

# PREVISÃO DE DADOS DE ALTA FREQUÊNCIA PARA CARGA ELÉTRICA USANDO HOLT-WINTERS COM DOIS CICLOS

**Cristina Vidigal Cabral de Miranda**

<sup>1</sup>Pontifícia Universidade Católica do Rio de Janeiro  
Rua Marquês de São Vicente 225, Rio de Janeiro, Brasil  
cristina@ele.puc-rio.br

**Reinaldo Castro Souza<sup>1</sup>**

reinaldo@ele.puc-rio.br

**Lilian M. de Menezes**

Cass Business School, City University  
106 Bunhill Row. London. United Kingdom  
L.deMenezes@city.ac.uk

**Juan Guillermo Lazo Lazo<sup>1</sup>**

juan@ele.puc-rio.br

## RESUMO

Este artigo mostra um modelo univariado para previsão de carga elétrica com dados de alta frequência. Para tal, foi usado o modelo Holt-Winters com dois ciclos, um diário e o outro semanal, na sua forma multiplicativa. O modelo gera previsões 15 minutos à frente para os próximos 7 dias, i.e., totalizando 672 passos-à-frente previstos. Contudo, antes de gerar as previsões, é necessário estimar os valores iniciais do nível, tendência e cada sazonalidade (neste caso há 96 fatores diários e 672 fatores semanais) e também os hiperparâmetros (que são quatro). Os valores iniciais podem ser obtidos por um algoritmo, mas a estimação dos hiperparâmetros é mais complexa, sendo necessário um algoritmo de otimização não-linear. Portanto, utilizou-se um algoritmo genético, o qual minimizou o MSE. Também foi feita uma análise de sensibilidade para analisar o desempenho do modelo com o AG. Além disso, foi realizada uma intervenção exógena para tratar os feriados.

**PALAVRAS CHAVE.** Previsão para dados de alta frequência. Método de Holt-Winters com dois ciclos. Algoritmo Genético. Área de classificação principal: AE - Aplicações a Energia.

## ABSTRACT

This paper presents an univariate model to forecast high frequency load data. It was used the Holt-Winters approach with double cycles, one daily and the other weekly, in its multiplicative form. The model produces 15-minutes-ahead forecasts for the next 7 days, i.e., a total of 672 steps-ahead forecasts. However, before the forecasts are produced, is necessary to estimate the initial values for level, trend and each seasonality (in this case there are 96 factors intraday and 672 factors intraweek) and also the hyper parameters (they are four). The initial values can be obtained by an algorithm, but the hyper parameters estimation is rather complex, as it needs a nonlinear optimization algorithm. It was used a genetic algorithm, which minimises the MSE. Besides that, was also carried out a sensibility analysis to verify the model's performance with the GA. In addition, the bank holidays were considered separately with an exogenous intervention.

**KEYWORDS.** High frequency load forecasts. Double Seasonal Exponential Smoothing Methods. Genetic Algorithm. Main área: AE - Applications to Energy.

## 1. Introdução

A transmissão de energia elétrica entre as regiões de geração e consumo é um processo que envolve vários fatores diferentes e importantes, como a qualidade e confiabilidade. Por isso, um planejamento adequado é parte essencial do processo, no qual devem ser levados em consideração necessidades futuras da distribuição, que podem ser projetadas usando técnicas de previsão.

No Brasil, o consumo de energia elétrica tem crescido a uma taxa média de 7% durante os últimos 30 anos. Aqui, as plantas hidroelétricas são responsáveis por quase 80% do total de energia produzida, sendo que, nos últimos anos, estão sendo construídas usinas térmicas, que servirão de proteção contra condições hidrológicas desfavoráveis.

A previsão de curto prazo, que envolve dados de alta frequência, é o objeto de estudo desse trabalho, sendo essencial para a confiabilidade e eficiência da operação do setor elétrico, fazendo com que a alocação da carga seja feita de forma eficiente, além de indicar possíveis distorções nos próximos períodos (dias, horas, ou frações de horas).

Sendo assim, é de suma importância produzir uma boa previsão para a variável “carga elétrica”, a qual depende exclusivamente do usuário e de fatores que interferem no cotidiano do mesmo, como o clima, a economia e o nível social. Com uma previsão de qualidade para valores futuros da carga elétrica, pode-se melhorar, em muito, procedimentos intrínsecos ao processo global de distribuição de energia, além, é claro, de corrigir possíveis problemas pré-existentes.

Para tanto, neste trabalho será apresentada uma metodologia que é uma extensão do modelo de amortecimento exponencial, o método de Holt-Winters com múltiplos ciclos, originalmente desenvolvido por Taylor (2003a). Serão realizadas previsões de carga elétrica de 15 em 15 minutos, para sete dias à frente, isto é, 672 passos à frente, para uma distribuidora de energia elétrica da região sudeste do Brasil.

