

MARIANA CRISTINA COELHO

PREVISÃO DE CARGA EM REDES DE MAPAS ACOPLADOS

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica, Área de Concentração Sistemas de Energia, Departamento de Engenharia Elétrica, Setor de Tecnologia, Universidade Federal do Paraná, como parte das exigências para a obtenção do título de Mestre em Engenharia Elétrica.

Orientador: Dr. Alexandre Rasi Aoki


**CURITIBA
2012**

TERMO DE APROVAÇÃO

MARIANA CRISTINA COELHO


PREVISÃO DE CARGA EM REDES DE MAPAS ACOPLADOS

Dissertação aprovada como requisito parcial para a obtenção do grau de Mestre no Curso de Pós-Graduação em Engenharia Elétrica, Setor de Tecnologia da Universidade Federal do Paraná, pela seguinte banca examinadora:


Orientador: Prof. Dr. Alexandre Rasi Aoki
Departamento de Engenharia Elétrica, UFPR.


Prof. Dra. Thelma S. Piazza Fernandes
Departamento de Engenharia Elétrica, UFPR.


Dr. Lúcio de Medeiros
Departamento de Eletricidade, LACTEC.


Prof. Dr. Vitor Hugo Ferreira
Departamento de Engenharia Elétrica, UFF.

Curitiba, 23 de agosto de 2012.

AGRADECIMENTOS

Agradeço aos meus pais e irmãs que me guiaram nos primeiros passos em direção à área que gosto, e por sempre demonstrarem sentir amor e orgulho por mim, além de constantemente oferecerem palavras de incentivo.

Aos meus amigos e colegas de trabalho pela paciência durante meus “sumiços” e expressões encorajadoras, ainda que algumas vezes ríspidas, mas cheias de boas intenções e carinho.

Ao meu orientador pela confiança, pelos constantes empurrões e por me ajudar a ver uma solução quando eu já não conseguia encontrá-la sozinha.

Aos meus professores, ao LACTEC, à UFPR e a todos aqueles que de alguma forma contribuíram para a conclusão deste trabalho.

RESUMO

As previsões de carga são foco de interesse por parte das operadoras e concessionárias de energia elétrica, pois com base nessas projeções é feita a tomada de decisões no âmbito de planejamento, operação e controle de sistemas de potência, ressaltando sua importância econômica. Ao longo dos anos, diversos métodos foram aplicados ao problema de previsão, alguns inclusive utilizando variáveis externas que influenciam indiretamente nas cargas, porém normalmente não considerando a topologia do sistema. Para unir a previsão por barramento às características da rede elétrica podem-se aplicar conceitos de sistemas dinâmicos como a modelagem por redes de mapas acoplados, um modelo que abrange sistemas espacialmente extensos que possuam dinâmica no tempo e espaço. Ao se modelar um sistema de potência por esta técnica são adicionadas variáveis que especificam características da rede, tais como conexões entre as barras e impedâncias das linhas, teoricamente tornando a previsão de carga elétrica mais precisa que os modelos atuais. Pelo fato de considerar a influência de elementos da rede, para a aplicação da técnica, não é necessário um vasto histórico para a realização das previsões. Uma dinâmica local e superficial do problema é detectada com apenas um instantâneo do sistema, o qual representa um atraso de tempo. Os resultados são comparados com um modelo de regressão linear. Os valores de erro obtidos sugerem que com pouco histórico disponível o método proposto possui um desempenho adequado, porém com a vantagem de realizar um passo da previsão de demanda para todas as barras de um dado sistema em apenas uma iteração, independente do número de barramentos considerados.

Palavras Chaves: Redes de Mapas Acoplados. Previsão de Carga. Sistemas de Potência.

ABSTRACT

The operators and power utilities have shown interest in load forecasting, to use its projections as basis for decision-making within planning, operation and power systems control. Over the years, several methods were applied to forecasting problem, some even using extra variables that influence load indirectly, but usually without considering the system topology. The characteristics of power grid can be added to load forecast by applying dynamical systems concepts, such as coupled map lattices, a model which includes spatially extended systems that have time and space dynamic. When modeling a power system by this technique, are added to the problem variables that specify network characteristics, such as connections between buses and lines impedances, possibly making the load forecasting more accurate than current models. For this technique application is not necessary a long data history. The problem local dynamics is detected only with one delay. The results are compared with a linear regression model. The error values obtained suggest that the proposed method has an adequate performance when are available just a few historical data. Compared to other models has the advantage of solving the whole system in one iteration, regardless the system size.

Keywords: Coupled Map Lattices. Load Forecasting. Power System.

LISTA DE FIGURAS

FIGURA 1 - ELEMENTOS ADJACENTES CONSIDERADOS COMO VIZINHOS EM UM SISTEMA DE DUAS DIMENSÕES.(A) MODELO DE VON NEUMANN. (B) MODELO DE MOORE	30
FIGURA 2 - DIAGRAMA UNIFILAR DO SISTEMA DE 5 BARRAS	38
FIGURA 3 - SÉRIE DE DADOS DE UMA BARRA REAL PARA OS PRIMEIROS 31 DIAS.....	41
FIGURA 4 - SÉRIE DE DADOS APÓS A ADEQUAÇÃO PARA O PATAMAR DO SISTEMA TESTE.....	41
FIGURA 5 - CURVAS DE CARGA SINTÉTICAS UTILIZADAS PARA HISTÓRICO NO SISTEMA TESTE.....	42
FIGURA 6 - CURVAS DE CARGA SEMANAIS PARA A BARRA 3 (POTÊNCIA ATIVA).....	43
FIGURA 7 - CURVAS DE CARGA SEMANAIS PARA A BARRA 4 (POTÊNCIA ATIVA).....	43
FIGURA 8 - CURVAS DE CARGA SEMANAIS PARA A BARRA 5 (POTÊNCIA ATIVA).....	44
FIGURA 9 - DIAGRAMA UNIFILAR DO SISTEMA TESTE IEEE DE 14 BARRAS	45
FIGURA 10 -SÉRIES DE CARGA DE POTÊNCIA ATIVA CONVERTIDAS PARA O SISTEMA TESTE DE 14 BARRAS.....	46
FIGURA 11 -SÉRIES DE CARGA DE POTÊNCIA REATIVA CONVERTIDAS PARA O SISTEMA TESTE DE 14 BARRAS.....	47
FIGURA 12 -ESQUEMA DA MATRIZ REPRESENTANDO UM INSTANTE DA SÉRIE NO SISTEMA DE CINCO BARRAS. PODE-SE OBSERVAR A POTENCIA GERADA (-PG ; -QG), A POTÊNCIA DEMANDADA (PD; QD), E OS FLUXOS ENTRE AS BARRAS (PMN; QMN).	50
FIGURA 13 -ESQUEMA REPRESENTANDO OS VIZINHOS DO ELEMENTO ANALISADO.....	52
FIGURA 14 -FLUXOGRAMA QUE APRESENTA A SEQUÊNCIA DE PROCESSOS PARA A REALIZAÇÃO DA PREVISÃO EM REDES DE MAPAS ACOPLADOS.	54
FIGURA 15 -MATRIZ DE PERTURBAÇÕES REPRESENTADAS EM ESCALA DE CORES. (A) P1 = AUMENTA 10% A CARGA NA BARRA 4; (B) P2 = AUMENTA 5% A CARGA NAS BARRAS 3 E 5; (C) P3 = LINHA 3-4 FORA DE OPERAÇÃO; (D) P4 = LINHA 2-5 FORA DE OPERAÇÃO; (E) P5 = DIMINUI 5% A CARGA NA BARRA 4 E	

AUMENTA 10% A CARGA NA BARRA 5; (F) SISTEMA ORIGINAL (PONTO 10 DA SÉRIE)	59
FIGURA 16 - ESQUEMA REPRESENTANDO OS VIZINHOS DO ELEMENTO ANALISADO E33	59
FIGURA 17 - FORMULAÇÃO MATRICIAL DE UM INSTANTÂNEO DO SISTEMA DE CINCO BARRAS (1º DOMINGO)	61
FIGURA 18 - FORMULAÇÃO MATRICIAL DE UM INSTANTÂNEO DO SISTEMA DE CINCO BARRAS (2º DOMINGO)	61
FIGURA 19 - FORMULAÇÃO MATRICIAL PARA UM PONTO DA SÉRIE (2º DOMINGO) COM CARGAS PREVISTAS UTILIZANDO A FUNÇÃO DO MAPA LOGÍSTICO.	62
FIGURA 20 - MÉDIA SEMANAL DOS MAPES OBTIDOS COM O MÉTODO DE CML FP PARA PREVISÃO DE MÚLTIPLOS PASSOS	64
FIGURA 21 - MAPE DA QUARTA-FEIRA OBTIDOS PARA 12 SEMANAS COM O MÉTODO DE CML FP PARA PREVISÃO DE MÚLTIPLOS PASSOS	65
FIGURA 22 - MAPES RESULTANTES PARA AS PREVISÕES REALIZADAS PELO MÉTODO CML EM FLUXOS COM ALOCAÇÃO DE PERDAS (CML FP) E MÍNIMOS QUADRADOS BATELADA (MQNR).....	66
FIGURA 23 - MAPES INDIVIDUALIZADOS POR BARRAMENTOS PARA PREVISÕES REALIZADAS COM CML FP E MQNR. COLUNAS AMARELADAS REPRESENTAM MAIOR ERRO DO MQNR EM COMPARAÇÃO COM O ERRO DE CML FP.....	67
FIGURA 24 - CARGA DA BARRA 9 REALIZADA E PREVISTA POR CML FP E INTENSIDADE DE ACOPLAMENTO $E = 1,1$	69
FIGURA 25 - CARGA DA BARRA 9 REALIZADA E PREVISTA POR CML FP E INTENSIDADE DE ACOPLAMENTO $E = 0,5$	70
FIGURA 26 - CARGA DA BARRA 12 REALIZADA E PREVISTA POR CML FP E INTENSIDADE DE ACOPLAMENTO $E = 0,5$	70
FIGURA 27 - CARGA DA BARRA 13 REALIZADA E PREVISTA POR CML FP E INTENSIDADE DE ACOPLAMENTO $E = 0,5$	71
FIGURA 28 - CARGA DA BARRA 14 REALIZADA E PREVISTA POR CML FP E INTENSIDADE DE ACOPLAMENTO $E = 0,5$	71

LISTA DE TABELAS

TABELA 1 - RESUMO DA ESTRUTURA BÁSICA DE TRÊS MODELOS APLICÁVEIS A SISTEMAS DINÂMICOS.....	29
TABELA 2 - DADOS DAS BARRAS DO SISTEMA DE 5 BARRAS.....	39
TABELA 3 - DADOS DAS LINHAS DO SISTEMA DE 5 BARRAS.....	39
TABELA 4 - EXEMPLO DE CONVERSÃO DOS DADOS DE CARGA PARA UMA SEMANA.....	40
TABELA 5 - VALORES DE MAPE MÉDIOS DAS ABORDAGENS CML: CML FP, PREVISÃO DE FLUXO COM ALOCAÇÃO DE PERDAS; CML LINHA, PREVISÃO DE FLUXOS; E CML BARRA, PREVISÃO DAS CARGAS NAS BARRAS.....	62
TABELA 6 - TESTES PARA IDENTIFICAR A INTENSIDADE DE ACOPLAMENTO (E) MAIS ADEQUADA AO PROBLEMA. SÃO MOSTRADOS OS RESULTADOS PARA AS SEMANAS 2, 3 E 4.	63
TABELA 7 - MAPE POR BARRA DOS MÉTODOS CML POR FLUXO E ALOCAÇÃO DE PERDAS E MÍNIMOS QUADRADOS COM DOIS ATRASOS.....	69
TABELA 8 - VALORES MAPE GERAL DO SISTEMA DE 14 BARRAS PARA OS MÉTODOS CMLFP (POTÊNCIA ATIVA) E CMLFP COMPLEXO (POTÊNCIA ATIVA E REATIVA), (E= 0,05)	72
TABELA 9 - VALORES MAPE GERAL DO SISTEMA DE 14 BARRAS PARA OS MÉTODOS CMLFP (POTÊNCIA ATIVA) E CMLFP COMPLEXO (POTÊNCIA ATIVA E REATIVA), (E= 0,01)	72

SUMÁRIO

1	INTRODUÇÃO	11
1.1	Objetivos	12
1.2	Justificativa	13
1.3	Estrutura da Dissertação	13
2	PREVISÃO DE CARGA	15
2.1	Introdução	15
2.2	Previsão de carga no setor elétrico	17
2.3	Empresa de Pesquisa Energética	19
2.4	Operador Nacional do Sistema Elétrico	20
2.5	Revisão de Literatura	21
2.6	Considerações Finais	25
3	REDE DE MAPAS ACOPLADOS	26
3.1	Introdução	26
3.2	Modelos de Vizinhança	30
3.3	Mapas	31
3.4	Acoplamentos	31
3.5	Revisão de Literatura	34
3.6	Considerações Finais	36
4	MATERIAIS E MÉTODOS	38
4.1	Materiais	38
4.1.1	<i>Sistema teste de cinco barras</i>	38
4.1.2	<i>Sistema teste de 14 barras</i>	44
4.1.3	<i>Software</i>	48
4.2	Método	48
4.2.1	<i>Formulação do problema</i>	49
4.2.2	<i>Dimensão Local</i>	51
4.2.3	<i>MAPE</i>	53
4.2.4	<i>Implementação</i>	53
4.2.5	<i>Modelo de regressão linear</i>	56

5 Resultados	57
5.1 Sistema de cinco barras	58
5.2 Sistema de 14 barras.....	68
6 Conclusões e Trabalhos Futuros	74
REFERÊNCIAS	76
APÊNDICES	81
I - Exemplo de curvas de carga realizadas e previstas pelo método mínimos quadrados batelada para a Barra 3 do sistema de cinco barras.....	81
II - MAPE para a série de dados prevendo 12 semanas incompletas de forma contínua, sazonalidade semanal e intensidade de acoplamento $\epsilon = 0,1$	83
III - MAPE para a série de dados (90 pontos, 12 semanas incompletas), considerando sazonalidade semanal e intensidade de acoplamento 0,1	84
IV - Comparativo entre o modelo de redes de mapas acoplados nas linhas com FP e mínimos quadrados em batelada com 2, 3, 4, 5 e 6 atrasos de tempo.....	85

1 INTRODUÇÃO

Em sistemas elétricos de potência, para a tomada de decisões no âmbito de planejamento, operação e controle, é importante o conhecimento antecipado do comportamento da demanda, tanto que, ao longo dos anos, a comunidade acadêmica e agentes do setor elétrico tem demonstrado interesse na implementação de métodos para previsão de carga.

A previsão de carga considera diferentes horizontes e é essa característica que define sua aplicação para as empresas de energia. Esses horizontes são usualmente classificados como curtíssimo, curto, médio e longo prazos. De maneira geral, previsões em longo prazo podem ser aplicadas no planejamento técnico e financeiro das concessionárias de energia e no planejamento da expansão do sistema. Previsões em médio prazo possuem aplicação no planejamento da expansão da rede e da operação de sistemas de potência ou ainda despacho da geração. As previsões de curto prazo podem ser aplicadas na elaboração de planos de manutenção e operação de sistemas de potência. Previsões no curtíssimo prazo possuem aplicação na operação em tempo real de sistemas de controle e operação de redes elétricas inteligentes (*smart grid*).

No Brasil, o Operador Nacional do Sistema Elétrico (ONS), responsável pela coordenação e controle da operação do Sistema Interligado Nacional (SIN) visando à otimização energética ao menor custo, determina o fornecimento de previsões referentes à potência ativa e reativa por barramento pelos agentes de distribuição, sendo para tanto considerados horizontes com variação de sete meses a quatro anos, em base mensal (ONS, 2008).

As concessionárias de energia elétrica, para atender à demanda do ONS, precisam elaborar o estudo de previsão e para isso utilizam métodos, tais como, regressão múltipla, amortecimento exponencial, modelos neurais, entre outros.

Alguns métodos, com o intuito de aprimorar o resultado das previsões, adicionam mais variáveis ao problema. Uma possibilidade é aplicar conceitos de

sistemas dinâmicos, considerando o problema sob a ótica espaço-temporal. 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 destes elementos onde, dada uma regra de acoplamento, o estado no instante $t+1$ passa a depender do estado no instante t e do estado de seus vizinhos em determinados instantes.

Assim, modelar um sistema de potência, de acordo com redes de mapas acoplados, adiciona variáveis ao problema que especificam a posição dos barramentos no espaço e também a forma com que os barramentos são conectados, carregando informações das linhas. Dessa forma, um elemento da rede vizinho tende a influenciar outro elemento da rede.

1.1 Objetivos

O objetivo geral da dissertação é aplicar o conceito de sistemas dinâmicos através da aplicação do modelo de redes de mapas acoplados (CML, do inglês *Coupled Map Lattice*) à previsão de carga elétrica.

Para isso são destacados os seguintes objetivos específicos:

- Desenvolver um modelo de mapas acoplados para redes elétricas;
- Modelar um sistema teste como uma rede de mapas acoplados;
- Implementar e testar uma solução para previsão de carga e CML para um sistema teste;
- Analisar e comparar o resultado da CML com uma técnica de previsão tradicional.

