



**XXII SNTPEE
SEMINÁRIO NACIONAL
DE PRODUÇÃO E
TRANSMISSÃO DE
ENERGIA ELÉTRICA**

BR/GPL/01
13 a 16 de Outubro de 2013
Brasília - DF

GRUPO - VII

GRUPO DE ESTUDO DE PLANEJAMENTO DE SISTEMAS ELÉTRICOS – GPL

METODOLOGIA HÍBRIDA PARA PREVISÃO DE LONGO TERMO APLICADA A CLASSES E FAIXAS DE CONSUMO DE ENERGIA

Daniel H. M. Detzel(*)
LACTEC

Lúcio de Medeiros
LACTEC

Ana Paula Oening
LACTEC

Débora Cintia Marcilio
LACTEC

Alexandre R. Aoki
LACTEC

Eloy P. Rocha Jr.
COPEL

Jefferson M. Schiochet
COPEL

Rafael A. Guimarães
COPEL

RESUMO

O objetivo do presente trabalho foi apresentar uma metodologia de previsão de longo termo para classes e faixas de consumo de energia. A grande dificuldade em se trabalhar com horizontes longos está em manter a coerência nas projeções, considerando que o comportamento das séries é altamente variável. Propôs-se, portanto, uma metodologia híbrida que utiliza modelos clássicos acoplados com previsão logística. O estudo de caso envolveu oito classes e 94 faixas de consumo da Copel, cujas previsões servem de subsídios ao setor financeiro da empresa e para composição do SIMPLES anual.

PALAVRAS-CHAVE

Previsão de carga, longo termo, modelos ARIMA multiplicativos, amortecimento exponencial, regressão logística

1.0 - INTRODUÇÃO

A previsão de carga em sistemas elétricos é um desafio matemático na área de previsão de séries temporais, pois na maioria das vezes os dados históricos disponíveis apresentam acentuada sazonalidade e também elevado nível de incerteza devido aos procedimentos de coleta dos dados. As mais variadas metodologias para previsão de carga vêm sendo desenvolvidas e testadas nas últimas décadas em todo o mundo (1)-(3). Não existe, entretanto, um único modelo para tratar este problema. As aplicações usam tanto métodos lineares, tais como Box & Jenkins (4)-(6) e amortecimento exponencial (7)(8), quanto métodos não lineares, e.g. redes neurais (9)(10) e fuzzy(11)(12). Modelos variantes das formulações clássicas têm também obtido bons resultados quando usados para previsão de carga (13)-(17).

No Brasil, modelos de previsão de carga têm sido especialmente desenvolvidos para atender aos requisitos de agentes do setor elétrico, nos diversos horizontes de previsão. Entre esses requisitos estão previsões de carga para estudos de ampliações e esforços, planejamento da operação elétrica, programação diária da operação eletroenergética, entre outros. Do ponto de vista das empresas distribuidoras de energia, a previsão de carga é essencial na sua operação diária, no planejamento de sua infraestrutura e para compra de energia.

De uma maneira geral, as previsões de carga são classificadas em três tipos, de acordo com os horizontes de interesse e a frequência das observações: curto, médio e longo prazo. Estes prazos podem contemplar desde horizontes de alguns minutos no curto prazo, até vários anos no longo prazo. O presente trabalho tem foco em previsões de longo prazo e, especificamente, horizonte mensal para até dez anos à frente. Está inserido no contexto

(*) Centro Politécnico da UFPR-Prédio do LAC – DVSE – CEP 81.531-980 Curitiba, PR, – Brasil
Tel: (+55 41) 3361-6178 – Email: daniel@lactec.org.br

do projeto de P&D “Sistema de Previsão Integrada de Mercado de Energia Elétrica – SPIM” financiado pela Copel Distribuição e executado pelo Instituto de Tecnologia para o Desenvolvimento (LACTEC), cujo objetivo é o desenvolvimento de um sistema integrado de previsão de carga e demanda, com interface amigável e mecanismos para acompanhamento periódico das previsões e atualização dos modelos. As projeções de longo prazo são necessárias para os estudos de planejamento financeiro da Copel, bem como nos estudos do sistema SIMPLES, da Empresa de Pesquisa Energética (18).

O grande problema de previsões que lidam com prazos tão extensos é a aplicação de um modelo robusto o suficiente que gere previsões coerentes para todo o horizonte. Além disso, somado à volatilidade característica de séries de consumo e demanda de energia, o histórico disponível para estimação dos modelos é, muitas vezes, pequeno e apresenta problemas com consistência de seus dados. Como consequência, a aplicação direta de modelos de previsão frequentemente resulta em valores que tendem ao infinito ou a zero antes do término do horizonte. E isso se torna especialmente verdade quando se analisam as séries das diversas faixas¹ que compõe uma classe; mesmo que esta classe apresente tendência de crescimento ao longo dos anos, existem faixas com tendência contrária, o que torna o ajuste dos modelos uma tarefa laboriosa e com grande dependência do analista.

Uma solução comumente empregada é a previsão anual e desagregação em valores mensais com uso de índices sazonais médios. Apesar de resultar em previsões coesas, sua confiabilidade pode ser questionável devido à forma com que os mencionados índices são inseridos no modelo, dado que não se pode afirmar que o comportamento do consumo de energia tenha sazonalidade bem definida.

