

## PREVISÃO DE CARGA GLOBAL – UMA COMPARAÇÃO DE MÉTODOS PARA O PROGRAMA MENSAL DE OPERAÇÃO

**Ana Paula Oening<sup>1</sup>**  
ana.oening@lactec.org.br

**Daniel Henrique Marco Detzel<sup>1</sup>**  
daniel@lactec.org.br

**Lucio de Medeiros<sup>1</sup>**  
lucio.medeiros@lactec.org.br

**Helon Vicente Hultmann Ayala<sup>1</sup>**  
helon.ayala@lactec.org.br

**Débora Cintia Marcilio<sup>1</sup>**  
debora@lactec.org.br

**Alexandre Rasi Aoki<sup>1</sup>**  
aoki@lactec.org.br

**Jefferson Marcelo Schiochet<sup>2</sup>**  
jefferson.schiochet@copel.com

**Rafael Arsie Guimarães<sup>2</sup>**  
rafael.guimaraes@copel.com

<sup>1</sup>LACTEC – Instituto de Tecnologia para o  
Desenvolvimento  
Divisão de Sistemas Elétricos  
Curitiba, Paraná, Brasil

<sup>2</sup>COPEL – Companhia Paranaense de Energia  
Departamento de Mercado  
Curitiba, Paraná, Brasil

### RESUMO

O objetivo deste trabalho é propor uma metodologia de integração entre previsões diárias e semanais para o estudo do programa mensal de operação eletro energética (PMO), especificamente para a revisão semanal do mesmo. Foram utilizados diferentes métodos, entre modelos clássicos e modelos de inteligência artificial para gerar essas previsões, de forma que o usuário possa escolher a previsão final dentre os seis modelos disponíveis. Os resultados se mostraram bastante satisfatórios e a utilização de dados recentes agrega informações que melhoram o desempenho dos métodos.

**PALAVRAS CHAVE.** Previsão de carga; PMO; Amortecimento Exponencial; Modelos SARIMA; Redes Neurais.

**Área principal:** PO na área de energia

### ABSTRACT

The objective of this paper is propose a methodology of integration between daily and weekly forecasts for the study of the monthly operating electrical energy (PMO-Programa

Mensal da Operação Energética), specifically for the weekly review of the same. Using different methods, between classical models and models of artificial intelligence, for generate these predictions and the user can choose the final forecast of the six models available. The results were very satisfactory and the use of recent data adds information to improve the performance of the methods.

**KEYWORDS.** Load forecast. PMO. Exponential Smoothing. SARIMA Models. Neural Networks.

**Main area:** PO in energy

## 1. Introdução

Previsão da carga elétrica é muito importante para a operação e o planejamento do sistema elétrico. Para uma distribuidora de energia elétrica, a previsão de carga é essencial na sua operação diária, no planejamento de sua infraestrutura e para compra de energia, impondo o desenvolvimento de modelos de previsão adequados aos diversos horizontes de previsão.

As mais variadas metodologias para previsão de carga vêm sendo desenvolvidas e testadas nas últimas décadas em todo o mundo (Bunn e Farmer, 1985; Feinberg e Genethliou, 2005; Campbell e Adamson, 2006). Não existe, entretanto, um único modelo para tratar este problema. As aplicações usam tanto métodos lineares, tais como Box-Jenkins (Paretkar *et al.*, 2010; Cho *et al.*, 1995; Box *et al.*, 1994) e Amortecimento Exponencial (Taylor, 2012; Gardner, 2006), quanto métodos não lineares, e.g. redes neurais (Park *et al.*, 1991; AlFuhaid *et al.*, 1997) e fuzzy (Sachdeva, 2008; Hinojosa, 2010). Modelos híbridos e variantes dos modelos clássicos têm também obtido bons resultados quando usados para previsão de carga (Taylor, 2003; Lee e Tong, 2012; Pandey *et al.*, 2010; Yun *et al.*, 2008; Bakirtzis *et al.*, 1995).

Quanto ao horizonte de previsão, no curtíssimo prazo (minutos, horas e dias à frente) é comum o uso de métodos de inteligência artificial, especialmente devido à maior quantidade de dados disponíveis e, muitas vezes, pequeno conhecimento sobre o processo gerador, além da possibilidade de se melhor mapear a relação não linear da carga com variáveis climáticas ou econômicas (Qingle e Min, 2010).

No curto e médio prazos (semanas, meses e alguns anos à frente), por sua vez, o problema é usualmente tratado com uma abordagem estatística (Barakat e Al-Qasem, 1998), mas outras abordagens também são comuns (Soares e Medeiros, 2008).

