_{\max} - L_{\min}} \quad (1)$$

Onde,  $L$  é o valor da carga horária do sistema CELPE,  $L_{\max}$  e  $L_{\min}$  são os valores máximos e mínimos de carga horária entre todos os valores observados, respectivamente. Neste trabalho  $L_{\min} = 0$  e  $L_{\max} = 1,1 \cdot L_{A_{\max}}$ , onde  $L_{A_{\max}}$  é o valor máximo da carga no banco de dados atual. O fator 1,1 tem como objetivo manter as cargas futuras com valores até 10% acima de  $L_{A_{\max}}$  inferiores a unidade, após sua normalização.

Os padrões das curvas de carga podem ser classificados em dois tipos: dias feriados e dias não-feriados. Existem poucos padrões de dias feriados, o que implica em um baixo desempenho no aprendizado destes padrões na etapa de treinamento da RNA. Este problema foi solucionado nos trabalhos [1, 2] através da replicação direta de dados. Nesta técnica de replicação, o objetivo é tornar o número de padrões de dias feriados iguais aos de dias não feriados para evitar que a rede se destaque no reconhecimento das características do padrão de maior número em detrimento do outro de menor número.

A proposta atual é prever um dia feriado, o qual é indicado, a priori, pelo especialista como um sábado ou como um domingo. Ou seja, o especialista indica se o comportamento da curva de carga desse feriado específico está mais correlacionado com a curva de carga de sábado ou de um domingo. Visto que as curvas de carga dos feriados têm características próximas de um sábado ou de um domingo, elas foram utilizadas apenas no conjunto de teste da rede.

Duas bases de dados foram geradas com o objetivo de comparar o desempenho da RNA treinada com os dados utilizando a técnica de replicação dos dias feriados e a técnica onde a curva de carga diária de um feriado específico é fixada como sendo próximo ao formato da curva de carga diária de um sábado ou de um domingo. Estes resultados são apresentados na seção 4.

O treinamento das redes MLP segue um paradigma de treinamento supervisionado, onde cada padrão é representado por um conjunto de entrada e saída desejada. O conjunto de entrada é caracterizado da seguinte forma: os primeiros 24 valores correspondem ao consumo horário de 31 dias antes do dia a ser previsto; os próximos 24 valores correspondem ao

consumo horário 30 dias antes do dia a ser previsto; e por fim, os próximos 7 valores definem o dia da semana que será previsto (Dom, Seg, ..., Sab). Esta informação utiliza a codificação 1-de-m. E o conjunto de saída é caracterizado pelos 24 valores, um para cada hora do dia, que correspondem ao consumo de carga horária do dia a ser previsto.

A base de dados construída para realizar a previsão no horizonte de 30 dias possui 1160 padrões, distribuídos da seguinte forma: 60% para o conjunto de treinamento, 30% para o conjunto de validação e 10% para o conjunto de teste. Os padrões de cada conjunto foram selecionados de forma aleatória.

O objetivo principal do sistema, baseado em RNA, desenvolvido é aprender a partir de exemplos e generalizar para novos casos. O desempenho do sistema será medido pela porcentagem de erro médio quadrático (MSE), segundo [9] e especificado na equação (2), e pela porcentagem de erro médio absoluto (MAPE) equação (3).

$$MSE_{\%} = 100 \times \frac{L_{\max} - L_{\min}}{N \cdot P} \sum_{p=1}^P \sum_{i=1}^N (L_{pi} - T_{pi})^2 \quad (2)$$

Onde  $L_{\max}$  e  $L_{\min}$  são os valores máximos e mínimos de carga horária entre todos os valores observados, respectivamente;  $N$  é o número de unidades de saída da rede neural;  $P$  é o número de padrões da base de dados considerada;  $L_{pi}$  e  $T_{pi}$  são as saídas obtida e desejada da rede para cada unidade da camada de saída, respectivamente.

$$MAPE_{\%} = \frac{1}{P} \sum_{p=1}^P \frac{|L_p - T_p|}{T_p} \times 100 \quad (3)$$

Onde  $L_p$  é o valor obtido de saída para uma determinada entrada;  $T_p$  é o valor desejado pelo sistema para esta mesma entrada; e  $P$  é o número de padrões da base de dados considerada.