Na tentativa de contornar os problemas citados, propôs-se uma metodologia de previsão híbrida para aplicação em toda hierarquia, na qual se consideram a variabilidade e a tendência das séries separadamente. Em um primeiro momento, ajustaram-se modelos clássicos de Box & Jenkins e de amortecimento exponencial aos totais de cada classe. Na sequência, foram aplicados modelos logísticos individualmente às proporções de participação de cada faixa em sua respectiva classe, na intenção de reproduzir tendências de longo termo sem que as previsões tendam ao infinito, no caso de crescimento do consumo, ou à zero, no caso inverso.

O restante do artigo está dividido da seguinte forma: a seção 2 descreve a metodologia de previsão, incluindo os métodos clássicos, a regressão logística e a forma de acoplamento das projeções; a seção 3 descreve o estudo de caso, caracterizando as séries utilizadas; a seção 4 exibe os resultados e principais comentários; por fim, a seção 5 conclui o trabalho.

2.0 - METODOLOGIA DE PREVISÃO

2.1 Modelos Box & Jenkins

Os modelos Box & Jenkins, muito conhecidos pela sigla ARIMA (autorregressivos integrados de médias móveis), geram previsões através da informação contida na própria série cronológica. George Box e Gwilym Jenkins (4) tornaram populares os modelos ARIMA no início dos anos 70, sendo os seus nomes usados, frequentemente, como sinônimos dos modelos ARIMA gerais, aplicados à análise de séries temporais e previsões. São modelos matemáticos que visam captar o comportamento da correlação serial ou autocorrelação entre os valores da série temporal e, com base nesse comportamento, realizar previsões futuras. Se essa estrutura de correlação for bem modelada, fornecerá boas previsões.

Essa classe de modelos possui também extensão para considerar a sazonalidade da série em questão, recebendo a denominação SARIMA, ou ARIMA multiplicativo. O modelo geral ARIMA(p,d,q)(P,D,Q) multiplicativo pode ser definido matematicamente pela eq.1:

$$\phi(B^s) \cdot \varphi(B) \cdot \nabla_s^D \cdot \nabla^d z_t = \theta(B^s) \cdot \theta(B) \cdot a_t \quad \text{eq.1}$$

onde:

- B operador de atraso da série, tal que $B^k z_t = z_{t-k}$ e $B^k a_t = a_{t-k}$, sendo k a defasagem (*lag*) considerada;
- $\phi(B^s)$ operador sazonal autorregressivo (AR), tal que $\phi(B^s) = (1 - \phi_1 B^s - \dots - \phi_p B^{ps})$;
- $\varphi(B)$ operador não sazonal autorregressivo (AR), tal que $\varphi(B) = (1 - \phi_1 B - \dots - \phi_p B^p)$;
- ∇_s^D operador diferença sazonal de ordem D , tal que $\nabla_s^D = (1 - B^s)^D$;
- ∇^d operador diferença não sazonal de ordem d , tal que $\nabla^d = (1 - B)^d$;

¹Neste artigo denominam-se *faixas* a totalização das séries dos grupos e subgrupos de tensão que compõem cada classe de consumo.

- $\theta(B^s)$ operador sazonal de médias móveis (MA), tal que $\theta(B^s) = (1 - \theta B^s - \dots - \theta_q B^{qs})$;
 $\theta(B)$ operador não sazonal de médias móveis (MA), tal que $\theta(B) = (1 - \theta_1 B - \dots - \theta_q B^q)$;
 z_t série histórica considerada, indexada ao período de tempo t ;
 a_t série de ruídos brancos, independentes e normalmente distribuídos com média zero e variância unitária, indexada ao período de tempo t ;
 s período sazonal considerado.

A formulação apresentada na eq.1 é a mais completa possível, sendo que alguns termos podem ser negligenciados de acordo com a característica da série. Ademais, muito raramente se encontra um modelo ARIMA com ordens superiores a dois, ou seja $p_{\max} = P_{\max} = q_{\max} = Q_{\max} = 2$, respeitando-se o princípio da parcimônia. Cabe ao analista, portanto, identificar a necessidade de cada um dos parâmetros no modelo e estimar os seus valores, usando técnicas descritas em maiores detalhes na referência (4). No presente trabalho, utilizaram-se modelos de ordens máximas ARIMA(2,1,2)(2,1,2) e período sazonal de 12 meses.

2.2 Modelos de amortecimento exponencial

As três versões mais usadas dos métodos de amortecimento exponencial – simples (19), linear de Holt(20) e com tendência e sazonalidade de Holt-Winters (21), embora de simples implementação, são bastante robustas. Neste artigo, considerando que as séries de carga possuem tendência e sazonalidade, utiliza-se o método de amortecimento exponencial de Holt-Winters. Este método está baseado em três equações de amortecimento, (nível, tendência e sazonalidade), sendo dois modelos de sazonalidade: multiplicativo ou aditivo.

