



MATEUS NEVES BARRETO

**UMA ABORDAGEM PARA A PREVISÃO DE CARGA CRÍTICA DO SISTEMA
ELÉTRICO BRASILEIRO**

***AN APPROACH FOR CRITICAL LOAD FORECASTING OF BRAZILIAN POWER
SYSTEM***

**CAMPINAS
2014**



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

MATEUS NEVES BARRETO

**UMA ABORDAGEM PARA A PREVISÃO DE CARGA CRÍTICA DO SISTEMA
ELÉTRICO BRASILEIRO**

Orientador: Prof. Dr. Takaaki Ohishi

Coorientador: Prof. Dr. Ricardo Menezes Salgado

AN APPROACH FOR CRITICAL LOAD FORECASTING OF BRAZILIAN POWER SYSTEM

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.

Master dissertation presented to the Electrical Engineering Postgraduation Program of the School of Engineering Electrical of the University of Campinas to obtain the M.Sc. grade in Engineering Electrical, in field of Computer Engineering.

ESTE EXEMPLAR CORRESPONDE À VERSÃO FINAL DA DISSERTAÇÃO
DEFENDIDA PELO ALUNO MATEUS NEVES BARRETO
E ORIENTADO PELO PROF. DR. TAKAAKI OHISHI

Assinatura do Orientador

**CAMPINAS
2014**

Ficha catalográfica
Universidade Estadual de Campinas
Biblioteca da Área de Engenharia e Arquitetura
Luciana Pietrosanto Milla - CRB 8/8129

B275a Barreto, Mateus Neves, 1989-
Uma abordagem para a previsão de carga crítica do sistema elétrico brasileiro / Mateus Neves Barreto. – Campinas, SP : [s.n.], 2014.

Orientador: Takaaki Ohishi.

Coorientador: Ricardo Menezes Salgado.

Dissertação (mestrado) – Universidade Estadual de Campinas, Faculdade de Engenharia Elétrica e de Computação.

1. Previsão de carga. 2. Redes neurais artificiais. 3. Metodos de suavização. 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: An approach for critical load forecasting of brasilian power system

Palavras-chave em inglês:

Load forecasting

Artificial neural networks

Smoothing methods

Área de concentração: Engenharia de Computação

Titulação: Mestre em Engenharia Elétrica

Banca examinadora:

Takaaki Ohishi [Orientador]

Gelson da Cruz Junior

Akebo Yamakami

Data de defesa: 07-03-2014

Programa de Pós-Graduação: Engenharia Elétrica

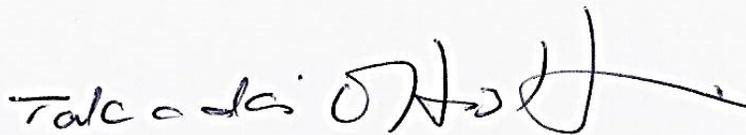
COMISSÃO JULGADORA - TESE DE MESTRADO

Candidato: Mateus Neves Barreto

Data da Defesa: 7 de março de 2014

Título da Tese: "Uma Abordagem para a Previsão de Carga Crítica do Sistema Elétrico Brasileiro."

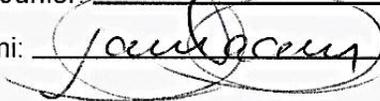
Prof. Dr. Takaaki Ohishi (Presidente):



Prof. Dr. Gelson da Cruz Junior:



Prof. Dr. Akebo Yamakami:



RESUMO

O Sistema Elétrico Brasileiro abastece cerca de 97% da demanda de energia nacional. Frente ao extenso território brasileiro, necessita-se de um sistema de transmissão de larga escala, devido as grandes distâncias entre as gerações, das hidroelétricas, e a principal concentração da demanda, no Sudeste brasileiro.

Para garantir segurança e economia da operação do Sistema Elétrico Brasileiro são realizadas análises da operação do sistema de geração e transmissão frente às condições de cargas críticas. A ideia é preparar o sistema para suportar as condições mais severas de carga.

A curva de carga crítica é calculada para cada mês com discretização horária (ou menor). A mesma é composta pela carga mínima observada num dado mês, no período da primeira à oitava hora, e pela carga máxima observada no mês para as horas restantes.

Utilizando históricos de demanda pertencentes aos agentes do Setor Elétrico Brasileiro, foi possível criar um histórico de cinco anos, 60 meses, de curvas de carga crítica. Esses dados foram disponibilizados pelo Operador Nacional do Sistema Elétrico Brasileiro – ONS, em conjunto com o desenvolvimento de um projeto de pesquisa, através de um sistema de suporte a decisão nomeado SysPrev.

Nesta dissertação são propostos três modelos para realizar a previsão da curva de carga crítica. Dois modelos utilizam Redes Neurais Artificiais e um modelo utiliza Suavização Exponencial de Holt-Winters (HW). Os resultados obtidos por todos os modelos foram satisfatórios e compatíveis com procedimentos em vigor. O modelo de Suavização Exponencial se destacou perante os outros dois modelos atingindo erros médios absolutos próximos a 3%. Esses resultados justificam-se devido às séries históricas de curvas de carga crítica possuírem características de tendência e sazonalidade e o modelo de HW ser projetado especificamente para séries temporais com estas características.

Palavras-chave: Curva de carga crítica. Previsão de carga. Redes Neurais Artificiais. Suavização exponencial.

ABSTRACT

The Brazilian Power System supplies around 97 % of national energy demand. By reason of the broad Brazilian territory, it requires a transmission system of large scale, due to the large distances between the generations of hydropower and the main concentration of demand that stay in southeastern of Brazil.

To ensure security and economy of operation of the Brazilian Electric System are performed analyzes the operation of generation and transmission system due to the conditions of critical loads. The idea is to prepare the system to resist the harshest load conditions.

The curve of critical load is calculated for each month with hourly discretization (or less). It's made with the minimum load observed in a given month between the first to eighth hour, and to maximum load observed in the month for the rest of hours.

Using the demand agents' history belonging to the Brazilian Power System, it was possible to create a record of five years, 60 months, of curves of critical load. These datas were available by the National Operator of the Brazilian Power System as part of the development of a research project, made available by a decision support system named SysPrev.

This dissertation proposed three models to perform the forecasting of the critical load curve. Two models using Artificial Neural Networks and one model using Exponential Smoothing Holt-Winters (HW). The results obtained by all the models were satisfactory and compatible with existing procedures. The exponential smoothing model stood out against the other two models, this having absolute average errors near 3%. These results are justified due to the historical series of curves of critical load has characteristics of trend and seasonality and the HW model is specifically designed for time series with such characteristics.

Keywords: *Critical Load Curve. Load Forecasting. Artificial Neural Networks. Exponential Smoothing.*

SUMÁRIO

1 INTRODUÇÃO	29
1.1 MOTIVAÇÃO	29
1.2 PROBLEMATIZAÇÃO	31
1.3 OBJETIVOS	33
1.4 SYSPREV	33
1.5 ORGANIZAÇÃO DA DISSERTAÇÃO	34
2 CURVA DE CARGA CRÍTICA E A SUA PREVISÃO MENSAL	35
2.1 CURVA DE CARGA CRÍTICA	35
2.1.1 Curva de carga média	36
2.1.2 Valores críticos	38
2.1.3 Cálculo da curva de carga crítica	40
2.2 EXEMPLOS CURVAS DE CARGA CRÍTICA	43
2.3 PREVISÃO MENSAL DA CURVA DE CARGA CRÍTICA	47
3 MODELOS DE PREVISÃO	49
3.1 MODELOS DE PREVISÃO	49
3.1.1 Previsão de Carga de Curto Prazo	50
3.2 TÉCNICAS DE PREVISÃO	57
3.2.1 Redes Neurais e Artificiais (RNA)	58
3.2.2 Suavização exponencial sazonal de holt-winters (HW)	62
4 SYSPREV – UM SISTEMA DE SUPORTE PARA ESTUDOS DE DEMANDA POR BARRAMENTO	69
4.1 SISTEMAS DE SUPORTE À DECISÃO (SSD)	70
4.2 O SISTEMA SYSPREV	70
5 METODOLOGIA	75
5.1 MODELOS DE PREVISÃO BASEADOS EM REDES NEURAIAS ARTIFICIAIS	75
5.1.1 Modelo I	76
5.1.2 Modelo II	79
5.2 SUAUVIZAÇÃO EXPONENCIAL SAZONAL DE HOLT-WINTERS	81

6 RESULTADOS E ANÁLISES.....	87
6.1 TRATAMENTO DOS DADOS HISTÓRICOS.....	89
6.1.1 Identificação de transferência de carga	90
6.1.2 Tratamento de transferência de carga	97
6.1.3 Identificação de <i>outliers</i>	100
6.1.4 Tratamento de <i>outliers</i>	101
6.2 PREVISÕES UM PASSO À FRENTE.....	102
6.2.1 Resultados modelo I.....	103
6.2.2 Resultados modelo II	108
6.2.3 Resultados modelo Holt-Winters	116
6.3 PREVISÕES DOIS A QUATRO PASSOS À FRENTE.....	118
6.3.1 Agente II.....	118
6.3.2 Agente I	129
6.3.3 Barramento I-Ag.I	138
6.4 COMENTÁRIOS SOBRE TODAS AS SÉRIES	147
6.5 COMENTÁRIOS SOBRE GASTOS COMPUTACIONAIS DAS PREVISÕES	148
7 CONCLUSÕES	151
7.1 TRABALHOS FUTUROS	152
REFERÊNCIAS.....	153

Dedico este trabalho as pessoas que fizeram e fazem parte da minha vida.

AGRADECIMENTOS

Agradeço as pessoas que me apoiaram no decorrer do mestrado e contribuíram diretamente na elaboração deste trabalho. Agradeço aos meus pais, Adilson e Elisabete, pelo apoio afetivo e financeiro, me apoiando em todas as decisões de vida. Aos meus irmãos, Mariana, Maira e Pedro pelos momentos de incentivo e confiança. Ao meu sobrinho Luigi, por me proporcionar momentos alegres e felizes. A minha namorada Talita, por toda compreensão e apoio durante os momentos difíceis e árduos, que passei pelo mestrado. Sou grato também, a toda a minha família, avós, tios e primos que me apoiam e me incentivam todas as vezes que nos encontramos.

Aos meus colegas e amigos do laboratório COSE (FEEC/UNICAMP), Miguel, Leonardo, Mônica, Cássio, Maiana, Elma, Makoto, André, Marcos, Anibal, Ana, Cynara, João, Thayze e Prof. Secundino, agradeço as contribuições e o convívio. Sou grato ao meu coorientador, Ricardo, pelo apoio durante todo o mestrado. Agradeço e me espelho em meu orientador, Takaaki, que, além de me apoiar, contribuiu integralmente na elaboração deste trabalho.

Também sou grato aos meus amigos e companheiros de grandes histórias, Fernando, Marcelo, Douglas, Rodrigo, Tadeu e Mateus. Que mesmo após o término da graduação, o convívio e a amizade continuaram.

Aos meus AMIGOS que fazem e fizeram parte da minha vida contribuindo na conclusão de mais um objetivo, o mestrado, deixo o meu muito Obrigado!

“Para que levar a vida tão a sério, se ela é uma alucinante aventura da qual jamais sairemos vivos”

(Bob Marley)

LISTA DE FIGURAS

Figura 1 - Curva de carga diária – Agente I e Barramento I-Ag.I.....	32
Figura 2 - Dados históricos de carga com a demanda diária horária – Barramento I-Ag.I Março/2012.....	37
Figura 3 - Curva de carga média – Barramento I-Ag.I Março/2012.....	37
Figura 4 - Valores críticos - Barramento I-Ag.I Março/2012.....	39
Figura 5 - Curva de carga crítica - Barramento I-Ag.I Março/2012.....	41
Figura 6 - Curva de carga média, valores críticos e carga crítica.....	43
Figura 7 - Série carga crítica global - 2007 – Agente II.....	44
Figura 8 - Série carga crítica global - 2007 a 2011 – Agente II.....	44
Figura 9 - Série carga crítica – 2007 – Barramento I-Ag.II.....	45
Figura 10 - Série carga crítica – 2007 – Barramento II-Ag.II.....	45
Figura 11 - Série carga crítica - 2007 a 2011 – Barramento I-Ag.II.....	46
Figura 12 - Série carga crítica - 2007 a 2011 – Barramento II-Ag.II.....	47
Figura 13 - Rede Neural Artificial.....	59
Figura 14 - Estratégia de Treinamento Rede Neural.....	61
Figura 15 - Tela principal - SysPrev.....	71
Figura 16 - Tela consulta curva diária - SysPrev.....	72
Figura 17 - Resultado consulta curva diária - SysPrev.....	72
Figura 18 - Consulta ah-hoc - SysPrev.....	73
Figura 19 - Tela previsão - SysPrev.....	74
Figura 20 - Série histórica 1ª, 2ª e 3ª intervalo de tempo - Barramento I-Ag.I.....	77
Figura 21 - Curva de carga crítica Jan. de 2007 a Mar. de 2012 - Global Agente I.....	79
Figura 22 - Curvas de carga crítica divididas entre intervalo superior - 2007-2008 Agente I.....	82
Figura 23 - Curvas de carga crítica divididas entre intervalo inferior - 2007-2008 Agente I.....	82
Figura 24 - Séries de médias de intervalos inferiores e superiores das curvas de carga crítica – 2007- 2008 Agente I.....	83
Figura 25 - Perfil série inferior curvas de carga crítica - 2007-2008 Agente I.....	83
Figura 26 - Perfil série superior curvas de carga crítica - 2007-2008 Agente I.....	84
Figura 27 - Série curvas de carga crítica Jan. de 2007 à Dez. de 2011 – Agente II.....	88

Figura 28 - Série curvas de carga crítica Jan. de 2007 à Dez. de 2011 – Agente I.....	88
Figura 29 - Série curvas de carga crítica Jan. de 2007 à Dez. de 2011 - Barramento I-Ag.I.....	89
Figura 30 - Curva de carga diária Barramento I-Ag.III.	91
Figura 31 - Curva de carga diária Barramento II-Ag.III.....	92
Figura 32 - Variação da demanda diária no Barramento I-Ag.III Jan. e Fev. de 2006.....	93
Figura 33 - Variação da demanda diária no Barramento II-Ag.III Jan. e Fev. de 2006.	94
Figura 34 - Variação da demanda diária do Barramento I-Ag.III e Barramento II-Ag.III Jan. e Fev. de 2006.....	94
Figura 35 - Variação da demanda diária do Barramento I-Ag.III e Barramento II-Ag.III 2ºsem de 2006.....	95
Figura 36 - Variação da demanda diária do Barramento III-Ag.III e Barramento IV-Ag.III em 2006.	95
Figura 37 - Perfil carga média semanal comum - Fev. de 2006 Barramento II-Ag.III.....	98
Figura 38 - Curva de carga diária do Barramento I-Ag.III com tratamento de transferência de carga.	99
Figura 39 - Curva de carga diária do Barramento II-Ag.III com tratamento de transferência de carga.	99
Figura 40 - Curva de carga diária com <i>outlier</i> - Barramento I-Ag.I.....	100
Figura 41 - Curva de carga média e curva de carga real com <i>outlier</i> – Barramento I-Ag.I.	101
Figura 42 - Curva de carga diária e limitantes para identificação de <i>outliers</i> - Barramento I-Ag.I.	101
Figura 43 - Tratamento de dado atípico (<i>outliers</i>).	102
Figura 44 - Resultado previsão modelo I - 2011 Agente II - 1 passo à frente.	104
Figura 45 - Resultado previsão modelo I comparado ao histórico total - 2011 Agente II - 1 passo à frente.	104
Figura 46 - Resultado previsão modelo I - 2011 Agente I - 1 passo à frente.	105
Figura 47 - Resultado previsão modelo I comparado ao histórico total - 2011 Agente I - 1 passo à frente.	106
Figura 48 - Resultado previsão modelo I - 2011 Barramento I-Ag.I - 1 passo à frente.....	107
Figura 49 - Resultado previsão modelo I comparado ao histórico total - 2011 Barramento I-Ag.I - 1 passo à frente.....	108

Figura 50 - Previsões máximas - modelo II - 2011 Agente II – 1 passo à frente.	109
Figura 51 - Previsões mínimas - modelo II - 2011 Agente II – 1 passo à frente.	110
Figura 52 - Resultado previsão modelo II - 2011 Agente II - 1 passo à frente.	111
Figura 53 - Previsões máximas - modelo II - 2011 Agente I – 1 passo à frente.	112
Figura 54 - Previsões mínimas - modelo II - 2011 Agente I – 1 passo à frente.	112
Figura 55 - Resultado previsão modelo II - 2011 Agente I - 1 passo à frente.	113
Figura 56 - Previsões máximas - modelo II - 2011 Barramento I-Ag.I – 1 passo à frente.	114
Figura 57 - Previsões mínimas - modelo II - 2011 Barramento I-Ag.I – 1 passo à frente.	115
Figura 58 - Resultado previsão modelo II - 2011 Barramento I-Ag.I - 1 passo à frente.	115
Figura 59 - Resultado previsão Holt-Winters - 2011 Agente II - 1 passo à frente.	116
Figura 60 - Resultado previsão Holt-Winters - 2011 Agente I - 1 passo à frente.	117
Figura 61 - Resultado previsão Holt-Winters - 2011 Barramento I-Ag.I - 1 passo à frente.	118
Figura 62 - Resultado previsão modelo I - 2011 Agente II - 1 passo à frente.	119
Figura 63 - Resultado previsão modelo I - 2011 Agente II - 2 passos à frente.	120
Figura 64 - Resultado previsão modelo I - 2011 Agente II - 3 passos à frente.	120
Figura 65 - Resultado previsão modelo I - 2011 Agente II - 4 passos à frente.	121
Figura 66 - Resultado previsão modelo II - 2011 Agente II - 1 passo à frente.	123
Figura 67 - Resultado previsão modelo II - 2011 Agente II - 2 passos à frente.	124
Figura 68 - Resultado previsão modelo II - 2011 Agente II - 3 passos à frente.	124
Figura 69 - Resultado previsão modelo II - 2011 Agente II - 4 passos à frente.	125
Figura 70 - Resultado previsão Holt-Winters - 2011 Agente II - 1 passo à frente.	126
Figura 71 - Resultado previsão Holt-Winters - 2011 Agente II - 2 passos à frente.	126
Figura 72 - Resultado previsão Holt-Winters - 2011 Agente II - 3 passos à frente.	127
Figura 73 - Resultado previsão Holt-Winters - 2011 Agente II - 4 passos à frente.	127
Figura 74 - Resultado previsão modelo I - 2011 Agente I - 1 passo à frente.	129
Figura 75 - Resultado previsão modelo I - 2011 Agente I - 2 passos à frente.	130
Figura 76 - Resultado previsão modelo I - 2011 Agente I - 3 passos à frente.	130
Figura 77 - Resultado previsão modelo I - 2011 Agente I - 4 passos à frente.	131
Figura 78 - Resultado previsão modelo II - 2011 Agente I - 1 passo à frente.	133
Figura 79 - Resultado previsão modelo II - 2011 Agente I - 2 passos à frente.	133
Figura 80 - Resultado previsão modelo II - 2011 Agente I - 3 passos à frente.	134

Figura 81 - Resultado previsão modelo II - 2011 Agente I - 4 passos à frente.....	134
Figura 82 - Resultado previsão Holt-Winters - 2011 Agente I - 1 passo à frente.....	135
Figura 83 - Resultado previsão Holt-Winters - 2011 Agente I - 2 passos à frente.	136
Figura 84 - Resultado previsão Holt-Winters - 2011 Agente I - 3 passos à frente.	136
Figura 85 - Resultado previsão Holt-Winters - 2011 Agente I - 4 passos à frente.	137
Figura 86 - Resultado previsão modelo I - 2011 Barramento I-Ag.I - 1 passo à frente.....	139
Figura 87 - Resultado previsão modelo I - 2011 Barramento I-Ag.I - 2 passos à frente.	139
Figura 88 - Resultado previsão modelo I - 2011 Barramento I-Ag.I - 3 passos à frente.	140
Figura 89 - Resultado previsão modelo I - 2011 Barramento I-Ag.I - 4 passos à frente.	140
Figura 90 - Resultado previsão modelo II - 2011 Barramento I-Ag.I - 1 passo à frente.	142
Figura 91 - Resultado previsão modelo II - 2011 Barramento I-Ag.I - 2 passos à frente.....	143
Figura 92 - Resultado previsão modelo II - 2011 Barramento I-Ag.I - 3 passos à frente.....	143
Figura 93 - Resultado previsão modelo II - 2011 Barramento I-Ag.I - 4 passos à frente.....	144
Figura 94 - Resultado previsão Holt-Winters - 2011 Barramento I-Ag.I - 1 passo à frente.....	145
Figura 95 - Resultado previsão Holt-Winters - 2011 Barramento I-Ag.I - 2 passos à frente.	145
Figura 96 - Resultado previsão Holt-Winters - 2011 Barramento I-Ag.I - 3 passos à frente.	146
Figura 97 - Resultado previsão Holt-Winters - 2011 Barramento I-Ag.I - 4 passos à frente.	146

LISTA DE QUADROS

Quadro 1 - Barramentos vinculados do Agente III..... 97

LISTA DE TABELAS

Tabela 1 - Curva média em MW e em p.u. – Barramento I-Ag.I Março/2012.	38
Tabela 2 - Valores críticos – Barramento I-Ag.I Março/2012.	40
Tabela 3 - Curva de carga crítica em MW – Barramento I-Ag.I Março/2012.	42
Tabela 4 - Erro médio absoluto métodos RNAs - Agente II - 1 passo à frente.	103
Tabela 5 - Erro médio absoluto métodos RNAs - Agente I - 1 passo à frente.	105
Tabela 6 - Erro médio absoluto métodos RNAs - 1 passo à frente.	106
Tabela 7 - Erro médio absoluto métodos RNAs - modelo II – Agente II - 1 passo à frente.	109
Tabela 8 - Erro médio absoluto métodos RNAs - modelo II – Agente I - 1 passo à frente.	112
Tabela 9 - Erro médio absoluto métodos RNAs - modelo II - Barramento I-Ag.I - 1 passo à frente.	114
Tabela 10 - Erro médio absoluto métodos RNAs - Agente II - 1 a 4 passos à frente.	119
Tabela 11 - Erro médio absoluto métodos RNAs - modelo II - Agente II – 1 a 4 passos à frente.	122
Tabela 12 - Erro médio absoluto - modelo II - Agente II – 1 a 4 passos à frente.	123
Tabela 13 - Erro médio absoluto - modelo Holt-Winters - Agente II – 1 a 4 passos à frente.	125
Tabela 14 - Resultados série Agente II.	128
Tabela 15- Erro médio absoluto métodos RNAs - Agente I - 1 a 4 passos à frente.	129
Tabela 16 - Erro médio absoluto métodos RNAs - modelo II - Agente I – 1 a 4 passos à frente.	132
Tabela 17 - Erro médio absoluto - modelo II - Agente I – 1 a 4 passos à frente.	132
Tabela 18 - Erro médio absoluto - modelo Holt-Winters - Agente I – 1 a 4 passos à frente.	135
Tabela 19 - Resultados série Agente I.	138
Tabela 20 - Erro médio absoluto métodos RNAs – Barramento I-Ag.I - 1 a 4 passos à frente. .	138
Tabela 21 - Erro médio absoluto métodos RNAs - modelo II – Barramento I-Ag.I – 1 a 4 passos à frente.	141
Tabela 22 - Erro médio absoluto - modelo II – Barramento I-Ag.I – 1 a 4 passos à frente.	142
Tabela 23 - Erro médio absoluto - modelo Holt-Winters – Barramento I-Ag.I – 1 a 4 passos à frente.	144
Tabela 24 - Resultados série Barramento I-Ag.I.	147

Tabela 25 - Tempos de execuções das previsões 148

LISTA DE ABREVIATURAS E SIGLAS

ABS	<i>Antiblockier-Bremssystem</i>
AR	Modelo Auto-Regressivo
ARMA	Modelo Auto-Regressivo de Médias Móveis
BFGS	Método <i>Broyden-Fletcher-Goldfarb-Shanno</i>
BPM	Método <i>Back Propagation</i> com termo <i>momentum</i>
CG	<i>Conjugate Gradient</i>
DFP	Método <i>Davidon-Fletcher-Powell</i>
FR	Método <i>Fletcher & Reeves</i>
GRAD	Método <i>Gradient</i>
HW	Holt-Winters
IA	Inteligência Artificial
MLP	<i>Multilayer Perceptron</i>
MVAR	<i>Megavolt Ampere Reactive</i>
MW	<i>Megawatts</i>
ONS	Operador Nacional do Sistema Elétrico Brasileiro
OSS	Método <i>One-Step Secant</i>
PR	Método <i>Polak-Ribière</i>
QN	<i>quasi-Newton</i>
RNAs	Redes Neurais Artificiais
SCG	Método <i>Scaled Conjugate Gradient</i>
SEB	Setor Elétrico Brasileiro
SSD	Sistemas de Suporte à Decisão

1

Introdução

Este capítulo apresenta inicialmente, na Seção 1.1, a motivação para a execução desta dissertação. Na Seção 1.2, é apresentado o problema principal que virá a ser tratado. Em seguida, na Seção 1.3, são expostos os objetivos a fim de auxiliar a elaboração da conclusão dos resultados atingidos. Na Seção 1.4 é apresentado uma breve descrição do sistema de suporte à decisão SysPrev. Finalmente, na Seção 1.5, tem-se a estrutura geral desta dissertação.

1.1 MOTIVAÇÃO

As sociedades atuais estão cada vez mais dependentes das diversas formas de energia que existem. Dentre esta diversidade, ressalta-se a importância da energia elétrica no desenvolvimento socioeconômico dos países e regiões. Em termos de suprimento energético, a eletricidade se tornou uma das formas mais versáteis e convenientes de energia.

Sabe-se que a energia elétrica, pela natureza da sua forma, é um insumo não estocável em grande quantidade, fazendo com que, desta maneira, a preservação, o planejamento e o uso racional desta assumam uma importância significativa para garantir a continuidade da sua utilização. A localização geográfica dos recursos energéticos existentes no Brasil está associada à grande extensão territorial e características próprias de algumas regiões, se tornam importantes desafios ao planejamento da oferta e gerenciamento da demanda. Vale destacar também as regiões com fortes restrições ambientais, pouco desenvolvidas e distantes dos grandes centros consumidores são as que abrangem grande parte dos recursos energéticos ainda não explorados do país.

Sabe-se que, no Brasil, a concentração populacional dista da região com maior potencial hidráulico, a região norte. Assim, o Setor Elétrico Brasileiro vem sofrendo diversas modificações e ajustes, estando em constante evolução, com a finalidade de evitar que tais desafios acabem se

tornando obstáculos, dificultando o desenvolvimento do país. Estas alterações são fruto tanto do avanço tecnológico quanto de mudanças legais e criação de normativas. A busca por uma maneira capaz de conferir um melhor gerenciamento e um uso otimizado da energia elétrica tem sido alvo de estudos.

Neste sentido, além de existir uma dependência substancial do papel da energia elétrica nas sociedades atuais, existe também uma tendência positiva ao consumo. Tendo como base essa premissa, é possível perceber que o consumo de energia elétrica pode ser um dos principais indicadores do desenvolvimento econômico e do nível da qualidade de vida das sociedades.

Diante deste cenário, a previsão de consumo de eletricidade se mostra importante e indispensável, tanto na programação da operação de curto prazo, quanto no que tange o aspecto do planejamento de longo prazo dos agentes do setor. Tratando-se deste último, de acordo com Caio e Bermann (CAIO & BERMAN, 1998), o setor elétrico é caracterizado por investimentos de grande porte e lenta maturação, sendo necessário realizar aprimoramentos nas metodologias de projeção da demanda, procurando sempre reduzir as discrepâncias entre o mercado previsto e o mercado observado. Deste modo, se viabiliza a redução dos custos e desperdícios na expansão e operação do sistema de energia elétrica.

No Setor Elétrico Brasileiro (SEB) os dados de carga normalmente encontram-se em base temporal, com diferentes discretizações: um minuto, quinze minutos, horário e outras discretizações. A partir desta base temporal gera-se a curva de carga diária. De acordo com a (AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA - ANEEL, 2008), o Sistema Elétrico Brasileiro deve ser analisado para condições de carga pesada, média e leve e, quando necessário, para outros patamares de carga, bem como para condições de despachos alternativos, considerando a diversidade energética. Para fins de estudos elétricos é comum considerar os patamares de carga: leve (período de menor demanda de energia elétrica, de 00h às 07h), média (período de transição entre a carga leve e a pesada, de 08h às 17h) e pesada (período de maior demanda de energia elétrica, de 18h às 24h). Estes patamares procuram representar as diferentes condições de operação de carga. Nesta ótica, uma abordagem utilizada no setor é a realização dos estudos de operação do sistema levando em consideração as condições de carga críticas. Estas análises são realizadas por meio de uma curva crítica calculada a partir dos dados históricos levando em consideração os patamares de carga definidos anteriormente.

1.2 PROBLEMATIZAÇÃO

Para descrever a estrutura dos dados históricos, dos agentes (empresa distribuidora de energia elétrica) do SEB faz-se necessário um entendimento básico da estrutura de distribuição do SEB. Em toda estrutura, os agentes possuem barramentos. Os barramentos de carga são responsáveis pelo fornecimento da demanda de energia para pequenas regiões, como bairros, distritos (industriais e/ou residencial) e regiões menores. Nestes barramentos são observados, com discretizações constantes, dados de potência ativa (em MW) e reativa (MVAR). Estes dados, de potência ativa, observados são os que geram os dados históricos utilizados neste trabalho. Vale destacar que cada barramento pode ter um tipo de comportamento, conhecido como perfil de consumo. Os perfis mais comuns são:

- **Industrial:** apresenta em geral dois tipos de perfis. O primeiro apresenta uma demanda com pouca variação ao longo do dia, a menos nos períodos de demanda de ponta, quando a tarifa de energia é muito alta. No segundo caso o consumo é muito variável, sem um padrão típico, e constituindo assim um perfil de consumo muito irregular;
- **Residencial:** Apresenta um perfil bastante regular, com baixo consumo na madrugada; uma demanda crescente no período da manhã, e a demanda de ponta ocorrendo no começo da noite;
- **Comercial:** Apresenta uma elevada demanda durante o período comercial.

Cada agente também possui uma série histórica chamada de carga global. A carga global do agente é a soma da carga de todos os barramentos pertencentes ao agente. Então, cada agente possui uma série de carga global ativa e outra de carga global reativa. Para este trabalho, todas as manipulações de dados, que serão realizadas, são de carga ativa (MW). A Figura 1 apresenta as curvas de carga diária (um período de 24h), do dia 20 de Setembro de 2010, da carga global de um agente e da carga de seu maior barramento, Note que a carga global do agente sempre será maior ou igual que a carga de qualquer barramento que o mesmo possui.

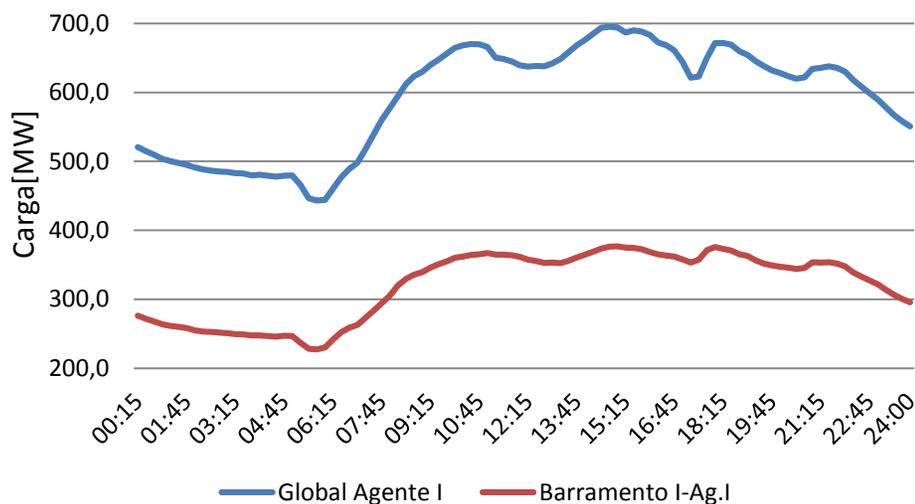


Figura 1 - Curva de carga diária – Agente I e Barramento I-Ag.I.

Os dados históricos de carga ativa utilizados nesta dissertação são dados de medições do SEB disponibilizadas pelo Operador Nacional do Sistema Elétrico Brasileiro (ONS). Os mesmos são divididos em dados pertencentes a três agentes: Agente I, Agente II e Agente III. Para cada agente existe a disponibilidade dos dados históricos de carga global ou dos dados históricos pertencentes aos barramentos das mesmas. Para o Agente I, presente na região Nordeste, as aquisições datam de Janeiro de 2007 à Março de 2012, assumindo um histórico de cinco anos e três meses, na discretização de 15 minutos. Para o Agente II, presente na região Sudeste, as aquisições datam de Janeiro de 2007 à Dezembro de 2011, compondo um histórico de cinco anos, na discretização de 15 minutos. Finalmente, para o Agente III trata-se na realidade de um barramento do AGENTE I. Assim, serão tratadas duas séries históricas de demandas globais e uma série histórica de demanda de um barramento. Os dados dos Agentes I e II utilizam a discretização de 15 minutos, sendo que a cada 15 minutos existe o registro de uma medição de carga (96 dados por dia). Já os dados pertencentes ao Agente III possuem discretização de 60 minutos, conseqüentemente totalizando a cada dia 24 aquisições.

Construir um previsor de curto prazo para dados de carga, do SEB, considerados críticos é uma tarefa complexa. Dado a existência de comportamentos distintos em casos de carga máxima e mínima no decorrer de curvas diárias de um mês. A previsão de um passo à frente resume-se em

prever apenas uma curva de um mês, na discretização horária utilizada, a partir das curvas de carga crítica históricas. Ou seja, supondo-se conhecidos os dados de carga até um dado mês, pretende-se estimar a carga do próximo mês. Na previsão dois passos à frente pretende-se estimar a carga com dois meses de antecedência. Seguindo a mesma regra para previsões com maiores horizontes de tempo.

1.3 OBJETIVOS

Esta dissertação objetiva o desenvolvimento de abordagens para previsão mensal da curva de carga crítica global e por barramento dos agentes do Setor Elétrico Brasileiro. O objetivo geral é focado no desenvolvimento de modelos para previsão da curva de carga crítica em base mensal. Esta pesquisa é aplicada e validada com base em históricos de cargas elétricas em termos de potência ativa (MW).

1.4 SYSPREV

Esta dissertação de mestrado foi desenvolvida como parte de um projeto de pesquisa desenvolvido em parceria com o ONS. O objetivo, deste convênio com o ONS, foi o aperfeiçoamento do sistema de suporte para estudos de demanda por barramento, denominado SysPrev. A primeira versão do SysPrev foi desenvolvida na tese de doutorado do Prof. Dr. Ricardo Menezes Salgado, co-orientador desta dissertação (SALGADO, 2009). O SysPrev é composto de uma base de dados, uma base de modelos e um sistema de interfaces. Todas as previsões apresentadas nesta dissertação foram obtidas através deste sistema. No Capítulo 4 será feita uma breve apresentação do SysPrev.

1.5 ORGANIZAÇÃO DA DISSERTAÇÃO

O próximo Capítulo 2 aborda sobre a descrição do que vem a ser a curva de carga crítica. O mesmo apresentará um exemplo completo do processo realizado para se calcular a curva de carga crítica de um mês a partir de dados históricos.

No Capítulo 3 é apresentada uma breve revisão e explicação sobre modelos de previsão de carga, Redes Neurais Artificiais e Modelos de Suavização Exponencial Sazonal de Holt-Winters. O problema tratado neste trabalho foi pouco explorado e ainda não possui referências bibliográficas. Por consequência de tal situação, deixam-se ausentes revisões sobre curva de carga crítica.

No Capítulo 4 é apresentado um sistema de suporte para estudos e previsões utilizado neste trabalho.

O Capítulo 5 apresenta a metodologia utilizada para a construção dos modelos de previsão. Neste capítulo são apresentados os modelos de previsão da curva de carga crítica, compostos em duas partes: Redes Neurais Artificiais e Métodos de Suavização de Holt-Winters.

Resultados e análises deste trabalho encontram-se no Capítulo 6, onde são apresentados os resultados de previsões de cada modelo proposto na metodologia e são apresentados gráficos para fins comparativos. Inicialmente o capítulo foca no tratamento dos dados históricos, a identificação e tratamento de dados atípicos e transferência de carga.

Finalmente, o Capítulo 7 apresenta as conclusões obtidas com base nas análises dos resultados deste trabalho.

2

Curva de Carga Crítica e a Sua Previsão Mensal

Este capítulo apresenta a descrição e exemplificação da curva de carga crítica e caracteriza o problema de sua previsão mensal. Para tal apresentação, é necessária uma breve abordagem sobre o conceito de carga crítica e o processo como a mesma pode ser calculada, Seção 2.1. Em seguida, Seção 2.2, apresentam-se exemplos de curvas de carga crítica. Finalmente é apresentado o problema da previsão mensal da curva de carga crítica, Seção 2.3.

2.1 CURVA DE CARGA CRÍTICA

A ideia de carga crítica está associada com as condições de demanda de carga menos favoráveis. Em termos operativos, estas condições menos favoráveis são aquelas que podem levar a uma operação do sistema a um nível crítico. Em geral, os dois casos mais comuns são de sobrecarga no sistema de transmissão e controle de tensão. As sobrecargas ocorrem comumente nos períodos de demanda de ponta e também de demanda média. Enquanto que o controle de tensão se faz necessário tanto na alta demanda, quando algumas tensões ficam muito baixas, e nos períodos de carga leve, quando podem ocorrer problemas de sobre-tensões. Os problemas de sobrecarga e sub-tensões ocorrem mais frequentemente nos casos de maiores demandas, e os problemas de sobre-tensões ocorrem em geral nos casos de menores cargas durante a carga leve. Por isso, nos períodos de carga leve, a carga crítica é dada pelas menores cargas observadas, e nos períodos de carga média e alta, a carga crítica é dada pelas maiores cargas.

A curva de carga crítica é calculada mensalmente e em cada mês são calculados valores críticos para cada intervalo horário (ou menor). Assim, a curva de carga crítica procura representar as condições de cargas mais severas, frente à demanda de operação do SEB.

No processo de planejamento da operação são realizados diversos tipos de estudos visando uma operação mais econômica e segura. Um destes estudos avalia a operação do sistema para os próximos meses, quando são consideradas as previsões das curvas de cargas críticas dos próximos meses. O objetivo aqui é preparar a operação do sistema para suportar estas condições severas.

Os subtópicos a seguir descrevem as etapas necessárias para a obtenção mensal da curva de carga crítica utilizada nas previsões desta dissertação. São necessárias as seguintes etapas: cálculo da curva média de carga mensal; obtenção dos valores críticos e obtenção da curva de carga crítica.

2.1.1 Curva de carga média

Para realizar o cálculo da curva de carga crítica, faz-se necessário primeiramente a obtenção da curva de carga média de cada mês. Para cada mês são considerados quatro tipos de dias em função de diferenças nos perfis de carga diária, que são os sábados, domingos e feriados, segundas-feiras, e dias úteis (terça-feira a sexta-feira). As seguintes etapas descrevem a obtenção da curva de carga média para um determinado tipo de dia. O exemplo a seguir considerou o cálculo da curva média para os dias úteis de um mês.

- i) **Dados históricos de carga:** selecionam-se os dados históricos de carga com a demanda diária horária para um dado mês. A Figura 2 mostra um exemplo para o mês de Março de 2012, onde são apresentadas todas as curvas diárias dos dias úteis, terça à sexta feira, do Barramento I-Ag.I pertencente ao Agente I;
- ii) **Obtenção da Curva de Carga Média:** calcula-se a média dos valores em MW para cada hora;
- iii) **Obtenção da Curva de Carga Média por unidade (p.u.):** calculam-se os valores em p.u., tendo como base o maior valor, da curva de carga média calculada no Item ii, ou seja, todos os horários são divididos pelo maior valor. A Figura 3 apresenta a curva de

carga média, em preto, acompanhada das curvas de carga diária do mês de Março de 2012. A Tabela 1 mostra a curva de carga média e também a curva de carga em p.u..

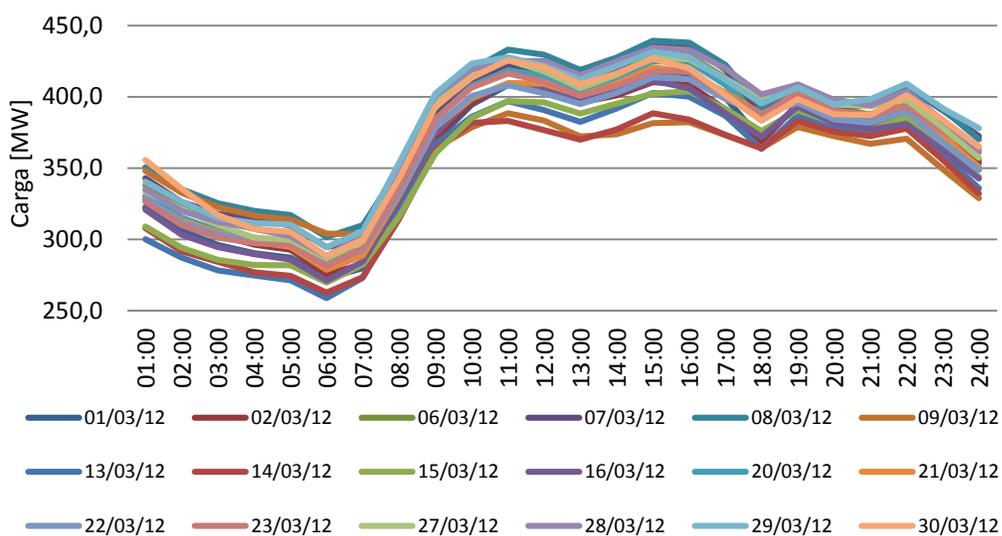


Figura 2 - Dados históricos de carga com a demanda diária horária – Barramento I-Ag.I Março/2012.

