

A INFLUÊNCIA DA DESAGREGAÇÃO DA DEMANDA NOS MODELOS DE PREVISÃO DE ENERGIA ELÉTRICA EM MERCADOS COMPETITIVOS

FABIANO F. ANDRADE¹, MARIA A. UBERTTI¹, LEANDRO S. MONTEIRO¹,
CHRYSYTIAN L. REMES¹, ANA BÁRBARA K. SAMBAQUI².

1. *Laboratório de Planejamento Energético - LAPER, Departamento de Engenharia Elétrica, Universidade do Estado de Santa Catarina – UDESC
Campus Universitário Avelino Marcante S/N, Bairro Bom Retiro, 89223-100, Joinville, SC, Brasil.
E-mails: fabianof@joinville.udesc.br, m.ubertti@hotmail.com,
leosmonteiro@gmail.com, crhystian.r17@gmail.com*

2. *Instituto Federal de Santa Catarina – IFSC, Unidade Joinville.
Campus Joinville, Rua Pavão, 1337, Bairro Costa e Silva, 89220-200, Joinville, SC, Brasil.
E-mails: anabarbara@ifsc.edu.br*

Abstract— With the recent modernization of the electricity sector in several countries, the knowledge about the behavior of the electricity demand of the main consuming classes has become a problem enough interest from companies and agents connected to the electric power market. This article deals with this issue by addressing the effects of the disaggregation of consumption demand of the industrial sector of Santa Catarina on the forecast models. In the methodology are considered economic variables and parameters of the climate that more variation in demand over more than 10 years of data. With forecasters models based on artificial neural networks in this type of problem was obtained precise estimates for the demand in the medium term considering a specific segment of the industry and also the entire industrial class. Finally, this work draws attention to the need for specific studies for each type of consumer and risks using sectorial projections on the behavior of the demand of specific segments.

Keywords— time series models, load forecasting, disaggregated demand, neural network applications.

Resumo— Com a recente modernização do setor elétrico em vários países, o conhecimento sobre o comportamento da demanda de energia elétrica das principais classes consumidoras tem se tornado um problema de bastante interesse de empresas e agentes ligados ao mercado de energia elétrica. Esse artigo trata deste tema abordando os efeitos da desagregação da demanda do consumo do setor industrial de Santa Catarina sobre os modelos de previsão. Na metodologia são consideradas variáveis econômicas e parâmetros do clima além da variação da demanda ao longo de mais de 10 anos de dados. Com a aplicação de modelos previsores, baseados em redes neurais artificiais, neste tipo de problema obteve-se estimativas bem precisas para a demanda no médio prazo considerando um segmento específico da indústria e também toda a classe industrial. Finalmente, este trabalho alerta para a necessidade de estudos específicos de cada tipo de consumidor e os riscos da utilização de projeções setoriais sobre o comportamento da demanda de segmentos específicos.

Palavras-chave— modelagem de séries temporais, previsão de demanda, desagregação da demanda, redes neurais.

1 Introdução

Desde meados dos anos 90, com a desverticalização e modernização do setor elétrico brasileiro, o país conheceu novos agentes com intuito de atrair investimentos e sustentar o crescimento do país. Nesse período é notório o dinamismo deste setor da sociedade com duas grandes reformas em termos de marco regulatório e ainda um período de racionamento em 2001. No setor elétrico, planejar envolve a determinação de uma estratégia de expansão do sistema que permita atender à demanda futura de energia elétrica, de modo a minimizar os custos de expansão e propiciar condições para a operação segura e econômica do sistema elétrico (Tolmasquim, 2011).

Embora o planejamento da oferta de energia elétrica seja de grande relevância, nesse artigo aborda-se a questão do planejamento pelo lado da demanda. Entende-se que o comportamento da demanda dos principais consumidores de energia elétrica deve ser melhor estudado, estimado e previsto para que os

agentes geradores, comercializadores e distribuidores de energia elétrica reduzam o nível de incertezas sobre seus negócios, com ganhos econômicos para a sociedade.