O método de amortecimento de Holt-Winters é um método univariado, isto é, usa somente a própria série para realizar a previsão. Contudo, pelo seu preciosismo, robustez e adaptabilidade (Williams, 1987), é muito utilizado em várias áreas, como por exemplo, em consumo de energia elétrica (Taylor, 2003a, Taylor, 2003b e Taylor, Menezes e McSharry, 2006), vendas de passagens aéreas (Grubb & Manson, 2001) e vendas no mercado agrícola (Cipra et al, 1995).

Contudo, antes das previsões serem realizadas, é necessário estimar os valores iniciais do nível, tendência e cada sazonalidade (lembrando que, neste caso, tem-se 96 fatores sazonais dentro de dia e 672 fatores sazonais dentro da semana) e há também os hiperparâmetros (são quatro, um para cada parâmetro anterior), que são as constantes de amortecimento do modelo.

Os valores iniciais podem ser obtidos através de um algoritmo de inicialização, mas a estimação dos hiperparâmetros é um processo mais complexo, pois é necessário otimizar um processo não linear. Para solucionar este problema, foi utilizado um algoritmo genético, o qual minimiza o *mean squared error*. Além disso, está sendo desenvolvida uma análise de sensibilidade a fim de verificar a performance do algoritmo genético.

Também foi inserida uma intervenção exógena para considerar os efeitos do feriado, pois em uma empresa é importante ter previsões precisas para todos os tipos de dias. Sabe-se que um dia de feriado provoca uma distorção no perfil de demanda da carga elétrica e essa distorção é diferente dependendo do dia da semana em que ocorre e também dos períodos dentro do dia. Além disso, verificou-se que a ocorrência de um feriado afeta não somente este dia, mas também outros dias adjacentes, sendo que os dias a serem afetados dependerão do dia da semana em que o feriado ocorrer. Portanto, essas datas foram tratadas exogenamente, sendo criada uma base de regras para cada 15 minutos do feriado e dos dias antes e depois do feriado e assim as previsões dos feriados e de seus dias adjuntos são corrigidas de acordo com essas regras.

## 2. Formulação Teórica

### 2.1- Holt-Winters com dois ciclos

O modelo Holt-Winters padrão é muito utilizado para a previsão de séries temporais que contém sazonalidade. No entanto, esta modelagem é capaz de comportar apenas um padrão sazonal.

Taylor (2003a) desenvolveu um trabalho no qual previa dados de demanda elétrica no intervalo de trinta minutos. Neste artigo, ele mostrou que havia um ciclo sazonal dentro do dia com duração de 48 períodos (de trinta minutos cada) e também havia um ciclo sazonal dentro da semana, isto é, o perfil da demanda de um dia tinha um comportamento bastante parecido com o perfil da demanda do próximo dia, principalmente ao analisar os dias de semana. Este ciclo dentro da semana, com duração de 336 períodos (esta é a quantidade de trinta minutos em uma semana), fica bastante evidente ao analisar simultaneamente duas semanas. Estes padrões sazonais evidenciados por Taylor também foram verificados em dados do Brasil.

Tendo estes dois padrões sazonais em vista e sabendo que o método de Holt-Winters é conhecido por sua robustez e precisão e por isto vem sendo muito utilizado, Taylor adaptou o método de Holt-Winters padrão de tal forma que ele passasse a acomodar mais do que um padrão sazonal, isto é, múltiplos ciclos. Portanto, este método é adequado para séries com dois ou mais ciclos.

O modelo Holt-Winters com dois ciclos, um diário e o outro semanal, está expresso matematicamente abaixo:

$$X_t = (S_t + T_t)D_{t-1}W_{t-1} + \varepsilon_t$$

Considerando uma série com periodicidade de 15 minutos, a sazonalidade diária e a semanal são, respectivamente,  $s_1 = 96$  (24 vezes 4) e  $s_2 = 672$  (168 vezes 4). Sendo  $t$  o índice de tempo e  $X_t$  a carga observada,  $\hat{X}_t(k)$  é a previsão  $k$  passos à frente feita em  $t$  (neste trabalho,  $k=672$ ).  $D_t$  e  $W_t$  representam os fatores sazonais diários e semanais,  $S_t$  é o nível e  $T_t$  a tendência. As constantes de amortecimento são representadas por  $\alpha, \gamma, \delta, \omega, \phi$ . Assim, as equações de atualização para o modelo Holt-Winters multiplicativo com dois ciclos são mostradas na tabela 1 (Taylor, 2003a e Taylor, 2008):

O parâmetros do amortecimento  $\alpha, \gamma, \delta, \omega, \phi$  foram otimizados usando o critério de minimizar o erro de previsão ao quadrado 672 passos à frente (isto é, minimizou-se o erro de previsão 672 passos à frente), utilizando o método de algoritmo genético. Além disso, neste trabalho, a primeira sazonalidade indica o ciclo dentro de dia e a segunda sazonalidade o ciclo dentro da semana.

