



EDGAR FONSECA FRANCO JUNIOR

**MODELO PARA PREVISÃO DE DEMANDA ATIVA E REATIVA UTILIZANDO
TÉCNICAS DE SELEÇÃO DE ENTRADAS E REDES NEURAIS ARTIFICIAIS**

**CAMPINAS
2013**



**UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ENGENHARIA ELÉTRICA E DE COMPUTAÇÃO**

EDGAR FONSECA FRANCO JUNIOR

**MODELO PARA PREVISÃO DE DEMANDA ATIVA E REATIVA UTILIZANDO
TÉCNICAS DE SELEÇÃO DE ENTRADAS E REDES NEURAIS ARTIFICIAIS**

Orientador: Prof. Dr. Takaaki Ohishi

Coorientador: Prof. Dr. Ricardo Menezes Salgado

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Faculdade de Engenharia Elétrica e de Computação da Universidade Estadual de Campinas para obtenção do título de Mestre em Engenharia Elétrica, na área de Engenharia de Computação.

ESTE EXEMPLAR CORRESPONDE À VERSÃO FINAL DA DISSERTAÇÃO
DEFENDIDA PELO ALUNO EDGAR FONSECA FRANCO JUNIOR
E ORIENTADA PELO PROF. DR. TAKAAKI OHISHI

**CAMPINAS
2013**

Ficha catalográfica
 Universidade Estadual de Campinas
 Biblioteca da Área de Engenharia e Arquitetura
 Rose Meire da Silva - CRB 8/5974

F848m Franco Junior, Edgar Fonseca, 1987-
 Modelo para previsão de demanda ativa e reativa utilizando técnicas de seleção de entradas e redes neurais artificiais / Edgar Fonseca Franco Junior. – Campinas, SP : [s.n.], 2013.

Orientador: Takaaki Ohishi.
 Coorientador: Ricardo Menezes Salgado.
 Dissertação (mestrado) – Universidade Estadual de Campinas, Faculdade de Engenharia Elétrica e de Computação.

1. Previsão de séries temporais. 2. Potência ativa e reativa. 3. Seleção de variáveis. 4. Redes neurais artificiais. I. Ohishi, Takaaki, 1955-. II. Salgado, Ricardo Menezes. III. Universidade Estadual de Campinas. Faculdade de Engenharia Elétrica e de Computação. IV. Título.

Informações para Biblioteca Digital

Título em outro idioma: Model for forecasting of active and reactive demand using technical selection of inputs and artificial neural networks

Palavras-chave em inglês:

Time series prediction

Active and reactive power

Variable selection

Artificial neural network

Área de concentração: Engenharia de Computação

Titulação: Mestre em Engenharia Elétrica

Banca examinadora:

Takaaki Ohishi [Orientador]

Evandro Luiz Mendes

Luiz Carlos Pereira da Silva

Data de defesa: 30-07-2013

Programa de Pós-Graduação: Engenharia Elétrica

COMISSÃO JULGADORA - TESE DE MESTRADO

Candidato: Edgar Fonseca Franco Junior


Data da Defesa: 30 de julho de 2013

Título da Tese: "Modelo para Previsão de Demanda Ativa e Reativa Utilizando Técnicas de Seleção de Entradas e Redes Neurais Artificiais"

Prof. Dr. Takaaki Ohishi (Presidente):

Dr. Evandro Luiz Mendes:

Prof. Dr. Luiz Carlos Pereira da Silva:


The image shows three handwritten signatures in blue ink, each written over a horizontal line. The first signature is 'Takaaki Ohishi', the second is 'Evandro Luiz Mendes', and the third is 'Luiz Carlos Pereira da Silva'.

*Dedico esta **Dissertação**
a todos que de alguma forma fizeram parte da minha vida.*

*Aos meus pais, **Edgar e Nailza**,
meus primeiros mestres,
que sempre acreditaram em mim,
orando, acreditando e torcendo por mim.*

*Aos **Familiares**,
que nos momentos de minha ausência,
sempre fizeram entender que o futuro,
é feito a partir da constante dedicação no presente!!!*

*À minha namorada, **Regiane**,
que mesmo nos privando da vida social em prol de nossos objetivos,
descobrimos o quanto é bom estarmos juntos ao encararmos os desafios e,
principalmente, o quanto é gratificante ter alguém com quem festejar nossas conquistas.*

*Aquelas pessoas que quando deveriam ser simplesmente **Professores**,
foram Mestres.
Que quando deveriam ser Mestres,
foram Amigos.*

*Aos verdadeiros **Amigos**,
que me incentivaram a seguir
quando nem eu mais acreditava que conseguiria.*

AGRADECIMENTOS

*Aos meus pais **Edgar Fonseca Franco** e **Nailza Rosângela Santos Franco**, por terem feito o possível e o impossível para me oferecerem a oportunidade de estudar.*

*À **Universidade Estadual de Campinas (Unicamp)**, juntamente com a **Faculdade de Engenharia Elétrica e de Computação (FEEC)** e o **Departamento de Engenharia de Sistemas (DENSIS)**, meu reconhecimento e agradecimento pela oportunidade de me formar no programa de **Pós-Graduação**.*

*À **Universidade Federal de Alfenas (UNIFAL-MG)**, em especial ao curso de **Bacharelado em Ciência da Computação (BCC)**, por criar e solidificar a minha base acadêmica.*

*Ao Prof. Dr. **Takaaki Ohishi**, pela orientação no desenvolvimento deste projeto e na elaboração desta dissertação, guiando de forma sábia os meus passos.*

*Ao Prof. Dr. **Ricardo Menezes Salgado**, por disponibilizar seus conhecimentos e pesquisas realizadas em torno deste projeto e incentivar a busca por mais conhecimento.*

*A **Mateus Neves Barretos**, por ceder várias amostras de dados para que eu pudesse realizar os experimentos.*

*Ao **Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq)**, pela bolsa concedida, sem a qual a realização deste sonho seria impossível.*

*À minha namorada, amiga e companheira de todas as horas, **Regiane Silva de Barros**, pelo carinho, compreensão, paciência e amor, além de sempre me apoiar em todas as minhas decisões.*

*À minha prima e Prof^a. **Valéria Barbosa Ferraz**, por auxiliar na correção desta monografia, tornando-a mais fácil de ser compreendida.*

*Aos demais **amigos** que, de alguma forma, ajudaram na elaboração desta dissertação e enriqueceram meus conhecimentos.*

*E a você, **amigo leitor**. Muito Obrigado!!*

“E se fosse possível prever o futuro!?”

(Autor Desconhecido)

RESUMO

Em um sistema de energia elétrica em corrente alternada, a geração, a transmissão e o consumo de energia elétrica são divididos em potência ativa e reativa. O planejamento, a operação e análise destes sistemas são baseados em estimativas futuras do consumo de energia, e neste contexto são importantes os modelos de previsão de carga ativa e reativa. Nesta dissertação são testados modelos de previsão de curto prazo para carga ativa e reativa utilizando modelos de redes neurais artificiais. Em particular, são implementados e testados várias metodologias de seleção de entradas. A seleção de um subconjunto apropriado de variáveis para a inclusão em um sistema é um passo vital no desenvolvimento de qualquer modelo. Isto é particularmente importante nos modelos de previsão como redes neurais artificiais, pois o desempenho do modelo final é fortemente dependente das variáveis de entrada utilizadas. Esta dissertação desenvolveu um modelo que dá suporte à integração de algumas técnicas de seleção (informação mútua e informação mútua parcial) tendo o intuito de facilitar a utilização destas, assim como a sua comparação quando aplicada a determinados problemas de previsão. Para os experimentos, foram trabalhados 3 barramentos (com faixas de demanda diferentes), sendo que para cada um utilizou-se da carga de potência ativa e reativa. Os resultados alcançados são dados em função do erro médio absoluto e do erro percentual médio absoluto; além dessas medidas, foi realizada uma análise sobre o fator de potência para os valores reais e previstos.

Palavras-chave: Previsão de séries temporais. Potência ativa e reativa. Seleção de variáveis. Redes neurais artificiais.

ABSTRACT

In a system of alternating current electricity, generation, transmission and consumption of electricity are divided into active and reactive power. The planning, operation and analysis of these systems are based on estimates of future energy consumption, and in this context are important predictive models of active and reactive load. This dissertation tested forecasting models for short-term active and reactive load models using artificial neural networks. In particular, are implemented and tested many methods of selection enters. The selection of an appropriate subset of variables for inclusion in a system is a vital step in the development of any model. This is particularly important in forecasting models such as artificial neural networks, due to the performance of the final model is strongly dependent on the input variables used. This dissertation developed a model that supports the integration of some techniques for selection (mutual information and partial mutual information) with the aim to facilitate the use of these, as well as, its comparison when applied to certain prediction problems. For the experiments have been worked 3 buses (with different ranges of demand), and for each one used the load active and reactive power. The results obtained are given in function of the mean absolute error and mean absolute percentage error; in addition to these measures, an analysis was made of the power factor for the actual and target values.

Keywords: *Time series prediction. Active and reactive power. Variable selection. Artificial neural networks.*

LISTA DE FIGURAS

Figura 2.1 - Representação gráfica do conjunto de variáveis aleatórias X e Y.	17
Figura 2.2 - Representação gráfica do conjunto de variáveis aleatórias X, Y e Z.	18
Figura 3.1 - Rede do sistema elétrico brasileiro (Fonte: (ONS, 2013)).	31
Figura 3.2 - Série histórica da demanda ativa da Barra-I.	34
Figura 3.3 - Série histórica da demanda reativa da Barra-I.	34
Figura 3.4 – Demanda semanal de potência ativa da Barra-I.	35
Figura 3.5 - Demanda semanal de potência reativa da Barra-I.	35
Figura 3.6 – Demanda de 1 ano de potência ativa da Barra-I.	36
Figura 3.7 – Demanda de 3 semanas de potência ativa da Barra-I.	36
Figura 3.8 – Demanda de 1 ano de potência reativa da Barra-I.	37
Figura 3.9 – Demanda de 3 semanas de potência reativa da Barra-I.	37
Figura 3.10 - Série histórica da demanda ativa da Barra-II.	38
Figura 3.11 - Série histórica da demanda reativa da Barra-II.	38
Figura 3.12 - Demanda semanal de potência ativa da Barra-II.	39
Figura 3.13 - Demanda semanal de potência reativa da Barra-II.	39
Figura 3.14 – Demanda de 1 ano de potência ativa da Barra-II.	40
Figura 3.15 – Demanda de 3 semanas de potência ativa da Barra-II.	40
Figura 3.16 – Demanda de 1 ano de potência reativa da Barra-II.	41
Figura 3.17 – Demanda de 3 semanas de potência reativa da Barra-II.	41
Figura 3.18 - Série histórica da demanda ativa da Barra-III.	42
Figura 3.19 - Série histórica da demanda reativa da Barra-III.	42
Figura 3.20 - Demanda semanal de potência ativa da Barra-III.	43
Figura 3.21 - Demanda semanal de potência reativa da Barra-III.	43
Figura 3.22 – Demanda de 1 ano de potência ativa da Barra-III.	44
Figura 3.23 – Demanda de 3 semanas de potência ativa da Barra-III.	44
Figura 3.24 – Demanda de 1 ano de potência reativa da Barra-III.	45
Figura 3.25 – Demanda de 3 semanas de potência reativa da Barra-III.	45
Figura 3.26 - Distribuições (normal e real) da Barra-I com demanda ativa.	48
Figura 3.27 - Distribuições (normal e real) da Barra-I com demanda reativa.	48

Figura 3.28 - Distribuições (normal e real) da Barra-II com demanda ativa.....	49
Figura 3.29 - Distribuições (normal e real) da Barra-II com demanda reativa.	49
Figura 3.30 - Distribuições (normal e real) da Barra-III com demanda ativa.	50
Figura 3.31 - Distribuições (normal e real) da Barra-III com demanda reativa.	50
Figura 3.32 - <i>Boxplot</i> da demanda ativa da Barra-I.	51
Figura 3.33 - <i>Boxplot</i> da demanda reativa da Barra-I.....	51
Figura 3.34 - <i>Boxplot</i> da demanda ativa da Barra-II.....	52
Figura 3.35 - <i>Boxplot</i> da demanda reativa da Barra-II.....	52
Figura 3.36 - <i>Boxplot</i> da demanda ativa da Barra-III.....	53
Figura 3.37 - <i>Boxplot</i> da demanda reativa da Barra-III.	53
Figura 4.1 – Normalização dos dados. (a) Dados Brutos, (b) MaxSerie, (c) MaxDia.	58
Figura 4.2 – Normalização dos dados. (a) MaxMin, (b) MediaVar, (c) MaxHora.	58
Figura 4.3 - Normalização de duas semanas. (a) Dados Brutos, (b) MaxSerie, (c) MaxDia.	59
Figura 4.4 - Normalização de duas semanas. (a) MaxMin, (b) MediaVar, (c) MaxHora.	59
Figura 4.5 - Intervalos de <i>lags</i> para a seleção de entradas.....	61
Figura 4.6 – Calculo do MI selecionando 3 <i>lags</i>.....	62
Figura 4.7 – Calculo do PMI selecionando 3 <i>lags</i>.....	64
Figura 5.1 - Divisão dos gráficos polares (tipo da normalização).....	75
Figura 5.2 – Divisão dos gráficos polares. (a) ordem da normalização. (b) tipo da seleção..	76
Figura 5.3 – Divisão dos gráficos polares. (a) tipo do <i>jump</i>. (b) quantidade de <i>lags</i>.....	76
Figura 5.4 - MAPE da Barra-I com demanda ativa para todas as configurações (%).	77
Figura 5.5 - MAE da Barra-I com demanda reativa para todas as configurações (MVar).	77
Figura 5.6 - MAPE da Barra-II com demanda ativa para todas as configurações (%).	78
Figura 5.7 - MAE da Barra-II com demanda reativa para todas as configurações (MVar).	78
Figura 5.8 - MAPE da Barra-III com demanda ativa para todas as configurações (%).	79
Figura 5.9 - MAE da Barra-III com demanda reativa para todas as configurações (MVar).	79
Figura 5.10 – Análise da previsão de potência ativa para Barra-I para a Semana A.	81
Figura 5.11 – Análise da previsão de potência ativa para Barra-I para a Semana B.....	81
Figura 5.12 – Análise da previsão de potência ativa para Barra-I para a Semana C.	82

Figura 5.13 – Análise da previsão de potência reativa para Barra-I para a Semana A.	83
Figura 5.14 – Análise da previsão de potência reativa para Barra-I para a Semana B.	83
Figura 5.15 – Análise da previsão de potência reativa para Barra-I para a Semana C.	84
Figura 5.16 – Análise da previsão de potência ativa para Barra-II para a Semana A.	85
Figura 5.17 – Análise da previsão de potência ativa para Barra-II para a Semana B.	85
Figura 5.18 – Análise da previsão de potência ativa para Barra-II para a Semana C.	86
Figura 5.19 – Análise da previsão de potência reativa para Barra-II para a Semana A.	87
Figura 5.20 – Análise da previsão de potência reativa para Barra-II para a Semana B.	87
Figura 5.21 – Análise da previsão de potência reativa para Barra-II para a Semana C.	88
Figura 5.22 – Análise da previsão de potência ativa para Barra-III para a Semana A.	89
Figura 5.23 – Análise da previsão de potência ativa para Barra-III para a Semana B.	89
Figura 5.24 – Análise da previsão de potência ativa para Barra-III para a Semana C.	90
Figura 5.25 – Análise da previsão de potência reativa para Barra-III para a Semana A. ...	91
Figura 5.26 – Análise da previsão de potência reativa para Barra-III para a Semana B. ...	91
Figura 5.27 – Análise da previsão de potência reativa para Barra-III para a Semana C. ...	92
Figura 5.28 - Série real e prevista (DaPh7 SCGM) para a Barra-I com demanda ativa.	93
Figura 5.29 - Série real e prevista (DdPh7 SCGM) para a Barra-I com demanda reativa. .	93
Figura 5.30 - Série real e prevista (SdMd7 SCGM) para a Barra-II com demanda ativa. ..	94
Figura 5.31 - Série real e prevista (SaMh7 SCGM) para a Barra-II com demanda reativa. 94	
Figura 5.32 - Série real e prevista (SdMd7 SCGM) para a Barra-III com demanda ativa. .	95
Figura 5.33 - Série real e prevista (SaPh7 SCGM) para a Barra-III com demanda reativa. 95	
Figura 5.34 - <i>Boxplot</i> da série prevista e real para a Barra-I com demanda ativa.	98
Figura 5.35 - <i>Boxplot</i> da série prevista e real para a Barra-I com demanda reativa.	98
Figura 5.36 - <i>Boxplot</i> da série prevista e real para a Barra-II com demanda ativa.	99
Figura 5.37 - <i>Boxplot</i> da série prevista e real para a Barra-II com demanda reativa.	99
Figura 5.38- <i>Boxplot</i> da a série prevista e real para a Barra-III com demanda ativa.	100
Figura 5.39 - <i>Boxplot</i> da série prevista e real para a Barra-III com demanda reativa.	100
Figura 5.40 - Comparativo do fator de potência real vs. previsto para a Barra-I.	108
Figura 5.41 - Comparativo do fator de potência real vs. previsto para a Barra-II.	108
Figura 5.42 - Comparativo do fator de potência real vs. previsto para a Barra-III.	109

LISTA DE TABELAS

Tabela 3.1 - Momentos amostrais para os barramentos com potência ativa.....	47
Tabela 3.2 - Momentos amostrais para os barramentos com potência reativa.	47
Tabela 5.1 - Análise dos tempos de execução do sistema (minutos).....	80
Tabela 5.2 – Momentos amostrais da Barra-I com potência ativa para as Semanas.....	82
Tabela 5.3 – Momentos amostrais da Barra-I com potência reativa para as Semanas.	84
Tabela 5.4 – Momentos amostrais da Barra-II com potência ativa para as Semanas.	86
Tabela 5.5 – Momentos amostrais da Barra-II com potência reativa para as Semanas.....	88
Tabela 5.6 – Momentos amostrais da Barra-III com potência ativa para as Semanas.....	90
Tabela 5.7 – Momentos amostrais da Barra-III com potência reativa para as Semanas.	92
Tabela 5.8 - Momentos amostrais para a série real, série prevista, ME, MAE e MAPE para os barramentos com potência ativa.....	96
Tabela 5.9 - Momentos amostrais para a série real, série prevista, ME, MAE e MAPE para os barramentos com potência reativa.	97
Tabela 5.10 – MAE semanal e horário para a Barra-I com demanda ativa (MW*).	102
Tabela 5.11 – MAE semanal e horário para a Barra-I com demanda reativa (MVar*). ..	102
Tabela 5.12 – MAE semanal e horário para a Barra-II com demanda ativa (MW*).	103
Tabela 5.13 – MAE semanal e horário para a Barra-II com demanda reativa (MVar*). ..	103
Tabela 5.14 – MAE semanal e horário para a Barra-III com demanda ativa (MW*).	104
Tabela 5.15 – MAE semanal e horário para a Barra-III com demanda reativa (MVar*). ..	104
Tabela 5.16 – Conjunto de <i>lags</i> para a Barra-I.	105
Tabela 5.17 – Conjunto de <i>lags</i> para a Barra-II.....	105
Tabela 5.18 – Conjunto de <i>lags</i> para a Barra-III.	106
Tabela 5.19 - Momentos amostrais dos fatores de potência real e previsto.	109
Tabela A.1 - Combinação de configurações.	125
Tabela A.2 - MAPE para a potência ativa da Barra-I (%).	126
Tabela A.3 - MAE para a potência ativa da Barra-I (MW).	127
Tabela A.4 - MAPE para a potência reativa da Barra-I (%).	128
Tabela A.5 - MAE para a potência reativa da Barra-I (MVar).	129
Tabela A.6 - MAPE para a potência ativa da Barra-II (%).	130

Tabela A.7 - MAE para a potência ativa da Barra-II (MW).	131
Tabela A.8 - MAPE para a potência reativa da Barra-II (%).	132
Tabela A.9 - MAE para a potência reativa da Barra-II (MVar).	133
Tabela A.10 - MAPE para a potência ativa da Barra-III (%).	134
Tabela A.11 - MAE para a potência ativa da Barra-III (MW).	135
Tabela A.12 - MAPE para a potência reativa da Barra-III (%).	136
Tabela A.13 - MAE para a potência reativa da Barra-III (MVar).	137

LISTA DE ABREVIATURAS E SIGLAS

AC	<i>Autocorrelation Criterion</i>
AG	Algoritmo Genético
ANNSTLF	<i>Artificial Neural Network Short-Term Load Forecaster – Generation Three</i>
AR	<i>Moving Average processes</i>
ARIMA	<i>Autoregressive, Integrated, Moving Average</i>
ARMA	<i>Autoregressive, Moving Average</i>
BFGS	Método de <i>Broyden-Fletcher-Goldfarb-Shanno</i>
BIAMLPs	<i>Bayesian Inference Applied to Multi-Layered Perceptrons</i>
BP	<i>Backpropagation</i>
BPM	<i>Backpropagation com Termo Momentum</i>
COSE	Laboratório de Coordenação da Operação de Sistemas Eletroenergéticos
DFP	Método de <i>Davidon-Fletcher-Powell</i>
FR	Método de <i>Fletcher-Reeves</i>
GA	<i>Genetic Algorithms</i>
GRAD	Método Gradiente
IC	<i>Independent Component</i>
ICA	<i>Independent Component Analysis</i>
IVS	<i>Input Variable Selection</i>
kV	kilo Volt
LInC	Laboratório de Inteligência Computacional
LLNF	<i>Locally Linear Neuro-Fuzzy</i>
LoLiMoT	<i>Local Linear Model Tree</i>
LS-SVM	<i>Least Squares Support Vector Machines</i>
MA	<i>Autoregressive processes</i>
MAE	<i>Mean Absolute Error</i>
MAPE	<i>Mean Absolute Percentage Error</i>
MATLAB	<i>MATrix LABoratory</i>
MCP	Modelo de McCulloch e Pits
ME	<i>Mean Error</i>
MI	<i>Mutual Information</i>

MLP	<i>Multi-layer Perceptron</i>
MOGA	<i>Multi-Objective Genetic Algorithm</i>
MVAr	mega volt-ampère reativo
MW	Megawatt
ONS	Operador Nacional do Sistema Elétrico
OSS	<i>One Step Secant</i>
PC	<i>Principal Component</i>
PCA	<i>Principal Component Analysis</i>
PIB	Produto Interno Bruto
PMI	<i>Partial Mutual Information</i>
PR	Método de <i>Polak-Ribière</i>
RNA	Rede Neural Artificial
RVM	<i>Releave Vector Machine</i>
SA	<i>Sensitivity Analysis</i>
SARIMA	<i>Seasonal, Autoregressive, Integrated, Moving Average</i>
SCGM	<i>Scaled Conjugate Gradient Method</i>
SE	Subestação
SIN	Sistema Interligado Nacional
UNICAMP	Universidade Estadual de Campinas
UNIFAL-MG	Universidade Federal de Alfenas – Minas Gerais

SUMÁRIO

AGRADECIMENTOS	IX
RESUMO.....	XIII
ABSTRACT.....	XV
LISTA DE FIGURAS	XVII
LISTA DE TABELAS.....	XXI
LISTA DE ABREVIATURAS E SIGLAS	XXIII
SUMÁRIO.....	XXV
1 INTRODUÇÃO	1
1.1 JUSTIFICATIVA E MOTIVAÇÃO.....	1
1.2 DESCRIÇÃO DO PROBLEMA.....	5
1.2.1 Pré-processamento	5
1.2.2 Seleção de Entradas	6
1.2.3 Métodos de Previsão	7
1.3 OBJETIVOS.....	8
1.3.1 Gerais.....	8
1.3.2 Específicos	8
1.4 ORGANIZAÇÃO DA DISSERTAÇÃO	8
2 REVISÃO BIBLIOGRÁFICA	11
2.1 PREVISÃO DE SÉRIES TEMPORAIS.....	11
2.1.1 Previsão de Cargas Elétricas	13
2.1.2 Previsão de Cargas por Barramento	15
2.2 MÉTODOS DE SELEÇÃO DE ENTRADAS	16
2.2.1 Autocorrelação	16
2.2.2 Informação Mútua (MI) e Informação Mútua Parcial (PMI)	17
2.2.3 Análise de Componentes Principais (PCA).....	20
2.2.4 Análise de Componentes Independentes (ICA)	21
2.2.5 Modelagem Gráfica.....	22
2.2.6 Algoritmos Genéticos (AG) e Análise de Sensibilidade (SA)	22

2.2.7 Teoria do Caos	24
2.3 MODELOS DE PREVISÃO	24
2.3.1 Redes Neurais Artificiais (RNA)	25
3 BASE DE DADOS	29
3.1 SISTEMA ELÉTRICO	29
3.2 CARGA POR BARRAMENTO	31
3.2.1 Demandas de Carga Ativa e Reativa por Barramento.....	32
3.2.1.1 Barra-I.....	33
3.2.1.2 Barra-II	38
3.2.1.3 Barra-III.....	42
3.3 ANÁLISE DA SÉRIE TEMPORAL	46
4 METODOLOGIA PROPOSTA	55
4.1 DESCRIÇÃO DA METODOLOGIA	55
4.2 PRÉ-PROCESSAMENTO.....	56
4.3 SELEÇÃO DE VARIÁVEIS	60
4.3.1 Definição dos <i>lags</i> utilizando MI.....	60
4.3.2 Definição dos <i>lags</i> utilizando PMI	63
4.3.3 Variáveis Exógenas	65
4.4 CONJUNTO DE BASES	65
4.5 MÉTODOS DE PREVISÃO.....	66
4.6 CONSIDERAÇÕES FINAIS	69
5 EXPERIMENTOS	71
5.1 CONFIGURAÇÕES	71
5.2 MEDIDAS DE AVALIAÇÃO	74
5.3 RESULTADOS	75
5.3.1 Melhores Previsões	80
5.3.2 Comparação do Fator de Potência (FP).....	107
6 CONCLUSÃO.....	111
6.1 CONCLUSÃO	111
6.2 TRABALHOS FUTUROS	113
7 REFERÊNCIAS.....	115

APÊNDICES 123

A. APÊNDICE A..... 125

1 Introdução

*“A mente que se abre a uma nova ideia,
jamais voltará ao seu tamanho original.”
(Albert Einstein)*

O Capítulo 1 apresenta a motivação e os objetivos para o desenvolvimento desta dissertação. A Seção 1.1 apresenta os motivos e a justificativa para a escolha do tema. Na Seção 1.2, é encontrada a descrição do problema (problematização). Os objetivos, gerais e específicos, são descritos na Seção 1.3. A organização é apresentada ao final do capítulo, na Seção 1.4.

1.1 Justificativa e Motivação

A previsão de uma série temporal é um importante problema em várias áreas, incluindo economia, planejamento de produção, previsão de vendas, controle de estoque, índices de mercado na bolsa de valores e consumo de eletricidade. No âmbito de problemas voltados para a energia elétrica, pode-se destacar a previsão de carga, que é um típico problema de previsão de séries temporais.

De forma geral, as previsões fornecem estimativas que são importantes em diversos processos de tomada de decisão. Tipicamente, a previsão de uma série temporal é obtida através de modelos de previsão, os quais estimam os valores futuros em função de valores já observados da própria série e de outras variáveis.

A definição de um modelo de previsão requer a escolha dos tipos de variáveis a serem consideradas, da técnica de previsão e de sua configuração. Na definição do modelo é desejável que se conheça o sistema do qual a série temporal representa, e é desejável também que se tenha conhecimento das técnicas de previsão. Nos casos reais, as possíveis configurações de entradas podem ser muito numerosas, que combinadas com a diversidade de técnicas e suas possíveis configurações, resultam em uma quantidade de combinações, cujos testes exaustivos iriam requerer um tempo e esforço muito grandes. E por isso, na prática, é comum os modelos serem escolhidos por tentativa-e-erro, no qual um conjunto bastante reduzido de alternativas são testadas.

Nesse sentido, é interessante o desenvolvimento de sistemas que facilitem este processo, tornando-o mais rápido, flexível e requerendo uma menor especialização nos métodos.

Diversos modelos têm sido propostos para resolver o problema da previsão de séries temporais. Segundo MORI e KURATA (2007), os métodos convencionais podem ser classificados nos seguintes tipos:

- modelo de regressão;
- método adaptativo;
- filtragem Kalman;
- modelo Box & Jenkins (AR, MA, ARMA, ARIMA, SARIMA, entre outros);
- sistema especialista;
- modelo de decisão fuzzy;
- rede neural artificial (RNA);
- rede radial basis function;
- modelo neuro-fuzzy;
- teoria do caos em modelo de séries temporais;

Desta lista pode-se perceber a grande variedade de diferentes métodos de previsão disponíveis e esta tende somente a crescer, dado o constante desenvolvimento de novas metodologias. É essencial perceber que não existe um método universalmente aplicável. Além da escolha da metodologia de previsão, a qualidade dos resultados está fortemente associada à correta seleção das variáveis de entrada.

Para a construção de um modelo de previsão deve-se tomar várias decisões, tais como a técnica a ser empregada e as variáveis a serem utilizadas. Supondo que a opção seja por RNA, ainda assim há outros parâmetros a serem configurados, tais como a arquitetura da rede, a função de ativação, o método de treinamento, entre outros.

Em relação às entradas, é preciso decidir quais tipos de variáveis devem ser utilizadas e, além disso, para um dado tipo de variável é preciso escolher quais dados (*lags*) farão parte do sistema. Diversas técnicas para realizar a seleção de variáveis são empregadas atualmente, porém todas possuem certo grau de erro e quase nunca estão agrupadas em um mesmo sistema, o que facilitaria a sua comparação e utilização.

O desenvolvimento de modelos de previsão de carga começou na década de 1920 (SACHDEV, BILLINTON e PETERSON, 1977), inicialmente baseado em técnicas estatísticas e modelos estocásticos, e a partir da década de 1990, a grande maioria dos modelos foram baseados em inteligência computacional, principalmente com RNAs. A maioria destas abordagens tratou do problema de previsão da carga global de curto prazo (de um dia a uma semana à frente em base horária).

Atualmente, o objetivo principal do setor de energia elétrica é atender às necessidades em termos de consumo de energia elétrica. Nesse sentido, é necessário estimar esse consumo futuro, pois uma série de decisões se baseia nestas estimativas, tais como a elaboração de planos de expansão dos sistemas de produção/transmissão/distribuição, decisões operacionais de longo, médio e curto prazo, decisões de comercialização de energia elétrica, e assim por diante. Cada uma destas diferentes áreas requer diferentes informações sobre o mercado futuro.

Por exemplo, nas decisões de longo prazo é comum trabalhar com classes de consumidores (residencial, comercial, industrial e outros (rural, serviço público e iluminação pública)), considerando um longo horizonte de tempo, o qual engloba variáveis como: crescimento populacional, e variáveis macroeconômicas (crescimento de PIB, o comportamento das taxas de juros, entre outras).

No outro extremo, têm-se decisões na operação em tempo real, que focam a operação do sistema nos próximos minutos/horas. Na operação em tempo real de um sistema de energia elétrica, um dos principais focos é a operação coordenada dos sistemas de geração e de transmissão. No caso brasileiro, o sistema de transmissão do Sistema Interligado Nacional (SIN) praticamente interliga todo o território nacional, transportando principalmente a energia elétrica gerada nas usinas hidrelétricas situadas no interior do País para o mercado consumidor, boa parte concentrada na região litorânea. Este constitui um sistema de grande complexidade operacional, dada a sua dimensão e também pela ocorrência de eventos aleatórios, tais como as saídas forçadas de equipamentos e variações bruscas na demanda de carga. Para assegurar uma operação mais segura e econômica, uma etapa importante é a de análise de operação do sistema de transmissão considerando diferentes condições operativas. Para esta análise, as demandas de carga por barramento influenciam a operação da rede.

A previsão de carga também é importante em outra etapa, a de elaboração do programa de operação do sistema para os próximos dias. Nesta etapa, faz-se necessário conhecer uma estima-

tiva da demanda de carga global ao longo do dia, como também ter uma estimativa da demanda por barramento para análise da operação dos sistemas de transmissão/distribuição.

Um problema similar à previsão de carga global é a previsão de carga por barramento, e por isso pode ser tratado por metodologias similares, como as RNAs. Porém, um aspecto que a carga por barramento diferencia da previsão global é a quantidade de previsões, no caso brasileiro, há mais de mil barramentos de carga. O desenvolvimento de modelos de previsão é ainda um processo de tentativa-e-erro, e o seu refinamento requer conhecimento e experiência em técnicas de previsão e na série temporal em estudo. No contexto de previsão por barramento, é desejável que este processo de definição dos modelos de previsão por barramento seja mais automatizado.

A previsão de carga por barramento é um tema de pesquisa deste grupo já há alguns anos ((SALGADO, 2004), (SALGADO, 2009) e (MOREIRA, SALGADO, *et al.*, 2011)). Até então, o enfoque foi desenvolver modelos de previsão por grupo de barramentos, uma abordagem que se mostrou interessante, tanto em termos de redução no tempo de cálculo das previsões, como também em termos de qualidade das previsões. Esta dissertação é uma parte deste projeto de um sistema de suporte para desenvolvimento de modelos de previsão por barramento, com o objetivo de automatizar o processo de modelagem.

Os modelos de previsão de carga de curto prazo utilizam informações disponíveis em um dado momento, como os valores de demanda de carga medidos recentemente, informações climáticas atuais e do passado recente e valores futuros previstos. Estas informações são relacionadas com as demandas futuras através de um modelo que utiliza um conjunto de entradas (informações disponíveis) com um conjunto de saídas (estimativa de cargas futuras). Para o modelo, é necessário definir a técnica de previsão (Box-Jenkins, RNA, modelos Fuzzy, modelos híbridos, entre outros); após a escolha da técnica, abre-se uma gama de possibilidades, impossível de testá-las exaustivamente.

Outro aspecto é a escolha do histórico de treinamento que tem uma grande influência no desempenho do modelo. Alguns modelos utilizam somente informações recentes (as últimas semanas), enquanto outros requerem o treinamento utilizando dados de mais de um ano. Não há ainda desenvolvimento teórico que determine qual o melhor modelo para cada caso, de forma que na prática, a definição é por tentativa-e-erro, no qual somente um subconjunto muito restrito de possibilidades são testadas.

1.2 Descrição do Problema

O processo de elaboração de um modelo de previsão pode ser resumido em etapas. A primeira etapa é de preparação dos dados, quando os mesmos são transformados no formato adequado e com a consistência verificada. A segunda etapa é de seleção de entradas, quando são escolhidos os tipos de variáveis a serem consideradas na entrada do modelo e o seu formato. A terceira e última etapa é a seleção da técnica de previsão e a sua configuração. A seguir detalham-se cada uma dessas etapas.

1.2.1 Pré-processamento

O pré-processamento de dados é uma etapa essencial para importantes áreas de pesquisas como a modelagem de sistemas, mineração de dados, previsores, reconhecimento e classificação de padrões. Tais problemas normalmente apresentam alta dimensão (na ordem de dezenas, centenas ou milhares de variáveis), criando assim problemas no processo de aprendizagem.

No pré-processamento, várias técnicas são utilizadas para captação, organização, tratamento e preparação dos dados. São etapas que compreendem desde a detecção e correção de dados errados, formatação e transformação dos dados. Segundo REZENDE (2005), diversas transformações podem ser executadas na etapa de pré-processamento dos dados, entre elas:

- **extração e integração:** consiste na obtenção e unificação (consistência) dos dados em uma ou mais fontes de informação (arquivos texto, banco de dados, planilhas);
- **transformação:** adequação dos dados para serem utilizados nos algoritmos de extração de padrões (normalização, transformações estatísticas);
- **limpeza:** tratamento realizado sobre os dados selecionados de forma a assegurar a qualidade (erro de digitação, erros na leitura de dados, veracidade, integridade);

1.2.2 Seleção de Entradas

A seleção de entradas é uma das mais custosas dentro do pré-processamento de dados, pois a qualidade dos dados reflete diretamente na qualidade do conhecimento gerado a partir desses dados (MICHALSKI, BRATKO e KUBAT, 1998). Esse problema torna-se ainda mais complexo ao se trabalhar com dados temporais, pois a ordem desses dados constitui uma informação valiosa para sua compreensão.

Em um modelo de previsão, as entradas são as variáveis que serão levadas em conta para estimar os valores futuros. A ideia é que cada entrada contribua com alguma informação sobre valores futuros, e nesse sentido há uma tendência a incluir um conjunto maior de entradas com o objetivo de fornecer mais informações. Mas, na prática, observa-se que incluir um número muito grande de entradas nem sempre resulta em melhores resultados. Com um número maior de entradas, tem-se uma quantidade maior de informações que são fornecidas ao modelo, mas é possível que parte destas informações acrescente características que não são interessantes do ponto de vista de previsão. Por outro lado, um número muito reduzido de entradas também não é interessante, pois características importantes podem não ser apreendidas pelo modelo.

A escolha inadequada das variáveis assim como a sua quantidade tem um forte impacto sobre o espaço de memória e tempo de processamento do modelo. Para obter melhores resultados, várias metodologias necessitam de um conjunto adequado de dados, portanto, a seleção de um subconjunto de variáveis visa escolher o menor número de entradas que representem adequadamente o sistema que se pretende estimar, e dessa forma obter um modelo mais parcimonioso.

A grande maioria dos modelos de previsão de carga de curto prazo utiliza como entrada valores de carga do passado recente, com horizonte de curto prazo. A demanda de carga é muito influenciada pelas condições climáticas, principalmente temperatura e umidade. Neste caso específico, a seleção de entradas precisa determinar quais dados de carga (*lags*) devem ser incluídos no conjunto de entrada. E no caso das variáveis climáticas, há em geral dois aspectos a serem considerados, é preciso definir qual o formato dos dados (pode-se considerar o valor máximo, mínimo ou médio das variáveis climáticas) e o seu *lag* (quantos dias passados do momento atual).

Lag é definido como sendo um instante ou momento anterior ao estado atual, consequentemente *lags* é um conjunto de instantes. Em uma série temporal, o *lag* indica que uma dada informação está a um determinado período de tempo da informação a ser analisada.

A qualidade da previsão de qualquer modelo está fortemente associada à correta escolha das variáveis. Se tais variáveis não são suficientemente representativas do problema a ser modelado, a capacidade de ajuste e previsão do modelo fica comprometida (VELÁSQUEZ, 2006).

