

PROPOSTA DE UM MÉTODO HÍBRIDO DE REDES DE MAPAS ACOPLADOS PARA PREVISÃO DE CARGA

ANA PAULA OENING¹, MARIANA C. COELHO¹, ALEXANDRE RASI AOKI¹, MARIA TEREZINHA ARNS STEINER²

1. LACTEC – Instituto de Tecnologia para o Desenvolvimento
Caixa Postal 19067, 81531-980, Jardim das Américas, Curitiba, PR

E-mails: ana.oening@lactec.org.br, mariana@lactec.org.br, aoki@lactec.org.br

2. PUCPR – Pontifícia Universidade Católica do Paraná
Curitiba, PR

E-mail: maria.steiner@pucpr.br

Abstract— During the past few years, load forecasting has been studied and various methods have been proposed to solve this problem. Some methods use external variables to indirectly influence loads, but usually do not consider the system topology. Using concepts from dynamical systems it is possible to include network characteristics in the problem, by applying models that consider dynamical behavior in time and space, such as coupled map lattices. For this application, it is used the historical data and system topology for load forecasting. This paper proposes a hybrid prediction method, where prediction outcome from any method are coupled through the use of concepts from coupled map lattices. The results indicate that the proposed method has a promising application in load forecasting problem.

Keywords— Load forecasting, Coupled map lattices, Bus, Time series forecasting, Hybrid prediction method.

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 no problema, através da aplicação de modelos que possuam dinâmica no tempo e espaço, como as Redes de Mapas Acoplados. Para esta aplicação, são utilizados os dados históricos e a topologia do sistema para a previsão de carga. Este trabalho propõe um método híbrido de previsão, onde os resultados de previsão obtidos por um método qualquer são acoplados através da utilização dos conceitos de Redes de Mapas Acoplados. Os resultados obtidos indicam que o método proposto apresenta um desempenho bastante promissor.

Palavras-chave— Previsão de carga, Redes de mapas acoplados, Barramento, Previsão de séries temporais, Método de previsão híbrido.

1 Introdução

Diversos estudos desenvolvidos no Setor Elétrico necessitam de previsão, 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 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. 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 manei-

ra, 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 e da complexidade da rede.

Diversos métodos tem sido utilizados para solução do problema de previsão de carga, desde técnicas clássicas de previsão como Box & Jenkins (BOX *et al.*, 1994; PARETKAR *et al.*, 2010) e Amortecimento Exponencial (TAYLOR, 2012), até modelos derivados de sistemas inteligentes, como Redes Neurais (REIS, 2005), Sistemas Especialistas (KANDIL *et al.*, 2002) e Previsores Fuzzy (SACHDEVA *et al.*, 2008; HINOJOSA *et al.*, 2010).

A grande maioria dos métodos resolve o problema somente utilizando o histórico da própria variável a ser prevista, no entanto, algumas variações nos métodos de previsão de carga abordam a inclusão de variáveis exógenas, 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).

O modelo de Redes de Mapas Acoplados (CML, do inglês *Coupled Map Lattice*) representa uma subdivisão de modelos de sistemas dinâmicos espaço-temporais, no qual elementos de uma rede interagem entre si. O estudo de CML 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 CML, 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 (vizinhas) 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 e o método proposto, apresentados na seção 3. A seção 4 apresenta o estudo de caso utilizado e os resultados obtidos. Conclusões e trabalhos futuros finalizam o artigo.

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 CML, com a descrição matemática dos mapas e das funções de acoplamento.

2.1 Redes 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:

- 1) Escolher um conjunto de variáveis em uma rede: definição de um sistema de potência estabelecendo sua abrangência, o número de barramentos, as linhas existentes e o posicionamento destes, e também do conjunto de variáveis como, por exemplo, reatância, potência ativa, etc.
- 2) Decompor os processos subjacentes aos fenômenos em componentes independentes: 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.
- 3) 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 matrizes de incidência.
- 4) 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.

2.2 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, normalmente apresentado como o deslocamento temporal e x representa um elemento da rede.

2.4 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 ε como a intensidade do acoplamento e i uma coordenada para estabelecer a posição do elemento.

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 (5). Neste tipo de acoplamento, o alcance é ilimitado e a intensidade é uniforme.

$$x_{n+1}^{(i)} = (1 - \varepsilon)x_n^{(i)} + \frac{\varepsilon}{N - 1} \sum_{\substack{j=1 \\ j \neq i}}^N g(x_n^{(j)}) \quad (5)$$

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 e o método de previsão de carga proposto. 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.