Para o longo prazo (acima de dez anos) os modelos de uso final e os econométricos (ou suas combinações) são os mais empregados, pois permitem incluir, por exemplo, a descrição dos eletrodomésticos usados pelos consumidores e a idade dos equipamentos, tamanho das residências, comportamento dos consumidores, além da dinâmica da população expressa através de variáveis exógenas, tais como PIB e população (Granger e Jeon, 2007). Existem, também, alguns métodos que propõem uma decomposição da carga anual em fatores, tais como coeficientes de sazonalidade do dia útil, ponderação diária e modulação horária, obtendo-se assim as 8.760 demandas médias horárias previstas para todo o ano (Sobral *et al.*, 2001).

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 eletro energética e programação de intervenções em instalações da rede de operação, planejamento anual da operação energética e para o programa mensal da operação.

### ***Programa Mensal da Operação Eletro Energética (PMO)***

O Operador Nacional do Sistema (ONS), em particular, realiza o Programa Mensal da Operação Eletro Energética (PMO), que estabelece as diretrizes eletro energéticas de curto prazo, de modo a otimizar a utilização dos recursos de geração e transmissão do Sistema Interligado Nacional (SIN). Para realização do PMO são solicitadas aos agentes de distribuição previsões

globais da concessionária (ONS, 2010). O foco deste artigo é voltado às previsões de carga e demanda necessárias para o PMO.

Para atender aos objetivos do PMO, as distribuidoras brasileiras têm desenvolvido internamente seus modelos de previsão e poucas soluções foram propostas. Dentre elas, está o sistema PREVCAR, um dos sistemas de previsão da cadeia oficial de programas do Setor Elétrico Brasileiro, desenvolvido para o ONS (Macrini, 2000). Este sistema combina as duas melhores previsões da carga mensal entre dois modelos lineares (Box-Jenkins e Holt-Winters) e dois modelos não lineares (Redes Neurais e Fuzzy) para, em seguida, desagregar a carga em base semanal, diária e por patamar.

De acordo com Mendes (2002), com a crise brasileira de abastecimento de energia elétrica no ano de 2001, os modelos de previsão do sistema PREVCAR perderam a sua eficiência preditiva. O autor propõe identificar e eliminar os efeitos do racionamento de energia elétrica nas modelagens lineares Box-Jenkins e Holt-Winters trabalhando com a série de carga dessazonalizada e estimando taxas de crescimento pós-acionamento via Filtro de Kalman. Ferreira (2004), por sua vez, propõe a eliminação do efeito do racionamento nos modelos do sistema PREVCAR através da estimação de fatores de redução das previsões causados pelo racionamento utilizando Mapas Auto Organizáveis de Kohonen.

O PMO pode ser dividido em duas fases: PMO-Mensal e PMO-Revisão. No PMO-Mensal, são necessárias previsões de carga de energia ativa global, mensal e semanal, e em patamares de carga (leve, média e pesada), em MW médios. Os patamares de carga são definidos de acordo com os horários e tipo de dias. Também devem ser enviadas previsões de carga de demanda ativa, mensal e semanal, nas condições de carga de ponta e fora de ponta, em MW. Para as previsões semanais, devem ser consideradas semanas operativas (SO). As semanas operativas são definidas como o período que se inicia às 0h do sábado e termina às 24h da sexta-feira subsequente, de forma a conter todos os dias do mês de referencia do estudo.

O PMO-Revisão é realizado quando o mês de referencia se inicia. A cada semana, em geral na quarta-feira, são realizadas revisões para as demais previsões do mês vigente. O esquema de realização das revisões é apresentado na Figura 1, onde pode ser verificado que, no envio das revisões semanais, as previsões são baseadas em dados ainda não realizados. Por exemplo, na primeira revisão (em 05/10) a concessionária possui dados realizados até o dia 04/10 e precisa enviar a previsão para as SOs 2, 3, 4 e 5, que iniciam a partir do dia 08/10. Dessa forma, os três dias entre o último dado realizado e o primeiro dia da semana a ser previsto também necessitam de previsão.




Figura 1. Esquema de envio do PMO Revisão

## 2. METODOLOGIA

A metodologia desenvolvida para este artigo propõe uma combinação entre previsões diárias e semanais, para resolver a questão dos dias ainda não realizados quando da execução da revisão semanal. Primeiro, são realizadas previsões diárias e, com o resultado dessas previsões é realizada a composição da semana operativa vigente. Com a semana composta, é realizada a previsão semanal para as demais semanas operativas do mês.

Para exemplificar (Figura 1), se o analista está realizando a primeira revisão semanal, no dia 05/10, são realizadas previsões diárias de carga, demanda na ponta e demanda fora de ponta para os dias 05, 06 e 07/04. Com os resultados dessas previsões é realizada a composição da primeira semana operativa. Utilizando esse dado, são realizadas as previsões para as demais

semanas operativas do mês de abril. Essa metodologia foi desenvolvida de forma a utilizar os dados realizados disponíveis em seu período mais recente.