1.2.3 Métodos de Previsão

Segundo BARBANCHO (1970), previsão é uma manifestação relativa a sucessos desconhecidos em um futuro determinado. A previsão não constitui um fim em si, mas um meio de fornecer informações e subsídios para uma consequente tomada de decisão, visando atingir determinados objetivos (MORETTIN e TOLOI, 1981).

O objetivo principal de um previsor é a obtenção de modelos com boa capacidade de generalização, tendo como base o conjunto de dados. A ideia é estabelecer uma relação entre as entradas e a saída que se pretende estimar.

Esta relação entre entradas e saídas depende da técnica de previsão selecionada. Muitos dos modelos estocásticos estabelecem uma relação linear entre as entradas e as saídas, enquanto outras técnicas (como RNAs, redes neuro-fuzzy, filtro de Kalman, etc) fazem o uso das relações contidas no conjunto de dados, a partir do qual os modelos apreendem os comportamentos característicos. Por isso, é importante que o conjunto de dados utilizados (seleção de entradas) seja representativo do comportamento do sistema.

O problema de previsão não requer uma estrutura específica para a sua solução, podendo o mesmo ser tratado como um problema de aproximação de funções, considerando que a saída do sistema seja uma função das entradas e saídas anteriores.

A escolha da estrutura determina diretamente a qualidade do modelo obtido. O grande desafio no desenvolvimento de modelos é selecionar a melhor, entre as inúmeras soluções possíveis.

Há uma variedade enorme de métodos de previsão, cada qual com suas capacidades e limitações (WHEELWRIGHT e MAKRIDAKIS, 1985). É possível utilizar uma grande variedade de métodos para descrever o comportamento de uma série particular. A seleção do método de previsão adequado depende de vários fatores, tais como o comportamento do fenômeno observável ou o conhecimento a priori sobre a natureza da série e do objetivo em análise.

1.3 Objetivos

1.3.1 Gerais

Este projeto objetiva desenvolver um sistema de suporte que integre as técnicas de seleção de variáveis de entrada (MI e PMI), com métodos de previsão (RNAs com arquiteturas MLP (*Multi-layer Perceptron*)) para problemas de carga elétrica. O intuito é fornecer, em função dos parâmetros especificados pelo usuário, subsídios relevantes para a escolha da técnica de seleção de variáveis que melhor esteja associado ao método de previsão para o problema a ser trabalhado.

1.3.2 Específicos

Têm-se como objetivos secundários:

- compreender e analisar as diferentes técnicas de seleção de variáveis;
- examinar a utilização de diferentes subconjuntos de valores necessários para a resolução de problemas;
- construir uma ferramenta que integre as técnicas de seleção e redução de dados;
- analisar a diferença de desempenho em alguns problemas de séries temporais;
- apresentar os fatores influenciadores no quesito de consumo computacional;
- apresentar possíveis soluções para melhor aproveitar os recursos computacionais disponíveis;
- avaliar estatisticamente os resultados obtidos com o intuito de validar o sistema proposto, tornando hábil a divulgação dos conhecimentos obtidos e práticas aplicadas.

1.4 Organização da Dissertação

Este trabalho encontra-se dividido nos seguintes capítulos:

O Capítulo 2 apresenta uma contextualização em torno da previsão de séries temporais para a previsão de cargas, inserindo seus conceitos e variações. Após a definição, são apresentadas as diferentes técnicas de seleção de entradas. Por fim, também são apresentados os processos envolvidos para a previsão, utilizando redes neurais.

No Capítulo 3, é apresentada a base de dados. Descreve-se sucintamente o sistema elétrico onde está localizada a base de dados. Por fim, uma análise dessa base é realizada.

O Capítulo 4 apresenta a proposta principal deste projeto, expondo as técnicas de seleção de entrada e os métodos de previsão. As técnicas de seleção utilizadas foram a MI e PMI, com a implementação de algumas combinações para o seu uso. Já as redes neurais foram os métodos utilizados para previsão, variando os algoritmos de treinamento (BFGS, DFP, FR, GRAD, OSS, PR e SCGM).

Os experimentos realizados são apresentados no Capítulo 5, no qual é descrito a metodologia aplicada e as configurações utilizadas para a execução dos experimentos. São apresentados os resultados obtidos (para uma semana à frente e um ano à frente) com os diferentes barramentos utilizados, juntamente com uma análise para os resultados mais prósperos e apresentado os *lags* utilizados. Há uma comparação dos fatores de potência reais e previstos, além da análise dos tempos de execução e dos resultados em geral.

O Capítulo 6 apresenta as conclusões gerais em torno da dissertação, as principais contribuições e os possíveis trabalhos futuros.

As referências bibliográficas estão disponíveis no Capítulo 7.

Por fim, no Apêndice A, é descrito o processo de criação e execução das configurações, além de serem apresentados os resultados MAPE e MAE para todas as configurações testadas nos barramentos com demanda ativa e reativa.

2 Revisão Bibliográfica

*“Se queres prever o futuro,
estuda o passado.”
(Confúcio)*

O Capítulo 2 faz uma descrição dos processos envolvidos na previsão de séries temporais, enfocando a previsão de carga de curto prazo por barramento e técnica de seleção de entradas em modelos de previsão. A Seção 2.1 apresenta uma introdução às séries temporais, assim como a importância de prevê-las. Os métodos de seleção de entradas e algumas aplicações são apresentados na Seção 2.2. Na Seção 2.3, é feita uma descrição de sistemas previsão e um detalhamento das técnicas conhecidas.

2.1 Previsão de Séries Temporais

Uma série temporal é constituída por um conjunto de observações realizadas no tempo, em geral, em intervalos de tempo igualmente espaçados. Segundo MORETTIN e TOLOI (2006), dada uma série temporal $S(t_1), \dots, S(t_n)$, observada nos instantes $t_1, \dots, t_n$, os objetivos da análise de séries temporais são:

- a) investigar o mecanismo gerador da série temporal;
- b) descrever o comportamento da série;
- c) procurar periodicidades relevantes nos dados;
- d) fazer previsões de valores futuros, que podem ser a curto, médio ou a longo prazo;

Considerando apenas a previsão, pode-se defini-la como sendo a análise, estudo e/ou cálculo realizado previamente de algo que deverá ocorrer no futuro. Na prática, os procedimentos de previsão utilizados variam muito, podendo ser simples e intuitivos ou mais quantitativos e complexos. No primeiro caso, pouca ou nenhuma análise de dados é envolvida, enquanto no segundo caso, esta análise pode ser considerável.

A previsão de séries temporais (seja de carga elétrica, climática, econômica ou outra série), é difícil de ser realizada com exatidão dada a sua natureza aleatória, por isso, é importante entender os fatores que têm maior impacto sobre a série. Tal conhecimento é, muitas vezes, adquirido por especialistas e num processo de tentativa-e-erro. No entanto, fatores selecionados de forma manual requerem primeiramente a dedicação de um especialista para isso, o que nem sempre é disponível, e além disso, a solução obtida nem sempre é ideal, por causa da sua subjetividade. Assim, diferentes modelos são construídos com o intuito de selecionar os fatores relevantes, automaticamente, a partir de dados históricos.

Segundo VELÁSQUEZ (2006), a previsão de carga tem sido uma das áreas de maior pesquisa em Engenharia Elétrica. Neste esforço, a maioria das técnicas são baseadas na estatística, em modelos estocásticos e nas chamadas técnicas de inteligência computacional. As ferramentas estatísticas e modelos estocásticos mais usados são:

- modelos de regressão linear univariados ou multivariados;
- modelos de alisamento exponencial;
- modelos baseados em filtros de Kalman;
- modelos Box Jenkins e suas variações (AR, MA, ARMA, ARIMA, SARIMA),

No grupo das técnicas inteligentes, merecem destaque especial as Redes Neurais Artificiais (RNA), tema que surge em centenas de artigos, nos últimos anos. Outras técnicas, como sistemas *fuzzy* e sistemas especialistas, também têm sido o interesse dos pesquisadores.

Segundo VELÁSQUEZ (2006) além da escolha da metodologia de previsão, a qualidade dos resultados na projeção de carga está fortemente associada à correta escolha das variáveis de entrada. Se tais variáveis não apresentam dependência com a variável de carga, a capacidade de ajuste e previsão do modelo fica comprometida. Muitos métodos, tais como informação mútua, informação mútua parcial, análise de componentes principais, análise de componentes independentes, autocorrelação, entre outros foram criados para lidar com a seleção de entradas.

Uma premissa importante na previsão de séries temporais é que o sistema em estudo se comporte futuramente de maneira similar ao seu passado, e nesse sentido, os valores anteriores da série podem ser usados para prever valores futuros. Dada esta suposição, uma questão importante é quantos períodos de *lag* devem ser incluídos na previsão do futuro. De acordo com HUANG,

NAKAMORI e WANG (2004) o ideal seria um pequeno número de *lags* que possam prever as características únicas incorporadas nos dados.

A inclusão de *lags* excessivos pode afetar negativamente a qualidade das previsões obtidas e também o tempo de treinamento do modelo, e o algoritmo provavelmente ficará preso em ótimos locais. Por outro lado, se a quantidade de *lags* for menor do que o requerido, a acurácia da previsão será prejudicada porque a busca fica limitada a um subespaço. Poucos ou muitos *lags* afetam a aprendizagem ou a capacidade de previsão. É desejável reduzir o número a um mínimo absoluto de *lags* essenciais.

2.1.1 Previsão de Cargas Elétricas

A previsão de cargas elétricas é uma das principais funções de um centro de controle de sistemas elétricos. O conhecimento futuro da carga auxilia no bom desempenho dos sistemas elétricos, isto é, no fornecimento de energia com qualidade, segurança e confiabilidade a um custo mínimo.

Com a competitividade do mercado de energia, em consequência da desregulamentação dos sistemas de potência, a eletricidade tem-se tornado uma mercadoria a ser vendida e comprada levando a grande competição no mercado, no qual o risco de perda tem de ser mínimo. Logo, a previsão de cargas exerce um papel importante para os sistemas de potência e influi de forma significativa nos preços das tarifas elétricas (NOSE, LOTUFO e LOPES, 2008).

A previsão de carga é comumente classificada em três horizontes de previsão: curto, médio e longo prazo. Segundo VELÁSQUEZ (2006), cada uma destas previsões tem importância para as empresas elétricas.

- a previsão de curto prazo é usada para determinar o despacho de carga (SALGADO, OHISHI e BALLINI, 2010), (MOREIRA, SALGADO, *et al.*, 2011);
- a previsão de médio prazo é necessária para programar a manutenção e os intercâmbios de carga (OHISHI, FARIAS, *et al.*, 2005), (SIQUEIRA e SALGADO, 2011);
- a previsão de carga de longo prazo é útil para embasar análises financeiras e de planejamento do sistema elétrico (SOARES, SECUNDINO, *et al.*, 2012).

Realizar a previsão de cargas com precisão é muito importante, já que é através dela que se estabelecem quando e quanto de capacidade de geração e transmissão deve-se dispor para atender a carga prevista, sem interrupções no fornecimento. Uma previsão subdimensionada pode facilmente levar a um corte de carga e, conseqüentemente, perda de faturamento. Por outro lado, uma previsão superdimensionada pode acarretar problemas financeiros, por força de um excessivo investimento alocado em um sistema, cuja capacidade não está sendo corretamente utilizada (NOSE, LOTUFO e LOPES, 2008).

De forma geral, se o mercado de eletricidade possui um sistema de previsão de demanda de carga que execute esta tarefa com um erro mínimo, ou seja, o método desenvolvido seja bastante preciso, este mercado terá uma maximização dos seus lucros com a redução das suas possíveis perdas.

De acordo com NOSE, LOTUFO e LOPES (2008) existem diversas aplicações na área de sistemas de potência onde a previsão de carga também possui um alto grau de importância. São elas: geração econômica de potência, controle de distribuição e operação, planejamento de manutenção, segurança do sistema, entre outras.

Qualquer que seja a classificação feita para os modelos de séries temporais, pode-se considerar um número muito grande de modelos diferentes para descrever o comportamento de uma série particular. A construção destes modelos depende de vários fatores, tais como o comportamento do fenômeno ou o conhecimento a priori que temos de sua natureza e do objetivo da análise. Na prática, depende da existência de métodos apropriados de estimação e da disponibilidade de programas adequados (MORETTIN e TOLOI, 2006).

Mais especificamente em relação aos modelos de previsão de carga, este é um tema de interesse das empresas do setor de energia elétrica, praticamente desde os seus primórdios, como atesta um levantamento bibliográfico realizado por SACHDEV, BILLINTON e PETERSON (1977), que identifica um artigo escrito em 1918 (REYNEAU, 1918), o qual destaca a importância da previsão de carga no planejamento e operação de um sistema de energia elétrica.

Dada a importância do tema e a sua longa história, é natural que muitas abordagens tenham sido propostas. Num levantamento parcial de metodologias de previsão de carga apresentados nos artigos de SACHDEV, BILLINTON e PETERSON (1977), GROSS e GALIANA (1987) e HIPPERT, PEDREIRA e SOUZA (2001), estão relacionados aproximadamente duas centenas de artigos. Como a maioria das abordagens tratam de sistemas específicos, fica difícil identificar

as melhores metodologias, pois isso requer a comparação destes métodos em um ambiente comum a todos. Destas revisões bibliográficas, constata-se que a grande maioria dos modelos trata do problema de previsão de carga global de curto prazo (de algumas horas ou dias à frente).

Em relação aos modelos de previsão de curto-prazo, há uma diversidade em termos de técnicas, tais como os métodos estatísticos, modelos estocásticos, redes neurais artificiais, e muitos outros. Além disso, há muitas variações de modelagem em uma dada técnica específica. Por exemplo, considerando os modelos baseados em redes neurais, a grande maioria das metodologias propostas utilizam redes com arquitetura MLP, tendo como entradas cargas verificadas recentemente, os valores de temperatura de passado recente e os valores previstos para os próximos dias (PARK, EL-SHARKAWI, *et al.*, 1991), (KIARTZIS, ZOUMAS, *et al.*, 1997) e (BAKIRTZIS, PETRIDIS, *et al.*, 1996).

Porém, mesmo nas redes MLP, há outras variações como na metodologia proposta por KHOTANZAD, AFKHAMI-ROHANI, *et al.*, (1997) denominada *ANNSTLF* (“*Artificial Neural Network Short-Term Load Forecaster – Generation Three*”), que certamente é uma das metodologias mais aplicadas em diferentes empresas. O *ANNSTLF* utiliza dois modelos de redes MLP, sendo que um modelo estima a carga básica e o outro modelo estima a variação na carga em relação ao dia anterior. Assim, para uma mesma técnica há variações tanto em termos das entradas e saídas consideradas, mas também há variações nas estruturas e combinações de modelos.

Além das redes MLP, há outras abordagens que utilizam outras estruturas de RNAs, como por exemplo, as redes recorrentes (VERMAAK e BOTHAS, 1998), ou modelos adaptativos que levam em conta também o erro verificado na previsão realizada previamente (PENG, HUBELE e KARADY, 1993). Outra variação muito comum são os modelos híbridos, que combinam diferentes técnicas, como por exemplo, redes neurais e com lógica Fuzzy (PIRAS, GERMOND, *et al.*, 1995) e (KIM, PARK, *et al.*, 1995). Dessa breve análise dos modelos de previsão de carga de curto prazo, fica evidente a dificuldade de escolher a melhor metodologia para um dado caso.

2.1.2 Previsão de Cargas por Barramento

Há poucos modelos específicos para previsão de carga ativa por barramento (SALGADO, 2009) e modelos que tratam a demanda ativa e reativa são menos exploradas ainda. LEITE

(1997) desenvolveu modelos de previsão de carga ativa e reativa baseado em modelos auto-regressivos não-lineares. REIS e SILVA (2004) utilizou transformada wavelet discreta para um previsor baseado redes neurais artificiais. E, ANTUNES e MINUSSI (2012) desenvolveu modelo utilizando rede neural ART-ARTMAP-FUZZY.

2.2 Métodos de Seleção de Entradas

Na literatura, não é comum encontrar ferramentas computacionais que trabalhem com várias técnicas de seleção de dados. Em linhas gerais, pode-se afirmar que a grande maioria dos softwares ou ferramentas encontrados preocupa-se apenas em realizar a seleção com um ou dois métodos, onde essas aplicações são voltadas para sistemas específicos.

A preocupação com quais variáveis deve-se trabalhar vem desde os primeiros modelos de previsão de carga, pois esta decisão é parte importante no desenvolvimento de uma metodologia de previsão. Na prática, ainda as seleções são feitas por tentativa-e-erro, mas muitas técnicas de seleção já foram propostas e utilizadas em aplicações específicas.

Um dos objetivos desta dissertação é testar algumas destas técnicas de seleção de entradas no problema de previsão de carga de curto prazo, sendo o foco principal a utilização de técnicas de seleção de dados. Ao longo desta Seção, serão apresentadas apenas as técnicas mais comumente utilizadas para a seleção de variáveis de entrada nos problemas de previsão de séries.

2.2.1 Autocorrelação

Correlação é o grau em que duas ou mais informações são linearmente associadas. Em um plano bidimensional, o grau de correlação entre os valores nos dois eixos é quantificado pelo coeficiente de correlação. Este coeficiente mede o grau de correlação entre as observações vizinhas de dados em séries temporais. Correlacionando os valores de uma variável X com valores correspondentes em tempos diferentes, denomina-se autocorrelação.

A função de autocorrelação é extremamente útil na obtenção de uma descrição parcial de uma série para a previsão, pois informa o quanto uma variável aleatória é capaz de influenciar seus vizinhos. Assumindo as séries temporais x_t , a função é estimada da seguinte forma (Eq. 2.1):

$$R(k) = \frac{E[(x_t - \mu)(x_{t+k} - \mu)]}{\sigma^2} \quad \text{Eq. 2.1}$$

Onde $E[.]$ é definido como o valor médio ou expectativa da expressão, k como o deslocamento no tempo e σ^2 a variância da variável x_t .

Segundo a definição, o valor da autocorrelação está entre 1 (correlação perfeita) e -1, o que significa anti-correlação perfeita. O valor 0 significa total ausência de correlação.

HUANG, NAKAMORI e WANG (2004) utilizaram o critério autocorrelação (*autocorrelation criterion* - AC) para determinar as variáveis de entrada da rede neural para os problemas de previsão de séries. Não foram assumidas quaisquer hipóteses, completamente independente de classe de modelo. Foi aplicada a abordagem AC para determinar as variáveis de entrada para a previsão e comparar o desempenho com outras estruturas. Os resultados dos experimentos mostram que o AC supera os outros modelos, com base no critério de seleção da amostra por modelo.

2.2.2 Informação Mútua (MI) e Informação Mútua Parcial (PMI)

Informação Mútua (*Mutual Information* - MI) ou trans-informação tem sido usada com sucesso para medir a dependência entre as variáveis de entrada e de saída (Figura 2.1). Em contraste com o coeficiente de correlação linear, que muitas vezes constitui a base empírica para abordagens de seleção de variáveis, a MI é capaz de medir as dependências com base em relações lineares e não lineares, tornando-o adequado para uso com sistemas complexos não-lineares.




Figura 2.1 - Representação gráfica do conjunto de variáveis aleatórias X e Y.

A metodologia baseada em MI para a seleção de variáveis de entrada é introduzida para melhorar o desempenho de tarefas de previsão, mesmo quando valores defasados das séries temporais são os únicos sinais de entrada possíveis. O método pode ser usado para eliminar *lags* menos úteis, reduzindo assim o número de parâmetros e melhorando o desempenho.

A MI avalia a relação entre duas variáveis aleatórias. A informação mútua $MI(X; Y)$ de duas variáveis aleatórias pode ser definida como a redução da incerteza com relação a Y devido à observação de X . A definição matemática é dada pela Eq. 2.2:

$$MI(X; Y) = H(X) + H(Y) - H(X; Y) \quad \text{Eq. 2.2}$$

Onde H é definido como a entropia do dado (Eq. 2.3):

$$H(X) = - \int f_X(x) \ln f_X(x) dx \quad \text{Eq. 2.3}$$

Sendo $MI(X; Y)$ igual a 0 (zero), se X e Y são variáveis independentes, então X não possui nenhuma informação de Y , e vice-versa. Os demais valores $MI(X; Y)$ determina se X e Y são idênticos, isto é, o quão dependente X é de Y ou Y é de X .

O critério MI não leva em conta as interdependências entre mais de duas variáveis candidatas. Para resolver este problema, SHARMA (2000) desenvolveu um algoritmo que explora o conceito de Informação Mútua Parcial (*Partial Mutual Information* - PMI), que é o análogo estatístico não-linear de correlação parcial. O PMI representa as informações entre duas observações que não está contido ($PMI(X; Y; Z)$ igual a 0) ou está contido ($PMI(X; Y; Z)$, diferente de 0) em uma terceira observação (Figura 2.2).




Figura 2.2 - Representação gráfica do conjunto de variáveis aleatórias X , Y e Z .

A pontuação PMI entre o candidato X e Y de saída é calculada considerando-se os resíduos de ambas as variáveis, uma vez que os efeitos existentes Z foram tidos em conta. Em outras

palavras, a dependência arbitrária entre as variáveis é removida por computação para cada um dos resíduos.

Esta abordagem precisa de um critério para avaliar se cada variável selecionada é de fato uma variável de entrada significativa para a saída do sistema. Diferentes métodos para terminar o algoritmo foram propostos:

- técnica de estimativa *bootstrap* (SHARMA, LUK, *et al.*, 2000), (SHARMA, 2000);
- abordagens computacionalmente menos intensivas (MAY, DANDY, *et al.*, 2008);
- teste *Hampel*, uma modificação do Z-teste comumente adotada para encontrar *outliers* dentro de uma população de valores (MAY, DANDY, *et al.*, 2008).

MESIN, ORIONE, *et al.* (2010) utilizaram o PMI, com o teste de *Hampel*, como critério de parada para determinar os parâmetros meteorológicos que estão envolvidos na dinâmica da poluição do ar (temperatura, umidade relativa, velocidade do vento e direção, pressão atmosférica, radiação solar e chuva). Este trabalho utilizou o RNA realimentado com uma camada oculta, saída simples e função tangente hiperbólica.

FERNANDO, MAIER, *et al.* (2005) utilizou também o PMI com o teste de *Hampel*, por ser uma técnica robusta de detecção de *outlier*. A técnica de *bootstraps* não foi utilizada por requerer muitas iterações para poder aumentar a confiança do problema, o que diminuiria sua eficiência computacional. Para a previsão da salinidade no Rio Murray, no sul da Austrália foi aplicada o teste de *Hampel*. O método utilizado foi a RNA do tipo *backpropagation* com termo momentum com uma camada oculta, sendo identificadas 11 entradas significativas, a partir de 1323 entradas candidatas.

MARALLOO, KOUSHKI, *et al.* (2009) é uma evolução do trabalho de VAHABIE, YOUSEFI, *et al.* (2007), onde ambos apresentam uma metodologia para selecionar as variáveis de entrada para a previsão de carga a curto e longo prazo. Foi utilizada a modelagem neuro-fuzzy com metodologia de entrada de seleção com base em MI, com o objetivo de maximizar a relevância entre as entradas e saída, e minimizar a redundância de entradas selecionadas para os dados históricos da rede elétrica norte-americana.

A ideia principal foi utilizar o *Locally Linear Neuro-Fuzzy* (LLNF) com função de aproximação, para dividir o espaço de entrada em pequenos subespaços lineares com funções de validade difusa. Um modelo LLNF com aprendizagem em árvore (*Local Linear Model Tree* - Lo-

LiMoT) foi implementado para previsão de carga de longo prazo. Os experimentos mostram que o desempenho do LoLiMoT com MI para seleção de entrada, com base em previsões de longo prazo de carga é melhor do que a do LoLiMoT com MI sem seleção de entrada.

Por fim, MAY, DANDY, *et al.* (2008) utilizaram o algoritmo PMI modificado para o desenvolvimento de modelos de RNA para previsão residual nos sistemas de distribuição de água. O principal benefício da abordagem é que ele identifica o número mínimo de variáveis de entrada para o RNA fazer a previsão residual, sem perda de precisão da previsão.

Como resultado, as RNAs produzidas são mais simples e mais facilmente interpretadas. Além disso, a análise estatística das relações de entrada-saída faz parte do processo de IVS (*input variable selection*) e fornece esclarecimentos adicionais sobre a importância relativa de cada uma das variáveis de entrada do RNA.

2.2.3 Análise de Componentes Principais (PCA)

A Análise de Componentes Principais (*principal component analysis* - PCA) é uma técnica estatística não supervisionada para extrair informações a partir de conjuntos de dados multivariados (técnica desenvolvida por (PEARSON, 1901) e aperfeiçoada por (HOTELLING, 1933)). Isto é conseguido através da identificação de componentes principais (*principal components* - PC), que são combinações lineares das variáveis originais.

A variabilidade máxima do conjunto de dados original multivariada é representada pelo primeiro componente principal e o segundo explica as variações máximas do conjunto de dados residuais; enquanto o terceiro descreve a variabilidade mais importante do próximo conjunto de dados residuais, e assim por diante. Segundo VASCONCELOS (2006), o PCA é um método estatístico linear que encontra os autovalores e autovetores da matriz de covariância dos dados e, com esse resultado, pode-se realizar a redução dimensional dos dados e analisar os padrões principais de variabilidade presentes.

O objetivo é encontrar uma transformação mais representativa e geralmente mais compacta das observações. Geralmente, grande parte da variância dos dados é explicada por um número reduzido de componentes, sendo possível descartar as variáveis restantes sem grande perda de

informação (MARQUES, 2006). A vantagem do PCA reside no fato de que os componentes principais, por sua própria natureza, não estão correlacionados.

LIU e YANG (2008) apresentaram um método para previsão de carga baseado em PCA e *Least Squares Support Vector Machines* (LS-SVM). A previsão de carga é obtida em duas etapas, primeiro extraindo os componentes principais irrelevantes de vários fatores de carga e, depois, analisando os componentes principais para prever a carga de pelo LS-SVM. O modelo híbrido foi testado e comparado com o LS-SVM, sem compressão das entradas. Os resultados mostraram que o modelo proposto obtém uma previsão mais precisa e rápida do que a convencional.

2.2.4 Análise de Componentes Independentes (ICA)

A técnica chamada Análise de Componentes Independentes (*independent component analysis* - ICA) é usada para extrair os componentes independentes (*independent component* - ICs) de um conjunto de séries temporais mensais sobre uma ampla gama de variáveis. O ICA é um processo que reduz estatisticamente os dados muito complexos de conjunto em um sub-conjunto de componentes que são estatisticamente independentes. Este procedimento reduz o número de variáveis, condensando o conjunto de informações a um conjunto muito menor de ICs. Esses ICs são esperados para capturar a maioria das informações úteis sobre os eventos subjacentes que formam a base do problema.

O ICA é um processo que extrai um vetor de sinais de um novo conjunto de componentes estatisticamente independentes. Estes componentes representam estimativas da fonte de dados original. Este processo pressupõe uma matriz de série temporal que tem um processo misturado e que pode ser ordenada, e quando assume que há tantos sinais observados como fontes, a separação ocorre e se pode encontrar a matriz que melhor define o movimento das variáveis. O fato de duas variáveis aleatórias não serem correlacionadas, também não implica que elas sejam independentes.

CICHOCKI, LEONOWICZ, *et al.* (2005) utilizaram o ICA para previsões de séries temporais financeiras com um horizonte de 12 meses e outro, variando de 1 a 6 meses. Resultados estatísticos indicam que as previsões realizadas com variáveis baseadas na técnica ICA, com seleção por ICs, obteve previsões positivas.

2.2.5 Modelagem Gráfica

Os coeficientes de correlação entre as variáveis parecem úteis, mas geralmente incluem erros devido à correlação parcial (estabelece o grau de associação entre duas variáveis depois de se encontrar ou eliminar a parcialidade de uma terceira). Como resultado, é impossível compreender a relação entre a entrada e a variável de saída apenas através dos coeficientes de correlação. Para superar o problema, os coeficientes de correlação parciais são utilizados para avaliar os melhores resultados. No entanto, eles ainda têm uma desvantagem, pois avaliam pequenos coeficientes de correlação parciais para as variáveis que não são originalmente relacionadas com a variável de saída. Ou seja, esses coeficientes são redundantes no sentido de que o modelo com menos parâmetro deve ser construído a partir de um ponto de vista do princípio da parcimônia.

DEMPSTER (1972) desenvolveu um método para a seleção de covariância da matriz de coeficiente de correlação. O método faz com que os coeficientes que possuem pequena correlação, sob a hipótese zero, sejam condicionalmente independentes. WERMUTH e SCHEIDT (1977) propôs um método para estimar a variação dos coeficientes pelo algoritmo iterativo, o método é chamado de modelagem gráfica.

O método é baseado em modelagem gráfica, leva em conta à influência da correlação parcial. Embora os coeficientes de correlação tragam resultados errados, a modelagem gráfica é muito útil para a identificação de relação realista entre as variáveis, o que evita a superestimação dos coeficientes de correlação entre variáveis de entrada e de saída.

O método proposto por MORI e KURATA (2007) foi aplicado com sucesso a dados reais, com um dia de antecedência para previsão de carga no curto prazo. De 2047 variáveis, 11 entradas foram selecionadas pela modelagem gráfica utilizando MLP e *Guassian Process*, sendo que os resultados da simulação mostraram que o método proposto oferece melhores resultados que o método de coeficientes de correlação em termos da média e os erros máximos.

2.2.6 Algoritmos Genéticos (AG) e Análise de Sensibilidade (SA)

A abordagem, análise de sensibilidade (*sensitivity analysis* - SA) foi baseada no estudo proposto por MOODY e UTANS (1994), onde a seleção de entradas é baseada na sensibilidade

do modelo de treinamento MLP com todas as variáveis de entrada. A sensibilidade de uma entrada é estimada através da substituição de variável de entrada no conjunto de teste por sua média calculada sobre o conjunto de treinamento (deve ser escalado a variância) e calculado o efeito da eliminação na saída do MLP.

Algoritmos Genéticos (AG, *genetic algorithms* - GA) são estratégias de busca estocástica desenvolvidas como a inspiração da evolução biológica. Eles têm sido usados com sucesso para resolver diferentes problemas de otimização, em uma ampla gama de áreas de aplicação. A vantagem dos AG é que eles são capazes de procurar espaços de busca complexos com múltiplos mínimos locais que não pode ser produzido usando os algoritmos de otimização convencional. No entanto, uma grande desvantagem dos AG é relacionada com carga computacional, que é devido à estratégia de busca estocástica.

Otimização multi-objetivo (*multi-objective GAs* - MOGA) é o processo de otimização simultâneo de dois ou mais objetivos conflitantes sujeitos a determinadas restrições. Para problemas multi-objetivo não triviais, não se pode identificar uma única solução que otimiza simultaneamente cada objetivo. A pesquisa de soluções pode chegar a pontos de tal forma que, ao tentar melhorar um objetivo, outros objetivos sofrem com o resultado. Uma nova abordagem para representar a seleção de entrada está sendo utilizada, na qual dois critérios de otimização são minimizados: o número de entradas e o erro de modelagem. Tal abordagem tem muitas características atraentes em comparação com a AG pura, como a orientação da pesquisa para áreas interessantes do espaço de busca e pequeno número de entradas potenciais.

NISKA, HEIKKINEN e KOLEHMAINEN (2006) utilizaram os algoritmos genéticos e a análise de sensibilidade para a seleção de entradas de uma rede MLP aplicada à previsão de séries temporais de poluentes do ar urbano. Das diferentes combinações de técnicas (SA, SA + AG, SA + MOGA, AG e MOGA), os resultados numéricos, em geral, mostraram que o SA é técnica suficiente para identificar as variáveis de entrada significativa de MLP. Além disso, foi visto que a combinação de SA e AG ou MOGA não melhorou o desempenho. Finalmente, cabe ressaltar que a avaliação de métodos de seleção de entrada foi baseada no conjunto de validação de um ano.

2.2.7 Teoria do Caos

O controle de complexidade de modelos neurais tem o objetivo de ajustar a forma não-linear à rede neural para a regularidade exibida pelos dados. Esta etapa é necessária para evitar a modelagem do ruído nos dados. Isso pode comprometer a capacidade de generalização do modelo neural, ou seja, boas previsões para os dados invisíveis.

A fim de melhorar a capacidade autônoma dos modelos, técnicas para a definição automática do conjunto inicial de entradas disponíveis a partir da série temporal são necessárias. A aplicação da Teoria do Caos é utilizada como uma ferramenta para a definição automática do conjunto inicial de entradas.

FERREIRA e SILVA (2011) investigaram a aplicação da Teoria do Caos como uma ferramenta de seleção de entrada do espaço no desenvolvimento de modelos de RNA para previsão de carga. Basearam em dois modelos de rede neural: a Inferência Bayesiana Aplicada à MLPs, treinamento e especificação (*Bayesian Inference Applied to Multi-Layered Perceptrons* - BIA-MLPs), e *Relevance Vector Machine* (RVMs).

Os resultados obtidos, se comparáveis com os indicadores disponíveis na literatura, especialmente para o BIAMPs, mostrou o potencial da proposta. O nível de automação das técnicas foi aumentado, permitindo a aplicação dos novos modelos para os problemas, envolvendo séries temporais múltiplas, como por exemplo, previsão de carga por barramento.

O resultado para RVMs, apesar de competitivo, pode ser melhorado pela seleção de funções de base mais apropriadas.

2.3 Modelos de Previsão

Segundo VELÁSQUEZ (2006), a previsão é uma atividade complexa que tem um grau notório de incerteza, sendo que o trabalho do especialista consiste em selecionar a melhor ferramenta de previsão, coletar os dados requeridos, processar os dados, construir um modelo matemático e finalmente gerar e validar a série prevista.

2.3.1 Redes Neurais Artificiais (RNA)

BILOBROVEC, MARÇAL e PILATTI (2004, p. 2) dizem que as RNAs consistem em:

“um método de solucionar problemas de inteligência artificial, construindo um sistema que tenha circuitos que simulem o cérebro humano, inclusive seu comportamento, ou seja, aprendendo, errando e fazendo descobertas. São mais que isso, são técnicas computacionais que apresentam um modelo inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento através da experiência.”

Uma rede neural artificial é um modelo de grafo orientado, disposto em uma rede em que os nós representam neurônios artificiais e as arestas orientadas são as conexões entre as entradas e saídas dos neurônios. As redes neurais podem ser vistas como máquinas massivamente paralelas com muitos processadores simples e muitas interconexões (JAIN, DUIN e MAO, 2000). As redes neurais podem ser hábeis a aprender relações entre entradas e saídas complexas e não-lineares. Dentre outras características, inclui-se a possibilidade de usar procedimentos sequenciais de treinamento e o poder de adaptação aos dados.

O modelo geral de neurônio é uma generalização do modelo de McCulloch e Pitts ou MCP (MCCULLOCH e PITTS, 1943). Um neurônio é uma estrutura, o qual recebe de entrada, estímulos de um conjunto de valores $X = [x_1, x_2, \dots, x_n]^T$ contendo n atributos. Para cada valor x_i , é atribuído um peso w_i , onde $w_i \in W$, sendo que $W = [w_1, w_2, \dots, w_n]^T$.

A soma dos produtos dos valores x_i pelos pesos w_i é chamada de saída linear u , onde $u = \sum_{i=1}^n (x_i \cdot w_i)$. A saída linear u é utilizada no cálculo da função de ativação, $y = f(u)$, onde y é a saída do neurônio (saída de ativação).

As redes neurais possuem a capacidade de se adaptarem a problemas específicos, utilizando diferentes tipos de aprendizagem. O processo de aprendizado envolve atualização da arquitetura da rede e dos pesos das conexões, de forma que a rede pode efetuar tarefas específicas de previsão, classificação e análise de agrupamentos (“*clustering*”).

O algoritmo de treinamento verifica o erro para cada padrão e altera os pesos da rede a fim de minimizá-lo. Diversos algoritmos de treinamento foram desenvolvidos. Eles se diferem principalmente na maneira como os pesos são atualizados, sendo os mais conhecidos:

- **Backpropagation (BP):** é uma forma de treinamento para redes multi-camadas. Apresenta vantagens de precisão e versatilidade, apesar de ter como desvantagem a complexidade e a lentidão. O método ajusta os pesos para alcançar o mínimo da função de erro. Porém, a rede pode ficar presa em mínimos locais. (HAYKIN, 1999);
- **Backpropagation com Termo Momentum (BPM):** O problema do BP de ficar preso em mínimos locais é resolvido pela adição de um impulso (termo *momentum*) no método de treinamento. O termo *momentum* força o sistema a continuar se movendo parcialmente na mesma direção sobre a superfície de erro, sem ficar preso em mínimos locais. (RUMELHART, 1986);
- **Método Gradiente (GRAD):** dentre os métodos que utilizam diferenciação e busca, o método do gradiente é o mais simples para a obtenção da direção, pois utiliza apenas informações de primeira ordem. Ele possui um comportamento monotônico decrescente da função de erro, a taxa de aprendizagem oscila e o número de épocas para convergência é menor. (VON ZUBEN, 1996);
- **Método de Fletcher-Reeves (FR):** é um método de gradiente conjugado aplicado a funções não-lineares, onde o sentido de busca deve-se reverter periodicamente (depois de um ciclo de pesquisas lineares) para a direção de descida mais íngreme, quando toda a informação anterior das direções é descartada. (FLETCHER e REEVES, 1964);
- **Método de Polak-Ribière (PR):** é outra versão do algoritmo do gradiente conjugado. Este é o produto interno da mudança anterior do gradiente com o gradiente corrente dividido pelo quadrado da norma do gradiente anterior. (SCALES, 1985);
- **Método de Broyden-Fletcher-Goldfarb-Shanno (BFGS):** é um método para a resolução de problemas de otimização não linear, sem restrições. O método não precisa convergir, a menos que a função tenha uma expansão de Taylor quadrática perto de um ideal. Este método utiliza derivadas de primeira e segunda. (DENNIS e SCHNABEL, 1983);
- **Método de Davidon-Fletcher-Powell (DFP):** encontra a solução para a equação secante que está mais próxima da estimativa atual e satisfaz a condição de curvatura. Foi o primeiro método quase-Newton a generalizar o método da secante a um problema multidimensional. (DAVIDON, 1991) e (FLETCHER, 1986);

- **Método das Secantes de um Passo (*One Step Secant* - OSS):** é uma tentativa de preencher a lacuna entre os algoritmos de gradiente conjugado e o quase-Newton. Este não armazena a matriz Hessiana completa, pois assume que a cada iteração, a Hessiana anterior é uma identidade. Isto tem a vantagem de que o novo sentido de busca pode ser calculado sem calcular uma matriz inversa. (BATTITI, 1992);
- **Método do Gradiente Conjugado Escalonado (*Scaled Conjugate Gradient Method* - SCGM):** é um algoritmo para a solução numérica de sistemas, cuja matriz é simétrica e definida positiva. O método do gradiente conjugado é um método iterativo, para que possa ser aplicada a sistemas esparsos que são demasiadamente grandes para serem manuseados por métodos diretos. O método do gradiente conjugado também pode ser utilizado para resolver os problemas de otimização sem restrições. (MØLLER, 1993) e (PEARLMUTTER, 1994);

A popularidade das redes cresceu devido ao fato que, aparentemente, elas têm uma baixa dependência a um específico domínio, de forma que o mesmo tipo de rede pode ser aplicado em vários problemas, o que não ocorre com as abordagens baseadas em modelos ou em regras.