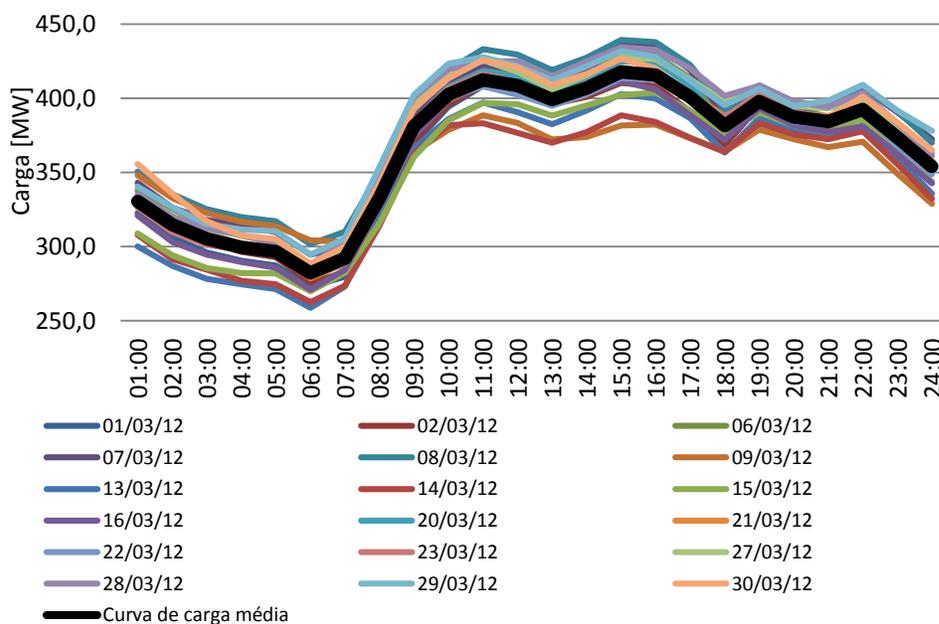


Figura 3 - Curva de carga média – Barramento I-Ag.I Março/2012.

Tabela 1 - Curva média em MW e em p.u. – Barramento I-Ag.I Março/2012.

Hora	Curva de carga média	Curva de carga média p.u.
01:00	330,5	0,79
02:00	314,8	0,75
03:00	305,2	0,73
04:00	299,6	0,72
05:00	296,7	0,71
06:00	282,2	0,68
07:00	292,1	0,70
08:00	332,9	0,80
09:00	381,1	0,91
10:00	402,6	0,96
11:00	412,5	0,99
12:00	408,6	0,98
13:00	399,2	0,96
14:00	406,8	0,97
15:00	417,8	1,00
16:00	415,7	0,99
17:00	400,9	0,96
18:00	381,5	0,91
19:00	397,7	0,95
20:00	387,3	0,93
21:00	384,4	0,92
22:00	392,5	0,94
23:00	373,7	0,89
24:00	354,1	0,85

2.1.2 Valores críticos

Na segunda etapa, para calcular a curva de carga crítica, faz-se necessário a obtenção dos valores de carga críticos a partir da demanda de carga diária horária selecionada na Seção anterior. Os itens seguintes descrevem o modo de obtenção dos valores críticos.

- i) **Dados históricos de carga:** selecionam-se os mesmos dados históricos de carga utilizados para a obtenção da curva média (Figura 2);
- ii) **Obtenção dos valores críticos superiores:** selecionam-se maiores valores de carga (MW) para cada intervalo de tempo no intervalo da 9^a à 24^a hora;

Tabela 2 - Valores críticos – Barramento I-Ag.I Março/2012.

Hora	Curva de carga média	Curva de carga média p.u.	Valores críticos	Valores críticos p.u.
01:00	330,5	0,791	300,2	0,683
02:00	314,8	0,753	287,2	0,654
03:00	305,2	0,730	278,4	0,634
04:00	299,6	0,717	274,7	0,625
05:00	296,7	0,710	271,5	0,618
06:00	282,2	0,675	258,8	0,589
07:00	292,1	0,699	273,1	0,622
08:00	332,9	0,797	314,4	0,716
09:00	381,1	0,912	402,3	0,916
10:00	402,6	0,963	423,3	0,964
11:00	412,5	0,987	433,2	0,986
12:00	408,6	0,978	429,4	0,977
13:00	399,2	0,955	418,9	0,954
14:00	406,8	0,974	427,4	0,973
15:00	417,8	1,000	439,3	1,000
16:00	415,7	0,995	437,9	0,997
17:00	400,9	0,959	422,4	0,961
18:00	381,5	0,913	401,6	0,914
19:00	397,7	0,952	408,6	0,930
20:00	387,3	0,927	397,9	0,906
21:00	384,4	0,920	398,3	0,907
22:00	392,5	0,939	409,2	0,931
23:00	373,7	0,894	391,8	0,892
24:00	354,1	0,847	378,0	0,860

2.1.3 Cálculo da curva de carga crítica

Na última etapa, para a obtenção da curva de carga crítica, faz-se necessário a ordenação dos valores críticos de acordo com a curva de carga média obtida na Seção anterior. A mesma pode ser obtida seguindo as seguintes etapas.

- i) **Ordenação dos valores críticos:** após o cálculo dos valores críticos em p.u., para um determinado mês de um determinado ano, é feita a ordenação dos valores críticos para cada condição de carga (leve, média e pesada);

ii) **Ordenação pela curva de carga média:** a curva de carga crítica deve seguir o mesmo perfil diário da curva de carga média. Por exemplo, se a maior demanda da condição de carga média de um determinado mês ocorre às 15:00 horas e a segunda maior carga às 16:00h, então na construção da curva crítica o maior valor crítico será alocado às 15:00h, mesmo que este máximo não tenha ocorrido neste horário, como no exemplo acima, quando a máxima crítica ocorreu às 16:00h. O segundo maior valor crítico será alocado às 16:00h, e assim por diante para todos os valores, como ilustrado na Tabela 3. A Figura 5 apresenta o resultado do cálculo da curva de carga crítica do mês de Março de 2012 do Barramento I-Ag.I.

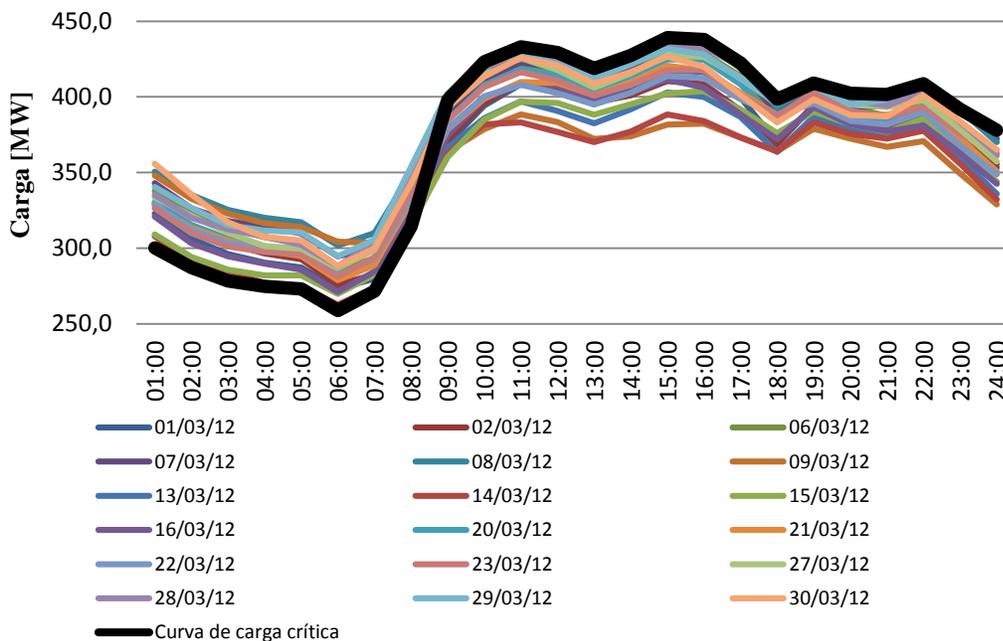


Figura 5 - Curva de carga crítica - Barramento I-Ag.I Março/2012.

Tabela 3 - Curva de carga crítica em MW – Barramento I-Ag.I Março/2012.

Hora	Curva de carga média	Curva de carga média p.u.	Valores críticos	Valores críticos p.u.	Curva de carga crítica
01:00	330,5	0,791	300,2	0,683	300,20
02:00	314,8	0,753	287,2	0,654	287,20
03:00	305,2	0,730	278,4	0,634	278,40
04:00	299,6	0,717	274,7	0,625	274,70
05:00	296,7	0,710	271,5	0,618	273,10
06:00	282,2	0,675	258,8	0,589	258,80
07:00	292,1	0,699	273,1	0,622	271,50
08:00	332,9	0,797	314,4	0,716	314,40
09:00	381,1	0,912	402,3	0,916	397,90
10:00	402,6	0,963	423,3	0,964	423,30
11:00	412,5	0,987	433,2	0,986	433,20
12:00	408,6	0,978	429,4	0,977	429,40
13:00	399,2	0,955	418,9	0,954	418,90
14:00	406,8	0,974	427,4	0,973	427,40
15:00	417,8	1,000	439,3	1,000	439,30
16:00	415,7	0,995	437,9	0,997	437,90
17:00	400,9	0,959	422,4	0,961	422,40
18:00	381,5	0,913	401,6	0,914	398,30
19:00	397,7	0,952	408,6	0,930	409,20
20:00	387,3	0,927	397,9	0,906	402,30
21:00	384,4	0,920	398,3	0,907	401,60
22:00	392,5	0,939	409,2	0,931	408,60
23:00	373,7	0,894	391,8	0,892	391,80
24:00	354,1	0,847	378,0	0,860	378,00

O gráfico presente na Figura 6 apresenta as curvas que são necessárias para a obtenção da curva de carga crítica a partir de um histórico de carga acompanhadas da própria curva de carga crítica.

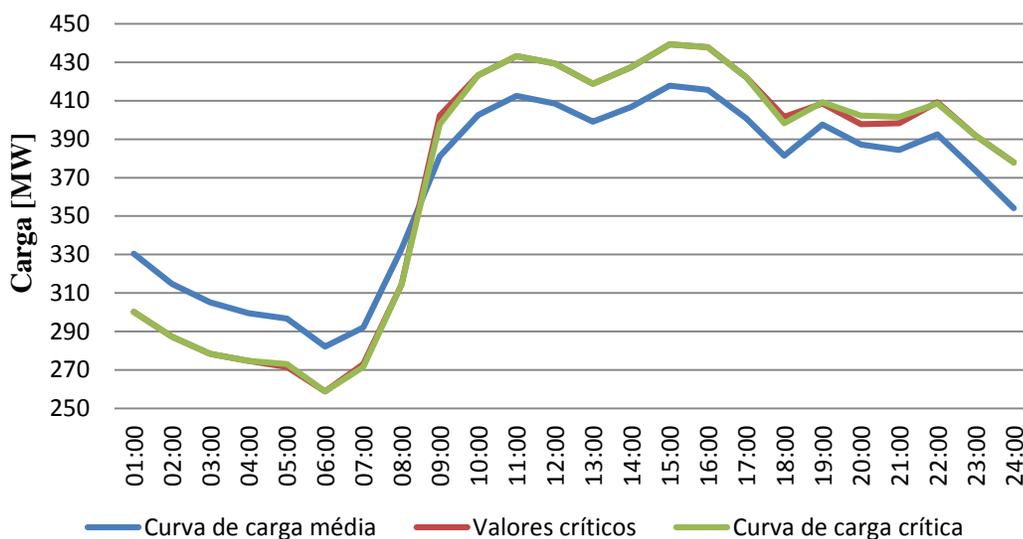


Figura 6 - Curva de carga média, valores críticos e carga crítica.

2.2 EXEMPLOS CURVAS DE CARGA CRÍTICA

Nesta Seção são apresentados alguns exemplos de séries de curvas de carga crítica no período de Janeiro de 2007 à Dezembro de 2010. A Figura 7 apresenta uma série de carga crítica global pertencente ao Agente II, referente ao ano de 2007. A Figura 8 apresenta o histórico do mesmo agente para cinco anos, 2007 a 2011. Observando as duas Figuras, nota-se a existência de uma sazonalidade com uma frequência anual, uma mudança de perfil nos meses do meio do ano, que se apresentam mais altas no horário de carga pesada e também uma leve tendência no horizonte dos anos.

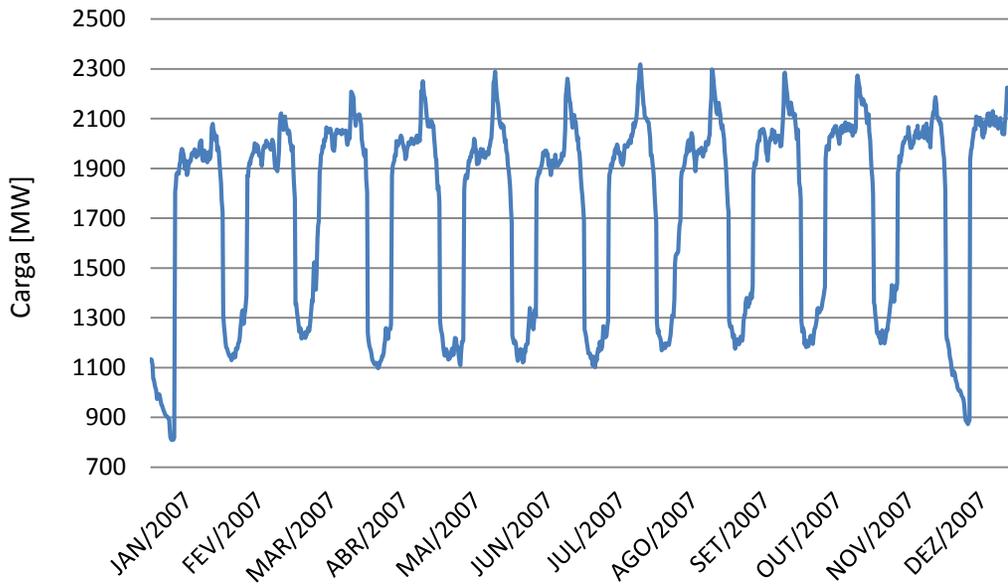


Figura 7 - Série carga crítica global - 2007 – Agente II.

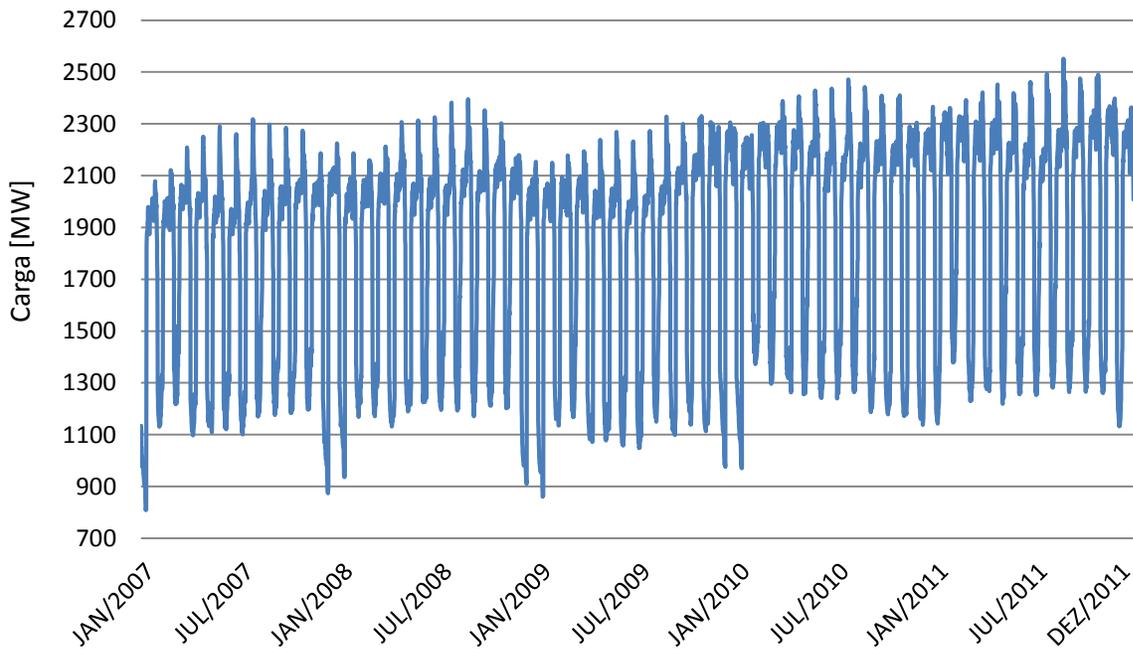


Figura 8 - Série carga crítica global - 2007 a 2011 – Agente II.

A Figura 9 e Figura 10 apresentam séries de carga crítica de dois barramentos pertencentes ao agente da Figura 8, referente ao ano de 2007. Observe que nestas séries a sazonalidade e novamente a mudança do perfil em meses do meio do ano.

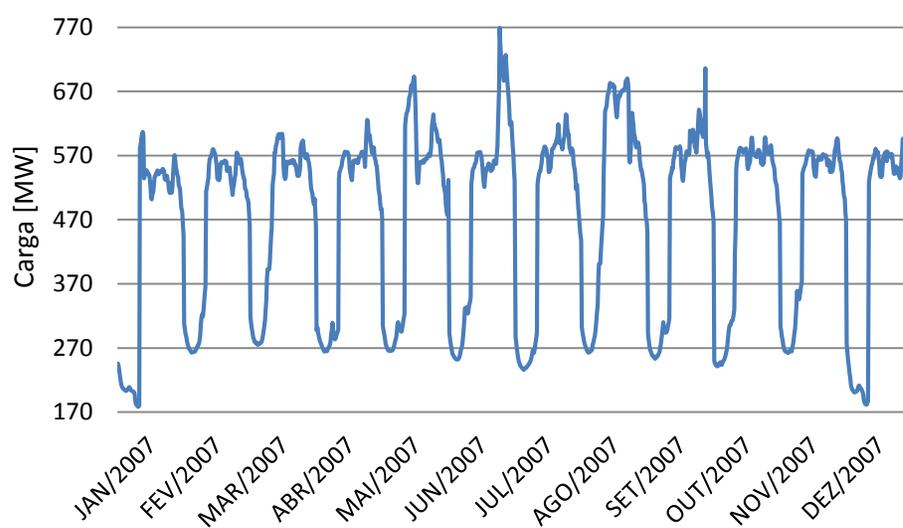


Figura 9 - Série carga crítica – 2007 – Barramento I-Ag.II.

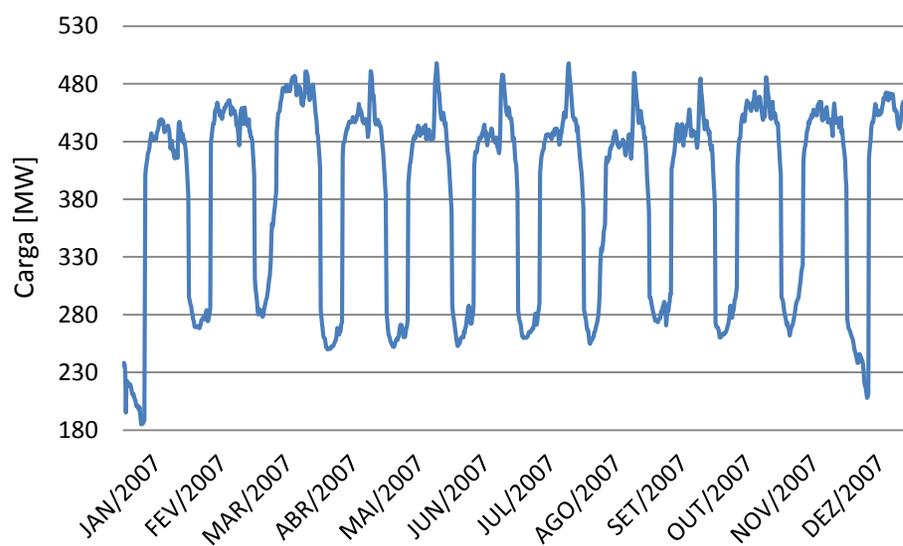


Figura 10 - Série carga crítica – 2007 – Barramento II-Ag.II.

Se as cargas globais dos agentes possuem sazonalidade e tendência, obviamente este fato é decorrente das cargas dos barramentos possuírem estas características. Então, observe a Figura 11 e Figura 12, que apresentam as séries das curvas de carga crítica do agente da Figura 8, possuindo uma similaridade no período de cinco anos.

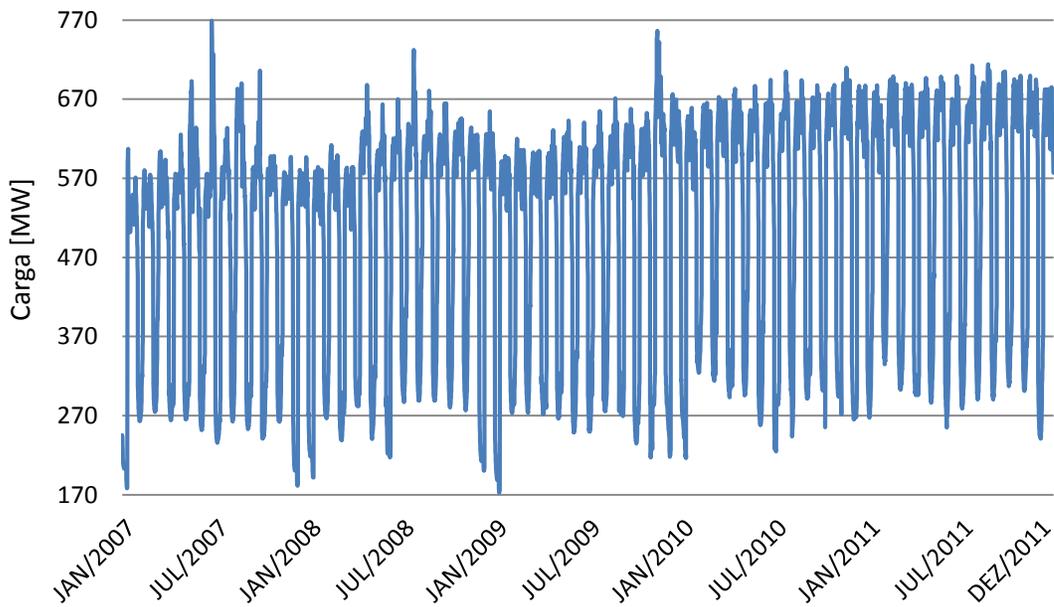


Figura 11 - Série carga crítica - 2007 a 2011 – Barramento I-Ag.II.

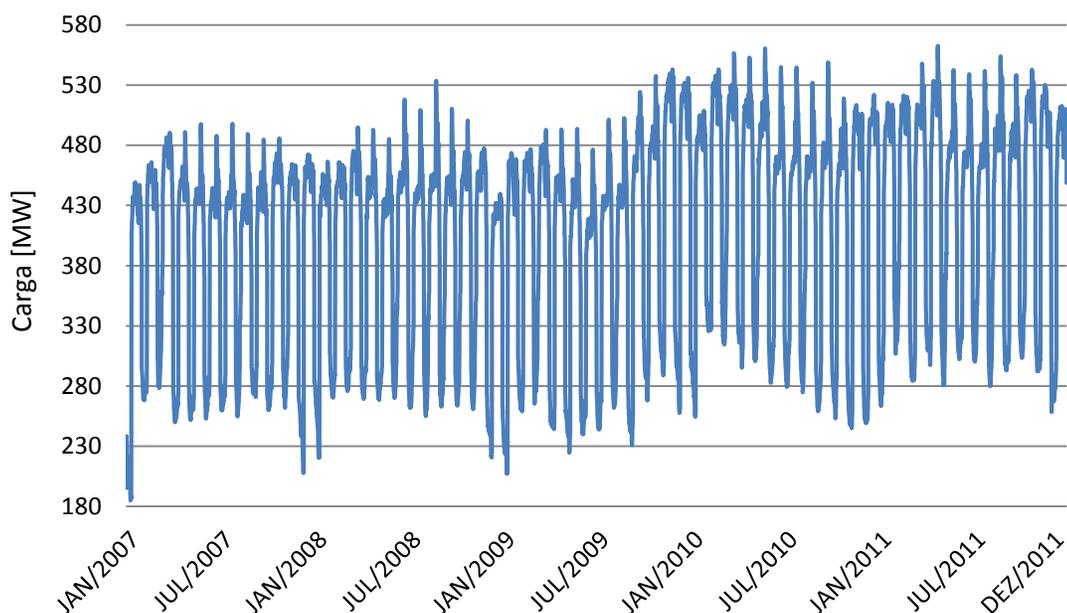


Figura 12 - Série carga crítica - 2007 a 2011 – Barramento II-Ag.II.

Observe que todas as sazonalidades encontradas nas séries apresentadas possuem a correspondência com os meses de altas temperaturas para as cargas mais baixas e os meses de baixa temperatura para as cargas mais altas.

2.3 PREVISÃO MENSAL DA CURVA DE CARGA CRÍTICA

A prática do Setor Elétrico Brasileiro é realizar a previsão das curvas de carga crítica, por agente e por barramento, referentes aos próximos meses. Estas previsões são importantes para a análise da operação do sistema para os meses vindouros, quando são analisados vários cenários operativos. Estes estudos visam analisar a operação neste período, considerando vários cenários operativos em função de previsões de disponibilidade de recursos energéticos (água armazenada nos reservatórios e previsão de aflúências, volume de gás natural e outros combustíveis), previsão de carga, disponibilidade de equipamentos e liberação de equipamentos para manutenção.

Analisando a curva de carga crítica de um dado mês, esta é bastante similar às curvas de cargas diárias horárias, com as menores cargas no período da madrugada, e os maiores consumos se verificando-se em geral nos períodos da tarde e início da noite. Porém, algumas características

dificultam a utilização dos modelos de previsão de carga de curto prazo (alguns dias à frente) na previsão mensal da carga crítica. A primeira delas está relacionada com as variáveis climáticas. Por exemplo, a curva de carga horária de uma quinta-feira será bastante próxima da curva de carga do dia anterior. Quando há variações significativas, estas em geral são consequências de grandes variações nas condições climáticas de um dia para outro. Assim, dada esta forte influência das variáveis climáticas e a disponibilidade de previsões climáticas de curto prazo de boa qualidade, nos modelos de previsão de carga de curto prazo é comum a inclusão de variáveis climáticas no conjunto das variáveis de entrada. No caso da previsão da carga crítica com alguns meses de antecedência, é difícil considerar as variáveis climáticas dada a dificuldade de previsões climáticas de qualidade neste horizonte de tempo. Outra diferença importante também está relacionada com a diferença nos *lead times* de previsão. Nas previsões com alguns meses de antecedência, a sazonalidade anual e as tendências são importantes, enquanto que nas previsões de curto prazo estes aspectos são menos importantes.

A previsão mensal da curva crítica, por outro lado, também é diferente das previsões de longo prazo, pois para o longo prazo as variáveis macro econômicas, tais como o comportamento do PIB e da massa salarial, são importantes. No horizonte de alguns meses, estas variáveis macroeconômicas apresentam pouca variação, e portanto pouco significativo na previsão da curva crítica. Assim, a previsão mensal da curva crítica apresenta aspectos que a diferencia de outros problemas de previsão e, por este motivo, merece uma investigação para determinar abordagens mais adequadas ao problema.

3

Modelos de Previsão

Este capítulo faz uma breve apresentação sobre modelos de previsão. Inicialmente são apresentados alguns modelos de previsão de carga de curto prazo, que são os modelos mais próximos do problema de previsão da curva crítica. O objetivo da apresentação destes exemplos é mostrar a influência do tipo de previsão que se pretende realizar com o tipo de modelo utilizado em cada caso. Após, são apresentadas resumidamente, as técnicas de Redes Neuras Artificiais e de Alisamento Exponencial, que são as técnicas utilizadas nesta tese.

3.1 MODELOS DE PREVISÃO

O objetivo desta dissertação é desenvolver alguns modelos para a previsão mensal da curva de carga crítica. Os modelos de previsão estimam valores futuros de uma dada variável de interesse utilizando um conjunto de informações, que se supõem conhecidos no momento da previsão. Este conjunto de informações usualmente são denominadas as entradas do modelo, e o valor estimado a sua saída. Assim, na definição de um modelo de previsão é necessário selecionar o conjunto de entradas, a técnica de previsão, a estrutura do modelo, e a estratégia de previsão.

A seleção de variáveis de entrada é uma etapa importante na definição do modelo, pois o conjunto de informações utilizadas tem um grande impacto em seu desempenho. Várias técnicas de seleção de entradas já foram propostas, mas não há ainda uma técnica que assegure sempre o melhor conjunto de entradas, de forma que na prática, quando há um conjunto pequeno de variáveis candidatas para entradas, a seleção de entradas é realizada através de busca exaustiva, como foi o caso desta dissertação.

O interesse pela previsão de séries temporais já vem de longa data, e muitas técnicas foram desenvolvidas. Por exemplo, os modelos Box-Jenkins, Alisamento Exponencial, Redes Neurais Artificiais, Redes Neuro-Fuzzy, *Wavelet*, e Modelos de Estado. Aqui também não há uma técnica

que sempre apresenta o melhor desempenho. Portanto, para desenvolver um modelo de previsão todas estas técnicas poderiam ser testadas, para selecionar o melhor. Mas, isto é difícil, principalmente por limitações de tempo devido a grande quantidade de casos a avaliar. Na prática, concentra-se a pesquisa em um conjunto bastante reduzido de técnicas. No caso desta dissertação, foram implementados e testados modelos baseados em Redes Neurais Artificiais e Alisamento exponencial.

A estrutura do modelo está relacionada com a forma com que a informação contida no conjunto de entradas é utilizada para obter a previsão. Um mesmo conjunto de entradas pode ser utilizado de diversas maneiras diferentes, e esta estrutura está bastante relacionada com a técnica selecionada.

Finalmente, depois de selecionado o conjunto de entradas, a técnica e a estrutura do modelo, resta ainda adequar o modelo ao problema de interesse. Este processo de adequação é realizado através de cálculo de parâmetros de forma que o modelo resultante seja o mais “aderente” possível ao problema de interesse. O cálculo destes parâmetros é afetado por alguns fatores, principalmente o tipo de normalização e o período do histórico utilizado para o cálculo dos parâmetros.

A curva de carga crítica é utilizada por agentes do SEB e pelo ONS. Devido a este motivo, o referencial bibliográfico sobre esta técnica é limitado e não existem publicações sobre este assunto até o momento, mas apenas alguns relatórios e apresentações sobre o assunto. A seguir serão apresentados alguns exemplos de modelos de previsão de carga de curto prazo.

3.1.1 Previsão de Carga de Curto Prazo

A previsão de carga de curto prazo pode ser abordada de várias formas. Esta Seção apresenta algumas propostas de metodologias que utilizam técnicas de redes neurais artificiais e modelos estatísticos como suavização exponencial e médias móveis. Para fins de organização as propostas de modelos estatísticos e redes neurais artificiais são apresentadas em tópicos distintos.

3.1.1.1 Previsão de Carga de Curto Prazo – Modelos Estatísticos

Em 1971 (CHRISTIAANSE, 1971) já se preocupava em prever carga de curto prazo. Computar as previsões horárias faz grande sentido para o controle da operação do sistema elétrico. Utilizando um histórico de carga ativa de 2 anos com discretização horária, a proposta deste autor foi prever a carga, hora a hora, com um *lead*¹ de no máximo uma semana. A Equação 1 apresenta o modelo de combinação linear proposto pelo mesmo.

$$x(t) = \bar{a}'\bar{f}(t) + \varepsilon(t)$$

Equação 1 - Modelo geral Christiaanse.

Onde t representa a hora da série, $x(t)$ a carga observada, \bar{a} são as constantes locais, $\bar{f}(t)$ funções de ajuste e $\varepsilon(t)$ um ruído para o instante t . Conhecidas as funções de ajuste e estimadas as constantes locais da hora corrente T , a Equação 2 apresenta a proposta de (CHRISTIAANSE, 1971) para prever carga ativa a partir da hora corrente T para uma hora $(T + \tau)$.

$$\hat{x}_\tau(T + \tau) = \bar{a}'(T)\bar{f}(t + \tau)$$

Equação 2 - Modelo previsão Christiaanse.

O maior trabalho do modelo proposto na Equação 2 é estimar os valores dos parâmetros. Para que este modelo funcione na previsão de carga de curto prazo, faz-se necessário que os dados históricos possuam tendência, sazonalidade e padrões nos dias semanais.

Outros autores que também propuseram a utilização de métodos estatísticos para a previsão de carga em curto prazo foram (VEMURI, HUANG, & NELSON, 1981). A proposta dos mesmos foi utilizar algoritmos de mínimos quadrados para ajustar os parâmetros dos modelos auto-regressivo (AR) e auto-regressivo de médias móveis (ARMA). A estimação do valor de carga no

¹ *Lead ou Lag* – Em séries temporais significa os valores a serem observados, ou seja, a janela deslizante que servirá os valores de entrada para a previsão.

momento t é representada na Equação 3, onde y_t é a carga estimada no momento t , θ_p são parâmetros a serem estimados do modelo auto-regressivo, ω_j são parâmetros a serem estimados no modelo de médias móveis.

$$y_t = \left(- \sum_{i=1}^P \theta_p y_{t-i} \right) + \hat{a}_t + \left(\sum_{j=1}^q \omega_j \hat{a}_{t-j} \right)$$

Equação 3 - Modelo ARMA previsão de carga.

A proposta de (VEMURI, HUANG, & NELSON, 1981) apresenta-se com maior complexidade do que a anterior. Em contra partida ganha-se na robustez utilizando os modelos AR e ARMA de Box e Jenkins (BOX, JENKINS, & REINSEL, 1994).

3.1.1.2 Previsão de Carga de Curto Prazo – Redes Neurais Artificiais

Outra forma de realizar a previsão de curto prazo é utilizando Redes Neurais Artificiais. (LEE, CHA, & PARK, 1992) realizam a previsão de carga em curto prazo, utilizando o algoritmo *Backpropagation*, de duas formas, a primeira forma por abordagem estática, que realiza a previsão das 24h diárias simultaneamente, e a segunda forma por abordagem dinâmica, que prevê a carga sequencialmente usando previsões anteriores.

A primeira proposta de (LEE, CHA, & PARK, 1992), método 1, é representada na Equação 4, modelo não linear para prever um dia à frente, ou seja, as 24h simultaneamente.

$$y(i) = F(W_i, Y(i-1))$$

Equação 4 - Método 1 previsão RNA um dia à frente.

Onde na Equação 4 $y(i) = \{y(i, t): t = 1, 2, \dots, 24\}$ representa a carga do dia i , $Y(i-1)$ o vetor de entrada com dados de carga de dias anteriores, W_i o vetor de pesos da RNA e F a função

vetorial não linear representando a RNA. Para ajustar os pesos W_i para prever dias da semana é necessário possuir dados de carga de três semanas anteriores. A Equação 5 apresenta o procedimento de ajuste dos pesos para a RNA, onde $y(i - 1)$ representa a saída do dia mais recente e $Y(i - 2)$ representa a entrada dos dois dias que antecedem este dia da saída, sendo que $Y(i - 2) = |y(i - 2), y(i - 3)|^T$.

$$y(i - 1) = F(\widehat{W}_i, Y(i - 2))$$

Equação 5 - Estimação dos pesos da RNA.

A segunda proposta de (LEE, CHA, & PARK, 1992), método 2, pode ser observada na Equação 6. Onde $y(i, t)$ representa a carga do dia i no instante t , $W(i, t)$ representa o vetor de pesos da mesma forma, m representa o número de horas anteriores que são utilizadas na entrada da previsão da carga da hora t e n representa o número de dias anteriores que são utilizados para comporem as entradas.

$$y(i, t) = F \begin{pmatrix} W(i, t), y(i, t - 1), y(i, t - 2), \dots, y(i, t - m), \\ y(i - 1, t), y(i - 1, t - 1), \dots, y(i - 1, t - m), \\ \vdots \\ y(i - n, t), y(i - n, t - 1), \dots, y(i - n, t - m) \end{pmatrix}$$

Equação 6 - Método 2 previsão RNA hora a hora.

O ajuste do vetor de pesos $W(i, t)$ na segunda proposta de (LEE, CHA, & PARK, 1992) também é obtido pela Equação 5. Após o ajuste dos pesos, a previsão pode ser realizada aplicando a Equação 7.

$$\hat{y}(i, t) = F \begin{pmatrix} \hat{W}(i, t), \hat{y}(i, t - 1), \hat{y}(i, t - 2), \dots, \hat{y}(i, t - m), \\ y(i - 1, t), y(i - 1, t - 1), \dots, y(i - 1, t - m), \\ \vdots \\ y(i - n, t), y(i - n, t - 1), \dots, y(i - n, t - m) \end{pmatrix}$$

Equação 7 – Previsão hora a hora método 2.

Note que há diferença entre o método 1 e 2 proposto por (LEE, CHA, & PARK, 1992), onde o método 1 possui a saída das 24h prevista em apenas uma previsão enquanto o método 2 necessita de 24 repetições para obter as previsões. Vale ressaltar que os pesos precisam ser ajustados apenas uma vez para cada instante do dia.

(KHOTANZAD, ROHANI, & MARATUKULAM, 1998) propõem um previsor de carga de curto prazo utilizando RNAs. Este é o modelo com maior aplicação pelas empresas de energia dos Estados Unidos. O modelo é composto por três módulos, onde dois módulos distintos de RNAs realizam previsões sobre o mesmo conjunto de dados e um terceiro módulo combina o resultado da saída das duas RNAs. Os dois módulos de RNA possuem a mesma configuração sendo 79 entradas e as 24h do dia a ser previsto como saída. O primeiro módulo estima a carga básica para um dado dia; enquanto que o segundo calcula a variação da carga de um dia para outro, em função principalmente das condições climáticas. As entradas utilizadas no dois módulos são:

- 24 são as cargas horárias do dia anterior k , sendo denotadas por $L_k(1), L_k(2), \dots, L_k(24)$;
- 24 são as medições horárias da temperatura efetiva do dia anterior, denotadas por $T_eff_k(1), T_eff_k(2), \dots, T_eff_k(24)$;
- 24 são as previsões horárias da temperatura efetiva para o dia que se está realizando a previsão, denotadas por $\hat{T}_eff_{k+1}(1), \hat{T}_eff_{k+1}(2), \dots, \hat{T}_eff_{k+1}(24)$;
- 7 são indicadores para cada tipo de dia da semana, de segunda-feira a domingo.

Para prever a temperatura efetiva (KHOTANZAD, ROHANI, & MARATUKULAM, 1998) utiliza a Equação 8.

$$T_{eff} = \begin{cases} T + \alpha * H, & T > 75^{\circ}F \\ T, & 65^{\circ}F \leq T \leq 75^{\circ}F \\ T - \frac{W * (65^{\circ}F - T)}{100}, & T < 65^{\circ}F \end{cases}$$

Equação 8 - Previsão temperatura efetiva.

As saídas das RNAs são diferentes, uma rede neural possui como saída a previsão das 24h de carga do próximo dia, RNA I, e a outra rede neural, RNA II, possui como saída a variação de carga de cada uma das 24h com relação ao dia anterior. Para facilitar a compreensão, as saídas da RNA I são representadas pela Equação 9 e as saídas da RNA II são representadas pela Equação 10.

$$RNA\ I: \hat{L}_{k+1}^I(1), \hat{L}_{k+1}^I(2), \dots, \hat{L}_{k+1}^I(24)$$

Equação 9 - Saídas RNA I.

$$RNA\ II: \Delta\hat{L}_{k+1}^{II}(1), \Delta\hat{L}_{k+1}^{II}(2), \dots, \Delta\hat{L}_{k+1}^{II}(24)$$

Equação 10 - Saídas RNA II.

Observando a Equação 9 e Equação 10, \hat{L}_{k+1}^I representa a carga prevista pela RNA I do próximo dia e $\Delta\hat{L}_{k+1}^{II}$ representa a variação de carga prevista pela RNA II do próximo dia. Para obter a carga prevista pela RNA II, denotada por \hat{L}_{k+1}^{II} , é necessário somar a variação prevista com a carga que ocorreu no mesmo instante do dia anterior, Equação 11.

$$\hat{L}_{k+1}^{II}(i) = \Delta\hat{L}_{k+1}^{II}(i) + L_k(i), \quad i = 1, 2, \dots, 24.$$

Equação 11 - Previsões RNA II.