As equações básicas do método Holt-Winters multiplicativo são os seguintes:

$$\begin{aligned} L_t &= \alpha(z_t/S_{t-s}) + (1 - \alpha)(L_{t-1} + b_{t-1}) \\ b_t &= \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1} \\ S_t &= \gamma(z_t/L_t) + (1 - \gamma)S_{t-s} \\ z_{t+m} &= (L_t + b_t m)S_{t-s+m} \end{aligned} \quad \text{eq.2}$$

Por outro lado, as equações básicas do método Holt-Winters aditivo são dadas por:

$$\begin{aligned} L_t &= \alpha(z_t - S_{t-s}) + (1 - \alpha)(L_{t-1} + b_{t-1}) \\ b_t &= \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1} \\ S_t &= \gamma(z_t - L_t) + (1 - \gamma)S_{t-s} \\ z_{t+m} &= (L_t + b_t m)S_{t-s+m} \end{aligned} \quad \text{eq.3}$$

onde:

- L_t nível da série;
 b_t tendência da série;
 S_t componente sazonal da série;
 z_{t+m} previsão m períodos à frente;
 α, β, γ pesos com valores limitados a $[0,1]$.

Makridakis *et al.*(22) descrevem algumas questões sobre a implementação dos métodos de amortecimento exponencial, tais como a inicialização das variáveis na seq.2 e eq.3, estimação, otimização dos parâmetros e intervalos de confiança.

2.3 Modelos de regressão logística

As regressões são empregadas quando se deseja prever uma variável aleatória Z tendo disponível outra variável aleatória, dita explicativa, X . Constrói-se um modelo de regressão estabelecendo-se uma relação entre as duas variáveis, do tipo $Z = f(X)$. A função f pode assumir formulações diversas, dependendo do tipo de relação observada entre Z e X ; por exemplo, se $f(X) = aX + b$, tem-se definida uma relação linear entre as variáveis.

No entanto, uma relação linear nem sempre se ajusta bem aos propósitos desejados, sendo necessária a utilização de funções não lineares. No caso do presente estudo, por exemplo, previsões sobre séries que apresentam tendências de crescimento (ou decrescimento) acabam por tender ao infinito (ou a zero) no longo prazo. Para solucionar essa questão, propôs-se a utilização de uma função logística, definida através da eq.4(23):

$$\begin{cases} \zeta = \frac{a}{1 + be^{-cx}}; a > 0 \text{ e s\u00e9rie crescente} \\ \zeta = \frac{a}{1 - be^{-cx}}; a > 0 \text{ e s\u00e9rie decrescente} \end{cases} \quad \text{eq.4}$$

Onde a \u00e9 denominado n\u00edvel de satura\u00e7\u00e3o, respons\u00e1vel por fornecer o limite assint\u00f3tico superior ou inferior para previs\u00f5es em s\u00e9ries crescentes ou decrescentes, respectivamente. \u00c9 este par\u00e2metro que impede que as previs\u00f5es subam a valores exorbitantes ou zerem antes do final do horizonte de previs\u00e3o. Os demais par\u00e2metros s\u00e3o estimados atrav\u00e9s das eq.5:

$$\begin{cases} \tilde{\zeta} = \log\left(\frac{a - \zeta}{\zeta}\right), \text{ s\u00e9rie crescente} \\ \tilde{\zeta} = \log\left(\frac{\zeta - a}{\zeta}\right), \text{ s\u00e9rie decrescente} \end{cases} \quad \text{eq.5}$$

$$\begin{aligned} \tilde{\zeta} &= \tilde{c}x + \tilde{b} \\ \tilde{b} &= \log(b) \\ \tilde{c} &= -c \end{aligned}$$

As diferen\u00e7as nas formula\u00e7\u00f5es que envolvem o n\u00edvel de satura\u00e7\u00e3o s\u00e3o necess\u00e1rias para impedir que valores negativos sejam submetidos \u00e0 transforma\u00e7\u00e3o logar\u00edtmica.

2.4 Acoplamento das previs\u00f5es

De um modo geral, pode-se dizer que os modelos cl\u00e1ssicos de Box & Jenkins e de amortecimento exponencial ficam respons\u00e1veis pela variabilidade das s\u00e9ries, enquanto que o modelo log\u00edstico representa a tend\u00eancia individual de cada faixa. A combina\u00e7\u00e3o desses fatores resulta na previs\u00e3o individual das faixas de consumo, como ilustra a Figura 1.

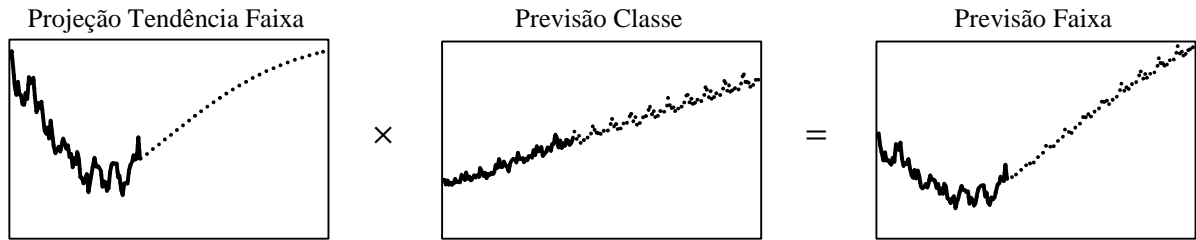


Figura 1 – Esquema de previs\u00e3o para faixas de consumo

Matematicamente, as previs\u00f5es das faixas de consumo s\u00e3o obtidas atrav\u00e9s da eq.6:

$$\hat{z}_t^F = \zeta_t^F \hat{z}_t \quad \text{eq.6}$$

onde:

- \hat{z}_t^F previs\u00e3o do consumo na faixa F , no tempo t ;
- ζ_t^F previs\u00e3o da propor\u00e7\u00e3o de participa\u00e7\u00e3o da faixa F na classe, no tempo t , obtida pelo modelo log\u00edstico;
- \hat{z}_t previs\u00e3o do total da classe, no tempo t , obtida pelos modelos cl\u00e1ssicos.