As redes neurais são criadas utilizando o princípio básico de dividir a amostra de exemplos em três grupos mutuamente exclusivos. O primeiro chamado de conjunto de treinamento é usado para treinar o sistema, e o segundo chamado de conjunto de validação é usado para medir a taxa de erro do sistema e evitar o *overfitting*. O terceiro, denominado de conjunto de teste, é usado para testar o sistema após seu treinamento. A idéia é que o desempenho do sistema em um conjunto de teste seja seu desempenho em uso real. Isto significa que nenhum exemplo do conjunto de teste deve estar disponível no conjunto de treinamento da rede [9].

Os conjuntos de treinamento, validação e teste devem ser amostras aleatórias de alguma população e

devem ser independentes. Isto significa que não há relação entre eles [4].

Com o objetivo de obter uma estimativa do erro mais próxima do erro verdadeiro, o método de *validação cruzada múltipla* foi escolhido para criação dos conjuntos de treinamento, validação e teste. Este método tem se tornado um método padrão em termos práticos [4, 12].

Dessa forma os padrões foram divididos em dez partições independentes, sendo que cada partição possui 10% dos dados. Em cada experimento, seis partições foram usadas para treinar, três, para validar e uma, para testar a rede. A divisão das partições nos conjuntos é apresentada na **Tabela 1**.

**Tabela 1** - Formação dos conjuntos.

| Exp. | Rede        | Treinamento       | Validação | Teste |
|------|-------------|-------------------|-----------|-------|
| 1    | De 1 a 10   | 5, 6, 7, 8, 9, 10 | 2, 3, 4   | 1     |
| 2    | De 11 a 20  | 1, 6, 7, 8, 9, 10 | 3, 4, 5   | 2     |
| 3    | De 21 a 30  | 1, 2, 7, 8, 9, 10 | 4, 5, 6   | 3     |
| 4    | De 31 a 40  | 1, 2, 3, 8, 9, 10 | 5, 6, 7   | 4     |
| 5    | De 41 a 50  | 1, 2, 3, 4, 9, 10 | 6, 7, 8   | 5     |
| 6    | De 51 a 60  | 1, 2, 3, 4, 5, 10 | 7, 8, 9   | 6     |
| 7    | De 61 a 70  | 1, 2, 3, 4, 5, 6  | 8, 9, 10  | 7     |
| 8    | De 71 a 80  | 2, 3, 4, 5, 6, 7  | 9, 10, 1  | 8     |
| 9    | De 81 a 90  | 3, 4, 5, 6, 7, 8  | 1, 2, 10  | 9     |
| 10   | De 91 a 100 | 4, 5, 6, 7, 8, 9  | 1, 2, 3   | 10    |

### 3. Experimentos para escolha da arquitetura

Todos os experimentos realizados neste trabalho criaram RNAs com a arquitetura MLP, treinadas com o algoritmo *Rprop*. O algoritmo *Rprop*, denominado *resilient backpropagation*, é um algoritmo de adaptação global que realiza treinamento supervisionado *batch* em redes do tipo MLP [10]. Uma diferença substancial entre os algoritmos *Rprop* e *backpropagation* está no processo de ajuste dos pesos. No algoritmo *Rprop*, a atualização dos pesos é influenciada pelo sinal da derivada parcial, e não pelo seu valor, como ocorre no *backpropagation*. Cada vez que a derivada parcial de um determinado peso  $w_{ij}$  troca de sinal, indicando que o último ajuste dos pesos foi grande demais e o algoritmo pulou sobre o mínimo local, o valor do ajuste individual e específico deste peso ( $\Delta_{ij}$ ) é diminuído por um fator  $\eta^-$ . Se a derivada manteve o mesmo sinal, o fator individual de ajuste do peso é ligeiramente aumentado por um fator  $\eta^+$  de modo a acelerar a convergência do peso. O treinamento utilizando o algoritmo *Rprop* resulta em melhorias no processo de aprendizagem, tornando a convergência nesta fase mais rápida.