1.2 Justificativa

Em sistemas de potência, para o planejamento da operação, expansão, comercialização, entre outros, é desejável conhecer antecipadamente o comportamento da carga em determinados pontos do sistema, pois anualmente é solicitado às concessionárias de energia elétrica o envio de previsões discretizadas por barramento aos agentes do setor elétrico.

No entanto, métodos de previsão de carga, usualmente, não incluem a topologia do sistema, ou seja, desconsideram as ligações e o posicionamento dos barramentos no espaço. Assim, para unir a previsão por barramento às características da rede elétrica, podem-se aplicar conceitos de sistemas dinâmicos, tal como o modelo de Redes de Mapas Acoplados, que possibilita a adição de características da rede, como conexões entre as barras e impedâncias das linhas, a fim de tornar a previsão de carga elétrica mais precisa que os modelos atuais.

A técnica de redes de mapas acoplados já foi aplicada na modelagem de problemas de física, química e biologia, porém, até o presente momento inexistem trabalhos utilizando o método para a estimativa do comportamento da carga em sistemas de potência.

1.3 Estrutura da Dissertação

A fundamentação teórica é apresentada nos capítulos 2 e 3. O capítulo 2 contém informações sobre séries temporais e previsões. Dentro do contexto do Setor elétrico é mencionada a previsão de carga requerida por agentes de operação e planejamento do setor elétrico, no final do capítulo é ainda feita uma revisão da literatura. O capítulo 3 apresenta características da modelagem por redes de mapas acoplados, situando inicialmente a técnica perante outros dois métodos de sistemas dinâmicos e depois definindo vizinhança, mapas e acoplamentos.

No capítulo 4 são expostos os materiais e métodos aplicados no desenvolvimento do trabalho proposto. Em materiais, expõe-se o diagrama unifilar do sistema teste; a maneira como foram obtidas as séries de dados com potências

ativas e reativas para cada uma das barras de carga; e os *softwares* auxiliares utilizados no desenvolvimento. Em métodos, é exibida a formulação do problema, a estatística para identificar a dimensão local (*bred vector dimension*), o método para a alocação de perdas, o erro percentual médio absoluto, e a forma como foi feita a implementação.

Os resultados obtidos no trabalho são descritos no capítulo 5, seguido pelas conclusões e trabalhos futuros no capítulo 6.

2 PREVISÃO DE CARGA

Tanto em nível nacional quanto internacional, os agentes reguladores e operadores do Setor Elétrico exigem diversos estudos de previsão de carga, os quais motivaram pesquisas de métodos de previsão de carga encontrados na literatura técnico-científica.

Este capítulo apresenta conceitos básicos sobre séries temporais importantes para a compreensão das características de previsão de carga. Em seguida, são delineadas as previsões de demanda exigidas por duas agências atuantes na operação ou regulação do Setor Elétrico Brasileiro.

2.1 Introdução

Série temporal é um conjunto de observações de uma dada variável tomadas sequencialmente em um período de tempo, como exemplo, medições horárias de temperatura em uma determinada região. Se as observações forem tomadas em condições diferentes, não é formada uma série temporal, ou seja, no exemplo de temperatura citado, se as medições forem feitas em cidades distintas, o agrupamento dessas observações não consolida uma série temporal.

Tipicamente as observações adjacentes, fornecidas em intervalos de tempo discretos e equidistantes, possuem uma determinada dependência. A análise de séries temporais é dedicada ao estudo dessa dependência entre observações, sendo necessário para isso o desenvolvimento de modelos estocásticos e dinâmicos (BOX *et al.*, 1994).

Como exemplo de aplicações da análise de séries temporais pode ser citado o exame de inter-relações entre diversas variáveis de interesse de séries distintas, isto é, avaliar se variáveis externas exercem alguma influência nas séries analisadas.

Tendo realizado o estudo de inter-relações, a análise de séries temporais pode também ser aplicada na determinação do modelo apropriado para representar essas relações conjuntas ao longo do tempo. Essa seleção pode ser feita dentre os diversos modelos de dinâmica multivariada disponíveis.

Outra aplicação, bastante difundida, é a previsão de valores futuros de uma série temporal a partir de observações correntes e passadas.

Para desenvolver um previsor, variadas técnicas, métodos e modelos estatísticos são aproveitados, desde regressão linear até modelos autorregressivos e médias móveis. Sendo que, em alguns cenários, a não linearidade das séries temporais, como é o caso da previsão de carga, fomentou o uso de redes neurais artificiais, lógica *fuzzy* e aprendizado de máquina, além de outras técnicas de inteligência computacional.

Outra característica da previsão de séries temporais é a definição de horizonte, sendo que para Souza e Camargo (2004) esse conceito refere-se ao comprimento de tempo ou prazo para o qual as previsões devem ser determinadas.

Cada ponto (intervalo de tempo) previsto é chamado de passo, sendo que quando são realizadas previsões de sucessivos períodos pode-se dizer que o estudo abrange múltiplos passos.

Os horizontes de previsão são geralmente estratificados em quatro prazos: longo, médio, curto e curtíssimo. A definição do tempo que compreende cada uma dessas divisões está relacionada ao tipo de modelo empregado, dados disponíveis e ao foco do estudo.

Em muitas séries ocorre, de acordo com um intervalo sazonal, uma conduta similar à já observada. Essa ocorrência é denominada sazonalidade.

O termo sazonalidade, em uma definição formal, é tido como a tendência de determinado sistema em repetir certo tipo de comportamento com uma periodicidade definida (SOUZA e CAMARGO, 2004). Essa tendência sazonal existente no sistema de origem é refletida na série temporal observada, o que propicia a identificação das características da sazonalidade.

Neste cenário, por exemplo, observando uma série temporal do preço de produção de um produto alimentício como o sorvete, é notória a variação periódica de acordo com o advento das estações do ano. Isto ocorre, pois direta ou indiretamente, séries temporais, tais como as econômicas, muitas vezes são afetadas por eventos relacionados ao clima ou eventos culturais, apresentando uma tendência periódica anual, mensal, diária, horária, etc.

Em casos específicos, quando não superficialmente determinado o período sazonal pelo conhecimento de eventos que influenciem a série, cabe o estudo da sazonalidade através da aplicação de métodos como, por exemplo, o filtro de Kalman, Holt-Winters e ARIMA Multiplicativo.

2.2 Previsão de carga no setor elétrico

Diversos estudos do setor elétrico empregam os métodos de previsão, seja na estimativa de consumo de um cliente industrial; na projeção espacial de demanda; ou no conhecimento antecipado da potência demandada em um barramento qualquer.

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; operação de sistemas de potência; ou ainda a contratação eficiente de energia para os consumidores regulados.

Como exemplo, pode ser citado o processo licitatório para contrato de energia de novas plantas geradoras no ambiente de contratação regulada (distribuidores), onde são utilizadas previsões de demanda de energia. Em uma licitação inicial, feita com antecedência de cinco anos devido ao prazo de maturação de uma nova hidrelétrica, é realizada a contratação da energia para atender o crescimento previsto da carga. Decorridos dois anos do processo, é feita uma licitação complementar para contratação de acréscimos de energia utilizando projeções de demanda reajustadas para diminuir o erro (BRASIL, 2003).

Como já mencionado, podem-se classificar os estudos de previsão de carga de acordo com o horizonte ao qual se referem. Na literatura, esses horizontes são classificados como curtíssimo, curto, médio e longo prazo.

De maneira geral, previsões em longo prazo contemplam períodos de alguns meses até poucas dezenas de anos, em base mensal ou anual, sendo aplicadas no planejamento da expansão do sistema, além de fornecer insumos para a organização financeira das concessionárias de energia.

Previsões em médio prazo focam em períodos de uma semana até poucos anos, em base diária, semanal ou mensal, com aplicação no planejamento da expansão da rede básica ou ainda no despacho da geração.

Para períodos de alguns minutos a até poucos meses, a previsão é de curto prazo, em base de minutos, horas ou dias, sendo aplicadas na elaboração de planos da manutenção e operação de sistemas de potência.

O prazo curtíssimo abrange períodos de um minuto até poucos dias, em base de minutos ou frações de horas, com aplicação na operação de sistemas de controle das concessionárias e operação de redes inteligentes.

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.

Órgãos nacionais como a Empresa de Pesquisa Energética (EPE) ou o Operador Nacional do Sistema Elétrico (ONS) que atuam no planejamento e na operação do setor elétrico solicitam às concessionárias de energia elétrica estudos envolvendo a previsão de potência ativa e reativa individualizadas por barramento.

Um cenário para projeção de potência ativa e reativa por barramento considera a parte ativa e reativa como duas séries temporais distintas a serem previstas. Em outro cenário é feita a previsão de potência ativa e, para a entrega do estudo de previsão da demanda da potência reativa, é utilizado o produto entre a previsão de demanda de potência ativa e um fator de potência fixo por patamar de carga do barramento, calculado com base no histórico.

Os próximos tópicos exemplificam as previsões de carga solicitadas às concessionárias de energia elétrica para atender os estudos elaborados pelos órgãos do setor. O foco de ambos os exemplos é a previsão de carga por barramento, a qual é também objetivo desta dissertação.

2.3 Empresa de Pesquisa Energética

As principais funções da Empresa de pesquisa Energética (EPE) incluem a execução de estudos de viabilidade econômico-financeira e socioambiental de usinas. Também é a entidade responsável por estudos de longo prazo para a definição da Matriz Energética, indicando metas e estratégias a serem seguidas. Os estudos de planejamento integrado dos recursos energéticos e o planejamento para a expansão do setor elétrico, distribuição e transmissão, também ficam a cargo desta empresa (BRASIL, 2003).

Para que a EPE exerça suas atividades, é solicitado às concessionárias de energia elétrica estudos de previsão para a elaboração do plano decenal de expansão dos sistemas elétricos. As projeções requeridas referem-se à previsão anual da demanda de potência por barramento, com foco nos patamares de carga leve, média e pesada.

Na elaboração destas projeções são frequentemente utilizados dados históricos de demanda horária e previsão de consumo anual global, para um horizonte de dez anos.

Para a realização do estudo são utilizados valores históricos (para cada tipo de horário) e os fatores de carga empregados, sendo que o histórico de demanda mínima verificada para o horário pode ser aplicado no patamar leve e; para os horários de carga média ou pesada, pode ser utilizada a demanda máxima.

A topologia do sistema também é considerada para que seja possível estratificar por barramentos a previsão global obtida por patamar. Neste levantamento é preciso considerar todas as barras existentes e ainda as que entrarão em operação dentro do horizonte de estudo.

Essa informação consta no planejamento da empresa e deve ser precisa ao ponto de constar datas de entrada dos elementos da rede e percentuais de transferência de carga entre as subestações envolvidas.

Os consumidores horossazonais também influenciam na previsão. Muitas vezes, nos barramentos onde há clientes horossazonais, as cargas por patamar são fixadas. Em algumas ocasiões, estes valores de carga são obtidos nas concessionárias a partir de informações contratuais, por isto podem permanecer imutáveis nos anos pertencentes ao horizonte de previsão.

2.4 Operador Nacional do Sistema Elétrico

O Operador Nacional do Sistema Elétrico (ONS) possui a atribuição de coordenar e controlar a operação do Sistema Interligado Nacional (SIN), devendo esta ser realizada visando à otimização energética ao menor custo (BRASIL, 2003).

Ao ONS são enviados, em diferentes épocas, os estudos para o plano de ampliações e reforços da rede básica (PAR); planejamento da operação elétrica de médio prazo (PEL) e; o planejamento da operação de curto prazo, incluindo horizonte quadrimestral e mensal (ONS, 2008).

Mais especificamente, esses estudos consistem em previsões mensais de demanda ativa e reativa para diferentes horizontes, discretizadas por:

- Patamares leve, médio e pesado para dias úteis;
- Patamares médio e pesado para sábados;
- Patamares pesado, médio e leve (mínimo) para domingos e feriados.

Os estudos solicitados para a formação do PAR são feitos para um horizonte de até cinco anos em base mensal, sendo o seu envio feito anualmente no início do mês de setembro.

Para a elaboração do PAR, são requeridas dos agentes as informações sobre propostas de novas obras, solicitações de acesso, variações nas previsões de carga, atrasos na implantação de instalações de geração e transmissão, além de

dados do planejamento e programação da operação elétrica/energética e da operação em tempo real (ONS, 2011).

O estudo para o PEL é enviado em abril para o primeiro ciclo e em setembro para o segundo ciclo, logo o histórico de dados realizados é dado até os meses imediatamente anteriores a cada envio.

Previsões para o planejamento de curto prazo com horizonte quadrimestral são enviadas três vezes ao ano, em agosto, dezembro e abril.

Para os estudos do planejamento de curto prazo com horizonte mensal são enviadas projeções no dia 19 de cada mês ou no último dia útil anterior ao dia 19. Esses estudos requerem previsões para até três meses à frente.

O processo realizado para essas previsões desagregadas por barramento é semelhante ao utilizado para o plano decenal de expansão do sistema elétrico.

Vale salientar que para o nível de discretização do patamar leve em dias úteis ou domingos e feriados é possível utilizar a demanda mínima verificada. Para os demais patamares pode ser aplicada a demanda máxima observada.

Na próxima seção, são apresentados trabalhos aplicando diferentes métodos na solução de problemas relacionados à previsão de carga em sistemas de potência.

2.5 Revisão de Literatura

Há bastante tempo, as operadoras de energia elétrica, têm se preocupado com o problema de previsão de carga devido à sua importância técnica e econômica. Para solucioná-lo, diversos métodos vêm sendo propostos, desde técnicas clássicas de previsão, tais como regressão linear (PAPALEXOPOULOS, 1990), Box & Jenkins (BOX *et al.*, 1994) até diversos modelos não lineares onde sistemas *fuzzy* (CHEN, 2001) e sistemas especialistas (KANDIL, 2002) vêm de encontro a uma modelagem não linear, não paramétrica ou orientada por dados de difícil obtenção.

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, tais como:

- Variáveis meteorológicas:
 - Temperaturas médias, máximas e mínimas diárias;
 - Umidade relativa do ar;
 - Velocidade do vento.

- Eventos especiais:
 - Feriados: durante, pré e pós-feriados (SRINIVASAN, 1998);
 - Transmissão de eventos televisivos;
 - Início de aulas;
 - Terremotos.

Fay e Ringwood (2010) utilizam informações climáticas para diminuir os erros associados à previsão de carga do sistema elétrico irlandês. O autor afirma que no treinamento de um previsor de carga, usualmente é aplicado o comportamento real de determinada variável meteorológica, ao invés da série prevista da mesma. No entanto, quando o previsor é requisitado, são aplicadas as séries meteorológicas previstas ao invés da curva real utilizada no treinamento. Os dados meteorológicos previstos adicionam ao modelo treinado um valor de erro que não segue uma distribuição normal, prejudicando a resposta do sistema. Para aprimorar os resultados, Fay e Ringwood (2010) aplicam uma técnica de fusão de modelos onde são consideradas redes neurais (*feed forward*) com duas camadas ocultas e saídas únicas como submodelos para estimar os valores de carga.

Há autores, no entanto que afirmam a irrelevância dos valores climáticos em previsões considerando um curto espaço de tempo. Taylor (2012) observa que as variáveis meteorológicas tendem a mudar relativamente pouco em curtos períodos, o que causaria nenhuma ou pouca influência na previsão de carga. O trabalho de Taylor (2012) compara métodos univariados com uma abordagem baseada em dados climáticos. Cinco métodos são aplicados: suavização exponencial; regressão

ponderada (DWR, do inglês *Discount Weighted Regression*); DWR com *spline* para ajustar a sazonalidade; DWR com *spline* e suavização exponencial; e decomposição de valores singulares (SVD, do inglês *Singular Value Decomposition*). No trabalho de Taylor são ainda utilizados como *benchmarks* o modelo auto-regressivo integrado de média móvel (ARIMA), Holt-Winters e rede neural artificial.

Entre as técnicas aplicadas a um horizonte de previsão específico existem trabalhos focados no curtíssimo prazo a exemplo de Alamaniotis *et al.* (2012), onde a previsão de meia hora, com intervalo de cinco minutos, é feita utilizando um conjunto de processos gaussianos independentes baseados em *kernel*. Nesta abordagem, os processos são unificados como termos de um previsor linear, sendo que os coeficientes de cada termo são soluções de um problema de otimização multiobjetivo. A otimização, por sua vez, é resolvida com algoritmos evolucionários, mais especificamente algoritmos genéticos.

Prosseguindo com previsões de carga em horizonte específico, abundam trabalhos que utilizam séries temporais para o curto prazo. Moghram e Rahman (1989) realizam um estudo comparativo entre cinco métodos de previsão: regressão linear múltipla, séries temporais estocásticas, suavização exponencial generalizada, método do espaço de estados e abordagem baseada no conhecimento. No estudo, é utilizado histórico de carga horária de até quatro semanas e, para os modelos que consideram variáveis ambientais, histórico de dados horários de temperatura de bulbo seco, ponto de orvalho e velocidade de vento. Como resultado, são obtidas previsões de carga horária com horizonte de 24 horas. Os autores do estudo comparativo concluem que métodos fortemente dependentes do histórico tendem a apresentar maior precisão na previsão de eventos ordinários, porém com erros expressivos durante a ocorrência de eventos extremos ou mudanças bruscas, os quais são melhor captados por métodos flexíveis, como o sistema especialista.