Outro fator importante na popularidade é o fato de existirem muitos algoritmos eficientes de aprendizado com redes neurais. Existem vários tipos de redes neurais artificiais e dentre essas redes, a mais usada é a rede neural do tipo *multi-layer perceptron* (MLP), devido à sua fácil implementação e por sua simplicidade.

A utilidade das redes neurais está no fato delas serem utilizadas para resolver diversos problemas que apresentam um alto grau de complexidade, uma vez que as redes são capazes de serem adaptadas a diferentes problemas.

As RNAs são aplicadas na identificação e controle de sistemas, jogo de interpretação, tomada de decisão, reconhecimento de padrões, reconhecimento de sequências, diagnóstico médico, aplicações financeiras, de mineração de dados, entre outras áreas.

Apesar de possuírem aparentemente princípios diferentes, a maioria dos modelos de redes neurais populares são implicitamente equivalentes ou similares.

Diante de tais informações e do poder de aprendizagem das redes neurais, diversos problemas foram atrelados às redes neurais, visto o fato desta ser capaz de resolver diferentes categorias de problemas, modificando apenas alguns parâmetros e configurações.

3 Base de Dados

*“É necessário ter o caos aqui dentro para gerar uma estrela.”
(Friedrich Nietzsche)*

O Capítulo 3 tem por finalidade descrever o conjunto de base de dados a ser trabalhado. A Seção 3.1 define de forma sucinta o sistema elétrico brasileiro. Já a Seção 3.2 apresenta as séries temporais a serem utilizadas e as classifica de acordo com o tipo de demanda (ativa e reativa). Por fim, a Seção 3.3 faz uma análise geral das séries a serem utilizadas.

3.1 Sistema Elétrico

Sistemas elétricos são sistemas que englobam a geração, a transmissão e a distribuição de energia elétrica até os consumidores. O aumento da demanda por energia elétrica e o crescente número de interligações entre os sistemas elétricos existentes tornaram a operação e o controle do sistema uma tarefa extremamente complexa.

Uma etapa importante no planejamento da operação de um sistema elétrico é a definição da programação da operação diária, a qual tem por objetivo o estabelecimento de um plano de produção de energia elétrica para o(s) próximo(s) dia(s), para cada uma das usinas do sistema.

O programa de operação define para cada intervalo de tempo, em geral de 30 minutos, quais as unidades geradoras devem estar em operação e o seu nível de geração médio em cada intervalo de tempo. O programa, assim obtido, será uma referência para a operação em tempo real do sistema, de forma que a operação real deverá oscilar em torno destes valores, se as condições reais não apresentarem grandes desvios em relação aos valores previstos utilizados no cálculo do programa de operação.

Na operação em tempo real, o principal aspecto é a operação do sistema elétrico, buscando uma coordenação entre geração, transmissão e distribuição, de modo a evitar violações de requisitos operativos nestes sistemas. Nesse sentido, no cálculo do programa de operação, uma etapa importante é a avaliação do impacto do despacho programado sobre a operação do sistema

de transmissão. Para esta avaliação, uma informação essencial é a estimativa de demanda por barramento, pois estas demandas influenciam a operação do sistema de transmissão. Daí a necessidade das previsões de demanda de carga por barramento.

O fluxo de potência é uma das ferramentas básicas em análise de sistemas elétricos. Através dele, pode-se conhecer o seu desempenho sob o ponto de vista de operação e/ou planejamento. Os estudos em geral utilizam um modelo da rede elétrica chamado de modelo barra-linha, no qual as barras (ou barramentos) são os nós da rede e as linhas/transformadores são os elos entre esses nós.

A previsão de demanda por barramento não é útil apenas no cálculo do programa de operação. De acordo com HANDSCHIN e DORNEMANN (1988), o conhecimento da carga por barramento é uma referência fundamental no planejamento da expansão do sistema. A grande importância na previsão de carga por barramento encontra-se no fato desta previsão proporcionar um conhecimento da carga na rede de distribuição, facilitando o planejamento energético e proporcionando maior segurança e estabilidade nas operações em tempo real do sistema elétrico (SALGADO, 2004). As barras, em geral, estão localizadas em subestações e na realidade podem ser constituídas por várias seções de barras interligadas.

Uma subestação (SE) é uma instalação elétrica que contém equipamentos para transmissão e distribuição de energia elétrica, além dos equipamentos de proteção e controle. Funciona como ponto de controle e transferência em um sistema de transmissão de energia elétrica, direcionando e controlando o fluxo energético, transformando os níveis de tensão.

A Figura 3.1 apresenta uma visão da rede do sistema elétrico brasileiro, onde são apresentados os principais barramentos e conexões. Os barramentos a serem trabalhados estão localizados na região Nordeste, sendo denominados nesta dissertação de Barra-I, Barra-II e Barra-III.

É importante lembrar que o fornecimento de energia elétrica no Brasil é feito por meio de um grande e complexo sistema de subestações e linhas de transmissão, interligadas às várias usinas. Assim, uma cidade não recebe energia gerada por uma única usina, mas por diversas usinas (hidrelétricas, termoeletricas, eólicas ou nucleares) que constituem o chamado Sistema Interligado Nacional (SIN).




Figura 3.1 - Rede do sistema elétrico brasileiro (Fonte: (ONS, 2013)).

3.2 Carga por Barramento

A principal função de um sistema de energia é a de fornecer as potências ativas e reativas, necessárias às diversas cargas a ele ligadas. A previsão da potência ativa, em conjunto com a potência reativa, constitui numa ferramenta de extremo valor para o sistema de energia elétrica.

As potências ativas e reativas são características de sistemas elétricos operados em corrente alternada e usualmente é representado no plano, onde a potência ativa é situada no eixo real e a potência reativa é situada no eixo imaginário. O fator de potência é definido pelo cosseno do ângulo formado pelas potências ativa e reativa no plano. A potência aparente é representada pela soma vetorial dessas potências. O conjunto denomina-se de “Triângulo de Potência”.

A demanda de potência reativa em um dado barramento pode ser positiva ou negativa. Quando a carga for indutiva (a corrente está atrasada em relação à tensão) os valores de demanda reativa serão positivos e quando a carga for capacitiva (a corrente está adiantada em relação à tensão), os valores serão negativos.

Conhecer o conjunto de dados que será utilizado é fundamental em qualquer etapa do desenvolvimento de uma pesquisa. A análise prévia dos dados pode fornecer informações relevantes que serão levadas em consideração, em etapas futuras.

Segundo SALGADO (2009) *“nas previsões de carga, é comum utilizar o histórico da carga e dados exógenos (temperatura, umidade, estação do ano, dados econômicos entre outros) para representar a carga em um instante futuro”*.

A previsão pode ser aplicada para vários tipos de variáveis, como por exemplo, as séries climáticas, econômicas, demográficas entre outras. O comportamento futuro de cada componente é estimado através da combinação de diversos valores que aconteceram em um determinado período do passado. Esta dissertação propõe uma metodologia na qual utiliza apenas dados históricos da carga com demandas ativa e reativa.

3.2.1 Demandas de Carga Ativa e Reativa por Barramento

Serão utilizados dados de três barramentos (Barra-I, Barra-II e Barra-III). As medições dos barramentos foram feitas no período de 01/04/2007 a 31/03/2011 e tais barras operam na tensão de 69kV. As demandas de potência ativa são medidas em mega watt (MW), por sua vez, as demandas de potência reativa são dadas em mega volt-ampère reativo (MVar).

Um previsor necessita que a base seja separada em grupos: período de treinamento, de validação e de teste. Essa divisão tem a finalidade de distinguir as fases no processo de predição.

- **período de treinamento:** é um conjunto de dados utilizado para treinar os pesos da rede neural. Está representado, nesta dissertação, na cor marrom e compreende o período de 01/04/2007 a 31/03/2009 (2 anos).
- **período de validação:** é um conjunto de dados utilizado para encontrar a melhor configuração da rede neural e dos parâmetros de treino. O conjunto de validação é usado para evitar o “*overfitting*” no treinamento. Está representado, nesta dissertação, na cor verde e compreende o período de 01/04/2009 a 31/03/2010 (1 ano).
- **período de teste:** é um conjunto de amostras utilizadas apenas para avaliar a rede neural treinada. Está representado, nesta dissertação, na cor azul e compreende o período de 01/04/2010 a 31/03/2011 (1 ano).

Para verificar o comportamento semanal das séries, de acordo com o período (treino, validação e teste), foi feita uma apresentação por semana dos dados. Dessa forma, é possível verificar as tendências e variações em relação a cada período.

Além dessa verificação, é apresentado o comportamento da carga ao longo do período de teste. Sendo possível analisar as características da carga em um ano.

Para apresentar a demanda de forma mais visual, optou-se por escolher três semanas as quais são utilizadas para caracterização, análise e previsão. A primeira semana intitulada Semana A representa o período de 04/04/2010 a 09/04/2010, que é o início do período de teste e também início do mês de abril. A segunda, Semana B, diz respeito ao período de 12/09/2010 a 17/09/2010, situado no meio do período de teste e também no meio do mês de setembro. Por fim, a Semana C, vai de 20/03/2011 a 25/03/2011, final do período de teste e fim do mês de março.

A seguir será caracterizado o comportamento das demandas destes barramentos.

3.2.1.1 Barra-I

A Barra-I possui demanda de potência ativa (Figura 3.2) de 22,1 MW a 57,1 MW e isso impacta diretamente na demanda de potência reativa (Figura 3.3), que gira em torno de -19,2 MVar a 15,3 MVar (variando entre potência reativa capacitiva e indutiva). A demanda ativa tem uma sazonalidade anual marcante, enquanto que a reativa, a sazonalidade não é clara.




Figura 3.2 - Série histórica da demanda ativa da Barra-I.




Figura 3.3 - Série histórica da demanda reativa da Barra-I.

Analisando o comportamento semanal, a Barra-I com potência ativa (Figura 3.4), apresenta valores elevados no período de treinamento (no final da noite e durante a madrugada). O conjunto de treino apresenta um perfil diferente dos conjuntos de validação e de teste, indicando uma alteração neste perfil dos dois primeiros anos em relação aos anos posteriores.

Com a potência reativa (Figura 3.5), a demanda diminui e há uma redução da carga do período de treinamento até o teste.




Figura 3.4 – Demanda semanal de potência ativa da Barra-I.




Figura 3.5 - Demanda semanal de potência reativa da Barra-I.

A Figura 3.6 mostra a demanda ativa para a Barra-I durante um ano (01/04/2010 a 31/03/2011), houve uma redução da carga de abril a maio, logo após há uma aumento até meados de outubro. De novembro a março a demanda oscila, aumentando e reduzindo a carga.

Analisando as três semanas na Figura 3.7, nota-se que a carga possui um comportamento cíclico e com dois picos de carga durante o dia de segunda a sexta na Semana B e de segunda a quarta na C, enquanto nos sábados e domingos a carga é quase constante.




Figura 3.6 – Demanda de 1 ano de potência ativa da Barra-I.




Figura 3.7 – Demanda de 3 semanas de potência ativa da Barra-I.

A Figura 3.8 mostra a demanda reativa durante um ano, nota-se que a carga mantém-se entre -5 e 5 MVar de abril a fevereiro (oscilando entre capacitiva e indutiva), mas em março a carga trabalha grande parte como capacitiva. A Figura 3.9 mostra a demanda reativa para a Barra-I para as mesmas três semanas. A carga possui um comportamento similar ao descrito para a demanda ativa, já que estes são complementares.




Figura 3.8 – Demanda de 1 ano de potência reativa da Barra-I.




Figura 3.9 – Demanda de 3 semanas de potência reativa da Barra-I.

3.2.1.2 Barra-II

A Barra-II tem uma demanda de potência ativa (Figura 3.10), a qual vai de 60,7 MW a 163,3 MW, que por sua vez influencia na potência reativa (Figura 3.11) de -9,3 MVar a 39,7 MVar, sendo na maior parte do tempo, potência reativa indutiva.




Figura 3.10 - Série histórica da demanda ativa da Barra-II.




Figura 3.11 - Série histórica da demanda reativa da Barra-II.

Para o comportamento semanal da Barra-II com potência ativa (Figura 3.12), a demanda do teste tem um aumento em relação ao treinamento, enquanto para a potência reativa da Barra-II (Figura 3.13), não é possível inferir muito, apenas salientar que os dados não apresentam uma tendência ao longo dos anos.




Figura 3.12 - Demanda semanal de potência ativa da Barra-II.




Figura 3.13 - Demanda semanal de potência reativa da Barra-II.

Para a demanda ativa da Barra-II ao longo de um ano (Figura 3.14) há uma elevação da carga de abril a dezembro e rebaixada de janeiro a março. Na Figura 3.15, as três semanas possuem uma redução da carga no começo do dia, seguido pela sua elevação, nos finais de semana a carga é quase constante.




Figura 3.14 – Demanda de 1 ano de potência ativa da Barra-II.




Figura 3.15 – Demanda de 3 semanas de potência ativa da Barra-II.

Analisando a demanda da Figura 3.16 verifica-se que a carga é elevada ao longo de um ano e na maior parte do tempo indutiva. As cargas reativa da Barra-II (Figura 3.17) possuem comportamento distintos entre si, nota-se que na Semana A e C as cargas são reduzidas no começo do dia, já na Semana C a carga é elevada. No final de semana a carga apresentada um comportamento similar aos dias da semana.




Figura 3.16 – Demanda de 1 ano de potência reativa da Barra-II.




Figura 3.17 – Demanda de 3 semanas de potência reativa da Barra-II.

3.2.1.3 Barra-III

A Barra-III opera de 173,7 MW a 431,9 MW na potência ativa (Figura 3.18), e toda a sua potência reativa (Figura 3.19) é do tipo indutiva, dado que seus valores vão de 17,16 a 144,0 MVar.




Figura 3.18 - Série histórica da demanda ativa da Barra-III.




Figura 3.19 - Série histórica da demanda reativa da Barra-III.

A Barra-III com potência ativa (Figura 3.20) apresenta o mesmo comportamento da Barra-II ativa, a demanda aumenta ao longo do tempo e dos períodos. É possível notar que, em alguns momentos, há uma queda de demanda, tendo um comportamento diferente aos demais dias. Por fim, a Barra-III com potência reativa (Figura 3.21), verificou uma redução na faixa de valores cobertos pelo treinamento para o teste.




Figura 3.20 - Demanda semanal de potência ativa da Barra-III.




Figura 3.21 - Demanda semanal de potência reativa da Barra-III.

Para a Barra-III ao longo de um ano (Figura 3.22) a carga possui um redução e aumento longo (de abril a novembro), e uma redução e aumento curto (dezembro a fevereiro). Para as três semanas (Figura 3.23) verifica-se que o comportamento é bastante similar (devido a demanda ser maior, o comportamento da carga é mais estável), a carga é reduzida no começo do dia e depois aumenta, além de possui um comportamento similar nos fins de semana.




Figura 3.22 – Demanda de 1 ano de potência ativa da Barra-III.




Figura 3.23 – Demanda de 3 semanas de potência ativa da Barra-III.

A Barra-III ao longo de um ano (Figura 3.24) a demanda reativa é totalmente indutiva. Quanto as semanas a Semana B e C da Barra-III (Figura 3.25) possui um comportamento similar, com redução da carga no início do dia, seguido de seu aumento. Na Semana A o comportamento é aleatório e sem um padrão aparente.




Figura 3.24 – Demanda de 1 ano de potência reativa da Barra-III.




Figura 3.25 – Demanda de 3 semanas de potência reativa da Barra-III.

3.3 Análise da Série Temporal

Os dados foram analisados pela estatística descritiva, caracterizando seus comportamentos e calculando os momentos amostrais. Os momentos são quantidades numéricas, calculadas a partir de um conjunto de dados, que fornecem uma descrição resumida da base utilizada.

- **medidas de posição:** representam uma série de dados que orientam quanto à posição da distribuição em relação ao eixo horizontal do gráfico da curva de frequência. As medidas mais utilizadas são: média aritmética, valor mínimo e máximo;
- **medidas de dispersão:** Determina a variabilidade ou dispersão dos dados, em relação à medida de localização do centro da amostra. Foi utilizado o desvio padrão;
- **medidas de assimetria:** proporcionam a descrição e compreensão completa da distribuição de frequências. A assimetria e curtose foram as medidas utilizadas.

Baseando-se nas medidas acima, foi gerada a Tabela 3.1, que apresenta os dados referentes ao barramento com potência ativa e para o barramento com potência reativa, tem-se a Tabela 3.2. Para cada barramento foi calculado os valores para os diferentes períodos (treino, validação e teste), além de apresentar também a análise para toda a série histórica.

Em relação aos valores e figuras apresentadas, é possível identificar a faixa de atuação de cada barramento (sub-divididos em períodos), definindo assim o seu valor médio. O desvio padrão apresenta valores baixos, indicando que os dados estão próximos da média; porém, é importante verificar a assimetria e curtose, pois eles informam como é a distribuição dos dados.

A assimetria é o grau de afastamento que uma distribuição apresenta do seu eixo de simetria (neste caso, o eixo de simetria é baseado na média). Quando a cauda da curva da distribuição declina para direita, tem-se uma distribuição com curva assimétrica positiva. Analogamente, quando a cauda da curva da distribuição declina para esquerda, tem-se uma distribuição com curva assimétrica negativa. Salvo em alguns casos, os períodos avaliados possuem simetria perfeita, pois os valores estão próximos de 0 (zero).

A curtose é o grau de achatamento da distribuição, ou seja, indica o quanto a curva de frequência está achatada em relação a uma curva normal de referência (distribuição normal). Quando o grau é negativo, tem-se uma distribuição afunilada, sendo menos propensa a possuir *outliers*.

Por outro lado, quando o grau é positivo, a distribuição é achatada, apresentando mais *outliers*. Para os barramentos de potência ativa, a curtose foi mais afunilada, enquanto para os barramentos de potência reativa, a curtose foi mais achatada.

Tabela 3.1 - Momentos amostrais para os barramentos com potência ativa.

<i>Barramento</i>	<i>Período</i>	<i>Média</i>	<i>D. Padrão</i>	<i>Mínimo</i>	<i>Máximo</i>	<i>Assimetria</i>	<i>Curtose¹</i>
Barra-I (MW*)	treino	41,54*	5,82*	22,70*	57,10*	-0,04	-0,73
	validação	38,34*	4,54*	22,50*	51,60*	0,14	-0,75
	teste	37,92*	5,01*	22,10*	52,30*	0,18	-0,01
	série	39,83*	5,59*	22,10*	57,10*	0,18	-0,46
Barra-II (MW*)	treino	98,51*	13,78*	60,70*	139,70*	0,18	-0,40
	validação	107,09*	15,19*	68,70*	147,00*	0,13	-0,58
	teste	120,19*	14,45*	83,20*	163,30*	0,22	-0,42
	série	106,07*	16,84*	60,70*	163,30*	0,26	-0,30
Barra-III (MW*)	treino	296,21*	47,42*	173,70*	401,50*	-0,10	-1,00
	validação	311,76*	51,77*	178,60*	431,90*	-0,12	-0,90
	teste	330,26*	50,20*	202,10*	430,80*	-0,13	-1,04
	série	308,60*	51,19*	173,70*	431,90*	-0,05	-0,86

Tabela 3.2 - Momentos amostrais para os barramentos com potência reativa.

<i>Barramento</i>	<i>Período</i>	<i>Média</i>	<i>D. Padrão</i>	<i>Mínimo</i>	<i>Máximo</i>	<i>Assimetria</i>	<i>Curtose¹</i>
Barra-I (MVAr*)	treino	2,59*	3,25*	-7,80*	15,30*	-0,06	-0,38
	validação	1,92*	2,52*	-9,20*	12,60*	-0,09	0,27
	teste	0,95*	3,50*	-19,20*	10,30*	-1,46	4,44
	série	2,01*	3,22*	-19,20*	15,30*	-0,54	2,15
Barra-II (MVAr*)	treino	10,48*	6,24*	-8,50*	39,70*	0,40	0,22
	validação	11,04*	5,79*	-7,80*	30,30*	0,01	-0,25
	teste	12,58*	7,27*	-9,30*	36,80*	-0,10	-0,13
	série	11,14*	6,47*	-9,30*	39,70*	0,21	0,01
Barra-III (MVAr*)	treino	80,14*	18,95*	17,16*	144,00*	0,13	-0,41
	validação	78,92*	18,60*	23,30*	136,60*	0,08	-0,64
	teste	74,19*	19,02*	19,80*	125,80*	0,00	-0,61
	série	78,35*	19,04*	17,16*	144,00*	0,08	-0,47

Da Figura 3.26 à Figura 3.31, são apresentadas a distribuição (normal e real) dos barramentos para cada período, juntamente com o valor médio da série e o intervalo, onde 95% dos dados estão presentes. Dessa forma, é possível verificar a assimetria e curtose das séries, levando a uma melhor compreensão do seu comportamento.

¹ Algumas definições de curtose subtraem 3 (três) do valor calculado, para que a distribuição normal tenha curtose 0 (zero). Para uma melhor compreensão dos resultados, esta dissertação também adotou essa medida.

Na Figura 3.26 de demanda ativa para a Barra-I, observa-se que a distribuição do conjunto de treino é bem diferente das distribuições dos conjuntos de validação e de teste. No caso da demanda reativa da Barra-I (Figura 3.27), a distribuição do conjunto de teste está acima da distribuição normal, enquanto os demais conjuntos possuem distribuições próximas da normal.




Figura 3.26 - Distribuições (normal e real) da Barra-I com demanda ativa.




Figura 3.27 - Distribuições (normal e real) da Barra-I com demanda reativa.

Para a Barra-II com demanda ativa (Figura 3.28), o conjunto de validação e teste apresenta uma leve distorção da distribuição em relação a normal. Enquanto para a demanda reativa da Barra-II (Figura 3.29), as distribuições são bem similares a normal.




Figura 3.28 - Distribuições (normal e real) da Barra-II com demanda ativa.




Figura 3.29 - Distribuições (normal e real) da Barra-II com demanda reativa.

Por fim, a Barra-III, tanto para demanda ativa (Figura 3.30) quanto reativa (Figura 3.31), todos os conjuntos possuem uma distorção da distribuição em relação a normal, mas o comportamento é similar entre um conjunto e outro.




Figura 3.30 - Distribuições (normal e real) da Barra-III com demanda ativa.




Figura 3.31 - Distribuições (normal e real) da Barra-III com demanda reativa.

Com o intuito de também fazer uma análise hora a hora dos dados, utilizou-se de um recurso chamado "*Diagrama de Caixas*" ou "*Boxplot*". Este recurso é uma maneira rápida de examinar um ou mais conjuntos de dados graficamente (da Figura 3.32 à Figura 3.37).

O *Boxplot* mostra as diferenças entre as populações, sem fazer quaisquer suposições da distribuição estatística. A caixa central inclui os 50% dos dados e os espaçamentos entre as dife-

rentes partes da caixa indicam o grau de dispersão (*spread*) e a simetria nos dados, visto que é relativamente fácil comparar grupos de populações. Os *outliers* (representados com o sinal “+”) são valores atípicos, pois apresentam um grande afastamento dos demais valores da série.




Figura 3.32 - Boxplot da demanda ativa da Barra-I.




Figura 3.33 - Boxplot da demanda reativa da Barra-I.

Em relação aos “outliers”, nota-se que, as demandas de potência reativas apresentam um número maior de dados “atípicos”, sendo dessa forma, mais suscetível a variações dos dados que a demanda de potência ativa.




Figura 3.34 - Boxplot da demanda ativa da Barra-II.




Figura 3.35 - Boxplot da demanda reativa da Barra-II.




Figura 3.36 - Boxplot da demanda ativa da Barra-III.




Figura 3.37 - Boxplot da demanda reativa da Barra-III.

Dessa forma, tem-se uma ampla visão sobre o comportamento da série, podendo inferir que a Barra-I possui um comportamento mais instável que as demais barras, isto é, por que ela possui uma demanda menor e assim estar sujeita a qualquer sutil variação da carga. Todavia qualquer uma das séries está sujeita a variações e modificações no comportamento, cabendo ao seletor e ao previsor encontrarem a(s) combinação(ões) que melhor se ajusta(m) ao problema.

4 Metodologia Proposta

*“Eu não procuro saber as respostas,
procuro compreender as perguntas.”
(Confúcio)*

No Capítulo 4, é descrita toda a metodologia proposta para o desenvolvimento do sistema de previsão. A Seção 4.1 faz uma descrição geral do sistema. O pré-processamento é apresentado na Seção 4.2. A Seção 4.3 dá ênfase ao processo de seleção de entradas e sua configuração. A Seção 4.4 descreve a integração do pré-processamento com a seleção de variáveis para construir as bases. Os métodos de previsão utilizados e os parâmetros são descritos na Seção 4.5. Por fim, na Seção 4.6, são feitas as considerações finais sobre a metodologia.

4.1 Descrição da Metodologia

A busca por sistemas que obtenham resultados prósperos é almejada por todos os pesquisadores; dessa forma, diferentes linhas de pesquisas são estudadas a fim de estabelecer novos resultados para diversos tipos de problemas. Em particular, o desenvolvimento de modelos para previsão de demanda de carga a curto prazo requer a definição de vários aspectos: seleção das variáveis de entrada (tipo de variável e seus “lags”), seleção da técnica de previsão (redes neurais, modelos estocásticos, etc.) da sua configuração e escolha do histórico de treinamento.

Em geral, a definição do modelo é em função do conjunto de entradas, das técnicas e de dados que apresentar melhor desempenho em um período de testes. Esta dissertação baseia-se num procedimento que testa um conjunto de alternativas e que pode ser automatizado a partir de parâmetros especificados pelo usuário. Baseado nesta ideia, o grupo COSE/UNICAMP e LInC/UNIFAL-MG está desenvolvendo um sistema de suporte para previsão de carga de curto prazo, que realiza o processo de busca do melhor conjunto de entradas/técnicas/dados de forma autônoma, em função de parâmetros especificados pelo usuário. O sistema terá uma base de modelos

contendo técnicas de seleção de entradas, técnicas de previsão, um histórico de demanda de carga e um sistema que irá coordenar os testes das alternativas e escolher o melhor conjunto.

A presente dissertação é parte deste projeto com um enfoque nas técnicas de seleção de entradas. Foram consideradas as técnicas de MI e PMI para a seleção de entradas e como método de previsão, utilizaram-se os modelos baseados em redes neurais com arquitetura MLP, considerando diferentes técnicas de treinamento. A estratégia de busca adotada é a de força bruta, na qual todas as alternativas dentro de uma faixa especificada são testadas. Futuramente, pretende-se incrementar, incluindo outras técnicas de seleção de entradas e de previsão e testar outras estratégias de busca, como por exemplo, a técnica de TAKAGI e SUGENO (1985).

Este trabalho propõe agrupar um conjunto de ferramentas de modo que se possa selecionar o conjunto de variáveis que se pretende testar, bem como as técnicas de seleção de entradas e os métodos de previsão mais aptos para o problema a ser trabalhado.

Inicialmente, a ferramenta é configurada com os parâmetros gerais do sistema, para que esta esteja apta a utilizar as técnicas de seleção e redução de dados e também os métodos de previsão, visto que cada técnica e método apresentam um subconjunto possível de parâmetros. Juntamente ao processo de configuração, será carregada a série temporal a ser analisada.

Para a etapa de pré-processamento, o sistema pode fazer uso de um conjunto de técnicas de normalização de dados. Na etapa de seleção de entradas, as técnicas de MI e PMI são empregadas para a definição de quais *lags* irão gerar os períodos (de treino, validação e teste). Em relação à etapa de previsão, são utilizadas diferentes técnicas de treinamento de RNAs e variações nas suas configurações. A seguir, cada etapa é apresentada com mais detalhes.

4.2 Pré-Processamento

Independentemente da forma como os dados são adquiridos, a grande parte das técnicas de seleção e/ou previsão necessita que o dado seja pré-processado. Assim, muitas pesquisas fazem uso de transformações dos dados para a utilização nas metodologias propostas. Para as RNAs é necessário que os dados escalados em torno de 0 a 1 para a sua utilização.

Segundo REZENDE (2005) *"o pré-processamento deve ser realizado criteriosamente e com o devido cuidado, uma vez que é fundamental garantir que as informações presentes nos*

dados brutos continuem presentes nas amostras geradas, para que os modelos finais sejam representativos da realidade expressa nos dados brutos." A partir dessas informações, foram estabelecidos alguns métodos para o pré-processamento dos dados.

A normalização consiste no pré-processamento dos dados visando uniformizar tamanho, tipo, qualidade, dimensão e desempenho, contudo, sem prejudicar a unidade do conjunto.

Para o entendimento das técnicas de normalização, suponha $X_{h,d}$ um conjunto contendo h horas do dia e d dias da série, onde $X_{h,d} \in \mathbb{R}$. Uma demanda $x_{i,j} \in X$ é um elemento tal que $1 \leq i \leq h, 1 \leq j \leq d$, onde $i, j \in \mathbb{N}$.

Logo abaixo são apresentadas as normalizações utilizadas pela pesquisa e os efeitos de cada uma delas sobre os dados. Uma simulação do comportamento da normalização foi feita com os dados da Barra-I para demanda ativa, no período de 1 ano (Figura 4.1 (a)).

- **Normalização pelo valor máximo da série (Eq. 4.1, Figura 4.1 (b)):** mantém os valores normalizados entre limitantes superior ou inferior (se o elemento de maior valor em módulo for negativo temos um intervalo entre $[-1, 1[$, caso contrário, se o maior valor em modulo for positivo temos $] -1, 1]$).

$$\tilde{x}_{i,j} = \frac{x_{i,j}}{\max(|X|)} \quad \text{Eq. 4.1}$$

- **Normalização pelo valor máximo do dia (Eq. 4.2, Figura 4.1 (c)):** a diferença entre a normalização anterior (Eq. 4.1) é que esta estabelece os limites para cada dia, ao invés de ser para a série inteira.

$$\tilde{x}_{i,j} = \frac{x_{i,j}}{\max(|X_j|)}, \text{ para um dado } j \quad \text{Eq. 4.2}$$

- **Normalização pela diferença do valor máximo e mínimo da série (Eq. 4.3, Figura 4.2 (a)):** utilizada a diferença do elemento pelo valor mínimo do conjunto, dividido pelo intervalo dos dados (máximo e mínimo). O resultado limita o valor entre $[0, 1]$.

$$\tilde{x}_{i,j} = \frac{x_{i,j} - \min(X)}{\max(X) - \min(X)} \quad \text{Eq. 4.3}$$

- **Normalização da média em razão do desvio padrão (Eq. 4.4, Figura 4.2 (b)):** valor normalizado de uma distribuição caracterizada pela média e desvio padrão.

$$\tilde{x}_{i,j} = \frac{x_{i,j} - \bar{X}}{\sigma_X} \quad \text{Eq. 4.4}$$

- **Normalização pelo valor máximo da hora (Eq. 4.5, Figura 4.2 (c)):** a diferença entre a normalização anterior (Eq. 4.1 e Eq. 4.2) é que esta estabelece os limites para cada hora, ao invés de ser para a série inteira ou para o dia.

$$\tilde{x}_{i,j} = \frac{x_{i,j}}{\max(|X_i|)}, \text{ para um dado } i \quad \text{Eq. 4.5}$$




Figura 4.1 – Normalização dos dados. (a) Dados Brutos, (b) MaxSerie, (c) MaxDia.




Figura 4.2 – Normalização dos dados. (a) MaxMin, (b) MediaVar, (c) MaxHora.

Também se verificou o comportamento da normalização para duas semanas. Em relação aos dados brutos (Figura 4.3 (a)), a normalização MaxSerie (Figura 4.3 (b)) escalou os dados pelo valor máximo da serie, o MaxDia (Figura 4.3 (c)) escalou pelo valor máximo de cada dia, o MinMax (Figura 4.4 (a)) escalou para o intervalo 0 e 1, o MediaVar (Figura 4.4 (b)) apresenta a variância em torno da média e o MaxHora (Figura 4.4 (c)) escalou pelo máximo de cada hora.




Figura 4.3 - Normalização de duas semanas. (a) Dados Brutos, (b) MaxSerie, (c) MaxDia.




Figura 4.4 - Normalização de duas semanas. (a) MaxMin, (b) MediaVar, (c) MaxHora.

Tendo em vistas as várias técnicas de pré-processamento e inclusive de normalização, é importante ter em mente que cada uma se aplica melhor a determinados sistemas e contextos. Mesmo com o pré-processamento dos dados, uma grande quantidade de informação pode reduzir a eficácia do sistema; assim, torna-se necessário utilizar e reduzir o conjunto de dados a fim de diminuir o volume de dados a ser trilhado.

4.3 Seleção de Variáveis

Com o intuito de expandir a atuação das técnicas de seleção para diferentes situações, são utilizadas diferentes configurações, que combinam os parâmetros e formam muitos conjuntos a serem trabalhados, assim pode-se chegar a algumas conclusões gerais sobre a eficácia de cada tipo de seleção. Este tipo de análise também ajuda a identificar as características particulares de uma ferramenta de seleção, as quais parecem fazê-la funcionar melhor e os recursos que possam prejudicar a sua eficácia.

A ferramenta inicia o processo de seleção de dados, onde o objetivo é encontrar os possíveis melhores subconjuntos de variáveis para o sistema, estabelecidos a partir do número de *lags* desejados (atrasos em relação ao instante atual). São utilizadas as seguintes técnicas de seleção e redução de dados: informação mútua e informação mútua parcial.

4.3.1 Definição dos *lags* utilizando MI

A informação mútua $MI(X; Y)$ é uma medida da quantidade de informação entre os dados X e Y . Quanto mais próximo de 0 (zero), mais os dados são independentes, do mesmo modo, quanto maior o valor, mais os dados são dependentes.

A proposta é utilizar os *lags* que apresentam maior dependência, pois dessa forma, têm-se os atrasos que são mais significativos. A aplicação é simples, suponha que se pretende determinar quais os valores anteriores a x_t da série, os quais apresentam maiores dependência com este valor. Estes valores são determinados através do cálculo da MI de valores anteriores a x_t com o

próprio valor de x_t , e são escolhidos os *lags* que apresentarem maiores valores de MI. Em termos práticos, a pesquisa com os valores anteriores fica restrita ao intervalo $[t - m, t - n]$.

A pesquisa dos *lags* mais significativos pode ser feita de várias maneiras, uma delas é por blocos de elementos sucessivos, em que, ao invés de buscar as relações para um único elemento pode-se pesquisar os *lags* mais significativos para um conjunto de elementos X . Dado um período a ser analisado $X = [x_t, x_{t+1}, \dots, x_{t+i}]$, e o intervalo de m a n , onde $m < n$, têm-se vários conjuntos de $Y_m = [x_{t-m}, x_{t+1-m}, \dots, x_{t+i-m}]$ até $Y_n = [x_{t-n}, x_{t+1-n}, \dots, x_{t+i-n}]$ (Figura 4.5).

O objetivo do cálculo dos MI's é identificar as entradas mais dependentes de um dado conjunto de saída $X = [x_t, x_{t+1}, \dots, x_{t+i}]$ com cada possível conjunto de entrada $Y_j = [x_{t-j}, x_{t+1-j}, \dots, x_{t+i-j}]$. Inicialmente, calcula-se o $MI(X, Y_m)$, em seguida o $MI(X, Y_{m-1})$, e assim sucessivamente, até $MI(X, Y_n)$. Depois de calculado todos os MI's, são selecionados os *lags* com maiores valores de MI. Supondo hipoteticamente que $MI(X, Y_j)$ é o conjunto com maior valor, então para todos os elementos de X será considerado que o elemento do intervalo anterior j é o de maior dependência.




Figura 4.5 - Intervalos de *lags* para a seleção de entradas.

O sistema calcula o $MI(X; Y)$ para todos os intervalos de Y (Y_m até Y_n). Com os resultados, ordenam-se os valores $[MI(X; Y_m), \dots, MI(X; Y_n)]$ para que se obtenham os *lags* que apresentem maior dependência.

A Figura 4.6 mostra um exemplo do MI calculado, no qual o último ponto à direita é o valor de $MI(X, Y_m)$, o próximo elemento à esquerda é o valor de $MI(X, Y_{m-1})$, e assim sucessivamente, até $MI(X, Y_n)$. De acordo com os valores apresentados, foram selecionados os três *lags* (Y_a , Y_b e Y_c) com os maiores valores. Assim, a construção da base utiliza os dados que estão situados à a , b e c intervalos de tempo atrás do momento atual. Dessa forma, o conjunto de pontos da série $[x_{t-a}, x_{t-b}, x_{t-c}]$ são as entradas mais dependentes com cada elemento $x_t \in X$.




Figura 4.6 – Cálculo do MI selecionando 3 lags.

A construção da base utiliza os dados que estão situados à a , b e c horas atrás do momento atual. Dessa forma o conjunto $[x_{t-a}, x_{t-b}, x_{t-c}]$ são os instantes utilizados para compor o momento x_t a ser verificado. O mesmo vale para qualquer momento x_{t+l} , o qual possui o conjunto $[x_{t+l-a}, x_{t+l-b}, x_{t+l-c}]$.

Uma variação que pode ser adicionada ao MI é o *jump*, dado que o objetivo da metodologia é trabalhar com séries temporais. Assim, temos a série discretizada em horas $t = \{(hora)\}$, por exemplo, $t = \{(1), (2), \dots, (24), (25), \dots, (48)\}$, mas ela pode ser dividida em dias $t = \{(dia; hora)\}$, por exemplo, $t = \{(1; 1), (1; 2), \dots, (1; 24), (2; 1), \dots, (2; 24)\}$.

Para a técnica de seleção exemplificada acima, considera-se o *jump* “hora a hora”, pois a análise é feita indiferentemente do dia. Mas dada a discretização em dias, pode-se trabalhar com a seleção MI verificando apenas o *jump* “dia a dia”, isto é, os conjuntos X e Y são definidos em função de cada hora do dia, porém o intervalo $[t - m, t - n]$ é contínuo e definido em horas.