Nível	$S_t = \alpha \left( \frac{X_t}{D_{t-s_1} W_{t-s_2}} \right) + (1-\alpha)(S_{t-1} + T_{t-1})$
Tendência	$T_t = \gamma(S_t - S_{t-1}) + (1-\gamma)T_{t-1}$
Sazonalidade 1	$D_t = \delta \left( \frac{X_t}{S_t \cdot W_{t-s_2}} \right) + (1-\delta)D_{t-s_1}$
Sazonalidade 2	$W_t = \omega \left( \frac{X_t}{S_t D_{t-s_1}} \right) + (1-\omega)W_{t-s_2}$
Erro	$e_t = y_t - [(S_{t-1} + T_{t-1})D_{t-s_1}W_{t-s_2}]$
Previsão	$\hat{X}_t(k) = (S_t + kT_t)D_{t-s_1+k}W_{t-s_2+k} + \phi^k e_t$

Tabela 1. Equações de atualização e previsão – Holt-Winters com dois ciclos

A formulação expressa acima está representando o modelo de Holt-Winters multiplicativo com dois ciclos sazonais. Contudo, um Holt-Winters aditivo com dois ciclos pode ser desenvolvido de forma similar a partir do método de Holt-Winters aditivo padrão. Além do mais, outros padrões sazonais podem ser acrescentados, bastando para tal incluir o índice sazonal e a equação de amortecimento para cada ciclo adicional.

## 2.2. Algoritmo Genético

Os algoritmos genéticos começaram a ser pesquisados por volta de 1975, contudo, sua eficiência na solução de problemas complexos iniciou-se em torno de 1985, onde ocorreram os principais avanços (Goldberg, 1989).

Seu princípio é baseado na idéia da evolução e da seleção natural, como proposto por Darwin em “A Origem das Espécies”. Assim, na década de 70 vários autores começaram a imitar esse mecanismo da evolução para resolver problemas de várias ordens de complexidade, o que resultou em várias abordagens algorítmicas, compondo então a computação evolucionária, cujos principais tópicos são: as estratégias evolucionárias, a programação evolucionária e os algoritmos genéticos (Goldberg, 1989 e Mitchell, 1996).

Algoritmos genéticos são métodos de busca e otimização estocástica que procuram soluções para problemas complexos ou que tenham espaço de soluções (Espaço de Busca) muito grande. Geralmente, esses problemas são difíceis de serem modelados e solucionados através dos métodos convencionais de otimização.

Assim, baseados nos processos genéticos de organismos biológicos, os algoritmos genéticos procuram soluções ótimas ou sub-ótimas. Isso ocorre da seguinte forma: cada possível solução do problema é codificada, formando uma estrutura denominada cromossomo, que é formada por uma cadeia de bits ou caracteres. Esses cromossomos representam os indivíduos que evoluem através das gerações de acordo com os princípios de seleção natural e sobrevivência dos mais aptos (Lazo, 2000).

Dessa forma, os algoritmos genéticos manipulam uma população formada por indivíduos, na qual cada um representa uma solução candidata para o problema em questão. O espaço de busca ou região viável é a denominação dada ao espaço que engloba todas as soluções candidatas.

Ainda baseando-se na evolução da natureza, a cada indivíduo da população é dado um valor de adaptação que se refere à sua aptidão, indicando assim a qualidade da solução deste indivíduo frente às outras soluções dessa população para resolver o problema em questão. Os indivíduos mais aptos têm a chance de se reproduzirem através de cruzamentos com outros indivíduos da população, gerando, conseqüentemente, descendentes com características de ambos. Novos indivíduos também podem ser introduzidos na população através da mutação, que ocorre de forma aleatória.

Para os problemas de otimização, a função de aptidão equivale à função objetivo do problema, isto é, à função que será otimizada. Assim, os indivíduos ou cromossomos de alta aptidão são aqueles em que a função objetivo a ser minimizada (ou maximizada) possui valores baixos (ou altos).

A evolução começa com a criação aleatória dos indivíduos que irão pertencer à população inicial. Depois os indivíduos são separados para a reprodução (através da seleção baseada na aptidão), criando novas soluções, sendo usado para tal um conjunto de operadores genéticos. Então, será a aptidão do indivíduo quem irá determinar o seu grau de sobrevivência e, conseqüentemente, a chance do cromossomo prosseguir nas próximas gerações. A essência é que os indivíduos gerados possam representar, a cada desenvolvimento, soluções melhores.

Neste processo de otimização através do algoritmo genético também é utilizado um algoritmo de otimização simplex, o qual é usado como ponto inicial da população do algoritmo genético, visando assim melhorar sua convergência.

No algoritmo genético utilizado neste trabalho foi usada a função aritmética para a função *crossover*, na qual os novos indivíduos são criados através de uma média aritmética ponderada, respeitando os limites das variáveis. Para a função mutação (que prover a diversidade genética) foi usada a função gaussiana com variância constante. Com estas definições feitas através das

características da série em questão foram testadas algumas configurações para o tamanho ideal da população e geração, as quais serão apresentadas neste estudo.

