

Previsão de carga a curto prazo: Modelagem em duas etapas

Lacir J. Soares *

Egnaldo de Souza Almeida †

8 de julho de 2009

Resumo

This paper studies the hourly electricity load demand in the area covered by a utility situated in the Seattle, USA, called Puget Sound Power and Light Company. Our proposal is put into proof with the famous dataset from this company. We propose a stochastic model which employs ANN (Artificial Neural Networks) to model short-run dynamics and the dependence among adjacent hours. The model proposed treats each hour's load separately as individual single series. This approach avoids modeling the intricate intra-day pattern (load profile) displayed by the load, which varies throughout days of the week and seasons. The forecasting performance of the model is evaluated in similiar mode a TLSAR (Two-Level Seasonal Autoregressive) model proposed by Soares (2003) using the years of 1995 and 1996 as the holdout sample. Moreover, we conclude that non linearity is present in some series of these data. The model results are analyzed. The experiment shows that our tool can be used to produce load forecasting in tropical climate places.

KEYWORDS. Neural networks, nonlinear models, short-term load forecasting, statistical model building.

1 Introdução

A principal característica no processo de planejamento e operação de sistemas elétricos tem sido a previsão de carga. O crescimento dos sistemas de potência e os incrementos nas suas complexidades fazem com que muitos fatores influenciem a geração e o consumo de energia elétrica (gerenciamento de carga, intercâmbio de energia, precificação instantânea, produtores independentes de energia, energia não convencional, entre outros).

É senso comum que está configurado um novo cenário que ratifica um velho princípio da estatística que para obtenção de bons resultados precisa-se de dados confiáveis. Os agentes econômicos já identificam estes dados, como um novo ativo patrimonial. Isto determina que os sistemas de previsão

*L.J. Soares é Professor Associado da UENF - Universidade Estadual do Norte Fluminense Darcy Ribeiro, Campos dos Goytacazes, Brasil; e-mail: lacir@uenf.br.

†E.S. Almeida é Professor do Instituto Federal de Educação, Ciência e Tecnologia Fluminense, Campos dos Goytacazes, Brasil; e-mail: esouza@cefetcampos.br.

tenham maior complexidade e que resultados mais acurados são necessários. O relacionamento entre a carga e os fatores exógenos é complexo e, na maioria das vezes, não lineares, tornando a previsão uma tarefa difícil para modelos que utilizem técnicas estatísticas convencionais, como séries temporais e análise de regressão linear. Muitos trabalhos afirmam que a maioria das técnicas tradicionais não oferece a precisão desejada e não são suficientemente robustas, pois tem dificuldade para incorporar variáveis de mudanças bruscas como às climáticas, por exemplo.

Um exemplo da importância da precisão das previsões é relatado em (Bunn and Farmer 1985b) mostrando que a estimativa de um incremento de 1% no erro de previsão pode aumentar em 10 milhões de libras o custo de operação por ano para uma empresa de eletricidade no Reino Unido.

A literatura clássica de series temporais, ao longo dos anos, tem apresentado um grande número de técnicas de previsão desenvolvidas para modelar demanda de carga elétrica (Bunn and Farmer 1985a, Huang, Huang and Wang 2005, Soares and Medeiros 2005). Hippert, Pedreira and Souza (2001) apresentam uma revisão completa dos métodos clássicos e de inteligência computacional.

O tipo de modelagem aqui proposto não é novo e propostas similares tem sido apresentadas na literatura nas últimas duas décadas (veja, por exemplo, Harvey and Koopman (1993); Temraz, Salama and Quintana (1996) e Nowicka-Zagrajek and Weron (2002)).

Entretanto, a estratégia de modelagem desenvolvida por Soares (2003) contribui em diferentes aspectos, principalmente porque a forma como são especificados os modelos para cada componente não é comum na literatura de previsão de carga e apoia-se somente em argumentos da estatística clássica. Cottet and Smith (2003) propuseram uma abordagem similar, mas a metodologia deles é baseada em estatística bayesiana e tem um alto custo computacional.

Dentre as propostas de inteligência computacional Charytoniuk and Chen (2000), Amjady (2001), Marin, Garcia-Lagos, Joya and Sandoval (2002) e Beccali, Cellura, Brano and Marvuglia (2006) construíram modelos de redes neurais para prever carga máxima, mínima e total. Reis and Silva (2005a) propuseram procedimentos para prever o perfil da carga diária.