Veja o exemplo: para a seleção *MI* da hora 01, temos $X_1 = [x_{(t;1)}, x_{(t+1;1)}, \dots, x_{(t+i;1)}]$ e $Y_{(j;1)} = [x_{(t-j;1)}, x_{(t+1-j;1)}, \dots, x_{(t+i-j;1)}]$, o mesmo vale para qualquer hora h , onde $X_h = [x_{(t;h)}, x_{(t+1;h)}, \dots, x_{(t+i;h)}]$ e $Y_{(j;h)} = [x_{(t-j;h)}, x_{(t+1-j;h)}, \dots, x_{(t+i-j;h)}]$. Assim, cada X_h possui um conjunto de *lags* específicos, no caso ($Y_{(a;h)}$, $Y_{(b;h)}$ e $Y_{(c;h)}$). Nesta abordagem, a composição dos elementos dos conjuntos não são sucessivos no tempo.

4.3.2 Definição dos *lags* utilizando PMI

Outra técnica de seleção de variáveis é o $PMI(X; Y; Z)$, que parte do mesmo princípio do MI, a diferença é que a dependência dos dados é comparada com um terceiro grupo de variáveis candidatas. O conjunto de variáveis candidatas (Z) é composto por conjuntos de entradas com as maiores dependências, no entanto, a seleção destes conjuntos utiliza uma estratégia diferente do MI. A dificuldade dessa técnica está em estabelecer o conjunto de variáveis candidatas iniciais e um critério de parada eficiente.

Para a seleção das variáveis candidatas iniciais, optou-se por utilizar as informações obtidas no MI, adotando o conjunto de entrada com *lag* mais significativo, o qual compõe o conjunto das entradas candidatas. Ou seja, são calculados os valores de MI como descrito na Seção 4.3.1 e apresentado como parte do processo do PMI, na Figura 4.7 (1ª iteração). Neste cálculo, o conjunto Y_a foi o que apresentou maior correlação, e portanto, será a primeira série do conjunto de entradas candidatas ($Z = \{Y_a\}$).

As demais iterações são executadas pelo PMI, o qual segue o mesmo princípio do MI, mas que é influenciado pelo conjunto de entradas candidatas. A correlação de todos os conjuntos de entradas Y_j é calculada em relação ao conjunto de saída X , levando em consideração os efeitos existentes do conjunto de entradas candidatas Z já selecionados.

Na 2ª iteração, o PMI calcula a relação de independência para todos os conjuntos de entrada Y_j em relação ao conjunto de saída X e a entrada candidata Y_a selecionada. Os resultados obtidos são apresentados na Figura 4.7 (2ª iteração), sendo selecionado o conjunto de entrada de maior dependência (Y_d) e adicionado ao conjunto de entradas candidatas $Z = \{Y_a, Y_d\}$.

Por fim, a 3ª iteração segue o mesmo procedimento Y_e é o conjunto de entrada com maior dependência e que também é adicionado às variáveis candidatas $Z = \{Y_a, Y_d, Y_e\}$. Os *lags* são dados pelo conjunto de variáveis candidatas $Z = \{Y_a, Y_d, Y_e\}$.




Figura 4.7 – Calculo do PMI selecionando 3 lags.

Da mesma forma que o MI, o PMI selecionou apenas 3 *lags* (Y_a , Y_d e Y_e) que possuem maior dependência a cada iteração, mas o número de *lags* pode ser alterado para a quantidade que melhor se adequar a metodologia e ao problema. A construção da base é feita da mesma forma, o conjunto $[x_{t-a}, x_{t-d}, x_{t-e}]$ são os instantes utilizados para compor o momento x_t a ser verificado; o mesmo vale para qualquer momento x_{t+l} o qual possui o conjunto $[x_{t+l-a}, x_{t+l-d}, x_{t+l-e}]$.

Esse processo é mais lento, pois é preciso percorrer todo o intervalo a ser analisado ($[t - m, t - n]$) para definir um único atraso, e assim sucessivamente, até se obter um número suficiente de *lags* que componham as variáveis candidatas. O *jump* “hora a hora” ou “dia a dia” também pode ser empregado ao PMI, já que a estrutura dos dados continua a mesma, diferindo apenas no processo de seleção.

Nenhum método de seleção é perfeito. Na melhor das hipóteses, podemos fazer uso de informações obtidas durante a seleção para fazer algumas previsões razoavelmente precisas sobre o desempenho futuro. Em certo sentido, a seleção pode ser vista como um procedimento de gestão de risco que ajuda a organizar e a evitar a escolha de candidatos inadequados.

4.3.3 Variáveis Exógenas

Uma das principais influências no consumo de energia elétrica num horizonte de curto prazo é a condição climática. Altas temperaturas e clima úmido levam a um maior consumo de equipamentos de refrigeração, como também temperaturas muito baixas requerem maior consumo para aquecimento. Nesse sentido, é importante que se considere variáveis climáticas, principalmente a temperatura, como entradas dos modelos de previsão de demanda de curto prazo.

Nesta dissertação, não foi levado em conta as séries de temperatura, por serem necessárias séries de temperatura geograficamente próximas dos barramentos. Também é preciso pré-processá-las para torná-las compatíveis com as séries de carga.

No caso das variáveis climáticas, é possível, de maneira similar ao apresentado acima, aplicar as técnicas de MI e PMI para identificar os conjuntos de variáveis climáticas mais correlacionadas com a carga a ser prevista.

4.4 Conjunto de Bases

A partir dos procedimentos acima (pré-processamento e seleção), é necessário uni-los e criar as bases necessárias (treino, validação e teste) para os métodos de previsão. De posse dos dados (treino e validação), é aplicada a normalização sobre os dados. O fator de normalização encontrado é aplicado nos dados de teste, criando assim uma base uniforme e padronizada.

O próximo passo é a definição da quantidade de *lags* que irão compor as bases. No processo de seleção das variáveis, os *lags* definem até que ponto o algoritmo faz a busca por características correlacionadas.

Como visto, as técnicas de seleção MI e PMI estão associadas ao uso do *jump* (“hora a hora” ou “dia a dia”) para a definição de como é a abordagem nos dados. O *lag* funciona como um critério de parada para o algoritmo, interrompendo ao atingir a quantidade de variáveis candidatas, além de reduzir a quantidade de processamento necessário, dado que a busca é feita apenas em cima do maior valor do *lag*, pois valores menores já estão embutidos no intervalo procurado.

Uma variação dessa ordem (pré-processamento e seleção) pode ser empregada. A seleção pode trabalhar tanto com os dados brutos quanto eles normalizados, portanto pode ser adicionado um critério de ordem da normalização, a qual deve ser aplicada antes ou depois do processo de seleção, gerando assim diferentes resultados a partir dos mesmos princípios.

É importante salientar que todo esse procedimento pode ser suprimido, total ou parcialmente, podendo optar por não utilizar o pré-processamento e/ou a seleção das variáveis, bastando apenas definir o número de *lags* para compor as bases (nesse caso, dado um *lag* igual a n , utiliza-se o intervalo $[t - 1, t - n]$).

As bases são construídas a partir dessas condições, onde todo o processo de geração das configurações é baseado apenas nos períodos de treino e validação. O período de teste apenas utiliza tais informações geradas para a sua própria criação.

4.5 Métodos de Previsão

Tendo o conjunto de variáveis a serem utilizadas, a ferramenta passa para o processo seguinte, de execução do método de previsão. Esse processo tem a finalidade de encontrar o previsor que melhor se adapte ao conjunto de dados, uma vez que cada metodologia possui características próprias. Para tais testes são aplicadas as Redes Neurais Artificiais (do tipo MLP) para a previsão de séries temporais, uma vez que estas já se encontram bem definidas e desenvolvidas.

O sistema proposto tem o objetivo de averiguar e selecionar as melhores configurações para diferentes algoritmos de treinamento, dado que o grande desafio na utilização de redes neurais é selecionar um algoritmo de treinamento, e consequentemente, ajustar seus parâmetros, a fim de obter os pesos que possuam um melhor ajuste ao problema tratado.

Os algoritmos de treinamento utilizados foram o *backpropagation* com termo *momentum* (BPM) e o método gradiente (GRAD), método de *Fletcher-Reeves* (FR), método de *Polak-Ribière* (PR), método de *Davidon-Fletcher-Powell* (DFP), método de *Broyden-Fletcher-Goldfarb-Shanno* (BFGS), método das secantes de um passo (OSS) e método do gradiente conjugado escalonado (SCGM).

A seguir, são dados mais detalhes sobre os parâmetros de configuração dos algoritmos de previsão, assim como o funcionamento da ferramenta.

Os algoritmos de previsão possuem as seguintes entradas:

- **entrada do conjunto de treinamento:** características selecionadas do problema a ser treinada (base de dados);
- **saída do conjunto de treinamento:** saída esperada dos dados treinados;
- **entrada do conjunto de validação:** características selecionadas dos dados a serem validados (base de dados);
- **saída do conjunto de validação:** saída esperada dos dados de validação;
- **número de neurônios:** quantidade de neurônios nas camadas intermediárias;
- **taxa de aprendizagem:** capacidade do neurônio em aprender a cada iteração. O valor deve ser pequeno para evitar saturação;
- **termo *momentum*:** influência do termo momentum na atualização dos pesos;
- **limite de busca:** limiar da seção áurea;
- **erro mínimo desejado:** taxa de erro esperado para a parada do algoritmo;
- **número máximo de épocas:** número de iterações para a atualização dos pesos;
- **aleatoriedade:** fator de aleatoriedade do algoritmo.

E os retornos dos algoritmos de previsão são;

- **pesos da camada intermediária:** pesos de ativação da camada intermediária;
- **pesos da camada de saída:** pesos da camada de saída;

Para cada algoritmo de treinamento há um conjunto de parâmetros do qual faz uso. No geral, todos utilizam o conjunto de treinamento, conjunto de validação, número de neurônios, o erro mínimo, o número de épocas e a aleatoriedade, sendo que todos têm, como saída, os pesos da camada intermediária e de saída.

Apenas BPM e o GRAD fazem uso do termo *momentum*, mas somente o BPM utiliza a taxa de aprendizagem. Por sua vez, o FR, PR, DFP, BFGS e OSS utilizam do parâmetro limite de busca. Contudo, o SCGM é o único que faz uso do conjunto básico de parâmetros.

Para a seleção dos parâmetros de configuração, foi adotado o processo de busca exaustiva (força bruta), o qual consiste no teste de todas as configurações; mais detalhes sobre esse processo pode ser visto em (FRANCO JR., 2010). Esse processo foi adotado devido ao fato da complexidade em escolher tais valores de forma arbitrária.

Apesar do demorado tempo gasto para varrer todo o conjunto de parâmetros, esse processo se mostrou bastante útil, pois o torna automático e independente do fator humano.

Suponha que haja os parâmetros, número de neurônios (nh) e termo momentum (tm), onde $nh \in \{1; 2; \dots; 10\}$ e $tm \in \{0,1; 0,2; \dots; 1,0\}$. É feita uma enumeração da permutação desses parâmetros ($nh; tm$), como pode ser visto abaixo.

Combinação 1 - (1; 0,1);

Combinação 2 - (1; 0,2);

...

Combinação n-1 - (10; 0,9);

Combinação n - (10; 1,0);

Desse modo, o esforço humano é determinar os valores que devem fazer parte do conjunto de parâmetros configuráveis, para que o sistema realize de forma exaustiva a busca por resultados que melhor se apliquem ao problema tratado.

A execução do algoritmo de previsão percorre todas as combinações de parâmetros treinando e validando seus resultados, isso acontece k vezes. A cada resultado mais próspero encontrado utilizando os dados de validação, os melhores pesos são armazenados para compor o resultado final para cada tipo de previsor.

Dado que esta aplicação é voltada para séries temporais (mais especificamente, demanda de carga), a previsão é feita por faixa de horas, portanto para a hora 01 temos um conjunto de pesos, para a hora 02 temos outro conjunto de pesos, e assim por diante, até completar as 24 horas. Esse tipo de abordagem foi escolhido, devido ao fato que a demanda apresenta comportamento muito divergente ao longo do dia, mas similar na mesma faixa de horário e dessa forma, tem-se para cada hora, uma determinada combinação de pesos mais próspera.

Isto pode parecer óbvio, mas é importante ressaltar que o desempenho do previsor é formado por um grande número de fatores. Diferentes previsores podem ter desempenhos completamente diferentes para um mesmo conjunto de dados, isso porque os dados podem receber diferentes níveis de exposição ao treinamento. Alguns previsores podem ser mais aptos a outros tipos de problema, ou mesmo se adequarem melhor a situações mais ou menos complexas.

4.6 Considerações Finais

Ao final da metodologia, têm-se os valores previstos, porém normalizados (caso tenha utilizado o pré-processamento), sendo necessário inverter os valores através do fator de normalização. O fator de normalização é obtido pelo processo inverso da normalização, isto é, corresponde aos valores médios, em que ao multiplicar o dado normalizado, obtém-se o valor real previsto.

Nesta dissertação, utilizou-se o fator de normalização encontrado na validação, para transformar os valores previstos no período de teste, isto para evitar a utilização de dados que, na prática, ainda não existe no processo de previsão.

Ao transformar os dados previstos normalizados em dados previstos ajustados, são aplicadas medidas de análise de erro, que podem ser: erro médio (ME), erro médio absoluto (MAE), erro percentual médio absoluto (MAPE) e outros. A transformação pode causar uma perturbação adicional na previsão (além do erro de previsão), mas deixa a metodologia com um funcionamento próximo de uma aplicação real.

Os resultados são dados em função de cada configuração adotada e dos métodos de previsão, podendo ter uma gama enorme de resultados a serem analisados. Demais tipos de análises e gráficos são feitas de forma manual.

A ferramenta foi desenvolvida para ter pouca interferência do usuário (necessário apenas ajustar as configurações desejadas). O sistema funciona sem que o usuário tenha a necessidade de configurar e interferir durante o processo, tornando o sistema mais ágil, prático e simples de ser utilizado.

Para o desenvolvimento da ferramenta utilizou o código-M (linguagem do MATLAB®), os algoritmos de seleção de variáveis (MI e PMI) foram adaptados de RUTANEN (2011) e para previsão, foram utilizados os algoritmos de RNAs de CASTRO e ZUBEN (1998).

5 Experimentos

*“Deus não joga dados com o universo.”
(Albert Einstein)*

O Capítulo 5 apresenta o procedimento para a execução dos experimentos. Na Seção 5.1, há uma breve descrição da metodologia aplicada para a execução dos experimentos, onde foram evidenciados os conjuntos de parâmetros utilizados. A qualidade de uma previsão pode ser mensurada através de muitas medidas da avaliação, visto na Seção 5.2. A Seção 5.3 apresenta os resultados mais relevantes para os experimentos, juntamente com uma análise de tempo de execução. Na Seção 5.3.1, são apresentadas as melhores previsões obtidas para cada barramento, analisando a previsão para uma semana qualquer e para durante um ano inteiro. Por fim, na Seção 5.3.2, é feita uma análise dos fatores de potência em relação aos valores previstos.

5.1 Configurações

A fase de testes tem como finalidade obter os resultados de diversas execuções do sistema. Esse procedimento visa testar de forma diversificada e repetida o sistema, com o intuito de analisar e validar toda a proposta envolvida.

Uma série de combinações do processo de seleção foi feita, de tal forma que foi possível averiguar a influência da diversificação dos atributos para criar as bases, e consequentemente, identificar e analisar as configurações mais prósperas a serem utilizadas.

Como descrito nas Seções 4.2 à 4.4, há uma série de combinações possíveis para trabalhar com os dados e assim gerar os conjuntos (treinamento, validação e teste) necessários para utilizar nos métodos de previsão.

No Apêndice A, mais especificamente na Tabela A.1, é possível verificar todas as combinações utilizadas para criar os conjuntos de dados. Devido à grande quantidade de possibilidades, citadas anteriormente, foram selecionados apenas alguns casos que apresentaram resultados promissores em testes preliminares.

Para o pré-processamento, fez-se uso da “normalização pelo valor máximo da série” e “normalização pelo valor máximo do dia”, denominados “Máximo Série” e “Máximo Dia”, respectivamente.

Para a seleção de entradas, utilizaram-se todas as possibilidades apresentadas. Para a técnica de seleção, usou-se o “MI” e o “PMI”, agregado ao *jump* “dia a dia” e “hora a hora”. A possibilidade de trocar a ordem do pré-processamento também foi utilizada, sendo denominada “antes” e “depois” da seleção de entradas. Um campo importante de determinar é a quantidade de *lags* que deve ser observado, nesse caso, optou-se por ter 3, 5 ou 7 atrasos.

Um sistema de previsão necessita de que a base de dados seja separada em três grupos: período de treinamento, de validação e teste. Na etapa de pré-processamento e seleção, foram utilizados apenas os conjuntos de treinamento e validação.

Já para a etapa de previsão, a base de dados é utilizada durante duas fases do processo. A primeira fase utiliza o conjunto de treinamento com o intuito de treinar a rede neural; para verificar e validar os resultados obtidos, faz-se uso do conjunto de validação. A segunda etapa tem a finalidade de testar o resultado obtido pelo treinamento da rede com o conjunto de teste.

Após a geração de diferentes bases, foi possível obter uma gama de conjunto de dados que são passíveis de serem utilizados para a previsão de séries. Porém, da mesma forma que a etapa de criação do conjunto, os métodos de previsão possuem parâmetros a serem configurados.

Uma vez que o grande desafio na utilização de redes neurais é selecionar um algoritmo de treinamento, suas entradas e conseqüentemente, ajustar seus parâmetros, tem-se o intuito de fazer uma busca exaustiva das configurações para as redes neurais, de forma que se possa encontrar as melhores configurações que geram os resultados mais prósperos para o sistema a ser previsto.

Para a seleção dos parâmetros de configuração, foi adotado o processo de busca exaustiva (força bruta), o qual consiste em testar uma ampla gama de configurações. Esse processo foi adotado devido ao fato da complexidade em escolher tais valores de forma arbitrária.

Os algoritmos de treinamentos utilizados pela rede neural são: BFGS, DFP, FR, GRAD, OSS, PR e SCGM. Estes algoritmos foram escolhidos devido à sua rápida execução e ampla divulgação na literatura. Mais detalhes podem ser encontrados nas Seções 2.3.1 e 4.5.

Após analisar o comportamento dos algoritmos, com diferentes parâmetros, foram determinados quais os intervalos de variações que cada algoritmo é mais apto a executar.

Para todos os algoritmos foram definidos os seguintes parâmetros a serem utilizados: número de neurônios, nh , (Eq. 5.1), erro mínimo desejado, $minerro$, (Eq. 5.2), número máximo de épocas, $maxep$, (Eq. 5.3) e aleatoriedade, val , (Eq. 5.4).

$$neuronios = \{nh \in \mathbb{N} \text{ e } 2 \leq nh \leq 20\} \quad \text{Eq. 5.1}$$

$$erro = \{minerro = 1^{-7}\} \quad \text{Eq. 5.2}$$

$$iterações = \{maxep = 5000\} \quad \text{Eq. 5.3}$$

$$aleatoriedade = \{val = 0,5\} \quad \text{Eq. 5.4}$$

Entretanto para o GRAD, tem-se a necessidade de configurar um parâmetro a mais, o termo momentum, cm , (Eq. 5.5).

$$momentum = \begin{cases} cm \mid cm \in \mathbb{R} \text{ e } 0,1 \leq cm \leq 1,0 \text{ e} \\ (\exists x)(x \in \mathbb{N} \text{ e } cm = 0,1 + 0,1x) \end{cases} \quad \text{Eq. 5.5}$$

Para cada conjunto de configuração dos algoritmos de treinamento e base de dados trabalhada, foi executada 5 vezes a fase de treinamento, selecionando os pesos que obtiveram o menor erro para o conjunto de validação.

Selecionados os algoritmos de treinamentos, juntamente com o conjunto de configurações e determinada a divisão da base nos conjuntos de treinamento, validação e teste, é possível, assim, executar toda uma gama de experimentos a fim de validar o sistema proposto.

Esse árduo processo de geração de bases e de configuração de parâmetros tem o intuito de atacar de diferentes formas os problemas. Não existe uma relação clara e direta entre os tipos de técnicas de seleção e métodos de previsão que utilizados em conjunto levem a resultados prósperos, inclusive para a verificação de espaço de memória gasto e tempo de processamento.

Todo o sistema proposto foi desenvolvido na linguagem conhecida como Código-M, o qual foi utilizado na fase de elaboração e executado através da plataforma de desenvolvimento MATLAB® R2010a. Os experimentos foram testados em um computador com Sistema Operacional Linux Ubuntu 10.04, com processador Core2Quad de 2,0GHz e 8Gb de memória RAM.

5.2 Medidas de Avaliação

Para avaliar o desempenho de uma previsão de séries temporais, podem-se comparar os valores previstos com valores reais, através de vários métodos de avaliação. O ME, MAE e o MAPE são amplamente utilizados para avaliarem o desempenho de previsão de carga. Tais métodos são dados como se segue (Eq. 5.6, Eq. 5.7 e Eq. 5.8):

$$ME = \frac{\sum_{i=1}^n (real_i - previsto_i)}{n} \quad \text{Eq. 5.6}$$

$$MAE = \frac{\sum_{i=1}^n |real_i - previsto_i|}{n} \quad \text{Eq. 5.7}$$

$$MAPE = \frac{100 \sum_{i=1}^n \left| \frac{real_i - previsto_i}{real_i} \right|}{n} \quad \text{Eq. 5.8}$$

O erro médio (*“mean error”* - ME) é a diferença entre a quantidade medida e a quantidade estimada. O ME é dado na mesma medida que os dados originais.

O erro médio absoluto (*“mean absolute error”* - MAE) é uma medida usada para verificar o quão próximo as previsões estão dos valores reais. O MAE é medido nas mesmas unidades que os dados originais, e é geralmente similar em magnitude, mas ligeiramente menor do que, o erro quadrático médio.

O erro percentual médio absoluto (*“mean absolute percentage error”* - MAPE) é uma medida da precisão para determinar o erro de previsão em séries temporais. É expresso em valores percentuais. Embora o conceito de MAPE seja muito simples e convincente, ele apresenta algumas desvantagens:

- se existirem valores iguais a 0, então há divisão por 0, sendo o resultado indefinido;
- valores reais muito pequenos apresentam erros muito elevados, pois qualquer variação da previsão torna-se muito significativa;
- ao ter um ajuste perfeito, o MAPE é zero. Mas para erros grandes, o MAPE não tem nenhuma restrição (nenhum limite superior).

No entanto, mesmo com as desvantagens apresentadas, o MAPE foi o método de avaliação utilizado para análise dos resultados, devido à sua comparação subjetiva, pois é independente da grandeza dos valores trabalhados. O MAE foi utilizado para comparação dos resultados, mas

em segundo plano, seu uso efetivo foi no processo de validação, onde foi empregado como um dos critérios de seleção de pesos durante o treinamento. O ME foi apenas utilizado, apenas em algumas tabelas para efeito de comparação com o MAE.

5.3 Resultados

Os resultados obtidos foram avaliados para os 7 algoritmos de treinamento (BFGS, DFP, FR, GRAD, OSS, PR e SCGM) em função das métricas MAPE e MAE, sendo estes distribuídos de acordo com a configuração utilizada para criar as bases (Apêndice A).

Foi utilizado um conjunto de siglas para representar tais informações. Na primeira posição, tem-se a normalização, com “D” para “Máximo Dia” e “S” para “Máximo Série”. A segunda é a ordem da normalização “a” para “antes” e “d” para “depois”. A seleção está situada na terceira posição, com “M” para MI e “P” para PMI. O “h” representa o *jump* “hora a hora” e o “d” o *jump* “dia a dia”, na quarta posição. Na última posição tem-se a quantidade de *lags*.

Os resultados são apresentados em gráficos polares, mas antes, é necessária uma breve explicação de como foi feita a sua divisão. Os gráficos foram divididos em dois grupos (Figura 5.1), em que os da esquerda contêm apenas a normalização pelo “Máximo Dia”, enquanto os da direita contêm a normalização pelo “Máximo Série”.



Figura 5.1 - Divisão dos gráficos polares (tipo da normalização).

A ordem da normalização é apresentada na Figura 5.2 (a). No 1º e 4º quadrantes está situada a ordem da normalização “antes”, enquanto no 2º e 3º quadrantes a ordem da normalização é “depois”. O tipo de seleção utilizada (Figura 5.2 (b), em que os quadrantes são definidos) fica distribuído no 1º e 3º quadrante para o “MI” e o 2º e 4º quadrante para o “PMI”.




Figura 5.2 – Divisão dos gráficos polares. (a) ordem da normalização. (b) tipo da seleção.

A configuração de *jump* “dia a dia” fica posicionada sempre no início de cada quadrante, enquanto o *jump* “hora a hora” está no final do quadrante (Figura 5.3 (a)). Por fim, a quantidade de *lags* (3, 5 e 7) está distribuída, uniformemente, ao longo de todo o gráfico (Figura 5.3 (b)).




Figura 5.3 – Divisão dos gráficos polares. (a) tipo do *jump*. (b) quantidade de *lags*.

Foi utilizada a métrica de avaliação MAPE para os barramentos com potência ativa e o MAE para os barramentos com potência reativa (devido à demanda reativa oscilar em torno de zero, fazendo com que o MAPE seja muito elevado). Quanto mais próximos do centro, melhor é o resultado médio da avaliação para cada conjunto de base e algoritmos de treinamento.

Para a Barra-I com demanda ativa (Figura 5.4), os resultados possuem pouca influência do algoritmo de treinamento, sendo possível verificar o agrupamento das curvas. Quando utilizada a normalização “Máximo Dia”, os resultados apresentam uma melhora no *jump* “hora a hora”; já em relação à normalização “Máximo Série” fica evidente a diferença de desempenho, quando utilizado *lags* com 7 atributos e *jump* “dia a dia”.

Para os resultados com demanda reativa da Barra-I (Figura 5.5), é possível verificar, especialmente na normalização “Máximo Dia”, que os algoritmos de treinamento BFGS e DFP destacam os resultados em relação aos demais, enquanto com a normalização “Máximo Série”, não é possível fazer essa análise. Pode-se verificar para qualquer configuração uma tendência clara de melhora nos resultados que utilizam 7 atributos para definir a quantidade de *lags*.




Figura 5.4 - MAPE da Barra-I com demanda ativa para todas as configurações (%).




Figura 5.5 - MAE da Barra-I com demanda reativa para todas as configurações (MVar).

Quanto aos resultados da Barra-II de demanda ativa (Figura 5.6), há uma clara diferença no comportamento dos resultados, enquanto as bases utilizando normalização “Máximo Dia” estão todas agrupadas e próximas de 4%. As bases utilizando “Máximo Série” encontram-se visi-

velmente dispersas uma das outras e variam de 3% a 9%, podendo destacar o algoritmo de treinamento SCGM, que está mais próximo do centro que os demais.

O gráfico da demanda reativa da Barra-II (Figura 5.7) apresenta comportamento de melhora sempre que se utiliza *lags* com 7 atributos; a normalização, nesse caso, não afeta tanto os resultados. Apenas vale destacar que em alguns casos, os algoritmos de treinamento DFP, FR e SCGM apresentaram um deslocamento de melhora em relação aos demais.




Figura 5.6 - MAPE da Barra-II com demanda ativa para todas as configurações (%).




Figura 5.7 - MAE da Barra-II com demanda reativa para todas as configurações (MVar).

A Barra-III com demanda ativa (Figura 5.8) apresenta um comportamento similar ao Barra-II com demanda ativa, com os resultados agrupados na normalização “Máximo Dia” e separados, com especial destaque para o SCGM, na normalização “Máximo Série”.

Por fim, a Barra-III com demanda reativa (Figura 5.9), novamente comporta-se como a Barra-II com demanda reativa: resultados agrupados, com tendências de melhora quando utilizando 7 atributos para os *lags* e uma sutil distinção para os algoritmos DFP, FR e SCGM.




Figura 5.8 - MAPE da Barra-III com demanda ativa para todas as configurações (%).




Figura 5.9 - MAE da Barra-III com demanda reativa para todas as configurações (MVar).

Para mais detalhes, pode-se verificar a Tabela A.2 à Tabela A.13, onde são encontrados os resultados das medidas MAPE e MAE para todas as subestações (Barra-I, Barra-II e Barra-III), além de demanda ativa e reativa para cada um dos casos. Os resultados são apresentados em escala de cor, dos piores em vermelho aos melhores em azul, passando por tons mais claros.

Durante todos os experimentos, foram armazenados os tempos de execução, cujo controle tem o intuito de comparar a diferença entre as diversas configurações que o sistema possui, além de servir como um comparativo para outros trabalhos. Os tempos foram avaliados em minutos, sendo separados por barramento e tipo de demanda. Devido ao alto volume de bases e previsores, estes foram agrupados em conjuntos que apresentaram valores similares (Tabela 5.1).

A variação de tempo para a geração das bases dá-se em função das técnicas de seleção utilizadas, tendo uma diferença considerável entre “MI” e “PMI”, a quantidade de *lags* influencia nesse cálculo também, mas de forma mais amena.

Quanto aos métodos de previsão, estes podem ser divididos em 3 grupos de algoritmos de treinamento, GRAD, SCGM e Outros (BFGS, DFP, FR, OSS e PR). O método GRAD possui um tempo elevado, devido ao número maior de parâmetros a serem testados; por sua vez, o SCGM e os Outros apresentam tempos similares, tendo destaque o SCGM, devido à sua ampla presença nos melhores resultados.

Tabela 5.1 - Análise dos tempos de execução do sistema (minutos).

<i>Barramento</i>	<i>Demanda</i>	<i>Técnicas de Seleção</i>		<i>Algoritmos de Treinamento</i>		
		MI	PMI	GRAD	SCGM	Outros
Barra-I	ativo	5,98	67,95	46,87	9,31	10,36
	reativo	5,92	76,80	43,15	4,20	5,33
Barra-II	ativo	12,32	62,95	37,98	4,09	5,60
	reativo	6,44	75,94	38,26	4,11	5,11
Barra-III	ativo	6,01	60,58	34,09	3,75	5,14
	reativo	6,39	72,45	37,53	4,28	5,21

Apesar do alto custo computacional gasto para executar todos os experimentos e configurações, a execução a partir das bases criadas e dos pesos gerados é muito rápida, em média, menos de 1 segundo, o que a torna viável para a utilização em sistemas de previsão de tempo real.

5.3.1 Melhores Previsões

Em uma primeira análise dos melhores resultados, são apresentadas as previsões de todos os barramentos para três semanas (Semana A de 09/04/2010 a 09/04/2010, Semana B de 12/09/2010 a 17/09/2010 e Semana C de 20/03/2011 a 25/03/2011). Tanto os gráficos, quanto nas

tabelas é evidenciada a previsão da demanda ativa e reativa em relação aos valores reais. Nas tabelas, também há o cálculo das medidas ME, MAE e MAPE.

Para a Barra-I com demanda ativa na Semana A (Figura 5.10) verifica-se uma redução da previsão na quarta e um aumento da carga na sexta. O MAE foi de 1,87 MW e o MAPE de 5,89%. Para a Semana B (Figura 5.11) a previsão acompanha os picos de energia, tendo na maior parte do tempo um aumento da carga, vale destacar que as 18h a previsão apresenta um aumento significativo em relação ao real. O MAE foi de 1,34 MW e o MAPE de 3,22%.




Figura 5.10 – Análise da previsão de potência ativa para Barra-I para a Semana A.




Figura 5.11 – Análise da previsão de potência ativa para Barra-I para a Semana B.




Figura 5.12 – Análise da previsão de potência ativa para Barra-I para a Semana C.

Para a Semana C (Figura 5.12), a previsão não acompanha os picos de energia (de segunda a quinta), tendo assim uma redução da carga, nos demais dias a previsão acompanha bem a carga. O MAE foi de 1,74 MW e 4,85% o MAPE. Pela Tabela 5.2 é possível obter informações gerais sobre cada Semana analisada.

Tabela 5.2 – Momentos amostrais da Barra-I com potência ativa para as Semanas.

<i>Semana</i>	<i>Série</i>	<i>Média</i>	<i>D. Padrão</i>	<i>Mínimo</i>	<i>Máximo</i>	<i>Assimetria</i>	<i>Curtose²</i>
A (MW*)	real	34,17*	4,61*	22,40*	41,60*	-0,49	-0,74
	previsto	34,16*	3,20*	24,37*	40,23*	-0,48	-0,31
	ME	0,01*	2,56*	-12,08*	4,64*	-1,55	3,84
	MAE	1,87*	1,75*	0,03*	12,08*	2,49	9,49
	MAPE	5,89%	6,82%	0,08%	53,92	3,69	18,99
B (MW*)	real	42,20*	4,70*	33,80*	52,00*	0,38	-0,80
	previsto	42,56*	4,21*	34,08*	50,78*	0,06	-0,95
	ME	-0,36*	1,64*	-5,61*	2,97*	-0,38	0,07
	MAE	1,34*	1,01*	0,01*	5,61*	1,28	2,21
	MAPE	3,22%	2,55%	0,04%	14,65	1,51	3,18
C (MW*)	real	36,10*	4,11*	25,20*	46,90*	0,46	-0,03
	previsto	36,13*	3,25*	27,49*	45,29*	0,26	-0,09
	ME	-0,03*	2,48*	-9,88*	5,74*	-0,74	2,23
	MAE	1,74*	1,76*	0,01*	9,88*	1,75	3,91
	MAPE	4,85%	5,50%	0,03%	39,20%	3,09	14,31

² Algumas definições de curtose subtraem 3 (três) do valor calculado, para que a distribuição normal tenha curtose 0 (zero). Para uma melhor compreensão dos resultados, esta dissertação também adotou essa medida.

A Semana A da Barra-I com demanda reativa (Figura 5.13) obteve uma previsão próxima da real, apresentado no domingo e sexta um leve aumento da carga reativa. O MAE foi de 0,91 MVar e o MAPE de 123,42%, devido a carga estar próxima de zero, isso causa uma perturbação nos resultados do MAPE. Para a Semana B (Figura 5.14) a previsão segue da carga real, tendo um MAE de 0,77 MVar e o MAPE de 74,07%.




Figura 5.13 – Análise da previsão de potência reativa para Barra-I para a Semana A.




Figura 5.14 – Análise da previsão de potência reativa para Barra-I para a Semana B.




Figura 5.15 – Análise da previsão de potência reativa para Barra-I para a Semana C.

Por fim a Semana C (Figura 5.15) apresenta toda a carga prevista aumentada em relação a real, isso se deu pela carga real ter uma redução brusca nesse período (como pode ser verificado na Figura 3.3) e o predictor não estar treinado para tal evento. O MAE foi de 3,64 MVAr e o MAPE de 30,55%. Pela Tabela 5.3 é possível verificar os momentos amostrais para a Barra-I com potência reativa ao longo das três Semanas.

Tabela 5.3 – Momentos amostrais da Barra-I com potência reativa para as Semanas.

<i>Semana</i>	<i>Série</i>	<i>Média</i>	<i>D. Padrão</i>	<i>Mínimo</i>	<i>Máximo</i>	<i>Assimetria</i>	<i>Curtose²</i>
A (MVAr*)	real	0,70*	2,11*	-5,20*	5,70*	-0,21	-0,07
	previsto	1,03*	2,14*	-4,21*	5,40*	-0,05	-0,66
	ME	-0,33*	1,17*	-4,30*	2,68*	-0,33	0,64
	MAE	0,91*	0,80*	0,00*	4,30*	1,33	1,86
	MAPE	123,42%	275,52%	0,12%	2.308,71%	5,30	31,85
B (MVAr*)	real	2,40*	2,50*	-2,50*	8,10*	0,34	-0,67
	previsto	2,05*	2,25*	-2,42*	7,46*	0,34	-0,58
	ME	0,36*	0,99*	-3,02*	3,56*	0,18	1,61
	MAE	0,77*	0,71*	0,01*	3,56*	1,58	2,91
	MAPE	74,07%	152,45%	0,31%	1.387,05%	5,13	34,49
C (MVAr*)	real	-11,61*	3,26*	-19,20*	-3,90*	0,00	-0,45
	previsto	-8,24*	3,41*	-14,95*	0,45*	0,63	0,07
	ME	-3,37*	3,33*	-15,79*	3,89*	-1,15	2,15
	MAE	3,64*	3,03*	0,06*	15,79*	1,64	3,13
	MAPE	30,55%	24,00%	0,78%	108,79%	1,52	1,75

Para a potência ativa na Barra-II na Semana A (Figura 5.16) verifica-se que o comportamento da previsão próximo do real, pode-se destacar um leve aumento da carga no domingo e na sexta. O MAE foi de 2,61 MW e de 2,32% para o MAPE. Já a Semana B (Figura 5.17) a previsão também próxima da real, mas com uma sutil redução da carga ao longo da semana. O MAE obteve 3,34 MW e o MAPE 2,60%.




Figura 5.16 – Análise da previsão de potência ativa para Barra-II para a Semana A.




Figura 5.17 – Análise da previsão de potência ativa para Barra-II para a Semana B.




Figura 5.18 – Análise da previsão de potência ativa para Barra-II para a Semana C.

Por último, a Semana C (Figura 5.18) prevê com uma certa redução das 18h as 22h durante toda a semana, enquanto para a quinta e sábado há uma elevação das 9h as 15h. O MAE calculado foi de 3,11 MW e o MAPE de 2,55%. A Tabela 5.4 apresenta os dados para a Barra-II com potência ativa para as Semanas analisadas.

Tabela 5.4 – Momentos amostrais da Barra-II com potência ativa para as Semanas.

