

PREV-ENERGY: PROPOSTA DE UM SISTEMA DE PREVISÃO DE DEMANDA POR ENERGIA ELÉTRICA UTILIZANDO REDES NEURAIAS ARTIFICIAIS

STEINMETZ, T.* FERREIRA, S.* SOUZA, G.* VALIATI J.* CANTO DOS SANTOS, J.*

*PIPCA - UNISINOS

São Leopoldo, Rio Grande do Sul, Brasil

Email: trsteinmetz@unisinios.br
sferreira@unisinios.br
gsouza@unisinios.br
jfvaliati@unisinios.br
jvcanto@unisinios.br

Abstract— This work presents the analysis, design and development of an Artificial Neural Network based software to predict the electric load demand for the northeastern region of Rio Grande do Sul. This software is the result of a research and development project undertaken by a partnership between the Rio Grande Energia (RGE) and UNISINOS. Although the software is currently on development phase, the results observed so far are very encouraging: its architecture is very modular and easy to maintain and evolve, it has a user-friendly interface and the neural network developed can predict the load demand for the next thirty days with a NRMSE of 0.02367.

Keywords— Artificial Neural Networks, electric load demand forecast, time series.

Resumo— Este trabalho apresenta as atividades de análise, desenho e desenvolvimento de um sistema baseado em Redes Neurais Artificiais para prever a demanda por energia elétrica para a região norte-nordeste do estado do Rio Grande do Sul. Este sistema é resultado de um projeto de pesquisa e desenvolvimento executado em parceria entre a Rio Grande Energia (RGE) e a UNISINOS. Embora o sistema ainda esteja em fase de desenvolvimento, o mesmo já apresenta resultados encorajadores: a arquitetura do software é bastante modular, garantindo facilidade de manutenção e evolução; tem uma interface gráfica bastante amigável; a rede neural desenvolvida até o presente momento realiza a previsão de demanda por energia para os próximos trinta dias com Erro Quadrático Médio Normalizado de 0,02367.

Palavras-chave— Redes Neurais Artificiais, previsão de demanda por energia elétrica, séries temporais.

1 Introdução

Após a aprovação da Lei Federal nº 10.848 de 15/5/2004, o setor elétrico brasileiro passou por uma setorização das principais atividades relacionadas à energia elétrica: geração, transmissão e distribuição. Isto faz com que empresas exclusivamente de distribuição de energia sejam criadas, fornecendo serviços e cobrando tarifas coerentes com a geração e transmissão da energia elétrica.

As empresas de distribuição de energia devem funcionar sob as regulamentações da Agência Nacional de Energia Elétrica (ANEEL). A Agência define, basicamente, que as empresas devem efetuar um contrato contendo a quantidade de energia a ser distribuída. Além disso, caso a energia distribuída seja menor que o estabelecido no contrato, a empresa deve pagar todo o valor contratado. Por outro lado, se a energia distribuída exceder o valor estabelecido, a empresa estará exposta a penalidades por lastro de energia elétrica. Assim, caso a empresa distribua energia em quantidades muito diferentes do valor contratado, essa estará sujeita a grandes prejuízos.

Vários métodos de previsão de demanda por energia elétrica têm sido propostos pela academia, com o objetivo de solucionar problemas de enfoque co-

mercial como o mencionado acima, assim como problemas de ordem técnica em uma empresa de energia elétrica (Ghods and Kalantar, 2008). Esse trabalho apresenta um sistema de previsão de carga de médio prazo baseado em Redes Neurais Artificiais (RNAs) para a parte norte-nordeste do Estado do Rio Grande do Sul. O sistema é fruto de um projeto de pesquisa e desenvolvimento realizado em parceria entre a UNISINOS e a Rio Grande Energia (RGE). O documento segue o seguinte roteiro: a Seção 2 detalha os aspectos teóricos necessários para o acompanhamento do texto. Na Seção 3 encontra-se o detalhamento do problema, bem como a descrição dos principais requisitos do sistema. A Seção 4 apresenta questões importantes relacionadas ao projeto do sistema, e como as mesmas foram sanadas. A Seção 5 mostra o procedimento adotado para a construção das RNAs de previsão de carga. Por fim, a Seção 6 finaliza o documento, apresentando as conclusões e lições aprendidas pela equipe ao longo do projeto.