Ling S.H. and P.K.S. (2003), Vellasco, Pacheco, Ribeiro Neto and Souza (2004), Song, Baek, Hong and Jang (2005) e Saksornchai, Lee, Methaprayoon, Liao and Ross (2005) desenvolveram modelos baseados na aprendizagem não-supervisionada. A idéia destes modelos é, geralmente, classificar o perfil de carga diário em tipos de dias diferentes. A previsão propriamente dita é feita por uma rede baseada em aprendizagem supervisionada. Em todas as referências que utilizam aprendizagem não-supervisionada, a curva do perfil de carga formada pelas 24 horas é prevista de uma única vez. Neste trabalho a metodologia em duas etapas é aplicada para modelar e prever a demanda de carga elétrica horária da *Puget Sound Power and Light Company*, empresa de Seattle, Estados Unidos. Na primeira etapa desenvolvemos um modelo preditivo para identificar as variáveis significantes, a forma funcional (linear x não-linear) e aspectos relacionados à dependência da forma funcional em relação ao horizonte de previsão e a taxa de discretização dos dados, modelamos a tendência, a sazonalidade anual, os efeitos dos dias da semana e alguns efeitos especiais como feriados, dias entre feriados, seguindo a metodologia proposta em Soares and Medeiros (2005). Na segunda etapa são

utilizadas técnicas de redes neurais artificiais para modelar e estimar a parte não determinística do modelo. A metodologia trabalha bem com o conjunto de dados utilizado e pode ser usada por qualquer empresa de energia elétrica no Brasil ou no exterior. O objetivo final será avaliar a capacidade preditiva do modelo de *RNA* desenvolvido.

A seqüência deste trabalho é descrita a seguir. A seção 2 descreve e apresenta o modelo desenvolvido. A seção 3 descreve a estratégia de modelagem. A seção 4 mostra a organização dos dados utilizados e o descreve o experimento realizado. A seção 5 apresenta os resultados da previsão e comentários finais são feitos na seção 6.

2 O modelo

A abordagem é baseada na decomposição das séries de carga em duas componentes, considerando um modelo separado para cada hora do dia para remover o ciclo diário conforme as idéias contidas em Ramanathan, Engle, Granger, Vahid-Arahi and Brace (1997), onde modelos de regressão paramétricos tem um desempenho superior quando comparados com alternativas semi-paramétricas. A carga é modelada como a soma de duas componentes. A primeira componente é chamada de “carga potencial” e descreve a dinâmica de longo prazo ou permanente que reflete, principalmente, a tendência de longo prazo, o ciclo anual e os efeitos dos diferentes tipos de dias.

A segunda componente é a “carga irregular” e descreve a dinâmica de curto prazo e as possíveis dependências de horas próximas. Matematicamente o modelo é representado por:

$$L_{h,d} = L_{h,d}^P + L_{h,d}^I, \quad (1)$$

onde $L_{h,d}^P$ e $L_{h,d}^I$ são, respectivamente, a carga potencial e a carga irregular da hora h do dia d .

A carga potencial é definida por:

$$L_{h,d} = T_{h,d} + S_{h,d}, \quad (2)$$

onde $T_{h,d}$ é a componente de tendência que pode ser, a princípio, determinística ou estocástica e $S_{h,d}$ é um termo sazonal que representa os efeitos dos dias da semana e as estações do ano.

A componente irregular é definida por um processo autorregressivo que pode ser linear ou não-linear com a seguinte formulação:

$$L_{h,d}^I = f(L_{h,d-1}^I + \dots + L_{h,d-p}^I + u_{h,d}; \Psi), \quad (3)$$

onde $f(\cdot; \Psi)$ é uma função autorregressiva indexada por um vetor de parâmetros Ψ e $u_{h,d}$ é o termo de erro. As premissas sobre o termo de erro seguem o que estabelece Soares and Medeiros (2008). Então, os erros não são considerados gaussianos assim como em Huang and Shih (2003) e ?. A distribuição dos erros pode ser assimétrica ou leptocúrtica, mas, diferentemente desses autores, consideramos ser possível a heterocedasticidade condicional não ser constante.

2.1 A Componente Potencial

2.1.1 A Tendência

A primeira etapa da modelagem da carga potencial é uma decisão sobre a natureza da tendência que pode ser uma função determinística do tempo (tendência linear) ou estocástica. No caso de tendência linear, regressão linear e mínimos quadrados ordinários devem ser usados para modelar e estimar a componente de tendência (veja Ramanathan et al. (1997) e Soares and Souza (2006)). Quando a tendência é estocástica a série de carga deve ser diferenciada para tornar-se estacionária (Reis and Silva 2005b) ou algum filtro pode ser usado. Neste caso, duas são as possibilidades, utilizar filtro de Kalman (Harvey 1991) ou fazer a decomposição de Beveridge-Nelson (Beveridge and Nelson 1981). Além disso, a decisão sobre a natureza da tendência é igualmente importante. Quando a tendência é determinística, a aplicação da primeira diferença introduz uma componente de média-móvel não inversível (dependência serial espúria) no processo de geração dos dados que provoca sérios problemas de estimação como descritos em muitos textos básicos sobre séries temporais (Box, Jenkins and Reinsel 1994). Adicionalmente, não existe um modelo autorregressivo que seja capaz de descrever corretamente a dinâmica (espúria) dos dados, quando o termo de média-móvel é não inversível – veja uma discussão no capítulo 4 de Enders (2004). Entretanto, se a tendência é estocástica e um método determinístico é aplicado, a tendência não será modelada corretamente, os dados continuarão não estacionários e a inferência estatística clássica não será válida.

Uma possível alternativa para identificar se a tendência é determinística ou estocástica é utilizar os testes para raízes unitárias da maneira como são utilizados em econometria. Existem diversos testes disponíveis na literatura. Neste artigo nós usamos dois dos testes mais usados, a saber: teste Aumentado de Dickey-Fuller (ADF) (Dickey and Fuller 1979) e teste de Phillips-Perron (PP) (Phillips and Perron 1988).