<i>Semana</i>	<i>Série</i>	<i>Média</i>	<i>D. Padrão</i>	<i>Mínimo</i>	<i>Máximo</i>	<i>Assimetria</i>	<i>Curtose²</i>
A (MW*)	real	112,46*	12,97*	85,10*	138,20*	-0,11	-1,00
	previsto	112,05*	12,47*	86,84*	138,83*	0,08	-1,00
	ME	0,41*	4,06*	-21,39*	17,85*	-0,24	7,29
	MAE	2,61*	3,13*	0,00*	21,39*	2,92	11,49
	MAPE	2,32%	2,74%	0,00%	19,36%	2,84	11,12
B (MW*)	real	127,05*	14,05*	99,10*	156,00*	-0,01	-0,97
	previsto	124,55*	13,40*	96,12*	151,35*	0,03	-0,86
	ME	2,50*	4,05*	-11,22*	20,12*	0,82	2,77
	MAE	3,34*	3,38*	0,02*	20,12*	1,80	4,09
	MAPE	2,60%	2,52%	0,02%	14,33%	1,54	2,81
C (MW*)	real	120,33*	11,95*	94,70*	145,90*	-0,05	-0,82
	previsto	118,75*	11,56*	95,46*	143,34*	-0,02	-0,91
	ME	1,58*	4,09*	-15,90*	11,48*	-0,50	2,44
	MAE	3,11*	3,08*	0,00*	15,90*	1,37	1,58
	MAPE	2,55%	2,48%	0,00%	14,18%	1,48	2,59

A previsão da Semana A da Barra-II com potência reativa (Figura 5.19) possui um comportamento próximo do real, prevendo adequadamente mesmo com a redução de carga na manhã de sábado. Para esse cenário MAE foi de 1,59 MVar e o MAPE de 78,57%. Para a Semana B (Figura 5.20) a previsão acompanha a carga, mas possui diferenças significativas quanto a carga real. O MAE foi de 2,48 MVar e o MAPE de 14,78%.




Figura 5.19 – Análise da previsão de potência reativa para Barra-II para a Semana A.




Figura 5.20 – Análise da previsão de potência reativa para Barra-II para a Semana B.




Figura 5.21 – Análise da previsão de potência reativa para Barra-II para a Semana C.

Para a Semana C (Figura 5.21) a previsão tem um comportamento similar a Semana B, onde a previsão acompanha a carga real, mas apresenta diferenças significativas ao longo da semana. O MAE foi de 1,97 MVAr e o MAPE de 16,55%. Os dados para a Barra-II com potência reativa para as Semanas analisadas estão na Tabela 5.5.

Tabela 5.5 – Momentos amostrais da Barra-II com potência reativa para as Semanas.

<i>Semana</i>	<i>Série</i>	<i>Média</i>	<i>D. Padrão</i>	<i>Mínimo</i>	<i>Máximo</i>	<i>Assimetria</i>	<i>Curtose²</i>
A (MVAr*)	real	7,41*	5,96*	-7,30*	19,20*	-0,12	-0,58
	previsto	7,51*	5,81*	-8,31*	18,02*	-0,30	-0,51
	ME	-0,10*	2,21*	-9,48*	5,16*	-0,37	2,07
	MAE	1,59*	1,53*	0,02*	9,48*	1,78	4,11
	MAPE	78,57%	285,55%	0,32%	2.948,80%	8,26	73,39
B (MVAr*)	real	17,99*	5,96*	4,90*	30,70*	-0,15	-0,78
	previsto	17,22*	5,40*	5,00*	28,14*	-0,39	-0,67
	ME	0,76*	3,16*	-8,86*	10,85*	0,32	0,53
	MAE	2,48*	2,09*	0,00*	10,85*	1,34	1,94
	MAPE	14,78%	13,80%	0,00%	72,78%	1,74	3,23
C (MVAr*)	real	14,26*	6,12*	2,60*	28,80*	0,26	-0,76
	previsto	14,23*	5,73*	3,47*	27,72*	0,07	-0,91
	ME	0,03*	2,58*	-7,87*	6,66*	0,06	0,38
	MAE	1,97*	1,65*	0,02*	7,87*	1,14	0,97
	MAPE	16,55%	17,47%	0,24%	110,81%	2,53	8,65

A previsão da Barra-III com potência ativa na Semana A (Figura 5.22), durante segunda a quinta e sábado, há uma redução da carga das 18h as 22h. No domingo a carga aumento no meio do dia, e reduz ao final. O MAE foi de 9,76 MW e de 2,83% para o MAPE. Para a Semana B (Figura 5.23) o comportamento é melhor, a previsão acompanha bem a carga, havendo apenas uma redução no sábado e domingo das 19h as 23h. O MAE obteve 7,24 MW e o MAPE 2,30%.




Figura 5.22 – Análise da previsão de potência ativa para Barra-III para a Semana A.




Figura 5.23 – Análise da previsão de potência ativa para Barra-III para a Semana B.




Figura 5.24 – Análise da previsão de potência ativa para Barra-III para a Semana C.

Já a Semana C (Figura 5.24), apresenta os mesmos problemas que a Semana A, onde há uma redução da carga prevista ao final do dia. O MAE foi de 10,03 MW e o MAPE de 2,76%. A Tabela 5.6 apresenta os dados para a Barra-III com potência ativa para as Semanas analisadas.

Tabela 5.6 – Momentos amostrais da Barra-III com potência ativa para as Semanas.

<i>Semana</i>	<i>Série</i>	<i>Média</i>	<i>D. Padrão</i>	<i>Mínimo</i>	<i>Máximo</i>	<i>Assimetria</i>	<i>Curtose²</i>
A (MW*)	real	347,06*	48,74*	248,50*	422,40*	-0,22	-1,25
	previsto	342,03*	47,85*	246,38*	424,39*	-0,09	-1,21
	ME	5,02*	12,66*	-27,41*	58,54*	0,69	1,89
	MAE	9,76*	9,48*	0,13*	58,54*	1,73	4,48
	MAPE	2,83%	2,77%	0,04%	15,54%	1,76	4,29
B (MW*)	real	320,87*	48,06*	221,70*	385,10*	-0,29	-1,39
	previsto	318,66*	48,18*	225,59*	392,80*	-0,24	-1,35
	ME	2,20*	11,30*	-15,70*	62,17*	2,21	7,66
	MAE	7,24*	8,93*	0,01*	62,17*	3,28	14,24
	MAPE	2,30%	2,78%	0,00%	18,95%	2,98	11,76
C (MW*)	real	355,78*	45,63*	267,60*	428,60*	-0,19	-1,24
	previsto	350,92*	45,28*	258,07*	434,66*	-0,05	-1,04
	ME	4,87*	13,88*	-26,20*	56,67*	1,06	1,76
	MAE	10,03*	10,74*	0,18*	56,67*	1,81	3,72
	MAPE	2,76%	2,84%	0,05%	14,57%	1,64	2,86

A previsão da Barra-III com potência reativa na Semana A (Figura 5.25) conseguiu acompanhar a carga real, mesmo durante uma variação desta durante terça e quarta. O MAE calcula foi de 3,91 MVar e de 4,50% para o MAPE. Para a Semana B (Figura 5.26) a previsão não conseguiu detectar um aumento da carga no início do dia de quinta a sábado, além de não suprir o pico de energia no final de sábado. O MAE foi de 3,85 MVar e o MAPE de 5,40%.




Figura 5.25 – Análise da previsão de potência reativa para Barra-III para a Semana A.




Figura 5.26 – Análise da previsão de potência reativa para Barra-III para a Semana B.




Figura 5.27 – Análise da previsão de potência reativa para Barra-III para a Semana C.

A Semana C (Figura 5.27) apresenta uma previsão próxima da carga real. O MAE foi de 3,93 MVAr e o MAPE de 5,54%. A Tabela 5.7 apresenta os dados para a Barra-III com potência reativa para as Semanas analisadas.

Tabela 5.7 – Momentos amostrais da Barra-III com potência reativa para as Semanas.

<i>Semana</i>	<i>Série</i>	<i>Média</i>	<i>D. Padrão</i>	<i>Mínimo</i>	<i>Máximo</i>	<i>Assimetria</i>	<i>Curtose²</i>
A (MVAr*)	real	87,14*	14,89*	52,80*	120,20*	0,08	-0,91
	previsto	86,56*	14,33*	56,36*	121,01*	0,05	-1,03
	ME	0,58*	5,48*	-23,44*	19,75*	-0,40	3,47
	MAE	3,91*	3,88*	0,04*	23,44*	2,22	6,32
	MAPE	4,50%	4,45%	0,05%	31,71%	2,60	10,21
B (MVAr*)	real	78,01*	20,37*	42,50*	116,10*	-0,06	-1,20
	previsto	77,74*	21,12*	41,50*	116,23*	-0,13	-1,35
	ME	0,27*	5,31*	-12,68*	18,17*	0,76	1,59
	MAE	3,85*	3,66*	0,06*	18,17*	1,70	3,06
	MAPE	5,30%	5,38%	0,10%	28,84%	1,97	4,46
C (MVAr*)	real	73,79*	19,47*	31,70*	113,80*	0,07	-0,92
	previsto	73,33*	19,78*	31,14*	113,24*	0,04	-0,97
	ME	0,46*	5,08*	-11,40*	16,50*	0,30	0,25
	MAE	3,93*	3,24*	0,01*	16,50*	1,13	1,05
	MAPE	5,54%	4,48%	0,01%	19,81%	1,00	0,40

Para uma visão ao longo de um ano, foram feitas análises dos gráficos anteriores (Figura 5.4 a Figura 5.9) e, avaliando os resultados no Apêndice A, verificam-se os melhores resultados obtidos. Os gráficos, a seguir, apresentam os valores reais e os previstos para cada barramento analisado (de 01/04/2010 a 31/03/2011). Em todos os casos, o melhor algoritmo de treinamento foi o SCGM, diferindo apenas a base de dados utilizada.




Figura 5.28 - Série real e prevista (DaPh7 SCGM) para a Barra-I com demanda ativa.




Figura 5.29 - Série real e prevista (DdPh7 SCGM) para a Barra-I com demanda reativa.

Para Barra-I com demanda ativa (Figura 5.28) o melhor desempenho foi DaPh7 com 4,18% do MAPE e 1,54 MW do MAE; já a demanda reativa (Figura 5.29), foi a base DdPh7 com 84,31% do MAPE e 0,97 MVar do MAE, ambas utilizam a normalização “Máximo Dia”, técnica de seleção “PMI” associada com o *jump* “hora a hora” e com 7 atributos no *lags*, a única diferença está que a ativa utiliza a ordem de normalização “antes” e a reativa “depois” da seleção.




Figura 5.30 - Série real e prevista (SdMd7 SCGM) para a Barra-II com demanda ativa.




Figura 5.31 - Série real e prevista (SaMh7 SCGM) para a Barra-II com demanda reativa.

Para Barra-II com demanda ativa (Figura 5.30), o melhor desempenho foi SdMd7 com 2,54% do MAPE e 3,09 MW do MAE, já a demanda reativa (Figura 5.31) foi a base SaMh7 com 35,55% do MAPE e 2,00 MVar do MAE, ambas utilizam a normalização “Máximo Série”, a técnica de seleção “MI” e com 7 atributos para os *lags*, porém a ativa, a ordem da normalização é “depois” e o *jump* “dia a dia”, enquanto a reativa, a ordem é “antes” e com *jump* “hora a hora”.




Figura 5.32 - Série real e prevista (SdMd7 SCGM) para a Barra-III com demanda ativa.




Figura 5.33 - Série real e prevista (SaPh7 SCGM) para a Barra-III com demanda reativa.

Para Barra-III com demanda ativa (Figura 5.32), o melhor desempenho foi SdMd7 com 2,48% do MAPE e 8,16 MW do MAE, já com demanda reativa (Figura 5.33) foi a base SaPh7 com 6,38% do MAPE e 4,43 MVar do MAE, ambas utilizam a normalização “Máximo Série” e 7 lags. Enquanto a barra com demanda ativa tem ordem de normalização “depois”, técnica de seleção “MI” e *jump* “dia a dia”, a reativa é “antes”, “PMI” e “hora a hora” respectivamente.

É importante salientar que, mesmo os resultados sendo mais prósperos em algumas configurações, há outras que são tão boas quanto as escolhidas, é o caso do conjunto de bases criados utilizando a normalização pelo “Máximo Dia” com ordem “depois”, dando destaque especial quando se utilizam lags com 7 atributos e algoritmo de treinamento SCGM.

Em função dos valores previstos, aplicaram-se alguns testes com o intuito de aprofundar o entendimento dos resultados mais prósperos. Foram calculados os momentos amostrais (média, desvio padrão, valor mínimo e máximo, assimetria e curtose) para cada experimento. Para mais detalhes sobre as medidas veja a seção 3.3.

A Tabela 5.8 apresenta os momentos amostrais para os barramentos com potência ativa, enquanto a Tabela 5.9 os barramentos com potência reativa.

Tabela 5.8 - Momentos amostrais para a série real, série prevista, ME, MAE e MAPE para os barramentos com potência ativa.

<i>Barramento</i>	<i>Série</i>	<i>Média</i>	<i>D. Padrão</i>	<i>Mínimo</i>	<i>Máximo</i>	<i>Assimetria</i>	<i>Curtose</i> ³
Barra-I (MW*)	real	37,92*	5,01*	22,10*	52,30*	0,18	-0,01
	previsto	38,28*	4,50*	23,13*	51,17*	0,05	-0,14
	ME	0,36*	1,99*	-12,07*	8,30*	0,29	1,41
	MAE	1,54*	1,31*	0,00*	15,34*	1,62	4,72
	MAPE	4,18%	3,85%	0,00%	53,92%	2,38	12,92
Barra-II (MW*)	real	120,19*	14,45*	83,20*	163,30*	0,22	-0,42
	previsto	118,72*	13,45*	81,72*	156,19*	0,19	-0,54
	ME	-1,48*	3,98*	-30,70*	21,05*	0,20	3,48
	MAE	3,09*	2,91*	0,00*	30,70*	1,86	5,57
	MAPE	2,55%	2,38%	0,00%	30,10%	2,15	9,61
Barra-III (MW*)	real	330,26*	50,20*	202,10*	430,80*	-0,13	-1,04
	previsto	327,90*	47,87*	206,56*	434,66*	-0,14	-0,95
	ME	-2,36*	11,73*	-91,99*	73,68*	-0,08	5,51
	MAE	8,16*	8,74*	0,00*	91,99*	2,54	10,08
	MAPE	2,48%	2,74%	0,00%	37,32%	3,19	18,55

³ Algumas definições de curtose subtraem 3 (três) do valor calculado, para que a distribuição normal tenha curtose 0 (zero). Para uma melhor compreensão dos resultados, esta dissertação também adotou essa medida.

Tabela 5.9 - Momentos amostrais para a série real, série prevista, ME, MAE e MAPE para os barramentos com potência reativa.

<i>Barramento</i>	<i>Série</i>	<i>Média</i>	<i>D. Padrão</i>	<i>Mínimo</i>	<i>Máximo</i>	<i>Assimetria</i>	<i>Curtose³</i>
Barra-I (MVAr*)	real	0,95*	3,50*	-19,20*	10,30*	-1,46	4,44
	previsto	1,00*	2,88*	-14,95*	8,44*	-1,22	3,36
	ME	0,05*	1,47*	-12,73*	8,81*	1,60	12,07
	MAE	0,97*	1,10*	0,00*	15,79*	3,80	27,04
	MAPE	84,31%	194,43%	0,01%	4.098,61%	7,56	83,94
Barra-II (MVAr*)	real	12,58*	7,27*	-9,30*	36,80*	-0,10	-0,13
	previsto	12,31*	6,83*	-9,28*	33,55*	-0,28	-0,24
	ME	-0,27*	2,65*	-11,10*	14,05*	-0,40	1,58
	MAE	2,00*	1,76*	0,00*	15,93*	1,72	4,51
	MAPE	35,55%	182,57%	0,00%	11.104,57%	32,26	1.639,48
Barra-III (MVAr*)	real	74,19*	19,02*	19,80*	125,80*	0,00	-0,61
	previsto	73,87*	18,99*	17,72*	124,26*	-0,09	-0,64
	ME	-0,33*	6,03*	-29,67*	26,03*	0,23	1,89
	MAE	4,43*	4,10*	0,00*	29,68*	1,73	3,88
	MAPE	6,38%	6,42%	0,00%	89,80%	2,41	10,39

As tabelas acima apresentam os valores apenas para o período de teste (01/04/2010 à 31/03/2011), onde a série real retrata o que aconteceu nesse período e a série prevista apresenta os valores mais prósperos obtidos pelo sistema de previsão. Foi adicionado também o cálculo do ME, em conjunto com os resultados obtidos no MAE e MAPE. A diferença entre os resultados dá-se pelo fato do MAE utilizar os valores absolutos e o ME apenas a diferença entre real e previsto.

Ainda dando ênfase aos melhores resultados, são apresentados gráficos em função do erro para cada um dos barramentos. Os *boxplots* estão em função do erro médio (ME) para cada hora, ao longo de todo o período de teste.

Como o objetivo é minimizar o erro de previsão, quanto mais próximo os valores de 0 (zero), melhor é a previsão, independente da demanda (ativa ou reativa). Quando os valores estão acima de zero, a previsão é inferior ao valor real. Caso os valores estejam abaixo de zero, a previsão será superior ao real.

A Figura 5.34 apresenta o *boxplot* para a Barra-I com demanda ativa, o ME fica em torno de 0 (zero) e possui poucos *outliers*, enquanto a Barra-I com demanda reativa (Figura 5.35), o erro gira em torno de zero, com uma tendência de previsão superior aos valores reais. Vale destacar os erros nas horas 9, 19 e 23, com uma grande quantidade de *outliers*.




Figura 5.34 - Boxplot da série prevista e real para a Barra-I com demanda ativa.




Figura 5.35 - Boxplot da série prevista e real para a Barra-I com demanda reativa.

A previsão da Barra-II com demanda ativa (Figura 5.36) foi inferior aos valores reais, causando em alguns casos um erro médio positivo. Por sua vez, a Barra-II com demanda reativa (Figura 5.37) apresenta os erros em torno de zero, com destaque aos *outliers* da hora 1 à 7.




Figura 5.36 - Boxplot da série prevista e real para a Barra-II com demanda ativa.




Figura 5.37 - Boxplot da série prevista e real para a Barra-II com demanda reativa.

A previsão da Barra-III com demanda ativa (Figura 5.38) teve uma variação sutil entre os valores reais e previstos, com destaque para as horas 8 à 10 e 19, com uma quantidade elevada de *outliers*. Já a Barra-III com demanda reativa (Figura 5.39), apresenta os erros em torno de zero.




Figura 5.38- Boxplot da série prevista e real para a Barra-III com demanda ativa.




Figura 5.39 - Boxplot da série prevista e real para a Barra-III com demanda reativa.

Devido à análise ser feita ao longo de 1 ano, em praticamente todos os casos há *outliers* e isso se dá pelo predictor ser de uso amplo e independente da época do ano testado, além de não ter sido feito o deslocamento da carga para o período correspondente ao horário de verão.

A fim de verificar qual o impacto do dia da semana e da hora, foi calculado o MAE semanal, de forma horária, para analisar as tendências da previsão, como pode ser visto nas Tabela 5.10, Tabela 5.12 e Tabela 5.14 para as barras com demanda ativa e as Tabela 5.11, Tabela 5.13 e Tabela 5.15 para as barras com demanda reativa.

Foram calculadas as tabelas para todos os barramentos, utilizando os melhores resultados obtidos. Os resultados são dados em função do MAE para cada dia da semana e hora, também é possível analisar os valores médios para o dia da semana, para cada hora ou o MAE total.

A Tabela 5.10 contém os resultados da Barra-I com demanda ativa, não há grandes variações no âmbito semanal, os valores estão situados entre 1 MW e 2 MW. No âmbito horário, os resultados ficam em torno de 1 MW, mas pode-se destacar na hora 19 um MAE maior que 2 MW, seguido logo de uma queda para menos de 1 MW nas horas 20 e 21.

A Barra-I com demanda reativa é apresentada na Tabela 5.11, possui um comportamento similar a barra com demanda ativa. Os valores oscilam entre 0,5 MVar e 1,3 MVar na análise horária e há uma variação na hora 19, com um MAE de aproximadamente 2 MVar. Ao longo da semana, não há grandes variações entre os dias.

Na Tabela 5.12 da Barra-II com demanda ativa, é possível verificar que os erros estão situados na faixa de 1 MW e 3 MW, mas nas horas 4, 8 à 10, 14 à 16 e 19, o erro supera os 4 MW. A variação da semana é baixa em relação aos dias, ficando entre 2,8 MW e 3,5 MW.

A Barra-II com demanda reativa (Tabela 5.13) possui baixa variação do MAE entre os dias da semana. Mas em relação à variação nas horas, há algumas faixas que o MAE aproxima ou supera os 2 MVar (7 à 10, 12 à 16, 18 à 20 e 24 horas).

A Tabela 5.14 apresenta a Barra-III com demanda ativa, onde a maioria dos erros da faixa horária ficam abaixo de 10 MW, salvo as horas 7, 9 à 11 e 18 à 22, em que o MAE é maior que 10MW. Como os casos anteriores, a faixa semanal não apresenta grandes variações.

Por fim, a Tabela 5.15 contém a Barra-III com demanda reativa, em que o erro está situado abaixo de 4 MVar para a faixa horária e acima dos 4 MVar para as horas 1, 7 à 10, 14 à 21 e 23. A faixa semanal não apresenta variações.

Com base nestes resultados, verificar-se que a faixa variação horária tem um fator de impacto maior que a variação semanal. Motiva-se, dessa forma, a realização de pesquisas com modelos mais específicos para faixas de horas. Claro que a construção de modelos que trabalham com a previsão específica para os dias da semana também pode contribuir de forma positiva.

Tabela 5.10 – MAE semanal e horário para a Barra-I com demanda ativa (MW*).

<i>hora</i>	<i>domingo*</i>	<i>segunda*</i>	<i>terça*</i>	<i>quarta*</i>	<i>quinta*</i>	<i>sexta*</i>	<i>sábado*</i>	<i>média*</i>
1	1,2790	0,9303	1,6485	1,7016	2,0320	1,9840	1,9497	1,6464
2	1,0984	1,1389	1,8779	1,5733	1,8568	1,9316	1,4243	1,5573
3	1,2466	0,9696	1,8904	1,9383	2,2416	2,3087	1,6090	1,7434
4	1,7068	1,6838	1,1047	1,1726	1,2767	1,5597	1,9582	1,4947
5	1,2098	1,6681	1,7670	2,1217	2,0586	2,1061	1,3662	1,7568
6	1,3478	1,2854	1,4696	1,3805	1,3532	1,5080	1,4992	1,4062
7	1,1387	1,7819	1,2307	1,4838	1,2796	1,3365	1,1736	1,3464
8	1,3003	1,5428	1,4500	1,2823	1,2840	1,5740	1,2851	1,3884
9	1,1965	1,2714	1,4483	1,3279	1,3695	1,5229	1,2286	1,3379
10	1,5801	1,5862	1,7107	1,4386	1,2566	1,6447	1,4078	1,5178
11	2,5608	2,4353	1,8585	1,7128	1,5929	1,7579	1,4099	1,9040
12	1,4302	1,8180	2,2539	1,9731	2,1833	2,1304	1,6996	1,9269
13	1,2052	2,0083	1,4010	1,2672	1,3081	1,6530	1,2966	1,4485
14	0,8451	2,8203	1,7167	1,5199	1,5800	1,8723	1,8177	1,7389
15	0,8464	1,8522	1,7724	1,3183	1,5163	1,5458	1,4669	1,4740
16	1,2431	2,0208	1,7507	1,1706	1,5108	1,8429	1,9930	1,6474
17	1,1554	2,4333	2,3365	1,6792	1,8785	1,8936	1,8325	1,8870
18	0,8108	1,2593	1,2001	1,0718	0,9933	1,1406	1,5231	1,1427
19	2,0234	2,8323	2,6574	3,1184	3,1699	3,3982	1,8681	2,7240
20	0,7754	0,6886	0,7555	0,6859	0,7688	0,6994	1,0410	0,7735
21	0,7252	1,1445	0,9736	0,7849	0,7339	1,0408	0,9240	0,9039
22	0,7912	1,4657	1,5023	1,4691	1,4823	1,4281	1,1253	1,3234
23	1,0187	1,1553	1,5235	1,7581	1,9338	2,1026	1,9157	1,6297
24	1,0913	1,0666	1,3757	1,2376	1,3921	1,5510	1,2787	1,2847
<i>média*</i>	1,2344	1,6191	1,6115	1,5078	1,5855	1,7305	1,5039	1,5418

Tabela 5.11 – MAE semanal e horário para a Barra-I com demanda reativa (MVar*).

<i>hora</i>	<i>domingo*</i>	<i>segunda*</i>	<i>terça*</i>	<i>quarta*</i>	<i>quinta*</i>	<i>sexta*</i>	<i>sábado*</i>	<i>média*</i>
1	0,6085	0,7591	0,5359	0,5827	0,5327	0,6512	0,6898	0,6229
2	0,8847	0,5933	0,7200	0,6466	0,6470	0,6281	0,7619	0,6974
3	0,9983	0,6467	0,7152	0,7843	0,7182	0,7628	0,8352	0,7801
4	0,7198	0,4525	0,4865	0,5822	0,5834	0,5557	0,5376	0,5597
5	0,8574	0,6933	0,5910	0,7001	0,7254	0,5896	0,6578	0,6878
6	0,8122	0,7907	0,7513	0,8520	0,7950	0,9396	0,7232	0,8092
7	1,0574	1,1717	0,8986	0,9571	0,9409	1,0836	1,0183	1,0182
8	1,2619	1,4480	1,1570	1,5459	1,3358	1,3940	1,1940	1,3338
9	0,9277	1,1197	1,1954	1,0327	1,2046	1,2577	1,1042	1,1203
10	0,7711	1,2072	0,8041	0,8422	0,8505	0,9479	0,6568	0,8685
11	0,7265	1,1343	0,7195	0,7548	0,8042	0,9942	0,6836	0,8310
12	1,0322	1,3964	1,2662	1,2175	1,2488	1,4222	1,1740	1,2510
13	0,7393	1,2375	0,7262	0,8998	1,1002	0,9676	0,8692	0,9343
14	0,8286	1,3236	0,8646	0,8998	0,9298	0,9703	0,8930	0,9585
15	0,6432	1,1653	0,9589	0,8526	0,9824	1,0271	0,7090	0,9055
16	0,5863	1,0152	0,8365	0,7855	0,8293	0,8450	0,7929	0,8129
17	0,7240	1,0490	0,9214	0,8219	1,0195	1,0641	0,9354	0,9336
18	0,8302	1,4475	1,2421	1,1674	1,0626	1,3654	0,8946	1,1443
19	1,8588	2,0527	1,8309	2,1930	2,1863	2,2187	1,9202	2,0372
20	0,9281	0,6838	0,6081	0,7359	0,6931	0,7643	1,2075	0,8030
21	0,7964	0,5658	0,6242	0,6066	0,6647	0,5998	0,7844	0,6631
22	0,9763	1,1609	1,0166	1,0903	1,0019	0,9557	1,0755	1,0396
23	1,3931	2,0603	1,8963	2,1096	2,0984	2,1949	1,5085	1,8944
24	0,8152	0,7165	0,6225	0,7768	0,6885	0,6712	0,5470	0,6911
<i>média*</i>	0,9074	1,0788	0,9162	0,9766	0,9851	1,0363	0,9239	0,9749

Tabela 5.12 – MAE semanal e horário para a Barra-II com demanda ativa (MW*).

<i>hora</i>	<i>domingo*</i>	<i>segunda*</i>	<i>terça*</i>	<i>quarta*</i>	<i>quinta*</i>	<i>sexta*</i>	<i>sábado*</i>	<i>média*</i>
1	2,4587	2,6910	2,5151	2,1447	2,0331	1,7935	1,9321	2,2240
2	1,1201	0,9860	1,1342	1,2231	1,2812	1,1572	1,0288	1,1329
3	1,7375	2,1426	1,9937	2,4397	2,4691	2,6277	2,8054	2,3165
4	3,9550	3,3840	4,5353	5,1652	5,4147	5,4024	5,4243	4,7544
5	0,9492	1,1009	0,9798	1,2203	1,4238	1,2565	1,3352	1,1808
6	1,9829	1,7184	2,0683	2,0121	2,2210	1,9181	2,3106	2,0331
7	1,8291	2,2791	2,0860	2,3405	2,0562	2,3040	2,1265	2,1459
8	2,6801	5,6430	4,4255	4,2668	4,4248	3,9486	3,3393	4,1040
9	2,6896	6,4435	6,3559	5,4444	4,7942	4,4178	3,8202	4,8522
10	2,5512	7,7107	6,4807	6,0770	5,7256	5,8455	3,2317	5,3746
11	3,6652	2,5458	2,5197	2,2110	2,0552	2,6530	2,1941	2,5491
12	1,4741	4,2202	4,2282	3,7687	3,7854	3,8522	2,2177	3,3638
13	1,5244	2,0890	1,2114	1,3050	1,6873	1,4046	1,9908	1,6018
14	1,5572	5,8442	5,2165	5,0308	4,9067	5,0476	2,2914	4,2706
15	1,6061	4,1670	3,6827	3,0602	3,5666	3,4458	4,5445	3,4390
16	4,4856	4,3793	3,9653	3,3871	3,6769	3,7668	9,5146	4,7394
17	0,9279	2,0796	1,8215	1,8037	2,1014	1,6748	1,2553	1,6663
18	4,7733	4,7603	5,2063	5,1868	4,9263	4,0148	3,6294	4,6425
19	7,1890	5,1566	4,6667	4,6693	4,6288	4,2521	7,4242	5,4267
20	5,0114	2,7861	2,0248	2,0520	1,9998	1,8627	6,2392	3,1394
21	5,1466	2,3202	1,7757	1,7213	1,3953	1,5568	5,3228	2,7484
22	0,8333	2,4544	2,2170	2,5225	2,2245	2,1752	1,0126	1,9199
23	1,4257	2,4704	2,1041	1,9774	2,1411	2,0233	1,8845	2,0038
24	4,8706	2,4548	2,1689	2,2527	2,0273	2,0665	1,6589	2,5000
<i>média*</i>	2,7685	3,4095	3,1410	3,0534	3,0403	2,9361	3,2722	3,0887

Tabela 5.13 – MAE semanal e horário para a Barra-II com demanda reativa (MVar*).

<i>hora</i>	<i>domingo*</i>	<i>segunda*</i>	<i>terça*</i>	<i>quarta*</i>	<i>quinta*</i>	<i>sexta*</i>	<i>sábado*</i>	<i>média*</i>
1	2,2283	1,8075	1,6804	1,9355	2,1917	1,9751	1,8880	1,9581
2	1,7568	1,2745	2,0911	2,0647	1,8366	1,6354	1,8863	1,7922
3	1,4373	1,1197	1,4990	1,5951	1,5628	2,3551	1,3932	1,5660
4	1,8836	0,8906	1,4502	1,7046	2,3036	1,8940	1,5643	1,6701
5	1,1151	1,4165	1,4749	1,2119	1,6950	1,3655	1,5296	1,4012
6	1,7068	1,5823	1,9987	1,7059	1,8260	1,3750	1,7839	1,7112
7	2,4137	2,1062	2,4443	1,9000	2,0926	2,2633	2,3390	2,2227
8	2,8269	2,8610	2,9478	2,7698	2,8865	2,9090	1,8777	2,7255
9	2,5105	3,5497	3,2347	3,1692	3,2579	2,9295	2,4486	3,0143
10	1,6866	2,5244	2,2858	2,2376	2,7669	2,1145	2,5458	2,3088
11	1,1064	1,7708	1,6974	2,0095	1,8727	1,6425	1,5994	1,6712
12	1,8127	2,2889	2,2929	2,3238	2,4191	1,9683	1,5974	2,1004
13	2,6163	1,7454	1,7337	1,8682	1,9153	1,7318	1,9636	1,9392
14	1,6196	2,8848	2,3896	2,4234	1,9914	1,6964	2,1457	2,1644
15	1,1900	2,0059	2,3463	2,0988	1,9799	1,8676	2,3657	1,9792
16	1,8329	2,1545	2,5895	1,9541	2,6674	2,0009	2,3192	2,2169
17	0,9358	1,7430	1,4365	1,3303	1,5755	1,6463	1,6174	1,4692
18	2,2157	2,3375	2,0101	1,6885	2,1370	1,7618	2,2142	2,0521
19	3,4577	2,7838	2,5966	2,4611	2,3017	2,6019	3,5966	2,8285
20	3,0764	2,2591	2,0258	1,5970	1,8911	1,8604	3,2576	2,2811
21	1,2608	1,1244	0,9934	1,1986	1,2331	1,3614	1,4327	1,2292
22	1,5009	1,3786	1,6394	1,4577	1,5510	1,8113	1,7863	1,5893
23	1,7100	1,9417	1,8530	1,2722	1,4551	1,6346	2,1146	1,7116
24	2,6510	2,8493	2,4775	2,0602	2,6132	2,0885	2,2547	2,4278
<i>média*</i>	1,9397	2,0167	2,0495	1,9182	2,0843	1,9371	2,0634	2,0013

Tabela 5.14 – MAE semanal e horário para a Barra-III com demanda ativa (MW*).

<i>hora</i>	<i>domingo*</i>	<i>segunda*</i>	<i>terça*</i>	<i>quarta*</i>	<i>quinta*</i>	<i>sexta*</i>	<i>sábado*</i>	<i>média*</i>
1	3,3088	4,0288	2,7580	2,6480	2,9844	3,1184	3,3430	3,1699
2	2,4258	3,9524	2,5094	2,5013	3,0572	2,7594	3,1155	2,9030
3	12,9449	11,2832	6,0826	6,4313	6,8862	6,9197	9,2674	8,5451
4	3,2173	2,2531	3,2411	3,3013	3,6793	4,1627	4,6104	3,4950
5	3,6137	1,4184	1,8848	1,5846	2,2462	1,7824	1,8463	2,0538
6	8,5293	4,1624	5,0124	4,0310	4,4384	4,3257	6,3486	5,2640
7	7,7991	17,1960	9,9658	10,6510	9,9214	10,4645	5,9187	10,2738
8	6,0433	11,7729	13,4661	10,4534	9,4291	10,5869	7,4373	9,8842
9	10,4200	15,1396	15,9245	12,7969	11,5995	13,1827	14,4204	13,3548
10	8,2616	14,3281	16,8434	10,0830	10,3039	10,5133	10,8899	11,6033
11	13,2542	11,0683	11,3699	11,7214	11,0718	13,0184	9,6905	11,5992
12	2,5728	5,4442	6,0298	5,1417	6,4956	6,6463	3,6726	5,1433
13	7,1083	7,8344	2,6501	3,6793	3,1310	3,0902	2,9882	4,3545
14	2,4311	5,1327	5,2458	5,4436	4,6645	4,0697	4,5797	4,5096
15	2,1651	3,9633	3,5903	3,2643	3,1590	4,6578	7,1837	3,9977
16	4,3826	7,2019	7,4953	7,0810	6,8941	7,1355	13,2272	7,6311
17	2,6035	3,7693	3,7588	3,7068	3,8103	4,0260	2,6070	3,4688
18	17,8692	8,1234	8,3343	8,0829	9,0171	7,8830	17,8031	11,0161
19	20,1297	11,3867	13,8248	14,0367	14,6205	13,7648	28,3222	16,5836
20	25,3492	9,4804	11,4860	11,8701	12,6019	10,9613	35,3733	16,7317
21	21,6103	9,9730	11,2035	11,0338	11,3821	10,3460	25,5293	14,4397
22	15,9750	10,4200	11,1048	11,8403	11,3761	10,0496	14,4373	12,1719
23	5,0278	6,4462	5,5026	5,8698	6,1186	4,2258	13,4927	6,6691
24	5,2666	6,1307	6,1958	5,1305	5,5596	4,5590	16,3356	7,0254
<i>média*</i>	8,8462	7,9962	7,7283	7,1827	7,2687	7,1770	10,9350	8,1620

Tabela 5.15 – MAE semanal e horário para a Barra-III com demanda reativa (MVar*).

<i>hora</i>	<i>domingo*</i>	<i>segunda*</i>	<i>terça*</i>	<i>quarta*</i>	<i>quinta*</i>	<i>sexta*</i>	<i>sábado*</i>	<i>média*</i>
1	4,2939	3,5103	4,2920	4,2799	4,0049	4,2586	4,3858	4,1465
2	3,0970	3,3197	3,7497	3,4736	3,7343	3,2674	3,4086	3,4358
3	3,0768	3,2634	3,5235	2,7415	3,3782	3,0519	3,1748	3,1729
4	2,1211	1,7173	2,4164	1,7085	2,1804	1,9295	2,1228	2,0280
5	4,1873	4,4954	4,3466	2,8553	3,2799	3,4500	3,6129	3,7468
6	2,8365	2,3738	2,8315	2,2198	2,9582	2,9813	3,1459	2,7639
7	4,9651	6,0691	5,3942	4,7475	5,2802	5,3069	4,2351	5,1426
8	4,4890	5,6825	4,5143	4,8397	4,0603	4,2286	3,7399	4,5078
9	3,9842	7,6055	7,8091	7,0405	6,8957	6,1921	4,4077	6,2764
10	3,1768	6,6606	5,9110	5,9711	5,7135	5,7379	5,0123	5,4547
11	2,2097	4,4632	4,4252	4,3066	5,0102	4,0253	3,3891	3,9756
12	2,9136	3,0020	3,2346	3,0898	3,6884	3,5661	2,4726	3,1382
13	2,3030	2,6365	2,9354	3,0543	3,1809	3,3499	3,0510	2,9301
14	5,0097	5,9952	5,0741	4,2842	5,6798	5,1980	5,3207	5,2231
15	3,1120	4,6770	4,8511	5,1913	4,0381	5,1307	5,8811	4,6973
16	6,1145	5,0725	4,5119	3,8295	3,7095	4,4419	3,2753	4,4222
17	2,2128	3,8847	4,2015	3,7847	5,0385	5,3953	4,0236	4,0773
18	8,2514	6,2985	6,0807	7,5342	6,6976	7,2486	9,3383	7,3499
19	7,9322	6,2417	6,8002	6,5837	8,5942	6,3378	9,4828	7,4246
20	7,5366	5,1517	5,4937	4,5649	5,1706	5,4382	9,7370	6,1561
21	4,0602	4,4386	3,6950	3,6161	4,3349	4,3875	5,0158	4,2212
22	2,1497	4,9015	3,7414	3,8086	3,7166	3,6832	3,8996	3,7001
23	2,6601	6,1418	5,0338	4,6601	4,6933	5,2467	4,0916	4,6468
24	3,5666	3,8328	3,4022	4,2213	2,9680	4,1894	4,3461	3,7895
<i>média*</i>	4,0108	4,6431	4,5112	4,2669	4,5003	4,5018	4,6071	4,4345

Por fim, é verificar-se os *lags* (dos melhores resultados) que foram obtidos pela seleção de entradas. Tal informação é crucial para determinar os atrasos que possuem maior correlação com o momento a ser previsto. Na Barra-I (Tabela 5.16), os *lags* são idênticos para todas as horas na demanda ativa e o mesmo acontece com a reativa (devido ao *jump* “hora a hora”).

Tabela 5.16 – Conjunto de *lags* para a Barra-I.

