

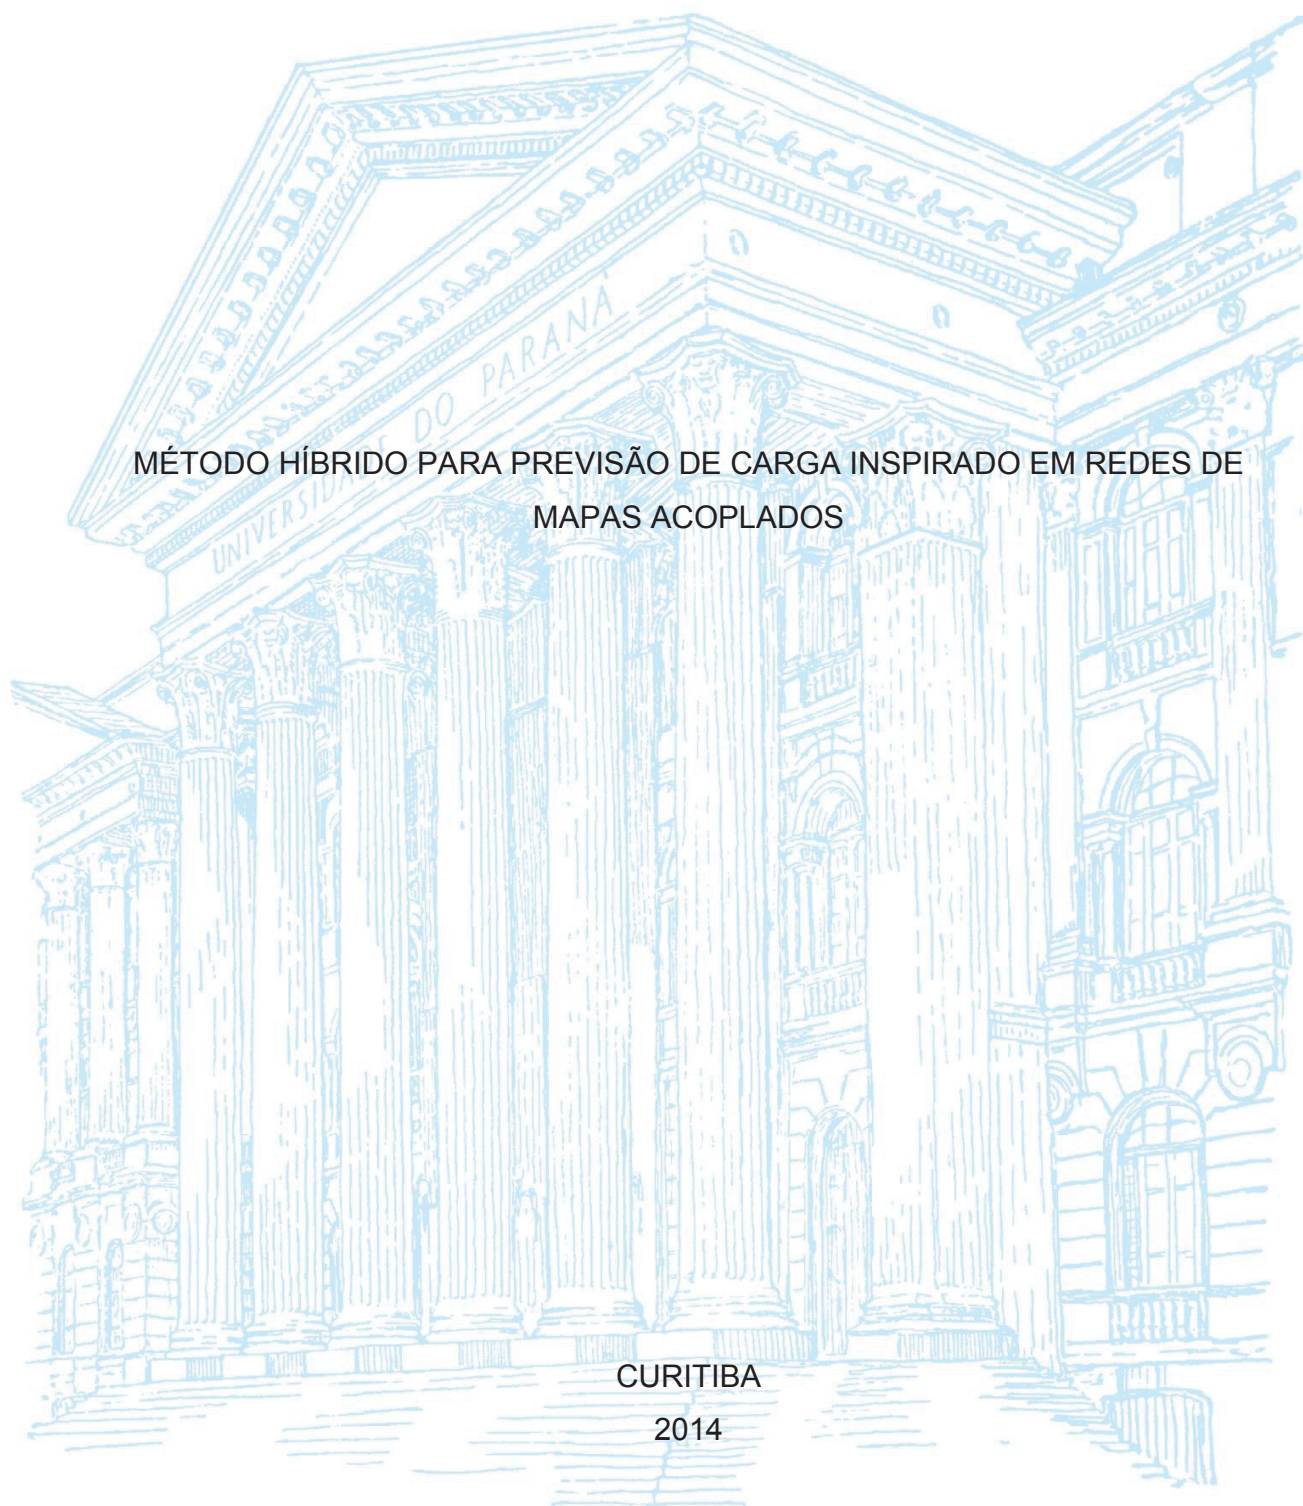
UNIVERSIDADE FEDERAL DO PARANÁ

ANA PAULA OENING

MÉTODO HÍBRIDO PARA PREVISÃO DE CARGA INSPIRADO EM REDES DE
MAPAS ACOPLADOS

CURITIBA

2014



ANA PAULA OENING

MÉTODO HÍBRIDO PARA PREVISÃO DE CARGA INSPIRADO EM REDES DE
MAPAS ACOPLADOS

Tese apresentada no curso de Pós-Graduação em Métodos Numéricos em Engenharia, Área de Concentração em Programação Matemática, Departamento de Engenharia Civil, Departamento de Matemática dos Setores de Tecnologia e de Ciências Exatas da Universidade Federal do Paraná, como parte das exigências para a obtenção do título de Doutor em Métodos Numéricos em Engenharia.

Orientadora: Profa. Dra. Maria Teresinha Arns Steiner
Coorientador: Prof. Dr. Alexandre Rasi Aoki

CURITIBA

2014

Catálogo na Fonte: Sistema de Bibliotecas, UFPR
Biblioteca de Ciência e Tecnologia

- O28m Oening, Ana Paula
Método híbrido para previsão de carga inspirado em redes de mapas acoplados[recurso eletrônico] / Ana Paula Oening – Curitiba, 2014.
- Tese - Universidade Federal do Paraná, Setores de Tecnologia e de Ciências Exatas, Programa de Pós-graduação em Métodos Numéricos em Engenharia.
Orientadora: Profa. Dra. Maria Teresinha Arns Steiner
Coorientador: Prof. Dr. Alexandre Rasi Aoki.
1. Sistemas de energia elétrica. 2. Redes de Mapas Acoplados. 3. Inteligência artificial. I. Universidade Federal do Paraná. II. Steiner, Maria Teresinha Arns. III. Aoki, Alexandre Rasi. IV. Título.

CDD: 621.381044

Bibliotecária: Roseny Rivelini Morciani CRB-9/1585

TERMO DE APROVAÇÃO

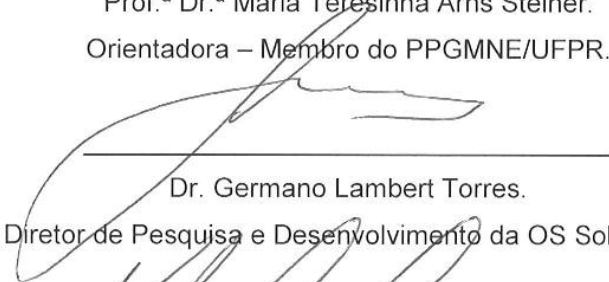
ANA PAULA OENING

MÉTODO HÍBRIDO PARA PREVISÃO DE CARGA INSPIRADO EM REDES DE
MAPAS ACOPLADOS.

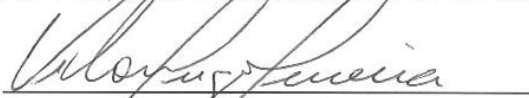
Tese aprovada como requisito parcial para obtenção do grau de doutora no Programa de Pós-Graduação em Métodos Numéricos em Engenharia, da Universidade Federal do Paraná, pela seguinte banca examinadora:



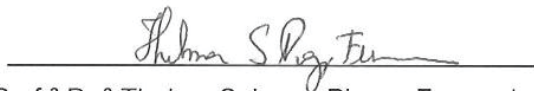
Prof.ª Dr.ª Maria Teresinha Arns Steiner.
Orientadora – Membro do PPGMNE/UFPR.



Dr. Germano Lambert Torres.
Diretor de Pesquisa e Desenvolvimento da OS Soluções.



Prof. Dr. Vitor Hugo Ferreira.
Membro da Universidade Federal Fluminense/RJ.



Prof.ª Dr.ª Thelma Solange Piazza Fernandes.
Membro do Dep. de Engenharia Elétrica da UFPR.



Prof.ª Dr.ª Elizabeth Wegner Karas.
Membro do Dep. de Matemática da UFPR.

Curitiba, 26 de setembro de 2014.

RESUMO

As previsões de carga são foco de interesse por parte das operadoras do sistema e das 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 técnica e econômica. Ao longo dos anos, diversos métodos têm sido desenvolvidos e aplicados ao problema de previsão, alguns inclusive utilizando variáveis externas que influenciam indiretamente no comportamento das cargas, porém normalmente não considerando a topologia do sistema. Para unir a previsão por barramento à topologia 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 meio desta técnica, faz-se necessário adicionar variáveis que especifiquem as características da rede, como as conexões entre as barras. Neste trabalho foi desenvolvido um método híbrido para previsão de carga inspirado nos conceitos de Redes de Mapas Acoplados. Neste método, são realizadas previsões individuais para as barras através de técnicas de previsão de séries temporais, cujos resultados são acoplados de forma a considerar a topologia do sistema. Para testar o método proposto foram utilizados dois sistemas teste com dados reais, um com 11 e o outro com 14 barras. Os resultados mostraram que para sistemas maiores e com melhor qualidade nos dados históricos, o acoplamento das previsões retorna menores erros de previsão. Em sistemas com maior quantidade de erros a estratégia de acoplamento é prejudicada, pois se perde a influência que as barras exercem umas sobre as outras. Outro resultado interessante foi que em todas as vezes que uma técnica apresenta erro maior que a média de erros obtida com todos os métodos de previsão o acoplamento traz benefícios e reduz o erro de previsão da barra.

Palavras Chaves: Redes de Mapas Acoplados. Previsão de Carga. Sistemas Híbridos. Inteligência Artificial.

ABSTRACT

Load forecasting is an interesting task focused by system operators and power utilities because their results are the basis to the decision-making in power systems planning, operation and control. Over the years, several methods have been developed and applied to load forecasting problem, some of them use external variables which influence the loads behavior in an indirect way, but usually without considering the system topology. The characteristics of power grid can be added to load forecasting by applying dynamic systems theory, such as coupled map lattices, a model which includes spatially extended systems with time and space dynamic. When modeling a power system by this technique, it is necessary to add to the problem variables which specify network topology, such as connections between buses. In this work, it was developed a hybrid method for load forecast inspired by the concepts of coupled map lattices. In this method, first the forecast for the buses are performed by a technique of time series forecast. Then the results are coupled using system topology. This methodology was tested using two test systems, one with 11 buses and another with 14 buses, including real data series. The results showed that for larger and better quality of historical data systems, the coupling of forecasts returns smaller prediction errors. In systems with more problems the coupling is worse, because the influences between the buses are lost. Another interesting result was that at all times that the errors of a technique is higher than the mean of the others methods, the coupling is good and reduces the bus prediction error.

Keywords: Coupled Map Lattices. Load Forecasting. Hybrid Systems. Artificial Intelligence.

LISTA DE TABELAS

TABELA 1 – PREVISÕES ENVIADAS EM CADA FASE DO SIMPLES.....	16
TABELA 2 – DEFINIÇÃO DO HORÁRIO DE PONTA DO SISTEMA	17
TABELA 3 – HORIZONTES E PERIODICIDADE DE ENVIO DOS ESTUDOS POR BARRAMENTO ENVIADOS AO NOS.....	24
TABELA 4 – INTERVALOS HORÁRIOS DAS CONDIÇÕES DE CARGA DE PONTA E FORA DE PONTA ..	24
TABELA 5 – INTERVALOS HORÁRIOS DOS PATAMARES DE CARGA DE ENERGIA	26
TABELA 6 - RESUMO DA ESTRUTURA BÁSICA DE TRÊS MODELOS APLICÁVEIS A SISTEMAS DINÂMICOS	52
TABELA 7 – INFORMAÇÕES SOBRE O PERÍODO DAS SÉRIES HISTÓRICAS DO SISTEMA TESTE 1 ...	64
TABELA 8 – QUANTIDADE DE PONTOS CORRIGIDOS NAS SÉRIES DO SISTEMA TESTE 1	66
TABELA 9 – INFORMAÇÕES SOBRE O PERÍODO DAS SÉRIES HISTÓRICAS DO SISTEMA TESTE 1 ...	70
TABELA 10 – QUANTIDADE DE PONTOS CORRIGIDOS NAS SÉRIES DO SISTEMA TESTE 2	71
TABELA 11 – ATRASOS NAS ENTRADAS DE CARGA PARA SÉRIE INTEIRA – SISTEMA TESTE 1	86
TABELA 12 – MODELOS FINAIS DOS MÉTODOS DE PREVISÃO PARA A SÉRIE INTEIRA – SISTEMA TESTE 1	86
TABELA 13 – MODELOS FINAIS DOS MÉTODOS DE PREVISÃO PARA A SÉRIE POR TIPO DE DIA – SISTEMA TESTE 1	87
TABELA 14 – RESULTADOS DAS PREVISÕES INDIVIDUAIS – SISTEMA TESTE 1	88
TABELA 15 – INTENSIDADE DE ACOPLAMENTO OTIMIZADA MÉDIA - SISTEMA TESTE 1	89
TABELA 16 – MAPES ACOPLAMENTO DAS PREVISÕES - MÉTODO MLP – SISTEMA TESTE 1	90
TABELA 17 – MAPES ACOPLAMENTO DAS PREVISÕES - MÉTODO RBF – SISTEMA TESTE 1.....	91
TABELA 18 – MAPES ACOPLAMENTO DAS PREVISÕES - PREVISOR FUZZY – SISTEMA TESTE 1 ..	92
TABELA 19 – COMPARAÇÃO DAS MÉDIAS DOS MAPES – SISTEMA TESTE 1.....	93
TABELA 20 – RESUMO DOS MELHORES CASOS DE PREVISÃO ACOPLADA – SISTEMA TESTE 1.....	95
TABELA 21 – ATRASOS NAS ENTRADAS DE CARGA PARA SÉRIE INTEIRA – SISTEMA TESTE 2.....	96
TABELA 22 – MODELOS FINAIS DOS MÉTODOS DE PREVISÃO PARA A SÉRIE INTEIRA – SISTEMA TESTE 2	97

TABELA 23 – MODELOS FINAIS DOS MÉTODOS DE PREVISÃO PARA A SÉRIE POR TIPO DE DIA – SISTEMA TESTE 2	97
TABELA 24 – RESULTADOS DAS PREVISÕES INDIVIDUAIS – SISTEMA TESTE 2.....	98
TABELA 25 – INTENSIDADE DE ACOPLAMENTO OTIMIZADA MÉDIA - SISTEMA TESTE 2	99
TABELA 26 – MAPES ACOPLAMENTO DAS PREVISÕES - MÉTODO MLP – SISTEMA TESTE 2 ...	101
TABELA 27 – MAPES ACOPLAMENTO DAS PREVISÕES - MÉTODO RBF – SISTEMA TESTE 2....	102
TABELA 28 – MAPES ACOPLAMENTO DAS PREVISÕES - PREVISOR FUZZY – SISTEMA TESTE 2	103
TABELA 29 – COMPARAÇÃO DAS MÉDIAS DOS MAPES – SISTEMA TESTE 2.....	104
TABELA 30 – RESUMO DOS MELHORES CASOS DE PREVISÃO ACOPLADA – SISTEMA TESTE 2...	105

LISTA DE FIGURAS

FIGURA 1 – DEFINIÇÃO DOS PATAMARES LEVE, INTERMEDIÁRIO E PESADO PARA DIAS ÚTEIS	15
FIGURA 2 – HORIZONTE DE PREVISÃO PARA O PAR	19
FIGURA 3 – DEFINIÇÃO DOS PATAMARES LEVE, INTERMEDIÁRIO E PESADO	20
FIGURA 4 – HORIZONTE DE PREVISÃO PARA OS ESTUDOS DO PLANEJAMENTO DA OPERAÇÃO ELÉTRICA DE MÉDIO PRAZO	21
FIGURA 5 – HORIZONTE DE PREVISÃO PARA OS ESTUDOS DO PLANEJAMENTO DA OPERAÇÃO ELÉTRICA COM HORIZONTE QUADRIMESTRAL.....	23
FIGURA 6 – HORIZONTE DE PREVISÃO PARA OS ESTUDOS DO PLANEJAMENTO DA OPERAÇÃO ELÉTRICA COM HORIZONTE MENSAL	23
FIGURA 7 – HORIZONTE DE PREVISÃO PARA OS ESTUDOS DO PLANEJAMENTO ANUAL DA OPERAÇÃO ENERGÉTICA	25
FIGURA 8 – EXEMPLO DAS SEMANAS OPERATIVAS DO MÊS DE ABRIL/2014	26
FIGURA 9 – HORIZONTE DE PREVISÃO DO ESTUDO MENSAL DO PMO	27
FIGURA 10 – REVISÕES SEMANAIS DO PMO PARA ABRIL/2014.....	28
FIGURA 11 – ELEMENTOS ADJACENTES CONSIDERADOS COMO VIZINHOS EM UM SISTEMA DE DUAS DIMENSÕES.(A) MODELO DE VON NEUMANN. (B) MODELO DE MOORE	54
FIGURA 12 – DIAGRAMA UNIFILAR DO SISTEMA TESTE 1.....	63
FIGURA 13 – SÉRIE HISTÓRICA BARRA 1 – SISTEMA TESTE 1.....	66
FIGURA 14 – SÉRIE HISTÓRICA BARRA 3 – SISTEMA TESTE 1.....	67
FIGURA 15 – SÉRIE HISTÓRICA BARRA 4 – SISTEMA TESTE 1.....	67
FIGURA 16 – SÉRIE HISTÓRICA BARRA 8 – SISTEMA TESTE 1.....	68
FIGURA 17 – SÉRIE HISTÓRICA BARRA 11 – SISTEMA TESTE 1.....	68
FIGURA 18 – DIAGRAMA UNIFILAR DO SISTEMA TESTE 2.....	69
FIGURA 19 – SÉRIE HISTÓRICA BARRA 1 – SISTEMA TESTE 2.....	72
FIGURA 20 – SÉRIE HISTÓRICA BARRA 5 – SISTEMA TESTE 2.....	72
FIGURA 21 – SÉRIE HISTÓRICA BARRA 7 – SISTEMA TESTE 2.....	73
FIGURA 22 – SÉRIE HISTÓRICA BARRA 8 – SISTEMA TESTE 2.....	73
FIGURA 23 – SÉRIE HISTÓRICA BARRA 10 – SISTEMA TESTE 2.....	74

FIGURA 24 – SÉRIE HISTÓRICA BARRA 14 – SISTEMA TESTE 2.....	74
FIGURA 25 - FLUXOGRAMA GERAL DO MÉTODO HÍBRIDO INSPIRADO EM CML	76
FIGURA 26 – EXEMPLO DE TABELA UTILIZADA NO SOFTWARE <i>ROUGH SETS</i>	107

LISTA DE ABREVIATURAS E SIGLAS

AG	Algoritmos Genéticos
AR	Modelo Auto-regressivo
ARCH	Modelo Auto-regressivo Heterocedástico (<i>Autoregressive Conditional Heteroskedasticity</i>)
ARMA	Modelo Auto-regressivo de Média Móvel (<i>Autoregressive Moving Average</i>)
ARMAX	Modelo Auto-regressivo de Média Móvel e Entrada Exógena (<i>Autoregressive Moving Average with exogenous input model</i>)
CA	Autômatos Celulares (<i>Cellular Automata</i>)
CML	Redes de Mapas Acoplados (<i>Coupled Map Lattices</i>)
COPEL	Companhia Paranaense de Energia
EDP	Equações Diferenciais Parciais
EPE	Empresa de Pesquisa Energética
GARCH	Modelo Auto-regressivo generalizado (<i>Generalized Autoregressive Conditional Heteroskedasticity</i>)
MA	Modelo de Médias Móveis (<i>Moving Average</i>)
MAPE	Erro Médio Absoluto Percentual (<i>Mean Absolute Percentage Error</i>)
MATLAB	Laboratório de Matrizes (<i>Matrix Laboratory</i>)
MME	Ministério de Minas e Energia
NARX	Modelo Não Linear Auto-regressivo com Entrada Exógena (<i>Non-linear Autoregressive with exogenous input model</i>)
ONS	Operador Nacional do Sistema Elétrico
PAR	Plano de Ampliações e Reforços da Rede Básica
PDE	Plano Decenal de Expansão de Energia
PEL	Planejamento da Operação Elétrica de Médio Prazo
PMO	Programa Mensal da Operação
PSO	Enxame de Partículas (<i>Particle Swarm Optimization</i>)
RN	Rede Neural
SEP	Sistemas Elétricos de Potência
MLP	<i>Perceptron</i> de Múltiplas Camadas (<i>Multiple Layer Perceptron</i>)

SIMPLES	Sistema de Informações de Mercado para o Planejamento do Setor Elétrico
SIN	Sistema Interligado Nacional
RBF	Redes de Função de Base Radial (<i>Radial-Basis Functions</i>)

SUMÁRIO

1	INTRODUÇÃO	7
1.1	OBJETIVOS	9
1.2	JUSTIFICATIVA.....	9
1.3	ESTRUTURA DA TESE.....	10
2	FUNDAMENTAÇÃO TEÓRICA	11
2.1	PREVISÃO DE CARGA	11
2.1.1	Previsões para a Empresa de Pesquisa Energética.....	14
2.1.2	Previsões para o Operador Nacional do Sistema Elétrico	17
2.1.3	Outros estudos de previsão.....	28
2.1.4	Revisão de Literatura.....	30
2.2	REDE DE MAPAS ACOPLADOS.....	50
2.2.1	Modelos de Vizinhança.....	53
2.2.2	Mapas.....	54
2.2.3	Acoplamento.....	55
2.2.4	Revisão de Literatura – CML.....	57
2.3	CONSIDERAÇÕES FINAIS DO CAPÍTULO	60
3	MATERIAIS E MÉTODO.....	62
3.1	MATERIAIS	62
3.1.1	Sistema Teste 1.....	63
3.1.2	Sistema Teste 2.....	69
3.2	MÉTODO	75
3.2.1	Pré-processamento dos dados.....	75
3.2.2	Previsão individual das barras.....	77
3.2.3	Otimização da intensidade de acoplamento	78
3.2.4	Acoplamento das previsões.....	80
3.2.5	Cálculo dos indicadores de desempenho	81
3.3	CONSIDERAÇÕES FINAIS DO CAPÍTULO	81
4	RESULTADOS.....	83
4.1	PARÂMETROS GERAIS	83

4.2	RESULTADOS PARA O SISTEMA TESTE 1.....	85
4.3	RESULTADOS PARA O SISTEMA TESTE 2.....	95
4.4	EXTRAÇÃO DE CONHECIMENTO DOS RESULTADOS UTILIZANDO CONUNTOS APROXIMADOS.....	105
4.5	CONSIDERAÇÕES FINAIS DO CAPÍTULO	108
5	CONCLUSÕES E TRABALHOS FUTUROS	110
	REFERÊNCIAS	113
	APÊNDICE 1 - ATRASOS NA VARIÁVEL DE CARGA PARA A SÉRIE POR TIPO DE DIA – SISTEMA TESTE 1.....	126
	APÊNDICE 2 - ATRASOS NA VARIÁVEL DE CARGA PARA A SÉRIE POR TIPO DE DIA – SISTEMA TESTE 2.....	129

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 os agentes do setor elétrico têm demonstrado interesse na implementação de métodos para previsão de carga.

Diferentes horizontes são considerados para a previsão de carga e é essa característica que define sua aplicação para as empresas de energia. Esses horizontes são usualmente classificados como curtíssimo, curto, médio e longo prazo. 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 básica e da operação de sistemas de potência ou ainda despacho da geração. As previsões de curto prazo podem ser aplicadas na elaboração de planos da manutenção e operação de sistemas de potência. Previsões no curtíssimo prazo possuem aplicação na operação em tempo real de sistemas de controle e operação, inclusive para redes inteligentes (*smart grid*).

No Brasil, diversos agentes do Sistema Interligado Nacional (SIN) solicitam às empresas de distribuição de energia o fornecimento de previsões em diversas discretizações e horizontes. Os estudos de previsão que uma distribuidora faz variam desde previsões globais anuais de energia para dez anos à frente, até previsões de demanda de potência ativa e reativa por barramento com horizontes de até quatro anos.

Para atender as distintas necessidades de previsão que as concessionárias possuem, diversos métodos de previsão de carga têm sido propostos na literatura. Para a solução do problema de previsão de carga são utilizados desde métodos simples, como Regressão Linear, até métodos complexos baseados em Inteligência Computacional. Alguns métodos, com o intuito de aprimorar o resultado das previsões, adicionam mais

variáveis ao problema, como temperatura e número de consumidores. Seguindo essa linha, uma possibilidade é aplicar conceitos de sistemas dinâmicos, que consideram o problema sob a ótica espaço-temporal e adicionam informações das conexões entre os diversos elementos do sistema.

Seguindo essa linha, tem-se o modelo de Redes de Mapas Acoplados (do inglês, *Coupled Map Lattice* - CML) que representa uma subdivisão de modelos de sistemas dinâmicos espaço-temporais, no qual elementos de uma rede interagem entre si. Portanto, ao se modelar um sistema de potência, de acordo com redes de mapas acoplados, adiciona-se ao problema variáveis que especificam a posição dos barramentos no espaço e também a forma com que as barras são conectadas. Dessa forma, um elemento do sistema pode ser influenciado pelo comportamento dos elementos vizinhos.

Assim, o estudo de redes de mapas acoplados compreende a ligação entre elementos de dinâmica complexa, onde mapas da série temporal são dispostos de forma a constituir uma rede onde, dada uma regra de acoplamento, o estado no instante $t+1$ passa a depender do estado no instante t e do estado de seus vizinhos em determinados instantes.

Este trabalho apresenta uma proposta de modelar o problema de previsão de carga utilizando um sistema híbrido baseado nos conceitos de CML. Para tanto foi desenvolvido um método híbrido que realiza previsões para cada uma das barras através de um método de previsão de séries temporais, que são posteriormente acopladas empregando os conceitos de CML. Neste trabalho foram utilizadas Redes Neurais do tipo MLP (*Perceptron* de Múltiplas Camadas) e RBF (Redes de Função de Base Radial) e um previsor Fuzzy para realizar as previsões individuais das barras.

1.1 OBJETIVOS

O objetivo geral deste trabalho é melhorar a previsão de carga de sistemas elétricos, em base horária para um horizonte de até uma semana à frente, através da incorporação de informações da topologia do sistema, baseada na utilização dos conceitos de Redes de Mapas Acoplados (CML).

Para isso são destacados os seguintes objetivos específicos:

- Analisar os conceitos de Redes de Mapas Acoplados em face da aplicação em previsão de carga em Sistemas Elétricos de Potência (SEPs);
- Analisar as técnicas utilizadas atualmente para previsão de carga em SEPs;
- Desenvolver um método híbrido de previsão de carga inspirado nas Redes de Mapas Acoplados;
- Testar e validar o método híbrido desenvolvido através da previsão em sistemas reais;
- Analisar as influências que as variações nas previsões de uma barra exercem sobre as outras;
- Estabelecer as diretrizes de aplicação do método híbrido desenvolvido.

1.2 JUSTIFICATIVA

Em sistemas de potência, para o planejamento da operação e da expansão, 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. Além desses estudos, muitas vezes, a própria concessionária necessita de estudos específicos de previsão para dar suporte às decisões tomadas na empresa.

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, a fim de tornar a previsão de carga elétrica mais precisa que os modelos atuais.

1.3 ESTRUTURA DA TESE

A fundamentação teórica deste trabalho é apresentada no capítulo 2. Este capítulo é dividido em duas seções, a saber, previsão de carga e Redes de Mapas Acoplados (CML). Inicialmente é apresentado o problema de previsão de carga e os tipos de previsão usualmente realizados pelas concessionárias de distribuição no Brasil. Uma breve revisão bibliográfica sobre previsão de carga é apresentada ao final da primeira seção. A segunda seção apresenta o conceito de CML e os trabalhos encontrados na literatura que utilizam essa técnica.

No capítulo 3 são expostos os materiais e o método aplicado no desenvolvimento do trabalho proposto. Nos materiais, são apresentados os dois casos teste utilizados. Para cada caso são apresentados o diagrama unifilar do sistema teste; as séries de dados para cada uma das barras de carga; e os *softwares* auxiliares utilizados no desenvolvimento. Na sequência é apresentado o método proposto nesse trabalho, que utiliza os conceitos de CML para realizar o acoplamento das previsões previamente realizadas por um método de previsão de séries temporais.

Os resultados obtidos são descritos no capítulo 4, que é dividido entre os resultados individuais apresentados pelas metodologias de previsão utilizadas e os resultados obtidos após o acoplamento.

Por fim, o capítulo 5 contém as conclusões do trabalho e sugestões para trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA

Este capítulo apresenta a fundamentação teórica dos métodos e conceitos utilizados no desenvolvimento deste trabalho. A primeira seção apresenta alguns conceitos básicos sobre previsão de séries temporais e a definição do problema de previsão de carga em sistemas elétricos. São abordados alguns estudos de previsão que usualmente são realizados no Brasil, entregues a diferentes órgãos reguladores e também estudos provenientes de demandas internas das concessionárias. Ao final da seção, é realizada uma revisão da literatura técnico-científica na área de previsão de carga no curto prazo, com enfoque nos métodos híbridos de previsão.