O processo de transformação dos mercados de energia elétrica, em curso nas principais economias nas últimas décadas, ampliou a eficiência e o conhecimento dos agentes envolvidos neste setor. O surgimento, expansão e amadurecimento do ambiente de contratação livre (ACL) de energia no país atestam a evolução neste sentido e beneficiam os setores mais competitivos da nossa economia. Para manterem-se ativas e expandindo neste mercado, as comercializadoras e geradoras de energia têm oferecido produtos diferenciados para seus clientes, que vão desde a gestão dos contratos de energia à programas de conservação.

Com a consolidação do mercado de energia mais competitivo, tem-se também um ambiente cheio de riscos e oportunidades, onde a incerteza sobre os movimentos regulatórios, sobre as variações de preço da energia e sobretudo em relação aos rumos da economia doméstica e mundial estão sempre em pauta.

Num movimento mais recente, áreas de inteligência dos agentes do setor elétrico vêm desenvolvendo modelos que reduzem a incerteza sobre o comportamento da demanda de energia elétrica, precedente principal de toda a cadeia do setor.

O problema da previsão de séries temporais relativas ao consumo mensal de energia elétrica tem a sua complexidade associada ao nível de imprevisibilidade do agente consumidor em questão. Reduzindo o conjunto de consumidores de todo um país, passando por uma classe consumidora, neste caso a indústria, até delimitar um segmento industrial específico, o problema torna-se mais complexo e a demanda mais desagregada.

O artigo apresenta uma discussão com foco mais teórico sobre as vantagens de analisar o comportamento da demanda conforme o nível de desagregação. De um modo geral, a desagregação da demanda industrial, com uma análise setorial, possibilita conhecer melhor as características próprias de cada segmento e os graus de influência das variáveis externas sobre os mesmos. Diferentes indústrias têm diferentes processos de produção, que são influenciados por diferentes parâmetros externos e, portanto, apresentam diferentes padrões de consumo (Chang e Chern, 1981).

Alguns poucos trabalhos tratam da previsão de demanda industrial desagregada (Mc Cafferty e Beattie, 1991; Ang, 1995; Kamerschen e Porter, 2004; Zotteri et al., 2005; Azadeh e Sohrabkhani, 2006; Úbeda e Berzosa, 2007). Por outro lado, trabalhos de previsão de demanda em níveis mais altos de agregação são largamente estudados.

2 Propósito

Este trabalho alerta para os cuidados sobre a tomada de decisões sobre o comportamento futuro da demanda de segmentos específicos da indústria baseados em modelos de previsão da demanda agregada. Defende-se a necessidade de estudos específicos capazes de prever individualmente o consumo mensal de energia elétrica dos segmentos da indústria, baseada nos fatores econômicos e climáticos de maior influência. Com a aplicação de redes neurais artificiais pôde-se estabelecer boas estimativas para o consumo nos meses seguintes.

A metodologia utilizada pode ser dividida em três etapas: (i) levantamento das características próprias de cada segmento; (ii) seleção das variáveis exógenas de maior impacto baseado na modelagem econométrica; e (iii) configuração de modelos neurais de previsão da demanda. Para validar a proposta, foram utilizadas séries históricas do consumo de energia elétrica de todos os segmentos industriais de Santa Catarina, de 1997 a 2006, e de indicadores econômicos e climáticos relacionados.

Para demonstrar a viabilidade de um estudo específico e desagregado, a metodologia de previsão foi aplicada apenas o setor têxtil de Santa Catarina.

3 Metodologia

3.1 Processo de Desagregação da Demanda

Existem várias formas de se realizar a desagregação da demanda, (1) por classe social: residencial, comercial, industrial e outros, (2) pela intensidade energética: eletro-intensivos e os demais, (3) pelo consumo: grandes consumidores e os demais, (4) por atividades econômicas: agricultura, transportes, comércio, construção civil, energético, etc., (5) por segmentos industriais: têxtil, metalúrgico, cerâmico, alimentar, etc.

A desagregação a um nível de detalhamento muito grande não é uma garantia de modelos mais precisos para estudo da demanda. Deve-se compreender, porém, que os objetivos de um estudo sobre a demanda, juntamente com os meios disponíveis para sua consecução, são determinantes para a escolha do nível de desagregação. Mc Cafferty e Beattie (1991) relacionam na Tabela 1 algumas vantagens e desvantagens do estudo da demanda industrial de forma desagregada.

Tabela 1. Vantagens e Desvantagens da Desagregação.

