

## PREVISÃO DE CARGA UTILIZANDO REDES DE MAPAS ACOPLADOS

### **Ana Paula Oening**

LACTEC – Instituto de Tecnologia para o Desenvolvimento  
Curitiba, Paraná, Brasil  
ana.oening@lactec.org.br

### **Mariana Cristina Coelho**

LACTEC – Instituto de Tecnologia para o Desenvolvimento  
Curitiba, Paraná, Brasil  
mariana@lactec.org.br

### **Maria Teresinha Arns Steiner**

PUCPR – Pontifícia Universidade Católica do Paraná  
Curitiba, Paraná, Brasil  
maria.steiner@pucpr.br

### **Alexandre Rasi Aoki**

LACTEC – Instituto de Tecnologia para o Desenvolvimento  
Curitiba, Paraná, Brasil  
aoki@lactec.org.br

### RESUMO

A previsão de carga vem sendo estudada há diversos anos e as mais variadas metodologias têm sido propostas para resolver este problema algumas, inclusive, utilizando variáveis externas que influenciam indiretamente nas cargas, porém normalmente não considerando a topologia do sistema. Usando conceitos de sistemas dinâmicos, é possível incluir características da rede, tais como ligações entre barras e linhas de impedâncias, através da aplicação de modelos que possuam dinâmica no tempo e espaço, tais como as Redes de Mapas Acoplados. Para esta aplicação, não é necessário um histórico de dados extenso, dado que as dinâmicas locais do problema são detectadas com apenas um atraso. Os resultados obtidos indicam que o método proposto apresenta um desempenho promissor.

**PALAVRAS CHAVE. Redes de Mapas Acoplados, Previsão de carga, Barramento.**

**Área: PO na Área de Energia**

### ABSTRACT

The load forecasting has been studied for several years and a variety of methods have been proposed to solve this problem, including methods that use some external variables that influence indirectly the load, but usually not considering the topology of the system. Using dynamical systems concepts it is possible to include network characteristics, such as connections between buses and lines impedances, by applying models that include spatially extended systems which have time and space dynamic, such as coupled map lattices. For this application, it is not necessary a long historical registers due to the fact that local dynamics are detected with only one delay. The obtained results suggest that the proposed method present a promising performance.

**KEYWORDS. Coupled Map Lattices, Load Forecasting, Bus****1. Introdução**

Diversos estudos desenvolvidos no Setor Elétrico necessitam que sejam empregados métodos de previsão. Esses estudos vão desde a estimativa de consumo de um cliente industrial até a projeção espacial de demanda. Esses variados estudos são aplicados na tomada de decisão das concessionárias de energia elétrica e dos órgãos que regulamentam o setor. Seja para planejamento de expansão da distribuição e transmissão; aplicação de programas de eficiência e redução das perdas na rede elétrica; planejamento da manutenção programada de equipamentos; ou ainda operação de sistemas de potência e *smart grids*.

Um foco dos estudos de previsão realizados no setor recai sobre a projeção do consumo ou demanda de energia, usualmente referida como previsão de carga, a qual pode ser obtida segregada por barramento, ou seja, é necessário o conhecimento antecipado da potência demandada em um barramento qualquer. No Brasil, o Operador Nacional do Sistema (ONS) solicita aos agentes de distribuição previsões de carga por barramento, discretizadas em patamares de carga leve, média e pesada, para horizontes de até cinco anos à frente (ONS, 2013).

A quantidade de barramentos no Setor tem uma tendência de crescimento bastante acentuada e o número de barramentos de uma distribuidora de energia pode passar facilmente de 100. Dessa maneira, são necessários métodos robustos e computacionalmente eficientes. Nessa linha, Ferreira e Alves da Silva (2007) desenvolveram um método de Redes Neurais com seleção automática das entradas.

Para a solução do problema de previsão de carga, diversos métodos vêm sendo propostos, desde técnicas clássicas de previsão como Box & Jenkins (BOX *et al.*, 1994; PARETKAR *et al.*, 2010; CHO *et al.*, 1995) e Amortecimento Exponencial (TAYLOR, 2012; GARDNER, 2006), até modelos derivados de sistemas inteligentes, como Redes Neurais (CARPINTEIRO, 2000; REIS, 2005), Sistemas Especialistas (KANDIL *et al.*, 2002) e Previsores Fuzzy (SACHDEVA *et al.*, 2008; HINOJOSA *et al.*, 2010).