2 Previsão da Demanda por Energia Elétrica

A demanda por energia ou carga do sistema pode ser compreendida como o somatório do uso de ener-

gia elétrica de cada ponto de consumo (usuários), atendido por uma estação de fornecimento de energia. Uma estimativa precisa da demanda para diversos instantes de tempo no futuro caracteriza uma valiosa informação para o planejamento técnico e de marketing em uma empresa de distribuição de energia elétrica.

Como mencionado anteriormente, diferentes modelos de previsão de carga foram propostos pela academia. Em (Ghods and Kalantar, 2008) é possível encontrar uma classificação desses modelos com base no prazo em que os mesmos devem realizar a previsão. Em um dos extremos dessa lista, encontram-se previsores de carga de curto prazo, realizando previsões para os próximos minutos, horas ou alguns dias à frente. Esses previsores são usados pelas empresas de distribuição de energia elétrica principalmente no auxílio da compra e venda de quotas no mercado de energia; e também em sistemas de gestão de carga, para garantir que o suprimento de energia seja sempre capaz de suportar a demanda. No outro extremo figuram previsores de muito longo prazo, onde a previsão de demanda é realizada para vários anos no futuro. Previsões desse tipo são usadas para agendar atividades de manutenção dos equipamentos nas empresas de distribuição de energia, para planejar a expansão das linhas de transmissão e para firmar contratos de distribuição de energia elétrica entre a empresa de distribuição e seus maiores clientes.

Os previsores de curto prazo receberam grande atenção dos cientistas no passado e muitas abordagens foram propostas, sendo as mais notáveis: ARIMA (Mbamalu and El-Hawary, 1993), regressão linear (Papalexopoulos and Hesterberg, 1990), sistemas especialistas (Rahman and Hazim, 1990), RNAs (Park et al., 1991) e RNAs combinadas com lógica difusa (Srinivasan et al., 1999).

Dentre os trabalhos com foco em previsores de médio prazo, gerando previsões mensais, encontram-se (Soto et al., 2000) e (Romera et al., 2007). Trabalhos envolvendo previsões para prazos mais longos raramente são publicados, mas é possível mencionar (Ghods and Kalantar, 2008).

Quando os dados sobre a demanda de energia são analisados ao longo do tempo, eles podem ser tratados como uma série temporal. Dessa forma, a previsão para os valores futuros de demanda por energia é realizada com base nos dados sobre a própria demanda registrados no passado (Romera et al., 2007). No entanto, para previsores de curto prazo (para poucos minutos até algumas semanas no futuro), é aconselhável utilizar dados climáticos, tais como temperatura e umidade, em conjunto com os dados de consumo de energia. Essa mesma abordagem não pode ser adotada em previsores para o próximo mês ou ano. Nesse caso

apenas a série temporal de carga é considerada.

3 Definição do Problema

Atualmente, a RGE utiliza um método de previsão de carga baseado no consumo dos últimos três meses, onde também é analisado o comportamento da carga típico de dias de semana, fins de semana e feriados. No entanto, este método é realizado de forma manual, consumindo tempo, recursos e gerando resultados não muito confiáveis.

Dessa forma, o principal interesse da RGE consiste em um sistema capaz de automatizar ao máximo o processo de previsão, além de torná-lo mais preciso. Após reuniões entre a equipe do projeto e a RGE, foi compilada uma listagem estável de requisitos do sistema. Os principais requisitos funcionais estão relacionados abaixo:

1. previsão de carga de curto prazo: tem como objetivo informar a média da demanda por energia elétrica prevista para o mês corrente e para o mês seguinte. No sistema, o mês é tratado como tendo 30 dias;
2. previsão de carga de longo prazo: deve informar a média da demanda por energia elétrica prevista para o ano corrente ou para o ano seguinte. Adotou-se como medida de ano um conjunto de 365 dias;

É importante destacar que a terminologia de horizontes de previsão empregada pela RGE difere daquela comumente utilizada pelos pesquisadores da área de previsão de carga (Seção 2). No texto, será utilizada a terminologia adotada pelo cliente ou seja, previsões de curto e longo prazo referem-se, respectivamente a previsões mensais e anuais.