É importante ressaltar que muitos artigos na literatura de previsão de carga aplicam diferença de primeira ordem nas séries de carga sem utilizar testes de raízes unitárias previamente – veja, por exemplo Reis and Silva (2005b). Então, contrariando muitos autores, nós modelamos a tendência de longo prazo como uma função linear do tempo.

2.1.2 A componente sazonal

É bem conhecido que séries de carga apresentam sazonalidade diária, mensal e anual. Existem diversas abordagens para modelar a componente sazonal. Nos anos 80 da década passada muitos autores defenderam o uso da soma de senos e cossenos como na decomposição em séries de Fourier. Referências mais recentes são: Schneider, Takenawa and Schiffman (1985) e El-Keib, Ma and Ma (1995). Em ambos os artigos os autores aplicam decomposição de Fourier em uma série horária ao invés de 24 séries diferentes uma para cada hora. Mais recentemente Cottet and Smith (2003) usaram funções trigonométricas para modelar a sazonalidade em séries de carga. Os autores também

consideraram modelos distintos para cada hora do dia, mas eles mantiveram fixos o número de senos e cossenos. A abordagem deles foi baseada em estatística bayesiana. Todavia, esta característica pode ser identificada por inspeção visual de gráficos (veja figura 2), mas diversos autores tem criticado fortemente o uso deste tipo de decomposição e tem defendido o uso de ferramentas mais complexas como *wavelets*. Reis and Silva (2005b) usaram uma decomposição baseada em *wavelets* para descrever diversas características das séries de carga. Eles mostraram que quando existe sazonalidade variante no tempo, dados aberrantes e dados faltantes a análise de *wavelets* é recomendada. Todavia, existem argumentos contra o uso indiscriminado de decomposição em *wavelets*. Primeiramente, valores faltantes podem ser facilmente identificados e corrigidos com técnicas muito simples e dados aberrantes podem ser removidos com um procedimento padrão de análise de intervenção – veja Silva (2001).

Como o objetivo neste trabalho é descrever o comportamento periódico fixo, nós seguiremos a proposta desenvolvida recentemente em Soares and Medeiros (2008) e usaremos um conjunto de senos e cossenos para descrever a sazonalidade mensal. A sazonalidade semanal (efeitos dos dias da semana e de dias especiais, tais como feriados) é modelada com variáveis *dummy*. Cottet and Smith (2003) adotaram uma abordagem similar. A componente sazonal é dado por:

$$\hat{S}_{h,d} = \hat{\alpha}_0 + \sum_{r=1}^H [\hat{\alpha}_{1r} \cos(\omega rd) \hat{\alpha}_{2r} \sin(\omega rd)] + \sum_{k=1}^K \hat{\mu}_k \delta_k, \quad (4)$$

onde $\omega = 2\pi/365$, $\alpha_0, \alpha_{1r}, \alpha_{2r}, r = 1, \dots, H, \mu_k, k = 1, \dots, K$, são parâmetros e $\delta_i, i = 1, \dots, K$, são variáveis *dummy* identificando os dias da semana, feriados, dias especiais, etc.

Resumindo, a carga potencial é modelada como:

$$L_{h,d}^P = \alpha_0 + \rho d + \sum_{r=1}^H [\alpha_{1r} \cos(\omega rd) + \alpha_{2r} \sin(\omega rd)] + \sum_{k=1}^K \mu_k \delta_k, \quad (5)$$

onde ρ é a inclinação da tendência linear.

3 Estratégia de Modelagem

A estratégia de modelagem utilizada para modelar a componente irregular segue a proposta desenvolvida por Medeiros, Teräsvirta and Rech (2006), definida da seguinte forma:

$$L_{h,d}^I = \beta_0' \tilde{z} + \sum_{m=1}^M \beta_m g(z_t; \theta_m) + u_{h,d}, \quad (6)$$

onde $\beta_0, \beta_m, \theta_m = (\mathbf{w}'_m, w_0)'$, $m = 1, \dots, M$, são parâmetros e

$$g(z_t; \theta_m) = \frac{1}{1 + e^{-(\mathbf{w}'_m z_t - w_0)}} \quad (7)$$

é a função logística. É importante ressaltar que o modelo de redes neurais, neste caso, engloba um modelo linear autorregressivo quando $M = 0$. Para determinar o número de unidades ocultas da equação 6 nós usamos a estratégia proposta em Medeiros et al. (2006). Mais detalhes sobre a evidência de não-linearidades podem ser encontrados em Soares and Medeiros (2005).

