

**UNIVERSIDADE FEDERAL DE SANTA MARIA
CENTRO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA
ÁREA DE CONCENTRAÇÃO EM SISTEMAS DE ENERGIA**

**COMBINAÇÃO SELETIVA DE MÉTODOS
PARA PREVISÃO DE DEMANDA A
CURTÍSSIMO PRAZO EM TEMPO REAL**

TESE DE DOUTORADO

Lukas Neusser

Santa Maria, RS, Brasil

2015

COMBINAÇÃO SELETIVA DE MÉTODOS PARA PREVISÃO DE DEMANDA A CURTÍSSIMO PRAZO EM TEMPO REAL

Lukas Neusser

Tese apresentada ao Programa de Pós-Graduação em Engenharia Elétrica,
Área de Concentração em Sistemas de Energia da Universidade Federal de
Santa Maria, como requisito parcial para a obtenção do grau de

Doutor em Engenharia Elétrica

Orientadora: Prof^a. Dr^a. Luciane Neves Canha

Santa Maria, RS, Brasil

2015

Neusser, Lukas

Combinação seletiva de métodos para previsão de demanda a curtíssimo prazo em tempo real / por Lukas Neusser. – 2015.

131 f.: il.; 30 cm.

Orientadora: Luciane Neves Canha

Tese (Doutorado) - Universidade Federal de Santa Maria, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia Elétrica, Área de Concentração em Sistemas de Energia, RS, 2015.

1. Previsão de demanda. 2. Curtíssimo prazo. 3. Combinação de métodos. I. Canha, Luciane Neves. II. Título.

© 2015

Todos os direitos autorais reservados a Lukas Neusser. A reprodução de partes ou do todo deste trabalho só poderá ser feita mediante a citação da fonte.

E-mail: lukasneusser@hotmail.com

**Universidade Federal de Santa Maria
Centro de Tecnologia
Programa de Pós-Graduação em Engenharia Elétrica
Área de Concentração em Sistemas de Energia**

A Comissão Examinadora, abaixo assinada,
aprova a Tese de Doutorado

**COMBINAÇÃO SELETIVA DE MÉTODOS PARA PREVISÃO DE
DEMANDA A CURTÍSSIMO PRAZO EM TEMPO REAL**

elaborada por
Lukas Neusser

como requisito parcial para obtenção do grau de
Doutor em Engenharia Elétrica

COMISSÃO EXAMINADORA:

Luciane Neves Canha, Dr^a.
(Presidente/Orientadora)

Gladis Bordin, Dr^a. (UFRGS)

Luciano Lopes Pfitscher, Dr. (UFSC)

Alzenira da Rosa Abaide, Dr^a. (UFSM)

Daniel Pinheiro Bernardon, Dr. (UFSM)

Santa Maria, 6 de Março de 2015.

À minha esposa Adriana e meus filhos Joshua e Sarah. E à Madu.

AGRADECIMENTOS

Agradeço em primeiro lugar a Deus, pela oportunidade e privilégio de fazer um Doutorado.

À minha orientadora Prof^a. Dr^a. Luciane Neves Canha, que apesar de enfrentar períodos difíceis na vida pessoal, nunca esmoreceu, mantendo inalterado o nível de empenho durante estes anos de gestação da tese.

À minha esposa Adriana pelo amor, compreensão, noites pouco ou mal dormidas, preocupações e por todo o cuidado para tornar meus estudos os mais leves possíveis, retirando todo e qualquer peso das minhas costas que pudessem interferir na qualidade do trabalho.

Aos meus filhos Joshua e Sarah, por entenderem a importância do projeto do pai.

Aos agora já na maioria mestrandos ou engenheiros, acadêmicos Maicon Finger, Juliano André Wenzel e Wiliam Ismael Schmitz pelos auxílios, ideias e participação no projeto.

Ao funcionário da UFSM, mestre e engenheiro Luiz Fernando Guarienti Martins, pelo apoio logístico e técnico.

A todos estes, e tantos outros não citados aqui, meus sinceros agradecimentos pelas contribuições de diversas formas, sem as quais a presente tese não existiria.

“Haja luz!”

— DEUS, NO INÍCIO DA CRIAÇÃO, AO LANÇAR A DUALIDADE ONDA-PARTÍCULA DA LUZ

RESUMO

Tese de Doutorado
Programa de Pós-Graduação em Engenharia Elétrica
Área de Concentração em Sistemas de Energia
Universidade Federal de Santa Maria

COMBINAÇÃO SELETIVA DE MÉTODOS PARA PREVISÃO DE DEMANDA A CURTÍSSIMO PRAZO EM TEMPO REAL

AUTOR: LUKAS NEUSSER

ORIENTADORA: LUCIANE NEVES CANHA

Local da Defesa e Data: Santa Maria, 6 de Março de 2015.

No processo de transformação das redes de energia elétrica atuais, em redes elétricas inteligentes (*smart grid*), a previsão de demanda é relevante para processos como o gerenciamento da demanda, resposta a demanda, geração distribuída, entre outros. Para os consumidores, a substituição de medidores eletromecânicos, por medidores eletrônicos, possibilita o acesso em tempo real aos dados da medição, disponibilizando estes dados para a previsão de demanda.

O presente trabalho focaliza em consumidores de diferentes perfis, comerciais, industriais e institucionais, ligados à rede de distribuição em média tensão, com demandas situadas em uma faixa de algumas dezenas de quilowatts até dois megawatts. Para estes consumidores, uma previsão de demanda para curtíssimo prazo (até 2 horas) será uma importante ferramenta na tomada de decisão em um ambiente dinâmico, com tarifas variáveis no tempo, gerenciamento pelo lado da demanda e eventual geração própria.

A partir da aplicação de métodos de previsão de demanda em consumidores de variados perfis de carga, é demonstrado que os métodos de previsão com melhor precisão (menor erro médio) variam de consumidor para consumidor. Para um mesmo consumidor o método de melhor precisão também é variável, sendo dependente da hora do dia.

Uma combinação de diversos métodos de previsão de demanda resulta em performance similar ou superior se comparado ao uso de apenas um método individual. Propõe-se um método de combinação seletiva, com o objetivo de eliminar o risco da escolha de um único método, cujos resultados são imprevisíveis. Os resultados da aplicação do método de combinação proposto, em diversos consumidores de características diferentes, demonstram que a combinação seletiva representa uma melhora na qualidade da previsão.

Palavras-chave: Previsão de demanda. Curtíssimo prazo. Combinação de métodos.

ABSTRACT

Post-Graduate Program in Electrical Engineering - Research Area in Energy Systems
Federal University of Santa Maria

SELECTIVE COMBINATION OF VERY SHORT-TERM LOAD FORECASTING METHODS IN REAL-TIME

AUTHOR: LUKAS NEUSSER

ADVISOR: LUCIANE NEVES CANHA

Defense Place and Date: Santa Maria, March 6th, 2015.

In transforming the current electricity network, in a so called smart grid, demand forecasting is relevant to processes such as demand management, demand response, distributed generation, among others. For consumers, the replacement of electromechanical meters by electronic meters, enables real-time access to measurement data, providing this data for demand forecasting.

The present work focuses on consumers with different profiles, commercial, industrial and institutional, connected to the the distribution network in medium-voltage and loads ranging between a few tens of kilowatts and two megawatts. For these consumers, very short-term demand forecasting (up to 2 hours) will be an important tool for decision making in a dynamic environment, with time-variable energy prices, demand-side management and eventually own generation.

With the application of demand forecasting methods to various consumers with different profiles, it is shown that the forecasting methods with better accuracy (lower average error) are variable from consumer to consumer. For one consumer individually, the method with better accuracy is also variable, depending on the hour of the day.

Combination of several demand forecasting methods results in similar or better performance compared to using only a single method. A method of selective combination is proposed, in order to eliminate the risk of choosing a unique method, which results are unpredictable. The results of the application of the proposed combination method, on several consumers with different characteristics, demonstrate that selective combination improves the quality of the forecast.

Keywords: Load Forecasting, Real-time methods.

LISTA DE FIGURAS

Figura 2.1 – Previsão de demanda: horizontes / métodos para curtíssimo prazo	26
Figura 3.1 – Amostra das demandas incluindo faixa de variação máx/mín para dias de inverno	35
Figura 3.2 – Exemplo de preenchimento de dados faltantes na série temporal	36
Figura 3.3 – Fluxo para aquisição de dados, adequação e armazenamento.	37
Figura 3.4 – Fluxo da previsão de demanda na primeira etapa.	39
Figura 3.5 – Gráfico com a demanda lida, previsão feita 15 minutos antes e o erro absoluto entre os dias 12 e 16 de janeiro de 2014	48
Figura 3.6 – Demandas do consumidor A1 entre 21 de novembro de 17 de dezembro de 2013	50
Figura 3.7 – Demandas do consumidor A2 entre 10 de setembro de 7 de outubro de 2013	50
Figura 3.8 – Demandas do consumidor B entre 2 de julho e 1 de agosto de 2013	51
Figura 3.9 – Demandas do consumidor C entre 14 de outubro de 12 de novembro de 2013	51
Figura 3.10 – Demandas do consumidor D entre 14 de outubro de 12 de novembro de 2009	52
Figura 3.11 – Demandas do consumidor E entre 9 de julho e 8 de agosto de 2013	52
Figura 3.12 – Demandas do consumidor F entre 8 e 28 de junho de 2013	53
Figura 3.13 – Demandas do consumidor G entre 6 de setembro e 7 de outubro de 2013	53
Figura 3.14 – Exemplo de decomposição de uma série temporal de demandas de um posto de combustíveis	58
Figura 3.15 – Rede neural alimentada adiante focada atrasada no tempo. Figura adaptada de Haykin (1999).	59
Figura 3.16 – Fluxograma da previsão de demanda aplicando um dos oito métodos utilizando dados de um consumidor	62
Figura 3.17 – Consumidor E: MAPE em função do horizonte de previsão para cada um dos oito métodos	65
Figura 3.18 – Consumidor E: MAPE do método HWMULT em função do horário e do horizonte de previsão	66
Figura 3.19 – Consumidor E: Mapeamento dos métodos com menor erro em função do horário e horizonte de previsão.	67
Figura 4.1 – Detalhamento das etapas na previsão de demanda proposta	71
Figura 4.2 – Fluxo lógico da previsão de demanda em duas etapas, com combinação seletiva na segunda etapa.	78
Figura 4.3 – Consumidor E: Erros percentuais dos métodos de combinação em comparação aos métodos de avaliação.	80
Figura 4.4 – Consumidor E: Comparação dos erros absolutos em função do horário para horizonte 30 minutos.	82
Figura 4.5 – Consumidor E: Comparação dos erros absolutos em função do horário para horizonte 60 minutos.	82
Figura 4.6 – Demandas do consumidor V entre 6 de abril e 6 de maio de 2009.	84
Figura 4.7 – Demandas do consumidor W entre 2 de março de 9 de abril de 2014.	84
Figura 4.8 – Demandas do consumidor X entre 2 de fevereiro e 3 março de 2009.	85
Figura 4.9 – Demandas do consumidor Y entre 14 de janeiro e 13 de fevereiro de 2009. ..	85
Figura A.1 – Consumidor A1: Oito métodos e seu MAPE em função do horizonte de previsão	105

Figura A.2 – Consumidor A2: Oito métodos e seu MAPE em função do horizonte de previsão	106
Figura A.3 – Consumidor B: Oito métodos e seu MAPE em função do horizonte de previsão	107
Figura A.4 – Consumidor C: Oito métodos e seu MAPE em função do horizonte de previsão	108
Figura A.5 – Consumidor D: Oito métodos e seu MAPE em função do horizonte de previsão	109
Figura A.6 – Consumidor E: Oito métodos e seu MAPE em função do horizonte de previsão	110
Figura A.7 – Consumidor F: Oito métodos e seu MAPE em função do horizonte de previsão	111
Figura A.8 – Consumidor G: Oito métodos e seu MAPE em função do horizonte de previsão	112
Figura A.9 – Relevos dos erros percentuais do consumidor A1 - Método X Horizonte X Horário	113
Figura A.10 – Relevos dos erros percentuais do consumidor A2 - Método X Horizonte X Horário	114
Figura A.11 – Relevos dos erros percentuais do consumidor B - Método X Horizonte X Horário	115
Figura A.12 – Relevos dos erros percentuais do consumidor C - Método X Horizonte X Horário	116
Figura A.13 – Relevos dos erros percentuais do consumidor D - Método X Horizonte X Horário	117
Figura A.14 – Relevos dos erros percentuais do consumidor E - Método X Horizonte X Horário	118
Figura A.15 – Relevos dos erros percentuais do consumidor F - Método X Horizonte X Horário	119
Figura A.16 – Relevos dos erros percentuais do consumidor G - Método X Horizonte X Horário	120
Figura A.17 – Legenda de cores dos mapeamentos dos métodos com menor erro em cada hora e horizonte	121
Figura A.18 – Consumidor A1: Mapeamento dos métodos com menor erro em função do horário e horizonte de previsão	121
Figura A.19 – Consumidor A2: Mapeamento dos métodos com menor erro em função do horário e horizonte de previsão	121
Figura A.20 – Consumidor B: Mapeamento dos métodos com menor erro em função do horário e horizonte de previsão	122
Figura A.21 – Consumidor C: Mapeamento dos métodos com menor erro em função do horário e horizonte de previsão	122
Figura A.22 – Consumidor D: Mapeamento dos métodos com menor erro em função do horário e horizonte de previsão	122
Figura A.23 – Consumidor E: Mapeamento dos métodos com menor erro em função do horário e horizonte de previsão	123
Figura A.24 – Consumidor F: Mapeamento dos métodos com menor erro em função do horário e horizonte de previsão	123
Figura A.25 – Consumidor G: Mapeamento dos métodos com menor erro em função do horário e horizonte de previsão	123
Figura B.1 – Consumidor A1: MAPE dos métodos de combinação e métodos de avaliação	124
Figura B.2 – Consumidor A2: MAPE dos métodos de combinação e métodos de avaliação	125

- Figura B.3 – Consumidor B: MAPE dos métodos de combinação e métodos de avaliação . 126
- Figura B.4 – Consumidor C: MAPE dos métodos de combinação e métodos de avaliação . 127
- Figura B.5 – Consumidor D: MAPE dos métodos de combinação e métodos de avaliação . 128
- Figura B.6 – Consumidor E: MAPE dos métodos de combinação e métodos de avaliação . 129
- Figura B.7 – Consumidor F: MAPE dos métodos de combinação e métodos de avaliação . 130
- Figura B.8 – Consumidor G: MAPE dos métodos de combinação e métodos de avaliação . 131

LISTA DE TABELAS

Tabela 3.1 – Erros médios obtidos nas previsões para os dias 6 a 9 de agosto de 2013	45
Tabela 3.2 – Erros médios obtidos nas previsões para os dias 5 a 13 de novembro de 2013.	46
Tabela 3.3 – Erros médios obtidos nas previsões para os dias 14 a 21 de novembro de 2013.	46
Tabela 3.4 – Erros médios obtidos nas previsões para os dias 12 a 16 de janeiro de 2014. .	46
Tabela 3.5 – Resumo dos consumidores utilizados na segunda etapa	49
Tabela 3.6 – Tabela de consulta às funções utilizadas	60
Tabela 3.7 – Exemplo da estrutura inicial da planilha contendo as demandas lidas	61
Tabela 3.8 – Método de gravação em tabela das previsões, facilitando análise posterior . . .	63
Tabela 3.9 – Erros percentuais médios por método e horizonte de previsão - Consumidor E	64
Tabela 3.10 – Tempos de computação médios necessários para calcular um vetor com as 24 previsões	69
Tabela 4.1 – Processo SELECT para uma previsão com horizonte de 60 minutos. Os círculos indicam o menor erro e a demanda selecionada correspondente para as 19:50h	73
Tabela 4.2 – Processo de média seletiva AVG2 para uma previsão com horizonte de 60 minutos. Os círculos indicam o menor erro e as demandas selecionadas para cálculo da média, que é a previsão para 19:50h.	73
Tabela 4.3 – Demonstração do processo de seleção a partir do menor erro médio para uma previsão com horizonte de 60 minutos. As caixas indicam o menor erro médio e o predictor selecionado para as 19:50h.	74
Tabela 4.4 – Processo de regressão seletiva (REG2) feita com das previsões dos três métodos com menor erro médio nos 12 períodos anteriores, para uma previsão com horizonte de 60 minutos. As caixas indicam os métodos com menor erro utilizados na regressão, e as demandas da previsão para as 19:50 que foram combinadas.	76
Tabela 4.5 – Processo de média seletiva (AVG3) feita com das previsões dos três métodos com menor erro médio nos 12 períodos anteriores, para uma previsão com horizonte de 60 minutos. As caixas indicam os métodos com menor erro utilizados na média, e as demandas da previsão para as 19:50h que foram combinadas.	77
Tabela 4.6 – Métodos, por consumidor, que apresentam o menor erro global.	79
Tabela 4.7 – Consumidor E: Erros percentuais médios da etapa de combinação e métodos de avaliação.	81
Tabela 4.8 – Comparativo entre o MAPE do melhor método isolado e dos três melhores métodos de combinação.	81
Tabela 4.9 – Comparação dos erros absolutos médios do melhor método isolado e dos três melhores métodos de combinação.	83
Tabela 4.10 – Resumo dos consumidores adicionais.	86
Tabela 4.11 – Comparação dos erros absolutos médios do melhor método isolado e dos três melhores métodos de combinação.	86
Tabela A.1 – Tabela resumindo funções em R utilizadas - Séries Temporais	103
Tabela A.1 – Erros percentuais médios por método e horizonte de previsão - Consumidor A1	105

Tabela A.2 – Erros percentuais médios por método e horizonte de previsão - Consumidor A2	106
Tabela A.3 – Erros percentuais médios por método e horizonte de previsão - Consumidor B	107
Tabela A.4 – Erros percentuais médios por método e horizonte de previsão - Consumidor C	108
Tabela A.5 – Erros percentuais médios por método e horizonte de previsão - Consumidor D	109
Tabela A.6 – Erros percentuais médios por método e horizonte de previsão - Consumidor E	110
Tabela A.7 – Erros percentuais médios por método e horizonte de previsão - Consumidor F	111
Tabela A.8 – Erros percentuais médios por método e horizonte de previsão - Consumidor G	112
Tabela B.1 – Consumidor A1: MAPE dos métodos de combinação e métodos de avaliação	124
Tabela B.2 – Consumidor A2: MAPE dos métodos de combinação e métodos de avaliação	125
Tabela B.3 – Consumidor B: MAPE dos métodos de combinação e métodos de avaliação .	126
Tabela B.4 – Consumidor C: MAPE dos métodos de combinação e métodos de avaliação .	127
Tabela B.5 – Consumidor D: MAPE dos métodos de combinação e métodos de avaliação .	128
Tabela B.6 – Consumidor E: MAPE dos métodos de combinação e métodos de avaliação .	129
Tabela B.7 – Consumidor F: MAPE dos métodos de combinação e métodos de avaliação .	130
Tabela B.8 – Consumidor G: MAPE dos métodos de combinação e métodos de avaliação .	131

LISTA DE ANEXOS

ANEXO A – Tabelas e gráficos com resultados do capítulo 3	105
ANEXO B – Tabelas e gráficos com resultados do capítulo 4	124

LISTA DE ABREVIATURAS E SIGLAS

AR	<i>Autoregressive</i>
ARIMA	<i>Autoregressive Integrated Moving Average</i>
ARMA	<i>Autoregressive Moving Average</i>
ARMAX	<i>Autoregressive Moving Average with exogenous variables</i>
EUA	Estados Unidos da América
GARCH	modelo autoregressivo condicionalmente heterocedástico/ heteroscedástico generalizado
GD	Geração distribuída
GLD	Gerenciamento pelo Lado da Demanda
GPRS	<i>General Packet Radio Service</i>
HWT	Holt-Winters
IEEE	<i>Institute of Electrical and Electronics Engineers</i>
MA	<i>Moving Average</i>
MAE	<i>Mean absolute error</i>
MAPE	<i>Mean Absolute Percentage Error</i>
MASE	<i>Mean Absolute Scaled Error</i>
PDCP	Previsão de demanda para curtíssimo prazo
PSO	<i>Particle Swarm Optimization</i>
RMSE	<i>Root mean squared error</i>
SARIMA	<i>Seasonal Autoregressive Integrated Moving Average</i>
STL	<i>Seasonal-Trend decomposition using Loess</i>
SVR	<i>Support Vector Regression</i>
TCP/IP	<i>Transmission Control Protocol / Internet Protocol</i>
UFSM	Universidade Federal de Santa Maria

SUMÁRIO

1 INTRODUÇÃO	19
1.1 Motivação	21
1.2 Objetivos	22
1.3 Contribuições inovadoras	23
1.4 Organização do trabalho	24
2 REVISÃO BIBLIOGRÁFICA DE PREVISÃO DA DEMANDA PARA CURTÍSSIMO PRAZO	25
2.1 Principais estudos de PDCP	26
2.1.1 Métodos lineares ou estatísticos	26
2.1.2 Métodos não-lineares	27
2.2 Combinação de previsões	28
2.2.1 A combinação de previsões na estatística	28
2.2.2 Combinação de métodos na previsão de demanda	30
2.3 Considerações finais	31
3 PREVISÃO DE DEMANDA PARA CURTÍSSIMO PRAZO	33
3.1 Análise dos aspectos técnicos na previsão de demanda para curtíssimo prazo	33
3.1.1 O medidor empregado	34
3.1.2 Aquisição de dados, controle e previsão.....	34
3.1.3 Métodos utilizados na previsão e sua implementação	38
3.1.4 Resultados	44
3.1.5 Discussão dos resultados e da análise dos aspectos técnicos	45
3.2 Comparativo na aplicação PDCP a consumidores de perfis diferentes	48
3.2.1 Características das curvas de demanda usados no comparativo	49
3.2.2 Aplicação dos métodos de previsão	54
3.2.3 Detalhes práticos da aplicação dos métodos	60
3.2.4 Resultados	63
3.2.5 Discussão dos resultados	67
3.3 Considerações finais do capítulo	69
4 COMBINAÇÃO SELETIVA PARA PREVISÃO DE DEMANDA EM CURTÍSSIMO PRAZO	70
4.1 Avaliação dos dos métodos de combinação propostos	70
4.2 Métodos de combinação propostos nesta tese	72
4.2.1 Seleção do método com menor erro anterior	72
4.2.2 Média seletiva - critério menor erro anterior	73
4.2.3 Seleção do método com menor erro médio em passado recente	74
4.2.4 Regressão linear seletiva	75
4.2.5 Média seletiva - critério menor média de erros anterior	76
4.3 Resultados na aplicação dos métodos propostos	77
4.3.1 Aplicação do método proposto em consumidores adicionais	83
4.4 Discussão dos resultados	86
5 CONCLUSÃO	88
5.1 Considerações finais	88
5.2 Publicações	89
5.3 Trabalhos futuros	90
REFERÊNCIAS	91

APÊNDICES	98
ANEXOS	104

1 INTRODUÇÃO

A energia elétrica, como produto, possui uma característica única que a diferencia de qualquer outro insumo necessário para a vida moderna: a dificuldade em armazená-la. Como consequência, a energia elétrica precisa ser produzida no mesmo instante que ela é consumida. Além disso, do ponto de vista geográfico, a energia elétrica é consumida de forma distribuída, enquanto a produção se concentra em determinados pontos. Pela impossibilidade de existirem entrepostos de armazenamento, todo sistema elétrico de potência que interliga o local de geração com os locais de consumo, deve ser dimensionado para o momento de maior demanda.

A partir do início da geração da energia elétrica em corrente alternada (Niagara Falls, novembro de 1896), a preocupação inicial dos engenheiros era dimensionar os sistemas somando corretamente todas as cargas conectadas. O foco das pesquisas naquela época estava na expansão do sistema, no carregamento de alimentadores e na necessidade de construção de novas linhas.

Atualmente a energia elétrica tornou-se o recurso indispensável à sobrevivência da humanidade, tal o grau de dependência da vida moderna deste insumo. O foco das pesquisas mudou completamente: está no esgotamento das grandes fontes de energia e as consequências climáticas da emissão de CO₂ na atmosfera, proveniente da queima de combustíveis fósseis na produção de energia. Em decorrência disso, as pesquisas e ações práticas delas resultantes, foram buscar fontes alternativas de energia e maior eficiência do sistema elétrico como um todo. Como efeito, a geração da energia elétrica passa a acontecer cada vez mais de maneira distribuída (descentralizada) e com fontes limpas.

Na questão da eficiência, o sistema elétrico está sendo dotado de inteligência, agregando capacidade decisória e de comunicação aos seus atuadores, no que é chamado de rede elétrica inteligente (*smart grid*). É fundamental que isto ocorra, pois com a maior penetração de geração e armazenamento distribuído, muda a topologia lógica das redes, visto que o fluxo de energia, antes unidirecional, pode se tornar bidirecional. Regiões, bairros e consumidores individuais, antes agentes estáticos, estão se tornando atores dinâmicos neste novo cenário.

Todavia, as fontes de energia limpas, em especial a solar e a eólica, mas também a energia vindo do bagaço da cana ou da casca de arroz, são fontes cuja disponibilidade é flutuante. Dependem de fatores climáticos, sobre os quais os operadores não têm influência. Há necessidade de um gerenciamento pelo lado da demanda (GLD) de modo que a energia proveniente

destas fontes seja utilizada de forma eficiente, isto é, em momentos de tarifa mais elevada (em um ambiente de tarifas variáveis) ou em momentos de maior demanda¹. A crescente dependência de fontes de energia variáveis, exige uma inversão da lógica de operação do sistema elétrico: a carga necessita se adaptar à geração disponível (WIJAYA; LARSON; ABERER, 2013), (RAMCHURN et al., 2012).

Uma implementação satisfatória do GLD necessita de uma ferramenta indispensável na tomada de decisão: a previsão da demanda para curtíssimo prazo, em tempo real. O conhecimento da demanda futura possibilita a eficiente utilização de fontes de energia alternativas, cuja disponibilidade é intermitente ou de potência variável, mesmo tendo o consumidor uma demanda variável e pouco repetitiva.

Ocorre que a previsão da demanda pressupõe o conhecimento da curva de carga típica do consumidor e ainda depende da escolha de um método eficaz e parametrizado para a situação. Esta condição normalmente é satisfeita apenas após vários ciclos de medições (meses) e uma escolha do método baseado na tentativa e erro para obter o menor erro (HINOJOSA; HOESE, 2010). Para consumidores individuais e com cargas de apenas algumas dezenas de quilowatts, a dificuldade de previsão de demanda é ainda maior, visto que suas curvas apresentam maior variabilidade em comparação a curvas com agregação de vários medidores.

O presente trabalho propõe uma metodologia baseada na combinação seletiva de vários métodos matemáticos de previsão de demanda para curtíssimo prazo, com o objetivo de permitir uma previsão com apenas algumas semanas de histórico, e sem a necessidade de encontrar um método adequado através da tentativa e erro. A meta é obter uma performance similar ou superior ao melhor método isolado que integrará o conjunto de combinação. A proposta é focada em pequenos consumidores de média tensão, cuja demanda possui alta variabilidade, os quais até o presente momento ficaram à margem das pesquisas com previsão de demanda.

Trabalha-se com dados vindos diretamente dos medidores, sendo o método capaz de realizar todos os cálculos na mesma velocidade que as demandas são medidas. Paralelamente o presente trabalho propõe o uso de ferramentas computacionais gratuitas e de código aberto, ainda pouco difundidas no Brasil, podendo desta forma servir como base para futuros trabalhos e melhorias a quem interessar.

¹ A Agência Internacional de Energia (IEA) mantém um site especializado em gerenciamento pelo lado da demanda, reunindo resumos de todos projetos no mundo, dos grupos de estudo, além de ampla base teórica. É acessível por <http://www.ieasm.org>

1.1 Motivação

A principal motivação para o presente trabalho, é a ausência de estudos e métodos de previsão de demanda para curtíssimo prazo, para consumidores individuais, com demandas pequenas (30-2.000 kW), e que ao mesmo tempo necessitam de um histórico de demandas de apenas algumas semanas. Há a necessidade de um método de previsão com um tempo de computação tal que permita o uso em tempo real, ideal para um pequeno sistema de GLD.

Existem inúmeros métodos de previsão de demanda, porém a maioria focaliza nas necessidades das concessionárias de energia, e desta forma, abordando a previsão da demanda de países, regiões ou cidades inteiras. Estas demandas a serem previstas por estes métodos são grandes, situando-se geralmente entre centenas até milhares de MW. Nota-se uma ausência de métodos ajustados para consumidores individuais, que não residenciais, com demandas de algumas dezenas de quilowatts até 2 megawatts.

Os métodos existentes, via de regra, necessitam de um longo histórico de demandas passadas (muitos meses ou até anos). Dentro das necessidades das concessionárias ou outros órgãos, este histórico está disponível. Para consumidores individuais este histórico na maioria das vezes não existe (medidores eletromecânicos, ou dados estão nos arquivos das concessionárias, sem uso). A dependência dos métodos existentes do histórico amplo também se traduz em elevado tempo de computação, inviabilizando qualquer uso dos mesmos em sistemas mais dinâmicos, característicos de pequenos consumidores.

Como motivações secundárias, porém não menos importantes, figuram a crescente difusão de medidores inteligentes entre consumidores com o perfil citado, o incentivo à geração distribuída (GD) e a flexibilização das tarifas de energia.

Na transformação da rede elétrica em rede elétrica inteligente, o medidor inteligente (*Smart Meter*) passou a ser um dos principais protagonistas. O que diferencia este medidor dos medidores atualmente em uso é sua capacidade de comunicação bidirecional e de armazenamento das medições. Outra característica é a medição em quatro quadrantes, ou seja, a capacidade de registrar o fluxo da energia ativa e reativa em qualquer direção. A comunicação com o medidor possibilita o acesso em tempo real às grandezas medidas. O armazenamento das grandezas medidas possibilita à concessionária a leitura remota para fins de faturamento e formação de histórico de consumos e demandas. A medição em quatro quadrantes habilita o consumidor a ter uma geração própria (GD) e injetar o excesso de geração no sistema.

Da forma como está sendo implementado, o novo sistema elétrico possibilita a cada consumidor, não importando o porte de sua instalação, a ser um agente do sistema, visto que não apenas consome mas eventualmente também gera energia. Portanto, o que era uma premissa apenas das empresas de geração, agora passa a ser uma preocupação de qualquer consumidor que quer se habilitar a gerar energia: a tomada de decisão de quando, quanto e como gerar.

Atualmente, no Brasil, consumidores comerciais e industriais de médio porte (75 kW até 3 MW de demanda) já podem optar entre três tarifas diferentes: a tarifa convencional, a tarifa verde e a tarifa azul (ANEEL, 2005). As tarifas verde e azul possuem dois postos horários, com custos diferentes. O custo da energia no horário de ponta (geralmente entre 18 e 21h) é aproximadamente 8 vezes superior ao custo da energia no restante do dia. Alguns consumidores, então, tomaram a decisão de gerar sua própria energia no horário de ponta, baseado no estudo do histórico de consumos neste horário, resultando em menores custos. Esta geração na grande maioria das instalações é através de derivados de petróleo.

A futura flexibilização das tarifas de energia (tarifas em tempo real) e a intermitência da geração a partir de fontes alternativas tornam a tomada de decisão mais difícil. Os consumidores necessitam de um histórico atualizado e de um prognóstico confiável para tomar a decisão. Principalmente se há a intenção de se isolar em determinados momentos completamente do sistema elétrico (operação ilhada) um gerenciamento pelo lado da demanda torna-se crucial para evitar um descompasso entre geração e consumo.

1.2 Objetivos

O objetivo do presente trabalho é propor um método de previsão de demanda em tempo real para consumidores individuais cujas demandas situam-se em uma faixa de algumas dezenas de quilowatts até alguns megawatts. Consumidores com esta magnitude de demanda são aqueles que possuem o maior potencial na instalação de geração própria (pequenos aproveitamentos de fontes alternativas) e adesão à programas de tarifas variáveis. A previsão de demanda para curtíssimo prazo, é uma importante ferramenta para tomada de decisão de um sistema de gerenciamento de energia que pode atuar sobre a demanda, geração ou armazenamento.

A proposta é um método que, fazendo uso de um histórico de demandas de duas semanas, cujos registros possuem intervalos de alguns minutos, forneça um perfil de demandas, com mesmo espaçamento, alguns minutos até duas horas à frente. Este perfil de demandas previsto deve ser atualizado a cada nova demanda real medida, incorporada ao histórico.