Na segunda seção são apresentados os principais conceitos sobre o modelo de sistemas dinâmicos, conhecido por Rede de Mapas Acoplados (do inglês *Coupled Map Lattices* - CML). São apresentados os conceitos de vizinhança, que é uma das principais características de um modelo baseado em rede, mapas e características dos acoplamentos entre os elementos da rede. As redes de mapas acoplados têm sido aplicadas em diversas áreas de estudo, e uma breve revisão da literatura técnico-científica é apresentada ao final desta segunda seção.

2.1 PREVISÃO DE CARGA

Prever é o processo de estimar um evento futuro com determinada antecedência. A antecedência com que um evento precisa ser estimado pode variar de alguns anos até algumas horas ou minutos. Previsões podem ser utilizadas nas mais diversas áreas, principalmente em Engenharia e Economia, a fim de se obter um planejamento eficaz e eficiente. Segundo Makridakis, Wheelwright e Hyndman (1998), uma organização deve possuir conhecimentos e habilidades para identificar e definir os problemas de previsão; aplicar diversos métodos de previsão; estabelecer procedimentos para selecionar os métodos adequados para situações específicas; e aplicar e utilizar métodos formais de previsão.

Várias técnicas de previsão têm sido desenvolvidas e podem ser classificadas em qualitativas e quantitativas. Métodos qualitativos em geral são utilizados quando não se possuem informações quantitativas sobre o problema e métodos quantitativos são utilizados quando essas informações existem. Dentro da classe de métodos quantitativos, um dos problemas abordados é a previsão de séries temporais, ou seja, dado que “o passado é conhecido”, como reconhecer um padrão de comportamento com o qual seja possível prever o futuro.

Uma série temporal é um conjunto de medidas ou observações ordenadas no tempo como, por exemplo, uma série contendo as temperaturas máximas diárias no Estado do Paraná. Se estas observações são dependentes umas das outras, então é possível conseguir uma previsão ou identificação do sistema. 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, JENKINS e REINSEL, 1994).

Para desenvolver um previsor, diversas técnicas têm sido utilizadas. Estas técnicas podem ser divididas em modelos clássicos de previsão e modelos baseados em Inteligência Computacional.

Os modelos clássicos são em geral métodos estatísticos ou matemáticos, que podem ser lineares ou não lineares. Como exemplo de métodos clássicos lineares podem ser citados os métodos de regressão linear, que são modelos matemáticos derivados de ajustes exponenciais e modelos utilizados em conjunto com métodos do tipo mínimos quadrados para sistemas de previsão. Para os modelos clássicos não lineares tem-se como exemplo os modelos auto regressivos (tipicamente, apenas funções matemáticas simples têm sido consideradas, como função seno, cosseno e logística), modelos de função de transferência, modelos de média móvel não lineares e modelos NARMAX.

Devido à complexidade e não linearidade de muitas séries de previsão, diversas técnicas baseadas em Inteligência Computacional, como Redes Neurais Artificiais, Sistemas Fuzzy e Computação Evolutiva vêm sendo utilizadas para previsão de séries temporais.

Outra característica da previsão de séries temporais é a definição do horizonte de previsão. Esse conceito refere-se ao comprimento de tempo ou prazo para o qual as previsões devem ser determinadas. Em geral, as previsões são classificadas de acordo com o seu horizonte em previsões de curtíssimo, curto, médio e longo prazo; no entanto essa nomenclatura pode variar de acordo com o modelo utilizado, os dados disponíveis e o foco do estudo. Hahn, Meyer-Nieberg e Pickl (2009) fazem uma revisão detalhada sobre as considerações quanto aos horizontes de previsão de carga, apresentando as diferentes definições encontradas na literatura.

De maneira geral, previsões em longo prazo contemplam períodos de alguns meses até poucas dezenas de anos, com discretização 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, discretizados semanal ou mensalmente, com aplicação no planejamento da expansão da rede básica ou ainda no despacho da geração. Para períodos de alguns dias a até poucos meses, com discretização horária ou diária, a previsão pode ser denominada como de curto prazo, sendo aplicada na elaboração de planos da manutenção e operação de sistemas de potência. O prazo curtíssimo abrange períodos de um minuto até poucos dias, com discretização por minutos ou horas, e aplicação na operação de sistemas de controle das concessionárias e operação, inclusive de redes inteligentes.

No setor elétrico são necessários diversos estudos de previsão, desde previsão do número de consumidores até previsão de demanda de potência para um barramento específico. Esses estudos servem como subsídio para o planejamento da expansão da distribuição e transmissão (ALRASHIDI e EL-NAGGAR, 2010; AL-SHOBAKI e MOHSEN, 2008); operação de sistemas de potência (BO, LI E TOMSOVIC, 2012; HOOSHMAND, AMOOSHAHI e PARASTEGARI, 2103); contratação eficiente de energia (YUN *et al.*, 2008); programação do despacho de geração (MAMLOOK, BADRAN e ABDULHADI, 2009), operação em tempo real (HINOJOSA e HOESE, 2010; LIN e CHOU, 2013), redes inteligentes (BORGES, PENYA e FERNÁNDEZ, 2013; HERNÁNDEZ *et al.*, 2013) e na compra de energia (YUN *et al.*, 2008). Resumidamente, são realizadas previsões de demanda de energia ou de potência, usualmente referidas como previsão de carga.

No Brasil, as concessionárias de energia realizam estudos de previsão para atender interesses próprios e, principalmente, para atender requisições dos órgãos reguladores do sistema interligado nacional (SIN). Especificamente, para uma distribuidora de energia, são necessárias desde previsões de carga global da concessionária até previsões de potência ativa por barramento. Essas previsões possuem horizontes e discretizações variados de acordo com o objetivo do estudo.

As próximas seções exemplificam as previsões de carga solicitadas às concessionárias de energia elétrica para atender os estudos elaborados pelos órgãos do setor e também outros estudos para atendimento de demandas internas de previsão das próprias concessionárias. O foco dos estudos apresentados neste trabalho são os realizados pelas empresas de distribuição de energia elétrica.

2.1.1 Previsões para a Empresa de Pesquisa Energética

A Empresa de Pesquisa Energética (EPE) foi criada em 2004 vinculada ao Ministério de Minas e Energia (MME) para desenvolver estudos e pesquisas para subsidiar a formulação, o planejamento e a implementação de ações do MME no âmbito da política energética nacional. Um dos fatores preponderantes para a criação da EPE foram os racionamentos e apagões ocorridos em 2000 e 2001, atribuídos em parte à carência de planejamento.

A autorização da criação da EPE se deu em março de 2004 pela Lei 10.847 e sua criação em agosto de 2004 através do Decreto 5.184. "A Empresa de Pesquisa Energética – EPE tem por finalidade prestar serviços na área de estudos e pesquisas destinadas a subsidiar o planejamento do setor energético, tais como energia elétrica, petróleo e gás natural e seus derivados, carvão mineral, fontes energéticas renováveis e eficiência energética, dentre outras." (BRASIL, Lei nº 10.847, de 15 de março de 2004).

Dentre as várias atribuições da EPE, são solicitados às concessionárias de energia elétrica estudos de previsão para a elaboração do Plano Decenal de Expansão de Energia (PDE) e do Sistema de Informações de Mercado para o Planejamento do

Setor Elétrico (SIMPLES). O horizonte desses dois estudos é de 10 anos e os mesmos são considerados estudos de médio prazo pela EPE.

2.1.1.1 Plano Decenal de Expansão de Energia (PDE)

O PDE é um documento publicado anualmente pelo MME, a partir dos estudos elaborados pela EPE, que incorpora uma visão integrada da expansão da demanda e da oferta de recursos energéticos para um horizonte de 10 anos e contribui para o delineamento das estratégias de desenvolvimento do país a serem traçadas pelo Governo Federal (EPE, 2013).

Para a realização do estudo do PDE são solicitadas previsões anuais da demanda de potência ativa global e por barramento, para os patamares de carga leve (demanda mínima), intermediária (demanda máxima) e pesada (demanda máxima) para dias úteis. O horizonte de previsão é de 10 anos, no entanto, o envio dessas previsões acontece no mês de agosto, sendo necessário acrescentar um ano ao horizonte de previsão. Os patamares de carga são definidos de acordo com as horas do dia, conforme ilustrado na figura 1

Hora	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24
Patamar	Leve								Intermediário								Pesado							

FIGURA 1 – DEFINIÇÃO DOS PATAMARES LEVE, INTERMEDIÁRIO E PESADO PARA DIAS ÚTEIS

FONTE: O AUTOR

Neste levantamento é preciso considerar todas as barras existentes e as que entrarão em operação dentro do horizonte de estudo, sendo necessária a consideração da topologia da rede. Essa informação consta no planejamento da empresa, que deve fornecer datas de entrada dos elementos da rede e percentuais de transferência de carga entre as subestações envolvidas.

2.1.1.2 Sistema de Informações de Mercado para o Planejamento do Setor Elétrico (SIMPLES)

O SIMPLES é um sistema que concentra todas as informações de mercado de energia elétrica do SIN. O sistema é abastecido com informações do mercado realizado e previsto dos agentes de distribuição, geração e transmissão que atendam ao consumidor final (EPE, 2009).

A alimentação de dados no SIMPLES ocorre em três fases, sendo a primeira realizada no mês de fevereiro, a segunda fase no início do mês de agosto e a terceira no final do mês de agosto. Em cada fase são enviados dados realizados e dados previstos, com diferentes horizontes e discretizações. A tabela 1 apresenta um resumo das previsões enviadas em cada fase do SIMPLES. A última coluna da tabela descreve o horizonte real de previsão, considerando que a concessionária possui dados realizados somente até o mês anterior ao envio dos estudos.

TABELA 1 – PREVISÕES ENVIADAS EM CADA FASE DO SIMPLES

FONTE: ADAPTADO DE EPE 2009

<i>Fase</i>	<i>Data limite de envio</i>	<i>Tipo da previsão</i>	<i>Horizonte do estudo</i>	<i>Horizonte real</i>
1	28/fev	Previsão mensal do mercado de distribuição por classe de consumo para o ano base Previsão mensal do número de consumidores residenciais para o ano base	11 meses	11 meses
2	01/ago	Previsões anuais de mercado e carga de energia e demanda	10 anos	11 anos
3	31/ago	Previsões mensais de mercado e carga de energia e demanda	60 meses (5 anos)	65 meses

Na primeira fase são enviadas as previsões mensais de energia por classe de consumo e do número de consumidores residenciais para o ano em vigência, totalizando um horizonte de 11 meses de previsão. São consideradas 8 classes de consumo, conforme especificadas a seguir:

- Residencial;
- Industrial;

- Comercial;
- Rural;
- Poderes Públicos;
- Iluminação Pública;
- Serviços Públicos;
- Outros Consumos.

Na segunda fase são enviadas previsões anuais de consumo cativo e não cativo e número de consumidores cativos e não cativos estratificados por classes e subclasses de consumo e previsões de demanda máxima no horário de ponta do sistema, de demanda máxima independente do horário e de perdas. Na terceira fase são enviados os mesmos tipos de previsões da segunda fase, no entanto essas previsões têm discretização mensal e horizonte de previsão de cinco anos. O horário de ponta do sistema é definido de acordo com a tabela 2.

TABELA 2 – DEFINIÇÃO DO HORÁRIO DE PONTA DO SISTEMA

FONTE: ONS (2013)

<i>Sem horário de verão</i>	<i>Com horário de verão</i>
17:00 às 22:00	18:00 às 23:00

2.1.2 Previsões para o Operador Nacional do Sistema Elétrico

O ONS é uma instituição jurídica, sem fins lucrativos, que foi criada em 1998 (BRASIL, Lei nº 9.648, de 27 de maio de 1998) e teve suas atribuições ratificadas com a mudança do setor elétrico em 2004 (BRASIL, Decreto 5.081, de 14 de maio de 2004). O ONS tem por objeto executar as atividades de coordenação e controle da operação das instalações de geração e transmissão de energia elétrica do SIN, sob a fiscalização e

regulação da Agência Nacional de Energia Elétrica (ANEEL), visando à otimização energética ao menor custo (ONS, 2013).

Ao ONS são enviados, em diferentes épocas, previsões de carga para atender aos seguintes estudos (ONS, 2010a): Plano de ampliações e reforços da rede básica (PAR); Planejamento da operação elétrica, incluindo o planejamento da operação elétrica de médio prazo (PEL), diretrizes para operação elétrica com horizonte quadrimestral e diretrizes para operação elétrica com horizonte mensal; Planejamento anual da operação energética; e Programa mensal da operação energética (PMO).

Esses estudos envolvem desde previsões globais da concessionária até previsões por barramento, tanto de demanda de energia quanto de potência, com diversos horizontes de previsão. A seguir, cada um desses estudos é brevemente descrito, sob a ótica de uma distribuidora de energia.

2.1.2.1 Plano de Ampliações e Reforços da Rede Básica (PAR)

As ampliações e reforços para a expansão das instalações de transmissão são objeto de estudo do Plano de Ampliações e Reforços na Rede Básica (PAR). Neste estudo são registradas as ações identificadas como necessárias para garantir que a operação futura do SIN ocorra de acordo com os padrões de desempenho estabelecidos nos Procedimentos de Rede (ONS, 2010).

Para a elaboração do PAR são necessárias previsões mensais de demanda de potência ativa e reativa por barramento e por agente do SIN para um horizonte de estudo de cinco anos à frente. As previsões por barramento devem ser de demanda coincidente, ou seja, a demanda que ocorre no mesmo horário da máxima (ou mínima) global da distribuidora. Além disso, 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).

As previsões para o PAR são enviadas ao ONS em planilhas específicas no mês de setembro de cada ano, mais especificamente no dia 01/09 (ONS, 2010b). Dessa maneira, além dos cinco anos do horizonte de estudos, também devem ser enviadas as previsões mensais para o ano corrente, do mês de setembro até o mês de dezembro, além da previsão do mês de agosto, já que na data de envio os dados desse mês ainda não estão consolidados. Dessa forma, o horizonte real de previsão para este estudo é de cinco anos e cinco meses, ou seja, 65 meses de horizonte de previsão. Na figura 2 é apresentado um esquema ilustrativo do horizonte de previsão.

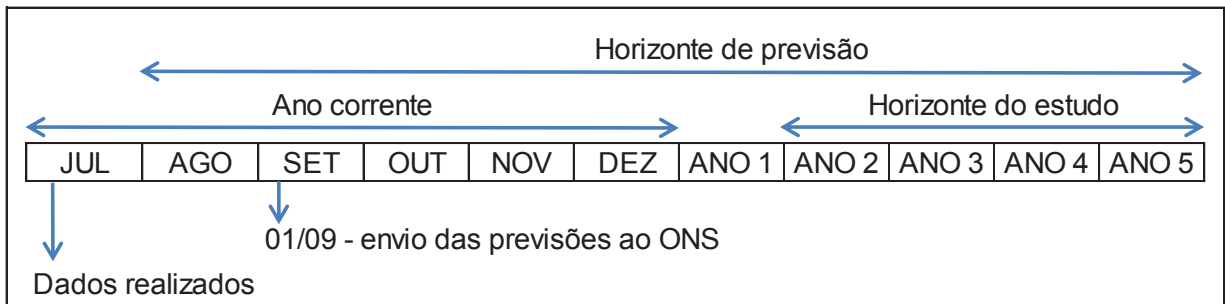


FIGURA 2 – HORIZONTE DE PREVISÃO PARA O PAR

FONTE: ADAPTADO DE PROCEDIMENTOS DE REDE (ONS, 2010b)

As previsões mensais desse estudo são desagregadas por tipo de dia e patamar de carga. São considerados três tipos de dias, dias úteis (DU), sábados (SAB), domingos e feriados (DOM). Os dias de sexta-feira posteriores a feriados que ocorrem na quinta-feira, denominados de dias ponte, não entram na contabilização dos dias úteis, assim como todas as segundas-feiras. Para os patamares de carga, também são considerados três patamares: leve (ou mínima para domingo), intermediário e pesado. Os horários que cada patamar de carga abrange dependem do tipo de dia e estão ilustrados na figura 3.

Hora	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24
DU	Leve (3ª a 6ª)								Intermediária									Pesada						
SAB	Leve								Intermediária									Pesada						
DOM	Mínima								Intermediária									Pesada						

FIGURA 3 – DEFINIÇÃO DOS PATAMARES LEVE, INTERMEDIÁRIO E PESADO

FONTE: O AUTOR

2.1.2.2 *Planejamento da Operação Elétrica*

Para os estudos do Planejamento da Operação Elétrica são utilizados como insumo as previsões da carga global por agente e da carga por barramento. Esses estudos podem ser subdivididos de acordo com seus horizontes em três:

1. Estudo do planejamento da operação elétrica de médio prazo;
2. Estudo de diretrizes para operação elétrica com horizonte quadrimestral;
3. Estudo de diretrizes para a operação elétrica com horizonte mensal.

Para estes estudos são enviadas previsões globais e previsões por barramento, além das previsões dos consumidores horo-sazonais (consumidores cujo preço das tarifas é diferenciado para os diferentes horários do dia e períodos do ano) e geradores que estejam representados em barramentos da distribuidora.

Para o caso global são necessárias as previsões das curvas de carga de demanda ativa, com intervalo de integralização de uma hora, discretizadas por tipo de dia, mês a mês (ONS, 2010c).

Por barramento, são enviadas as previsões de carga de demanda ativa e reativa associada coincidente, com intervalo de integralização de uma hora, para as condições de carga pesada, média e leve de dia útil, pesada e média de sábado, pesada e média de sábado e mínima (ONS, 2010c). O horário de previsão de carga dos barramentos deve ser coincidente com o horário de maior ou menor carga global da distribuidora. A definição dos horários de cada patamar de carga são as mesmas ilustradas na figura 3.

Para os consumidores horo-sazonais, cativos ou livres, são enviadas as previsões de carga de demanda ativa e para os geradores a previsão de despacho de geração ativa e reativa associada, para as mesmas condições de carga descritas na previsão por barramento (ONS, 2010c).

Além das previsões, também devem ser enviados os montantes de remanejamento de carga de demanda ativa entre barramentos da rede da distribuidora. Dessa forma, é necessário o conhecimento da entrada de novos barramentos na rede e como esses barramentos irão afetar a carga já existente e a carga futura, dentro do horizonte de previsão.

Uma particularidade das previsões enviadas nesses estudos diz respeito à compatibilidade entre as previsões por barramento e a previsão global. A soma da carga coincidente de todos os barramentos (incluindo os consumidores horo-sazonais e sem considerar geradores) deve ser igual à carga global abatida de um percentual de perdas. Essa questão dificulta a utilização de modelos de previsão independentes para os barramentos e para a carga global, já que não é possível garantir que os mesmos produzam resultados de previsão que atendam esse requisito.

Os horizontes e periodicidades de envio de cada um dos estudos contemplados neste tópico são variáveis. O estudo de médio prazo é realizado em dois ciclos, o ciclo 1 é enviado no início de abril e contempla previsões para um horizonte de dezesseis meses, contados a partir de janeiro do ano seguinte. O ciclo 2 é enviado no início de setembro, com previsões para dezesseis meses contados a partir de julho do ano seguinte. Dessa forma, os horizontes reais de previsão são de 26 e 27 meses para o ciclo 1 e 2 respectivamente, considerando que os dados do mês imediatamente anterior ao estudo não podem ser utilizados, já que o envio se dá no dia primeiro do mês. A figura 4 ilustra o esquema de envio do estudo de médio prazo, ciclos 1 e 2.

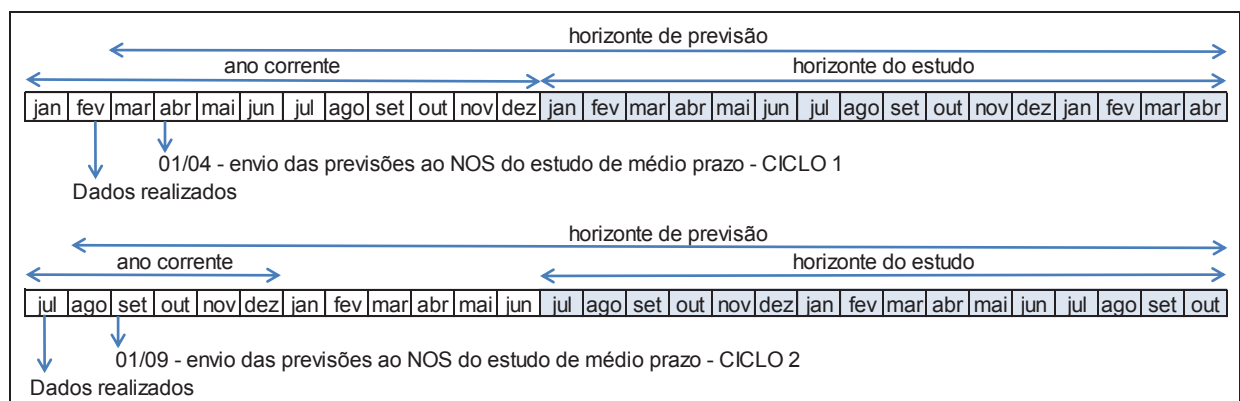


FIGURA 4 – HORIZONTE DE PREVISÃO PARA OS ESTUDOS DO PLANEJAMENTO DA OPERAÇÃO ELÉTRICA DE MÉDIO PRAZO

FONTE: ADAPTADO DE PROCEDIMENTOS DE REDE (ONS, 2010c)

O estudo quadrimestral é enviado três vezes ao ano, no final dos meses de agosto, dezembro e abril. No mês de agosto são enviadas as previsões para o primeiro quadrimestre (janeiro a abril) do ano seguinte, em dezembro para o segundo quadrimestre (maio a agosto) do ano seguinte e em abril para o terceiro quadrimestre (setembro a dezembro) do ano corrente. O horizonte de previsão desse estudo é de quatro meses, no entanto, considerando as diferentes datas de envio têm-se um horizonte real de previsão de nove meses. A figura 5 ilustra o esquema de envio e horizontes de previsão para o estudo quadrimestral.

A data de envio do estudo mensal é o dia 19 de cada mês. Nessa data, são enviadas as previsões para o mês subsequente ao mês seguinte, ou seja, em janeiro são enviadas as previsões para março, em fevereiro para abril, e assim sucessivamente. Na figura 6 é apresentado um esquema ilustrativo do horizonte de previsão e envio desse estudo. Nesse caso, o horizonte real de previsão é de três meses, já que o envio é realizado antes da finalização do mês corrente.

A tabela 3 apresenta um resumo dos horizontes de previsão de cada um dos estudos e as datas limites para envio dos mesmos. Caso a data limite aconteça fora de um dia útil, é considerado o dia útil imediatamente anterior como data limite para envio do estudo. Estão descritos o horizonte oficial do estudo e o horizonte real, que deve ser utilizado para fins de modelos de previsão.

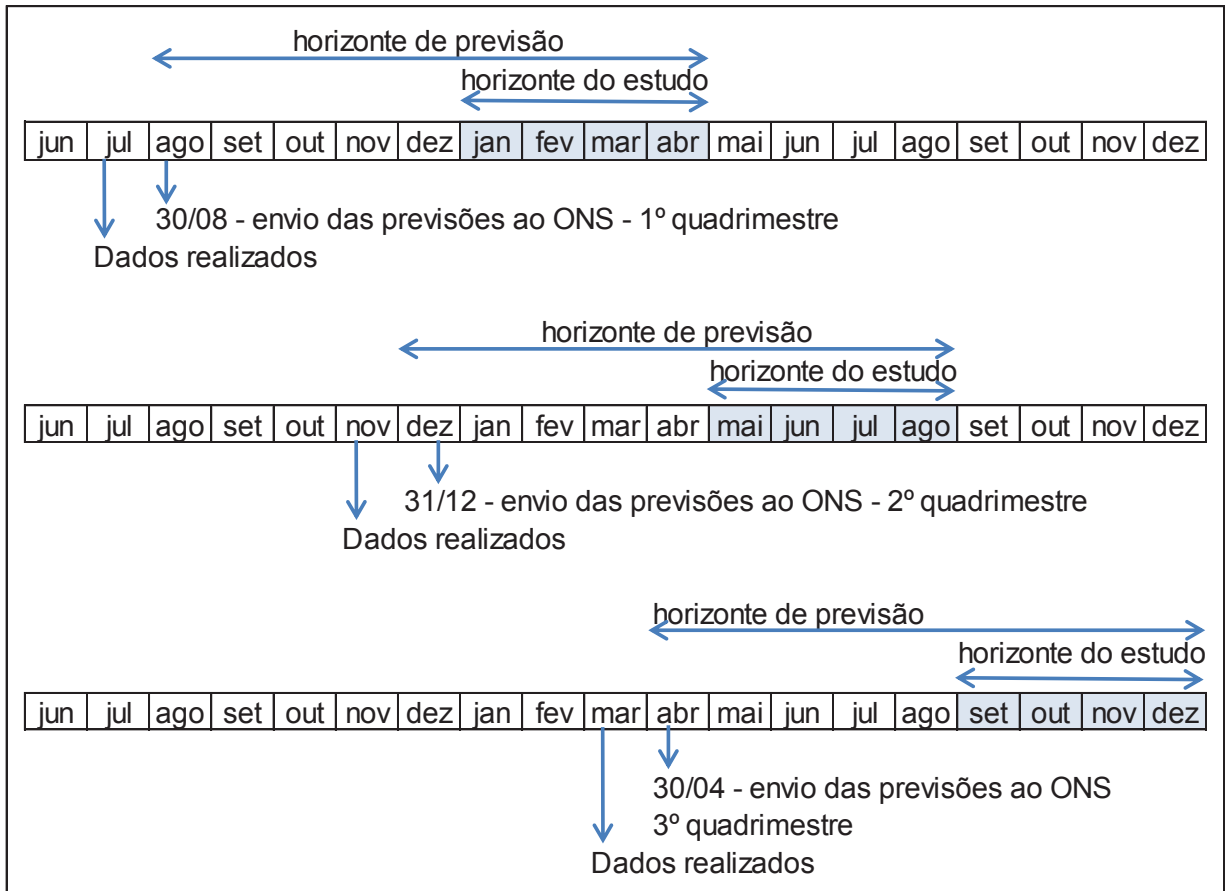


FIGURA 5 – HORIZONTE DE PREVISÃO PARA OS ESTUDOS DO PLANEJAMENTO DA OPERAÇÃO ELÉTRICA COM HORIZONTE QUADRIMESTRAL

FONTE: ADAPTADO DE PROCEDIMENTOS DE REDE (ONS, 2010c)




FIGURA 6 – HORIZONTE DE PREVISÃO PARA OS ESTUDOS DO PLANEJAMENTO DA OPERAÇÃO ELÉTRICA COM HORIZONTE MENSAL

FONTE: ADAPTADO DE PROCEDIMENTOS DE REDE (ONS, 2010c)

TABELA 3 – HORIZONTES E PERIODICIDADE DE ENVIO DOS ESTUDOS POR BARRAMENTO ENVIADOS AO NOS

FONTE: AUTOR

<i>Estudo</i>	<i>Horizonte do estudo</i>	<i>Horizonte real</i>	<i>Data limite para envio</i>
Médio prazo – ciclo 1	16 meses	26 meses	01/04
Médio prazo – ciclo 2	16 meses	27 meses	01/09
Quadrimestral	4 meses	9 meses	19/08
			10/12
			01/04
Mensal	1 mês	3 meses	Dia 19 de cada mês

2.1.2.3 Planejamento Anual da Operação Energética

O planejamento anual da operação energética utiliza, dentre outros dados, a previsão da carga global das distribuidoras para elaborar estudos energéticos para um horizonte de cinco anos. São enviadas ao ONS previsões da carga de energia ativa global mensal e a da carga de demanda ativa global mensal para as condições de carga de ponta e fora de ponta (ONS, 2009). Os horários que compõem os horários de ponta e fora de ponta estão descritos na tabela 4.

TABELA 4 – INTERVALOS HORÁRIOS DAS CONDIÇÕES DE CARGA DE PONTA E FORA DE PONTA

FONTE: PROCEDIMENTOS DE REDE (ONS, 2009)

<i>Condição de carga</i>	<i>Sem horário de verão</i>		<i>Com horário de verão</i>	
	<i>2ª feira a Sábado</i>	<i>Domingos e Feriados</i>	<i>2ª feira a Sábado</i>	<i>Domingos e Feriados</i>
Ponta	17 às 22h	-	18 às 23h	
Fora de Ponta	00 às 17h 22 às 24h	00 às 24h	00 às 18h 23às 24h	00 às 24h

Esse estudo tem periodicidade anual e pode ser atualizado duas vezes ao ano. O horizonte de previsão do estudo é de cinco anos (60 meses), a contar a partir de janeiro do ano seguinte ao envio do estudo, conforme ilustrado na figura 7. Como os dados realizados são obtidos até o mês de setembro do ano corrente, se torna necessário acrescentar três meses ao horizonte de previsão, totalizando assim 63 meses de horizonte real de previsão.

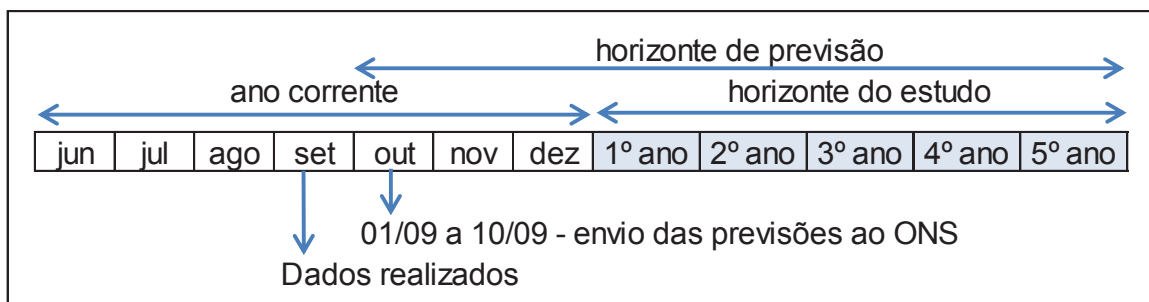


FIGURA 7 – HORIZONTE DE PREVISÃO PARA OS ESTUDOS DO PLANEJAMENTO ANUAL DA OPERAÇÃO ENERGÉTICA

FONTE: PROCEDIMENTOS DE REDE (ONS, 2009)

2.1.2.4 Programa Mensal da Operação Energética (PMO)

Os estudos de previsão para o Programa Mensal da Operação (PMO) podem ser divididos em dois casos, o estudo mensal e suas revisões semanais. As previsões para esses estudos são de carga global de energia e de demanda, para um horizonte que pode variar de um a 12 meses à frente. São realizadas previsões mensais e, para o primeiro mês de estudo, são realizadas previsões para cada semana operativa considerada no período (ONS, 2009a).

As semanas operativas (SO) são definidas como o período que inicia às 0h do sábado e termina às 24h da sexta-feira subsequente, contendo todos os dias do mês do PMO (ONS, 2009a). A primeira semana de um dado mês é a semana que contém o primeiro dia desse mês, da mesma forma que a última é a que contém o último dia do mês. Dessa maneira, a última semana operativa de um mês pode ser coincidente com a primeira do mês seguinte e um mês pode chegar a conter seis semanas operativas. Na

figura 8 é ilustrado o caso das semanas operativas para o mês de abril de 2014. Pode ser visualizado que a SO1 do mês de abril é coincidente com a SO5 do mês de março. Da mesma forma, a SO5 do mês de abril é coincidente com a SO1 de maio.