Dentre outras abordagens, são também encontradas na literatura, trabalhos para a previsão de carga baseadas em redes neurais artificiais (CARPINTEIRO, 2000; REIS, 2005; FERREIRA, 2008).

As Redes Neurais Artificiais (RNAs), ou redes conexionistas, consistem em técnicas computacionais, inspiradas na estrutura neural de organismos inteligentes,

que adquirem conhecimento através da experiência. A RNA, na maioria dos casos, é um sistema adaptável que modifica sua estrutura básica a partir de informações que passam pela rede durante uma fase de treinamento (HAYKIN, 2001).

Braga (2000) afirma que a capacidade de generalizar a informação aprendida na fase de treinamento através de amostras de exemplos é um grande atrativo de uma rede neural na solução de problemas. Ainda segundo Braga (2000), a habilidade de fornecer respostas coerentes para dados de padrões desconhecidos, aliada à capacidade de processamento temporal e auto-organização, faz da RNA uma ferramenta bastante interessante para aplicação em problemas complexos.

Considerando estas características das RNAs, Ferreira (2008) propõe modelos neurais autônomos para previsão de carga elétrica. O fator que oferece distinção a esta proposta é a autonomia adquirida através da criação de procedimentos automáticos para a escolha do espaço de entrada e controle de complexidade da estrutura, buscando a estimação de modelos com elevada capacidade de generalização, dispensando análises individuais de cada barra do sistema por parte dos especialistas.

Fan *et al.* (2009) também aplicam redes neurais para previsão, com a particularidade de agregar o resultado de várias RNAs que ponderam valores de cinco previsões meteorológicas originadas em fontes distintas. No problema estudado, a temperatura é a variável que exerce maior influência na demanda por eletricidade e por este motivo, com a estratégia de utilizar variadas fontes de informações meteorológicas, o erro da previsão é diminuído.

Outro fator bastante presente nos trabalhos que contemplam a previsão de carga é a sazonalidade das séries adotadas. Dependendo do intervalo de medições, os trabalhos seguem variadas táticas para identificar uma periodicidade na curva de dados, seja filtro de Kalman (FAY, 2010); a análise da correlação de variáveis distintas (FAN, 2009); ou conhecimento adquirido pela preexistência de trabalhos na área.

2.6 Considerações Finais

O objetivo do exposto foi apresentar um panorama sobre séries temporais e previsão de potência ativa. As previsões de carga realizadas no domínio de uma concessionária de energia elétrica podem ser divididas em diversos horizontes, patamares e, muitas vezes, separadas por elementos da rede.

Órgãos que atuam no planejamento e na operação do sistema elétrico brasileiro, como a EPE e o ONS, solicitam às concessionárias previsões de carga discretizadas por barramento. Para a composição dessas previsões, normalmente é necessário um histórico de dados muitas vezes não disponível, seja pela falha na medição ou pela análise de um barramento recém-adicionado ao sistema.

Dificultando a previsão, pode-se ainda ser considerado um remanejamento de carga, o qual pela adição ou manutenção de um elemento de rede, causa mudanças nos níveis patamares de carga, comprometendo o uso do histórico.

Outro detalhe a ser observado é a quantidade de barramentos sob responsabilidade da concessionária. Esse valor, dependendo da empresa de energia, pode variar de algumas para centenas de barras. Nesse sentido, pelo número de elementos, a previsão individualizada pode se tornar um desafio.

3 REDE DE MAPAS ACOPLADOS

Neste capítulo são apresentados os principais conceitos sobre o modelo de sistemas dinâmicos conhecidos por rede de mapas acoplados, sendo exposto um paralelo do modelo com equações diferenciais parciais e autômatos celulares. Em sequência, é apresentado o conceito de vizinhança, que é uma das principais características de um modelo baseado em rede, pois influencia o comportamento da unidade analisada.

Com isso, definem-se o conceito de mapas e características dos acoplamentos entre os elementos da rede. As redes de mapas acoplados foram aplicadas em diversas áreas de estudo, sendo uma revisão da literatura técnico-científica apresentada ao final do presente capítulo.

3.1 Introdução

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. A partir deste ponto a técnica foi aprimorada e passou a ser aplicada também nas áreas de biologia, matemática e engenharia (KANEKO, 1993).

A CML é parte da teoria que engloba os sistemas dinâmicos, sendo aplicada para abranger sistemas espacialmente extensos que possuam dinâmica no tempo e espaço. Essa dinâmica refere-se à variação de um sistema no tempo, sendo que são as variáveis dependentes e independentes do sistema os elementos que sofrem a mudança.

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, a

turbulência em fluídos, a organização estrutural de sistemas biológicos e também sistemas bioquímicos como os de reação-difusão.

A CML consiste em elementos de uma rede que interagem (acoplados) com um conjunto de outros elementos também dinâmicos, ou como define Pontes (2008), 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 nas seguintes etapas:

- a) Escolher um conjunto de variáveis em uma rede, definindo também a topologia e o tamanho;
- b) Decompor os processos subjacentes aos fenômenos em componentes independentes;
- c) Substituir cada componente por alguma transformação da variável nos pontos da rede e/ou por um termo de acoplamento entre vizinhos apropriadamente selecionados;
- d) Propagar as dinâmicas sucessivamente.

Traçando um paralelo à modelagem de um sistema para previsão de carga tem-se que o primeiro passo (a) 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.

O segundo passo (b) 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.

O próximo passo (c) determina que seja substituído por equações o comportamento dos elementos decompostos da rede, 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).

No passo (d) 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.

O estudo do caos espaço-temporal, a exemplo das CMLs, pode também ser abordado sob os conceitos de outros modelos dinâmicos, tais como autômatos celulares (CA, do inglês *Cellular Automata*) e equações diferenciais parciais (EDP, ou em inglês *Partial Differential Equations*).

Algumas características diferem redes de mapas acoplados dos modelos CA e EDP, por exemplo, os já citados mapas. Quando são adotados mapas não lineares para descrever as dinâmicas em uma rede é possível a observação de comportamento caótico em sistemas unidimensionais, fato não observado na técnica de sistemas dinâmicos de equações diferenciais parciais.

Para classificar os modelos de sistemas dinâmicos de acordo com uma hierarquia de abrangência e utilização, pode-se utilizar a tratativa de cada modelo direcionada ao conjunto tempo, espaço e variáveis de estado.

O modelo EDP, frequentemente aplicado em sistemas naturais, trata o conjunto (tempo, espaço e variável de estado) de forma contínua sendo caracterizado por sua generalidade. Essa capacidade de modelar diversos problemas físicos é penalizada pela necessidade de utilização de métodos numéricos para a solução dos modelos, resultando em demasiado tempo e esforço computacional.

Autômatos celulares, inicialmente aplicado na pesquisa dos processos biológicos de auto-reprodução celular, ao contrário do EDP, considera o conjunto de forma discretizada, o que limita sua utilização a problemas específicos. Com o uso desse modelo não é possível observar comportamentos aperiódicos e para se atingir uma simulação realista é preciso considerar uma rede com muitos elementos.

O tempo e o espaço são considerados discretos na rede de mapas acoplados e apenas a variável de estado pode ser avaliada de maneira contínua. Com a aplicação deste modelo mantém-se uma parte da generalidade do EDP a um custo computacional pouco superior ao CA. Neste modelo pode ser observado um comportamento estatístico adequado mesmo com a utilização de uma rede considerada pequena para as outras técnicas.

A tabela 1 apresenta um resumo da estrutura básica dos três modelos discutidos. A aplicabilidade do modelo ou quantidade de problemas abrangidos pela técnica cresce proporcionalmente à sua complexidade, portanto o CA é pouco aplicável, porém, se comparado aos outros modelos, é capaz de resolver um problema em menor tempo e sujeito a um custo computacional relativamente baixo comparado ao recurso necessário para execução do EDP.

TABELA 1 - RESUMO DA ESTRUTURA BÁSICA DE TRÊS MODELOS APLICÁVEIS A SISTEMAS DINÂMICOS

<i>Modelo</i>	<i>Espaço</i>	<i>Tempo</i>	<i>Estado</i>
Equações Diferenciais Parciais (EDP)	Contínuo	Contínuo	Contínuo
Rede de Mapas Acoplados (CML)	Discreto	Discreto	Contínuo
Autômatos Celulares (CA)	Discreto	Discreto	Discreto

O modelo de redes de mapas acoplados, quando comparado ao CA e ao EDP, se mostra como uma técnica interessante para aplicações em novos nichos, pois apresenta características equilibradas, assim, apesar de não ser tão generalista como EDP, também não é específica como CA, nesse sentido também se destaca na complexidade de implementação e custo computacional, por não se situar em um dos extremos.

3.2 Modelos de Vizinhança

Os sistemas que utilizam informações de acoplamento necessariamente precisam seguir um modelo de vizinhança, ou seja, é necessário definir, dentre os elementos próximos a um sítio da rede, quais influenciam no comportamento da unidade analisada.

Para sistemas bidimensionais, como mencionam Packard e Wolfram (1985), há basicamente duas estruturas de vizinhança: modelo de Von Neumann e modelo de Moore. As representações gráficas destas estruturas podem ser observadas na figura 1.

No modelo de Von Neumann, também conhecido por *five-neighbor square*, o elemento central sofre algum tipo de influência dos quatro elementos adjacentes: superior, inferior, esquerdo e direito.

Na estrutura de Moore, nomeado também de *nine-neighbor square*, os elementos que exercem algum controle sobre a unidade central compreendem também os elementos diagonais, além daqueles considerados no modelo de Von Neumann. Esta estrutura é usualmente aplicada em sistemas biológicos, como em Rand e Wilson (1995).



FIGURA 1 - ELEMENTOS ADJACENTES CONSIDERADOS COMO VIZINHOS EM UM SISTEMA DE DUAS DIMENSÕES.(A) MODELO DE VON NEUMANN. (B) MODELO DE MOORE

FONTE: PACKARD E WOLFRAM (1985)

3.3 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:

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

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

Diversos mapas foram definidos ao longo dos anos representando sistemas caóticos. O mapa logístico $f(x_n) = 1 - ax_n^2$, por exemplo, foi concebido como um modelo do crescimento de uma população biológica. A alteração do parâmetro de controle do mapa a , também conhecido como parâmetro de não-linearidade, faz com que o sistema apresente comportamentos tais como, pontos fixos, bifurcações e órbitas periódicas, enaltecendo a característica caótica do sistema.

O caos provocado pela alteração do parâmetro de controle se repete com outros mapas, como mapa de Rulkov, Hodgkin-Huxley e Hindmarsh-Rose (PONTES, 2008).

3.4 Acoplamentos

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 $g(x_n^{(i)}) = x_n^{(i)}$ ou dinâmica futura descrita por $g(x_n^{(i)}) = f(x_n^{(i)})$.

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 para o 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 como:

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

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

Sendo que, ao se adotar o comportamento linear considera-se:

$$x_{n+1}^{(i)} = (1 - \varepsilon)x_n^{(i)} + \frac{\varepsilon}{2} [x_n^{(i+1)} + x_n^{(i-1)}] \quad (3)$$

Ao convencionar como acoplamento futuro considera-se a função:

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

Caso um conjunto de elementos distantes exerçam influência no ponto da rede analisado existe a ocorrência de um acoplamento não local. Nessa situação deve ser considerada, além do alcance, a intensidade com que os vizinhos influenciam o determinado sítio.

O acoplamento dito global considera que o sítio interage com todos os pontos da rede, ou seja, o alcance é ilimitado e a intensidade é uniforme. Essa relação pode ser descrita por:

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

considerando N como o número de elementos da rede.

Em determinados problemas, a intensidade com que os sítios exercem influência em outros pontos da rede decai ao passo que se distanciam. Esse acoplamento é conhecido como lei de potência e pode ser descrito por:

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

sendo que $\eta(\alpha)$ (fator de normalização) refere-se à forma e quantidade de vizinhos adotados de acordo com o mapa aplicado; α é o alcance do acoplamento; j^α é a lei de potência que atesta o aumento ou diminuição da influência dos sítios; e $N' = \frac{N-1}{2}$ é o número de elementos da rede a serem considerados para o cálculo, onde N é um número ímpar.

Analisando a equação do acoplamento tipo lei de potência tem-se que quanto maior o valor de α (alcance do acoplamento) menor a capacidade de um sítio influenciar outros pontos da rede.

Assim sendo, se $\alpha = 0$ e $\eta(\alpha) = N - 1$ recai no acoplamento global, ou seja, todos os N elementos da rede menos o sítio analisado exercem a mesma influência no elemento em questão.

Da mesma forma, se for considerado $\alpha \rightarrow \infty$ o sistema remete ao acoplamento local e $\eta(\alpha)$ passa a ser o número de vizinhos diretamente conectados ao elemento. Neste caso, os elementos dentro do alcance do acoplamento do sítio em questão se restringem aos elementos próximos.

Outras formas de acoplamento podem ser identificadas de acordo com o problema que é modelado, destas pode-se citar o acoplamento derivativo, onde a intensidade é parametrizada por equações de coeficientes ajustáveis, fazendo com que o termo de acoplamento seja $F(x_n(i) - x_n(j))$.

Na próxima seção, na falta de trabalhos unindo redes de mapas acoplados e previsão de carga, são resumidos estudos de aplicações gerais com o uso da modelagem baseada em redes de mapas acoplados.

3.5 Revisão de Literatura

Em 1981, iniciaram-se estudos de um modelo que consiste numa cadeia de mapas logísticos acoplados aos seus próprios vizinhos e com parametrizações nas regiões de comportamento caótico. Desde o início de sua modelagem e simulações, a rede de mapas acoplados (CML) evoluiu, e sua aplicação foi expandida para outros campos além da formulação de padrões e caos espaço temporal, passando a ser aproveitada em áreas como biologia, matemática e engenharia (KANEKO, 1992).

Na literatura, é possível encontrar aplicações da CML, como a publicação de Kaneko (1993) que apresenta sistemas dinâmicos com a fase espaço evoluindo ao longo de uma coordenada, o que engloba um sistema de fluxo tal como o movimento de fumaça no interior de um recipiente; ou também exemplifica a modelagem de sistemas reagindo quimicamente, sendo descritos por equações químicas de reação-difusão.

Rand e Wilson (1995), por outro lado, realizam a aplicação na biologia estudando o comportamento de um sistema artificial ecológico do tipo recurso-predador-presa. No trabalho, os autores identificam o padrão estabelecido pelo crescimento da população através da CML e o fazem estudando o comportamento da vizinhança dadas as regras onde: se há recurso, pode se estabelecer uma bactéria vizinha que pode ser consumida por um organismo predador localizado nas redondezas o qual por sua vez morre ou movimenta-se, deixando um lugar vazio onde pode crescer um novo recurso.

Na mesma linha, Marcos-Nikolaus e Martin-González (2002) aplicam a CML a um sistema ecológico o qual descreve o comportamento de uma população espacialmente distribuída. A intenção da modelagem é detectar o determinismo considerando um instante representativo do espaço inerente à população. O trabalho envolve uma abordagem preditiva onde partes da rede são utilizadas para realizar as previsões baseadas na distância entre vizinhos.

Na área de saúde, Pavlov *et al.* (2011) aplica o modelo CML para simular a atividade cardíaca. Para isso são analisadas duas características: a dinâmica das células marca-passo (oscilatórias) e não marca-passo (excitáveis); e o modelo de

acoplamento elétrico entre as células que compõe o tecido cardíaco. Com o sistema construído é possível propagar ondas pelo modelo simulando, por exemplo, uma arritmia cardíaca.

Existem ainda alguns trabalhos atuando no controle local ou global de um sistema suprimindo o caos espaço temporal em uma rede de mapas acoplados. Parekh *et al.* (1998) demonstram o uso do método de controle por pinagem uniforme e pinagem não uniforme com distribuição regular e aleatória, além de controle em redes espacialmente heterogêneas em sua dinâmica local e força de acoplamento. Já Herzallah e Lowe (2011) traçam um comparativo entre o método de controle por pinagem convencional com o estocástico. Nesse método de pinagem são colocados alguns controles locais no espaço de estado da rede para estabilizar certo estado instável.

No estudo de sistemas caóticos, pode ocorrer a sincronização, definida pelo comportamento comum de alguma variável de movimento devido a um acoplamento entre dois ou mais sistemas. Neste campo, há trabalhos que abordam o assunto em redes de mapas acoplados na detecção da sincronização global em osciladores (JUANG, 2007); ou verificando a sincronização completa, de fase ou com atraso, para o controle de ritmos neurológicos, nos quais a ocorrência de sincronização representa uma neuropatia (PONTES, 2008).