Após obter as previsões da RNA I e RNA II (KHOTANZAD, ROHANI, & MARATUKULAM, 1998) combina o resultado, no terceiro módulo, utilizando o algoritmo

recursivo de mínimos quadrados. A combinação é feita utilizando a Equação 12 e os parâmetros $\alpha_I(i)$ e $\alpha_{II}(i)$ são obtidos pela Equação 13 que minimizam a soma ponderada dos quadrados dos erros.

$$\hat{L}_{k+1}(i) = \alpha_I(i)\hat{L}_{k+1}^I(i) + \alpha_{II}(i)\hat{L}_{k+1}^{II}(i), \quad i = 1, 2, \dots, 24.$$

Equação 12 - Resultado previsão Terceira Geração.

$$J = \sum_{k=1}^N \beta^{N-k} [L_k(i) - \hat{L}_k(i)]^2$$

Equação 13 - Soma ponderado dos quadrados dos erros.

Observando a Equação 12 e Equação 13, $\alpha_I(i) + \alpha_{II}(i) = 1$, $0 < \beta \leq 1$, N significa o número de dias anteriores previstos e β possui o efeito de diminuir a significância nos dados passados para as previsões futuras.

Observa-se que o modelo de previsão apresentado (KHOTANZAD, ROHANI, & MARATUKULAM, 1998) é mais elaborado com relação aos outros dois modelos apresentados por (LEE, CHA, & PARK, 1992). Nos modelos propostos por (LEE, CHA, & PARK, 1992) utiliza-se apenas os dados da própria série a ser prevista, em contra partida, no modelo terceira geração proposto por (KHOTANZAD, ROHANI, & MARATUKULAM, 1998) utiliza-se como entrada nas previsões, históricos e previsões de temperatura efetiva. Como a proposta dos mesmos é realizar previsões de carga de curto prazo para barramentos, a temperatura efetiva é uma informação importante que se relaciona diretamente com a sensação térmica que um indivíduo está sentindo e pode desencadear um aumento no consumo de energia em um curto período de tempo. Por exemplo, no inverno o vento contribuir para a sensação menor de temperatura induzir a população a utilizar aquecedores ou o caso contrário no verão, induzindo a população a utilizar eletrodomésticos que resfriem sua temperatura.

3.1.1.3 Previsão de Carga de Curto Prazo – Modelagem

Como foi apresentado nos dois Itens anteriores, o problema de previsão de curto prazo pode ser modelado de várias formas e grande parte da acurácia das previsões depende diretamente da modelagem e da técnica utilizada como exemplo suavização exponencial ou redes neurais artificiais.

(HIPPERT, PEDREIRA, & SOUZA, 2001) destaca uma comparação de aproximadamente setenta artigos que realizam a previsão de carga de curto prazo utilizando redes neurais artificiais *multilayer perceptron* (MLP). Neste estudo, (HIPPERT, PEDREIRA, & SOUZA, 2001) apresenta uma comparação entre os diferentes tipos de modelagens realizadas, separadas por configurações utilizadas nas RNAs.

Com estas análises, é possível observar que não existe um modelo ideal para a previsão de carga de curto prazo e que este problema é sujeito a variações em curtíssimo período. Sendo assim, pode-se concluir que para realizar previsões neste contexto justifica-se a busca por uma modelagem específica para cada série, pois cada série apresenta-se como um problema diferente. Também ressalva-se que não existe um modelo ideal ou que possui maior acurácia para a previsão de carga de curto prazo e sim uma melhor modelagem para cada problema específico.

3.2 TÉCNICAS DE PREVISÃO

Para realizar previsão de carga existem modelos inteligentes avançados com uma ampla opção de variantes. Para esta dissertação foram testados modelos de Redes Neurais e Artificiais (RNAs) e modelos para Séries Sazonais, especificamente o modelo de suavização exponencial sazonal de Holt-Winters (HW). O objetivo deste Seção é a apresentação breve das Redes Neurais Artificiais e do modelo de Holt-Winters.

3.2.1 Redes Neurais e Artificiais (RNA)

As aplicações de sucesso de modelos de Redes Neurais Artificiais são populares desde a década de 80 (HO, HSU, & YANG, 1992). Inspiradas no cérebro humano, as RNAs simulam o funcionamento e a comunicação de neurônios biológicos. "Uma rede neural é formada por um conjunto de unidades de processamento simples que se comunicam enviando sinais uma para a outra através de conexões ponderadas" (BILOBROVEC, MARÇAL, & PILATTI, 2004).

As Redes Neurais Artificiais (RNAs) são um ramo da Inteligência Artificial (IA), fazendo parte da IA Conexionista. IA Conexionista basicamente visa a representação e reprodução do comportamento de raciocínio cerebral por meio de algoritmos chamados de neurônios artificiais ou *perceptrons*. Podendo trabalhar de modo *off-line* ou *online*, onde o treinamento da rede é feito antes das previsões (*offline*) e o treinamento é realizado constantemente junto com as previsões (*online*).

As RNAs organizam os *perceptrons* em uma dada estrutura, em geral organizadas em uma camada de entradas, uma camada intermediária e uma camada de saída. Nesta estrutura os *perceptrons* são interligados e associados a cada ligação com uma ponderação, chamada de peso. Os pesos são individuais e estes são ajustados no treinamento do modelo. Alguns modelos utilizam o atributo *bias* com objetivo de auxiliar o ajuste e a polarização dos pesos. Sem o atributo *bias* algumas RNAs ficam limitadas, como o famoso problema do ou-exclusivo (HAYKIN, 1999). Na estrutura apresentada na Figura 13, as informações sempre fluem de camada da entrada para a camada de saída. Estas são chamadas redes *Feedforward*, mas outras arquiteturas são possíveis, como as redes retroalimentadas nas quais a saída de uma certa camada pode novamente ser uma entrada da própria camada ou outra camada.

Os neurônios são unidades de processamento de informações, e nas RNAs a representação do processamento das informações em um dado *perceptron* é realizada através de uma função de ativação. Estas funções são utilizadas para intensificar, reduzir ou apenas propagar o sinal de cada neurônio da RNA. Existem vários tipos de funções de ativação, podendo citar: linear, tangente hiperbólica, sigmoide logística, gaussiana e outras. Para o bom funcionamento da rede neural, os dados que estas funções tratam precisam estar dentro de seus intervalos de domínio. Para isso, geralmente são realizadas normalizações em todo o conjunto antes e depois da utilização das RNAs.

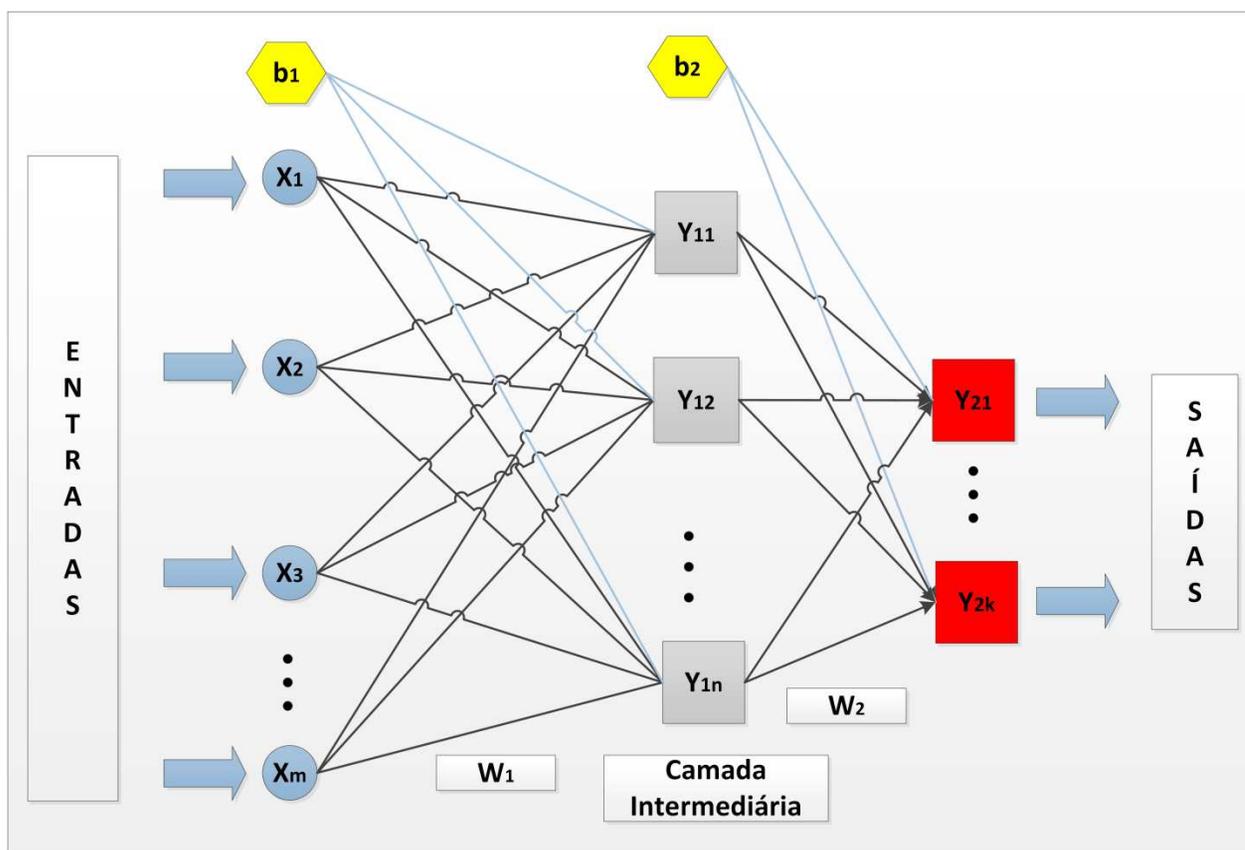


Figura 13 - Rede Neural Artificial.

Se um modelo de previsão de carga utiliza uma estrutura como representada na Figura 13, então as saídas indicam os valores que se pretende prever, e as entradas indicam as variáveis que serão utilizadas como entradas do modelo. Ou seja, se ao modelo for fornecida informações das entradas, o modelo deverá ter como saída valores próximos das saídas esperadas. Sendo assim, as saídas podem ser representadas como funções das entradas e dos pesos das conexões. Para isso, considerando y_i um vetor de h *perceptrons* da camada i , W_i uma matriz de pesos com v entradas e h saídas da camada i , sendo $W_i^{n^{v,h}}$, e finalmente b_i o *bias* da camada i , é possível calcular a saída da RNA utilizando a Equação 14.

$$y_i = \varphi \left(\sum_{j=1}^v (W_i^j x_j) + b_i \right)$$

Equação 14 - Representação RNA.

Para realizar o cálculo da saída, faz-se necessário calcular, desde a entrada da RNA, camada a camada de *perceptrons* utilizando como entrada x o resultado da camada anterior, no caso da primeira camada as entradas são as mesmas fornecidas para a RNA. A saída desejada da rede é o resultado do vetor y da última camada, ressaltando que φ , Equação 14, é uma função de ativação não linear, citada anteriormente.

Portanto, para que a rede neural represente a relação entre as variáveis de entrada e as variáveis de saída, é necessário calcular o valor adequado para os pesos, as conexões. O processo de treinamento de uma RNA é nomeado de aprendizagem, onde o mesmo pode ser supervisionado ou não supervisionado. No aprendizado supervisionado a RNA gera saídas e as compara com saídas esperadas de acordo com a entrada fornecida. Os pesos da RNA são ajustados, ou não, de acordo com o resultado da comparação. No aprendizado não supervisionado, são fornecidas apenas entradas para as RNAs que se ajustam agrupar os elementos da saída de acordo com características similares. Estes grupos são chamados de *clusters*.

As RNAs utilizadas para os experimentos desta dissertação são de aprendizagem supervisionada do tipo *Multilayer Perceptron* (MLP). O método de treinamento de uma RNA tem influência sobre o resultado. Há várias metodologias de treinamento, mas não há uma que sempre se destaca. Uma alternativa é treinar através de diversas metodologias e selecionar a que apresenta os melhores desempenhos. Os algoritmos de treinamento propostos no relatório técnico de (CASTRO & ZUBEN, 1998) são utilizados para a geração das previsões com as RNAs. São eles:

- Método *Back Propagation* com termo *momentum* (BPM);
- Método *Scaled Conjugate Gradient* (SCG);
- Método *Fletcher & Reeves* (FR);
- Método *Polak-Ribière* (PR);
- Método *One-Step Secant* (OSS);

- Método *Davidon-Fletcher-Powell* (DFP);
- Método *Broyden-Fletcher-Goldfarb-Shanno* (BFGS);
- Método Gradient (GRAD).

A Figura 14 apresenta um diagrama das diferentes estratégias de treinamento dos métodos citados. O objetivo do treinamento é encontrar erros mínimos (chamados mínimos globais). Das estratégias de treinamento são usados métodos de primeira e segunda ordem, onde os métodos de segunda ordem são mais eficientes para encontrar o mínimo global em relação aos métodos de primeira ordem.

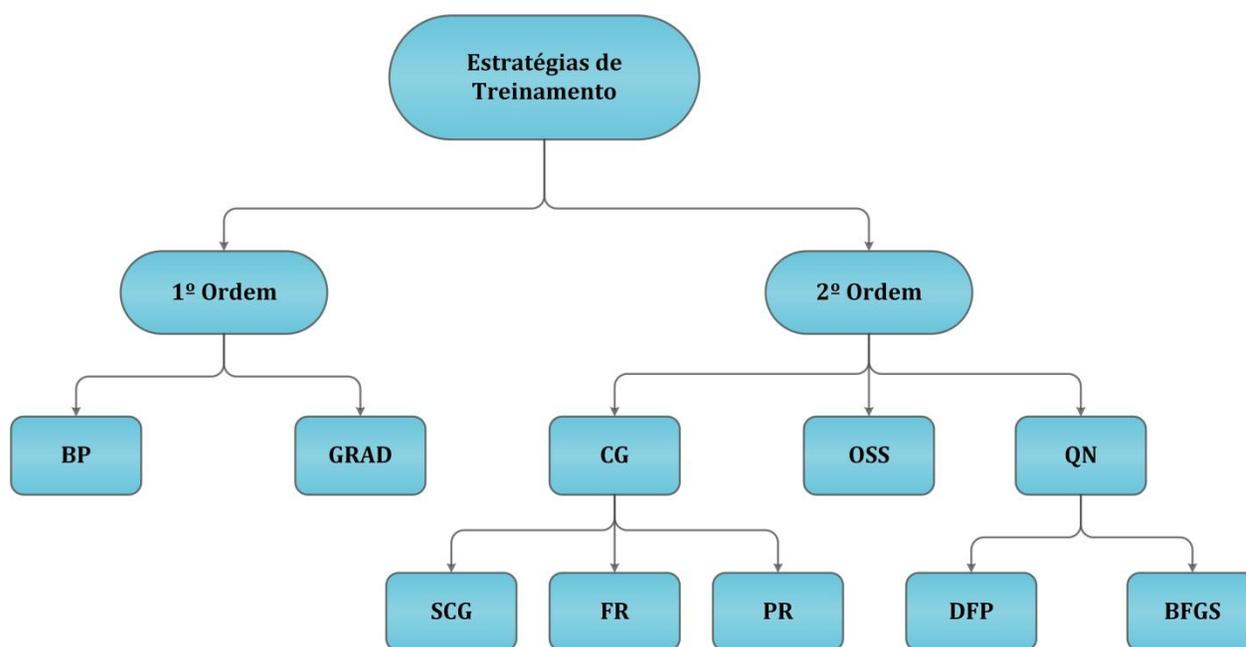


Figura 14 - Estratégia de Treinamento Rede Neural.

Fonte: (CASTRO & ZUBEN, 1998).

Observando a Figura 14, o elemento “CG”, usado para os modelos SCG, FR e PR, representa o conjunto dos métodos de Gradiente Conjugado (*Conjugate Gradient*). Já o elemento “QN” usado para os modelos DFP e BFGS, representa o conjunto dos métodos *quasi-Newton*.

Uma RNA aprende o comportamento de uma série temporal utilizando, minimamente, um histórico da série temporal que se pretende prever. Para isso é apresentada à RNA parte do histórico

da série temporal. Neste histórico, conhece-se tanto os valores das entradas, como também os valores das respectivas saídas. Então o processo de treinamento se inicia com valores aleatórios para os pesos, e para essa rede inicial é apresentado um conjunto de variáveis de entrada e calcula-se a respectiva saída para os pesos atuais. Se a saída calculada, pela RNA, for igual à respectiva saída (dentro de uma precisão esperada), então diz-se que a RNA está treinada. Caso contrário, os pesos são atualizados de modo a diminuir os erros na saída. Com os novos pesos, nesta mesma RNA, apresenta-se um segundo conjunto de dados e este processo de atualização dos pesos é repetido até que a RNA represente fielmente a relação das entradas com as saídas esperadas, mesmo esperando precisões mínimas. Por este motivo, diz-se que as RNAs são aproximadores universais. Porém, a prática tem mostrado que um treinamento muito prolongado torna a rede muito especializada (“viciada”) no conjunto utilizado para treino. Decorrente disso há a dificuldade em generalizar para amostras diferentes, prejudicando o processo de previsão. Neste caso, diz-se que houve um *overfitting* no processo de treinamento. Para evitar esta situação, na prática evita-se um treinamento excessivo da rede, através de um conjunto de validação. O conjunto de validação é constituído de amostras diferentes das amostras presentes no conjunto de treinamento, sendo da mesma série temporal em um período do histórico distinto. A cada atualização dos pesos, a RNA, com os novos pesos, é aplicada ao conjunto de validação. O processo de treinamento continua enquanto o erro de previsão deste conjunto de validação apresentar reduções significativas.

Existe também o caso contrário ao *overfitting*, nomeado de *underfitting*. Neste caso o ajuste dos pesos da RNA é realizado com uma precisão esperada baixa, ou seja, não esperando muitos acertos. Este fato configura a RNA com a característica de generalização alta, com isso a rede não terá uma boa precisão.

3.2.2 Suavização exponencial sazonal de holt-winters (HW)

De acordo com (MORETTIN & TOLOI, 2004), técnicas específicas de suavização exponencial assumem que os valores extremos da série histórica representam a aleatoriedade e a partir da suavização desses extremos é possível identificar o padrão básico da série histórica para realizar previsões. A utilização das técnicas de suavização é atribuída devido a sua simplicidade, desempenho computacional e acurácia. O alisamento é adequado para séries temporais com

sazonalidade, tendências e para os casos de séries históricas com poucos dados e quando a série histórica não apresenta nenhum tipo de comportamento ligado ao seu passado.

O modelo de suavização sazonal de Holt-Winters foi inspirado nos métodos de Holt (MONTGOMERY & JOHNSON, 1976) e aprimorado, incluindo o fator de sazonalidade, por Winters (WINTERS, 1960). Baseado em três equações com parâmetros de suavização distintos, que são associados a cada um dos itens que compõem o padrão da série, são eles: nível, tendência e sazonalidade. Existem dois tipos de procedimento de suavização, a multiplicativa e a aditiva. No procedimento multiplicativo o fator sazonal é multiplicativo, e no outro o fator sazonal é aditivo. De acordo com (ZHU, G. et al., 2006), se existe um fator de sazonalidade na série histórica, usualmente escolhe-se o procedimento da série sazonal multiplicativa. Considerando uma série sazonal com período s , é possível descrever os dois procedimentos de suavização exponencial sazonal de Holt-Winters, multiplicativo e aditivo conforme a seguir.

3.2.2.1 Holt-Winters (HW) – Série sazonal multiplicativa

Para realizar o procedimento de suavização, considera-se μ_t o fator multiplicativo da variável sazonal F_t , T_t representando a variável de tendência e a_t o elemento residual não previsível. A Equação 15 representa a série sazonal.

$$Z_t = \mu_t F_t + T_t + a_t; \quad t = 1, \dots, N.$$

Equação 15 - Série sazonal multiplicativa.

O processo de suavização é realizado calculando as estimativas presentes na Equação 16, Equação 17 e Equação 18, onde A, C e D representam respectivamente as ponderações dos fatores sazonais, de nível e de tendência. Os valores destes parâmetros são calculados iterativamente visando obter o menor erro médio de previsão utilizando um dado histórico da série temporal.

$$\hat{F}_t = D \left(\frac{Z_t}{\bar{Z}_t} \right) + (1 - D) \hat{F}_{t-s}; \quad 0 < D < 1; \quad t = s + 1, \dots, N.$$

Equação 16 - Fator de sazonalidade instante t – série sazonal multiplicativa.

$$\bar{Z}_t = A \left(\frac{Z_t}{\hat{F}_{t-s}} \right) + (1 - A)(Z_{t-1} + \hat{T}_{t-1}); 0 < A < 1; t = s + 1, \dots, N.$$

Equação 17 - Fator do nível no instante t – série sazonal multiplicativa.

$$\hat{T}_t = C(\bar{Z}_t - \bar{Z}_{t-1}) + (1 - C)\hat{T}_{t-1}; 0 < C < 1; t = s + 1, \dots, N.$$

Equação 18 - Fator de tendência no instante t – série sazonal multiplicativa.

Após o processo de suavização é possível realizar as previsões dos valores futuros desejados utilizando a Equação 19, sendo que \hat{F}_t , \bar{Z}_t e \hat{T}_t são derivados respectivamente da Equação 16, Equação 17 e Equação 18.

$$\begin{aligned} \hat{Z}_t(h) &= (\bar{Z}_t + h\hat{T}_t)\hat{F}_{t+h-s}; h = 1, 2, \dots, s; \\ \hat{Z}_t(h) &= (\bar{Z}_t + h\hat{T}_t)\hat{F}_{t+h-2s}; h = 1, 2, \dots, 2s; \\ &\vdots \\ &\vdots \\ &\vdots \end{aligned}$$

Equação 19 - Previsão de valores futuros no instante t – série sazonal multiplicativa.

Continuando a previsão para o valor histórico Z_{t+1} basta somar um instante a toda variável que tiver o termo t na Equação 16, Equação 17 e Equação 18. Resultando na Equação 20, Equação 21 e Equação 22 respectivamente. Para a previsão de \hat{Z}_{t+1} o cálculo deverá ser feito de acordo com a Equação 23. Para a previsão dos próximos valores a analogia utilizada é a mesma.

$$\hat{F}_{t+1} = D \left(\frac{Z_{t+1}}{\bar{Z}_{t+1}} \right) + (1 - D)\hat{F}_{t+1-s}; 0 < D < 1;$$

Equação 20 - Fator de sazonalidade instante (t+1) – série sazonal multiplicativa.

$$\bar{Z}_{t+1} = A \left(\frac{Z_{t+1}}{\hat{F}_{t+1-s}} \right) + (1 - A)(Z_t + \hat{T}_t);$$

Equação 21 - Fator do nível no instante (t+1) – série sazonal multiplicativa.

$$\hat{T}_{t+1} = C(\bar{Z}_{t+1} - \bar{Z}_t) + (1 - C)\hat{T}_t;$$

Equação 22 - Fator de tendência no instante (t+1) – série sazonal multiplicativa.

$$\begin{aligned} \hat{Z}_{t+1}(h-1) &= (\bar{Z}_{t+1} + (h-1)\hat{T}_{t+1})\hat{F}_{t+1+h-s}; & h = 1, 2, \dots, s+1; \\ \hat{Z}_{t+1}(h-1) &= (\bar{Z}_{t+1} + (h-1)\hat{T}_{t+1})\hat{F}_{t+1+h-2s}; & h = 1, 2, \dots, 2s+1; \\ &\cdot & \cdot & \cdot \\ &\cdot & \cdot & \cdot \\ &\cdot & \cdot & \cdot \end{aligned}$$

Equação 23 - Previsão de valores futuros no instante (t+1) – série sazonal multiplicativa.

A Equação 24 e Equação 25 apresentam as informações do cálculo dos valores iniciais do processo de suavização respectivamente para os fatores de sazonalidade e nível. Observando que o fator de tendência, \hat{T}_s , inicia-se em zero.

$$\hat{F}_j = \frac{Z_j}{\left(\frac{1}{s}\right) \sum_{k=1}^s Z_k}, j = 1, 2, \dots, s;$$

Equação 24 - Cálculo inicial do fator sazonalidade.

$$\bar{Z}_s = \frac{1}{s} \sum_{k=1}^s Z_k;$$

Equação 25 - Cálculo inicial do fator do nível.

3.2.2.2 Holt-Winters (HW) – Série sazonal aditiva

Seguindo o mesmo conceito presente da Seção 3.2.2.1, a série sazonal aditiva representa-se pela Equação 26.

$$Z_t = \mu_t + F_t + T_t + a_t;$$

Equação 26 - Série sazonal aditiva.

Então o processo de suavização é obtido utilizando a Equação 27, Equação 28 e Equação 29 para calcular as estimativas respectivamente do fator sazonal, nível e tendência.

$$\hat{F}_{t+1} = D(Z_t - \bar{Z}_t) + (1 - D)\hat{F}_{t-s}; 0 < D < 1;$$

Equação 27 - Fator de sazonalidade instante t – série sazonal aditiva.

$$\bar{Z}_t = A(Z_t - \hat{F}_{t-s}) + (1 - A)(\bar{Z}_{t-1} + \hat{T}_{t-1}); 0 < A < 1;$$

Equação 28 - Fator do nível no instante t – série sazonal aditiva.

$$\hat{T}_t = C(\bar{Z}_t - \bar{Z}_{t-1}) + (1 - C)\hat{T}_{t-1}; 0 < C < 1;$$

Equação 29 - Fator de tendência no instante t – série sazonal aditiva.

Para realizar a previsão na série sazonal aditiva é utilizada a Equação 30, e para as previsões seguintes utiliza-se o mesmo procedimento presente na Seção 3.2.2.1.

$$\begin{aligned}
 \hat{Z}_t(h) &= \bar{Z}_t + h\hat{T}_t + \hat{F}_{t+h-s}; & h = 1, 2, \dots, s; \\
 \hat{Z}_t(h) &= \bar{Z}_t + h\hat{T}_t + \hat{F}_{t+h-2s}; & h = 1, 2, \dots, 2s; \\
 \cdot & & \cdot \\
 \cdot & & \cdot \\
 \cdot & & \cdot
 \end{aligned}$$

Equação 30 - Previsão de valores futuros no instante t – série sazonal aditiva.

Os métodos de Holt-Winters são utilizados em diversas áreas, abrangendo manipulação e previsão de séries históricas: (EKBERG, YLINEN, & LOULA, 2011), (AGAPIE & AGAPIE, 1997), (ZHU, G. et al., 2006) e outros.

4

SysPrev – Um Sistema de Suporte para Estudos de Demanda por Barramento

Neste capítulo é apresentada uma breve história sobre os sistemas de suporte à decisão (SSD), Seção 4.1, e uma descrição do Sistema SysPrev, Seção 4.2. Um protótipo desenvolvido, por um grupo de pesquisadores, em um projeto em conjunto com o ONS para auxiliar análises no setor de estudos de carga elétrica. O mesmo possibilitou grande avanço e auxílio em análises de carga para a observação do comportamento da carga que, conseqüentemente, auxiliou no desenvolvimento dos modelos de previsão.

Um sistema de suporte à decisão é um conjunto de ferramentas combinadas com o intuito de oferecer suporte em tomada de decisões em um dado problema específico. Geralmente são utilizados em problemas não estruturados e lidam com variáveis desconhecidas. São compostos por três elementos principais: simulação, previsão e otimização. A simulação se responsabiliza por explorar o domínio de possibilidades a fim de encontrar todas as possíveis opções para a solução de um problema. A previsão responsabiliza-se pela seleção das melhores decisões com base em decisões passadas. Finalmente, a otimização fica a cargo das análises pós-decisões e penaliza ou pontua de acordo com o resultado obtido.

A estrutura básica para construção de um sistema de qualquer natureza engloba: algoritmos; base de dados e interfaces, onde os algoritmos são compostos pelos diferentes modelos utilizados pelo sistema. A base de dados, ou banco de dados, fica responsável pela persistência e fornecimento dos dados submissos aos algoritmos. Não menos importante, a interface, que realiza a interação do sistema com dispositivos externos e usuários.

4.1 SISTEMAS DE SUPORTE À DECISÃO (SSD)

Segundo (BISPO & CAZARINI, 1998), “Desde o início da civilização, o homem sempre procurou algo que lhe auxiliasse no seu processo decisório. Ele buscava nas divindades esse auxílio para que pudesse tomar decisões consideradas sábias”. O homem passou então a criar ferramentas que auxiliassem suas decisões, a fim de diminuir os erros. Por volta de 1965, os auxílios dos sistemas eram apenas para cálculos matemáticos. No início dos anos 70 iniciaram-se os sistemas de suporte à decisão primitivos. Então, os SSD evoluíram em conjunto com as tecnologias e ferramentais da época. Hoje existem sistemas de suporte à decisão e tomada de decisão autônoma. Podendo ser citados: os computadores de bordo de um avião, sistemas contra incêndio, o freio *abs* (*Antiblockier-Bremssystem*) dos carros, computador de bordo de novos carros que podem até sugerir uma parada na viagem por observação de sinais vitais demonstrando cansaço do motorista, e outros inúmeros sistemas.

4.2 O SISTEMA SYSPREV

O SysPrev é um protótipo de um sistema de suporte à decisão desenvolvido em conjunto com o ONS afim de oferecer um ferramental para o auxílio nos estudos de carga elétrica. O objetivo de utilizar um sistema como este é unificar informações correlacionadas a fim de disponibilizar ao usuário um ambiente computacional que faça previsões, consultas, análises e comparações.

Este Sistema de Suporte à Decisão foi desenvolvido em JAVA, implementado seguindo conceitos de Engenharia de *Software* e com a arquitetura de desenvolvimento *Model-view-controller* (MVC).

Existe no SysPrev um ferramental de consultas personalizadas, onde o usuário pode visualizar os dados históricos de várias formas e extrair estatísticas. Também existe um módulo de tratamento de dados históricos, onde, nos dados de carga elétrica podem existir transferência de carga de um barramento para outro, ou erros de medições; este modo é responsável pela identificação e tratamento destes dados. O SysPrev também conta com um módulo de previsão e estudo dos dados, onde é possível selecionar períodos históricos da curva de carga crítica e realizar previsões sobre a mesma.

Para que as funcionalidades do SysPrev sejam possíveis é necessário a existência de um banco de dados especialmente projetado para o armazenamento de dados na disposição de hierarquias de agentes, barramentos, áreas e agrupamentos. Neste mesmo banco de dados é possível armazenar dados históricos tratados e reais adquiridos ou fornecidos pelos agentes.

A Figura 15 apresenta a tela principal do sistema a tela principal do SysPrev, onde encontram-se os agentes com seus respectivos barramentos no canto esquerdo.

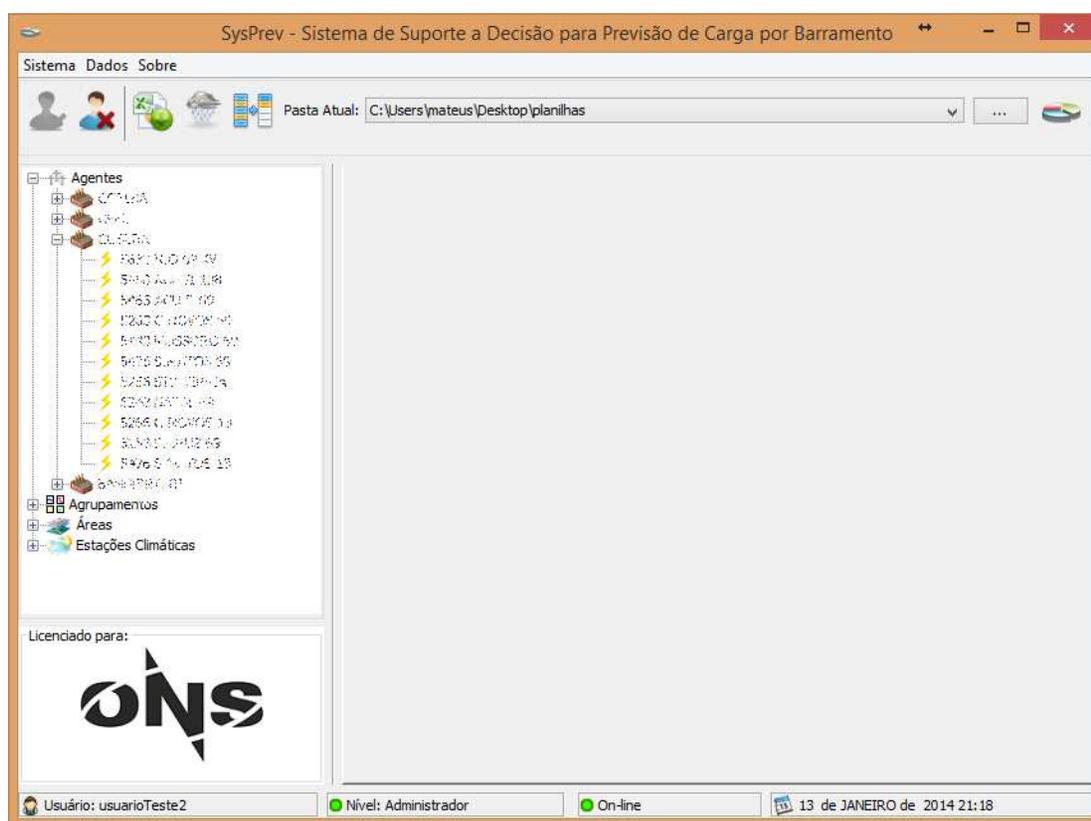


Figura 15 - Tela principal - SysPrev.

A Figura 16 apresenta uma tela com opções para a consulta da curva de carga diária, com base em um histórico de carga ativa e reativa para o período escolhido. A Figura 17 apresenta o resultado da consulta.

Consulta Personalizada

Consulta Personalizada - Total

Nova Consulta
 Pesquisar Consulta Existente

Consulta
Nome:

Tipo de Consulta
Curva Diária

Período e Intervalo de Integração
Início:
Fim:

Histórico: 01/01/2007 à 31/03/2012

Tipo de Dia
 Todos
 Seg-Sex
 Ter-Sex
 Dom-Fer
 Feriados
 Dom
 Seg
 Ter
 Qua
 Qui
 Sex
 Sáb
 Não considerar dias após feriados

Grandeza
 MW
 Mvar
 Fator de Potência
 MVA
 Mvar/MW
 Todas

Confirmação - Configuração Consulta
 Gerar Planilha(s)

Figura 16 - Tela consulta curva diária - SysPrev.

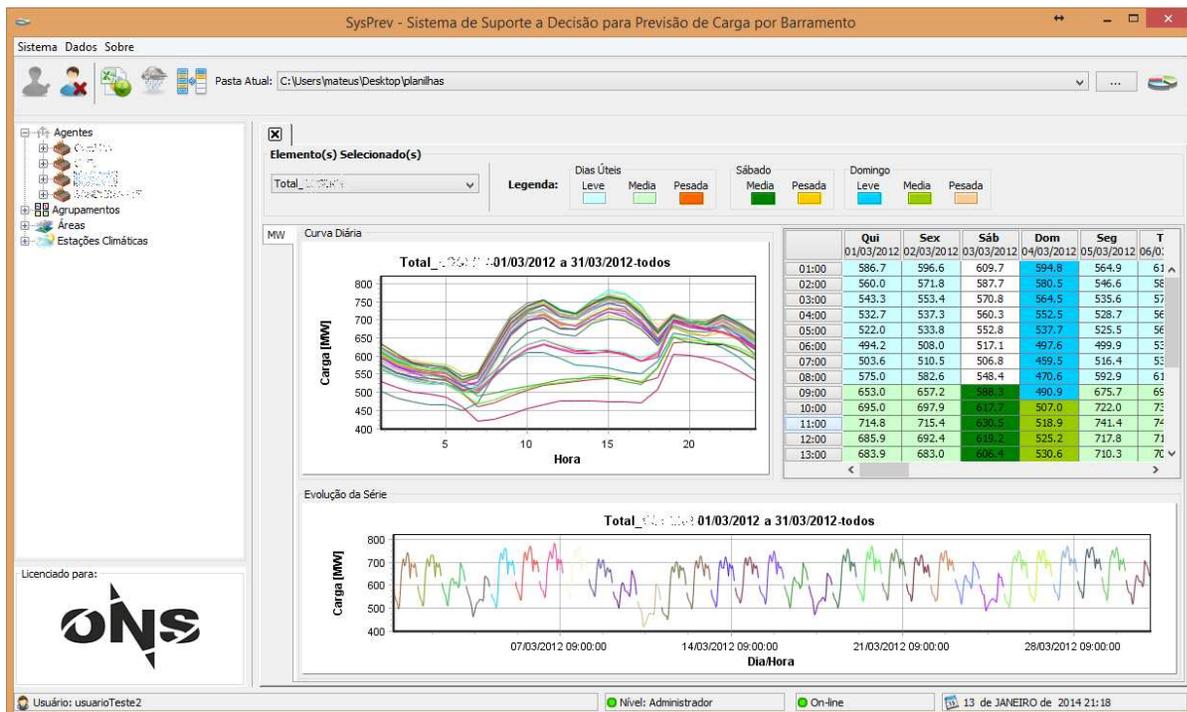


Figura 17 - Resultado consulta curva diária - SysPrev.

Através da consulta presente na Figura 18, é possível realizar a maior parte das estatísticas utilizadas no setor de carga elétrica. Consultas como máximas cargas por semana, ou agrupamentos como mês, dia, ano, entre outras possibilidades.

The image shows a software interface for creating a custom query. The window is titled "Consulta Personalizada" and contains the following sections:

- Consulta Personalizada - Total_BANCA_LINHA_001**: Title bar.
- Novo Consulta** / **Pesquisar Consulta Existente**: Radio buttons to select the query type.
- Tipo de Consulta**: A dropdown menu set to "Ad Hoc".
- Período e Intervalo de Integração**: Fields for "Início" (01/12/2011), "Fim" (31/12/2011), and "Intervalo" (60 min). Below it, "Histórico: 01/01/2007 à 31/12/2011".
- Tipo Seleção**: Radio buttons for "Condição de Carga" (selected) and "Escolha do Usuário".
- Periodicidade e Valor**: A dropdown menu set to "Mensal" and radio buttons for "Máximo" (selected), "Mínimo", and "Todos os Valores".
- Condição de Carga**: A grid of checkboxes for various load conditions:
 - Leve de Dias Úteis
 - Pesada de Sábado
 - Média de Sábado
 - Média de Dias Úteis
 - Pesada de Domingo
 - Mínima de Domingo/Feriados
 - Pesada de Dias Úteis
 - Média de Domingo
 - Máxima não Coincidente
- Modo de Consulta**: Radio buttons for "Coincidentes" (selected) and "Não Coincidentes".
- Grandeza**: A row of checkboxes for "MW" (checked), "Mvar", "Fator de Potência", "MVA", "Mvar/MW", and "Todas".
- Confirmação - Configuração Consulta**: A checkbox for "Gerar Planilha(s)" and two buttons: "Cancelar" and "Confirmar".

Figura 18 - Consulta ah-hoc - SysPrev.

A Figura 19 apresenta, no SysPrev, a previsão do ano de 2011 para a carga crítica global do Agente II, utilizando o modelo de suavização exponencial sazonal de Holt-Winters.

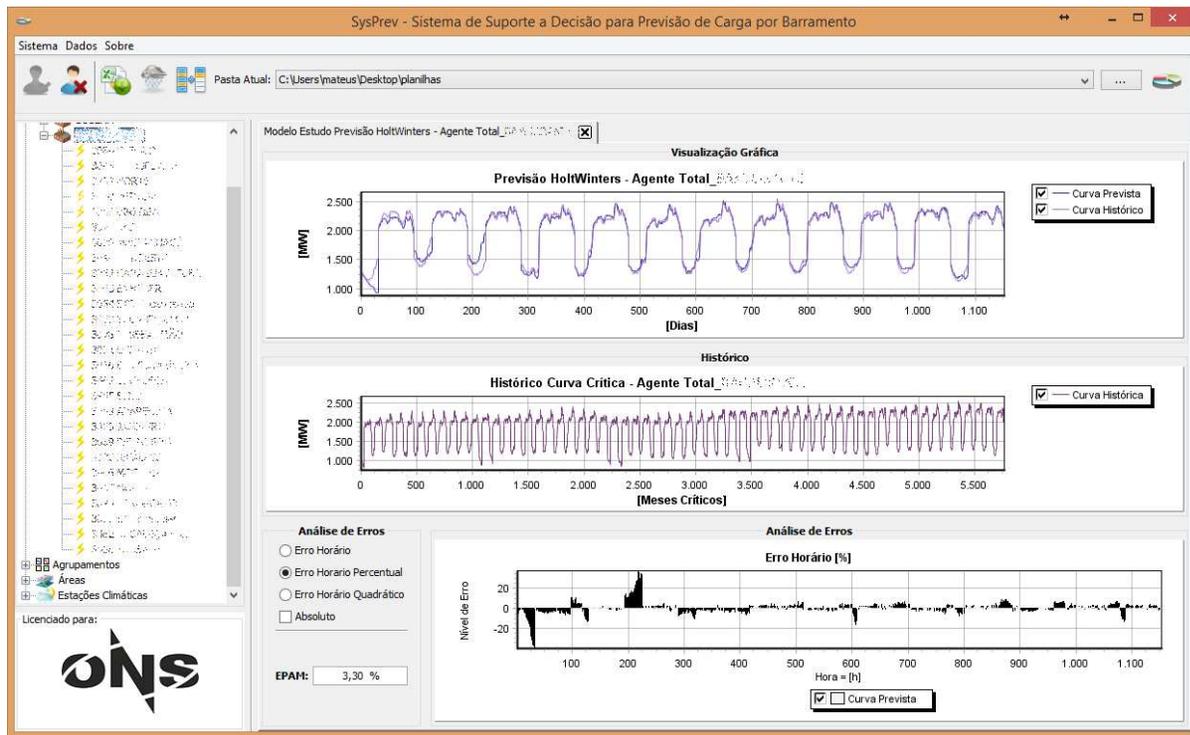


Figura 19 - Tela previsão - SysPrev.