Especificamente os objetivos são:

1. Um método que faz uso de dados vindos diretamente de um medidor inteligente, sem filtragem prévia;
2. Independentemente do tipo de carga (comercial, industrial, outros);
3. Uso de uma série histórica das demandas registradas, necessárias ao método, de apenas duas semanas. Possibilita o aproveitamento das potencialidades dos medidores inteligentes em pouco tempo;
4. Um método de fácil aplicação e reprodução por terceiros, de modo a possibilitar o aprimoramento do mesmo. O uso de software livre é uma premissa básica para alcançar este objetivo;
5. Tempo de computação e treinamento que possibilite uma aplicação em tempo real ou pelo menos muito próximo ao tempo real;

1.3 Contribuições inovadoras

Enquanto as concessionárias de energia elétrica já estão bem servidas de propostas para previsão de suas demandas, para os mais variados horizontes, consumidores de pequeno porte e com perfis de demanda diários diferentes entre si, ainda carecem de estudos quando se trata de previsão de demanda para curtíssimo prazo.

Portanto, a presente tese apresenta as seguintes contribuições inovadoras:

- Utilização do histórico e fluxo de medidas da demanda dos medidores do atual padrão brasileiro de medidores eletrônicos, como única variável de previsão;
- Previsão da demanda, para curtíssimo prazo, usando um histórico de apenas duas semanas, aplicada em vários consumidores de pequeno porte e de perfis distintos (comerciais, industriais, etc);
- Proposta de um método de previsão alternativo, em duas etapas, combinando os resultados da primeira etapa de previsão em uma previsão final na segunda etapa. Esta combinação não é rígida adaptando-se às variações na própria curva de carga e de consumidor para consumidor;

1.4 Organização do trabalho

A presente tese é organizada conforme segue: no capítulo 2, é apresentada a revisão bibliográfica, sendo ela dividida em duas partes. A primeira parte apresenta os principais estudos de previsão de demanda em curto ou curtíssimo prazo, publicados em periódicos ou livros conceituados. A segunda parte focaliza a combinação de métodos incluindo publicações que de alguma forma se utilizaram da combinação de métodos na previsão de demanda. No capítulo 3 é demonstrado como foi realizada a previsão e a teoria envolvida. Este capítulo é o arcabouço de dados e conclusões da qual deriva a tese proposta no capítulo 4. As considerações finais encontram-se no capítulo 5. No Apêndice A podem ser consultados os detalhes técnicos no uso da linguagem R. Nos Anexos A e B estão os resultados tabelados e gráficos de todos os cálculos realizados ao longo deste trabalho.

2 REVISÃO BIBLIOGRÁFICA DE PREVISÃO DA DEMANDA PARA CURTÍSSIMO PRAZO

A preocupação com a demanda futura tem a sua origem ainda nos primeiros anos do início do uso da eletricidade no século passado. O primeiro estudo nesta área foi publicado em 1918 com o título "*Predicting load on residence circuits*", no periódico *Electrical World*¹, P.O. Reyneau (1918), um engenheiro de distribuição da *Detroit Edison Company*, descreveu os fatores que influenciavam a expansão da demanda e forneceu um método para previsão da demanda máxima esperada para vários meses à frente.

Mais recentemente, nas últimas décadas, especialmente após a introdução consistente dos computadores e pacotes de softwares matemáticos no meio acadêmico, milhares de estudos sobre previsão de demanda foram apresentados. Vários pesquisadores compilaram estes estudos em resumos bibliográficos, como Huck et al. (1980), Mahmoud, Ortmeier e Reardon (1981) e Gross e Galiana (1987). Estes autores apontam que foram publicados em torno de 40 estudos até o final dos anos 60, com maior concentração a partir de 1965. Os estudos em previsão de demanda foram classificados segundo seus horizontes de previsão. Feinberg e Genethliou (2005) dividiram os métodos em três categorias: curto prazo (uma hora até uma semana), médio prazo (uma semana até um ano) e longo prazo (horizonte maior que um ano). Hahn, Meyer-Nieberg e Pickl (2009), acrescentam como uma quarta categoria o horizonte de curtíssimo prazo (minutos até horas, abaixo de 24 horas). A compilação de estudos apresentada por Hernandez et al. (2014) identifica estas mesmas categorias entre 123 publicações. Esta classificação se ajusta aos horizontes utilizados para o planejamento da operação quanto os horizontes de longo, médio e curto prazos. A previsão para curtíssimo prazo, compartilha o mesmo horizonte da operação do sistema elétrico em tempo real (FORTUNATO, 1990).

A figura 2.1 resume os horizontes na previsão de demanda, com destaque aos métodos encontrados na bibliografia para o curtíssimo prazo.

Embora haja vasta literatura sobre previsão de demanda, esta concentra-se no curto prazo, sendo o horizonte para curtíssimo prazo ainda carente de publicações. A proporção de publicações pode ser estimada consultando a base de dados da IEEE, na qual há apenas 5 publicações em periódicos abordando PDCEP, ao lado de quase 200 publicações abordando a previsão para curto prazo, nos mesmos meios. Uma proporção similar é encontrada na análise

¹ As edições da *Electrical World*, de 1894 em diante, foram totalmente digitalizadas com fomento da Universidade de Toronto em 2010. É acessível por <https://archive.org/details/electricalworld71newy>

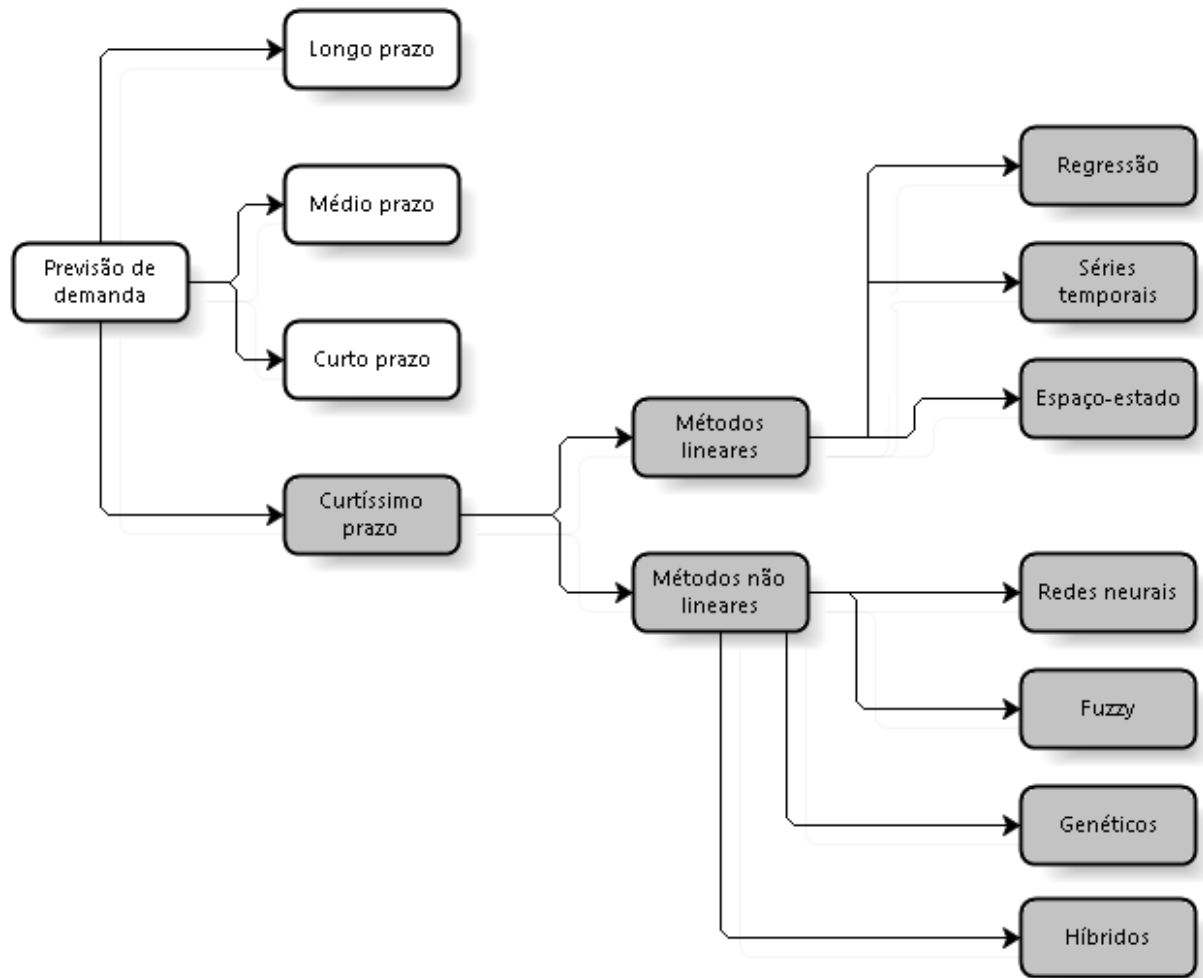


Figura 2.1: Previsão de demanda: horizontes / métodos para curtíssimo prazo

compilada por Hernandez et al. (2014) em que apenas 6% entre as 123 publicações analisadas abordam o curtíssimo prazo, enquanto 58% trabalham com o curto prazo.

Na seção 2.1 são apresentados os estudos de PDCP mais significativos, publicados em periódicos conceituados. Em seguida, a seção 2.2 focaliza na combinação de previsões, primeiramente de forma geral (estudos de estatística) e posteriormente especificamente na previsão de demanda.

2.1 Principais estudos de PDCP

2.1.1 Métodos lineares ou estatísticos

Usando como variáveis de entrada o consumo, hora do dia, dia da semana e temperatura externa, Charytoniuk et al.(1999), faz previsões para consumidores individuais (1,8 kW) ou grupos (15 MW). Em Zivanovic (2001) é usada uma regressão polinomial local para prever a

demanda até 72 horas à frente, em um sistema com 250 MW.

James W. Taylor da Universidade de Oxford, é um dos principais estudiosos na previsão de demanda. A suavização exponencial de dupla (TAYLOR, 2003), e tripla sazonalidade é de sua autoria (TAYLOR, 2010a). Vários estudos com demandas da Inglaterra, países Europeus (TAYLOR; MCSHARRY, 2007), e até do Brasil (TAYLOR, 2006) foram publicados, incluindo resoluções de até 1 minuto. Múltiplas sazonalidades foram propostas por Gould et al. (2008). Estes trabalhos têm em comum o uso de demandas de países inteiros, ficando na faixa de dezenas de GW. Naturalmente estas curvas são extremamente suaves, resultando em erros MAPE (*Mean Absolute Percentage Error*) muito baixos, não mais que 2%.

Hydman et al.(2002) propôs um modelo de espaço-estado para a suavização, incorporando as formulações de Taylor em seu livro (HYNDMAN et al., 2008) e também em um pacote de funções para a linguagem R em 2011 (vide no apêndice A). O uso de múltiplas sazonalidades na suavização exponencial foi abordado também por Hyndman, Snyder e Livera (2011), usando um exemplo da demanda da Turquia, que é influenciada pelo uso de dois calendários no país (o Gregoriano e o Islâmico).

A autorregressão (AR) foi utilizada por Liu et al. (1996) em um comparativo entre um método autorregressivo simples (AR), lógica fuzzy e redes neurais para uma concessionária elétrica do Texas, EUA (TU Electric), cuja demanda média é de 13 GW . Um método ARI (ARIMA sem média móvel) foi a solução encontrada por Abu-El-Magd e Sinha (1982) para previsão das demandas da Ontario Hydro (140 MW).

Em um estudo brasileiro, comparando previsões de três subestações em São Paulo (14 MW), Andrade e Silva (2009) utilizaram o método SARIMA em um comparativo a um sistema adaptativo neuro-fuzzy.

2.1.2 Métodos não-lineares

O uso de redes neurais na previsão de demanda até 1999 foi resumido em um estudo publicado por Hippert et al. (2001). Apenas uma única publicação aborda o curtíssimo prazo, já citado anteriormente (LIU et al., 1996).

Charytoniuk et al. (2000) apresenta uma análise na qual a curva de carga diária de uma concessionária dos EUA foi dividida em cinco seções, cada uma com sua própria rede neural. Como resultado, os erros MAPE figuram entre 1,1 e 0,4%, porém ao custo de 42 minutos de treinamento. Redes neurais também são aplicadas na previsão de demandas residenciais

e agrupamentos em (CHARYTONIUK; CHEN, 2000), na Okinawa Electric Power Company (600 - 1000 MW)(SENJYU et al., 2002), e para uma região na Austrália (10 GW) (YUN et al., 2008).

Em Guan et al. (2013), o uso de wavelets² é proposto na previsão de uma concessionária na Nova Inglaterra (até 27 GW). Todavia há necessidade de alto poder computacional (3h de treinamento). Os mesmos autores, usando os mesmos dados, propõe o uso de Filtros de Kalman como alternativa em (GUAN et al., 2013). Trudnowski, McReynolds e Johnson (2001) aplicam wavelets na previsão da demanda em intervalos de 5 minutos, aplicado no controle automático da geração em uma região no noroeste dos EUA.

Métodos híbridos são a proposta de Huang et al. (2012) fazendo uso de PSO (*Particle Swarm Optimization*) na determinação da localização das funções de pertinência de um sistema de inferência Fuzzy. A previsão de demanda é para residências com cargas tão baixas quanto 1 kW, em intervalos de 15 minutos. Uma proposta híbrida também é de Yang et al. (2006), prevendo demandas de uma província chinesa (550 MW, 15 minutos). Kawauchi et al. (2004) propõe um método híbrido usando a teoria do caos e um método fuzzy, com várias alternativas em um ambiente com carga de 9 GW

O uso de Mapas Auto-organizáveis (*SOM - Self Organizing Maps*) para obter a probabilidade de um determinado patamar de demanda ser ultrapassado por um distribuidor de energia elétrica no Rio Grande do Sul (4-8 MW), é proposto por Sperandio et al. (2014). O método faz uso de dados climáticos e demanda medida. O uso de Mapas Auto-organizáveis também é objeto no estudo de Che et al. (2012), para gerar as regras de um sistema Fuzzy para previsão da demanda em uma região da Austrália (6-11 GW).

2.2 Combinação de previsões

2.2.1 A combinação de previsões na estatística

O trabalho de Bates e Granger³ (1969) é tido como o estudo seminal quando o assunto é combinação de previsões. Partindo do pressuposto que a combinação de duas previsões pode resultar em uma previsão mais precisa, propuseram uma combinação ótima de previsões que

² É um método para decompor um sinal (neste caso a curva de carga) em seus múltiplos componentes no domínio da frequência.

³ Granger recebeu o prêmio Nobel de Economia em 2003, pelo trabalho "Methods of analyzing economic time series with common trends (cointegration)".

reside na aplicação de pesos que multiplicam as previsões de forma que o erro médio quadrático resulte no menor possível (média ponderada). Esta combinação foi chamada de combinação ótima, e os pesos poderiam, em tese, assumir qualquer valor.

Posteriormente, Granger e Ramanathan (1984) propuseram limitar a soma dos pesos a um, o que na prática seria uma regressão. A aplicação destes métodos em várias séries foi analisada por Clemen (1989), que de modo crítico avaliou que uma simples média traz melhores resultados do que a combinação ótima na maioria dos casos. Este fato é tratado como surpresa no meio acadêmico e citado exaustivamente em várias publicações. Baseado nos ótimos resultados de uma média de previsões, em recente estudo, Graham Elliott (2011) propõe uma média que é chamada de "média do melhor subconjunto" (*Best subset average*). A técnica consiste em calcular a média de todas as combinações possíveis das previsões do momento anterior e usar a combinação com menor erro como a combinação válida para as próximas previsões.

Estudando o levantamento de Clemen, citado anteriormente, Armstrong (1989) recomenda que, em uma combinação de métodos, estes devem ser substancialmente diferentes no que refere aos dados utilizados e procedimentos de análise. Também conclui que a combinação traz melhores resultados para o curto prazo, no qual erros aleatórios dos métodos têm impacto mais significativo. Uma combinação suaviza estes erros.

A combinação de diversos métodos de previsão usando simples médias, também foi avaliada por Hibon e Evgeniou (2005). A conclusão desta publicação é muito importante para o presente trabalho ao afirmar que é preferível usar uma combinação de métodos de previsão ao invés de um único método, tendo em vista o risco de escolher o método cujos resultados serão piores do que a média (salvo que se saiba de antemão qual método é o melhor). Os autores focalizam na necessidade de estudos em como e quais métodos combinar.

A questão das médias é abordado por José e Winkler (2008) que sugerem um ajuste das previsões antes de fazer a média. A justificativa é que quando se usa vários métodos para a previsão, alguns deles fornecem previsões substancialmente acima ou abaixo do dado real, necessitando ser eliminadas da média. Esta média é chamada de média ajustada. Outra proposta, chamada de *Winsorized mean*, não elimina estes valores mas aplica ajustes de graus variados às previsões. Uma das alternativas é substituir as previsões máximas e mínimas extremas, pelas máximas e mínimas remanescentes. O método só funciona em ambientes em que há um maior número de métodos.

2.2.2 Combinação de métodos na previsão de demanda

A combinação que está sob análise nesta seção da tese não deve ser confundida com métodos híbridos. No caso de métodos híbridos, os métodos dividem as tarefas, para no final produzirem a previsão. Já a combinação em tela é quando dois ou mais métodos são capazes de individualmente produzir boas previsões, porém são combinadas para dar maior robustez ou maior precisão ao processo. Sob esta ótica, são raros os estudos de previsão de demanda que propõe a combinação de dois ou mais métodos para produção de previsões mais precisas.

Srinivasan (1975) apresenta a combinação de quatro previsões, respectivamente baseadas em dados do ano anterior, mês anterior, semana anterior e dia anterior, através de uma média ponderada. Os pesos da média ponderada são inversamente proporcionais à variância passada. Neste caso, são previsões horárias e há necessidade de um histórico de um ano atrás.

Em um estudo de seleção de curvas do passado como previsores para o futuro (demandas do dia seguinte, resolução de 30 minutos, tipicamente para concessionária de energia) Taylor e Majithia (2000) propõe o uso de três métodos: combinação ótima, regressão e simples média. Trata-se porém de uma previsão para o dia seguinte, e não para curtíssimo prazo.

Em Borges et al. (2011) é usada a combinação de quatro métodos para previsão da demanda da Universidade de Deusto, Espanha (apenas 400 kW). São combinados um modelo autorregressivo, polinomial, rede neural e máquinas de vetor suporte. A combinação é feita através da média ponderada, cujos pesos são calculados a partir dos erros passados. Os resultados são comparados a vários métodos de seleção do melhor método dentre os quatro primeiros. A conclusão é que a combinação linear (média ponderada) é mais precisa que métodos de seleção mais sofisticados. Um estudo similar, porém utilizando outros métodos de previsão, é proposto por Niu e Wei (2013). Os métodos individuais são uma rede neural, máquinas de vetor suporte, GARCH⁴ e ARMA.

Estudo mais amplo, com medidores individuais e agregações de vários medidores é apresentado por Mirowski et al. (2014), cujo foco é a previsão de demanda de forma geral na rede inteligente. Não obstante, apresenta estudo com mais de 400 medidores, em conjunto ou separadamente. Ao final sugere que os métodos utilizados SARIMA, Holt-Winters (HWT), modelo de espaço-estado e regressão de vetor suporte (SVR) sejam combinados para melhorar a precisão das previsões. Cinco métodos de combinação são testados: Média simples entre os

⁴ modelo autorregressivo condicionalmente heterocedástico/heteroscedástico generalizado

quatro métodos, mediana, seleção do método com menor erro no passo anterior, media apenas entre HWT e SVR, seleção entre HWT e SVR escolhendo aquele cujo erro foi o menor no passo anterior. O resultado final comprova, mais uma vez, que a média entre os quatro métodos traz o menor erro. No final do artigo os autores questionam se este resultado também seria esperado usando dados de apenas um medidor.

2.3 Considerações finais

Uma análise detalhada da bibliografia revela evidencia que são raros os estudos em que a previsão da demanda é realizada com dados cujo intervalo entre registros é de apenas alguns minutos. A maioria dos estudos apresenta um intervalo entre registros de uma hora, numa aparente padronização, classificando-os como previsões para curto prazo. O presente trabalho utiliza-se de demandas registradas em intervalos menores, de alguns minutos, e desta forma boa parte da bibliografia se afasta do foco da presente tese. Estudos para consumidores individuais, com demandas abaixo de 2MW, para curtíssimo prazo (minutos) estão ausentes.

Estão listados abaixo as características comuns à maioria dos estudos analisados:

- As cargas provêm de países, regiões de países ou concessionárias e são elevadas, de algumas dezenas de MW até GW;
- Maioria dos estudos alcançou erros MAPE logo abaixo dos 2%;
- Métodos aplicados aos dados de forma *offline*, dados históricos consolidados;
- Alguns métodos sugerem que passaram por ajustes finos, tornando-se específicos apenas para o conjunto de dados analisado;
- O foco é a precisão da previsão (minimização do erro) e não o desempenho computacional;
- As séries históricas necessárias para a previsão são longas (de dois, três meses até dezenas de meses em alguns casos);

Estão listados abaixo as informações ausentes na maioria dos estudos:

- Tempo necessário para calcular a previsão;
- Informações quanto à maneira prática de implementação do método teórico, ou seja, qual o software ou a ferramenta utilizada;

- Os métodos propostos geralmente são aplicados à curva de demanda de uma única concessionária, região ou país. Falta uma validação aplicando o método à curva de outras concessionárias;

Quanto aos estudos de combinação de demanda, estes estão em sintonia com a teoria: ao final, uma média simples é ainda a melhor combinação. Embora Mirowski et al. (2014) sugere algumas variantes de médias e métodos de seleção, no caso específico deste estudo não foram superiores à média.

3 PREVISÃO DE DEMANDA PARA CURTÍSSIMO PRAZO

Neste capítulo são apresentados estudos preliminares, aspectos técnicos e resultados que são a fundamentação para a proposta de uma metodologia de previsão de demanda a curtíssimo prazo em tempo real. O desenvolvimento é apresentado em duas etapas, concomitante com a base teórica dos métodos utilizados.

Na primeira etapa são analisados aspectos técnicos para a realização da previsão de demanda em tempo real, acessando um medidor e obtendo dele as medidas de demanda. Trata-se de um trabalho de campo realizado para subsidiar as etapas seguintes.

Na segunda etapa, a partir da aplicação de métodos de previsão em vários consumidores de perfis diferentes, é demonstrado que para curtíssimo prazo, não existe um método geral que tenha desempenho satisfatório (erro médio) independente do tipo de consumidor e do horário do dia. A proposta de uma nova metodologia, descrita no capítulo 4, utiliza a combinação seletiva dos métodos que foram utilizados nesta segunda etapa.

3.1 Análise dos aspectos técnicos na previsão de demanda para curtíssimo prazo

O presente trabalho apresenta a proposta de um novo método de previsão de demanda (baseado na combinação seletiva de métodos), bem delimitado quanto ao histórico (duas semanas), velocidade de cálculo (tempo real, ou seja previsão feita em segundos), horizonte (duas horas à frente) e tipo de consumidores (industriais, comerciais e outros), conforme citado na seção 1.2.

Para possibilitar a proposição de uma combinação seletiva de métodos de previsão, que em tempo real realiza todos os cálculos e posterior combinação, há a necessidade de testar seu funcionamento em campo. Parte-se do pressuposto que, para que o presente trabalho não fique restrito ao meio acadêmico e possa ter um desenvolvimento prático posterior, os métodos devem ser testados em um ambiente real (medidor + software previsor).

Desta forma, a primeira etapa foi desenvolvida a partir dos seguintes questionamentos:

- É possível fazer uma PDCP, utilizando as medidas da demanda obtidas *on-line* de um medidor inteligente/eletrônico?
- Quais os possíveis problemas e como contorná-los?

- Todo processo de recepção de dados, armazenamento e cálculo é suficientemente rápido, de modo a permitir o uso em tempo real?
- Quais recursos de hardware e que ferramentas de software podem ser utilizados?

3.1.1 O medidor empregado

Para obter um fluxo constante de demandas medidas um multimedidor foi instalado no barramento geral de baixa tensão de uma subestação no campus da UFSM. Trata-se de uma subestação de 500 kVA cuja demanda média situa-se entre 100 e 200 kW nos dias úteis. O medidor utilizado foi da marca IMS - Indústria de Micro sistemas, modelo PowerNet P600 (IMS, 2009).

Incorporado ao medidor está um modem GPRS da Ativa Soluções, modelo Marthe A820 (ATIVA, 2011). Desta forma, com a aquisição de um pacote de dados de uma operadora de telefonia celular, foi possível estabelecer uma linha direta de comunicação com o medidor, através do MODEM.

Pelo MODEM o medidor aceita comandos em sua porta serial (RS232) fazendo uso do protocolo de comunicação MODBUS RTU. A função do MODEM é ser a interface entre a porta serial do medidor e a rede GPRS da operadora de telefonia, podendo ser programado a fazer contínuas tentativas de estabelecer uma conexão TCP/IP (Transmission Control Protocol/Internet Protocol) com um endereço IP pré-determinado. Portanto, para acessar o medidor à distância e fazer a leitura dos registros, um computador remoto recebeu um endereço IP fixo, habilitando-se a comunicar com o medidor de forma bi-direcional.

Na figura 3.1 está representada uma amostra das demandas, com resolução de minuto em minuto, mostrando máximos e mínimos para dias de inverno.

3.1.2 Aquisição de dados, controle e previsão

Fazendo uso da linguagem de programação C-Sharp e utilizando o ambiente de programação gratuito da Microsoft, o Visual Studio Express (foram utilizados versões 2010, 2011, 2012 e 2013) um programa foi escrito com as seguintes funcionalidades:

- Estabelecer a comunicação com o medidor, através da internet, protocolo TCP/IP;
- Solicitar a demanda medida, em intervalos fixos ao medidor - no presente caso de minuto em minuto;

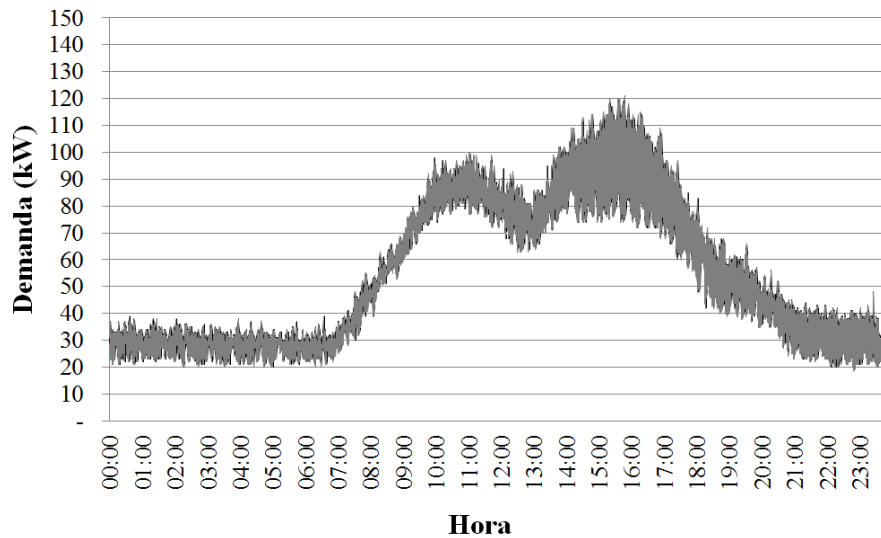


Figura 3.1: Amostra das demandas incluindo faixa de variação máx/mín para dias de inverno

- Gerenciar um banco de dados, com o registro das demandas medidas, incluindo um carimbo de data e hora;
- Contornar eventuais problemas de comunicação, de falta de dados e de inconsistências no banco de dados;
- Indiretamente, utilizando funções da linguagem R, fazer a previsão da demanda, utilizando métodos e horizontes pré-determinados;
- Gravar os resultados em um banco de dados para posterior análise;
- Exibir em uma tela supervisória a última demanda medida, as previsões e um gráfico do histórico;

O banco de dados utilizado para armazenar os registros das demandas lidas bem como os resultados das previsões foi o SQLite¹ (também gratuito). Para que os dados registrados pudessem ser usados em rotinas de previsão de demanda, o registro deve obrigatoriamente ocorrer com um carimbo de dia, hora, minuto e segundo precisos e em intervalos fixos. Como o tempo de resposta do medidor varia, dependendo do tráfego da rede e também de condições da telefonia celular, a solução encontrada foi a utilização de dois temporizadores. O primeiro temporizador, chamado aqui de temporizador "A" tem como função garantir que em cada minuto, uma solicitação é feita ao medidor e uma previsão das próximas demandas é calculada. O segundo

¹ A documentação e o pacote de software é acessível por <https://www.sqlite.org/>

temporizador, chamado aqui de "B", aguarda a chegada do último valor medido pelo medidor e realiza a gravação no banco de dados em um momento precisamente definido. Para evitar eventuais imprecisões, a gravação ocorre sempre no quinto segundo de cada minuto (exemplo de sequência: 13:30:05, 13:31:05, 13:32:05, etc.). Uma rotina de ajuste de tempo de alguns milissegundos garante que não haja desvios no tempo de gravação.

Tendo em vista o caráter experimental do sistema, durante sua implementação muitas paradas foram necessárias, durante as quais dados vindos do medidor não eram registrados no banco de dados. Outra necessidade era o preenchimento de lacunas surgidas durante faltas de energia ou longos períodos (várias horas) de problemas na rede de telefonia celular. Desta forma, uma rotina de preenchimento era acionada cada vez que o programa era iniciado. Também em casos de falta de dados por mais de 30 minutos, o previsor era parado (temporizadores parados). Restabelecida a conexão, a lacuna de dados era preenchida até momento em questão, sendo retomados os temporizadores. Para interrupções da conexão menores que 30 minutos foi convencionado que a demanda a ser registrada fosse a demanda prevista para aquele momento. A figura 3.2 ilustra o procedimento adotado, através de um exemplo em que o programa foi reiniciado em uma sexta-feira à tarde, depois que ficou parado desde as 15 horas e 13 minutos da quinta-feira. Dados do mesmo período da semana anterior foram utilizados para completar a série temporal.

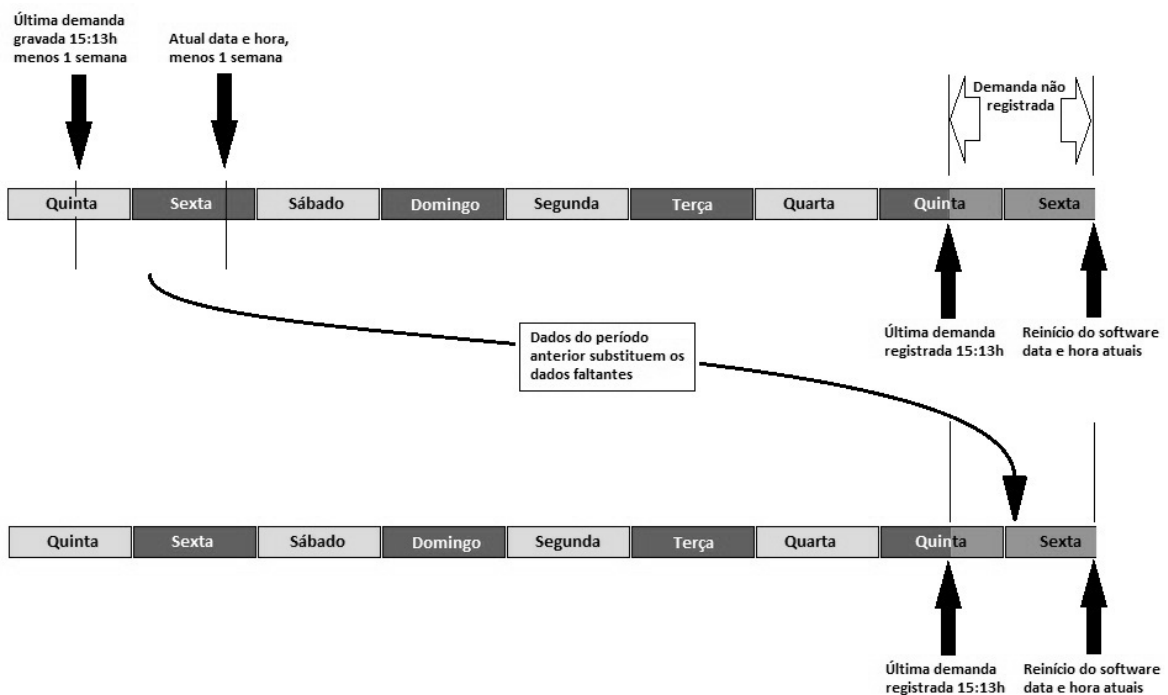


Figura 3.2: Exemplo de preenchimento de dados faltantes na série temporal

O fluxo para aquisição, adequação e armazenamento dos dados, criado em C-Sharp é mostrado na figura 3.3.