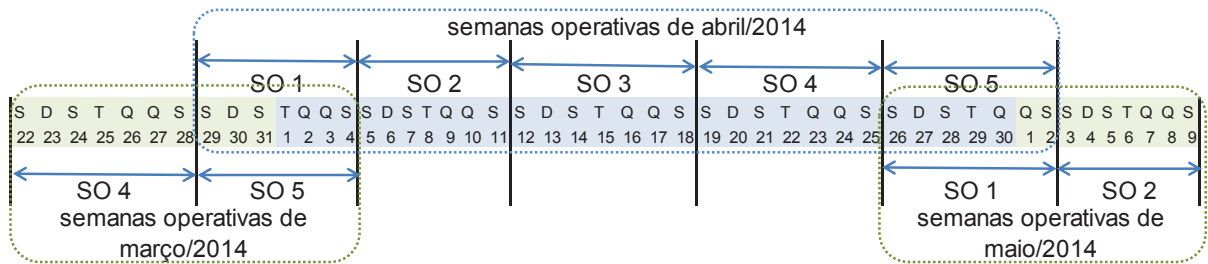


FIGURA 8 – EXEMPLO DAS SEMANAS OPERATIVAS DO MÊS DE ABRIL/2014

FONTE: AUTOR

No estudo mensal do PMO são realizadas previsões mensais e semanais de carga de energia ativa e de demanda ativa. Para a variável de carga de energia, são necessárias as previsões do mês e das semanas operativas e também as discretizações para os patamares de carga leve, média e pesada, conforme intervalos horários definidos na tabela 5.

TABELA 5 – INTERVALOS HORÁRIOS DOS PATAMARES DE CARGA DE ENERGIA

FONTE: PROCEDIMENTOS DE REDE 5.6 (ONS, 2009a)

Condição de carga	Sem horário de verão		Com horário de verão	
	2ª feira a Sábado	Domingos e Feriados	2ª feira a Sábado	Domingos e Feriados
Ponta	17 às 22h	-	18 às 23h	
Fora de Ponta	00 às 17h 22 às 24h	00 às 24h	00 às 18h 23às 24h	00 às 24h

Para a variável de carga de demanda ativa, as previsões mensais devem ser realizadas nas condições de carga de ponta e fora da ponta e as previsões semanais na

condição de carga de ponta. Os intervalos horários que definem as condições de carga de ponta e fora de ponta foram apresentados na tabela 4.

O estudo mensal é enviado uma vez por mês, aproximadamente no dia 15, com as previsões para o mês seguinte e demais, caso sejam requeridas. A figura 9 apresenta um esquema do horizonte do estudo mensal. O horizonte do estudo varia de um até 12 meses e o horizonte real de previsão é acrescido de um mês para o caso das previsões mensais. Para as previsões semanais, o número de semanas que deve ser acrescido ao horizonte do estudo depende do número de semanas operativas do mês de envio. Como o máximo de semanas operativas que um mês pode possuir é seis, pode-se concluir que o horizonte máximo para as previsões semanais será de doze, referentes às semanas do mês de envio e do mês do PMO.




FIGURA 9 – HORIZONTE DE PREVISÃO DO ESTUDO MENSAL DO PMO

FONTE: AUTOR

Quando um mês é iniciado, são realizadas as chamadas revisões semanais do PMO. As revisões são realizadas semanalmente, na quarta-feira ou em dia útil anterior no caso de feriado. Nas revisões semanais são enviadas previsões de carga de energia ativa semanal e de carga de demanda ativa semanal na condição de demanda de ponta. O horizonte desse estudo depende da semana de revisão e pode variar de uma a cinco semanas, pois são realizadas no máximo quatro revisões em um mês.

As revisões dizem respeito ao mês previsto no estudo mensal do PMO. Na figura 10 é apresentado um exemplo para o mês de abril/2014, que possui cinco semanas operativas. Na primeira semana operativa desse mês é realizada a revisão semanal 1,

no dia 2. Nessa revisão devem ser enviadas as previsões para as semanas 2 a 5. Na semana seguinte é realizada a segunda revisão, para as semanas 3 a 5, e assim sucessivamente. Dessa maneira, os horizontes das revisões são de 4, 3, 2 e 1 semana. Considerando que o estudo é enviado na quarta-feira e a semana operativa corrente só se encerra na sexta, deve-se acrescentar uma semana no horizonte de previsão real para este estudo. Considerando que o máximo de semanas operativas que um mês pode ter é de 6, o horizonte real máximo de previsão para as revisões semanais é de cinco semanas.

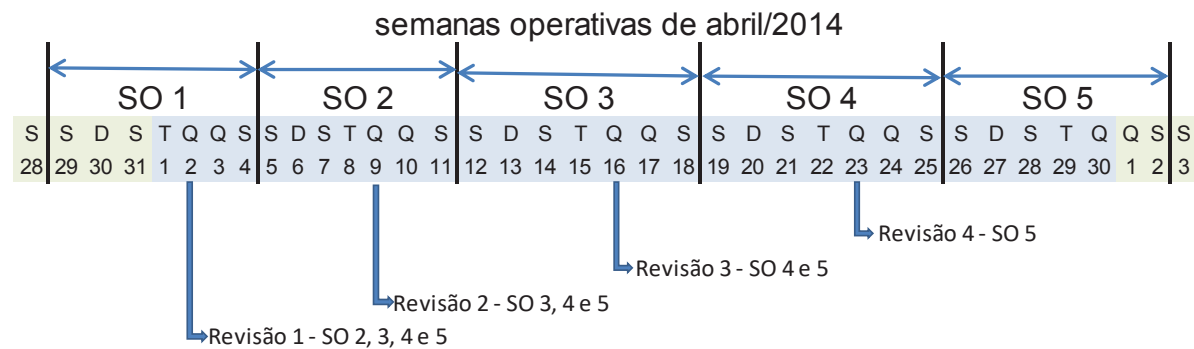


FIGURA 10 – REVISÕES SEMANAIS DO PMO PARA ABRIL/2014

FONTE: AUTOR

2.1.3 Outros estudos de previsão

Além dos estudos de previsão que uma concessionária de distribuição de energia elétrica realiza para atender requisições dos agentes reguladores do SIN, também é necessária a realização de previsões para atender a diferentes estudos desenvolvidos internamente.

Uma concessionária pode realizar previsões de consumo de energia para todas as classes de consumo, estratificadas por grupo e subgrupo de tensão, com a finalidade de atender a estudos financeiros. Essas previsões em geral possuem base mensal (devido ao período de faturamento) e devem ser realizadas para horizontes de alguns anos. O foco de interesse nesse caso são os dados faturados, que servirão de base para o planejamento econômico do faturamento da distribuidora. Ainda com cunho financeiro,

podem ser necessárias previsões de demanda faturada para os grandes consumidores conectados na rede da distribuidora.

Outro estudo que necessita de dados previstos é o planejamento da expansão do sistema de distribuição. Os horizontes de previsão para atender a esses estudos são bastante longos, entre 20 e 30 anos. Na análise de onde e quando construir uma nova subestação são necessárias previsões de demanda máxima para alimentadores e para localidades. Também devem ser considerados, de forma individualizada, os consumidores especiais conectados aos alimentadores, pois estes podem afetar significativamente a carga de algumas subestações. Um consumidor especial é definido como o "consumidor responsável por unidade consumidora ou conjunto de unidades consumidoras do Grupo "A", integrante(s) do mesmo submercado no SIN, reunidas por comunhão de interesses de fato ou de direito, cuja carga seja maior ou igual a 500 kW." (BRASIL, Resolução nº 247, de 21 de dezembro de 2006).

A previsão por localidade deve ser realizada de forma georreferenciada, ou seja, não basta saber que existe um crescimento na carga, mas também em que localização geográfica esse crescimento irá ocorrer. Esse tipo de previsão é usualmente denominado de previsão espacial ou previsão geo-referenciada e é realizado para grandes centros urbanos. Esse tipo de previsão é de grande importância para a decisão não só da construção de uma nova subestação como também para a decisão da localização em que a mesma deve ser construída.

Eventualmente, a concessionária precisa realizar estudos específicos para um barramento em que são necessárias previsões diárias ou horárias para alguns dias à frente. Esses estudos normalmente são de caráter emergencial, por exemplo, quando da elevação abrupta da temperatura ou ocorrência de um grande evento. Nesse caso, essas previsões são utilizadas para subsidiar a operação do sistema elétrico.

Além dos estudos citados, uma distribuidora de energia pode realizar diversos outros estudos para atender as mais variadas finalidades. Neste trabalho, foram citados alguns estudos de previsão que distribuidoras brasileiras em geral realizam para atender demandas tanto internas quanto dos órgãos reguladores do Setor Elétrico Brasileiro. A

próxima seção apresenta uma revisão da literatura sobre previsão de carga em sistemas elétricos, para horizontes de curto prazo.

2.1.4 Revisão de Literatura

O problema de previsão de carga vem sendo abordado há diversos anos e os mais variados métodos têm sido utilizados para modelagem e resolução desse problema. Com isso, a literatura técnica acerca do problema de previsão de carga é extremamente vasta, abordando diferentes enfoques. Nesta seção, são apresentados trabalhos recentes, relacionados ao problema de previsão de carga no horizonte de curto prazo.

Para uma revisão mais detalhada, no trabalho de Zhang, Patuwo e Hu (2001) é apresentado o estado da arte em previsão de séries temporais usando redes neurais, com a análise de técnicas publicadas até o ano de 1997. O trabalho apresenta uma introdução às redes neurais, definindo os principais pontos a serem decididos pelos projetistas que usam esta técnica, tais como considerações sobre a arquitetura da rede (número de camadas, número de neurônios em cada camada, tipo de funções de ativação, interconectividade dos neurônios) e algoritmos de aprendizado e seus parâmetros (taxa de treinamento, uso do momento, critério de parada). Os autores traçam comentários sobre o banco de dados, seu pré-processamento, normalização e uso para treinamento, teste e validação da rede neural. Uma breve revisão das medidas mais utilizadas para avaliar o desempenho da rede é também realizada. Para diversos trabalhos com diferentes aplicações, os autores verificam que redes neurais se comparam ou são melhores que os métodos estatísticos convencionais, tais como modelos ARMA, modelo ARIMA proposto por Box-Jenkins e Regressão Linear ou de ordem superior. Embora os autores não tenham focado em um problema específico, as conclusões deixam clara a adequação do uso de redes neurais em problemas de previsão.

Seguindo a mesma linha, Hippert, Pedreira e Souza (2001) examinaram uma coleção de artigos (publicados entre 1991 e 1999) que relatam a aplicação de redes neurais na previsão de carga de curto prazo. O objetivo deste trabalho é ajudar a

esclarecer o porquê das redes neurais terem sido projetadas e testadas e tentar entender o ceticismo por parte da comunidade científica com a aplicação dessas técnicas. Os autores concluíram que a maioria dos modelos propostos, especialmente os projetados para prever perfis de carga, parecem ter sido superparametrizados e que os resultados dos testes realizados nem sempre foram muito convincentes. No entanto, a grande quantidade de publicações semelhantes em revistas renomadas e o fato de alguns dos modelos terem tido muito sucesso no uso diário sugeriram que pesquisas adicionais sobre o uso dessas grandes redes neurais seriam necessárias.

Já no trabalho de Metaxiotis *et al.* (2003) é realizada uma revisão da aplicação de técnicas de inteligência artificial no problema de previsão de carga no curto prazo. São apresentadas as diversas abordagens e também as direções de pesquisa na época, considerando trabalhos publicados até o ano de 2001. O artigo conclui que as técnicas de inteligência artificial podem oferecer benefícios reais práticos em muitas de suas aplicações. Contudo, como todas as outras técnicas de aproximação, têm vantagens e desvantagens e não existem regras sobre quando uma técnica em particular é mais ou menos adequada para previsão de curto prazo.

O trabalho de Kyriakides e Polycarpou (2007) fornece um tutorial de introdução ao problema de previsão de curto prazo e um breve resumo das várias abordagens propostas, desde as que utilizam técnicas clássicas até as que utilizam técnicas de inteligência artificial. Os autores concluem que alguns métodos funcionam bem para alguns casos e podem ser inferiores em outros casos. Já em Hahn, Meyer-Nieberg e Pickl (2009), é apresentada uma visão geral sobre os vários modelos e métodos utilizados para prever futuras demandas de carga. São relacionadas diferentes aplicações apresentadas em publicações realizadas até o ano de 2007. Além disso, é realizada uma breve descrição dos métodos de previsão de carga comumente utilizados.

A partir de 2007, a grande maioria dos trabalhos na área de previsão de carga no curto prazo se concentram em métodos de inteligência computacional. A seguir, são apresentados alguns trabalhos publicados nessa área. Para facilitar a compreensão, os mesmos foram divididos em modelos que utilizam um único método de previsão ou modelos híbridos.

2.1.4.1 Métodos de Previsão Clássicos ou de Inteligência Computacional

A utilização massiva de Redes Neurais Artificiais (RNA) para previsão instiga a investigação de dois problemas comumente relatados: o da complexidade da rede utilizada e o da definição das entradas a serem utilizadas nos modelos. Nessa linha, Ferreira e da Silva (2011) desenvolvem métodos autônomos para especificação dos modelos de redes neurais para previsão de carga no curto prazo. São propostos procedimentos analíticos e acoplados de seleção de entradas e controle de complexidade, combinando teoria do caos, inferência bayesiana e minimização de limites superiores do erro de generalização. 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.

Lauret et al. (2008) também utilizam técnicas Bayesianas a fim de projetar um modelo ideal baseado em rede neural para previsão de carga. Os autores concluem que a utilização dessa técnica é bastante benéfica, pois proporciona um tratamento explícito da incerteza na modelagem.

No trabalho de Aguirre *et al.* (2008) é proposta uma discussão sobre os problemas encontrados na literatura e sobre como melhorar os resultados de previsão. Os autores afirmam que o problema de previsão de carga deve ser decomposto em dois problemas principais: a previsão dinâmica e mapeamento do padrão. Argumenta-se que, enquanto o segundo problema é essencialmente estático e torna-se não linear quando novos dados são obtidos, o primeiro pode não ser determinante, já que alguns dados não possuem correlação. Os autores discutem a utilização de modelos não lineares para previsão de carga e a sazonalidade a ser considerada, salientando que esses dois itens podem ser o centro de vários problemas de previsão.

Ferrara *et al.* (2009) propõem a aplicação de um método baseado em lógica paraconsistente anotada para previsão de perfis de carga. A vantagem na utilização

dessa metodologia é a grande capacidade de tratar a imprecisão e inconsistências nos dados, tornando a técnica bastante interessante. O método foi aplicado em uma subestação do município de São Paulo, SP, e os resultados mostraram a viabilidade do uso da técnica aliado a um baixo custo computacional, possibilitando sua utilização como ferramenta de apoio a operação elétrica da companhia de energia AES - Eletropaulo.

O trabalho de Yadav e Srinivasan (2011) apresenta um novo método para inicialização inteligente dos pesos da camada escondida da rede neural. Esse método é dividido em dois passos: no primeiro os dados são agrupados e no segundo são encontradas equações de separação dos planos. Esse método apresentou resultados promissores e se mostrou robusto frente a variações nas condições iniciais da previsão.

O objetivo do trabalho desenvolvido por Ying e Pan (2011) foi aplicar o modelo ANFIS para prever as cargas regionais de energia elétrica no Taiwan e demonstrar o desempenho de previsão deste modelo. Os autores comparam o modelo ANFIS com um modelo de regressão, RNA, SVM com algoritmos genéticos, SVM recorrentes com algoritmos genéticos e um sistema *fuzzy* elipsoidal híbrido para previsão. Os resultados obtidos pela ANFIS para previsão de carga regional foram mais precisos do que os dos outros modelos.

Nose-Filho, Lotufo e Minussi (2011) propõem uma previsão de curto prazo com múltiplos nós, no caso dois grupos, um de sete dias convencionais e outro de dois feriados a frente, utilizando três diferentes subtipos de redes neurais artificiais de regressão generalizada (GRNN). Utilizou-se a GRNN convencional, uma modificada e uma modificada com uma redução no número de termos na entrada. O termo “múltiplos nós” surge pelas propostas de previsão de vários tipos de subestações de duas formas distintas, fazendo previsões de carga de forma local, e outra utilizando uma previsão global junto de uma previsão de participação, para realizar a desagregação. Como resultado, tanto os três tipos de rede como os dois tipos de previsão possuíram erros diminutos e próximos entre si, revelando, assim, a robustez deste método de previsão, sendo a previsão de picos de carga o único ponto fraco encontrado, onde os valores estavam sempre abaixo dos reais.

No trabalho de García *et al.* (2013) não é proposto um método de previsão, mas o uso de dois indicadores da previsibilidade da série de carga, juntamente com um valor de precisão, para avaliar a aplicabilidade dos modelos de previsão em diferentes bases de dados. O objetivo deste trabalho é o de fornecer aos pesquisadores uma ferramenta que é capaz de avaliar a previsibilidade de uma série de carga e, conseqüentemente, a precisão da previsão. Foram utilizadas nove bases de dados dos EUA, todas com carga e temperatura horárias. Os testes mostraram que os indicadores têm forte correlação com o erro de previsão, tanto utilizando temperatura quanto não. Dessa forma, os indicadores podem ser utilizados para caracterizar a série de dados e, a priori, avaliar a sua previsibilidade.

A utilização de variáveis exógenas na previsão de carga é bastante comum. Especificamente na previsão de curto prazo, utilizam-se variáveis meteorológicas, como temperaturas, velocidade do vento e umidade, para agregar informação ao método de previsão. A utilização dessas variáveis é bastante discutida na literatura, principalmente devido a dificuldade de se obter boas previsões para as variáveis climáticas, e inúmeros trabalhos tratam da inserção dessas variáveis nos modelos de previsão. Coelho e Klein (2009) propõem um método de previsão de demanda utilizando SVR com mínimos quadrados, que utiliza a temperatura ambiente como variável exógena. O modelo foi validado num conjunto teste e obteve resultados promissores.

Fan, Chen e Lee (2009) aplicam redes neurais para previsão, com a particularidade de agregar o resultado de várias RNA que ponderam valores de cinco previsões meteorológicas originadas em fontes distintas. Os autores afirmam que, no problema estudado, a temperatura é a variável que exerce maior influência na demanda e por este motivo, com a estratégia de utilizar variadas fontes de informações meteorológicas, o erro da previsão é diminuído.

Mamlook, Badran e Abdulhadi (2009) apresentam um previsor *Fuzzy* para previsão de carga horária. Nesse previsor são utilizadas a carga do último dia, e da última semana, a temperatura do dia anterior, a temperatura prevista, o clima e o tipo de dia da semana. Foram utilizados dados da Jordania para validar o modelo, que foi comparado

com resultados de métodos clássicos de previsão. Os resultados obtidos foram em média 5% melhores que os obtidos pela técnica de previsão convencional.

Iwashita e Mori (2009) propuseram novo método de avaliação de risco para a previsão de carga máxima diária. O método proposto faz uso de uma RBF para a previsão de cargas máximas diárias, com horizonte de um dia. São utilizados pseudo-cenários realistas para gerar os dados de entrada da rede. Com os resultados, são calculados índices de risco de ultrapassagem da capacidade máxima de geração. Os resultados mostraram que a variação dos picos de carga segue a variação da temperatura máxima, e que os índices de risco tendem a ser grandes no verão.

Fay e Ringwood (2010) utilizam informações climáticas para diminuir os erros associados à previsão de carga do sistema elétrico irlandês. Os autores afirmam 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, os autores aplicam uma técnica de fusão de modelos onde são consideradas RNA com duas camadas ocultas e saídas únicas como submodelos para estimar os valores de carga.

Xinhui *et al.* (2010) utilizam a aplicação de uma RNA e de uma SVM, para previsão de carga horária para um 24 horas. São utilizados oito dados meteorológicos como variáveis exógenas e a comparação entre os métodos indicou um resultado superior, para quase todas as horas previstas, da SVM.

Kebriaei, Araabi e Rahimi-Kian (2011) propõem uma nova métrica para o problema de previsão de carga de curto prazo, chamada de extensão da soma convencional de erro quadrado (SSE). É utilizada uma RBF modificada para a previsão, otimizada por algoritmos genéticos. Além disso, um sistema de inferência é combinado com a rede RBF modificada para incorporar o impacto da temperatura na carga. O método é aplicado num sistema real do Irã e os resultados demonstram a eficiência do método proposto com a nova métrica de previsão.

Zhang e Ye (2011) estabelecem a previsão de longo prazo como sendo variável entre algumas semanas e, por exemplo, 20 anos, evidenciando a dificuldade de realizar previsões para tal horizonte e enaltecendo a importância desses estudos para mercados em desenvolvimento. O trabalho propõe o uso da técnica SVR para a realização de previsões para até cinco anos a frente. O trabalho apresenta um comparativo entre o método proposto, regressão linear e uma rede neural para a previsão de carga, com aplicação no mercado de energia da China. As comparações mostraram resultados mais consistentes com o panorama atual do mercado energético chinês. Os autores também salientam que fatores econômicos, para previsão de longo prazo, estão mais ligados a variação no consumo de energia que fatores climáticos, que são mais correntemente utilizados, e realiza previsões de importação e exportação de carga e do PIB.

Em seu artigo, Ahmadi, Bevrani e Jannaty (2012) propõem uma metodologia baseada em um sistema de regras *Fuzzy* para fazer previsão horária de carga para um período de 24 horas. Como variáveis de entrada, o sistema utiliza a carga do dia e da semana anterior. Como variáveis exógenas são utilizados os dados de temperatura do dia anterior e a prevista para o dia desejado, o clima, que é codificado a partir das condições climáticas (céu limpo, nublado, etc.) e o tipo de dia que é classificado como dia normal ou feriado. As regras são definidas por curvas gaussianas, exceto para o tipo de dia, que funciona de maneira binária. Para separar as regras para as variáveis relacionadas ao histórico de carga, são utilizadas sete curvas, para a temperatura são utilizadas três e para o clima quatro. Os erros obtidos são baixos e com baixa variação (em torno de 3%).

O artigo de Dkrr, Qlidp e Frp (2012) propõe uma metodologia de previsão de carga diária para curto prazo (aproximadamente um mês) utilizando diferentes regressões. Segundo os autores, os três principais parâmetros que influenciam o consumo de energia são a temperatura, a umidade e o tipo de dia. Os dados são separados em quatro tipos de dia: dia de semana normal (de terça-feira até sexta-feira), segunda-feira, sábado e domingo. Primeiramente, a previsão é feita a partir da busca por dias semelhantes utilizando norma Euclidiana com os dados dos últimos 30 dias. Dentre esses dados estão a temperatura máxima, a umidade média e o tipo de dia. Assim, dentre os 30 dias

calculados, os cinco que apresentarem menor valor são considerados dias semelhantes. Posteriormente, a previsão é feita utilizando uma regressão linear baseada nas correlações entre consumo e os demais parâmetros considerados, calculadas a partir dos valores médios do histórico. Por último, um ajuste de curva é proposto utilizando as mesmas variáveis exógenas. Nesse método são montadas regressões não lineares que descrevem a carga em função das variáveis exógenas.

Apadula *et al.* (2012) fazem uma análise do efeito da variabilidade meteorológica na demanda de energia elétrica mensal na Itália. São avaliadas a temperatura, velocidade do vento, umidade relativa e cobertura de nuvens. Um modelo de regressão linear múltipla é desenvolvido para estudar as relações entre as variáveis meteorológicas e a demanda, bem como para prever a demanda mensal até um mês a frente. O modelo foi testado extensivamente, usando diferentes combinações das variáveis relacionadas. As precisões obtidas são bastante semelhantes e indicam que a temperatura é a variável com maior influência sobre a carga.

Deihimi e Showkati (2012) apresentam a aplicação de *Eco State Networks* (ESN) para previsão de carga de 1 a 24 horas à frente, utilizando como entradas a carga atual e a temperatura. O método foi testado no sistema de uma concessionária de energia norte americana, que atua no oeste e leste americanos, no Texas, Quebec e Alaska. São realizados testes com a inclusão dos finais de semana e feriados no estudo e uma comparação dos resultados obtidos. Os resultados se mostraram promissores, no entanto os autores concluem que é necessário um maior aprofundamento do estudo e a inclusão de outras variáveis climáticas.

López *et al.* (2012) propõem um modelo de previsão de carga utilizando Mapas Auto-organizáveis de Kohonen. Foram utilizados dados do consumo de energia da Espanha para testar validar a aplicação da técnica, juntamente com dados meteorológicos. Os autores também propoem um método de seleção de entradas, através de uma análise de diferentes variáveis meteorológicas, da relevância destes dados meteorológicos, de quando os valores de carga recentes são usados como entrada e o efeito do uso de padrões diferentes para selecionar os dias para treinar o mapa. Os resultados numéricos mostraram que o modelo proposto é bastante flexível quanto as

variáveis de entrada e ao horizonte de previsão, dessa maneira, tornando fácil sua aplicação para diferentes usos.

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 autor compara métodos univariados com uma abordagem baseada em dados climáticos. Cinco métodos são aplicados: suavização exponencial; regressão ponderada, regressão ponderada com *spline* para ajustar a sazonalidade, regressão ponderada com *spline* e suavização exponencial, e decomposição de valores singulares.

2.1.4.2 Métodos Híbridos de Previsão

Com a grande utilização de métodos de inteligência computacional para previsão de curto prazo, diversos métodos híbridos de previsão de carga surgiram na literatura. Nessas técnicas são combinados métodos de inteligência computacional com outros da mesma classe, com métodos de pré-processamento dos dados e até mesmo métodos estatísticos de previsão.

Coelho *et al.* (2007) propõem a utilização de previsor *Fuzzy*, com agrupamento dos dados pelo método das c-médias nebuloso e otimização da parte consequente por mínimos quadrados. O método foi testado em dados de uma cidade no interior do Paraná, com objetivo de realizar a previsão um passo à frente para os pontos de conexão entre o sistema de distribuição e a rede básica. Os resultados foram promissores e os autores propõem a expansão da aplicação do modelo para as demais cidades do estado.

Vários trabalhos tratam do problema de previsão em duas etapas. Soares e Medeiros (2008) desenvolveram um modelo em dois níveis para previsão de carga horária. Para cada hora do dia é construído um modelo de previsão, onde é realizada uma decomposição da série diária de cada hora em dois componentes, um determinístico e outro estocástico. O método é aplicado em dados de uma concessionária no Sudeste do Brasil, para previsões horárias com horizonte variando de um a sete dias à frente. Os

resultados indicam que a metodologia é útil para a previsão de carga de energia elétrica em ambientes tropicais.

Maia e Gonçalves (2008) propõem uma metodologia para previsão da carga máxima para o dia seguinte. Primeiro, um modelo não linear para a carga máxima é utilizado, considerando o histórico de carga e a temperatura. Em seguida são obtidos intervalos de temperatura e o sistema de previsão é construído com base nesses intervalos. É construído um modelo para cada tipo de dia e para cada faixa de temperatura. Os autores utilizam dados de uma concessionária no Brasil para validar a metodologia e concluem que é mais adequado usar vários modelos, que são baseados no tipo do dia e em intervalos de temperatura, em vez de um único modelo para descrever o comportamento de carga.

Yun *et al.* (2008) tratam da influência dos preços da eletricidade na carga de curto prazo. O modelo de previsão de carga é uma combinação de uma RBF com um sistema ANFIS. O modelo da RBF realiza a previsão de carga considerando o preço da eletricidade e, em seguida, com base nas alterações recentes do preço em tempo real é realizado um ajuste nessa previsão utilizando o ANFIS. Foram utilizados dados de uma região da Austrália para validar o método proposto e verificou-se a integração do sistema melhora a precisão das previsões.

Em seu trabalho Wang *et al.* (2010) apresentam um modelo combinado para previsão de carga com base no modelo de previsão ARIMA sazonal, no modelo de suavização exponencial sazonal e nas SVMs ponderadas. Para otimizar os coeficientes de peso no modelo combinado foi utilizado algoritmo de otimização por enxame de partículas adaptativo. O modelo proposto foi testado em dados de um estado da Austrália e os resultados do modelo combinado foram melhores que a aplicação dos modelos individuais.

No trabalho de Hinojosa e Hoese (2010) é proposta uma metodologia de previsão não linear com base em *Fuzzy Inductive Reasoning* (FIR) e um método de otimização para seleção de variáveis de entrada. Com esta metodologia, variáveis quantitativas (meteorológicas e carga) e qualitativas (variáveis de tipo de dia e estação) são

incorporadas no modelo sem necessidade de formulações complexas. O método depende apenas do horizonte de previsão (semana/dia/hora).

Masseli *et al.* (2010) apresentam um método baseado em redes neurais polinomiais e lógica *Fuzzy*, otimizados por Enxame de Partículas (PSO, do inglês *Particle Swarm Optimization*). A ideia geral do método consiste em gerar uma estrutura final compacta, flexível e capaz de produzir bons resultados quando aplicada á resolução de problemas de identificação do sistema e previsão de séries temporais. O método foi aplicado em dois sistemas, um sistema teste acadêmico e um sistema real da concessionária de Minas Gerais. Os resultados da metodologia proposta foram comparados com outros métodos de previsão e confirmaram a viabilidade do método.

Chen *et al.* (2010) propoem um método que utiliza seleção de dias similares, decomposição *wavelet* e redes neurais para previsão de carga horária um dia a frente. O método foi aplicado em duas bases de dados do estado de Nova Inglaterra nos Estados Unidos e os resultados mostraram ganhos na qualidade das previsões.

Pandey, Singh e Sinha (2010) também propõem uma abordagem de decomposição *wavelet* para previsão de carga horária, com horizonte de um a sete dias a frente. A metodologia de previsão proposta está dividida em três partes: primeiro é realizada a decomposição *wavelet* da carga e das variáveis de temperatura, em seguida é feito o suavizamento e a reconstrução desses dados, e por último os dados são utilizados como entrada para um método de previsão. Foram realizados testes com métodos clássicos e métodos de inteligência computacional, com e sem a utilização da decomposição. Os resultados mostraram que com a utilização dos *wavelets* os resultados foram melhores que sem sua utilização.

Amjady e Daraeepour (2011) propõem uma técnica híbrida de previsão de demanda para curto e médio prazo, a qual utiliza a combinação de dois métodos para o treinamento de uma MLP. O primeiro método é composto pelas melhores características da Evolução Diferencial (ED), da otimização por PSO, de Algoritmos Genéticos e de Recozimento Simulado, é chamada de Evolução Diferencial Aprimorada (IDE, do inglês *Improved Differential Evolution*) e tem como principal objetivo fugir de mínimos locais. O segundo é uma variação do Método de Newton, denominado Levenberg-Marquardt. Essa

combinação realiza uma busca iterativa pelos melhores parâmetros da rede neural, que são os pesos da primeira camada da MLP e os *bias*. São criados dois indicadores de calendário: o primeiro é diário, o qual separa os dias em fins de semana e feriados, vésperas de fins de semana e feriados e dias úteis; o segundo é sazonal e separa em verão, inverno e outono ou primavera. A metodologia proposta apresentou menores erros de validação se comparada com outras combinações de MLPs treinadas por algoritmos de otimização avulsos.

Wang *et al.* (2011) propõem o uso de uma RN combinada com um algoritmo de clusterização *fuzzy* para a previsão de um dia à frente. O algoritmo *fuzzy* das C médias é utilizado para separar os consumos em cinco classes: consumo residencial, altamente industrial, industrial e comercial, não industrial e rural. Após a classificação, são treinadas as redes neurais através do algoritmo de retropropagação do erro. Os resultados das previsões, realizadas através das curvas típicas criadas pela técnica *fuzzy*, possuem erro inferior a três por cento. Enquanto isto, as previsões sem os dados da curva típica apresentaram erro, em sua maioria, acima do mesmo percentual.