Ainda existem inúmeras outras ferramentas que o SysPrev possui, expô-las não é o foco deste trabalho. Este capítulo tem como o objetivo justificar o grande volume de dados gerados e análises que foram realizadas nesta dissertação, que sem o auxílio desta ferramenta iria-se desperdiçar esforços em trabalhos manuais ao invés de gerar ganhos em pesquisas científicas, como foi o caso.

O sistema SysPrev auxiliou no desenvolvimento desta dissertação, facilitando observações estatísticas, manipulação dos dados, realização de estudos de previsões da curva de carga crítica, tratamento dos dados e inúmeras outras tarefas que convergiram no desenvolvimento e propostas dos módulos de previsão para a curva de carga crítica, que é o foco principal desta dissertação.

5

Metodologia

Este capítulo apresenta os modelos de previsão mensal da curva de carga crítica. Inicialmente, Seção 5.1, apresentam-se os modelos de previsão propostos com RNAs. Nesta Seção foram implementados dois modelos utilizando arquiteturas diferentes. Na Seção 5.2 é apresentado o modelo de previsão utilizando a metodologia de Holt-Winter baseado em alisamento exponencial.

5.1 MODELOS DE PREVISÃO BASEADOS EM REDES NEURAIAS ARTIFICIAIS

O desenvolvimento de modelos de previsão de carga crítica envolve a definição do conjunto de entradas, a escolha da técnica a ser utilizada, a sua configuração, o histórico a ser utilizado e parâmetros específicos de cada técnica. Como não conhece-se a priori qual o melhor modelo para cada série temporal, então na prática as metodologias são desenvolvidas por uma busca de melhor resultado em cada série temporal, dificultando a busca por um modelo genérico. No caso da curva de carga crítica, por ser de base mensal, a previsão deve ser realizada com pelo menos um mês de antecedência (um passo à frente), e neste horizonte as variáveis climáticas são difíceis de considerar, dada a sua dificuldade de previsão. Então, a previsão da curva crítica deve se basear principalmente no comportamento da própria série temporal. Em termos de técnica, os modelos baseados em Redes Neurais Artificiais foram escolhidos, dado a facilidade em tratar diferentes tipos de séries temporais e modelar de forma eficiente séries não lineares. Foram testadas várias técnicas de treinamento das redes neurais (Castro;Zuben,1998), Seção 3.2.1, e as melhores técnicas são apresentadas nos resultados, Capítulo 6.

Nesta dissertação foram propostos dois modelos de previsão utilizando RNA. Na primeira abordagem, implementou-se um modelo específico para a previsão da carga crítica de cada intervalo de tempo de um dado mês. Ou seja, há um modelo específico e independente para cada intervalo de tempo t . Como o primeiro modelo faz a previsão independente para cada intervalo de

tempo, há a possibilidade de se obter uma previsão da curva de carga crítica de um dado mês com desvios significativos em relação ao seu perfil (formato da curva). Assim, o segundo modelo privilegia a manutenção do perfil típico da curva crítica de um dado mês, realizando a previsão em duas etapas, com base em previsões de valores extremos.

5.1.1 Modelo I

Existe uma curva de carga crítica para cada mês/ano na série histórica e as mesmas possuem a mesma discretização de uma curva de carga diária, ou seja, os mesmos intervalos horários. Assim, a primeira abordagem desenvolvida (Modelo I) realiza a previsão da demanda crítica para cada intervalo de tempo (cada discretização), utilizando um modelo de RNA específico para cada um destes intervalos. O histórico de cada intervalo é construído seguindo a sequência histórica mensal de cada horário. Um exemplo seria a primeira hora de cada mês. A Figura 20 apresenta as séries históricas do primeiro, segundo e terceiro intervalo de tempo, correspondente às horas 00:15h, 00:30h e 00:45h (discretização de 15 minutos), do período de Janeiro de 2007 a Março de 2012, montada a partir da série histórica de curva de carga crítica para o mesmo período do Barramento I-Ag.I do Agente I.

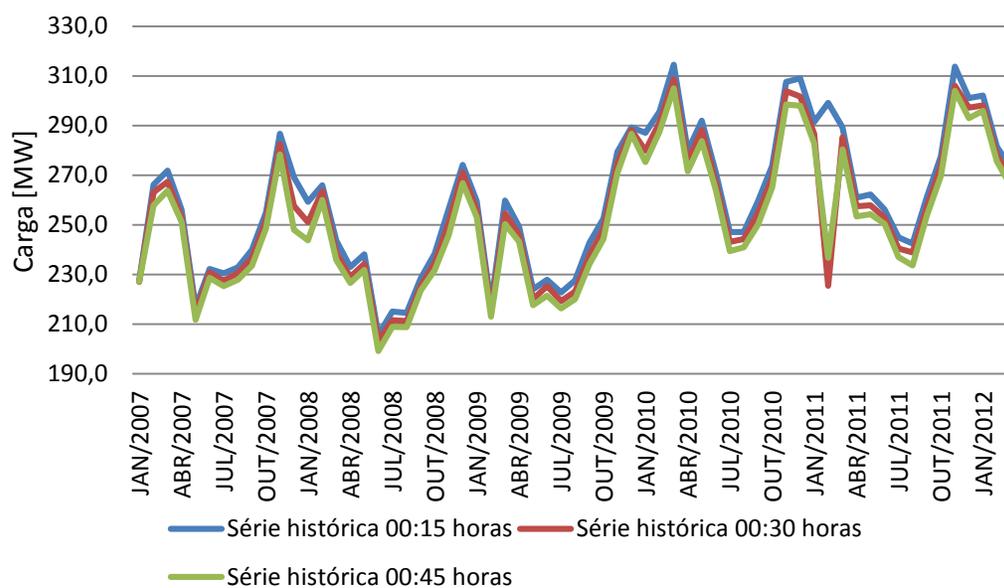


Figura 20 - Série histórica 1^a, 2^a e 3^a intervalo de tempo - Barramento I-Ag.I.

O processo realizado pelo Modelo I segue as etapas a seguir apresentadas. Este processo é utilizado para a previsão da carga crítica do intervalo de tempo m . Para todos os intervalos de tempo, o processo se repete.

- i) Para cada intervalo de tempo m da série história de curvas de carga crítica, cria-se uma série histórica com apenas as cargas críticas do intervalo m ;
- ii) Cria-se um modelo baseado em RNA para a previsão da carga crítica do intervalo m . Nos modelos testados nesta dissertação, utilizou-se sempre redes de três camadas, onde na camada de entrada considerou-se a carga crítica de intervalos anteriores. A escolha de quais entradas considerarem e qual técnica de treinamento utilizar foi através de uma busca exaustiva para cada método de treinamento apresentado na Seção 3.2.1. Nos casos de exemplo desta dissertação as melhores configurações de entradas foram 4 intervalos anteriores, e em relação aos métodos de treinamento, o método PR, junto com o método BFGS em alguns casos, obtiveram melhores resultados. A busca exaustiva para este método foi apenas a variação do número de neurônios na camada intermediária da rede *multilayer perceptron* (MLP), de 5 a 15 *perceptrons*. Ao terminar esta etapa,

tem-se o modelo de RNA constituído e treinado para a previsão de carga crítica do intervalo de tempo m ;

- iii) Tendo o modelo inteligente adequado para o intervalo de tempo m , faz-se a previsão da carga crítica em função das últimas informações disponíveis;
- iv) Realiza-se este procedimento para todos os intervalos horários e com as previsões, de cada discretização, constrói-se a previsão de um ou n meses a frente da curva de carga crítica.

Quando aplicado na previsão do próximo mês (um passo à frente), seu desempenho é razoável em termos do erro médio absoluto, mas apresenta alguns desvios significativos em termos de perfil. Quando faz-se a previsão sobre previsão, mais de um passo à frente, o seu desempenho piora sensivelmente e os perfis das curvas também são afetados.

Analisando-se as curvas de cargas críticas globais do Agente I, Figura 21, observa-se que na carga mínima, os meses de verão apresentam em geral os menores consumos e para os meses de inverno os maiores consumos. Já na carga média e pesada, as maiores cargas são registradas nos meses quentes, e as menores cargas no inverno. Ou seja, o perfil da curva crítica é bastante influenciado pelas condições climáticas, de modo que o mesmo varia ao longo do ano. Outra observação que deve ser destacada é a sazonalidade da curva crítica e também a existência de uma tendência de baixo grau.

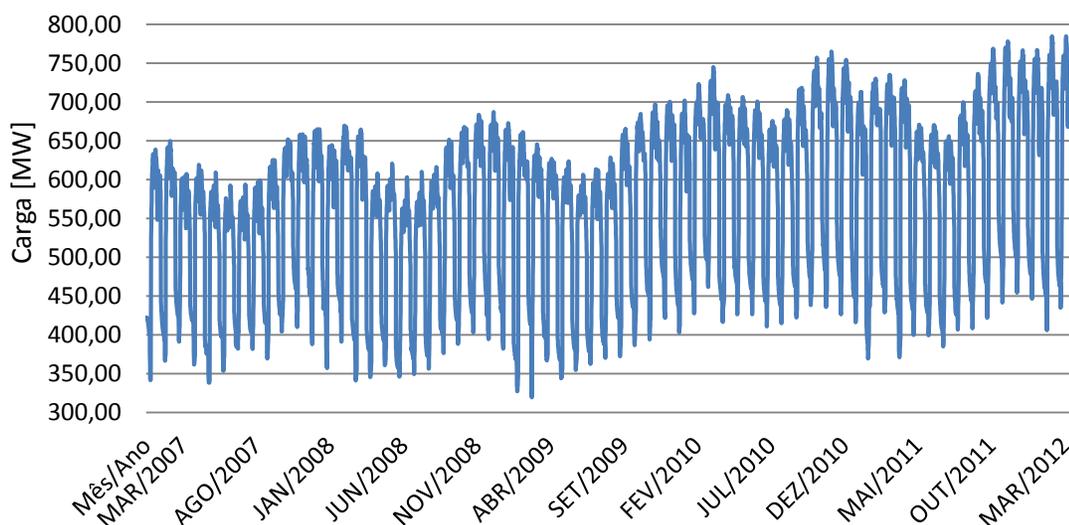


Figura 21 - Curva de carga crítica Jan. de 2007 a Mar. de 2012 - Global Agente I.

5.1.2 Modelo II

Como o Modelo I faz as previsões independentemente para cada intervalo de tempo, há a possibilidade de que o perfil da curva de carga crítica apresente desvios. Para minimizar estes desvios no perfil, implementou-se um outro modelo também baseado em RNA, que privilegia a manutenção do perfil da curva crítica. Este segundo método parte do princípio de que o perfil da curva de um dado mês será bastante próximo do perfil apresentado no mesmo mês em anos anteriores. Então, baseado no histórico, determina-se um perfil típico (em p.u.) para a curva crítica de cada mês do ano a ser previsto. Como este perfil é dado em p.u., então é necessário definir o nível deste perfil, ou seja, é preciso reescalar o perfil típico. Para isso, o segundo modelo (Modelo II) realoca o perfil baseado na previsão das cargas críticas máxima e mínima de cada mês. Ou seja, em vez de realizar a previsão de cada intervalo de tempo, faz-se somente duas previsões, das cargas críticas máxima e mínima em um dado mês. A partir destas previsões, a curva crítica do mês é obtida utilizando um perfil típico, que é utilizado para reconstruir os valores previstos. Os passos deste modelo são os seguintes:

- i) **Previsão da demanda máxima e mínima:** a previsão da carga crítica máxima de cada mês é obtida utilizando as Redes Neurais Artificiais apresentadas na Seção 3.2.1. A RNA selecionada utiliza como entrada valores críticos máximos verificados em meses anteriores e possui uma busca exaustiva da configuração dos parâmetros. A previsão da demanda crítica mínima também é obtida de forma similar, através de uma busca exaustiva procura-se um modelo e os parâmetros específicos para o histórico de carga mínima.
- ii) **Escolha do perfil típico de cada mês:** escolhe-se como perfil típico de um dado mês, o perfil em p.u. verificado no mesmo mês do ano anterior. Alternativa para esta escolha é o cálculo de um perfil médio dos mesmos meses dos anos do histórico. O perfil é criado a partir do valor máximo e mínimo de cada mês, seguindo a Equação 31, os valores resultantes pertencem ao intervalo de $[0; 1]$.
- iii) **Obtenção da curva crítica mensal:** a curva crítica do mês é obtida reescalando o perfil típico do mês em p.u. para os valores máximo e mínimo previstos. O cálculo inverso da Equação 31, Equação 32.

$$\tilde{h}_i = (h_i - \min(\mathcal{H})) / (\max(\mathcal{H}) - \min(\mathcal{H})) \quad \mathcal{H} \in \mathfrak{R}^n, i = 1, 2, \dots, n$$

Equação 31 - Normalização dos dados de entrada - Modelo II.

Sendo \mathcal{H} o mês calculado da curva de carga crítica a ser transformado em perfil, onde cada mês possui um intervalo horário de n elementos (exemplo 24 elementos para discretização horária) e h_i cada intervalo horário. Assim calcula-se todo o histórico em perfil para ser utilizado pela Equação 32 após as previsões dos valores de máximos e mínimos de cada mês.

$$\tilde{p}_i = (\tilde{h}_i * (\max_p - \min_p) + \min_p) \quad i = 1, 2, \dots, n$$

Equação 32 - Desnormalização dos dados de saída - Modelo II.

5.2 SUAUIZAÇÃO EXPONENCIAL SAZONAL DE HOLT-WINTERS

Observando que os dados de séries históricas da curva de carga crítica possuem sazonalidade e uma leve tendência. O modelo de suavização exponencial sazonal de Holt-Winters é adequado para realizar previsões sobre as mesmas. Os modelos de HW são adequados para previsões quando se tem poucas bases históricas, não sendo possíveis outras tentativas de modelos inteligentes devido à necessidade de um histórico com tamanho mínimo significativo.

Séries históricas que apresentam sazonalidade com leve tendência são mais indicadas para o modelo de série sazonal multiplicativa. As séries das curvas de carga crítica condizem com tal comportamento. Consequente a este fato, o modelo utilizado para a realização das previsões utilizando HW foi o multiplicativo.

Observou-se, através de análises estatísticas com auxílio do sistema SysPrev, que as condições de cargas máximas frente as condições de cargas mínimas, da mesma série temporal, comportavam-se de maneiras muito distintas. Concluiu-se que a realização da previsão das mesmas separadamente gera uma diminuição nos erros e facilita o trabalho com o modelo de HW. Então, a metodologia criada para realizar as previsões de uma série de carga crítica foi:

- i) Dada à série de curvas de cargas crítica S , calculadas a partir da carga global do Agente I dos anos 2007 e 2008, constroem-se duas séries históricas S_{inf} e S_{sup} , respectivamente a série inferior e a série superior, utilizando para série inferior S_{inf} de cada mês de curva crítica presente em S os dados dos intervalos horários do 1º intervalos até às 8 horas, e para série superior S_{sup} os dados a partir das 8 horas até às 24 horas. A Figura 22 apresenta a série superior e a Figura 23 apresenta a série inferior;
- ii) Em paralelo com o processo anterior, cria-se duas séries históricas M_{inf} e M_{sup} , respectivamente série da média inferior e média superior. Para cada mês de curva de carga crítica presente em S , calcula-se a média dos dados do intervalo de carga inferior (0h às 8h) e armazena o cálculo na série M_{inf} , o processo se repete para o intervalo de carga superior armazenando o cálculo na série M_{sup} . A Figura 24 apresenta as séries M_{inf} e M_{sup} construídas;

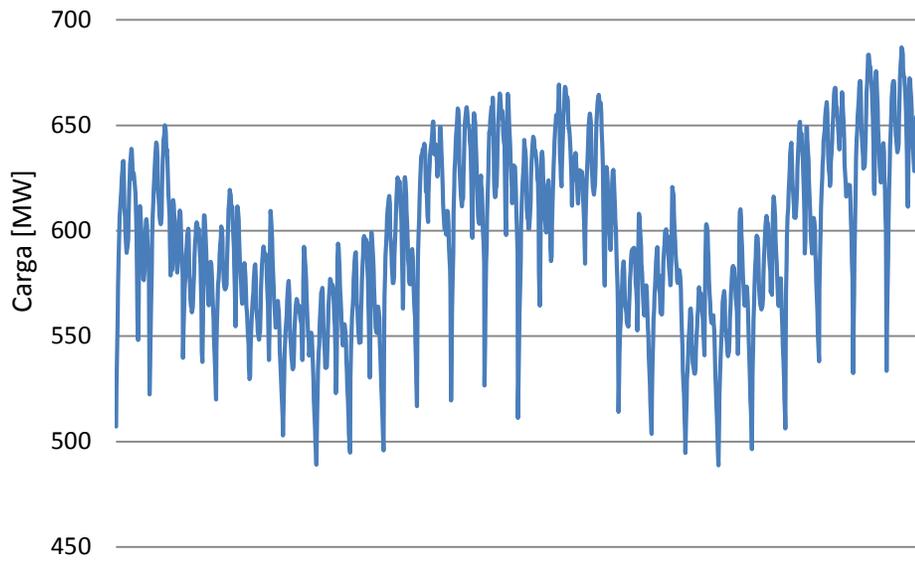


Figura 22 - Curvas de carga crítica divididas entre intervalo superior - 2007-2008 Agente I.

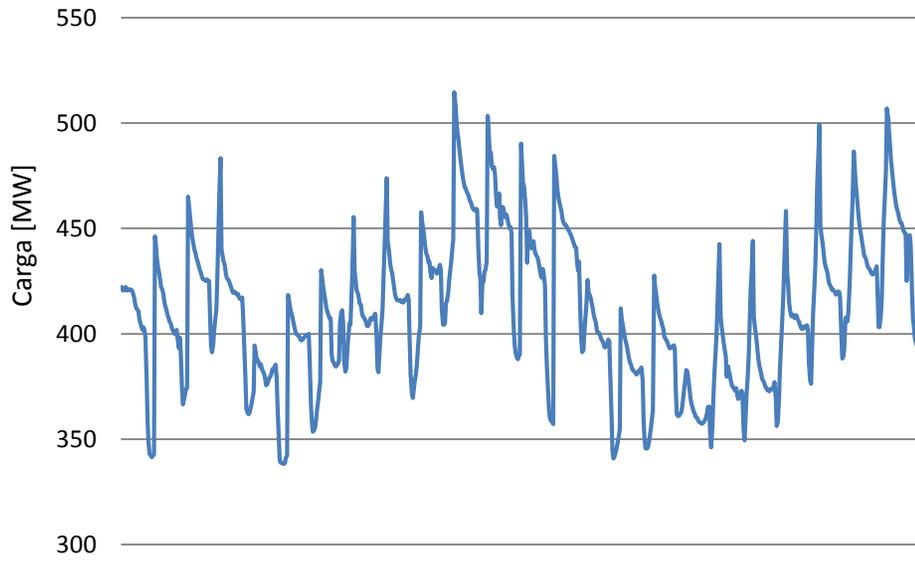


Figura 23 - Curvas de carga crítica divididas entre intervalo inferior - 2007-2008 Agente I.

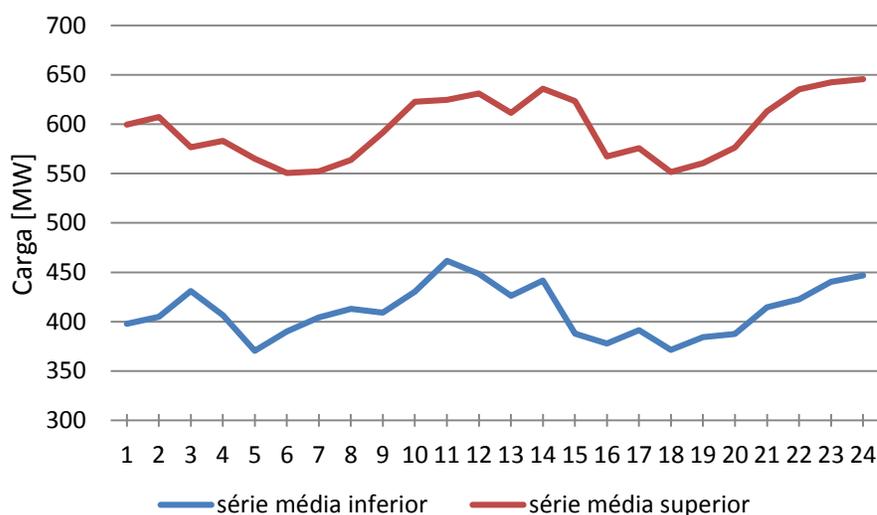


Figura 24 - Séries de médias de intervalos inferiores e superiores das curvas de carga crítica – 2007-2008 Agente I.

iii) Então utilizando as séries M_{inf} e M_{sup} calculadas, constroem-se mais duas séries P_{inf} e P_{sup} respectivamente série de perfil superior e inferior. A série P_{inf} armazena a divisão da série S_{inf} pela série M_{inf} . O mesmo cálculo aplica-se a série P_{sup} utilizando as séries superiores de cada variável. A Figura 25 e Figura 26 apresentam respectivamente o resultado do cálculo da série de perfil inferior seguido pelo resultado da superior;

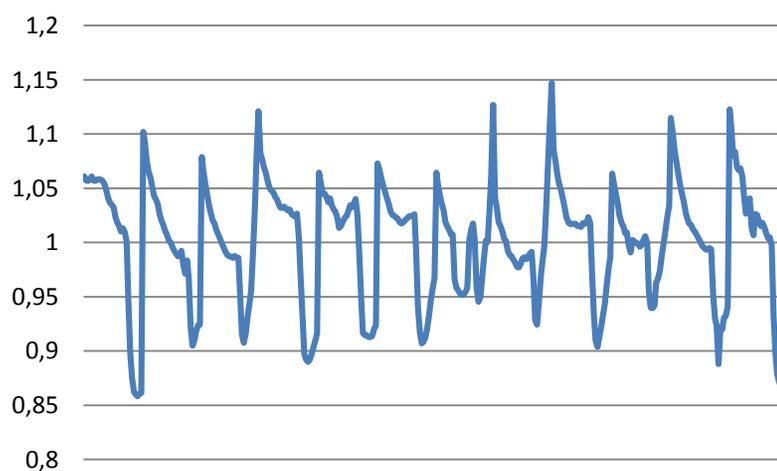


Figura 25 - Perfil série inferior curvas de carga crítica - 2007-2008 Agente I.

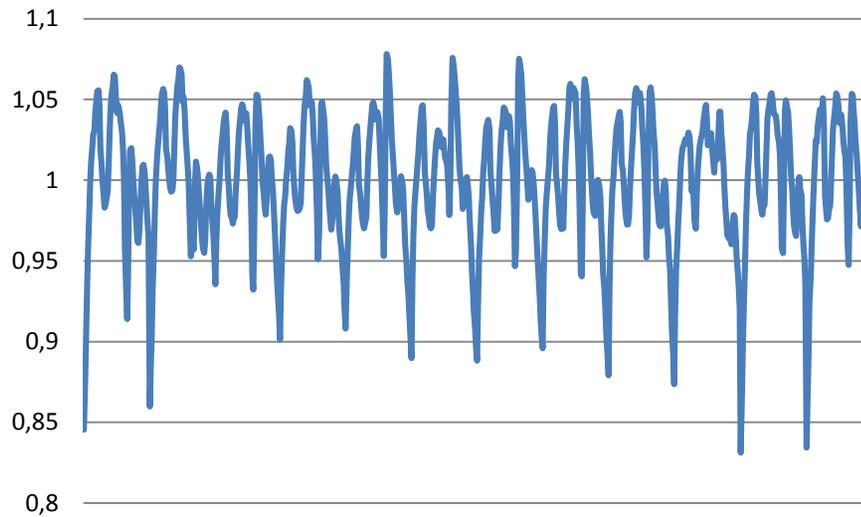


Figura 26 - Perfil série superior curvas de carga crítica - 2007-2008 Agente I.

- iv) Utilizando as séries médias inferiores e superiores, para cada uma, M_{inf} e M_{sup} , aplica-se o modelo de série sazonal multiplicativa, presente na Seção 3.2.2.1. Para o treinamento, utilizando os dados das séries passados como dados de treinamento, primeiramente aplica-se a suavização em seguida é realizada uma previsão, com esta previsão e o dado de treinamento esperado (o dado real) é possível calcular o erro obtido na previsão do treino. Se o erro não for aceitável, realiza-se uma busca exaustiva para definir as variáveis livres, as constantes de suavização A, C e D, buscando minimizá-lo. O cálculo do erro médio absoluto foi utilizado para os cálculos;
- v) Finalizado o treinamento, viabiliza-se a previsão dos dados futuros, inexistentes no histórico fornecido para o previsor, mas em caso de estudo reservado um histórico de teste, dividindo as séries em dois grupos antes das previsões, dados de treinamento e dados de teste;
- vi) Considerando PM_{inf} e PM_{sup} a previsão do valor da média inferior para um mês K e a previsão da média superior para o mesmo mês, é possível calcular o valor da curva de carga crítica prevista. Basta utilizar as séries de perfil, P_{inf} e P_{sup} , para calcular o valor de cada hora. Primeiramente, seleciona-se de cada série de perfil o mês K do ano anterior ao valor previsto. Obtendo P_{inf}^k e P_{sup}^k , respectivamente o perfil inferior e

superior do mês K do ano anterior à previsão. Para calcular a curva de carga crítica prevista, basta concatenar cada perfil, inferior e superior, multiplicado pelos valores de médias previstos, respeitando a separação dos inferiores e superiores. A Equação 33 apresenta tal cálculo, observando que a notação $[a; b]$, significa a concatenação da série a com a série b .

$$CurvaCargaCritica_{prevista} = [PM_{inf}.* P_{inf}^k; PM_{sup}.* P_{sup}^k]$$

Equação 33 - Cálculo curva de carga crítica prevista - Holt-Winters.

6

Resultados e Análises

Este capítulo apresenta os resultados da aplicação dos modelos e está organizado em seis partes. A Seção 6.1 apresenta o tratamento dos dados que deve ser feito antes das previsões. A Seção 6.2 apresenta as previsões de 1 passo à frente e a Seção 6.3 apresenta respectivamente as previsões de 2, 3 e 4 passos (meses) à frente. Na Seção 6.4 são apresentadas as análises e comparações dos resultados obtidos. Finalmente na Seção 6.5, são apresentadas simples análises de gastos computacionais das previsões.

As três séries de curva de carga crítica correspondem ao período de Janeiro de 2007 à Dezembro de 2011, com discretização de 15 minutos. Duas séries são da carga crítica global de dois agentes (distribuidores de energia elétrica), e da carga crítica de um barramento pertencente ao Agente I. As Figura 27, Figura 28 e Figura 29 representam respectivamente as séries do Agente II, Agente I e Barramento I-Ag.I.

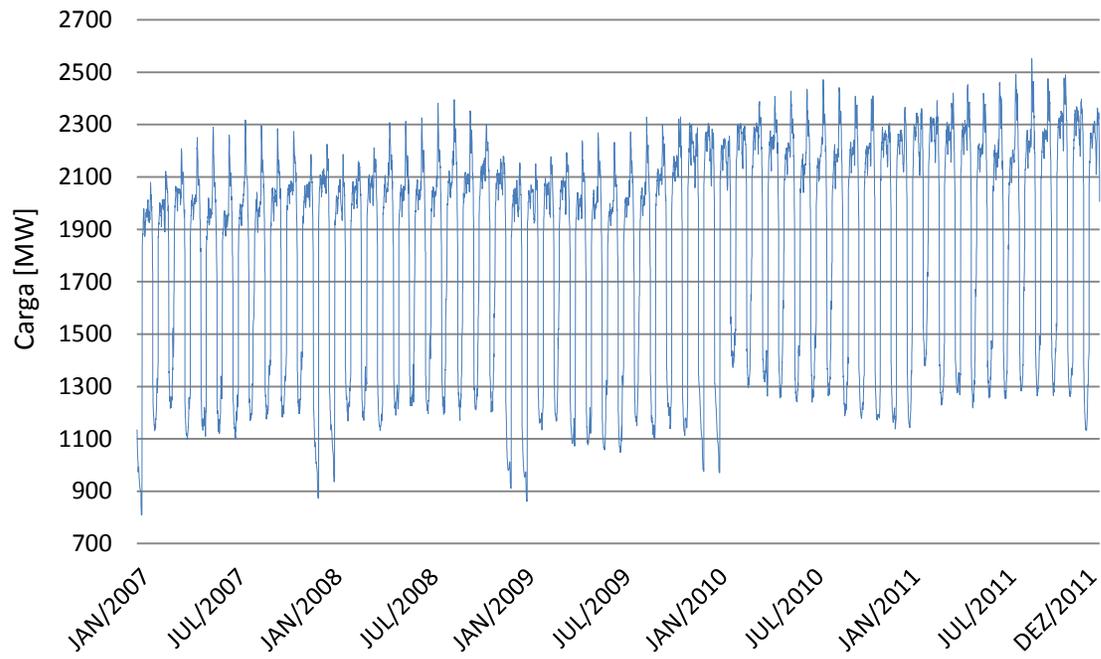


Figura 27 - Série curvas de carga crítica Jan. de 2007 à Dez. de 2011 – Agente II.

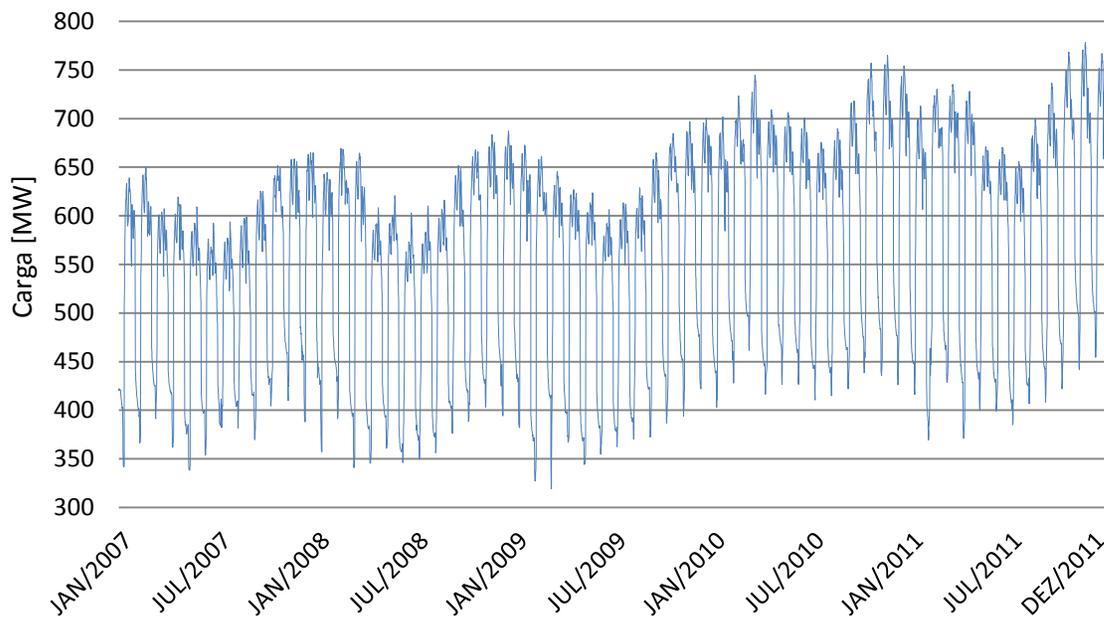


Figura 28 - Série curvas de carga crítica Jan. de 2007 à Dez. de 2011 – Agente I.

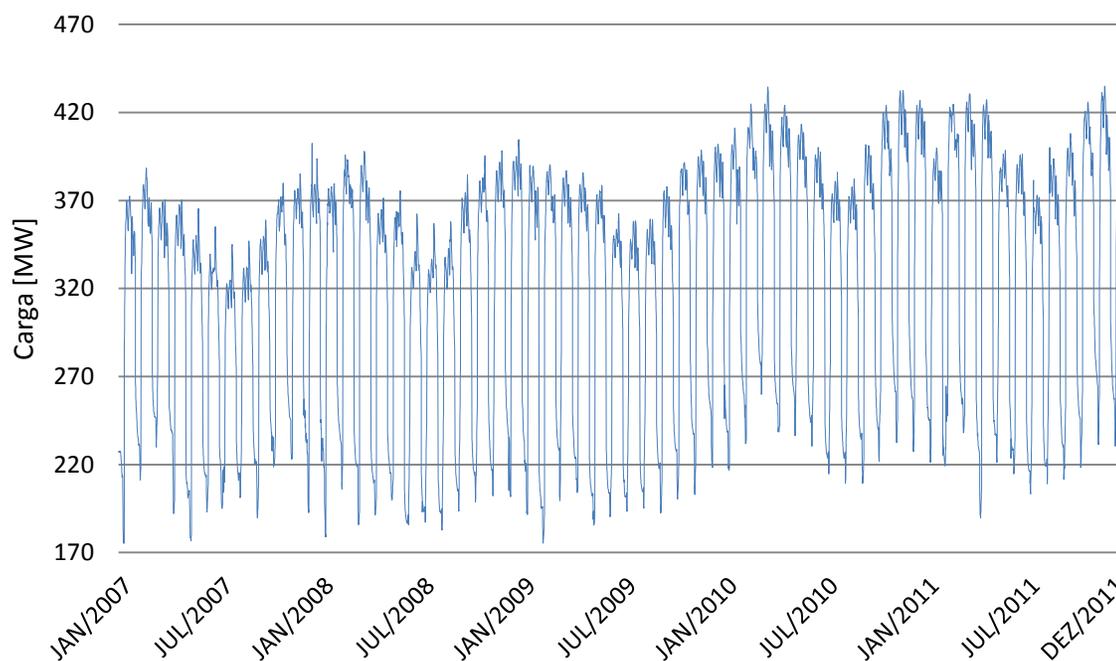


Figura 29 - Série curvas de carga crítica Jan. de 2007 à Dez. de 2011 - Barramento I-Ag.I.

Antes de realizar a previsão, é necessário realizar o tratamento dos dados históricos que compõem a curva de carga crítica. Os dados históricos podem conter dados atípicos (*outliers*) e transferência de carga entre barramento. Estas duas ocorrências podem alterar a composição da curva de carga crítica mensal e interferir diretamente nas previsões. Os itens a seguir apresentam primeiramente o processo de tratamento dos dados na Seção 6.1. Os resultados obtidos com relação às previsões do ano de 2011 nos históricos apresentados para 1 passo à frente, na Seção 6.2, e 2, 3 e 4 passos à frente na Seção 6.3.

6.1 TRATAMENTO DOS DADOS HISTÓRICOS

Para realizar a previsão de dados históricos, faz-se necessário possuir uma série histórica livre de *outliers*. Os dados de demanda de carga quase sempre possuem uma pequena porcentagem de dados atípicos. Isto pode ser atribuído a erros de medição, transmissão, digitação, ou ainda ser um dado correto, mas com um comportamento atípico. Estes dados precisam ser identificados e

substituídos, pois caso contrário podem interferir significativamente nas previsões. Quando trata-se de demanda por barramento, além dos possíveis *outliers*, há também uma possibilidade de transferência de carga. Associado a um dado barramento há um conjunto de consumidores atendidos por este ponto. Mas, no dia-a-dia da operação de uma rede de distribuição, parte dos consumidores de um dado barramento pode ser atendido através de outro barramento. Isto é realizado através de manobras na rede de distribuição e um dos principais motivos para isso é o serviço de manutenção. Essa transferência ocorre entre barramentos, do mesmo agente. Para os barramentos envolvidos na transferência é necessário estimar as curvas de carga sem a transferência, ou seja, “desfazer” a transferência. Esta retificação é importante, pois a transferência de carga altera o perfil e o nível de demanda tanto do barramento que recebe a transferência, quanto o barramento que cede a carga, podendo afetar o cálculo da série da curva de carga crítica e suas previsões. Assim, o procedimento para tratamento de dados adotado nesta dissertação primeiramente identifica e trata as transferências de carga entre barramentos do mesmo agente, mostrados nos Itens 6.1.3 e 6.1.2 e posteriormente, são identificados e tratados os dados atípicos (*outliers*), respectivamente Itens 6.1.3 e 6.1.4. É importante destacar que o tratamento de dados é realizado sobre o histórico de carga horário dos barramentos. A partir do histórico tratado é que se constrói o histórico de cargas críticas.

O processo de tratamento de dados desenvolvido nesta dissertação é dividido em quatro etapas. A primeira corresponde a etapa de identificação da ocorrência de uma transferência de dados. Neste processo sempre são identificados pares de barramentos, sendo um que cede carga e outro que recebe a transferência de carga. O objetivo da segunda etapa é “desfazer” a transferência de carga, ou seja, procurar estimar as curvas de carga horária sem a ocorrência da transferência. A terceira etapa do tratamento é responsável pela identificação dos dados atípicos. Finalmente, na quarta etapa tratam-se os *outliers* identificados na terceira etapa. Após a execução das quatro etapas, constrói-se o histórico de curvas de cargas críticas.

6.1.1 Identificação de transferência de carga

A transferência de carga em alguns casos é temporária e em outros definitiva. Aqui serão tratados os casos de transferências temporárias. Assim, se parte dos consumidores, conectados a

um barramento, são transferidos para outro barramento. Então, em uma situação normal, o barramento que recebeu os consumidores terá um acréscimo em sua demanda de carga, e o barramento que cedeu os consumidores terá um decréscimo. Um exemplo desta situação pode ser observado na Figura 30 contendo a demanda diária, do Barramento I-Ag.III do Agente III, no período de 16 de Janeiro a 15 de Fevereiro de 2006, para os dias de terça-feira à sexta-feira. Observe que as demandas diárias no início do mês de Fevereiro apresentam um nível de demanda superior aos dias anteriores, e a partir do dia 9 de Fevereiro a demanda retorna novamente aos padrões das semanas anteriores. Em uma pesquisa visual em outros barramentos do Agente III, nestes mesmos dias e com auxílio do Sistema SysPrev, foi identificado que o Barramento II-Ag.III havia apresentado um decréscimo de demanda, como mostra a Figura 31.

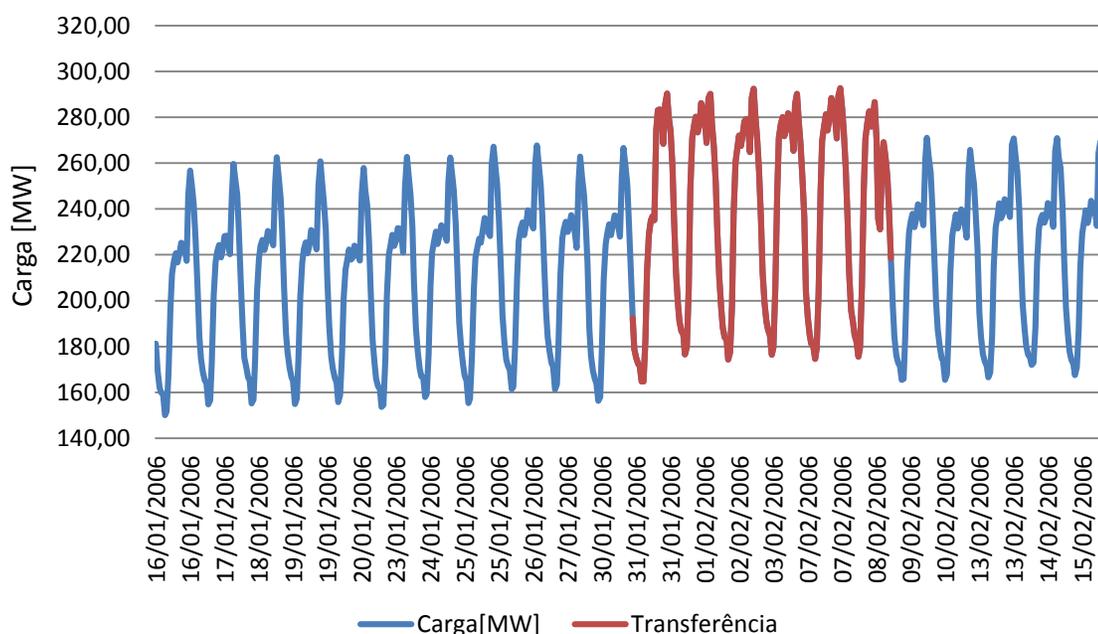


Figura 30 - Curva de carga diária Barramento I-Ag.III.