A principal motiva\u00e7\u00e3o para o emprego do modelo h\u00edbrido de previs\u00e3o se deve \u00e0 necessidade de que a somat\u00f3ria das previs\u00f5es das faixas de consumo de uma classe seja igual \u00e0 previs\u00e3o do total desta classe em todo o horizonte considerado. Naturalmente, empregar m\u00e9todos cl\u00e1ssicos individuais a cada faixa (modelo *bottom-up*) torna esta tarefa extremamente laboriosa para o analista. Al\u00e9m disso, a grande volatilidade das faixas de consumo faz com que a somat\u00f3ria de suas previs\u00f5es individuais quase nunca coincida com a previs\u00e3o total da classe. Alternativamente, a t\u00e9cnica proposta (modelo *top-down*) consegue garantir a coer\u00eancia entre as previs\u00f5es de faixas e classes.

3.0 - ESTUDO DE CASO

Os dados utilizados para aplicação da metodologia se referem a séries de consumo médio (MWh) de energia da Copel, em escala mensal, variando de janeiro de 2004 a dezembro de 2011. Estas séries são compostas por registros de oito classes de consumo, cada qual contemplando diferentes faixas, como mostra o esquema geral da Figura 2.

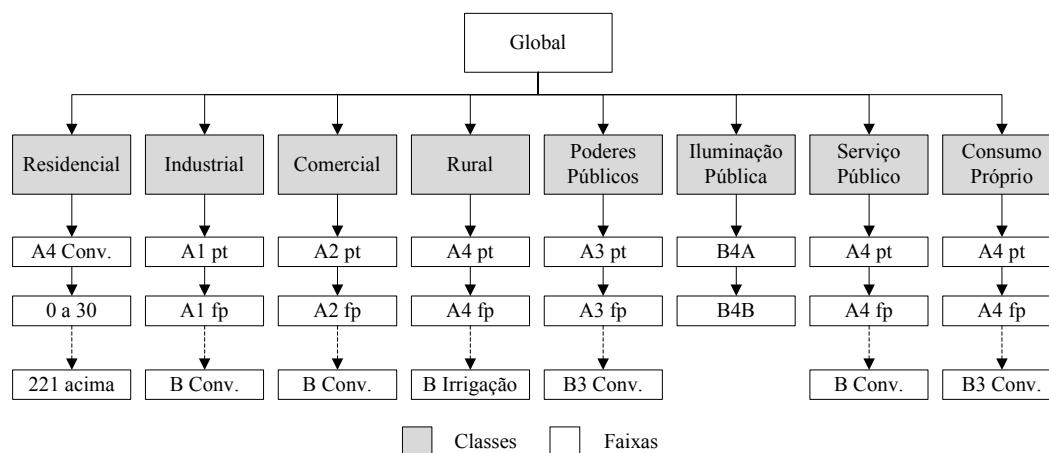


Figura 2 – Composição das séries de consumo utilizadas

Os modelos clássicos de Box & Jenkins e amortecimento exponencial foram aplicados às classes de consumo, utilizando como período de ajuste dados de janeiro de 2004 a dezembro de 2010. O período de janeiro de 2011 a dezembro de 2011 foi reservado para análise dos erros de previsão, avaliados segundo o erro absoluto médio percentual (MAPE).

Como dito na introdução deste trabalho, as previsões de classes e faixas possuem dois objetivos: subsidiar o departamento financeiro da empresa para seu planejamento de longo prazo e fornecer as projeções necessárias para composição do SIMPLES(18) anual. No primeiro caso, trabalha-se com horizonte de previsão de 120 meses à frente, enquanto que no segundo são requeridas previsões com, no máximo, 60 meses à frente. A fim de unificar os dois objetivos, optou-se pelo horizonte maior de 120 meses para todas as previsões.

Dada a volatilidade presente nas séries do estudo, utilizaram-se somente os dois últimos anos do histórico para estimar os parâmetros da regressão logística. Dessa maneira deu-se prioridade ao perfil de consumo mais recente para realizar as previsões das faixas. Em cada caso, fixou-se o nível de saturação aem duas vezes o máximo (ou mínimo) observado nestes dois últimos anos.

Previamente à aplicação dos modelos para todas as séries, fez-se uma investigação sobre a condição de cada uma na qual se identificou diversos casos de séries vazias e/ou incompletas. Algumas séries apresentam valores isolados zerados, sendo necessário seu preenchimento para tornar possível a transformação logarítmica. Elaborou-se um algoritmo simples para detecção e eliminação dos zeros das séries, baseado em interpolações. Cabe mencionar que as séries foram separadas mês a mês para aplicação das interpolações, garantindo que os valores estimados seguissem a tendência de crescimento (ou decrescimento) anual.

4.0 - RESULTADOS E DISCUSSÕES

4.1 Previsões dos totais das classes

Os primeiros resultados se referem aos totais de cada classe de consumo. Como dito anteriormente, as projeções foram realizadas para 120 meses à frente (jan./2011 a dez./2020), separando-se o primeiro ano (jan./11 a dez./11) para avaliação das previsões. A Tabela 1 exhibe os modelos utilizados e resultados resumidos, em termos dos MAPEs obtidos.