Outras variações nos métodos de previsão de carga abordam a inclusão de variáveis com o intuito de aprimorar o resultado das técnicas, adicionando fatores externos que melhor representam a realidade. Nesse sentido alguns trabalhos apostam na aplicação de variáveis meteorológicas (FAY e RINGWOOD, 2010; FAN *et al.*, 2009) outros na influência de eventos especiais tais como o período pré e pós-feriados (SRINIVASAN *et al.*, 1998).

Nesta linha, tem-se o modelo de Redes de Mapas Acoplados que representa uma subdivisão de modelos de sistemas dinâmicos espaço-temporais, no qual elementos de uma rede interagem entre si. O estudo de Redes de Mapas Acoplados compreende a ligação entre elementos de dinâmica complexa, onde mapas da série temporal são dispostos de forma a constituir uma rede onde, dada uma regra de acoplamento, o estado no instante imediatamente posterior passa a depender do estado no instante atual e do estado de seus vizinhos em determinados instantes.

Assim, modelar um sistema de potência, de acordo com Redes de Mapas Acoplados, adiciona ao problema variáveis que especificam a posição dos barramentos no espaço e também a forma com que esses barramentos são conectados. Dessa forma, um elemento vizinho da rede tende a influenciar outro sítio da rede, ou seja, as barras conectadas a uma determinada barra do sistema têm influência sobre seu comportamento.

Este artigo está organizado da seguinte forma: na seção 2 é apresentada uma breve revisão sobre Redes de Mapas Acoplados, seguida de uma descrição da modelagem utilizada para previsão de carga, apresentada na seção 3. A seção 4 apresenta o estudo de caso utilizado e os resultados obtidos. Conclusões e trabalhos futuros finalizam o artigo na

seção 5.

## 2. Redes de Mapas Acoplados

Nesta seção são apresentados, de forma bastante resumida, os principais conceitos relacionados ao tema abordado. São introduzidos os principais conceitos de Redes de Mapas Acoplados, com a descrição matemática dos mapas e das funções de acoplamento.

### 2.1. Rede de Mapas Acoplados

Rede de mapas acoplados (CML, do inglês *Coupled Map Lattices*) foi primeiramente apresentada por Kunihiko Kaneko na década de 80 como um modelo que representa de forma simplificada o caos espaço-temporal, fazendo parte da teoria que engloba os sistemas dinâmicos. A partir deste ponto, a técnica foi aprimorada e passou a ser aplicada também nas áreas de biologia (RAND e WILSON, 1995), matemática e engenharia (KANEKO, 1993).

O caos espaço-temporal, como define Kaneko (1993), é a dinâmica irregular no espaço-tempo em um sistema determinístico espacialmente extenso, e cujos graus de liberdade efetivos divergem conforme o tamanho do sistema é incrementado. Como exemplos destes sistemas, citam-se as Redes Neurais (JOST e KOLWANKAR, 2009), a Turbulência em Fluidos e também a Organização Estrutural de Sistemas Biológicos (MARCOS-NIKOLAUS e MARTIN-GONZÁLEZ, 2002).

A CML consiste em elementos de uma rede que interagem (acoplados) com um conjunto de outros elementos também dinâmicos. Nesse universo, a dinâmica local de cada sítio é representada por um mapa (equação algébrica), sendo que o conjunto de mapas forma a rede na qual a influência de um elemento nos outros é dado pelo acoplamento segundo uma regra definida.

A estratégia para modelar fenômenos dinâmicos em sistemas espacialmente extensos com CML é baseada em quatro etapas, as quais, quando traçado um paralelo à modelagem de um sistema para previsão de carga, podem ser resumidas como:

- Escolher um conjunto de variáveis em uma rede: corresponde à definição de um sistema de potência estabelecendo sua abrangência, o número de barramentos, as linhas existentes e o posicionamento destes, também é preciso determinar o conjunto de variáveis como, por exemplo, reatância, potência ativa e reativa, *shunt*, etc.
- Decompor os processos subjacentes aos fenômenos em componentes independentes: remete à seleção de uma unidade dentro da rede definida, de modo a decompor o sistema em partes menores, independentes e representativas do problema. A seleção da barra como componente parece adequada ao ponto que se deseja estudar o comportamento da potência demandada nessa unidade específica.
- Substituir cada componente por um termo de acoplamento entre vizinhos apropriadamente selecionados: determina que o comportamento dos elementos decompostos da rede seja substituído por equações, além de adicionar funções que descrevem a forma com que esses elementos se comunicam. Podem-se representar os barramentos pelo valor da potência ativa gerada ou demandada; já as conexões podem ser substituídas por informações de impedância das linhas ou pelo fluxo de potência (FP).
- Propagar as dinâmicas sucessivamente: as dinâmicas determinadas para compor o modelo são transmitidas, ou seja, considerando o tempo, é feito esse método de transformação para os vários pontos ou instantes das séries temporais que ajudam a compor o sistema.

### 2.1.1. Mapas

As equações algébricas utilizadas para estudo da formação de padrões representam os elementos de uma rede de forma individualizada, ou seja, podem descrever separadamente as dinâmicas de cada sítio da rede. Conforme descrito por Kaneko (1993), esses mapas ou equações de recorrência, quando considerados em um mapeamento não linear de um sistema caótico, podem ser descritos como em (1).

$$x_{n+1} = f(x_n) \quad (1)$$

Onde  $n$  representa uma das dimensões do problema, comumente apresentado como o deslocamento temporal e  $x$  representa um elemento da rede.

### 2.1.2. Acoplamento

As conexões existentes entre os mapas podem ser descritas de diversas formas e representadas por uma função  $g$  que define o comportamento do acoplamento podendo assumir uma dinâmica linear dada por (2) ou dinâmica futura descrita por (3).

$$g(x_n^{(i)}) = x_n^{(i)} \quad (2)$$

$$g(x_n^{(i)}) = f(x_n^{(i)}) \quad (3)$$

A escolha da dinâmica (linear ou futura) é realizada com base no problema modelado. Usualmente, observa-se que a utilização da dinâmica futura com um mapa adequado ao problema, tende a apresentar resultados melhores do que a dinâmica linear, porém o uso da dinâmica linear possui comportamento superior à dinâmica futura quando o mapa do sistema analisado é desconhecido.

Os acoplamentos são classificados pela ótica do alcance. Se a dinâmica de um elemento for definida somente pelo comportamento de seus vizinhos mais próximos, então se diz que o acoplamento é local. Nesse caso, para dois vizinhos, considera-se a função de acoplamento local como descrito em (4).

$$x_{n+1}^{(i)} = (1 - \varepsilon)g(x_n^{(i)}) + \frac{\varepsilon}{2} [g(x_n^{(i+1)}) + g(x_n^{(i-1)})] \quad (4)$$

considerando  $\varepsilon$  como a intensidade do acoplamento e  $i$  uma coordenada para estabelecer a posição do elemento.

Ao se adotar o comportamento linear, a equação (4) recai na equação (5).

$$x_{n+1}^{(i)} = (1 - \varepsilon)x_n^{(i)} + \frac{\varepsilon}{2} [x_n^{(i+1)} + x_n^{(i-1)}] \quad (5)$$

Quando a dinâmica de um elemento pode ser definida pelo comportamento de todos os seus vizinhos, então tem-se um acoplamento global, conforme mostrado em (6). Neste tipo de acoplamento, o alcance é ilimitado e a intensidade é uniforme.

$$x_{n+1}^{(i)} = (1 - \varepsilon)x_n^{(i)} + \frac{\varepsilon}{N-1} \sum_{\substack{j=1 \\ j \neq i}}^N g(x_n^{(j)}) \quad (6)$$

onde  $N$  é o número de elementos da rede.

## 3. Método Proposto

Nesta seção é apresentada a maneira com a qual foi estruturada a modelagem de

CML a fim de comportar um dado sistema de potência. A modelagem utilizada neste trabalho é um aperfeiçoamento da modelagem proposta por Coelho, Oening e Aoki (2013).

Em um sistema de potência, diferente da maioria das redes, como bacteriana ou neural, não se pode considerar apenas a probabilidade das barras estarem conectadas entre si. A conexão ou não de uma linha influencia o comportamento do sistema. Por este motivo, o problema precisa ser modelado de forma que fiquem evidentes os pontos da rede conectados por linhas.