O uso das redes de mapas acoplados na previsão de séries temporais é também explorado. Nestes trabalhos, muitas vezes a modelagem é aplicada à sistemas genéricos, não representando um problema real.

Dentre estes trabalhos se destaca o estudo de Muruganandam e Francisco (2005). No artigo mencionado os autores fazem uma análise para definir a dimensão local de uma CML a fim de identificar a previsibilidade do sistema proposto. As séries temporais dos pontos de dimensão local mínima e máxima do modelo são então submetidas a duas técnicas de previsão, um método clássico não linear e outro baseado em estimativa de densidade de probabilidade. Conclui-se que os previsores testados apresentam melhores resultados para o ponto de menor dimensão local.

Parlitz e Merkwirth (2000) focam na previsão de séries temporais de um sistema espacialmente distribuído, considerando uma região local de interesse como um sistema de baixa dimensão. Esse sistema interage com o resto da rede através de seus limites espaciais, sendo penalizado quando há alteração de dinâmica dentro do domínio. Após o processo, as pequenas porções selecionadas são utilizadas na reconstrução da rede, permitindo a subsequente análise do sistema e por fim atingindo a previsão da dinâmica básica do problema.

A CML pode também auxiliar na identificação de sistemas, como apresenta Pan e Billings (2008) cujo trabalho descreve uma abordagem para detecção de vizinhanças de sistemas espaço-temporais baseada em CML. Já Wei *et al.* (2010) incorporam transformações de *wavelet* em um tipo específico de CML. Considera-se para o acoplamento uma rede quadrada com duas dimensões, onde o mapa logístico é aplicado como equação de propósito geral em um acoplamento local. Os autores empregam otimização por enxame de partículas (PSO, do inglês *particle swarm optimization*) na fase de treinamento e para a definição da quantidade de neurônios *wavelets*.

Em Jost e Kolwankar (2009) o foco do estudo reside nas ligações existentes em uma rede. No nascimento, o cérebro de um indivíduo é repleto de conexões sinápticas entre os neurônios através das quais trafegam sinais elétricos. Com a evolução do processo de aprendizagem, parte dessas ligações é extinta. Neste trabalho, os autores evoluem a rede até o ponto de estabilidade, ou seja, quando ligações fracas são eliminadas e as demais são fortalecidas, chegando ao estado final da rede. É aplicado inicialmente o acoplamento global, porém sua intensidade é variada conforme a evolução do sistema.

3.6 Considerações Finais

A CML, apresentada neste capítulo, é uma vertente de sistemas dinâmicos, utilizada para modelar um sistema espaço temporal. Foi traçado um comparativo entre outros modelos, para esclarecer características específicas da técnica e a tratativa dada a variável de estado, tempo e espaço.

Foram também apresentados conceitos de vizinhanças e mapas, além de expor as classificações básicas do acoplamento. Nesta dissertação foram realizados testes aplicando a dinâmica linear e a futura (mapa logístico) considerando o acoplamento local.

Vale salientar que, para integrar um modelo definido, a escolha de estrutura de vizinhança, mapa e acoplamento é feita com base nas características do problema, não ficando estes itens limitados àqueles aqui apresentados.

Na literatura, são encontrados trabalhos teóricos ou aplicações das redes de mapas acoplados em sistemas biológicos, mecânica dos fluídos, fenômenos naturais, dentre outros, porém sobre o uso de CML em previsão de carga não foram encontradas aplicações semelhantes ao estudo proposto nesta dissertação.

4 MATERIAIS E MÉTODOS

Este capítulo divide-se em duas seções principais; materiais, onde são apresentadas características e a construção da série de dados utilizada para o sistema teste; métodos, onde são expostos os métodos aplicados para formulação do problema e implementação.

4.1 Materiais

Nos tópicos a seguir são comentados os materiais aplicados no desenvolvimento do método proposto. Inicialmente são apresentados os sistemas testes submetidos à aplicação da modelagem de redes de mapas acoplados. Na sequência é descrito o software e pacotes utilizados para o desenvolvimento do método.

4.1.1 Sistema teste de cinco barras

Para o desenvolvimento do método, foi necessária a utilização de um sistema conhecido. Para isso foi adotado um sistema de cinco barras, apresentado na figura 2. Esse sistema é composto por duas barras de geração (1 e 2) e três barras de carga (3, 4 e 5).




FIGURA 2 - DIAGRAMA UNIFILAR DO SISTEMA DE 5 BARRAS

A tabela 2 apresenta os dados relativos às barras do sistema teste proposto. Estão relacionados o ângulo e a magnitude da tensão; a potência ativa (P_g) e reativa (Q_g) geradas; e a potência ativa (P_d) e reativa (Q_d) das barras de carga.

TABELA 2 - DADOS DAS BARRAS DO SISTEMA DE 5 BARRAS

Barra	Tipo	Tensão		Geração		Carga	
		Ângulo (graus)	Magnitude (pu)	P_g (MW)	Q_g (Mvar)	P_d (MW)	Q_d (Mvar)
1	$V\theta$	-	1,060	-	-	-	-
2	PV	-	1,050	20,00	-	-	-
3	PQ	-	-	-	-	45,00	15,00
4	PQ	-	-	-	-	40,00	5,00
5	PQ	-	-	-	-	60,00	10,00

Os parâmetros das linhas estão relacionados na tabela 3 (resistência, reatância e elemento *shunt* das linhas).

TABELA 3 - DADOS DAS LINHAS DO SISTEMA DE 5 BARRAS

De	1	1	2	2	2	3	4
Para	2	3	3	4	5	4	5
Resistência (r)	0,020	0,080	0,060	0,060	0,040	0,010	0,080
Reatância (x)	0,060	0,240	0,180	0,180	0,120	0,030	0,240
Shunt (bsh)	0,030	0,025	0,020	0,020	0,015	0,010	0,025

Para o desenvolvimento do método, considerando previsão, foi necessária a obtenção de um histórico. Para tal, três curvas de carga reais foram adaptadas para o sistema teste a fim de obter séries de dados para cada barra.

Nessas séries históricas, são analisados os valores de máxima demanda diária, sendo que cada observação, ou seja, cada dia que compõe a curva de carga é considerado um ponto da série.

A conversão da série original para a série sintética foi realizada com a ajuda de alguns conceitos de sistemas de potência, o cálculo da potência aparente (S) e o fator de potência (f), dados pelas fórmulas:

$$S = \sqrt{P^2 + Q^2} \quad (7)$$

$$f = \frac{P}{S} = \frac{P}{\sqrt{P^2 + Q^2}} \quad (8)$$

onde P e Q são, respectivamente, a potência ativa e reativa, da barra em análise.

Inicialmente foi calculado o fator de potência do sistema teste utilizando os valores de P e Q fornecidos para o sistema de 5 barras. A seguir, a série original foi convertida para o Sistema por Unidade (pu) considerando como base o valor máximo dos dados em análise. O último passo refere-se à conversão dos valores em pu para MW e Mvar utilizando o fator de potência inicialmente calculado para o sistema de 5 barras.

A tabela 4 exemplifica a conversão, de posse dos valores da potência aparente e fator de potência, as curvas de carga das barras reais (P e Q na cor preta) foram transformadas para pu (P e Q na cor vermelha) e depois convertidas para valores adequados ao sistema teste (P' e Q' na cor verde). Na tabela, foi convertida apenas uma semana para efeitos de demonstração.

TABELA 4 - EXEMPLO DE CONVERSÃO DOS DADOS DE CARGA PARA UMA SEMANA

Ponto	Data	Dia da Semana	P (MW)	Q (Mvar)	P (pu)	Q (pu)	P' (MW)	Q' (Mvar)
1	01/03/2009	domingo	16010	2668	0,78	0,13	47,1576	7,8596
2	02/03/2009	segunda-feira	19600	3267	0,95	0,16	57,7320	9,6220
3	03/03/2009	terça-feira	19870	3312	0,96	0,16	58,5272	9,7545
4	04/03/2009	quarta-feira	17610	2935	0,85	0,14	51,8704	8,6451
5	05/03/2009	quinta-feira	19780	3297	0,96	0,16	58,2622	9,7104
6	06/03/2009	sexta-feira	20370	3395	0,99	0,16	60,0000	10,0000
7	07/03/2009	sábado	17790	2965	0,86	0,14	52,4006	8,7334

Após a conversão, é possível observar que o comportamento da curva de carga se mantém, mesmo após as transformações necessárias para adequar os dados em um patamar aceitável para o sistema teste. As figura 3 e figura 4, mostram as séries para os primeiros 31 pontos de um total de 90 para uma barra, primeiro com os valores originais e depois após a transformação.




FIGURA 3 - SÉRIE DE DADOS DE UMA BARRA REAL PARA OS PRIMEIROS 31 DIAS




FIGURA 4 - SÉRIE DE DADOS APÓS A ADEQUAÇÃO PARA O PATAMAR DO SISTEMA TESTE

Na figura 5 é possível visualizar as curvas de carga de potência ativa e reativa obtidas para as barras 3, 4 e 5 do sistema teste.




FIGURA 5 - CURVAS DE CARGA SINTÉTICAS UTILIZADAS PARA HISTÓRICO NO SISTEMA TESTE. A) BARRA 3. B) BARRA 4. C) BARRA 5.

Se for considerada uma sazonalidade semanal nas séries pode-se organizar os dados de carga de acordo com as semanas, conforme apresentado para a barra 3 (figura 6), barra 4 (figura 7) e barra 5 (figura 8). Nas figuras, é utilizado apenas “S” para indicar as 12 semanas.




FIGURA 6 - CURVAS DE CARGA SEMANAIS PARA A BARRA 3 (POTÊNCIA ATIVA)




FIGURA 7 - CURVAS DE CARGA SEMANAIS PARA A BARRA 4 (POTÊNCIA ATIVA)




FIGURA 8 - CURVAS DE CARGA SEMANAIS PARA A BARRA 5 (POTÊNCIA ATIVA)

4.1.2 Sistema teste de 14 barras

O sistema IEEE de 14 barras (WASHINGTON, 2012) também foi utilizado para validação do método proposto. Este sistema representa uma porção do sistema elétrico norte americano em fevereiro de 1962.

Na figura 9 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).

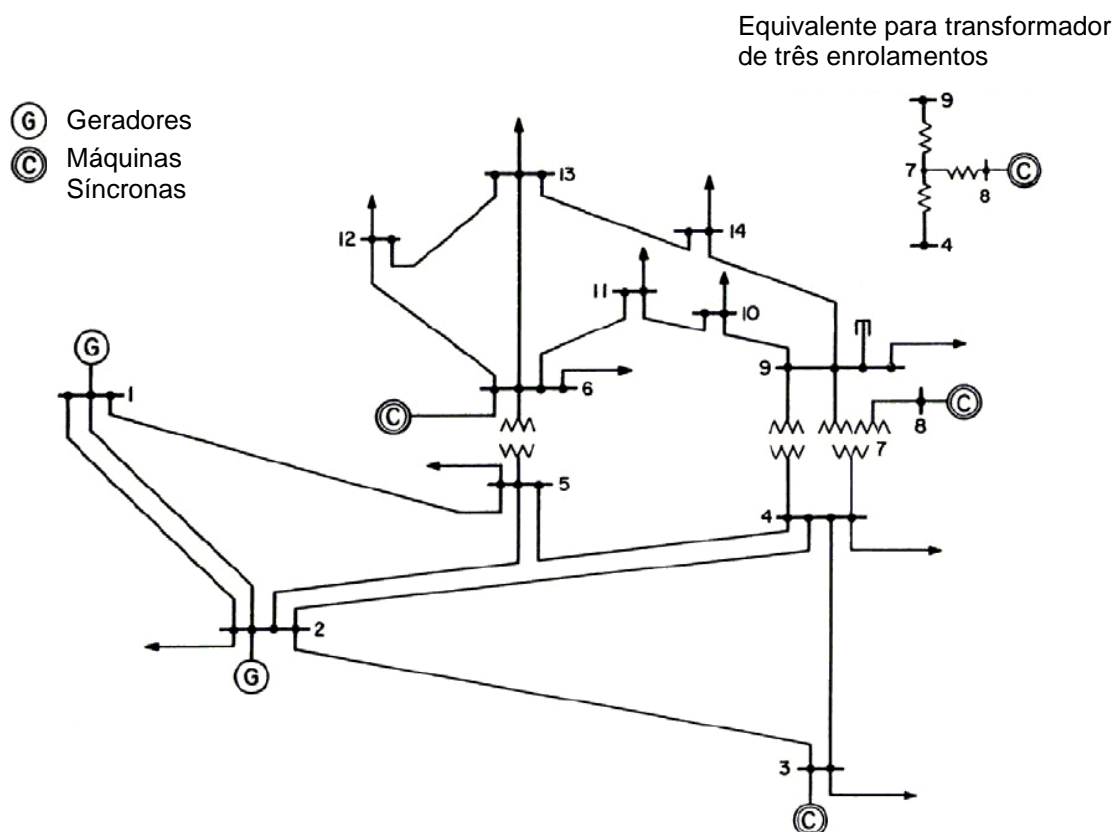


FIGURA 9 – DIAGRAMA UNIFILAR DO SISTEMA TESTE IEEE DE 14 BARRAS
 FONTE: WASHINGTON (2012).

Para a execução de testes no sistema de 14 barras, também foi necessária a adaptação de séries de dados sintéticas, elaboradas de forma análoga ao descrito no tópico anterior. Tais séries, visualizadas na figura 10 (Potência ativa) e figura 11 (Potência reativa), são referentes às máximas mensais em patamar de carga pesada para dias úteis, sendo considerados seis anos de valores, totalizando 72 pontos.




FIGURA 10 - SÉRIES DE CARGA DE POTÊNCIA ATIVA CONVERTIDAS PARA O SISTEMA TESTE DE 14 BARRAS




FIGURA 11 - SÉRIES DE CARGA DE POTÊNCIA REATIVA CONVERTIDAS PARA O SISTEMA TESTE DE 14 BARRAS

4.1.3 Software

O método proposto foi implementado e testado com o uso do MATLAB (MATHWORKS, 2010). O MATLAB (do inglês, *Matrix Laboratory*) é um software voltado para a execução de cálculos numéricos de alto desempenho, integra desde cálculos simples, cálculo de Matrizes, análise numérica, processamento de sinais, construção de gráficos dentre outros, para a solução de problemas matemáticos lineares e não lineares.

O fluxo de potência é calculado pelas rotinas do MATPOWER (ZIMMERMAN, 2011), versão 4.1, um pacote de arquivos MATLAB desenvolvidos para resolver problemas de fluxo de potência e fluxo de potência ótimo.

4.2 Método

Nesta seção são apresentados conceitos sobre métodos aplicados no desenvolvimento desta dissertação.

Inicialmente é descrita a formulação do problema, isto é, como a modelagem de CML foi estruturada a fim de comportar um sistema de potência. Para executar o método proposto, os sistemas testes foram transformados em várias matrizes contendo fluxos entre as barras e potência ativa e reativa, cada matriz representa um instante de tempo (ponto) da série temporal.

Essas matrizes são submetidas a perturbações, seja pela retirada de uma linha de transmissão, ou pelo acréscimo ou decréscimo de potência nas barras. Dessas matrizes, originais e perturbadas, são extraídos os vizinhos para cálculo da dimensão do sistema (*bred vector dimension*). Este cálculo é feito para determinar a dimensão local do problema analisado, pois na literatura é dito que um sistema com alta dimensão local tem sua previsibilidade comprometida, não sendo possível a aplicação de previsores como a CML.

Tendo determinado a baixa dimensão local do problema é feito o processamento da CML, no qual, dependendo da abordagem, as perdas elétricas do sistema são potencializadas e por isto é utilizado um algoritmo de alocação de perdas, também descrito nesta seção.

Após os testes, o desempenho da CML no quesito precisão é comparado com o modelo de regressão linear com parâmetros ajustados por mínimos quadrados em batelada, doravante referenciado como MQnR, um modelo clássico de previsão (MAKRIDAKIS,1998).

A seção é encerrada com o fluxograma da implementação e uma explicação aperfeiçoada sobre o processo.

4.2.1 *Formulação do problema*

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 estes motivos, o problema precisa ser modelado de forma que fiquem evidentes os pontos da rede conectados por linhas.

Optou-se por organizar as informações do problema por matrizes, dessa forma, para cada estado do sistema, ou seja, a cada ponto da série de dados, têm-se uma estrutura em duas dimensões que representa um instantâneo de tempo do problema modelado.

Nesta matriz, com dimensão $nb \times nb$ (onde nb é o número de barras) cada posição representa o domínio de uma barra, portanto tudo o que entra ou sai de um barramento está presente na determinada linha e/ou coluna.

Para agregar ao problema informações referentes às conexões das barras 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.

A potência das barras, tanto de geração (P_g, Q_g) quanto de carga (P_d, Q_d), é posicionada na diagonal principal da matriz, onde ocorre o encontro da linha k e coluna k que representam o domínio da barra k . As posições fora da diagonal contêm os valores de fluxo que entram e saem de cada barra (P_{mn}, Q_{mn})

A figura 12 apresenta uma matriz representativa do sistema teste de 5 barras. Como exemplo, na coluna 4, tem-se valores para as linhas de-para: 2-4, 3-4, 5-4. Por convenção, adotam-se negativos os valores de potência ativa gerada e positivos para valores de carga.