A rede utilizada neste trabalho possui uma camada de entrada, uma camada escondida e uma camada de saída. Os nós da camada escondida possuem a função de ativação tangente hiperbólica e os nós da camada de saída possuem a função de ativação sigmóide logística. O número máximo de iterações definido para todos os treinamentos foi 2500 épocas. O treinamento pára se o critério de *Early Stop* [9] implementado pelo Matlab, ocorre 20 vezes consecutivamente, ou se o número máximo de iterações é atingido ou ainda se o MSE no conjunto de treinamento for igual a zero.

O critério de *Early Stop* tem o objetivo de aumentar a capacidade de generalização das redes. O Matlab implementa este critério monitorando o erro no conjunto de validação durante o treinamento. O erro no conjunto de validação geralmente diminui durante a fase inicial do treinamento. Entretanto, quando a rede começa a memorizar os dados de treinamento, o erro no conjunto de validação começa a aumentar. Quando o erro no conjunto de validação aumenta em um número específico de iterações, o treinamento é interrompido e os pesos e bias são retornados para os valores do momento do erro mínimo de validação. Todas as redes criadas neste trabalho foram treinadas com os seguintes parâmetros:

- Número máximo de épocas 2500
- MSE desejado no conjunto de teste (*goal*) 0
- Gradiente de desempenho mínimo  $1e^{-6}$
- Número máximo de falhas consecutivas 20

#### 3.1. Arquitetura para previsão em médio prazo

Para escolha da melhor arquitetura foram realizados dez experimentos com inicialização de pesos aleatórios, variando de 30 a 120 nós, com incremento de 5. Inicialmente o melhor resultado observando o MSE no conjunto de validação foi para configuração com 120 nós, o máximo valor de nós pesquisados. Por isso, foi dada continuidade na busca da melhor arquitetura, analisando o desempenho da rede no intervalo de 120 a 160 nós na camada escondida com incremento de 5. A arquitetura com 125 nós na camada escondida foi escolhida por apresentar um MSE no conjunto de validação de 0,0863% - menor valor obtido.

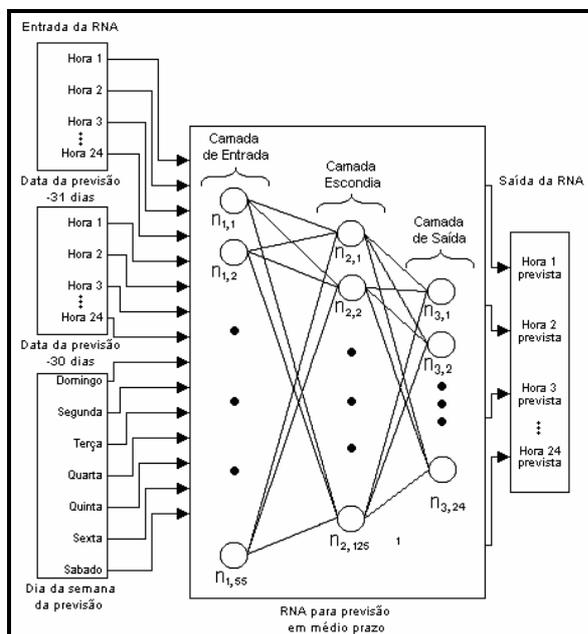
#### 3.2. Criação do sistema para previsão horária

Para o caso em que os feriados são tratados como sábados ou domingos a rede criada é composta de 55 unidades na camada de entrada: 24 nós correspondem ao consumo horário 31 dias antes do dia da previsão, 24 correspondem ao consumo horário 30 dias antes do

dia da previsão, 7 definem o dia da semana usando a codificação 1-de-m (Ex. Dom = '1000000'). No caso onde os dados dos feriados são replicados, a rede é composta de 57 unidades na camada de entrada. Acrescenta-se ao caso anterior 2 entradas que definem se o dia da previsão é um feriado ou não, usando a codificação 1-de-m, conforme [1],[2].