3.1 Resumo

A especificação e estimação do modelo é dividida em duas etapas. Resumindo, o procedimento segue o seguinte fluxo:

- Para cada hora do dia, nos estimamos conjuntamente $\alpha_0, \rho, \alpha_{1r}, \alpha_{2r}, \mu_k, \xi_1, r = 1, \dots, H$, e $k = 1, \dots, K$ na equação (5) por mínimos quadrados ordinários (MQO). O número de harmônicas (H) é determinado pela minimização do critério de Schwarz - Schwarz Bayesian Information Criteria (SBIC) (Schwarz 1978). O número de variáveis *dummies* (K), representando os diferentes tipos de dias é mantido fixo.
- Após estimar a carga potencial nós calculamos os resíduos $\hat{L}_{h,d}^S = L_{h,d} - \hat{L}_{h,d}^P$ onde

$$\hat{L}_{h,d}^P = \hat{\alpha}_0 + \hat{\rho}d + \sum_{r=1}^H \hat{\alpha}_{1r} \cos(\omega r d) + \hat{\alpha}_{2r} \sin(\omega r d) + \sum_{k=1}^K \hat{\mu}_k \delta_k,$$

- A etapa final é a modelagem da componente irregular conforme descrito na seção 3.1.1.

3.1.1 A Modelagem com Redes Neurais

Construir modelos com *RNA* envolve duas escolhas cruciais. Primeiramente, a seleção das variáveis de entrada \mathbf{z}_t . No caso univariado, como o considerado neste trabalho, isto é equivalente a selecionar as defasagens relevantes de $L_{h,d}^I$. Em segundo lugar, a escolha do número de camadas escondidas M. Existem duas maneiras de abordar este problema. Pode-se começar com um modelo pequeno (mínimo) e gradualmente incrementar o tamanho. Isto é, algumas vezes, denominado abordagem de baixo para cima (em inglês “*bottom-up*”). Ou então, pode-se iniciar com um modelo grande e ir “podando-o” gradualmente, o que significa ir removendo, sequencialmente, unidades escondidas ou variáveis. Neste trabalho, nós adotamos uma estratégia partindo de um modelo pequeno e utilizamos técnicas de inferência estatística para selecionar as variáveis de entrada de maneira similar a apresentada em (Medeiros et al. 2006).

A primeira etapa da estratégia de baixo para cima é selecionar as variáveis de entrada. Isto é feito aplicando a metodologia descrita em (Rech, Teräsvirta and Tschernig 2001). A idéia geral é aplicar uma aproximação polinomial para a “carga irregular” e usar o critério *SBIC* para selecionar as defasagens relevantes de $L_{h,d}^I$. A segunda etapa consiste em selecionar o número de unidades




Figura 1: Arquitetura dos modelos utilizando RNA

da camada escondida. Foram aplicados testes de linearidade e se a linearidade foi rejeitada, um modelo com uma unidade na camada escondida ($M = 1$ na equação 6) é estimado. Nós preferimos modelos parcimoniosos que não produzam custos computacionais muito altos. A figura 1 mostra o esquema geral de previsão do modelo *RNA* desenvolvido.

4 O Experimento

A série de dados consiste de cargas horárias da *Puget Sound and Light Company*, EUA, que foi analisada extensivamente na literatura de previsão da carga. O período entre 1 janeiro 1985 e 31 dezembro 1990 (2191 observações) é usado para construir os modelos. O período entre 1 janeiro 1990 e 12 outubro 1992 (651 observações) é utilizado para testar o desempenho do modelo.

Para todas as 24 séries foi considerada uma tendência linear. Nós utilizamos os teste *ADF* e *PP* para testar as raízes unitárias e os *p-valores* de ambos os testes são próximos de zeros, indicando uma forte rejeição da hipótese nula das raízes unitárias. Aqui, nós omitimos os resultados mas detalhes podem ser obtidos em Soares and Medeiros (2005). Continuamos a estimação da carga potencial de acordo com a seção 3. A Tabela 2 mostra, para cada hora do dia, o número de harmônicas estimadas. Para a maioria das horas, o SBIC seleciona 3 ou 4 harmônicas. Um fato interessante é que para as horas 8, 9, 18, 21, 22, 23, e 24, o número de harmônicas aumentam. Para as horas 8, 9, e 18, este resultado talvez seja explicado pelo comportamento dos consumidores

durante as horas de pico que igualmente induz um aumento na volatilidade da série de carga (veja a figura 2).

Onze tipos diferentes de dias são usados: Domingo, segunda-feira, terça-feira, quarta-feira, quinta-feira, sexta-feira, sábado, feriado oficial ou religioso, dia após feriado, dia anterior a feriado e dia útil entre feriado e final de semana (veja tabela 1). As componentes irregulares estimadas são mostradas na figura 3.

Tabela 1: Classificação dos tipos de dias para efeito de previsão.

código	descrição
1	domingo
2	segunda-feira
3	terça-feira
4	quarta-feira
5	quinta-feira
6	sexta-feira
7	sábado
8	feriado oficial ou religioso
9	dia após feriado
10	dia anterior a feriado
11	dia útil entre feriado e final de semana

A tabela 2 mostra o número de unidades escondidas estimadas (M) para cada hora do dia. Quando $M = 0$, significa que um modelo autorregressivo linear será estimado preferivelmente. O número de defasagens selecionadas para a carga irregular é igualmente apresentado na tabela. É importante realçar que um número muito pequeno de unidades escondidas é selecionado, indicando que a não linearidade no meio condicional não é muito forte.