Nota-se que o desempenho dos dois modelos foi semelhante, com exceção da classe Poderes Públicos, na qual observou-se maior discrepância. Com relação à qualidade das previsões, resultados diversos foram obtidos. Tradicionalmente, considera-se um modelo bom quando fornece previsões com MAPEs máximos variando de 3% a 5%; nota-se, todavia, que para classes Industrial e Consumo Próprio os erros superaram essa margem. No caso da

classe Industrial, a série é fortemente influenciada pela constante migração de grandes clientes para o mercado livre (e vice-versa), o que a torna de difícil previsão. Da mesma forma, essa movimentação de clientes tem sido observada recentemente na classe Comercial, fato que explica os erros de maior magnitude também nesta classe. Para a classe de Consumo Próprio, os erros elevados se devem à extrema volatilidade da série provocada por uma alteração no sistema interno de medição da Copel, ocorrida durante o ano de 2011.

Tabela 1 – MAPEs obtidos no ajuste dos modelos clássicos aos totais das classes de consumo

Classes	Box & Jenkins		Amortecimento Exponencial	
	Modelo	MAPE	Modelo	MAPE
Residencial	(0,1,2)(0,1,1)	1,40%	Linear Multiplicativo	1,34%
Industrial	(0,1,1)(0,1,0)	6,09%	Linear Aditivo	5,41%
Comercial	(0,1,1)(0,1,1)	3,66%	Linear Multiplicativo	2,59%
Rural	(1,1,1)(0,1,1)	2,44%	Linear Multiplicativo	2,69%
Poderes Públicos	(0,1,1)(0,1,1)	8,25%	Linear Aditivo	3,72%
Iluminação Pública	(0,1,1)(2,0,0)	0,43%	Linear Multiplicativo	0,74%
Serviço Público	(1,1,1)(0,1,1)	1,48%	Amortecido Multiplicativo	1,35%
Consumo Próprio	(1,1,0)(1,0,1)	7,63%	Multiplicativo	7,98%

4.2 Previsões das faixas de consumo

As previsões logísticas de cada classe, em conjunto com os 120 meses de carga prevista pelos modelos clássicos, foram acoplados para obter as previsões das faixas de consumo. Evidentemente, como se trata de um método de desagregação das previsões das classes, os erros de previsão são os mesmos apresentados anteriormente na Tabela 1. Somando-se as previsões das faixas de todas as classes do estudo, foram determinadas previsões para 94 séries de consumo.

A título de ilustração da metodologia proposta, a Figura 3 exibe a comparação de previsões elaboradas para a série Baixa Renda 1, da classe Residencial. Para a previsão tradicional, utilizou-se o método de Box & Jenkins, por apresentar menor erro nesta classe (ver Tabela 1). Da mesma forma, a previsão híbrida foi feita com Box & Jenkins para a classe e logística para as proporções de participação. Em primeiro lugar, nota-se que a série é de difícil previsão por não ter sazonalidade e padrão de variabilidade bem definidos, embora apresente forte tendência de decaimento no consumo. Por esse motivo, a previsão tradicional atingiu valores nulos em alguns meses a partir de novembro de 2018 (mês 85), tornando os resultados não confiáveis. Já a previsão híbrida conseguiu suavizar essa tendência, mantendo valores factíveis de consumo mesmo após os 120 meses de horizonte.

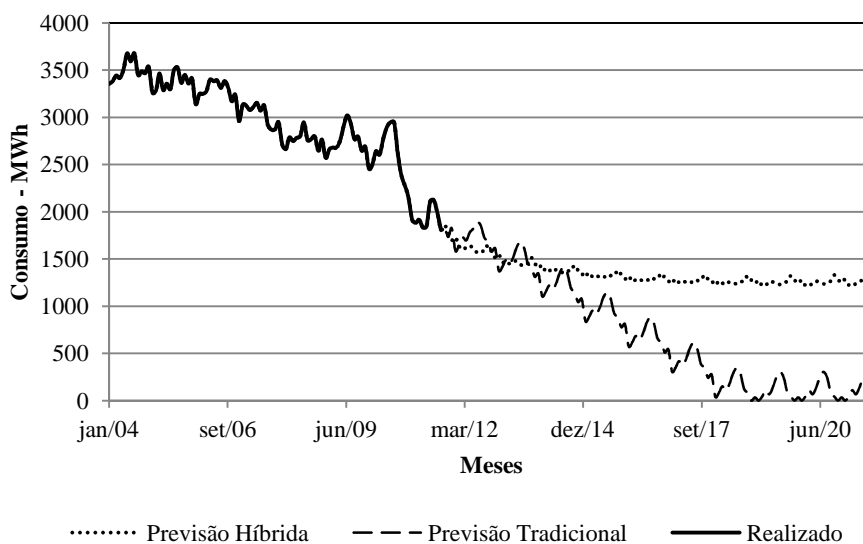


Figura 3 – Comparação de previsão tradicional (Box & Jenkins) com a previsão híbrida proposta para série Residencial – Baixa Renda 1

Na sequência, dada a quantidade de previsões efetuadas, optou-se por exibir somente algumas previsões de faixas cujos resultados foram mais interessantes no contexto da metodologia proposta. A Figura 4 exibe quatro casos de faixas pertencentes às classes Residencial, Comercial, Poderes Públicos e Rural.