<i>Demanda</i>	<i>hora</i>	<i>lag 1</i>	<i>lag 2</i>	<i>lag 3</i>	<i>lag 4</i>	<i>lag 5</i>	<i>lag 6</i>	<i>lag 7</i>
Ativa	1:24	-1h	-14d	-14d e 1h	-2h	-4h	-6h	-1d
Reativa	1:24	-2h	-1h	-3h	-1d	-1d e 1h	-6d	-62d e 23h

Na Barra-II (Tabela 5.17) e Barra-III (Tabela 5.18), o comportamento dos *lags* é diferente para a demanda ativa e reativa. A demanda ativa possui conjuntos de *lags* diferentes ao longo do dia. Isso se dá pelo tipo de *jump* utilizado para gerar a base (“hora a hora”) e consequentemente possui um melhor desempenho na previsão, enquanto a reativa apresenta *lags* idênticos para todas as horas, devido ao *jump* “dia a dia” com um melhor ajuste na previsão.

Tabela 5.17 – Conjunto de *lags* para a Barra-II.

<i>Demanda</i>	<i>hora</i>	<i>lag 1</i>	<i>lag 2</i>	<i>lag 3</i>	<i>lag 4</i>	<i>lag 5</i>	<i>lag 6</i>	<i>lag 7</i>
Ativa	1	-1h	-2h	-4h	-3h	-5h	-12h	-6d e 23h
	2	-1h	-2h	-3h	-5h	-4h	-6h	-1d e 3h
	3	-1h	-2h	-3h	-4h	-6h	-5h	-7h
	4	-1h	-2h	-3h	-4h	-5h	-7h	-6h
	5	-1h	-2h	-3h	-4h	-6h	-5h	-7h
	6	-1h	-2h	-5h	-3h	-4h	-6h	-7h
	7	-1h	-2h	-5h	-3h	-6h	-4h	-7h
	8	-1h	-2h	-3h	-23h	-18h	-7d	-9h
	9	-1h	-2h	-4h	-7d	-6d e 23h	-7d e 1h	-17h
	10	-1h	-2h	-3h	-7d	-6d e 23h	-19h	-6d e 20h
	11	-1h	-2h	-3h	-7d e 1h	-4h	-6d e 23h	-7d
	12	-1h	-2h	-3h	-4h	-7d	-6d e 23h	-5h
	13	-1h	-2h	-3h	-4h	-5h	-7d e 1h	-7d
	14	-1h	-2h	-3h	-4h	-5h	-6h	-7d
	15	-1h	-5h	-4h	-3h	-2h	-6h	-7d
	16	-1h	-2h	-3h	-5h	-4h	-6h	-7h
	17	-1h	-2h	-3h	-5h	-4h	-6h	-7h
	18	-1h	-2h	-6h	-3h	-7h	-4h	-5h
	19	-1h	-2h	-5h	-3h	-10h	-7d	-4h
	20	-1h	-3h	-18h	-4h	-23h	-14h	-7d
	21	-1h	-14h	-22h	-15h	-1d	-4h	-7d
	22	-1h	-2h	-7h	-9h	-1d	-10h	-5h
	23	-1h	-2h	-3h	-10h	-11h	-6h	-6d e 19h
	24	-1h	-2h	-3h	-4h	-11h	-12h	-18h
Reativa	1:24	-1h	-2h	-1d	-3h	-4h	-2d	-23h

Tabela 5.18 – Conjunto de *lags* para a Barra-III.

<i>Demanda</i>	<i>hora</i>	<i>lag 1</i>	<i>lag 2</i>	<i>lag 3</i>	<i>lag 4</i>	<i>lag 5</i>	<i>lag 6</i>	<i>lag 7</i>
Ativa	1	-1h	-2h	-4h	-3h	-5h	-12h	-8h
	2	-1h	-2h	-3h	-5h	-4h	-6h	-10h
	3	-1h	-2h	-3h	-4h	-6h	-5h	-10h
	4	-1h	-2h	-3h	-4h	-5h	-7h	-6h
	5	-1h	-2h	-3h	-4h	-5h	-6h	-8h
	6	-2h	-1h	-5h	-4h	-6h	-3h	-7h
	7	-2h	-1h	-15h	-14h	-16h	-17h	-19h
	8	-1h	-15h	-16h	-17h	-7d	-21h	-6d e 23h
	9	-1h	-2h	-7d	-17h	-13d e 23h	-7d e 1h	-16h
	10	-1h	-2h	-6d e 23h	-6d e 18h	-6d e 19h	-6d e 20h	-7d
	11	-1h	-2h	-3h	-6d e 22h	-6d e 18h	-6d e 19h	-7d
	12	-1h	-2h	-3h	-4h	-6d e 20h	-7d	-6d e 23h
	13	-1h	-2h	-3h	-4h	-5h	-7d	-20h
	14	-1h	-2h	-3h	-4h	-5h	-6h	-7d e 2h
	15	-1h	-4h	-2h	-3h	-5h	-6h	-7h
	16	-1h	-2h	-3h	-4h	-5h	-6h	-7h
	17	-1h	-2h	-4h	-3h	-5h	-6h	-7h
	18	-1h	-2h	-4h	-3h	-7h	-5h	-6h
	19	-2h	-4h	-3h	-5h	-6h	-1h	-9h
	20	-1h	-3h	-7h	-4h	-8h	-6h	-5h
	21	-1h	-4h	-5h	-8h	-6h	-7h	-2h
	22	-1h	-2h	-6h	-8h	-5h	-7h	-10h
	23	-1h	-2h	-3h	-6h	-7h	-10h	-8h
	24	-1h	-2h	-3h	-4h	-7h	-11h	-8h
Reativa	1:24	-1h	-2h	-4h	-23h	-1d e 1h	-1d	-20d e 23h

Nos casos acima, é interessante notar que há uma grande incidência de *lags* próximo do momento x_t , isto é, próximos do instante a ser previsto, estes *lags* vão de 1 hora a 9 horas atrás. Mas também há *lags* que retomam por volta de 1 dia atrás como também há quase 7 dias. Dessa forma pode-se verificar que a composição dos atributos está relacionada aos últimos instantes e aos ciclos semanais (isto é o *lags* indicam o mesmo dia da semana em períodos anteriores).

Em casos específicos, a composição dos *lags* utiliza atributos que estão há muitos instantes atrás, mesmo assim os ciclos semanais ainda são preservados, garantindo que os dias da semana possuem comportamentos similares.

Para cada base gerada, há um conjunto diferente de *lags* associados e a sua variação é regida pelo conjunto de parâmetros configurados e até mesmo pelo intervalo de tempo utilizado. Mas, mais importante que isso, é o fato de que, mesmo a seleção das entradas ser baseada na correlação dos dados, podem existir outros conjuntos e combinações de *lags* que melhor se adéquem a modelo de previsão e consequentemente obtenham resultados mais prósperos.

5.3.2 Comparação do Fator de Potência (FP)

De posse dos valores reais e previstos para os barramentos, tanto com potência ativa e reativa, é possível fazer uma análise quanto ao fator de potência obtido através das séries previstas em relação aos valores reais empregados no sistema elétrico.

Para calcular o fator de potência a partir das séries de potência ativa e reativa, primeiro é necessário calcular a potência aparente (Eq. 5.9, cálculo da hipotenusa pelo teorema de Pitágoras). Com os valores da potência aparente, o fator de potência (Eq. 5.10) é expresso pela razão da potência ativa pela potência aparente.

$$PotenciaAparente = \sqrt{PotenciaAtiva^2 + PotenciaReativa^2} \quad \text{Eq. 5.9}$$

$$FatorPotencia = \frac{PotenciaAtiva}{PotenciaAparente} \quad \text{Eq. 5.10}$$

Para o cálculo do fator de potência, foram utilizados as séries previstas que apresentaram os melhores resultados no MAPE, independente se a configuração para a potência ativa e reativa era igual (uma vez que o objetivo principal deste trabalho não é estimar o melhor fator de potência e sim, obter as melhores previsões).

Como expresso anteriormente (na seção 3.2), o fator de potência no sistema elétrico brasileiro para consumidores industriais, deve ser maior que 92% para um melhor aproveitamento da energia, e assim uma menor tarifa do consumidor.

Para comparar os resultados do fator de potência (Figura 5.40 à Figura 5.42), adotou-se para as abscissas (eixo x) o fator de potência real e as ordenadas (eixo y) o fator de potência previsto. Uma reta foi traçada separando, igualmente, os valores em dois conjuntos, onde o triângulo superior apresenta os valores que o fator de potência previsto foi melhor, inversamente, o triângulo inferior apresenta os valores onde o fator de potência real foi superior.

Apenas na Barra-I foram obtidos valores menores do que 92%, sendo apenas 2 valores no fator de potência prevista e 30 para o fator de potência real, enquanto a Barra-III não obteve nenhum fator de potência igual a 100%.

Pode-se notar que as Barra-I (Figura 5.40) e Barra-II (Figura 5.42) apresentam uma dispersão de valores que tendem mais para o triângulo superior, informando que o fator de potência previsto é superior ao fator de potência real. Tal afirmação não é possível de ser feita para a Barra-III (Figura 5.41), uma vez que os valores encontram-se distribuídos uniformemente.




Figura 5.40 - Comparativo do fator de potência real vs. previsto para a Barra-I.




Figura 5.41 - Comparativo do fator de potência real vs. previsto para a Barra-II.




Figura 5.42 - Comparativo do fator de potência real vs. previsto para a Barra-III.

Através da Tabela 5.19, é possível verificar os momentos amostrais para cada resultado. Os valores confirmam que o fator de potência prevista para a Barra-I e Barra-II possuem valores superiores aos valores reais. E a Barra-III apresenta valores praticamente idênticos, confirmando a avaliação feita graficamente.

Tabela 5.19 - Momentos amostrais dos fatores de potência real e previsto.

<i>Barramento</i>	<i>Fator de Potência</i>	<i>Média</i>	<i>D. Padrão</i>	<i>Mínimo</i>	<i>Máximo</i>	<i>Assimetria</i>	<i>Curtose⁴</i>
Barra-I (%*)	real	99,56*	1,03*	84,57*	100,00*	-6,24	52,65
	previsto	99,69*	0,62*	90,07*	100,00*	-5,68	43,72
	ME	-0,13*	0,61*	-10,78*	3,02*	-6,72	67,21
	MAE	0,22*	0,58*	0,00*	10,78*	7,50	76,28
Barra-II (%*)	Real	99,32*	0,58*	95,47*	100,00*	-1,14	1,51
	previsto	99,34*	0,52*	96,75*	100,00*	-0,81	0,22
	ME	-0,02*	0,26*	-2,53*	1,54*	-0,91	6,12
	MAE	0,17*	0,19*	0,00*	2,53*	2,62	12,28
Barra-III (%*)	real	97,52*	0,86*	94,73*	99,69*	-0,31	-0,28
	previsto	97,51*	0,86*	94,14*	99,75*	-0,23	-0,24
	ME	0,01*	0,38*	-2,06*	2,23*	0,31	2,29
	MAE	0,28*	0,25*	0,00*	2,23*	1,91	5,78

⁴ Algumas definições de curtose subtraem 3 (três) do valor calculado, para que a distribuição normal tenha curtose 0 (zero). Para uma melhor compreensão dos resultados, esta dissertação também adotou essa medida.

6 Conclusão

*“Não há fatos eternos,
como não há verdades absolutas.”
(Friedrich Nietzsche)*

O Capítulo 6 apresenta algumas discussões envolvidas nesta dissertação. Na Seção 6.1, é apresentada a conclusão, onde é descrita a proposta envolvida, assim como as dificuldades encontradas e os resultados obtidos pelo sistema. A Seção 6.2 traz os possíveis trabalhos futuros, seguindo esta mesma linha de pesquisa ou atuando em outros problemas de previsão.

6.1 Conclusão

A dificuldade de encontrar ferramentas que agreguem as técnicas de seleção e os métodos de previsão torna o processo de previsão custoso e de difícil operação, uma vez que é necessário definir e implementar várias técnicas dentre uma gama de possibilidades existentes, juntamente com a definição de qual método de previsão adapta-se melhor e traz resultados mais prósperos para o problema trabalhado.

A construção de ferramentas não é uma tarefa simples, é necessário ter em mente quais as possíveis formas de entrada e saída dos dados, bem como todos os processos envolvidos nas diferentes técnicas de seleção e redução de dados. Além disso, a quantidade de dados, suas qualidades e como eles são amostrados e medidos, têm implicações para a escolha e eficácia das técnicas de seleção de dados utilizados na análise posterior.

Quando a série disponível possui uma grande quantidade de dados, é necessário selecionar um subconjunto das variáveis de entrada potencial para reduzir o número de parâmetros livres do modelo, a fim de obter uma boa generalização com dados finitos. A escolha correta dos parâmetros do modelo também é importante para melhorar a eficiência computacional.

O pré-processamento dos dados está presente apenas antes do início do processo de previsão, porém sua aplicação requer grande responsabilidade, pois toma grande parte do desenvolvi-

mento e consome muito processamento.

A seleção de dados apresenta um alto custo computacional e dessa forma, a busca por estratégias que reduzam o tempo de execução, possibilitando maximizar os recursos computacionais e melhorar os resultados, é fundamental para o bom desempenho do sistema.

A literatura apresenta uma grande variedade de metodologias que podem ser empregadas para previsão. Esta variedade de técnicas reflete a busca por métodos capazes de gerar previsões com uma maior acurácia.

Tomar decisões com auxílio dos computadores é extremamente desejável, o que faz com que se impulse o descobrimento de algoritmos novos e aprimore os já usuais. Em especial, a seleção e redução de dados, por serem tão importantes merecem destaque na pesquisa, já que ainda não se tem uma receita pronta para a melhor combinação de técnicas.

Esta dissertação apresentou estudos sobre técnicas de seleção de entradas em modelos de previsão de curto prazo de demanda ativa por barramento, com o objetivo de auxiliar o processo de definição dos modelos de previsão.

Para o modelo, foram utilizadas as técnicas MI e PMI para a seleção das variáveis, juntamente com rede neurais do tipo MLP (treinada com os algoritmos BFGS, DFP, FR, GRAD, OSS, PR e SCGM), com o propósito de averiguar, de forma ampla, o potencial da previsão. Foram feitos testes exaustivos com um grande conjunto de parâmetros e diferentes barramentos (baixa, média e alta demanda).

Dados os barramentos testados (Barra-I, Barra-II e Barra-III), pode-se inferir que os melhores resultados para a potência ativa para o MAPE foram de 4,18%, 2,54% e 2,48%, e para o MAE foram 1,54 MW, 3,09 MW e 8,16 MW, de acordo com cada tipo de configuração utilizada para gerar a base (DaPh7, SdMd7 e SdMd7).

Enquanto para os mesmos barramentos a potência reativa obteve 84,31%, 35,55% e 6,38% do MAPE e para o MAE 0,97 MVar, 2,00 MVar e 4,43 MVar, de acordo com cada tipo de configuração utilizada para gerar a base (DdPh7, SaMh7 e SaPh7).

Os principais ganhos estão relacionados a um melhor conhecimento das técnicas de seleção de entradas e do problema de previsão de carga por barramento, a implementação de um sistema que possibilita utilizar e comparar diferentes técnicas de seleção de entradas, a utilização dos modelos de redes neurais (do tipo MLP) com diferentes estruturas e técnicas de treinamento,

e finalmente, a grande quantidade de testes realizados possibilitou ter uma ideia do desempenho das técnicas utilizadas.

Os resultados mostram que o desenvolvimento de sistemas com estas características é interessante, pois em previsão de carga, quase sempre há características específicas, de modo que uma dada técnica é melhor em uma dada aplicação, e já em outra aplicação, isto não se verifica, por exemplo, as técnicas de MI e PMI. Destes testes, somente o algoritmo de treinamento SCGM foi unânime em todas as faixas de demanda e a utilização de 7 atributos como *lags*, dando destaque às Barra-II e Barra-III, que convergiram para a mesma base (SdMd7).

É importante salientar que mesmo que os resultados sejam mais prósperos em algumas configurações, há outras que são tão boas quanto as escolhidas, é o caso do conjunto de bases criados utilizando a normalização pelo “Máximo Dia” com ordem “depois”.

Sendo assim, um bom sistema de previsão de carga propicia um melhor uso da capacidade instalada do sistema elétrico. O impacto que a atividade de previsão de carga causa, não somente na operação, mas também no planejamento e na comercialização de energia.

6.2 Trabalhos Futuros

Em termos de trabalhos futuros, destacam-se algumas vertentes:

- realizar experimentos e adequar a metodologia para intervalos menores de tempo (semestralmente ou mensalmente);
- aumentar os esforços computacionais em torno do algoritmo SCGM e utilizar outros algoritmos para o treinamento (redes recorrente, *extreme learning machine*);
- fazer previsões para cargas ativas e reativas, podendo combiná-las para estipular o fator de potência para cada barramento;
- utilizar séries climáticas, econômicas e populacionais para a previsão de carga.
- testar a previsão com o aumento da quantidade de *lags*;
- testar a metodologia para outros tipos de séries temporais.
- utilizar a metodologia para prever valores n passos a frente;
- entre outras aplicações e modificações possíveis.

7 Referências

ANTUNES, J. F.; MINUSSI, C. R. Previsão de Carga Multinodal a Curto Prazo Usando Uma Rede Neural ART-ARTMAP-FUZZY. **IX Encontro Nacional de Inteligência Artificial (ENIA-2012)**, p. 12, outubro 2012. Disponível em: <<http://goo.gl/6rCr8S>>.

BAKIRTZIS, A. G. et al. A neural network short term load forecasting model for the Greek power system. **IEEE Transactions on Power Systems**, v. 11, n. 2, p. 858-863, 1996. ISSN: 0885-8950 DOI: 10.1109/59.496166. Disponível em: <<http://goo.gl/1y4iu>>.

BARBANCHO, A. G. **Fundamentos e possibilidades econometria**. [S.l.]: Forum, 1970. 193 p. Disponível em: <<http://goo.gl/32fMY>>.

BATTITI, R. First and Second-Order Methods for Learning: between Steepest Descent and Newton's Method. **Neural Computation**, v. 4, p. 141-166, 1992. ISSN DOI: 10.1.1.17.4823. Disponível em: <<http://goo.gl/iatF3>>.

BILOBROVEC, M.; MARÇAL, R. F. M.; PILATTI, L. A. Aplicações de redes neurais artificiais em simulações. **XI SIMPEP**, v. 1, p. 7, novembro 2004. ISSN: 1809-7189. Disponível em: <<http://goo.gl/yHpGR>>.

BURAGOHAIN, M.; MAHANTA, C. A novel approach for ANFIS modelling based on full factorial design. **Applied Soft Computing**, v. 8, n. 1, p. 609-625, junho 2008. ISSN: 1568-4946 DOI: 10.1016/j.asoc.2007.03.010. Disponível em: <<http://goo.gl/GbSHF>>.

CASTRO, L. N. D.; ZUBEN, F. J. V. Optimised training techniques for feedforward neural networks, julho 1998. Disponível em: <<http://goo.gl/kSb1W>>.

CICHOCKI, A. et al. Independent variable selection: an application of independent component analysis to forecasting a stock index. **Journal of Asset Management**, v. 6, n. 4, p. 248-265, dezembro 2005. Disponível em: <<http://goo.gl/zn6Su>>.

DAVIDON, W. C. Variable metric method for minimization. **SIAM Journal on Optimization**, v. 1, p. 1-17, 1991. ISSN DOI: 10.1137/0801001. Disponível em: <<http://goo.gl/XSqA0>>.

DEMPSTER, A. P. Covariance selection. **Biometrics**, v. 28, n. 1, p. 157-175, março 1972. ISSN: 0006341X. Disponível em: <<http://goo.gl/TaHUo>>.

DENNIS, J. E.; SCHNABEL, R. B. **Numerical Methods for Unconstrained Optimization and Nonlinear Equations**. [S.l.]: Society for Industrial and Applied Mathematics, 1983. ISBN: 9780898713640 LCCN: lc95051776. Disponível em: <<http://goo.gl/cx7QT>>.

FERNANDO, T. M. K. G. et al. **Efficient selection of inputs for artificial neural network models**. International Congress on Modelling and Simulation. Australia and New Zealand: MODSIM 2005. 2005. p. 1806-1812.

FERREIRA, V. H.; SILVA, A. P. A. D. Chaos theory applied to input space representation of autonomous neural network-based short-term load forecasting models. **Controle & Automação Sociedade Brasileira de Automatica (SBA)**, v. 22, p. 585-597, novembro-dezembro 2011. ISSN ISSN: 0103-1759 DOI: 10.1590/S0103-17592011000600004. Disponível em: <<http://goo.gl/tHzqj>>.

FLETCHER, R. **Practical Methods of Optimization**: Unconstrained optimization. the University of Michigan: J. Wiley, 1986. ISBN ISBN: 9780471277118 LCCN: 79041486. Disponível em: <<http://goo.gl/dX5Cg>>.

FLETCHER, R.; REEVES, C. M. Function minimization by conjugate gradients. **The Computer Journal**, v. 7, n. 2, p. 149-154, 1964. ISSN DOI: 10.1093/comjnl/7.2.149. Disponível em: <<http://goo.gl/UHkS>>.

FRANCO JR., E. F. **Classificação de padrões para o escoamento gás/líquido via modelos inteligentes**. Bacharelado em Ciência da Computação (BCC) / Universidade Federal de Alfenas-MG (Unifal-MG). Alfenas, MG, Brasil. 2010.

GROSS, G.; GALIANA, F. D. Short-term load forecasting. **Proceedings of the IEEE**, v. 75, n. 12, p. 1558-1573, 1987. ISSN ISSN: 0018-9219 DOI: 10.1109/PROC.1987.13927. Disponível em: <<http://goo.gl/kyPV2>>.

HANDSCHIN, E.; DORNEMANN, C. Bus load modelling and forecasting. **IEEE Transactions on Power Systems**, v. 3, n. 2, p. 627-633, 1988. ISSN ISSN: 0885-8950 DOI: 10.1109/59.192915. Disponível em: <<http://goo.gl/RI1I9>>.

HAYKIN, S. S. **Neural networks: a comprehensive foundation**. 2. ed. the University of Michigan: Prentice Hall, 1999. 842 p. ISBN ISBN: 9780132733502 LCCN: gb98059240. Disponível em: <<http://goo.gl/jlT5s>>.

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. ISSN ISSN: 0885-8950 DOI: 10.1109/59.910780. Disponível em: <<http://goo.gl/7TFLA>>.

HOTELLING, H. Analysis of a complex of statistical variables into principal components. **Journal of Educational Psychology**, v. 24, p. 417-441, 1933. ISSN ISSN: 1939-2176 DOI: 10.1037/h0071325. Disponível em: <<http://goo.gl/DIvPV>>.

HUANG, W.; NAKAMORI, Y.; WANG, S. Y. A general approach based on autocorrelation to determine input variables of neural networks for time series forecasting. **Journal of Systems Science and Complexity**, v. 17, n. 3, p. 297, julho 2004. Disponível em: <<http://goo.gl/N0rW9>>.

JAIN, A. K.; DUIN, R. P. W.; MAO, J. Statistical pattern recognition: a review. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 22, n. 1, p. 4-37, janeiro 2000. ISSN ISSN: 0162-8828 DOI: 10.1109/34.824819. Disponível em: <<http://goo.gl/FI1tU>>.

KHOTANZAD, A. et al. ANNSTLF - a neural-network-based electric load forecasting system. **IEEE Transactions on Neural Networks**, v. 8, n. 4, p. 835-846, 1997. ISSN ISSN: 1045-9227 DOI: 10.1109/72.595881. Disponível em: <<http://goo.gl/ysa5v>>.

KIARTZIS, S. J. et al. Short-term load forecasting in an autonomous power system using artificial neural networks. **IEEE Transactions on Power Systems**, v. 12, n. 4, p. 1591-1596, 1997. ISSN ISSN: 0885-8950 DOI: 10.1109/59.627863. Disponível em: <<http://goo.gl/tCr5j>>.

KIM, K.-H. et al. Implementation of hybrid short-term load forecasting system using artificial neural networks and fuzzy expert systems. **IEEE Transactions on Power Systems**, v. 10, n. 3, p. 1534-1539, 1995. ISSN ISSN: 0885-8950 DOI: 10.1109/59.466492. Disponível em: <<http://goo.gl/yt9Lh>>.

LEITE, F. E. D. A. **Aplicação de redes neurais artificiais na previsão de curto prazo da carga nodal de sistemas de energia elétrica**. Departamento de Sistemas de Energia Elétrica (DSEE), Faculdade de Engenharia Elétrica e Computação (FEEC), Universidade Estadual de Campinas (Unicamp). Campinas. 1997.

LIMA, C. A. D. M. **Emprego de teoria de agentes no desenvolvimento de dispositivos neurocomputacionais híbridos e aplicação ao controle e identificação de sistemas dinâmicos**. Faculdade de Engenharia Elétrica e de Computação (FEEC), Universidade Estadual de Campinas (Unicamp). Campinas, Brasil. 2000.

LIU, B.; YANG, R. **A novel method based on PCA and LS-SVM for power load forecasting**. Electric Utility Deregulation and Restructuring and Power Technologies. Nanjing: DRPT 2008. abril 2008. p. 759-763.

MARALLOO, M. N. et al. **Mutual information based input selection in neuro-fuzzy modeling for long term load forecasting**. Computer Science and Information Technologies. Yerevan, Armenia: CSIT 2009. 2009. p. 6.

MARQUES, G. **Análise em componentes principais**. [S.l.]. 2006.

MAY, R. J. et al. Application of partial mutual information variable selection to ANN forecasting of water quality in water distribution systems. **Environmental Modelling & Software**, v. 23, n. 10-11, p. 1289-1299, outubro-novembro 2008. ISSN ISSN: 1364-8152 DOI: 10.1016/j.envsoft.2008.03.008. Disponível em: <<http://goo.gl/GaanA>>.

MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **Bulletin of Mathematical Biology**, v. 5, n. 4, p. 115-133, dezembro 1943. ISSN ISSN: 0007-4985 DOI: 10.1007/bf02478259. Disponível em: <<http://goo.gl/4Js03>>.

MESIN, L. et al. **A feature selection method for air quality forecasting**. Proceedings of the 20th international conference on Artificial neural networks: Part III. Berlin, Heidelberg: Springer-Verlag. 2010. p. 489-494.

MICHALSKI, R. S.; BRATKO, I.; KUBAT, M. **Machine learning and data mining: methods and applications**. New York, USA: John Wiley & Sons Inc., 1998. 472 p. ISBN ISSN: 978-0-471-97199-3. Disponível em: <<http://goo.gl/vVPL7>>.

MØLLER, M. F. A scaled conjugate gradient algorithm for fast supervised learning. **Neural Networks**, v. 6, n. 4, p. 525-533, 1993. ISSN DOI: 10.1.1.38.3391. Disponível em: <<http://goo.gl/FceUD>>.

MOODY, J.; UTANS, J. Architecture selection strategies for neural networks: application to corporate bond rating prediction. **Neural Networks in the Capital Markets**, v. 1, p. 27, 1994. ISSN DOI: 10.1.1.37.9405. Disponível em: <<http://goo.gl/7ycpx>>.

MOREIRA, M. O. et al. Modelo baseado em combinação de previsores para previsão de séries temporais de carga elétrica. **XLIII Simpósio Brasileiro de Pesquisa Operacional**, p. 803-814, agosto 2011. Disponível em: <<http://goo.gl/cMyaI>>.

MORETTIN, P. A.; TOLOI, C. M. D. C. **Modelos para previsão de séries temporais**. Rio de Janeiro: Instituto de Matemática Pura e Aplicada, v. 1, 1981. 624 p. Disponível em: <<http://goo.gl/RjfbB>>.

MORETTIN, P. A.; TOLOI, C. M. D. C. **Análise de séries temporais**. 2. ed. São Paulo: Edgard Blucher, 2006. 538 p. ISBN ISBN: 9788521203896. Disponível em: <<http://goo.gl/Da0JM>>.

MORI, H.; KURATA, E. **Graphical modeling for selecting input variables of short-term load forecasting**. Power Tech, 2007 IEEE Lausanne. Lausanne, Suíça: IEEE Conference Publications. julho 2007. p. 1084-1089.

NISKA, H.; HEIKKINEN, M.; KOLEHMAINEN, M. Genetic algorithms and sensitivity analysis applied to select inputs of a multi-layer perceptron for the prediction of air pollutant time-series. In: CORCHADO, E., et al. **Intelligent Data Engineering and Automated Learning - IDEAL 2006**. [S.l.]: Springer Berlin Heidelberg, v. 4224, 2006. p. 224-231. ISBN ISBN: 978-3-540-45485-4 DOI: 10.1007/11875581_27. Disponível em: <<http://goo.gl/zLIqf>>.

NOCEDAL, J. A.; WRIGHT, S. J. **Numerical optimization**. 2. ed. [S.l.]: Springer-Verlag New York, 1999. 636 p. ISBN ISBN: 9780387987934 LCCN: 99013263. Disponível em: <<http://goo.gl/A9xWN>>.

NOSE, K.; LOTUFO, A. D. P.; LOPES, M. L. M. Utilização de redes neurais artificiais e redes neuro-fuzzy para previsão de cargas elétrica. **7th Brazilian Conference on Dynamics, Control and Applications**, v. 2, p. 6, maio 2008. Disponível em: <<http://goo.gl/K3yS2>>.

OHISHI, T. et al. **Comparison of two heuristic approaches to hydro unit commitment**. Power Tech. St. Petersburg, Russia: [s.n.]. junho 2005. p. 1-7.

OLIVEIRA, C. A.; BELDERRAIN, M. C. N. Modelo para apoio à decisão no processo de classificação de unidades móveis no ambiente marítimo. **IX SIGE Simpósio de Guerra Eletrônica**, v. 1, p. 2, 2007. Disponível em: <<http://goo.gl/iGyii>>.

ONS. Rede de operação sistêmica. **Operador Nacional do Sistema Elétrico (ONS), Centro Nacional de Operação do Sistema (CNOS)**, março 2013. Disponível em: <<http://goo.gl/s6ZHp>>.

PARK, D. C. et al. Electric load forecasting using an artificial neural network. **IEEE Transactions on Power Systems**, v. 6, n. 2, p. 442-449, 1991. ISSN ISSN: 0885-8950 DOI: 10.1109/59.76685. Disponível em: <<http://goo.gl/pGESr>>.

PEARLMUTTER, B. A. Fast Exact Multiplication by the Hessian. **Neural Computation**, v. 6, p. 147-160, 1994. ISSN DOI: doi=10.1.1.29.6143. Disponível em: <<http://goo.gl/insIy>>.

PEARSON, K. On lines and planes of closest fit to systems of points in space. **Philosophical Magazine**, v. 2, n. 6, p. 559-572, 1901. Disponível em: <<http://goo.gl/OEyVC>>.

PENG, T. M.; HUBELE, N. F.; KARADY, G. G. An adaptive neural network approach to one-week ahead load forecasting. **IEEE Transactions on Power Systems**, v. 8, n. 3, p. 1195-1203, 1993. ISSN ISSN: 0885-8950 DOI: 10.1109/59.260877. Disponível em: <<http://goo.gl/ctKbV>>.

PIRAS, A. et al. **Heterogeneous artificial neural network for short term electrical load forecasting**. Power Industry Computer Application Conference, 1995. Conference Proceedings., 1995 IEEE. [S.l.]: [s.n.]. 1995. p. 319-324.

REIS, A. J. R.; SILVA, A. P. A. D. Aplicação da transformada wavelet discreta na previsão de carga a curto prazo via redes. **Sba: Controle & Automação Sociedade Brasileira de Automatica**, v. 15, p. 101-108, março 2004. ISSN ISSN: 0103-1759 DOI: <http://dx.doi.org/10.1590/S0103-17592004000100013>. Disponível em: <<http://goo.gl/UtH2Ue>>.

REYNEAU, P. O. Predicting load on residence circuits. **Electrical World**, v. LXXI, n. 19, p. 969-971, maio 1918.

REZENDE, S. O. **Sistemas inteligentes: fundamentos e aplicações**. 1ª. ed. Barueri, Brasil: Ed. Manole Ltda., 2005. 525 p. ISBN ISSN: 85-204-1683-7. Disponível em: <<http://goo.gl/RMV5H>>.

RICH, E.; KNIGHT, K. **Inteligência artificial**. [S.l.]: Makron Books, 1993. 503 p. ISBN ISBN: 9788534601221. Disponível em: <<http://goo.gl/jkAfC>>.

RUMELHART, D. E. **Parallel Distributed Processing: Explorations in the Microstructure of Cognition**. 7. ed. University of California, San Diego: Psychological and biological models, The MIT Press, v. 2, 1986. 567 p. ISBN ISBN: 9780262680530 LCCN: 85024073. Disponível em: <<http://goo.gl/SFda5>>.

RUTANEN, K. A C++ library for efficient estimation of information-theoretic measures from time-series' in arbitrary dimensions. **Homepage of Kalle Rutanen**, agosto 2011. ISSN DOI: <http://goo.gl/tv49o>.

SACHDEV, M. S.; BILLINTON, R.; PETERSON, C. A. Representative bibliography on load forecasting. **IEEE Transactions on Power Apparatus and Systems**, v. 96, n. 2, p. 697-700, março 1977. ISSN ISSN: 0018-9510 DOI: 10.1109/T-PAS.1977.32382. Disponível em: <<http://goo.gl/cAzXI>>.

SALGADO, R. M. **Um modelo de previsão de carga por barramento**. Departamento de Engenharia de Sistemas (DENSIS), Faculdade de Engenharia Elétrica e Computação (FEEC), Universidade Estadual de Campinas (Unicamp). Campinas. 2004.

SALGADO, R. M. **Sistema de suporte à decisão para análise e previsão de carga por barramento**. Departamento de Engenharia de Sistemas (DENSIS), Faculdade de Engenharia Elétrica e Computação (FEEC), Universidade Estadual de Campinas (Unicamp). Campinas. 2009.

SALGADO, R. M.; OHISHI, T.; BALLINI, R. **A short-term bus load forecasting system**. 10th International Conference on Hybrid Intelligent Systems (HIS). Atlanta, GA: [s.n.]. agosto 2010. p. 55-60.

SCALES, L. E. **Introduction to Non-Linear Optimization**. [S.l.]: Springer Verlag Gmbh, 1985. ISBN ISBN: 9780387912523 LCCN: 84010553. Disponível em: <<http://goo.gl/35Gal>>.

SCARSELLI, F.; TSOI, A. C. Universal approximation using feedforward neural networks: a survey of some existing methods, and some new results. **Neural Networks**, v. 11, n. 1, p. 15-37, 1998. ISSN ISSN: 0893-6080 DOI: 10.1016/S0893-6080(97)00097-X. Disponível em: <<http://goo.gl/p6UFU>>.

SHARMA, A. Seasonal to interannual rainfall probabilistic forecasts for improved water supply management: part 1 - a strategy for system predictor identification. **Journal of Hydrology**, v. 239, n. 1-4, p. 232-239, dezembro 2000. ISSN ISSN: 0022-1694 DOI: 10.1016/S0022-1694(00)00346-2. Disponível em: <<http://goo.gl/uwaT2>>.

SHARMA, A. Seasonal to interannual rainfall probabilistic forecasts for improved water supply management: part 3 - a nonparametric probabilistic forecast model. **Journal of Hydrology**, v. 239, n. 1-4, p. 249-258, dezembro 2000. ISSN ISSN: 0022-1694 DOI: 10.1016/S0022-1694(00)00348-6. Disponível em: <<http://goo.gl/lwkHO>>.

SHARMA, A. et al. Seasonal to interannual rainfall probabilistic forecasts for improved water supply management: part 2 - predictor identification of quarterly rainfall using ocean-atmosphere information. **Journal of Hydrology**, v. 239, n. 1-4, p. 240-248, dezembro 2000. ISSN ISSN: 0022-1694 DOI: 10.1016/S0022-1694(00)00347-4. Disponível em: <<http://goo.gl/5wwgC>>.

SIQUEIRA, T. G.; SALGADO, R. M. An Intelligent Approach for Medium Term Hydropower Scheduling Using Ensemble Model. In: WAN, X. **Electrical Power Systems and Computers**. [S.l.]: Springer Berlin Heidelberg, v. 99, 2011. p. 353-362. ISBN ISBN: 978-3-642-21746-3 DOI: 10.1007/978-3-642-21747-0_43. Disponível em: <<http://goo.gl/zXKNU>>.

SOARES et al. Análise do erro de previsão de vazões mensais com diferentes horizontes de previsão. **Sba: Controle & Automação Sociedade Brasileira de Automatica**, v. 23, p. 294-305, jun. 2012. ISSN ISSN: 0103-1759 DOI: 10.1590/S0103-17592012000300004. Disponível em: <<http://goo.gl/QukpS>>.

TAKAGI, T.; SUGENO, M. Fuzzy identification of systems and its applications to modeling and control. **IEEE Transactions on Systems, Man and Cybernetics**, v. SMC-15, n. 1, p. 116-132, janeiro 1985. ISSN ISSN: 0018-9472 DOI: 10.1109/TSMC.1985.6313399. Disponível em: <<http://goo.gl/dfsdu>>.

VAHABIE, A. H. et al. **Mutual information based input selection in neuro-fuzzy modeling for short term load forecasting of iran national power system**. IEEE International Conference on Control and Automation. Guangzhou: IEEE Conference Publications. maio 2007. p. 2710-2715.

VASCONCELOS, S. **Análise de componentes principais**. [S.l.]. 2006.

VELÁSQUEZ, R. M. G. **Seleção de variáveis de entrada para previsores neurais de carga**. Universidade Federal do Rio de Janeiro (UFRJ), COPPE. Rio de Janeiro, Brasil. 2006.

VERMAAK, J.; BOTHA, E. C. Recurrent neural networks for short-term load forecasting. **IEEE Transactions on Power Systems**, v. 13, n. 1, p. 126-132, 1998. ISSN ISSN: 0885-8950 DOI: 10.1109/59.651623. Disponível em: <<http://goo.gl/mv426>>.

VON ZUBEN, F. J. **Modelos Paramétricos e Não-Paramétricos de Redes neurais Artificiais e Aplicações**. Faculdade de Engenharia Elétrica e de Computação (FEEC), Unicamp. Campinas. 1996.

WERMUTH, N.; SCHEIDT, E. Algorithm AS 105: fitting a covariance selection model to a matrix. **Journal of the Royal Statistical Society**, v. 26, n. 1, p. 88-92, 1977. ISSN ISSN: 00359254. Disponível em: <<http://goo.gl/N90AG>>.