Para a hora 10, o meio-dia, a hora 13 e o intervalo entre 15 – 19 horas um modelo linear é selecionados porque não há nenhuma evidência estatística de não linearidades. Para 13 das 24 séries, somente uma unidade escondida é estimada e para a série da hora 5, o modelo especificado tem duas unidades escondidas. Entretanto, quando os resíduos dos modelos são analisados, aparecem fortes evidências de existir heterocedasticidade condicional (veja Soares and Medeiros (2005) para uma análise detalhada). Os resultados da previsão dos modelos RNA são resumidos na tabela 3. Para cada hora do dia, a tabela mostra o erro médio absoluto percentual da previsão para um a sete passos a frente.

As cargas reais e as cargas potenciais estimadas são apresentadas na figura 2.

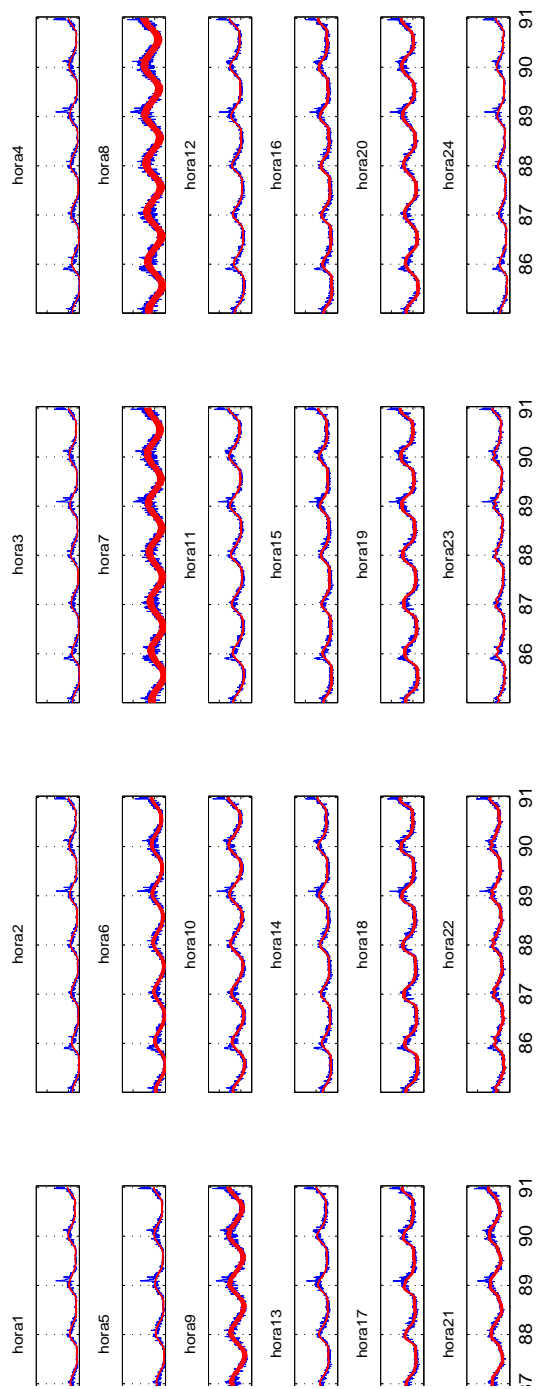


Figura 2: Carga horária (azul) e carga potencial estimada (vermelho) para cada hora entre 1 de janeiro de 1985 e 31 de dezembro de 1990.