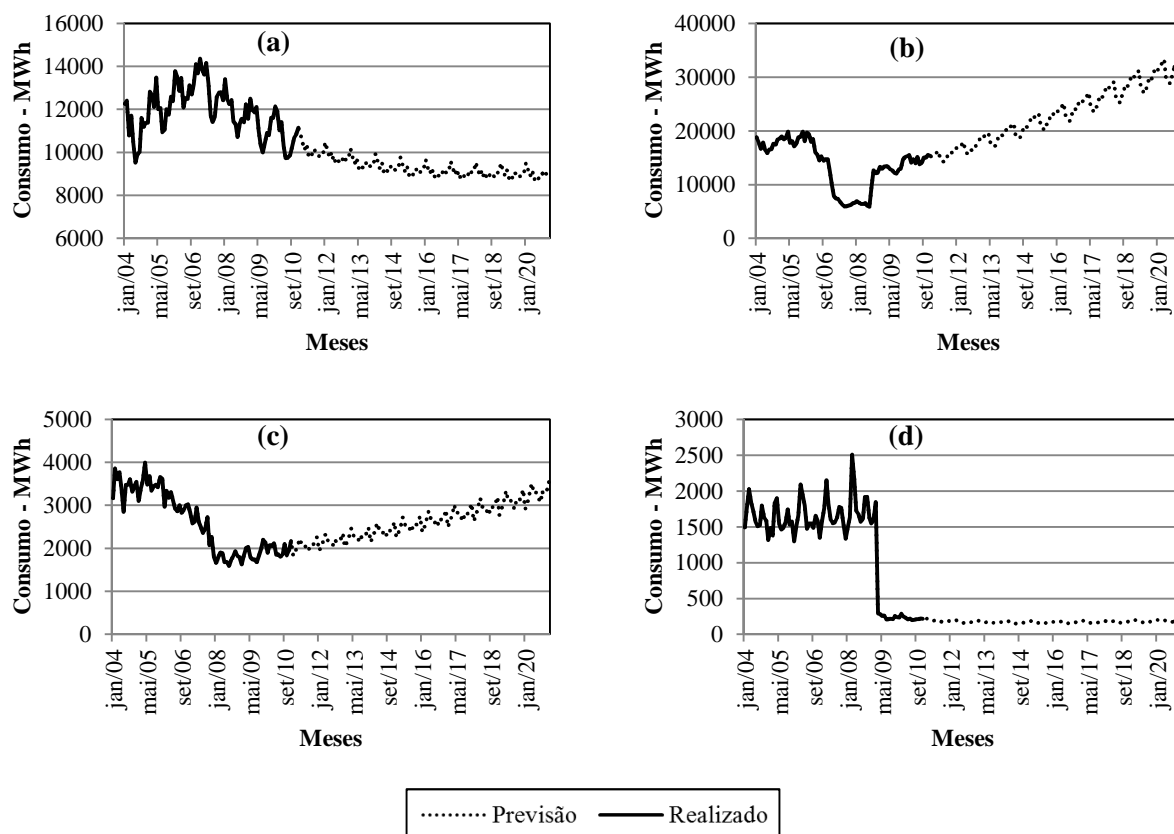


Figura 4 – Previsões para as faixas: (a) Residencial – Baixa Renda 3 (b) Comercial – A4 horo-sazonal fora de ponta Azul (c) Poderes Públicos – A4 horo-sazonal fora de ponta Azul (d) Rural – A4 Convencional Cooperativas

Estas séries foram selecionadas para mostrar a conveniência de se utilizar somente o período mais recente da série para estimar as previsões das proporções de participação. A volatilidade inerente de séries de consumo de energia é uma característica conhecida e foi observada na grande maioria das faixas consideradas no estudo. Entretanto, percebe-se que as previsões conseguiram respeitar a tendência atual de cada série e fornecer projeções coerentes. Para as séries Baixa Renda 3, classe Residencial (Figura 4-(a)) e A4 horo-sazonal fora de ponta Azul, classe Poderes Públicos (Figura 4-(c)), por exemplo, observa-se uma inversão na tendência geral no meio do histórico. A série A4 horo-sazonal fora de ponta Azul, classe Comercial (Figura 4-(b)), apresenta um vale no consumo também na porção intermediário do histórico. Finalmente, a série A4 Convencional Cooperativas, classe Rural (Figura 4-(d)) sofre um degrau que altera completamente o perfil do consumo. Ainda assim, em todos os casos o modelo de previsão foi capaz de fornecer resultados satisfatórios.

5.0 - CONCLUSÃO

O objetivo do presente trabalho foi apresentar uma metodologia de previsão de longo prazo para classes e faixas de consumo de energia. A grande dificuldade em se trabalhar com horizontes longos está em manter a coerência nas projeções, considerando que o comportamento das séries é altamente variável. Propôs-se, portanto, uma metodologia híbrida que utiliza modelos clássicos de Box & Jenkins e amortecimento exponencial acoplados com uma previsão logística. O estudo de caso envolveu oito classes e 94 faixas de consumo da Copel, cujas previsões servem de subsídios ao setor financeiro da empresa e para composição do SIMPLES anual.

