

CIDEL Argentina 2014
Congreso Internacional de Distribución Eléctrica

**PROJEÇÃO DE DEMANDA DE ENERGIA ELÉTRICA NO CURTO PRAZO
CONSIDERANDO EFEITOS CLIMÁTICOS: UMA ABORDAGEM ATRAVÉS DE
REDES NEURAIS**

D. Boff¹ **G. Bordin²** **M. O. Oliveira³**
diego.boff@aes.com gladis.bordin@ufrgs.br oliveira@fio.unam.edu.ar

- ¹ AES Sul Empresa. Departamento de Mercado e Regulação Econômica. Rua Dona Laura 320, Tel 55- 51-33161494, Porto Alegre - Brasil. Porto Alegre–Brasil.
- ² Escola de Engenharia – Universidade Federal do Rio Grande do Sul (UFRGS). Av. Osvaldo Aranha 103, Tel +55-51-33084282, Porto Alegre –Brasil.
- ³ Facultad de Ingeniería – Universidad Nacional de Misiones (UNaM). Juan Manuel de Rosas 325, Tel/Fax +54-03755-422169/170, Misiones –Argentina.

Palavras-chave: Projeção de demanda, energia elétrica, redes neurais artificiais, variáveis climáticas.

➤ **RESUMO**

O presente trabalho apresenta um modelo para projeção de demanda de energia elétrica para o horizonte de curto prazo, considerando os efeitos de variações climáticas com uso de Redes Neurais Artificiais (RNA). Um sistema automático de projeção de demanda foi desenvolvido em ambiente MatLab®. A cada projeção de demanda diária é associado um determinado dia da semana (dia útil, domingo e feriado ou sábado), pré-definido na fase de treinamento da RNA. Com base no estudo das principais variáveis climáticas com influência na projeção de demanda no curto prazo, considera-se: temperatura média diária, insolação e umidade relativa do ar. Um estudo de caso utilizando dados reais de uma concessionária de energia elétrica na região sul do Brasil é apresentado, mostrando a eficiência e robustez da metodologia proposta.

1. INTRODUÇÃO

A projeção de demanda de energia elétrica é um estudo básico para o planejamento da expansão e operação, programação da operação e confiabilidade de sistemas elétricos de potência. Diversas são as metodologias propostas para a projeção de demanda elétrica sob o foco de distintos intervalos de tempo [1]. Historicamente, a projeção de demanda de energia elétrica no curto prazo (horas a frente até algumas semanas) tem sido realizada utilizando-se modelos estatísticos, porém, a carga e seus fatores exógenos têm caráter não-linear, limitando a aplicação destes modelos.

Alguns métodos em uso para projeção de curto prazo são apresentados em [2] como: modelo de Box e Jenkins, *exponential smoothing*, regressão linear e múltipla, modelos adaptativos, modelos climáticos, RNA, e sistemas inteligentes. Segundo

[3], a técnica de RNA substitui os métodos estatísticos de projeção e mostra uma comparação com os métodos de projeção causal, séries temporais e *judgmental forecasting*. Por outro lado, [4] apresenta um modelo que permite capturar as principais causas de variação de demanda de energia elétrica utilizando séries temporais e considerando a temperatura, velocidade do vento e luminosidade para produzir projeções probabilísticas para picos de demanda diários.

Em [5], o modelo ARIMA e o modelo função transferência são utilizados para projeções de curto prazo, considerando a relação entre clima e demanda de energia elétrica. O estudo é feito para três tipos de consumidores: residencial, comercial e industrial. Neste sentido, [6] apresenta o modelo de séries temporais utilizando o modelo ARIMA para projeções horárias, em condições de incluir a experiência do planejador. Comparações entre soluções baseadas em RNA e o modelo ARIMA para o problema de projeção mensal de energia elétrica são apresentados em [7] e [8]. Em [9] é proposto um método de projeção de curto prazo baseado em RNA e lógica fuzzy, com o objetivo de eliminar erros introduzidos pela dependência da carga com a sazonalidade de alguns fatores.

O presente artigo apresenta uma metodologia de projeção de demanda de energia elétrica para o horizonte de curto prazo baseada na utilização de RNA que permitem estabelecer relações entre dados complexos e não-lineares como as variáveis envolvidas neste estudo. Os resultados obtidos com o método proposto são promissores e mostram a robustez do algoritmo desenvolvido.