### 2.3. Tratamento do Feriado

Assim como em outros países, o Brasil possui uma gama de feriados, sejam eles nacionais ou estaduais, os quais geram um perfil de demanda de carga elétrica totalmente diferente de todos os outros dias do ano. Mesmo assim, não é comum encontrar na literatura metodologia para tratamentos específicos para esses casos. Como citado por Taylor (2003a) e Taylor, Menezes & McSharry (2006), o mais comum é utilizar os métodos de previsão para períodos em que não há feriados.

Na literatura, há algumas publicações que trazem o resultado do tratamento de feriados para aprimorar a acurácia do modelo de previsão (Cancelo, Espasa & Grafe (2007), Cancelo & Espasa (1996), Papalexopoulos & Hesterberg (1990)), tendo esses a idéia básica de detectar padrões no comportamento da demanda nos dias em que houve feriado. Há também alguns autores, como por exemplo: Song et al (2005), Fidalgo & Lopes (2005) e Kim, Youn & Kang (2000), que utilizam técnicas de inteligência artificial para modelar dias que apresentam carga elétrica com comportamentos anormais, como ocorre nos feriados.

No entanto, foi observado que a ocorrência de um feriado distorce não somente a carga desse dia. Dependendo do dia da semana em que o feriado ocorre, ele poderá acarretar modificações no perfil das últimas horas do dia anterior ao feriado e das primeiras horas do dia posterior, como também poderá modificar as características de um dia inteiro ou vários dias antes e após o dia do feriado, como mostrado na figura 1.

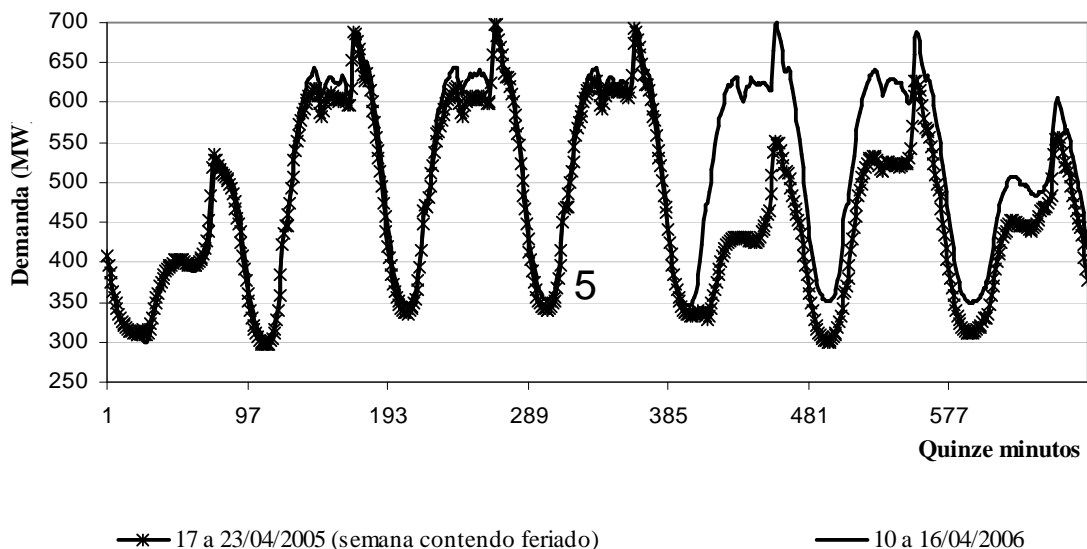


Figura 1. Demanda de carga elétrica em uma semana que ocorreu um feriado e em uma semana em que não houve feriado

Tendo isto em vista, foi desenvolvido um banco de fatores de redução, para ser incorporado ao modelo de previsão de forma exógena, que contém fatores que serão incorporados na previsão da energia, sendo assim capaz de ajustar melhor o modelo, reduzindo o erro de previsão, o que a torna mais precisa.

Como o feriado gera comportamentos distintos ao ocorrer em dias da semana diferentes, foram criadas regras para cada dia da semana, analisando também os dias (ou partes de dias) que são influenciados por esse feriado. Os fatores foram ajustados no mesmo período para o qual a previsão foi realizada, neste caso, para cada 15 minutos.

A metodologia utilizada consiste em verificar a variação percentual de cada quinze minutos existente entre um dia de feriado e o mesmo dia da semana anterior e posterior. Para tal, considerou-se uma semana em torno do dia de feriado. Em seguida, foi analisada a variação percentual entre dias de não feriado, o que foi feito separadamente para cada dia da semana. Sendo que, a distribuição dessa variação, para cada dia da semana, em cada período analisado, indicou uma distribuição normal. Assim, a regra de decisão tornou-se: se a variação de um dia de feriado com relação a um dia de não feriado for superior à  $\mu \pm 1,96\sigma$ , então a variação é significativa. Por fim, foi feita a média de todas as variações significativas (de acordo com o dia da semana que o feriado ocorreu e considerando também seus dias adjacentes), formando assim a base de regras.