As redes criadas para previsão, **Figura 1**, possuem 125 nós na camada escondida e 24 nós na camada de saída (um nó para cada hora do dia).

Com a arquitetura da rede neural escolhida (55-125-24) procurou-se a melhor rede para o horizonte de previsão de 30 dias. A escolha da melhor rede é obtida através do menor MSE no conjunto de teste.



**Figura 1** – Sistema de previsão em médio prazo

Para cada conjunto de treinamento, validação e teste, formados a partir das partições criadas pelo método de validação cruzada múltipla, foram criadas 10 redes (55-125-24), totalizando 100 redes para previsão em médio prazo. A **Tabela 1** apresentada na seção 2, identifica as redes e seus respectivos conjuntos de treinamento, validação e teste.

Os valores médios de MSE e MAPE, obtidos em cada experimento formado pelo conjunto de dez redes, são considerados como resultado esperado na literatura para RNAs utilizadas na tarefa de previsão de carga.

A **Tabela 2** descreve os resultados médios obtidos para previsão em médio prazo nos 10 experimentos. Dentre as 100 redes criadas, a rede de número 27 foi selecionada como a melhor rede por apresentar o menor valor de MSE e de MAPE no conjunto de teste.

A rede 27 apresentou um MSE de 0,0891% e um MAPE de 3,953%.

**Tabela 2** - Resultado da previsão em médio prazo.

| Exp.          | Média de épocas | Validação     |                | Teste         |                |
|---------------|-----------------|---------------|----------------|---------------|----------------|
|               |                 | Média MSE (%) | Média MAPE (%) | Média MSE (%) | Média MAPE (%) |
| 1             | 772.60          | 0.1312        | 4.9155         | 0.1567        | 5.2417         |
| 2             | 686.50          | 0.1327        | 4.9569         | 0.1386        | 4.9964         |
| 3             | 1135.40         | 0.1213        | 4.7151         | 0.1066        | 4.3455         |
| 4             | 802.40          | 0.1268        | 4.8142         | 0.1376        | 5.2424         |
| 5             | 1024.80         | 0.1221        | 4.7004         | 0.1235        | 4.7226         |
| 6             | 833.50          | 0.1249        | 4.7851         | 0.1311        | 4.8267         |
| 7             | 535.00          | 0.1470        | 5.0818         | 0.1295        | 4.9992         |
| 8             | 582.50          | 0.1522        | 5.1136         | 0.1554        | 5.0665         |
| 9             | 1106.60         | 0.1358        | 4.8837         | 0.1218        | 4.6880         |
| 10            | 1695.20         | 0.1115        | 4.4509         | 0.1114        | 4.4266         |
| <b>Média</b>  | <b>917.4500</b> | <b>0.1306</b> | <b>4.8417</b>  | <b>0.1312</b> | <b>4.8556</b>  |
| <b>Desvio</b> | <b>342.0140</b> | <b>0.0122</b> | <b>0.1957</b>  | <b>0.0166</b> | <b>0.3117</b>  |

## 4. Análise dos resultados

Para verificarmos como o sistema criado se comporta na previsão de carga horária da CELPE no período de Janeiro à Junho de 2004, foi realizada a previsão em médio prazo utilizando a melhor rede obtida na seção 3.2, cuja arquitetura foi selecionada na seção 3.1.

O resultado obtido na previsão em médio prazo será comparado com o resultado obtido pela previsão CELPE no mesmo horizonte.

### 4.1 Análise da previsão em médio prazo

A **Tabela 3** apresenta o MAPE médio da previsão horária em médio prazo para os meses de Janeiro à Junho de 2004. Os resultados são da previsão realizada pela CELPE, da previsão realizada pela RNA considerando o comportamento dos dias feriados como sábado ou domingo (sistema proposto), e finalmente os resultados para a previsão quando os dados de feriados foram replicados e utilizado no treinamento.