2. ASPECTOS REGULATÓRIOS DO SISTEMA ELÉTRICO BRASILEIRO

Com a regulamentação do Sistema Elétrico Brasileiro (SEB) a demanda projetada para os

mercados consumidores é parte essencial no processo de formação de preço da energia comercializada no curto prazo. De acordo com [10], o mercado atacadista de energia (câmara de comercialização de energia elétrica) foi criado para ser o ambiente de liquidação e contabilização de todas as atividades de compra de curto prazo (mercado *spot*). Devido à implantação deste mercado surgem novas relações entre os agentes, com destaque para as mudanças envolvendo as transações comerciais e a necessidade dos agentes em conhecer o comportamento do mercado e seus respectivos preços de curto prazo.

A contabilização de energia é o processo que define os pagamentos associados à geração necessária para que a carga seja atendida totalmente. Essa contabilização é composta por uma etapa que antecede à operação e outra após a operação do mercado [11]. Na primeira, todas as distribuidoras contratam energia (basicamente em leilões) para cobrir o mercado e as perdas no longo prazo. Nesta etapa são firmados contratos individuais com cada usina (volume e preço) para um determinado horizonte de contratação (5/10/15 anos). Neste cenário, quando acontece a operação do mercado pode haver diferenças entre a energia contratada e a energia necessária (chamamos de requerida). Essa diferença é “comprada” em caso de falta de contratos ou “vendida” em caso de sobra de contratos no mercado de curto prazo ao preço de PLD. Esse processo não depende da projeção de demanda no curto prazo e sim de projeções de mercado de energia no longo prazo, com ajuste, somente financeiros no curto prazo.

O objetivo deste processo é a declaração de informações consistentes de geração e de carga a ser atendida pelo sistema interligado nacional. Dessa forma, os geradores que venham a gerar menos do que o planejado têm sua renda líquida garantida e paga pelo mercado. Assim, com base nos atuais aspectos regulatórios do SEB, a projeção de demanda de curto prazo requer modelos computacionais que permitam estimativas confiáveis para este horizonte de planejamento, dado que influencia diretamente na formação de preço de energia elétrica. Assim, os estudos de projeção de demanda no curto prazo são essenciais para que o ONS programe o despacho das usinas considerando a ordem de mérito econômico e as restrições de sistema. Um dos resultados deste processo é o preço da energia no curto prazo, que é utilizado na liquidação de contratos de curto prazo.

3. METODOLOGIA PROPOSTA PARA PROJEÇÃO DE DEMANDA

Na metodologia proposta, para cada projeção diária é associado um tipo de dia (dia de semana ou fim de semana) o qual é pré-definido na fase de treinamento. Para projetar a carga do dia seguinte o

sistema considera a informação sobre a projeção do tempo que é a variável de entrada da RNA. A resposta é a demanda projetada apresentada em megawatts (MW).

3.1 VARIÁVEIS DE ENTRADA

Neste trabalho, as variáveis de entrada do algoritmo de projeção são a temperatura média diária, insolação (número de horas de sol no dia) e umidade relativa do ar. A umidade relativa do ar associada com a temperatura média diária representa um fator relevante no consumo de energia elétrica [12].

Vale salientar que, o conjunto de amostras de dados históricos referentes às variáveis de entrada deve ser relevante e abranger o maior número de diferentes eventos ao longo do tempo.

3.2 ESTRUTURA DA RNA

A estrutura da RNA é fundamental para o processo de modelagem, pois a capacidade de identificar padrões não presentes na fase de treinamento depende da estrutura escolhida. Neste trabalho utiliza-se uma estrutura de quatro camadas, sendo uma de entrada, duas ocultas e uma de saída. O número de neurônios das camadas ocultas determina a capacidade de aprendizado da rede. A Fig. 1 apresenta o algoritmo de treinamento da RNA, adaptado de [13].

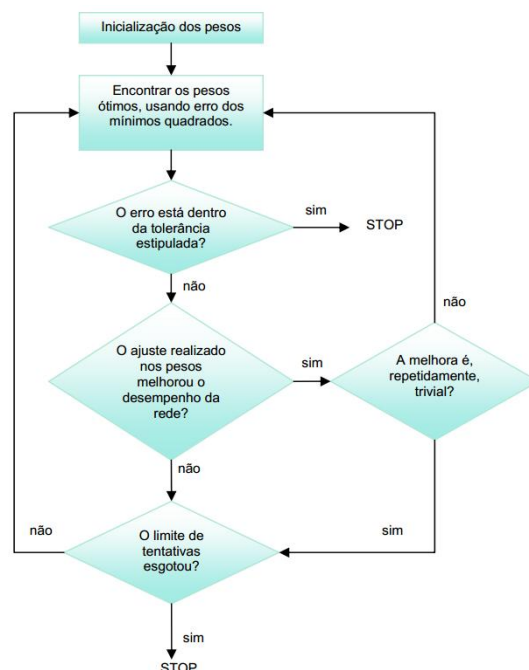


Fig. 1: Algoritmo Utilizado para Treinamento da RNA.