Optou-se por organizar as informações para cada estado do sistema em vetores, ou seja, a cada ponto da série de dados, tem-se um vetor que representa um instantâneo de tempo do problema modelado. Cada posição desse vetor representa a potência, tanto de geração ( $P_g, Q_g$ ) quanto de carga ( $P_d, Q_d$ ), de uma determinada barra.

As informações das conexões entre os barramentos foram organizados em matrizes de incidência, dessa forma quando uma posição  $(i, j)$  da matriz recebe o valor "1" significa que a barra  $i$  está conectada com a barra  $j$ ; caso contrário, recebe o valor "0".

A dinâmica de acoplamento utilizada foi a linear, onde o valor da potência de uma barra em um determinado instante de tempo é considerado igual ao seu valor no instante anterior.


O cálculo da intensidade de acoplamento ( $\epsilon$ ) foi realizado através de um processo de otimização. Uma parte do histórico de dados foi separada para otimização da intensidade do acoplamento, realizada com a utilização do *toolbox* de Algoritmos Genéticos do MATLAB. A função objetivo utilizada foi o erro médio quadrático entre o dado realizado e o dado previsto.

Quanto às funções de acoplamento, foram utilizados o acoplamento local e o global. No acoplamento local, somente as barras diretamente conectadas podem sofrer influência umas das outras. No acoplamento global, todas as barras do sistema influenciam no comportamento das demais.

Para obter os dados de geração e verificar se os resultados obtidos são eletricamente viáveis, foi utilizado o Fluxo de Potência (FP). O FP, em seu cálculo, considera informações como impedância, reatância, *shunt*, injeções de potência, linhas, dentre outras, para calcular os fluxos de potência que entram e saem das barras. Dessa maneira, um evento que afete a topologia da rede do sistema elétrico analisado, tem influência sobre o cálculo do FP e conseqüentemente é percebido pelo modelo.


#### 4. Obtenção dos Resultados

Nesta seção são descritos os resultados obtidos com a aplicação do método descrito de previsão de potência ativa por barramento utilizando redes de mapas acoplados. O método foi aplicado em um sistema teste de cinco barras, composto por duas barras de geração (barras 1 e 2) e três barras de carga (barras 3, 4 e 5), conforme ilustrado na Figura 1.



**FIGURA 1** - DIAGRAMA UNIFILAR DO SISTEMA DE 5 BARRAS


Foram utilizadas séries temporais com histórico de três meses, formadas por demandas máximas diárias, com sazonalidade semanal. Nesse sistema, seguindo a proposta inicial de Coelho, Oening e Aoki (2013), foi considerada apenas a parte real da matriz, ou seja, somente a potência ativa foi utilizada para a previsão. A potência reativa é resultado direto da conversão por um fator de potência. As curvas de potência ativa e reativa das três barras de carga estão ilustradas na Figura 2.




**FIGURA 2** - CURVAS DE POTÊNCIA ATIVA E REATIVA DAS BARRAS DE CARGA

(A) BARRA 3; (B) BARRA 4; (C) BARRA 5.


Considerando a sazonalidade semanal das séries, podem-se organizar os dados de carga de acordo com as semanas, conforme apresentado para a barra 3 (Figura 3), barra 4 (Figura 4) e barra 5 (Figura 5). Nestas figuras, cada curva representa uma das 12 semanas do histórico.



**FIGURA 3 - CURVAS DE CARGA SEMANAIS PARA A BARRA 3 (POTÊNCIA ATIVA)**



**FIGURA 4 - CURVAS DE CARGA SEMANAIS PARA A BARRA 4 (POTÊNCIA ATIVA)**



**FIGURA 5 - CURVAS DE CARGA SEMANAIS PARA A BARRA 5 (POTÊNCIA ATIVA)**

Duas estratégias distintas foram adotadas para a aplicação do modelo de CML, a primeira realizando a previsão com a série completa, ou seja, total (CML-TOT) e a segunda separando a série por tipos de dia da semana e realizando a previsão para cada dia individualmente (CML-DIA). Para cada caso foram realizados testes variando o tipo da função de acoplamento (global ou local) e a forma de consideração da intensidade do

acoplamento (um  $\varepsilon$  para cada barra ou um  $\varepsilon$  geral para todas as barras), esses testes estão listados a seguir:

- Teste 1: acoplamento global e  $\varepsilon$  individual
- Teste 2: acoplamento local e  $\varepsilon$  individual
- Teste 3: acoplamento global e  $\varepsilon$  geral
- Teste 4: acoplamento local e  $\varepsilon$  geral.