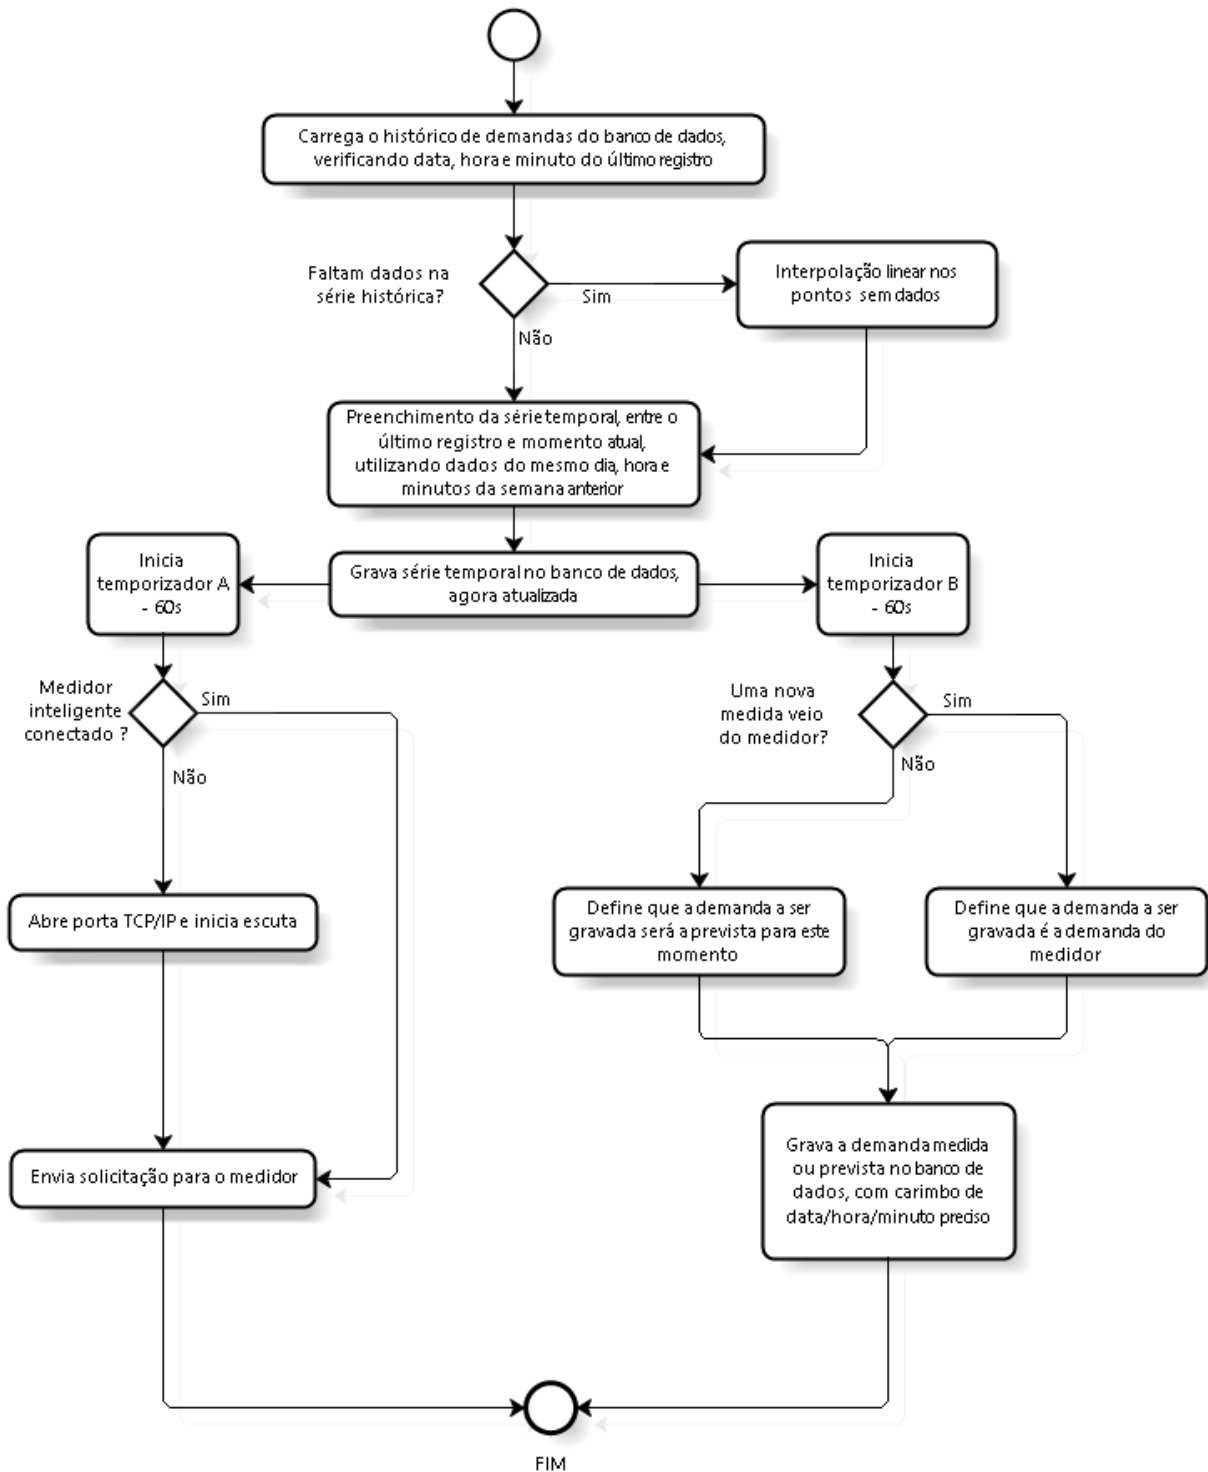


Figura 3.3: Fluxo para aquisição de dados, adequação e armazenamento.

3.1.3 Métodos utilizados na previsão e sua implementação

O histórico de demandas a ser utilizado na previsão foi limitado a duas semanas. É simulada assim, a aplicação prática em campo, quando após duas semanas da instalação do medidor, o histórico armazenado já pode ser utilizado. Nesta etapa o intervalo de registros é de um minuto, perfazendo 1.440 registros diários. Desta forma, há necessidade de pelo menos 20.160 registros passados para formar o histórico utilizado para previsão. De forma arbitrária, no programa, são carregados sempre 21.000 registros. Dadas as características diferentes da curva de demanda dos dias úteis em comparação com os finais de semana, internamente o programa retira da série histórica os sábados e domingos, restando 14.400 registros (duas semanas úteis).

Dois métodos de previsão foram utilizados nesta etapa: a suavização Holt-Winters de dupla sazonalidade (será doravante abreviada por DSHW) e a suavização exponencial Holt-Winters aditiva (abreviada por HWADD). A escolha destes dois métodos ocorreu principalmente devido ao sucesso de Taylor (2008) na aplicação destes métodos a dados de minuto-em-minuto do sistema elétrico britânico.

A figura 3.4 exibe o fluxo da previsão de demanda desta primeira etapa.

A aplicação prática dos métodos foi feita através do uso da linguagem R, cujo detalhamento está no Apêndice A.

3.1.3.1 Suavização exponencial Holt-Winters

A principal dificuldade da suavização exponencial simples é não poder lidar com séries temporais que apresentam uma tendência linear e sazonalidade (variações repetitivas em espaços de tempo bem definidos). Foi através do trabalho de Charles Holt (1957) e Peter Winters (1960) que o uso da suavização exponencial como método de previsão de séries temporais ganhou popularidade. O método passou a ser conhecido como suavização exponencial Holt-Winters. Dependendo das características da série, a tendência embutida pode ter natureza linear ou multiplicativa, da mesma que a sazonalidade pode ser aditiva ou multiplicativa.

A formulação do método com tendência linear e sazonalidade multiplicativa é:

$$\bar{S}_t = A \frac{S_t}{F_{t-L}} + (1 - A)(\bar{S}_{t-1} + R_{t-1}) \quad (3.1)$$

$$F_t = B \frac{S_t}{\bar{S}_t} + (1 - B)F_{t-L} \quad (3.2)$$

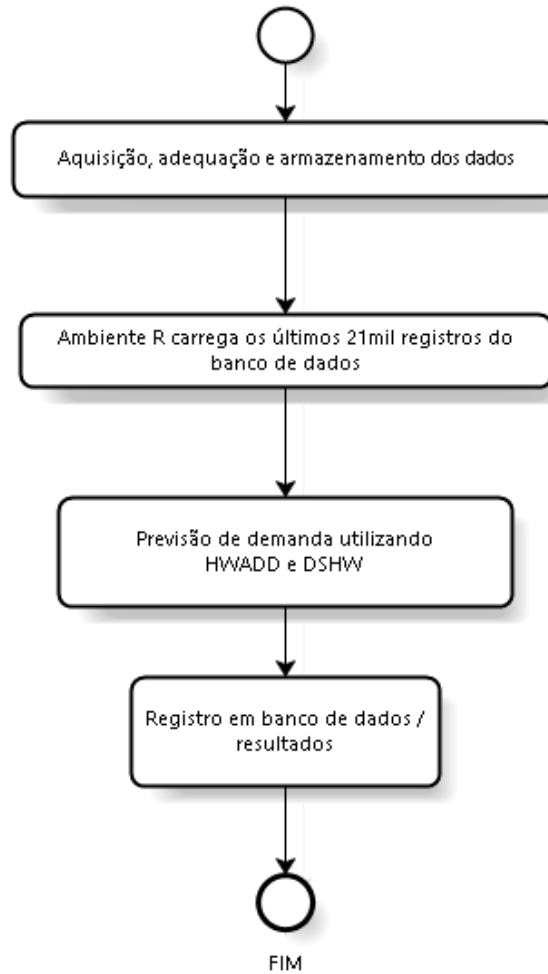


Figura 3.4: Fluxo da previsão de demanda na primeira etapa.

$$R_t = C(\bar{S}_t - \bar{S}_{t-1}) + (1 - C)R_{t-1} \quad (3.3)$$

Onde S_t é a série temporal, F_t é o fator sazonal e R_t o fator da tendência. L é o número de registros da sazonalidade (ou frequência). As constantes A , B e C são as constantes de suavização. Aqui as notações da publicação original foram preservadas. A previsão para um valor futuro no período T , é dado por:

$$S_{t+T} = (\bar{S}_t + TR_t)F_{t-L+T} \quad (3.4)$$

O mesmo método com sazonalidade aditiva possui a seguinte formulação:

$$\bar{S}_t = A(S_t - F_{t-L}) + (1 - A)(\bar{S}_{t-1} + R_{t-1}) \quad (3.5)$$

$$F_t = B(S_t - \bar{S}_t) + (1 - B)F_{t-L} \quad (3.6)$$

$$R_t = C(\bar{S}_t - \bar{S}_{t-1}) + (1 - C)R_{t-1} \quad (3.7)$$

Sendo que a previsão para um valor futuro no período T , é dado por:

$$S_{t,T} = \bar{S}_t + TR_t + F_{t-L+T} \quad (3.8)$$

A suavização exponencial foi sucessivamente revisada e melhorada por diversos pesquisadores. Métodos sem tendência, com tendência aditiva, multiplicativa ou amortecida foram propostos. Adicionando métodos sem sazonalidade, com sazonalidade multiplicativa ou aditiva chega-se a quinze possibilidades de suavização exponencial. Tal multiplicidade de opções foi transformada em modelos de espaço estado por Hyndman et al. (2002) para possibilitar uma automação na escolha correta do método. Uma tabela comparativa entre métodos foi publicada por Gardner (2006).

3.1.3.2 Suavização exponencial com dupla sazonalidade

Analisando o comportamento das curvas de demanda do setor elétrico, James Taylor (2003) propôs a inclusão de uma sazonalidade adicional, visto que a demanda possui ciclos diários e semanais. Taylor modificou as notações na sua proposta, chamando as duas sazonalidades de D_t e W_t , respectivamente para a sazonalidade diária (daí o uso da letra D, de "day" em inglês) e a sazonalidade semanal (usando a letra W, de "week" em inglês). A periodicidade de cada sazonalidade respectivamente foi chamada de $S1$ e $S2$. A versão com sazonalidades multiplicativas é a que segue:

$$L_t = \alpha \left(\frac{Y_t}{(D_{t-s1}W_{t-s2})} \right) + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad (3.9)$$

$$T_t = \gamma(L_t - L_{t-1}) + (1 - \gamma)T_{t-1} \quad (3.10)$$

$$D_t = \delta \left(\frac{Y_t}{(L_tW_{t-s2})} \right) + (1 - \delta)D_{t-s1} \quad (3.11)$$

$$W_t = \omega \left(\frac{Y_t}{(L_tD_{t-s1})} \right) + (1 - \omega)W_{t-s2} \quad (3.12)$$

Onde L_t é o nível, T_t a tendência, D_t a sazonalidade diária e W_t a sazonalidade semanal. Os parâmetros de suavização são α, γ, δ e ω . A previsão de um valor futuro na série temporal é dada por:

$$Y_t(k) = (Y_t + kT_t)D_{t-s1+k}W_{t-s2+k} \quad (3.13)$$

Uma versão com sazonalidade aditiva também foi proposta conforme segue:

$$L_t = \alpha(Y_t - D_{t-s1} - W_{t-s2}) + (1 - \alpha)L_{t-1} \quad (3.14)$$

$$T_t = \gamma(L_t - L_{t-1}) + (1 - \gamma)T_{t-1} \quad (3.15)$$

$$D_t = \delta(Y_t - L_t - W_{t-s2}) + (1 - \delta)D_{t-s1} \quad (3.16)$$

$$W_t = \omega(Y_t - L_t - D_{t-s1}) + (1 - \omega)W_{t-s2} \quad (3.17)$$

A representação possui o mesmo significado da apresentada nas equações (3.9), (3.10), (3.11) e (3.12).

Métodos com três sazonalidades foram propostos em (TAYLOR, 2010a) para incorporar a sazonalidade diária, semanal e anual de uma série temporal. Havendo múltiplas sazonalidades, variações foram propostas em (TAYLOR, 2010b), em (TAYLOR; SNYDER, 2012), e também em (GOULD et al., 2008). Um método com sazonalidades complexas, com alta frequência, fracionadas ou efeitos de calendário foi proposto em (HYNDMAN; SNYDER; LIVERA, 2011).

3.1.3.3 Avaliação da precisão da previsão - medição do erro

A busca por métodos de previsão em séries temporais traz a necessidade de avaliar a precisão de cada método, possibilitando a comparação entre diferentes métodos. Por outro lado, também há necessidade de comparar a precisão de um mesmo método de previsão aplicado a diferentes conjuntos de dados. Muitos métodos para medir a precisão de uma previsão já foram propostos, com diferentes abordagens, dependendo do público alvo e da aplicação sob avaliação.

Os métodos, chamados de métodos de avaliação do erro, ou métodos de medição do erro, em geral se dividem em três grandes grupos: os métodos dependentes da escala, os métodos independentes da escala e os métodos escalados.

Inicialmente há necessidade de definir o erro da previsão que é dado por:

$$e_i = y_i - \hat{y}_i \quad (3.18)$$

Onde y_i é o valor real da série e \hat{y}_i é o valor previsto. O erro e_i , portanto, está na mesma escala dos dados da série.

3.1.3.3.1 Métodos de avaliação dos erros, dependentes da escala

Qualquer método de avaliação do erro que utilize o valor e_i , resultante da equação (3.18) é um método dependente da escala. Para evitar erros negativos, quando o valor previsto é maior

que o valor real, utiliza-se o valor absoluto do erro. A média dos erros de uma série temporal resulta no erro médio absoluto ou MAE (*Mean absolute error*) dado por:

$$MAE = \text{media}(|e_i|) \quad (3.19)$$

Muito utilizado em estatística é a raiz do erro quadrático médio, ou RMSE (*Root mean squared error*):

$$RMSE = \sqrt{\text{media}(e_i^2)} \quad (3.20)$$

Porém, tanto o método da equação (3.19) quanto o da equação (3.20) só podem ser utilizados quando se está avaliando uma única série temporal. São inúteis quando estão sob avaliação métodos de previsão aplicados em diversas séries temporais com escalas diferentes. Há ainda outras formas de avaliação do erro, como por exemplo, o erro médio quadrático ou o erro mediano absoluto, não detalhados aqui.

3.1.3.3.2 Métodos de avaliação dos erros, independentes de escala

Havendo a necessidade de comparar métodos de previsão, sem preocupação com a escala dos dados utilizados, passa-se a utilizar erros percentuais. Métodos de avaliação de erros percentuais são muito populares, pois permitem a comparação direta de previsões, mesmo que os dados e métodos de previsão sejam de fontes totalmente distintas. A equação (3.21) mostra a formulação mais usada do erro absoluto percentual médio, ou MAPE (*Mean absolute percentage error*). O MAPE tornou-se um padrão na comparação de métodos de previsão, sendo utilizado na maioria das publicações.

$$MAPE = \text{media}\left(\left|100 \frac{y_i - \hat{y}_i}{y_i}\right|\right) \quad (3.21)$$

O uso do MAPE porém não é incontroverso, visto que traz alguns vícios: tomando como exemplo uma previsão de demanda cujo valor \hat{y}_i é 40 kW, e sendo o valor real medido y_i igual a 30 kW Pela equação (3.21) o erro percentual é:

$$APE = \left(\left|100 \frac{30 - 40}{30}\right|\right) = 33,33\% \quad (3.22)$$

Invertendo a situação, se a previsão \hat{y}_i fosse 30 kW com o valor real medido y_i igual a

40 kW, tem-se:

$$APE = (|100 \frac{40 - 30}{40}|) = 25\% \quad (3.23)$$

Esta aparente assimetria levou vários autores a publicar melhoramentos (ARMSTRONG; COLLOPY, 1992), (MAKRIDAKIS, 1993), propondo um MAPE simétrico ou sMAPE. Trata-se porém de um erro de avaliação, pois o valor percentual do erro é relativo ao valor real, e portanto a demonstração das equações (3.22) e (3.23) não é válida.

Todavia o principal problema com o MAPE é sua sensibilidade ao zero, e não à diferença entre valores: o erro tende ao infinito quanto mais próximo o valor real medido y_i estiver do zero. Se uma série temporal possui um único valor zero impossibilita o cálculo do MAPE. Na ocorrência de valores próximos de zero, o erro será muito alto, elevando a média, distorcendo a avaliação.

Especificamente, na avaliação de erros de previsão de demanda, o MAPE também se caracteriza por aumentar a média do erro em momentos de menor demanda. Exemplificando: um determinado consumidor possui em sua curva de demanda três regiões. Região 1, com demandas entre 1 e 2 kW, região 2 com demandas entre 10 e 20 kW e região 3 com picos de 50 kW. Supondo-se que um determinado método de previsão erre por 1 kW a demanda na região 1, por até 5 kW na região 2, e ignora totalmente o pico de 50 kW, prevendo 20 kW. Como resultado o erro percentual na região 1 será de até 100%, na região 2 por até 50% e 60% na região 3. Portanto, a região 1, com demanda menor, eleva o MAPE, embora o erro absoluto seja o menor de todos nesta região.

Apesar das deficiências, o MAPE continua sendo o método de avaliação de erros mais comum. Desta forma é o método empregado no presente trabalho.

3.1.3.3.3 Métodos de avaliação dos erros escalados

Uma alternativa à avaliação de erros dependentes ou independentes da escala são os métodos chamados de escalados. O erro é medido relativamente a um erro de referência. A referência usual é o método de previsão ingênuo¹.

Um formato simples é o erro médio absoluto relativo, que é dado na equação (3.24):

$$RelMAE = \frac{MAE}{MAE_r} \quad (3.24)$$

¹ No método de previsão ingênuo, o valor previsto é igual ao último valor medido da série temporal

Onde MAE é o erro médio absoluto da série, obtido pelo método de previsão sob avaliação, e MAE_r é o erro médio absoluto do método de referência. O erro médio absoluto relativo, portanto, mede a melhor ou menor precisão de um método de previsão relativamente a um método de referência. Quanto $RelMAE < 1$ significa que o método sob avaliação é melhor do que o método de referência. Já com $RelMAE > 1$ o método está sendo pior do que a referência.

A mesma lógica pode ser aplicada usando o erro quadrático médio, erro absoluto percentual médio, entre outros. Embora este tipo de método de avaliação seja independente da escala e não tenha os vícios observados nos erros percentuais, não é possível avaliar previsões pontuais futuras, fora da série temporal que gerou as médias.

Um método mais completo foi proposto em (HYNDMAN; KOEHLER, 2006) chamado de MASE (*Mean absolute scaled error*), ou seja, erro absoluto escalado médio, que é dado por:

$$q_j = \frac{e_j}{\frac{1}{T-1} \sum_{t=2}^T |y_t - y_{t-1}|} \quad (3.25)$$

$$MASE = \text{média}(|q_j|) \quad (3.26)$$

Onde e_j é o erro individual entre um valor previsto e seu correspondente real medido, em qualquer momento e qualquer horizonte. Já $y_t - y_{t-1}$ é o erro de previsão ingênuo interno da série temporal histórica com T observações.

3.1.4 Resultados

O objetivo desta primeira etapa foi testar a viabilidade do uso das demandas medidas por um medidor eletrônico na previsão da demanda em tempo real. Dentro da janela de tempo de um minuto, todo o processo de aquisição e armazenamento de dados, além da aplicação dos métodos de previsão devem ser realizados. Os métodos utilizados não devem apresentar convergências (para zero ou para o infinito) ao longo da operação ininterrupta dos processos descritos nos fluxogramas das figuras 3.3 e 3.4. Na prática o processo de solicitação e recepção da última demanda ao medidor, não havendo atrasos gerados pela rede GPRS da operadora de telefonia celular, leva dois segundos. A aplicação dos métodos de previsão mais dois segundos, totalizando portanto em quatro segundos todo o processo.

São apresentados aqui os resultados de algumas semanas de testes realizados ao longo

do segundo semestre de 2013 e no início de 2014. Para facilitar a análise e comparação, os resultados estão agrupados em semanas.

Em um primeiro momento o programa fornece dois vetores, um para cada método, com 30 demandas cada, representando as previsões do minuto 1 ao minuto 30. Para evitar excesso de dados (60 valores por minuto), e preservar a objetividade, apenas as previsões para os minutos 1, 15 e 30 foram gravados. A tabela 3.1 resume os primeiros resultados obtidos da previsão em tempo real, para dos dias de 6 a 9 de agosto de 2013. Nota-se que o método ingênuo (demanda futura igual à última demanda lida) apresenta menor erro para qualquer horizonte de previsão.

Horizonte	Erro médio percentual absoluto			Erro médio absoluto		
	Ingênuo	DSHW	HWADD	Ingênuo	DSHW	HWADD
1 minuto	2,91%	7,06%	4,43%	1,4 kW	3,4 kW	2,1 kW
15 minutos	7,39%	9,40%	8,96%	3,6 kW	4,6 kW	4,4 kW
30 minutos	9,56%	9,89%	10,17%	4,8 kW	4,9 kW	5,51 kW

Tabela 3.1: Erros médios obtidos nas previsões para os dias 6 a 9 de agosto de 2013

Em um segundo momento, uma variação foi introduzida, incluindo a média entre os dois métodos e o horizonte ampliado para 60 minutos. Novamente, por questões objetividade foram gravadas apenas as previsões para o minuto 1, 15, 30, 45 e 60. A tabela 3.2 apresenta os resultados tal qual fornecidos pelo software, com as médias dos resultados obtidos entre os dias 5 e 13 de novembro de 2013 (sábado e domingo foram excluídos).

Na tabela 3.3, estão os resultados para os dias 14 a 21 de novembro (só os dias úteis). A média entre as duas variantes de suavização exponencial resulta em um ganho na precisão sem porém superar o método ingênuo.

A tabela 3.4 mostra os resultados para os dias 12 a 16 de janeiro de 2014. Nota-se que o método ingênuo supera os demais métodos apenas para o horizonte de previsão de um minuto.

3.1.5 Discussão dos resultados e da análise dos aspectos técnicos

Em vista do processo de aquisição e previsão necessitar de apenas quatro segundos para ser realizado, ficou comprovada a possibilidade de realizar a previsão de demanda em tempo real, acessando um medidor diretamente e solicitando a demanda medida do minuto anterior.

Horiz	Erro médio percentual				Erro absoluto médio			
	Ingênuo	DSHW	HWADD	Média	Ingênuo	DSHW	HWADD	Média
1 min	2,71%	7,50%	6,19%	5,94%	1,4 kW	3,4 kW	2,6 kW	2,5 kW
15 min	7,29%	12,59%	9,80%	9,92%	4,2 kW	6,0 kW	4,7 kW	4,8 kW
30 min	9,01%	13,14%	11,88%	10,98%	6,0 kW	7,0 kW	6,0 kW	5,7 kW
45 min	10,98%	14,91%	14,58%	12,93%	7,9 kW	8,4 kW	7,6 kW	7,1 kW
60 min	13,21%	18,58%	16,21%	14,93%	10,0 kW	10,5 kW	8,8 kW	8,4 kW

Demanda mínima: 20 kW máxima: 218 kW média: 62 kW

Tabela 3.2: Erros médios obtidos nas previsões para os dias 5 a 13 de novembro de 2013.

Horiz	Erro médio percentual				Erro absoluto médio			
	Ingênuo	DSHW	HWADD	Média	Ingênuo	DSHW	HWADD	Média
1 min	2,17%	5,41%	4,05%	3,91%	1,6 kW	4,3 kW	2,4 kW	2,7 kW
15 min	7,23%	9,44%	10,52%	8,49%	5,8 kW	8,2 kW	7,2 kW	6,6 kW
30 min	10,32%	12,32%	14,51%	11,43%	9,0 kW	11,1 kW	11,0 kW	9,4 kW
45 min	14,05%	15,43%	19,06%	15,43%	12,5 kW	14,4 kW	15,1 kW	12,5 kW
60 min	17,59%	18,74%	24,02%	18,33%	16,0 kW	17,7 kW	19,0 kW	15,4 kW

Demanda mínima: 15 kW máxima: 234 kW média: 64 kW

Tabela 3.3: Erros médios obtidos nas previsões para os dias 14 a 21 de novembro de 2013.

Horiz	Erro médio percentual				Erro absoluto médio			
	Ingênuo	DSHW	HWADD	Média	Ingênuo	DSHW	HWADD	Média
1 min	2,02%	4,05%	3,01%	2,75%	1,5 kW	3,1 kW	2,2 kW	2,1 kW
15 min	6,46%	6,74%	6,87%	5,64%	5,4 kW	5,5 kW	5,5 kW	4,6 kW
30 min	9,44%	8,22%	8,81%	6,66%	8,6 kW	7,1 kW	7,8 kW	5,9 kW
45 min	13,00%	9,85%	11,39%	8,14%	12,1 kW	8,8 kW	10,4 kW	7,4 kW
60 min	16,48%	11,34%	16,15%	10,21%	15,5 kW	10,3 kW	14,3 kW	9,3 kW

Demanda mínima: 26 kW máxima: 218 kW média: 90 kW

Tabela 3.4: Erros médios obtidos nas previsões para os dias 12 a 16 de janeiro de 2014.

Isto significa que os métodos e a forma de aplicação podem ter uso prático, um dos objetivos do presente trabalho.

Porém, ficou evidenciado que a precisão das previsões sofre forte influência do histórico das demandas. As razões podem ser climáticas, dias especiais ou ainda problemas de conexão com o medidor. Por exemplo, tendo em vista o uso do histórico das duas semanas anteriores nas previsões de 5 a 13 de novembro (Tabela 3.2), observou-se a influência do dia 28 de outubro (dia do funcionário público), bem como a mudança do horário para o horário de verão. Pela mesma razão o feriado do dia 15 de novembro influencia as previsões entre 14 e 21 de novembro (Tabela 3.3).

Observou-se também uma significativa influência dos problemas de conexão através da rede GPRS. No programa de previsão, foi incluído um gerador de relatórios contínuos (log), com informações sobre diversas variáveis, incluindo o estado da conexão e tempos de resposta. Através deste relatório verificou-se em vários dias problemas na comunicação, sendo estes de responsabilidade da operadora de telefonia celular, e portanto fora do escopo de soluções. Este problema praticamente deixou de existir no início de 2014 o que ficou evidenciado em uma substancial queda do erro de previsão (Tabela 3.4). Apesar do feriado do dia 1º de janeiro fazer parte do histórico, as previsões calculadas através dos métodos de suavização exponencial obtiveram menor erro do que o método ingênuo.

Foi utilizado um computador com sistema operacional Windows 7, processador i3 a 3,19 GHz e 4 GB de memória RAM. Com esta configuração observou-se que o programa de previsão não necessita um computador dedicado unicamente para esta finalidade. O processo pode rodar de forma minimizada. A velocidade e a precisão das previsões não sofrem influência de outros processos que estão em execução no computador.

A figura 3.5 mostra os dados dos últimos dias do funcionamento do sistema, entre 12 e 16 de janeiro de 2014. Estão plotados no gráfico as demandas lidas, de minuto e minuto, a previsão feita 15 minutos antes e o erro absoluto resultante.

A partir das observações desta primeira etapa e dos resultados consolidados (janeiro 2014 - Tabela 3.3) pode-se fazer as seguintes afirmações:

1. É tecnicamente viável realizar PDCP utilizando um fluxo de medidas vindo diretamente de um medidor. Com os métodos testados, todo o processo de cálculo e armazenamento no banco de dados leva poucos segundos, permitindo uma operação em tempo real;
2. Métodos de previsão têm menor erro do que o método ingênuo (exceção observada na

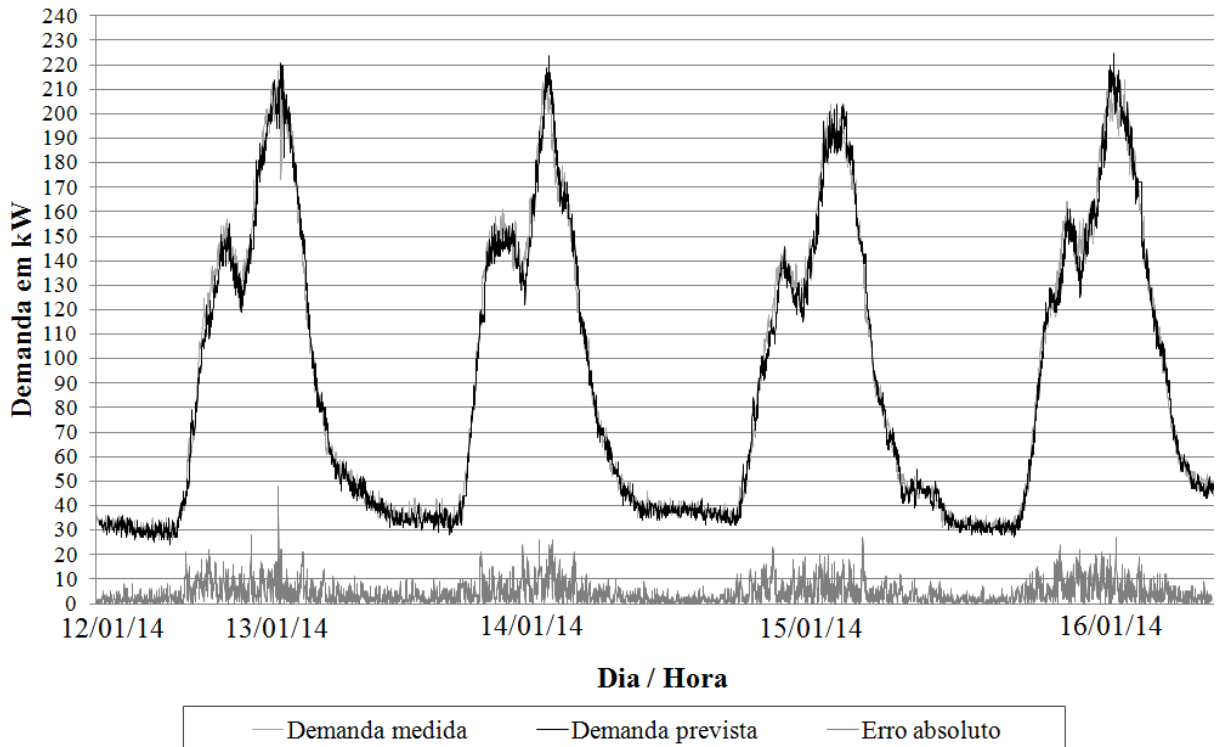


Figura 3.5: Gráfico com a demanda lida, previsão feita 15 minutos antes e o erro absoluto entre os dias 12 e 16 de janeiro de 2014

previsão para 1 minuto), ou seja, há justificativa na sua aplicação;

3. A média das previsões feita por dois métodos apresenta menor erro que cada método individualmente, sugerindo que a combinação de vários métodos é melhor que um método usado de forma isolada;

3.2 Comparativo na aplicação PDCP a consumidores de perfis diferentes

Na primeira etapa foram utilizados dados de um único consumidor, no caso uma subestação da Universidade Federal de Santa Maria. Utilizou-se dois métodos de previsão (HWADD e DSHW) além da média entre suas previsões, sendo que o processamento é capaz de ser realizado em tempo real.