A utilização de dados históricos no processo de treinamento possibilita a atualização dos pesos sinápticos baseada na comparação da resposta da rede com o valor realizado para aquele conjunto de variáveis de entrada. O presente trabalho utiliza o

algoritmo de treinamento de retropropagação, que faz uso da técnica de mínimo erro quadrático, buscando realizar o ajuste dos pesos sinápticos.

3.3 PRÉ-PROCESSAMENTO DE DADOS

O pré-processamento dos dados tem por objetivo normalizar as variáveis de entrada, visando reduzir o tempo de treinamento da RNA e melhorar o aprendizado da rede na fronteira dos dados de entrada.

O conjunto de dados que apresentam uma distribuição estatística normal facilita o aprendizado da RNA pelo fato de que a maioria dos dados individuais está em torno da média. Caso estes dados não apresentem distribuição normal, eles podem ser modificados ou rearranjados para que se tornem significativos para a saída.

O coeficiente de Skewness indica se um determinado conjunto de informação é normalmente distribuído. Assim, se o resultado obtido da equação (1) ficar na faixa de -0,5 e +0,5 pode-se afirmar que o conjunto de dados está normalmente distribuído.

$$Coef. Skewness = \frac{\sum \left[\frac{X_i - mean(X_T)}{Std(X_T)} \right]^3}{N_T} \quad (1)$$

onde:

X_i : dado i ,
 $mean(X_T)$: média do conjunto de dados,
 $Std(X_T)$: Desvio padrão do conjunto de dados,
 N_T : Número total de dados.

3.3.1 Normalização

É o processo que modifica um conjunto de informações para que este apresente uma distribuição normal. O fator de normalização pode ser calculado como na equação (2).

$$Normalized X = \frac{X_i - mean(X_T)}{Std(X_T)} \quad (2)$$

Caso o valor absoluto das variáveis de entrada seja, significativamente diferente, é plausível normalizá-los para melhorar a estabilidade numérica do processo [13]. Nesse caso, o valor referente a um dia de consumo de energia elétrica será normalizado pela média de todos os consumos diários dos pares entrada-saída do processo de treinamento. Assim, o valor normalizado é dado pela equação (3).

$$C_{norm} = \frac{C_{dia}}{C_{med}} \quad (3)$$

onde:

C_{norm} : consumo normalizado do dia,
 C_{dia} : consumo do dia em questão [MWh],
 C_{med} : consumo médio da amostra histórica utilizada no treinamento da rede [MWh],

A saída da rede é multiplicada pelo fator de normalização objetivando ter o valor projetado do consumo de energia elétrica em MWh, conforme expressão (4).

$$C_{proj} = C_{RNA} \times C_{med} \quad (4)$$

onde:

C_{proj} : consumo projetado do dia [MWh],
 C_{RNA} : Resposta da rede [adimensional],
 C_{med} : consumo médio da amostra histórica utilizada no treinamento da rede [MWh],

3.3.2 Mudança de Escala

A mudança de escala pode ser feita de forma que os dados variem entre $X_{min} = 0$ e $X_{max} = 1$. Este processo é importante para que o algoritmo de treinamento, baseado no método de gradiente descendente, atinja a convergência. Assim, a mudança de escala é feita conforme a expressão (5).

$$X = \frac{X_i - X_{min}}{X_{max} - X_{min}} \quad (5)$$

Com base no anteriormente descrito, o modelo computacional é ilustrado e descrito a seguir.

4. IMPLEMENTAÇÃO DO MODELO COMPUTACIONAL

O modelo computacional foi implementado em ambiente MatLab® [14], de acordo com a estrutura apresentada na Fig. 2.




Fig. 2: Estrutura do Algoritmo Computacional.