Para cada etapa de previsão, diária e semanal, foram utilizados seis métodos, sendo que três são modelos clássicos e três são modelos de inteligência artificial. As formulações utilizadas para os modelos são apresentadas na próxima seção. Os métodos utilizados foram Amortecimento Exponencial (AE), Box-Jenkins, Regressão Dinâmica (RD), Rede Neural de Múltiplas Camadas (RN-MLP), Rede Neural de Base Radial (RN-RBF) e Previsor *Fuzzy* (*Fuzzy*)

A Figura 2 apresenta um esquema geral da metodologia de previsão. Inicialmente, são compostas as séries diárias e semanais de dados históricos, obtidas a partir de dados horários de demanda (MWh/h). Na sequência são realizadas as previsões diárias pelos seis métodos citados anteriormente. Com base nesses seis resultados, o usuário escolhe uma das previsões. A previsão diária escolhida é composta aos dados diários realizados da semana operativa vigente. Com a semana composta mais a série histórica semanal, são realizadas as previsões semanais para as demais semanas operativas do mês. Da mesma forma que para a previsão diária, são gerados seis resultados de previsão e o usuário escolhe a previsão final.



Figura 2. Fluxograma geral da metodologia de previsão

Para cada um dos tipos de previsão, diária e semanal, são realizadas previsões para a carga, demanda nos horários de ponta e fora de ponta. Dessa maneira, as variáveis para a previsão diária são a carga  $C_{dia}$  (MWmed), demanda no período da ponta  $DP_{dia}$  (MWh/h) e demanda no período fora de ponta  $DFP_{dia}$  (MWh/h). Para as previsões semanais, as variáveis são a carga  $C_{sem}$  (MWmed), demanda no período de ponta  $DP_{sem}$  (MWh/h) e demanda fora de ponta  $DFP_{sem}$  (MWh/h). Cada uma dessas variáveis tem sua metodologia de previsão de acordo com o esquema apresentado na Figura 2.

### 3. Estudo de caso

Os dados utilizados neste trabalho foram fornecidos pelo Departamento de Mercado de Energia (DEME) da Companhia Paranaense de Energia (COPEL). A série histórica é a mesma utilizada para os estudos do PMO da companhia e envolvem o período de janeiro de 2006 a novembro de 2011, com dados em base horária. A partir dos dados horários, são geradas as séries necessárias para a previsão, três em base semanal (semanas operativas) e três em base diária.

As séries semanais geradas possuem 304 semanas operativas, da primeira semana operativa de jan/06 até a última semana operativa de out/11. A Figura 3 mostra um gráfico das séries semanais  $C_{sem}$ ,  $DP_{sem}$  e  $DFP_{sem}$ . Essas séries possuem tendência positiva e são marcadas por uma sutil mudança de comportamento a partir da semana operativa 150 (próximo ao início do ano de 2009).

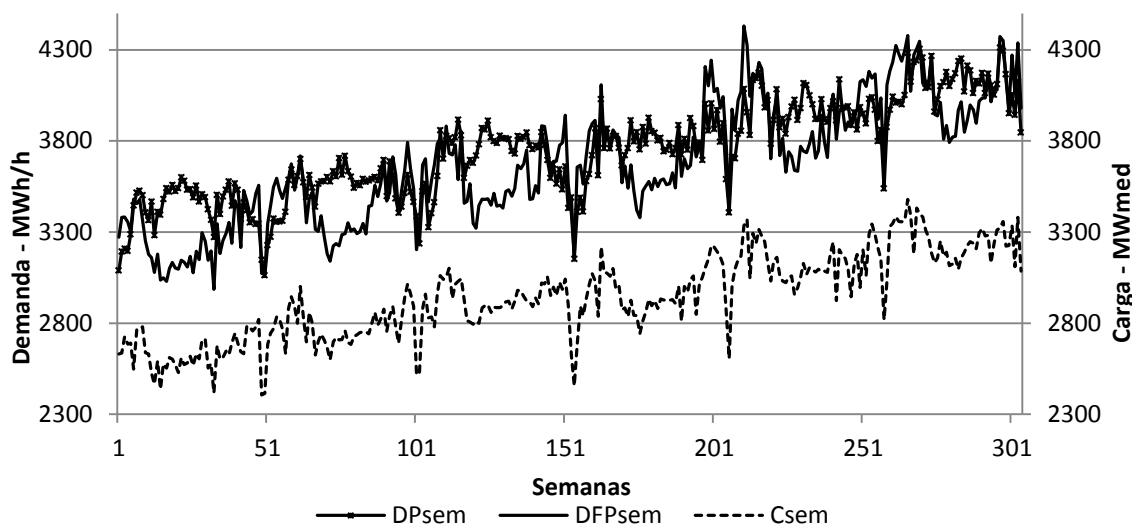


Figura 3. Séries Históricas Semanais

A Figura 4 apresenta uma amostra (últimos 200 dias) das séries diárias  $Cdia$ ,  $DPdia$  e  $DFPdia$  utilizadas neste trabalho. Essas séries possuem 2.134 dias, do dia 01/01/06 ao dia 04/11/11 e também apresentam leve tendência positiva.