	1	2	3	4	5
1	Barra 1 (-Pg-Qgi)	$P_{12}+Q_{12}i$	$P_{13}+Q_{13}i$	0	0
2	$P_{21}+Q_{21}i$	Barra 2 (-Pg-Qgi)	$P_{23}+Q_{12}i$	$P_{24}+Q_{24}i$	$P_{25}+Q_{25}i$
3	$P_{31}+Q_{31}i$	$P_{32}+Q_{32}i$	Barra 3 (Pd+Qdi)	$P_{34}+Q_{34}i$	0
4	0	$P_{42}+Q_{42}i$	$P_{43}+Q_{43}i$	Barra 4 (Pd+Qdi)	$P_{45}+Q_{45}i$
5	0	$P_{52}+Q_{52}i$	0	$P_{54}+Q_{54}i$	Barra 5 (Pd+Qdi)

FIGURA 12 - ESQUEMA DA MATRIZ REPRESENTANDO UM INSTANTE DA SÉRIE NO SISTEMA DE CINCO BARRAS. PODE-SE OBSERVAR A POTENCIA GERADA ($-P_G$; $-Q_G$), A POTÊNCIA DEMANDADA (P_D ; Q_D), E OS FLUXOS ENTRE AS BARRAS (P_{MN} ; Q_{MN}).

Essa formulação matricial mantém algumas características importantes para o desenvolvimento do método, tais como as perdas e composição dos valores de potência.

O somatório dos fluxos em determinada linha representa a potência ativa da barra, por exemplo, para a Barra 1 e com N representando o número de barras, tem-se:

$$\sum_{n=2}^N (P_{1n} + Q_{1n}i) = P_{g11} + Q_{g11}i \quad (9)$$

A diferença existente entre o somatório de cada coluna (equação 10) e a potência ativa da barra é equivalente à perda na barra, ou seja,

$$Pd_{nn} + Qd_{nn}i = \sum_{\substack{m=1 \\ m \neq n}}^N (P_{mn} + Q_{mn}i) + Perdas_n \quad (10)$$

considerando n o índice da barra, $n = 1:N$.

Da mesma forma, se for considerado um elemento da matriz e subtraído em módulo seu correspondente simétrico, o valor resultante é a perda na linha analisada, tal que:

$$Perda_{mn} = Perda_{nm} = |P_{mn} + Q_{mn}i| - |P_{nm} + Q_{nm}i| \quad (11)$$

4.2.2 Dimensão Local

Os sistemas espacialmente estendidos, quando considerados como um todo, possuem alta dimensão, isto é, muitas são as variáveis de estado e graus de liberdade agregados ao sistema. A existência dessa dimensão exacerbada dificulta na compreensão da dinâmica de um sistema, ou ainda, no estabelecimento de um padrão de comportamento.

A estatística *bred vector* (BV) *dimension* ou dimensão local foi apresentada por Patil *et al.* (2001) na definição de baixa dimensão local da dinâmica atmosférica aplicada em previsões do tempo.

No artigo foi demonstrada a relação entre a baixa dimensão local e a previsibilidade de um sistema, ou seja, tomando pequenas porções de um sistema espacialmente extenso é possível estudar a dinâmica que o descreve.

Mais tarde, foi apresentado o uso de BV *dimension* (BVD) para definição da previsibilidade de um problema com o uso de modelos voltados a sistemas espacialmente estendidos, o que inclui rede de mapas acoplados (MURUGANANDAM, 2005).

Para a formulação do BV são definidas k perturbações no sistema realizadas a partir de um estado normal da rede. Essas perturbações são feitas a fim de simular o comportamento do sistema diante de alterações em variáveis que

tenham impacto na rede. Como exemplo, no modelo proposto, são feitas alterações na carga dos barramentos ou modificado o status de operação nas linhas.

Após a definição das perturbações, o passo subsequente para o cálculo do BV *dimension* é a definição dos vizinhos (V) dos pontos analisados. Nesta definição, considerando o modelo de vizinhança de Von Neumann, a figura 13 destaca os elementos elegíveis para o cálculo da dimensão local tendo em vista o elemento (E) central da matriz.




FIGURA 13 - ESQUEMA REPRESENTANDO OS VIZINHOS DO ELEMENTO ANALISADO

Com a definição dos m vizinhos o *bred vector* é extraído para cada uma das k perturbações. Considerando um elemento, tem-se:

$$bred_k = [V_1 \quad \dots \quad V_m]_{m \times 1}^t$$

Os vetores coluna *bred* são normalizados e quando organizados, formam a matriz B , tal que:

$$B = [bred_1 \quad \dots \quad bred_k]_{m \times k}$$

A matriz de covariância de B , dada por $C = B^T B$, é simétrica e não negativa definida, seus k autovalores (λ_i) são positivos ou iguais à zero ($\lambda_i \geq 0$). Os autovalores são ordenados de forma decrescente e são calculados os valores singulares definidos como $\sigma_i = \sqrt{\lambda_i}$.

O passo final para o cálculo da dimensão BV é dada por:

$$\varphi(\sigma_1, \sigma_2, \dots, \sigma_k) = \frac{\left(\sum_{i=1}^k \sigma_i\right)^2}{\sum_{i=1}^k \sigma_i^2} \quad (12)$$

A dimensão local l é dada pelo menor inteiro maior que a dimensão BV encontrada.

Como os BV foram normalizados, os valores resultantes de φ estarão entre o intervalo $(0, k)$. Ressalta-se que, enquanto perturbações devido a ruídos ou erros irão tipicamente causar que a dimensionalidade do problema medido pelos k *bred vectors* locais seja k , pode ser que a dimensão efetiva de φ seja substancialmente menor.

4.2.3 MAPE

Para avaliar os previsores é necessário estabelecer medidas para contabilizar a acurácia das previsões obtidas, usualmente esse cálculo é utilizado para mensurar os riscos nas tomadas de decisão baseadas em um dado estudo (BOX, 1994).

O erro percentual médio absoluto (MAPE, do inglês *Mean Absolute Percentage Error*) foi adotado como indicador para averiguar o desempenho dos métodos de previsão por ser amplamente difundido na área (ALAMANIOTIS, 2012; FAN, 2009; RINGWOOD, 2010; TAYLOR, 2012).

O índice, representado em porcentagem, é calculado da seguinte forma:

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{real - previsto}{real} \right| * 100. \quad (13)$$

4.2.4 Implementação

O desenvolvimento deste método, realizado em MATLAB, segue o fluxograma representado na figura 14 e detalhado neste tópico.

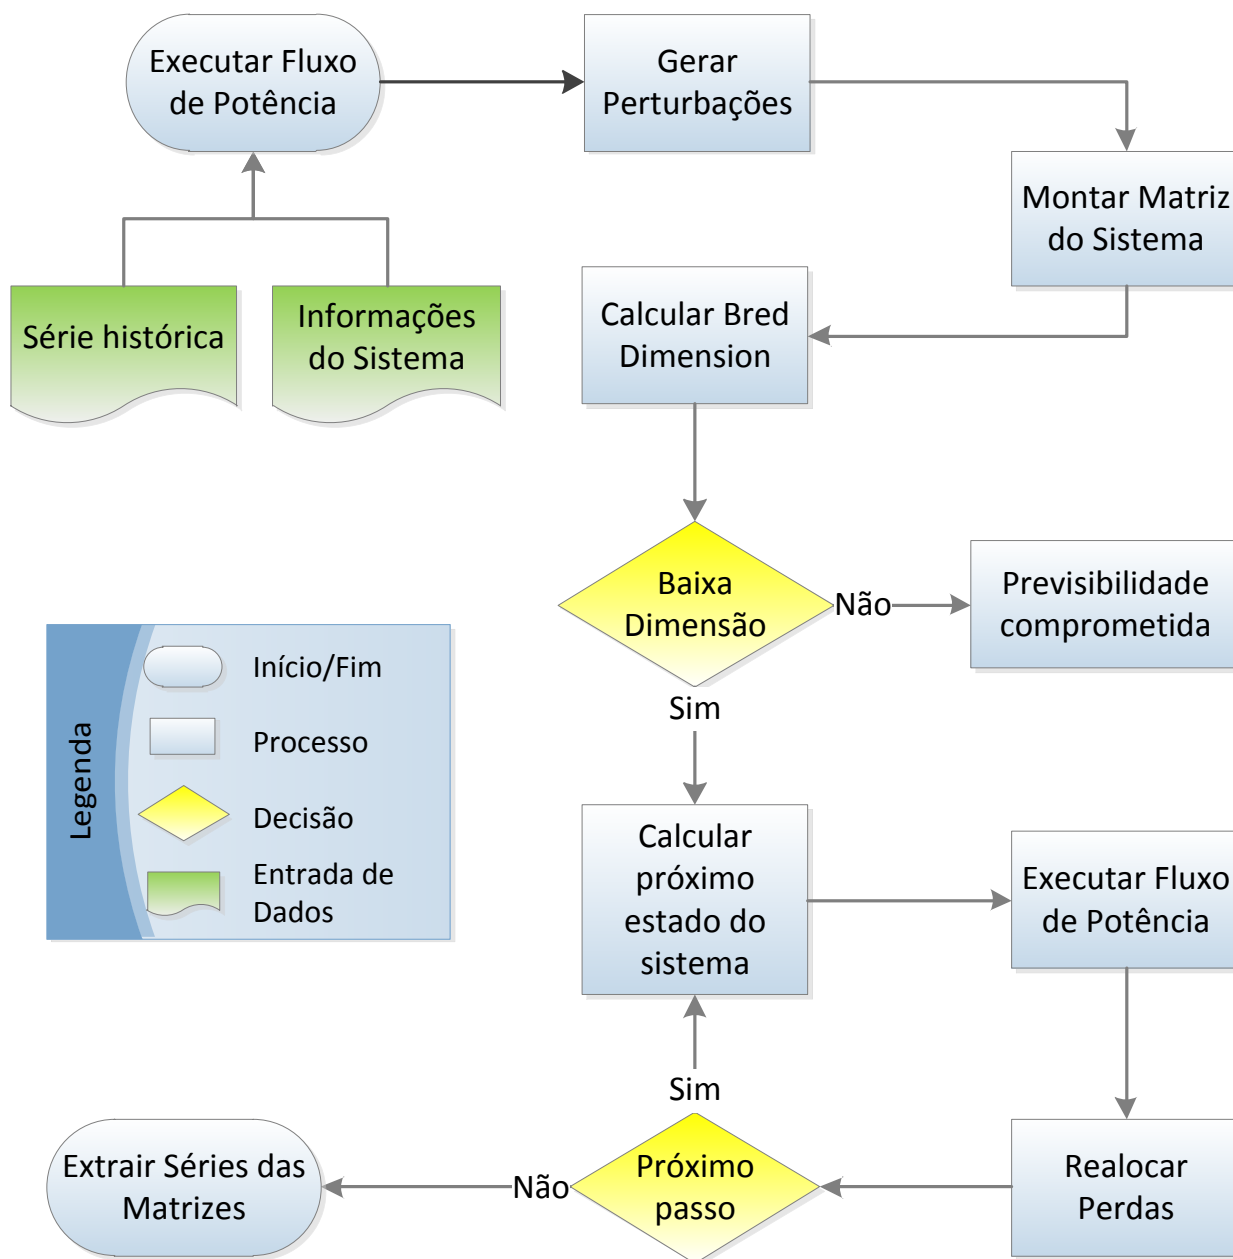


FIGURA 14 - FLUXOGRAMA QUE APRESENTA A SEQUÊNCIA DE PROCESSOS PARA A REALIZAÇÃO DA PREVISÃO EM REDES DE MAPAS ACOPLADOS.

O processo é iniciado executando-se o Fluxo de Potência Ótimo, calculado pelo MATPOWER com o uso de pontos interiores para minimizar as perdas, para todos os pontos da série histórica. Neste estágio são incluídas informações do sistema como número de barras, tipo, potência ativa e reativa, limites, magnitude da tensão, quantidade de linhas, resistência, reatância e *shunt*.

Na sequência são geradas as perturbações. Para cada estado da rede, as alterações no sistema previamente definidas $(p_1, p_2, p_3, p_4, p_5)$, são efetivadas e novos fluxos são calculados para o sistema modificado. Esse processo é realizado para todos os pontos da série sintética.

De posse dos resultados dos processos anteriores, são montadas as matrizes que representam o estado do sistema como um todo. Para cada ponto são obtidas seis matrizes, uma para o sistema original e cinco para os sistemas perturbados.

Com essas matrizes são calculadas as dimensões locais. É importante ressaltar que, para que seja atingida uma boa previsibilidade, torna-se necessário que o BVD seja relativamente baixo. Essa característica, de baixa dimensão local, está relacionada às particularidades do sistema em análise, isto é, não é necessário realizar este estudo a cada iteração do método.

Com a condição de baixa dimensionalidade satisfeita, é iniciada a estimativa do próximo estado do sistema.

A previsão é feita com o uso do modelo de redes de mapas acoplados em abordagens distintas, uma prevendo diretamente o valor de potência ativa na barra considerando vizinhos próximos; e outra estimando o fluxo de potência e depois reorganizando a matriz do problema para obter as previsões por barramento.

Nestes processos foi utilizado o acoplamento local com vizinhos próximos, tanto de forma linear ($g(x_n^{(i)}) = x_n^{(i)}$), quanto futura ($g(x_n^{(i)}) = f(x_n^{(i)})$) aplicando o mapa logístico dado por $f(x_n) = 1 - ax^2$.

A aplicação do acoplamento descaracteriza a matriz, tornando necessária a execução do fluxo de potência para atingir um estado novamente factível.

No caso de previsão por manipulação dos fluxos, a nova matriz apresenta um aumento nas perdas do sistema concentradas em algumas barras. Para mitigar o impacto dessas alterações nas perdas é executado um procedimento de realocação.

Esse procedimento considera que as perdas infligidas pelo cálculo por CML devem ser rateadas entre as barras. Dessa forma, a cada linha é feito o cálculo do

valor dissipado a ser rateada subtraindo o montante de perda na linha da matriz estimada pelo valor da matriz original. Essa diferença é então igualmente dividida entre as barras daquela linha e o fluxo de potência é refeito. Esse método não faz distinção por localização espacial das barras e considera apenas a potência demandada ou gerada do sistema.

Esse ciclo, que envolve o cálculo do próximo ponto com acoplamento, fluxo de potência e realocação de perdas; é executado quantas vezes sejam necessárias, até que o horizonte da previsão desejado seja alcançado.

4.2.5 Modelo de regressão linear

Para a comparação da previsão alcançada com o uso de redes de mapas acoplados, foi aplicado também um modelo de regressão linear representado em sua forma matricial como:

$$Y = \phi\theta + E, \quad (14)$$

onde Y representa as saídas, ϕ é o vetor de medidas, θ o vetor de parâmetros e E a perturbação, a qual se refere ao erro de modelagem, medição ou o ruído na saída.

A estimativa do vetor de parâmetros ($\hat{\theta}$) é obtida pelo procedimento dos mínimos quadrados (*least squares approach*), dada por:

$$\hat{\theta} = [\phi^T \phi]^{-1} \phi^T Y. \quad (15)$$

5 Resultados

Neste capítulo são apresentados os resultados obtidos na aplicação do método descrito de previsão de potência ativa por barramento utilizando redes de mapas acoplados.

O primeiro sistema testado, a saber, sistema de cinco (5) barras, serviu para ajustar a aplicação do método e a forma de análise do mesmo. O segundo teste, utilizado para aprimorar a aplicação do método, apresenta uma maior quantidade de barramentos, contando com 14 barras.

Uma das formas como foi aplicado o modelo de redes de mapas acoplado consiste na previsão dos fluxos nas linhas que conectam as barras de carga e geração do sistema teste. Outra forma foi a previsão diretamente das cargas, considerando os fluxos como vizinhos que influenciam as potências ativas das barras.

Essas duas abordagens inicialmente atingiram resultados similares, porém a previsão dos fluxos aumenta a perda do sistema e inviabiliza a solução. Para contornar esse revés, aplicou-se um algoritmo de alocação de perdas e então o cálculo do fluxo de potência é refeito para obter uma resposta factível. Esse método melhora a resposta da previsão realizada sobre os valores de fluxos.

Para avaliar a influência da intensidade de acoplamento na CML, foram realizados testes alterando o valor desta variável na abordagem de previsão dos fluxos com alocação de perdas. O melhor resultado obtido foi então comparado com o modelo de regressão linear, com o número de atrasos variável.

Para o sistema teste de 14 barras, foi também aplicada a previsão com CML dos fluxos e alocação de perdas, sendo os resultados apresentados por barramento e com variação na intensidade de acoplamento, para exemplificar as análises realizadas.

5.1 Sistema de cinco barras

Antes de iniciar a previsão através do método proposto, foi realizado o cálculo da dimensão local, onde foram definidas $k = 5$ perturbações para o sistema de cinco barras, arbitradas como:

- p_1 = Aumenta 10% a carga na Barra 4;
- p_2 = Aumenta 5% a carga nas Barras 3 e 5;
- p_3 = Linha 3-4 Fora de operação;
- p_4 = Linha 2-5 Fora de operação;
- p_5 = Diminui 5% a carga na Barra 4 e Aumenta 10% a carga na Barra 5.