Do total de dados adquiridos, referentes ao período de 1 de janeiro de 2012 a 18 de maio de 2013, 70% foram utilizados para o treinamento da rede e o restante foi utilizado para a validação do modelo proposto.

Os melhores resultados foram obtidos quando os dias da semana foram separados em três grupos: domingos e feriados, sábados e dias úteis da semana. Para os três grupos, a estrutura que apresentou resultados melhores é composta por duas camadas ocultas, a primeira com seis neurônios e a segunda com dois, com funções de ativação logarítmica (*logsig*) entre os neurônios da

camada de entrada e a primeira camada oculta, assim como entre esta e a segunda camada oculta e a camada de saída foi utilizada a função de ativação linear (*purelin*).

Para treinamento foi utilizada a função *trainlm* que é baseada na otimização de Levenberg-Marquardt. Essa função requer que os pesos sinápticos, as entradas e as funções de ativação tenham funções que possam ser derivadas. O treinamento é interrompido quando o número máximo de épocas (definido em 3000) ou o erro máximo permitido (1%) sejam atingidos. A cada época todas as entradas da rede para treinamento são processadas, ou seja, se o treinamento durar 500 épocas, cada vetor de entrada terá sido utilizado 500 vezes.

5. VALIDAÇÃO DA METODOLOGIA PROPOSTA PARA PROJEÇÃO DE DEMANDA

Para validação da metodologia de projeção no curto prazo, foi realizada a projeção de demanda de energia elétrica para um período em que as demandas projetadas eram conhecidas, os resultados obtidos são apresentados a seguir.

5.1 PROJEÇÃO PARA DOMINGOS E FERIADOS

Devido à quantidade de informações sobre domingos e feriados existentes no banco de dados (59 dados para treinamento e 25 dados para teste) acrescentando ainda à imprecisão dos dados coletados, a precisão do algoritmo de projeção desta RNA foi baixa. A Fig. 3 mostra a demanda projetada comparada com a demanda real de energia elétrica para um horizonte de 25 dias à frente. Os valores máximos de erro chegaram a 11%, o que não é satisfatório para o planejamento da operação.




Fig. 3: Projeção de Demanda para Domingos e Feriados 25 dias à Frente.

5.2 PROJEÇÃO PARA SÁBADOS

Pelos mesmos motivos citados em relação aos domingos e feriados, a precisão da projeção desta RNA ficou comprometida, o que pode ser

verificado na Fig. 4 que compara a demanda diária projetada com a demanda realizada. Nesse caso, foram utilizados 60 dados para treinamento e 26 dados para teste. Os valores máximos de erro chegaram a 10%, o que não é satisfatório para o planejamento da operação.

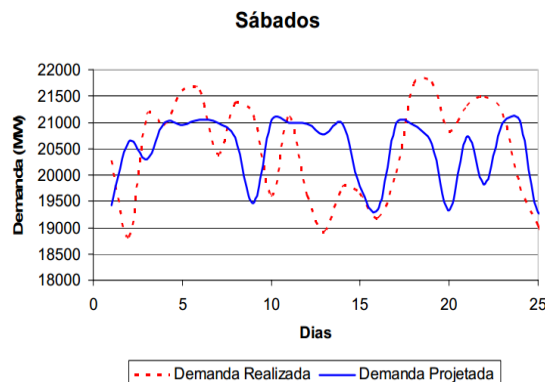


Fig. 4: Projeção de Demanda para Sábados 25 dias à Frente.

5.3 PROJEÇÃO PARA DIAS DE SEMANA

Ao contrario dos grupos anteriormente apresentados, o banco de dados para os dias de semana é mais completo, sendo utilizados 123 dados para validação do modelo e 287 para o treinamento da rede, embora a imprecisão da leitura dos dados seja a mesma.

A Fig. 5 ilustra a comparação entre a demanda projetada e a demanda realizada. Nesse caso, o erro máximo verificado foi de 5%.




Fig. 5: Projeção de Demanda para Dias Úteis da Semana 25 dias à Frente.

Embora o Operador Nacional do Sistema (ONS), responsável pela operação no Brasil trabalhe com precisão de 3%, o resultado obtido com a metodologia proposta foi satisfatório, considerando que o banco de dados é relativamente pequeno, podendo não ter contemplado algumas situações e prejudicando assim a generalização da RNA.