Uma das vantagens de se utilizar a técnica proposta está na redução dos esforços necessários ao ajuste de modelos tradicionais a todas as classes e faixas. As formulações de dois desses modelos foram mostradas de forma resumida nesse trabalho, porém sabe-se que seus ajustes não são tarefas triviais. Assim, o analista pode concentrar esforços para a estimação de apenas oito modelos, referentes às classes de consumo; as previsões das faixas que compõem cada classe são obtidas prontamente via proporção de participação através de regressão logística, cuja estimação é significativamente mais simples.

Outro aspecto positivo foi a utilização do histórico recente das faixas para projeção via função logística. Isso permitiu a obtenção de previsões coerentes com o perfil atual de consumo de cada faixa. Além disso, o uso desta

função logística impede que as previsões, no longo prazo, subam a valores extremos em casos de séries com tendência crescente, ou desçam a zero caso contrário.

6.0 - REFERÊNCIAS BIBLIOGRÁFICAS

- (1) BUNN, D. W.; FARMER, E. D. Review of Short-term Forecasting Methods in the Electric Power Industry, New York: Wiley, pp. 13-30, 1985.
- (2) FEINBERG, E.A.; GENETHLIOU, D. Load forecasting. In: CHOW, J.H.; WU, F.F.; MOMOH, J.J. (Eds.). Applied Mathematics for Restructured Electric Power Systems: Optimization, Control and Computational Intelligence, Power Electronics and Power Systems. Springer, p. 269–285, 2005.
- (3) CAMPBELL, P. R. J.; ADAMSON, K. Methodologies for Load Forecasting. 3rd International IEEE Conference on Intelligent Systems, p.800 – 806, 2006.
- (4) BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C. Time Series Analysis: Forecasting and Control. New Jersey: Prentice Hall, 1994.
- (5) PARETKAR, P. S.; MILI, L.; CENTENO, V.; KAIYAN, J.; MILLER, C. Short-term forecasting of power flows over major transmission interties: Using Box and Jenkins ARIMA methodology. Power and Energy Society General Meeting, IEEE, p.1 – 8, 2010.
- (6) CHO, M.Y.; HWANG, J. -C; CHEN, C-S. Customer short term load forecasting by using ARIMA transfer function model. Proceedings of the International Conference on Energy Management and Power Delivery, vol.1, p.317,322, 1995.
- (7) TAYLOR, J.W. Short-term load forecasting with exponentially weighted methods. IEEE Transactions on Power Systems, vol. 27, n. 1, p. 1-8, 2012.
- (8) GARDNER JR, E. S. Exponential smoothing: The state of the art – Part II, International Journal of Forecasting, vol. 22, n. 4, p. 637-666, 2006.
- (9) PARK, D. C.; EL-SHARKAWI, M. A.; MARKS II, R. J.; ATLAS, L. E.; DAMBORG, M. J. Electric load forecasting using an artificial neural network. IEEE Transactions on Power Systems, vol. 6, p. 442–449, 1991.
- (10) ALFUHAID, A.S.; EL-SAYED, M.A.; MAHMOUD, M. S. Cascaded artificial neural networks for short-term load forecasting. IEEE Transactions on Power Systems, vol. 12, n.4, p.1524 – 1529, 1997.
- (11) SACHDEVA, S.; VERMA, C.M. Load Forecasting using Fuzzy Methods. Power System Technology and IEEE Power India Conference, p. 12 – 15, 2008.
- (12) HINOJOSA, V. H.; HOESE, A. Short-Term Load Forecasting Using Fuzzy Inductive Reasoning and Evolutionary Algorithms", IEEE Transactions on Power Systems, vol. 25, n. 1, p.565,574, 2010.
- (13) TAYLOR, J.W. Short-term electricity demand forecasting using double seasonal exponential smoothing. Journal of the Operational Research Society, vol. 54, p. 799–805, 2003.
- (14) LEE, Y.-S, TONG, L.-I. Forecasting nonlinear time series of energy consumption using a hybrid dynamic model. Applied Energy vol. 94, p. 251–256, 2012.
- (15) PANDEY, A. S.; SINGH, D.; SINHA, S.K. Intelligent hybrid wavelet models for short-term load forecasting. IEEE Transactions on Power Systems, vol. 25, n. 3, p. 1266 – 1273, 2010.
- (16) YUN, Z.; QUAN, Z; CAIXIN, S.; SHAOLAN, L.; YUMING, L.; YANG, S. RBF Neural Network and ANFIS-Based Short-Term Load Forecasting Approach in Real-Time Price Environment, IEEE Transactions on Power Systems, vol. 23, n. 3, p.853 – 858, 2008.
- (17) BAKIRTZIS, A.G.; THEOCHARIS, J.B.; KIARTZIS, S. J.; SATSIOS, K.J. Short term load forecasting using fuzzy neural networks. IEEE Transactions on Power Systems, vol. 10, n. 3, p.1518 – 1524, 1995.
- (18) EMPRESA DE PESQUISAS ENERGÉTICAS. SIMPLES – Manual do usuário ciclo 2012, disponível em: http://www.epe.gov.br/downloads/SIMPLES2012_Manual_do_Usuuario.pdf, Acesso em: 28/03/2013.
- (19) BROWN, R. G. Smoothing, forecasting and prediction of discrete time series. Englewood Cliffs, NJ7 Prentice-Hall, 1963.
- (20) HOLT, C.C. Forecasting seasonals and trends by exponentially weighted moving averages. International Journal of Forecasting, vol. 20, p. 5–10, 2004.
- (21) WINTERS, P. R. Forecasting sales by exponentially weighted moving averages. Management Science, vol. 6, p. 324– 342, 1960.
- (22) MAKRIDAKIS, S., WHEELWRIGHT, S.C. & HYNDMAN, R.J. Forecasting: Methods and applications. New York: John Wiley & Sons, 1998.
- (23) SOBRAL, A. P. B.; MEDEIROS, L. de; PEREIRA, F. A.; SOUZA, R. C. Modelo de previsão de médio prazo da carga própria horária. In.: Anais do XVI Seminário Nacional de Previsão e Transmissão de Energia Elétrica (SNPTEE), Campinas: Cigrè, 2001.