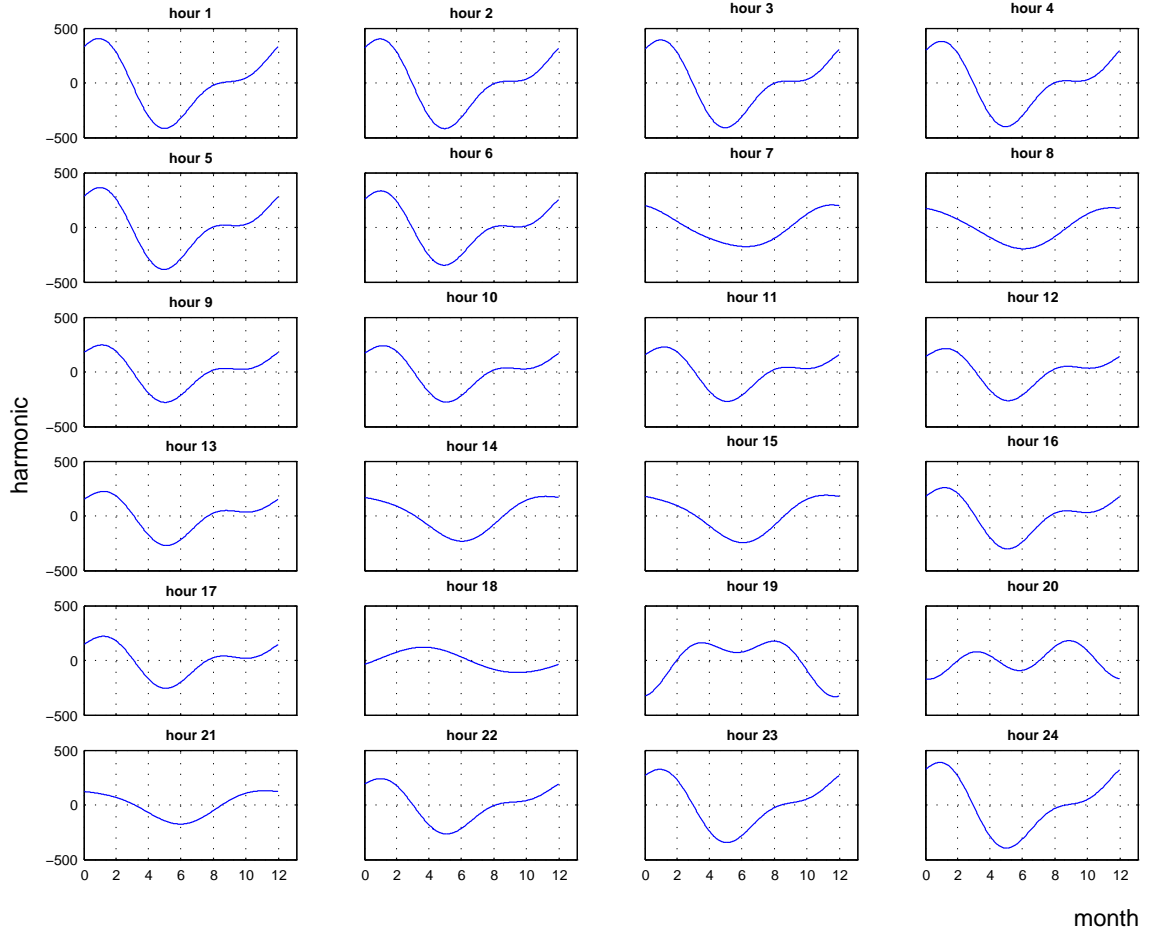


Figura 3: Carga irregular para cada hora entre 1 de janeiro de 1985 e 31 de dezembro de 1990.

5 As Previsões

As previsões para vários passos a frente das séries de carga são calculados como mostrado em Teräsvirta, van Dijk and Medeiros (2005). A partir da equação (3), a previsão um passo a frente denotada por $L_{h,d+1}^I$ é igual a

$$\widehat{L}_{h,d+1|d}^I = f(L_{h,d}^I, \dots, L_{h,d-p+1}^I; \widehat{\Psi}_d),$$

onde $\widehat{\Psi}_d$ indica que as estimativas dos parâmetros são obtidas usando observações que antecedem o dia d . A previsão dois passos a frente, denotada por $L_{h,d+2}^I$, é obtida por

$$\widehat{L}_{h,d+2|d}^I = \int_{-\infty}^{\infty} f(\widehat{L}_{h,d+1|d}^I + u_{h,d+1}, L_{h,d}^I, \dots, L_{h,d+2}^I; \widehat{\Psi}_d) du_{h,d+1}. \quad (8)$$

Para horizontes mais distantes a obtenção da previsão do ponto exigiria a resolução de uma

integral multidimensional. A integração numérica da equação (8) pode ser evitada pela aproximação da integral por simulação ou utilizando técnica de *bootstrapping* nos resíduos. A última alternativa requer supor que os erros da equação (3) sejam independentes. Nós produzimos as previsões das cargas $L_{h,d+1}^I, L_{h,d+2}^I, \dots, L_{h,d+7}^I$. A descrição completa do procedimento pode ser encontrada em Soares and Medeiros (2005).

Tabela 2: RESULTADOS DA ESTIMAÇÃO

Hora	Número de Harmônicas (H)	Número de Unidades ocultas (M)	Defasagens Seleccionadas
1	4	1	1, 2 e 7
2	4	1	1, 2 e 7
3	4	2	1, 2 e 7
4	4	1	1, 2 e 7
5	4	1	1, 2 e 7
6	4	2	1, 2 e 7
7	3	2	1, 2 e 7
8	6	2	1, 2 e 7
9	6	2	1, 2 e 7
10	3	0	1, 2 e 7
11	3	1	1, 2 e 7
12	3	0	1, 2 e 7
13	3	0	1, 2 e 7
14	3	1	1, 2 e 7
15	3	1	1, 2 e 7
16	3	1	1, 2 e 7
17	4	0	1, 2 e 7
18	6	0	1, 2 e 7
19	4	0	1, 2 e 7
20	3	1	1, 2 e 7
21	5	1	1, 2 e 7
22	6	1	1, 2 e 7
23	6	1	1, 2 e 7
24	7	1	1, 2 e 7

A tabela mostra, para cada hora, o número de harmônicas seleccionadas em 4, o número de unidades ocultas em 6 e as defasagens seleccionadas para componente irregular. As harmônicas e as defasagens são seleccionadas pelo SBIC e o número de unidades ocultas são determinados por testes robustos definidos em (Medeiros et al. 2006). Quando o número de unidades ocultas é 0, um modelo linear é estimado. As defasagens também são seleccionadas pelo SBIC.

6 Conclusão

Neste artigo nós consideramos um modelo de duas componentes para a demanda de carga elétrica horária. Este trabalho, aplica e estende a proposta desenvolvida por Soares and Medeiros (2005).