Sun e Bai (2011) propõem o uso de uma transformada *wavelet* composta com Redes Neurais, na qual, ao invés de realizar as previsões diretamente, realizam-se as previsões dos coeficientes da transformada. O procedimento pode ser dividido em cinco partes: 1) decomposição via transformada *wavelet*; 2) processamento dos limiares, para eliminar dados espúrios; 3) normalização, a fim de evitar problemas de saturação; 4) uso de rede neural para a previsão; 5) reconstrução dos dados através dos coeficientes previstos. O treinamento, realizado com quinze dias de dado histórico, resultou em uma previsão de um dia à frente com erro baixo, em consequência da eliminação das altas frequências dos dados, que posteriormente geraram as previsões.

Hanmandlu e Chauhan (2011) propõem uma metodologia de previsão de carga (diária ou horária) para aproximadamente um mês de horizonte, utilizando duas redes neurais híbridas derivadas de sistemas *Fuzzy*. A primeira é uma rede *neuro-fuzzy* cujo *fuzzyficador* possui características *wavelet* e a segunda é uma *neuro-fuzzy* com *Choquet* integral (utilizado na decisão entre múltiplos critérios) na saída. Foram realizadas

previsões diárias para o período de um ano e os resultados mostram que o aprendizado reforçado torna a segunda rede no mínimo três vezes mais rápida (pode chegar a cinco vezes conforme o número de regras do *fuzzyficador*). Quanto aos erros, a primeira rede é mais eficiente, pois mantém uma média de aproximadamente 1,5%, enquanto a segunda fica em torno de 1,8%. Ainda, os modelos propostos apresentam erros mais baixos se comparados a redes *neuro-fuzzy* comuns e ao ANFIS, os quais apresentaram, para o mesmo caso, erros em torno de 3%.

Wang, Xia e Kang (2011) desenvolvem um método híbrido para previsão da carga da China. O método é dividido em dois estágios, no primeiro a carga diária é prevista por método clássico de séries temporais, e no segundo o desvio causado pelo método de séries temporais é modelado e adicionado ao resultado da primeira fase. Com base numa análise aprofundada sobre o impacto dos desvios entre a carga real e o resultado de previsão é escolhido o algoritmo mais apropriado entre regressão linear, programação quadrática e SVM para utilização no estágio dois. Os autores afirmam que a eficácia da proposta foi mostrada pela experiência e aplicação prática da China.

Alamaniotis, Ikonopoulou e Tsoukalas (2012) realizam previsões de meia hora, com intervalo de 5 minutos, através de 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 Genéticos (AG).

Elattar, Goulermas e Wu (2012) propõem uma generalização do algoritmo *Group Method of Data Handling* (GMDH) com um método de regressão local e mínimos quadrados ponderados, com otimização dos parâmetros por Evolução Diferencial. O método foi testado para previsão de demanda e temperatura horária em Nova York e para previsão de carga, preço e temperatura horária em Victorian, Austrália. Os resultados mostraram superioridade do método, principalmente na previsão para períodos de inverno.

Niu, Shi e Wu (2012) apresentam um modelo de previsão com base em RNA Bayesianas com aprendizado pelo Algoritmo de Monte Carlo Híbrido. São utilizadas 11 variáveis de entradas, sendo uma relativa ao tempo, cinco relativas as condições climáticas da hora de previsão e cinco relativas as condições climáticas em períodos anteriores. O modelo é utilizado para previsão de carga horária, com horizonte de 25 dias, para a cidade de Baoding, na China. Os resultados mostram que o método proposto tem alta capacidade de generalização e melhor desempenho de previsão, quando comparado com RNA Bayesianas com aprendizado Laplaciano.

Liu, Li e Sun (2013) desenvolvem um método híbrido baseado em transformação *multiwavelet* e múltiplas redes neurais. Em primeiro lugar, é realizada a transformação dos dados através da *multiwavelet* e em seguida é realizado o treinamento através de três modelos, a saber, uma RNA do tipo back-propagation, uma RBF e uma rede neural *wavelet*. Por último, os dados treinados das três redes neurais são introduzidos numa RNA *feedforward* de três camadas para a previsão de carga. Os resultados da simulação, utilizando dados da cidade de Sichuan na China, mostram que a precisão da previsão de carga do modelo proposto é maior do que com a utilização de um único modelo de RNA e do que com o modelo de previsão combinado sem o método de transformação *multiwavelet*.

Hooshmand, Amooshahi e Parastegari (2013) propõem um novo algoritmo em dois passos. No primeiro passo, uma transformação *wavelet* e uma RNA são usadas para a previsão primária de carga para as próximas 24 horas. Nessa etapa, são utilizadas variáveis climáticas e o tipo de dia anterior. Na segunda etapa, são utilizadas a transformação *wavelet*, um método de identificação de horas similares e um ANFIS para melhorar os resultados obtidos na primeira fase. Neste estudo, a transformação *wavelet* é utilizada para extrair componentes de baixa ordem da carga e dados meteorológicos. Além disso, o número de dados meteorológicos é reduzido através de uma investigação das condições climáticas de cidades diferentes. Para avaliar o desempenho do método proposto, foram utilizados quatro casos diferentes para previsão de carga do Irã e de Nova Gales do Sul (Austrália). Os resultados das simulações, comparados a quatro

outros métodos, se mostraram o método proposto aumenta a precisão da previsão quando ocorrem variações na temperatura.

Ko e Lee (2013) propõem um algoritmo que combina SVR, RBF e Filtro de Kalman estendido para previsão de carga no curto prazo. No modelo proposto, em primeiro lugar, o modelo SVR é utilizado para determinar a estrutura e os parâmetros iniciais da RBF. Após a inicialização, o Filtro de Kalman estendido é usado como o algoritmo de aprendizagem para otimizar os parâmetros da RBF. Finalmente, o modelo ideal da RBF é adotado para prever a carga. O desempenho da abordagem proposta é avaliado no sistema da Companhia de Energia do Taiwan, para três casos diferentes. Os resultados das simulações mostram superioridade do método proposto, quando comparado a métodos híbridos semelhantes.

Hernández *et al.* (2013) apresentam um modelo de previsão em dois passos, baseado em RNA, a fim de realizar previsão de carga para o dia seguinte em ambiente de *microgrid*. Primeiramente, são realizadas as estimativas de picos e vales de demanda para o dia previsto. Esses dados, em conjunto com outras variáveis, são utilizados para prever a curva de demanda do dia. O método foi aplicado para um sistema da Espanha e os resultados foram comparados com outros modelos aplicados ao o mesmo sistema, gerando ganhos significativos na precisão da previsão.

Borges, Peña e Fernández (2013) apresentam um previsor agregado, combinando métodos de previsão para redes inteligentes. São utilizadas três abordagens, a agregação da carga de baixo para cima, a agregação de cima para baixo e agregação regressiva. O principal objetivo da metodologia é manter o equilíbrio entre a geração e a demanda de energia. Foram realizados testes com um sistema fictício e dados de carga reais, utilizando os métodos de previsão ARIMA, modelos de regressão polinomial e SVM.

A tabela 6 resume do levantamento do estado da arte realizado nesse trabalho, apresentando o tipo de aplicação, as variáveis consideradas em cada trabalho e as técnicas utilizadas pelos autores.

2.1.4.3 Tabela Resumo do Estado da Arte

TABELA 6 – RESUMO DO ESTADO DA ARTE

FONTE: O AUTOR

<i>Autores/Ano</i>	<i>Local de aplicação</i>	<i>Tipo de aplicação</i>	<i>Variáveis consideradas</i>	<i>Técnicas utilizadas</i>
Ferreira e da Silva (2011)		Desenvolvimento de métodos autônomos para especificação dos modelos de redes neurais.	Carga e temperatura	RNA
Coelho <i>et al.</i> (2007)	Brasil	Desenvolvimento de um modelo de previsão Fuzzy para um passo à frente.	Carga	Fuzzy
Lauret <i>et al.</i> (2008)	-	Projeção de um modelo ideal de redes neurais utilizando técnicas Bayesianas.	Carga	RNA
Aguirre <i>et al.</i> (2008)	-	Discussão sobre os problemas e propostas de melhorias nos estudos de previsão de carga.	-	-
Soares e Medeiros (2008)	Brasil	Desenvolvimento de um modelo de previsão em duas etapas, uma utilizando um modelo determinístico para cada hora do dia e a outra utilizando um modelo estocástico.	Carga e temperatura	ARIMA e Generalized Long Memory
Maia e Gonçalves (2008)	Brasil	Metodologia em duas fases: a primeira com um modelo não linear para previsão da carga máxima e a segunda utilizando intervalos de temperatura para prever a carga.	Carga e temperatura	
Yun <i>et al.</i> (2008)	Austrália	Discussão da influência dos preços da eletricidade na carga no curto prazo.	Carga e preço da eletricidade	RBF e ANFIS
Ferrara <i>et al.</i> (2009)	Brasil	Desenvolvimento de um método para previsão de perfis de carga.	Carga	Lógica paraconsistente anotada
Coelho e Klein (2009)	Dados criados	Aplicação de um modelo SVR com mínimos quadrados e avaliação da utilização ou não da temperatura.	Carga e temperatura	SVR com mínimos quadrados
Fan, Chen e Lee (2009)		Utilização de várias RNA que ponderam valores de cinco previsões meteorológicas originadas em fontes distintas.	Carga e temperatura	RNA
Mamlook, Badran e Abdulhadi (2009)	Jordânia	Utilização de um modelo de previsão baseado em lógica Fuzzy.	Carga, temperatura e clima	Fuzzy
Iwashita e Mori (2009)	-	Proposição de um novo método de avaliação de risco na previsão de carga máxima diária.	Carga e temperatura	RNA

<i>Autores/Ano</i>	<i>Local de aplicação</i>	<i>Tipo de aplicação</i>	<i>Variáveis consideradas</i>	<i>Técnicas utilizadas</i>
Fay e Ringwood (2010)	Irlanda	Proposição de um modelo de previsão que utiliza a série prevista das variáveis meteorológicas ao invés dos valores reais.	Carga e temperatura	RNA
Wang <i>et al.</i> (2010)	Austrália	Proposição de um modelo de previsão que combina diversas técnicas, cujos pesos são estimados através de um método de enxame de partículas.	Carga	ARIMA sazonal, no modelo de suavização exponencial sazonal e nas SVMs ponderadas
Hinojosa e Hoese (2010)	Equador	Proposição de um modelo de previsão com um método de otimização para seleção das entradas, que podem ser quantitativas ou qualitativas.	Carga e variáveis meteorológicas	<i>Fuzzy Inductive Reasoning</i>
Masseli <i>et al.</i> (2010)	Brasil	Proposição de um modelo híbrido com estrutura final compacta e flexível.	Carga	RNA, <i>Fuzzy</i> e PSO
Xinhui <i>et al.</i> (2010)		Comparação de desempenho da RNA e da SVM.	Carga e oito variáveis meteorológicas	RNA e SVM
Yadav e Srinivasan (2011)	Canadá, Austrália e Estados Unidos	Desenvolvimento de um método para inicialização inteligente dos pesos da camada escondida da rede neural.	Carga	RNA
Chen <i>et al.</i> (2010)	Estados Unidos	Proposição de um modelo híbrido que utiliza seleção de dias similares para prever a carga horária para um dia à frente.	Carga e variáveis meteorológicas	Decomposição <i>Wavelet</i> e RNA
Pandey, Singh e Sinha (2010)	-	Desenvolvimento de um método com tres fases: decomposição wavelet da carga e da temperatura; suavizamento e reconstrução dessas variáveis; e utilização dessas entradas para um método de previsão.	Carga e temperatura	Decomposição <i>Wavelet</i>
Nose-Filho, Lotufo e Minussi (2011)	Nova Zelandia	Desenvolvimento de um predictor de curto prazo com dois grupos, um de sete dias convencionais e outro de dois feriados a frente, para vários tipos de subestações.	Carga	RNA
Ying e Pan (2011)	Taiwan	Aplicar o modelo ANFIS para prever cargas regionais e demonstrar o desempenho de previsão deste modelo.	Carga	RNA

<i>Autores/Ano</i>	<i>Local de aplicação</i>	<i>Tipo de aplicação</i>	<i>Variáveis consideradas</i>	<i>Técnicas utilizadas</i>
Amjady e Daraeeepour (2011)	Base de dados EUNITE	Proposição de uma técnica híbrida que combina dois métodos distintos para treinamento de uma MLP.	Carga e temperatura	RNA, Evolução Diferencial Aprimorada e Levenberg-Marquardt
Wang <i>et al.</i> (2011)	China	Desenvolvimento de um método híbrido para previsão um dia à frente, com separação do consumo por classe.	Carga	RNA e Fuzzy
Sun e Bai (2011)	-	Desenvolvimento de um método que utiliza RNA e decomposição <i>Wavelet</i> com o objetivo de prever os coeficientes da transformada.	Carga	RNA e decomposição <i>Wavelet</i>
Hanmandlu e Chauhan (2011)	India	Proposição de um modelo híbrido com vários tipos de previsor Fuzzy.	Carga e temperatura	Fuzzy
Wang, Xia e Kang (2011)	China	Desenvolvimento de um modelo híbrido que utiliza um método clássico na primeira fase e, com base numa análise aprofundada dos desvios entre a carga real e a previsão escolhe um método para a segunda fase.	Carga	Regressão linear, programação quadrática e SVM
Alamaniotis, Ikononopoulos e Tsoukalas (2012)	-	Proposição de um método de previsão para meia hora à frente em intervalos de cinco minutos.	Carga	Processos gaussianos
Kebriaei, Araabi e Rahimi-Kian (2011)	Irã	Proposição de uma nova métrica para previsão.	Carga e temperatura	RNA modificada
Zhang e Ye (2011)	China	Proposição de um modelo de previsão com horizonte de algumas semanas até cinco anos, considerando variáveis econômicas.	Carga, importação e exportação de carga e PIB	SVR
Ahmadi, Bevrani e Jannaty (2012)	Irã	Proposição de um modelo de previsão baseado em regras Fuzzy com utilização de variáveis exógenas.	Carga, temperatura e tipo do clima	Fuzzy
Dkrr, Qlildp e Frp (2012)		Utilização de diferentes regressões e medidas de similaridades para prever a carga diária.	Carga, temperatura e umidade	Regressão linear e não linear
Deihimi e Showkati (2012)	Estados Unidos e Alasca	Aplicação de <i>Eco State Networks</i> para previsão de carga de uma a 24 horas à frente.	Carga e temperatura	<i>Eco State Networks</i>

Autores/Ano	Local de aplicação	Tipo de aplicação	Variáveis consideradas	Técnicas utilizadas
López <i>et al.</i> (2012)	Espanha	Proposição de um método de seleção de entradas através da análise de variáveis meteorológicas, valores recentes de carga e uso de diferentes padrões.	Carga e variáveis meteorológicas	Mapas Auto-organizáveis de Kohonen
Taylor (2012)	-	Comparação entre cinco métodos, com o intuito de mostrar que as variáveis climáticas pouco influenciam a carga em curtos períodos de tempo.	Carga e variáveis meteorológicas	Suavização exponencial; regressão ponderada, regressão ponderada com <i>spline</i> , regressão ponderada com <i>spline</i> e suavização exponencial, e decomposição de valores singulares
Elattar, Goulermas e Wu (2012)	Estados Unidos e Austrália	Proposição de uma generalização do algoritmo <i>Group Method of Data Handling</i> com um método de regressão local e mínimos quadrados ponderados, com otimização dos parâmetros por Evolução Diferencial	Carga, temperatura e preço	<i>Group Method of Data Handling</i> , regressão local, mínimos quadrados ponderados, e Evolução Diferencial
Niu, Shi e Wu (2012)	China	Proposição de um modelo híbrido que utiliza RNA Bayesianas e simulação de Monte Carlo.	Carga, temperatura e condições climáticas	RNA Bayesianas e Monte Carlo
Liu, Li e Sun (2013)	China	Proposição de um modelo híbrido baseado em transformação <i>multiwavelet</i> e múltiplas RNA.	Carga	Transformação <i>multiwavelet</i> , RNA do tipo MLP e RBF
Hooshmand, Amooshahi e Parastegari (2013)	Austrália	Proposição de um método híbrido em duas fases: a primeira realiza uma previsão primária para a carga e a segunda utiliza as horas similares para aperfeiçoar os resultados obtidos.	Carga e variáveis meteorológicas	Transformação <i>Wavelet</i> , RNA e ANFIS
Ko e Lee (2013)	Taiwan	Proposição de um método que combina três métodos para previsão no curto prazo.	Carga	SVR, RBF e Filtro de Kalman
Hernández <i>et al.</i> (2013)	Espanha	Apresentação de um método em dois passos, baseado em RNA, onde inicialmente são aproximados os picos e vales de carga e depois esses dados são utilizados para prever a curva de demanda.	Carga	RNA
Borges, Penya e Fernández (2013)		Proposição de um previsor agregado, que combina métodos distintos de agregação, com o	Carga	ARIMA, Regressão Polinomial e SVM

Autores/Ano	Local de aplicação	Tipo de aplicação	Variáveis consideradas	Técnicas utilizadas
García <i>et al.</i> (2013)	Estados Unidos	objetivo de manter o equilíbrio entre a geração e a demanda. Proposição do uso de indicadores de previsibilidade e um valor de precisão para avaliar a aplicabilidade de modelos de previsão em diferentes bases de dados.	Carga e temperatura	

2.2 REDE DE MAPAS ACOPLADOS

A Rede de Mapas Acoplados (*Coupled Map Lattices* ou CML) 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 dada 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, número de barramentos, linhas existentes, posicionamento destes, além de outras 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 descrevam 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 por um fluxo de potência.

No passo (d) as dinâmicas determinadas para compor o modelo são transmitidas, ou seja, considerando o tempo, é aplicado o 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 EDP.

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 mantêm-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 7 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 7 - RESUMO DA ESTRUTURA BÁSICA DE TRÊS MODELOS APLICÁVEIS A SISTEMAS DINÂMICOS

FONTE: ADAPTADO DE PONTES (2008)

<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.

2.2.1 Modelos de Vizinhaça

Os sistemas que utilizam informações de acoplamento necessariamente precisam seguir um modelo de vizinhaça, 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 vizinhaça: modelo de Von Neumann e modelo de Moore. As representações gráficas destas estruturas podem ser observadas na figura 11.

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 11 – 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)

2.2.2 Mapas

As equações algébricas utilizadas para estudo da formação de padrões representam os elementos de uma rede de forma individualizada, ou seja, podem descrever separadamente as dinâmicas de cada sítio da rede.

Conforme descrito por Kaneko (1993), esses mapas ou equações de recorrência, quando considerados em um mapeamento não linear de um sistema caótico, podem ser descritos como uma função, conforme apresentado em (1).

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

onde n representa uma das dimensões do problema, comumente apresentado como o deslocamento temporal e x representa um elemento da rede. A função $f(x)$ representa a lei evolutiva individual de cada mapa, ou seja, o comportamento isolado de um mapa.

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).

2.2.3 Acoplamento

As conexões existentes entre os mapas podem ser descritas de diversas formas e representadas por uma função g que define a dinâmica local do acoplamento. Essa função pode ser descrita por uma dinâmica linear (2) ou dinâmica futura (3).

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

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

A escolha da dinâmica (linear ou futura) é realizada com base no problema modelado. Usualmente, observa-se que a utilização da dinâmica futura com um mapa adequado ao problema, tende a apresentar resultados melhores do que a dinâmica linear, porém o uso da dinâmica linear possui comportamento superior à dinâmica futura quando o mapa 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 em (4).

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

onde $\varepsilon > 0$ é a intensidade do acoplamento e i uma coordenada para estabelecer a posição do elemento. Dessa maneira, ao se adotar o comportamento linear tem-se a equação (5).

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

Ao convencionar como acoplamento futuro considera-se a função dada em (6).

$$x_{n+1}^{(i)} = (1 - \varepsilon)f(x_n^{(i)}) + \frac{\varepsilon}{2} \left[f(x_n^{(i+1)}) + f(x_n^{(i-1)}) \right] \quad (6)$$

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 (7).

$$x_{n+1}^{(i)} = (1 - \varepsilon)g(x_n^{(i)}) + \frac{\varepsilon}{N - 1} \sum_{\substack{j=1 \\ j \neq i}}^N g(x_n^{(j)}) \quad (7)$$

onde N é o número de elementos da rede. Esse tipo de acoplamento também pode ser chamado de acoplamento campo médio.

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 (8).

$$x_{n+1}^{(i)} = (1 - \varepsilon)g(x_n^{(i)}) + \frac{\varepsilon}{\eta(\alpha)} \sum_{j=1}^{N'} \frac{g(x_n^{(i+j)}) + g(x_n^{(i-j)})}{j^\alpha} \quad (8)$$

sendo que $\eta(\alpha) = 2 \sum_{j=1}^{N'} \frac{1}{j^\alpha}$ é chamado de fator de normalização e refere-se à forma e quantidade de vizinhos adotados de acordo com o mapa aplicado; $\alpha > 0$ 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, quando $\alpha = 0$ e $\eta(\alpha) = N - 1$ a função de acoplamento do tipo lei de potencia 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 mais próximos.

Na próxima seção são apresentados estudos de aplicações gerais com o uso da modelagem baseada em redes de mapas acoplados.

2.2.4 *Revisão de Literatura – CML*

Em 1981, iniciaram-se estudos de um modelo que consistia 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 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).

Rand e Wilson (1995) realizaram uma 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-Nicolaus 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.

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. 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.

Na área de saúde, Pavlov *et al.* (2011) aplicam 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 compõem 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, Parthasarathy e Sinha (1998) demonstram o uso do método de controle por pinagem¹ 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 um determinado estado instável.

¹ pinagem: descrição ou diagrama dos pinos de um chip ou conector

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, LI e LIANG, 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).

As redes de mapas acoplados também são amplamente utilizadas no desenvolvimento de algoritmos para criptografia, sendo que a segurança desses sistemas é o principal requisito analisado. Wang, Wong e Xiao (2011) propõem um algoritmo para decodificação de mensagens baseado em redes de mapas acoplados. As análises teóricas e simulações numéricas demonstraram que o algoritmo proposto satisfaz os requisitos de segurança e sua eficácia é melhorada em plataformas paralelas.

No trabalho de Hussain e Gondal (2014) o emprego das redes de mapas acoplados e da transformação S-box foi utilizado para confundir a associação entre a imagem original e a imagem criptografada. Os experimentos mostraram que essa técnica de codificação de imagens possui alto nível de segurança e possui um excelente potencial para aplicações práticas. Behnia, Ahadpour e Ayubi (2014) propõem um algoritmo de detecção de imagens de marca d'água digital baseado em caos espaço-temporal utilizando um código privado.

Wang, Hu e Zhou (2014) utilizaram as CML unidirecionais combinadas com operações algébricas simples para desenvolver um algoritmo de auto-sincronização para textos criptografados. Segundo os autores, o algoritmo possui robustez na sincronização e forte segurança.

A utilização das redes de mapas acoplados na previsão de séries temporais é um tema pouco explorado. Na maioria das vezes a modelagem é aplicada a 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 seu trabalho 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 ser utilizada na identificação de sistemas. Pan e Billings (2008) tratam do problema de detecção do tamanho da vizinhança para a identificação de sistemas espaço-temporais. O método proposto busca determinar a menor dimensão possível para os dados de série temporal.

Em Wei *et al.* (2009) transformações *wavelet* são incorporadas 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. É ainda utilizada otimização por PSO na fase de treinamento e para a definição da quantidade de neurônios *wavelets*.

Especificamente, o uso da CML em previsão de carga foi utilizado no trabalho de Coelho, Oening e Aoki (2013). Neste trabalho é realizada a modelagem do problema de previsão de carga através da CML e realizada a previsão para sistemas teste de 5 e 14 barras. Os resultados se mostraram bastantes promissores para previsão um passo a frente, no entanto carecem de melhorias para previsões de múltiplos passos. Além disso, algumas questões na modelagem do problema necessitam de um estudo mais aprofundado, de forma a garantir a aplicação da técnica de forma efetiva.

2.3 CONSIDERAÇÕES FINAIS DO CAPÍTULO

O objetivo desse capítulo foi apresentar os conceitos teóricos básicos utilizados no desenvolvimento deste trabalho. O capítulo foi iniciado apresentando um panorama geral sobre previsão de carga. 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. São realizados estudos de previsão para atender a solicitações de órgãos que atuam no planejamento e na operação do sistema elétrico brasileiro, como a EPE e o ONS. Além disso, as próprias concessionárias realizam estudos de previsão para atender demandas internas, como setores financeiros e de planejamento.

Para a composição dessas previsões, normalmente são necessários históricos de dados, que muitas vezes não estão disponíveis, seja pela falha na medição ou pela análise de um barramento recém-adicionado ao sistema. Outro fator que dificulta os estudos de previsão são remanejamentos de carga, que causam mudanças nos níveis de carga, comprometendo o uso do histórico.

Um detalhe a ser observado nos diversos estudos de previsão que uma distribuidora de energia elétrica realiza é a quantidade de barramentos sob responsabilidade da concessionária. Esse valor, dependendo da empresa de energia, pode variar de algumas para centenas de barras, tornando a previsão individualizada um desafio.

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

Foram também apresentados conceitos de vizinhanças e mapas, além de expor as classificações básicas do acoplamento. Neste trabalho foram realizados testes aplicando a dinâmica linear e a futura, considerando os acoplamentos local e global. 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.

3 MATERIAIS E MÉTODO

Este capítulo divide-se em duas seções principais: materiais, onde são apresentadas características e a construção de série de dados utilizados para testar o método proposto, e métodos, onde são expostos os métodos aplicados para resolução do problema.

A primeira seção apresenta os dois sistemas teste utilizados, denominados sistema teste 1 e sistema teste 2, que foram obtidos junto à COPEL Distribuição e representam dois conjuntos distintos de barras no interior do Estado do Paraná. O primeiro sistema teste possui 11 barras e o segundo 14 barras, com períodos históricos distintos.

A segunda seção apresenta o método híbrido de previsão inspirado nos conceitos de CML, desenvolvido neste trabalho. O método possui duas fases que são inspiradas nos conceitos de acoplamento, introduzidos no capítulo anterior, cujo objetivo é o de utilizar as informações de carga das outras barras do sistema na previsão de uma determinada barra.

3.1 MATERIAIS

São aqui apresentados os materiais utilizados para testar e validar o método proposto. Foram utilizados dois sistemas testes, que representam dois conjuntos distintos de barras.

O primeiro sistema possui 11 barras de carga e o segundo 14. Nos dois casos, foram obtidos dados medidos de demanda de potência ativa [MW] integralizadas por hora. Cada uma das barras desses sistemas possuem dados históricos com períodos diferentes, conforme explicitado nas seções a seguir.

3.1.1 Sistema Teste 1

O primeiro sistema teste utilizado contém 11 barras de carga conectadas entre si. O diagrama unifilar desse sistema está apresentado na figura 12. Pode-se notar que todas as barras estão conectadas ao menos a uma barra do sistema. A barra 4 possui o maior número de barras conectadas, num total de oito. As barras 1, 2, 5, 6 e 8 possuem somente uma barra conectada.

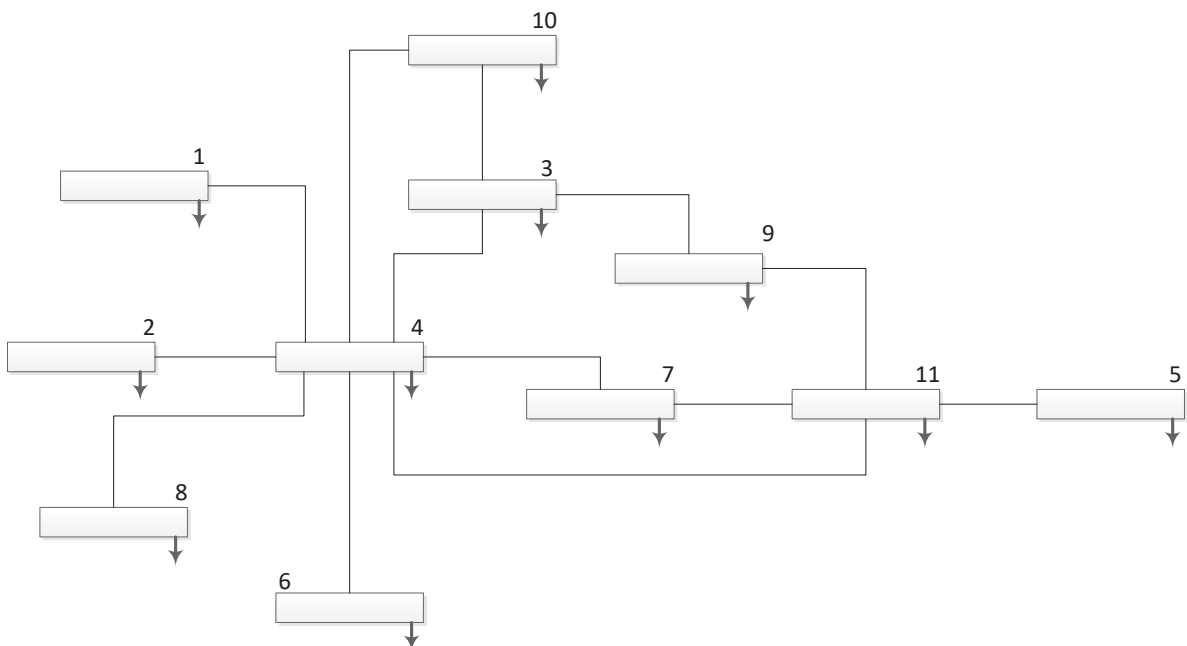


FIGURA 12 – GRAFO DO SISTEMA TESTE 1

FONTE: O AUTOR

Foram obtidos dados de demanda de potência ativa média (MW) integralizada em intervalos de uma hora para cada uma das barras do sistema, ou seja, os dados são resultantes do cálculo da média de todos os valores medidos de potência ativa durante um período de uma hora.

As séries históricas das barras possuem tamanhos distintos, sendo que a barra com o menor histórico é a barra 10, com aproximadamente um ano e sete meses de histórico, e a com maior histórico são as barras 2, 3, 5, 6, 7 e 9, com aproximadamente

quatro anos e quatro meses de histórico. A tabela 8 apresenta um resumo das informações sobre os períodos históricos de cada barra, descrevendo a data inicial e final do histórico de dados, o tamanho (aproximadamente, pois o último mês de dados não está fechado) e a quantidade (número de horas) de pontos de cada série.

TABELA 8 – INFORMAÇÕES SOBRE O PERÍODO DAS SÉRIES HISTÓRICAS DO SISTEMA TESTE 1
 FONTE: O AUTOR

<i>Barra</i>	<i>Data inicial</i>	<i>Data final</i>	<i>Tamanho do histórico</i>	<i>Quantidade de horas (pontos da série)</i>
1	01/04/2010	24/03/2013	3 anos	26.136
2	01/12/2008	24/03/2013	4 anos e 4 meses	37.800
3	01/12/2008	24/03/2013	4 anos e 4 meses	37.800
4	01/01/2009	24/03/2013	4 anos e 3 meses	37.056
5	01/12/2008	24/03/2013	4 anos e 4 meses	37.800
6	01/12/2008	24/03/2013	4 anos e 4 meses	37.800
7	01/12/2008	24/03/2013	4 anos e 4 meses	37.800
8	01/04/2010	24/03/2013	3 anos	26.136
9	01/12/2008	24/03/2013	4 anos e 4 meses	37.800
10	01/08/2011	24/03/2013	1 ano e 7 meses	14.448
11	01/01/2009	24/03/2013	4 anos e 3 meses	37.056

Os dados horários são provenientes do sistema de medição da distribuidora e possuem uma grande quantidade de inconsistências, como dados faltantes, zeros, valores negativos e *outliers*. De forma a minimizar os problemas de medição encontrados, cada uma das séries passou por um método de detecção e correção de falhas e *outliers* descrito em Nascimento *et al* (2012). Esse método utiliza o método Z-Score Modificado para detecção dos *outliers* e depois os pontos diagnosticados como problemáticos são

substituídos. Para a substituição, é utilizada uma métrica calculada através da média dos valores da mesma hora nos últimos três dias de mesmo tipo (dia útil, sábado e domingos e feriados).