Assim foi possível verificar qual a variação aceitável entre dias de não feriado e a variação decorrente do feriado. Com isso, os fatores foram encontrados, em intervalos de quinze minutos, para cada dia da semana em que o feriado ocorreu, e para os dias adjacentes que foram afetados por um dia de feriado. Na figura 2 há um exemplo dos fatores de redução, em percentual, quando ocorre um feriado em uma terça-feira e, também, nos dias que são afetados por ele, que é a segunda e a quarta-feira.

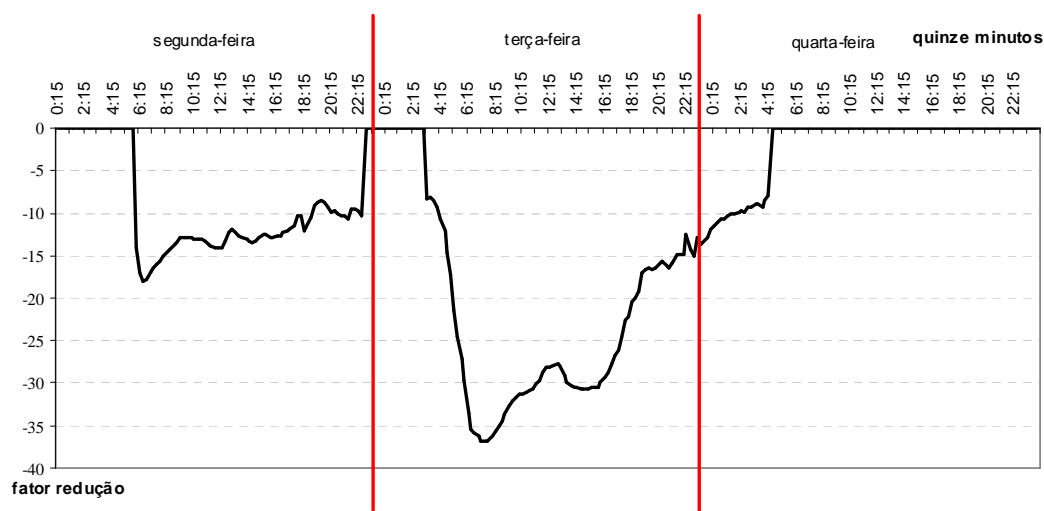


Figura 2. Ocorrência de feriado em uma terça-feira

O tratamento do feriado gerou uma base de regras para cada dia da semana, com exceção dos feriados de Carnaval, Natal e Ano Novo. Para tratar esses dois últimos, verificou-se que o impacto dos feriados de Natal e Ano Novo depende do dia da semana em que esses feriados ocorrem, por isso ambos foram analisados de acordo com o dia de sua ocorrência. Além disso, verificou-se que a ocorrência de feriado em um domingo não afeta significativamente o consumo de energia neste dia.

### 3. Aplicação

Neste estudo foram utilizados dados de carga elétrica de uma importante concessionária de energia elétrica da região sudeste do Brasil e, apenas para manter o caráter confidencial dos dados, eles foram mascarados. Havia disponível uma base de dados de quatro anos de carga elétrica em intervalos de quinze minutos, como mostrado nas figuras 3 a 6, onde é possível comprovar o caráter de dois fatores sazonais desses dados. Com isso, foram avaliados vários períodos usando este modelo e aqui serão apresentados dois exemplos usando dados de julho e setembro de 2005, sendo realizada a previsão para sete dias, na base de quinze minutos, totalizando 672 previsões. Ressalta-se que este modelo foi implementado e testado utilizando o *software* Matlab.

A otimização das constantes de amortecimento e o cálculo dos parâmetros iniciais foram encontrados utilizando uma amostra de um mês imediatamente anterior ao período previsto. Porém, foram testados períodos de um a seis meses, sendo que não foi observada nenhuma melhora com o aumento do tamanho da amostra. Além disso, para o horizonte considerado (7 dias à frente) assumiu-se não ter uma tendência crescimento, sendo então o modelo simplificado retirando-se o termo referente à tendência e passando a ter quatro constantes de amortecimento a serem otimizadas:  $\alpha$ ,  $\delta$ ,  $\omega$  e  $\phi$ .




Figura 3. Série de carga em quatro anos




Figura 4. Série de carga em um mês




Figura 5. Série de carga em uma semana




Figura 6. Série de carga em um dia

A tabela 2 mostra o resultado das otimizações para prever o período de 15 a 29 de julho de 2005, contendo os parâmetros usados na função não linear e no algoritmo genético. Também é apresentado o MAPE (erro médio percentual absoluto) dentro da amostra, sendo utilizado para tal o período de 15 de junho a 14 de julho de 2004. Ainda é exibido os valores otimizados das constantes de amortecimento. Analisando o resultado, conclui-se que a melhor configuração para o processo de otimização é com iterações e funções avaliadas de 300 cada uma e população e geração de tamanho, respectivamente, 40 e 80.