Nesta segunda etapa o número de consumidores é ampliado, com características de uso da energia bem diversos. Além dos métodos testados na prática na primeira etapa, mais seis métodos são acrescentados, de forma a criar referências quanto ao comportamento das previsões. Trata-se também de um comparativo da performance de diferentes métodos quanto ao tempo de computação e tamanho do erro. Esta etapa é importante pois a partir dos resultados obtidos com métodos já conhecidos é possível avaliar a proposta deste trabalho. A maior parcela de tra-

balhos publicados, citados na revisão bibliográfica, propõe novas metodologias, todavia não as aplicam a diversos consumidores, nem fazem comparativos com outros métodos, limitando-se a informar que o erro MAPE.

A segunda etapa responde aos seguintes questionamentos:

- Há um único método, que traz resultados aceitáveis, independentemente da escala de demandas e da curva do consumidor?
- Dependendo do horário ou dia da semana, um método diferente se sairá melhor?
- Existe de fato a necessidade de propor uma nova metodologia?

3.2.1 Características das curvas de demanda usados no comparativo

Os dados dos oito consumidores utilizados nesta etapa foram obtidos de medidores de consumidores do grupo A, da concessionária local (AES Sul). Os consumidores forneceram uma autorização para solicitar a memória de massa de seus medidores junto à concessionária.

A diferença dos dados obtidos através da concessionária em relação aos dados da primeira etapa é a resolução temporal. Por padrão os medidores de energia das concessionárias no Brasil registram a demanda de 5 em 5 minutos. Portanto, nesta segunda etapa ao invés de 1.440 registros diários tem-se 288 registros. A tabela 3.5 resume as características de cada consumidor, incluindo a referência ao gráfico da curva de demanda de cada um. Somente as demandas dos dias úteis estão representadas.

Id	Tipo de consumidor	Potência da subestação	Demanda máxima	Período	Curva Figura
A1	Universidade	500 kVA	288 kW	21/11 a 17/12/2013	3.6
A2	Universidade	500 kVA	255 kW	10/09 a 07/10/2013	3.7
B	Fábrica concretos	225 kVA	81 kW	02/07 a 01/08/2013	3.8
C	Metalúrgica	300 kVA	155 kW	14/10 a 12/11/2009	3.9
D	Supermercado	75 kVA	59 kW	07/10 a 08/11/2010	3.10
E	Posto de gasolina	75 kVA	35 kW	09/07 a 08/08/2013	3.11
F	Moinho de trigo	300 kVA	396 kW	08/06 a 28/06/2013	3.12
G	Fábr.de refrigerantes	4.550 kVA	2.160 kW	06/09 a 07/10/2013	3.13

Tabela 3.5: Resumo dos consumidores utilizados na segunda etapa

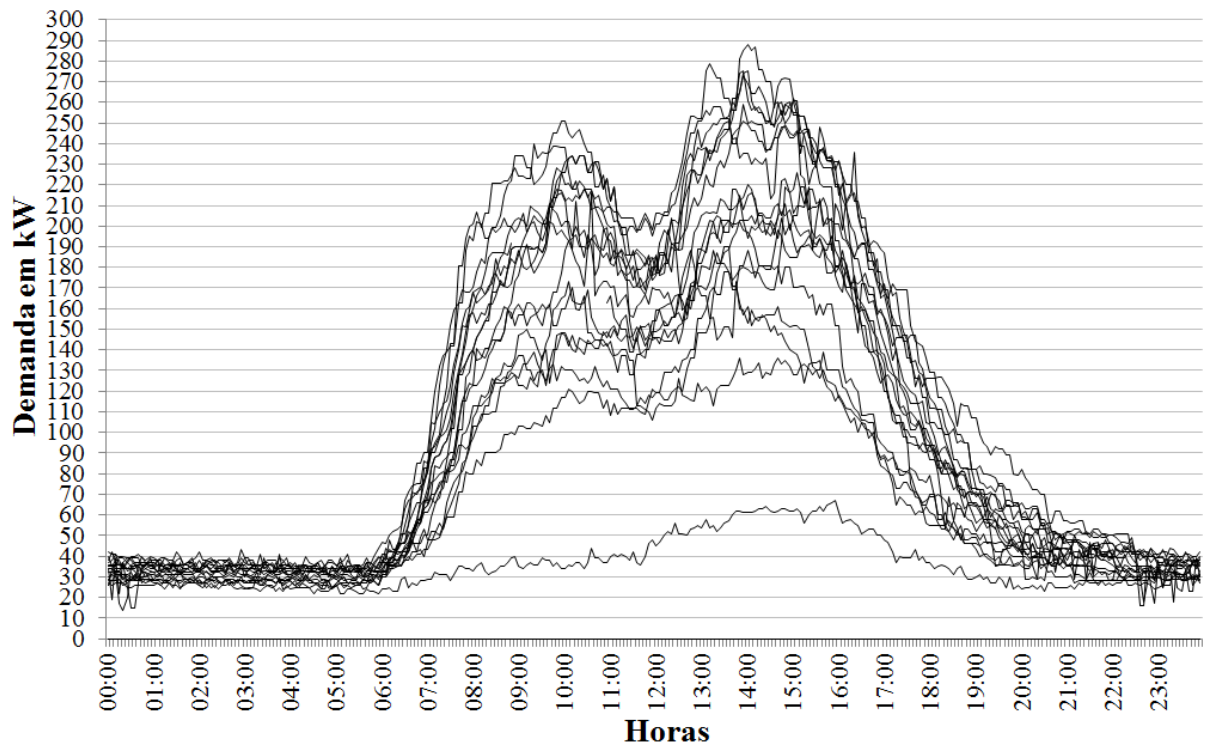


Figura 3.6: Demandas do consumidor A1 entre 21 de novembro de 17 de dezembro de 2013




Figura 3.7: Demandas do consumidor A2 entre 10 de setembro de 7 de outubro de 2013




Figura 3.8: Demandas do consumidor B entre 2 de julho e 1 de agosto de 2013




Figura 3.9: Demandas do consumidor C entre 14 de outubro de 12 de novembro de 2013




Figura 3.10: Demandas do consumidor D entre 14 de outubro de 12 de novembro de 2009




Figura 3.11: Demandas do consumidor E entre 9 de julho e 8 de agosto de 2013

Observa-se algumas similaridades nas curvas de demanda, apesar da origem de diferentes seg-

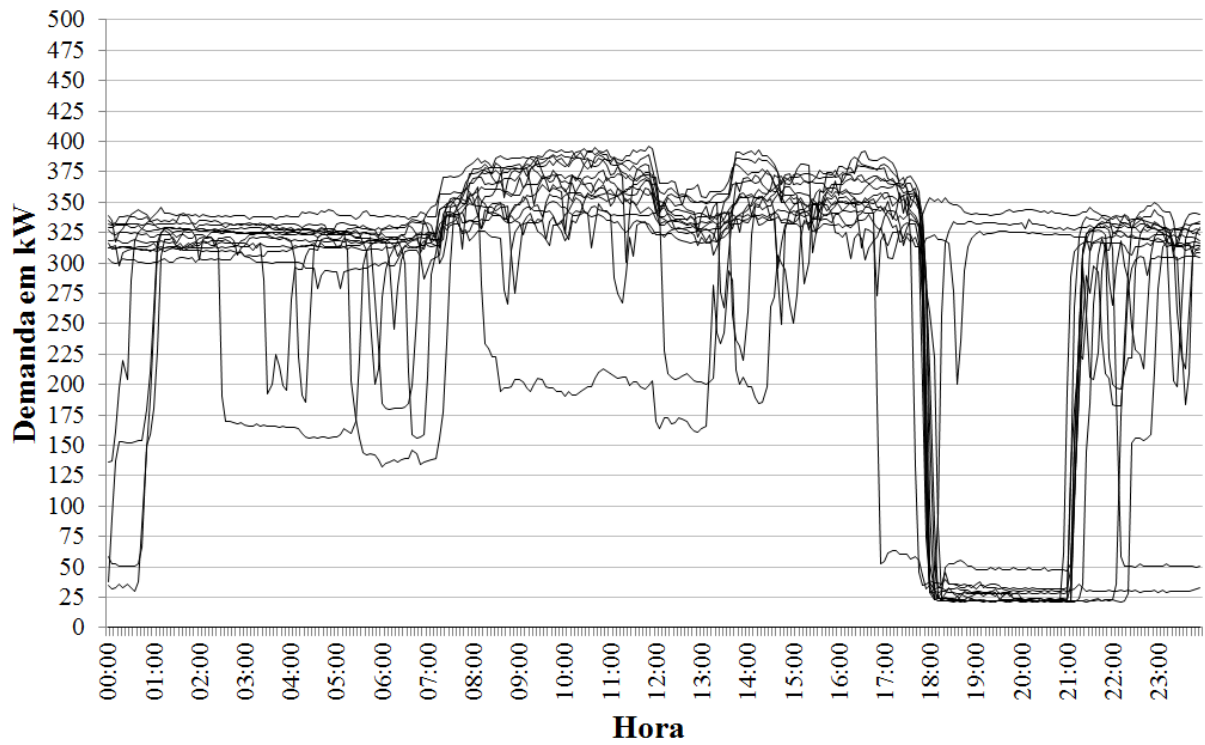


Figura 3.12: Demandas do consumidor F entre 8 e 28 de junho de 2013

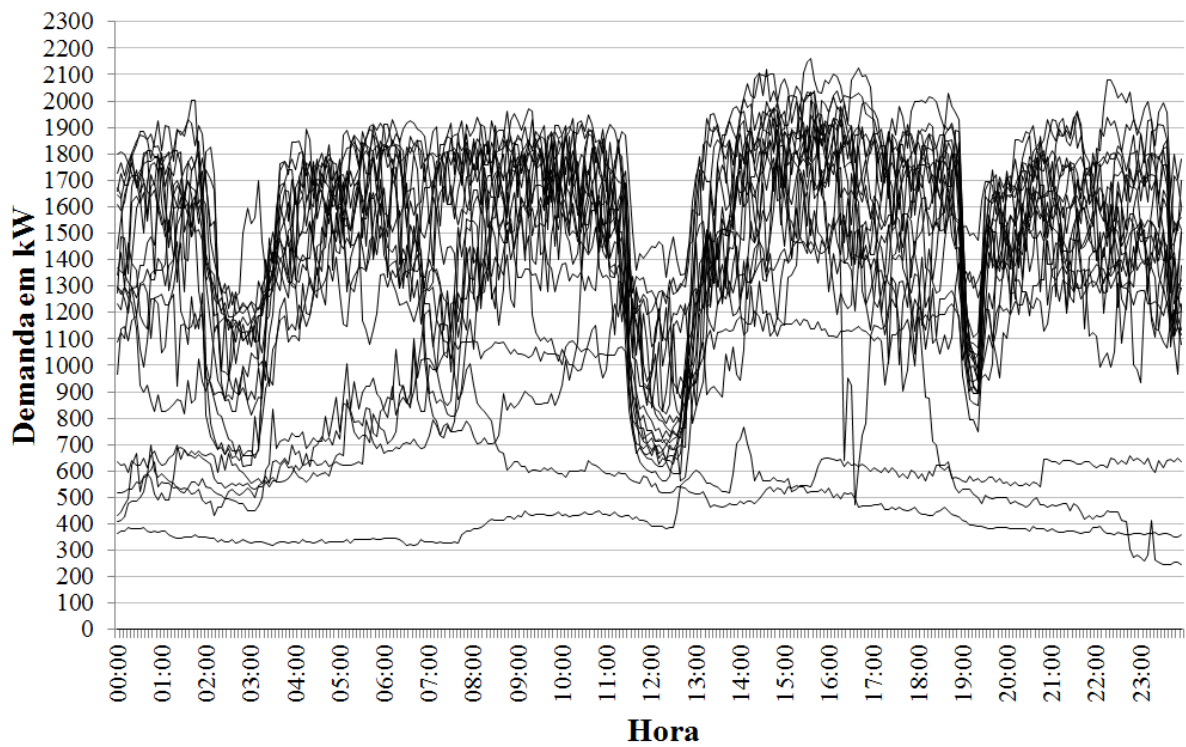


Figura 3.13: Demandas do consumidor G entre 6 de setembro e 7 de outubro de 2013

mentos comerciais ou industriais. No caso dos consumidores A1 e A2 é redundante por se tratar do mesmo, apenas em momentos distintos: inverno e final da primavera. Consumidores B e C,

sendo indústrias de pequeno porte possuem contornos muito similares, identificando-se os intervalos ao meio-dia e a ausência de labor à noite. Consumidores comerciais D e E também são similares, inclusive na ausência de demandas no horário das 18 às 21 horas. Este intervalo é o chamado horário de ponta, com tarifas mais elevadas, em que estes consumidores usam geração própria à óleo diesel, economicamente mais atraente. Os consumidores F e G diferenciam-se dos demais apresentando comportamento aleatório da sua curva de demanda. Operam durante as 24 horas do dia, sendo que o consumidor F na maioria dos dias úteis reduz a sua demanda drasticamente no horário de ponta. No consumidor G observam-se apenas os intervalos de troca de turnos: entre 2 e 3 horas da madrugada, por volta do meio dia e entre 19 e 20 horas.

3.2.2 Aplicação dos métodos de previsão

Uma série temporal é uma sequência de valores equidistantes e ordenadas no tempo, de observações de uma variável física ou financeira (BOX; JENKINS; REINSEL, 2008). Portanto, o registro em intervalos regulares, da demanda de energia elétrica através de um medidor eletrônico, é uma série temporal. Métodos de análise e previsão de séries temporais podem ser aplicados diretamente no histórico de demandas do consumidor.

Há um amplo espectro de métodos de previsão para séries temporais, que podem ser divididos em métodos sem modelo (suavização exponencial, regressão) e métodos com modelo (por exemplo o ARIMA - modelo autorregressivo e de médias móveis integrado) (PALIT; POPOVIC, 2005) .

Nesta etapa, oito métodos de PDGP foram aplicados aos dados da demanda de cada consumidor:

1. Suavização exponencial Holt-Winters aditiva;
2. Suavização exponencial Holt-Winters multiplicativa;
3. Suavização exponencial de dupla sazonalidade;
4. SARIMA: ARIMA com sazonalidade;
5. Decomposição de séries temporais, com posterior aplicação de suavização exponencial;
6. Decomposição de séries temporais, com posterior aplicação de um modelo ARIMA;

7. Rede neural;
8. Método ingênuo para avaliação;

Os métodos de suavização exponencial Holt-Winters e de dupla sazonalidade foram detalhados na seção 3.1.3. Os demais métodos estão detalhados nas seções seguintes.

3.2.2.1 Métodos ARIMA

ARIMA é a abreviação do inglês de *Autoregressive Integrated Moving Average* definido como um modelo autorregressivo e de médias móveis integrado (PAULINO et al., 2011). Trata-se de um método clássico da estatística cujo original foi proposto por Box e Jenkins (1970), com mais recente revisão em 2008 (BOX; JENKINS; REINSEL, 2008). Enquanto na suavização exponencial existem diferentes métodos, para ARIMA existem diferentes modelos. A suavização exponencial define a série temporal como composta por um valor básico (nível) e com adição de uma tendência e sazonalidades. Já um modelo ARIMA define a série temporal através das autocorrelações contidas nos dados. Desta forma as duas abordagens são complementares (HYNDMAN; ATHANASOPOULOS, 2014). Modelos ARIMA são compostos por um modelo autorregressivo (AR), e um modelo de média móvel (MA). Após diferenciação, cujo objetivo é conferir estacionaridade à série, o processo é chamado de autorregressivo e de médias móveis integrado, denotado por ARIMA(p,d,q) detalhado a seguir.

3.2.2.1.1 Estacionaridade

Uma série temporal é considerada estacionária quando seus valores se distribuem aleatoriamente ao redor de uma média, ou em outras palavras, seus valores independem do tempo em que são observados. Uma série temporal com uma tendência linear não é estacionária, pois a média de algumas observações no início da série será diferente da média de observações mais ao final da série (BOX; JENKINS; REINSEL, 2008).

3.2.2.1.2 Modelo autorregressivo de ordem p - AR(p)

O valor atual de uma série temporal pode ser expresso como função de p valores do passado $x_{t-1}, x_{t-2}, \dots, x_{t-p}$. Um modelo AR(p) pode ser escrito como:

$$x_t = c + \phi_1 x_{t-1} + \phi_2 x_{t-2} + \cdots + \phi_p x_{t-p} + w_t \quad (3.27)$$

onde c é uma constante, x_t é estacionário, $\phi_1, \phi_2, \dots, \phi_p$ são constantes diferentes de zero e w_t é ruído branco. A equação pode ser reescrita com o uso de um termo de translação para o passado B , escrevendo $Bx_t = x_{t-1}$, ou ainda $B^2 x_t = B(Bx_t) = Bx_{t-1} = x_{t-2}$, o que nos leva a:

$$B^k x_t = x_{t-k} \quad (3.28)$$

aplicando equação ((3.28)) na equação ((3.27)), e resolvendo em função de x_t resulta na definição geral de um modelo AR(p):

$$\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \cdots - \phi_p B^p \quad (3.29)$$

3.2.2.1.3 Modelo média móvel de ordem q - MA(q)

Analogamente ao modelo autorregressivo, um valor x_t de uma série temporal também pode ser escrito em função da média móvel de ordem q do ruído w_t :

$$x_t = w_t + \theta_1 w_{t-1} + \theta_2 w_{t-2} + \cdots + \theta_q w_{t-q} \quad (3.30)$$

onde q é o número de passos integrantes da média móvel e $\theta_1, \theta_2, \dots, \theta_q$ são os parâmetros, com w_t sendo o ruído. Usando o termo de translação para o passado conforme equação ((3.28)) leva à definição geral do modelo MA(q):

$$\theta(B) = 1 + \theta_1 B + \theta_2 B^2 + \cdots + \theta_q B^q \quad (3.31)$$

3.2.2.1.4 Diferenciação

Os modelos AR(p), MA(q) ou ARMA (p, q) somente podem ser aplicados a series temporais estacionárias. Na prática porém são raros os processos cujos dados são estacionários. Geralmente uma série temporal real é composta por dois componentes, um componente não-estacionário (tendência) e outro componente estacionário (valores com média zero). Uma maneira de tornar uma série estacionária é através da diferenciação (aqui representado por ∇), ou seja, calculando a diferença entre observações sucessivas.

$$\nabla x_t = x_t - x_{t-1} \quad (3.32)$$

Utilizando-se o termo de translação ao passado obtemos:

$$\nabla^d x_t = (1 - B)^d x_t \quad (3.33)$$

Onde d é a quantidade de diferenciações necessárias para tornar uma série temporal estacionária.

3.2.2.1.5 Modelos ARIMA (p, d, q)

Combinando a diferenciação com a autorregressão e a média móvel, obtêm-se o modelo ARIMA não-sazonal. Convencionou-se a escrita como ARIMA (p, d, q) onde p é a ordem da parte autorregressiva, d o número de diferenciações para que a série temporal se torne estacionária e q a ordem da parte de média móvel. Tendo em vista que tanto o modelo AR (p) quanto o modelo MA (q) representam a mesma série temporal, pode-se escrever, usando o termo B de translação:

$$\phi(B)x_t = \theta(B)w_t \quad (3.34)$$

Incluindo a diferenciação, tem-se a notação completa do modelo ARIMA (p, d, q) :

$$(1 - \phi_1 B - \dots - \phi_p B^p)(1 - B)^d x_t = c + (1 + \theta_1 B + \dots + \theta_q B^q)w_t \quad (3.35)$$

3.2.2.1.6 Modelos ARIMA com sazonalidade - SARIMA

Na prática, principalmente em séries temporais compostas por observações da demanda de energia elétrica de um determinado consumidor, observa-se um componente sazonal periódico, que se repete a cada s observações. Um modelo ARIMA que lida com a sazonalidade é escrito como SARIMA $(p, d, q)(P, D, Q)_s$, onde os operadores minúsculos p, d, q se referem à parte não-sazonal e os operadores maiúsculos P, D, Q se referem à parte sazonal. O modelo ARIMA multiplicativo pode ser escrito como segue:

$$\Phi_P(B^s)\phi(B)\nabla_s^D \nabla^d x_t = \alpha + \Theta_Q(B^s)\theta(B)w_t \quad (3.36)$$

As parcelas autorregressiva e de média móvel não-sazonais estão novamente representadas pelos polinômios $\phi(B)$ e $\theta(B)$ de ordens p e q respectivamente. As parcelas sazonais

autorregressiva e de média móvel estão representadas pelos polinômios $\Phi_P(B^s)$ e $\Theta_Q(B^s)$ de ordens P e Q . As diferenciações não-sazonal e sazonal, respectivamente, são definidas por $\nabla^d = (1 - B)^d$ e $\nabla_s^D = (1 - B^s)^D$.

3.2.2.2 Decomposição de séries temporais

Conforme Palit e Popovic (2005, p.21) as séries temporais possuem quatro componentes: sazonal, cíclica, tendência e um componente aleatório (ou ruído, ou restante). Na prática os componentes cíclicos e tendência podem ser combinados em um só, conforme Box et al. (2008, p.354). As séries temporais da demanda de energia elétrica têm estes componentes bem definidos, tornando-as candidatas à decomposição. Um método de decomposição bastante robusto é o método STL (*Seasonal-Trend decomposition using Loess*) proposto por Cleveland et al. (1990). O acrônimo Loess é uma abreviação de *Local Regression*, ou seja, regressão local. A aplicação deste método, através de ferramentas computacionais permite retirar da série temporal seus componentes sazonais e de tendência trabalhando cada componente separadamente. A figura 3.14 mostra o resultado da decomposição da curva de demanda de um mês de um posto de combustíveis.




Figura 3.14: Exemplo de decomposição de uma série temporal de demandas de um posto de combustíveis

A decomposição facilita a previsão da série temporal, pois esta é feita apenas com o restante dos dados, sendo posteriormente adicionados a previsão da tendência e da sazonalidade. A previsão dos componentes de tendência e sazonalidade pode ser feita através de um método

sazonal-ingênuo. Desta forma, nos dados restantes de comportamento mais complexo, usa-se métodos não sazonais, ARIMA ou de suavização exponencial.

3.2.2.3 Redes neurais

As redes neurais se popularizaram nos últimos anos, principalmente devido ao aprimoramento das ferramentas computacionais. Perceptrons de múltiplas camadas e redes de base radial têm seu uso no reconhecimento de padrões estruturais. Para usar redes neurais na previsão de séries temporais estas precisam ser adaptadas para o reconhecimento temporal de padrões, o que requer o processamento de padrões que evoluem no tempo. O valor de saída da rede neural não depende apenas do valor de entrada naquele instante mas também de seus valores passados (HAYKIN, 1999). A estrutura neural para o processamento de padrões temporais é um filtro não-linear com uma memória de linha de atraso derivada de ordem p e um perceptron de múltiplas camadas. Haykin (1999) chamou esta rede neural de *focused time lagged feedforward network* ou em português *rede alimentada adiante focada atrasada no tempo*, representada na figura 3.15, onde o valor atual é a entrada $x(n)$, seus valores passados $x(n - 1), \dots, x(n - p)$ e a saída $y(n)$.




Figura 3.15: Rede neural alimentada adiante focada atrasada no tempo. Figura adaptada de Haykin (1999).

Esta rede neural apresenta apenas uma única camada oculta, de modo que a saída pode ser representada por:

$$y(n) = \sum_{j=1}^{m_1} w_j y_j(n) = \sum_{j=1}^{m_1} w_j \varphi \left(\sum_{l=1}^{m_1} w_j(l) x(n-1) + b_j \right) + b_0 \quad (3.37)$$

onde w_j são os pesos sinápticos, $\varphi()$ a função de ativação do neurônio j , m_1 o tamanho da camada oculta e b_j e b_o os bias.

3.2.2.4 Método ingênuo para avaliação - BENCHMARK

Com a finalidade realizar comparações posteriores entre métodos quanto aos seus erros, um método de avaliação foi introduzido, doravante chamado de BENCHMARK. Este método é uma ampliação do método ingênuo (naive) para um método sazonal-ingênuo. A demanda prevista é a média de dez demandas registradas no mesmo instante em dez dias antecedentes, conforme equação (3.38):

$$\hat{y}_t = \frac{1}{10} \sum_{k=1}^{10} y_{t-km} \quad (3.38)$$

Onde \hat{y}_t é a demanda prevista, e m é a defasagem, no caso 288 registros.

3.2.3 Detalhes práticos da aplicação dos métodos

Para aplicação dos métodos recorreu-se à linguagem R conforme detalhamento no Apêndice A, tabela A.1. Para melhor identificação ao do presente trabalho, cada método foi abreviado conforme apresentado na tabela 3.6.

Abreviação	Descrição
DSHW	Suavização exponencial de dupla sazonalidade
HWADD	Suavização exponencial Holt-Winters aditiva
HWMULT	Suavização exponencial Holt-Winters multiplicativa
STLFETS	Suavização exponencial após decomposição utilizando Loess
STLFARIMA	ARIMA após decomposição utilizando Loess
NEURAL	Rede neural
SARIMA	ARIMA com sazonalidade
BENCHMARK	Média de 10 últimas demandas, no mesmo horário

Tabela 3.6: Tabela de consulta às funções utilizadas

As medições realizadas com o medidor instalado na subestação da UFSM (A1 e A2) tiveram seus registros alterados da frequência de 1 minuto para 5 minutos. Cada registro novo corresponde à média de 5 registros de um minuto. Estes dados posteriormente foram exportados para planilhas eletrônicas do tipo "xls", sendo excluídos os registros dos sábados e domingos.

Os dados fornecidos pela concessionária AES Sul (consumidores B até G) têm um formato nativo, regidos pela NBR14522:2000, sendo exportados para o formato de planilha eletrônica, com posterior retirada dos registros correspondentes aos sábados e domingos.

A Tabela 3.7 mostra um exemplo de planilha inicial do processo, composta de duas colunas e entre 5.000 e 6.000 linhas.

Linha	Dia/Hora	Demanda
1	6/9/13 10:55	1503
2	6/9/13 11:00	1457
3	6/9/13 11:05	1371
⋮	⋮	⋮
6119	07/10/13 16:45	1763

Tabela 3.7: Exemplo da estrutura inicial da planilha contendo as demandas lidas

Com todas as séries temporais das demandas medidas em formatos legíveis pela linguagem R, estas foram importadas e transformadas em séries temporais do tipo "msts" (*multiple seasonal time series*), com dupla sazonalidade: a sazonalidade diária (288 registros) e a sazonalidade semanal (1.440 registros, considerando-se apenas os dias úteis). Os primeiros 2.880 registros de cada consumidor formam a base histórica, sobre a qual não é feita qualquer previsão. A partir do registro 2.881 até o registro final de cada consumidor foram aplicados os 8 métodos, registro por registro, movendo-se a base histórica na forma de uma janela móvel. A cada passo de previsão, 24 demandas foram previstas, sendo estas as demandas estimadas para os momentos $t + 5$ até $t + 120$, onde t é o momento da previsão, utilizando-se as demandas históricas entre t e $t - 14.400$ (em minutos). De forma análoga, porém expressando-se a previsão em passos ao invés de minutos, no momento t foi prevista a demanda para os momentos $t + 1$ até $t + 24$ utilizando-se as demandas $t - 1$ até $t - 2880$. Na figura 3.16 estão as etapas do cálculo para um consumidor e aplicando um método. O processo foi repetido para cada método, sendo gravadas 8 planilhas de previsões, uma para cada método.

Para facilitar a análise posterior das previsões obtidas (cálculo de erros), os dados gerados foram gravados em tabelas da forma que ao final do processo, para cada demanda medida,

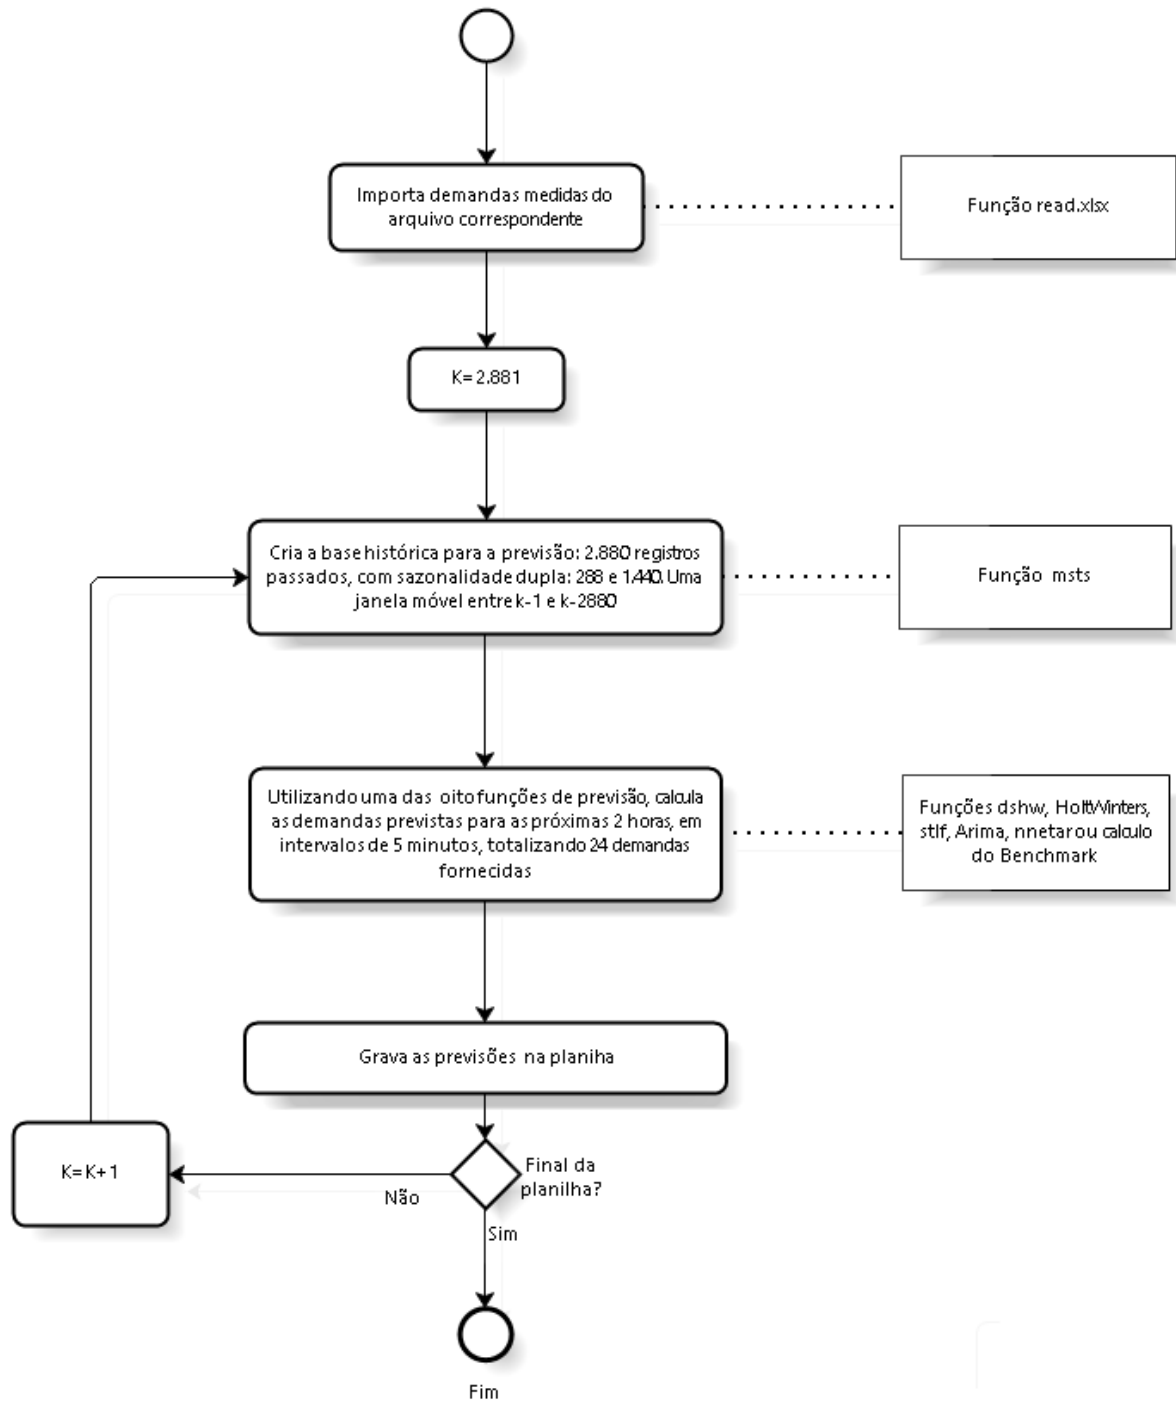


Figura 3.16: Fluxograma da previsão de demanda aplicando um dos oito métodos utilizando dados de um consumidor

na mesma linha estivessem as previsões feitas para esta demanda. Desta forma, para cada demanda medida existem 24 previsões, distribuídas entre a previsão imediatamente anterior (5 minutos antes da demanda real ser medida) e a previsão mais antiga, feita 120 minutos antes.