A previsão CELPE utiliza técnicas estatísticas e conhecimento de especialistas.

A previsão CELPE apresentou uma média de MAPE horário de 5,49%, enquanto que a RNA que utiliza os padrões de feriados replicados foi de 4,58%. Com menor erro médio (4,18%), destacou-se o sistema proposto que fixa os feriados anuais como um sábado ou um domingo.

**Tabela 3 - MAPE médio para a Previsão de Janeiro a Junho de 2004**

| MAPE Médio (%) |              |                            |                            |
|----------------|--------------|----------------------------|----------------------------|
| Mês            | CELPE        | RNA<br>Feriados Replicados | RNA<br>Feriado = Dom   Sab |
| jan/04         | 7,50%        | 6,55%                      | 6,29%                      |
| fev/04         | 7,42%        | 5,52%                      | 5,53%                      |
| mar/04         | 4,70%        | 4,96%                      | 4,43%                      |
| abr/04         | 3,57%        | 3,90%                      | 3,29%                      |
| mai/04         | 3,22%        | 2,94%                      | 2,26%                      |
| jun/04         | 6,54%        | 3,58%                      | 3,28%                      |
| <b>Média</b>   | <b>5,49%</b> | <b>4,58%</b>               | <b>4,18%</b>               |

A Tabela 4 apresenta o MAPE médio dos dias feriados para a previsão realizada no mesmo período.

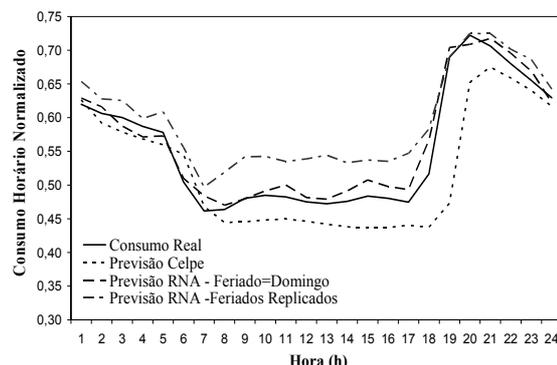
A previsão CELPE apresentou uma média de MAPE horário nos feriados de 9,41%, enquanto que a RNA onde os padrões e feriados são replicados resultou em 7,16%. Já o sistema desenvolvido atingiu 3,58%, apresentando uma redução significativa nos erros quando confrontados com os erros dos dois sistemas anteriores, mostrando desta forma o alto desempenho do sistema proposto.

**Tabela 4 - MAPE médio para os dias feriados da previsão de Janeiro a Junho de 2004**

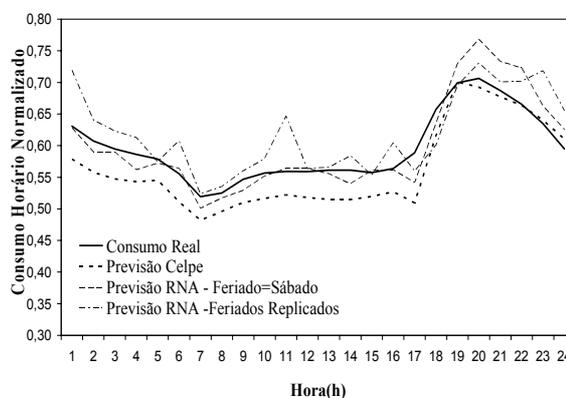
| MAPE Médio Horário Dias Feriados (%) |              |                            |                            |
|--------------------------------------|--------------|----------------------------|----------------------------|
| Mês                                  | CELPE        | RNA<br>Feriados Replicados | RNA<br>Feriado = Dom   Sab |
| jan/04                               | 6,79%        | 7,93%                      | 2,52%                      |
| fev/04                               | 14,59%       | 3,30%                      | 5,40%                      |
| mar/04                               | -            | -                          | -                          |
| abr/04                               | 4,26%        | 4,17%                      | 3,55%                      |
| mai/04                               | 2,61%        | 9,80%                      | 3,32%                      |
| jun/04                               | 18,79%       | 10,60%                     | 3,08%                      |
| <b>Média</b>                         | <b>9,41%</b> | <b>7,16%</b>               | <b>3,58%</b>               |