O estado da rede original e após o efeito das perturbações pode ser observado na figura 15, onde é aplicada uma escala de cores para observar as alterações entre as matrizes. As cores representam os valores que ocupam cada posição da matriz, sendo que cores frias (tonalidades de azul) referem-se a valores negativos; e cores quentes (tonalidades de vermelho) representam valores positivos.

É possível perceber que quando ocorre um desses eventos no sistema tais como a alteração no status de operação de uma linha ou mudança na carga, ainda que em apenas uma barra, acaba por afetar os fluxos da matriz toda, propagando o evento pela rede.




FIGURA 15 - MATRIZ DE PERTURBAÇÕES REPRESENTADAS EM ESCALA DE CORES. (A) P_1 = AUMENTA 10% A CARGA NA BARRA 4; (B) P_2 = AUMENTA 5% A CARGA NAS BARRAS 3 E 5; (C) P_3 = LINHA 3-4 FORA DE OPERAÇÃO; (D) P_4 = LINHA 2-5 FORA DE OPERAÇÃO; (E) P_5 = DIMINUI 5% A CARGA NA BARRA 4 E AUMENTA 10% A CARGA NA BARRA 5; (F) SISTEMA ORIGINAL (PONTO 10 DA SÉRIE)

Definidas as matrizes modificadas pelas perturbações é feita a seleção de vizinhos. Considerando o modelo de vizinhança de Von Neumann, no sistema de cinco barras, é possível definir oito vizinhos (V_i), ilustrado na figura 16 para um elemento E (barramento em análise).




FIGURA 16 - ESQUEMA REPRESENTANDO OS VIZINHOS DO ELEMENTO ANALISADO E_{33}

A cada uma das cinco perturbações arbitradas é feita a extração do bred vector. Para um elemento, tem-se:

$$bred_{[1 \dots 5]} = [V_1 \ V_2 \ V_3 \ V_4 \ V_5 \ V_6 \ V_7 \ V_8]_{8 \times 1}^T$$

A matriz B é formada a partir dos vetores coluna $bred$ normalizados e ordenados, tal que no sistema teste com cinco perturbações:

$$B = [bred_1 \ bred_2 \ bred_3 \ bred_4 \ bred_5]_{8 \times 5}$$

O cálculo da dimensão local é realizado para todos os elementos principais da matriz, ou seja, no sistema de cinco barras, os elementos E_{33} , E_{44} e E_{55} , que fazem alusão às barras de carga do problema são submetidos ao cálculo.

Para o sistema de cinco barras, a dimensão local manteve-se com o valor máximo igual a dois, mesmo quando analisada toda a série temporal. Conforme demonstrado em Muruganandam (2005), existe uma relação entre baixas dimensões locais e a previsibilidade de um problema. De fato, o autor afirma que o erro obtido na previsão de uma região com baixa dimensão local é menor do que em regiões com alta dimensão local.

Essa característica de separação em regiões menores com dinâmica previsível, baixa dimensão local, é inerente ao tipo de problema considerado, dessa forma, o que se observa é aproximadamente o mesmo resultado para todos os pontos da série temporal, mesmo com a mudança das perturbações arbitradas. Por este motivo, não é necessária a execução desta estatística em todas as iterações do método proposto.

Após a constatação da baixa dimensão local, toda a formulação matricial apresentada foi aplicada ao sistema de cinco barras para cada instante de tempo (ponto) da série temporal sintética. Cada uma dessas matrizes foi então sujeita ao método de previsão proposto.

Para o sistema de cinco barras, seguindo a proposta inicial, foi considerada apenas a parte real da matriz, ou seja, somente a potência ativa foi utilizada para os cálculos.

Como exemplo da formulação matricial, pode-se observar os dados presentes na figura 17 onde é exibida a matriz referente ao ponto 1 da série de 90 pontos. Esse ponto refere-se ao primeiro domingo do conjunto de dados, ou seja, é

um dia da primeira semana ($X(n)$). Em amarelo é destacada a diagonal principal da matriz que representa valores de potência ativa para o sistema.

	Posição 1	Posição 2	Posição 3	Posição 4	Posição 5	Soma
Posição 1	-61,6514	34,5497	27,1017	0,0000	0,0000	61,6514
Posição 2	-34,3171	-62,0552	24,6511	26,4532	45,2683	62,0554
Posição 3	-26,5228	-24,2741	40,3696	10,4273	0,0000	-40,3696
Posição 4	0,0000	-26,0259	-10,4152	33,7214	2,7197	-33,7214
Posição 5	0,0000	-44,4440	0,0000	-2,7136	47,1576	-47,1576
Soma	-60,8399	-60,1942	41,3376	34,1669	47,9879	X (n)

FIGURA 17 - FORMULAÇÃO MATRICIAL DE UM INSTANTÂNEO DO SISTEMA DE CINCO BARRAS (1º DOMINGO)

A figura 18 exibe a matriz obtida para o ponto 8, o segundo domingo da série e, portanto, considerando a sazonalidade semanal ($X(n+1)$), a sequência do ponto 1 previsto por CML.

	Posição 1	Posição 2	Posição 3	Posição 4	Posição 5	Soma
Posição 1	-62,6344	35,3730	27,2615	0,0000	0,0000	62,6345
Posição 2	-35,1293	-63,0710	24,5900	26,5411	47,0694	63,0712
Posição 3	-26,6764	-24,2151	39,5817	11,3098	0,0000	-39,5817
Posição 4	0,0000	-26,1112	-11,2959	33,8648	3,5423	-33,8648
Posição 5	0,0000	-46,1778	0,0000	-3,5320	49,7098	-49,7098
Soma	-61,8058	-61,1311	40,5556	34,3189	50,6117	X (n+1)

FIGURA 18 - FORMULAÇÃO MATRICIAL DE UM INSTANTÂNEO DO SISTEMA DE CINCO BARRAS (2º DOMINGO)

Assumindo como parâmetro de comparação o erro percentual MAPE, se obtém que ao fazer a previsão do ponto 8 a partir do ponto 1 tem-se: 5,61% de erro para a previsão por fluxo (denominada CML Linha), 5,43% de erro para a previsão na carga (denominada CML Barra) e 3,29% de erro para a previsão nos fluxos com alocação de perdas e FP (denominada CML FP). Todos estes cálculos foram feitos com a intensidade de acoplamento $\varepsilon = 0,1$.

A tabela 5 apresenta os valores de MAPE médios para as três abordagens de CML citadas, obtidos para a previsão de toda a série, feita um passo à frente e com intensidade de acoplamento $\varepsilon = 0,1$.

TABELA 5 - VALORES DE MAPE MÉDIOS DAS ABORDAGENS CML: CML FP, PREVISÃO DE FLUXO COM ALOCAÇÃO DE PERDAS; CML LINHA, PREVISÃO DE FLUXOS; E CML BARRA, PREVISÃO DAS CARGAS NAS BARRAS.

	<i>CML FP</i>	<i>CML Linha</i>	<i>CML Barra</i>
MAPE médio	4,47%	6,33%	5,77%

A aplicação do modelo de CML com acoplamento futuro, ou seja, utilizando a função do mapa logístico para descrever o comportamento do sistema, não apresentou resultados satisfatórios para as intensidades de acoplamento testadas, uma vez que a carga e geração do sistema foram demasiadamente elevadas. Isso ocorre pois a função aplicada não foi capaz de descrever a dinâmica do sistema. A figura 19 mostra os valores obtidos quando previstas as cargas nas barras utilizando a função do mapa logístico com $\varepsilon = 0,1$ e $\mu = 4$ para o ponto 8, sequência do primeiro domingo exibido na figura 17.

-80,8897	43,0071	37,8826	0,0000	0,0000	80,8898
-42,6534	-82,0547	36,2423	39,0886	49,3775	82,0550
-36,7507	-35,4250	55,9389	16,2369	0,0000	-55,9388
0,0000	-38,1540	-16,2080	58,9458	-4,5839	-58,9458
0,0000	-48,4019	0,0000	4,6041	43,7977	-43,7977
-79,4041	-78,9738	57,9170	59,9297	44,7936	$X(n+1)$

FIGURA 19 - FORMULAÇÃO MATRICIAL PARA UM PONTO DA SÉRIE (2º DOMINGO) COM CARGAS PREVISTAS UTILIZANDO A FUNÇÃO DO MAPA LOGÍSTICO.

Um ajuste que pode ser feito quando utilizado o modelo de redes de mapas acoplados está relacionado à intensidade de acoplamento. Essa variável define o grau com que determinado elemento é influenciado pelos seus vizinhos.

Foram realizadas simulações com o intuito de identificar a intensidade de acoplamento mais adequada ao problema. Um intervalo dos resultados pode ser observado na tabela 6, onde a escala de cores indica um comparativo entre os

valores, sendo verde para os erros que mais se aproximam de zero e, uma graduação de amarelo para vermelho nos maiores erros.

TABELA 6 - TESTES PARA IDENTIFICAR A INTENSIDADE DE ACOPLAMENTO (ϵ) MAIS ADEQUADA AO PROBLEMA. SÃO MOSTRADOS OS RESULTADOS PARA AS SEMANAS 2, 3 E 4.

	$\epsilon=0,30$	$\epsilon=0,20$	$\epsilon=0,16$	$\epsilon=0,14$	$\epsilon=0,12$	$\epsilon=0,1$	$\epsilon=0,08$	$\epsilon=0,06$	$\epsilon=0,04$	$\epsilon=0,02$	Melhor	
$X(n+2)$	1	6,68%	4,39%	3,48%	3,02%	2,57%	2,11%	1,65%	1,40%	1,36%	1,90%	$\epsilon=0,04$
	2	7,34%	4,83%	3,82%	3,32%	2,82%	2,32%	1,82%	1,32%	0,81%	0,31%	$\epsilon=0,02$
	3	6,04%	4,02%	3,42%	3,12%	2,82%	2,52%	2,22%	1,92%	1,62%	1,32%	$\epsilon=0,02$
	4	5,46%	4,11%	3,57%	3,31%	3,04%	2,77%	2,50%	2,49%	2,85%	3,21%	$\epsilon=0,06$
	5	5,10%	3,77%	3,43%	3,26%	3,09%	2,92%	2,75%	2,58%	2,41%	2,42%	$\epsilon=0,04$
	6	5,46%	3,03%	2,07%	1,69%	1,30%	0,91%	0,53%	0,46%	0,86%	1,35%	$\epsilon=0,06$
	7	6,71%	4,44%	3,53%	3,14%	2,93%	2,72%	2,50%	2,29%	2,08%	1,87%	$\epsilon=0,02$
$X(n+3)$	1	9,33%	7,06%	6,16%	5,71%	5,26%	4,82%	4,37%	3,92%	3,47%	3,02%	$\epsilon=0,02$
	2	7,74%	5,76%	5,14%	4,83%	4,53%	4,22%	3,91%	3,60%	3,29%	2,98%	$\epsilon=0,02$
	3	9,60%	7,33%	6,42%	5,97%	5,51%	5,06%	4,60%	4,15%	3,81%	3,48%	$\epsilon=0,02$
	4	5,97%	4,63%	4,10%	3,83%	3,56%	3,30%	3,03%	2,76%	2,50%	2,23%	$\epsilon=0,02$
	5	9,37%	7,75%	7,10%	6,78%	6,45%	6,13%	5,81%	5,48%	5,16%	4,84%	$\epsilon=0,02$
	6	15,99%	13,55%	12,57%	12,08%	11,59%	11,10%	10,61%	10,12%	9,64%	9,15%	$\epsilon=0,02$
	7	8,33%	7,10%	6,61%	6,36%	6,12%	5,87%	5,62%	5,38%	5,13%	4,89%	$\epsilon=0,02$
$X(n+4)$	1	8,61%	7,47%	7,02%	6,79%	6,57%	6,34%	6,11%	5,89%	5,66%	5,43%	$\epsilon=0,02$
	2	6,36%	3,93%	2,96%	2,47%	1,98%	1,50%	1,01%	0,52%	0,34%	0,62%	$\epsilon=0,04$
	3	5,27%	3,36%	2,60%	2,22%	1,84%	1,46%	1,25%	1,53%	1,92%	2,38%	$\epsilon=0,08$
	4	8,67%	7,26%	6,70%	6,42%	6,13%	5,85%	5,57%	5,61%	5,95%	6,29%	$\epsilon=0,08$
	5	3,74%	2,46%	1,94%	2,00%	2,38%	2,76%	3,15%	3,53%	3,91%	4,29%	$\epsilon=0,16$
	6	8,61%	7,35%	7,43%	7,46%	7,50%	7,53%	7,63%	8,32%	9,00%	9,69%	$\epsilon=0,20$
	7	8,66%	6,91%	6,20%	5,85%	5,50%	5,15%	4,80%	5,04%	5,34%	5,64%	$\epsilon=0,08$

A previsão de alguns dias apresentou melhor resultado quando aplicado uma intensidade de acoplamento baixa, como é o caso da terceira semana ($X(n+3)$) e alguns outros pontos.

Segundo Kaneko (1993), em um problema modelado por redes de mapas acoplados observa-se a sequência de transição do sistema envolvendo (i) estado aleatório congelado para (ii) seleção de padrão e depois (iii) caos espaço-temporal estabelecido por uma intermitência.

Quando a intensidade de acoplamento é baixa, os três estágios da sequência podem ser observados, pois se estabelece uma evolução lenta, porém com o crescimento da intensidade de acoplamento, aumenta a dificuldade em

observar os dois primeiros estágios. O domínio em análise acaba por tornar-se instável.

No apêndice se encontram os valores MAPE resultantes para a previsão de linhas com fluxo de potência e alocação de perdas quando a estimativa é realizada de forma contínua, ou seja, o próximo ponto é calculado com base no ponto recém-previsto.

Os resultados apontam que o acoplamento aplicado no modelo é adequado para curtos períodos de tempo, pois a dinâmica do sistema é rapidamente alterada. Até a quarta semana prevista, o erro médio obtido se situa na faixa inferior a 10%, conforme apresentado na figura 20.




FIGURA 20 – MÉDIA SEMANAL DOS MAPES OBTIDOS COM O MÉTODO DE CML FP PARA PREVISÃO DE MÚLTIPLOS PASSOS

Na figura 21 é exibida a série de MAPEs de um dia da semana específico, a quarta-feira.




FIGURA 21 - MAPE DA QUARTA-FEIRA OBTIDOS PARA 12 SEMANAS COM O MÉTODO DE CML FP PARA PREVISÃO DE MÚLTIPLOS PASSOS

Para validar a qualidade das previsões obtidas, utilizou-se a comparação do MAPE entre o modelo proposto e o modelo de regressão linear ajustado pelo método de mínimos quadrados em batelada (MQnR), apresentada na figura 22, para os quais, valores que mais se aproximam de zero representam melhores resultados.

Ambos os métodos foram aplicados sobre o conjunto de dados com 90 pontos de máximas diárias, considerando a sazonalidade semanal e sempre prevendo o próximo passo a partir de um existente, isto é, um passo-a-frente.