Para cada método de previsão utilizado, gerou-se uma tabela com 24 colunas e tantas linhas quanto registros iniciais, totalizando até 153.000 registros por método. Para maior clareza

a tabela 3.8 exemplifica o método de gravação. Cada passo de previsão grava uma diagonal. Individualmente cada consumidor, englobando os oito métodos gerava um arquivo com 1.228.000 pontos de dados. Este arquivo, ou bloco de dados, tem forma tridimensional, tendo em um dos eixos o tempo (passos de 5 em 5 minutos), e no outro eixo as previsões (24 ao todo) e no último eixo os métodos. Este formato facilita sobremaneira a análise dos resultados, permitindo uma análise cruzada.

Tempo	Linha	Previsões feitas T minutos atrás											
		5	10	15	20	25	30	35	40	45	...	120	
t	K	<- Momento em que é realizada a previsão											
t+5	K+1	1											
t+10	K+2		2										
t+15	K+3			3									
t+20	K+4				4								
t+25	K+5					5							
t+30	K+6						6						
t+35	K+7							7					
t+40	K+8								8				
t+45	K+9									9			
⋮	⋮										...		
t+120	K+24												24

Tabela 3.8: Método de gravação em tabela das previsões, facilitando análise posterior

3.2.4 Resultados

A aplicação dos oito métodos de previsão nas demandas dos oito consumidores, resulta em uma grande quantidade de dados (em média um milhão de previsões e mesmo número de erros calculados). Através do agrupamento dos resultados em gráficos é possível visualizar tendências com mais clareza, sendo possível tirar conclusões. Nesta seção, os resultados das previsões para o consumidor E (posto de gasolina) são analisados com mais profundidade. O detalhamento dos resultados dos demais consumidores e seus respectivos gráficos podem ser comparados no Anexo A, nas tabelas e figuras A.1 até A.8.

Para cada horizonte de previsão (t-5 até t-120) foi calculado o erro MAPE para cada método. Estes erros estão na tabela 3.9, em que os menores erros para cada horizontes estão destacados:

HORIZ	DSHW	HWADD	HWMULT	NEURA	STLFETS	STLFARIMA	SARIMA	BENCH
t-5	21,8%	12,8%	10,5%	112,7%	12,1%	13,0%	12,4%	13,6%
t-10	25,4%	15,2%	11,4%	113,6%	13,4%	15,5%	13,6%	13,6%
t-15	26,3%	16,0%	11,6%	113,6%	14,0%	16,5%	13,8%	13,6%
t-20	28,2%	17,3%	12,0%	111,8%	14,8%	17,2%	14,2%	13,6%
t-25	30,0%	18,4%	12,3%	112,6%	15,7%	18,1%	14,2%	13,6%
t-30	30,9%	19,9%	12,5%	113,5%	16,7%	19,2%	14,3%	13,6%
t-35	32,3%	21,5%	12,9%	117,0%	17,8%	20,1%	14,4%	13,6%
t-40	34,3%	22,9%	13,1%	118,9%	18,8%	21,1%	14,5%	13,6%
t-45	35,8%	24,3%	13,2%	119,0%	19,8%	22,1%	14,7%	13,6%
t-50	38,7%	25,6%	13,4%	118,1%	20,3%	22,8%	14,7%	13,6%
t-55	39,7%	26,6%	13,5%	118,7%	20,9%	23,4%	14,7%	13,6%
t-60	42,1%	28,0%	13,5%	117,7%	21,6%	23,9%	14,8%	13,6%
t-65	42,9%	29,4%	13,5%	117,1%	22,2%	24,5%	14,7%	13,6%
t-70	44,2%	30,8%	13,7%	118,4%	23,1%	24,9%	14,8%	13,6%
t-75	46,1%	32,0%	13,8%	118,1%	23,7%	25,3%	14,9%	13,6%
t-80	47,3%	33,3%	13,9%	118,5%	24,6%	25,6%	14,9%	13,6%
t-85	47,7%	34,1%	14,0%	119,2%	25,4%	25,9%	15,1%	13,6%
t-90	49,0%	34,9%	14,1%	119,6%	26,2%	26,5%	15,1%	13,6%
t-95	50,7%	36,1%	14,3%	117,3%	26,8%	26,6%	15,2%	13,6%
t-100	51,1%	37,1%	14,4%	115,6%	27,7%	26,9%	15,3%	13,6%
t-105	52,7%	38,0%	14,6%	115,5%	28,6%	27,2%	15,4%	13,6%
t-110	53,6%	38,7%	14,7%	116,2%	29,5%	27,5%	15,5%	13,6%
t-115	53,3%	39,3%	14,7%	115,6%	30,3%	27,8%	15,6%	13,6%
t-120	54,5%	40,3%	14,9%	116,1%	31,1%	28,1%	15,6%	13,6%

Tabela 3.9: Erros percentuais médios por método e horizonte de previsão - Consumidor E

Através da representação gráfica dos erros em função do horizonte de previsão, na figura 3.17, pode-se determinar qual dos oito métodos é mais preciso (menor erro MAPE). Cada curva representa um método, sendo que para cada horizonte de previsão, foi calculado o erro médio iniciando pelo erro do registro de número 2.881 (previsão do método em relação ao valor medido) até o final do arquivo, portanto a média de 5 mil a 6 mil previsões.

Com base na tabela e no gráfico observa-se que o método HWMULT apresenta menor erro para o horizonte t-5 até o horizonte t-65. A partir do horizonte t-70 até o horizonte t-120 o BENCHMARK é melhor.

O gráfico da figura 3.17 não permite tirar conclusões quanto aos erros em função do horário, pois baseia-se na média total dos erros, estratificados por horizonte. Para possibilitar a visualização dos erros em função do horário e também em função do horizonte, a figura 3.18 apresenta um relevo tridimensional, resultado da aplicação do método HWMULT. O eixo das abcissas e ordenadas respectivamente representam o horário e o horizonte de previsão. O eixo Z (a altura do relevo), representa a média dos erros percentuais naquele ponto.

Os relevos de todos os métodos para o Consumidor E, bem como os relevos dos demais consumidores estão no Anexo A, figuras A.9 até A.16




Figura 3.17: Consumidor E: MAPE em função do horizonte de previsão para cada um dos oito métodos




Figura 3.18: Consumidor E: MAPE do método HWMULT em função do horário e do horizonte de previsão

Na análise do gráfico da figura 3.18 observa-se que o horário exerce uma importante influência no tamanho do erro da previsão. Especialmente no horário de ponta (entre 18 e 21 horas) o método apresenta erro nulo. Erros entre 5% e 10% são observados durante a madrugada (1 a 6 horas). Os maiores erros são observados no período da manhã, entre 9 e 10 horas.

No Anexo A podem ser comparados os relevos de todos os métodos, observando-se que cada método possui características diferentes quando à ocorrência de maiores ou menores erros. Cite-se como exemplo o período da manhã entre 9 e 10 horas no qual o método HWMULT obteve os maiores erros, enquanto o método STLFARIMA apresentou erros muito menores no mesmo horário.

Calculou-se também a média horária dos erros, para cada um dos oito métodos e os respectivos horizontes de previsão, com o objetivo de identificar o método com menor erro em função da hora do dia. Esta necessidade foi detectada a partir da análise dos relevos, onde evidenciou-se uma variabilidade grande do erro por método em dependência do horário. Para facilitar o resultado, cada método recebeu uma cor identificadora, e o resultado está representado na figura 3.19.




Figura 3.19: Consumidor E: Mapeamento dos métodos com menor erro em função do horário e horizonte de previsão

O código de cores permite identificar padrões, neste exemplo do consumidor E, o método STLFETS se destaca na madrugada até as 3h, após este horário há predominância do método STLFARIMA até as 16 horas, HWMULT entre 17 e 18 horas, DSHW entre 19 e 20 horas, STLFETS novamente às 21 horas e após este horário STLFARIMA.

Esta análise foi repetida para os demais consumidores. Os gráficos estão no Anexo A, respectivamente da figura A.17 até a figura A.25.

3.2.5 Discussão dos resultados

Analisando-se as tabelas e gráficos do Anexo A (A.1 até A.8), observa-se que não há um método que se destaca como aquele que traz o menor erro de previsão, para todos os consumidores. Os consumidores A1 e A2, possuem curvas de carga similares, porém, no primeiro caso é o método HWMULT e no segundo o método SARIMA que fornece os menores erros. A demanda do consumidor B mostrou-se de difícil previsão, havendo alternância entre STLFETS e STLFARIMA como os de melhor resultado. No consumidor C, o método SARIMA. Para o consumidor D, o método STLFETS se destaca até o horizonte $t-40$ e para horizontes maiores o BENCHMARK. No consumidor E, para os horizontes até $t-70$ o melhor desempenho é do HWMULT e para horizontes maiores o BENCHMARK. O método STLFARIMA apresenta melhor

desempenho para o consumidor F e no consumidor G há um desempenho muito similar entre STLFETS e STLFARIMA.

Os relevos, com detalhamento horário, permitem visualizar a variação dos erros ao longo do dia, para cada horizonte de previsão. Como esperado, observam-se erros maiores para horizontes mais distantes. O desempenho individual de cada método mostra-se dependente do horário, e observam-se muitos momentos em que o erro de um determinado método é alto em comparação ao erro de outro método no mesmo horário. Esta constatação fica bem caracterizada no horário de ponta para aqueles consumidores cuja demanda é nula neste horário.

Nesta discussão dos resultados deve ser observado, que os erros são percentuais médios, e a grandeza do erro é dependente da magnitude da demanda de cada consumidor. Por exemplo, um erro absoluto de previsão de 5 kW, é um erro de 33 % para um consumidor com demanda média de 15 kW. Para um consumidor com demandas de 300 kW, o mesmo erro absoluto representa um erro percentual de apenas 1,6%. Portanto é natural obter-se erros percentuais maiores para consumidores com demandas mais baixas.

A análise do mapeamento dos métodos com menor erro em função do horário e horizonte de previsão (Anexo A, figuras A.17 até A.25) fundamenta a necessidade de uma combinação de métodos para a previsão da demanda. Em todos os oito consumidores analisados há uma variação dos métodos com os quais se obtêm o menor erro, sendo esta variação função do horário e em menor grau também do horizonte de previsão. Predominam os métodos STLFETS e STLFARIMA (o código de cores permite esta visualização), porém há muitos momentos onde SARIMA, BENCHMARK e em menor número também a rede neural se destaca.

Além da análise do desempenho dos métodos em relação aos erros, o tempo de computação é de suma importância, visto que a operação deve ocorrer em tempo real. A cada nova medição da demanda pelo medidor, um novo conjunto de previsões é calculado. O tempo para calcular as previsões foi medido, e está listado na tabela 3.10. Trata-se do tempo necessário para calcular um conjunto de previsões (vetor com 24 valores, de 5 minutos até 120 minutos à frente). Estes tempos foram obtidos com processador Intel i5, com 4 núcleos a 3,1 Ghz. Uma ressalva importante é o método SARIMA, cujo modelo leva 6 minutos a ser montado (cálculo dos pesos). Usando o modelo pronto para a previsão, esta leva apenas 7 segundos. O modelo, portanto, não pode ser atualizado a cada iteração, sugere-se um novo modelo a cada 24 horas, sistemática adotada neste trabalho.

Método	Tempo de computação
DSHW	325ms
HWADD	207ms
HWMULT	212ms
NEURAL	1,75s
STLFETS	3,6s
STLFARIMA	941ms
SARIMA	6 minutos ¹ / 7s ²
BENCHMARK	9ms

1 - Tempo médio para montar o modelo e calcular um vetor de previsões
2 - Tempo apenas para calcular o vetor de previsões

Tabela 3.10: Tempos de computação médios necessários para calcular um vetor com as 24 previsões

3.3 Considerações finais do capítulo

Nenhum dos oito métodos aplicados neste capítulo mostrou ter desempenho superior para todos os consumidores. O desempenho de cada método é influenciado pela taxa de variação da demanda, que depende do horário. Pode-se afirmar que a probabilidade de um determinado método, dentre os oito analisados, ser o método cuja previsão retorne o menor erro, é variável ao longo do tempo. Através da análise dos gráficos notou-se também que o comportamento da curva dia após dia, faz com que ora um, ora outro método apresente o menor erro.

Quanto ao tempo de computação todos os métodos são passíveis de serem utilizados em tempo real, com exceção do método SARIMA, que pode ser utilizado mudando-se a sistemática, conforme explicado anteriormente.

A inexistência de um único método que supere os demais independentemente do horário e horizonte de previsão e também independente do tipo de consumidor, fundamenta a necessidade de propor uma metodologia de combinação.

4 COMBINAÇÃO SELETIVA PARA PREVISÃO DE DEMANDA EM CURTÍSSIMO PRAZO

No capítulo anterior oito métodos clássicos de previsão de demanda foram aplicados em oito consumidores de perfis diferentes, fornecendo um vetor de demandas futuras de cinco em cinco minutos, para duas horas. O processo de aquisição de dados e cálculo das previsões é realizado em tempo real, utilizando o histórico de demandas obtidas diretamente dos respectivos medidores.

A análise dos resultados evidenciou que nenhum dos métodos se destacou como sendo o melhor (menor erro), existindo também uma variabilidade de métodos quanto ao horizonte de previsão e em relação ao horário do dia. Há necessidade de uma abordagem diferenciada para a previsão de demandas de consumidores do tipo aqui utilizados.

Propõe-se neste capítulo várias formas de combinação de métodos, com o objetivo de reduzir o erro de previsão sob qualquer condição. A previsão é realizada em duas etapas distintas: na primeira etapa aplicam-se vários métodos de PDCP paralelamente, cada método produzindo seu conjunto de previsões. Na segunda etapa, utilizando uma das técnicas propostas, é produzida uma previsão final, derivada das previsões da primeira etapa.

Parte-se da premissa que não é conhecido o método que produzirá as previsões com menores erros, desta forma, as técnicas propostas têm como objetivo alcançar performance similar ou superior ao que seria alcançado se fosse conhecido este método único.

Para melhor entendimento a Figura 4.1 apresenta o fluxo proposto na PDCP.

4.1 Avaliação dos dos métodos de combinação propostos

O método mais simples para previsão de séries temporais é o método ingênuo (do inglês *naive*). Nele o valor futuro da série é igual ao último valor conforme segue:

$$y_{t+k} = y_t \quad (4.1)$$

onde y é o valor da série temporal, e k o número de passos à frente na previsão.

Em séries com sazonalidade, como é o presente caso, este método apresenta a desvantagem que para qualquer k , a previsão sempre é igual. Por exemplo, se a última demanda medida for 50 kW ($y_t = 50$), a previsão da demanda para 5 minutos (y_{t+5}) ou para 60 minutos (y_{t+60})

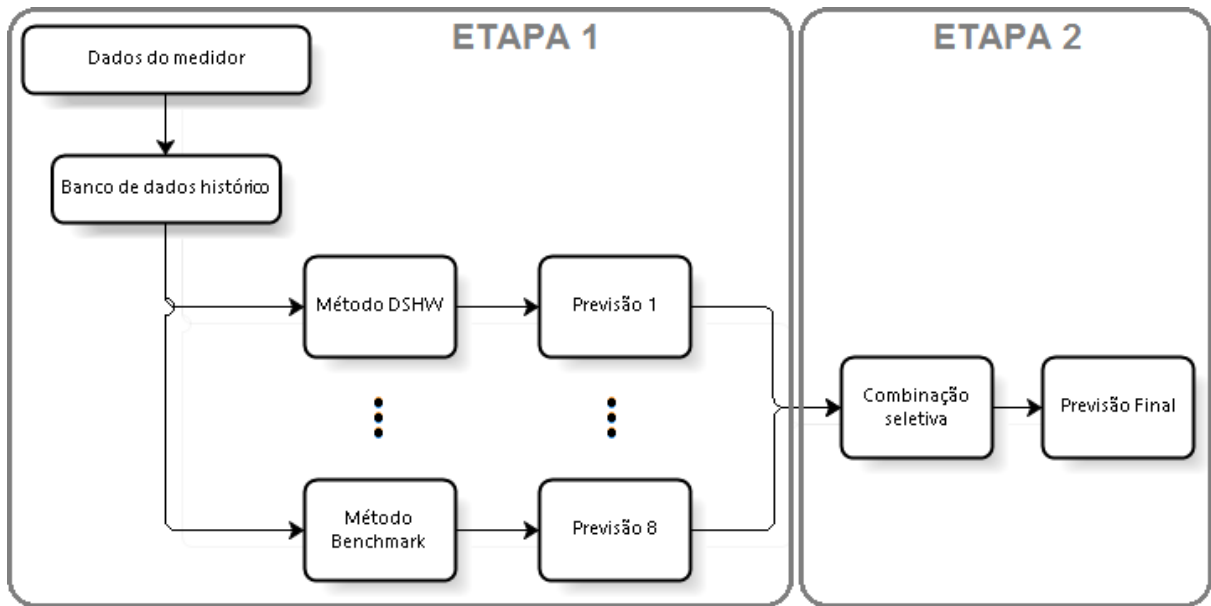


Figura 4.1: Detalhamento das etapas na previsão de demanda proposta

será a mesma.

No capítulo 3, seção 3.2.2, é introduzido o método ingênuo sazonal, identificado neste trabalho de BENCHMARK. Todavia o método BENCHMARK, sendo a média dos dez últimos valores da série no mesmo horário, suaviza eventuais flutuações abruptas. Se, por exemplo, há um súbito incremento ou decremento substancial na demanda, o BENCHMARK não detectará o fato.

Com isto, decidiu-se utilizar além do BENCHMARK também o método ingênuo normal (Naive) para avaliação dos métodos propostos. Os métodos de avaliação inclusive fazem parte da previsão em si, como é visto a seguir.

Um terceiro método de avaliação utilizado é a média simples de todas as previsões, incluindo do BENCHMARK. Na seção 2.2 observa-se que a média simples entre as previsões em muitos casos analisados na bibliografia resultou em menores erros médios do que os erros de cada método individualmente. Este erro, se revelou menor, em média, do que sofisticados métodos de combinação.

O método, chamado doravante de AVG (do inglês *average*, ou seja média) é a média simples entre os oito métodos de previsão.

$$AVG = \frac{(M1+M2+M3+M4+M5+M6+M7+M8)}{8} \quad (4.2)$$

Onde M1=DSHW, M2=HWADD, M3=HWMULT, M3=STLFETS, M5=STLFARIMA, M6=NEURAL, M7=SARIMA e M8=BENCHMARK.

Como a cada 5 minutos são feitas 24 previsões, para as demandas futuras de 5 a 120 minutos, calcula-se também 24 médias do conjunto de previsores a cada 5 minutos. Esta tarefa o programa realiza imediatamente após obter as previsões individuais.

4.2 Métodos de combinação propostos nesta tese

A seguir são descritos os cinco métodos propostos para seleção e/ou combinação de métodos.

4.2.1 Seleção do método com menor erro anterior

Supondo que em um processo contínuo de previsão de demanda, existem N métodos de previsão, fazendo a previsão para vários horizontes, iniciando em $t + p$ até $t + kp$, onde k é o número de passos à frente e p são os minutos de espaçamento entre os passos. Desta forma, a cada passo de previsão, são gerados k vetores com N previsores cada (um vetor por horizonte):

Para o horizonte $t + p$: $\overline{S}_{t+p}N$
 Para o horizonte $t + 2p$: $\overline{S}_{t+2p}N$
 \vdots \vdots
 Para o horizonte $t + kp$: $\overline{S}_{t+kp}N$

No momento t , a demanda do momento anterior $t - p$ já é conhecida, permitindo calcular o erro absoluto ϵ_t para todos os previsores e de todos os horizontes focados no momento $t - p$, conforme equação (4.3), obtendo um vetor de erros absolutos:

$$\epsilon_t N = ABS(D_t - \overline{S}_{tN}) \quad (4.3)$$

Cada horizonte de previsão tem o seu vetor de erros, visto que para o momento $t - p$ estão disponíveis as previsões de $t - 2p$ até $t - kp$ passos atrás. Com base no menor erro, dentro dos vetores de erros $\epsilon_t N$, é escolhido o método considerado o previsor válido para o respectivo horizonte. Doravante este método é chamado de SELECT. Na tabela 4.1 há um exemplo real para um horizonte de previsão de 60 minutos.

DSHW	HWADD	HWMULT	STLFETS	STLFARIMA	NEURAL	SARIMA	BENCH	AVG
Previsão feita às 17:50h para as demandas das 18:50h								
69	57	66	65	65	68	69	71	66
Erros calculados as 18:50h entre a demanda real e as previsões das 17:50h								
2	14	5	6	6	3	2	0	5
Previsão feita às 18:50h para as demandas das 19:50h								
50	44	51	54	54	52	61	52	52

Tabela 4.1: Processo SELECT para uma previsão com horizonte de 60 minutos. Os círculos indicam o menor erro e a demanda selecionada correspondente para as 19:50h

4.2.2 Média seletiva - critério menor erro anterior

O método da média seletiva, é uma conjugação das vantagens da média simples da equação (4.2), com a seleção do método com o menor erro anterior da seção 4.2.1. Ao invés de incluir todos os previsores na média, apenas três previsores são incluídos, escolhidos dentre aqueles que apresentaram o menor erro absoluto no passo anterior.

Tomando o vetor de erros conforme equação (4.3), dentro dele são selecionados os três menores valores e identificados os métodos que os geraram. No processo de previsão é feita a média dos três métodos escolhidos, sendo esta média a previsão da demanda.

Este método doravante é identificado pelo nome AVG2. Para cada horizonte de previsão é feita a média, não necessariamente com os mesmos métodos. Na tabela 4.2 é exemplificado o processo de escolha e cálculo da média, utilizando os mesmos dados do exemplo da seção 4.2.1.

DSHW	HWADD	HWMULT	STLFETS	STLFARIMA	NEURAL	SARIMA	BENCH	AVG
Previsão feita às 17:50h para as demandas das 18:50h								
69	57	66	65	65	68	69	71	66
Erros calculados as 18:50h entre a demanda real e as previsões das 17:50h								
2	14	5	6	6	3	2	0	5
Previsão feita às 18:50h para as demandas das 19:50h								
50	44	51	54	54	52	61	52	52
A demanda prevista para as 19:50, é a média de 50,61 e 52 = 54								

Tabela 4.2: Processo de média seletiva AVG2 para uma previsão com horizonte de 60 minutos. Os círculos indicam o menor erro e as demandas selecionadas para cálculo da média, que é a previsão para 19:50h.

4.2.3 Seleção do método com menor erro médio em passado recente

O método de proposto na seção 4.2.1 apresenta a desvantagem de absorver eventuais flutuações entre um passo e outro gerando altos erros pontuais. Isto porque determina que o método escolhido para a próxima previsão será o método que na previsão anterior foi o melhor. Se a previsão anterior foi em um momento atípico que por si só terá a tendência de um maior erro, transfere para a próxima previsão uma tendência de erro acima da média também.

Como proposta de suavização, uma alternativa é basear a seleção, em uma janela móvel dos erros médios absolutos de cada método. Novamente de forma arbitrária determinou-se uma janela contendo as 288 últimas previsões (um dia inteiro), ou seja, utiliza-se como critério de seleção a média dos 288 últimos erros de cada método, para cada horizonte de previsão. O método que apresenta, dentro da janela, a menor média dos erros é o método adotado para a previsão final. Este método doravante é chamado de SELECT2. A tabela 4.3 exemplifica o processo utilizando os mesmos dados dos exemplos anteriores. Por questões de espaço, neste exemplo, utiliza-se apenas a média de 12 previsões passadas ao invés de 288 como proposto. Casualmente o resultado de SELECT2 foi o mesmo do método SELECT o que não é regra.

DSHW	HWADD	HWMULT	STLFETS	STLFARIMA	NEURAL	SARIMA	BENCH	AVG
Erros calculados das 17:55h até 18:50h entre a demanda real e as previsões das 16:55 às 17:50h								
15	7	3	5	4	3	8	2	3
8	16	4	9	11	0	0	4	7
4	18	5	9	10	2	10	1	4
18	22	4	4	8	7	21	8	4
15	22	7	6	9	9	14	5	1
1	21	8	5	8	5	12	2	3
3	22	10	8	11	3	3	2	8
5	20	4	3	3	3	15	5	2
3	18	4	4	4	8	14	4	1
1	13	3	3	3	6	7	5	1
2	15	5	6	6	3	3	2	5
2	14	5	6	6	3	2	0	5
Erros médios das 12 últimas previsões - posição 18:50h								
6,42	17,33	5,17	5,67	6,92	4,33	9,08	3,33	3,67
Previsão feita às 18:50h para as demandas das 19:50h								
50	44	51	54	54	52	61	52	52

Tabela 4.3: Demonstração do processo de seleção a partir do menor erro médio para uma previsão com horizonte de 60 minutos. As caixas indicam o menor erro médio e o predictor selecionado para as 19:50h.

4.2.4 Regressão linear seletiva

Em um processo de previsão de demanda com múltiplos métodos (N métodos), como é o presente caso, para cada demanda D_t a ser prevista, tem-se um vetor de N previsões $\bar{S}_t = (S_{1t}, \dots, S_{Nt})$. Multiplicando-se cada previsão por uma constante w , forma-se um vetor de pesos $w = (w_1, \dots, w_N)$. Se o valor de todos os pesos for igual a $\frac{1}{N}$, uma simples média é calculada. Na proposta de regressão linear seletiva, a meta é encontrar um vetor de pesos w que seja uma combinação linear ótima para formar uma nova previsão, mais precisa: $\bar{S}_t = wS_t$. Os pesos w devem ser tais que minimizem o erro $\epsilon = (S_t - \bar{S}_t)$. Granger et al. (1984) propõe três variantes de regressão linear conforme equações (4.4), (4.5) e (4.6):

$$\bar{S}_t = wS_t + u_t \quad \text{com restrição que } \sum_{j=1}^N w_j = 1 \quad (4.4)$$

$$\bar{S}_t = wS_t + u_t \quad \text{sem restrições aos pesos} \quad (4.5)$$

$$\bar{S}_t = \alpha + wS_t + u_t \quad (4.6)$$

Aplicações práticas com grande quantidade de dados revelaram que a formulação (4.6) apresenta os menores erros (HSIAO; WAN, 2014). A forma natural da regressão utilizando os métodos disponíveis é:

$$D_{t+k} = I + w_1 DSHW_k + w_2 HWADD_k + w_3 HWMULT_k + w_4 STLFETS_k + w_5 STLFARIMA_k + w_6 NEURAL_k + w_7 SARIMA_k + w_8 BENCHMARK_k$$

Onde k é o número de passos à frente na previsão. Para dados de 5 em 5 minutos, $k = 1$ para a previsão 5 minutos à frente. Previsão para 10 minutos $k = 2$ e assim sucessivamente, até $k = 24$, duas horas à frente. Para cada horizonte de previsão é necessário fazer uma regressão utilizando-se os previsores prévios gravados para o horizonte em questão (daí $DSHW_k$, etc.). A constante I é o intercepto (ordenada na origem).

Testes prévios realizados com os dados, retornaram erros de previsão muito elevados. Desta forma, propõe-se uma alternativa para seleção prévia dos vetores com os quais será feita a regressão.

Reutilizando as médias dos erros absolutos de cada método nos 288 períodos anteriores apurados na proposta da seção 4.2.3, escolhem-se os três métodos que apresentam o menor erro médio, utilizando-se estes para a regressão linear, em uma minimização de erro.

O equacionamento proposto neste método é:

$$D_{t+k} = I + w_1 Met1_k + w_2 Met2_k + w_3 Met3_k \quad (4.7)$$

Onde $Met1$, $Met2$ e $Met3$ são respectivamente as demandas estimadas pelos três métodos que apresentaram o menor erro médio absoluto num universo de 288 previsões anteriores. Os pesos w_1, w_2, w_3 retornados pelo processo de regressão, além da ordenada na origem, são aplicados às previsões do momento t produzindo-se uma combinação de previsões dos três métodos em questão.

Este método de regressão seletiva doravante é chamado de REG2. A tabela 4.4 exemplifica o processo, porém utilizando apenas a média das 12 últimas previsões, por questões de espaço.

DSHW	HWADD	HWMULT	STLFETS	STLFARIMA	NEURAL	SARIMA	BENCH	AVG
Erros calculados das 17:55h até 18:50h entre a demanda real e as previsões das 16:55 às 17:50h								
15	7	3	5	4	3	8	2	3
8	16	4	9	11	0	0	4	7
4	18	5	9	10	2	10	1	4
18	22	4	4	8	7	21	8	4
15	22	7	6	9	9	14	5	1
1	21	8	5	8	5	12	2	3
3	22	10	8	11	3	3	2	8
5	20	4	3	3	3	15	5	2
3	18	4	4	4	8	14	4	1
1	13	3	3	3	6	7	5	1
2	15	5	6	6	3	3	2	5
2	14	5	6	6	3	2	0	5
Erros médios das 12 últimas previsões - posição 18:50h								
6,42	17,33	5,17	5,67	6,92	4,33	9,08	3,33	3,67
Previsão feita às 18:50h para as demandas das 19:50h								
50	44	51	54	54	52	61	52	52
O previsor para a demanda das 19:50, através da regressão seletiva será então:								
$D = i + w_1 * 52 + w_2 * 52 + w_3 * 52$								

Tabela 4.4: Processo de regressão seletiva (REG2) feita com das previsões dos três métodos com menor erro médio nos 12 períodos anteriores, para uma previsão com horizonte de 60 minutos. As caixas indicam os métodos com menor erro utilizados na regressão, e as demandas da previsão para as 19:50 que foram combinadas.

4.2.5 Média seletiva - critério menor média de erros anterior

Na seção 4.2.2 foi proposta uma média seletiva, cujo critério é a utilização dos três previsores com menor erro no passo anterior. Ao invés de utilizar como critério apenas os erros

do passo anterior, propõe-se uma alternativa mais abrangente: o critério de seleção dos métodos a serem combinados passa a ser a média dos erros. Utiliza-se uma janela móvel para cada método, e calcula-se a média dos erros.

Neste método, chamado doravante de AVG3, a previsão válida é uma média de três previsões, tendo como critério de escolha aquelas cujos erros médios nas 288 previsões anteriores foram os menores. A janela de 288 previsões passadas foi determinada de forma arbitrária (288 passos representam um dia, se espaçados de 5 em 5 minutos como é o presente caso).

A tabela 4.5 exemplifica o método, utilizando novamente os mesmos dados já utilizados nos exemplos anteriores, porém com apenas 12 previsões anteriores.

DSHW	HWADD	HWMULT	STLFETS	STLFARIMA	NEURAL	SARIMA	BENCH	AVG
Erros calculados das 17:55h até 18:50h entre a demanda real e as previsões das 16:55 às 17:50h								
15	7	3	5	4	3	8	2	3
8	16	4	9	11	0	0	4	7
4	18	5	9	10	2	10	1	4
18	22	4	4	8	7	21	8	4
15	22	7	6	9	9	14	5	1
1	21	8	5	8	5	12	2	3
3	22	10	8	11	3	3	2	8
5	20	4	3	3	3	15	5	2
3	18	4	4	4	8	14	4	1
1	13	3	3	3	6	7	5	1
2	15	5	6	6	3	3	2	5
2	14	5	6	6	3	2	0	5
Erros médios das 12 últimas previsões - posição 18:50h								
6,42	17,33	5,17	5,67	6,92	4,33	9,08	3,33	3,67
Previsão feita às 18:50h para as demandas das 19:50h								
50	44	51	54	54	52	61	52	52
O predictor para a demanda das 19:50, através da média seletiva será então:								
$D = (52 + 52 + 52)/3$								= 52

Tabela 4.5: Processo de média seletiva (AVG3) feita com das previsões dos três métodos com menor erro médio nos 12 períodos anteriores, para uma previsão com horizonte de 60 minutos. As caixas indicam os métodos com menor erro utilizados na média, e as demandas da previsão para as 19:50h que foram combinadas.

4.3 Resultados na aplicação dos métodos propostos

De forma similar ao capítulo anterior, nesta seção os resultados para o consumidor E (posto de gasolina) são analisados com maior profundidade, enquanto os gráficos e tabelas dos demais consumidores podem ser consultados no Anexo B.