O erro máximo definido para as RNAs constitui um importante requisito não-funcional do sistema: a equipe acordou que as RNAs não devem apresentar um erro superior a 5%. Uma metodologia rigorosa para a seleção das RNAs que seriam incorporadas ao sistema foi adotada. A mesma é detalhada na Seção 5.

As previsões de curto e longo prazo devem ser realizadas para qualquer uma das sete regiões geoeletricas que constituem o território atendido pela RGE, representadas pelas cidades de: Caxias do Sul, Erechim, Gravataí, Nova Prata, Passo Fundo, Santa Rosa e Taquara. Todas essas cidades são localizadas no Estado do Rio Grande do Sul. Cada região é responsável por fornecer energia elétrica para as cidades menores localizadas em seu entorno.

4 O Sistema de Previsão de Carga

O sistema foi desenvolvido de acordo com o padrão de arquitetura MVC (*Model-View-Controller*) (Larman, 2002). Essa abordagem propicia uma separação dos dados (*Model*) da interface (*View*), sendo o controlador (*Controller*) responsável por manipular os dados e realizar a submissão dos mesmos à RNA correspondente. Essa decomposição também garante uma maior facilidade de entendimento e manutenção do sistema. A Figura 1 ilustra a arquitetura do sistema.

Os módulos da interface e controle foram desenvolvidos com a linguagem C#. Já as redes neurais foram construídas e treinadas com a plataforma estatística R (R Development Core Team, 2008). Ao todo, o sistema conta com catorze RNAs, responsáveis por realizar a previsão de curto e longo prazo para cada uma das sete regiões geo-elétricas que compõem o território da RGE (ver Seção 3). A ligação entre os diferentes módulos foi possível graças à tecnologia COM (*Component Object Model*), evitando a necessidade de codificar meios de comunicação entre módulos gerados em tecnologias diferentes.

A interface gráfica do sistema foi desenvolvida com base nos requisitos de software (Seção 3) e análises de Caso de Uso (Larman, 2002). Algumas propostas de interface foram apresentadas à RGE. A Figura 2 mostra a interface selecionada.

O funcionamento básico do sistema pode ser descrito do seguinte modo: o usuário informa ao sistema qual região geo-elétrica deseja obter a previsão, e também envia um arquivo contendo os dados de entrada para a RNA (ver seção 5). O módulo de controle então submete os dados informados pelo usuário para a RNA responsável por prever a demanda para a região selecionada. Após, o módulo de controle atualiza a interface gráfica com a resposta estimada pela RNA. O usuário pode salvar o resultado encontrado, caso julgar necessário. Abaixo encontra-se um exemplo de resultado apre-

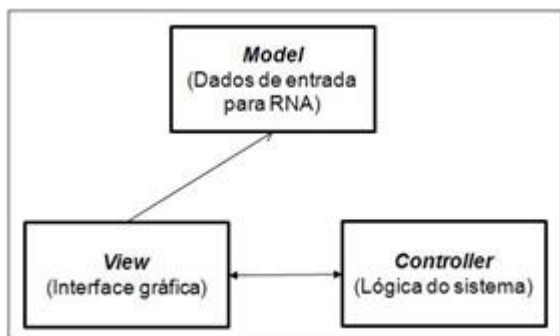


Figura 1: Arquitetura do sistema



Figura 2: Interface gráfica do sistema

sentado para o usuário via interface do sistema:

22/06/2009 - 14:00
Previsão de curto prazo - mês corrente: 27125,91

5 Preparação das RNAs

Esta seção apresenta os aspectos técnicos relacionados à elaboração da RNA de previsão de curto prazo para a região geo-elétrica de Gravataí. A metodologia de geração dessa RNA será adotada para produzir as demais RNAs de previsão de curto prazo.