WHEELWRIGHT, S. C.; MAKRIDAKIS, S. G. **Forecasting methods for management**. New York: John Wiley & Sons Inc, 1985. 404 p. ISBN ISBN: 9780471816874 LCCN: lc85003295. Disponível em: <<http://goo.gl/Z3dAS>>.

APÊNDICES

APÊNDICE A

Tabela A.1 - Combinação de configurações.

Barramento	Normalização	Ordem	Seleção	Jump	lags	Repet	Código
Barramento	Máximo Dia	Antes	MI	Dia a Dia	3	10	Bar - DaMd3
Barramento	Máximo Dia	Antes	MI	Dia a Dia	5	10	Bar - DaMd5
Barramento	Máximo Dia	Antes	MI	Dia a Dia	7	10	Bar - DaMd7
Barramento	Máximo Dia	Antes	MI	Hora a Hora	3	10	Bar - DaMh3
Barramento	Máximo Dia	Antes	MI	Hora a Hora	5	10	Bar - DaMh5
Barramento	Máximo Dia	Antes	MI	Hora a Hora	7	10	Bar - DaMh7
Barramento	Máximo Dia	Antes	PMI	Dia a Dia	3	10	Bar - DaPd3
Barramento	Máximo Dia	Antes	PMI	Dia a Dia	5	10	Bar - DaPd5
Barramento	Máximo Dia	Antes	PMI	Dia a Dia	7	10	Bar - DaPd7
Barramento	Máximo Dia	Antes	PMI	Hora a Hora	3	10	Bar - DaPh3
Barramento	Máximo Dia	Antes	PMI	Hora a Hora	5	10	Bar - DaPh5
Barramento	Máximo Dia	Antes	PMI	Hora a Hora	7	10	Bar - DaPh7
Barramento	Máximo Dia	Depois	MI	Dia a Dia	3	10	Bar - DdMd3
Barramento	Máximo Dia	Depois	MI	Dia a Dia	5	10	Bar - DdMd5
Barramento	Máximo Dia	Depois	MI	Dia a Dia	7	10	Bar - DdMd7
Barramento	Máximo Dia	Depois	MI	Hora a Hora	3	10	Bar - DdMh3
Barramento	Máximo Dia	Depois	MI	Hora a Hora	5	10	Bar - DdMh5
Barramento	Máximo Dia	Depois	MI	Hora a Hora	7	10	Bar - DdMh7
Barramento	Máximo Dia	Depois	PMI	Dia a Dia	3	10	Bar - DdPd3
Barramento	Máximo Dia	Depois	PMI	Dia a Dia	5	10	Bar - DdPd5
Barramento	Máximo Dia	Depois	PMI	Dia a Dia	7	10	Bar - DdPd7
Barramento	Máximo Dia	Depois	PMI	Hora a Hora	3	10	Bar - DdPh3
Barramento	Máximo Dia	Depois	PMI	Hora a Hora	5	10	Bar - DdPh5
Barramento	Máximo Dia	Depois	PMI	Hora a Hora	7	10	Bar - DdPh7
Barramento	Máximo Série	Antes	MI	Dia a Dia	3	10	Bar - SaMd3
Barramento	Máximo Série	Antes	MI	Dia a Dia	5	10	Bar - SaMd5
Barramento	Máximo Série	Antes	MI	Dia a Dia	7	10	Bar - SaMd7
Barramento	Máximo Série	Antes	MI	Hora a Hora	3	10	Bar - SaMh3
Barramento	Máximo Série	Antes	MI	Hora a Hora	5	10	Bar - SaMh5
Barramento	Máximo Série	Antes	MI	Hora a Hora	7	10	Bar - SaMh7
Barramento	Máximo Série	Antes	PMI	Dia a Dia	3	10	Bar - SaPd3
Barramento	Máximo Série	Antes	PMI	Dia a Dia	5	10	Bar - SaPd5
Barramento	Máximo Série	Antes	PMI	Dia a Dia	7	10	Bar - SaPd7
Barramento	Máximo Série	Antes	PMI	Hora a Hora	3	10	Bar - SaPh3
Barramento	Máximo Série	Antes	PMI	Hora a Hora	5	10	Bar - SaPh5
Barramento	Máximo Série	Antes	PMI	Hora a Hora	7	10	Bar - SaPh7
Barramento	Máximo Série	Depois	MI	Dia a Dia	3	10	Bar - SdMd3
Barramento	Máximo Série	Depois	MI	Dia a Dia	5	10	Bar - SdMd5
Barramento	Máximo Série	Depois	MI	Dia a Dia	7	10	Bar - SdMd7
Barramento	Máximo Série	Depois	MI	Hora a Hora	3	10	Bar - SdMh3
Barramento	Máximo Série	Depois	MI	Hora a Hora	5	10	Bar - SdMh5
Barramento	Máximo Série	Depois	MI	Hora a Hora	7	10	Bar - SdMh7
Barramento	Máximo Série	Depois	PMI	Dia a Dia	3	10	Bar - SdPd3
Barramento	Máximo Série	Depois	PMI	Dia a Dia	5	10	Bar - SdPd5
Barramento	Máximo Série	Depois	PMI	Dia a Dia	7	10	Bar - SdPd7
Barramento	Máximo Série	Depois	PMI	Hora a Hora	3	10	Bar - SdPh3
Barramento	Máximo Série	Depois	PMI	Hora a Hora	5	10	Bar - SdPh5
Barramento	Máximo Série	Depois	PMI	Hora a Hora	7	10	Bar - SdPh7

Tabela A.2 - MAPE para a potência ativa da Barra-I (%).

Código	BFGS	DFP	FR	GRAD	OSS	PR	SCGM	Média
BI - DaMd3	6,2740	5,7945	5,8620	5,8734	5,8825	5,8993	5,5695	5,8793
BI - DaMd5	6,1020	5,7177	6,0376	6,0884	5,8525	6,2116	5,4180	5,9183
BI - DaMd7	6,1199	6,2021	6,3265	6,0867	6,3668	5,8924	5,2785	6,0390
BI - DaMh3	7,0474	6,9358	7,0584	6,9263	7,0374	7,0583	6,7464	6,9729
BI - DaMh5	6,9728	6,7620	7,0383	6,8584	6,9635	6,7379	6,5326	6,8379
BI - DaMh7	6,8792	7,3524	7,1021	7,2609	7,3096	7,1269	6,5003	7,0759
BI - DaPd3	8,1396	8,5308	8,0098	8,0702	8,1215	8,1417	7,8611	8,1250
BI - DaPd5	7,8828	8,4308	8,2816	8,4115	8,1882	8,2554	7,7322	8,1689
BI - DaPd7	8,0497	8,2071	7,9413	7,9418	8,2575	8,1054	7,7700	8,0390
BI - DaPh3	7,7116	7,7506	7,7769	7,5125	7,7323	7,5504	7,4265	7,6373
BI - DaPh5	5,8072	5,5899	5,8386	5,6528	6,1495	6,0581	5,2749	5,7673
BI - DaPh7	5,0206	5,3713	5,4547	4,8687	5,3216	5,5039	4,1847	5,1036
BI - DdMd3	5,7648	5,6794	5,9571	5,7450	5,6218	5,6013	5,3385	5,6726
BI - DdMd5	5,5745	4,9441	5,2836	5,1608	5,3233	5,2985	4,7595	5,1920
BI - DdMd7	5,3297	5,1840	5,2261	4,9875	4,6947	4,9672	4,6710	5,0086
BI - DdMh3	6,3228	5,8568	6,3729	5,7946	5,9898	6,0462	5,6545	6,0054
BI - DdMh5	5,2727	5,3360	5,1508	5,4485	5,2831	5,0885	4,3943	5,1391
BI - DdMh7	5,4227	5,2585	4,7433	4,4266	5,3013	4,7334	4,2234	4,8727
BI - DdPd3	7,2935	7,0578	7,1495	7,0144	7,0632	7,2611	7,0989	7,1341
BI - DdPd5	7,5957	7,3319	7,4073	7,2915	7,5169	7,1700	7,5739	7,4125
BI - DdPd7	8,1537	7,8645	7,4844	7,3337	7,6868	7,4281	7,5051	7,6366
BI - DdPh3	6,4200	6,0285	6,2348	5,9841	5,9468	6,2043	5,7048	6,0748
BI - DdPh5	5,7913	5,9225	5,7474	5,6901	5,5282	5,9146	5,4944	5,7269
BI - DdPh7	5,9085	6,0144	6,1603	6,0109	5,9216	6,1602	5,7150	5,9844
BI - SaMd3	6,4603	6,2442	6,4880	6,2667	7,0461	6,3435	5,9759	6,4035
BI - SaMd5	5,9200	5,8404	6,4428	5,9810	6,0388	5,8048	5,9197	5,9925
BI - SaMd7	5,1854	4,8823	6,0672	5,1014	5,6973	5,1530	4,4064	5,2133
BI - SaMh3	7,0230	6,4925	7,3264	6,4639	6,9775	7,0873	6,2036	6,7963
BI - SaMh5	7,4740	6,0152	6,3157	6,1871	6,5964	6,5484	5,3044	6,3487
BI - SaMh7	5,5787	4,4942	5,6898	5,7084	6,4747	5,7719	5,3846	5,5860
BI - SaPd3	9,4439	9,2273	9,4074	8,7609	9,2344	9,5584	8,8846	9,2167
BI - SaPd5	8,6105	9,1637	8,9914	8,4638	8,6040	8,6050	8,0381	8,6395
BI - SaPd7	6,0409	6,7539	6,4128	6,7297	7,5968	7,1575	6,0754	6,6810
BI - SaPh3	6,9377	6,6717	7,0697	6,8229	7,5766	6,4493	5,8332	6,7659
BI - SaPh5	6,5654	6,2791	6,8856	6,2805	7,0631	7,4012	6,6696	6,7349
BI - SaPh7	5,4129	5,2064	7,0092	5,8588	5,7522	6,3952	5,1987	5,8333
BI - SdMd3	7,0597	6,3571	6,9554	6,5557	6,5755	6,7542	5,8674	6,5893
BI - SdMd5	6,2046	5,8051	6,1433	5,9789	6,5951	6,2646	5,3597	6,0502
BI - SdMd7	5,0729	4,6170	6,0615	5,3042	5,2061	6,1738	5,2751	5,3872
BI - SdMh3	6,7471	6,5019	7,2314	6,1484	6,6048	6,4578	5,9068	6,5140
BI - SdMh5	6,1825	6,2678	6,7745	6,1749	6,6269	5,7390	5,8216	6,2267
BI - SdMh7	5,1673	4,8737	6,6507	5,2429	6,1410	5,2314	4,4658	5,3961
BI - SdPd3	9,4612	10,0300	9,4506	9,2432	10,0203	9,8706	9,2889	9,6235
BI - SdPd5	8,9666	9,1806	9,2153	8,8820	8,8451	9,2505	8,9453	9,0408
BI - SdPd7	6,5175	6,9625	6,1807	7,2240	8,1771	7,3539	5,2759	6,8131
BI - SdPh3	7,8712	8,3241	7,9444	7,6832	8,2682	8,1188	7,3642	7,9392
BI - SdPh5	7,4467	6,5508	6,8627	6,9755	6,9735	7,0224	6,2110	6,8632
BI - SdPh7	5,0676	4,5952	6,5774	6,0309	6,1281	6,2589	5,2039	6,3032
Média	6,6515	6,5096	6,7875	6,5106	6,7892	6,6914	6,1106	6,5786

Tabela A.3 - MAE para a potência ativa da Barra-I (MW).

Código	BFGS	DFP	FR	GRAD	OSS	PR	SCGM	Média
BI - DaMd3	2,2752	2,1147	2,1314	2,1401	2,1441	2,1504	2,0349	2,1415
BI - DaMd5	2,2262	2,0870	2,1954	2,2155	2,1380	2,2587	1,9789	2,1571
BI - DaMd7	2,2321	2,2525	2,2945	2,2114	2,3087	2,1406	1,9228	2,1947
BI - DaMh3	2,5678	2,5313	2,5609	2,5134	2,5636	2,5682	2,4579	2,5376
BI - DaMh5	2,5222	2,4618	2,5549	2,4869	2,5222	2,4485	2,3733	2,4814
BI - DaMh7	2,4847	2,6517	2,5659	2,6175	2,6347	2,5796	2,3595	2,5562
BI - DaPd3	2,9511	3,0971	2,9038	2,9185	2,9566	2,9660	2,8510	2,9492
BI - DaPd5	2,8542	3,0485	2,9888	3,0267	2,9449	2,9921	2,8006	2,9508
BI - DaPd7	2,8985	2,9543	2,8488	2,8660	2,9640	2,9326	2,8067	2,8958
BI - DaPh3	2,8247	2,8383	2,8421	2,7414	2,8310	2,7535	2,7182	2,7927
BI - DaPh5	2,1311	2,0491	2,1304	2,0754	2,2525	2,2207	1,9385	2,1140
BI - DaPh7	1,8541	1,9638	1,9886	1,7770	1,9508	2,0235	1,5410	1,8713
BI - DdMd3	2,1217	2,0740	2,1735	2,0936	2,0637	2,0567	1,9607	2,0777
BI - DdMd5	2,0524	1,8045	1,9319	1,8984	1,9580	1,9480	1,7512	1,9063
BI - DdMd7	1,9582	1,8967	1,9139	1,8349	1,7253	1,8328	1,7167	1,8398
BI - DdMh3	2,3189	2,1462	2,3184	2,1201	2,1778	2,1985	2,0789	2,1941
BI - DdMh5	1,9256	1,9557	1,8914	2,0014	1,9252	1,8622	1,6113	1,8818
BI - DdMh7	1,9984	1,9466	1,7452	1,6258	1,9226	1,7411	1,5452	1,7893
BI - DdPd3	2,6579	2,5782	2,6008	2,5564	2,5670	2,6428	2,5922	2,5993
BI - DdPd5	2,7446	2,6390	2,6686	2,6298	2,7114	2,5817	2,7406	2,6737
BI - DdPd7	2,9377	2,8366	2,6903	2,6462	2,7754	2,6706	2,6996	2,7509
BI - DdPh3	2,3418	2,1951	2,2623	2,1746	2,1591	2,2607	2,0840	2,2111
BI - DdPh5	2,1287	2,1741	2,1152	2,0929	2,0400	2,1656	2,0458	2,1089
BI - DdPh7	2,1927	2,2358	2,2699	2,2048	2,1844	2,2824	2,1255	2,2136
BI - SaMd3	2,3837	2,2693	2,4085	2,3386	2,5728	2,3405	2,2160	2,3613
BI - SaMd5	2,2082	2,1720	2,3372	2,1933	2,2318	2,1592	2,1849	2,2124
BI - SaMd7	1,9355	1,8240	2,2461	1,8932	2,1155	1,9024	1,6172	1,9334
BI - SaMh3	2,5730	2,3822	2,6906	2,4147	2,5685	2,6015	2,3065	2,5053
BI - SaMh5	2,7013	2,1969	2,2946	2,3103	2,4295	2,4208	1,9811	2,3335
BI - SaMh7	2,0327	1,6807	2,0819	2,1471	2,3771	2,1269	1,9942	2,0629
BI - SaPd3	3,4521	3,3674	3,4090	3,2522	3,3753	3,5035	3,2533	3,3733
BI - SaPd5	3,1704	3,3477	3,2920	3,1271	3,1636	3,1431	2,9879	3,1760
BI - SaPd7	2,2212	2,4358	2,3331	2,4969	2,7675	2,6472	2,2265	2,4469
BI - SaPh3	2,5455	2,4432	2,5557	2,5140	2,7354	2,3332	2,1573	2,4692
BI - SaPh5	2,4186	2,3103	2,4983	2,3286	2,5898	2,6809	2,4136	2,4629
BI - SaPh7	1,9871	1,9230	2,5340	2,1952	2,1070	2,3352	1,9485	2,1471
BI - SdMd3	2,5689	2,3210	2,5365	2,4279	2,4149	2,5049	2,1971	2,4245
BI - SdMd5	2,2849	2,1499	2,2894	2,2398	2,4203	2,3051	2,0086	2,2426
BI - SdMd7	1,8601	1,6971	2,2054	2,0275	1,9122	2,2747	1,9574	1,9906
BI - SdMh3	2,4974	2,3605	2,6278	2,3080	2,4258	2,3859	2,2011	2,4009
BI - SdMh5	2,2874	2,2914	2,5175	2,3010	2,4362	2,1322	2,1573	2,3033
BI - SdMh7	1,9014	1,7862	2,4700	1,9404	2,2852	1,9273	1,6708	1,9973
BI - SdPd3	3,4222	3,6093	3,4446	3,3813	3,6035	3,5738	3,3672	3,4860
BI - SdPd5	3,2786	3,3609	3,3148	3,2576	3,2603	3,3493	3,2737	3,2993
BI - SdPd7	2,3887	2,4854	2,2583	2,6882	2,9363	2,7028	1,9443	2,4863
BI - SdPh3	2,9135	3,0605	2,9406	2,8586	3,0317	2,9536	2,7270	2,9265
BI - SdPh5	2,7518	2,4167	2,5248	2,6108	2,5514	2,5742	2,2775	2,5296
BI - SdPh7	1,9013	1,7130	2,3842	2,2660	2,2540	2,3089	1,9144	3,0579
Média	2,4351	2,3779	2,4746	2,3956	2,4789	2,4472	2,2441	2,4076

Tabela A.4 - MAPE para a potência reativa da Barra-I (%).

Código	BFGS	DFP	FR	GRAD	OSS	PR	SCGM	Média
BI - DaMd3	115,3682	118,9665	129,3682	131,2370	129,2478	127,8616	137,4952	127,0778
BI - DaMd5	115,5598	115,1194	127,9815	125,6568	120,0928	124,1566	125,6951	122,0374
BI - DaMd7	96,4309	85,6537	96,3606	95,3193	99,7036	95,1341	91,6734	94,3251
BI - DaMh3	108,1446	111,5362	123,5679	114,8851	120,6563	119,2550	121,7403	117,1122
BI - DaMh5	109,9666	107,2954	127,2140	116,4363	117,2796	120,3014	120,4704	116,9948
BI - DaMh7	94,0988	87,7819	97,9368	91,9111	95,6998	88,7942	89,6200	92,2632
BI - DaPd3	119,5223	118,9675	154,0755	162,5473	152,4578	164,2451	161,4862	147,6145
BI - DaPd5	125,8909	124,4683	160,3109	160,4750	151,0841	159,7902	162,5572	149,2252
BI - DaPd7	95,1656	98,5153	109,8782	97,5332	104,4612	96,7993	96,9060	99,8941
BI - DaPh3	120,1194	122,2515	153,5421	145,8529	158,2708	151,3683	150,2505	143,0936
BI - DaPh5	110,6784	109,0760	123,6044	113,2512	121,3723	116,4589	112,3959	115,2624
BI - DaPh7	96,0844	96,4566	103,2503	94,2427	95,4061	95,5614	92,7385	96,2486
BI - DdMd3	111,7718	116,9883	130,2298	125,9154	128,3465	125,5605	136,7282	125,0772
BI - DdMd5	105,2967	109,6506	118,7692	124,8161	117,5332	120,0095	122,1749	116,8929
BI - DdMd7	88,9045	89,0628	92,9612	97,5087	91,6563	94,8185	88,6417	91,9362
BI - DdMh3	109,4028	114,9843	126,8627	118,9881	124,1149	122,8566	118,7500	119,4228
BI - DdMh5	115,4766	114,8066	121,8775	125,6737	122,4860	121,8491	129,7249	121,6992
BI - DdMh7	90,3904	92,3743	97,0114	92,2168	94,1623	92,8999	84,8525	91,9868
BI - DdPd3	127,0665	116,1129	153,5025	152,6283	151,6587	152,8493	153,1902	143,8583
BI - DdPd5	118,7799	118,5301	145,7567	144,4915	141,3033	143,8012	145,5466	136,8870
BI - DdPd7	97,2803	92,7494	104,4981	96,1236	103,0248	97,8694	97,0606	98,3723
BI - DdPh3	114,1013	114,6342	139,0905	137,3475	137,2700	140,8951	136,6779	131,4309
BI - DdPh5	109,1035	114,8930	120,0397	120,1864	120,2253	125,6901	126,6821	119,5457
BI - DdPh7	93,5081	86,5990	96,5777	90,5317	97,2637	92,1742	84,3126	91,5667
BI - SaMd3	118,4277	116,4538	127,0762	133,1124	141,4811	131,4333	130,4843	128,3527
BI - SaMd5	114,6560	116,5750	117,6385	119,9905	126,4565	120,6973	126,5718	120,3694
BI - SaMd7	94,6079	92,8770	101,4307	101,5203	110,9162	102,9396	86,7595	98,7216
BI - SaMh3	119,5170	122,9832	127,7749	132,9007	132,0833	121,2225	130,8979	126,7685
BI - SaMh5	113,6427	119,9981	124,4900	130,8826	133,5946	124,8844	120,0796	123,9389
BI - SaMh7	103,8539	95,9793	101,5033	101,6871	109,0300	102,3610	95,7980	101,4589
BI - SaPd3	136,9016	147,2420	146,4641	153,7900	141,4422	144,6449	164,1280	147,8018
BI - SaPd5	144,0641	139,3448	152,4935	143,6841	162,9291	151,7843	146,3427	148,6632
BI - SaPd7	97,9126	99,1896	101,9608	111,7570	126,1109	116,8226	85,7423	105,6423
BI - SaPh3	126,7725	132,0652	135,1691	146,4614	144,8861	137,2078	144,1778	138,1057
BI - SaPh5	114,0539	120,0084	124,1952	123,8516	134,4399	124,3303	122,8942	123,3962
BI - SaPh7	103,8173	93,4431	101,5796	114,7266	107,0765	114,2093	85,3237	102,8823
BI - SdMd3	122,5726	122,9556	128,5342	133,8553	129,9966	120,8823	127,3046	126,5859
BI - SdMd5	114,4536	119,4322	112,4462	109,1020	126,8830	115,5913	119,9943	116,8432
BI - SdMd7	101,8826	97,8959	94,9996	100,6064	110,1378	98,0158	88,9482	98,9266
BI - SdMh3	124,8722	115,3251	125,5891	132,2525	128,4487	128,1745	125,0475	125,6728
BI - SdMh5	119,9666	115,2140	124,9824	137,8103	129,5428	128,9227	123,8038	125,7489
BI - SdMh7	99,6192	94,7328	104,6406	103,6142	113,1047	105,3518	88,1990	101,3232
BI - SdPd3	148,9733	149,5215	133,3505	160,4482	146,7489	165,9941	171,2709	153,7582
BI - SdPd5	134,6067	135,5826	143,1001	149,2353	143,7516	148,3034	151,0093	143,6556
BI - SdPd7	103,2606	102,2446	118,4310	106,9852	125,6741	115,6545	94,1749	109,4893
BI - SdPh3	125,1678	130,6614	137,8933	145,8592	148,3232	141,3093	149,7482	139,8518
BI - SdPh5	125,8819	121,2354	124,2299	134,6012	131,6951	121,8045	122,2586	125,9581
BI - SdPh7	101,1790	94,0148	107,7232	95,5610	109,5937	100,7648	91,7376	100,0820
Média	112,4745	111,9260	122,3326	122,9181	125,1901	122,3814	120,4181	119,6630

Tabela A.5 - MAE para a potência reativa da Barra-I (MVar).

Código	BFGS	DFP	FR	GRAD	OSS	PR	SCGM	Média
BI - DaMd3	1,9028	1,9509	1,6654	1,6937	1,7105	1,7671	1,6444	1,7621
BI - DaMd5	1,7333	1,6907	1,4805	1,4052	1,6017	1,5315	1,6163	1,5799
BI - DaMd7	1,1087	1,0351	1,0834	0,9817	1,1738	1,0495	0,9465	1,0541
BI - DaMh3	1,7509	1,6101	1,5145	1,4877	1,6102	1,4964	1,5004	1,5672
BI - DaMh5	1,6637	1,7152	1,4091	1,4220	1,5898	1,4157	1,4818	1,5282
BI - DaMh7	1,1517	1,0337	1,0386	1,0313	1,1204	1,0012	0,9674	1,0492
BI - DaPd3	2,4169	2,4565	2,2189	2,2154	2,2286	2,2201	2,2459	2,2860
BI - DaPd5	2,3243	2,4191	2,1370	2,1817	2,1852	2,1629	2,1585	2,2241
BI - DaPd7	1,2345	1,2472	1,1906	1,1787	1,2398	1,2325	1,1254	1,2070
BI - DaPh3	2,3903	2,4430	2,1508	2,0505	2,2200	2,1780	2,1242	2,2224
BI - DaPh5	1,4878	1,5202	1,4636	1,4052	1,5034	1,3791	1,3508	1,4443
BI - DaPh7	1,1487	1,0963	1,1365	1,0593	1,1088	1,0594	1,0218	1,0901
BI - DdMd3	1,9334	1,9360	1,6366	1,5627	1,6670	1,6845	1,6659	1,7266
BI - DdMd5	1,7818	1,7413	1,4839	1,4172	1,5998	1,4889	1,5191	1,5760
BI - DdMd7	1,0097	0,9669	0,9622	1,0014	1,0090	1,0017	0,9157	0,9809
BI - DdMh3	1,8484	1,7635	1,5104	1,4463	1,5940	1,6442	1,5175	1,6178
BI - DdMh5	1,8120	1,6886	1,5554	1,4753	1,5673	1,5800	1,4620	1,5915
BI - DdMh7	1,1168	1,0155	0,9862	0,9471	1,1555	1,0108	0,9632	1,0279
BI - DdPd3	2,4468	2,4518	2,1800	2,1781	2,2134	2,1694	2,2013	2,2630
BI - DdPd5	2,2749	2,3388	1,9937	2,0033	2,0622	1,9790	1,9901	2,0917
BI - DdPd7	1,3532	1,2444	1,1660	1,1677	1,2498	1,1494	1,0946	1,2036
BI - DdPh3	2,2785	2,3596	1,9360	1,9084	2,0197	1,9968	1,9560	2,0650
BI - DdPh5	1,8572	1,6768	1,4165	1,4591	1,5094	1,5323	1,4478	1,5570
BI - DdPh7	1,1805	1,0513	1,0007	1,0161	1,1128	0,9903	0,9747	1,0466
BI - SaMd3	1,8924	1,9956	1,8084	1,7880	1,9242	1,8589	1,7089	1,8538
BI - SaMd5	1,8251	1,7262	1,6378	1,6104	1,8070	1,8701	1,5233	1,7143
BI - SaMd7	1,2132	1,2431	1,3758	1,3587	1,6959	1,3902	1,0372	1,3306
BI - SaMh3	2,0380	1,9514	1,8462	1,8343	2,0636	2,0257	1,6588	1,9169
BI - SaMh5	1,8641	1,8112	1,8104	1,8073	1,8602	1,6709	1,6402	1,7806
BI - SaMh7	1,2178	1,1728	1,3634	1,3273	1,5370	1,4707	1,1011	1,3129
BI - SaPd3	2,3535	2,2797	2,3013	2,2440	2,4109	2,3763	2,1919	2,3082
BI - SaPd5	2,2666	2,3096	2,2841	2,2305	2,3035	2,2239	2,1077	2,2466
BI - SaPd7	1,3424	1,2417	1,3848	1,4286	1,7788	1,5945	0,9587	1,3899
BI - SaPh3	2,2427	2,3408	2,1735	2,2313	2,2200	2,2395	2,0578	2,2151
BI - SaPh5	1,7548	1,7349	1,8483	1,7650	2,0099	1,8327	1,6083	1,7934
BI - SaPh7	1,3068	1,0492	1,2983	1,4106	1,5406	1,5104	0,9632	1,2970
BI - SdMd3	2,0027	1,8396	1,8882	1,9343	1,9854	1,9209	1,7900	1,9087
BI - SdMd5	1,6581	1,8051	1,6919	1,6780	1,9702	1,8841	1,5120	1,7428
BI - SdMd7	1,2765	1,3307	1,2886	1,2449	1,4308	1,3811	1,0583	1,2873
BI - SdMh3	1,7976	1,8977	1,8683	1,8211	1,9508	1,9312	1,5266	1,8276
BI - SdMh5	1,8661	1,7941	1,9351	1,8464	1,9759	1,8685	1,7568	1,8633
BI - SdMh7	1,2766	1,1754	1,3411	1,2546	1,6776	1,3350	1,0331	1,2991
BI - SdPd3	2,3908	2,3158	2,3056	2,2970	2,4083	2,3381	2,2490	2,3292
BI - SdPd5	2,2325	2,1403	2,1992	2,2087	2,2836	2,3645	1,9718	2,2001
BI - SdPd7	1,2995	1,2194	1,5066	1,4043	1,7832	1,5216	0,9941	1,3898
BI - SdPh3	2,1996	2,2233	2,2236	2,1833	2,2180	2,1812	2,0245	2,1791
BI - SdPh5	1,7674	1,6202	1,8407	1,8308	1,9945	1,9525	1,5146	1,7887
BI - SdPh7	1,2254	1,1464	1,3479	1,2471	1,5303	1,5173	0,9865	1,2858
Média	1,7399	1,7045	1,6435	1,6184	1,7586	1,6871	1,5180	1,6671

Tabela A.6 - MAPE para a potência ativa da Barra-II (%).

Código	BFGS	DFP	FR	GRAD	OSS	PR	SCGM	Média
BII - DaMd3	3,6432	3,2229	3,3987	3,6621	3,4201	3,5929	3,1823	3,4460
BII - DaMd5	3,0521	3,1921	3,7212	3,3284	3,5073	3,5403	3,0764	3,3454
BII - DaMd7	3,0117	3,1970	3,4296	3,3028	3,4739	3,3249	2,9360	3,2394
BII - DaMh3	4,0386	3,9191	4,0630	3,9958	4,0010	3,9492	3,8461	3,9733
BII - DaMh5	4,1752	4,1978	3,9514	4,2848	4,2469	4,0886	3,7519	4,0995
BII - DaMh7	4,1731	4,1547	4,1912	4,1121	4,1719	4,2729	4,0942	4,1672
BII - DaPd3	4,6454	4,5408	4,5027	4,4896	4,4174	4,5364	4,5016	4,5191
BII - DaPd5	4,9176	4,5931	4,7283	4,6918	4,9943	4,7967	4,6128	4,7621
BII - DaPd7	4,8892	4,8996	5,2068	5,1953	4,9072	4,8576	4,9648	4,9886
BII - DaPh3	3,8225	3,4246	3,6255	3,5732	3,5416	3,6679	3,3106	3,5666
BII - DaPh5	3,3109	3,2615	3,4818	3,5219	3,6879	3,4897	2,9616	3,3879
BII - DaPh7	3,5538	3,2522	3,4727	3,3533	3,4851	3,5916	2,8354	3,3634
BII - DdMd3	3,8859	3,4146	3,5761	3,5420	3,5907	3,6764	3,3117	3,5711
BII - DdMd5	3,1925	2,9670	2,9564	3,4537	3,4340	3,3084	2,8421	3,1649
BII - DdMd7	3,0877	3,1633	2,9000	3,1323	2,8622	3,0613	2,6643	2,9816
BII - DdMh3	3,9287	3,6218	4,2029	4,0128	3,7825	3,8978	3,4344	3,8401
BII - DdMh5	3,4139	3,4071	3,5653	3,4457	3,6877	3,6442	3,0867	3,4644
BII - DdMh7	3,6938	3,6728	3,8147	3,8597	3,8686	3,7080	3,4900	3,7297
BII - DdPd3	4,6264	4,4127	4,3661	4,3432	4,3173	4,3288	4,2414	4,3766
BII - DdPd5	4,5989	4,5234	4,5983	4,6532	4,5756	4,5940	4,3408	4,5549
BII - DdPd7	4,9196	4,8657	4,9469	4,8023	4,4509	4,5046	4,5181	4,7154
BII - DdPh3	4,1373	4,0095	4,1278	3,9238	4,0063	4,0568	3,7892	4,0072
BII - DdPh5	3,7132	3,7302	3,8465	3,8579	3,7804	3,6741	3,2013	3,6862
BII - DdPh7	3,5048	3,4339	3,5257	3,7062	3,5067	3,6283	3,1757	3,4973
BII - SaMd3	5,7854	5,8987	6,3954	7,3699	8,3639	7,4694	3,6036	6,4123
BII - SaMd5	5,3252	5,2679	5,0054	5,6200	6,7581	7,3957	3,2056	5,5111
BII - SaMd7	5,6550	6,1280	4,6102	5,3876	6,5728	6,8186	2,7953	5,4239
BII - SaMh3	5,9368	5,6973	7,4995	6,6813	7,4193	7,8720	3,3378	6,3491
BII - SaMh5	5,9744	6,0187	6,2547	6,4866	6,9542	7,2739	3,3749	6,0482
BII - SaMh7	5,0902	4,9791	6,4359	4,6608	6,4764	6,0118	2,8489	5,2147
BII - SaPd3	8,0576	8,2099	9,0168	7,8016	8,9577	8,0642	6,6050	8,1018
BII - SaPd5	7,1269	7,7767	7,9156	7,7829	8,3921	8,7979	5,4157	7,6011
BII - SaPd7	4,9133	4,7941	6,0616	6,1669	7,5538	7,4861	3,1063	5,7260
BII - SaPh3	8,0524	7,1343	7,9729	5,6454	8,1207	8,7481	5,2178	7,2702
BII - SaPh5	6,0892	6,9764	7,4988	6,3485	8,2674	7,8094	4,8028	6,8275
BII - SaPh7	5,6361	5,7677	5,9433	5,6627	7,4090	7,0912	3,1401	5,8072
BII - SdMd3	7,1306	5,0855	6,9252	7,7830	7,3210	7,2678	3,7206	6,4620
BII - SdMd5	4,9746	5,2014	6,2616	5,9245	6,7608	7,9475	3,0865	5,7367
BII - SdMd7	6,0201	4,6959	6,1649	4,3996	6,7161	6,2298	2,5451	5,2531
BII - SdMh3	6,5962	5,9222	7,9999	5,4955	7,4420	8,1672	3,2281	6,4073
BII - SdMh5	5,4480	5,1064	5,9749	6,2091	6,6189	7,4881	3,3836	5,7470
BII - SdMh7	5,5725	4,5806	6,8497	5,8841	6,1746	6,7191	2,8168	5,5139
BII - SdPd3	8,3350	8,1003	8,8497	7,5331	9,0220	9,0262	6,5003	8,1952
BII - SdPd5	7,1905	7,9042	7,6940	7,0764	8,2832	9,2398	5,3917	7,5400
BII - SdPd7	6,1528	5,6664	7,1368	6,6680	8,2288	7,6530	2,9407	6,3495
BII - SdPh3	7,6958	7,4614	8,1848	7,4579	8,9624	8,1439	6,1772	7,7262
BII - SdPh5	8,2756	6,2220	6,7902	6,3930	7,6900	8,5159	4,3053	6,8846
BII - SdPh7	5,3270	5,5264	6,0104	6,1384	6,4384	6,8509	3,0562	7,9427
Média	5,1312	4,9416	5,4094	5,1421	5,7213	5,7891	3,7662	5,1287

Tabela A.7 - MAE para a potência ativa da Barra-II (MW).

Código	BFGS	DFP	FR	GRAD	OSS	PR	SCGM	Média
BII - DaMd3	4,2879	3,7894	3,9630	4,3273	4,0251	4,2423	3,7420	4,0539
BII - DaMd5	3,6337	3,7874	4,3755	3,9176	4,1010	4,2064	3,6270	3,9498
BII - DaMd7	3,5496	3,7878	4,0272	3,8705	4,1076	3,9392	3,4719	3,8220
BII - DaMh3	4,7425	4,6230	4,7868	4,7531	4,7246	4,6665	4,5281	4,6892
BII - DaMh5	4,9290	4,9344	4,6643	5,0345	5,0146	4,8373	4,4221	4,8337
BII - DaMh7	4,8927	4,8860	4,9315	4,8248	4,8961	5,0366	4,8464	4,9020
BII - DaPd3	5,5053	5,3454	5,3117	5,2927	5,2104	5,3436	5,3308	5,3343
BII - DaPd5	5,7924	5,4274	5,5754	5,5423	5,8863	5,6774	5,4451	5,6209
BII - DaPd7	5,7488	5,7595	6,0770	6,1333	5,8203	5,7497	5,8152	5,8720
BII - DaPh3	4,4701	4,0224	4,2332	4,1703	4,1217	4,2986	3,8650	4,1688
BII - DaPh5	3,9011	3,8521	4,1288	4,1888	4,3933	4,1411	3,5084	4,0162
BII - DaPh7	4,2256	3,8289	4,0981	3,9894	4,1629	4,2949	3,3468	3,9924
BII - DdMd3	4,5548	4,0028	4,1573	4,1335	4,1925	4,3348	3,8668	4,1775
BII - DdMd5	3,7530	3,4874	3,4524	4,0962	4,0332	3,9105	3,3493	3,7260
BII - DdMd7	3,6465	3,7264	3,3851	3,6793	3,3884	3,6183	3,1231	3,5096
BII - DdMh3	4,6207	4,2986	4,9650	4,7452	4,4927	4,6258	4,0803	4,5469
BII - DdMh5	4,0359	4,0290	4,1941	4,0742	4,3437	4,2975	3,6596	4,0906
BII - DdMh7	4,3379	4,3271	4,4893	4,5189	4,5618	4,3777	4,1346	4,3925
BII - DdPd3	5,4386	5,2264	5,1523	5,1165	5,0937	5,1049	4,9996	5,1617
BII - DdPd5	5,4243	5,3342	5,4014	5,4724	5,4105	5,4171	5,1226	5,3689
BII - DdPd7	5,7792	5,6995	5,8585	5,6460	5,2849	5,3375	5,3250	5,5615
BII - DdPh3	4,8120	4,6635	4,8063	4,5593	4,6813	4,7436	4,4360	4,6717
BII - DdPh5	4,3753	4,4262	4,5326	4,5312	4,4654	4,3294	3,8062	4,3523
BII - DdPh7	4,1237	4,0582	4,1432	4,3534	4,1533	4,2945	3,7244	4,1215
BII - SaMd3	7,2996	7,3132	7,9542	9,2690	10,2858	9,2449	4,3768	7,9634
BII - SaMd5	6,5056	6,5145	6,1586	6,8511	8,4922	9,0958	3,8668	6,7835
BII - SaMd7	7,0794	7,5266	5,6626	6,6623	8,2423	8,4319	3,4105	6,7165
BII - SaMh3	7,3579	7,0365	9,2634	8,1707	9,1018	9,6117	3,9872	7,7899
BII - SaMh5	7,4770	7,3294	7,7295	7,9926	8,5614	9,1258	4,0435	7,4656
BII - SaMh7	6,2289	6,1607	7,9193	5,7113	7,9446	7,5007	3,4178	6,4119
BII - SaPd3	10,0560	10,2295	11,2767	9,6557	11,1933	10,0520	7,9447	10,0583
BII - SaPd5	8,7304	9,6128	9,6901	9,4901	10,2253	10,9006	6,5199	9,3099
BII - SaPd7	5,8704	5,8032	7,4520	7,7035	9,3614	9,3179	3,7346	7,0347
BII - SaPh3	10,0172	8,7394	9,8714	6,8766	10,1428	10,9754	6,2754	8,9855
BII - SaPh5	7,4476	8,6864	9,1419	7,7820	10,1662	9,7071	5,7246	8,3794
BII - SaPh7	6,8639	7,0406	7,4068	7,0495	9,2656	8,8331	3,8279	7,1839
BII - SdMd3	8,7896	6,3992	8,6654	9,6283	9,0690	9,0279	4,5216	8,0144
BII - SdMd5	6,1306	6,4583	7,9307	7,5058	8,3495	9,8985	3,7139	7,1410
BII - SdMd7	7,4208	5,8933	7,6184	5,4073	8,4577	7,8244	3,0878	6,5300
BII - SdMh3	8,2248	7,3240	9,8646	6,6838	9,1038	10,1490	3,9020	7,8931
BII - SdMh5	6,7837	6,2379	7,3853	7,6360	8,2629	9,3836	4,0978	7,1125
BII - SdMh7	6,9788	5,5891	8,4310	7,1139	7,6002	8,3536	3,3775	6,7777
BII - SdPd3	10,3021	10,0889	10,9481	9,3992	11,1818	10,9591	7,8367	10,1023
BII - SdPd5	8,8967	9,6683	9,4738	8,7973	10,2943	11,5048	6,4540	9,2985
BII - SdPd7	7,4835	6,9819	8,8209	8,2810	10,2669	9,3792	3,4996	7,8161
BII - SdPh3	9,4804	9,2125	10,1060	9,1417	11,2057	10,0245	7,3217	9,4989
BII - SdPh5	10,2848	7,6059	8,3210	7,9581	9,3938	10,6684	5,1923	8,4892
BII - SdPh7	6,5733	6,9035	7,4725	7,7165	7,8818	8,5124	3,6688	6,6272
Média	6,2263	5,9933	6,5682	6,2386	6,9712	7,0689	4,4871	6,2219

Tabela A.8 - MAPE para a potência reativa da Barra-II (%).