A previsão da demanda em curtíssimo prazo, conforme proposto, é realizada em duas

etapas: na primeira etapa (etapa de previsão) aplicam-se paralelamente os oito métodos explicados no capítulo anterior. Em uma segunda etapa (etapa de combinação), aplicam-se os cinco métodos de combinação propostos, tendo como critérios de seleção o erro do passo anterior (ou erros dos passos anteriores, dependendo do método utilizado). O fluxo do processo proposto está na figura 4.2

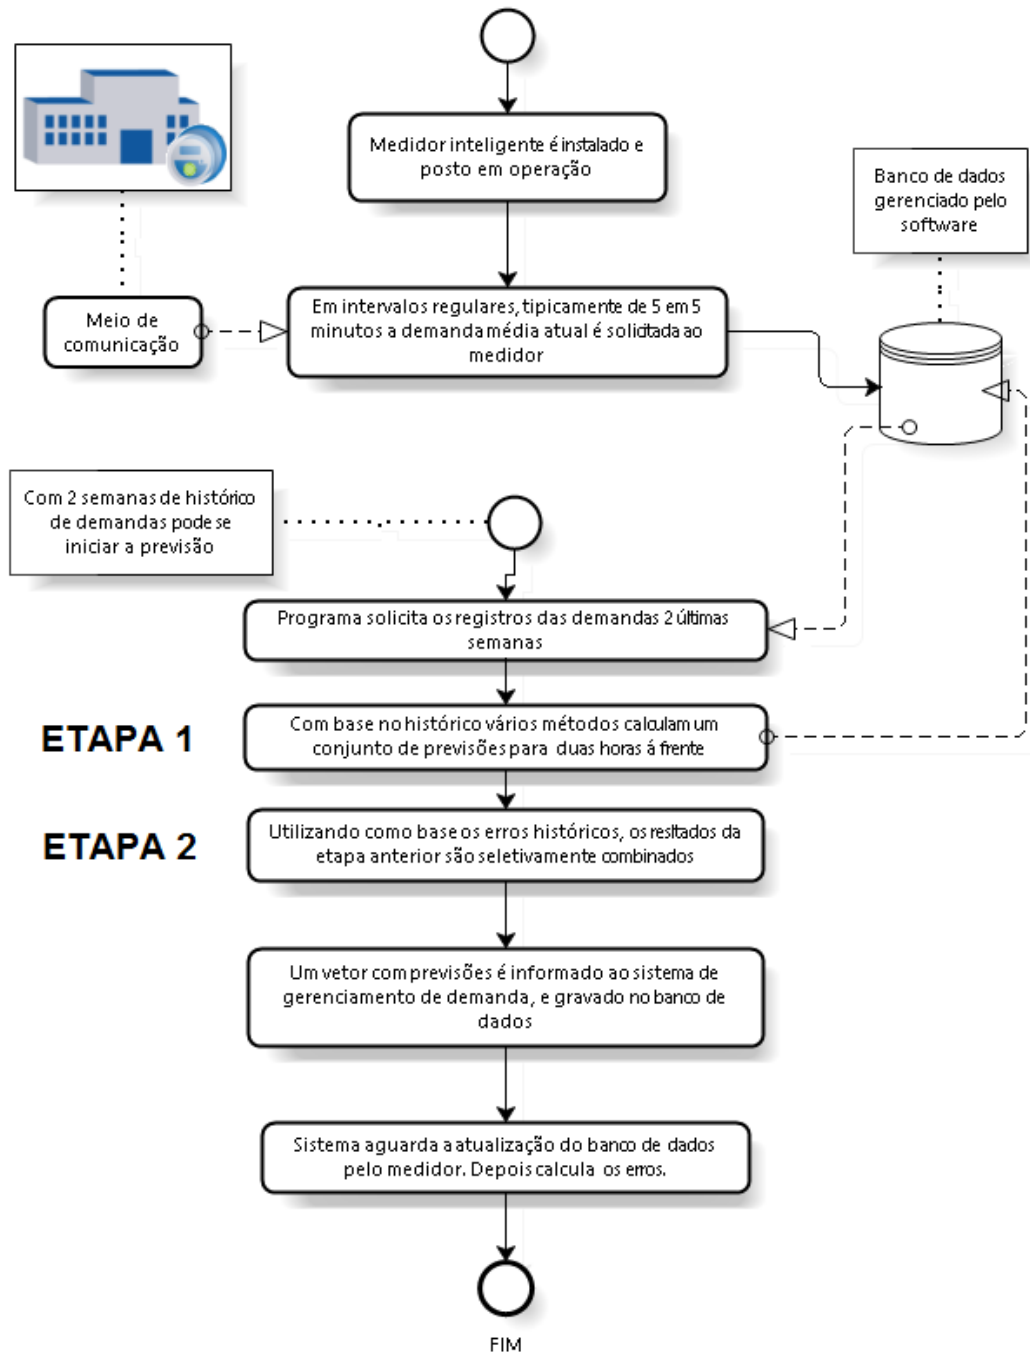


Figura 4.2: Fluxo lógico da previsão de demanda em duas etapas, com combinação seletiva na segunda etapa.

Os resultados aqui apresentados têm como objetivo comparar os cinco métodos de com-

binação. Como será visto a seguir, especialmente os métodos de média seletiva são promissores e mais adequados ao tipo de consumidor, característica das curvas e tipo de previsão em foco neste trabalho.

No capítulo anterior observou-se que nenhum método isoladamente, consegue fornecer os menores erros para todos os horizontes e para em todos os momentos. Os gráficos e tabelas do Anexo A fornecem os números que fundamentam esta afirmação.

Se fosse possível saber, antes da aplicação dos oito métodos da primeira etapa, qual método teria a menor erro médio global (média do MAPE para todos os horizontes), os escolhidos seriam os métodos conforme tabela 4.6.

Consumidor	Método	Erro médio global
A1	HWMULT	12,20%
A2	SARIMA	8,20%
B	STLFARIMA	44,10%
C	SARIMA	25,30%
D	BENCHMARK	25,60%
E	HWMULT	13,30%
F	STLFARIMA	30,50%
G	STLFARIMA	15,60%

Tabela 4.6: Métodos, por consumidor, que apresentam o menor erro global.

Os métodos desta tabela, em conjunto com o método ingênuo e a média simples (AVG) são usados para fins avaliativos dos cinco métodos da etapa de combinação. No caso do consumidor E, o melhor método da etapa de previsão é o método HWMULT, cujos erros por horizonte juntamente com os demais métodos da etapa de combinação estão plotados no gráfico da figura 4.3, que é resultado dos dados da tabela 4.7.




Figura 4.3: Consumidor E: Erros percentuais dos métodos de combinação em comparação aos métodos de avaliação.

Os resultados dos demais consumidores e seus respectivos gráficos estão no Anexo B, tabelas B.1 até B.8 e figuras B.1 até B.8.

Observando os gráficos em conjunto com os dados do Anexo B, nota-se que os métodos SELECT2, AVG2 e AVG3 são os métodos que apresentam os melhores resultados. A tabela 4.8 apresenta um comparativo do MAPE entre o melhor método individual (média de todos os erros, em todos os horizontes) com o MAPE dos três melhores métodos da etapa de combinação. Em todos os consumidores o método AVG3 tem o melhor resultado na etapa de combinação. Observa-se que para quatro consumidores (A1, A2, B e G) o método AVG3 traz um ganho na precisão. Os consumidores para os quais o método AVG3 não é o melhor no âmbito geral são exatamente aqueles que não apresentam as menores (ou nenhuma) demanda no horário de ponta.

Uma análise mais detalhada do comportamento dos métodos é obtida através dos gráficos dos erros absolutos médios. Nas figuras 4.4 e 4.4 estão respectivamente os resultados para previsões feitas 30 e 60 minutos antes da medida. Nota-se que o método AVG3 apresenta o menor erro absoluto, exceto no horário de ponta, onde a demanda real é de 1 kW. O erro absoluto médio entre 0 e 1 indica que o método ficou indeciso entre prever 1 kW ou 0 kW (em determinados momentos do horário de ponta previu zero, em outros um), o que pode ter como

HWMULT	AVG	SELECT	AVG2	SELECT2	REG2	AVG3	Ingênuo
10,5%	21,9%	12,8%	10,8%	11,7%	12,7%	11,5%	14,6%
11,4%	23,3%	15,4%	12,4%	13,0%	18,2%	12,8%	23,0%
11,6%	23,6%	15,6%	12,9%	13,8%	19,0%	13,2%	29,5%
12,0%	23,9%	16,1%	13,4%	14,0%	18,5%	14,5%	36,7%
12,3%	24,4%	16,7%	13,8%	15,4%	18,0%	15,1%	43,4%
12,5%	24,8%	18,1%	14,6%	16,0%	18,5%	15,8%	50,6%
12,9%	25,6%	19,2%	15,9%	17,3%	18,6%	16,4%	58,3%
13,1%	26,0%	19,8%	16,9%	17,6%	18,4%	16,9%	66,2%
13,2%	26,4%	20,0%	18,5%	16,6%	18,3%	17,0%	73,6%
13,4%	27,0%	20,2%	21,9%	18,3%	19,0%	18,0%	81,0%
13,5%	27,3%	22,3%	26,4%	17,7%	19,5%	17,8%	88,0%
13,5%	27,5%	22,2%	29,9%	19,9%	20,0%	18,5%	95,3%
13,5%	28,0%	21,2%	32,9%	20,4%	19,2%	18,2%	101,9%
13,7%	28,6%	23,7%	36,7%	20,4%	19,3%	18,9%	108,9%
13,8%	28,5%	23,9%	39,5%	21,2%	20,3%	19,2%	115,9%
13,9%	28,9%	23,8%	41,6%	21,5%	20,5%	20,0%	122,2%
14,0%	29,3%	25,3%	44,7%	21,7%	19,8%	19,7%	128,8%
14,1%	29,4%	26,1%	48,4%	21,4%	20,8%	20,3%	135,8%
14,3%	29,2%	26,5%	49,1%	22,1%	20,4%	19,5%	142,6%
14,4%	29,3%	28,1%	49,1%	21,5%	19,6%	19,9%	149,2%
14,6%	29,0%	27,7%	47,6%	21,9%	19,8%	20,0%	155,2%
14,7%	29,0%	28,6%	45,4%	22,1%	19,8%	19,6%	161,1%
14,7%	29,0%	28,5%	44,1%	21,2%	20,0%	19,8%	167,0%
14,9%	29,5%	29,8%	42,5%	20,9%	20,5%	20,5%	173,1%

Tabela 4.7: Consumidor E: Erros percentuais médios da etapa de combinação e métodos de avaliação.

Consumidor	Erros médios (em %)			
	Etapa previsão Melhor	Etapa combinação		
		AVG2	SELECT2	AVG3
A1	12,2%	11,0%	11,2%	10,3%
A2	8,2%	7,9%	7,2%	7,0%
B	44,1%	196,0%	47,7%	44,3%
C	25,3%	32,7%	30,6%	28,7%
D	25,6%	50,8%	32,0%	31,8%
E	13,3%	30,4%	18,6%	17,6%
F	30,5%	32,6%	35,0%	34,8%
G	15,6%	15,4%	15,7%	14,5%

Tabela 4.8: Comparativo entre o MAPE do melhor método isolado e dos três melhores métodos de combinação.

resultado um erro percentual de 100%, tendo como consequência a distorção do erro percentual.




Figura 4.4: Consumidor E: Comparação dos erros absolutos em função do horário para horizonte 30 minutos.

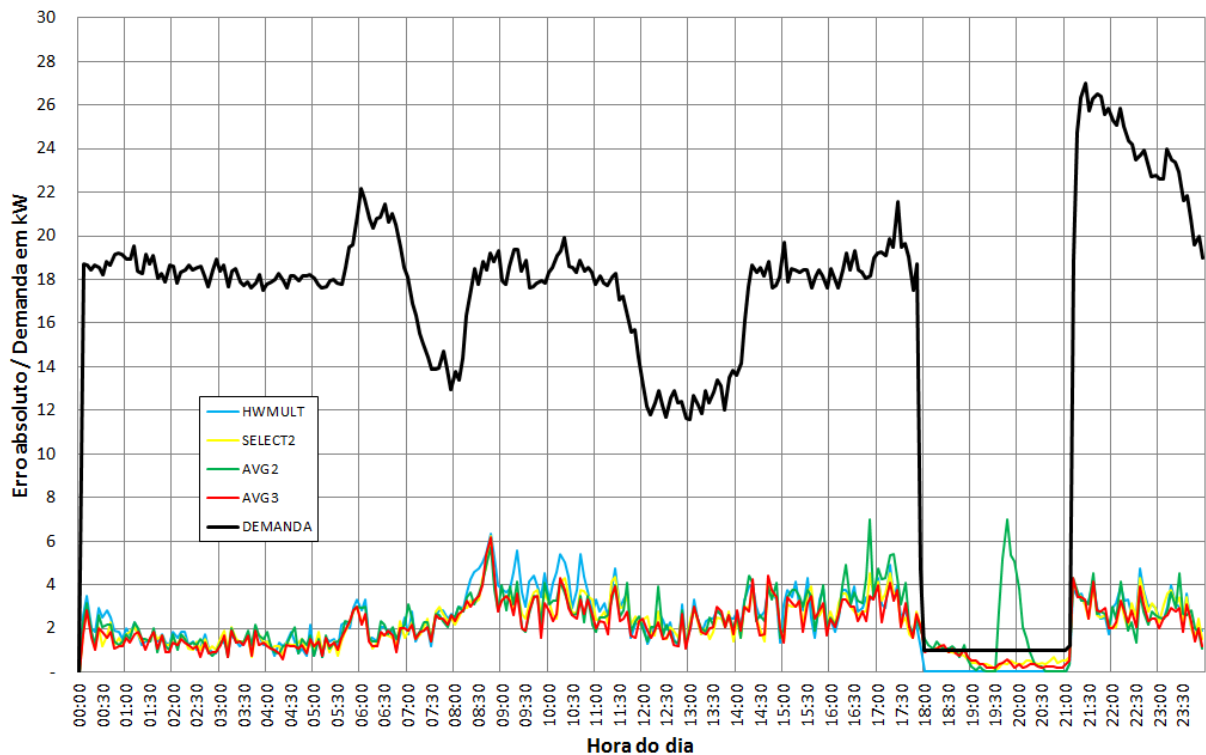


Figura 4.5: Consumidor E: Comparação dos erros absolutos em função do horário para horizonte 60 minutos.

A análise de erros percentuais é útil na comparação de resultados entre diferentes consumidores, com demandas em escalas diferentes. Para avaliar a qualidade da previsão a análise dos erros absolutos é uma ferramenta mais adequada, pois elimina-se a distorção dos erros percentuais em momentos de demanda muito baixa. A tabela 4.9 compara os erros absolutos (média de todos horizontes em todo conjunto de dados) do melhor método da etapa de previsão, com os três melhores métodos da etapa de combinação. O método AVG3 se destaca por erros iguais ou menores em todos consumidores, com exceção do consumidor F.

Consumidor	Erros absolutos médios (em kW)			
	Etapa previsão Melhor	Etapa combinação		
		AVG2	SELECT2	AVG3
A1	9,50	8,20	8,80	7,70
A2	4,90	5,00	4,40	4,40
B	5,50	7,10	6,00	5,50
C	10,00	10,20	8,90	8,50
D	4,50	5,90	5,20	4,60
E	2,30	2,30	2,10	2,00
F	27,20	32,70	32,50	31,90
G	177,00	185,20	182,90	171,20

Tabela 4.9: Comparação dos erros absolutos médios do melhor método isolado e dos três melhores métodos de combinação.

4.3.1 Aplicação do método proposto em consumidores adicionais

Aplicou-se a combinação seletiva de métodos para previsão de demanda a curtíssimo prazo adicionalmente em quatro consumidores: Dois consumidores do segmento comercial e dois consumidores do segmento industrial. O objetivo é ampliar o número de perfis de consumidores, abrangendo os mais diversos comportamentos da curva de carga: estabilidade da curva, presença ou não de cargas à noite, intervalos, períodos com cargas próximo de zero, interrupções repentinas, etc.. Os detalhes estão na tabela 4.10 e as respectivas curvas das demandas diárias nas figuras 4.6 até 4.9.

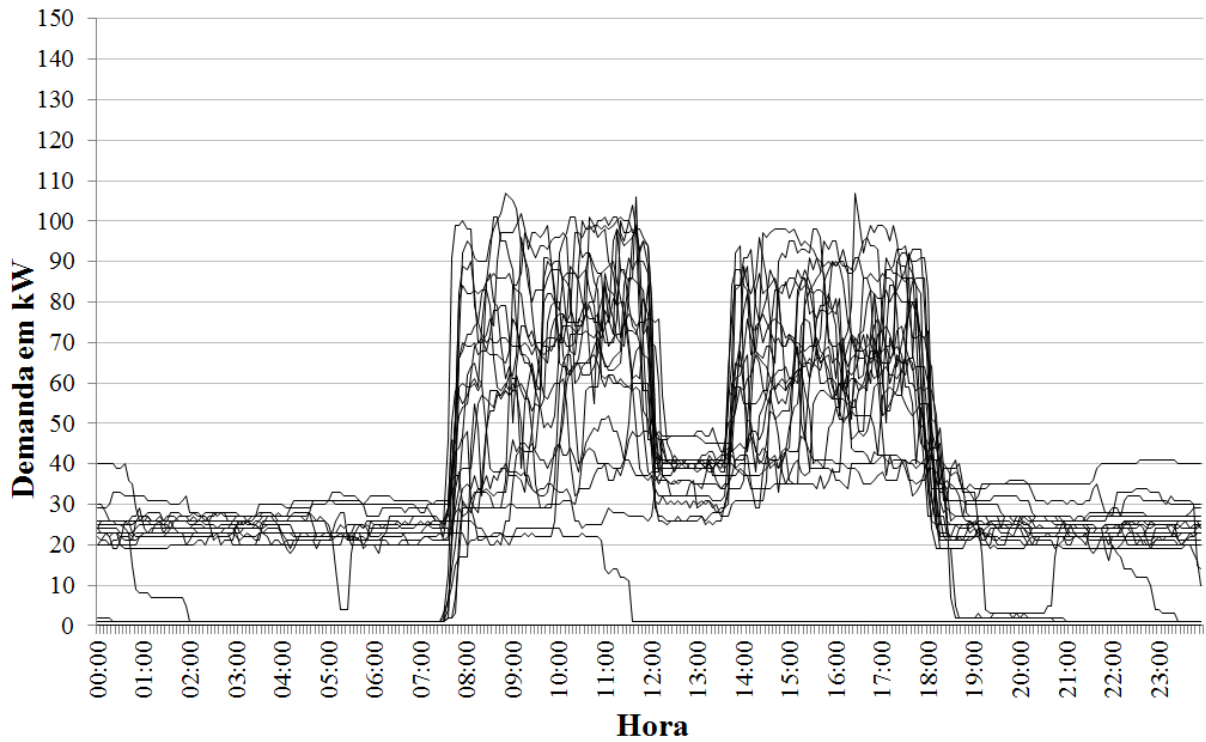


Figura 4.6: Demandas do consumidor V entre 6 de abril e 6 de maio de 2009.




Figura 4.7: Demandas do consumidor W entre 2 de março de 9 de abril de 2014.




Figura 4.8: Demandas do consumidor X entre 2 de fevereiro e 3 março de 2009.

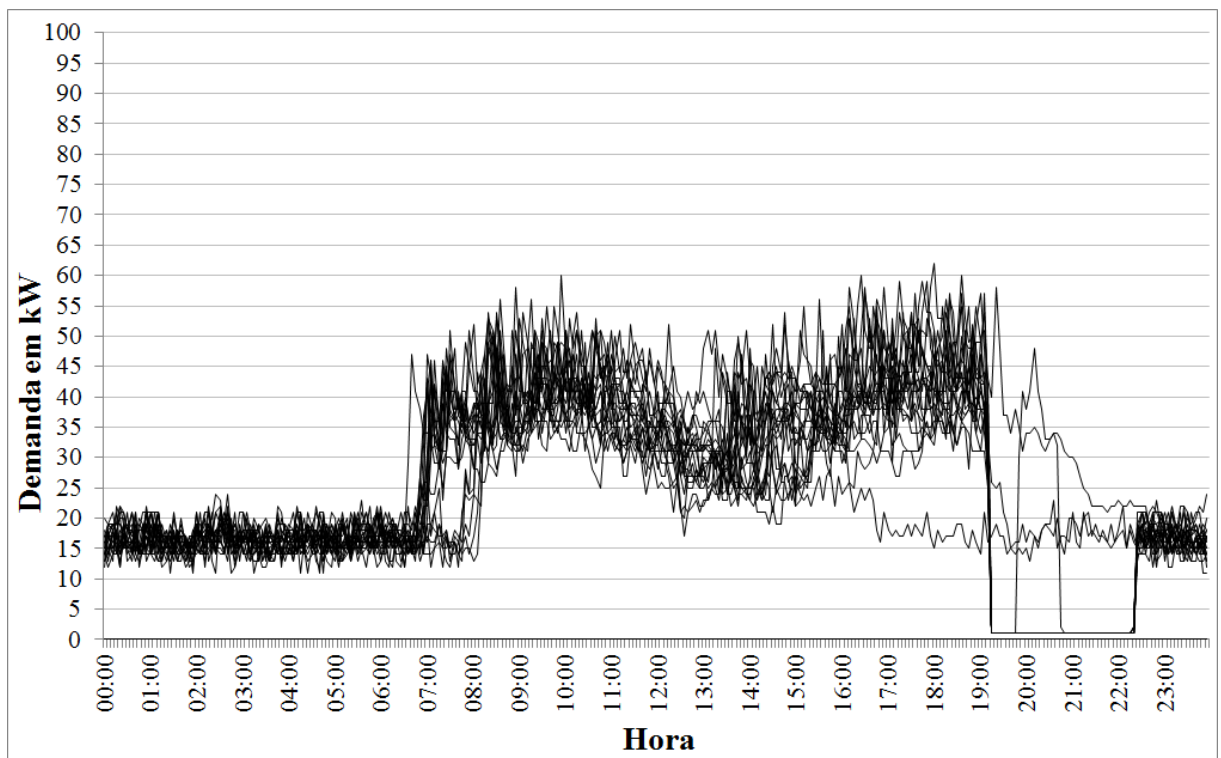


Figura 4.9: Demandas do consumidor Y entre 14 de janeiro e 13 de fevereiro de 2009.

Id	Tipo de consumidor	Potência da subestação	Demanda máxima	Período	Curva Figura
V	Fábrica de ração	150 kVA	118 kW	06/04 a 06/05/2009	4.6
W	Frigorífico	150 kVA	82 kW	12/03 a 09/04/2014	4.7
X	Centro de compras	225 kVA	128 kW	02/02 a 03/03/2009	4.8
Y	Comércio varejo	225 kVA	62 kW	14/01 a 13/02/2009	4.9

Tabela 4.10: Resumo dos consumidores adicionais.

A tabela 4.11 resume os erros absolutos dos consumidores adicionais, solidificando a eficácia do método de combinação AVG3.

Consumidor	Erros absolutos médios (em kW)			
	Etapa previsão Melhor (método)	Etapa combinação		
		AVG2	SELECT2	AVG3
V	10,0(STLFARIMA)	9,90	10,50	9,80
W	5,8 (STLFARIMA)	7,70	5,90	5,90
X	8,1 (SARIMA)	8,20	8,70	7,90
Y	3,7 (STLFARIMA)	3,60	3,80	3,50

Tabela 4.11: Comparação dos erros absolutos médios do melhor método isolado e dos três melhores métodos de combinação.

4.4 Discussão dos resultados

Para uma interpretação adequada dos resultados, deve-se observar o funcionamento prático do método de previsão proposto. Lembrando que, ao iniciar o processo de previsão para um determinado consumidor, apenas um curto histórico é conhecido, não sendo possível determinar qual método clássico vai fornecer a previsão mais precisa. Nesta tese se delimitou o histórico em duas semanas

Ao realizar a previsão em duas etapas, usando os erros históricos como critério para seleção da combinação, três métodos se destacam, a saber: AVG2, SELECT2 e AVG3. Entre estes o AVG3 se diferencia como o melhor no conjunto dos horizontes de previsão.

Para consumidores cuja carga é desligada, ou assumida por um gerador interno, durante o horário de ponta, o melhor método da primeira etapa (antes da combinação) tende a ser mais preciso (em termos de erro percentual) do que os métodos de combinação. Este fato se deve à influência da magnitude da demanda sobre o erro percentual como foi explicado na seção 3.1.3.

Em função dos erros percentuais altos em momentos de baixa demanda, analisou-se o comportamento do erro absoluto (diferença entre kW previstos e kW medidos). Em campo, o erro absoluto é mais adequado estando diretamente associado ao custo, pois um sistema de gerenciamento de demanda tem como meta a redução de custos.

A aplicação dos cinco métodos de combinação seletiva propostos apontou o método da média seletiva (AVG3) como sendo o mais eficaz na captura as melhores previsões da primeira etapa, apresentando um erro de previsão absoluto igual ou menor do que o melhor método individual.

5 CONCLUSÃO

O presente trabalho trata da previsão de demanda em curtíssimo prazo, em consumidores onde não há histórico de demanda disponível, e cujo perfil de demandas é típico para pequenas e médias indústrias, comércios e instalações públicas.

Como exigência adicional, a previsão precisa estar disponível em tempo real, usando como dados de entrada as demandas medidas por um medidor inteligente. É uma situação típica, que futuramente será encontrada em campo, onde consumidores novos, ou outros com intenção de migrar para tarifas diferentes, necessitarão de uma previsão em tempo real, para fins de gerenciamento da demanda.

Existem inúmeros métodos de previsão de demanda, porém, nenhum dos métodos apresentados na bibliografia em estudos anteriores, comprovou-se eficaz e preciso para um amplo universo de consumidores. No capítulo 3, utilizando dados de consumidores de variados perfis e com demandas de 10 kW até cerca 2.000 kW evidenciou-se este fato. Comprovou-se também, que com o uso da linguagem R e das funções disponíveis, a previsão em tempo real pode ser realizada.

Indica-se através do presente trabalho, uma potencial solução e um direcionamento das pesquisas para um método de previsão geral, que pode ser utilizado na rede elétrica inteligente em consumidores do perfil citado.

5.1 Considerações finais

Consumidores do perfil analisado neste trabalho possuem curvas de carga que apresentam fortes oscilações ao longo do dia e uma não repetibilidade da curva dia após dia. Apresentam também períodos com demanda muito baixa, como ocorre no horário de ponta por exemplo, e interrupções na curva causados pelos mais variados motivos. Portanto, este tipo de consumidor possui uma baixa previsibilidade de sua demanda, dificultando a escolha de um único método de previsão como o mais adequado para todos consumidores.

Dentre dos vários métodos que podem ser utilizados em tempo real, a performance de cada um depende do perfil do consumidor, do horário e dia da semana, entre outros. A dificuldade é ainda maior se o histórico de demandas disponível para análise é curto (menor que um mês), como é o caso em consumidores novos.

Na existência de um histórico maior (acima de um mês), há a possibilidade de escolher

um método através da tentativa e erro, na análise da curva da demanda do consumidor. Porém, mesmo uma vez definido o método, um software predictor necessita ser configurado para atender às condições particulares de cada consumidor.

Como solução, o presente trabalho propõe que, nestes casos, devem ser utilizados vários métodos em paralelo, devendo estes apresentar três características: usar como variável de entrada apenas as demandas históricas, ter velocidade suficiente para uso em tempo real e não necessitar de um longo histórico para treinamento. Os resultados, continuamente fornecidos pelos métodos atuando em paralelo, passam a ser as variáveis de entrada para um método que denominou-se de Combinação Seletiva.

Dentre os métodos de combinação seletiva propostos e avaliados, três destacaram-se apresentando os menores erros: AVG2, SELECT2 e AVG3. Destes três, o método de média seletiva AVG3, é o método que apresenta os menores erros no conjunto dos horizontes.

Como vantagens do método proposto, bem como da forma de cálculo proposto, destacam-se:

- O número de métodos aplicados em paralelo, na etapa de previsão, pode ser maior ou menor, desde que adequados aos critérios anteriormente definidos;
- A eventual falha de um ou mais métodos não afeta a saída de forma continuada. A falha se refletirá na média dos erros, sendo descartada na seleção para a combinação;
- A janela da média móvel de cada método que atua em paralelo, pode ser ajustada;
- Por utilizar software livre e aberto, a proposta não traz custos e pode ser melhorada, acessada e modificada pela comunidade acadêmica;

5.2 Publicações

As conclusões iniciais deste trabalho, detalhados na secção 3.1, foram publicados em um artigo com título "*Very short-term load forecast for demand side management in absence of historical data*" no *Renewable Energy & Power Quality Journal* em abril de 2012 (NEUSSER, 2012).

5.3 Trabalhos futuros

O presente trabalho deve ser visto como um estudo inicial na utilização das potencialidades dos medidores inteligentes. Desta forma, sugere-se aprimoramentos quais sejam:

- Incluir sábados, domingos e feriados, implementando um detector para estes dias e usando rotinas para previsão em separado;
- Tratamento de valores extremos, resultantes de faltas de energia ou mudanças abruptas no comportamento do consumidor;
- Ampliação do número de métodos da primeira etapa, já que o método proposto admite isto;
- Aplicação on-line do método aqui proposto, durante muitos meses;
- Variações dos métodos, em especial, experimentando com o tamanho da janela móvel dos métodos REG2, SELECT2 e AVG3;

REFERÊNCIAS

- ABU-EL-MAGD, M. A.; SINHA, N. K. Modelling and Forecasting Short-term Load Demand - A multivariate approach. **Automatica**, [S.l.], v.18, n.3, p.329–333, 1982.
- ANDRADE, L. C. M. d.; SILVA, I. N. da. **Very Short-Term Load Forecasting Based on ARIMA model and Intelligent Systems**. Curitiba, 2009. 1-6p.
- ANEEL. **Tarifas de fornecimento de energia elétrica**. Acessível por: <http://www.aneel.gov.br/arquivos/pdf/caderno4capa.pdf>: Agência Nacional de Energia Elétrica, 2005.
- ARMSTRONG, J.; COLLOPY, F. Error measures for generalizing about forecasting methods: empirical comparisons. **International Journal of Forecasting**, [S.l.], v.8, p.69–80, June 1992.
- ARMSTRONG, J. S. Combining Forecasts - The End of the Beginning or the Beginning of the End? **International Journal of Forecasting**, [S.l.], v.5, n.4, p.585–588, 1989.
- ATIVA. **Manual do usuário - Marthe GPRS A820**. [S.l.]: Ativa Soluções, 2011.
- BATES, J.; GRANGER, C. The combination of forecasts. **Operational Research Quarterly**, [S.l.], v.20, p.451–468, 1969.
- BORGES, C. E.; PENYA, Y. K.; FERNANDEZ, I. **Optimal combined short-term building load forecasting**. 2011.
- BOX, G. E.; JENKINS, G. **Time Series Analysis, Forecasting and Control**. Oakland: Holden-Day, 1970.
- BALDING, D. J. (Ed.). **Time Series Analysis - Forecasting and Control**. 4.ed. [S.l.]: John Wiley & Sons, 2008.
- CHARYTONIUK, W.; CHEN, M.-S. Very short-term load forecasting using artificial neural networks. **IEEE Transactions on Power Systems**, [S.l.], v.15, n.1, p.263–268, February 2000.
- CHARYTONIUK, W. et al. Demand forecasting in power distribution systems using nonparametric probability density estimation. **IEEE Transactions on Power Systems**, [S.l.], v.14, n.4, November 1999.

CHARYTONIUK, W. et al. Neural-Network-Based Demand Forecasting in a deregulated environment. **IEEE Transactions on Industry Applications**, [S.l.], v.36, n.3, p.893–898, May/June 2000.

CHE, J.; WANG, J.; WANG, G. An adaptive fuzzy combination model based on self-organizing map and support vector regression for electric load forecasting. **Energy**, [S.l.], v.37, p.657–664, 2012.

CLEMEN, R. T. Combining forecasts - A review and annotated bibliography. **International Journal of Forecasting**, [S.l.], n.5, p.559–583, 1989.

CLEVELAND, R. B. et al. STL: a seasonal-trend decomposition procedure based on loess. **Journal of Official Statistics**, [S.l.], v.6, p.3–73, 1990.

DATABASES, R. S. I. G. on. **DBI: r database interface**. [S.l.: s.n.], 2014. R package version 0.3.1.

DRAGULESCU, A. A. **xlsx: read, write, format excel 2007 and excel 97/2000/xp/2003 files**. [S.l.: s.n.], 2014. R package version 0.5.7.

ELLIOTT, G. **Averaging and the optimal combination of forecasts**. acessível por: <http://econweb.ucsd.edu/~grelliott/AveragingOptimal.pdf>, 2011.

JOE H. CHOW FELIX F. WU, J. M. (Ed.). **Applied Mathematics for Restructured Electric Power Systems -**. [S.l.]: Springer, 2005.

FORTUNATO, L. A. M. **Introdução ao planejamento da expansão e operação de sistemas de produção de energia elétrica**. [S.l.]: Universidade Federal Fluminense, 1990.

GARDNER, E. J. Exponential smoothing - The state of the art—Part II. **International Journal of Forecasting**, [S.l.], p.637–666, April 2006.

GOULD, P. G. et al. Forecasting time series with multiple seasonal patterns. **European Journal of Operational Research**, [S.l.], v.191, p.207–222, 2008.

GRANGER, C.; RAMANATHAN, R. Improved methods of combining forecasts. **Journal of Forecasting**, [S.l.], v.3, p.197–204, 1984.