Com base nos padrões adotados na maioria dos trabalhos relacionados à previsão de carga na literatura, optou-se pela utilização de RNAs do tipo *feedforward* com uma camada oculta. Todas as RNAs foram treinadas com o algoritmo *backpropagation*. Os parâmetros de taxa de aprendizagem e *momentum* para o algoritmo de treinamento foram definidos, respectivamente, como 0,01 e 0,5.

5.1 Dados de Treinamento

A base de dados usada para elaborar a RNA é constituída pelo consumo diário de energia elétrica, registrado no período de março de 1999 até dezembro de 2007, para a cidade de Gravataí. Para verificar a quantidade ideal de dias necessários para melhor estimar a demanda para os próximos 30 dias, foi realizada uma análise de cruzamento por zero na curva de auto-correlação da série temporal de carga (Ostrom Junior, 1990). Após a análise, a equipe concluiu que um conjunto dos últimos trinta dias seria o suficiente para estimar, com relativa precisão, o valor da demanda média para o mês seguinte.

A série temporal também foi processada para gerar

os dados de saída do conjunto de treinamento: a lista foi percorrida por uma janela de trinta dias. A cada iteração foi gerado um novo dado correspondendo à média dos trinta dias dentro da janela.

Após os processamentos realizados sobre a série temporal, obteve-se um arquivo contendo os dados de treinamento para a RNA com a seguinte estrutura:

- dados de entrada: consumo diário dos últimos trinta dias (trinta colunas).
- dados de saída: consumo médio de energia elétrica para os próximos trinta dias (uma coluna).

Finalmente, os dados de treinamento foram normalizados de acordo com a Equação (1):

$$d_n = \frac{d_i - \mu_D}{\sigma_D} \quad (1)$$

onde d_i refere-se ao dado original, μ_D é a média e σ_D o desvio padrão da coluna onde o dado está armazenado.

5.2 Definição da Arquitetura da RNA

O consumo médio de energia elétrica registrado nos últimos trinta dias foi utilizado como referência na tomada de decisão sobre diversos aspectos relacionados à arquitetura da RNA. A Tabela 1 lista as propriedades consideradas no estudo, bem como os valores testados para as mesmas. As redes foram avaliadas segundo o Erro Quadrático Médio Normalizado (EQMN) obtido. Essa métrica pode ser calculada através da equação (2):

$$EQMN = \frac{EQM}{V - v} \quad (2)$$

onde EQM é o Erro Quadrático Médio, V e v correspondem respectivamente ao maior e menor valor da série temporal de carga. O EQM é obtido como mostra a Equação (3):

$$EQM = \sqrt{\frac{(v_r - v_e)^2}{n}} \quad (3)$$

Propriedade	Valores
Neurônios ocultos	1 - 64
<i>Shortcut connections</i>	Sim, Não
Épocas de treinamento	1000, 3000, 6000
Semente para inicialização dos pesos	0 - 6

Tabela 1: Propriedades das RNAs testadas contra os dados de consumo médio dos últimos 30 dias

onde v_r é o valor real (presente na base de dados), v_e é o valor estimado pela RNA e n é o número total de dados. Embora a métrica MAPE (*Mean Absolut Percentage Error*) seja comumente empregada na avaliação de desempenho de previsores de carga, o EQMN foi selecionado nesse trabalho por uma questão de padronização: o EQMN é utilizado como métrica padrão em projetos desse tipo na empresa cliente.

A Tabela 2 descreve as características da RNA selecionada como previsor de carga de curto prazo, tendo-se como base o menor EQMN encontrado durante o teste das arquiteturas candidatas.

5.3 Teste da RNA Gerada

Com o objetivo de mensurar o real desempenho da RNA quando a mesma entrar em produção, ou seja, quando o sistema passar a ser utilizado pela RGE, foi realizada uma última simulação: um padrão até então nunca visto pela RNA, compreendendo os dados de consumo registrados no último mês, foi submetido à rede e seu erro foi avaliado. O EQMN apresentado pela RNA para esse padrão foi de 0,0247. Assim, é possível concluir que a RNA incorporada ao sistema tem um desempenho semelhante ao verificado na etapa de seleção da arquitetura.