Código	BFGS	DFP	FR	GRAD	OSS	PR	SCGM	Média
BII - DaMd3	77,9025	79,9529	87,7208	81,7196	88,0656	86,2647	81,0647	83,2415
BII - DaMd5	73,2622	69,6829	75,8668	77,4843	75,0373	75,1044	68,3695	73,5439
BII - DaMd7	48,7486	44,9801	52,8798	61,2263	59,8713	53,9750	42,1943	51,9822
BII - DaMh3	62,4965	64,7193	61,3881	61,4451	72,5633	69,0107	60,7564	64,6256
BII - DaMh5	63,0912	59,1097	65,0336	70,5498	75,0317	72,7016	62,1921	66,8157
BII - DaMh7	40,9569	40,6239	46,3430	49,6209	56,6183	50,4005	38,3765	46,1343
BII - DaPd3	89,6725	83,6067	91,7850	87,1679	93,1073	95,3088	93,3430	90,5702
BII - DaPd5	88,9925	86,6300	96,8992	96,6685	90,8425	90,5236	95,0002	92,2224
BII - DaPd7	48,6973	50,4003	47,9257	69,9976	68,9535	64,1362	41,8939	56,0006
BII - DaPh3	76,2963	76,1429	81,0841	81,4874	81,7053	79,3827	72,9052	78,4291
BII - DaPh5	73,2103	73,2841	75,8705	73,9913	79,9275	76,0722	68,6449	74,4287
BII - DaPh7	47,4434	42,4497	50,3663	57,0819	48,7989	55,0963	37,8076	48,4349
BII - DdMd3	73,8826	74,5851	77,4568	77,5837	80,2018	81,4355	74,6630	77,1155
BII - DdMd5	61,4505	61,2830	62,1496	64,6438	72,9036	70,7312	62,1230	65,0407
BII - DdMd7	41,8695	43,4413	43,6968	51,4836	51,8203	49,9555	39,2727	45,9342
BII - DdMh3	65,5952	68,8655	70,0542	69,4886	72,1298	73,7014	66,7364	69,5102
BII - DdMh5	63,1174	57,6688	65,2480	66,2961	70,8164	61,5227	59,2607	63,4186
BII - DdMh7	42,3258	40,0774	43,9036	46,9203	51,6115	46,1743	36,8262	43,9770
BII - DdPd3	84,2724	88,5708	89,5758	90,3179	92,0935	90,9497	93,8801	89,9515
BII - DdPd5	88,2343	87,2249	98,0563	91,6153	91,7318	93,2882	91,0755	91,6038
BII - DdPd7	51,8955	48,6073	50,9025	66,2755	62,0934	59,4895	43,8999	54,7377
BII - DdPh3	71,5442	69,9499	70,8993	73,2011	76,4575	75,8476	67,4149	72,1878
BII - DdPh5	61,8207	63,2116	59,9751	64,0877	66,0787	63,3289	58,7985	62,4716
BII - DdPh7	41,3391	39,3312	43,6474	47,9241	48,1940	48,8050	38,6894	43,9900
BII - SaMd3	77,3983	80,3210	88,0418	87,0832	92,8187	82,5836	73,9842	83,1758
BII - SaMd5	63,1574	62,2605	69,6445	80,1649	73,9379	68,5625	60,0446	68,2532
BII - SaMd7	43,1937	42,3611	44,9146	56,8515	67,5299	61,6109	36,7471	50,4584
BII - SaMh3	67,6434	68,6179	69,8520	82,7448	88,5780	82,8671	66,7744	75,2968
BII - SaMh5	61,2388	59,8844	64,1119	69,3104	73,0933	71,1416	59,7375	65,5026
BII - SaMh7	40,3673	40,1737	42,4814	67,5589	56,3204	55,0151	35,5510	48,2097
BII - SaPd3	98,7107	98,9200	112,6978	101,0456	105,3391	110,0342	109,5520	105,1856
BII - SaPd5	94,3209	88,0235	103,8222	104,6814	97,4212	105,7790	93,0753	98,1605
BII - SaPd7	42,8296	35,9724	45,3823	84,2204	63,1232	67,0909	37,4137	53,7189
BII - SaPh3	71,4398	67,0338	89,2745	76,9094	91,3867	86,2250	70,8492	79,0169
BII - SaPh5	62,0563	59,4276	62,5031	74,1812	77,6057	78,5695	59,2822	67,6608
BII - SaPh7	40,8447	36,2436	38,7722	51,1891	59,7233	63,6966	37,1696	46,8056
BII - SdMd3	76,3160	76,1548	81,0760	85,7776	81,1978	83,7226	75,0884	79,9047
BII - SdMd5	62,3490	60,9665	66,5370	88,0273	80,3401	72,3856	60,3785	70,1406
BII - SdMd7	42,1617	37,6655	42,0678	57,6358	65,9598	59,7274	36,2332	48,7787
BII - SdMh3	68,0336	68,7435	75,9652	87,6458	90,9592	93,4320	69,6373	79,2024
BII - SdMh5	62,5126	60,1843	59,9614	78,1655	72,3608	76,9451	59,9941	67,1605
BII - SdMh7	38,2041	40,8469	46,0468	61,1734	57,3977	54,9417	38,6091	48,1742
BII - SdPd3	101,3249	103,8664	107,2692	97,3895	107,1403	108,4090	110,7191	105,1598
BII - SdPd5	84,3110	99,2299	105,7900	106,3212	110,1597	102,0364	97,1976	100,7208
BII - SdPd7	49,9629	37,1410	56,5963	95,6852	55,9241	63,7065	38,1960	56,7446
BII - SdPh3	76,4849	74,1215	82,9242	87,3636	83,9574	83,8340	72,2996	80,1407
BII - SdPh5	60,2662	59,5419	63,7252	79,4154	79,2153	78,8561	58,5293	68,5071
BII - SdPh7	43,2654	37,6903	42,3834	58,0695	63,6899	50,8663	38,0212	47,7123
Média	63,8856	62,7040	68,1369	74,9352	75,4549	73,8593	62,2974	68,7533

Tabela A.9 - MAE para a potência reativa da Barra-II (MVar).

Código	BFGS	DFP	FR	GRAD	OSS	PR	SCGM	Média
BII - DaMd3	4,4567	4,6607	3,8489	3,8816	3,9190	3,9118	3,7745	4,0647
BII - DaMd5	4,1474	3,8798	3,5525	3,7599	3,7527	3,6901	3,4385	3,7458
BII - DaMd7	2,9639	2,6591	2,7538	3,0900	2,9811	2,8538	2,5150	2,8310
BII - DaMh3	3,3927	3,2775	2,9860	3,1600	3,1600	3,0618	3,2097	3,1782
BII - DaMh5	3,2905	3,4966	3,1249	3,2805	3,5475	3,3525	3,0507	3,3062
BII - DaMh7	2,4128	2,2960	2,4319	2,5889	2,8208	2,6361	2,2499	2,4909
BII - DaPd3	5,0524	4,7480	4,1549	4,2300	4,2077	4,1620	4,1785	4,3905
BII - DaPd5	4,7039	4,7534	4,2144	4,4171	4,4215	4,2739	4,2026	4,4267
BII - DaPd7	2,8501	3,0257	2,7524	3,5296	3,4117	3,2264	2,5442	3,0486
BII - DaPh3	4,0585	3,9771	3,6800	3,8658	3,9258	3,6661	3,5860	3,8228
BII - DaPh5	4,9244	3,9034	3,5046	3,5079	3,6790	3,5320	3,3444	3,7708
BII - DaPh7	2,8484	2,3919	2,5818	2,8520	2,6713	2,7423	2,2197	2,6153
BII - DdMd3	4,3573	4,5308	3,6351	3,7018	3,7203	3,6754	3,7072	3,9040
BII - DdMd5	3,4598	3,3995	3,1050	3,3732	3,4046	3,2811	3,3007	3,3320
BII - DdMd7	2,3786	2,6187	2,4051	2,7402	2,6789	2,6283	2,1295	2,5113
BII - DdMh3	3,7607	3,9496	3,3380	3,5069	3,3301	3,3408	3,3541	3,5115
BII - DdMh5	3,3224	3,3968	3,0500	3,2177	3,3836	3,1246	2,9230	3,2026
BII - DdMh7	2,2265	2,3429	2,3820	2,6151	2,6409	2,4651	2,0888	2,3945
BII - DdPd3	5,2877	4,7957	4,1266	4,1890	4,2494	4,1928	4,0792	4,4172
BII - DdPd5	4,8080	4,7585	4,2832	4,2494	4,1998	4,2439	4,0900	4,3761
BII - DdPd7	2,8926	2,9318	2,8571	3,3109	3,1885	3,1439	2,6603	2,9979
BII - DdPh3	4,1268	4,0105	3,3186	3,5005	3,4815	3,6626	3,3487	3,6356
BII - DdPh5	3,5596	3,4172	2,9839	3,1498	3,3564	3,1442	2,9832	3,2278
BII - DdPh7	2,4197	2,1927	2,3182	2,6332	2,5288	2,4926	2,1322	2,3882
BII - SaMd3	4,0943	4,6211	4,0572	4,5906	4,2232	4,4070	4,0748	4,2955
BII - SaMd5	3,2854	3,3456	3,5283	4,0190	3,9029	3,6655	3,3981	3,5921
BII - SaMd7	2,3479	2,3477	2,3590	3,0606	3,2385	3,2069	2,0515	2,6589
BII - SaMh3	3,6572	3,5410	3,6243	4,6141	4,2204	4,1272	3,7771	3,9373
BII - SaMh5	3,3020	3,2606	3,3526	3,9619	3,9654	3,6801	3,3393	3,5517
BII - SaMh7	2,2716	2,1896	2,4191	3,5546	2,9003	2,9279	2,0011	2,6092
BII - SaPd3	5,3426	5,7689	5,2320	5,5162	5,3539	5,5169	5,0469	5,3968
BII - SaPd5	4,9126	4,8776	4,7488	5,4060	5,1714	5,2722	4,7109	5,0142
BII - SaPd7	2,1807	1,9833	2,4585	4,1275	3,1441	3,2970	2,0074	2,7426
BII - SaPh3	3,7715	4,4757	4,0391	4,4927	4,2760	4,1560	3,7516	4,1375
BII - SaPh5	3,4704	3,4721	3,3183	4,0146	3,8381	3,7617	3,3516	3,6038
BII - SaPh7	2,2220	2,0964	2,2232	3,0188	2,8499	3,3623	2,1190	2,5559
BII - SdMd3	4,5652	4,5242	4,0284	4,6176	4,6348	4,5160	4,0613	4,4211
BII - SdMd5	3,3087	3,5825	3,3505	4,3259	4,0080	3,9077	3,5468	3,7186
BII - SdMd7	2,2539	1,9995	2,4404	3,1250	3,5597	3,1676	2,1072	2,6648
BII - SdMh3	3,6880	3,8986	3,6632	4,4117	4,6103	4,5356	3,5208	4,0469
BII - SdMh5	3,2356	3,1459	3,2549	4,0503	3,8221	3,8376	3,1570	3,5005
BII - SdMh7	2,1469	2,1861	2,5013	3,4261	2,8297	2,9226	2,1506	2,5948
BII - SdPd3	5,2860	5,5301	5,3495	5,6686	5,7080	5,6589	5,1965	5,4854
BII - SdPd5	4,8583	4,9620	4,8061	5,3563	5,4486	4,9490	4,6108	4,9987
BII - SdPd7	2,6331	2,1587	2,7650	4,5099	3,1179	3,0343	2,1963	2,9165
BII - SdPh3	4,4348	4,2379	3,8070	4,5673	4,2479	4,1606	3,5306	4,1409
BII - SdPh5	3,3667	3,5177	3,2059	3,9042	4,1141	3,7675	3,2600	3,5909
BII - SdPh7	2,4144	2,2237	2,2723	3,2485	3,0262	2,7132	2,0190	2,5596
Média	3,5573	3,5283	3,3374	3,8321	3,7265	3,6470	3,2104	3,5484

Tabela A.10 - MAPE para a potência ativa da Barra-III (%).

Código	BFGS	DFP	FR	GRAD	OSS	PR	SCGM	Média
BIII - DaMd3	3,8725	4,1343	4,0680	4,0994	4,3209	4,2976	3,3347	4,0182
BIII - DaMd5	4,0746	3,7193	3,6365	4,0226	3,8038	3,9150	3,3122	3,7834
BIII - DaMd7	3,5192	3,4429	3,8352	3,8996	4,1310	3,9523	3,3500	3,7329
BIII - DaMh3	4,7670	4,8059	4,7735	4,6761	4,8914	4,7793	4,2559	4,7070
BIII - DaMh5	5,1178	4,5277	5,0902	5,1008	4,9927	5,0602	4,3715	4,8944
BIII - DaMh7	5,4702	5,0949	5,0918	5,2513	5,4569	5,4211	4,9146	5,2430
BIII - DaPd3	5,8152	5,5875	5,6363	5,5768	5,6843	5,6391	5,3698	5,6156
BIII - DaPd5	6,2356	6,1497	6,3006	6,3342	6,3637	6,1235	6,0805	6,2268
BIII - DaPd7	5,1683	5,4280	5,7764	6,0530	5,6958	6,0975	4,8114	5,5758
BIII - DaPh3	5,7823	5,8814	5,7997	5,9657	5,8338	5,7505	5,0210	5,7192
BIII - DaPh5	4,3023	3,9009	3,9092	4,2742	4,3155	4,5329	3,4834	4,1026
BIII - DaPh7	3,9456	3,5959	3,7952	3,5189	4,2235	3,7185	3,1005	3,6997
BIII - DdMd3	3,8923	3,8958	4,3739	4,2719	4,0783	4,2145	3,2547	3,9973
BIII - DdMd5	3,7269	3,5316	3,7560	3,7086	3,9228	3,7196	3,0657	3,6330
BIII - DdMd7	3,4982	3,3788	3,5102	3,4582	3,4941	3,7386	3,1357	3,4591
BIII - DdMh3	4,5987	4,5535	4,5570	4,8216	4,7294	4,8018	4,1689	4,6044
BIII - DdMh5	4,3990	4,0852	4,0058	4,2975	4,4099	4,4179	3,5856	4,1716
BIII - DdMh7	4,2080	4,4379	4,4949	4,4641	4,4070	4,8957	3,7582	4,3808
BIII - DdPd3	5,3045	5,3305	5,2999	5,1718	5,4324	5,3633	5,1139	5,2880
BIII - DdPd5	5,9813	5,3786	5,8660	5,9918	5,9163	6,0918	5,4148	5,8058
BIII - DdPd7	4,7923	5,3873	4,9151	5,5214	5,7032	5,0937	4,1643	5,0825
BIII - DdPh3	4,9351	4,8388	4,7936	4,6970	4,8004	4,8623	4,6233	4,7929
BIII - DdPh5	4,6390	4,9812	4,9255	4,8771	4,9231	5,0441	4,1467	4,7910
BIII - DdPh7	3,7336	3,7952	4,7912	4,5658	4,7062	4,5259	3,2975	4,2022
BIII - SaMd3	5,5059	4,9887	6,1142	5,5949	7,8187	6,6042	4,4669	5,8705
BIII - SaMd5	4,9997	4,6355	5,0242	5,7172	6,6700	6,4703	3,7540	5,3244
BIII - SaMd7	4,7252	3,7557	4,9390	4,4853	5,7103	5,7030	2,8114	4,5900
BIII - SaMh3	7,4596	5,8104	6,8023	6,4152	7,3206	6,5105	4,8081	6,4467
BIII - SaMh5	5,1258	5,8468	5,0632	5,9612	6,1907	6,7596	3,3010	5,4640
BIII - SaMh7	5,7439	4,6206	5,1355	4,9541	6,6492	6,2944	2,6963	5,1563
BIII - SaPd3	8,7903	8,0192	7,7822	7,4939	8,6143	8,6313	7,4727	8,1148
BIII - SaPd5	8,1688	7,3798	7,5720	7,1177	8,2228	8,0020	6,1993	7,5232
BIII - SaPd7	5,8119	5,5514	6,0743	5,9777	6,2478	6,9093	3,5114	5,7263
BIII - SaPh3	7,3852	7,6224	7,7813	7,6878	8,1525	7,9142	6,9282	7,6388
BIII - SaPh5	6,7392	6,7891	7,6632	6,9967	7,7655	8,1115	5,6376	7,1004
BIII - SaPh7	4,9264	5,3080	4,8949	5,3163	7,2699	6,5575	2,8974	5,3101
BIII - SdMd3	5,5520	5,4500	5,7948	5,6809	6,5055	6,2389	4,7100	5,7046
BIII - SdMd5	5,9551	5,0819	5,5733	5,7833	5,7834	6,2219	3,6511	5,4357
BIII - SdMd7	4,1877	4,2798	5,0712	4,6658	5,4301	5,6612	2,4847	4,5401
BIII - SdMh3	6,6785	6,4734	7,0488	6,6740	6,9055	6,8440	5,6970	6,6173
BIII - SdMh5	4,6816	6,1154	4,6849	5,6141	6,5874	6,3575	3,5136	5,3649
BIII - SdMh7	4,1450	4,9112	5,4493	5,4829	5,9271	6,2542	2,9528	5,0175
BIII - SdPd3	8,4808	7,1581	8,2585	7,4412	8,1433	8,7642	6,6360	7,8403
BIII - SdPd5	7,8474	7,8389	7,7409	7,3047	8,0831	8,0162	5,9894	7,5458
BIII - SdPd7	5,5225	4,7444	6,3768	5,7980	6,4632	6,9947	3,1063	5,5723
BIII - SdPh3	7,7532	7,6391	7,9122	8,0969	8,0862	8,2316	7,0310	7,8215
BIII - SdPh5	7,0626	7,0504	7,7417	7,0403	7,6386	7,5539	5,8935	7,1401
BIII - SdPh7	5,5353	3,9685	5,5034	5,8210	6,6820	6,5048	2,8512	6,8063
Média	5,4284	5,2271	5,5209	5,4946	5,9397	5,9202	4,3362	5,4096

Tabela A.11 - MAE para a potência ativa da Barra-III (MW).

Código	BFGS	DFP	FR	GRAD	OSS	PR	SCGM	Média
BIII - DaMd3	12,2203	13,0585	12,8705	12,7746	13,6377	13,5072	10,6118	12,6687
BIII - DaMd5	12,6854	11,7862	11,5614	12,8255	12,0688	12,4886	10,4793	11,9850
BIII - DaMd7	11,2166	11,0477	12,0737	12,3753	13,1897	12,6468	10,9518	11,9288
BIII - DaMh3	14,9817	15,0447	15,0806	14,7430	15,3994	15,2170	13,5092	14,8537
BIII - DaMh5	16,2151	14,3863	16,1018	16,1284	15,9209	16,1353	14,0016	15,5556
BIII - DaMh7	17,3943	16,3775	16,1702	16,7081	17,4057	17,2964	15,7959	16,7354
BIII - DaPd3	18,0609	17,4589	17,5214	17,3669	17,7257	17,5700	17,0707	17,5392
BIII - DaPd5	19,5273	19,2736	19,7838	19,9465	19,9891	19,2733	19,5974	19,6273
BIII - DaPd7	16,4724	17,1652	18,1929	19,1037	18,1455	19,3421	15,5546	17,7109
BIII - DaPh3	18,3722	18,5703	18,1629	18,6954	18,1791	18,0147	16,1797	18,0249
BIII - DaPh5	13,5912	12,3110	12,4430	13,5323	13,6284	14,5533	11,2475	13,0438
BIII - DaPh7	12,4813	11,3781	11,9871	11,0936	13,4535	11,8538	9,8345	11,7260
BIII - DdMd3	12,2165	12,2954	13,7241	13,2343	12,8797	13,1895	10,2094	12,5356
BIII - DdMd5	11,8507	11,2777	11,8192	11,7108	12,5787	11,9335	9,7778	11,5641
BIII - DdMd7	11,1304	10,6802	11,1321	10,8852	11,1209	11,8263	9,8643	10,9485
BIII - DdMh3	14,5795	14,4430	14,3445	15,0876	14,8935	15,2323	13,3216	14,5574
BIII - DdMh5	13,9370	12,8665	12,6784	13,6863	14,0314	14,1175	11,5008	13,2597
BIII - DdMh7	13,4475	14,1271	14,1148	14,2626	14,0638	15,5384	12,1454	13,9571
BIII - DdPd3	16,5680	16,7072	16,4605	16,3296	17,0350	16,8290	16,1652	16,5849
BIII - DdPd5	18,8844	17,0943	18,3116	18,7344	18,6423	19,0369	17,5178	18,3174
BIII - DdPd7	15,1771	17,0835	15,6059	17,5726	18,0726	16,3390	13,5450	16,1994
BIII - DdPh3	15,6391	15,1275	15,0071	14,6718	14,9275	15,1495	14,8007	15,0462
BIII - DdPh5	14,8641	15,5880	15,3818	15,1979	15,2805	16,0475	13,4442	15,1149
BIII - DdPh7	11,6369	11,8927	15,0496	14,4173	14,6927	14,2741	10,5947	13,2226
BIII - SaMd3	17,9849	16,4802	20,2629	18,5115	26,2341	21,8351	14,7149	19,4319
BIII - SaMd5	16,3798	15,1147	16,5607	19,0320	22,4324	21,7230	12,3239	17,6524
BIII - SaMd7	15,6794	12,5344	16,3251	14,8921	18,9064	19,0509	9,2302	15,2312
BIII - SaMh3	24,7310	19,0199	22,4543	20,7564	24,3102	21,3987	15,5130	21,1691
BIII - SaMh5	16,7289	19,0712	16,7358	19,5934	20,4494	22,6407	10,8490	18,0098
BIII - SaMh7	19,0350	15,0867	17,0315	16,2117	22,3389	20,9045	8,8343	17,0632
BIII - SaPd3	28,9204	26,1291	25,3753	24,0746	28,4971	28,4828	24,6076	26,5838
BIII - SaPd5	26,9077	24,0155	25,0743	23,0467	26,8337	26,2085	20,3125	24,6284
BIII - SaPd7	19,2994	18,2990	20,0956	19,5716	20,3054	22,6539	11,6505	18,8393
BIII - SaPh3	24,1020	25,0272	25,3444	24,7771	26,7646	25,7522	22,8114	24,9398
BIII - SaPh5	21,9658	21,7046	24,9860	22,6025	25,5240	26,6427	18,5396	23,1379
BIII - SaPh7	16,3194	17,4524	15,9231	17,3453	24,3829	21,9863	9,5329	17,5632
BIII - SdMd3	18,4754	17,8372	19,1641	18,4521	21,6114	20,6133	15,4932	18,8067
BIII - SdMd5	19,8424	16,6444	18,4047	19,1308	19,0589	20,8194	11,9782	17,9827
BIII - SdMd7	13,9652	14,3268	17,0556	15,3884	17,9586	19,1586	8,1639	15,1453
BIII - SdMh3	21,7552	21,1375	23,2559	21,6594	22,7247	22,2396	18,5603	21,6189
BIII - SdMh5	15,1700	20,4683	15,1995	18,3591	21,7263	20,8573	11,3321	17,5875
BIII - SdMh7	13,5977	16,0732	17,7847	18,0378	19,6736	21,0869	9,7171	16,5673
BIII - SdPd3	28,3256	23,5910	27,2407	24,2778	26,9287	29,0956	21,8506	25,9014
BIII - SdPd5	26,1630	25,6897	25,2435	23,7269	26,7006	26,5012	19,4313	24,7795
BIII - SdPd7	18,3676	15,7989	20,9082	19,3789	21,3323	23,4569	10,3387	18,5116
BIII - SdPh3	25,6523	25,1281	25,8768	26,3078	26,4396	26,9637	23,1252	25,6419
BIII - SdPh5	23,0292	22,7328	25,6003	22,5708	25,0284	24,9638	19,3559	23,3259
BIII - SdPh7	18,0064	12,8064	18,0705	19,0921	22,1703	21,7139	9,4995	22,1944
Média	17,5740	16,8585	17,8240	17,6642	19,2770	19,2534	14,0726	17,5034

Tabela A.12 - MAPE para a potência reativa da Barra-III (%).

Código	BFGS	DFP	FR	GRAD	OSS	PR	SCGM	Média
BIII - DaMd3	12,7155	12,7006	12,8190	12,6770	12,8330	13,1809	12,1921	12,7312
BIII - DaMd5	11,4457	11,5560	12,0510	12,0443	11,9385	12,2272	10,8592	11,7317
BIII - DaMd7	9,7327	9,8230	9,6505	11,1295	10,4781	11,0083	9,1513	10,1391
BIII - DaMh3	12,9206	13,1420	13,1300	13,0466	13,0870	12,8931	12,7116	12,9901
BIII - DaMh5	13,9904	14,0857	14,0511	14,0777	14,1393	14,3017	13,5547	14,0287
BIII - DaMh7	11,1135	10,6623	11,6585	12,2124	12,3129	11,8518	9,7758	11,3696
BIII - DaPd3	14,8077	15,0317	14,9167	14,7455	14,9080	14,7854	14,5745	14,8242
BIII - DaPd5	15,5226	15,2988	15,3151	15,4078	15,2461	15,4344	14,7930	15,2883
BIII - DaPd7	12,1817	12,1213	12,2774	13,8486	13,5096	12,2396	11,3546	12,5047
BIII - DaPh3	12,9284	12,6141	12,6640	12,7008	12,9532	12,9043	12,3860	12,7358
BIII - DaPh5	13,9449	14,1157	14,0571	14,1323	14,0021	14,4072	13,7397	14,0570
BIII - DaPh7	10,2954	10,2565	10,8321	12,0546	10,9976	11,5531	9,5642	10,7934
BIII - DdMd3	12,1960	11,9904	12,0503	12,0264	12,1338	12,2507	11,5756	12,0319
BIII - DdMd5	10,8328	10,4158	10,8284	11,2110	11,0436	11,0590	10,0075	10,7712
BIII - DdMd7	8,4404	8,5101	9,1054	10,4592	9,6958	10,0323	8,0603	9,1862
BIII - DdMh3	11,2504	11,1341	11,3480	11,7764	11,5996	11,7448	10,5298	11,3404
BIII - DdMh5	9,8476	10,3189	10,5370	11,1867	11,1504	11,0791	9,6348	10,5364
BIII - DdMh7	9,0723	8,1824	8,8101	10,5238	9,7591	9,9010	8,0309	9,1828
BIII - DdPd3	14,8996	14,9870	14,8883	14,8656	14,9279	14,7596	14,5903	14,8455
BIII - DdPd5	15,4501	15,4265	15,3413	15,5581	15,5449	15,5627	15,0629	15,4209
BIII - DdPd7	11,9287	11,3883	12,2049	14,2785	13,0801	13,1472	10,5784	12,3723
BIII - DdPh3	12,7370	12,8217	12,6543	12,5039	12,6373	12,6326	12,2372	12,6034
BIII - DdPh5	12,1700	12,1648	12,2044	12,4988	12,4822	12,8525	11,3345	12,2439
BIII - DdPh7	9,6010	10,0893	10,1993	10,9324	10,9488	10,7923	8,8645	10,2039
BIII - SaMd3	13,9335	13,6808	13,8748	14,3462	14,5136	14,6508	13,3396	14,0485
BIII - SaMd5	11,5742	11,2702	11,3722	12,5428	12,4358	12,5064	10,5824	11,7549
BIII - SaMd7	8,4936	7,2730	8,5275	9,4218	9,9157	9,1129	7,4133	8,5940
BIII - SaMh3	12,1122	11,8852	12,2510	13,8234	13,7412	13,5099	11,5907	12,7019
BIII - SaMh5	10,5745	10,9460	10,8390	12,5259	12,9275	11,7320	10,1881	11,3904
BIII - SaMh7	8,1001	7,3041	8,1924	10,5390	9,9077	9,6909	6,9876	8,6745
BIII - SaPd3	18,4982	18,8204	18,0240	17,8166	17,7797	17,7241	17,8554	18,0741
BIII - SaPd5	17,0915	17,0823	17,0872	17,5340	17,7366	17,9173	16,8874	17,3338
BIII - SaPd7	9,0742	8,6147	9,4364	12,9525	12,2827	10,6361	6,7608	9,9653
BIII - SaPh3	14,5462	14,7074	14,5758	15,2963	15,6046	15,3257	14,1758	14,8903
BIII - SaPh5	12,2883	11,7673	11,4211	13,6317	13,5090	13,6684	11,0546	12,4772
BIII - SaPh7	7,8797	6,9710	7,4120	11,9694	10,3082	9,8134	6,3807	8,6763
BIII - SdMd3	13,4605	13,8986	13,5271	14,9491	14,4897	14,5163	13,2529	14,0135
BIII - SdMd5	11,4074	11,0376	11,4372	13,2963	12,8956	12,1206	10,7655	11,8515
BIII - SdMd7	7,9869	7,4969	7,9937	11,2130	9,3037	9,5530	6,9597	8,6438
BIII - SdMh3	12,2664	12,1707	13,1191	14,5493	13,9803	14,0018	11,8500	13,1339
BIII - SdMh5	10,9152	10,8176	10,1571	13,5402	12,8373	12,5430	10,1625	11,5676
BIII - SdMh7	7,0663	7,4835	7,4644	11,5975	10,8277	9,2986	7,1336	8,6959
BIII - SdPd3	18,3432	18,4571	18,3843	17,6940	18,3500	18,0508	17,9579	18,1768
BIII - SdPd5	17,5826	17,3534	17,2647	17,9314	17,8768	17,6589	16,8246	17,4989
BIII - SdPd7	8,8630	8,4240	8,4388	14,4315	12,8321	11,3443	7,3288	10,2375
BIII - SdPh3	15,4069	15,3762	15,6184	16,2181	16,2217	16,2826	14,5582	15,6689
BIII - SdPh5	11,6191	11,6541	12,0737	13,9735	15,0566	13,3794	11,1736	12,7043
BIII - SdPh7	7,8446	7,3175	8,3227	11,6737	10,3454	10,3944	6,5196	8,9168
Média	12,0199	11,8885	12,0919	13,3201	13,0643	12,8757	11,3097	12,3671

Tabela A.13 - MAE para a potência reativa da Barra-III (MVar).

Código	BFGS	DFP	FR	GRAD	OSS	PR	SCGM	Média
BIII - DaMd3	8,1768	8,1195	8,1543	8,1697	8,2037	8,4476	7,7949	8,1524
BIII - DaMd5	7,4954	7,5840	7,8436	7,7904	7,8202	7,8810	7,1274	7,6489
BIII - DaMd7	6,5427	6,5179	6,4330	7,3325	6,9509	7,2051	6,1065	6,7269
BIII - DaMh3	8,2843	8,4266	8,3804	8,3763	8,3480	8,2886	8,1790	8,3262
BIII - DaMh5	8,9875	9,0043	9,0044	9,0533	9,0911	9,1601	8,7747	9,0108
BIII - DaMh7	7,5179	7,2533	7,8158	8,0983	8,1440	8,0339	6,7488	7,6589
BIII - DaPd3	9,5152	9,6483	9,5284	9,4690	9,5758	9,5203	9,3516	9,5155
BIII - DaPd5	9,9387	9,7853	9,7819	9,9078	9,8677	9,9082	9,5120	9,8145
BIII - DaPd7	8,1952	8,1158	8,2193	9,0496	8,8724	8,1999	7,7182	8,3386
BIII - DaPh3	8,3464	8,1820	8,1700	8,3516	8,3468	8,3650	8,0730	8,2621
BIII - DaPh5	9,2259	9,2842	9,2503	9,3497	9,3247	9,4745	9,0763	9,2837
BIII - DaPh7	7,0695	6,9979	7,4438	8,0766	7,4939	7,8730	6,6424	7,3710
BIII - DdMd3	7,9431	7,7778	7,8085	7,8763	7,8904	8,0135	7,5191	7,8327
BIII - DdMd5	7,1258	6,8584	7,0959	7,3791	7,3861	7,3502	6,6944	7,1271
BIII - DdMd7	5,6967	5,8458	5,9660	6,8813	6,4758	6,7084	5,3703	6,1349
BIII - DdMh3	7,3098	7,2078	7,3552	7,7346	7,4622	7,7138	6,9393	7,3890
BIII - DdMh5	6,5365	6,8425	6,9165	7,4108	7,3533	7,3145	6,4508	6,9750
BIII - DdMh7	6,1375	5,5807	5,9784	7,0207	6,5429	6,6515	5,4305	6,1917
BIII - DdPd3	9,4569	9,5670	9,4800	9,5623	9,5626	9,4630	9,3372	9,4899
BIII - DdPd5	9,9173	9,8687	9,8106	9,9645	9,9519	10,0221	9,6967	9,8903
BIII - DdPd7	8,0452	7,6513	8,2295	9,2408	8,6677	8,6708	7,1964	8,2431
BIII - DdPh3	8,1254	8,1360	8,1105	8,1360	8,0980	8,1367	7,8945	8,0910
BIII - DdPh5	8,0594	8,0611	8,0523	8,2679	8,2580	8,3561	7,5656	8,0886
BIII - DdPh7	6,6140	6,9009	6,9601	7,3388	7,4151	7,2896	6,1620	6,9544
BIII - SaMd3	9,1524	9,0074	9,1303	9,5348	9,4650	9,5436	8,9458	9,2542
BIII - SaMd5	7,8322	7,5488	7,6740	8,3593	8,1246	8,2311	7,2185	7,8555
BIII - SaMd7	5,7531	5,0250	5,8278	6,3454	6,6215	6,0803	5,0994	5,8218
BIII - SaMh3	8,1609	7,9894	8,3163	9,1913	8,9375	8,8510	7,9151	8,4802
BIII - SaMh5	7,2395	7,5050	7,3820	8,4997	8,4386	7,8922	7,0413	7,7140
BIII - SaMh7	5,5784	5,0612	5,6080	7,0879	6,4234	6,4586	4,9127	5,8757
BIII - SaPd3	11,6570	11,7604	11,4530	11,5152	11,3290	11,3574	11,1969	11,4670
BIII - SaPd5	10,9596	10,9494	11,0502	11,3950	11,3817	11,3928	10,8329	11,1374
BIII - SaPd7	6,2190	5,6044	6,4020	8,2701	7,6971	6,9733	4,6668	6,5475
BIII - SaPh3	9,6093	9,6781	9,6070	10,1724	10,1120	9,9680	9,4813	9,8040
BIII - SaPh5	8,3289	8,0307	7,8538	8,9915	8,9448	8,9442	7,5896	8,3834
BIII - SaPh7	5,3796	4,8116	5,0514	7,6873	6,7039	6,4798	4,4333	5,7924
BIII - SdMd3	9,0068	9,1567	8,9967	9,9658	9,2627	9,4614	8,7660	9,2309
BIII - SdMd5	7,6725	7,4359	7,6872	8,6748	8,3891	8,0219	7,3028	7,8835
BIII - SdMd7	5,4560	5,1604	5,4599	7,5111	6,2480	6,4547	4,7620	5,8646
BIII - SdMh3	8,2753	8,1737	8,7515	9,4396	9,0124	9,1345	8,0224	8,6871
BIII - SdMh5	7,5197	7,3642	6,9931	8,9370	8,2493	8,2474	6,9459	7,7509
BIII - SdMh7	4,8569	5,0928	5,1571	7,5163	7,1013	6,2671	4,9480	5,8485
BIII - SdPd3	11,6708	11,6981	11,6973	11,5513	11,6848	11,5678	11,4378	11,6154
BIII - SdPd5	11,2465	11,2063	11,1176	11,7203	11,4812	11,3657	10,9100	11,2925
BIII - SdPd7	6,1371	5,7797	5,7497	9,2670	8,2198	7,1712	5,0785	6,7719
BIII - SdPh3	10,0027	9,9571	10,0939	10,5589	10,4011	10,4808	9,6210	10,1594
BIII - SdPh5	7,9757	7,9088	8,2102	9,2546	9,7492	8,8390	7,6803	8,5168
BIII - SdPh7	5,3785	5,0754	5,6876	7,6354	6,6639	6,9772	4,5565	5,9964
Média	7,9444	7,8375	7,9739	8,7275	8,4947	8,4210	7,5151	8,1306