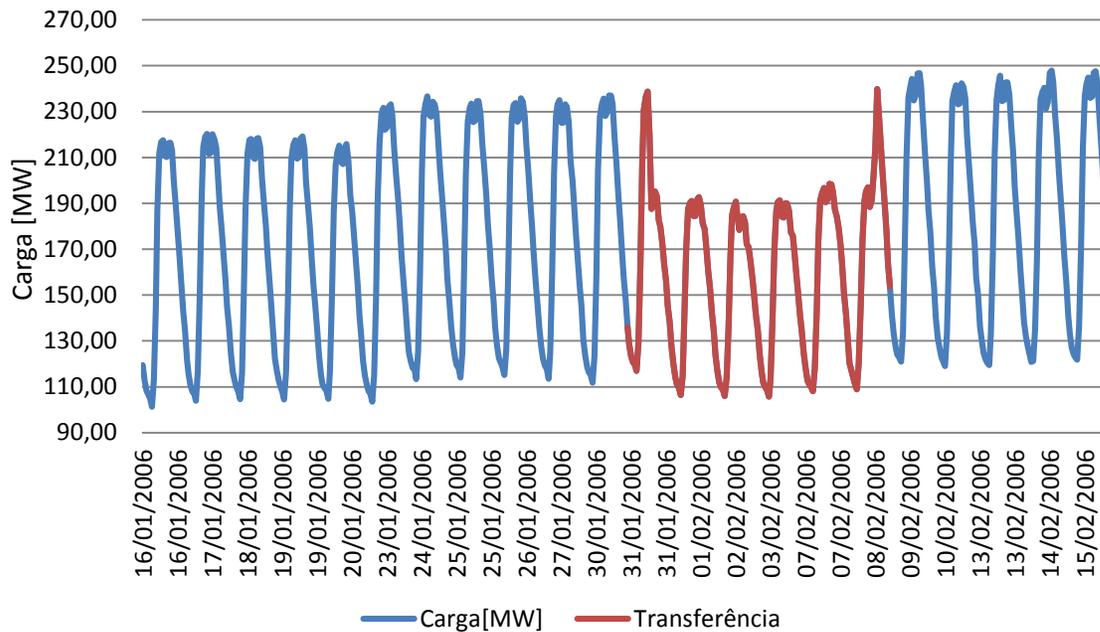


Figura 31 - Curva de carga diária Barramento II-Ag.III.

Baseado no fato de que o barramento que recebe a transferência de carga sofre um aumento de demanda, implementou-se um procedimento de identificação que calcula a variação da carga média diária de um dia para outro, como mostrado no gráfico da Figura 32. Onde, verifica-se que de fato nos dias iniciais do mês de Fevereiro a demanda média no Barramento I-Ag.III em relação à demanda média diária do mês anterior é significativamente superior. A variação negativa significa média diária superior à média do mês anterior. No final de Fevereiro, observa-se uma redução na demanda do Barramento I-Ag.III devido ao Carnaval de 2006 e no final de Março verifica-se mais uma redução na demanda devida ao feriado da Sexta-Feira Santa. Realizando o mesmo procedimento aplicado ao Barramento II-Ag.III, mostrado na Figura 33, observa-se que no início de Fevereiro houve uma redução em sua demanda, tendo um comportamento oposto ao Barramento I-Ag.III. Porém, no final de Fevereiro e final de Março houve redução na demanda como ocorreu também no Barramento I-Ag.III. A Figura 34 mostra a variação dos dois barramentos no mesmo gráfico, onde fica evidente o comportamento simétrico no início do mês. No entanto, nos dias a seguir, no início de Fevereiro observa-se o comportamento oposto, quando no Barramento II-Ag.III há um aumento significativo, mas no Barramento I-Ag.III há uma diminuição, mas em um valor de carga muito menor. Em uma comparação visual, esta diminuição

no Barramento I-Ag.III aparenta ser apenas uma flutuação em sua demanda. Neste caso, se for estabelecido que somente variações maiores, por exemplo, que 15 MW serão considerados como possíveis ocorrências de transferências, então estes dois casos seriam diferenciados. A Figura 35 mostra as variações nos barramentos, Barramento I-Ag.III e Barramento II-Ag.III, durante o segundo semestre de 2006, onde se identificam outras transferências, por exemplo, fim de Novembro. A Figura 36 mostra as variações na demanda, do ano 2006, do Barramento III-Ag.III e do Barramento IV-Ag.III, ambos do Agente III, onde também se observam transferências de carga, por exemplo, meio do mês de Março.

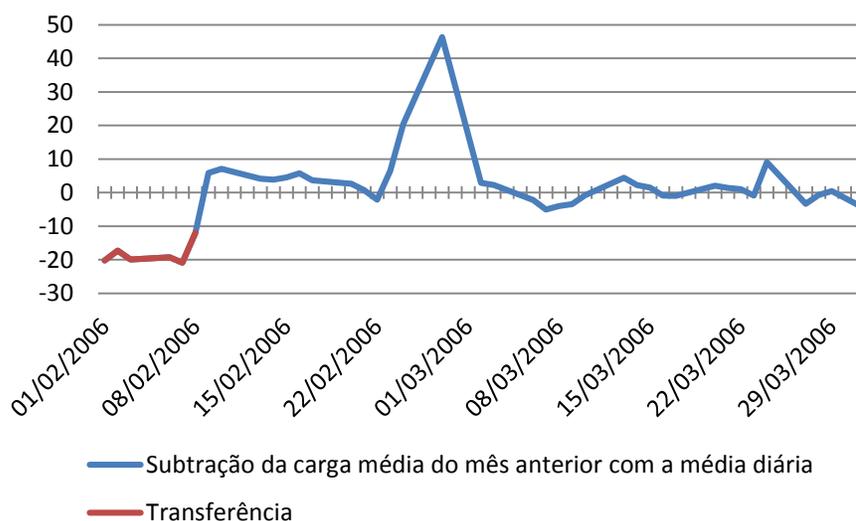


Figura 32 - Variação da demanda diária no Barramento I-Ag.III Jan. e Fev. de 2006.

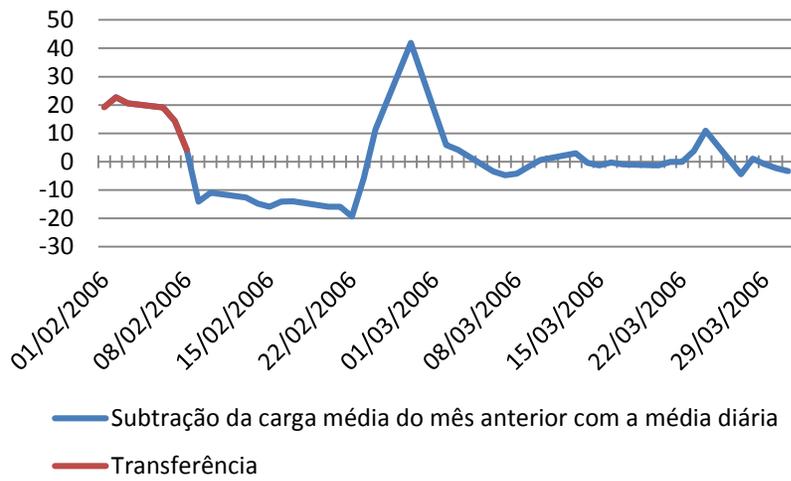


Figura 33 - Variação da demanda diária no Barramento II-Ag.III Jan. e Fev. de 2006.

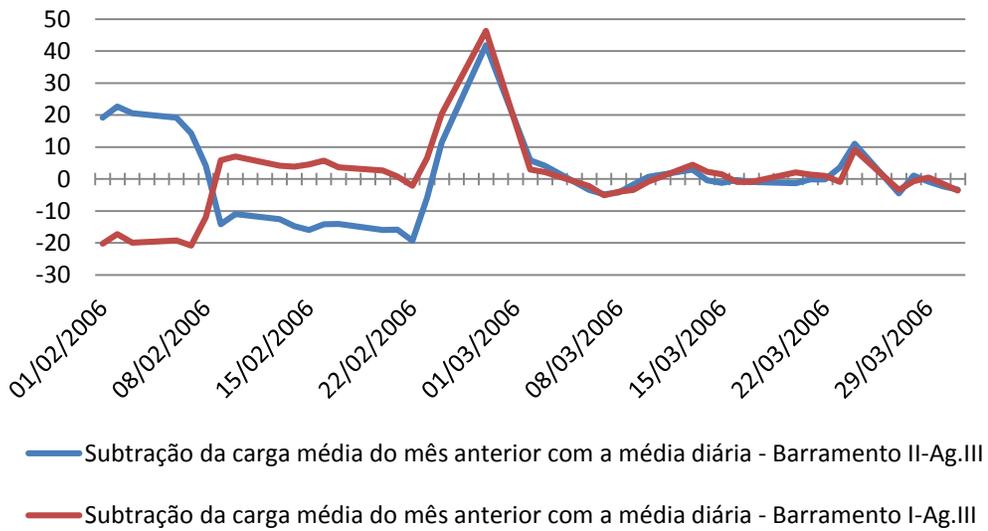


Figura 34 - Variação da demanda diária do Barramento I-Ag.III e Barramento II-Ag.III Jan. e Fev. de 2006.

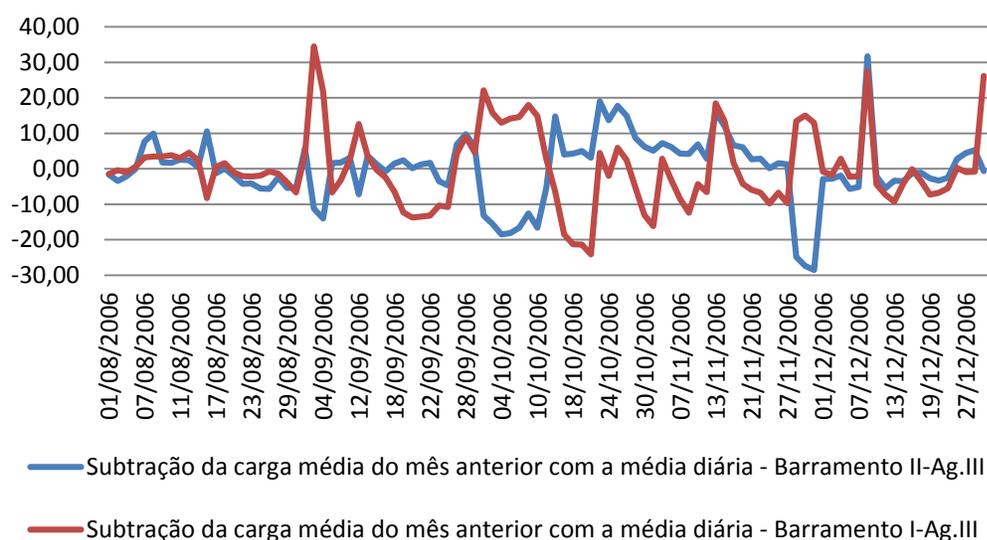


Figura 35 - Variação da demanda diária do Barramento I-Ag.III e Barramento II-Ag.III 2ºsem de 2006.

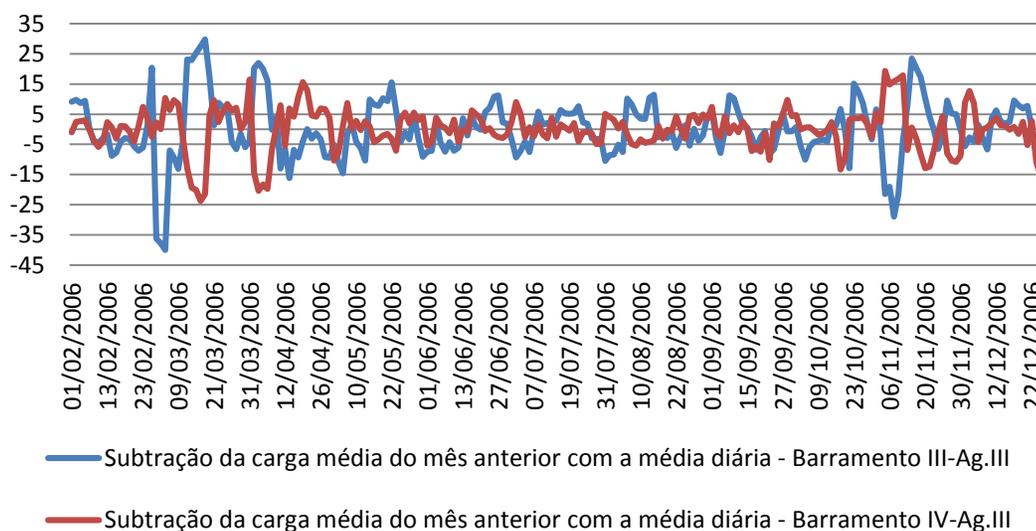


Figura 36 - Variação da demanda diária do Barramento III-Ag.III e Barramento IV-Ag.III em 2006.

A partir destas análises foi possível criar um procedimento para a identificação de transferência de carga, através dos seguintes passos:

- i) Calcula-se a demanda média diária dos barramentos;

- ii) Para um dado mês m : Calcula-se a demanda média mensal do mês anterior para dias do mesmo tipo (dias semanais). Calcula-se a variação da demanda média, de cada dia do mês m com média mensal do mês anterior;
- iii) Para os dias com variação maior que um dado valor δ , pesquisa-se se em algum outro barramento do mesmo agente houve uma variação significativa no sentido oposto. Se a identificação for positiva, então estabelece-se que neste dia houve transferência de carga entre estes barramentos. Em caso contrário, esta variação não é identificada como uma transferência de carga. Neste caso se a variação da demanda for muito grande, este dia poderá ser identificado (Seção 6.1.3) como atípico, para evitar incluí-lo nos conjuntos de treinamento.

O procedimento acima requer que a demanda do barramento não apresente grandes flutuações, pois isto dificulta o cálculo da variação da demanda média diária. No caso, por exemplo, de barramentos industriais que costumam apresentar grandes flutuações no consumo, esta variação na demanda se torna difícil de calcular, e conseqüentemente as transferências de carga são menos evidentes. Uma dificuldade deste procedimento é o estabelecimento do limiar δ para a variação da demanda média a partir do qual é considerado que houve transferência de carga. A definição deste limiar só pode ser realizada através da simulação de diferentes valores e análise dos seus resultados. Nos casos reais, no entanto, para que ocorra a transferência é necessário que os barramentos tenham “proximidade elétrica” de modo que facilmente possam transferir os consumidores. Este processo é realizado, em geral, através de operações de chaveamento. Assim, na prática as transferências sempre ocorrem entre o mesmo conjunto de barramentos. Então, para evitar que a cada possível transferência seja realizada uma busca entre todos os outros barramentos (passo (iii) do procedimento de identificação de transferência) verificando se existe ou não transferência, uma alternativa é detectar antes quais os barramentos são “vinculados” (que fazem transferência de carga entre eles). Assim, a verificação de transferência fica restrita apenas entre os barramentos vinculados.

O Quadro 1 mostra os barramentos vinculados identificados para uma variação da demanda média diária em relação à demanda diária média do mês anterior, para um limiar (δ) de 15 MW. Ou seja, se para um barramento em um dado dia possuir a variação da demanda diária em relação à demanda diária média do mês anterior maior, em valores absolutos, de 15MW, então para este

dia pesquisa-se outros barramentos. Para este limiar foram identificados cinco vínculos, como mostrados no Quadro 1. No vínculo de número 4, foi identificado que o Barramento II-Ag.III fez transferências com o Barramento I-Ag.III e o Barramento V-Ag.III. Os demais vínculos são, entre dois barramentos.

Quadro 1 - Barramentos vinculados do Agente III.

Vínculo	Barramento	Fez transferência para o Barramento	
1	Barramento III-Ag.III	Barramento IV-Ag.III	
2	Barramento I-Ag.III	Barramento II-Ag.III	
3	Barramento IV-Ag.III	Barramento III-Ag.III	
4	Barramento II-Ag.III	Barramento I-Ag.III	Barramento V-Ag.III
5	Barramento V-Ag.III	Barramento II-Ag.III	

6.1.2 Tratamento de transferência de carga

Uma vez identificado as transferências de carga, o próximo passo é estimar as demandas nos barramentos envolvidos sem o efeito da transferência. Para estes casos, a solução adotada é substituir toda a curva de demanda diária pela curva diária média observada nas últimas semanas, para o mesmo tipo de dia, do mesmo barramento. A curva diária será substituída segundo o procedimento a seguir apresentado. Supõe-se já identificado uma transferência de carga.

- i) Calcula-se o perfil diário médio em p.u. para o mesmo tipo de dia verificado nas últimas três semanas;
- ii) Reescala-se a curva média em p.u. levando em conta a curva média semanal em p.u..

Observa-se em geral que a demanda média diária ao longo de uma semana costuma apresentar maiores demandas no meio da semana. Isso pode ser observado na Figura 37, que mostra as cargas médias diárias para o Barramento II-Ag.III em uma semana de Março de 2006, onde se observa que as cargas médias de terça-feira e quarta-feira são um pouco superiores às demandas médias da segunda-feira, quinta-feira e sexta-feira. Este é um padrão que se observa na maioria dos

barramentos. Ou seja, a nova curva de carga diária será obtida reescalando a curva média em p.u. para um valor médio que esteja de acordo com a curva semanal. A Figura 38 e Figura 39 apresentam o tratamento da transferência de carga, mostrado na Seção 6.1.1, no período de 16 de Janeiro a 15 de Fevereiro de 2006, respectivamente do Barramento I-Ag.III e Barramento II-Ag.III. Vale ressaltar que as segundas-feiras não foram tratadas devido a similaridade com dia pós-feriados, devendo as mesmas serem tratadas em uma série em conjunto com domingos, feriados e pós-feriados, devido semelhanças. O dia primeiro de Maio, também não foi considerado, pelo motivo de ser feriado nacional, Dia do Trabalhador.

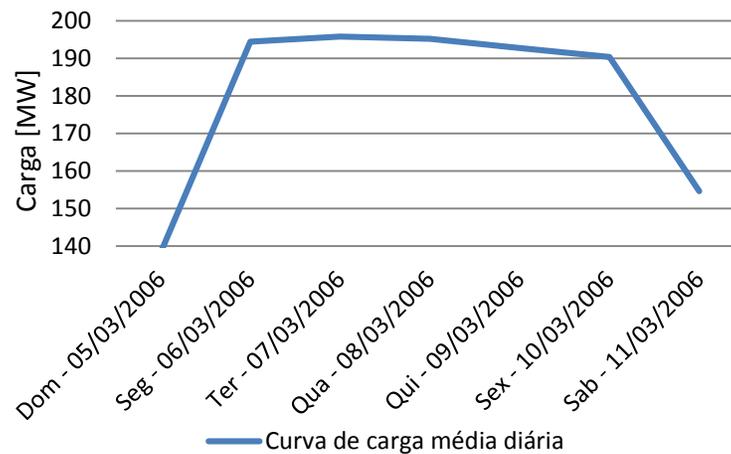


Figura 37 - Perfil carga média semanal comum - Fev. de 2006 Barramento II-Ag.III.

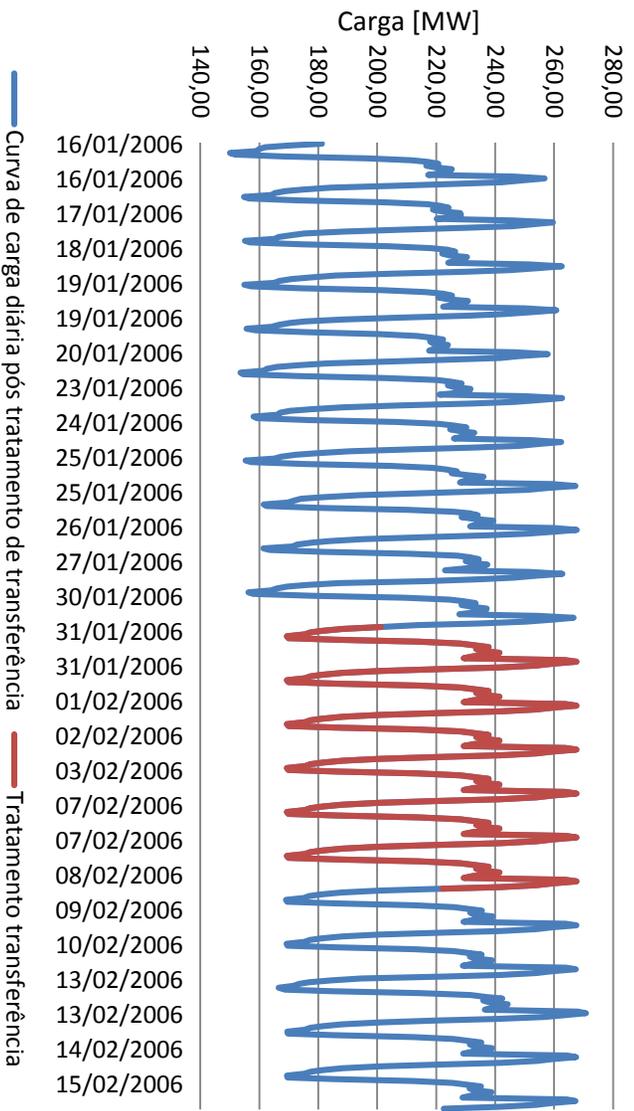


Figura 38 - Curva de carga diária do Barramento I-Ag. III com tratamento de transferência de carga.

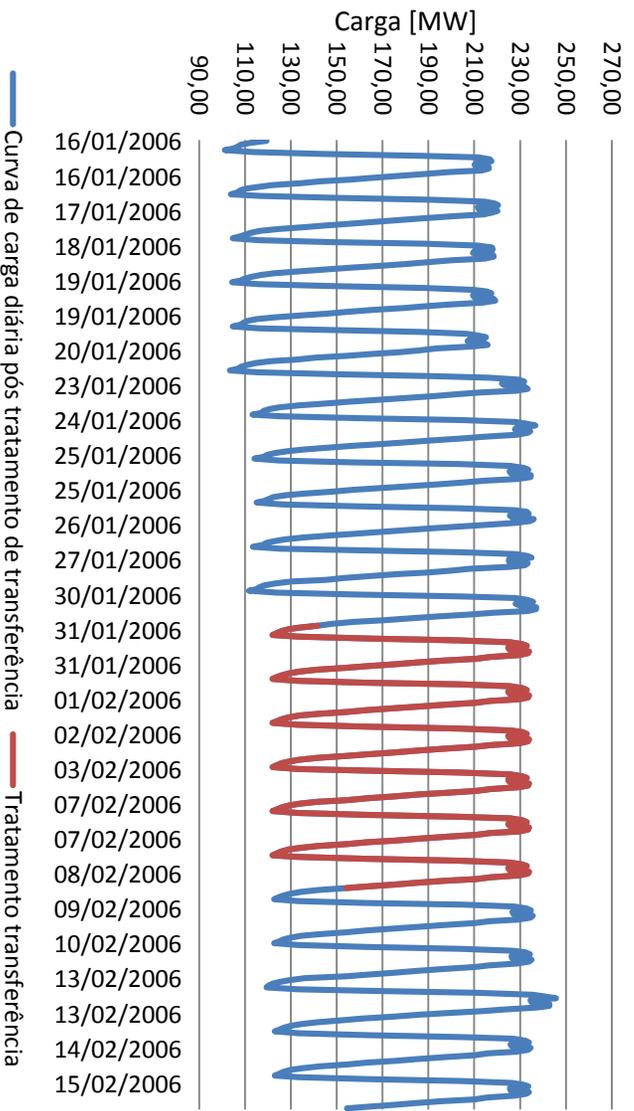


Figura 39 - Curva de carga diária do Barramento II-Ag. III com tratamento de transferência de carga.

6.1.3 Identificação de *outliers*

Após as identificações e tratamentos das transferências, o próximo passo é a identificação de dados atípicos, os chamados *outliers*. A identificação de carga atípica é baseada na ideia de que há um comportamento padrão, e assim a carga atípica é aquela que se afasta significativamente deste padrão. Na implementação do procedimento para identificação de carga atípica, adotou-se como o comportamento padrão a carga média verificada nas últimas três semanas. A Figura 40 apresenta um caso de carga atípica no Barramento I-Ag.I, pertencente ao Agente I, do período de 23 a 30 de Abril de 2007. A Figura 41 mostra a curva original do dia 25 de Abril de 2007 e a curva mediana correspondente à curva média dos dias anteriores. Em torno da curva média estabelece-se uma faixa, no caso de 20% do valor da curva média, e todas as cargas fora desta faixa são consideradas atípicas (*outliers*). A Figura 42 mostra que as cargas dos intervalos 18:30h e 18:45h estão fora da faixa (abaixo da faixa mínima), e portanto estas são consideradas *outliers*.

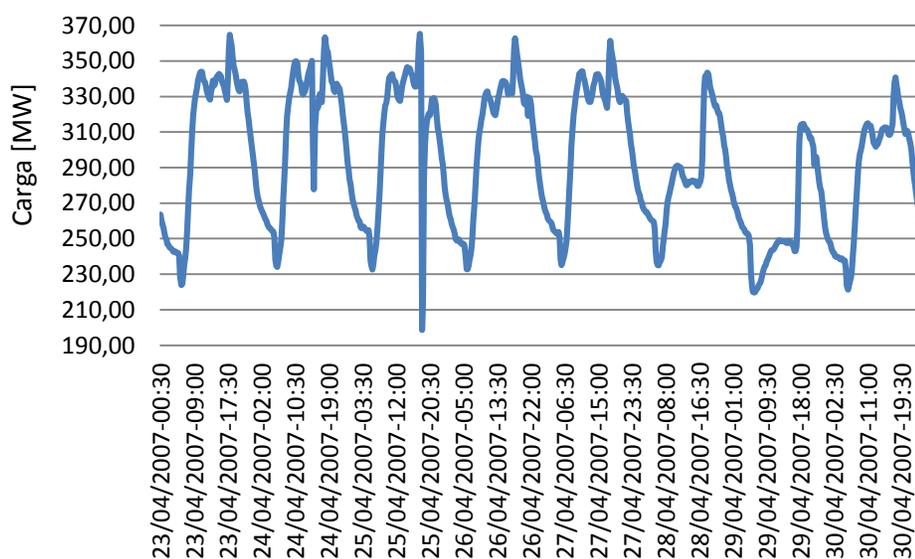


Figura 40 - Curva de carga diária com *outlier* - Barramento I-Ag.I.

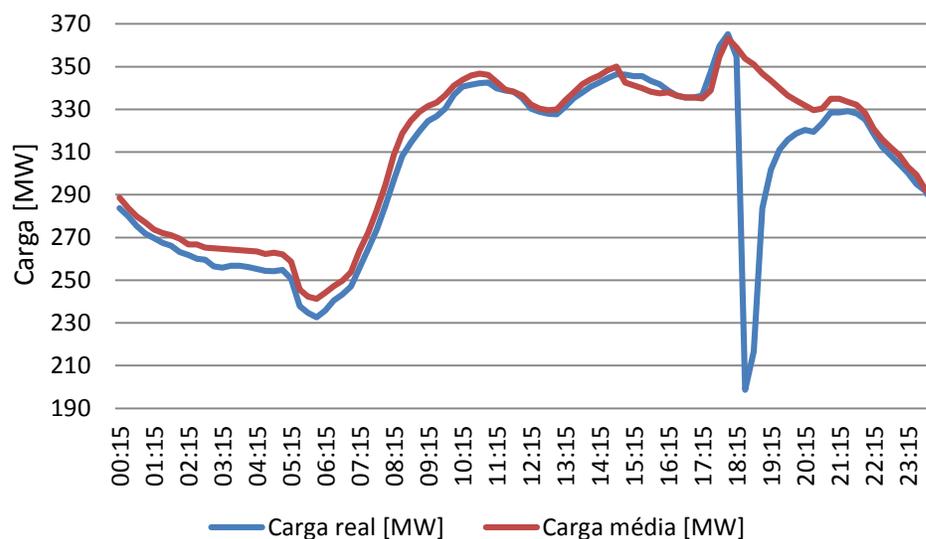


Figura 41 - Curva de carga média e curva de carga real com *outlier* – Barramento I-Ag.I.

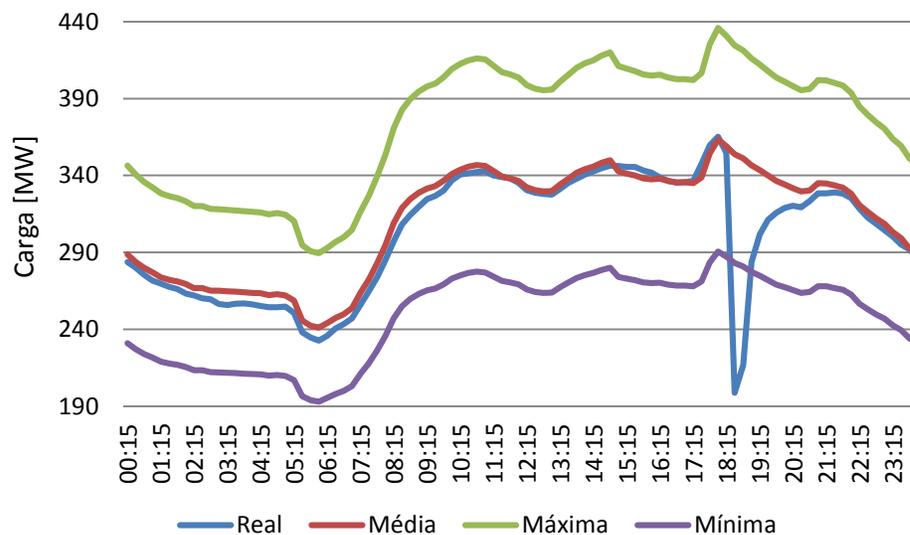


Figura 42 - Curva de carga diária e limitantes para identificação de *outliers* - Barramento I-Ag.I.

6.1.4 Tratamento de *outliers*

A substituição da carga atípica é baseada na curva média. A ideia é substituir os dados relativos às cargas atípicas por uma curva com perfil similar à curva média neste intervalo, mas

adaptado ao restante da curva que não será alterado. A curva média calculada representa a média das últimas três semanas para o mesmo tipo de dia.

Caso um dia inteiro seja considerado atípico e o mesmo não tenha sido identificado como transferência de carga, este algoritmo irá substituí-lo totalmente pela curva média. A Figura 43 mostra o tratamento do *outlier* identificado na Seção anterior, 6.1.3, e no caso o tratamento chegou a substituir a curva real do intervalo de 18:15h até o limite superior pela curva média.

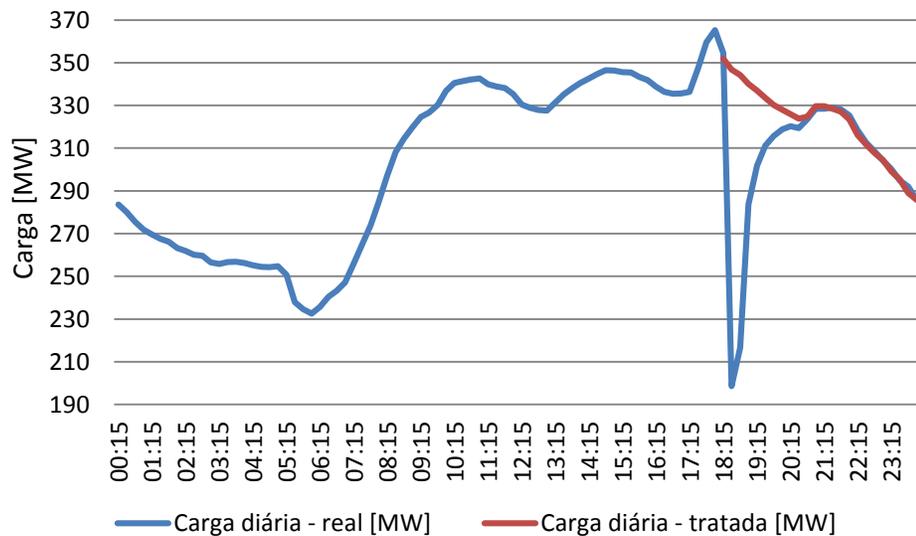


Figura 43 - Tratamento de dado atípico (*outliers*).

6.2 PREVISÕES UM PASSO À FRENTE

Esta Seção apresenta o resultado das previsões realizadas para um passo à frente (um mês) para todos os modelos propostos com relação às três séries históricas propostas no início deste capítulo.

6.2.1 Resultados modelo I

6.2.1.1 Resultados modelo I - Agente II

Todas as séries foram previstas pelo modelo I, e para cada série foram testados todos os métodos de treinamento da Seção 3.2.1. Os erros médios na simulação da carga crítica global do Agente II são apresentados na Tabela 4. Observa-se que a menor média dos erros médios absolutos foi obtida pelo método de treinamento BPM, com 2,86%.

Tabela 4 - Erro médio absoluto métodos RNAs - Agente II - 1 passo à frente.

GRAD	BFGS	DFP	OSS	PR	FR	SCGM	BPM
3,44%	3,89%	3,87%	3,67%	3,23%	3,38%	3,57%	2,86%

A Figura 44 apresenta as previsões de um passo à frente, utilizando o método de treinamento BPM, para as RNAs das 96 discretizações, no período de 2011. Nestas previsões, nota-se os maiores erros na previsão das cargas baixas. A Figura 45 mostra o mesmo resultado, mas conjuntamente com todo o histórico utilizado para treinamento e validação.

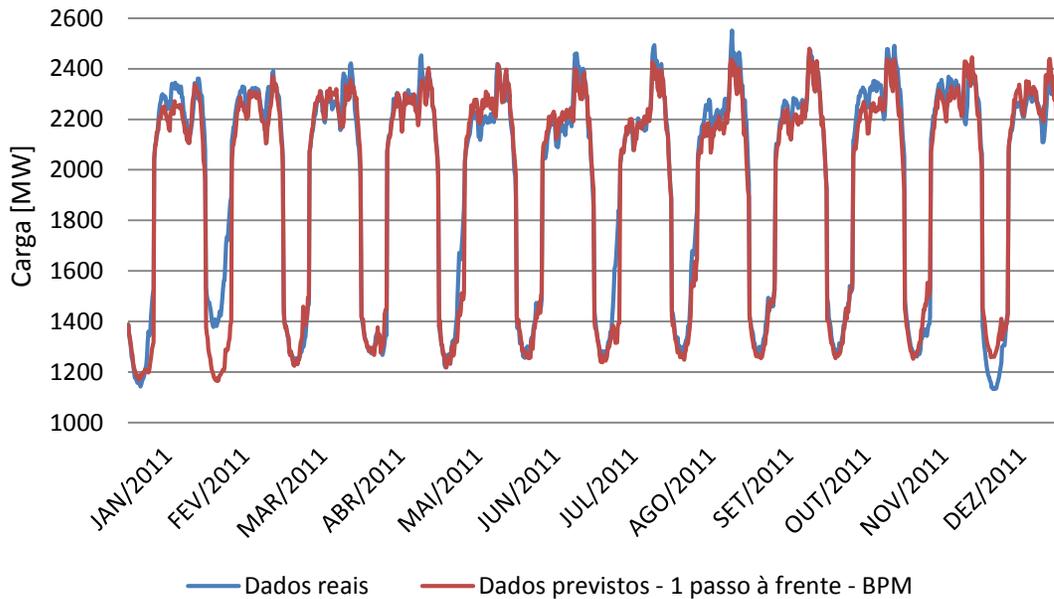


Figura 44 - Resultado previsão modelo I - 2011 Agente II - 1 passo à frente.

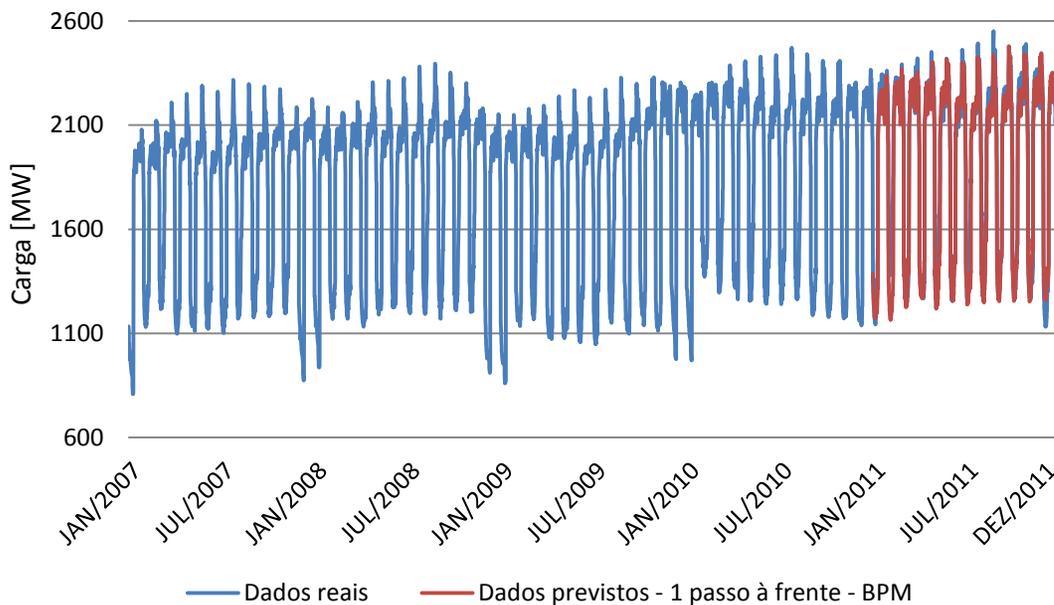


Figura 45 - Resultado previsão modelo I comparado ao histórico total - 2011 Agente II - 1 passo à frente.

Pode-se observar que o comportamento da série em Fevereiro de 2010 não segue um padrão de amplitude dos perfis que se apresentam em outros anos. Mas, mesmo apresentando este erro de previsão o erro médio absoluto pode ser considerado bom.

6.2.1.2 Resultados modelo I - Agente I

Os resultados das previsões, de um passo à frente, da série do Agente I podem ser observados na Tabela 5. Ela expõe o erro médio absoluto dos métodos para a previsão de 2011. Pode-se observar que o método BPM foi o que obteve menor erro junto com o método PR.

Tabela 5 - Erro médio absoluto métodos RNAs - Agente I - 1 passo à frente.

GRAD	BFGS	DFP	OSS	PR	FR	SCGM	BPM
4,73%	4,49%	4,49%	4,78%	4,04%	4,62%	4,25%	3,99%

A Figura 46 e Figura 47 apresentam os resultados das previsões dos dois métodos, BPM e PR, de forma gráfica para o ano de 2011.

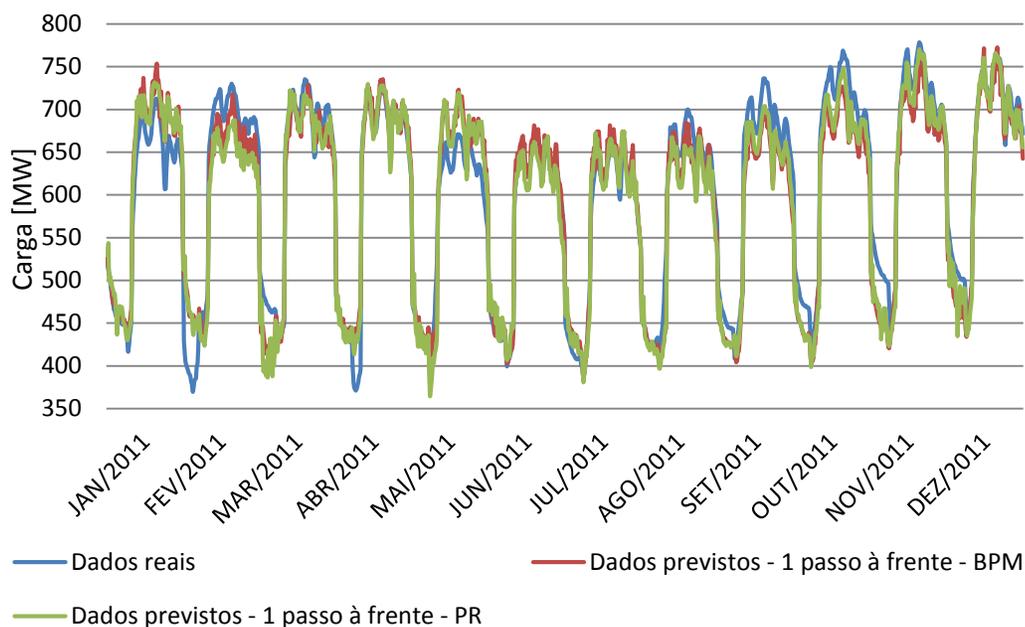


Figura 46 - Resultado previsão modelo I - 2011 Agente I - 1 passo à frente.

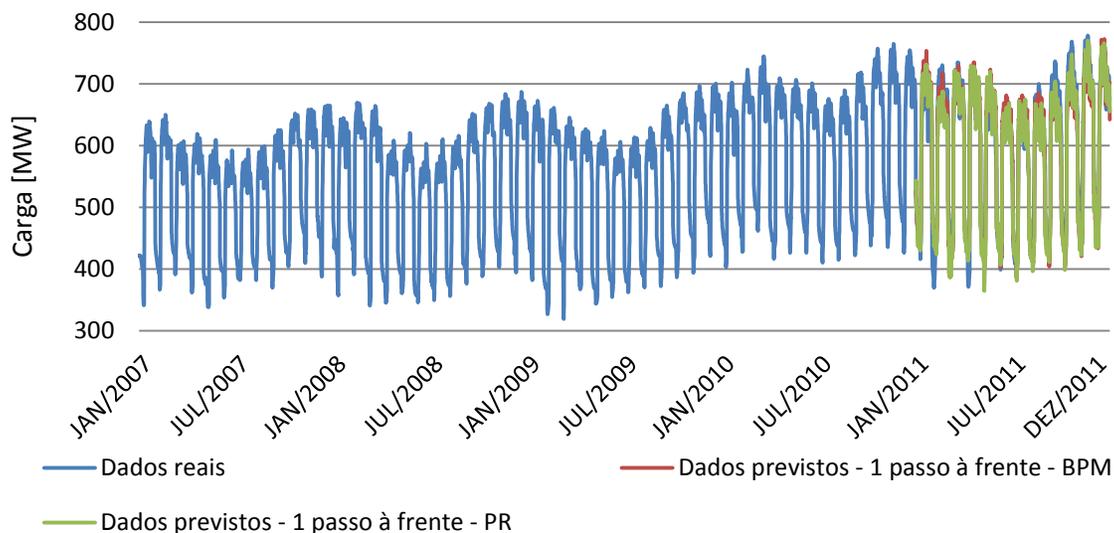


Figura 47 - Resultado previsão modelo I comparado ao histórico total - 2011 Agente I - 1 passo à frente.