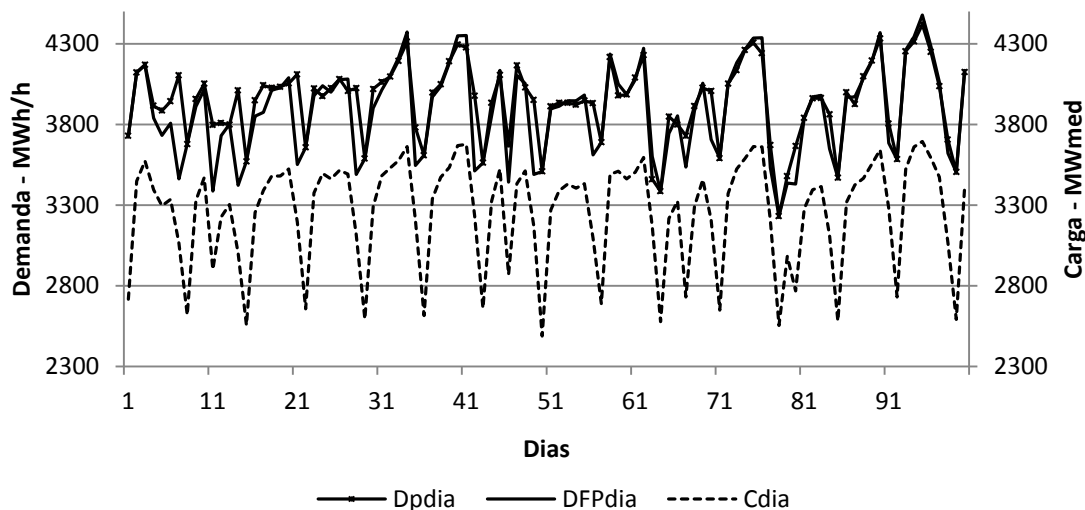


Figura 4. Amostra das Séries Históricas Diárias

De interesse ao ajuste da formulação Box-Jenkins, é necessário avaliar a condição de estacionariedade estatística das séries em questão. Como dito, todas possuem tendência positiva e, portanto, são não estacionárias na média. No que diz respeito à variância, essa conclusão não é direta e uma verificação formal é necessária. Para tanto, foi aplicado o teste de Levene com significância de 95%. Para todas as séries, semanais e diárias, o teste falhou em rejeitar a hipótese de não estacionariedade.

Dadas as primeiras análises, os modelos para previsão foram ajustados. A Tabela 1 mostra as formulações resultantes para os modelos de Box-Jenkins e de Amortecimento Exponencial. Especificamente para o Box-Jenkins, a indicação de estacionariedade na variância das séries dispensa a aplicação de transformações numéricas aos dados. No entanto, notou-se que os erros de previsão foram minimizados quando se ajustaram os modelos Box-Jenkins sobre os logaritmos das séries.

Tabela 1. Formulações resultantes para modelos de Box-Jenkins e de Amortecimento Exponencial

	<b>Box-Jenkins</b>	<b>Amortecimento Exponencial</b>
<i>Csem</i>	ARIMA(1,1,1)*(1,0,1)	Aditivo com tendência linear
<i>DPsem</i>	ARIMA(0,1,1)*(1,0,1) com transformação logarítmica	Aditivo com tendência linear
<i>DFPsem</i>	ARIMA(0,1,1)*(1,0,2) com transformação logarítmica	Aditivo com tendência linear
<i>Cdia</i>	ARIMA(1,0,0)*(1,1,1)	Aditivo sem tendência
<i>DPdia</i>	ARIMA(1,1,1)*(1,1,1) com transformação logarítmica	Multiplicativo sem tendência
<i>DFPdia</i>	ARIMA(1,1,1)*(1,1,2) com transformação logarítmica	Multiplicativo sem tendência

Para os métodos de inteligência artificial previsão é realizada sempre um passo a frente. Dessa maneira, para as previsões mais passos a frente são utilizadas as previsões imediatamente anteriores como entradas. Além disso, são utilizadas algumas variáveis exógenas, assim como no método de Regressão Dinâmica, conforme descrito na Tabela 2. Os atrasos tanto das variáveis exógenas quanto da própria série foram selecionados por um método de seleção automática das entradas (Ferreira, 2008), no caso dos métodos de inteligência artificial.

Tabela 2. Entradas Exógenas

	<b>Variáveis Utilizadas</b>
<i>Csem</i>	n° de feriados na semana n° dias ponte na semana n° de dias uteis na semana considerando dias ponte temperatura média
<i>DPsem</i>	n° de feriados na semana temperatura máxima
<i>DFPsem</i>	temperatura máxima
<i>Cdia</i>	tipo de dia da semana feriado pontes pré-pós feriado temperatura média temperatura mínima
<i>DPdia</i>	tipo de dia da semana feriado pontes pré-pós feriado temperatura média temperatura mínima
<i>DFPdia</i>	tipo de dia da semana feriado pontes pré-pós feriado temperatura média temperatura mínima

#### 4. Resultados

Os resultados obtidos pelos vários métodos utilizados estão detalhados a seguir. As Figuras 5, 6 e 7 mostram os ajustes das previsões para as três variáveis de periodicidade semanal. Conforme descrito anteriormente, foram utilizados seis modelos de previsão e, analisando estes resultados, o usuário escolhe o modelo final.