A figura 7 mostra a carga observada e prevista para o período de 15 a 29 de julho de 2005 usando a melhor configuração da tabela 2.

A figura 7 mostra que o modelo apresentou um bom desempenho. O MAPE para todo o período foi 0,98%, sendo o MAPE do modelo NAIVE 1,29%. A figura 8 mostra o MAPE em cada hora durante os sete dias previstos, sendo seu desempenho diferente em cada hora do dia. Claramente, os maiores erros estão nas previsões dentro do intervalo das 16 às 19 horas, o que corresponde ao horário pico da carga elétrica no sistema.

Função Não Linear		Algoritmo Genético		MAPE dentro da amostra	$\alpha$	$\delta$	$\omega$	$\phi$
Iterações	Funções Avaliadas	População	Gerações					
200	200	40	40	1,034	0,0033	0,1328	0,4113	0,5365
100	100	40	40	1,019	0,0043	0,1577	0,2709	0,5689
300	300	40	40	1,008	0,0035	0,1478	0,2442	0,8078
300	300	40	80	0,984	0,0038	0,1476	0,2461	0,8103
200	200	40	80	1,003	0,0040	0,1345	0,3216	0,8961
100	100	40	80	0,999	0,0041	0,1651	0,2116	0,6227

Tabela 2. Resultados das otimizações para previsão de 15 a 29 de julho de 2005

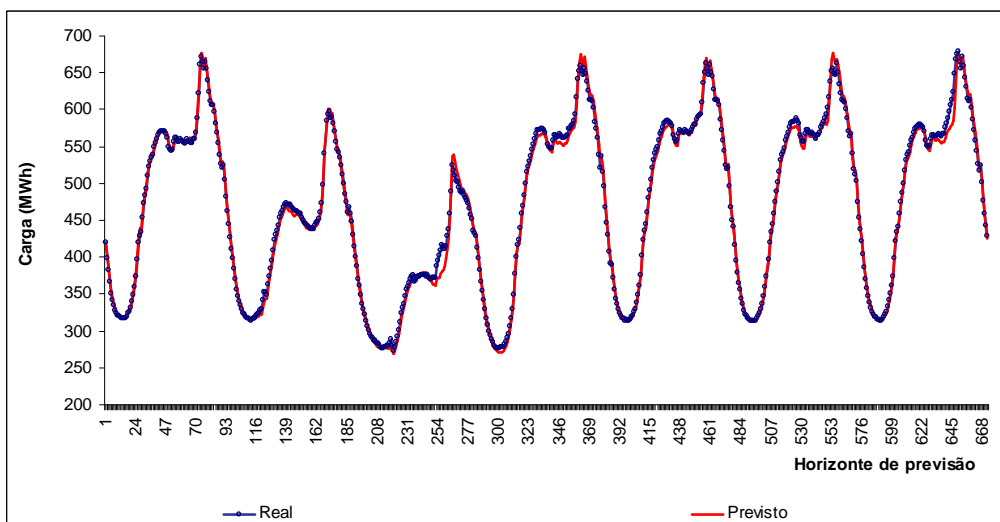


Figura 7. Demanda de carga elétrica prevista e realizada para 15 a 29 de julho de 2005




Figura 8. MAPE horário



A figura 9 apresenta o MAPE diário. Nela, pode-se ver que não há uma tendência de aumento na MAPE à medida que aumenta o horizonte de previsão, sendo esta uma característica importante de que a previsão não se deteriorou ao longo do tempo.




Figura 9. MAPE diário

Esta análise foi repetida usando o mês de agosto de 2005 para prever os sete primeiros dias de setembro de 2005. Os hiperparâmetros otimizados (foi feita a mesma análise do exemplo anterior para definir a melhor otimização, sempre a configuração escolhida igual a daquele exemplo) são  $\alpha = 0.0071$ ,  $\delta = 0.1780$ ,  $\omega = 0.0741$  e  $\phi = 0.8119$ . Este período foi escolhido para testar os fatores de redução a serem aplicados em feriados, pois 7 de setembro é feriado nacional no Brasil e, com isso, será possível analisar o efeito da correção do feriado.

A figura 10 mostra que realmente o ajuste desse período foi pior que o do anterior, especialmente ao analisar o dia do feriado. O MAPE do período foi de 6,25%, sendo que o MAPE apenas do dia do feriado foi 29,09%. O MAPE do modelo NAIVE para todo o período foi 6,40%.