A escolha da melhor intensidade de acoplamento ( $\varepsilon$ ) se deu através de um processo de otimização, onde parte da série foi utilizada. No primeiro caso foram utilizados os primeiros 30 dias da série e no segundo foram utilizados os quatro primeiros dias de cada série para essa otimização.

A seguir estão apresentados os resultados para o primeiro caso (CML-TOT). Como o histórico de dados utilizado foi de 90 dias e 30 foram separados para a otimização da intensidade de acoplamento, a previsão foi realizada para os demais 60 pontos da série. Os erros de cada barra e do sistema para cada teste realizado estão apresentados na Tabela 1. Em negrito, está destacado o melhor resultado para esse caso, no entanto todos os testes apresentaram resultados semelhantes, inclusive no erro individual de cada barramento.

**TABELA 1 – MAPES PARA O CASO CML-TOT**

	MAPE por barra			MAPE do sistema
	Barra 3	Barra 4	Barra 5	
Teste 1	4,34%	4,27%	4,87%	<b>4,49%</b>
Teste 2	4,34%	4,30%	5,12%	4,59%
Teste 3	4,35%	4,46%	5,10%	4,64%
Teste 4	4,37%	4,46%	5,08%	4,64%

Os resultados da otimização da intensidade do acoplamento ( $\varepsilon$ ) estão apresentados na Tabela 2. Analisando os resultados, tanto do MAPE quanto do  $\varepsilon$ , a melhor consideração é a utilização do acoplamento individual. Nesse caso, pode-se verificar que a barra 5 foi a que apresentou maior interferência de suas vizinhas, enquanto a barra 4 é a barra que tem a menor influência.

**TABELA 2 –  $\varepsilon$  OTIMIZADO PARA O CASO CML-TOT**

	Barra 3	Barra 4	Barra 5	$\varepsilon$ individual
Teste 1	0,01212	0,0096	0,80056	
Teste 2	0,01281	0,01382	0,465511	
Teste 3	0,019714			$\varepsilon$ geral
Teste 4	0,022581			

Para o caso CML-TOT, as séries foram divididas por tipo de dia, gerando assim sete séries. Cada série é composta de 10 ou 12 dados, representando as semanas. Em cada série, foram separados para a otimização da intensidade de acoplamento 4 dados e a previsão foi realizada para os demais pontos. Os erros obtidos para este caso estão apresentados na TABELA 3 e o melhor resultado está destacado em negrito. Neste caso, as intensidades de acoplamento otimizadas são multiplicadas por sete, devido ao número de séries, e foram suprimidas.



TABELA 3 – MAPES PARA O CASO CML-TOT

	MAPE por barra			MAPE do sistema
	Barra 3	Barra 4	Barra 5	
Teste 1	3,83%	5,07%	2,71%	3,87%
Teste 2	3,84%	5,10%	2,86%	3,93%
Teste 3	3,77%	4,63%	2,73%	3,71%
Teste 4	3,81%	4,50%	2,73%	<b>3,68%</b>

## 5. Conclusões e Sugestões para Trabalhos Futuros

O objetivo deste trabalho foi a aplicação do conceito de sistemas dinâmicos através do modelo de Redes de Mapas Acoplados à previsão de carga. Este trabalho apresenta o aperfeiçoamento da modelagem proposta em Coelho, Oening e Aoki (2013), que já tinha apresentado resultados promissores.

Foram consideradas as conexões entre os barramentos na utilização das funções de acoplamento. As informações das grandezas elétricas do sistema, como resistência, reatância e *shunt* das linhas que conectam as barras, foram adicionadas ao modelo através do uso do fluxo de potência.

Com a consideração de grandezas elétricas do sistema através do fluxo de potência, ao contrário de outros métodos, não é necessário um vasto histórico para a realização das previsões. A dinâmica local do problema é detectada com apenas um atraso, ou seja, tomando o comportamento dos vizinhos de um elemento como base, o próximo passo é calculado sem necessitar de mais informações históricas.