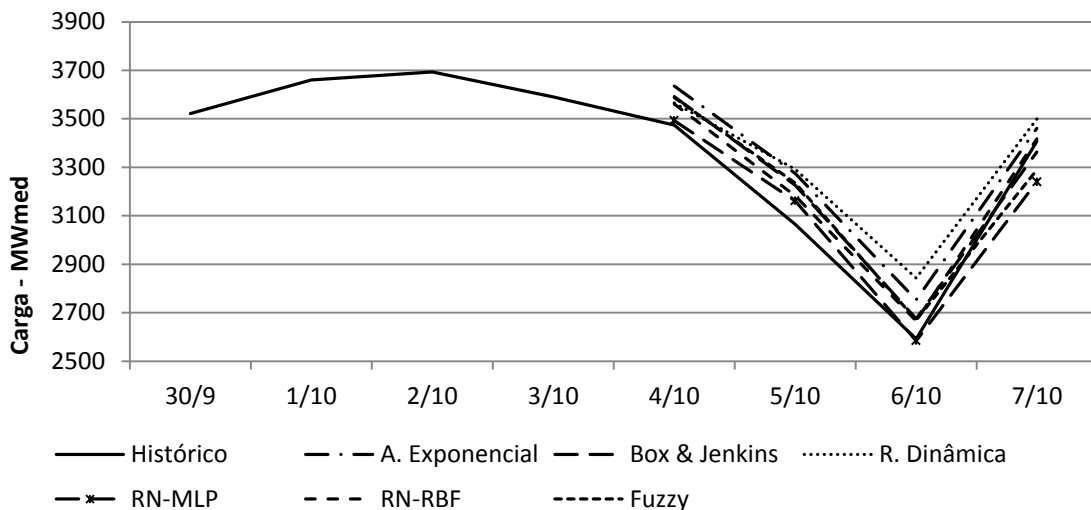


Figura 5 – Resultados das previsões para *Cdia*

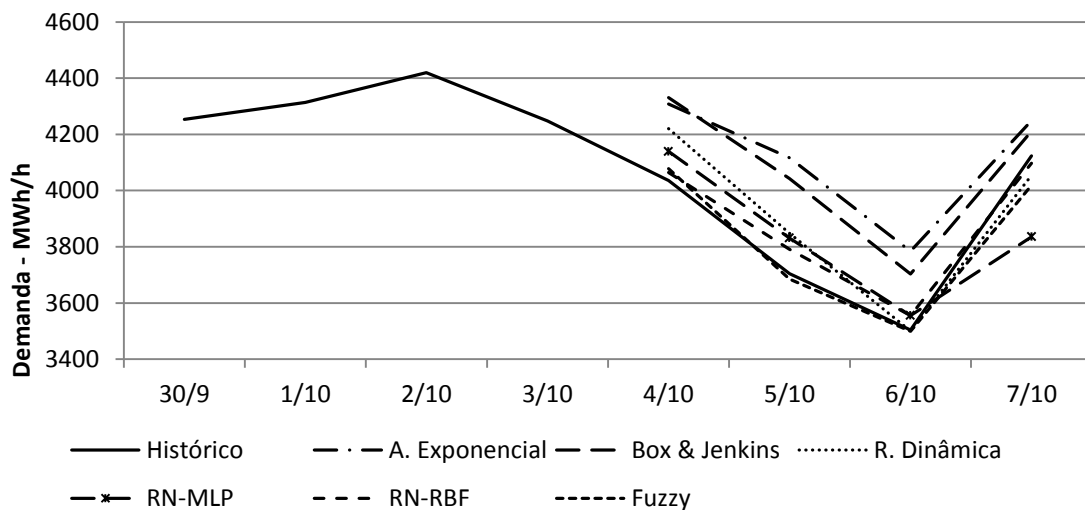


Figura 6 – Resultados das previsões para *DPdia*

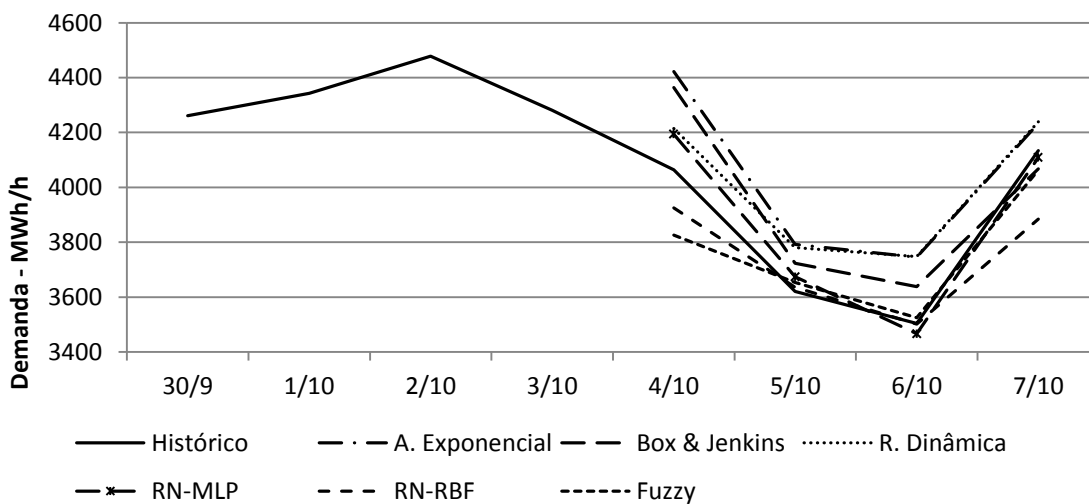


Figura 7 – Resultados das previsões para *DFPdia*

A Tabela 3 mostra os erros percentuais de previsão de cada um dos métodos para as previsões diárias. Erros positivos e negativos representam, respectivamente, previsões abaixo e acima dos valores realizados. A estatística MAPE (sigla do inglês *mean absolut percentage error*) indica o erro percentual médio absoluto de todas as previsões, para cada modelo, destacado em negrito está o modelo que melhor respondeu a cada uma das variáveis de previsão.

De um modo geral, pode-se considerar que todas as previsões em escala diária foram satisfatórias. Os métodos de inteligência artificial tiveram um desempenho ligeiramente acima dos métodos clássicos de previsão, principalmente nas previsões de demanda. O método RN-MLP se destacou, obtendo o menor MAPE para duas variáveis de previsão.

Tabela 3. Erros percentuais das previsões mensais

	Método\Dia	04/10	05/10	06/10	07/10	MAPE
<i>Cdia</i>	A. Exponencial	-4,64%	-6,85%	-6,25%	-1,59%	4,83%
	Box-Jenkins	-3,38%	-5,25%	-3,21%	1,27%	3,28%