A tabela 9 apresenta a quantidade de pontos detectados como incorretos e corrigidos pelo método descrito em Nascimento *et al* (2012). Pode-se verificar que algumas barras tem um alto percentual de correção nas séries, especialmente as barras 4 e 8, onde quase 50% dos dados históricos apresentaram algum tipo de inconsistência, de acordo com o método de detecção de falhas utilizado. Essa alta quantidade de inconsistências encontradas tem origem principalmente em falhas nos medidores e transferências temporárias de carga entre as barras. A última coluna da tabela 9 apresenta o Coeficiente de Variação de Pearson (CV), uma medida relativa de dispersão da série temporal. De acordo com esse índice, as séries das barras com CV entre vinte e trinta por cento são consideradas de média dispersão e as que possuem CV acima de trinta por cento são consideradas de elevada dispersão (MARTINS, 2002),

Nas figuras mostradas na sequência (figura 13 a figura 17) é apresentada uma visão geral do comportamento das séries históricas para algumas barras selecionadas. Na parte superior de cada figura é apresentada a série bruta (antes da aplicação da metodologia de detecção e substituição de *outliers*) juntamente com a série após o tratamento dos dados.

Na parte inferior de cada figura são apresentadas amostras semanais dos dados. Foi escolhida sempre a terceira semana do mês de março, dessa forma, as séries com maior histórico possuem cinco semanas ilustrativas e as com menor histórico duas semanas. A título de exemplificação, foram selecionadas as quatro barras com maior quantidade de erros detectados, barras 1, 3, 4 e 8, e a barra 11, que possui a menor quantidade de correções.

TABELA 9 – QUANTIDADE DE PONTOS CORRIGIDOS NAS SÉRIES DO SISTEMA TESTE 1

FONTE: O AUTOR

<i>Barra</i>	<i>Número de Pontos Corrigidos</i>	<i>% de Correção da Série</i>	<i>Média</i>	<i>Desvio Padrão</i>	<i>Coefficiente de Variação de Pearson</i>
1	6988	27%	13,76	2,99	21,72%
2	5024	13%	35,56	9,39	26,42%
3	9685	26%	46,84	17,00	36,29%
4	13976	38%	36,83	10,23	27,79%
5	5259	14%	28,17	7,29	25,86%
6	5927	16%	38,54	9,71	25,19%
7	5304	14%	29,55	9,19	31,11%
8	12625	48%	2,17	0,90	41,64%
9	5374	14%	9,90	3,18	32,08%
10	498	3%	21,41	5,21	24,32%
11	5324	14%	53,80	17,68	32,86%




FIGURA 13 – SÉRIE HISTÓRICA BARRA 1 – SISTEMA TESTE 1

FONTE: O AUTOR




FIGURA 14 – SÉRIE HISTÓRICA BARRA 3 – SISTEMA TESTE 1

FONTE: O AUTOR




FIGURA 15 – SÉRIE HISTÓRICA BARRA 4 – SISTEMA TESTE 1

FONTE: O AUTOR




FIGURA 16 – SÉRIE HISTÓRICA BARRA 8 – SISTEMA TESTE 1

FONTE: O AUTOR




FIGURA 17 – SÉRIE HISTÓRICA BARRA 11 – SISTEMA TESTE 1

FONTE: O AUTOR

3.1.2 Sistema Teste 2

O segundo sistema teste utilizado contém 14 barras de carga conectadas entre si, conforme diagrama unifilar apresentado na figura 18. Nesse sistema várias barras possuem somente uma conexão e as barras que possuem maior número de conexões são as barras 7, com 10 conexões, e a barra 5 com 6 conexões.

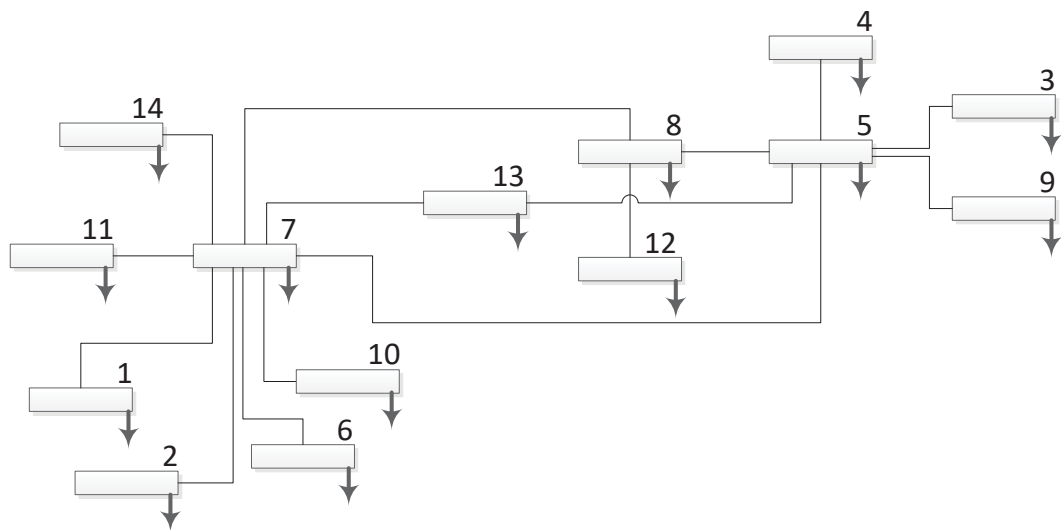


FIGURA 18 – GRAFO DO SISTEMA TESTE 2

FONTE: O AUTOR

Da mesma maneira que para o sistema teste 1, foram obtidos dados de demanda de potência ativa (MW) integralizada na hora. Os tamanhos de cada uma das séries históricas das barras desse sistema estão apresentados na tabela 10. As barras 9 e 10 são as que possuem o menor tamanho, de um ano e oito meses, as barras 5, 11 e 13 possuem em torno de dois anos de histórico e as demais barras possuem um histórico de dados de aproximadamente quatro anos.

Da mesma forma que para o sistema teste 1, os dados horários são provenientes do sistema de medição da distribuidora e passaram pelo método de detecção e correção de falhas de Nascimento *et al.* (2012). O número de problemas encontrados pelo método e o percentual que representam estão apresentados na tabela 11. A barra 1 foi a barra

que apresentou o maior número de problemas, sendo corrigida aproximadamente 50% da série. As barras 5, 7, 8 e 14 também apresentaram um número elevado de correções, em torno de 30% da série.

A última coluna da tabela 11 apresenta o CV para as séries históricas do sistema 2. Neste sistema somente a série da barra 13 possui elevada dispersão e as demais séries possuem média dispersão.

TABELA 10 – INFORMAÇÕES SOBRE O PERÍODO DAS SÉRIES HISTÓRICAS DO SISTEMA TESTE 1
FONTE: O AUTOR

<i>Barra</i>	<i>Data inicial</i>	<i>Data final</i>	<i>Tamanho do histórico</i>	<i>Quantidade de horas (pontos da série)</i>
1	01/01/2009	24/03/2013	4 anos e 3 meses	37.057
2	01/12/2008	24/03/2013	4 anos e 4 meses	37.801
3	01/12/2008	24/03/2013	4 anos e 4 meses	37.801
4	01/12/2008	24/03/2013	4 anos e 4 meses	37.801
5	01/05/2010	24/03/2013	2 anos e 11 meses	25.417
6	01/12/2008	24/03/2013	4 anos e 4 meses	37.801
7	01/12/2008	24/03/2013	4 anos e 4 meses	37.801
8	01/12/2008	24/03/2013	4 anos e 4 meses	37.801
9	01/08/2011	24/03/2013	1 ano e 8 meses	14.449
10	01/08/2011	24/03/2013	1 ano e 8 meses	14.449
11	01/01/2011	24/03/2013	2 anos e 3 meses	19.537
12	01/12/2008	24/03/2013	4 anos e 4 meses	37.801
13	01/05/2010	24/03/2013	2 anos e 11 meses	25.417
14	01/12/2008	24/03/2013	4 anos e 4 meses	37.801

Foram escolhidas as barras 1, 5, 7, 8 e 14, que possuem a maior quantidade de falhas, e a barra 10 que possui a menor quantidade de problemas, para ilustrar o

comportamento geral das séries históricas. Da figura 19 até a figura 24 estão ilustradas a série bruta e a série após o tratamento dos dados na parte superior e uma amostra semanal na parte inferior, referentes à última semana do mês de março de cada ano. Pode ser verificado nas figuras que algumas séries possuem um comportamento diário bem definido, o que colabora para a qualidade dos resultados de previsão.

TABELA 11 – QUANTIDADE DE PONTOS CORRIGIDOS NAS SÉRIES DO SISTEMA TESTE 2

FONTE: O AUTOR

<i>Barra</i>	<i>Número de Pontos Corrigidos</i>	<i>% de Correção da Série</i>	<i>Média</i>	<i>Desvio Padrão</i>	<i>Coefficiente de Variação de Pearson</i>
1	11864	32%	38,86	8,82	22,71%
2	8847	23%	29,12	7,25	24,89%
3	5196	14%	11,57	2,62	22,64%
4	5781	15%	22,97	4,16	18,11%
5	7066	28%	10,24	2,11	20,65%
6	5478	14%	12,43	3,67	29,56%
7	12256	32%	40,23	8,55	21,24%
8	12576	33%	34,74	7,44	21,41%
9	1920	13%	9,23	1,90	20,53%
10	1292	9%	22,77	4,97	21,83%
11	2765	14%	18,07	4,23	23,43%
12	6370	17%	24,92	6,33	25,39%
13	4263	17%	28,02	8,62	30,79%
14	11361	30%	19,12	5,05	26,42%




FIGURA 19 – SÉRIE HISTÓRICA BARRA 1 – SISTEMA TESTE 2

FUNTE: O AUTOR




FIGURA 20 – SÉRIE HISTÓRICA BARRA 5 – SISTEMA TESTE 2

FUNTE: O AUTOR




FIGURA 21 – SÉRIE HISTÓRICA BARRA 7 – SISTEMA TESTE 2

FONTE: O AUTOR

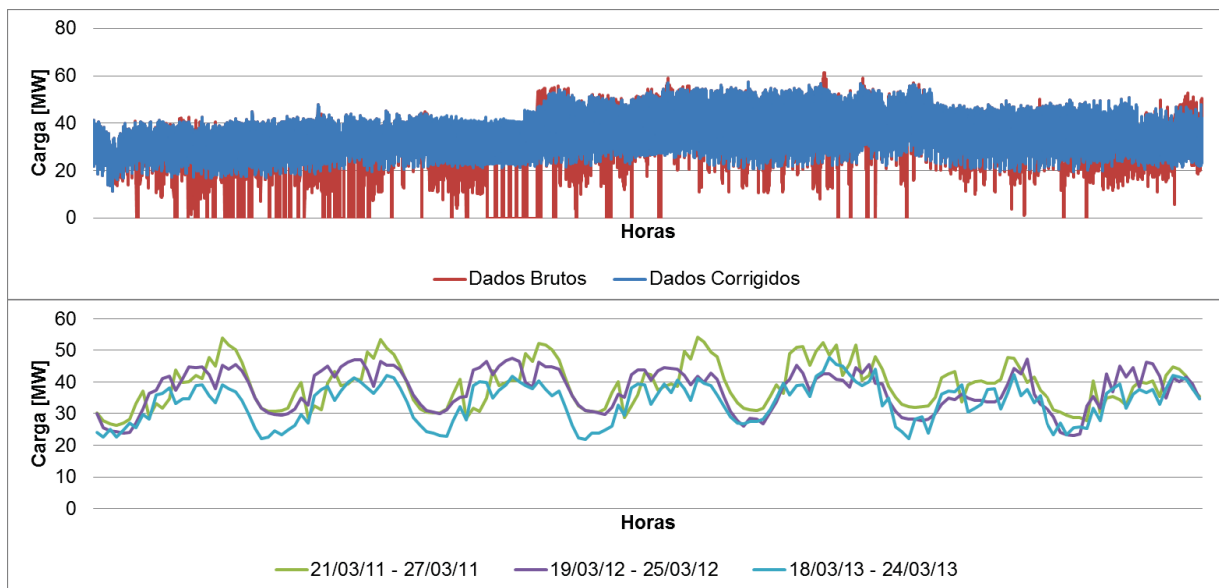


FIGURA 22 – SÉRIE HISTÓRICA BARRA 8 – SISTEMA TESTE 2

FONTE: O AUTOR

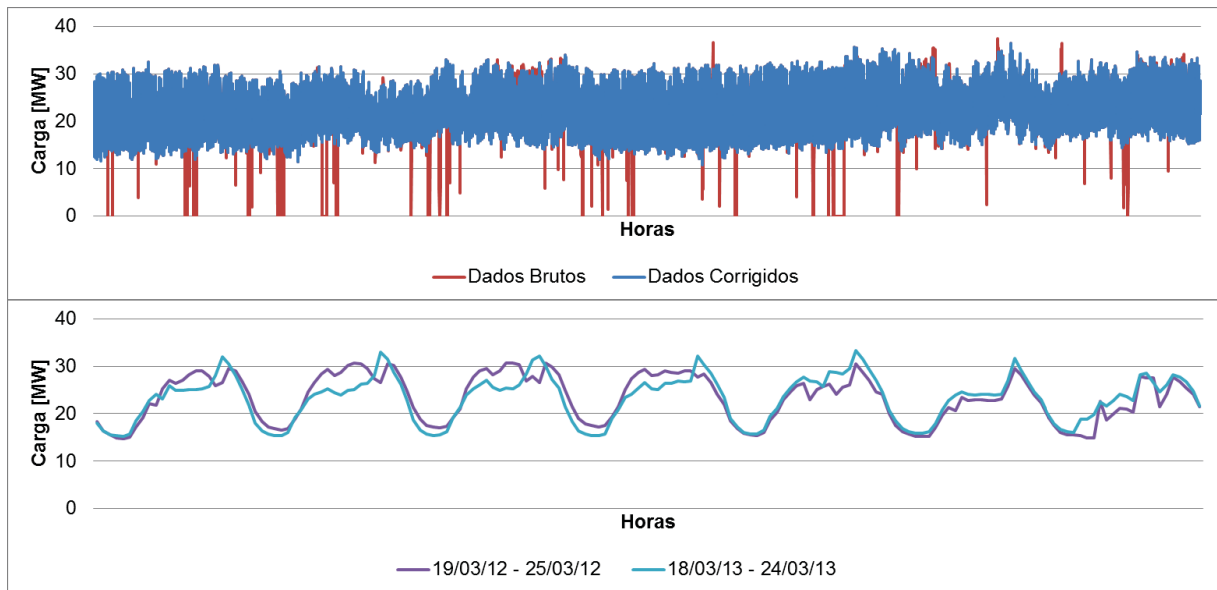


FIGURA 23 – SÉRIE HISTÓRICA BARRA 10 – SISTEMA TESTE 2

FUNTE: O AUTOR




FIGURA 24 – SÉRIE HISTÓRICA BARRA 14 – SISTEMA TESTE 2

FUNTE: O AUTOR

3.2 MÉTODO

Nesta seção é apresentado o método de previsão de carga, inspirado nos conceitos de CML, que é proposto neste trabalho. O método desenvolvido realiza a previsão individual das barras através de um método de previsão de séries temporais e, posteriormente, essas previsões são acopladas utilizando os conceitos da CML. A figura 25 apresenta um fluxograma geral do método. Inicialmente cada série histórica é submetida a uma etapa de pré-processamento e, em seguida é realizada a previsão individual por barra através de uma técnica de previsão de séries temporais e a otimização da intensidade de acoplamento. Com os resultados das previsões individuais e das intensidades de acoplamento otimizadas é realizado o acoplamento das previsões. Por fim, são calculados os índices de desempenho. Cada uma das etapas descritas no fluxograma será detalhada a seguir.

3.2.1 Pré-processamento dos dados

A etapa de pré-processamento dos dados é composta de duas partes: a primeira consiste no tratamento dos dados e a segunda na preparação da série histórica para a previsão.

Como descrito na seção anterior, as séries históricas das barras foram submetidas a um método de tratamento de dados, descrito em Nascimento *et al.* (2012). Primeiramente são encontrados todos os dados faltantes, zeros e *outliers* da série histórica utilizando o método *Z-Score* Modificado. Na sequência, esses dados são corrigidos de acordo com uma métrica que leva em consideração o tipo de dia e a hora de ocorrência do problema. Esse tratamento é realizado para cada uma das séries históricas que compõe o sistema.

A preparação da série histórica consiste em dividir o conjunto de dados em conjunto de treinamento e conjunto de validação. Essa divisão é realizada de acordo com o horizonte de previsão adotado neste trabalho, de 168 passos à frente (uma semana de dados horários). Dessa maneira, a última semana dos dados horários de cada uma das

barras é chamada de conjunto de validação e os demais dados compõem o conjunto de treinamento. A quantidade de pontos que compõem o conjunto de validação de cada uma das barras do sistema é exatamente igual, no entanto, o conjunto de treinamento varia de acordo com o tamanho da série histórica de cada barra, conforme apresentado nas tabela 8 e tabela 10.

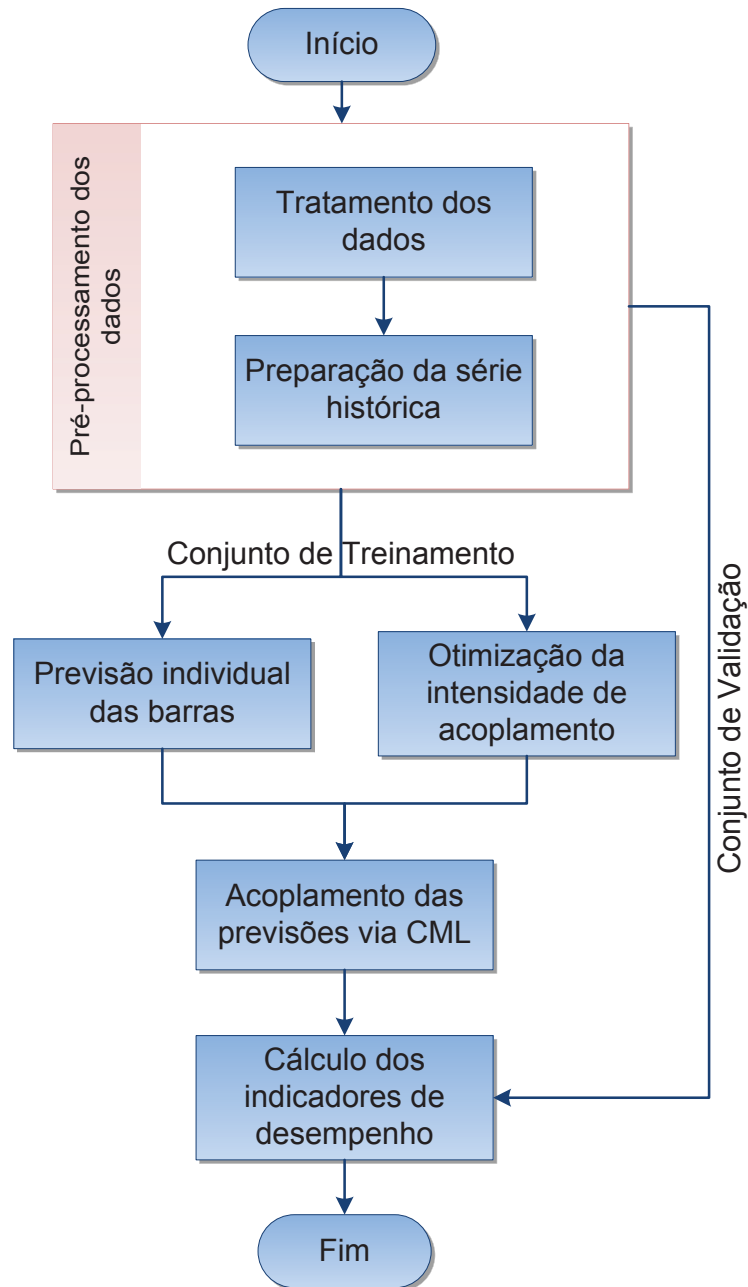


FIGURA 25 - FLUXOGRAMA GERAL DO MÉTODO HÍBRIDO INSPIRADO EM CML
 FONTE: O AUTOR

Além disso, a série pode também ser subdividida de acordo com o tipo de dia da semana. Os dias da semana foram classificados de 1 (Domingo) a 7 (Sábado). Feriados foram tratados como domingos nessa subdivisão. Dessa maneira, foram adotadas neste trabalho duas estratégias para trabalhar com a previsão das séries históricas, conforme apresentado a seguir:

1. Série inteira: nesse caso somente é realizada a separação dos conjuntos de treinamento e validação.
2. Série por tipo de dia: nesse caso é realizada uma subdivisão de acordo com o tipo de dia da semana, variando de 1 (Domingos) até 7 (Sábados). Dessa maneira, têm-se sete subconjuntos de dados, um para cada dia da semana, em cada um dos conjuntos de treinamento e validação.

Após esse pré-processamento, os dados do conjunto de treinamento são utilizados para a continuidade do processo de previsão enquanto os dados do conjunto de validação somente serão utilizados para a análise de desempenho do método proposto, não sendo utilizados em nenhum momento durante a metodologia de previsão.

3.2.2 *Previsão individual das barras*

Nesta etapa é realizada a previsão de carga para cada uma das barras individualmente através de um método de previsão de séries temporais. Foram utilizados três métodos de previsão, de forma comparativa, uma Rede Neural do tipo MLP, uma Rede Neural do tipo RBF e um Previsor *Fuzzy*.

A MLP utilizada neste trabalho foi proposta por Ferreira e da Silva (2011) e combina a teoria do caos, inferência bayesiana e minimização de limites superiores do erro de generalização para selecionar automaticamente as entradas e a complexidade do modelo de previsão.

A RBF utilizada neste trabalho é baseada no algoritmo de Billings e Zheng (1995), mas utiliza o algoritmo de Evolução Diferencial de Becerra e Coello (2006) na otimização

dos parâmetros. São realizadas variações no número de *clusters*, resultando em diferentes modelos de previsão para cada série histórica.

O previsor *Fuzzy* utilizado é baseado no modelo Takagi-Sugeno (Takagi e Sugeno, 1985). O modelo nebuloso de TS adotado neste trabalho possui funções lineares como consequentes e regras que apresentam boas características de interpolação e extrapolação dos dados de previsão com um número reduzido de regras de produção. O previsor *Fuzzy* usa Filtro de Kalman (Jang, 1993), Algoritmo Kaczmarz (Strohmer e Vershynin, 2007), método da pseudo-inversa ou descida de encosta (Jang, 1993) para otimização do mesmo para realizar previsões. Dessa forma, para cada série histórica tem-se como resultado quatro modelos de previsão.

O conjunto de entradas selecionado pelo método de Ferreira e da Silva (2011) para a MLP foi utilizado também para os outros dois métodos testados. Dessa maneira, a entrada de dados (atrasos na variável de carga e variáveis de calendário) foram os mesmos nos três métodos de previsão.

Conforme mencionado anteriormente, o conjunto de dados utilizado para a previsão individual das barras foi o conjunto de treinamento. A quantidade de modelos de previsão depende de ter sido utilizada a série completa ou a divisão por tipo de dia. A complexidade da MLP é realizada internamente no algoritmo, de acordo com os critérios definidos em Ferreira e da Silva (2011). Para a RBF e o Previsor *Fuzzy*, foram avaliados todos os resultados obtidos nas simulações e escolhido o melhor.

3.2.3 Otimização da intensidade de acoplamento

A etapa de otimização da intensidade de acoplamento ε é realizada com os dados do conjunto de treinamento. Para esta otimização foi utilizado o método de Pontos Interiores, implementado no *toolbox* de otimização do MATLAB, e a função objetivo adotada foi a de minimização do erro quadrático. O modelo de otimização é o descrito em (9):

$$\text{minimizar} \quad \sum_{b=1}^B \|x^{(b)} - \tilde{x}^{(b)}\|^2 \quad (9)$$

onde B é o número de barras consideradas, $x^{(b)} = [x_1^{(b)} \dots x_T^{(b)}]$ representa a série histórica da barra b , com T sendo o número de pontos do conjunto de treinamento e $\tilde{x}^{(b)} = [\tilde{x}_1^{(b)} \dots \tilde{x}_T^{(b)}]$ representa o resultado de previsão obtido com a utilização da função de acoplamento.

A equação (7), do acoplamento global, juntamente com a dinâmica linear, descrita em (2), foi utilizada como base para o acoplamento proposto nesse trabalho. No entanto, foram realizadas algumas modificações, de forma a melhor representar o problema. A principal modificação consiste na utilização de intensidades de acoplamento individualizadas por barra, ao invés de uma única intensidade que representa todo o sistema. Outra modificação consiste na utilização dos dados das barras vizinhas no instante $t + 1$, para determinar a carga no instante t .

Com essas considerações, foram utilizados neste trabalho quatro casos distintos, resultantes da combinação dos acoplamentos global e local com intensidade de acoplamento ε individual por barra e geral para o sistema. Cada um dos casos é detalhado a seguir.

Caso 1 - acoplamento local e ε individual: utilizando a função de acoplamento local (4) adaptada e intensidade de acoplamento individual por barra, tem-se a equação (10). Nesse caso somente as barras diretamente conectadas à barra b são consideradas no acoplamento, sendo B_v utilizado para representar essas barras.

$$\tilde{x}_{t+1}^{(b)} = (1 - \varepsilon_b)x_t^{(b)} + \frac{\varepsilon_b}{B_v - 1} \sum_{j=1}^{B_v} x_{t+1}^{(j)} \quad (10)$$

Caso 2 - acoplamento global e ε individual: utilizando a função de acoplamento global (7) e intensidade de acoplamento única para o sistema, tem-se a equação descrita em (11). Nesse caso, todas as barras do sistema são consideradas no acoplamento e uma intensidade de acoplamento é calculada para cada barra.

$$\tilde{x}_{t+1}^{(b)} = (1 - \varepsilon_b)x_t^{(b)} + \frac{\varepsilon_b}{B - 1} \sum_{\substack{j=1 \\ j \neq i}}^B x_{t+1}^{(j)} \quad (11)$$

Caso 3 - acoplamento local e ε geral: nesse caso a equação resultante é dada em (12), que considera o acoplamento local e intensidade de acoplamento única para todo o sistema.

$$\tilde{x}_{t+1}^{(b)} = (1 - \varepsilon)x_t^{(b)} + \frac{\varepsilon}{B_v - 1} \sum_{j=1}^{B_v} x_{t+1}^{(j)} \quad (12)$$

Caso 4 - acoplamento global e ε geral: esse caso é semelhante ao caso 1, considerando uma intensidade de acoplamento única para o sistema. Dessa forma, são consideradas todas as barras do sistema, resultando na equação (13).

$$\tilde{x}_{t+1}^{(b)} = (1 - \varepsilon)x_t^{(b)} + \frac{\varepsilon}{B - 1} \sum_{\substack{j=1 \\ j \neq i}}^B x_{t+1}^{(j)} \quad (13)$$

Para cada um dos casos descritos é realizada a otimização da intensidade de acoplamento. Os resultados dessa fase serão utilizados na etapa posterior, denominada de acoplamento das previsões.

3.2.4 Acoplamento das previsões

Com as intensidades de acoplamento otimizadas, para cada um dos casos descritos anteriormente, e o resultado da previsão individual das barras obtido pelos métodos é realizada a etapa de acoplamento das previsões. Para esta etapa são utilizados os mesmos quatro casos descritos nas equações (10), (11), (12) e (13). No entanto, como não se conhece a carga para os instantes futuros, os valores representados por x_t no lado direito dessas equações são substituídos pelos resultados das previsões individuais das barras.

Esta etapa consiste na utilização das informações de previsão das barras vizinhas, ou todas as barras do sistema, no ajuste da previsão de uma determinada barra. De acordo com a intensidade de acoplamento da barra com suas vizinhas, o comportamento da carga nessa vizinhança pode influenciar o comportamento da barra em estudo. Dessa forma, os resultados obtidos ao final desse processo são denominados de previsão acoplada, que é o resultado da metodologia de previsão proposta neste trabalho.

3.2.5 Cálculo dos indicadores de desempenho

A última etapa do método é o cálculo dos indicadores de desempenho, com o objetivo de avaliar os resultados de previsão obtidos por cada um dos métodos utilizados e pelo método de previsão proposto. Neste trabalho foi adotado o Erro Percentual Médio Absoluto (MAPE), representado em porcentagem, conforme (14).

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{real - previsto}{real} \right| \quad (14)$$

onde N é o número de dados previstos. Nessa fase, são utilizados os resultados de previsão obtidos tanto para os métodos individuais quanto para o método proposto, para os dados do conjunto de validação.

3.3 CONSIDERAÇÕES FINAIS DO CAPÍTULO

Neste capítulo são apresentados os casos teste utilizados neste trabalho. Foram utilizados dois casos teste, um com 11 barras e outro com 14 barras. Estes casos foram escolhidos por representarem conjuntos reais de dados encontrados no sistema elétrico do Paraná. Com a utilização de sistemas teste reais, tem-se representada a conexão entre as barras tanto fisicamente, como nos dados obtidos.

Foram utilizadas séries de potência ativa (MW) integralizadas na hora para cada uma das barras que compõe os dois sistemas. Cada barra possui um período histórico

distinto, de acordo com a disponibilidade dos dados. Além disso, como os dados são resultantes de sistemas reais de medição, uma grande dificuldade consiste na qualidade dos mesmos. Problemas como dados faltantes, zeros, valores negativos e *outliers* são facilmente encontrados. Dessa forma, antes da utilização dos métodos de previsão, foi realizada uma etapa de tratamento dos dados.

Na metodologia proposta são realizadas previsões individuais para as barras, que posteriormente são acopladas de acordo com regras inspiradas nos conceitos das CML. Para as previsões individuais das barras foram utilizados três métodos distintos de Inteligência Computacional, devido às características das séries e horizonte de previsão. Os métodos utilizados são duas Redes Neurais, uma do tipo MLP e outra do tipo RBF, e um previsor *Fuzzy*.

As características do sistema e os resultados individuais das previsões das barras são então utilizados para realizar o acoplamento das previsões, que consiste em ajustar a previsão da barra em estudo de acordo com os resultados de previsão obtidos para as demais barras do sistema, direta ou indiretamente conectadas. Com isso, têm-se previsões denominadas de previsões acopladas.

Para analisar e comparar todos os testes realizados é utilizado o MAPE. O próximo capítulo apresenta os testes realizados, além de uma análise dos resultados obtidos.

4 RESULTADOS

Neste capítulo são apresentados os resultados obtidos no desenvolvimento deste trabalho. Inicialmente, são apresentados os parâmetros gerais utilizados nas previsões individuais das barras e na sequência são apresentados os resultados para cada um dos sistemas teste. Para cada sistema, são apresentados os resultados obtidos para os métodos individuais de previsão e os resultados após a utilização da estratégia de acoplamento.