- GROSS, G.; GALIANA, F. D. Short-Term Load Forecasting. **Proceedings of the IEEE**, [S.l.], v.75, n.12, December 1987.
- GUAN, C. et al. Very Short-Term Load Forecasting - Wavelet Neural Networks With Data Pre-Filtering. **IEEE Transactions on Power Systems**, [S.l.], v.28, p.30–41, 2013 2013.
- GUAN, C. et al. Hybrid Kalman Filters for Very Short-Term Load Forecasting and Prediction Interval Estimation. **IEEE Transactions on Power Systems**, [S.l.], v.28, p.3806 – 3817, 2013.
- HAHN, H.; MEYER-NIEBERG, S.; PIKL, S. Electric load forecasting methods - Tools for decision making. **European Journal of Operational Research**, [S.l.], n.199, p.902–907, 2009.
- HAYKIN, S. **Neural networks - a comprehensive foundation**. 2th Edition.ed. [S.l.]: Prentice Hall, 1999.
- HERNANDEZ, L. et al. A Survey on Electric Power Demand Forecasting - Future Trends in Smart Grids, Microgrids and Smart Buildings. **IEEE Communications Surveys and Tutorials**, [S.l.], v.16, n.3, November 2014.
- HIBON, M.; EVGENIOU, T. To combine or not to combine - selecting among forecasts and their combinations. **International Journal of Forecasting**, [S.l.], v.21, p.15–24, 2005.
- HINOJOSA, V.; HOESE, A. Short-Term Load Forecasting Using Fuzzy Inductive Reasoning and Evolutionary Algorithms. **IEEE Transactions on Power Systems**, [S.l.], v.1, n.25, p.565–574, February 2010.
- HIPPERT, H. S.; PEDREIRA, C. E.; SOUZA, R. C. Neural Networks for Short-Term Load Forecasting - A Review and Evaluation. **IEEE Transactions on Power Systems**, [S.l.], v.16, n.1, p.44–55, February 2001.
- HOLT, C. C. Forecasting seasonals and trends by exponentially weighted moving averages. **Memorandum Number 52 - Office of Naval Research**, [S.l.], 1957.
- HSIAO, C.; WAN, S. K. Is there an optimal forecast combination? **Journal of Econometrics**, [S.l.], n.178, p.294–309, January 2014.
- HUANG, C.-M.; HUANG, Y.-C.; HUANG, C.-J. An Intelligence-Based Fuzzy Inference System for Smart Home Real-Time Load Forecasting. **Procedia Engineering**, [S.l.], n.50, p.297–304, 2012.

HUCK, G. et al. Load Forecast Bibliography Phase I. **IEEE Transactions on Power Apparatus and Systems**, [S.l.], v.PAS-99, n.1, January 1980.

SPRINGER (Ed.). **Forecasting with Exponential Smoothing - The state space approach**. [S.l.]: Springer Verlag Berlin - Heidelberg, 2008.

HYNDMAN, R. J.; ATHANASOPOULOS, G. **Forecasting - principles and practice**. [S.l.]: Otexts, 2014.

HYNDMAN, R. J. et al. A state space framework for automatic forecasting using exponential smoothing methods. **International Journal of Forecasting**, [S.l.], v.18, n.439-454, 2002.

HYNDMAN, R. J. et al. **forecast - Forecasting functions for time series and linear models**. [S.l.: s.n.], 2014. R package version 5.6.

HYNDMAN, R. J.; KHANDAKAR, Y. Automatic Time Series Forecasting - The forecast package for R. **Journal of Statistical Software**, [S.l.], v.27, p.1–22, 2008 2008.

HYNDMAN, R. J.; KOEHLER, A. B. Another look at measures of forecast accuracy. **International Journal of Forecasting**, [S.l.], p.679 – 688, 2006.

HYNDMAN, R. J.; SNYDER, R. D.; LIVERA, A. M. Forecasting Time Series With Complex Seasonal Patterns Using Exponential Smoothing. **Journal of the American Statistical Association**, [S.l.], v.106, n.496, p.1513–1527, 2011.

IMS. **Manual do Powernet P-600 - Medidor e Registrador de grandezas portátil**. [S.l.]: Indústria de Microsistemas, 2009.

JOSE, V. R. R.; WINKLER, R. L. Simple robust averages of forecasts: some empirical results. **International Journal of Forecasting**, [S.l.], v.24, p.163–169, Jan 2008.

KAWAUCHI, S.; SUGIHARA, H.; SASAKI, H. Development of Very-Short-Term Load Forecasting Based on Chaos Theory. **Electrical Engineering in Japan**, [S.l.], v.148, n.2, p.55–63, 2004.

LIU, K. et al. Comparison of Very Short-Term Load Forecasting Techniques. **IEEE Transactions on Power Systems**, [S.l.], v.11, p.877–882, 1996 1996.

MAHMOUD, A. A.; ORTMAYER, T. H.; REARDON, R. E. Load Forecast Bibliography Phase II. **IEEE Transactions on Power Apparatus and Systems**, [S.l.], v.PAS-100, n.7, July 1981.

MAKRIDAKIS, S. Accuracy measures - theoretical and practical concerns. **International Journal of Forecasting**, [S.l.], v.9, n.4, p.527–529, December 1993.

MIROWSKI, P. et al. Demand Forecasting in Smart Grids. **Bell Labs Technical Journal**, [S.l.], v.18, n.4, p.135–158, April 2014.

NEUSSER, L. Very short-term load forecast for demand side management in absence of historical data. **Renewable Energy & Power Quality Journal**, [S.l.], n.10, April 2012.

NIU, D.; WEI, Y. An Improved Short-Term Power Load Combined Forecasting With ARMA-GRACH-ANN- SVM Based on FHNN Similar-Day Clustering. **Journal of Software**, [S.l.], v.8, n.3, p.716–723, March 2013.

GRIMBLE, M.; JOHNSON, M. (Ed.). **Computational Intelligence in Time Series Forecasting - theory and engineering applications**. [S.l.]: Springer Verlag London, 2005.

PAULINO, C. D. et al. **Glossário Inglês-Português de Estatística**. [S.l.]: Sociedade Portuguesa de Estatística e Associação Brasileira de Estatística, 2011.

RAMCHURN, S. D. et al. Putting the 'Smarts' Into the Smart Grid - A Grand Challenge for Artificial Intelligence. **Communications of the ACM**, [S.l.], v.55, n.4, p.86–97, 2012.

REYNEAU, P. Predicting Load on Residence Circuits. **Electrical World**, [S.l.], v.71, n.19, p.969–971, May 1918.

SENJYU, T. et al. One-Hour-Ahead Load Forecasting Using Neural Network. **IEEE Transactions on Power Systems**, [S.l.], v.17, n.1, p.113–118, February 2002.

SPERANDIO, M. et al. Probabilistic demand forecasting to minimize overtaking the transmission contract. **Electric Power Systems Research**, [S.l.], n.112, p.27–36, 2014.

SRINIVASAN, K.; PRONOVOST, R. Short term load forecasting using multiple correlation models. **IEEE Transactions on Power Apparatus and Systems**, [S.l.], v.PAS-94, n.5, p.1854–1858, September 1975.

- TAYLOR, J. W. Short-Term Electricity Demand Forecasting Using Double Seasonal Exponential Smoothing. **Jornal Of Operational Research Society**, [S.l.], v.54, p.799–805, 2003.
- TAYLOR, J. W. A Comparison of Univariate Methods for Forecasting Electricity Demand Up to a Day Ahead. **International Journal of Forecasting**, [S.l.], p.1–16, 2006 2006.
- TAYLOR, J. W. An Evaluation of Methods for Very Short-Term Load Forecasting using minute-by-minute British Data. **International Journal of Forecasting**, [S.l.], v.24, p.645–658, 2008.
- TAYLOR, J. W. Triple Seasonal Methods for Short-Term Electricity Demand Forecasting. **European Journal of Operational Research**, [S.l.], n.204, p.139–152, 2010.
- TAYLOR, J. W. Exponentially Weighted Methods for Forecasting Intraday Time Series with Multiple Seasonal Cycles. **International Journal of Forecasting**, [S.l.], v.26, p.627–646, 2010.
- TAYLOR, J. W.; MAJITHIA, S. Using Combined Forecasts with Changing Weights for Electricity Demand Profiling. **Journal of the Operational Research Society**, [S.l.], v.51, p.72–82, 2000.
- TAYLOR, J. W.; MCSHARRY, P. W. Short-Term Load Forecasting Methods: an evaluation based on european data. **IEEE Transactions on Power Systems**, [S.l.], v.22, p.2213–2219, 2007.
- TAYLOR, J. W.; SNYDER, R. D. Forecasting intraday timeseries with multiple seasonal cycles using parsimonious seasonal exponential smoothing. **International Journal of Management Science**, [S.l.], n.40, p.748–757, 2012.
- TRUDNOWSKI, D. J.; MCREYNOLDS, W. L.; JOHNSON, J. M. Real-Time Very Short-Term Load Prediction for Power-System Automatic Generation Control. **IEEE Transactions on control systems technology**, [S.l.], v.9, p.254–260, 2001.
- WICKHAM, H.; JAMES, D. A.; FALCON, S. **RSQLite**: sqlite interface for r. [S.l.: s.n.], 2014. R package version 1.0.0.
- COMMUNICATION SYSTEMS, F. I. C. on; (COMSNETS), N. (Ed.). **Matching demand with supply in the smart grid using agent-based multiunit auction**. [S.l.]: IEEE, 2013. 1-6p.
- WINTERS, P. R. Forecasting Sales by exponentially weighted moving averages. **Management Science**, [S.l.], p.324–342, 1960.

YANG, H. Y. et al. Fuzzy neural very-short-term load forecasting based on chaotic dynamics reconstruction. **Chaos, Solitons and Fractals**, [S.l.], n.29, p.462–469, 2006.

YUN, Z. et al. RBF Neural Network and ANFIS-Based Short-Term Load Forecasting Approach in Real-Time Price Environment. **IEEE Transactions on Power Systems**, [S.l.], v.23, n.3, p.853–858, August 2008.

ZIVANOVIC, R. Local regression-based short-term load forecasting. **Journal of Intelligent and Robotic Systems**, [S.l.], n.31, p.115–127, 2001.

APÊNDICES

APÊNDICE A – Previsão de demanda utilizando R

A.1 Introdução

R é uma linguagem de programação e um ambiente para computação estatística. É uma plataforma de *softwares* que integram manipulação de dados, facilidades para plotar gráficos e realizar cálculos. A plataforma é um *software* livre e possui uma comunidade de colaboradores ao redor do mundo, gerenciados pela *R Foundation for Statistical Computing*, uma Fundação sem fins lucrativos. O princípio de administração e licenciamento do *software* é similar ao Linux. Tanto o Linux quanto o R são membros da *Free Software Foundation*. R é um *software* extensível ou seja, de acordo com a necessidade novas ferramentas e funcionalidades poderão ser acrescentadas. Estas ferramentas são chamadas de *packages* (pacotes). Tanto o *software* base quanto os pacotes podem ser baixados no site mantido pela Fundação, chamado *The Comprehensive R Archive Network - CRAN* (<http://cran.r-project.org>). Todo o conjunto está em constante atualização, e a todo momento os diferentes pacotes são atualizados, melhorados e erros são removidos.

A.1.1 Motivação pelo uso do R

A escolha da linguagem R em detrimento de outras possibilidades está fundamentado no que segue:

- Trata-se de um *software* livre, sem custos, cujo uso em projetos científicos é incentivado. O equivalente mais próximo é o *software* comercial Matlab da Mathworks. O uso do mesmo, porém, implicaria na necessidade de aquisição de uma ou mais licenças;
- É o ambiente no estado da arte utilizado pela maioria dos pesquisadores e estatísticos do meio acadêmico mundial;
- Um dos objetivos deste trabalho, e também de artigos publicados, é que as soluções aqui encontradas e resultados mostrados possam ser reproduzidos por terceiros. O uso de *software* livre é um elemento facilitador deste objetivo;
- A existência de uma interface de comunicação entre o ambiente de programação do Visual Studio da Microsoft, e a linguagem R. Este fato é crucial para a implementação da previsão de demanda em tempo real, utilizando dados vindos de medidores inteligentes;

A.2 Pacotes e funções utilizados

A.2.1 Leitura e escrita de planilhas e bancos de dados

Para leitura e escrita de planilhas no formato XLS (Microsoft Excel) foi utilizado o pacote "xlsx"(DRAGULESCU, 2014). A função `read.xls()` foi utilizada para leitura das demandas em formato de planilha eletrônica e a função `write.xls()` para gravar as previsões de volta à planilha para posterior análise. Para a leitura, escrita e consulta a bancos de dados sequenciais, com comandos do tipo *Structured Query Language - SQL* (Linguagem de Consulta Estruturada) foram utilizados os pacotes "DBI"(DATABASES, 2014) e "RSQLite"(WICKHAM; JAMES; FALCON, 2014). A abertura de bancos de dados do tipo SQLite foi realizada a partir do comando `dbConnect()`, a consulta através de `dbGetQuery()` e o fechamento através de `dbDisconnect()`.

A.2.2 Tratamento, análise e previsão de séries temporais

As funções para tratamento das séries temporais, análise e previsão provêm em sua totalidade do pacote "*forecast*"(HYNDMAN et al., 2014) e (HYNDMAN; KHANDAKAR, 2008), cujo embasamento teórico foi publicado em (HYNDMAN et al., 2008) e também em (HYNDMAN; ATHANASOPOULOS, 2014). A suavização Holt-Winters, através da função `HoltWinters()` é uma função nativa do *software R*.

Na tabela A.1 estão listadas de maneira compacta as funções em R utilizadas. Na coluna "função" está o nome sob o qual a função aparece na literatura explicativa do pacote. Na coluna "sintaxe" está a escrita mais comum, com seus argumentos. A coluna "argumentos" por sua vez apresenta os argumentos de fato utilizados no presente caso e a coluna "nota" contém o número da referência explicativa de cada função a seguir:

1. A função `msts()` transforma uma série temporal de demandas em um objeto pronto para o uso das funções de previsão, incluindo as informações da múltipla sazonalidade. No presente caso, com dados em intervalos de 5 minutos, a frequência diária é 288 e a frequência semanal de cinco dias úteis é 1440.
2. Suavização exponencial de dupla sazonalidade, desenvolvido por Taylor conforme item 3.1.3, com posterior previsão de 24 passos adiante (duas horas, intervalos de 5 minutos). Os parâmetros de suavização, aqui chamados de **alpha**, **beta**, **gama** e **omega** são calcu-

dados automaticamente pela função utilizando mínimos quadrados. O parâmetro ϕ é da parte autorregressiva (vide bibliografia), neste caso fixada em 0,944, resultado de vários testes prévios. O parâmetro λ não é utilizado. Já `armethod=true` significa que um método autorregressivo (AR) será utilizado para ajustar os erros auto-correlacionados. Neste trabalho quando há referência a este método é usada a abreviação DSHW.

3. Suavização Holt-Winters, conforme item 3.1.3. Os parâmetros α , β , γ são automaticamente calculados pela função através dos mínimos quadrados. Já no item `seasonal=` é informado se a sazonalidade será do tipo aditiva ou multiplicativa. Neste trabalho quando há referência a este método é usada a abreviação HWADD quando a sazonalidade for do tipo aditiva e HWMULT quando a sazonalidade for do tipo multiplicativa.
4. Decomposição de séries temporais, conforme item 3.2.2, com posterior previsão de 24 passos adiante (duas horas, intervalos de 5 minutos). Através do parâmetro `s.window` é informado o tamanho da janela móvel (neste caso 288 registros) para extração da sazonalidade. Indicando `robuste=TRUE` é informado o desejo pela estimação robusta nos parâmetros internos (vide bibliografia (CLEVELAND et al., 1990)). O método de previsão da série dessazonalizada é informado em `method=`, sendo no presente caso usada a suavização exponencial através do modelo de espaço-estado (ets) (HYNDMAN et al., 2008) ou ARIMA (arima). Neste trabalho quando há referência a este método é usada a abreviação STLFETS quando usada com suavização exponencial e STLFARIMA quando usado em conjunto com método ARIMA.
5. Rede neural alimentada adiante conforme item 3.2.2. Os dados de entrada são as quinze últimas demandas da série (parâmetro p), além das cinco demandas do dia anterior no mesmo horário (parâmetro P), totalizando 20 neurônios na camada de entrada. Na camada oculta estão outros 20 neurônios (`size=20`). A informação `repeats=2` significa que dois treinamentos completos são realizados, cada um com pesos sinápticos iniciais diferentes (aleatório). A rede treinada com melhor retrospecto entre estas duas é escolhida como a rede válida. O termo λ não é utilizado. Neste trabalho quando há referência a este método é usada a abreviação NEURAL.
6. Método ARIMA com sazonalidade (SARIMA) conforme item 3.2.2. A parcela não sazonal passa por um processo ARIMA(3,1,1) enquanto a parcela com sazonalidade pelo pro-

cesso ARIMA(0,1,0), ou seja, apenas diferenciação. A ordem dos fatores p, d, q e P, D, Q foram definidos em testes prévios, nos quais o modelo SARIMA(3,1,1)(0,1,0)_288 teve melhor desempenho. O parâmetro `period=288` informa o período da sazonalidade, no caso diária. O termo `lambda` também não é utilizado. Neste trabalho quando há referência a este método é usada a abreviação SARIMA.

7. Enquanto os métodos `dshw()` e `stlf()` já trazem incluídos na função a previsão com h passos adiante, as funções `HoltWinters()`, `nnetar()` e `Arima()` apenas constroem o método. Necessitam de um passo adicional para a previsão. Daí a necessidade da função `forecast()`, que fará a previsão h passos adiante baseado no modelo previamente aplicado à série temporal.
8. Regressão linear buscando identificar os coeficientes que satisfaçam a veracidade da fórmula, no caso $Demanda = W_1 * Met1 + W_2 * Met2 + W_3 * Met3$. Para realizar a regressão, o item x do método são 288 vetores contendo as 288 últimas demandas e previsões dos métodos selecionados para aquele instante. O método retorna os coeficientes W_1 até W_3 , além do valor no eixo das ordenadas onde a reta da regressão cruza este eixo.

Função	Sintaxe	Argumentos	Nota
msts()	msts(data, seasonal.periods, ts.frequency)	data=Demandas, seasonal. periods = 288(diário) e 1440 (semanal), ts.frequency = 288	(1)
dshw()	dshw(y, h, alpha, beta, gama, omega, phi, lambda, armethod)	y=série msts, h=24=passos adiante na previsão, alpha=null, beta=null, gama=null, omega=null, phi=0.944, lambda=null, armethod=TRUE	(2)
HoltWinters()	HoltWinters(x, alpha, beta, gamma, seasonal=)	x=série msts, alpha=null, beta=null, gamma=null, seasonal=c("additive") ou =c("multiplicative")	(3)
stlf()	stlf(x, h, s.window=, robust=, method=)	x=série msts, h=24=passos adiante na previsão, s.window=288, robust=TRUE, method=c("ets") ou c("arima")	(4)
nnetar()	nnetar(x, p, P, size, repeats=, lambda=)	x=série msts, p=15 número de entradas não sazonais, P=5 número de entradas sazonais, size=20 número de neurônios ocultos, repeats=2, lambda=null	(5)
Arima()	Arima(x, order=c(0,0,0), seasonal=list(order=c(0,0,0), period=), lambda=)	x=série msts, order=c(3,1,1), seasonal= list(order=c(0,1,0), period=288), lambda=null	(6)
forecast()	forecast(object, h)	object= objeto resultado de uma das funções (3), (5) ou (6). h=24= passos adiante na previsão	(7)
lm()	lm(formula, x, na.action)	formula = Demanda Met1 + Met2 + Met3, x=série contendo últimas 288 demandas e previsões	(8)

Tabela A.1: Tabela resumindo funções em R utilizadas - Séries Temporais

ANEXOS

ANEXO A – Tabelas e gráficos com resultados do capítulo 3

HORIZ	DSHW	HWADD	HWMULT	NEURA	STLFETS	STLFARIMA	SARIMA	BENCH
t-5	10,6%	5,7%	5,1%	32,1%	7,2%	7,2%	6,3%	34,5%
t-10	11,6%	7,8%	6,5%	32,1%	8,7%	8,6%	7,5%	34,5%
t-15	12,4%	8,9%	7,2%	32,1%	9,5%	9,4%	8,1%	34,5%
t-20	12,7%	9,9%	7,8%	32,1%	10,3%	10,2%	8,7%	34,5%
t-25	13,0%	11,0%	8,5%	32,1%	11,2%	11,0%	9,1%	34,5%
t-30	13,1%	12,2%	9,1%	32,1%	11,9%	11,8%	9,8%	34,5%
t-35	13,8%	13,4%	9,9%	32,1%	12,9%	12,7%	10,4%	34,5%
t-40	14,3%	14,4%	10,4%	32,1%	13,7%	13,6%	10,9%	34,5%
t-45	14,8%	15,2%	10,7%	32,1%	14,4%	14,2%	11,2%	34,5%
t-50	14,8%	16,2%	11,2%	32,1%	15,2%	15,0%	11,8%	34,5%
t-55	15,2%	17,3%	11,8%	32,1%	16,1%	16,0%	12,5%	34,5%
t-60	15,9%	18,5%	12,4%	32,1%	17,1%	17,0%	13,1%	34,5%
t-65	16,0%	19,3%	12,8%	32,1%	17,8%	17,7%	13,5%	34,5%
t-70	16,6%	20,3%	13,3%	32,1%	18,5%	18,5%	14,0%	34,5%
t-75	17,1%	21,3%	13,8%	32,1%	19,3%	19,2%	14,4%	34,5%
t-80	17,3%	22,1%	14,2%	32,1%	20,0%	20,0%	15,0%	34,5%
t-85	18,0%	23,1%	14,7%	32,1%	20,7%	20,6%	15,5%	34,5%
t-90	18,3%	23,8%	15,0%	32,1%	21,4%	21,4%	15,9%	34,5%
t-95	18,6%	24,7%	15,4%	32,0%	22,1%	22,0%	16,3%	34,5%
t-100	19,0%	25,5%	15,8%	32,0%	22,8%	22,8%	16,8%	34,5%
t-105	19,2%	26,5%	16,3%	32,0%	23,6%	23,6%	17,3%	34,5%
t-110	19,8%	27,4%	16,8%	32,0%	24,4%	24,4%	17,8%	34,5%
t-115	20,2%	28,2%	17,2%	32,0%	25,2%	25,1%	18,2%	34,5%
t-120	20,7%	29,0%	17,5%	32,0%	25,9%	25,8%	18,6%	34,5%

Tabela A.1: Erros percentuais médios por método e horizonte de previsão - Consumidor A1




Figura A.1: Consumidor A1: Oito métodos e seu MAPE em função do horizonte de previsão

HORIZ	DSHW	HWADD	HWMULT	NEURA	STLFETS	STLFARIMA	SARIMA	BENCH
t-5	9,9%	4,8%	4,5%	20,9%	6,1%	6,0%	5,1%	12,9%
t-10	10,8%	6,2%	5,6%	20,9%	6,6%	6,4%	5,7%	12,9%
t-15	11,3%	7,3%	6,4%	20,9%	7,0%	6,7%	6,0%	12,9%
t-20	11,8%	8,1%	7,0%	20,9%	7,2%	7,0%	6,3%	12,9%
t-25	11,6%	9,0%	7,5%	20,8%	7,4%	7,2%	6,5%	12,9%
t-30	12,1%	10,0%	8,3%	20,9%	7,7%	7,5%	6,8%	12,9%
t-35	12,8%	11,0%	8,9%	20,9%	7,9%	7,7%	7,1%	12,9%
t-40	13,2%	11,8%	9,3%	20,9%	8,0%	7,8%	7,3%	12,9%
t-45	13,4%	12,7%	9,8%	20,9%	8,4%	8,2%	7,7%	12,9%
t-50	13,7%	13,7%	10,4%	20,9%	8,7%	8,5%	8,0%	12,9%
t-55	13,9%	14,7%	10,9%	20,9%	9,0%	8,7%	8,3%	12,9%
t-60	14,4%	15,7%	11,5%	20,8%	9,2%	9,0%	8,6%	12,9%
t-65	14,8%	16,6%	11,9%	20,9%	9,4%	9,1%	8,7%	12,9%
t-70	15,0%	17,5%	12,3%	20,9%	9,5%	9,2%	8,8%	12,9%
t-75	15,5%	18,3%	12,8%	20,8%	9,7%	9,4%	9,0%	12,9%
t-80	15,5%	19,2%	13,2%	20,8%	9,7%	9,4%	9,0%	12,9%
t-85	15,9%	20,1%	13,7%	20,8%	9,9%	9,6%	9,3%	12,9%
t-90	16,3%	21,1%	14,1%	20,8%	10,0%	9,7%	9,5%	12,9%
t-95	16,5%	21,9%	14,6%	20,8%	10,2%	9,9%	9,6%	12,9%
t-100	16,9%	22,8%	15,1%	20,8%	10,4%	10,1%	9,8%	12,9%
t-105	17,0%	23,6%	15,4%	20,8%	10,4%	10,1%	9,8%	12,9%
t-110	17,3%	24,4%	15,8%	20,7%	10,5%	10,2%	9,9%	12,9%
t-115	17,7%	25,2%	16,2%	20,7%	10,6%	10,3%	9,9%	12,9%
t-120	18,0%	26,0%	16,5%	20,7%	10,7%	10,4%	10,0%	12,9%

Tabela A.2: Erros percentuais médios por método e horizonte de previsão - Consumidor A2

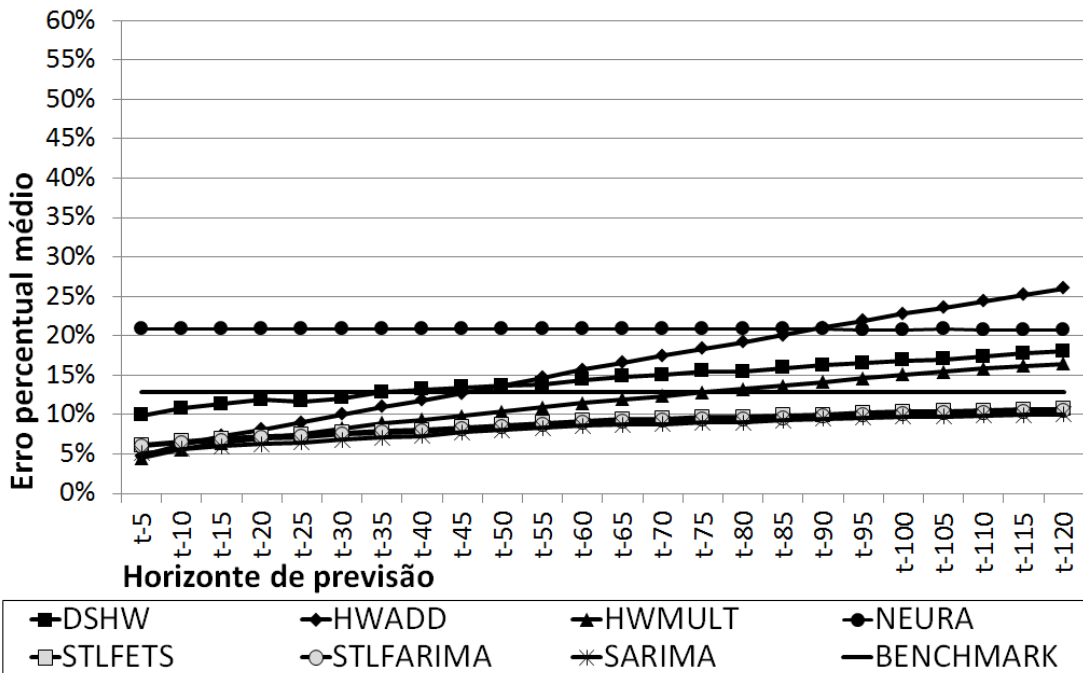


Figura A.2: Consumidor A2: Oito métodos e seu MAPE em função do horizonte de previsão

HORIZ	DSHW	HWADD	HWMULT	NEURA	STLFETS	STLFARIMA	SARIMA	BENCH
t-5	58,2%	21,1%	21,2%	105,4%	18,4%	18,8%	21,3%	50,2%
t-10	65,6%	32,2%	31,2%	106,9%	22,5%	23,1%	27,9%	50,2%
t-15	72,6%	41,0%	41,3%	107,8%	26,9%	27,4%	33,2%	50,2%
t-20	73,7%	48,8%	49,9%	109,2%	30,4%	31,5%	37,5%	50,2%
t-25	78,2%	56,2%	55,6%	106,4%	33,8%	35,0%	40,5%	50,2%
t-30	83,9%	62,9%	63,8%	107,8%	37,0%	38,4%	43,3%	50,2%
t-35	86,3%	70,5%	71,3%	105,2%	40,8%	41,4%	46,2%	50,2%
t-40	93,0%	77,6%	79,9%	106,7%	44,2%	43,2%	46,9%	50,2%
t-45	97,8%	84,5%	85,8%	107,8%	48,0%	46,1%	48,1%	50,2%
t-50	100,7%	89,7%	92,0%	109,7%	51,4%	47,2%	48,5%	50,2%
t-55	105,2%	93,9%	98,5%	107,9%	52,7%	47,6%	49,1%	50,2%
t-60	109,7%	97,8%	102,8%	109,3%	54,8%	48,5%	49,6%	50,2%
t-65	115,1%	102,0%	106,6%	109,7%	57,6%	49,3%	50,2%	50,2%
t-70	116,5%	105,0%	116,0%	110,1%	56,9%	49,5%	50,9%	50,2%
t-75	119,8%	109,0%	167,3%	108,8%	58,4%	49,3%	51,9%	50,2%
t-80	123,4%	112,9%	127,1%	108,3%	60,8%	49,7%	52,9%	50,2%
t-85	129,6%	116,9%	135,0%	109,7%	62,3%	50,2%	53,4%	50,2%
t-90	126,7%	119,9%	142,1%	110,0%	65,0%	50,7%	54,3%	50,2%
t-95	133,4%	123,5%	149,1%	108,9%	66,2%	50,8%	55,1%	50,2%
t-100	138,3%	126,1%	149,5%	108,2%	66,9%	51,6%	55,9%	50,2%
t-105	140,3%	128,3%	157,6%	106,9%	68,6%	52,0%	57,4%	50,2%
t-110	142,7%	130,6%	178,1%	108,7%	69,5%	52,2%	57,8%	50,2%
t-115	146,3%	132,9%	184,5%	109,3%	70,4%	51,8%	58,2%	50,2%
t-120	150,0%	136,2%	189,9%	107,1%	72,3%	52,4%	58,4%	50,2%

Tabela A.3: Erros percentuais médios por método e horizonte de previsão - Consumidor B

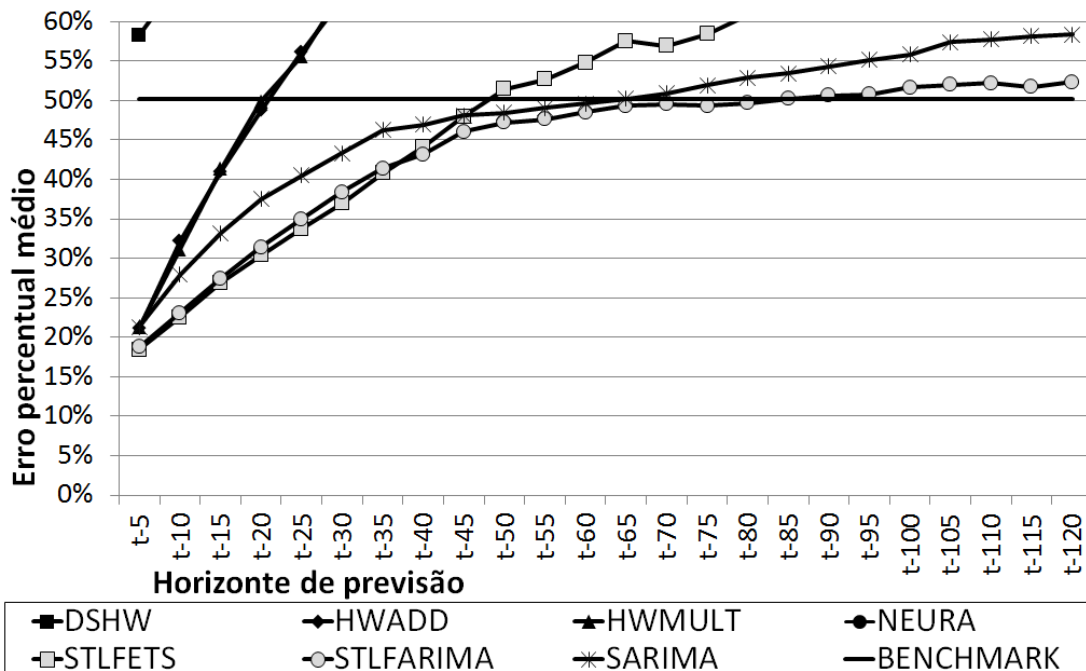


Figura A.3: Consumidor B: Oito métodos e seu MAPE em função do horizonte de previsão