	R. Dinamica	-2,60%	-7,41%	-9,70%	-2,71%	5,61%
	<b>RN-MLP</b>	-0,54%	-3,13%	0,27%	4,89%	<b>2,21%</b>
	RN-RBF	-2,48%	-3,80%	-2,89%	-0,32%	2,37%
	Fuzzy	-3,26%	-5,53%	-3,00%	3,47%	3,81%
<i>DPdia</i>	A. Exponencial	-6,75%	-11,12%	-7,99%	-3,03%	7,22%
	Box-Jenkins	-7,30%	-9,11%	-5,68%	-2,13%	6,05%
	R. Dinamica	-4,58%	-3,86%	0,09%	1,70%	2,56%
	RN-MLP	-2,56%	-3,40%	-1,47%	6,99%	3,61%
	RN-RBF	-0,70%	-2,33%	-1,44%	0,63%	1,27%
	<b>Fuzzy</b>	-1,05%	0,53%	0,14%	2,56%	<b>1,07%</b>
<i>DFPdia</i>	A. Exponencial	-8,83%	-4,74%	-6,89%	-2,39%	5,71%
	Box-Jenkins	-7,40%	-2,86%	-3,82%	1,61%	3,92%
	R. Dinamica	-3,70%	-4,43%	-6,96%	-2,54%	4,41%
	<b>RN-MLP</b>	-3,19%	-1,48%	1,07%	0,62%	<b>1,59%</b>
	RN-RBF	3,42%	-0,42%	0,06%	6,06%	2,49%
	Fuzzy	5,86%	-0,92%	-0,61%	1,72%	2,28%

Considerando que os métodos escolhidos pelo usuário para as previsões de *Cdia*, *DPdia* e *DFPdia* foram, respectivamente, RN-MLP, Fuzzy e RN-MLP. Com base nesses resultados é realizada a composição da primeira semana operativa do mês, nesse caso com dados realizados do dia 01 ao dia 03/10 e dados previstos do dia 04 ao dia 07/10. Com o resultado dessa composição e as demais semanas históricas é realizada a previsão para as semanas operativas 2 a 5. Os resultados das previsões semanais são mostrados nas figuras 8, 9 e 10.