4.1 PARÂMETROS GERAIS

Na aplicação dos métodos de previsão individualmente para cada conjunto de barras foram realizadas duas formas de consideração da série histórica: a primeira considerando toda a série histórica e a outra separando a série por tipo de dia da semana. Para cada um desses testes foram aplicados os métodos de previsão MLP, RBF e *Fuzzy*, individualmente para todas as barras dos dois sistemas teste considerados.

Conforme apresentado no capítulo anterior, foi utilizado o método proposto por Ferreira e da Silva (2011) para selecionar os atrasos na série histórica de cada barra. Como variáveis exógenas, foram utilizados o tipo do mês (considerando 1 para janeiro até 12 para dezembro), a hora do dia (de 1 até 24) e o tipo de dia da semana (1 para domingo até 7 para sábado) no caso da série total e o tipo do mês e a hora do dia para os modelos em que as séries históricas foram separadas de acordo com o tipo de dia semana. Além de selecionar as entradas, a MLP desenvolvida por Ferreira e da Silva (2011) também escolhe automaticamente o número de neurônios na camada escondida, sendo que o número máximo estabelecido para este trabalho foi de 20.

Para a RBF, foram testadas dez configurações para o número de clusters, iniciando com o número de entradas mais um e terminando com o número de entradas mais onze. Os centros e as aberturas da rede foram otimizados pelo algoritmo de

Evolução Diferencial de Becerra e Coello (2006), sendo que a função objetivo considerada é dada pelo MAPE da fase de treinamento mais o quadrado da média dos pesos da camada de saída.

No caso do previsor *Fuzzy* foram utilizados quatro algoritmos para otimização dos parâmetros, resultando em quatro modelos de previsão para cada barra. Por simplificação, foi adotada a seguinte notação para representar os algoritmos:

1. para o Filtro de Kalman
2. para o Algoritmo Kaczmarz
3. para o método da pseudo-inversa
4. para a descida de encosta

Tanto para a previsão da RBF quanto para o previsor *Fuzzy*, foram analisados todos os resultados (dez resultados para a RBF e quatro para o *Fuzzy*) para cada uma das barras e escolhido para continuação da metodologia somente o resultado que apresentou o menor MAPE.

Após a previsão individual é realizado o acoplamento dos resultados de previsão. Para o acoplamento foram utilizadas duas equações de acoplamento distintas (acoplamento local e global) e duas formas de considerar a intensidade de acoplamento ε (única para o sistema ou individual por barra). Combinando essas possibilidades, foram geradas quatro estratégias distintas de acoplamento:

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

Considerando essas quatro estratégias, é realizada a otimização das intensidades de acoplamento. Para esta otimização foi utilizado o método de Pontos Interiores, implementado no *toolbox* de otimização do MATLAB, e a função objetivo adotada foi a de minimização do erro quadrático, descrita na equação (9).

No acoplamento, foi adotada uma subdivisão da série histórica por tipo de dia e por hora do dia. Com essa divisão, considera-se nas equações de acoplamento que a carga em um instante t de uma barra é influenciada pelas cargas das barras vizinhas no instante t e pela carga da própria barra no instante $t - 1$, sendo esse instante o último da mesma hora e mesmo tipo de dia considerado.

Com o resultado das previsões individuais das barras e da otimização das intensidades de acoplamento é realizado o acoplamento das previsões, para os quatro casos descritos. Nas próximas seções são apresentados os resultados obtidos para cada um dos sistemas teste utilizados.

4.2 RESULTADOS PARA O SISTEMA TESTE 1

Na realização da previsão individual das barras foram utilizadas os mesmos conjuntos de entradas para todos os métodos de previsão. Na tabela 12 são apresentados os atrasos na carga utilizados no sistema teste 1 para a previsão de cada uma das barras considerando a série sem subdivisão (série inteira). Nesta tabela, os números apresentados na coluna de atrasos representam os períodos anteriores considerados na estrutura do modelo para a variável de carga. As variáveis exógenas consideradas foram o tipo do mês, tipo do dia e hora do dia, sem atrasos.

Os atrasos obtidos para os modelos de previsão quando considerada a subdivisão por tipo de dia estão apresentados no Apêndice I deste trabalho. Cada uma das barras dos dois sistemas teste possuem sete modelos, um para cada tipo de dia da semana. No caso da subdivisão das séries históricas por tipo de dia, as variáveis exógenas consideradas foram o tipo do mês e a hora do dia.

A tabela 13 apresenta os modelos finais dos três métodos de previsão utilizados, para cada uma das barras do sistema teste 1. Para a MLP estão descritos o número de neurônios na camada escondida do modelo final de cada barra, para a RBF são apresentados o número de *clusters* utilizados e para o previsor *Fuzzy* é apresentado o algoritmo de otimização escolhido para cada barra.

TABELA 12 – ATRASOS NAS ENTRADAS DE CARGA PARA SÉRIE INTEIRA – SISTEMA TESTE 1
 FONTE: O AUTOR

<i>Barra</i>	<i>Atrasos na carga</i>
1	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67, 73, 79, 85, 91, 97
2	1, 13, 25, 37, 49, 61, 73, 85, 97, 109, 121, 133, 145, 157, 169, 181, 193, 205, 217, 229, 241, 253
3	1, 12, 23, 34, 45, 56, 67, 78, 89, 100, 111, 122, 133, 144, 155, 166, 177, 188, 199, 210
4	1, 14
5	1, 13, 25
6	1, 9, 17
7	1, 13, 25, 37, 49, 61, 73, 85, 97, 109, 121, 133, 145, 157, 169, 181
8	1, 13, 25, 37, 49, 61, 73
9	1, 9, 17, 25, 33, 41, 49, 57, 65, 73, 81, 89, 97, 105
10	1, 12, 23, 34, 45, 56, 67, 78, 89, 100, 111, 122, 133, 144, 155, 166, 177
11	1, 14, 27, 40, 53, 66, 79, 92, 105, 118, 131, 144, 157, 170, 183, 196

TABELA 13 – MODELOS FINAIS DOS MÉTODOS DE PREVISÃO PARA A SÉRIE INTEIRA – SISTEMA TESTE 1

FONTE: O AUTOR

<i>Barra</i>	1	2	3	4	5	6	7	8	9	10	11
<i>Nº neurônios na camada escondida MLP</i>	16	14	19	19	19	20	15	20	19	16	15
<i>Nº de clusters da RBF</i>	25	28	27	10	19	18	32	22	30	23	31
<i>Método de otimização parâmetros Fuzzy</i>	3	3	3	2	3	2	3	2	3	2	2

Os modelos finais para o caso em que a série é dividida por tipo de dia estão apresentados na tabela 14. Para o caso da MLP e da RBF foram obtidos sete modelos, um para cada tipo de dia da semana, para cada uma das barras do sistema. Para o

previsor *Fuzzy* adotou-se o mesmo modelo para todos os dias da semana, resultando em modelos onze modelos distintos, um para cada barra. Para essa configuração, somente o Filtro de Kalman não foi utilizado em nenhum dos modelos do previsor *Fuzzy*.

TABELA 14 – MODELOS FINAIS DOS MÉTODOS DE PREVISÃO PARA A SÉRIE POR TIPO DE DIA – SISTEMA TESTE 1

FONTE: O AUTOR

	<i>Barra</i>	1	2	3	4	5	6	7	8	9	10	11
<i>Nº neurônios na camada escondida MLP</i>	<i>Domingo</i>	12	11	12	18	10	13	19	20	14	3	6
	<i>Segunda</i>	6	14	16	15	10	14	16	7	12	2	9
	<i>Terça</i>	6	14	17	13	12	14	14	11	15	6	12
	<i>Quarta</i>	3	9	13	11	6	12	13	9	10	9	10
	<i>Quinta</i>	4	11	13	14	11	10	15	8	11	3	12
	<i>Sexta</i>	5	16	18	11	16	14	11	18	10	7	7
	<i>Sábado</i>	3	10	16	17	7	14	11	15	18	9	6
	<i>Domingo</i>	12	11	12	18	10	13	19	20	14	3	6
<i>Nº de clusters da RBF</i>	<i>Domingo</i>	23	19	30	28	23	26	20	14	17	15	18
	<i>Segunda</i>	17	18	25	12	20	27	17	5	19	15	20
	<i>Terça</i>	18	24	27	12	23	27	16	25	21	16	23
	<i>Quarta</i>	16	19	27	13	22	24	18	19	19	14	21
	<i>Quinta</i>	17	18	27	21	24	26	19	15	17	17	20
	<i>Sexta</i>	18	17	28	12	23	17	16	14	16	17	22
	<i>Sábado</i>	20	21	21	24	23	27	17	20	18	14	20
<i>Método de otimização parâmetros Fuzzy</i>	2	2	3	4	2	3	3	4	2	4	3	

A tabela 15 apresenta os resultados das previsões individuais para os três métodos, MLP, RBF e *Fuzzy*, com as duas considerações quanto ao histórico. Os melhores resultados para cada uma das barras estão destacados em negrito. Na média,

o método que apresentou melhores resultados foi a RBF sem divisão na série histórica, que obteve os melhores resultados de previsão para as barras 4, 5, 6 e 8. No entanto, a MLP por tipo de dia foi a que obteve os menores erros para o maior número de barras (barras 2, 7, 9, 10 e 11).

TABELA 15 – RESULTADOS DAS PREVISÕES INDIVIDUAIS – SISTEMA TESTE 1

FONTE: O AUTOR

Barra	Série Inteira			Série por Tipo de Dia		
	MLP	RBF	Fuzzy	MLP	RBF	Fuzzy
1	12,16%	9,80%	8,05%	8,44%	9,72%	9,32%
2	10,84%	8,07%	10,14%	6,99%	7,80%	9,91%
3	8,87%	10,00%	9,89%	22,09%	11,44%	10,41%
4	22,04%	19,51%	19,55%	25,61%	24,48%	24,60%
5	21,58%	7,27%	9,53%	9,61%	8,00%	8,32%
6	44,00%	12,87%	17,33%	16,89%	16,70%	17,02%
7	10,51%	11,55%	12,05%	6,48%	9,48%	8,66%
8	31,54%	26,11%	26,84%	27,97%	29,91%	30,10%
9	11,76%	8,71%	8,94%	5,94%	7,38%	6,34%
10	11,98%	11,02%	13,17%	10,25%	11,30%	12,14%
11	10,56%	11,17%	9,45%	8,31%	8,62%	8,44%
Média	17,80%	12,37%	13,18%	13,51%	13,17%	13,21%

Na média, os erros de previsão das barras ficaram em torno de 10%, com exceção das barras 4, 6 e 8, cujos erros foram maiores. A barra 8 foi a barra que apresentou os piores resultados, com MAPEs em torno de 30%. Já a barra 6 foi a que obteve o maior MAPE entre todos, de 44% para a MLP da série inteira.

De forma geral, os resultados médios obtidos por todos os métodos, com ou sem divisão das séries históricas, foram semelhantes, ficando em torno de 13% na média de

todas as barras. Somente o método MLP com a série inteira apresentou desempenho inferior, com média de MAPES de 17,8%. No geral, o desempenho deste método para as barras foi semelhante aos demais, mas o grande erro na previsão da barra 6 prejudicou a média.

Os resultados da otimização da intensidade de acoplamento para o sistema teste 1 estão dispostos na tabela 16. Nos casos 3 e 4, foram obtidas 168 intensidades de acoplamento, uma para cada hora e tipo de dia. Para os casos 1 e 2 são obtidas 168 intensidades de acoplamento para cada barra no sistema. Por simplificação, a tabela 16 mostra a média das intensidades de acoplamento para cada caso analisado.

TABELA 16 – INTENSIDADE DE ACOPLAMENTO OTIMIZADA MÉDIA - SISTEMA TESTE 1
 FONTE: O AUTOR

<i>Barra</i>	<i>Caso 1</i>	<i>Caso 2</i>	<i>Caso 3</i>	<i>Caso 4</i>
1	0,2955	0,3203		
2	0,3604	0,1726		
3	0,2519	0,2976		
4	0,0257	0,0193		
5	0,1619	0,0992		
6	0,1064	0,0590	0,2554	0,1944
7	0,3065	0,2292		
8	0,0824	0,0680		
9	0,2069	0,1798		
10	0,3330	0,2818		
11	0,2105	0,2092		

Com os resultados da otimização obtidos, é realizado acoplamento das previsões. Para cada uma das barras foram aplicados os quatro casos de acoplamento a todos os resultados obtidos na previsão individual, totalizando 24 resultados de previsão acoplados para cada uma das barras do sistema.

A tabela 17 apresenta os resultados do acoplamento das previsões para os resultados obtidos com a previsão do método MLP, para as duas formas de tratamento da série histórica. O caso que apresentou melhor resultado está destacado na tabela. É possível observar que cinco barras (1, 4, 5, 6 e 8) obtiveram os melhores resultados com o mesmo caso de acoplamento para as duas formas de consideração da série.

TABELA 17 – MAPES ACOPLAMENTO DAS PREVISÕES - MÉTODO MLP – SISTEMA TESTE 1

FONTE: O AUTOR

Barra	Série Inteira				Série por Tipo de Dia			
	Caso 1	Caso 2	Caso 3	Caso 4	Caso 1	Caso 2	Caso 3	Caso 4
1	11,56%	11,56%	10,55%	10,44%	11,33%	9,49%	10,48%	9,17%
2	8,50%	11,62%	8,68%	9,14%	8,33%	8,01%	8,32%	7,21%
3	16,13%	13,81%	13,97%	12,70%	17,47%	16,35%	15,19%	15,88%
4	21,21%	21,32%	21,49%	21,32%	25,82%	23,09%	23,85%	23,32%
5	6,92%	11,04%	6,69%	9,06%	6,42%	8,62%	6,26%	7,25%
6	16,22%	16,32%	15,55%	16,58%	16,23%	17,07%	14,96%	19,16%
7	9,20%	9,12%	9,89%	8,90%	8,65%	9,25%	10,38%	11,25%
8	25,34%	25,53%	24,98%	25,17%	24,94%	26,36%	24,07%	28,52%
9	6,97%	8,05%	4,97%	6,16%	6,01%	6,16%	5,40%	5,18%
10	11,00%	11,90%	10,45%	9,63%	11,68%	10,14%	10,95%	11,08%
11	8,20%	7,71%	7,62%	7,94%	7,28%	6,88%	7,28%	6,90%
Média	13,81%	14,41%	13,01%	13,15%	13,55%	13,72%	12,86%	13,48%

Comparando os melhores casos das previsões acopladas para cada uma das barras (tabela 17) com os resultados das previsões sem acoplamento (tabela 15) para o método MLP, é possível verificar que no caso da utilização da série inteira para a previsão, somente o acoplamento para a barra 3 não apresentou melhores resultados que a previsão sem acoplamento. No caso da série separada por tipo de dia, a previsão individual foi melhor que a previsão acoplada para as barras 1, 2 e 7.

A tabela 18 mostra os resultados do acoplamento para o método de previsão RBF. Para este método, somente as barras 4, 6 e 11 não apresentaram o melhor resultado no mesmo tipo de caso para as duas considerações da série histórica. Ainda, é possível observar na tabela que os resultados das barras 8 e 9 não foram satisfatórios em todos os casos de acoplamento.

TABELA 18 – MAPES ACOPLAMENTO DAS PREVISÕES - MÉTODO RBF – SISTEMA TESTE 1

FONTE: O AUTOR

Barra	Série Inteira				Série por Tipo de Dia			
	Caso 1	Caso 2	Caso 3	Caso 4	Caso 1	Caso 2	Caso 3	Caso 4
1	10,80%	13,74%	24,08%	24,16%	10,47%	12,51%	15,80%	21,75%
2	7,57%	11,03%	6,81%	7,91%	8,95%	12,50%	8,86%	8,89%
3	14,38%	11,54%	7,37%	7,37%	16,69%	12,34%	8,07%	7,88%
4	20,21%	18,36%	18,73%	18,46%	24,67%	23,61%	23,39%	23,67%
5	14,77%	6,73%	21,18%	6,06%	13,70%	7,55%	18,88%	6,72%
6	16,94%	15,53%	17,74%	15,43%	15,96%	15,46%	14,03%	14,23%
7	26,21%	7,96%	25,30%	9,28%	20,54%	8,10%	20,18%	8,20%
8	37,96%	107,82%	205,62%	235,85%	39,78%	108,86%	150,84%	228,90%
9	139,04%	81,76%	52,65%	34,16%	132,69%	74,11%	49,14%	30,49%
10	14,30%	23,09%	19,94%	16,52%	12,96%	20,02%	16,71%	15,01%
11	9,14%	10,56%	8,56%	8,22%	9,23%	9,18%	9,31%	9,87%
Média	28,30%	28,01%	37,09%	34,86%	27,78%	27,66%	30,47%	34,15%

Na comparação entre os resultados da previsão individual (tabela 15) e da acoplada (tabela 18) para o método RBF, as barras 3, 4, 5 e 7 apresentaram ganhos com o acoplamento independentemente da consideração da série histórica. Já o acoplamento das barras 2 e 11 foi melhor somente para a previsão da série inteira, e para a barra 6 no caso da subdivisão por tipo de dia.

Na tabela 19 estão apresentados os resultados do acoplamento para o previsor *Fuzzy*. Neste método, somente a barra 6 obteve melhor desempenho em casos de acoplamento distintos. Novamente, os resultados para as barras 8 e 9 foram insatisfatórios para os quatro casos de acoplamento, com valores bastante elevados.

TABELA 19 – MAPES ACOPLAMENTO DAS PREVISÕES - PREVISOR *FUZZY* – SISTEMA TESTE 1
 FONTE: O AUTOR

Barra	Série Inteira				Série por Tipo de Dia			
	Caso 1	Caso 2	Caso 3	Caso 4	Caso 1	Caso 2	Caso 3	Caso 4
1	11,03%	11,31%	15,32%	20,17%	10,23%	11,82%	15,59%	21,84%
2	7,67%	11,65%	7,38%	8,12%	8,62%	12,45%	8,25%	8,88%
3	15,63%	11,73%	7,47%	7,40%	16,69%	12,14%	7,95%	7,85%
4	20,14%	19,50%	19,30%	19,52%	25,03%	23,88%	23,75%	23,95%
5	13,89%	6,96%	19,87%	6,00%	13,47%	7,36%	17,89%	6,69%
6	16,06%	15,61%	16,11%	15,17%	15,89%	15,62%	14,18%	14,47%
7	22,27%	7,93%	21,81%	8,61%	20,03%	8,05%	19,81%	8,24%
8	39,35%	112,00%	169,50%	236,75%	41,40%	110,44%	154,80%	230,78%
9	136,26%	79,91%	52,57%	34,28%	127,75%	73,64%	46,40%	28,92%
10	16,28%	24,69%	21,13%	18,88%	13,89%	20,66%	17,26%	15,89%
11	9,52%	10,98%	8,63%	8,85%	12,26%	11,47%	10,04%	12,44%
Média	28,01%	28,39%	32,64%	34,89%	27,75%	27,96%	30,54%	34,54%

A comparação entre os resultados com a aplicação (tabela 19) e sem a aplicação (tabela 15) do acoplamento para o previsor *Fuzzy* mostra que as barras 2, 3, 4, 5, 6 e 7 obtiveram ganhos com o acoplamento para as duas formas de considerar a série histórica. A barra 11 apresentou melhora com o acoplamento somente para a previsão considerando a série inteira.

A tabela 20 apresenta uma comparação entre os erros médios obtidos para cada um dos casos do acoplamento com os resultados das previsões sem acoplamento. A coluna denominada *mix* apresenta o resultado do acoplamento considerando as melhores formas de acoplamento para cada uma das barras, para estratégias distintas entre elas.

TABELA 20 – COMPARAÇÃO DAS MÉDIAS DOS MAPES – SISTEMA TESTE 1

FONTE: O AUTOR

	<i>Caso 1</i>	<i>Caso 2</i>	<i>Caso 3</i>	<i>Caso 4</i>	<i>Mix</i>	<i>Sem acoplamento</i>
<i>MLP Série Inteira</i>	13,81%	14,41%	13,01%	13,15%	11,93%	17,80%
<i>MLP Tipo de Dia</i>	13,55%	13,72%	12,86%	13,48%	11,89%	13,51%
<i>RBF Série Inteira</i>	28,30%	28,01%	37,09%	34,86%	15,22%	12,37%
<i>RBF Tipo de Dia</i>	27,78%	27,66%	30,47%	34,15%	15,62%	13,17%
<i>Fuzzy Série Inteira</i>	28,01%	28,39%	32,64%	34,89%	15,70%	13,18%
<i>Fuzzy Tipo de Dia</i>	27,75%	27,96%	30,54%	34,54%	15,75%	13,21%

Na média, os resultados da previsão individual para a série inteira do método MLP não foram satisfatórios, e a utilização do acoplamento apresentou ganhos significativos, baixando o erro médio do sistema de 17,80% para cerca de 14%. Essa diferença foi influenciada principalmente pelas barras 5, 6, 8 e 9, que apresentaram grandes reduções no MAPE. Independentemente da estratégia de acoplamento adotada a previsão para a MLP da série inteira tem seu desempenho melhorado com o acoplamento.

Para a previsão da RBF, o erro médio do sistema para as duas considerações da série histórica foi melhor para as previsões sem acoplamento. Apesar da distribuição entre os melhores MAPES para cada barra ficar praticamente dividida entre a previsão com ou sem acoplamento, o aumento significativo no erro das previsões das barras 8 e 9 prejudicou o erro médio do sistema, considerando o acoplamento. Se as barras 8 e 9

não forem consideradas, as médias de erros sem o acoplamento para a série inteira e para a série por tipo de dia são de 11,25% e 11,95%, respectivamente. Com o acoplamento, as médias de erro, considerando o mix, passam para 10,59% e 11,29%, respectivamente.

Semelhante aos resultados apresentados para o método RBF, o erro médio foi bastante prejudicado pelo mau desempenho do acoplamento, principalmente para as barras 8 e 9. Para essas barras, a estratégia de acoplamento não foi satisfatória e os resultados da previsão acoplada foram bem inferiores aos obtidos com a previsão direta dos métodos de previsão. Se essas barras não forem consideradas no cálculo do erro médio do sistema, para o mix, os erros médios das previsões considerando a série inteira e por tipo de dia, sem acoplamento, caem para 12,13% e 12,09, respectivamente. Com o acoplamento, os erros passariam a ser de 11,01% e 11,44%, para as mesmas considerações.

Comparando o desempenho do acoplamento para os três métodos de previsão, é possível verificar que o comportamento do acoplamento para os métodos RBF e *Fuzzy* foi semelhante, enquanto que para a MLP o acoplamento apresentou resultados melhores. Um resumo dos melhores desempenhos obtidos para cada situação é apresentado na tabela 21. As células vazias indicam que o erro foi prejudicado após o acoplamento das previsões, ou seja, os resultados da previsão obtida pelos métodos diretamente são melhores que os obtidos pela previsão com o acoplamento. De maneira geral, a utilização do acoplamento nas previsões foi satisfatória, pois foram obtidos ganhos para um maior número de casos com o acoplamento do que sem.

TABELA 21 – RESUMO DOS MELHORES CASOS DE PREVISÃO ACOPLADA – SISTEMA TESTE 1
 FONTE: O AUTOR

<i>Barra</i>	<i>MLP</i>		<i>RBF</i>		<i>Fuzzy</i>	
	<i>Série Inteira</i>	<i>Série por Tipo de Dia</i>	<i>Série Inteira</i>	<i>Série por Tipo de Dia</i>	<i>Série Inteira</i>	<i>Série por Tipo de Dia</i>
1	Caso 4					
2	Caso 1		Caso 3		Caso 3	Caso 3
3		Caso 3	Caso 4	Caso 4	Caso 4	Caso 4
4	Caso 1	Caso 2	Caso 2	Caso 2	Caso 3	Caso 3
5	Caso 3	Caso 3	Caso 4	Caso 4	Caso 4	Caso 4
6	Caso 3	Caso 3		Caso 3	Caso 4	Caso 3
7	Caso 4		Caso 2	Caso 2	Caso 2	Caso 2
8	Caso 3	Caso 3				
9	Caso 3	Caso 4				
10	Caso 4	Caso 2				
11	Caso 3	Caso 2	Caso 4		Caso 3	

4.3 RESULTADOS PARA O SISTEMA TESTE 2

No sistema teste 2 foi utilizada a mesma abordagem para escolha das variáveis de entrada que para o sistema 1, com as variáveis de tipo de mês, tipo de dia e hora do dia consideradas como variáveis exógenas e a escolha dos atrasos na carga realizada de forma automática. A tabela 22 apresenta os atrasos utilizados na variável de carga para cada uma das barras do sistema 2, quando a série histórica é utilizada inteira para a previsão. Os atrasos para o caso da divisão da série histórica por tipo de dia são apresentados no Apêndice II.

TABELA 22 – ATRASOS NAS ENTRADAS DE CARGA PARA SÉRIE INTEIRA – SISTEMA TESTE 2
 FONTE: O AUTOR

<i>Barra</i>	<i>Atrasos na carga</i>
1	1
2	1
3	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67, 73, 79, 85
4	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67, 73, 79, 85
5	1
6	1
7	1, 9
8	1, 9, 17, 25, 33, 41, 49, 57, 65, 73, 81, 89, 97, 105, 113, 121, 129, 137, 145
9	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67, 73, 79, 85
10	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67, 73, 79
11	1, 10, 19, 28, 37, 46, 55, 64, 73, 82, 91, 100, 109, 118
12	1, 8, 15, 22, 29, 36, 43, 50, 57, 64, 71, 78, 85, 92
13	1, 8, 15, 22, 29, 36, 43, 50, 57, 64, 71, 78, 85
14	1, 8, 15, 22, 29, 36, 43, 50, 57, 64, 71, 78, 85, 92, 99, 106, 113

A tabela 23 apresenta o número de neurônios na camada escondida da MLP, o número de *cluster* da RBF e o método de otimização dos parâmetros do previsor *Fuzzy* para as barras do sistema teste 2 quando considerada a série inteira. Os modelos finais para o caso em que a série é dividida por tipo de dia estão apresentados na tabela 24. Para o caso da MLP e da RBF foram obtidos sete modelos, um para cada tipo de dia da semana, para cada uma das barras do sistema. Para o previsor *Fuzzy* adotou-se o mesmo modelo para todos os dias da semana, resultando em quatorze modelos distintos, um para cada barra.

TABELA 23 – MODELOS FINAIS DOS MÉTODOS DE PREVISÃO PARA A SÉRIE INTEIRA – SISTEMA TESTE 2

FONTE: O AUTOR

<i>Barra</i>	1	2	3	4	5	6	7	8	9	10	11	12	13	14
<i>Nº neurônios na camada escondida MLP</i>	19	15	19	20	20	17	20	19	20	17	17	20	19	18
<i>Nº de clusters da RBF</i>	14	5	28	26	12	7	9	27	23	20	18	24	25	22
<i>Método de otimização parâmetros Fuzzy</i>	3	1	2	3	3	2	3	2	3	2	3	3	2	4

TABELA 24 – MODELOS FINAIS DOS MÉTODOS DE PREVISÃO PARA A SÉRIE POR TIPO DE DIA – SISTEMA TESTE 2

FONTE: O AUTOR

	<i>Barra</i>	1	2	3	4	5	6	7	8	9	10	11	12	13	14
<i>Nº neurônios na camada escondida MLP</i>	<i>Domingo</i>	11	9	8	8	8	8	9	8	1	3	5	9	5	5
	<i>Segunda</i>	12	7	5	7	10	11	11	10	5	5	5	5	8	10
	<i>Terça</i>	8	5	12	6	6	10	7	10	4	5	8	13	9	6
	<i>Quarta</i>	6	5	7	5	8	9	11	18	4	4	5	7	6	9
	<i>Quinta</i>	12	6	5	5	8	13	11	10	7	6	6	6	11	10
	<i>Sexta</i>	15	11	7	7	10	9	14	11	3	7	4	11	7	11
	<i>Sábado</i>	17	5	9	5	8	12	15	10	5	9	4	20	8	12
<i>Nº de clusters da RBF</i>	<i>Domingo</i>	6	21	20	21	8	23	17	20	19	23	27	28	25	21
	<i>Segunda</i>	9	24	22	22	12	18	27	19	19	22	27	26	24	18
	<i>Terça</i>	6	26	21	21	16	25	29	21	15	28	26	24	23	19
	<i>Quarta</i>	5	27	22	21	10	24	27	23	16	25	27	26	25	18
	<i>Quinta</i>	9	26	21	21	13	18	27	22	15	24	25	26	23	18
	<i>Sexta</i>	13	27	22	23	15	28	26	20	19	22	23	24	23	8
	<i>Sábado</i>	16	26	21	27	17	24	26	17	18	29	28	26	25	18
<i>Método de otimização parâmetros Fuzzy</i>	2	2	2	2	2	3	2	2	4	2	2	2	2	2	

A tabela 25 mostra os resultados das previsões para o sistema teste 2 para os três métodos utilizados. Para esse sistema, o desempenho dos métodos foi semelhante e a média dos MAPES ficou em torno de 8%. A RBF apresentou desempenho inferior para as duas considerações da série histórica (com ou sem divisão da série), sendo que para a série inteira foi o método que apresentou a maior média de MAPES.

TABELA 25 – RESULTADOS DAS PREVISÕES INDIVIDUAIS – SISTEMA TESTE 2

FONTE: O AUTOR

<i>Barra</i>	<i>Série Inteira</i>			<i>Série por Tipo de Dia</i>		
	<i>MLP</i>	<i>RBF</i>	<i>Fuzzy</i>	<i>MLP</i>	<i>RBF</i>	<i>Fuzzy</i>
1	7,00%	9,80%	8,89%	6,82%	8,81%	8,40%
2	16,34%	15,14%	13,46%	6,78%	11,74%	7,63%
3	5,56%	9,31%	7,20%	8,76%	8,84%	7,34%
4	4,20%	8,27%	5,45%	6,32%	7,46%	5,15%
5	7,24%	7,16%	6,42%	7,26%	6,85%	6,62%
6	10,93%	13,48%	15,11%	7,78%	8,71%	7,74%
7	13,41%	20,69%	9,75%	9,91%	10,28%	8,66%
8	7,64%	18,00%	10,28%	6,52%	9,18%	8,04%
9	6,72%	12,15%	10,39%	7,28%	9,83%	8,86%
10	7,08%	10,95%	5,21%	7,83%	8,73%	6,24%
11	6,27%	14,16%	7,15%	7,30%	10,03%	8,06%
12	3,79%	8,08%	5,45%	6,82%	8,81%	8,40%
13	6,19%	11,06%	5,87%	6,78%	11,74%	7,63%
14	8,67%	10,67%	10,55%	8,76%	8,84%	7,34%
Média	7,93%	12,07%	8,66%	7,86%	9,21%	7,78%

O método com o melhor desempenho médio foi o previsor *Fuzzy* por tipo de dia, no entanto, esse método só apresentou os melhores resultados individuais para as barras 6 e 7. Os erros de previsão das barras também foram semelhantes, sendo que nenhuma em específico teve desempenho inferior em todos os métodos de previsão. De maneira geral, as barras do sistema 2 apresentaram erros inferiores aos obtidos no sistema 1.

Os resultados médios da otimização das intensidades de acoplamento para o sistema teste 2 estão apresentados na tabela 26. Para os casos 3 e 4, são obtidas 168 intensidades de acoplamento e para os casos 1 e 2 168 intensidades por barra.