Desagregação da Demanda Industrial	
Vantagens	Desvantagens
Maior aproveitamento das informações disponíveis	A própria definição do nível adequado de desagregação a ser utilizado
Componentes de maior frequência não são omitidas	A disponibilidade de muitos dados
A variação dos dados de entrada é mais dinâmica	Maior esforço para modelagem
Permite desenvolver modelos mais especializados	

Segundo Zotteri et al. (2005) a previsão é um processo mais complexo do que a simples escolha do melhor algoritmo a ser implementado. Os autores dedicam especial atenção ao problema do ajuste correto do nível de agregação/desagregação dos dados, o que pode resultar na melhoria do modelo.

Previsões de demanda, mais precisas, dependem do conhecimento dos fatores que regem seu comportamento, que por sua vez, podem ser mais característicos de cada segmento da indústria. Entretanto, a necessidade de estimar tais fatores, traz o custo da habilidade em se capturar as diferenças entre os segmentos da indústria, ao mesmo tempo em que proporciona uma previsão mais acurada dos diferentes segmentos (Figura 1).

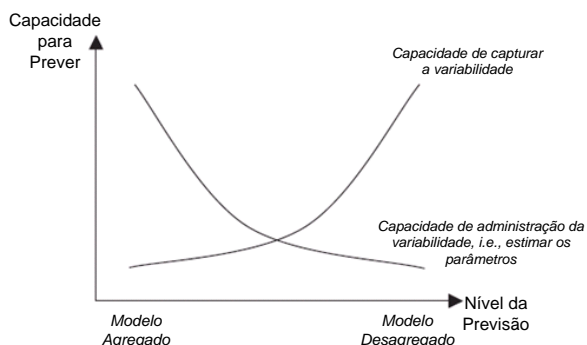


Figura 1. Relação de Perdas e Ganhos do Nível de Desagregação. (Zotteri et al., 2005)

Como pôde ser observada na literatura, a definição do nível ideal de desagregação dos dados da demanda industrial não é uma tarefa trivial.

3.2 Modelo Híbrido de Previsão de Demanda

O modelo de previsão de demanda construído apresenta uma metodologia bastante particular. A principal questão a respeito do comportamento do consumidor e que instigou o desenvolvimento deste trabalho foi: “Com que intensidade, uma variável econômica ou climática, pode estar correlacionada com o consumo de energia elétrica de um segmento da indústria?” A influência de uma determinada variável, seja econômica ou climática, sobre o consumo pode ser entendida, estatisticamente, pelo grau de correlação entre elas num processo de regressão. Para responder a questão anterior, a metodologia apresenta um modelo de descrição da demanda, baseado na econometria, capaz de inferir sobre as correlações entre o consumo e as variáveis econômicas/ climáticas, com qualidade e precisão. Com as melhores variáveis selecionadas para explicar o comportamento da indústria catarinense, foram construídos e aprimorados modelos de descrição para toda a classe industrial e também para o segmento têxtil.

O modelo econométrico da série histórica de consumo pode ser iniciado com uma equação de regressão múltipla (1). Em seguida, realiza-se diversos testes de hipóteses (Kachigan, 1991), a saber: testes de significância e contribuição marginal dos regressores, testes de multicolineariedade e testes de causalidade. Por fim, seu desempenho foi avaliado por: critério de informação de Akaike e Schwarz, coeficiente de determinação múltiplo normal e ajustado, e pelo erro médio percentual – MAPE.

$$Y_i = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \beta_3 X_{3i} + \dots + \beta_j X_{ji} + v_i \quad (1)$$

onde,

Y_i é o consumo efetivo de cada segmento ou regressando em cada período de tempo (i);

X_1 a X_j são as j-ésimas variáveis explicativas ou regressores de cada segmento;

β_0 é o coeficiente linear ou intercepto da regressão;

β_1 a β_j são os coeficientes parciais da regressão;

v_i é o termo de erro estocástico do período (i).

Para definição do modelo econométrico mais adequado foram consideradas seguintes diretrizes: (i) menores valores para os critérios de informação de Schwarz, de Akaike, e R^2 -Ajustado (ii) menores níveis de multicolineariedade; (iii) preferência por regressores com maior contribuição marginal ao modelo; (iv) escolha independente dos critérios puramente quantitativos como R^2 e MAPE.