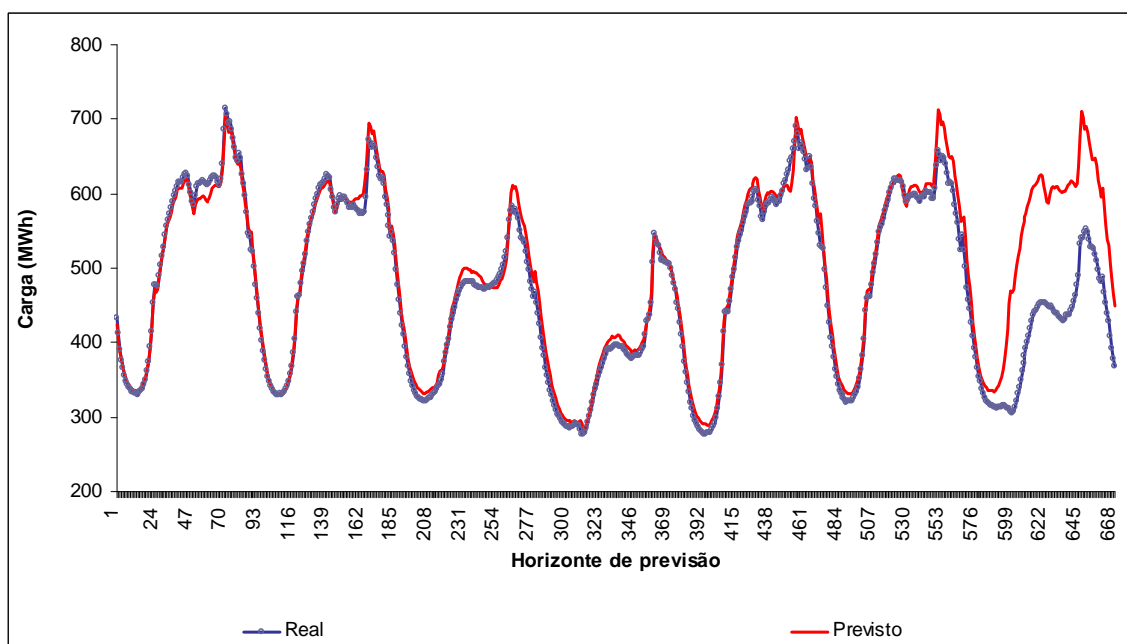


Figura 10. Demanda de carga elétrica realizada e prevista para 1 a 7 de setembro de 2005

Aplicando a correção devido ao feriado, o MAPE do período foi reduzido para 4,04%, sendo que o do dia do feriado foi para 13,68%. Nas figuras 11 e 12 temos o MAPE horário e o diário para a previsão sem e com a correção do feriado.