TABELA 26 – INTENSIDADE DE ACOPLAMENTO OTIMIZADA MÉDIA - SISTEMA TESTE 2

FONTE: O AUTOR

<i>Barra</i>	<i>Caso 1</i>	<i>Caso 2</i>	<i>Caso 3</i>	<i>Caso 4</i>
1	0,0017	0,0053		
2	0,1901	0,0755		
3	0,3385	0,1628		
4	0,2543	0,2201		
5	0,2597	0,2137		
6	0,0930	0,0434		
7	0,0686	0,0572		
8	0,1243	0,2286	0,1778	0,1102
9	0,3650	0,1788		
10	0,4452	0,1121		
11	0,0510	0,0226		
12	0,3192	0,2071		
13	0,1741	0,0959		
14	0,0746	0,0296		

Os resultados do acoplamento das previsões obtidas pela MLP, para o sistema teste 2, estão dispostos na tabela 27. O caso que apresentou melhor resultado para cada barra está destacado na tabela. É possível observar que seis barras (5, 8, 9, 11, 12 e 14) obtiveram os melhores resultados em casos diferentes de acoplamento para as duas formas de consideração da série, para as demais o melhor caso do acoplamento foi coincidente. Para o caso da utilização da série inteira para a previsão, os melhores resultados por barra ficaram divididos entre a utilização (tabela 27) ou não (tabela 25) do acoplamento. No caso da série separada por tipo de dia, somente as barras 1 e 8 não obtiveram ganhos com a utilização do acoplamento.

TABELA 27 – MAPES ACOPLAMENTO DAS PREVISÕES - MÉTODO MLP – SISTEMA TESTE 2
 FONTE: O AUTOR

Barra	Série Inteira				Série por Tipo de Dia			
	Caso 1	Caso 2	Caso 3	Caso 4	Caso 1	Caso 2	Caso 3	Caso 4
1	8,09%	8,24%	8,18%	7,91%	8,04%	8,31%	8,35%	7,79%
2	6,26%	6,63%	5,93%	6,11%	6,29%	6,45%	6,10%	6,16%
3	8,62%	7,54%	8,06%	7,16%	8,80%	8,31%	8,21%	7,53%
4	7,39%	5,64%	6,94%	5,55%	7,74%	6,00%	7,08%	5,85%
5	5,32%	5,23%	5,31%	4,98%	5,16%	5,09%	5,38%	5,10%
6	6,22%	5,79%	5,86%	5,21%	6,28%	5,63%	5,85%	5,23%
7	7,54%	7,75%	8,18%	9,21%	7,77%	8,09%	8,51%	9,92%
8	8,07%	8,05%	8,08%	7,90%	8,33%	8,36%	8,21%	8,34%
9	5,77%	7,15%	5,75%	6,30%	5,57%	6,50%	5,58%	6,13%
10	6,58%	5,24%	6,18%	6,47%	6,63%	5,99%	6,18%	6,83%
11	7,95%	7,61%	7,12%	7,03%	7,94%	7,62%	6,90%	7,07%
12	4,01%	3,89%	4,51%	4,36%	3,92%	4,21%	4,39%	4,58%
13	9,95%	10,10%	11,25%	11,86%	9,98%	10,74%	11,28%	12,53%
14	7,09%	7,04%	6,72%	7,00%	7,06%	7,13%	6,61%	7,15%
Média	7,06%	6,85%	7,00%	6,93%	7,11%	7,03%	7,05%	7,16%

A tabela 28 mostra os resultados do acoplamento para o método de previsão RBF. Para este método, somente as barras 9, 10 e 11 não apresentaram o melhor resultado no mesmo tipo de caso para as duas considerações da série histórica. Na comparação entre os resultados da previsão individual (tabela 25) e da acoplada (tabela 28) somente a barra 13 não obteve ganho com o acoplamento, para a previsão com a série dividida por tipo de dia. Para as demais barras, nas duas considerações da série, o acoplamento das previsões apresentou ganhos nos resultados.

TABELA 28 – MAPES ACOPLAMENTO DAS PREVISÕES - MÉTODO RBF – SISTEMA TESTE 2
 FONTE: O AUTOR

Barra	Série Inteira				Série por Tipo de Dia			
	Caso 1	Caso 2	Caso 3	Caso 4	Caso 1	Caso 2	Caso 3	Caso 4
1	8,20%	8,20%	8,51%	8,08%	8,05%	8,17%	8,35%	7,97%
2	6,35%	7,01%	5,52%	6,04%	6,34%	6,84%	6,09%	6,28%
3	7,87%	7,49%	7,56%	6,98%	7,67%	7,61%	7,35%	7,05%
4	6,85%	5,60%	6,63%	5,49%	6,75%	5,65%	6,43%	5,59%
5	5,28%	5,45%	5,39%	5,04%	5,27%	5,28%	5,33%	5,03%
6	6,30%	5,82%	6,03%	5,20%	6,31%	5,93%	6,00%	5,24%
7	7,43%	7,57%	7,93%	9,05%	7,52%	7,68%	8,07%	9,17%
8	8,02%	8,00%	7,95%	7,64%	8,06%	8,09%	8,08%	7,84%
9	5,78%	6,88%	5,81%	6,09%	5,89%	6,88%	5,80%	6,27%
10	6,47%	5,45%	5,94%	6,08%	6,60%	5,59%	6,09%	6,42%
11	7,70%	7,54%	6,64%	7,00%	7,94%	7,55%	6,88%	6,93%
12	5,40%	4,53%	5,06%	4,52%	4,36%	4,35%	4,59%	4,41%
13	9,57%	9,59%	11,09%	11,83%	9,43%	9,86%	10,75%	11,84%
14	7,00%	6,93%	6,36%	6,66%	7,04%	7,05%	6,57%	6,85%
Média	7,02%	6,86%	6,89%	6,84%	6,94%	6,90%	6,88%	6,92%

Na tabela 29 estão apresentados os resultados do acoplamento para o previsor *Fuzzy*. Conforme destacado na tabela, para este método as barras 8, 8 e 10 obtiveram melhor desempenho em casos de acoplamento distintos. A comparação entre os resultados com a aplicação (tabela 29) e sem a aplicação do acoplamento (tabela 25), mostra que as barras 4, 10, 11 e 13 não obtiveram ganhos com o acoplamento para a previsão utilizando a série inteira. Já no caso da previsão com a subdivisão da série por tipo de dias as barras 4, 8 e 13 não apresentaram melhoras após o acoplamento. Para as demais barras o acoplamento das previsões trouxe benefícios.

TABELA 29 – MAPES ACOPLAMENTO DAS PREVISÕES - PREVISOR FUZZY – SISTEMA TESTE 2
 FONTE: O AUTOR

Barra	Série Inteira				Série por Tipo de Dia			
	Caso 1	Caso 2	Caso 3	Caso 4	Caso 1	Caso 2	Caso 3	Caso 4
1	8,23%	8,16%	8,44%	8,05%	8,13%	8,25%	8,35%	7,87%
2	6,47%	7,03%	6,23%	6,14%	6,42%	6,60%	6,11%	6,10%
3	8,17%	7,12%	7,77%	6,92%	8,44%	7,80%	7,98%	7,32%
4	6,91%	5,56%	6,66%	5,51%	7,51%	5,80%	6,92%	5,70%
5	5,47%	5,50%	5,33%	5,11%	5,34%	5,29%	5,29%	5,08%
6	6,40%	5,91%	6,20%	5,36%	6,30%	5,74%	5,96%	5,23%
7	7,48%	7,62%	8,00%	8,97%	7,67%	7,90%	8,32%	9,51%
8	7,90%	8,04%	7,99%	7,81%	8,11%	8,18%	8,12%	8,07%
9	5,95%	7,44%	5,85%	6,41%	5,61%	6,77%	5,67%	6,22%
10	6,40%	5,30%	5,90%	6,30%	6,57%	5,47%	6,03%	6,61%
11	8,03%	7,60%	7,25%	7,19%	7,93%	7,59%	6,98%	6,99%
12	4,85%	4,16%	4,82%	4,50%	4,16%	3,92%	4,51%	4,46%
13	9,47%	9,83%	10,70%	11,65%	9,84%	10,40%	11,02%	12,15%
14	7,05%	6,90%	6,64%	6,72%	7,02%	7,06%	6,57%	6,94%
Média	7,05%	6,87%	6,98%	6,90%	7,08%	6,91%	6,99%	7,02%

A tabela 30 mostra um resumo das médias dos erros para cada caso de acoplamento juntamente com os resultados obtidos sem o acoplamento. A coluna denominada mix representa o erro médio combinando os melhores casos de cada barra. Para esse sistema os resultados com o acoplamento foram melhores para todos os métodos, independentemente da estratégia de acoplamento adotada. Entre todos os métodos, destaca-se a previsão pela RBF para a série inteira, cujo erro médio do sistema passou de 12% para 7%, aproximadamente. De todos os testes realizados, esse foi o que apresentou os melhores resultados para o acoplamento das previsões.

TABELA 30 – COMPARAÇÃO DAS MÉDIAS DOS MAPES – SISTEMA TESTE 2

FONTE: O AUTOR

	<i>Caso 1</i>	<i>Caso 2</i>	<i>Caso 3</i>	<i>Caso 4</i>	<i>Mix</i>	<i>Sem acoplamento</i>
<i>MLP Série Inteira</i>	7,06%	6,85%	7,00%	6,93%	6,48%	7,93%
<i>MLP Tipo de Dia</i>	7,11%	7,03%	7,05%	7,16%	6,61%	7,86%
<i>RBF Série Inteira</i>	7,02%	6,86%	6,89%	6,84%	6,41%	12,07%
<i>RBF Tipo de Dia</i>	6,94%	6,90%	6,88%	6,92%	6,50%	9,21%
<i>Fuzzy Série Inteira</i>	7,05%	6,87%	6,98%	6,90%	6,50%	8,66%
<i>Fuzzy Tipo de Dia</i>	7,08%	6,91%	6,99%	7,02%	6,53%	7,78%

Comparando o desempenho do acoplamento para os três métodos de previsão, é possível verificar que o comportamento do acoplamento para a RBF foi muito bom, trazendo bons resultados em praticamente todas as situações. Para a MLP e para o previsor *Fuzzy*, o desempenho também foi satisfatório e o número de casos que apresentaram melhora foi superior ao dos que não apresentaram. Um resumo dos melhores MAPES obtidos para cada situação é apresentado na tabela 31, onde as células vazias indicam que o erro foi prejudicado após o acoplamento das previsões.

TABELA 31 – RESUMO DOS MELHORES CASOS DE PREVISÃO ACOPLADA – SISTEMA TESTE 2
 FONTE: O AUTOR

Barra	MLP		RBF		Fuzzy	
	Série Inteira	Série por Tipo de Dia	Série Inteira	Série por Tipo de Dia	Série Inteira	Série por Tipo de Dia
1			Caso 4	Caso 4	Caso 4	Caso 4
2	Caso 3	Caso 3	Caso 3	Caso 3	Caso 4	Caso 4
3		Caso 4	Caso 4	Caso 4	Caso 4	Caso 4
4		Caso 4	Caso 4	Caso 4		
5	Caso 4	Caso 2	Caso 4	Caso 4	Caso 4	Caso 4
6	Caso 4	Caso 4	Caso 4	Caso 4	Caso 4	Caso 4
7	Caso 1	Caso 1	Caso 1	Caso 1	Caso 1	Caso 1
8			Caso 4	Caso 4	Caso 1	
9	Caso 3	Caso 1	Caso 1	Caso 3	Caso 3	Caso 1
10	Caso 2	Caso 2	Caso 2	Caso 2		Caso 2
11		Caso 3	Caso 3	Caso 3		Caso 3
12		Caso 1	Caso 4	Caso 2	Caso 2	Caso 2
13		Caso 1	Caso 1			
14	Caso 3	Caso 3	Caso 3	Caso 3	Caso 3	Caso 3

4.4 EXTRAÇÃO DE CONHECIMENTO DOS RESULTADOS UTILIZANDO CONUNTOS APROXIMADOS

Com a realização dos diversos testes descritos neste capítulo foi obtida uma grande quantidade de resultados para análise e extração de conhecimento acerca da aplicação do método desenvolvido. De forma a tentar extrair este conhecimento a respeito dos resultados obtidos foi utilizada a teoria dos conjuntos aproximados (*Rough Sets*), a qual foi desenvolvida por Pawlak (1982) e vem sendo bastante utilizada para

estudos de classificação e para eliminação de informações irrelevantes em bancos de dados (mineração de dados).

Ohrn (1999) desenvolveu, para aplicação em seu trabalho na área de medicina, o *software Rosetta*, que se mostrou bastante eficiente na aplicação de *Rough Sets*. Este *software* foi utilizado neste trabalho com diversas aplicações diferentes dos resultados obtidos, para tentar extrair informações relevantes quanto a aplicação do método desenvolvido.

Foram adotados diferentes parâmetros para identificar informações relevantes sobre o comportamento dos resultados do acoplamento. Os parâmetros de identificação adotados estão dispostos a seguir:

- Posição da barra: indica se a barra é final de linha ou não;
- Quantidade de pontos corrigidos no pré-tratamento: de acordo com a porcentagem de dados corrigidos na série histórica, foram estabelecidos os intervalos Baixo (se menos de 12% de dados foram corrigidos), Médio (se o número de dados corrigidos ficou entre 12% e 25%) e Alto (se foram corrigidos mais de 25% dos dados históricos);
- Intensidade do acoplamento: considerada baixa (B) se a média de valores ε foi menor que 0,35 e considerada alta (A) caso contrário;
- Erro de previsão: para cada barra foi calculada a média e o desvio padrão do erro entre todos os resultados de previsão obtidos para a barra. Foram classificados como alto (A) os erros que ultrapassaram a média mais um desvio padrão, baixo (B) os que ficaram abaixo da média menos um desvio padrão e médio (M) os demais.

Como resultados foram utilizados, em diferentes testes:

- Efetividade do acoplamento: se o acoplamento funcionou (S) para mais de três casos de previsão foi considerado como efetivo, caso contrário não (N);

- Tipo do acoplamento: qual foi o caso de acoplamento que resultou no menor erro de previsão;
- Tipo da intensidade de acoplamento: se o melhor caso de acoplamento utilizou intensidade de acoplamento geral para o sistema ou individual por barra;
- Tipo da equação de acoplamento: se o melhor caso do acoplamento utilizou a função de acoplamento global ou local.

A figura 26 mostra um exemplo de uma tabela utilizada no *software* Rosetta, onde foram utilizados o número de outliers, o erro de previsão e a intensidade de acoplamento como entradas e se o acoplamento funcionou ou não como saída. Nesse exemplo, foram colocadas todas as barras para os seis testes de previsão realizados, considerando os dois sistemas teste.

	Outliers	ERRO	EPS	FUNCIONOU
1	Alto	B	B	N
2	Médio	A	B	S
3	Baixo	B	B	N
4	Baixo	B	B	N
5	Médio	M	B	S
6	Baixo	M	B	S
7	Alto	M	B	S
8	Alto	M	B	N
9	Baixo	B	B	S
10	Baixo	M	B	S
11	Baixo	M	B	N
12	Médio	M	B	N
13	Médio	M	B	N
14	Médio	B	B	S
15	Alto	B	B	N
16	Médio	B	B	S
17	Baixo	M	B	S
18	Baixo	M	B	S
19	Médio	M	B	S
20	Baixo	M	B	S

FIGURA 26 – EXEMPLO DE TABELA UTILIZADA NO SOFTWARE ROSETTA

FONTE: O AUTOR

Com esses parâmetros foram realizados diversos testes a fim de identificar regras para definição da melhor estratégia de acoplamento para cada sistema. Dentre os diversos testes realizados, a única característica que o software conseguiu extrair em todos os testes, independentemente do sistema considerado é que se o erro de previsão da técnica é alto (maior que a média entre as demais técnicas com um desvio padrão), a utilização do acoplamento traz ganhos, reduzindo esses erros. Essa regra está destacada em vermelho na figura 27, que apresenta as regras geradas no software Rosetta para o conjunto de entrada mostrado na figura 26.

	Rule
1	ERRO(B) AND EPS(B) => FUNCIONOU(N) OR FUNCIONOU(S)
2	ERRO(A) AND EPS(B) => FUNCIONOU(S)
3	ERRO(M) AND EPS(B) => FUNCIONOU(S) OR FUNCIONOU(N)
4	ERRO(M) AND EPS(A) => FUNCIONOU(S)
5	ERRO(A) AND EPS(A) => FUNCIONOU(S)

FIGURA 27 – EXEMPLO DAS REGRAS GERADAS NO SOFTWARE ROSETTA
FONTE: O AUTOR

4.5 CONSIDERAÇÕES FINAIS DO CAPÍTULO

Neste capítulo foram apresentados os resultados obtidos com a aplicação do método híbrido de previsão de carga inspirado em redes de mapas acoplados. Foram realizados diferentes testes quanto às estratégias de acoplamento e quanto aos métodos de previsão utilizados para o acoplamento.

Foram utilizadas três técnicas de Inteligência Computacional, quais sejam, redes MLP e RBF e predictor *Fuzzy*, para realizar as previsões individuais das barras. Para cada uma das técnicas a série histórica foi considerada de duas formas, uma utilizando toda a série para o treinamento e outra com a série dividida por tipo de dia da semana.

Os resultados obtidos com as previsões individuais para cada barra se comportaram de forma semelhante, no que concerne o aspecto técnico dos erros de previsão, os quais para as barras que apresentaram erros de previsão elevados com uma determinada técnica, também tiveram o mesmo comportamento para os demais métodos

de previsão. Em relação aos sistemas testes, o sistema teste 2 obteve resultados de previsão melhores que os obtidos no sistema 1. Se for observado o comportamento do coeficiente de variação de Pearson dos dados históricos é possível verificar que o sistema teste 1 contém cinco barras com elevado índice de variação, enquanto para o sistema 2 somente duas barras possuem índice elevado. Proporcionalmente, o sistema 2 é um sistema cujas barras possuem menor índice de variação.

Na otimização das intensidades de acoplamento, o sistema 1 obteve uma maior quantidade de valores que ultrapassaram 0,35, o que, segundo Kaneko (1993), implica em domínio instável e menor capacidade de acoplamento entre os elementos.

Após a aplicação das estratégias de acoplamento, foram obtidos resultados de previsão acoplados que apresentaram comportamentos distintos nos dois casos teste. Para o sistema teste 2, independentemente da estratégia de acoplamento adotada, o acoplamento das previsões reduziu o erro médio do sistema. Quando são observados os MAPEs para cada barra individualmente, somente as barras 4, 8 e 13 não obtiveram ganhos com o acoplamento para mais de três dos testes de previsão realizados. Para as demais barras, a estratégia de acoplamento se mostrou adequada para quatro (ou mais) dos seis testes realizados.

O sistema teste 1 não apresentou um desempenho satisfatório com o acoplamento. Para a MLP, que apresentou erros mais elevados de previsão, o acoplamento resultou em erros menores para a maioria das barras, sendo que somente a barra 3 (previsão para a série inteira) e as barras 1, 2 e 7 (previsão por tipo de dia) não apresentaram melhora. No entanto, para a RBF e o *Fuzzy*, o acoplamento não resultou em menores erros médios. Quando analisadas as previsões de cada barra, diferentemente dos resultados para o sistema 2, quatro barras (1, 8, 9 e 10) não tiveram nenhum caso de acoplamento satisfatório e, ainda, obtiveram erros consideravelmente altos após o acoplamento.

No capítulo seguinte é apresentado um resumo do trabalho desenvolvido e são destacadas as principais conclusões acerca da utilização do método desenvolvido, bem como são sugeridos trabalhos futuros.

5 CONCLUSÕES E TRABALHOS FUTUROS

O problema de previsão de carga vem sendo estudado há bastante tempo e diversas técnicas são utilizadas de acordo com o horizonte de previsão adotado. No SEB são solicitados às concessionárias de energia diversos estudos de previsão, com diferentes horizontes e discretização, que atendem desde estudos focados no planejamento do sistema até estudos para a operação em tempo real.

São utilizadas técnicas de regressão linear, processos estocásticos, modelos autorregressivos, médias móveis, redes neurais, lógica *fuzzy*, dentre outros. Nesses estudos, além da variável de carga podem ser utilizadas variáveis econômicas, climáticas ou de calendário, para agregar informação aos estudos e tornar as técnicas mais robustas.

O objetivo deste trabalho foi o de adicionar informações relacionadas à topologia do sistema elétrico, considerando as conexões entre as barras e a influência que a variação na carga de uma barra exerce em suas vizinhas. Para isso, foi desenvolvido um método híbrido para previsão de carga inspirado nos conceitos de redes de mapas acoplados.

A primeira parte do método consiste na aplicação de um método de previsão de séries temporais para cada barra do sistema individualmente. Em seguida os resultados obtidos são acoplados para considerar a topologia do sistema. Foram testadas diferentes formas de considerar o tipo de acoplamento (local ou global) e a intensidade do acoplamento (individual por barra ou geral para o sistema). Para testar o método proposto, foram utilizados dois sistemas, um com 11 barras e outro com 14 barras, que representam sistemas elétricos reais do Brasil. Os dados obtidos foram submetidos a um pré-tratamento, para tratar as diversas incoerências e falhas na medição.

Após o pré-tratamento foram realizadas as previsões individuais, através das técnicas MLP, RBF e *Fuzzy*. Analisando os erros para os 168 passos à frente, a média de erros de todos os testes para o sistema 1 foi em torno de 14% e para o sistema 2 em

torno de 9%. Considerando a qualidade dos dados históricos, pode-se dizer que o desempenho de previsão dos métodos foi satisfatório. A barra cuja previsão teve o pior desempenho foi a barra 8 do primeiro sistema teste, que apresentou erros elevados (média de 29%) para todas as técnicas de previsão. Esses resultados podem ser explicados pela péssima qualidade dos dados históricos da barra, que teve praticamente metade (48%) de seus dados detectados como erros ou *outliers*. Além disso, mesmo após o tratamento dos dados, o comportamento diário da série não é bem definido e não segue um comportamento padrão.

Com os resultados das previsões foi realizada a otimização das intensidades de acoplamento e posterior acoplamento das previsões das barras. Os resultados obtidos com o acoplamento foram distintos para os dois sistemas utilizados. O sistema 2 teve seu desempenho médio aprimorado com o acoplamento (a média de erros do sistema passou de 8,92% para 6,88%), enquanto o sistema 1 teve seu desempenho prejudicado (passando de uma média de erro de 13,87% para 22,90%). Para o sistema 2 todas as estratégias de acoplamento resultam em menores erros médios para o sistema, chegando a uma média de 6,51% quando consideradas as melhores previsões de cada barra.

O desempenho inferior do acoplamento para o sistema 1 pode ser explicado pela má qualidade dos dados, já que a principal premissa do acoplamento é que os dados reflitam o comportamento real do sistema. Com altos índices de correção e substituição de valores na série histórica a influência que as barras exercem umas sobre as outras fica comprometida.

De forma geral, é possível indicar que a aplicação do método proposto se torna mais interessante para sistemas maiores, com maior grau de conexões e cujos dados representem o mais fielmente possível o comportamento real do sistema.

Quanto à utilização de intensidades de acoplamento distintas para cada uma das barras do sistema, verificou-se que, quando essas intensidades ficam muito elevadas (maiores que 0,35) o sistema diminui sua capacidade de acoplamento. Dessa maneira, se as intensidades de acoplamento individuais das barras forem elevadas recomenda-se a utilização de uma única intensidade de acoplamento para o sistema.

Por fim, verificou-se que sempre que a técnica de previsão para uma barra em particular apresenta MAPEs acima da média das demais técnicas a utilização do acoplamento é válida, ou seja, o acoplamento consegue tratar os piores casos de previsão, quando se utiliza uma técnica com menor robustez para a previsão individual da barra.

Como trabalhos futuros, sugere-se a utilização dos conceitos de acoplamento para realizar previsões conjuntas de barras, como as realizadas para os estudos do PAR. Nesses estudos, as previsões das barras somadas devem coincidir com a previsão global do sistema. Com os conceitos de acoplamento pode ser possível identificar quais barras possuem maior influência na carga global e realizar as previsões de todas as barras do sistema de forma conjunta.

A segunda sugestão para trabalho futuro é a utilização de intensidades de acoplamento individualizadas de uma barra com todas as demais do sistema. Com essa consideração, ao invés de um ε por barra, uma matriz de intensidades de acoplamento seria utilizada, atribuindo uma intensidade de acoplamento de uma barra com cada uma das demais barras conectadas a ela. Dessa maneira, deve ser possível identificar se o melhor tipo de acoplamento para cada barra, pois somente as barras que de fato exercem influência seriam consideradas.

Outra sugestão é a realização de uma análise do perfil de carga das barras do sistema, a fim de identificar a influência do acoplamento em barras que possuem as mesmas características. Uma análise detalhada do perfil de carga das barras pode determinar se barras com comportamento tipicamente residencial, por exemplo, possuem maior intensidade de acoplamento entre si. Com essa análise pode-se identificar barras que possuem pouco, ou nenhum, acoplamento com o sistema considerado.

Ainda, como continuidade dessa pesquisa, propõe-se que os conceitos do acoplamento sejam inseridos diretamente em um método de previsão. Dessa forma, as equações de acoplamento seriam parte integrante do método e a otimização das intensidades de acoplamento seria realizada em conjunto com a otimização dos parâmetros de previsão.

REFERÊNCIAS

AGUIRRE, L. A.; RODRIGUES, D. D.; LIMA, S. T.; MARTINEZ, C. B. Dynamical prediction and pattern mapping in short-term load forecasting, **Electrical Power and Energy Systems**, v.30, p. 73-82, 2008.

AHMADI, S.; BEVRANI, H.; JANNATY, H. A fuzzy inference model for short-term load forecasting, In: SECOND IRANIAN CONFERENCE ON RENEWABLE ENERGY AND DISTRIBUTED GENERATION, 2012, Irã, **Proceedings of Second Iranian Conference on Renewable Energy and Distributed Generation**, 2012, p. 39-44.

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.

ALRASHIDI, M. R.; EL-NAGGAR, K. M. Long term electric load forecasting based on particle swarm optimization, **Applied Energy**, v.87, p.320-326, 2010.

AL-SHOBAKI, S.; MOHSEN, M. Modeling and forecasting of electrical power demands for capacity planning, **Energy Conversion and Management**, v. 49, p.3367-3375, 2008.

AMJADY, N.; DARAEIPOUR, A. Midterm Demand Prediction of Electrical Power Systems Using a New Hybrid Forecast Technique, **IEEE Transactions on Power Systems**, v.26, n.2, p.755–765, 2011.

APADULA, F.; BASSINI, A.; ELLI, A.; SCAPIN, S. Relationships between meteorological variables and monthly electricity demand, **Applied Energy**, v.98, p. 346–356, 2012.

BECERRA, R.L.; COELLO, C.A.C. Cultured differential evolution for constrained optimization, **Computer Methods in Applied Mechanics and Engineering**, v.195, p. 4303-4322, 2006.

BILLINGS, S.A.; ZHENG, G.L. Radial Basis Function Networks Configuration Using Genetic Algorithms, **Neural Networks**, v.8, n6, p. 877-890, 1995.

BO, R.; LI, F.; TOMSOVIC, K. Prediction of critical load levels for AC optimal power flow dispatch model, **Electrical Power and Energy Systems**, v.42, p.635-643, 2012.

BORGES, C. E.; PENYA, Y. K.; FERNÁNDEZ, I. Evaluating Combined Load Forecasting in Large Power Systems and Smart Grids, **IEEE Transactions on Industrial Informatics**, v.9, n.3, p. 1570–1577, 2013.

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

BRASIL. Decreto nº 5.081, de 14 de maio de 2004. Regulamenta os arts. 13 e 14 da Lei nº 9.648, de 27 de maio de 1998, e o art. 23 da Lei nº 10.848, de 15 de março de 2004, que tratam do Operador Nacional do Sistema Elétrico – ONS. **Diário Oficial da União**, Brasília, DF, 17 mai. 2004.

BRASIL. Decreto nº 5.184, de 16 de agosto de 2004. Cria a Empresa de Pesquisa Energética – EPE, aprova seu Estatuto Social e dá outras providencias. **Diário Oficial da União**, Brasília, DF, 17 ago. 2004.

BRASIL. Lei nº 10.847, de 15 de março de 2004. Autoriza a criação da Empresa de Pesquisa Energética – EPE e dá outras providencias. **Diário Oficial da União**, Brasília, DF, 16 mar. 2004. P. 1.

BRASIL. Lei nº 9.648, de 27 de maio de 1998. Altera dispositivos das Leis no 3.890-A, de 25 de abril de 1961, no 8.666, de 21 de junho de 1993, no 8.987, de 13 de fevereiro de 1995, no 9.074, de 7 de julho de 1995, no 9.427, de 26 de dezembro de 1996, e autoriza o Poder Executivo a promover a reestruturação da Centrais Elétricas Brasileiras - ELETROBRÁS e de suas subsidiárias e dá outras providências. **Diário Oficial da União**, Brasília, DF, 28 mai. 1998.

BRASIL. Resolução Normativa nº 247, de 21 de dezembro de 2006. Estabelece as condições para a comercialização de energia elétrica, oriunda de empreendimentos de geração que utilizem fontes primárias incentivadas, com unidade ou conjunto de unidades consumidoras cuja carga seja maior ou igual a 500 kW e dá outras providências. **Diário Oficial da União**, Brasília, DF, 22 dez. 2006.

CHEN, Y.; LUH, P. B.; GUAN, C.; ZHAO, Y.; MICHEL, L. D.; COOLBETH, M. A.; FRIEDLAND, P. B.; ROURKE, S. J. Short-Term Load Forecasting: Similar Day-Based Wavelet Neural Networks, **IEEE Transactions on Power Systems**, v.25, n.1, p. 322–330, 2010.

COELHO, L. S., GUERRA, F. A., AOKI, A. R.; MIGUEL, F. N. Previsão do consume de energia elétrica em rede de distribuição de energia elétrica usando sistema nebuloso e agrupamento de dados, In: CMNE/CILAMCE - XXVIII CILAMCE - Iberian Latin American Congress on Computational Methods in Engineering, 2007, Porto, Portugal. **Anais do CMNE/CILAMCE - XXVIII CILAMCE - Iberian Latin American Congress on Computational Methods in Engineering**, 2007, p. 1-10.

COELHO, L. S., KLEIN, C. E. Power demand forecast using least-squares support vector machines, In: ISAP'09 15 INTERNATIONAL CONFERENCE ON INTELLIGENT SYSTEM APPLICATIONS TO POWER SYSTEMS, 2009, Curitiba. Proceedings of ISAP'09 15 INTERNATIONAL CONFERENCE ON INTELLIGENT SYSTEM APPLICATIONS TO POWER SYSTEMS, 2009, p. 1-5.

COELHO, M. C., OENING, A. P., AOKI, A. R. A new approach based on coupled map lattices for load forecasting in smart grids, In: IEEE PES CONFERENCE ON INNOVATIVE SMART GRID TECHNOLOGIES LATIN AMERICA, 2013, São Paulo. **Proceedings of IEEE PES Conference on Innovative Smart Grid Technologies Latin America**, 2013, p. 1-4.

DEIHIMI, A.; SHOWKATI, H. Application of echo state networks in short-term electric load forecasting, **Energy**, v.39, p. 327–340, 2012.

DKRR, E.; QLJDP, F. R. P.; FRP, B. D.; Curve fitting Regression line method Based Seasonal Short Term Load Forecasting, In: WORLD CONGRESS ON INFORMATION AND COMMUNICATION TECHNOLOGIES, 2012, Trivandrum. **Proceedings of World Congress on Information and Communication Technologies**, 2012, p. 332–337.