A segunda etapa da metodologia estabelece o modelo predictor da variação do consumo de energia (V12m_CEE)¹ que consiste de uma rede neural padrão do tipo *multilayer perceptron* (MLP) com três camadas. Na Figura 2 estão representadas, genericamente, as variáveis possíveis para a camada de entrada: econômicas [1-7], climática [8] e a própria variação do consumo de energia elétrica já conhecida [9]. Todas as variáveis foram normalizadas segundo a norma euclidiana. Considerando, t o tempo presente ou mês atual, o modelo pode prever V12m_CEE para h meses à frente. Devem-se considerar defasagens (d), entre as variáveis exógenas e a variável prevista, quando elas estiverem presentes.




Figura 2. Modelo genérico de predictor neural do consumo - MLP

Apesar da não-linearidade intrínseca ao funcionamento do modelo neural utilizado, optou-se pela seleção de variáveis de entrada que apresentassem um bom desempenho na modelagem econométrica, privilegiando aquelas com melhores correlações lineares. Tal opção, além de se tratar de uma hipótese a ser testada, valoriza as relações mais comuns existentes no ambiente econômico que possam ser precursoras do comportamento futuro da demanda.

No treinamento da rede, com intuito de prover maior generalização nos resultados de previsão, optou-se pelo processo de regularização bayesiana (Mackay, 1992). Esse procedimento evita o sobre-treinamento da rede uma vez que ele penaliza a função de desempenho do algoritmo com o somatório do quadrado dos pesos dos neurônios. Foi utilizado um pacote próprio do *Matlab* que supervisiona o treinamento e a regularização da MLP, não necessitando a definição de parâmetros específicos, como número de neurônios na camada intermediária épocas, gradiente, critério de parada e etc.

¹ Como a série histórica de consumo ao longo dos anos é não-estacionária fez-se necessário utilizar a variação do consumo em relação ao mesmo período do ano anterior (V12m) como um artifício matemático que permite a obtenção de regressões não-espúrias e correlações lineares entre a demanda e variáveis explicativas mais confiáveis.

A Figura 3 apresenta o particionamento das séries históricas para o treinamento e simulação das redes neurais.




Figura 3. Particionamento das series históricas.

4 Resultados

4.1 Modelagem Desagregada – Segmento Têxtil

Para aplicação do modelo econométrico para o segmento têxtil foram calculadas mais de 1.100 correlações lineares entre o consumo de energia elétrica e as variáveis candidatas à regressoras. Esse procedimento possibilitou a obtenção de um mapa das relações mais significativas entre a economia, o clima e o comportamento do consumidor têxtil. Os principais regressores foram definidos para participar do modelo descritivo do segmento têxtil, conforme equação abaixo:

$$V12m_CEE_T = -6,63 + 10,21ITMI - 0,071Selic + 0,086Exp.Têxtil + 0,17ICMS.BR \quad (2)$$

onde,

ITMI é o indicador da intensidade térmica das temperaturas mínimas com atraso de 4 meses;
 Selic á taxa de juros do Banco Central do Brasil;
 Exp.Têxtil é o montante das exportações do setor;
 ICMS.BR é o montante da arrecadação de impostos por circulação de mercadorias e serviços no país.

Além disso, o conjunto de regressores pré-selecionados apresentou níveis de correlação linear acima do esperado, se for considerada a natureza e a complexidade do processo de descrição do consumo numa periodicidade mensal. Os atrasos mensais que maximizaram as correlações (AMMCs) foram condizentes com o comportamento esperado para os regressores. No geral, os resultados obtidos nesta etapa não contrariaram as expectativas econômicas.

Na etapa seguinte, de construção do modelo predictor, definiu-se a arquitetura da MLP bem como suas variáveis de entrada mais efetivas. Para realizar a seleção das variáveis de entrada da rede foram consideradas as variáveis com melhor desempenho de correlação parcial e probabilidades de causalidade com a demanda. Também foram identificadas as defasagens (meses) que potencializavam o efeito de cada da variável explicativa sobre a demanda. Considerando diferentes horizontes de tempo da previsão foram realizadas simulações para definição da melhor arquitetura da MLP para um e doze meses à frente. As Figuras 4 e 5 ilustram as duas arquiteturas utilizadas para prever o segmento têxtil.