6 Conclusões

Esse trabalho apresentou o projeto de um sistema de previsão de demanda por energia elétrica baseado em RNAs, desde a sua concepção até a integração da RNA ao sistema. O projeto é realizado em parceria entre a UNISINOS e a RGE, empresa responsável pela distribuição de energia elétrica para a região norte-nordeste do Estado do Rio Grande do Sul. Embora o sistema ainda não esteja totalmente concluído, tanto a equipe de desenvolvimento (UNISINOS) quanto o cliente (RGE) percebem bons resultados.

Propriedade	Valores
Neurônios ocultos	8
<i>Shortcut connections</i>	Não
Épocas de treinamento	3000
Semente para inicialização dos pesos	4
EQMN	0,02367

Tabela 2: Propriedades da RNA selecionada como previsor de curto prazo para a cidade de Gravataí

A produção do sistema de forma modular seguindo o padrão de arquitetura MVC permite não somente facilidades de desenvolvimento e manutenção, mas possibilita também que as RNAs sejam construídas e treinadas segundo a metodologia descrita nesse trabalho de forma independente, enquanto outros módulos do sistema são desenvolvidos em paralelo. Essa abordagem, definida logo no início dos trabalhos, garante uma construção mais ágil e rápida do sistema.

Obviamente, a observação mais importante até o momento, tem relação com a precisão das RNAs desenvolvidas: elas apresentam um desempenho muito favorável, com erro médio medido em cerca de 2%.

Dentre as próximas atividades agendadas para o projeto destacam-se a geração das RNAs de curto prazo para as demais regiões geo-elétricas. Além disso, ainda é necessário definir uma metodologia eficiente para a produção das RNAs responsáveis pela previsão de carga de longo prazo. Os autores pretendem apresentar essas atividades em trabalhos futuros.

Agradecimentos

Os autores agradecem a RGE e todos os seus colaboradores, bem como a CAPES/CNPq pelo apoio à realização desse projeto.

Referências

- Ghods, L. and Kalantar, M. (2008). Methods for long-term electric load demand forecasting; a comprehensive investigation, *IEEE International Conference on Industrial Technology, 2008*.
- Larman, C. (2002). *Applying UML and patterns: an introduction to object-oriented analysis and design and the unified process*, second edn, Prentice-Hall.
- Mbamalu, G. and El-Hawary, M. (1993). Load forecasting via suboptimal seasonal autoregressive models and iteratively reweighted least squares estimation, *IEEE Transactions on Power Systems, 1993*.
- Ostrom Junior, C. W. (1990). *Time series analysis: regression techniques*, second edn, Sage.
- Papalexopoulos, A. and Hesterberg, T. (1990). A regression-based approach to short-term load forecasting, *IEEE Transactions on Power Systems, 1990*.
- Park, D., El-Sharkawi, M., Marks, R., Atlas, L. and Damborg, M. (1991). Electric load forecasting using an artificial neural network, *IEEE Transactions on Power Systems, 1991*.
- R Development Core Team (2008). *R: A Language and Environment for Statistical Computing*, R Foundation for Statistical Computing, Vienna, Austria.
- Rahman, S. and Hazim, O. (1990). A generalized knowledge-based short-term load-forecasting technique, *IEEE Transactions on Power Systems, 1993*.
- Romera, E., Morán, M. and Fernández, D. (2007). Forecasting of the electric energy demand trend and monthly fluctuation with neural networks, *Elsevier Computers and Industrial Engineering, 2007*.
- Soto, C., Vellasco, M. and Pacheco, M. (2000). Electric load time series forecasting using neural networks, *VII international congress of electronic, electrical and system engineering, 2000*.
- Srinivasan, D., Tan, S., Chang, C. and Chan, E. (1999). Parallel neural network-fuzzy expert system strategy for short-term load forecasting: system implementation and performance evaluation, *IEEE Transactions on Power Systems, 1999*.