6. CONCLUSÕES

Este trabalho apresentou um modelo de projeção de demanda de energia elétrica para o horizonte de curto prazo, com base em Redes Neurais Artificiais. Essas redes têm sido utilizadas no processo de projeção por permitirem a inclusão de dados que apresentem aleatoriedade, característico das variáveis de entrada (temperatura média diária, insolação e umidade relativa) utilizadas no modelo aqui apresentado.

A divisão dos dias da semana nos três grupos, ou seja, domingos e feriados, sábados e dias úteis da semana, possibilitou o melhor ajuste das redes neurais, uma vez que apresentaram características semelhantes. Portanto, para um melhor desempenho da metodologia proposta é necessário dispor de um maior banco de dados históricos o que permitirá uma generalização mais adequada do uso das RNA para projeção de demanda. Isso melhorará a eficiência da metodologia de projeção apresentada neste artigo. No entanto, o método de projeção apresentou melhores resultados quando foi criada uma RNA para cada grupo.

Os resultados da simulação com o modelo desenvolvido podem ser usados para outros estudos, como, por exemplo, o despacho econômico das usinas de geração.

4 REFERÊNCIAS BIBLIOGRÁFICAS

- [1] M. O. Oliveira, D. P. Marzec, G. Bordin, A. S. Bretas, D. P. Bernardon, V. M. Madeira, “Projeção de Demanda de Energia Elétrica Considerando o Índice de Desconforto”. *Simpósio Brasileiro de Sistemas Elétricos – SBSE*, Pará –Brasil, 2010.
- [2] S. M. Al-Alawi, S. M. Islam, “Principles of Electricity Demand Forecasting – Part I Methodologies”. *Power Engineering Journal*, June 1996.
- [3] L. Marquez, T. Hill, M. O’connor, W. Remus, “Neural Network Models for Forecast: A Review”. In: *25th Hawaii International Conference on System Sciences*, vol. 4, pp. 494-498, January 1992.
- [4] P. E. Mcsharry, S. Bouwman, G. Bloemhof, “Probabilistic Forecasting of the Magnitude and Timing of Peak Electricity Demand”. *IEEE Transaction on Power System*, vol. 20, no. 2, pp. 1166-1172, May 2005.
- [5] M. Y. Cho, C. S. Chen, J. C. Hwang, “Customer Short Term Load Forecasting by Using ARIMA Transfer Function Model”. In: *International Conference on Energy Management and Power Delivery*, vol. 1, pp. 317-322, November 1995.
- [6] N. Amjadi, “Short-term hourly load forecasting using time series modeling with peak load estimation capability”. *IEEE Transaction on Power System*, vol. 16, no. 4, pp. 798-805, 2001.
- [7] A. L. A. Júnior, G. C. Vasconcelos, “Previsão de Demanda Máxima Baseada em Redes Neurais”. *XV Seminário Nacional de Distribuição de Energia Elétrica*, Foz do Iguaçu, PR –Brasil, 1999.
- [8] M. H. Choueiki, C. A. Campbell, S. C. Ahalt, “Building a ‘Quasi-Optimal’ Neural Network to Solve the Short-Term Load Forecasting Problem”. *IEEE Transaction on Power System*, vol. 12, no. 4, pp. 1432-1439, 1997.
- [9] T. Senjyu, P. Mandal, K. Uezato, T. Funabashi, “Next Day Load Curve Forecasting Using Hybrid Correction Method”. *IEEE Transaction on Power System*, vol. 20, no. 1, pp. 102-109, 2005.
- [10] G. S. Schuch, F. Porrua, R. C. Lotero, “A Análise da Atividade de Comercialização de Energia Elétrica no Setor Elétrico Brasileiro”. Fórum de Energia, Novo Hamburgo, RS - Brasil, 2003.
- [11] E. L. Silva, “Formação de Preços em Mercados de Energia Elétrica”. Editora Sagra Luzzatto, 2001.
- [12] M. O. Oliveira, D. P. Marzec, G. Bordin, A. S. Bretas, D. P. Bernardon, “Análise do Efeito de Variáveis Climáticas sobre a Evolução de Demanda de Energia Elétrica”. *XVIII Congresso Brasileiro de Automática – CBA*, Bonito, MS –Brasil, 2010.
- [13] W. Charytoniuk, E. D. Box, W. J. Lee, M. S. Chen, P. Kotas, V. P. Olinda, “Neural Network Based Demand Forecasting in a Deregulated Environment”. *Energy Systems Research Center, Texas University*, 2010.
- [14] The Mathworks Inc. Matlab (2011). <http://www.mathworks.com>.