Figura 4. Arquitetura da MLP para previsão de 1 mês.




Figura 5. Arquitetura da MLP para previsão de 12 meses.

A utilização de variáveis específicas do segmento têxtil, cujos níveis de correlacionamento com o comportamento da demanda foram demonstrados pela análise econométrica, permitiram a obtenção de resultados de previsão com pequenas margens de erro. A Figura 6 apresenta os resultados do desempenho da MLP_CT1 nos períodos de treinamento e de simulação, para previsão em um mês à frente. Nesse caso, prevê-se a variação do consumo do segmento em relação ao mesmo período do ano anterior (V12m).

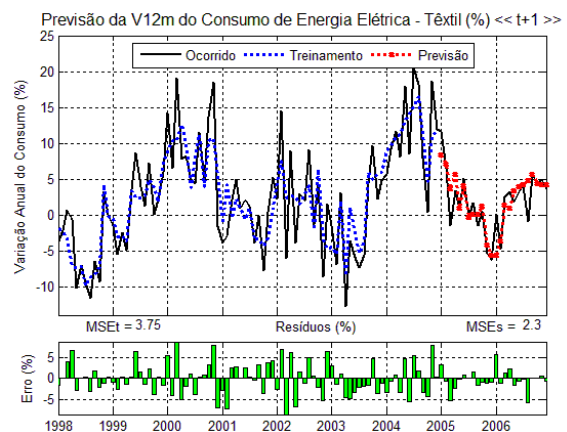


Figura 6. Treinamento e Simulação da MLP.

Nas Figuras 7 e 8 pode-se notar o nível de acurácia do modelo nos anos de simulação (2005 e 2006) tanto para a previsão de um quanto de doze meses à frente.

4.2 Modelagem Agregada – Toda Indústria de SC

Conforme a Figura 9, a variação do consumo de energia elétrica da indústria catarinense entre 1996 e 2006 mostrou-se relativamente mais comportado, variações de menor intensidade, que seus segmentos separadamente.




Figura 7. Previsão da Demanda Desagregada (T + 1 mês).




Figura 8. Previsão da Demanda para 12 meses à frente.




Figura 9. Consumo de Energia Elétrica Normalizado.

Como esperado, o modelo econométrico desenvolvido para estimar o comportamento da demanda de toda a classe industrial baseou-se em variáveis macroeconômicas e de diferentes setores da economia catarinense. Assim, foram identificadas as seguintes variáveis principais: índice de preços ao consumidor amplo (IPCA), índice nacional de preços ao consumidor (INPC), ICMS, salário mínimo real, produção de aço bruto, produção da indústria de transformação e produção de papel e celulose.

De modo semelhante à modelagem desagregada, foi implementado um modelo predictor neural para a demanda de toda indústria com uma MLP de 3 camadas e treinamento supervisionado pela regularização bayesiana. As variáveis de entrada respeitaram o conjunto de variáveis com melhor desempenho do modelo econométrico para toda a indústria.

Os resultados obtidos foram tão significativos quanto os resultados para previsão de segmento específico da indústria, porém obteve-se MAPEs um pouco acima do esperado. As Figuras 10 e 11 apresentam os resultados do modelo agregado para os anos de simulação (2005 e 2006) tanto para a previsão de um quanto de doze meses à frente.




Figura 10. Previsão da Demanda Agregada (T + 1 mês).

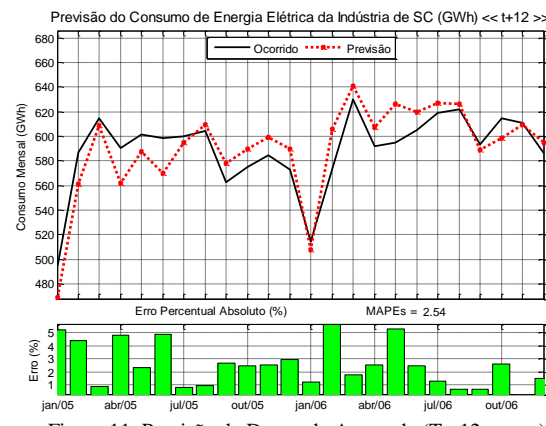


Figura 11. Previsão da Demanda Agregada (T + 12 meses).