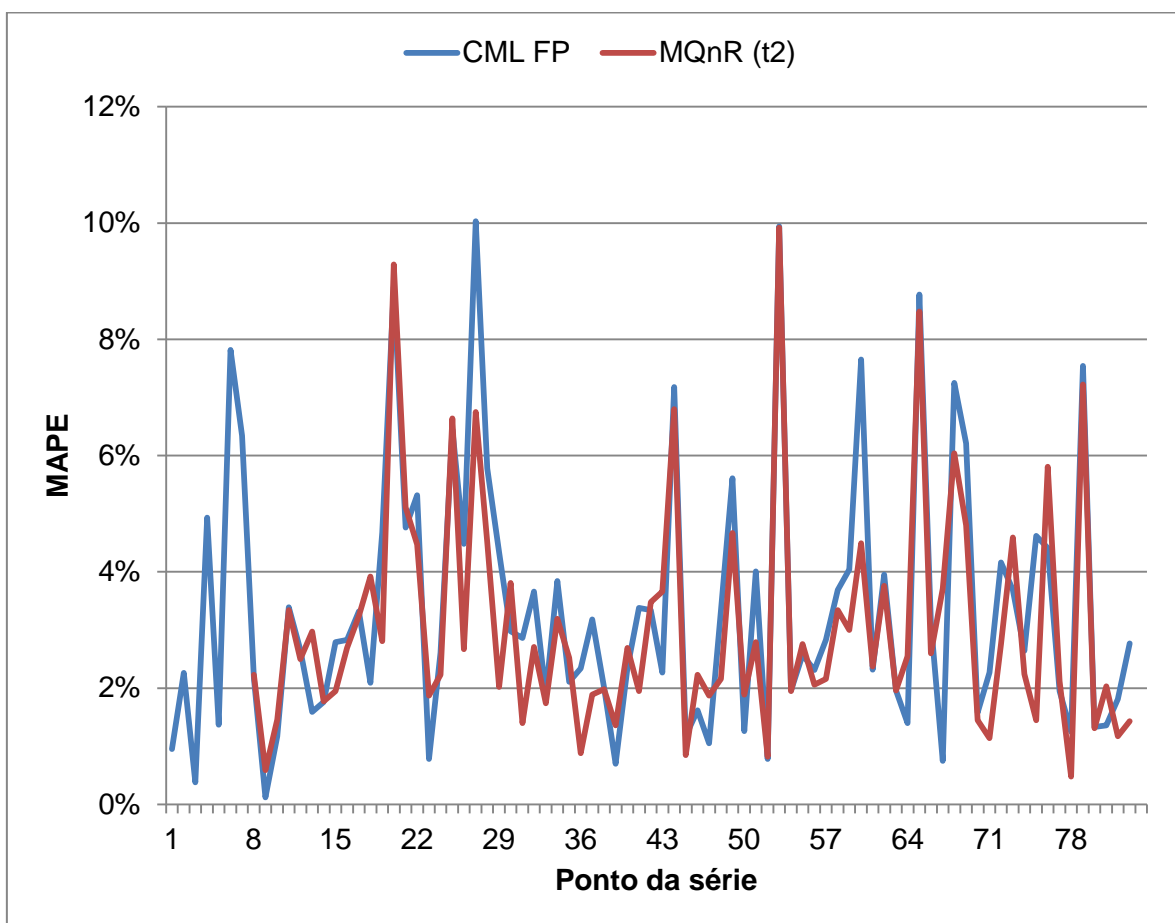


FIGURA 22 - MAPES RESULTANTES PARA AS PREVISÕES REALIZADAS PELO MÉTODO CML EM FLUXOS COM ALOCAÇÃO DE PERDAS (CML FP) E MÍNIMOS QUADRADOS BATELADA (MQNR)

Foram também calculados os MAPEs por barramento individualizado, os quais são visualizados na figura 23, (a) para a Barra 3, (b) para a Barra 4 e (c) para a Barra 5. Na figura, para cada dia da série analisado, as colunas amareladas representam o quanto o erro obtido no MQnR é maior que o erro obtido com CML FP.




FIGURA 23 – MAPES INDIVIDUALIZADOS POR BARRAMENTOS PARA PREVISÕES REALIZADAS COM CML FP E MQNR. COLUNAS AMARELADAS REPRESENTAM MAIOR ERRO DO MQNR EM COMPARAÇÃO COM O ERRO DE CML FP

5.2 Sistema de 14 barras

No sistema IEEE de 14 barras, foi aplicado, inicialmente considerando apenas a potência ativa, o método de previsão dos fluxos com CML e alocação de perdas (CML FP), o qual obteve melhor resultado no sistema de cinco barras. Para avaliação dos resultados foi também executado o modelo de regressão linear com os parâmetros ajustados por mínimos quadrados em batelada.

Para este último, o modelo de regressão linear, dentro de um limite, quanto maior o número de atrasos melhor é o resultado de sua previsão. Por este motivo, para a utilização do MQ, foram ponderados apenas dois atrasos para que a comparação com o método de CML fosse correta. Dessa forma, MQ tem acesso ao número mínimo de atrasos para sua execução, assim como a CML modelada.

Nos testes do sistema de 14 barras, os MAPEs obtidos foram analisados individualmente por barra e apresentados na tabela 7, onde consta um melhor resultado do método de CML comparado com MQ para as barras de carga 9 e 12.

Ressalta-se que com a desagregação dos resultados por barramento, é possível observar que algumas barras de carga não puderam ser ajustadas pelo método de CML FP (barras 5 e 11), apresentando um erro muito maior que o método de mínimos quadrados, prejudicando o resultado geral da CML. Analisando estes casos, observa-se que a modelagem proposta possui limitações para um sistema elétrico mais complexo, envolvendo outros equipamentos elétricos, como geradores síncronos e transformadores, não conseguindo capturar adequadamente a dinâmica do sistema.

Outra análise realizada foi com relação à intensidade de acoplamento, na tabela 7 também é apresentado o resultado da CML para a Barra 4, para a qual teve o melhor desempenho com a intensidade de acoplamento $\varepsilon = 1,05$, enquanto que para as demais barras, os melhores índices forem obtidos para a intensidade de acoplamento $\varepsilon = 0,05$.

TABELA 7 - MAPE POR BARRA DOS MÉTODOS CML POR FLUXO E ALOCAÇÃO DE PERDAS E MÍNIMOS QUADRADOS COM DOIS ATRASOS

	CMLFP $\varepsilon = 1,05$	CMLFP $\varepsilon = 0,05$	MQnR
Barra4	7,99%	156,55%	5,20%
Barra5	3386,92%	2125,79%	3,10%
Barra9	38,94%	7,98%	10,69%
Barra10	82,71%	56,81%	2,66%
Barra11	656,16%	205,24%	6,99%
Barra12	30,54%	5,07%	7,76%
Barra13	15,59%	7,32%	3,38%
Barra14	61,19%	11,38%	5,74%

Verificou-se que, as séries previstas das barras podem ser individualmente ajustadas de acordo com a variação da intensidade de acoplamento. As Figuras figura 24 e figura 25 demonstram um exemplo deste fato para a barra 9. Na figura 24 é exibida a curva de carga obtida na previsão com intensidade de acoplamento $\varepsilon = 1,1$, já na figura 25 é exposta a série prevista com o valor de $\varepsilon = 0,5$, onde se constata um ajuste mais aprimorado entre as curvas.

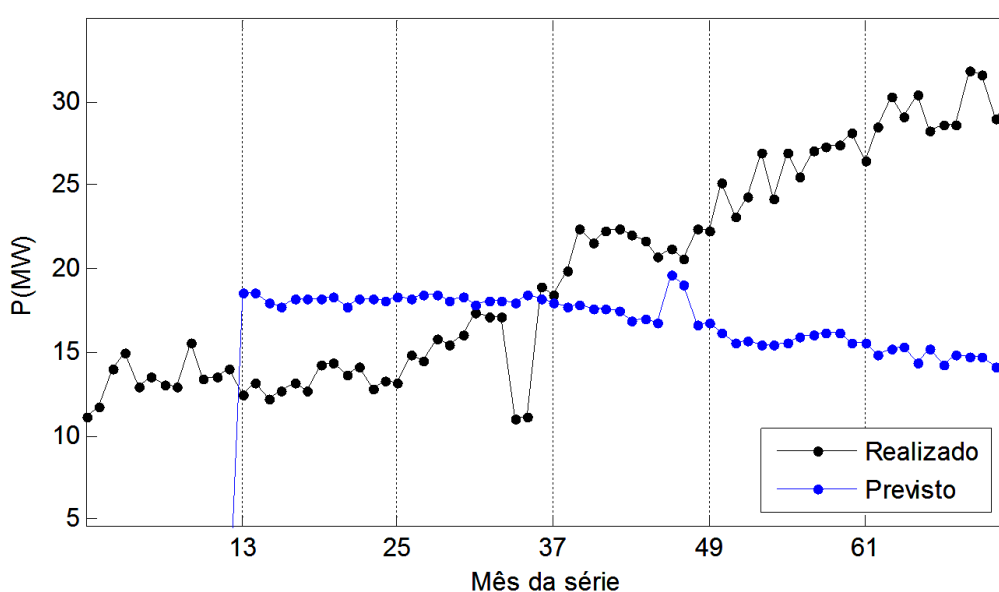


FIGURA 24 - CARGA DA BARRA 9 REALIZADA E PREVISTA POR CML FP E INTENSIDADE DE ACOPLAMENTO $\varepsilon = 1,1$




FIGURA 25 - CARGA DA BARRA 9 REALIZADA E PREVISTA POR CML FP E INTENSIDADE DE ACOPLAMENTO $E=0,5$

As séries obtidas para as barras de carga 12, 13 e 14 também apresentaram um ajuste adequado comparando o previsto com o realizado. Essas séries podem ser visualizadas nas figuras figura 26, figura 27 e figura 28.




FIGURA 26 - CARGA DA BARRA 12 REALIZADA E PREVISTA POR CML FP E INTENSIDADE DE ACOPLAMENTO $E=0,5$




FIGURA 27 - CARGA DA BARRA 13 REALIZADA E PREVISTA POR CML FP E INTENSIDADE DE ACOPLAMENTO $E=0,5$




FIGURA 28 - CARGA DA BARRA 14 REALIZADA E PREVISTA POR CML FP E INTENSIDADE DE ACOPLAMENTO $E = 0,5$

Durante o desenvolvimento foi possível identificar que alguns barramentos possuíam uma dinâmica mais acentuada na série de potência reativa. Para melhorar a resposta do método proposto, passou a ser considerada a parte imaginária da

formulação matricial com o intuito de capturar a influência do reativo, doravante denominada CMLFP Complexo.

O MAPE geral do método proposto com e sem o reativo é apresentado na tabela 8 para a intensidade de acoplamento de 0,05. O resultado geral, ainda que comprometido pelo erro de previsão em alguns barramentos, aponta que com o uso da parte ativa e reativa é possível aproximar melhor o resultado do sistema.

TABELA 8 - VALORES MAPE GERAL DO SISTEMA DE 14 BARRAS PARA OS MÉTODOS CMLFP (POTÊNCIA ATIVA) E CMLFP COMPLEXO (POTÊNCIA ATIVA E REATIVA), ($\epsilon = 0,05$)

	<i>CMLFP</i>	<i>CMLFP Complexo</i>
MAPE ($\epsilon = 0,05$)	268,83%	259,10%

Com o exercício de variar a intensidade do acoplamento é atingido o resultado geral apresentado na tabela 9, onde o método proposto com a parte real exibe em uma primeira análise uma resposta melhor em comparação ao uso de números complexos, porém quando os resultados são vistos de forma mais detalhada observa-se que o fluxo de potência não convergiu em alguns pontos com os valores obtidos pela previsão usando apenas a potência ativa. Esse fato não se repete quando é adicionado o reativo na modelagem, indicando que o uso da parte imaginária, além de melhorar a resposta do método, leva os valores previstos a um patamar mais factível.

TABELA 9 - VALORES MAPE GERAL DO SISTEMA DE 14 BARRAS PARA OS MÉTODOS CMLFP (POTÊNCIA ATIVA) E CMLFP COMPLEXO (POTÊNCIA ATIVA E REATIVA), ($\epsilon = 0,01$)

	<i>CMLFP</i>	<i>CMLFP Complexo</i>
MAPE ($\epsilon = 0,01$)	250,71%	252,34%

Quando é utilizado um sistema pequeno e malhado, como é o caso do sistema teste de cinco barras, a proporção entre elementos vazios comparada com sítios valorados, é pequena. À medida que o sistema é expandido a tendência aponta para que este cenário seja invertido, ou seja, quanto maior o sistema, maior é o grau de esparsidade da matriz formulada, pois poucos elementos possuem de fato uma conexão direta.

Uma sugestão para contornar este problema da esparsidade seria expandir o alcance dos acoplamentos, agregando desta forma, mais vizinhos à barra.

6 Conclusões e Trabalhos Futuros

Em sistemas de potência a previsão de carga é um problema bastante estudado. Existem muitos trabalhos na área propondo diferentes métodos para obter previsões robustas, isto é, estimativas da demanda com baixo índice de erro.

O objetivo deste projeto foi adicionar variáveis relacionadas à topologia de uma rede, aplicando o conceito de sistemas dinâmicos através do modelo de redes de mapas acoplados à previsão de carga, para o qual, na literatura, não foram encontradas aplicações semelhantes ao método proposto em sistemas de potência.

As informações das grandezas elétricas do sistema, como resistência, reatância e *shunt* das linhas que conectam as barras foram também consideradas, através do uso do fluxo de potência.

Pela agregação dessas informações, 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.

No comparativo entre o método proposto e mínimos quadrados, os resultados considerando um histórico pequeno foram equivalentes, porém o método de mínimos quadrados precisou ser executado para cada série de dados das barras. Isto significa que se um sistema contar com 100 (cem) barramentos de carga, serão necessárias 100 (cem) execuções do método de regressão linear para todos os instantes de tempo das séries, enquanto que a cada iteração da CML todo o sistema é previsto.

Nos resultados segregados por barramento, a modelagem de CML para previsão de fluxos com alocação de perdas, em algumas barras ou instantes de tempos, apresentou melhores resultados que o método de regressão linear ajustado por mínimos quadrados, indicando o seu potencial de aplicação no referido problema.

No desenvolvimento do método, a agregação de reativo na formulação do problema foi um avanço no sentido que permitiu que a resposta do método proposto fosse melhorada, tanto na questão de aproximar o estimado do realizado, quanto na previsão de valores mais próximos de um conjunto factível contribuindo para a convergência do fluxo de potência.

A aplicação da modelagem de CML em sistemas de potência está atrelada à topologia do sistema elétrico modelado e possivelmente aos equipamentos aplicados. Nesse sentido, um fator que pode ser melhorado em trabalhos futuros é o aperfeiçoamento da modelagem para sistemas elétricos mais complexos, contendo geradores síncronos e transformadores. Na questão de topologia, um sistema radial ou a existência de barramentos isolados prejudica a utilização dos vizinhos como influência na demanda prevista. Parte dessa vulnerabilidade do método poderá ser mitigada em trabalhos futuros com a expansão do alcance do acoplamento, sendo considerado um maior número de vizinhos na modelagem para cada barra analisada.

Outro ponto de interesse é a influência da variação na intensidade de acoplamento para cada barramento individualmente. Em alguns casos, a alteração desta variável permitiu um ajuste mais adequado da série prevista com a realizada. Sugere-se também como trabalho futuro a modelagem do fator de acoplamento individualizado por barra do sistema.

REFERÊNCIAS

ALAMANIOTIS, M.; IKONOMOPOULOS, A.; TSOUKALAS, L. H. Evolutionary Multiobjective Optimization of Kernel-Based Very-Short-Term Load Forecasting, **IEEE Transactions on Power Systems**, p.01-08, 2012.

BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C. **Time Series Analysis: Forecasting and Control**. 3 ed. New Jersey:Prentice Hall, 1994.

BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDERMIR, T. B. **Redes neurais artificiais: teoria e aplicações**. Rio de Janeiro: LTC, 2000.

BRASIL. Ministério de Minas e Energia - MME. **Modelo institucional do setor elétrico**. Brasília: Ministério de minas e energia, 2003.

CARPINTEIRO, O. A. S.; ALVES DA SILVA, A.P.; FEICHAS, C. H. L. A Hierarchical Neural Model in Short-Term Load Forecasting. **IEEE-INNS-ENNS International Joint Conference on Neural Networks (IJCNN'00)**, Italy, jul., 2000.

CHEN, G.J.; LI, K. K.; CHUNG, T. S.; SUN, H. B.; TANG, G. Q. Application of an innovative combined forecasting method in power system load forecasting. **Electric Power Systems Research**, v. 59, p. 131-137, 2001.

CONEJO, A. J.; GALIANA, F. D.; KOCKAR, I. Z-Bus loss Allocation. **IEEE Transactions on Power Systems**, v. 16, n. 1, p. 105-110, fev., 2001.

FAN, S.; CHEN, L.; LEE, W. Short-Term Load Forecasting Using Comprehensive Combination Based on Multimeteorological Information. **IEEE Transactions on Industry Applications**, v.45, n.4, p.1460-1466, july-aug., 2009.

FAY, D.; RINGWOOD, J.V. On the Influence of Weather Forecast Errors in Short-Term Load Forecasting Models, **IEEE Transactions on Power Systems**, v. 25, n. 3, p.1751-1758, aug., 2010.

FERREIRA, V. H. **Desenvolvimento de modelos neurais autônomos para previsão de carga elétrica**. Rio de Janeiro: COPPE/UFRJ, 2008

HAYKIN, S. **Redes neurais: princípios e prática**. Tradução Paulo Martins Engel. 2. ed. Porto Alegre: Bookman, 2001.

HERZALLAH, R.; LOWE, D. Comparison between conventional and stochastic pinning control. In: 19th Mediterranean Conference on Control and Automation, 2011. ISBN 978-1-4577-0124-5.

JOST, J.; KOLWANKAR, K. M. Evolution of network structure by temporal learning, **Physica A: Statistical Mechanics and its Applications**, v. 388, n. 9, p. 1959-19661 May, 2009.

JUANG, J.; LI, C.; LIANG, Y. Global synchronization in lattices of coupled chaotic systems. **CHAOS: American Institute of Physics**, v. 17, 2007. DOI 10.1063/1.2754668.

KANDIL, M. S.; EL-DEBEIKY, S. M.; HASANIEN, N. E. Long-term load forecasting for fast developing utility using a knowledge-based expert system. **IEEE Transactions on Power Systems**, v. 17, n. 2, p. 491-496, 2002.

KANEKO, K. Overview of coupled map lattices. **CHAOS: American Institute of Physics**, v. 2, n. 3, p 279-282, 1992.

KANEKO, K. **Theory and applications of coupled map lattices**. Inglaterra: John Wiley & Sons, 1993.