A primeira componente da modelagem é relacionada às tendências de longo prazo, a sazonalidade e aos efeitos dos dias especiais. A segundo descreve a dinâmica de curto prazo e a dependência entre horas adjacentes. A volatilidade da série é considerada cuidadosamente. Todo o ciclo de modelagem foi baseado em argumentos estatísticos rigorosos e os modelos lineares e não-lineares, incluindo redes neurais, são considerados. Este modelo aplica-se aos dados seccionais, isto é, a carga para cada hora do dia é tratada separada como uma série. Finalmente, o modelo proposto foi usado para prever a carga de hora em hora da *Puget Sound Power and Light Company*, EUA. Os resultados obtidos pelo modelo são comparáveis com os apresentados na literatura nos últimos anos.

Tabela 3: Resultados de previsão: modelo *RNA*-MAPE

Hour	1	2	3	4	5	6	7
1	3.14	4.34	4.85	5.03	5.30	5.62	5.68
2	3.37	4.73	5.39	5.58	5.87	6.35	6.59
3	3.64	4.94	5.52	5.69	5.95	6.30	6.45
4	3.85	5.23	5.82	6.00	6.22	6.54	6.76
5	3.93	5.27	5.79	5.97	6.14	6.47	6.56
6	6.46	6.60	6.74	6.81	6.84	6.85	6.86
7	7.12	7.13	7.13	7.13	7.13	7.13	7.13
8	6.43	6.47	6.47	6.47	6.47	6.47	6.47
9	5.38	5.39	5.39	5.39	5.39	5.39	5.39
10	3.20	4.39	4.79	4.92	5.06	5.05	5.00
11	3.23	4.40	4.79	4.88	4.95	4.86	4.69
12	3.40	4.42	4.76	4.89	4.98	4.95	4.92
13	3.64	4.57	4.88	5.01	5.07	5.03	5.01
14	3.79	4.69	4.99	5.09	5.08	5.00	4.98
15	3.89	4.78	5.04	5.05	4.96	4.86	4.85
16	3.97	4.81	5.04	5.06	5.01	4.98	5.00
17	3.88	4.66	4.88	4.94	4.98	5.00	5.03
18	3.55	4.35	4.58	4.62	4.68	4.74	4.81
19	3.25	3.98	4.23	4.31	4.44	4.53	4.61
20	3.09	3.87	4.18	4.30	4.41	4.51	4.60
21	2.92	3.75	4.11	4.24	4.42	4.55	4.61
22	2.80	3.72	4.10	4.30	4.49	4.67	4.74
23	2.81	3.81	4.27	4.42	4.65	4.87	4.93
24	2.94	4.05	4.50	4.61	4.88	5.21	5.20
min	2.80	3.72	4.10	4.24	4.41	4.51	4.60
med	3.90	4.76	5.09	5.20	5.31	5.41	5.45
max	7.12	7.13	7.13	7.13	7.13	7.13	7.13

A tabela mostra, para cada hora, o erro médio absoluto percentual do modelo linear *MLP*.

Referências

- Amjady, N.: 2001, Short-term hourly load forecasting using time-series modeling with peak load estimation capability, *IEEE Transactions on Power Systems* **16**, 498–504.
- Beccali, M., Cellura, M., Brano, V. and Marvuglia, A.: 2006, Forecasting daily urban electric load profiles using artificial neural networks, *Energy Conversion and Management* **45**, 2879–2900.
- Beveridge, S. and Nelson, C.: 1981, A new approach to decomposition of economic time series into permanent and transitory components with particular attention to measurement of the business cycle, *Journal of Monetary Economics* **7**, 151–174.
- Box, G. E. P., Jenkins, G. M. and Reinsel, G. C.: 1994, *Time Series Analysis, Forecasting and Control*, third edn, Prentice Hall, San Francisco.
- Bunn, D. and Farmer, E.: 1985a, *Comparative Models for Electrical Load Forecasting*, Wiley, New York.
- Bunn, D. and Farmer, E.: 1985b, Economic and operational context of electric load prediction, in D. Bunn and E. Farmer (eds), *Comparative Models for Electrical Load Forecasting*, Wiley, pp. 3–11.
- Charytoniuk, W. and Chen, M.-S.: 2000, Very-short term load forecasting using artificial neural networks, *IEEE Transactions on Power Systems* **15**(1), 263–268.
- Cottet, R. and Smith, M.: 2003, Bayesian modeling and forecasting of intraday electricity load, *Journal of the American Statistical Association* **98**, 839–849.
- Dickey, D. and Fuller, W.: 1979, Distribution of the estimators for autoregressive time series with a unit root, *Journal of the American Statistical Association* **74**, 427–431.
- El-Keib, A., Ma, X. and Ma, H.: 1995, Advancement of statistical based modeling techniques for short-term load forecasting, *Electric Power Systems Research* **35**, 51–58.
- Enders, W.: 2004, *Applied Econometric Time Series*, Wiley Series in Probability and Statistics, second edn, Wiley, New Jersey.
- Harvey, A. and Koopman, S.: 1993, Forecasting hourly electricity demand using time-varying splines, *Journal of the American Statistical Association* **88**, 1228–1237.
- Harvey, A. C.: 1991, *The Econometric Analysis of Time Series*, second edn, The MIT Press, Cambridge, MA.
- Hippert, H., Pedreira, C. and Souza, R.: 2001, Neural networks for short-term load forecasting: A review and evaluation, *IEEE Transactions on Power Systems* **16**, 44–55.