4.2 Projeções Equivocadas de Previsão de Demanda

De forma a demonstrar os riscos inerentes à tomada de decisão sobre o comportamento da demanda de segmentos específicos da indústria, baseados erroneamente em previsões macro ou agregadas, realizou-se a seguinte simulação: i) estimação das demandas futuras do segmento têxtil baseado nas previsões extraídas do modelo predictor desenvolvido para toda a indústria de SC (resultados da saída da MLP, variações percentuais da demanda da indústria seriam utilizados para o cálculo das demandas futuras do segmento); ii) calcular o desempenho desta projeção em comparação com os valores reais de consumo na série histórica de 1996 a 2006.

Esse procedimento simula como a tomada de decisão sobre a demanda futura, por gestor de segmento específico da indústria, nesse caso, o segmento têxtil, baseado em projeções macro realizadas para todo setor industrial pode ser equivocada.

Pode-se observar na Figura 12 que este tipo de previsão se apresenta enviesada e a qualidade da precisão sobre o comportamento futuro da demanda foi

bastante comprometido ao longo da série histórica. Assim, ressalta-se a necessidade de realização de estudos específicos sobre classes econômicas com características comuns tanto na indústria, como comércio e serviços.




Figura 12. Projeção Agregada sobre Demanda Desagregada.

5 Conclusões

De modo geral os resultados obtidos mostraram-se significativos em comparação com trabalhos semelhantes que focam a previsão no horizonte de médio prazo incluindo variáveis explicativas externas.

Neste trabalho evidencia-se a importância da realização de estudos específicos sobre os fatores de impacto, sobre a decisão dos consumidores em fazer uso de forma mais ou menos intensa da energia elétrica em seus processos produtivos, seja pela ação da economia ou de fatores climáticos correlacionados.

Além disso, espera-se contribuir à discussão dos níveis de desagregação da demanda para efeito de modelagem do comportamento futuro.

Nota-se que não é simples a estimação da demanda mesmo para um modelo que agregue todo consumo do segmento industrial e que não se alcança resultados confiáveis e com baixos erros percentuais sem um elevado conhecimento dos consumidores e aprimoramento das redes neurais e da escolha de suas variáveis de entrada.

Referências Bibliográficas

- Ang, B. W.: 'Multilevel Decomposition of Industrial Energy Consumption', *Energy Economics*, 1995, 17, (1), pp. 39–51
- Azadeh, M. A., and Sohrabkhani, S.: 'Annual Electricity Consumption Forecasting with Neural Network in High Energy Consuming Industrial Sectors of Iran'. *Proc. IEEE Int. Conf. on Industrial Technology*, 2006, pp. 2166–2171
- Chang, H. S., and Chern W. S.: 'Specification, Estimation, and Forecasts of Industrial Demand and Price Elasticity'. *Energy Systems and Policy*, 1981, 5, pp. 219–242.

Kachigan, S.K. *Multivariate Statistical Analysis*, Radius Press, New York, 1991.

Kamerschen, D. R., and Porter, D. V.: 'The Demand for Residential, Industrial and Total Electricity, 1973-1998', *Energy Economics*, 2004, 26, (1), pp. 87–100

Mackay, D. J. C.: 'A Practical Bayesian Framework for Backpropagation networks', *Neural Computation*, 1992, 4, (3), pp. 448–472

Mc Cafferty, P., and Beattie, W. C.: 'The Influence of Disaggregation Applied to Time Series Modelling of Electricity Demand in The Industrial Sector'. *Proc. IEEE Int. Conf. on EC3-Energy, Computer, Communication and Control Systems*, New Delhi, 1991, pp. 213–216

Tolmasquim, M. T. (2011). *Novo Modelo do Setor Elétrico Brasileiro*. Synergia Editora. Rio de Janeiro.

Úbeda, E. F. S., and Berzosa, A.: 'Modeling and forecasting industrial and-use natural gas consumption', *Energy Economics*, 2007, 29, (4), pp. 710–742

Zotteri, G., Kalchschmidt, M., Caniato, F.: 'The Impact of Aggregation Level on Forecasting Performance', *International Journal of Production Economics*, 2005, 93–94, pp. 479–491