As informações das conexões entre os barramentos foram organizados em matrizes de incidência, assim 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”.

O método de previsão de carga proposto neste trabalho é um método híbrido, onde a previsão é realizada através de um método de previsão de séries temporais qualquer e os resultados obtidos são acoplados, utilizando os conceitos de CML. A Figura 1 apresenta um fluxograma do funcionamento geral do método, que é denominado CML Híbrido.



Figura 1 – Método CML Híbrido

A etapa de pré-processamento dos dados consiste em dividir a série temporal em três conjuntos. O primeiro, denominado de conjunto de treinamento, é composto por aproximadamente 80% da série. Os dois conjuntos seguintes são denominados validação e teste, e cada um contém 10% dos dados da série. Essa divisão é realizada respeitando a ordem cronológica da série. Se necessário, antes de dividir o conjunto de dados em treinamento e validação, a série pode também ser subdividida de acordo com suas características e quantidade de dados históricos.

A próxima etapa consiste no treinamento da técnica de previsão de séries temporais. O método de previsão utilizado neste trabalho foi uma Rede Neural (RN) do tipo MLP (multicamadas) e foi utilizado o método desenvolvido por Ferreira (2008) em seu trabalho de doutorado para seleção automática das entradas e do número de neurônios na camada escondida. Foram utilizados os dados do conjunto de treinamento para treinar a rede e a previsão foi realizada para o período do conjunto de validação.

Com os resultados da previsão e os dados realizados do período de validação, foi realizada a etapa de otimização da intensidade de acoplamento ε . Para esta otimização, foi utilizado o método de Algoritmos Genéticos, implementado no MATLAB, e a função objetivo adotada foi a de minimização do erro ao quadrado. O resultado obtido pela Rede Neural é

então utilizado como a função que representa a dinâmica de cada barra. Dessa maneira, nas equações de acoplamento local (4) ou global (6) a função $g(x_n)$ foi substituída pela previsão da Rede Neural.

Foram testadas todas as combinações entre intensidades de acoplamento individual por barra ou intensidade de acoplamento geral para o sistema e os dois tipos de função de acoplamento, gerando os quatro casos descritos a seguir:

1. Caso 1: acoplamento global e ε individual
2. Caso 2: acoplamento local e ε individual
3. Caso 3: acoplamento global e ε geral
4. Caso 4: acoplamento local e ε geral.

A etapa de previsão utilizando a técnica de previsão de séries temporais foi realizada utilizando os dados dos conjuntos de treinamento e validação para prever o período do conjunto de testes. A seleção das entradas e da configuração da rede se deu de forma automática, conforme descrito em Ferreira (2008).

Com as intensidades de acoplamento otimizadas e os resultados obtidos pela previsão da rede é realizada a etapa de acoplamento das previsões via CML. Nessa etapa, os resultados das previsões são acoplados, utilizando cada um dos quatro casos e gerando novas previsões, que são denominadas de previsões acopladas.

Por fim, são calculados os MAPEs das previsões, para medir o desempenho do método de previsão de séries temporais e do método proposto.

4 Casos Teste e Resultados

Nesta seção são descritos os sistemas teste utilizados e os resultados obtidos com a aplicação do método de previsão CML Híbrido. O método foi aplicado em dois sistemas teste, um com cinco barras e outro com 14 barras.

4.1 Sistema Teste 5 Barras

O sistema teste de cinco barras é composto por duas barras de geração (barras 1 e 2) e três barras de carga (barras 3, 4 e 5), conforme ilustrado na Figura 2.

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.




Figura 2 - diagrama unifilar do sistema de 5 barras

Na aplicação do método CML Híbrido (CML-H) os dados foram divididos em três conjuntos. Os primeiros 76 dados compõem o conjunto de treinamento, os próximos sete valores o conjunto de validação e os últimos sete compõem o conjunto de testes.

Com os dados de treinamento, é realizado o treinamento da RN. Com a RN treinada, foram utilizados os dados do período de validação para otimização da intensidade de acoplamento. Foram testadas as funções de acoplamento global e local, com intensidades de acoplamento individual por barra.

Na Tabela 1 estão apresentados os resultados obtidos nessa otimização, onde pode ser verificado que a barra 4 não possui influência nenhuma das barras vizinhas em nenhum dos casos considerados. A barra 5 tem uma intensidade de acoplamento alta, quando se considera o acoplamento global e nula no caso do acoplamento local. Para os casos 3 e 4, ou seja, considerando uma única intensidade de acoplamento, o resultado da otimização foi nulo. Dessa forma, esses resultados foram omitidos da tabela.