Pelos gráficos presentes nas Figura 46 e Figura 47 é possível notar que os dois métodos se comportaram praticamente da mesma maneira, conseguindo representar a sazonalidade e a tendência existente. Aqui se observa alguns grandes erros tanto na carga alta, como na carga baixa.

6.2.1.3 Resultados modelo I - Barramento I-Ag.I

Para a série histórica do Barramento I-Ag.I, o método de treinamento BPM se mostrou a melhor opção para um passo à frente. A diferença com relação aos outros métodos foi mínima, a Tabela 6 apresenta os erros percentuais médios obtidos por cada método para a previsão de um passo à frente para a previsão de todos os meses de 2011.

Tabela 6 - Erro médio absoluto métodos RNAs - 1 passo à frente.

GRAD	BFGS	DFP	OSS	PR	FR	SCGM	BPM
4,80%	4,87%	4,46%	4,92%	4,33%	4,77%	4,55%	4,11%

A Figura 48 mostra as previsões do ano de 2011, utilizando o método BPM, comparadas com os dados reais, e a Figura 49 apresenta as mesmas previsões plotadas em conjunto com a série de curvas críticas utilizada para realizar as previsões.

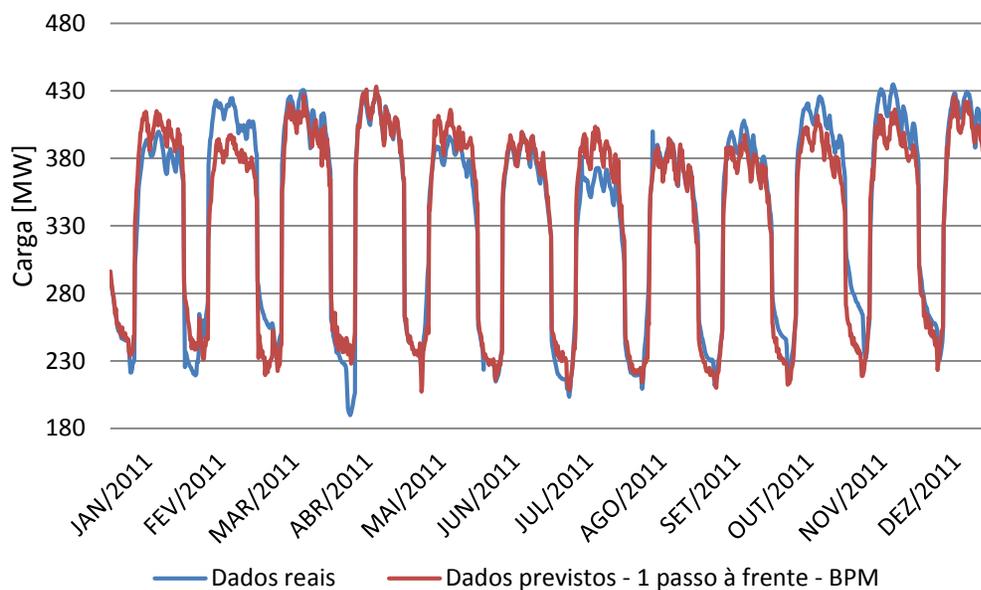


Figura 48 - Resultado previsão modelo I - 2011 Barramento I-Ag.I - 1 passo à frente.

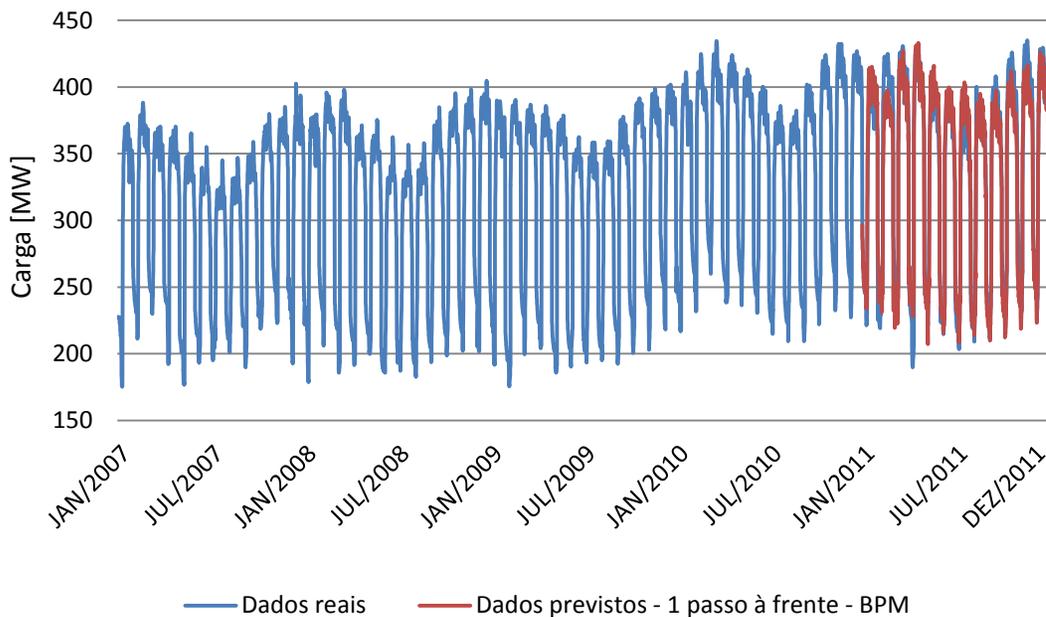


Figura 49 - Resultado previsão modelo I comparado ao histórico total - 2011 Barramento I-Ag.I - 1 passo à frente.

Os resultados para um passo à frente para esta série são satisfatórios, pode-se observar que foi possível modelar a sazonalidade e a leve tendência que a mesma possui.

6.2.2 Resultados modelo II

6.2.2.1 Resultados modelo II – Agente II

Nesta Seção são apresentadas as previsões obtidas, utilizando o modelo II, de um passo à frente.

A Tabela 7 apresenta os erros médios absolutos dos métodos das RNAs para as previsões das cargas máximas e cargas mínimas, de um passo à frente. Observe que para as previsões de carga máxima o método FR obteve o menor erro, e para as cargas mínimas o método BPM.

Tabela 7 - Erro médio absoluto métodos RNAs - modelo II – Agente II - 1 passo à frente.

Erro médio absoluto	GRAD	BFGS	DFP	OSS	PR	FR	SCGM	BPM
Carga máxima	1,75%	1,85%	1,69%	2,26%	1,72%	1,66%	1,79%	1,76%
Carga mínima	4,66%	5,37%	6,00%	6,79%	6,24%	6,20%	5,78%	3,37%

A Figura 50 e Figura 51 apresentam respectivamente as previsões realizadas, pelo método FR, para as cargas máximas e as previsões realizadas, pelo método BPM, para as cargas mínimas.



Figura 50 - Previsões máximas - modelo II - 2011 Agente II – 1 passo à frente.



Figura 51 - Previsões mínimas - modelo II - 2011 Agente II – 1 passo à frente.

Analisando os gráficos, Figura 50 e Figura 51, fica claro que não foi possível prever o perfil dos valores extremos das curvas críticas. Porém, as previsões não sofreram grandes perdas com este ocorrido, pois obteve-se uma previsão média. A partir das previsões das cargas médias, máximas e mínimas, é calculada a curva de carga crítica horária, apresentada na Figura 52. Utilizando o modelo FR para prever os resultados de carga máxima e o modelo BPM para prever os resultados de carga mínima, o modelo II resultou em um erro de 3,46%.

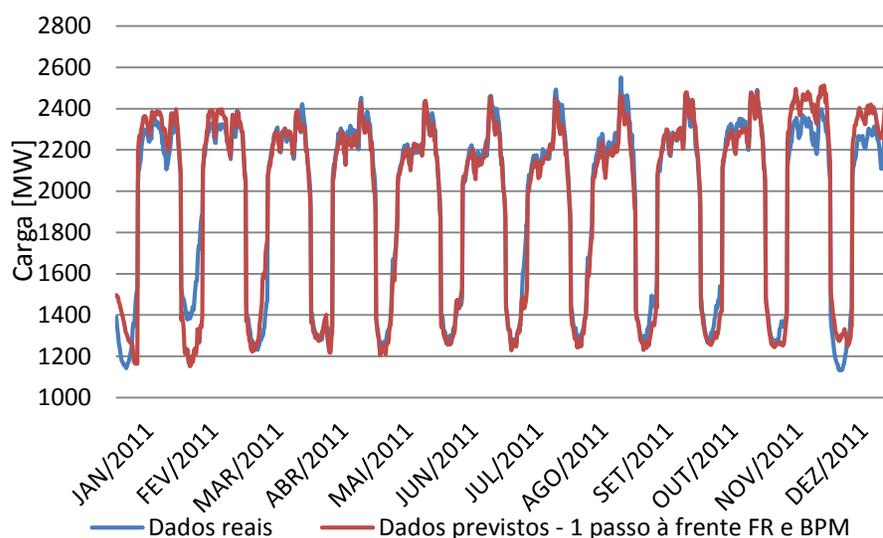


Figura 52 - Resultado previsão modelo II - 2011 Agente II - 1 passo à frente.

Observa-se que o modelo II conseguiu prever os máximos e mínimos próximos da carga média. Consequente a este fato, o mesmo obteve bons resultados na previsão de um passo à frente, seguindo a sazonalidade e tendência. A configuração das RNAs FR e BPM foi de três camadas, 4 neurônios na primeira, 8 na intermediária e um na saída, representando a previsão do máximo ou mínimo dependendo do método.

6.2.2.2 Resultados modelo II – Agente I

Para a série do Agente I os resultados nas previsões dos extremos, para um passo à frente, pode ser observado na Tabela 8. O método PR e BPM foram os que apresentaram menor resultado. A Figura 53 apresenta o gráfico para as previsões da carga máxima e a Figura 54 apresenta as previsões de carga mínima.

Tabela 8 - Erro médio absoluto métodos RNAs - modelo II – Agente I - 1 passo à frente.

Erro médio absoluto	GRAD	BFGS	DFP	OSS	PR	FR	SCGM	BPM
Carga máxima	4,29%	4,44%	3,77%	3,95%	2,87%	4,87%	3,08%	3,14%
Carga mínima	5,02%	5,11%	5,19%	5,17%	4,69%	5,04%	4,77%	4,35%

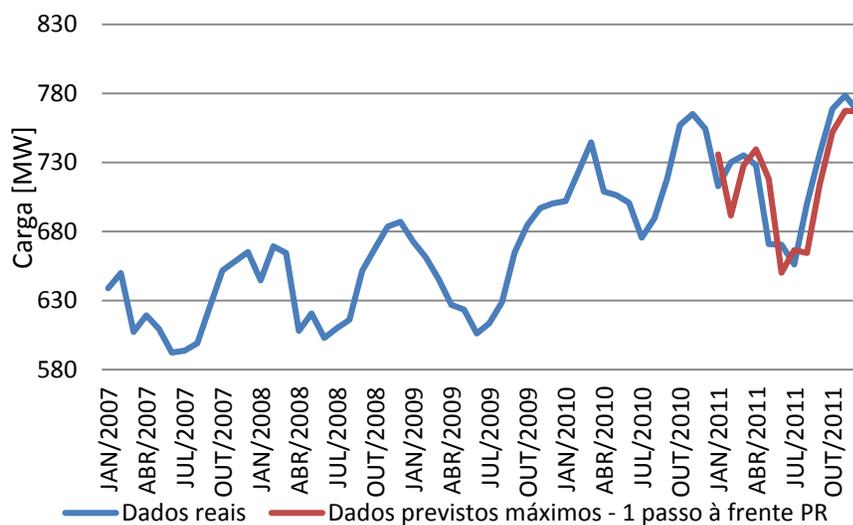


Figura 53 - Previsões máximas - modelo II - 2011 Agente I – 1 passo à frente.

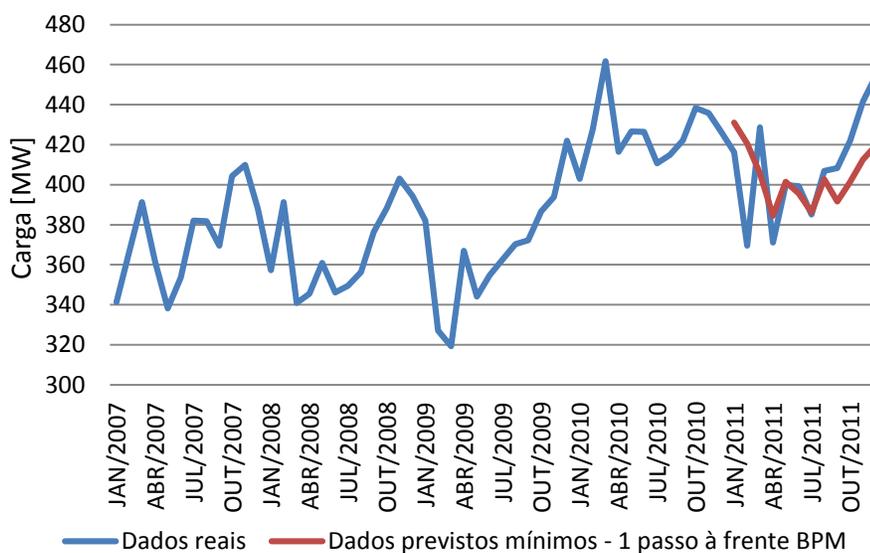


Figura 54 - Previsões mínimas - modelo II - 2011 Agente I – 1 passo à frente.

O erro obtido utilizando o modelo II composto pelos métodos FR e BPM foi de 4,11%, mostrado na Figura 55.

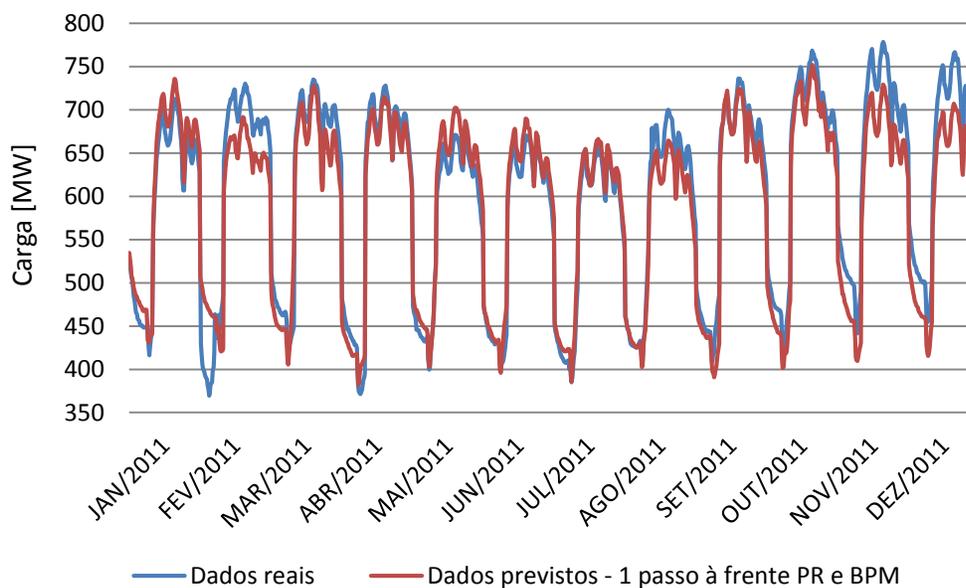


Figura 55 - Resultado previsão modelo II - 2011 Agente I - 1 passo à frente.

O desenvolvimento das RNAs utilizadas, foi de 3 camadas, sendo 4 neurônios na primeira camada, 5 neurônios na segunda camada (intermediária), e um neurônio na camada de saída.

6.2.2.3 Resultados modelo II - Barramento I-Ag.I

Para as previsões da série Barramento I-Ag.I, de 1 passo à frente, os erros que se mostraram menores pertencem ao método de treinamento BPM, mostrados na Tabela 9. Para a previsão dos valores máximos, métodos como o PR e o SCGM também se mostraram razoáveis.

Tabela 9 - Erro médio absoluto métodos RNAs - modelo II - Barramento I-Ag.I - 1 passo à frente.

Erro médio absoluto	GRAD	BFGS	DFP	OSS	PR	FR	SCGM	BPM
Carga máxima	3,98%	3,89%	3,56%	3,72%	3,14%	3,92%	3,19%	3,02%
Carga mínima	4,67%	5,34%	5,50%	5,28%	5,50%	5,23%	6,58%	4,44%

A Figura 56 e Figura 57 apresentam os valores máximos e mínimos previstos para o ano de 2011, utilizando nos dois casos o método BPM.

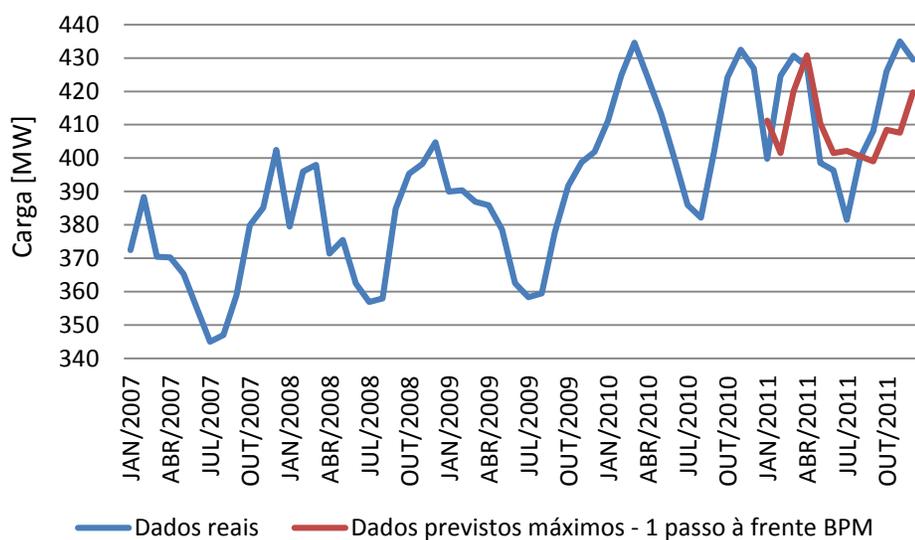


Figura 56 - Previsões máximas - modelo II - 2011 Barramento I-Ag.I – 1 passo à frente.



Figura 57 - Previsões mínimas - modelo II - 2011 Barramento I-Ag.I – 1 passo à frente.

Utilizando os extremos previstos é possível calcular as curvas de carga crítica desejadas. A Figura 58 mostra as previsões, a partir do cálculo, utilizando o modelo II composto pelo método de RNA BPM, o erro médio absoluto foi de 4,66%.

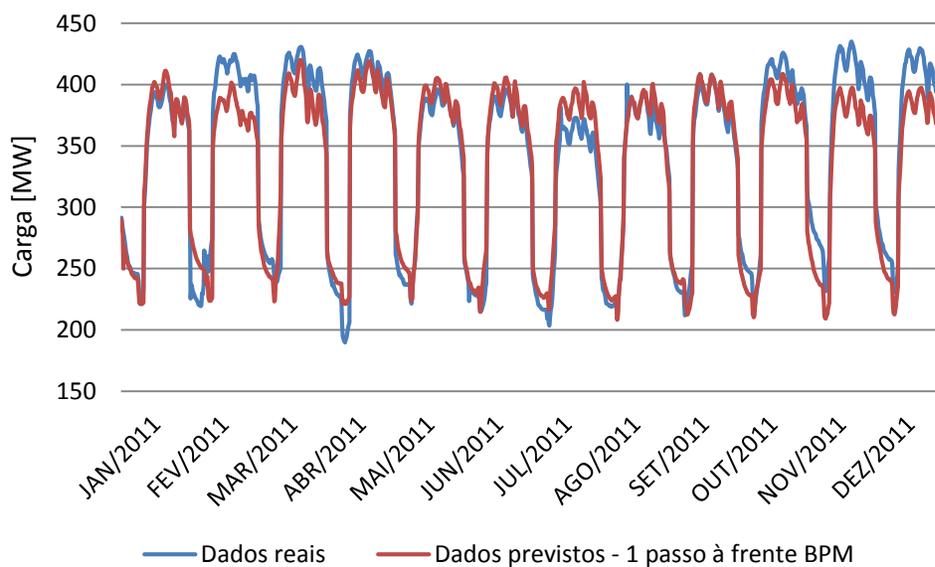


Figura 58 - Resultado previsão modelo II - 2011 Barramento I-Ag.I - 1 passo à frente.

As duas RNAs utilizadas tinham a configuração de três camadas. Sendo a primeira camada os dados de entrada, 4 neurônios, a segunda (camada intermediária) 7 neurônios e a última 1 neurônio (o valor da previsão).

6.2.3 Resultados modelo Holt-Winters

6.2.3.1 Resultados modelo Holt-Winters - Agente II

Os resultados do modelo Holt-Winters sobre a série do Agente II, para um passo à frente são apresentados na Figura 59, o erro obtido foi de 3,30%. Vale notar que o modelo HW conseguiu ajustar de modo eficiente o perfil de cada mês, sendo no erro o maior peso uma previsão de um período horário de carga baixa.

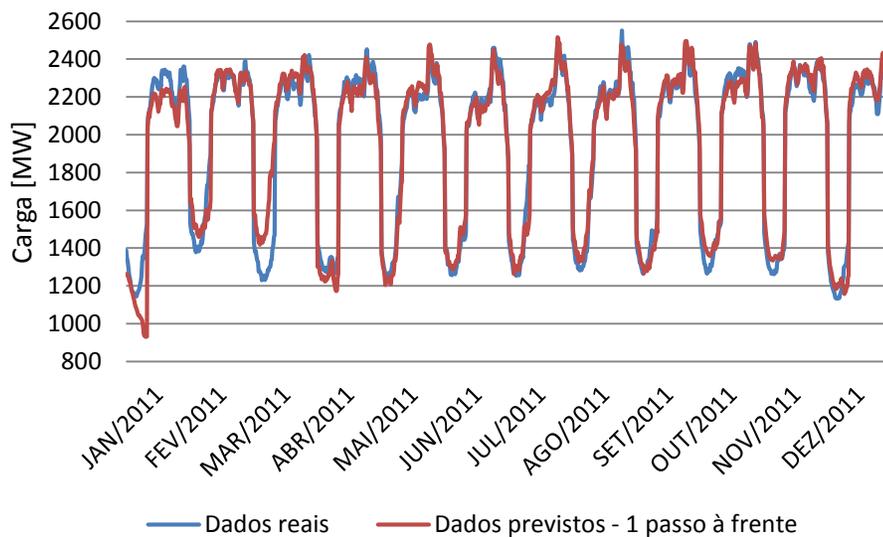


Figura 59 - Resultado previsão Holt-Winters - 2011 Agente II - 1 passo à frente.

Os resultados para um passo à frente são satisfatórios e se ajustam ao perfil tanto nas cargas altas quanto nas baixas.

6.2.3.2 Resultados modelo Holt-Winters - Agente I

As previsões para um passo à frente do modelo de HW para a série Agente I obtiveram um erro médio absoluto de 3,32%. A Figura 60 apresenta as curvas de carga crítica previstas para o ano de 2011 em conjunto com os dados reais, para fins de comparação.

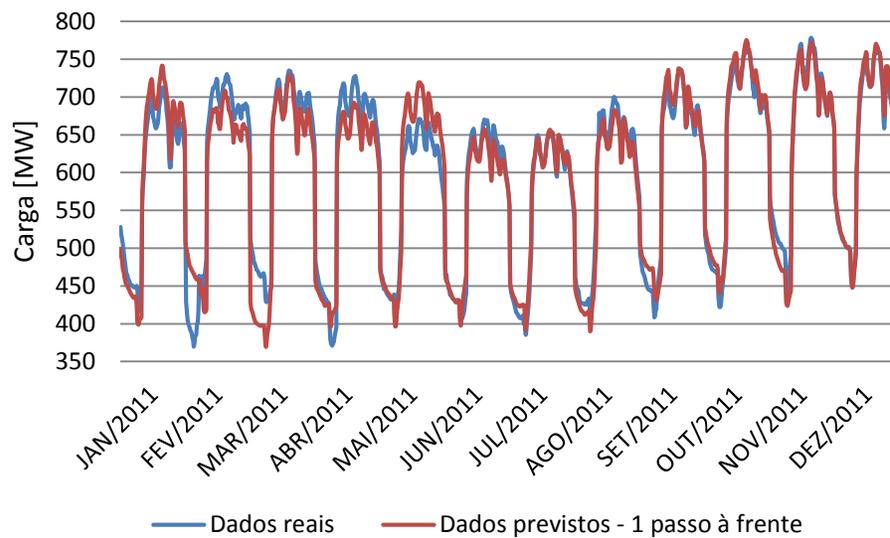


Figura 60 - Resultado previsão Holt-Winters - 2011 Agente I - 1 passo à frente.

Observe que o modelo de um passo à frente obteve bons resultados. O modelo HW possui uma vantagem em relação às outras técnicas devido à facilidade de tratar séries temporais com tendência e sazonalidade e ser um modelo específico para realizar tal tarefa.

6.2.3.3 Resultados modelo Holt-Winters - Barramento I-Ag.I

Os resultados do modelo de HW da série Barramento I-Ag.I obtiveram um erro médio absoluto de 3,78%. A Figura 61 apresenta os resultados gráficos das previsões de um passo à frente.

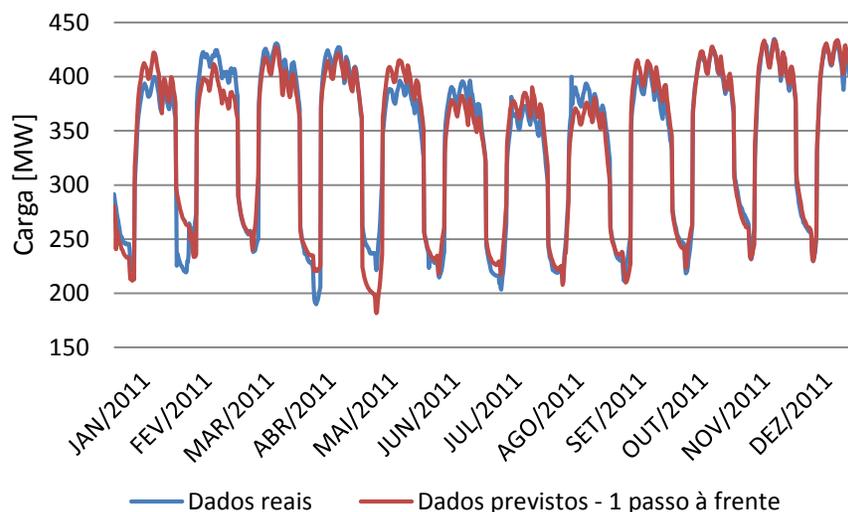


Figura 61 - Resultado previsão Holt-Winters - 2011 Barramento I-Ag.I - 1 passo à frente.

O modelo HW para um passo à frente realizou de maneira eficiente as previsões, poucos detalhes que não foram representados.

6.3 PREVISÕES DOIS A QUATRO PASSOS À FRENTE

Esta Seção apresenta o resultado das previsões realizadas para dois, três e quatro passos à frente para todos os modelos propostos com base nas três séries históricas propostas no início deste capítulo.

6.3.1 Agente II

6.3.1.1 Modelo I

A Tabela 10 possui os erros médios absolutos apresentados pelo modelo I para cada um dos métodos de treinamento das RNAs, de 1 a 4 passos à frente, para as 96 discretizações no ano de 2011.

Tabela 10 - Erro médio absoluto métodos RNAs - Agente II - 1 a 4 passos à frente.

Passos	GRAD	BFGS	DFP	OSS	PR	FR	SCGM	BPM
1 passo	3,44%	3,89%	3,87%	3,67%	3,23%	3,38%	3,57%	2,86%
2 passos	4,26%	5,67%	5,82%	4,90%	6,37%	4,72%	6,46%	4,03%
3 passos	4,70%	5,43%	5,57%	4,94%	5,56%	4,45%	8,10%	4,74%
4 passos	4,79%	5,35%	5,65%	5,85%	5,46%	4,67%	5,98%	5,26%

Novamente o método de treinamento BPM apresentou o menor erro médio absoluto, com 4,03%, para 2 passos à frente. Para 3 e 4 passos à frente o método FR apresentou menor erro médio absoluto, com respectivamente 4,45% e 4,67% de erro médio absoluto.

As Figura 62, Figura 63, Figura 64 e Figura 65 apresentam os gráficos com os resultados das previsões do ano de 2011, para todos os passos.

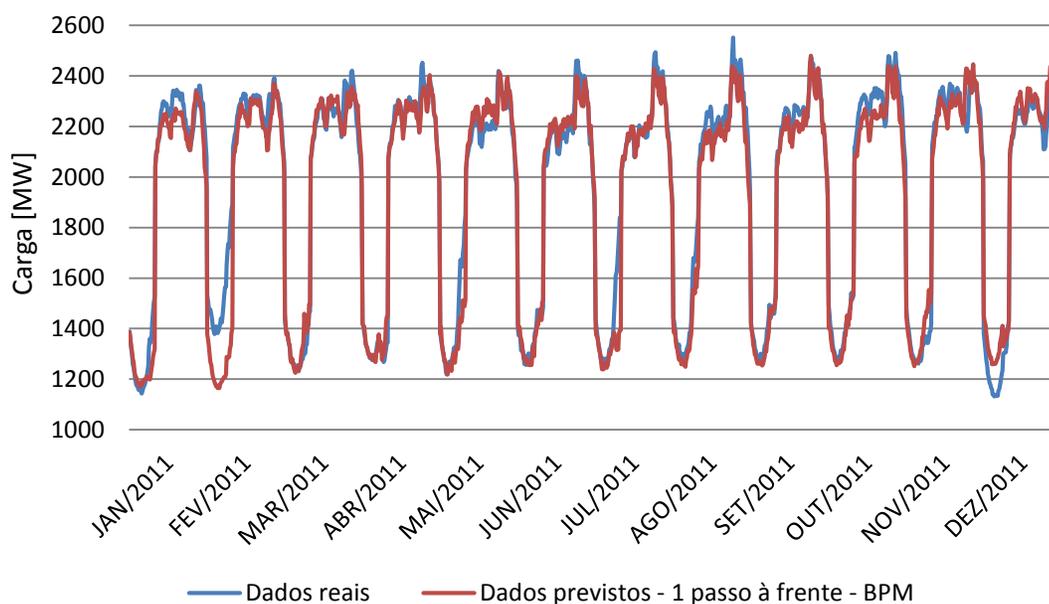


Figura 62 - Resultado previsão modelo I - 2011 Agente II - 1 passo à frente.

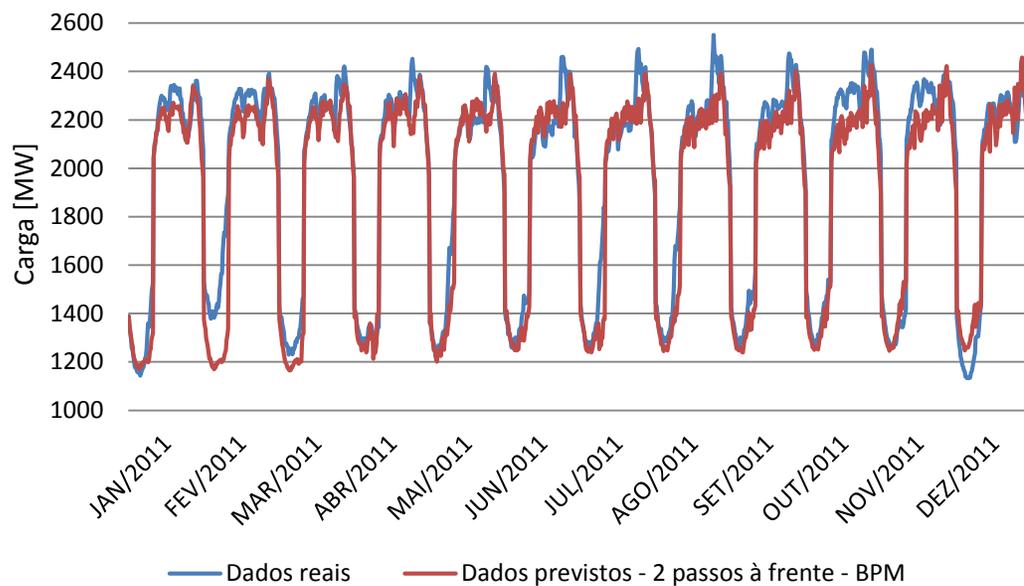


Figura 63 - Resultado previsão modelo I - 2011 Agente II - 2 passos à frente.

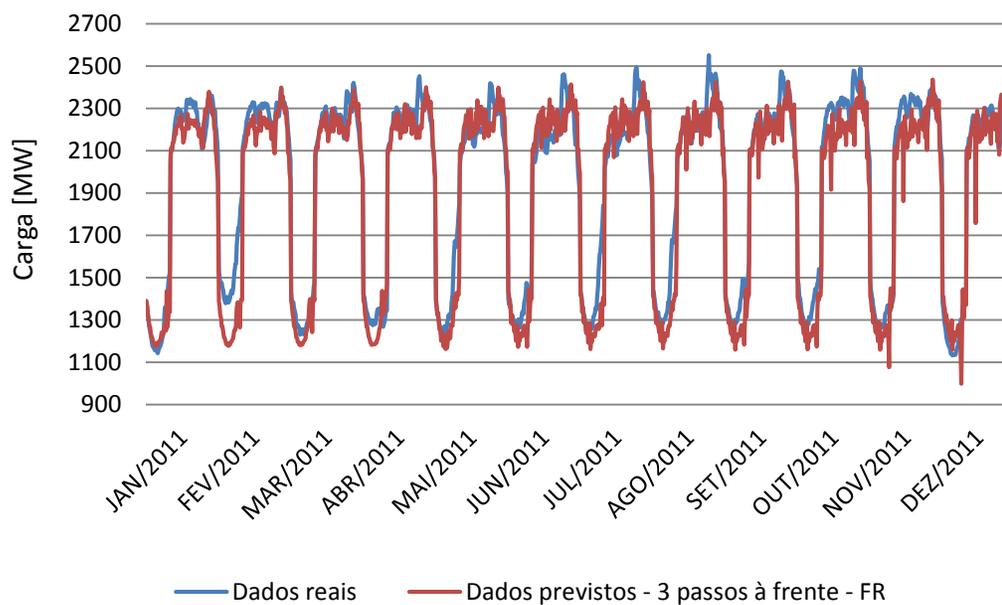


Figura 64 - Resultado previsão modelo I - 2011 Agente II - 3 passos à frente.

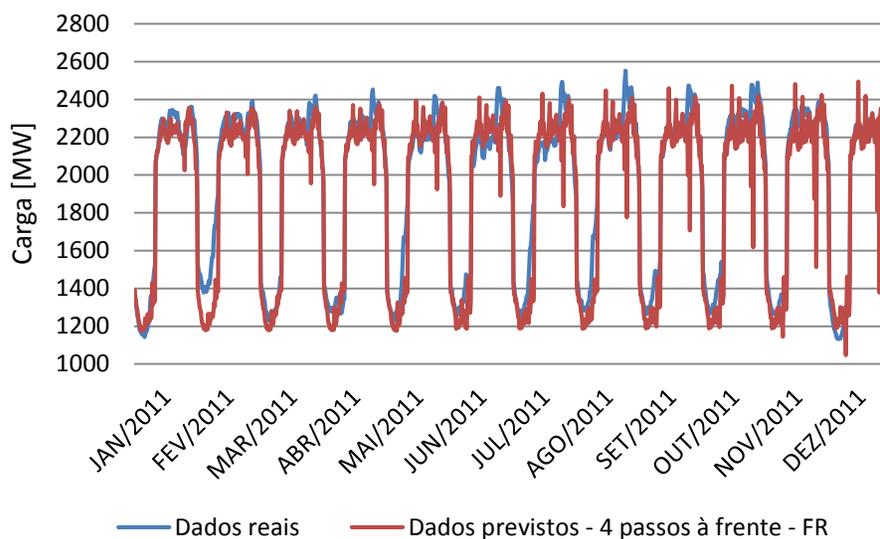


Figura 65 - Resultado previsão modelo I - 2011 Agente II - 4 passos à frente.

É possível observar que para a previsão de dois passos à frente, o modelo teve uma dificuldade em prever as cargas de condição horária pesada, das 9h às 24h, nos meses do fim do ano. Isso pode ter ocorrido devido às previsões não terem conseguido distinguir os meses de verão e inverno, onde a sazonalidade se mostra mais marcante nesta série, sendo possível observar isto pela observação dos extremos na Figura 63.

Pode-se notar, pelo gráfico apresentado na Figura 64, que nos últimos quatro meses previstos começam a aparecer alguns ruídos devido às previsões sobre previsões. Mesmo com estes ruídos citados a previsão ainda permanece aceitável, pois está sempre próxima do perfil esperado.

Observe na Figura 65 que as previsões para 4 passos à frente começam a apresentar um ruído, um desvio para baixo, que aparentemente cresce à medida que os meses avançam. Este ruído ocorre sempre na mesma hora, podendo ser um modelo inadequado para este intervalo de tempo específico. Abstraindo esses ruídos, os outros intervalos de tempo foram previstos com uma proximidade do valor real de forma satisfatória.

Para a configuração das RNAs, foi utilizada a mesma configuração para os dois modelos de previsão, 1 e 2 passos à frente, devido ao método BPM ter se destacado nos dois modos. A configuração final da RNA BPM utilizada foi de 4 neurônios de entrada, uma média de 7 a 10 neurônios na camada intermediária e um na camada de saída. Para 3 e 4 passos à frente a

configuração final da RNA FR utilizada foi de 4 neurônios na camada de entrada, uma média de 5 a 8 neurônios na camada intermediária e um neurônio na camada de saída.

6.3.1.2 Modelo II

A Tabela 11 apresenta os erros médios absolutos dos métodos das RNAs para as previsões das cargas máximas e cargas mínimas, de 1 a 4 passos à frente. Observe, que para 1 passo à frente, as previsões de carga máxima o método FR obteve o menor erro médio absoluto, e para as cargas mínimas o método BPM, com respectivamente 1,66% e 3,37%. Para 2 passos à frente os métodos DFP e BPM foram os que obtiveram melhores resultados com respectivamente 1,77% e 4,20% de erro médio absoluto. Para 3 passos à frente os métodos BFGS e FR foram os que obtiveram melhores resultados, com respectivamente 2,01% e 5,89%, para previsão da carga máxima e mínima. O método GRAD obteve 1,56% na previsão de 4 passos à frente para a carga máxima e o método BPM atingiu 6,84% para a previsão da carga mínima.

Tabela 11 - Erro médio absoluto métodos RNAs - modelo II - Agente II – 1 a 4 passos à frente.

Passos	Erro médio absoluto	GRAD	BFGS	DFP	OSS	PR	FR	SCGM	BPM
1 passo	Carga máxima	1,75%	1,85%	1,69%	2,26%	1,72%	1,66%	1,79%	1,76%
	Carga mínima	4,66%	5,37%	6,00%	6,79%	6,24%	6,20%	5,78%	3,37%
2 passos	Carga máxima	2,15%	1,91%	1,77%	2,32%	7,14%	1,85%	6,43%	2,83%
	Carga mínima	6,49%	26,86%	20,10%	13,01%	11,28%	12,96%	33,25%	4,20%
3 passos	Carga máxima	2,92%	2,01%	5,80%	2,81%	6,79%	3,90%	14,29%	8,45%
	Carga mínima	6,79%	16,58%	6,15%	7,00%	7,03%	5,89%	8,53%	6,97%
4 passos	Carga máxima	1,56%	1,99%	2,69%	2,64%	6,82%	2,14%	7,80%	2,95%
	Carga mínima	7,05%	8,95%	8,16%	8,46%	8,96%	8,70%	13,76%	6,84%

A Tabela 12 apresenta os erros médios absolutos da previsões das curvas de carga crítica horária de 1 a 4 passos à frente.

Tabela 12 - Erro médio absoluto - modelo II - Agente II – 1 a 4 passos à frente.

Passos	Erro médio absoluto
1 passo	3,46%
2 passos	3,54%
3 passos	4,20%
4 passos	4,19%

Note que o erro para 4 passos à frente foi menor, em um centésimo, que o erro de 3 passos à frente para a mesma série. Devido a proposta de modelagem das previsões estarem ligadas aos perfis e previsões de limites (máximos e mínimos de cada mês), este fato se justifica, não sendo obrigatório o erro de 3 passos ser menos que o erro de 4 passos.