ELATTAR, E. E.; GOULERMAS, J. Y.; WU, Q. H. Generalized Locally Weighted GMDH for Short Term Load Forecasting, **IEEE Transactions on Systems, Man, and Cybernetics – Part C: Applications and Reviews**, v.42, n.3, p. 345–356, 2012.

EPE, EMPRESA DE PESQUISAS ENERGÉTICAS. **Plano Decenal de Expansão de Energia 2021**. Brasília, DF, 2013. Disponível em <<http://www.epe.gov.br>>.

EPE, EMPRESA DE PESQUISAS ENERGÉTICAS. **SIMPLES Manual do Usuário Ciclo 2009**. Rio de Janeiro, RJ, 2009. Disponível em <<http://www.epe.gov.br>>.

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, 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, 2010.

FERRARA, L. F. P.; LAMBERT-TORRES, G.; DA SILVA FILHO, J. I.; BLANCO, F. B.; ROCCO, A.; SANTOS, M. R. Forecaster of Loads Profile in Power Electric Systems Based on Paraconsistent Annotated Logic, In: ISAP'09 15 INTERNATIONAL CONFERENCE ON INTELLIGENT SYSTEM APPLICATIONS TO POWER SYSTEMS, 2009, Curitiba. **Proceedings of ISAP'09 15 INTERNATIONAL CONFERENCE ON INTELLIGENT SYSTEM APPLICATIONS TO POWER SYSTEMS**, 2009, p. 1-6.

FERREIRA, V. H.; da SILVA, A. P. A. . Chaos theory applied to input space representation of autonomous neural network-based short-term load forecasting models. **Controle & Automação** (Impresso), v. 22, p. 585-597, 2011.

GARCÍA, M. L.; SENABRE, C.; MARÍN, A. G. Short-Term Predictability of Load Series: Characterization of Load Data Bases, **IEEE Transactions on Power Systems**, v.28, n.3, p. 2466–2474, 2013.

HAHN, H.; MEYER-NIEBERG, S.; PICKL, S. Electric load forecasting methods: Tools for decision making, **European Journal of Operational Research**, v.199, p. 902-907, 2009.

HANMANDLU, M.; CHAUHAN, B. K. Load Forecasting Using Hybrid Models, **IEEE Transactions on Power Systems**, v.26, n.1, p. 20–29, 2011.

HEIKO, H.; MEYER-NIEBERG, S.; PICKL, S. Electric load forecasting methods: Tools for decision making, **European Journal of Operational Research**, n.199, p. 902-907, 2009.

HERNÁNDEZ, L.; BALADRÓN, C.; AGUIAR, J. M.; CALAVIA, L.; CARRO, B.; SÁNCHEZ-ESGUEVILLAS, A.; SANJUÁN, J.; GONZÁLEZ, A.; LLORET, J. Improved Short-Term Load Forecasting Based on Two-Stage Predictions with Artificial Neural Networks in a Microgrid Environment, **Energies**, v.6, p. 4489–4507, 2013.

HERZALLAH, R.; LOWE, D. Comparison between conventional and stochastic pinning control. In: MEDITERRANEAN CONFERENCE ON CONTROL AND AUTOMATION, 19, 2011, Corfu. **Proceedings of Mediterranean Conference on Control and Automation**, 2011, p. 730-735. ISBN 978-1-4577-0124-5.

HINOJOSA, A. H.; HOESE, A. Short-Term Load Forecasting Using Fuzzy Inductive Reasoning and Evolutionary Algorithms, **IEEE Transactions on Power Systems**, v.25, n.1, p. 565–574, 2010.

HIPPERT, H. S.; PEDREIRA, C. E.; SOUZA, R. C. Neural Networks for Short-Term Load Forecasting: A Review and Evaluation, **IEEE Transactions on Power Systems**, v. 16, n.1, p. 44-55, 2001.

HOOSHMAND, R.; AMOOSHAHI, H.; PARASTEGARI, M. A hybrid intelligent algorithm based short-term load forecasting approach, **Electrical Power and Energy Systems**, v.45, p. 313-324, 2013.

HUSSAIN, I.; GONDAL, M. A. An extended image encryption using chaotic coupled map and S-box transformation, **Nonlinear Dynamics**, v.76, N.2, p.1355-1363, 2014.

IWASHITA, D; MORI, H. Risk Quantification for ANN Based Short-Term Load Forecasting, **Electrical Engineering in Japan**, v.166, n.2, p. 54-62 (traduzido de Denki Gakkai Ronbunshi, v.126-B, n.1, p. 29–35, 2006), 2009.

JANG, J.S.R., ANFIS: Adaptive-Network-based Fuzzy Inference Systems, **IEEE Transactions on Systems, Man, and Cybernetics**, v.23, n.3, p. 665-685, 1993.

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, 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.

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.

KEBRIAIEI, H.; ARAABI, B. N.; RAHIMI-KIAN, A. Short-Term Load Forecasting With a New Nonsymmetric Penalty Function, **IEEE Transactions on Power Systems**, v.26, n.4, p. 1817–1825, 2011.

KO, C.; LEE, C. Short-term load forecasting using SVR (support vector regression)-based radial basis function neural network with dual extended Kalman filter, **Energy**, v.49, p. 413-422, 2013.

KYRIAKIDES, E.; POLYCARPON, M. Short Term Electric Load Forecasting: A Tutorial, em CHEN, K; WANG, L.. **Trends in Neural Computation**, Springer, 2007, v. 35, p. 391-418.

LAURET, P.; FOCK, E.; RANDRIANARIVONY, R. N.; MANICOM-RAMSAMY, J. Bayesian neural network approach to short time load forecasting, **Energy Conversion and Management**, v.49, p. 1156-1166, 2008.

LIN, C.; CHOU, L. A novel economy reflecting short-term load forecasting approach, **Energy Conversion and Management**, v.65, p.331-342, 2013.

LIU, Z.; LI, W.; SUN, W. A novel method of short-term load forecasting based on multiwavelet transform and multiple neural networks, **IEEE Transactions on Industrial Informatics**, v.9, n.3, p. 1570–1577, 2013.

LÓPEZ, M.; VALERO, S.; SENABRE, C.; APARICIO, J.; GABALDON, A. Application of SOM neural networks to short-term load forecasting: The Spanish electricity market case study, **Electric Power Systems Research**, v.91, p. 18–27, 2012.

MAIA, C. A.; GONÇALVES, M. M. Application of switched adaptive system to load forecasting, **Electric Power Systems Research**, v.78, p. 721–727, 2008.

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.

MAMLOOK, R.; BADRAN, O.; ABDULHADI, E. A fuzzy inference model for short-term load forecasting, **Energy Policy**, v.37, p. 1239–1248, 2009.

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.

MARTINS, G. A. **Estatística Geral e Aplicada**. São Paulo: Editora Atlas, 2002.

MASSELI, Y. M. C.; LAMBERT-TORRES, G.; MORAES, C. H. V.; SILVA, L. E. B.; ESMIN, A. A. A. Proposition of PSO Fuzzy Polynomial Neural Network for Short-Term Load Forecasting, In: IEEE INTERNATIONAL CONFERENCE ON SYSTEMS MAN AND CYBERNETICS, 2010, Istambul. **Proceedings of IEEE INTERNATIONAL CONFERENCE ON SYSTEMS MAN AND CYBERNETICS**, 2010, p. 4224-4228.

METAXIOTIS, K.; KAGIANNAS, A.; ASKOUNIS, D.; PSARRAS, J. Artificial intelligence in short term electric load forecasting: a state-of-art survey for researcher, **Energy Conversion and Management**, v. 44, p. 1525-1534, 2003.

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, 2005.

NASCIMENTO, R. M.; OENING, A. P.; MARCILIO, D. C.; AOKI, A. R.; ROCHA JUNIOR, E.; SCHIOCHET, J.; Outliers' Detection and Filling Algorithms for Smart Metering Centers, In: IEEE PES TRANSMISSION AND DISTRIBUTION CONFERENCE AND EXPOSITION, 2012, Orlando, Flórida. **Proceedings of IEEE PES Transmission and Distribution Conference and Exposition**, 2012, p. 1-6.

NIU, D.; SHI, H.; WU, D. D. Short-term load forecasting using bayesian neural networks learned by Hybrid Monte Carlo algorithm, **Applied Soft Computing**, v.12, p. 1822-1827, 2012.

NOSE-FILHO, K.; DIVA, A.; LOTUFO, P.; MINUSSI, C. R.; Short-Term Multinodal Load Forecasting Using a Modified General Regression Neural Network. **IEEE Transactions on Power Delivery**, v. 26, n. 4, p. 2862–2869, 2011.

OHRN, A. **Discernibility and Rough sets in Medicine: Tools and Applications**. Norwegian University of Science and Technology. 1999.

ONS, OPERADOR NACIONAL DO SISTEMA ELÉTRICO. Disponível em <<http://www.ons.org.br>>, acessado em 13 de janeiro de 2013.

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

ONS, OPERADOR NACIONAL DO SISTEMA ELÉTRICO. **Procedimentos de Rede: Submódulo 4.1 – Ampliações e reforços: visão geral**. Rio de Janeiro, 2010. Disponível em <<http://www.ons.org.br>>.

ONS, OPERADOR NACIONAL DO SISTEMA ELÉTRICO. **Procedimentos de Rede: Submódulo 5.1 – Consolidação da previsão de carga: visão geral**. Rio de Janeiro, 2010a. Disponível em <<http://www.ons.org.br>>.

ONS, OPERADOR NACIONAL DO SISTEMA ELÉTRICO. **Procedimentos de Rede: Submódulo 5.2 – Consolidação da previsão de carga para estudos de ampliações e reforços**. Rio de Janeiro, 2010b. Disponível em <<http://www.ons.org.br>>.

ONS, OPERADOR NACIONAL DO SISTEMA ELÉTRICO. **Procedimentos de Rede: Submódulo 5.3 – Consolidação da previsão de carga para estudos do planejamento da operação elétrica**. Rio de Janeiro, 2010c. Disponível em <<http://www.ons.org.br>>.

ONS, OPERADOR NACIONAL DO SISTEMA ELÉTRICO. **Procedimentos de Rede: Submódulo 5.5 – Consolidação da previsão de carga para o planejamento anual da operação energética**. Rio de Janeiro, 2009. Disponível em <<http://www.ons.org.br>>.

ONS, OPERADOR NACIONAL DO SISTEMA ELÉTRICO. **Procedimentos de Rede: Submódulo 5.6 – Consolidação da previsão de carga para a elaboração do Programa Mensal da Operação Energética**. Rio de Janeiro, 2009a. Disponível em <<http://www.ons.org.br>>.

PACKARD, N. H. e WOLFRAM, S. Two-Dimensional Cellular Automata. **Journal of Statistical Physics**, 38, p.901-946, 1985.

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

PANDEY, A. S.; SINGH, D.; SINHA, S. K. Intelligent Hybrid Wavelet Models for Short-Term Load Forecasting, **IEEE Transactions on Power Systems**, v.25, n.3, p. 1266–1273, 2010.

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, 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, 2000.

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, 2011.

PAWLAK, Z. **Rough sets**. Int. J. Comput. Inf. Sci. 11, 341-356. 1982.

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**, The Royal Society, v. 259, n. 1355, p. 111-117, 1995.

SOARES, L. J.; MEDEIROS, M. C. Modeling and forecasting short-term electricity load: A comparison of methods with an application to Brazilian data, **International Journal of Forecasting**, v.24, p. 630-644, 2008.

STROHMER, T.; VERSHYNIN, R. A randomized Kaczmarz algorithm with exponential convergence, *Numerical Analysis*, 2007.

SUN, W.; BAI, Y.; Short-term load forecasting based on wavelet transform and BP neural network. In: INTERNATIONAL CONFERENCE ON MECHANIC AUTOMATION AND CONTROL ENGINEERING, 2, 2011, Hohhot. **Proceedings of Second International Conference on Mechanic Automation and Control Engineering**, 2011, p. 656–659.

TAKAGI, T.; SUGENO, M. Fuzzy identification of systems and its applications to modeling and control, **IEEE Transactions on Systems, Man and Cybernetics**, v. SMC15, n.1, p. 116-132, 1995.

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

WANG, S.; HU, G.; ZHOU, H. A one-way coupled chaotic map lattice based self-synchronizing stream cipher, **Commun Nonlinear Sci Numer Simulat**, v.19, p.905-913, 2014.

WANG, Y.; WONG, K.; XIAO, D. Parallel hash function construction based on coupled map lattices, **Commun Nonlinear Sci Numer Simulat**, v.16, p.2810–2821, 2011.

WANG, J.; ZHU, S.; ZHANG, W.; LU, H. Combined modeling for electric load forecasting with adaptive particle swarm optimization, **Energy**, v.35, p. 1671–1678, 2010.

WANG, Q.; ZHOU, B.; LI, Z.; REN, J.; Forecasting of short-term load based on fuzzy clustering and improved BP algorithm. In: INTERNATIONAL CONFERENCE ON ELECTRICAL AND CONTROL ENGINEERING, 2011, Yichang. **Proceedings of International Conference on Electrical and Control Engineering**, 2011, p. 4519–4522.

WANG, Y.; XIA, Q.; KANG, C. Secondary Forecasting Based on Deviation Analysis for Short-Term Load Forecasting, **IEEE Transactions on Power Systems**, v.26, n.2, p. 500–507, 2011.

WEI, H. L.; BILLINGS, S. A.; ZHAO, Y. F.; GUO, L. Z. Lattice Dynamical Wavelet Neural Networks Implemented Using Particle Swarm Optimization for Spatio–Temporal System Identification. **IEEE Transactions on Neural Networks**, v.20, n.1, p. 181-185, 2009.

XINHUI, D.; LIANG, W.; JIANCHENG, S.; YAN, Z.; Application of Neural Network and Support Vector Machines to Power System Short-term Load Forecasting. In: INTERNATIONAL CONFERENCE ON COMPUTATIONAL ASPECTS OF SOCIAL NETWORKS, 2010, Taiyuan. **Proceedings of International Conference on Computational Aspects of Social Networks**, 2010, p. 729–732.

YADAV, V.; SRINIVASAN, D. A SOM-based hybrid linear-neural model for short-term load forecasting, **Neurocomputing**, v.74, p. 2874–2885, 2011.

YING, L.; PAN, M. Using adaptive network based fuzzy inference system to forecast regional electricity loads, **Energy Conversion and Management**, v.49, p. 205–211, 2011.

YUN, Z.; QUAN, Z.; CAIXIN, S.; SHAOLAN, L.; YUMING, L.; YANG, S. RBF Neural Network and ANFIS-Based Short-Term Load Forecasting Approach in Real-Time Price Environment, **IEEE Transaction on Power Systems**, v.23, n.3, p. 853-858, 2008.

ZHANG, G. P.; PATUWO, B. E.; HU, M. Y. A simulation study of artificial neural networks for nonlinear time-series forecasting. **Computers & OR**, vol. 28, n. 4, p. 381-396, 2001.

ZHANG, Z.; YE, S.; Long Term Load Forecasting and Recommendations for China Based on Support Vector Regression. In: INTERNATIONAL CONFERENCE ON INFORMATION MANAGEMENT, INNOVATION MANAGEMENT AND INDUSTRIAL ENGINEERING, 2011, Shenzhen. **Proceedings of International Conference on Information Management, Innovation Management and Industrial Engineering**, 2011, p. 597–602.

APÊNDICE 1 - Atrasos na variável de carga para a série por tipo de dia – Sistema teste 1

<i>Barra</i>	<i>Dia da semana</i>	<i>Atrasos na variável de carga</i>
1	<i>Domingo</i>	1, 6, 11, 16, 21, 26, 31, 36, 41, 46, 51, 56, 61, 66, 71, 76, 81, 86, 91
	<i>Segunda</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67, 73
	<i>Terça</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67, 73, 79
	<i>Quarta</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67
	<i>Quinta</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67, 73
	<i>Sexta</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67, 73, 79
	<i>Sábado</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67, 73, 79, 85, 91
2	<i>Domingo</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67, 73, 79, 85
	<i>Segunda</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67, 73, 79
	<i>Terça</i>	1, 13, 25, 37, 49, 61, 73, 85, 97, 109, 121, 133, 145, 157, 169, 181, 193, 205, 217, 229
	<i>Quarta</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67, 73, 79, 85
	<i>Quinta</i>	1, 14, 27, 40, 53, 66, 79, 92, 105, 118, 131, 144, 157, 170
	<i>Sexta</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67, 73
	<i>Sábado</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67, 73, 79, 85, 91, 97
3	<i>Domingo</i>	1, 13, 25, 37, 49, 61, 73, 85, 97, 109, 121, 133, 145, 157, 169, 181
	<i>Segunda</i>	1, 8, 15, 22, 29, 36, 43, 50, 57, 64, 71
	<i>Terça</i>	1, 11, 21, 31, 41, 51, 61, 71, 81, 91, 101, 111, 121
	<i>Quarta</i>	1, 10, 19, 28, 37, 46, 55, 64, 73, 82, 91, 100, 109
	<i>Quinta</i>	1, 8, 15, 22, 29, 36, 43, 50, 57, 64, 71, 78, 85
	<i>Sexta</i>	1, 11, 21, 31, 41, 51, 61, 71, 81, 91, 101, 111, 121, 131
	<i>Sábado</i>	1, 8, 15, 22, 29, 36, 43
4	<i>Domingo</i>	1, 13, 25, 37, 49, 61, 73, 85, 97, 109, 121, 133, 145, 157, 169, 181, 193, 205, 217
	<i>Segunda</i>	1, 9, 17
	<i>Terça</i>	1, 9, 17

	<i>Quarta</i>	1, 5, 9, 13, 17, 21, 25
	<i>Quinta</i>	1, 5, 9, 13, 17, 21, 25, 29, 33, 37, 41, 45
	<i>Sexta</i>	1, 7, 13
	<i>Sábado</i>	1, 8, 15, 22, 29, 36, 43, 50, 57, 64, 71, 78, 85, 92, 99
5	<i>Domingo</i>	1, 6, 11, 16, 21, 26, 31, 36, 41, 46, 51, 56, 61, 66
	<i>Segunda</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61
	<i>Terça</i>	1, 8, 15, 22, 29, 36, 43, 50, 57, 64, 71, 78, 85, 92
	<i>Quarta</i>	1, 8, 15, 22, 29, 36, 43, 50, 57, 64, 71, 78, 85
	<i>Quinta</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67, 73, 79, 85
	<i>Sexta</i>	1, 8, 15, 22, 29, 36, 43, 50, 57, 64, 71, 78, 85, 92
	<i>Sábado</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67, 73, 79
6	<i>Domingo</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67, 73, 79, 85
	<i>Segunda</i>	1, 8, 15, 22, 29, 36, 43, 50, 57, 64, 71, 78, 85, 92, 99, 106
	<i>Terça</i>	1, 8, 15, 22, 29, 36, 43, 50, 57, 64, 71, 78, 85, 92, 99, 106
	<i>Quarta</i>	1, 8, 15, 22, 29, 36, 43, 50, 57, 64, 71, 78, 85
	<i>Quinta</i>	1, 8, 15, 22, 29, 36, 43, 50, 57, 64, 71, 78, 85, 92, 99
	<i>Sexta</i>	1, 9, 17, 25, 33, 41
	<i>Sábado</i>	1, 8, 15, 22, 29, 36, 43, 50, 57, 64, 71, 78, 85, 92, 99, 106
7	<i>Domingo</i>	1, 6, 11, 16, 21, 26, 31, 36, 41, 46, 51, 56, 61, 66, 71
	<i>Segunda</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67
	<i>Terça</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61
	<i>Quarta</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67, 73
	<i>Quinta</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67, 73, 79
	<i>Sexta</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61
	<i>Sábado</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67
8	<i>Domingo</i>	1, 9, 17, 25, 33, 41, 49, 57, 65, 73
	<i>Segunda</i>	1
	<i>Terça</i>	1, 13, 25, 37, 49, 61, 73, 85, 97, 109, 121, 133, 145, 157, 169, 181, 193, 205, 217, 229, 241

	<i>Quarta</i>	1, 16, 31, 46, 61, 76, 91, 106, 121, 136, 151, 166, 181, 196
	<i>Quinta</i>	1, 9, 17, 25, 33, 41, 49, 57, 65, 73, 81
	<i>Sexta</i>	1, 10, 19, 28, 37, 46, 55, 64, 73, 82
	<i>Sábado</i>	1, 9, 17, 25, 33, 41, 49, 57, 65, 73, 81, 89, 97, 105, 113, 121
9	<i>Domingo</i>	1, 6, 11, 16, 21, 26, 31, 36, 41, 46, 51, 56, 61
	<i>Segunda</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67, 73, 79, 85
	<i>Terça</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67, 73, 79, 85, 91, 97
	<i>Quarta</i>	1, 8, 15, 22, 29, 36, 43, 50, 57, 64, 71, 78, 85, 92, 99
	<i>Quinta</i>	1, 8, 15, 22, 29, 36, 43, 50, 57, 64, 71, 78, 85
	<i>Sexta</i>	1, 8, 15, 22, 29, 36, 43, 50, 57, 64, 71, 78
	<i>Sábado</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67, 73, 79
10	<i>Domingo</i>	1, 8, 15, 22, 29, 36, 43, 50, 57, 64, 71, 78
	<i>Segunda</i>	1, 8, 15, 22, 29, 36, 43, 50, 57, 64, 71, 78
	<i>Terça</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67, 73
	<i>Quarta</i>	1, 6, 11, 16, 21, 26, 31, 36, 41, 46, 51
	<i>Quinta</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67, 73, 79
	<i>Sexta</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67, 73, 79
	<i>Sábado</i>	1, 9, 17, 25, 33, 41, 49, 57, 65, 73, 81
11	<i>Domingo</i>	1, 14, 27, 40, 53, 66, 79, 92, 105, 118, 131, 144
	<i>Segunda</i>	1, 15, 29, 43, 57, 71, 85, 99, 113, 127, 141, 155, 169, 183
	<i>Terça</i>	1, 14, 27, 40, 53, 66, 79, 92, 105, 118, 131, 144, 157, 170, 183, 196, 209
	<i>Quarta</i>	1, 15, 29, 43, 57, 71, 85, 99, 113, 127, 141, 155, 169, 183, 197
	<i>Quinta</i>	1, 14, 27, 40, 53, 66, 79, 92, 105, 118, 131, 144, 157, 170
	<i>Sexta</i>	1, 15, 29, 43, 57, 71, 85, 99, 113, 127, 141, 155, 169, 183, 197, 211
	<i>Sábado</i>	1, 8, 15, 22, 29, 36, 43, 50, 57, 64, 71, 78, 85, 92

APÊNDICE 2 - Atrasos na variável de carga para a série por tipo de dia – Sistema teste 2

<i>Barra</i>	<i>Dia da semana</i>	<i>Atrasos na variável de carga</i>
1	<i>Domingo</i>	1, 8
	<i>Segunda</i>	1, 8, 15, 22, 29
	<i>Terça</i>	1, 5
	<i>Quarta</i>	1
	<i>Quinta</i>	1, 7, 13, 19, 25
	<i>Sexta</i>	13
	<i>Sábado</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67
2	<i>Domingo</i>	1, 5, 9, 13, 17, 21, 25, 29, 33
	<i>Segunda</i>	1, 6, 11, 16, 21, 26, 31, 36, 41, 46, 51, 56
	<i>Terça</i>	1, 8, 15, 22, 29, 36, 43, 50, 57, 64, 71, 78, 85, 92, 99, 106, 113, 120
	<i>Quarta</i>	1, 9, 17, 25, 33, 41, 49, 57, 65, 73, 81, 89, 97, 105, 113, 121, 129
	<i>Quinta</i>	1, 8, 15, 22, 29, 36, 43, 50, 57, 64, 71, 78, 85, 92, 99, 106, 113
	<i>Sexta</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67, 73, 79, 85
	<i>Sábado</i>	1, 6, 11, 16, 21, 26, 31, 36, 41, 46, 51, 56, 61, 66, 71
3	<i>Domingo</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67, 73
	<i>Segunda</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67, 73, 79, 85
	<i>Terça</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67, 73, 79
	<i>Quarta</i>	1, 6, 11, 16, 21, 26, 31, 36, 41, 46, 51, 56, 61, 66, 71
	<i>Quinta</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67, 73, 79
	<i>Sexta</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67, 73, 79, 85
	<i>Sábado</i>	1, 6, 11, 16, 21, 26, 31, 36, 41, 46, 51, 56, 61, 66
4	<i>Domingo</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67, 73, 79
	<i>Segunda</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67, 73, 79, 85
	<i>Terça</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67, 73, 79

	<i>Quarta</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67, 73, 79
	<i>Quinta</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67, 73, 79
	<i>Sexta</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67, 73, 79, 85, 91
	<i>Sábado</i>	1, 6, 11, 16, 21, 26, 31, 36, 41, 46, 51, 56, 61, 66, 71, 76, 81, 86, 91, 96
5	<i>Domingo</i>	1, 7, 13, 19
	<i>Segunda</i>	1, 7, 13, 19, 25, 31, 37, 43
	<i>Terça</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67
	<i>Quarta</i>	1, 7, 13, 19, 25, 31
	<i>Quinta</i>	1, 7, 13, 19, 25, 31, 37, 43, 49
	<i>Sexta</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61
	<i>Sábado</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67, 73
6	<i>Domingo</i>	1, 6, 11, 16, 21, 26, 31, 36, 41, 46, 51, 56, 61
	<i>Segunda</i>	1, 6, 11, 16, 21, 26, 31, 36
	<i>Terça</i>	1, 6, 11, 16, 21, 26, 31, 36, 41, 46, 51, 56, 61, 66, 71
	<i>Quarta</i>	1, 6, 11, 16, 21, 26, 31, 36, 41, 46, 51, 56, 61, 66
	<i>Quinta</i>	1, 6, 11, 16, 21, 26, 31, 36
	<i>Sexta</i>	1, 6, 11, 16, 21, 26, 31, 36, 41, 46, 51, 56, 61, 66, 71, 76, 81, 86
	<i>Sábado</i>	1, 6, 11, 16, 21, 26, 31, 36, 41, 46, 51, 56, 61, 66
7	<i>Domingo</i>	1, 8, 15, 22, 29, 36
	<i>Segunda</i>	1, 8, 15, 22, 29, 36, 43, 50, 57, 64, 71, 78, 85, 92, 99, 106
	<i>Terça</i>	1, 8, 15, 22, 29, 36, 43, 50, 57, 64, 71, 78, 85, 92, 99, 106, 113, 120
	<i>Quarta</i>	1, 8, 15, 22, 29, 36, 43, 50, 57, 64, 71, 78, 85, 92, 99, 106
	<i>Quinta</i>	1, 8, 15, 22, 29, 36, 43, 50, 57, 64, 71, 78, 85, 92, 99, 106
	<i>Sexta</i>	1, 8, 15, 22, 29, 36, 43, 50, 57, 64, 71, 78, 85, 92, 99
	<i>Sábado</i>	1, 8, 15, 22, 29, 36, 43, 50, 57, 64, 71, 78, 85, 92, 99
8	<i>Domingo</i>	1, 8, 15, 22, 29, 36, 43, 50, 57, 64, 71, 78, 85, 92, 99, 106
	<i>Segunda</i>	1, 8, 15, 22, 29, 36, 43, 50, 57, 64, 71, 78, 85, 92, 99
	<i>Terça</i>	1, 8, 15, 22, 29, 36, 43, 50, 57, 64, 71, 78, 85, 92, 99, 106, 113

	<i>Quarta</i>	1, 8, 15, 22, 29, 36, 43, 50, 57, 64, 71, 78, 85, 92, 99, 106, 113, 120, 127
	<i>Quinta</i>	1, 8, 15, 22, 29, 36, 43, 50, 57, 64, 71, 78, 85, 92, 99, 106, 113, 120
	<i>Sexta</i>	1, 8, 15, 22, 29, 36, 43, 50, 57, 64, 71, 78, 85, 92, 99, 106
	<i>Sábado</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67, 73
9	<i>Domingo</i>	1, 8, 15, 22, 29, 36, 43, 50, 57, 64, 71, 78, 85, 92, 99, 106
	<i>Segunda</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67, 73, 79, 85, 91
	<i>Terça</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67
	<i>Quarta</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67, 73
	<i>Quinta</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67
	<i>Sexta</i>	1, 6, 11, 16, 21, 26, 31, 36, 41, 46, 51, 56, 61, 66, 71, 76
	<i>Sábado</i>	1, 8, 15, 22, 29, 36, 43, 50, 57, 64, 71, 78, 85, 92, 99
10	<i>Domingo</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67
	<i>Segunda</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61
	<i>Terça</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67, 73, 79, 85, 91, 97
	<i>Quarta</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67, 73, 79
	<i>Quinta</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67
	<i>Sexta</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61
	<i>Sábado</i>	1, 6, 11, 16, 21, 26, 31, 36, 41, 46, 51, 56, 61, 66, 71, 76, 81, 86
11	<i>Domingo</i>	1, 5, 9, 13, 17, 21, 25, 29, 33, 37, 41, 45, 49, 53, 57
	<i>Segunda</i>	1, 6, 11, 16, 21, 26, 31, 36, 41, 46, 51, 56, 61, 66, 71
	<i>Terça</i>	1, 5, 9, 13, 17, 21, 25, 29, 33, 37, 41, 45, 49, 53
	<i>Quarta</i>	1, 5, 9, 13, 17, 21, 25, 29, 33, 37, 41, 45, 49, 53, 57
	<i>Quinta</i>	1, 5, 9, 13, 17, 21, 25, 29, 33, 37, 41, 45, 49
	<i>Sexta</i>	1, 9, 17, 25, 33, 41, 49, 57, 65, 73, 81
	<i>Sábado</i>	1, 8, 15, 22, 29, 36, 43, 50, 57, 64, 71, 78, 85, 92, 99, 106
12	<i>Domingo</i>	1, 9, 17, 25, 33, 41, 49, 57, 65, 73, 81, 89, 97, 105, 113, 121, 129
	<i>Segunda</i>	1, 8, 15, 22, 29, 36, 43, 50, 57, 64, 71, 78, 85, 92, 99
	<i>Terça</i>	1, 8, 15, 22, 29, 36, 43, 50, 57, 64, 71, 78, 85

	<i>Quarta</i>	1, 8, 15, 22, 29, 36, 43, 50, 57, 64, 71, 78, 85, 92, 99
	<i>Quinta</i>	1, 8, 15, 22, 29, 36, 43, 50, 57, 64, 71, 78, 85, 92, 99
	<i>Sexta</i>	1, 8, 15, 22, 29, 36, 43, 50, 57, 64, 71, 78, 85
	<i>Sábado</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67, 73, 79, 85
13	<i>Domingo</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67, 73
	<i>Segunda</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67
	<i>Terça</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61
	<i>Quarta</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67, 73
	<i>Quinta</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61
	<i>Sexta</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61
	<i>Sábado</i>	1, 8, 15, 22, 29, 36, 43, 50, 57, 64, 71, 78, 85
14	<i>Domingo</i>	1, 8, 15, 22, 29, 36, 43, 50, 57, 64, 71, 78, 85, 92, 99, 106, 113
	<i>Segunda</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67, 73, 79
	<i>Terça</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67, 73, 79, 85
	<i>Quarta</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67, 73, 79
	<i>Quinta</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67, 73, 79
	<i>Sexta</i>	1, 8, 15, 22
	<i>Sábado</i>	1, 7, 13, 19, 25, 31, 37, 43, 49, 55, 61, 67, 73, 79