Figura 8 – Resultados das previsões para *Csem*






Figura 9 – Resultados das previsões para *DPsem*

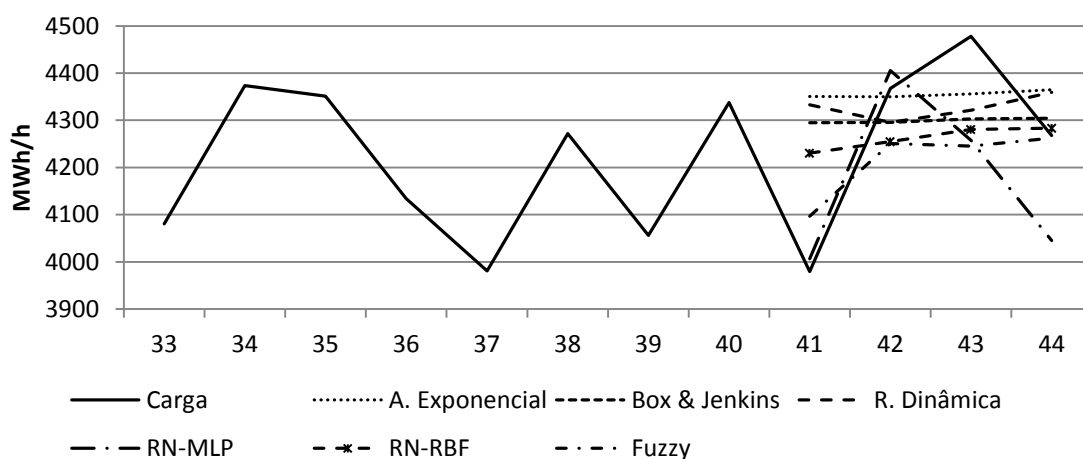


Figura 10 – Resultados das previsões para *DFPsem*

Os erros obtidos nas previsões semanais são apresentados na Tabela 4. Da mesma forma, os erros positivos indicam previsões acima do valor realizado e vice-versa. O MAPE traduz o erro percentual médio absoluto para cada modelo. Os melhores modelos, segundo o MAPE, estão destacados em negrito.

Tabela 4. Erros percentuais das previsões mensais

	Método\Dia	SO 2	SO 3	SO 4	SO 5	MAPE
<i>Csem</i>	A. Exponencial	-7,72%	-4,56%	-1,16%	-4,19%	4,41%
	Box&Jenkins	-7,16%	-3,25%	-0,03%	-3,26%	3,42%
	R. Dinamica	-2,58%	-1,49%	0,55%	-4,30%	2,23%
	RN-MLP	-2,50%	-1,16%	3,57%	0,69%	1,98%
	<b>RN-RBF</b>	-3,26%	-0,24%	3,76%	-0,24%	<b>1,87%</b>
	Fuzzy	-1,47%	-0,44%	0,81%	-4,91%	1,91%
<i>DPsem</i>	A. Exponencial	-4,61%	3,72%	5,32%	2,46%	4,03%
	Box&Jenkins	-4,39%	4,12%	5,59%	2,15%	4,06%
	R. Dinamica	-3,16%	2,11%	6,14%	2,18%	3,40%
	RN-MLP	-2,63%	3,32%	4,49%	1,65%	3,02%
	RN-RBF	-4,31%	1,25%	5,36%	-0,94%	2,97%
	<b>Fuzzy</b>	-3,18%	3,25%	5,00%	0,10%	<b>2,88%</b>

	Método\Dia	SO 2	SO 3	SO 4	SO 5	MAPE
DFPsem	A. Exponencial	-9,32%	0,41%	2,73%	-2,28%	3,69%
	Box&Jenkins	-7,93%	1,65%	3,91%	-0,87%	3,59%
	R. Dinamica	-8,87%	1,65%	3,50%	-2,15%	4,04%
	RN-MLP	-0,69%	-0,86%	4,93%	5,21%	2,92%
	RN-RBF	-6,30%	2,59%	4,42%	-0,37%	3,42%
	Fuzzy	-2,95%	2,68%	5,20%	0,11%	2,73%

Para as previsões semanais, todos os modelos obtiveram resultados satisfatórios, no entanto novamente os métodos de inteligência artificial tiveram um desempenho levemente superior.

## 5. Conclusões

O presente artigo apresentou os resultados obtidos com a utilização de diferentes métodos de previsão de carga para gerar resultados de previsão para o programa mensal da operação (PMO). O objetivo deste trabalho é realizar as previsões para a revisão semanal, integrando previsões diárias com previsões semanais.

A utilização de vários modelos, seis no total, foi de fundamental importância para o desenvolvimento deste trabalho, tornando a participação do analista indispensável para a escolha do melhor resultado. Os resultados mostraram que as técnicas de inteligência artificial tiveram um desempenho superior as técnicas clássicas nos estudos diários. Esse comportamento também se repetiu nas previsões semanais, no entanto a diferença entre os resultados nesse caso não foi tão grande.

Com a integração entre a previsão diária e a previsão semanal é possível a utilização das realizações mais recentes dos dados, agregando informações importantes para os estudos de previsão.

## Agradecimentos

O trabalho desenvolvido neste artigo é parte integrante de uma etapa de um projeto de pesquisa e desenvolvimento intitulado Sistema de Previsão Integrada de Mercado de Energia Elétrica (SPIM), desenvolvido pelo Instituto de LACTEC, financiado pela COPEL e regulado pela Agencia Nacional de Energia Elétrica (ANEEL).