A Figura 2 apresenta a curva de carga do dia 01 de Janeiro de 2004, feriado da Confraternização Universal. Estudos no comportamento da curva de carga indicaram que este feriado é previsto de forma precisa considerando seu comportamento similar ao domingo. Pode-se observar no mês de Janeiro de 2004 da Tabela 4 que o erro obtido pela previsão do sistema proposto foi de 2,52%, um terço do erro obtido quando se replica a quantidade de padrões de dias feriados.

Certos feriados são previstos considerando seu comportamento da curva de carga similar ao de um sábado, um exemplo é o feriado de 21 de abril de 2004, mostrado na Figura 3. Para esse dia específico o MAPE médio horário obtido pela previsão do sistema proposto foi de 3,20%, enquanto que o obtido replicando os dados de feriados é de 5,98%.



**Figura 2 – Curva de carga para o feriado de confraternização universal**



**Figura 3 – Curva de carga para o feriado de Tiradentes**

A Tabela 5 apresenta o MAPE médio para os dias não-feriados da previsão realizada no mesmo período.

**Tabela 5 - MAPE médio para os dias não-feriados da previsão de Janeiro a Junho de 2004**

| MAPE Médio Horário Dias Não-Feriados (%) |              |                            |                            |
|--|--------------|----------------------------|----------------------------|
| Mês                                      | CELPE        | RNA<br>Feriados Replicados | RNA<br>Feriado = Dom   Sab |
| jan/04                                   | 7,52%        | 6,51%                      | 6,42%                      |
| fev/04                                   | 6,89%        | 5,69%                      | 5,54%                      |
| mar/04                                   | 4,70%        | 4,96%                      | 4,43%                      |
| abr/04                                   | 3,52%        | 3,88%                      | 3,27%                      |
| mai/04                                   | 3,24%        | 2,71%                      | 2,22%                      |
| jun/04                                   | 6,11%        | 3,33%                      | 3,29%                      |
| <b>Média</b>                             | <b>5,33%</b> | <b>4,51%</b>               | <b>4,19%</b>               |

A previsão CELPE apresentou um MAPE médio horário dos dias não-feriados de 5,33%, enquanto que a RNA onde os padrões de feriados são replicados foi de 4,51%. Já o sistema desenvolvido respondeu com 4,19% para os dias não-feriados.

Podemos observar que além de reduzir substancialmente os erros para os dias feriados, o

sistema desenvolvido melhora também a previsão dos dias não-feriados.

## 5. Conclusões

Este trabalho apresenta resultados do projeto de pesquisa e desenvolvimento entre a CELPE e o DEESP/UFPE. Os resultados obtidos indicam a potencialidade do sistema de previsão de carga horária em médio prazo desenvolvido, destacando-se a redução do erro dos dias feriados. O sistema proposto apresenta um MAPE médio horário abaixo de 5%, ficando dentro dos limites atuais de pesquisa [3, 4]. Destaca-se ainda que os resultados de médio prazo foram melhores do que os obtidos com o método estatístico usado atualmente pela CELPE.

A partir dos resultados apresentados, podemos observar que os erros obtidos na previsão de carga dos dias feriados pelo sistema proposto são menores do que os erros obtidos quando os dados dos dias feriados são replicados.

No sentido de melhorar ainda mais os resultados da previsão de carga horária do projeto de pesquisa e desenvolvimento CELPE – DEESP estão sendo implementados ajustes na previsão baseados em outras técnicas de inteligência artificial e em análises heurísticas do comportamento sazonal do mercado da CELPE.