Tabela 1 – intensidade de acoplamento otimizada pelo método CML-H para o sistema teste 5 barras

	Barra 3	Barra 4	Barra 5
Acoplamento global	0,025	0,000	0,469
Acoplamento local	0,026	0,000	0,000

Na sequência, utilizando os dados do conjunto de treinamento e validação mais os resultados obtidos na otimização da intensidade de acoplamento, foram realizados os acoplamentos das previsões. A Tabela 2 apresenta os erros obtidos pelo método de RN e pelo método CLM-H. Neste caso, o melhor resultado foi obtido pelo acoplamento das previsões através da função de acoplamento local (CML-H Caso 2). Vale salientar que, para este caso, somente a barra 3 teve ganho com o acoplamento das previsões, já que as demais possuem intensidade de acoplamento nula. Os resultados para os casos 3 e 4 foram omitidos da Tabela 2, pois são exatamente os mesmos que os obtidos com a RN, já que não existe acoplamento.

Tabela 2 – MAPEs da previsão CML-H - Sistema teste 5 barras

	MAPE por barra		
	RN	CML-H Caso 1	CML-H Caso 2
Barra 3	4,84%	4,25%	4,23%
Barra 4	5,67%	5,67%	5,67%
Barra 5	4,86%	5,05%	4,86%
MAPE do sistema	5,12%	4,99%	4,92%

4.1 Sistema Teste 14 Barras

O sistema teste de 14 barras utilizado neste trabalho é o sistema IEEE de 14 barras (WASHINGTON, 2012). Este sistema representa uma porção do siste-

ma elétrico norte americano em fevereiro de 1962. Na Figura 3 é exibido o diagrama unifilar do sistema, no qual se observam, basicamente, cinco barras de geração (1, 2, 3, 6 e 8) e oito barras de carga (4, 5, 9, 10, 11, 12, 13 e 14).

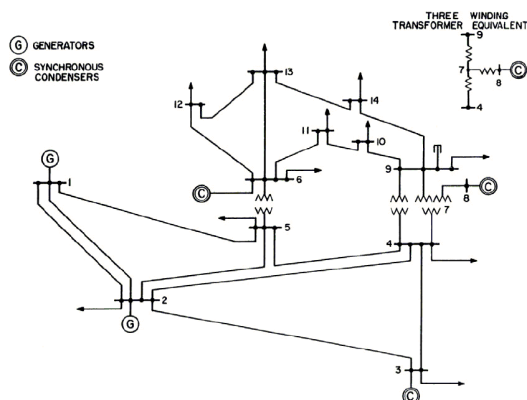


Figura 3 – diagrama unifilar do sistema de 14 barras

Fonte: WASHINGTON (2012).

As séries históricas utilizadas neste sistema são referentes às demandas máximas mensais, em patamar de carga pesada para dias úteis. Essas séries foram obtidas de barramentos distintos da Companhia Energética de Brasília (CEB) e foram normalizadas para se adequarem as dimensões do sistema teste. O histórico utilizado é de seis anos, de janeiro de 2006 a dezembro de 2011, totalizando 72 pontos.

Os dados utilizados não passaram por nenhum tratamento prévio. A barra 4 apresenta dois períodos com comportamento atípico, provenientes de transferências de carga. Já a barra 9 apresenta uma tendência de crescimento bastante acentuada a partir do terceiro ano, logo após um comportamento de quebra da série (no final do ano de 2008). Comportamentos como esses dificultam o bom desempenho dos modelos de previsão, pois modificam o padrão de comportamento das séries temporais.

Na aplicação do método CML-H, os dados foram divididos em três conjuntos. Os primeiros 58 dados compõem o conjunto de treinamento, os próximos sete valores o conjunto de validação e os últimos sete compõem o conjunto de testes.

Com os dados de treinamento, é realizado o treinamento da RN. Com a RN treinada, foram utilizados os dados do período de validação para otimização da intensidade de acoplamento. Conforme descrito previamente, foram quatro combinações entre as funções de acoplamento global e local e intensidades de acoplamento individual ou geral.

Na Tabela 3 estão os resultados obtidos na otimização. Os casos 3 e 4 resultaram em intensidades de acoplamentos nulas, logo foram omitidos da tabela. Nos casos 1 e 2, cuja intensidade de acoplamento é individual por barra, somente a barra 9 apresentou resultado nulo no acoplamento local, no entanto várias barras apresentaram intensidades baixas.