Os resultados segregados por barramento foram satisfatórios e sugerem a utilização de modelos mistos, onde tanto acoplamentos locais quanto globais devem ser considerados, de acordo com o comportamento de cada barra. A otimização da intensidade de acoplamento indica que algumas barras do sistema realmente sofrem influência das barras vizinhas, enquanto outras não apresentam esse comportamento.

Devido ao seu potencial de aplicação no problema de previsão de carga, trabalhos futuros visam uma modelagem mista, considerando acoplamento local e global simultaneamente, além da utilização de uma dinâmica futura através de uma função que descreva o comportamento de cada componente do sistema.

## Referências

- Box, G. E. P., Jenkins, G. M. e Reinsel, G. C.**, Time Series Analysis: Forecasting and Control. 3rd ed., New Jersey:Prentice Hall, 1994.
- Carpinteiro, O. A. S.; Alves Da Silva, A.P.; Feichas, C. H. L.** (2000). A Hierarchical Neural Model in Short-Term Load Forecasting. IEEE-INNS-ENNS International Joint Conference on Neural Networks (IJCNN'00), Italy, jul.
- 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.
- Coelho, M. C., Oening, A. P. e Aoki, A. R.** (2013). A new approach based on coupled map lattices for load forecasting in smart grids, IEEE ISGT LA 2013.
- Fan, S., Chen, L. e Lee, W.** (2009). Short-Term Load Forecasting Using Comprehensive Combination Based on Multimeteorological Information. IEEE Trans. on Industry Applications, vol. 45, n. 4, pp. 1460-1466.
- Fay, D., e Ringwood, J. V.** (2010). On the Influence of Weather Forecast Errors in Short-Term Load Forecasting Models, IEEE Trans. on Power Systems, vol. 25, n. 3, pp. 1751-1758.

- Ferreira , V. H. e Alves da Silva, A. P.** (2007). Toward Estimating Autonomous Neural Network-Based Electric Load Forecasters, *IEEE Trans. On Power Systems*, vol. 22, no. 4, pp. 1554-1562.
- 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.
- Hinojosa, V. H.; Hoese, A.** (2010) Short-Term Load Forecasting Using Fuzzy Inductive Reasoning and Evolutionary Algorithms", *IEEE Transactions on Power Systems*, vol. 25, n. 1, p.565,574.
- Jost, J e Kolwankar, K. M.** (2009). Evolution of network structure by temporal learning, *Physica A: Statistical Mechanics and its Applications*, vol. 388, n. 9, pp. 1959-19661.
- Kandil, M. S., El-Debeiky, S. M. e Hasanien, N. E.** (2002), Long-term load forecasting for fast developing utility using a knowledge-based expert system. *IEEE Transactions on Power Systems*, vol. 17, n. 2, pp. 491-496.
- Kaneko, K.**, Theory and applications of coupled map lattices. England: John Wiley & Sons, 1993.
- Marcos-Nikolaus, P. e Martin-González, J. M.** (2002). Spatial forecasting: Detecting determinism from single snapshots. *International journal of bifurcation and chaos*, vol. 12, n. 2, pp. 369-376.
- ONS, OPERADOR NACIONAL DO SISTEMA ELÉTRICO.** Disponível em <<http://www.ons.org.br>>. Acesso em: 15 de abril de 2013.
- 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.
- Rand, D. A. e Wilson, H. B.** (1995). Using spatio-temporal chaos and intermediate-scale determinism to quantify spatially extended ecosystems. *Proceedings: Biological Sciences, Great Britain: The royal society*, pp. 111-117.
- Reis, A.J.R.; Alves Da Silva, A.P.** (2005). Feature Extraction Via Multi-Resolution Analysis for Short-Term Load Forecasting, *IEEE Transactions on Power Systems*, v.20, n.1, p. 189-198, feb., 2005.
- Sacheda, S.; Verma, C.M.** (2008). Load Forecasting using Fuzzy Methods. *Power System Technology and IEEE Power India Conference*, p. 12 – 15.
- Srinivasan, D., Tan, S. S., Chang, C. S. e Chan, E. K.** (1998). Practical implementation of a hybrid fuzzy neural network for one-day-ahead load forecasting. *IEE Proc.-Gener., Transm., Distrib.*, vol. 145, n. 6, pp. 687-692.
- Taylor, J. W.** (2012). Short-term load forecasting with exponentially weighted methods. *IEEE Transactions on Power Systems*, vol. 27, n. 1, p. 1-8.