A utilização do algoritmo *Rprop* para o treinamento das redes neurais artificiais foi muito importante, pois além de fornecer bons resultados, este algoritmo permite realizar o treinamento das redes mais rapidamente que o algoritmo backpropagation padrão.

A facilidade de utilização do sistema confrontado com o sistema de previsão da CELPE é outra grande vantagem, pois apenas os dados históricos são necessários para realização de uma boa previsão. O sistema desenvolvido tem apresentado um bom desempenho e incorpora o conhecimento do especialista quando da fixação dos feriados anuais em um sábado ou um domingo.

## 6. Agradecimentos

Os autores agradecem o apoio obtido pela CELPE, que é a empresa financiadora do projeto.

## 7. Referências

[1] AQUINO, R. R. B., FERREIRA, A. A., MEDEIROS, L. H., SILVA, G. B., NÓBREGA NETO, O. *Previsão de Carga em Curto Prazo Utilizando Redes Neurais Artificiais, Modelados Para o Sistema da Celpe*. XXV Cilamce 25<sup>th</sup> Iberian Latin-American Congress On Computational Methods In Engineering, 2004, Recife. CIL32-023.

[2] AQUINO, R. R. B., FERREIRA, A. A., MEDEIROS, L. H., SILVA, G. B., NÓBREGA NETO, O. *Previsão de Carga Em Curto e Médio Prazo Utilizando Redes Neurais Artificiais: Uma Aplicação Ao Sistema CELPE*. XVI Seminário Nacional de Distribuição de Energia Elétrica – SENDI, 2004, Brasília. v. cd-rom, p. 1-6.

[3] BAKIRTZIS, A., PETRLDIS, V., KIARTIZ, S. J., ALEXIARDIS, M. C. *A Neural Network Short Term Load Forecasting Model for the Greek Power System*. IEEE Transactions on Power Systems, 1996, vol.11, no. 2, pp 858-863.

[4] FERREIRA, A. A. *Comparação de arquiteturas de redes neurais para sistemas de reconhecimento de padrões em narizes artificiais*. Dissertação de mestrado. UFPE, Recife-PE, 2004.

[5] KHOTANZAD, A., AFKHAMI-ROHANI, R., LU, T., ABAYE, A., DAVIS, M., MARATUKULAM, D. J. *A Neural-Network-Based Electric Load Forecasting System*. IEEE Transactions on Neural networks, 1997, vol. 8, no. 4, pp. 835-845.

[6] KIM, C., YU, I., SONG, Y. H. *Kohonen neural network and wavelet transform based approach to short-term load*. Electric Power Systems Research, 2002, vol. 63, issue 3, pp. 169-176.

[7] MONTGOMERY, D. C., JOHNSON, L. A., GARDINER, J. S. *Forecasting and Time Series Analysis*. McGraw-Hill International Editions, 1990.

[8] PAPADAKIS, S. E., THEOCHARIS, J. B., KIARTZIS, S. J., BAKIRTZIS, A. G. *A novel approach to Short-term Load Forecasting using Fuzzy neural networks*. IEEE Transactions on Power Systems, 1998, vol. 13, no. 2 , pp. 480-492.

[9] PRECHELT, L. *Proben1 – A Set of Neural Network Benchmark Problems and Benchmarking Rules*. Technical Report, 1994, pp. 21-94.

[10] RIEDMILLER, M., BRAUN, H. *A Direct adaptive Method for faster Backpropagation Learning: The RPROP Algorithm*. University of Karlsruhe, 1993.

[11] SILVA, A., MOULIN, L., REIS, A. J. R. *Feature Extraction via Multiresolution Analysis for Short-Term Load Forecasting*. IEEE Transactions on Power Systems, 2005, vol. 20, no. 1 , pp. 189-198.

[12] WITTEN, W., FRANK, E., *Data Mining, Practical Machine Learning Tools and Techniques with Java Implementations*, D.D. Cerra, Eds, Morgan Kaufmann Publishers, 2000, pp. 126.