Tabela 3 –Intesidade de acoplamento (ϵ) otimizada pelo método CML-H para o sistema teste 14 barras

	ϵ individual	
	Caso 1	Caso 2
Barra 4	0,0006	0,0008
Barra 5	0,0125	0,0034
Barra 9	0,0029	0
Barra 10	0,0079	0,0371
Barra 11	0,0049	0,0227
Barra 12	0,0066	0,0988
Barra 13	0,0159	0,0422
Barra 14	0,0553	0,0518

Na sequência, utilizando os dados do conjunto de treinamento e validação mais os resultados obtidos na otimização da intensidade de acoplamento, foram realizados os acoplamentos das previsões. A Tabela 4 apresenta os erros obtidos pelo método de RN e pelo método CLM-H para os casos 1 e 2, os resultados dos casos 3 e 4 foram omitidos por não possuírem acoplamento. O melhor resultado foi obtido pelo acoplamento das previsões através da função de acoplamento global e pode ser observado que algumas barras tiveram sua previsão aprimorada e outras tiveram seu desempenho prejudicado após o acoplamento das previsões.

Tabela 4 – MAPEs da previsão CML-H - Sistema teste 14 barras

	MAPE por barra		
	RN	CML-H Caso 1	CML-H Caso 2
Barra 4	2,96%	2,97%	2,99%
Barra 5	1,82%	1,68%	1,98%
Barra 9	4,52%	4,53%	4,52%
Barra 10	2,09%	2,01%	2,84%
Barra 11	8,45%	7,58%	9,47%
Barra 12	4,09%	5,47%	6,50%
Barra 13	2,63%	2,73%	4,55%
Barra 14	10,96%	9,98%	9,78%
MAPE do sistema	4,69%	4,62%	5,33%

5 Conclusões e 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.

Foi proposto um método híbrido para previsão de carga, no qual a previsão é realizada por um método de previsão de séries temporais, cujos resultados são acoplados utilizando os conceitos de CML. As

conexões entre os barramentos foram consideradas no problema, através da utilização das funções de acoplamento.

O desenvolvimento de um método híbrido de previsão, com a utilização dos conceitos de CML para acoplar resultados de previsão obtidos com um método qualquer, se deu em função da dificuldade de se obter uma função que represente a dinâmica do comportamento de cada barra individualmente. Dessa forma, essa função é substituída pelo método de previsão de séries temporais.

Os resultados mostraram que os resultados de previsão são aprimorados com o acoplamento, no entanto ainda não é possível definir qual a melhor estratégia de função de acoplamento a ser utilizada, já que foram obtidos resultados diferentes para cada um dos testes realizados. O sistema teste de cinco barras teve melhor desempenho com a utilização do acoplamento local, já para o sistema teste de 14 barras o melhor desempenho se deu com a utilização da função de acoplamento global.

No que diz respeito à intensidade de acoplamento, os resultados mostraram que não é possível definir uma única intensidade de acoplamento para todo o sistema.

Vale salientar que as séries históricas, tanto do sistema de cinco barras quanto do de 14 barras, foram obtidas de barramentos distintos sem levar em consideração a topologia do sistema. Como a ideia principal das CML é a utilização do conceito de vizinhança, os resultados podem ter sido prejudicados ao se realizar os testes com um sistema fictício.

De maneira geral os resultados obtidos até o momento são promissores. No entanto, é necessária uma investigação aprofundada das características dos sistemas dinâmicos para que seja possível encontrar as melhores estratégias para a previsão de cada sistema.

Referências Bibliográficas

- Box, G. E. P., Jenkins, G. M. and Reinsel, G. C. (1994). *Time Series Analysis: Forecasting and Control*. 3rd ed., New Jersey:Prentice Hall.
- Coelho, M. C., Oening, A. P. and 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. and Lee, W. (2009). Short-Term Load Forecasting Using Comprehensive Combination Based on Multimetereological Information. *IEEE Trans. on Industry Applications*, vol. 45, n. 4, pp. 1460-1466.
- Fay, D., and 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. and 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.
- 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. and 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. and Hasaniien, 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. (1993). *Theory and applications of coupled map lattices*. England: John Wiley & Sons.
- 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.
- WASHINGTON University. Power systems test case archive. Power Flow Test Cases 14 Bus. Disponível em: <<http://www.ee.washington.edu/research/pstca/>>. Acesso em: jul. 2012.