## Referências

- Alfuhaid, A.S.; El-Sayed, M.A.; Mahmoud, M. S.** (1997), Cascaded artificial neural networks for short-term load forecasting. *IEEE Transactions on Power Systems*, vol. 12, n.4, p.1524 – 1529.
- Bakirtzis, A.G.; Theocharis, J.B.; Kiartzis, S. J.; Satsios, K.J.** (1995), Short term load forecasting using fuzzy neural networks. *IEEE Transactions on Power Systems*, vol. 10, n. 3, p.1518 – 1524.
- Barakat, E.H. e Al-Qasem, J.M.** (1998), Methodology for weekly load forecasting. *IEEE Trans. on Power Systems*, vol. 13, no. 4.
- Box, G., Jenkins, G.M. & Reinsel, G.** (1994). *Time Series Analysis: Forecasting & Control* (3rd Edition).
- Bunn, D. W.; Farmer, E. D.** (1985), *Review of Short-term Forecasting Methods in the Electric Power Industry*, New York: Wiley, pp. 13-30.
- Campbell, P. R. J.; Adamson, K.** (2006), Methodologies for Load Forecasting. 3rd International IEEE Conference on Intelligent Systems, p. 800 – 806.
- Cho, M.Y.; Hwang, J. -C; Chen, C-S.** (1995), 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.

- Feinberg, E. A.; Genethliou, D.** (2005), 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.
- Ferreira, M.P.** (2004). Estimativa dos efeitos do racionamento nas previsões de carga. Dissertação de Mestrado, PUC-Rio.
- Ferreira, V. H.** (2008). Desenvolvimento de Modelos Neurais Autônomos para Previsão de Carga Elétrica, Tese de Doutorado, COPPE-UFRJ.
- Gardner Jr, E. S.** (2006), Exponential smoothing: The state of the art – Part II, *International Journal of Forecasting*, vol. 22, n. 4, p. 637-666.
- Granger, C.W.J. e Jeon, Y.** (2007). Long-term forecasting and evaluation. *International Journal of Forecasting* 23:539–551.
- Hinojosa, V. H.; Hoese, S.** (2010), A. Short-Term Load Forecasting Using Fuzzy Inductive Reasoning and Evolutionary Algorithms", *IEEE Transactions on Power Systems*, vol. 25, n. 1, p.565,574.
- Lee, Y.-S. e Tong, L.-I.** (2012). Forecasting nonlinear time series of energy consumption using a hybrid dynamic model. *Applied Energy* 94:251–256.
- Macrini, J.L.R.** (2000). Modelo de previsão de carga utilizando redes neurais: otimização camada a camada. Dissertação de Mestrado. PUC-Rio.
- Mendes, E.L.** (2002). Modelos de intervenção para previsão mensal de consumo de energia elétrica considerando cenários para o racionamento. Dissertação de Mestrado, PUC-Rio.
- ONS** (2010). Consolidação da previsão de carga para a elaboração do Programa Mensal da Operação Energética, Procedimentos de Rede, Rev. 1.1, Submódulo 5.6, 16/09/2010.
- Pandey, A.S., Singh, D. e Sinha, S.K.** (2010). Intelligent hybrid wavelet models for short-term load forecasting. *IEEE Transactions on Power Systems*, vol. 25, no. 3.
- Paretkar, P. S.; Mili, L.; Centeno, V.; Kaiyan, J.; Miller, C.** (2010), 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.
- Park, D.C., El-Sharkawi, M.A., Marks II, R.J., Atlas, L.E. & Damborg, M.J.** (1991). Electric load forecasting using an artificial neural network. *IEEE Transactions on Power Systems* 6:442–449.
- Qingle, P. e Min, Z.** (2010). Very short-term load forecasting based on neural network and rough set. Int. Conf. on Intelligent Computation Technology and Automation.
- Sachdeva, S. e Verma, C.M.** (2008). Load Forecasting using Fuzzy Methods. Power System Technology e IEEE Power India Conference.
- Soares, L. e Medeiros, M.** (2008). Modeling and forecasting short-term electricity load: A comparison of methods with an application to Brazilian data. *Journal of Forecasting* 24:630–644.
- Sobral, A.P., Medeiros, L., Pereira, F.A. e Souza, R.C.** (2001). Modelos de previsão de médio prazo da carga própria horária. XVI SNPTEE.
- Taylor, J. W.** (2012), Short-term load forecasting with exponentially weighted methods. *IEEE Transactions on Power Systems*, vol. 27, n. 1, p. 1-8.
- Taylor, J.W.** (2003), Short-term electricity demand forecasting using double seasonal exponential smoothing. *Journal of the Operational Research Society*, vol. 54, p. 799–805.
- Yun, Z.; Quan, Z; Caixin, S.; Shaolan, L.; Yuming, L.; Yang, S.** (2008), 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.