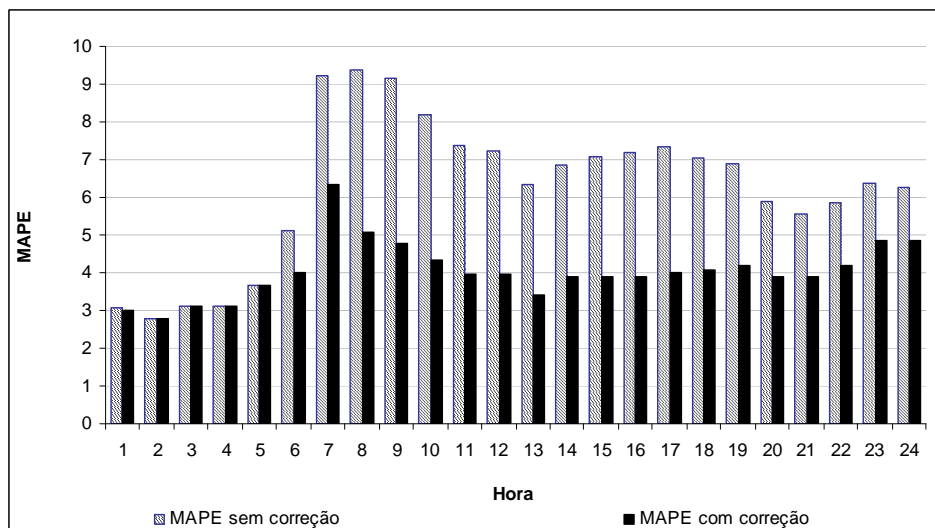


Figura 11. MAPE horário, previsão sem e com correção do feriado

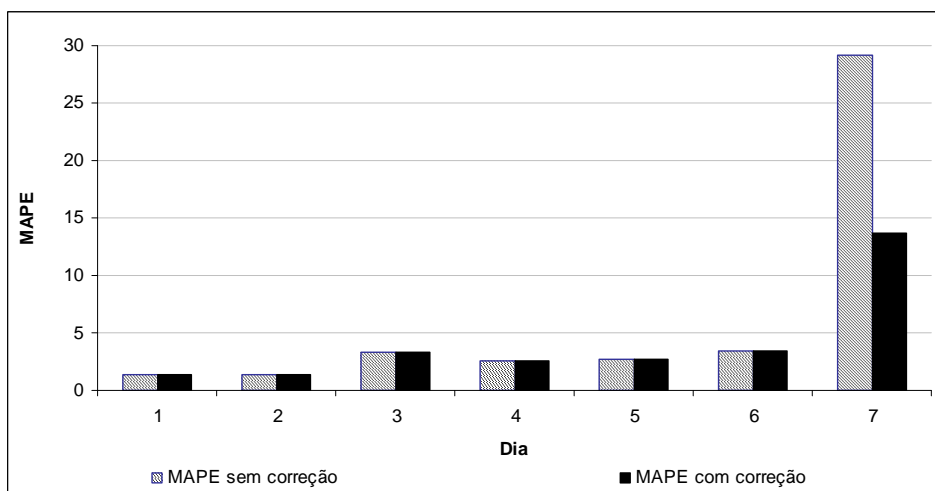


Figura 12. MAPE diário, previsão sem e com correção do feriado

#### 4. Conclusão

Neste artigo foi apresentado uma aplicação do modelo de Holt-Winters com dois ciclos para previsão a cada quinze minutos, sete dias à frente, totalizando 672 passos à frente, para dados da região sudeste do Brasil. O modelo foi testado e exemplificado aqui em dois períodos, considerando, em um deles, a ocorrência de feriado e sua correção. Além da correção do feriado, foi também mostrada a correção dos dias adjacentes que são afetados pelo feriado.

De modo geral, o modelo de Holt-Winters com dois ciclos apresentou resultados bastante satisfatórios, não evidenciando nenhuma deterioração à medida em que o horizonte de previsão aumenta, mostrando bons desempenhos para os períodos previstos.

Ao comparar a correção do feriado, considerando apenas o dia em que este ocorreu, percebe-se que a base de regras montada foi eficiente, pois melhorou a acurácia da previsão.

Estes resultados são considerados promissores e espera-se que eles podem ser melhorados principalmente através da inclusão de dados meteorológicos. Tendo isto em vista, estamos trabalhando com dados de temperatura, criando um modelo para corrigir os efeitos desta variável ao longo da série de carga elétrica.

## 5. Referências:

- Cancelo, J. R., Espasa, A.** (1996). *Modelling and Forecasting Daily Series of Electricity Demand*. *Investigaciones Economicas*, 20 (3), 359 – 376.
- Cancelo, J. R., Espasa, A., Grafe, R.** (2007). *Eighteen-years' experience in data adjustment and forecasting daily and hourly electricity consumption*. 4<sup>th</sup> International Institute of Forecasters' Workshop, Rio de Janeiro – Brasil.
- Cipra, T., Trujillo, J. & Rubio, A.** (1995). Holt-Winters Meted with Missing Observations. *Management Science*, 41 (1), 174 – 178.
- Fidalgo, J.N., Lopes, J.P.** (2005). *Load forecasting performance enhancement when facing anomalous events*. *IEEE Transactions on Power Systems*, 20 (1), 408-415.
- Goldberg, D. E.** *Genetic Algorithms in Search, Optimization and Machine Learning*. Addison-Wesley Reading, MA, 1989.
- Grubb, H., Mason, A.** (2001). Long lead-time forecasting of UK air passengers by Holt-Winters methods with damped trend. *International Journal of Forecasting*, 17 (1), 71 – 82.
- Kim, K., Youn, H., Kang, Y.** (2000). *Short-term load forecasting for special days in anomalous load conditions using neural networks and fuzzy inference method*. *IEEE Transactions on Power Systems*, 15 (2), 559-565.
- Lazo, J. G. L.**, Sistema híbrido genético-neural para montagem e gerenciamento de carteiras de ações, dissertação de mestrado, DEE, PUC-Rio, agosto 2000.
- Mitchell, M.** *An Introduction to Genetic Algorithms*. MIT Press, 1996.
- Papalexopoulos, A. D., Hesterberg, T. C.** (1990). *A regression-based approach to short-term system load forecasting*. *IEEE Transactions on Power Systems*, 5 (4), 1535-1547.
- Song, K., Baek, Y., Hong, D.H. & Jang, G.** (2005). *Short-term load forecasting for the holidays using fuzzy linear regression method*. *IEEE Transactions on Power Systems*, 20 (1), 96-101.
- Taylor, J. W.** (2003a). *Short-term electricity demand forecasting using double seasonal exponential smoothing*. *Journal of Operational Research Society*, 54, 799-805.
- Taylor, J. W.** (2003b). *Exponential Smoothing with a Damped Multiplicative Trend*. *International Journal of Forecasting*, 19, 715-725.
- Taylor, J. W., Menezes, L. M. de, McSharry, P. E.** (2006). *A comparison of univariate methods for forecasting electricity demand up to a day ahead*. *International Journal of Forecasting*, 22, 1 – 16.
- Taylor, J. W.** (2008). *An evaluation of methods for very short-term load forecasting using minute-by-minute British data*. *International Journal of Forecasting*, 24, 645 – 658.
- Williams, T. M.** (1987). *Adaptative Holt-Winters Forecasting*. *The Journal of the Operational Research Society*, 38 (6), 553 – 560.