As Figura 66, Figura 67, Figura 68 e Figura 69 apresentam as previsões das curvas de carga crítica horária para o ano de 2011 de 1 a 4 passos à frente.

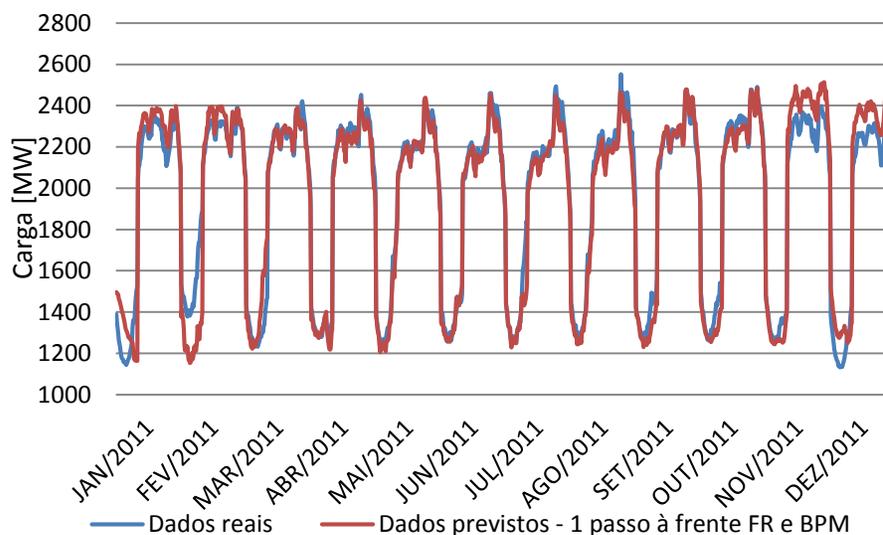


Figura 66 - Resultado previsão modelo II - 2011 Agente II - 1 passo à frente.

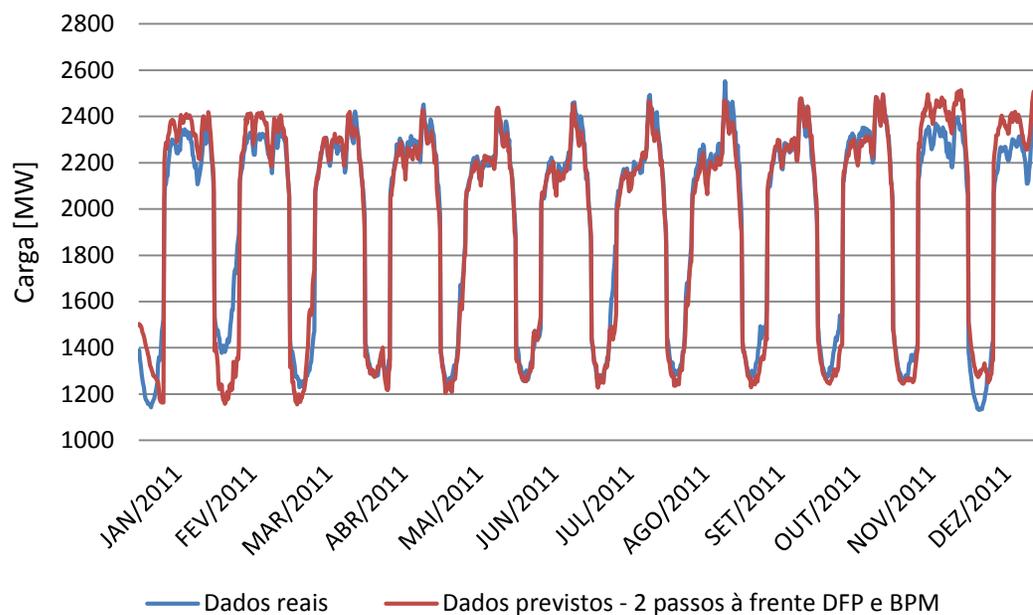


Figura 67 - Resultado previsão modelo II - 2011 Agente II - 2 passos à frente.

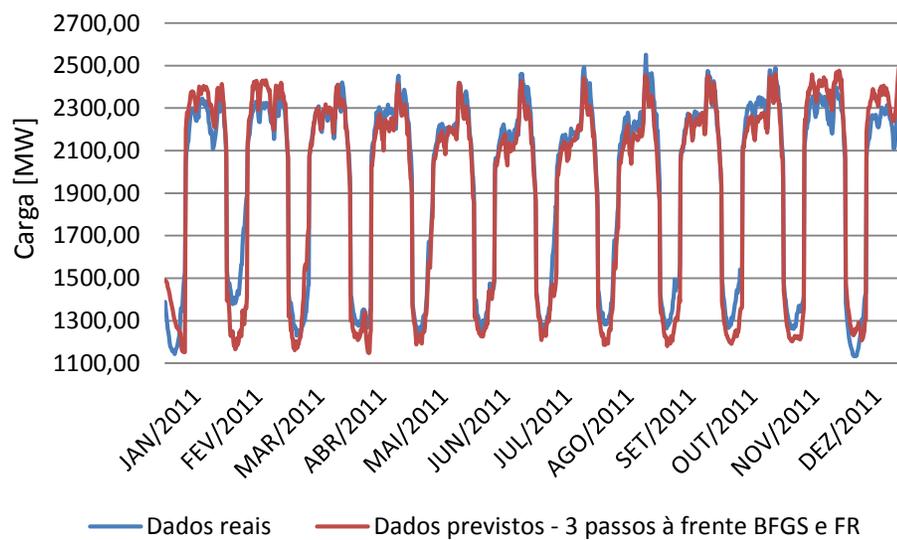


Figura 68 - Resultado previsão modelo II - 2011 Agente II - 3 passos à frente.

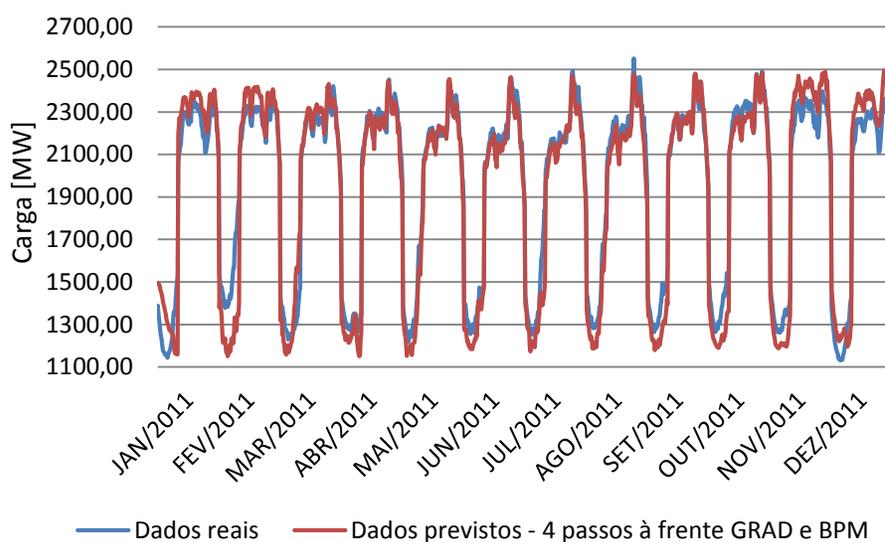


Figura 69 - Resultado previsão modelo II - 2011 Agente II - 4 passos à frente.

Para todas as previsões de 1 a 4 passos a frente apenas variou-se a configuração das RNAs na camada intermediária, sendo a camada de entrada com 4 neurônios e a camada de saída com um neurônio. Para 1 passo à frente foram utilizados 8 neurônios na intermediária. Para 2 passos à frente, utilizou-se 5 neurônios para o método DFP e 8 para o BPM. Para 3 e 4 passos à frente a média de neurônios utilizada na camada intermediária foi de 6 a 8.

6.3.1.3 Modelo Holt-Winters

A Tabela 13 apresenta os erros médios absolutos obtidos pelas previsões utilizando o modelo Holt-Winters de 1 a 4 passos à frente.

Tabela 13 - Erro médio absoluto - modelo Holt-Winters - Agente II – 1 a 4 passos à frente.

Passos	Erro médio absoluto
1 passo	3,30%
2 passos	3,88%
3 passos	5,07%
4 passos	5,33%

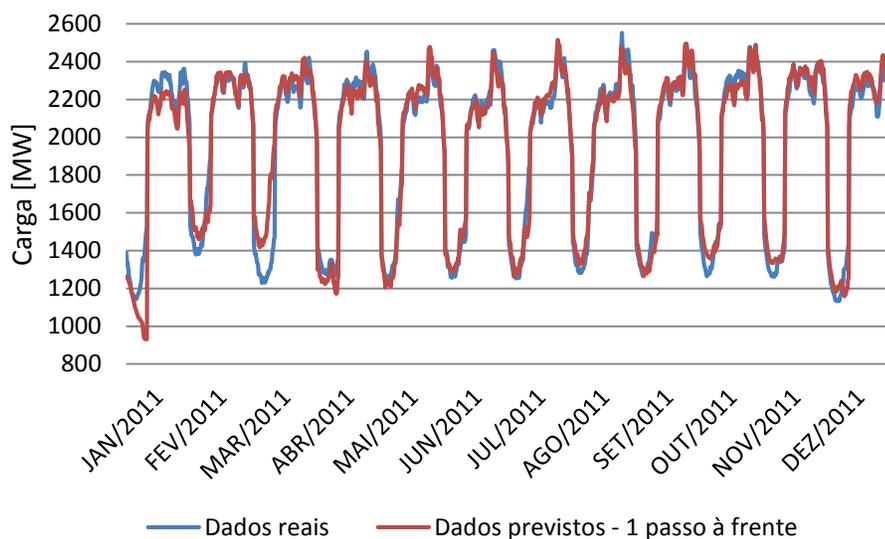


Figura 70 - Resultado previsão Holt-Winters - 2011 Agente II - 1 passo à frente.

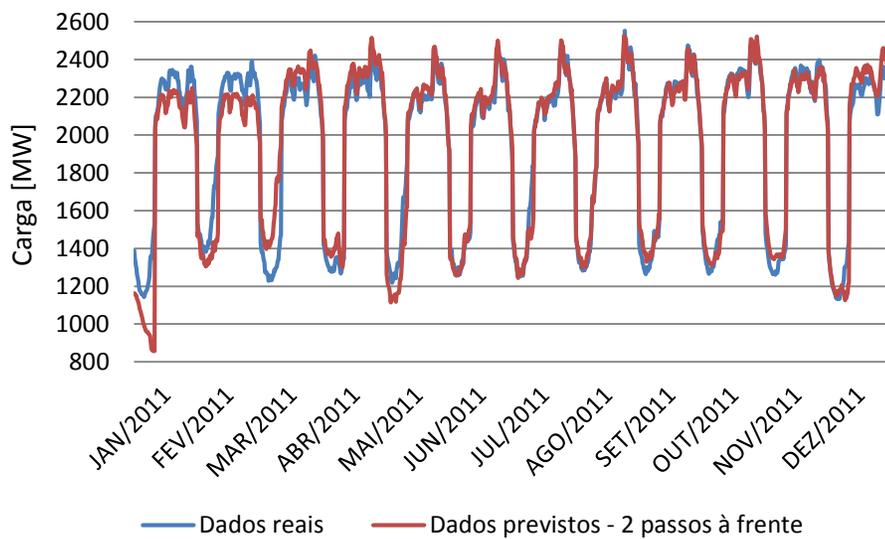


Figura 71 - Resultado previsão Holt-Winters - 2011 Agente II - 2 passos à frente.

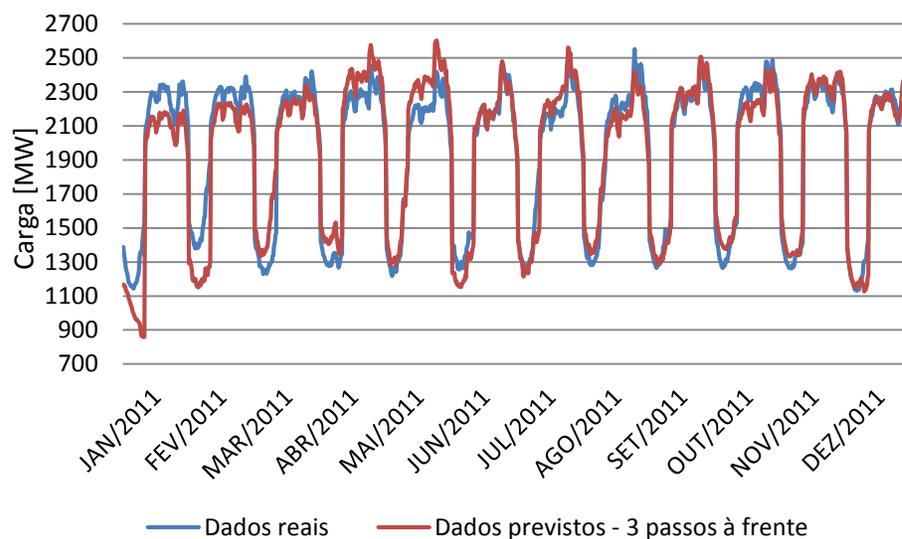


Figura 72 - Resultado previsão Holt-Winters - 2011 Agente II - 3 passos à frente.

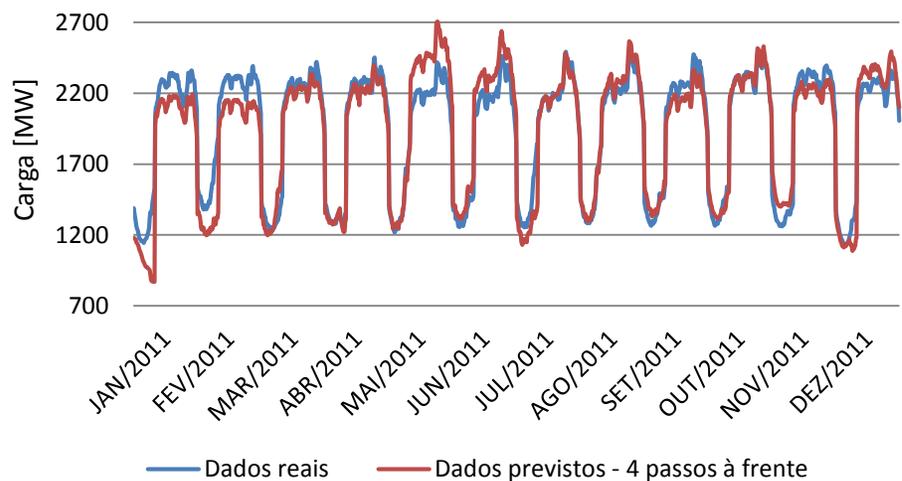


Figura 73 - Resultado previsão Holt-Winters - 2011 Agente II - 4 passos à frente.

6.3.1.4 Comparação entre os modelos

A Tabela 14 apresenta os modelos de previsão com os erros médios absolutos para 1, 2, 3 e 4 passos à frente.

Tabela 14 - Resultados série Agente II.

	1 passo à frente	2 passos à frente	3 passos à frente	4 passos à frente
Modelo I	2,86%	4,03%	4,45%	4,67%
Modelo II	3,48%	3,54%	4,20%	4,19%
Holt-Winters	3,30%	3,88%	5,07%	5,33%

Para 1 passo à frente o modelo I obteve 2,86% de erro com o método de treinamento BPM. O modelo II obteve 3,48% utilizando o método FR para prever as cargas máximas e BPM para prever as mínimas. O HW atingiu 3,30% de erro prevendo as cargas máximas e mínimas e aplicando a previsão inicial no perfil do mês do ano anterior a ser previsto.

Para 2 passos à frente, o modelo II se destacou com 3,54% utilizando o método DFP para prever as condições de carga máxima e o método BPM foi utilizado para prever as cargas mínimas. Vale ressaltar que todos os dados estão muito próximos estatisticamente, sendo interessante analisar a viabilidade da execução de cada um.

Nas previsões de 3 passos à frente o modelo II obteve melhores resultados, com 4,20% de erro, prevendo as cargas máximas com o método BFGS e as mínimas com o FR.

Finalmente, para as previsões de 4 passos à frente, novamente, o modelo II atingiu melhores resultados com 4,19% de erro, utilizando o método GRAD e BPM para prever respectivamente as cargas máximas e mínimas. Vale ressaltar, que devido a modelagem proposta para o modelo II, não se faz regra o erro de 3 passos à frente ter que ser menor que o erro de 4 passos à frente.

Então, conclui-se que para prever para a série do Agente II para 1 passo à frente utiliza-se o modelo I e para 2, 3 e 4 passos à frente utiliza-se o modelo II. Vale ressaltar que o modelo HW talvez não tenha tirado muita vantagem da série devido à mesma não possuir uma tendência marcante para esses cinco anos de histórico.

6.3.2 Agente I

6.3.2.1 Modelo I

A Tabela 15 apresenta os erros médios absolutos dos métodos das RNAs para as previsões de 1 a 4 passos à frente para o ano de 2011. Pode-se observar que o método BPM prevaleceu em todos os passos, 1, 2, 3 e 4 passos à frente, com os menores erros médios absolutos, respectivamente 3,99%, 5,31%, 5,41% e 5,76%.

Tabela 15- Erro médio absoluto métodos RNAs - Agente I - 1 a 4 passos à frente.

Passos	GRAD	BFGS	DFP	OSS	PR	FR	SCGM	BPM
1 passo	4,73%	4,49%	4,49%	4,78%	4,04%	4,62%	4,25%	3,99%
2 passos	5,61%	6,10%	5,96%	14,75%	8,75%	6,07%	10,67%	5,31%
3 passos	5,91%	6,41%	6,61%	5,99%	7,38%	6,13%	16,08%	5,41%
4 passos	5,87%	6,52%	6,20%	5,94%	6,55%	5,83%	15,26%	5,76%

A Figura 74, Figura 75, Figura 76 e Figura 77 apresentam as previsões das curvas de cargas críticas resultantes do modelo I para o ano de 2011.

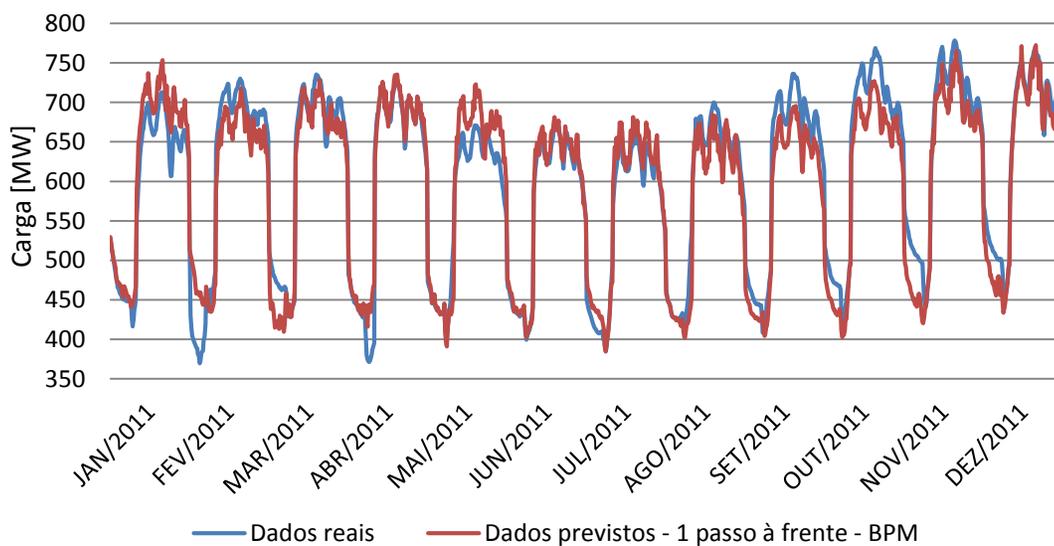


Figura 74 - Resultado previsão modelo I - 2011 Agente I - 1 passo à frente.

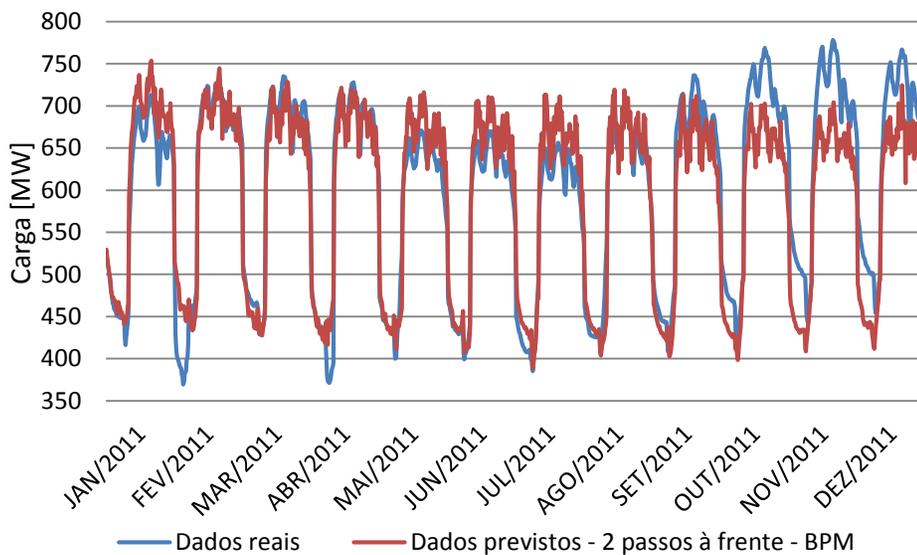


Figura 75 - Resultado previsão modelo I - 2011 Agente I - 2 passos à frente.

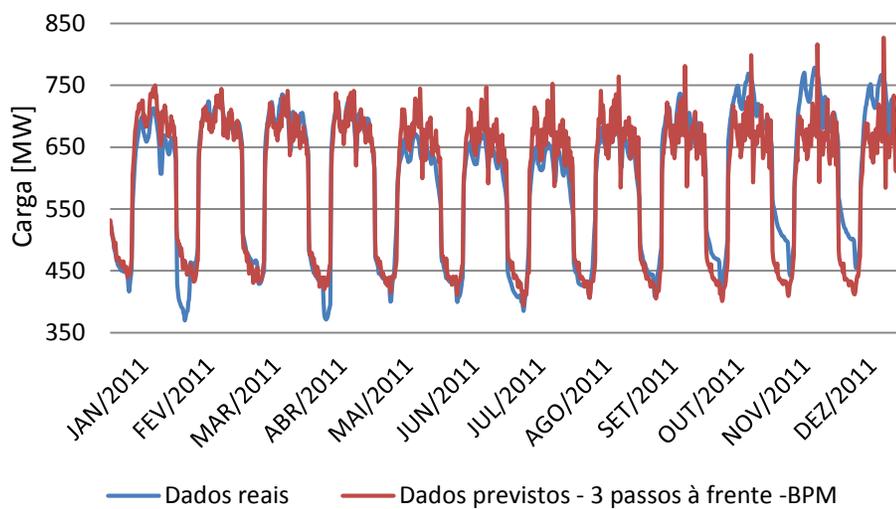


Figura 76 - Resultado previsão modelo I - 2011 Agente I - 3 passos à frente.

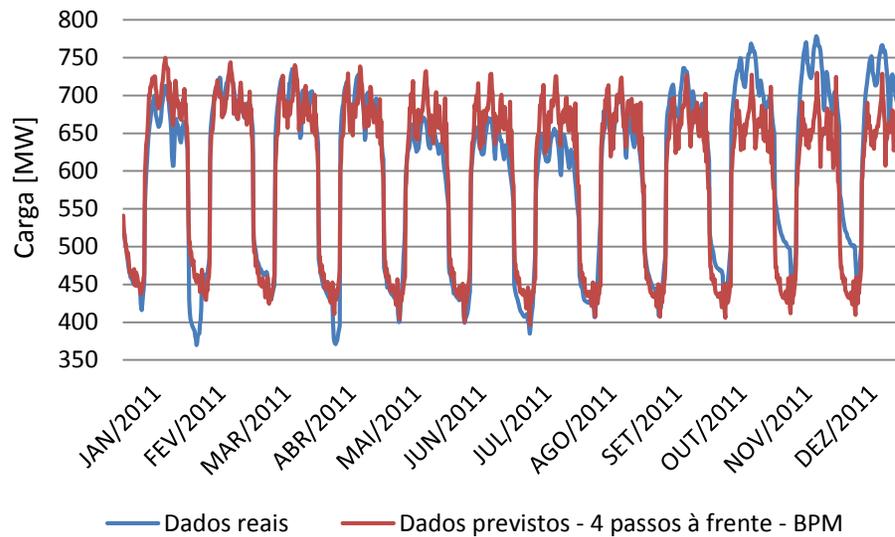


Figura 77 - Resultado previsão modelo I - 2011 Agente I - 4 passos à frente.

Para as previsões de 1 passo à frente é possível notar que o método conseguiu representar a sazonalidade e a tendência existente. Já para 2 passos à frente, o método BPM não conseguiu modelar a sazonalidade e nem a tendência presente na série. Para 3 passos à frente, as previsões apareceram ruídos em um intervalo de tempo durante toda o ano de 2011. Para as previsões de 2, 3 e 4 passos à frente o modelo se comportou com as previsões em uma faixa média, isso explica os erros satisfatórios.

6.3.2.2 Modelo II

A Tabela 16 apresenta os erros médios absolutos das previsões das cargas máximas e mínimas de 1 a 4 passos à frente. Para 1 passo à frente os métodos PR e BPM foram os que apresentaram menor resultado, com respectivamente 2,87% e 4,35%. Nota-se que os métodos PR e BPM foram novamente os que obtiveram menor erro médio absoluto para 2 passos à frente, com 3,59% e 4,40%. Os métodos que obtiveram melhores resultados para 3 passos à frente foram o OSS, para previsões das cargas máximas com 4,98% de erro médio absoluto, e o FR para as previsões mínimas com erro médio absoluto de 5,32%. Finalmente, para as previsões de 4 passos

à frente os métodos DFP e BFGS foram os que obtiveram menores erros com respectivamente 5,05% e 4,92%, para as cargas máximas e mínimas.

Tabela 16 - Erro médio absoluto métodos RNAs - modelo II - Agente I – 1 a 4 passos à frente.

Passos	Erro médio absoluto	GRAD	BFGS	DFP	OSS	PR	FR	SCGM	BPM
1 passo	Carga máxima	4,29%	4,44%	3,77%	3,95%	2,87%	4,87%	3,08%	3,14%
	Carga mínima	5,02%	5,11%	5,19%	5,17%	4,69%	5,04%	4,77%	4,35%
2 passos	Carga máxima	5,37%	5,99%	6,51%	5,48%	3,59%	5,39%	4,33%	5,08%
	Carga mínima	5,09%	5,00%	5,11%	5,15%	4,76%	5,06%	4,77%	4,40%
3 passos	Carga máxima	5,13%	5,36%	6,36%	4,98%	5,00%	5,36%	5,05%	5,44%
	Carga mínima	5,58%	5,56%	5,52%	5,62%	5,42%	5,32%	5,72%	5,49%
4 passos	Carga máxima	6,82%	5,24%	5,05%	6,52%	5,56%	5,29%	5,16%	5,68%
	Carga mínima	5,93%	4,92%	5,48%	5,48%	5,33%	5,53%	7,26%	6,10%

A Tabela 17 apresenta os erros médios absolutos das previsões, calculadas a partir das previsões dos limites do modelo II, das curvas de cargas críticas horarias.

Tabela 17 - Erro médio absoluto - modelo II - Agente I – 1 a 4 passos à frente.

Passos	Erro médio absoluto
1 passo	4,11%
2 passos	4,19%
3 passos	5,28%
4 passos	5,30%

As Figura 78, Figura 79, Figura 80 e Figura 81 apresentam as respectivas curvas de cargas críticas previstas de 1 a 4 passos à frente.

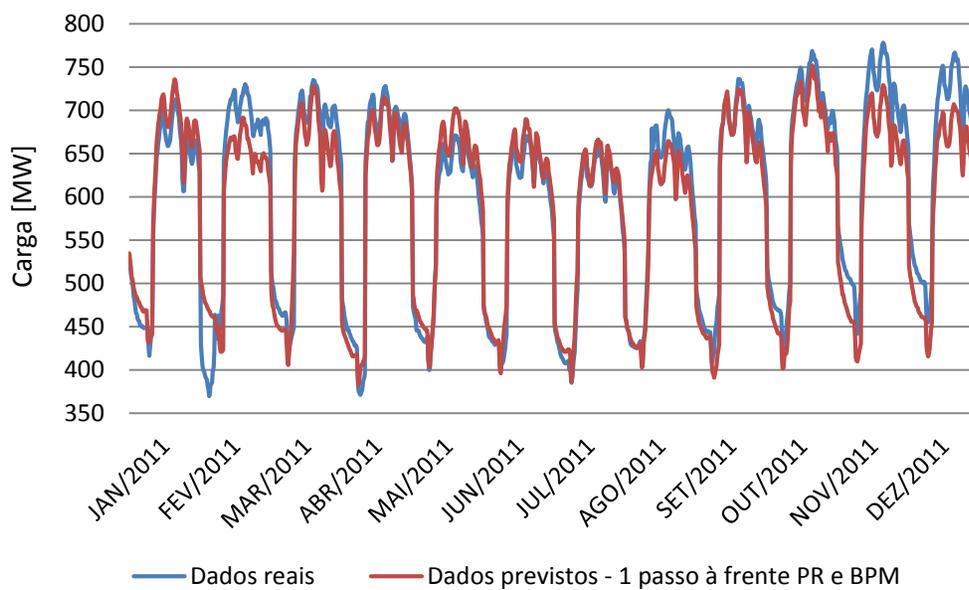


Figura 78 - Resultado previsão modelo II - 2011 Agente I - 1 passo à frente.

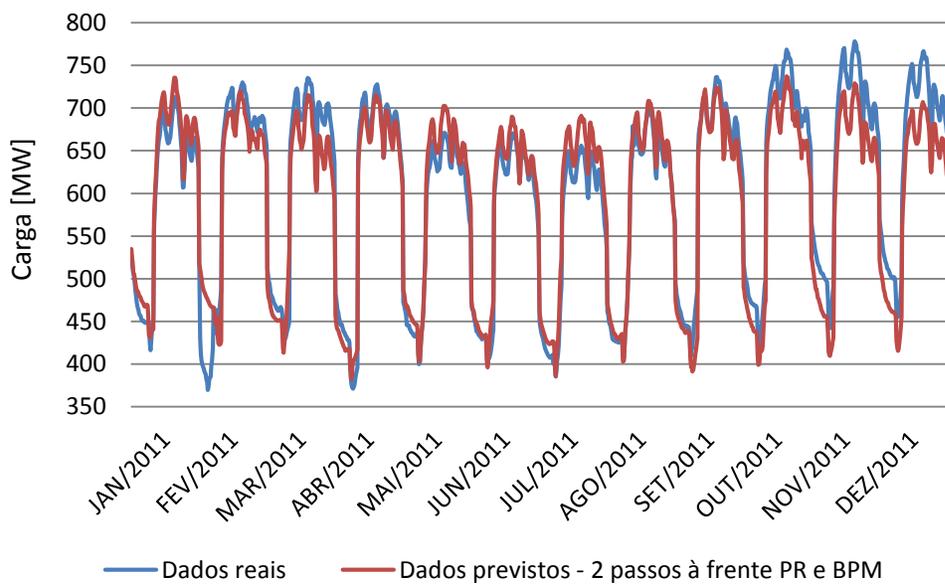


Figura 79 - Resultado previsão modelo II - 2011 Agente I - 2 passos à frente.

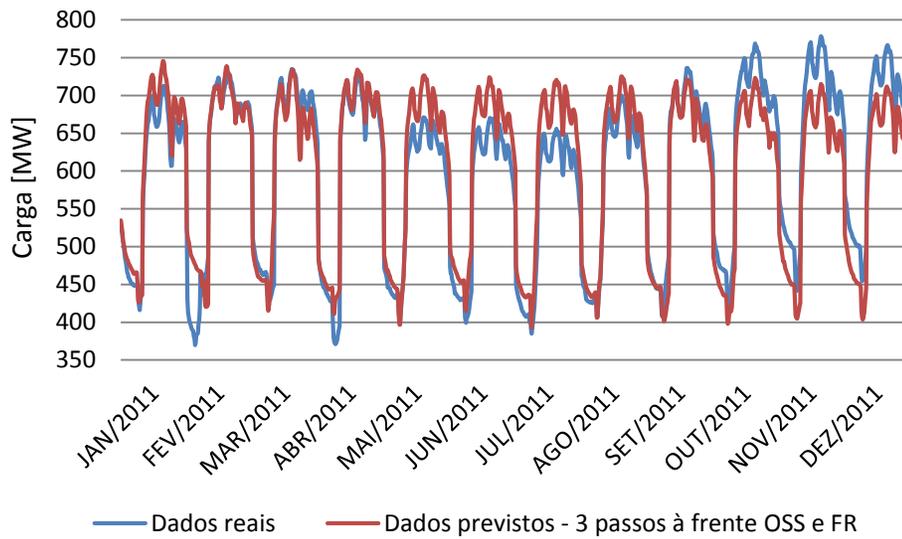


Figura 80 - Resultado previsão modelo II - 2011 Agente I - 3 passos à frente.

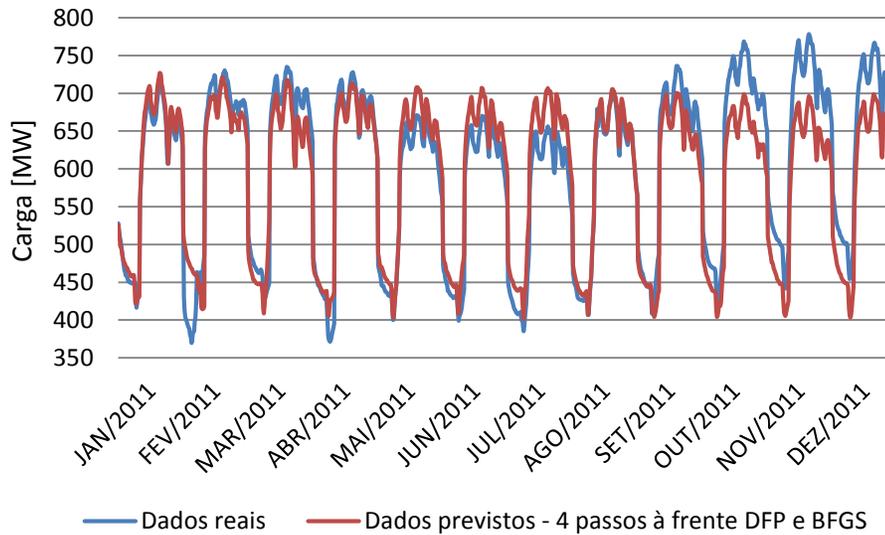


Figura 81 - Resultado previsão modelo II - 2011 Agente I - 4 passos à frente.

A configuração das RNAs utilizadas, para todas as previsões de 1 a 4 passos à frente, foi de 3 camadas, sendo 4 neurônios na primeira camada, uma média de 5 neurônios na segunda camada (intermediária), e um neurônio na camada de saída.

6.3.2.3 Modelo Holt-Winters

A Tabela 18 apresenta os erros médios absolutos das previsões do modelo Holt-Winters de 1 a 4 passos à frente. Observe que com o aumento de passos na previsão o erro aumenta gradativamente. Este fato está ligado diretamente as previsões dos máximos e mínimos realizadas na primeira etapa do modelo.

Tabela 18 - Erro médio absoluto - modelo Holt-Winters - Agente I – 1 a 4 passos à frente.

Passos	Erro médio absoluto
1 passo	3,32%
2 passos	3,57%
3 passos	4,36%
4 passos	5,56%

A Figura 82, Figura 83, Figura 84 e Figura 85 apresentam as previsões de 1 a 4 passos à frente das curvas de carga crítica.

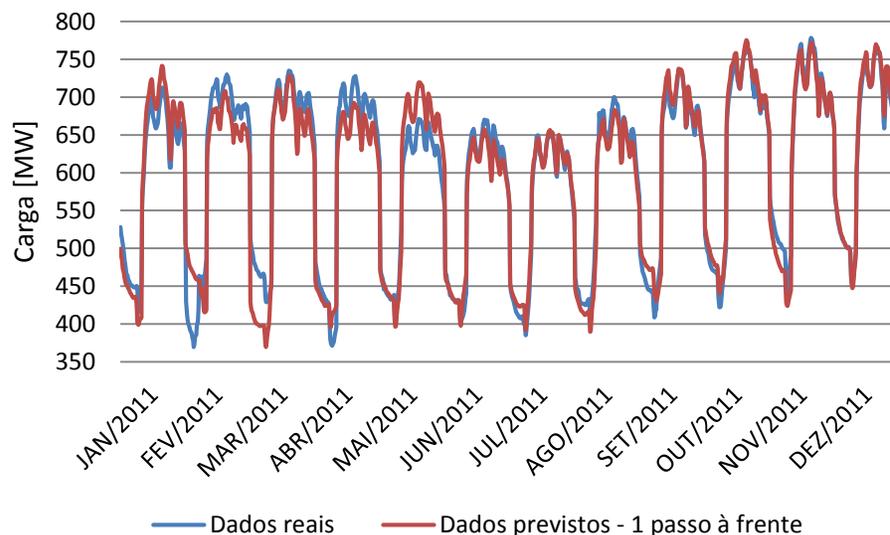


Figura 82 - Resultado previsão Holt-Winters - 2011 Agente I - 1 passo à frente.

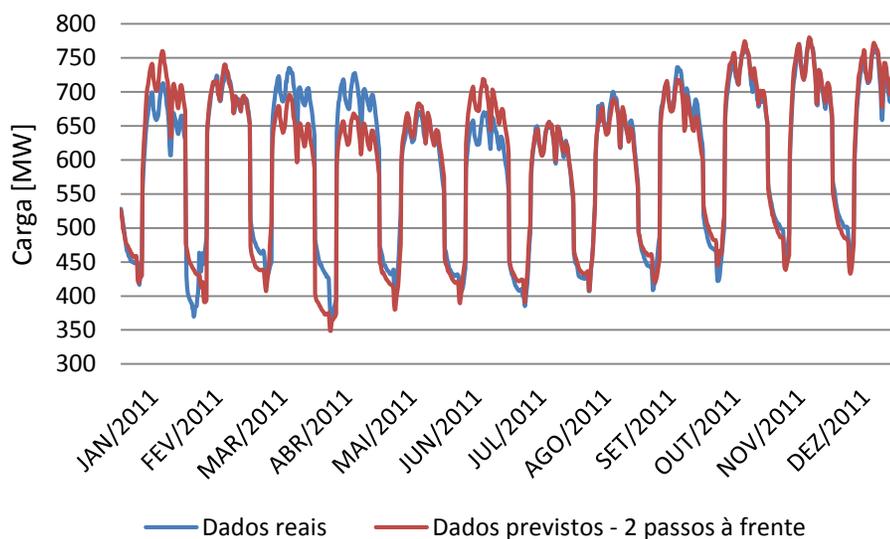


Figura 83 - Resultado previsão Holt-Winters - 2011 Agente I - 2 passos à frente.

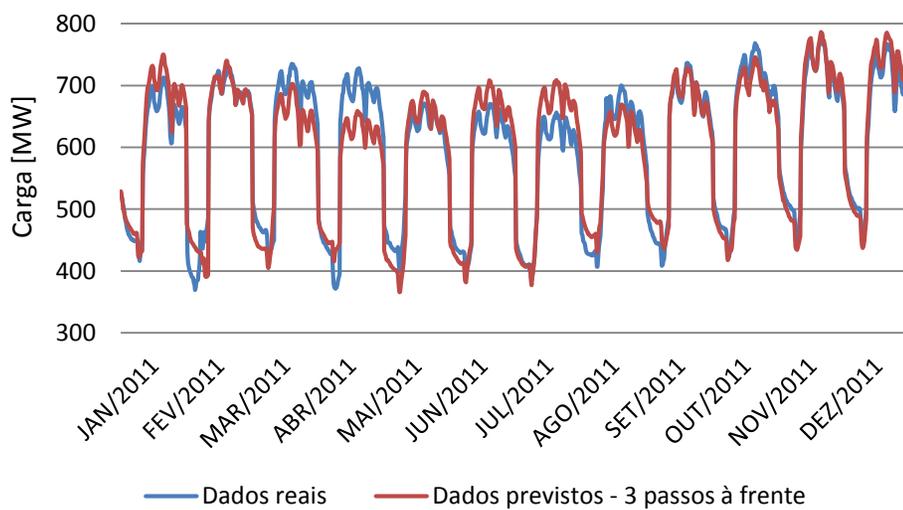


Figura 84 - Resultado previsão Holt-Winters - 2011 Agente I - 3 passos à frente.