MAKRIDAKIS, S.; WHEELWRIGHT, S. C.; HYNDMAN, R. J. **Forecasting methods and applications**. 3.ed. New York: John Wiley and Sons, 1998. Cap. 5, p. 185-240.

MARCOS-NIKOLAUS, P.; MARTIN-GONZÁLEZ, J. M. Spatial forecasting: Detecting determinism from single snapshots. **International journal of bifurcation and chaos**, v. 12, n. 2, p. 369-376, 2002.

MATHWORKS. **Matlab. Versão R2010a**. [S.l.]: The MathWorks Inc., 2010.

MOGHRAM, I.; RAHMAN, S.; Analysis and Evaluation of Five Short-term Load Forecasting Techniques. **IEEE Transactions on Power Systems**, v. 4, n. 4, p. 1484-1491., 1989.

MURUGANANDAM, P.; FRANCISCO, G. Local dimension and finite time prediction in coupled map lattices. **PRAMANA - Journal of physics**, v. 64, n. 3, p.381-387, mar., 2005.

ONS, OPERADOR NACIONAL DO SISTEMA ELÉTRICO. **Plano de ampliações e reforços**: Versão executiva. 2011.

ONS, OPERADOR NACIONAL DO SISTEMA ELÉTRICO. **Procedimentos de Rede - Módulo 5**: Consolidação da Previsão de Carga. 2008.

PAN, Y.; BILLINGS, S.A. Neighborhood Detection for the Identification of Spatiotemporal Systems. **IEEE Trans. On Systems, Man, and Cybernetics – Part B: Cybernetics**, v. 38, n. 3, p. 846-854, June 2008.

PAPALEXOPOULOS, A. D.; HESTERBERG, T. C. A Regression-Based Approach to Short-Term System load Forecasting. **IEEE Trans. on Power Systems**, v. 5, n. 4, p. 1535-1547, 1990.

PAREKH, N.; PARTHASARATHY, S.; SINHA, S. Global and local control of spatiotemporal chaos in coupled map lattices. **Physical Review Letters**, v. 81, n. 7, p. 1401-1404, 17 ago., 1998.

PARLITZ, U.; MERKWIRTH, C. Prediction of spatiotemporal time series based on reconstructed local states. **Physical Review Letters**, v. 84, n. 9, p. 1890-1893, 28 fev., 2000.

PATIL, D. J.; HUNT, B. R.; KALNAY, E.; YORKE, J. A.; OTT, E. Local low dimensionality of atmospheric dynamics. **Physical Review Letters**, v. 86, n. 26, p. 5878-5881, 25 jun., 2001

PAVLOV, E. A.; OSIPOV, G. V.; CHAN, C.K.; SUYKENS, J. A. K. Map-based model of the cardiac action potential. **Physics Letters A**, v. 375, n. 32, p. 2894-25, july, 2011.

PONTES, J. C. A. **Dinâmica de Redes de Mapas Acoplados**. Curitiba: UFPR, 2008.

RAND, D. A.; WILSON, H. B. Using spatio-temporal chaos and intermediate-scale determinism to quantify spatially extended ecosystems. **Proceedings: Biological Sciences**, Grã-Bretanha: The royal society p. 111-117, 1995. DOI 10.1098/rspb.1995.0017.

REIS, A.J.R.; ALVES DA SILVA, A.P. Feature Extraction Via Multi-Resolution Analysis for Short-Term Load Forecasting, **IEEE Transactions on Power Systems**, v.20, n.1, p. 189-198, fev., 2005.

RODRIGUES, F. **Análise de metodologias para alocação de perdas em sistemas elétricos de potência operando segundo mercado pool**. Curitiba: UFPR, 2007.

SOUZA, C. R.; CAMARGO, M. E. **Análise e previsão de séries temporais: Os modelos arima**. 2. ed. Rio de Janeiro: Gráfica e Editora Regional, 2004.

SRINIVASAN, D.; TAN, S. S.; CHANG, C. S.; CHAN, E. K. Practical implementation of a hybrid fuzzy neural network for one-day-ahead load forecasting. **IEE Proc.-Gener., Transm., Distrib.**, v. 145, n. 6, p. 687-692. 1998.

TAYLOR, J.W. Short-Term Load Forecasting With Exponentially Weighted Methods. **IEEE Transactions on Power Systems**, v. 27, n. 1, p.458-464, feb., 2012.

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.


WEI, H. L.; BILLINGS, S. A.; ZHAO, Y. F.; GUO, L. Z. An adaptive wavelet neural network for spatio-temporal system identification. **Neural Networks**, v. 23, n. 10, p. 1286-1299, dec., 2010.

ZIMMERMAN, R. D.; MURILLO-SÁNCHEZ, C. E.; THOMAS, R. J. MATPOWER Steady-State Operations, Planning and Analysis Tools for Power Systems Research and Education. **IEEE Transactions on Power Systems**, vol. 26, n. 1, p. 12-19, fev., 2011.


APÊNDICES

I - Exemplo de curvas de carga realizadas e previstas pelo método mínimos quadrados batelada para a Barra 3 do sistema de cinco barras


Mínimos quadrados batelada, Atraso 2 - Barra de carga 3




Mínimos quadrados batelada, Atraso 3 - Barra de carga 3




Mínimos quadrados batelada, Atraso 4 - Barra de carga 3



Mínimos quadrados batelada, Atraso 5 - Barra de carga 3



Mínimos quadrados batelada, Atraso 6 - Barra de carga 3



II - MAPE para a série de dados prevendo 12 semanas incompletas de forma contínua, sazonalidade semanal e intensidade de acoplamento $\epsilon = 0,1$.

Previsão de Linha com FP e alocação de perdas (Contínuo)											
X (n+1)	1	3,29%	X (n+4)	1	8,51%	X (n+7)	1	17,56%	X (n+10)	1	27,85%
	2	4,23%		2	9,73%		2	24,86%		2	37,69%
	3	2,15%		3	8,76%		3	19,18%		3	30,26%
	4	3,64%		4	7,51%		4	14,38%		4	23,80%
	5	2,71%		5	8,77%		5	18,02%		5	27,47%
	6	8,16%		6	9,61%		6	20,14%		6	32,92%
	7	6,63%		7	6,10%		7	13,42%		7	24,81%
X (n+2)	1	4,23%	X (n+5)	1	14,59%	X (n+8)	1	18,36%	X (n+11)	1	28,52%
	2	6,23%		2	10,02%		2	21,08%		2	43,28%
	3	4,01%		3	12,60%		3	20,67%		3	37,82%
	4	0,62%		4	8,64%		4	21,98%		4	28,81%
	5	4,88%		5	10,77%		5	22,62%		5	37,93%
	6	7,95%		6	14,04%		6	25,24%		6	43,24%
	7	8,14%		7	9,23%		7	16,43%		7	29,85%
X (n+3)	1	8,61%	X (n+6)	1	14,84%	X (n+9)	1	23,59%	X (n+12)	1	32,58%
	2	8,62%		2	14,96%		2	27,70%		2	44,22%
	3	8,79%		3	15,93%		3	27,79%		3	43,02%
	4	2,72%		4	10,68%		4	20,98%		4	31,16%
	5	9,05%		5	14,56%		5	28,87%		5	39,73%
	6	16,70%		6	17,04%		6	32,55%		6	43,22%
	7	9,33%		7	11,16%		7	20,73%			

III - MAPE para a série de dados (90 pontos, 12 semanas incompletas), considerando sazonalidade semanal e intensidade de acoplamento 0,1

		CML FP	CML Linha	CML Barra					
X (n+1)	1	3,29%	5,61%	5,43%	X (n+7)	1	3,47%	3,71%	3,31%
	2	4,23%	5,00%	4,97%		2	8,75%	12,01%	8,41%
	3	2,15%	5,31%	5,28%		3	3,02%	6,23%	4,65%
	4	3,64%	4,93%	5,88%		4	3,85%	6,49%	3,80%
	5	2,71%	6,32%	4,98%		5	2,59%	5,94%	4,95%
	6	8,16%	10,57%	7,00%		6	4,98%	8,10%	5,75%
	7	6,63%	11,55%	11,48%		7	7,15%	10,26%	9,07%
X (n+2)	1	2,11%	6,88%	6,67%	X (n+8)	1	2,26%	6,77%	6,62%
	2	2,32%	5,33%	5,27%		2	3,09%	9,57%	9,25%
	3	2,52%	6,04%	6,03%		3	1,84%	6,18%	6,06%
	4	2,77%	8,35%	8,35%		4	11,34%	3,80%	7,50%
	5	2,92%	5,09%	5,00%		5	3,83%	6,35%	4,40%
	6	0,91%	6,64%	6,47%		6	2,97%	3,92%	3,72%
	7	2,72%	5,47%	5,31%		7	3,08%	3,78%	3,58%
X (n+3)	1	4,82%	7,87%	6,85%	X (n+9)	1	5,06%	7,26%	6,93%
	2	4,22%	7,65%	6,96%		2	5,87%	4,54%	3,34%
	3	5,06%	8,12%	5,17%		3	6,22%	6,00%	3,11%
	4	3,30%	5,22%	5,07%		4	8,65%	12,08%	12,02%
	5	6,13%	9,33%	5,96%		5	3,63%	3,78%	3,09%
	6	11,10%	7,32%	9,44%		6	4,84%	4,23%	4,86%
	7	5,87%	3,40%	4,89%		7	4,07%	4,26%	4,09%
X (n+4)	1	6,34%	3,17%	4,71%	X (n+10)	1	3,98%	6,76%	4,40%
	2	1,50%	6,18%	6,05%		2	9,28%	8,55%	9,41%
	3	1,46%	7,58%	7,44%		3	1,26%	5,65%	5,40%
	4	5,85%	11,07%	11,19%		4	3,17%	5,89%	5,28%
	5	2,76%	6,45%	6,63%		5	6,31%	8,80%	8,58%
	6	7,53%	11,89%	11,84%		6	5,12%	7,64%	7,55%
	7	5,15%	7,06%	6,96%		7	4,06%	5,60%	5,48%
X (n+5)	1	6,37%	8,81%	8,77%	X (n+11)	1	1,78%	7,74%	7,45%
	2	3,98%	3,30%	4,54%		2	4,72%	3,80%	5,13%
	3	4,34%	5,91%	2,54%		3	5,83%	2,87%	4,83%
	4	5,15%	4,25%	1,78%		4	5,00%	3,36%	3,89%
	5	3,46%	6,22%	3,99%		5	7,17%	6,00%	2,41%
	6	5,80%	6,18%	3,31%		6	6,95%	4,22%	2,51%
	7	3,70%	7,12%	5,37%		7	4,68%	5,38%	3,71%
X (n+6)	1	2,95%	4,28%	4,29%	X (n+12)	1	3,83%	6,62%	4,63%
	2	5,06%	4,38%	3,38%		2	9,58%	9,55%	8,17%
	3	3,22%	4,35%	4,19%		3	3,63%	4,69%	4,56%
	4	2,44%	5,11%	5,01%		4	3,13%	5,44%	5,25%
	5	3,94%	4,28%	4,16%		5	1,66%	6,88%	6,65%
	6	3,78%	4,68%	5,50%		6	2,53%	8,13%	8,01%
	7	4,66%	2,42%	3,22%					
				Média		4,47%	6,33%	5,77%	

IV - Comparativo entre o modelo de redes de mapas acoplados nas linhas com FP e mínimos quadrados em batelada com 2, 3, 4, 5 e 6 atrasos de tempo

	CML FP	MQnR (t2)	MQnR (t3)	MQnR (t4)	MQnR (t5)	MQnR (t6)										
X (n+1)	1	0,95%						X (n+7)	1	2,27%	3,66%	2,84%	3,15%	3,37%	1,56%	
	2	2,26%							2	7,18%	6,80%	6,38%	6,57%	6,40%	5,44%	
	3	0,38%								3	1,18%	0,85%	1,03%	0,62%	0,37%	1,19%
	4	4,93%								4	1,62%	2,23%	2,09%	1,36%	1,01%	2,62%
	5	1,37%								5	1,05%	1,87%	2,22%	2,06%	1,63%	2,99%
	6	7,82%								6	3,33%	2,16%	1,56%	2,01%	1,97%	2,85%
	7	6,34%								7	5,61%	4,67%	4,19%	2,28%	1,95%	1,72%
X (n+2)	1	2,17%	2,23%					X (n+8)	1	1,26%	1,89%	2,94%	2,07%	1,78%	0,44%	
	2	0,12%	0,59%						2	4,01%	2,79%	2,86%	2,80%	3,48%	2,37%	
	3	1,17%	1,46%						3	0,78%	0,82%	1,24%	1,52%	1,63%	1,73%	
	4	3,39%	3,34%						4	9,94%	9,92%	10,73	10,89	7,40%	7,58%	
	5	2,66%	2,50%						5	1,96%	1,95%	2,45%	2,70%	2,41%	2,30%	
	6	1,59%	2,97%						6	2,57%	2,76%	1,91%	2,45%	1,11%	1,77%	
	7	1,76%	1,77%						7	2,31%	2,06%	2,16%	2,80%	3,67%	4,23%	
X (n+3)	1	2,79%	1,95%	2,13%				X (n+9)	1	2,83%	2,16%	2,21%	1,26%	1,50%	1,24%	
	2	2,83%	2,69%	3,66%					2	3,69%	3,34%	3,32%	3,22%	1,63%	0,60%	
	3	3,32%	3,24%	3,16%					3	4,04%	3,00%	3,06%	2,65%	2,41%	2,90%	
	4	2,09%	3,92%	3,74%					4	7,65%	4,49%	3,72%	3,20%	1,92%	1,80%	
	5	4,68%	2,81%	2,87%					5	2,32%	2,37%	2,62%	3,33%	4,32%	2,27%	
	6	8,90%	9,29%	7,84%					6	3,95%	3,76%	3,47%	4,64%	2,98%	1,00%	
	7	4,76%	5,11%	4,56%					7	1,96%	1,96%	3,40%	5,04%	6,29%	5,86%	
X (n+4)	1	5,32%	4,47%	3,46%	3,39%			X (n+10)	1	1,40%	2,55%	2,67%	2,21%	1,73%	1,46%	
	2	0,78%	1,87%	2,49%	3,47%				2	8,77%	8,48%	8,25%	6,52%	4,84%	2,39%	
	3	2,61%	2,23%	2,12%	2,05%				3	3,13%	2,60%	2,43%	2,17%	2,08%	1,79%	
	4	6,45%	6,64%	7,07%	6,59%				4	0,75%	3,71%	1,89%	2,98%	2,42%	1,95%	
	5	4,48%	2,67%	2,50%	2,13%				5	7,25%	6,04%	5,77%	5,62%	5,28%	2,95%	
	6	10,03	6,75%	5,42%	3,98%				6	6,21%	4,80%	4,53%	4,37%	3,53%	4,52%	
	7	5,78%	4,51%	3,67%	2,46%				7	1,58%	1,45%	2,08%	0,73%	2,54%	2,97%	
X (n+5)	1	4,34%	2,02%	2,21%	2,20%	2,57%		X (n+11)	1	2,27%	1,14%	1,21%	1,52%	1,38%	0,62%	
	2	2,98%	3,81%	2,91%	2,51%	1,76%			2	4,16%	2,76%	3,10%	3,76%	3,42%	0,66%	
	3	2,86%	1,40%	1,14%	1,49%	1,53%			3	3,69%	4,59%	4,07%	4,29%	5,05%	4,09%	
	4	3,66%	2,71%	2,02%	2,90%	1,65%			4	2,64%	2,24%	0,63%	1,08%	3,16%	1,97%	
	5	1,90%	1,74%	1,46%	1,07%	1,25%			5	4,62%	1,45%	1,89%	1,97%	1,62%	1,96%	
	6	3,84%	3,19%	2,77%	3,87%	1,00%			6	4,41%	5,81%	5,76%	5,22%	5,67%	5,88%	
	7	2,11%	2,52%	0,60%	1,03%	0,88%			7	1,95%	2,12%	3,09%	4,03%	3,08%	2,06%	
X (n+6)	1	2,34%	0,88%	0,25%	0,49%	0,79%	1,62%	X (n+12)	1	1,25%	0,48%	0,50%	0,99%	0,55%	1,00%	
	2	3,18%	1,89%	1,26%	2,40%	1,95%	2,96%		2	7,54%	7,22%	2,43%	1,63%	1,68%	0,97%	
	3	2,01%	1,98%	2,49%	2,42%	1,70%	2,24%		3	1,33%	1,31%	1,42%	1,20%	1,13%	0,98%	
	4	0,70%	1,36%	1,06%	1,39%	1,46%	2,78%		4	1,36%	2,03%	2,07%	1,28%	3,11%	4,02%	
	5	2,35%	2,69%	2,14%	2,12%	2,58%	3,68%		5	1,81%	1,17%	1,37%	1,70%	1,22%	1,34%	
	6	3,38%	1,95%	4,72%	3,38%	1,30%	0,67%		6	2,77%	1,43%	2,86%	2,61%	2,78%	3,73%	
	7	3,34%	3,48%	2,27%	2,80%	2,20%	2,61%		Média	3,39%	3,07%	2,99%	2,85%	2,51%	2,47%	