7.0 - DADOS BIOGRÁFICOS



Daniel H. M. Detzel nasceu em Curitiba, Paraná, em 1983. Graduiu-se em Engenharia Civil na Universidade Federal do Paraná (2005) e é mestre em Engenharia de Recursos Hídricos e Ambiental pela mesma Instituição (2009), sendo contemplado com o prêmio Heinz DieterFill pelo reduzido tempo de titulação. Trabalha como pesquisador no LACTEC desde abril de 2010 principalmente nas áreas de hidrologia estocástica e previsão de carga. Atualmente é doutorando em Engenharia de Recursos Hídricos na Universidade Federal do Paraná.



Possui graduação em Engenharia Elétrica pela Universidade Federal de Juiz de Fora (1995), Mestrado em Engenharia Elétrica em Teoria de Controle e Estatística pela Pontifícia Universidade Católica do Rio de Janeiro (1999) e Doutorado em Engenharia Elétrica em Sistemas de Energia Elétrica pela Pontifícia Universidade Católica do Rio de Janeiro (2003). Atualmente é Pesquisador Sênior do Instituto de Tecnologia para o Desenvolvimento - LACTEC. Tem experiência na área de Engenharia de Produção, com ênfase em Séries Temporais, atuando principalmente nos seguintes temas: previsão de preço spot de energia, mercado de eletricidade, eficiência energética e otimização.

Ana Paula Oening é bacharel em Matemática Industrial pela Universidade Federal do Paraná (2003), mestre em Métodos Numéricos com ênfase em otimização pelo Programa de Métodos Numéricos em Engenharia – PPGMNE/UFPR (2006) e atualmente faz doutorado em Métodos Numéricos com ênfase em previsão de carga na mesma instituição. É Pesquisadora Plena na Divisão de Sistemas Elétricos do LACTEC, atuando nas áreas de otimização, previsão de séries temporais, planejamento da operação e expansão, comercialização de energia e leilões.

Débora Cinta Marcilio possui graduação em Matemática Industrial – UFPR (2003), mestrado em Métodos Numéricos em Engenharia – PPGMNE/UFPR (2004 – 2006) e doutorado em andamento em Métodos Numéricos – PPGMNE/UFPR. Atualmente é pesquisadora do LACTEC, possui experiência na área de Matemática Aplicada com ênfase em Otimização, atuando principalmente nos seguintes temas: programação linear, programação não linear, alocação de geração distribuída, previsão de séries temporais e comercialização de energia, despacho hidrotérmico.



Alexandre Rasi Aoki, nascido em Bauru/SP em 1974, graduado em Engenharia Elétrica na EFEI em 1996, Mestre em Engenharia Elétrica pela EFEI em 1999 e Doutor em Engenharia Elétrica pela UNIFEI em 2003. Pesquisador Sênior da Divisão de Sistemas Elétricos do LACTEC e Professor Adjunto do Departamento de Engenharia Elétrica da UFPR. Membro do IEEE e do Cigré. Atua nas áreas de Distribuição de Energia Elétrica, Redes Elétricas Inteligentes e Aplicações de Sistemas Inteligentes.

Eloy Rocha possui graduação em Engenharia Industrial Elétrica com ênfase em Eletrotécnica pela Universidade Tecnológica Federal do Paraná (2001) e mestrado em Engenharia Elétrica pela Universidade Federal do Paraná (2011). Atualmente é engenheiro eletricista sênior da Copel - Companhia Paranaense de Energia. Tem experiência na área de previsão de demanda por subestações, planejamento da expansão do setor elétrico, encargos de uso do sistema e regulamentação do setor elétrico.

Jefferson Marcelo Schiochet é graduado em Engenharia Industrial Elétrica Ênfase em Eletrotécnica pela Universidade Tecnológica Federal do Paraná (2002). Atualmente é engenheiro eletricista sênior da Copel - Companhia Paranaense de Energia. Tem experiência na área de comercialização de energia, estudos de mercado de energia elétrica para o planejamento de sistemas elétricos de potência e regulamentação do setor elétrico.

Rafael Arsie Guimarães é graduado em Engenharia Industrial Elétrica com ênfase em Eletrotécnica pela Universidade Tecnológica Federal do Paraná (2005), especialista em Finanças Empresariais pela Universidade Positivo (2010) e acadêmico do curso de Estatística da Universidade Federal do Paraná. Atualmente é engenheiro eletricista pleno da Copel - Companhia Paranaense de Energia. Tem experiência na área de comercialização de energia, estudos de mercado de energia elétrica para o planejamento de sistemas elétricos de potência e regulamentação do setor elétrico.