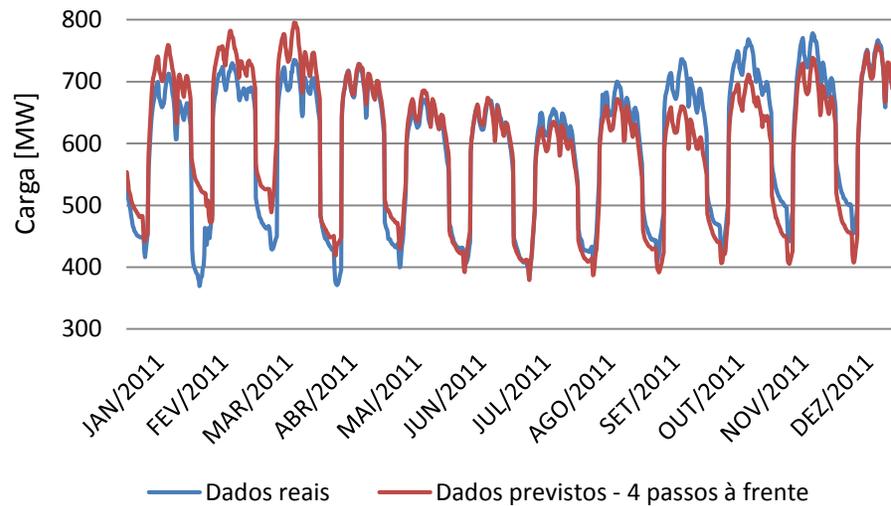


Figura 85 - Resultado previsão Holt-Winters - 2011 Agente I - 4 passos à frente.

Observe que o modelo de 1 passo à frente obteve bons resultados. Para as previsões de 2 passos à frente, após o terceiro mês, se ajustam de maneira eficiente, acompanhando os extremos e o perfil de cada mês. Para as previsões de 3 e 4 passos à frente nas cargas mínimas a precisão diminui consideravelmente, aumentando os erros nos primeiros meses. Mesmo com estas observações, o modelo HW possui uma vantagem em relação às outras técnicas devido à facilidade de tratar séries temporais com tendência e sazonalidade e ser um modelo específico para realizar tal tarefa.

6.3.2.4 Comparação entre os modelos

A Tabela 19 apresenta os melhores resultados de cada modelo de previsão proposto neste trabalho para a série do Agente I. Pode-se observar que o modelo Holt-Winters se destacou em três propostas, 1, 2 e 3 passos à frente, possuindo apenas 0,26% de erro maior que o modelo II para 4 passos à frente.

Tabela 19 - Resultados série Agente I.

	1 passo à frente	2 passos à frente	3 passos à frente	4 passos à frente
Modelo I	3,99%	5,31%	5,41%	5,76%
Modelo II	4,11%	4,19%	5,28%	5,30%
Holt-Winters	3,32%	3,57%	4,36%	5,56%

Uma desvantagem das RNAs, para séries como estas que possuem nitidamente tendência e sazonalidade, em relação ao modelo Holt-Winters se dá pelo motivo dos modelos HW serem projetados especificamente para séries temporais como esta. Mesmo não possuindo os melhores resultados entres os métodos, as RNAs conseguiram resultados relevantes frente à dificuldade de prever curvas críticas. Como estatisticamente 0,26% de erro é muito próximo de zero, pode-se dizer que o modelo HW é adequado para 1, 2, 3 e 4 passos à frente para esta série proposta.

6.3.3 Barramento I-Ag.I

6.3.3.1 Modelo I

Os erros médios absolutos obtidos nas previsões de 1 a 4 passos à frente do modelo I para o ano de 2011 são expostos na Tabela 20.

Tabela 20 - Erro médio absoluto métodos RNAs – Barramento I-Ag.I - 1 a 4 passos à frente.

Passos	GRAD	BFGS	DFP	OSS	PR	FR	SCGM	BPM
1 passo	4,80%	4,87%	4,46%	4,92%	4,33%	4,77%	4,55%	4,11%
2 passos	5,71%	6,35%	7,62%	5,67%	17,86%	6,63%	39,17%	5,17%
3 passos	5,72%	6,11%	9,43%	5,66%	10,02%	6,00%	24,77%	5,24%
4 passos	5,73%	6,80%	7,58%	5,54%	7,08%	7,07%	13,11%	5,96%

A Figura 86, Figura 87, Figura 88 e Figura 89 apresentam respectivamente as curvas de cargas críticas das previsões de 1, 2, 3 e 4 passos à frente obtidas pelo modelo I.

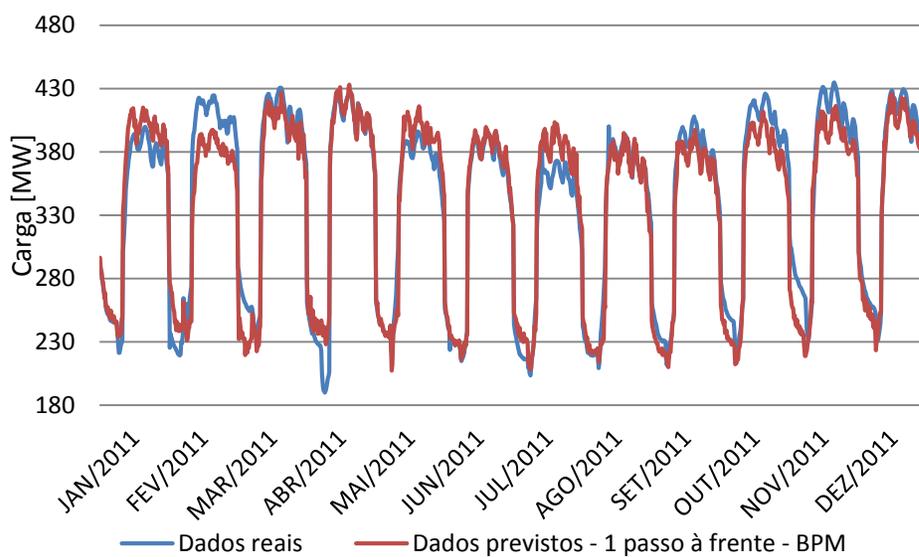


Figura 86 - Resultado previsão modelo I - 2011 Barramento I-Ag.I - 1 passo à frente.

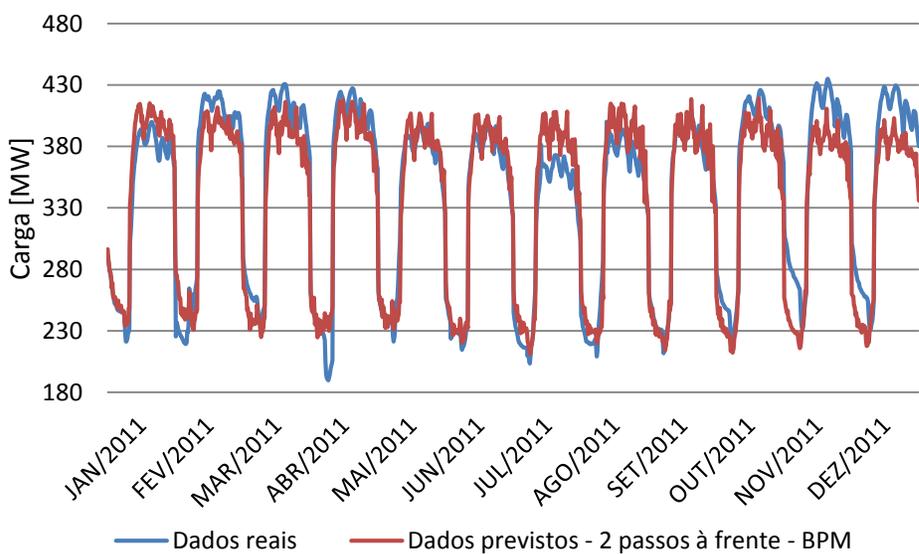


Figura 87 - Resultado previsão modelo I - 2011 Barramento I-Ag.I - 2 passos à frente.

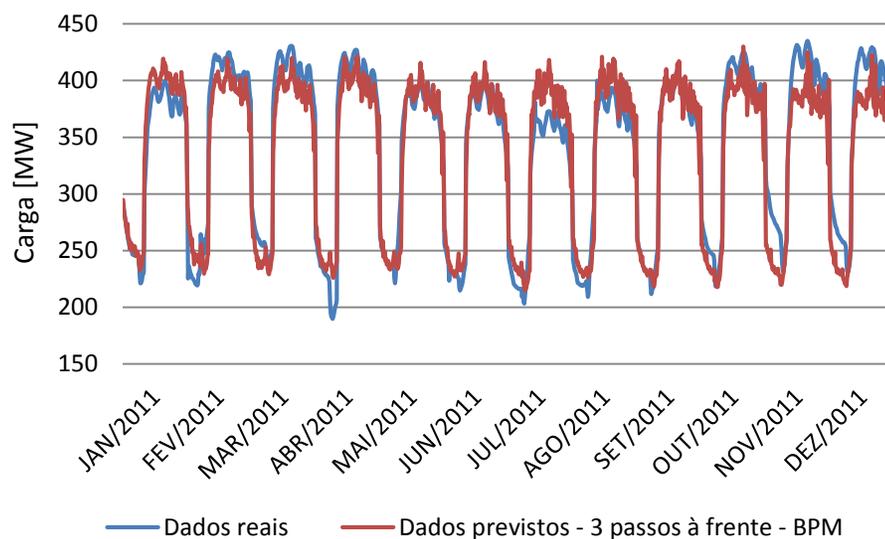


Figura 88 - Resultado previsão modelo I - 2011 Barramento I-Ag.I - 3 passos à frente.

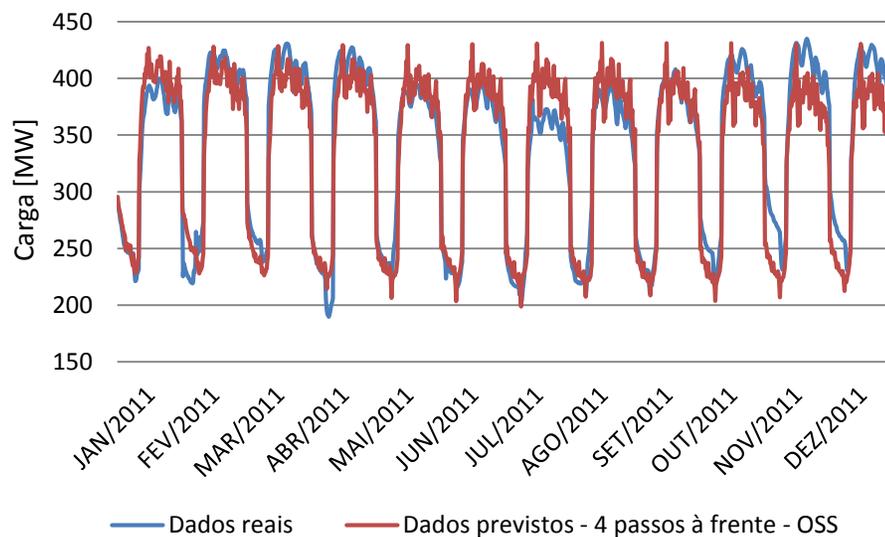


Figura 89 - Resultado previsão modelo I - 2011 Barramento I-Ag.I - 4 passos à frente.

Para 1 passo à frente foi possível modelar a tendência e a sazonalidade que existe na série proposta para as previsões. Em contra partida, nos outros casos não foram obtidos os mesmos resultados. Porém, os erros médios absolutos para todos os casos se mostraram satisfatórios.

6.3.3.2 Modelo II

Os erros médios absolutos das previsões dos limites, máximos e mínimos, de 1 a 4 passos à frente se encontram na Tabela 21. Os métodos PR e BPM foram os que obtiveram menores erros médios absolutos para as previsões de 1 passo à frente, respectivamente 3,14% para a carga máxima e 4,44% para a carga mínima. Para 2 passos à frente o método BPM obteve menor erro médio absoluto tanto para a previsão da carga máxima quanto da mínima, com respectivamente 4,06% e 4,48% de erro. Os métodos DFP e OSS foram os que obtiveram menores erros médios absolutos nas previsões de 3 passos à frente com 3,61% e 4,54% respectivamente na previsão da carga máxima e mínima. Finalmente, para as previsões de 4 passos à frente os métodos GRAD e BFGS foram os que obtiveram melhores resultados para prever a carga máxima e mínima com respectivamente 3,99% e 4,37% de erro médio absoluto.

Tabela 21 - Erro médio absoluto métodos RNAs - modelo II – Barramento I-Ag.I – 1 a 4 passos à frente.

Passos	Erro médio absoluto	GRAD	BFGS	DFP	OSS	PR	FR	SCGM	BPM
1 passo	Carga máxima	3,98%	3,89%	3,56%	3,72%	3,14%	3,92%	3,19%	3,02%
	Carga mínima	4,67%	5,34%	5,50%	5,28%	5,50%	5,23%	6,58%	4,44%
2 passos	Carga máxima	5,04%	4,59%	4,56%	4,78%	14,50%	4,50%	13,20%	4,06%
	Carga mínima	4,65%	4,70%	4,79%	4,79%	4,91%	4,96%	9,48%	4,48%
3 passos	Carga máxima	4,11%	3,73%	3,61%	4,67%	9,60%	5,24%	7,40%	3,82%
	Carga mínima	4,81%	4,84%	4,85%	4,54%	4,62%	4,76%	8,30%	4,96%
4 passos	Carga máxima	3,99%	4,18%	4,50%	4,50%	4,62%	4,24%	6,53%	4,54%
	Carga mínima	5,01%	4,37%	4,47%	4,54%	4,40%	4,48%	5,26%	4,80%

Na Tabela 22 é possível observar os erros médios absolutos das previsões das curvas de carga crítica de 1 a 4 passos à frente, obtidas pelo modelo II.

Tabela 22 - Erro médio absoluto - modelo II – Barramento I-Ag.I – 1 a 4 passos à frente.

Passos	Erro médio absoluto
1 passo	4,66%
2 passos	4,76%
3 passos	4,61%
4 passos	4,82%

As curvas de cargas críticas horárias previstas nesta Seção podem ser observadas nas Figura 90, Figura 91, Figura 92 e Figura 93.

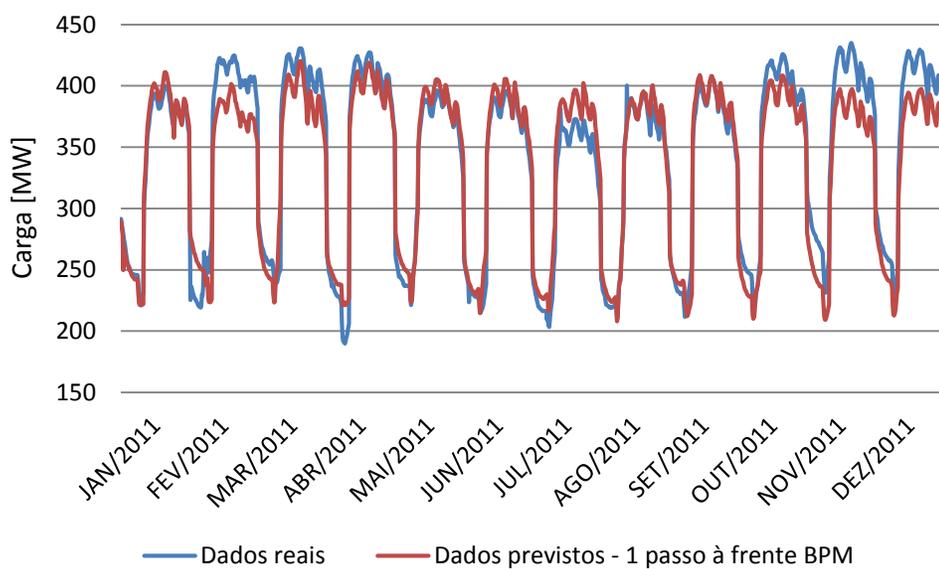


Figura 90 - Resultado previsão modelo II - 2011 Barramento I-Ag.I - 1 passo à frente.

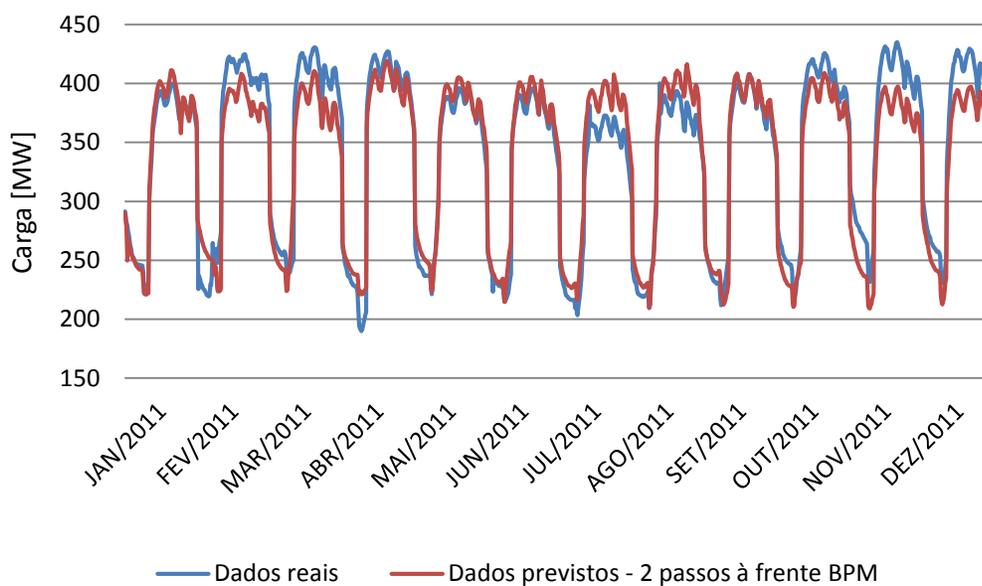


Figura 91 - Resultado previsão modelo II - 2011 Barramento I-Ag.I - 2 passos à frente.

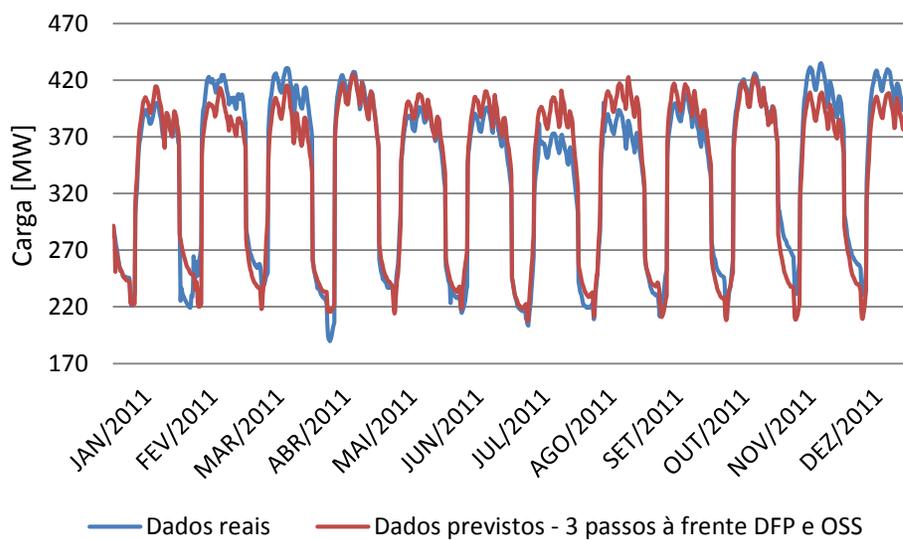


Figura 92 - Resultado previsão modelo II - 2011 Barramento I-Ag.I - 3 passos à frente.

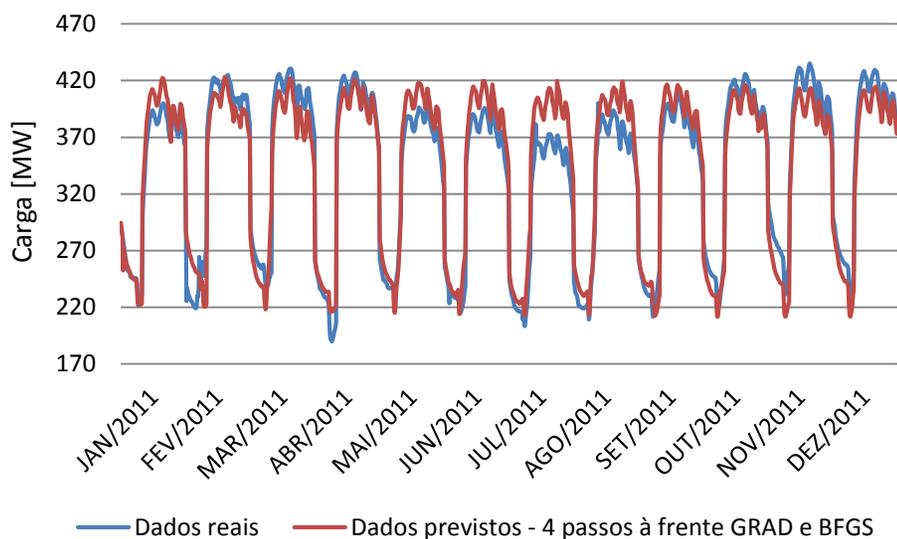


Figura 93 - Resultado previsão modelo II - 2011 Barramento I-Ag.I - 4 passos à frente.

Todas as RNAs utilizadas possuem arquitetura de 3 camadas sendo 4 neurônios na entradas, uma na saída e uma média de 7 neurônios na camada intermediária para as previsões de 1 a 4 passos à frente.

6.3.3.3 Modelo Holt-Winters

Os erros médios absolutos obtidos nas previsões das curvas de carga crítica para o ano de 2011 com o modelo Holt-Winters de 1 a 4 passos à frente estão presente na Tabela 23.

Tabela 23 - Erro médio absoluto - modelo Holt-Winters – Barramento I-Ag.I – 1 a 4 passos à frente.

Passos	Erro médio absoluto
1 passo	3,78%
2 passos	3,34%
3 passos	5,32%
4 passos	5,82%

A Figura 94, Figura 95, Figura 96 e Figura 97 apresentam as curvas de carga crítica previstas para respectivamente 1, 2, 3 e 4 passos à frente.

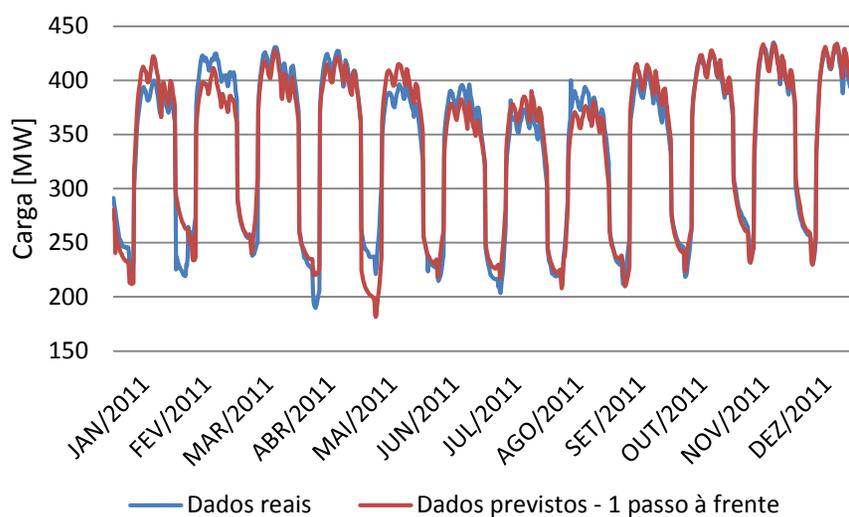


Figura 94 - Resultado previsão Holt-Winters - 2011 Barramento I-Ag.I - 1 passo à frente.

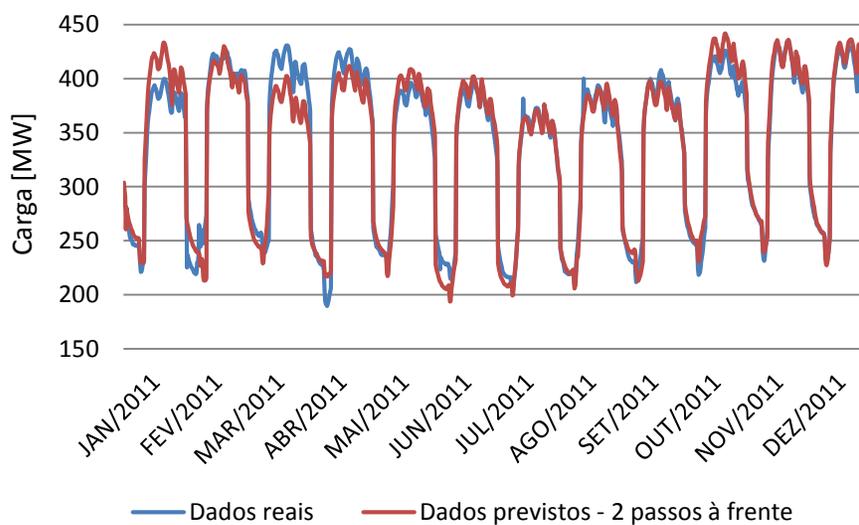


Figura 95 - Resultado previsão Holt-Winters - 2011 Barramento I-Ag.I - 2 passos à frente.

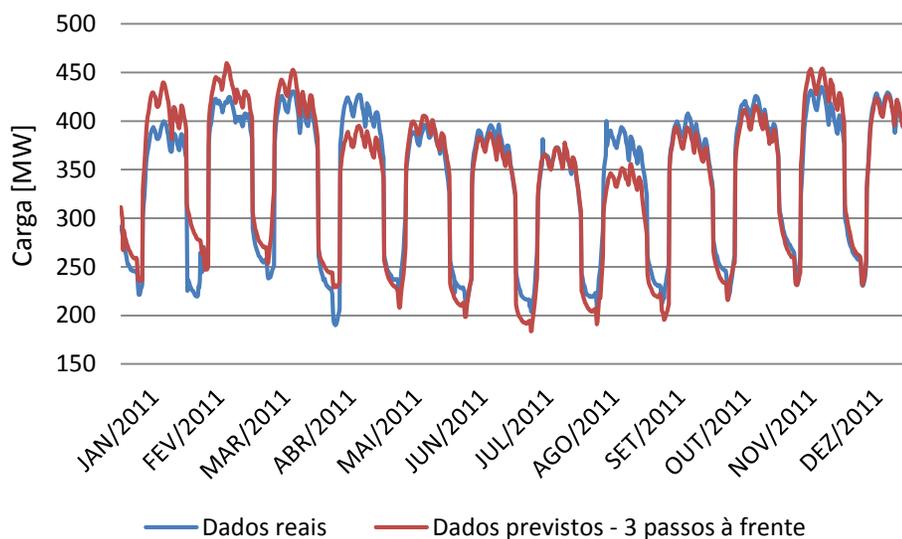


Figura 96 - Resultado previsão Holt-Winters - 2011 Barramento I-Ag.I - 3 passos à frente.

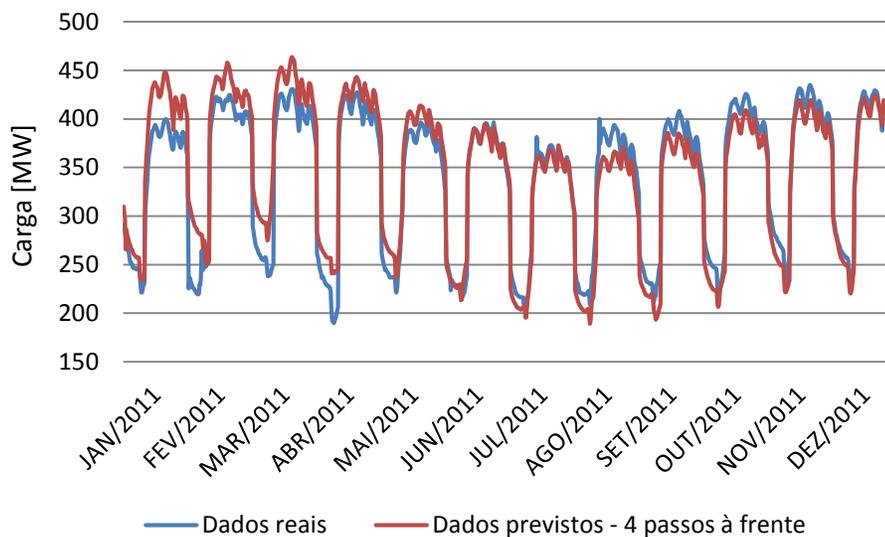


Figura 97 - Resultado previsão Holt-Winters - 2011 Barramento I-Ag.I - 4 passos à frente.

Para os resultados do modelo de HW da série Barramento I-Ag.I, ocorreu um fato não muito comum. O erro médio absoluto de um passo à frente, no decorrer do ano de 2011, foi maior que o erro de dois passos à frente. Isso se deve ao fato dos erros cometidos, pelo previsor, ao longo da série, serem mais “graves”, em valor ou em frequência, do que todos os outros erros ocorridos

durante a série pelo outro previsor. Para um passo à frente o erro médio absoluto foi de 3,78%, e não muito diferente, o erro médio absoluto de dois passos à frente foi de 3,34%. Para 3 e 4 passos à frente nota-se que no mês de Abril a carga leve da série real sofreu uma mudança diferente, com maior variação, com relação aos outros meses do histórico. Esta variação o modelo HW não conseguiu prever, porém para previsão de 3 e 4 passos à frente o modelo se apresentou bastante satisfatório.

6.3.3.4 Comparação entre os modelos

Os melhores resultados de cada modelo proposto encontram-se na Tabela 24. Observe que novamente o modelo HW obteve melhores resultados para 1 e 2 passos à frente e o modelo II para 3 e 4 passos à frente. Isso deve-se ao fato do Barramento I-Ag.I possuir uma similaridade de comportamento de série com o Agente I, o que se reforça pelo motivo de pertencer ao agente. A série do Barramento I-Ag.I, também possui sazonalidade e tendência marcante, o que facilita a utilização do modelo HW, não descartando a validade de utilização de RNAs para previsão de curvas de carga crítica, onde obteve melhor resultado para 3 e 4 passos.

Tabela 24 - Resultados série Barramento I-Ag.I.

	1 passo à frente	2 passos à frente	3 passos à frente	4 passos à frente
Modelo I	4,11%	5,17%	5,24%	5,54%
Modelo II	4,66%	4,76%	4,61%	4,82%
Holt-Winters	3,78%	3,34%	5,32%	5,82%

6.4 COMENTÁRIOS SOBRE TODAS AS SÉRIES

Os modelos apresentados nesta dissertação necessitam de características específicas para obterem bons resultados. A primeira característica que se impõe para todos os modelos é a utilização de uma série temporal (histórica) livre de ruídos que não façam parte da natureza da série. Outro fator que deve-se levar em conta é o tempo que os modelos necessitam para realizarem

as previsões. Se for necessário prever dados críticos com agilidade o modelo mais adequado computacionalmente é o Holt-Winters, devido a sua metodologia o processo de suavização e previsão não demorarem a ser executados, o que não ocorre nos modelos compostos por RNAs. Observa-se ainda que o modelo II realiza previsões em menor tempo que o modelo I, para a mesma série histórica. Lembrando que o modelo I cria uma RNA para cada discretização da série.

Pode-se dizer que os modelos I e II devem ser utilizados em séries de curvas críticas que não possuam tendência e que o modelo Holt-Winter é aconselhável para séries que possuam tendência e sazonalidade. Essas afirmações são sugestões, dado que observando os erros médios absolutos todos os modelos propostos atingirão resultados satisfatórios, compatíveis com procedimentos em vigor do Setor Elétrico Brasileiro.

6.5 COMENTÁRIOS SOBRE GASTOS COMPUTACIONAIS DAS PREVISÕES

As previsões realizadas nesta dissertação não precisaram ser executadas em servidores de grande porte. Todas as previsões foram executadas em um *desktop* com a seguinte configuração: processador *Intel i7 – 3ª geração CPU 3.4 GHz x 8; 8 gigabytes* de memória RAM DDR3 e Sistema Operacional Linux Ubuntu 12.04 LTS.

As linguagens de programação utilizadas foram MATLAB e Java. Previamente, todas as previsões foram implementadas e testadas em MATLAB e em seguida implementadas em Java.

Os tempos gastos para as execuções das previsões nas duas linguagens foi praticamente o mesmo. Vale lembrar, que todas as previsões foram executadas com um histórico de 4 anos de treinamento e 1 ano de teste. A Tabela 25 apresenta os tempos aproximados gastos, em minutos, por cada modelo para realizar as previsões de 1, 2, 3 e 4 passos à frente.

Tabela 25 - Tempos de execuções das previsões

	Modelo I	Modelo II	Modelo Holt-Winters
1 passo à frente	240 min	3 min	0,5 min
2 passos à frente	240 min	3 min	1 min
3 passos à frente	300 min	4 min	1 min
4 passos à frente	300 min	5 min	1 min

Observando a Tabela 25 pode-se observar que o modelo I foi o que requereu mais tempo para executar as previsões. Este fato se justifica pela modelagem do mesmo, que requer uma RNA para cada discretização horária a ser prevista. Tanto o modelo II quanto o modelo Holt-Winters foram eficientes quanto ao tempo gasto para as previsões não ultrapassando de 5 min. Porém vale ressaltar, que se for necessário executar um número grande de previsões, que é o caso do setor de Estudos de Carga do ONS, o modelo Holt-Winters é o mais indicado, por possuir uma boa acurácia e um tempo de execução viável para estes grandes números de previsões.

7

Conclusões

A demanda de energia elétrica vem crescendo a cada dia em nosso país. Frente a este desafio, a previsão de carga possui sua importância significativa para o planejamento de todo o Sistema Elétrico Brasileiro. Saber os limites máximos e mínimos no qual cada barramento ou agente vai consumir em um ou dois meses à frente, para poder realizar o planejamento, é uma informação que se busca a todo o momento. Pois, se o sistema não estiver preparado para alterações bruscas no consumo de eletricidade, problemas como apagões, aumento na taxa de energia e outros prejuízos começam a aparecer. A previsão da curva de carga crítica é uma alternativa que o ONS e agentes do SEB utilizam para evitar e/ou solucionar estes problemas. Consequente disto, faz-se necessário possuir um bom modelo de previsão, pois pequenos erros poderiam gerar grandes prejuízos.

Prever a curva de carga crítica não é uma tarefa trivial, dado que inicialmente é preciso validar os dados, procurando saber se os mesmos não possuem transferências de cargas ou *outliers*. Os métodos propostos para identificação de transferência de carga e tratamento de *outliers* obtiveram resultados suficientes para remover inconsistências que poderiam afetar o processo de previsão. Ressaltando que, construir um histórico de curvas críticas confiáveis é um pré-requisito para assegurar previsões de qualidade.

Os modelos (previsores) propostos neste trabalho mostraram em sua grande maioria uma boa acurácia, com erros médios absolutos baixos e consistência nas previsões, compatíveis com procedimentos em vigor do Setor Elétrico Brasileiro. O modelo I apresentou melhores resultados com séries históricas que não possuíam tendência nem sazonalidade, a acurácia do mesmo não é a melhor entre os modelos propostos, mas é considerável aceitável. Já o modelo II obteve melhores resultados em comparação com o modelo I, prevendo com maior eficiência séries com tendência e sazonalidade. O modelo Holt-Winters foi o que apresentou melhores resultados em conjunto com o modelo II; O mesmo apresentou-se computacionalmente eficiente com relação ao tempo de execução e bons resultados. Pelo motivo da curva de carga crítica possuir características marcantes

de tendência e sazonalidade, os últimos dois modelos citados se adequaram melhor ao problema apresentado.

Se for necessário escolher um dos três modelos propostos, a sugestão seria utilizar o modelo de suavização exponencial sazonal de Holt-Winters, devido à sua metodologia ser proposta para dados como são as curvas de carga crítica que na maioria possuem tendência e sazonalidade. Vale observar também a robustez do modelo Holt-Winters do ponto de vista computacional. Em conjunto com a proposta de modelagem de utilização o mesmo se mostrou o melhor ou muito próximo dos melhores resultados de previsão apresentados.

Concluindo, os resultados obtidos nesta dissertação foram satisfatórios porém ainda existem pesquisas a serem realizadas com relação a curva de carga crítica. A seção de Trabalhos Futuros apresenta as alternativas que ainda serão testadas.

7.1 TRABALHOS FUTUROS

Como trabalhos futuros, pretende-se explorar novas técnicas para a previsão da curva de carga crítica. Modelos que ainda serão testados são:

- Modelos ARIMA;
- Modelos compostos de *Wavelet*;
- Modelos compostos de *Support Vector Machine*;
- Modelos híbridos;

Dentre os modelos híbridos, pretende-se testar previsões com diferentes modelos para a condição de carga leve e condição de carga média e pesada. Além destes modelos a serem estudados, como trabalhos futuros também fica a proposta de um estudo mais detalhado na criação de um perfil típico que possa representar o comportamento de um dado mês a ser previsto, técnica utilizada pelo modelo II e modelo Holt-Winters. Outro aspecto importante é a estimativa da carga reativa (MVAR), pois vários estudos elétricos utilizam esta informação.

REFERÊNCIAS

- AGAPIE, A., & AGAPIE, A. (1997). FORECASTING THE ECONOMIC CYCLES BASED ON AN EXTENSION OF THE HOLT-WINTERS MODEL - A GENETIC ALGORITHMS APPROACH. *Computational Intelligence for Financial Engineering (CIFer) - IEEE*, 96-99. New York, NY. Disponível em: <<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=618920&tag=1>>. Acessado em: Jan. de 2014.
- AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA - ANEEL. (Maio de 2008). Manual do Programa de Pesquisa e Desenvolvimento Tecnológico do Setor de Energia Elétrica. Brasília, DF.
- BILOBROVEC, M., MARÇAL, R. F., & PILATTI, L. A. (2004). Aplicações de redes neurais artificiais em simulações. *XI SIMPEP*, Disponível em: <<http://www.pg.utfpr.edu.br/ppgep/Ebook/ARTIGOS/9.pdf>>. Acessado em: 02 Jun. 2013.
- BISPO, C. A., & CAZARINI, E. W. (1998). A evolução do processo decisório. *Associação Brasileira de Engenharia de Produção - ENEGEP*, Disponível em: <http://www.abepro.org.br/biblioteca/ENEGEP1998_ART094.pdf>. Acessado em: Jan. de 2014.
- BOX, G. E., JENKINS, G. M., & REINSEL, G. C. (1994). *Time Series Analysis: Forecasting and Control*. 3ª ed: Englewood Cliffs NJ: Prentice-Hall.
- CAIO, L., & BERMANN, C. (1998). Análise das metodologias de previsão de mercado de energia elétrica face ao novo perfil de planejamento no ambiente pós-privatização. *III Congresso Brasileiro de Planejamento Energético*, Anais, São Paulo.
- CASTRO, L. N., & ZUBEN, F. J. (1998). Optimised Training Techniques For Feedforward Neural Networks. Technical Report. *Faculdade de Engenharia Elétrica, UNICAMP*, Disponível em: <http://www.researchgate.net/publication/2428674_Optimised_Training_Techniques_For_Feedforward_Neural_Networks/file/9fcfd5075b7cc7c48a.pdf>. Acessado em: 29 Jun. 2013.
- CHRISTIAANSE, W. R. (1971). Short-Term Load Forecasting Using General Exponential Smoothing. *IEEE Transactions On Power Apparatus and Systems*, Vol. Pas-90, no. 2.
- EKBERG, J., YLINEN, J., & LOULA, P. (2011). Network Behaviour Anomaly Detection Using Holt-Winters Algorithm. *6th International Conference on Internet Technology and Secured Transactions - IEEE*, 11-14. Abu Dhabi, United Arab Emirates.
- HAYKIN, S. (1999). *Redes Neurais: Princípios e prática*. São Paulo: 2ª ed. traduzida. Artmed Editora-Bookman.

- HIPPERT, H. S., PEDREIRA, C. E., & SOUZA, R. C. (2001). Neural Networks for Short-Term Load Forecasting: A Review and Evaluation. *IEEE Transactions on Power Systems*, Vol. 16. No. 1.
- HO, K., HSU, Y., & YANG, C. (1992). Short-term load forecasting using a multi-layer neural network with an adaptative learning algorithm. *IEEE Transactions on Power Systems*, 7: 141–149.
- KHOTANZAD, A., ROHANI, R. A., & MARATUKULAM, D. (1998). ANNSTLF - Artificial Neural Network Short-Term Load Forecaster - Generation Three. *IEEE Transactions on Power Systems*, Vol. 13. No. 4.
- LEE, K. Y., CHA, Y. T., & PARK, J. H. (1992). Short-Term Load Forecasting Using An Artificial Neural Network. *IEEE Transactions on Power Systems*, Vol. 7, No. 1.
- MONTGOMERY, D. C., & JOHNSON, L. A. (1976). *Forecasting and Time Series Analysis*. New York: McGraw-Hill.
- MORETTIN, P. A., & TOLOI, C. M. (2004). *Análise de Séries Temporais*. São Paulo: Edgard Blucher.
- SALGADO, R. M. (2009). Sistema de Suporte a Decisão para Previsão e Análise de Carga por Barramento. *Tese de Doutorado*, Faculdade de Engenharia Elétrica e de Computação - FEEC. Universidade Estadual de Campinas.
- VEMURI, S., HUANG, W. L., & NELSON, D. J. (1981). On-Line Algorithms For Forecasting Hourly Loads Of An Electric Utility. *IEEE Transactions on Power Apparatus and Systems*, Vol. PAS-100, no. 8.
- WINTERS, P. R. (1960). Forecasting sales by exponentially weighted moving average. *Management Science*, 6, 324-342.
- ZHU, G. et al. (2006). A Kind of Demand Forecasting Model Based on Holt-Winters Model and Customer-credit Evaluation Model. *Service Systems and Service Management-2006 International Conference on*, 334-338. Disponível em: <<http://ieeexplore.ieee.org/xpl/articleDetails.jsp?tp=&arnumber=4114456&queryText%3DHolt-Winters>>. Acessado em: Jan. de 2014.