- Huang, C.-M., Huang, C.-J. and Wang, M.-L.: 2005, A particle swarm optimization to identify the ARMAX model for short-term load forecasting, *IEEE Transactions on Power Systems* **20**, 1126–1133.
- Huang, S.-J. and Shih, K.-R.: 2003, Short-term load forecasting via ARMA model identification including non-gaussian process considerations, *IEEE Transactions on Power Systems* **18**, 673–679.
- Ling S.H., Leung F.H.F., L. K. L. Y.-S. and P.K.S., T.: 2003, A novel genetic-algorithm-based neural network for short-term load forecasting, *IEEE Transactions on Industrial Electronics* **50**(4), 793–799.
- Marin, F., Garcia-Lagos, F., Joya, G. and Sandoval, F.: 2002, Global model for short-term load forecasting using artificial neural networks, *IEE Proceedings-Generation, Transmission and Distribution* **149**(2), 121–125.
- Medeiros, M. C., Teräsvirta, T. and Rech, G.: 2006, Building neural network models for time series: A statistical approach, *Journal of Forecasting* **25**, 49–75.
- Nowicka-Zagrajek, J. and Weron, R.: 2002, Modeling electricity loads in california: ARMA models with hyperbolic noise, *Signal Processing* **82**, 1903–1915.
- Phillips, P. and Perron, P.: 1988, Testing for a unit root in time series regression, *Biometrika* **75**, 335–346.
- Ramanathan, R., Engle, R. F., Granger, C., Vahid-Arahi, F. and Brace, C.: 1997, Short-run forecasts of electricity loads and peaks, *International Journal of Forecasting* **13**, 161–174.
- Rech, G., Teräsvirta, T. and Tschernig, R.: 2001, A simple variable selection technique for nonlinear models, *Communications in Statistics, Theory and Methods*.
- Reis, A. and Silva, A.: 2005a, Feature extraction via multiresolution analysis for short-term load forecasting, *IEEE Transactions on Power Systems* **20**(1), 189–198.
- Reis, A. and Silva, A.: 2005b, Feature extraction via multiresolution analysis for short-term load forecasting, *IEEE Transactions on Power Systems* **20**, 189–198.
- Saksornchai, T., Lee, W. J., Methaprayoon, K., Liao, J. and Ross, R.: 2005, Improve the unit commitment scheduling by using the neural-network-based short-term load forecasting, *IEEE Transactions on Industry Applications* **41**(1), 169–179.
- Schneider, A., Takenawa, T. and Schiffman, D.: 1985, 24-hour electric utility load forecasting, in D. Bunn and E. Farmer (eds), *Comparative Models for Electrical Load Forecasting*, Wiley.
- Schwarz, G.: 1978, Estimating the dimension of a model, *Annals of Statistics* **4**, 461–464.

- Silva, H. F.: 2001, *Um Sistema Integrado de Monitoração e Previsão de Carga elétrica curto prazo*, Phd. thesis, Pontifícia Universidade Católica do Rio de Janeiro.
- Soares, L.: 2003, *Ensaio em Previsão de Carga a Curto Prazo, Tese de Doutorado, Pontifícia Universidade Católica do Rio de Janeiro*, Phd. thesis, Pontifícia Universidade Católica do Rio de Janeiro.
- Soares, L. and Medeiros, M.: 2005, Modeling and forecasting short-term electric load demand: A two step methodology, *Textos para Discussão 495*, Pontifícia Universidade Católica do Rio de Janeiro.
- Soares, L. and Medeiros, M.: 2008, Modeling and forecasting short-term electricity load: A comparison of methods with an application to brazilian data, *International Journal of Forecasting* **24**(4), 630–644.
- Soares, L. and Souza, L.: 2006, Forecasting electricity demand using generalized long memory, *International Journal of Forecasting* **22**, 17–28.
- Song, K.-B., Baek, Y.-S., Hong, D. and Jang, G.: 2005, Short-term load forecasting for the holidays using fuzzy linear regression method, *IEEE Transactions on Power Systems* **20**, 96–101.
- Temraz, H., Salama, M. and Quintana, V.: 1996, Application of the decomposition technique for forecasting the load of a large electric power network, *IEE Proceedings - Generation, Transmission, and Distribution* **143**, 13–18.
- Teräsvirta, T., van Dijk, D. and Medeiros, M.: 2005, Linear models, smooth transitions autoregressions, and neural networks for forecasting macroeconomic time series: A re-examination, *International Journal of Forecasting* **21**, 755–774.
- Velasco, M., Pacheco, M., Ribeiro Neto, L. and Souza, F.: 2004, Electric load forecasting: evaluating the novel hierarchical neuro-fuzzy BSP model, *Electrical Power and Energy Systems* **26**, 131–142.