HORIZ	DSHW	HWADD	HWMULT	NEURA	STLFETS	STLFARIMA	SARIMA	BENCH
t-5	35,5%	17,0%	14,9%	84,9%	15,0%	16,6%	15,0%	33,0%
t-10	38,0%	24,9%	21,2%	85,2%	18,0%	21,9%	17,6%	33,0%
t-15	40,4%	31,5%	26,9%	86,3%	20,7%	25,8%	19,6%	33,0%
t-20	43,1%	37,4%	32,0%	85,9%	23,4%	28,5%	21,4%	33,0%
t-25	45,3%	41,6%	36,8%	87,1%	25,9%	30,3%	22,9%	33,0%
t-30	46,9%	45,7%	41,7%	85,4%	28,1%	31,5%	23,9%	33,0%
t-35	48,9%	49,9%	51,5%	85,4%	30,3%	32,2%	24,6%	33,0%
t-40	51,3%	54,0%	51,1%	86,2%	32,8%	33,1%	25,5%	33,0%
t-45	52,4%	58,0%	56,4%	85,4%	35,7%	33,6%	26,1%	33,0%
t-50	54,7%	61,7%	57,8%	86,0%	38,4%	34,1%	26,5%	33,0%
t-55	56,1%	64,5%	68,1%	85,9%	41,4%	34,7%	26,8%	33,0%
t-60	58,3%	67,4%	75,0%	86,0%	44,5%	34,8%	26,9%	33,0%
t-65	59,2%	69,8%	76,6%	85,9%	46,8%	34,8%	27,4%	33,0%
t-70	60,0%	72,1%	83,3%	86,6%	49,8%	34,9%	27,5%	33,0%
t-75	62,3%	75,0%	86,1%	86,9%	53,5%	35,2%	27,5%	33,0%
t-80	62,9%	76,9%	88,2%	88,0%	55,5%	35,2%	27,6%	33,0%
t-85	64,2%	79,0%	91,0%	87,8%	58,4%	35,4%	27,6%	33,0%
t-90	65,5%	81,3%	107,2%	87,8%	60,9%	35,6%	27,6%	33,0%
t-95	66,2%	84,1%	102,8%	87,5%	63,2%	35,7%	27,7%	33,0%
t-100	66,9%	86,3%	107,5%	86,8%	66,0%	35,6%	27,6%	33,0%
t-105	68,3%	88,4%	107,6%	85,9%	67,8%	35,7%	27,6%	33,0%
t-110	69,1%	90,0%	109,7%	87,2%	69,2%	35,8%	27,7%	33,0%
t-115	69,5%	91,8%	109,7%	86,9%	71,4%	35,7%	27,7%	33,0%
t-120	70,8%	94,6%	117,2%	87,0%	73,7%	35,8%	27,7%	33,0%

Tabela A.4: Erros percentuais médios por método e horizonte de previsão - Consumidor C




Figura A.4: Consumidor C: Oito métodos e seu MAPE em função do horizonte de previsão

HORIZ	DSHW	HWADD	HWMULT	NEURA	STLFETS	STLFARIMA	SARIMA	BENCH
t-5	46,2%	16,5%	15,4%	79,2%	12,7%	15,3%	16,1%	25,6%
t-10	52,8%	22,4%	24,0%	79,7%	16,4%	20,1%	23,1%	25,6%
t-15	55,8%	26,5%	28,6%	79,0%	19,1%	22,4%	27,6%	25,6%
t-20	62,2%	31,2%	37,2%	78,9%	22,5%	24,9%	33,5%	25,6%
t-25	68,2%	35,2%	43,3%	80,1%	24,9%	25,8%	39,2%	25,6%
t-30	71,0%	38,8%	51,5%	79,6%	27,3%	27,1%	43,7%	25,6%
t-35	75,2%	42,3%	57,3%	80,1%	30,6%	28,2%	48,1%	25,6%
t-40	81,4%	45,6%	60,9%	80,5%	33,8%	29,2%	50,8%	25,6%
t-45	84,4%	48,3%	66,4%	79,7%	35,9%	29,8%	52,5%	25,6%
t-50	88,7%	52,0%	77,5%	79,3%	38,7%	30,4%	54,6%	25,6%
t-55	93,4%	55,4%	81,0%	79,3%	41,6%	31,1%	56,2%	25,6%
t-60	98,0%	59,2%	88,6%	80,4%	44,3%	31,2%	58,2%	25,6%
t-65	102,5%	62,9%	97,3%	80,9%	47,0%	31,7%	60,7%	25,6%
t-70	107,3%	66,2%	106,2%	80,4%	49,3%	31,9%	63,0%	25,6%
t-75	111,6%	69,5%	106,0%	80,6%	51,9%	31,9%	65,0%	25,6%
t-80	114,9%	73,1%	116,9%	80,2%	54,6%	32,3%	67,8%	25,6%
t-85	119,3%	76,3%	114,7%	81,2%	57,3%	32,3%	70,0%	25,6%
t-90	124,1%	78,2%	137,5%	80,3%	59,5%	32,4%	71,8%	25,6%
t-95	128,1%	79,8%	127,0%	80,3%	61,4%	32,2%	73,4%	25,6%
t-100	133,3%	81,1%	147,9%	81,2%	62,3%	31,9%	73,9%	25,6%
t-105	137,4%	81,9%	151,5%	80,5%	62,7%	31,5%	74,4%	25,6%
t-110	140,6%	82,7%	150,5%	80,6%	62,8%	31,3%	74,4%	25,6%
t-115	144,5%	83,9%	155,5%	80,5%	62,8%	30,9%	74,2%	25,6%
t-120	149,2%	85,0%	159,1%	80,7%	62,8%	30,7%	73,8%	25,6%

Tabela A.5: Erros percentuais médios por método e horizonte de previsão - Consumidor D




Figura A.5: Consumidor D: Oito métodos e seu MAPE em função do horizonte de previsão

HORIZ	DSHW	HWADD	HWMULT	NEURA	STLFETS	STLFARIMA	SARIMA	BENCH
t-5	21,8%	12,8%	10,5%	112,7%	12,1%	13,0%	12,4%	13,6%
t-10	25,4%	15,2%	11,4%	113,6%	13,4%	15,5%	13,6%	13,6%
t-15	26,3%	16,0%	11,6%	113,6%	14,0%	16,5%	13,8%	13,6%
t-20	28,2%	17,3%	12,0%	111,8%	14,8%	17,2%	14,2%	13,6%
t-25	30,0%	18,4%	12,3%	112,6%	15,7%	18,1%	14,2%	13,6%
t-30	30,9%	19,9%	12,5%	113,5%	16,7%	19,2%	14,3%	13,6%
t-35	32,3%	21,5%	12,9%	117,0%	17,8%	20,1%	14,4%	13,6%
t-40	34,3%	22,9%	13,1%	118,9%	18,8%	21,1%	14,5%	13,6%
t-45	35,8%	24,3%	13,2%	119,0%	19,8%	22,1%	14,7%	13,6%
t-50	38,7%	25,6%	13,4%	118,1%	20,3%	22,8%	14,7%	13,6%
t-55	39,7%	26,6%	13,5%	118,7%	20,9%	23,4%	14,7%	13,6%
t-60	42,1%	28,0%	13,5%	117,7%	21,6%	23,9%	14,8%	13,6%
t-65	42,9%	29,4%	13,5%	117,1%	22,2%	24,5%	14,7%	13,6%
t-70	44,2%	30,8%	13,7%	118,4%	23,1%	24,9%	14,8%	13,6%
t-75	46,1%	32,0%	13,8%	118,1%	23,7%	25,3%	14,9%	13,6%
t-80	47,3%	33,3%	13,9%	118,5%	24,6%	25,6%	14,9%	13,6%
t-85	47,7%	34,1%	14,0%	119,2%	25,4%	25,9%	15,1%	13,6%
t-90	49,0%	34,9%	14,1%	119,6%	26,2%	26,5%	15,1%	13,6%
t-95	50,7%	36,1%	14,3%	117,3%	26,8%	26,6%	15,2%	13,6%
t-100	51,1%	37,1%	14,4%	115,6%	27,7%	26,9%	15,3%	13,6%
t-105	52,7%	38,0%	14,6%	115,5%	28,6%	27,2%	15,4%	13,6%
t-110	53,6%	38,7%	14,7%	116,2%	29,5%	27,5%	15,5%	13,6%
t-115	53,3%	39,3%	14,7%	115,6%	30,3%	27,8%	15,6%	13,6%
t-120	54,5%	40,3%	14,9%	116,1%	31,1%	28,1%	15,6%	13,6%

Tabela A.6: Erros percentuais médios por método e horizonte de previsão - Consumidor E




Figura A.6: Consumidor E: Oito métodos e seu MAPE em função do horizonte de previsão

HORIZ	DSHW	HWADD	HWMULT	NEURA	STLFETS	STLFARIMA	SARIMA	BENCH
t-5	33,0%	7,6%	45,3%	87,6%	5,9%	5,4%	3,8%	71,9%
t-10	36,3%	13,3%	31,7%	88,1%	10,4%	9,3%	8,6%	71,9%
t-15	39,9%	18,2%	46,3%	88,4%	14,4%	13,0%	14,2%	71,9%
t-20	43,2%	22,4%	44,1%	88,5%	17,9%	16,0%	20,0%	71,9%
t-25	46,2%	25,9%	64,3%	88,3%	20,7%	18,3%	25,7%	71,9%
t-30	48,9%	28,8%	97,8%	88,7%	23,3%	20,4%	31,3%	71,9%
t-35	51,4%	31,2%	88,9%	89,0%	25,8%	22,3%	36,9%	71,9%
t-40	54,1%	33,5%	126,5%	89,6%	28,1%	24,3%	42,3%	71,9%
t-45	56,3%	35,5%	132,9%	89,5%	30,3%	26,3%	47,5%	71,9%
t-50	58,7%	37,6%	126,1%	89,6%	32,5%	28,2%	52,6%	71,9%
t-55	60,9%	39,6%	110,0%	89,6%	34,8%	30,3%	57,7%	71,9%
t-60	63,6%	41,4%	186,7%	89,2%	37,1%	32,4%	62,7%	71,9%
t-65	65,9%	42,9%	137,9%	89,0%	39,3%	34,2%	67,7%	71,9%
t-70	67,7%	44,2%	150,5%	89,1%	41,2%	35,7%	72,7%	71,9%
t-75	69,6%	45,2%	161,6%	89,1%	42,6%	37,0%	77,6%	71,9%
t-80	71,2%	45,6%	230,5%	88,9%	43,9%	38,2%	82,4%	71,9%
t-85	72,9%	46,2%	344,4%	88,3%	45,1%	39,3%	87,2%	71,9%
t-90	74,6%	47,7%	233,6%	88,2%	46,2%	40,4%	91,9%	71,9%
t-95	76,2%	49,1%	231,9%	88,7%	47,3%	41,3%	96,4%	71,9%
t-100	77,7%	50,5%	224,9%	88,9%	48,6%	42,2%	100,8%	71,9%
t-105	79,1%	52,0%	240,2%	89,4%	49,7%	43,1%	105,0%	71,9%
t-110	80,7%	53,5%	281,8%	89,3%	50,8%	44,1%	109,2%	71,9%
t-115	82,3%	54,9%	281,9%	88,9%	52,1%	44,9%	113,2%	71,9%
t-120	84,1%	56,3%	297,0%	88,9%	53,2%	45,8%	117,1%	71,9%

Tabela A.7: Erros percentuais médios por método e horizonte de previsão - Consumidor F




Figura A.7: Consumidor F: Oito métodos e seu MAPE em função do horizonte de previsão

HORIZ	DSHW	HWADD	HWMULT	NEURA	STLFETS	STLFARIMA	SARIMA	BENCH
t-5	12,8%	6,9%	6,8%	23,8%	6,6%	6,7%	8,3%	23,3%
t-10	14,0%	9,5%	9,3%	23,7%	8,5%	8,7%	11,0%	23,3%
t-15	15,1%	11,4%	11,1%	23,8%	9,7%	10,0%	12,7%	23,3%
t-20	15,7%	12,9%	12,5%	23,8%	10,7%	11,1%	14,2%	23,3%
t-25	16,4%	14,3%	13,8%	23,8%	11,6%	12,1%	15,2%	23,3%
t-30	16,9%	15,5%	15,0%	23,8%	12,5%	12,9%	16,5%	23,3%
t-35	17,3%	16,6%	16,0%	23,7%	13,4%	13,7%	17,5%	23,3%
t-40	17,9%	17,5%	16,9%	23,7%	14,2%	14,4%	18,5%	23,3%
t-45	18,3%	18,3%	17,7%	23,7%	14,9%	15,0%	19,3%	23,3%
t-50	18,8%	19,1%	18,4%	23,7%	15,5%	15,4%	20,0%	23,3%
t-55	19,3%	19,8%	19,1%	23,7%	16,0%	15,9%	20,7%	23,3%
t-60	19,6%	20,4%	19,8%	23,8%	16,5%	16,3%	21,2%	23,3%
t-65	19,9%	21,1%	20,4%	23,8%	16,9%	16,7%	21,9%	23,3%
t-70	20,3%	21,6%	20,9%	23,8%	17,4%	17,1%	22,6%	23,3%
t-75	20,6%	22,1%	21,6%	23,8%	18,0%	17,6%	23,2%	23,3%
t-80	20,9%	22,7%	22,2%	23,9%	18,5%	18,0%	23,8%	23,3%
t-85	21,2%	23,2%	22,7%	23,9%	18,9%	18,3%	24,3%	23,3%
t-90	21,5%	23,7%	23,3%	24,0%	19,4%	18,6%	24,8%	23,3%
t-95	21,8%	24,2%	23,9%	23,9%	19,7%	18,9%	25,2%	23,3%
t-100	22,1%	24,6%	24,4%	23,8%	20,1%	19,1%	25,7%	23,3%
t-105	22,3%	25,1%	24,9%	23,9%	20,4%	19,4%	26,0%	23,3%
t-110	22,5%	25,6%	25,5%	24,0%	20,8%	19,6%	26,4%	23,3%
t-115	22,8%	26,1%	26,0%	23,9%	21,1%	19,8%	26,9%	23,3%
t-120	22,9%	26,5%	26,4%	23,9%	21,5%	20,0%	27,3%	23,3%

Tabela A.8: Erros percentuais médios por método e horizonte de previsão - Consumidor G




Figura A.8: Consumidor G: Oito métodos e seu MAPE em função do horizonte de previsão

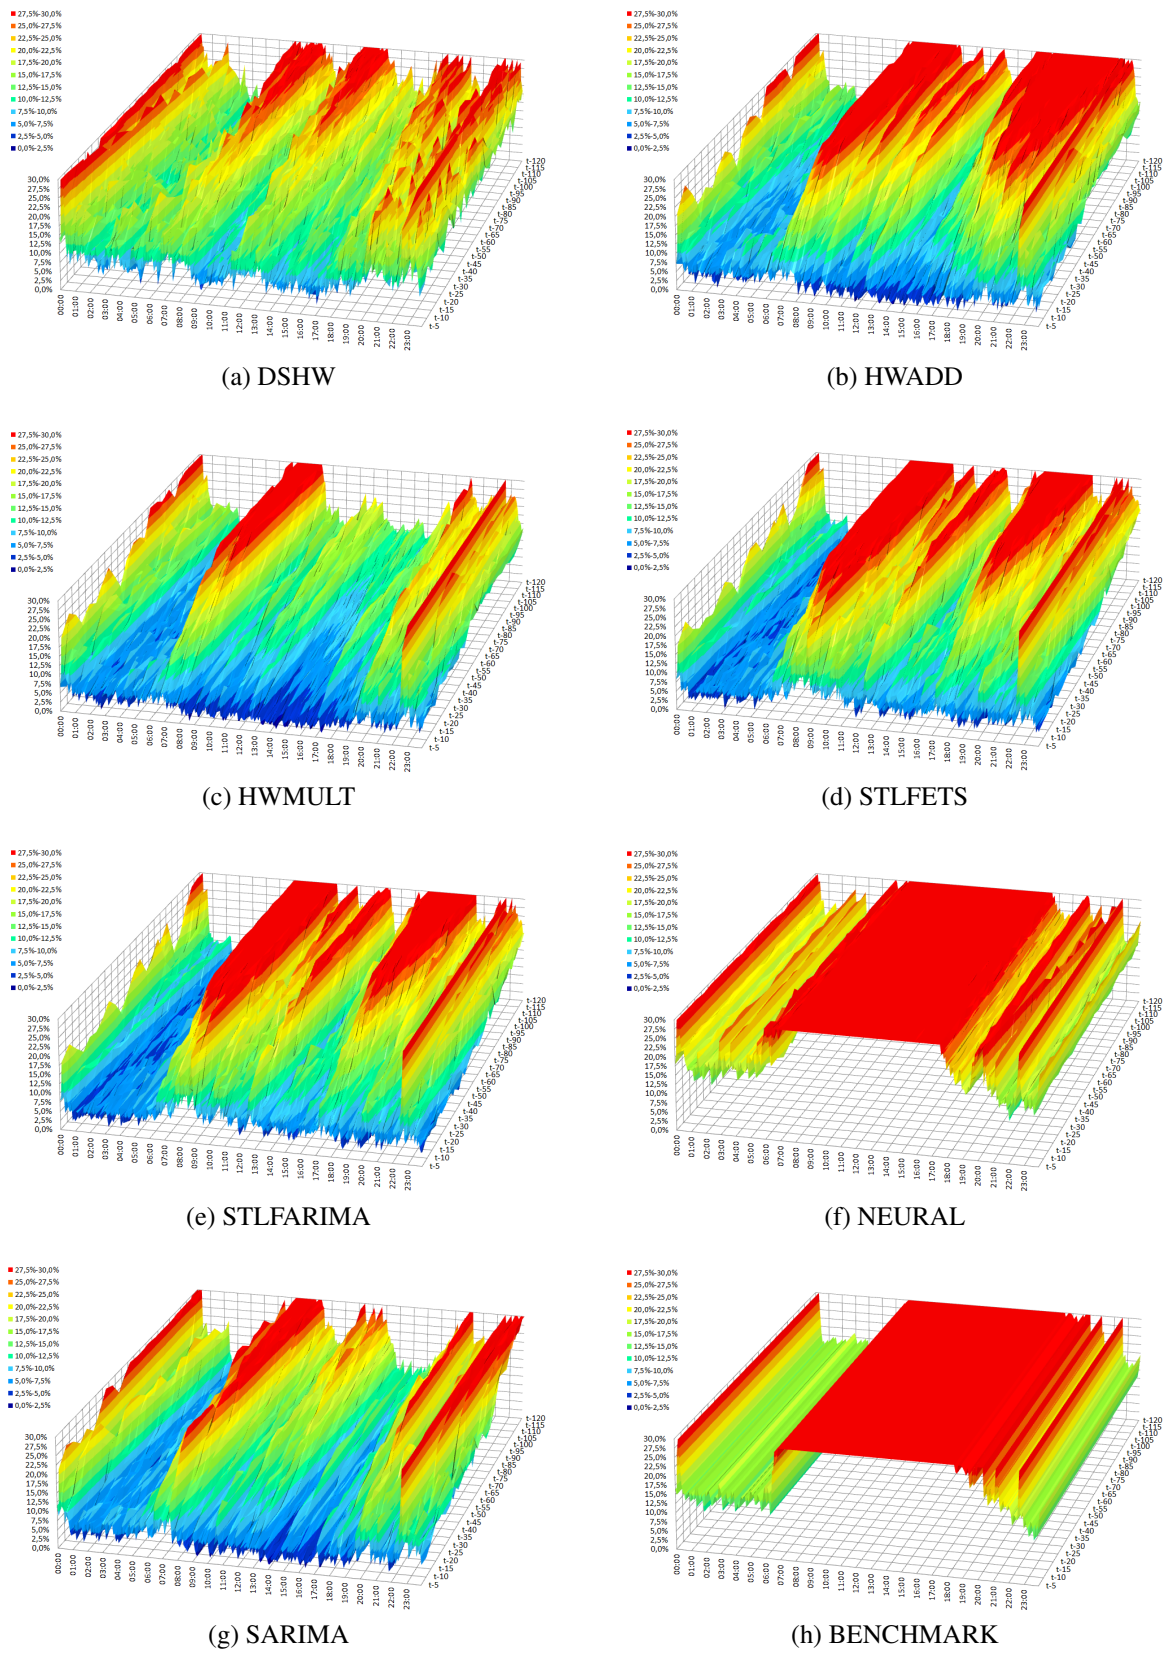


Figura A.9: Relevo dos erros percentuais do consumidor A1 - Método X Horizonte X Horário

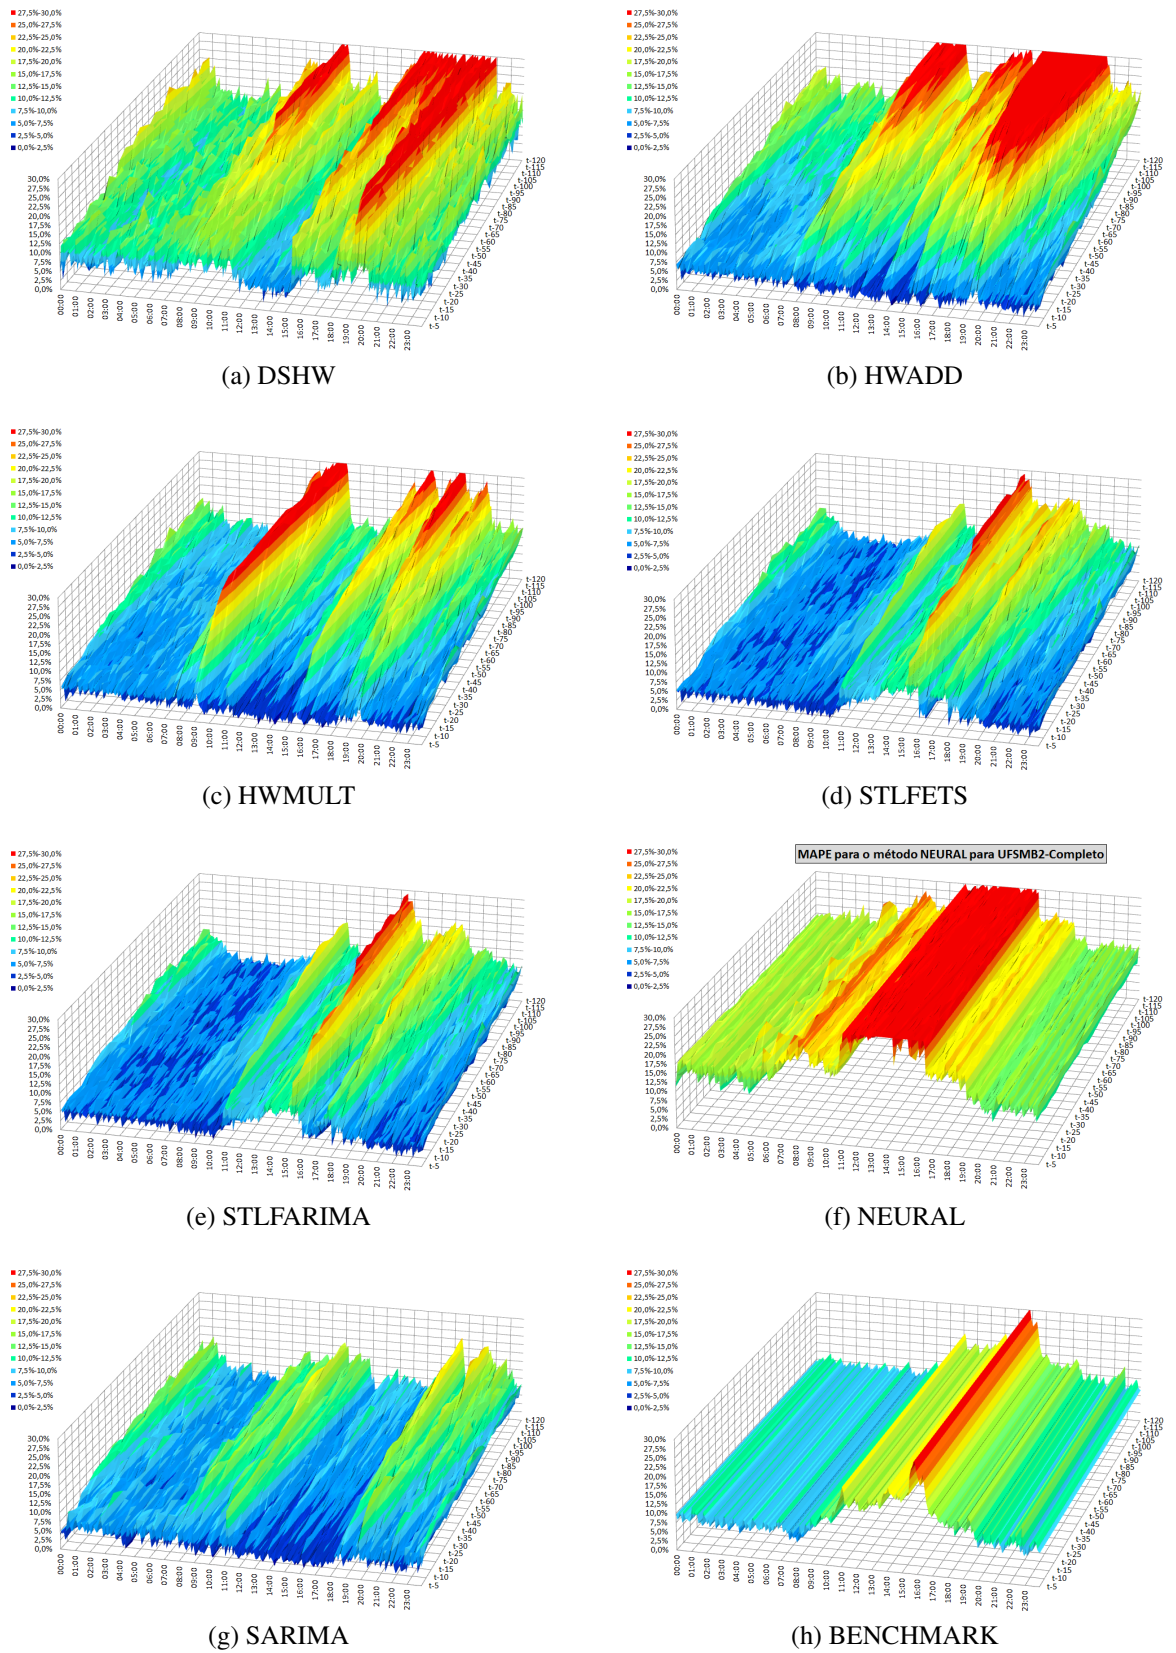


Figura A.10: Relevo dos erros percentuais do consumidor A2 - Método X Horizonte X Horário

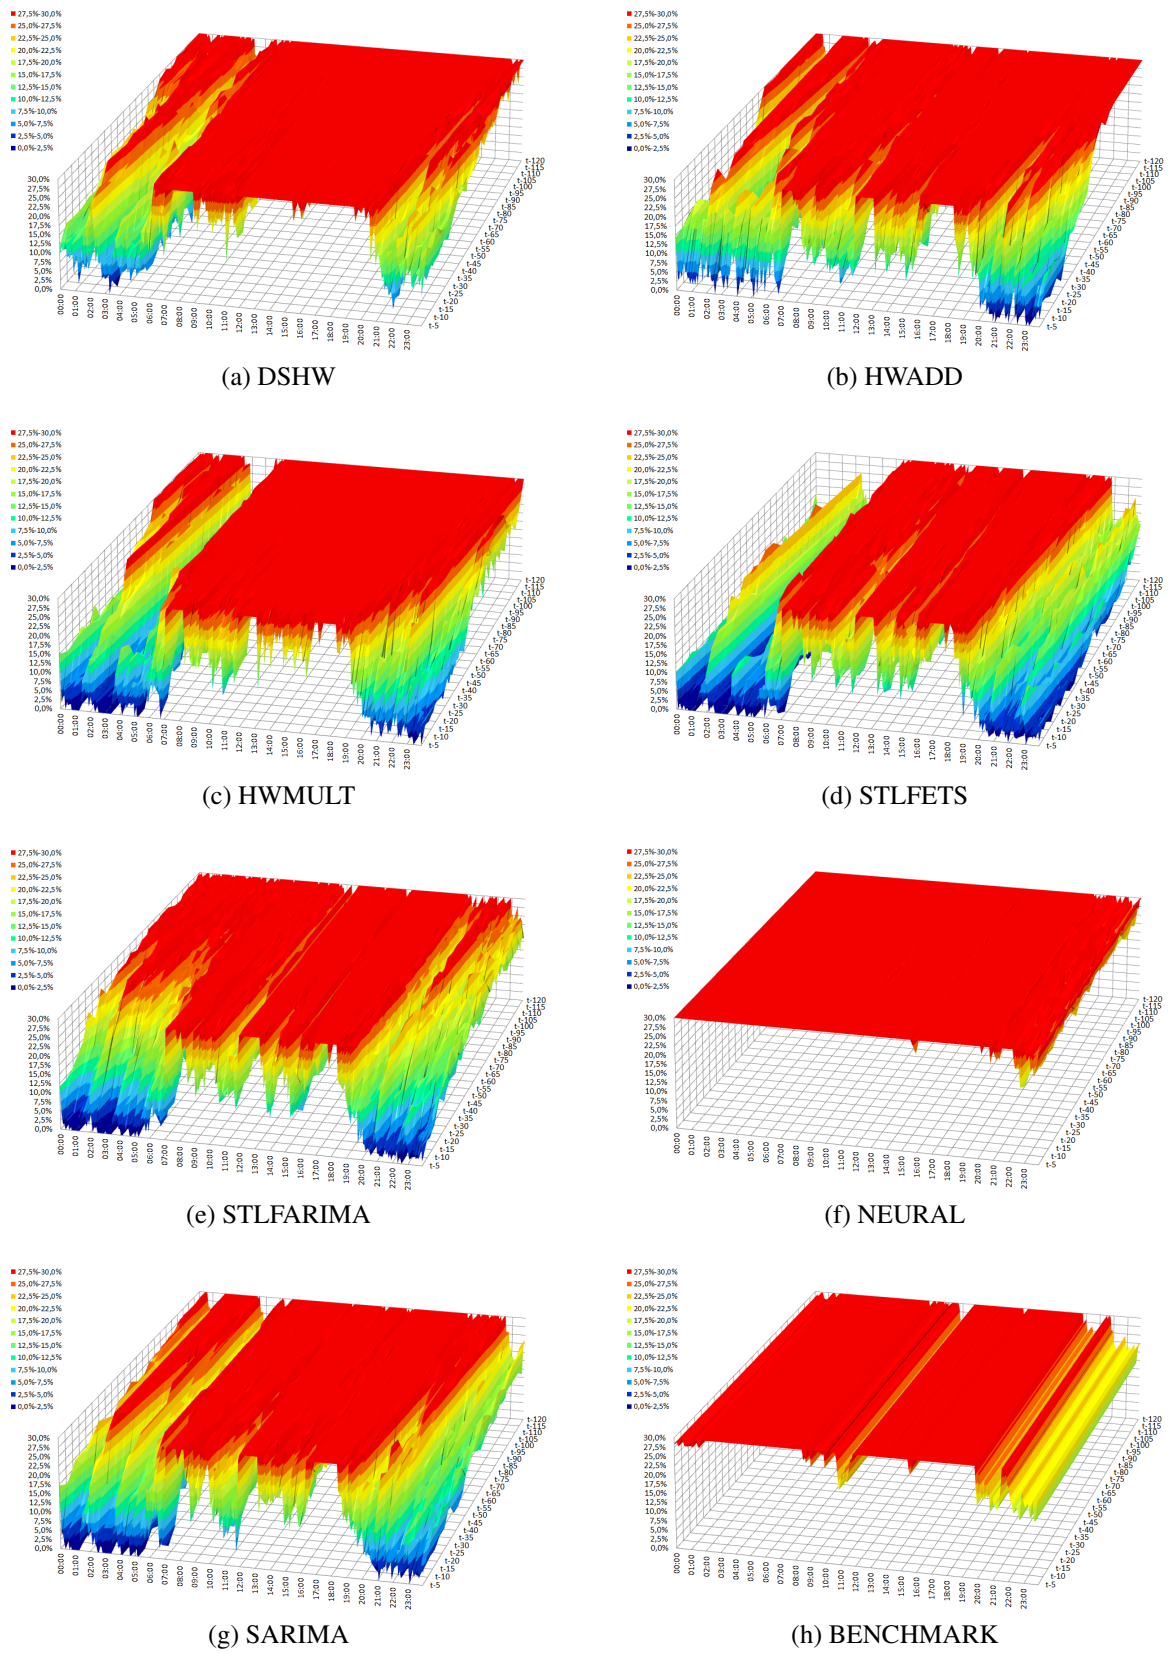


Figura A.11: Relevo dos erros percentuais do consumidor B - Método X Horizonte X Horário

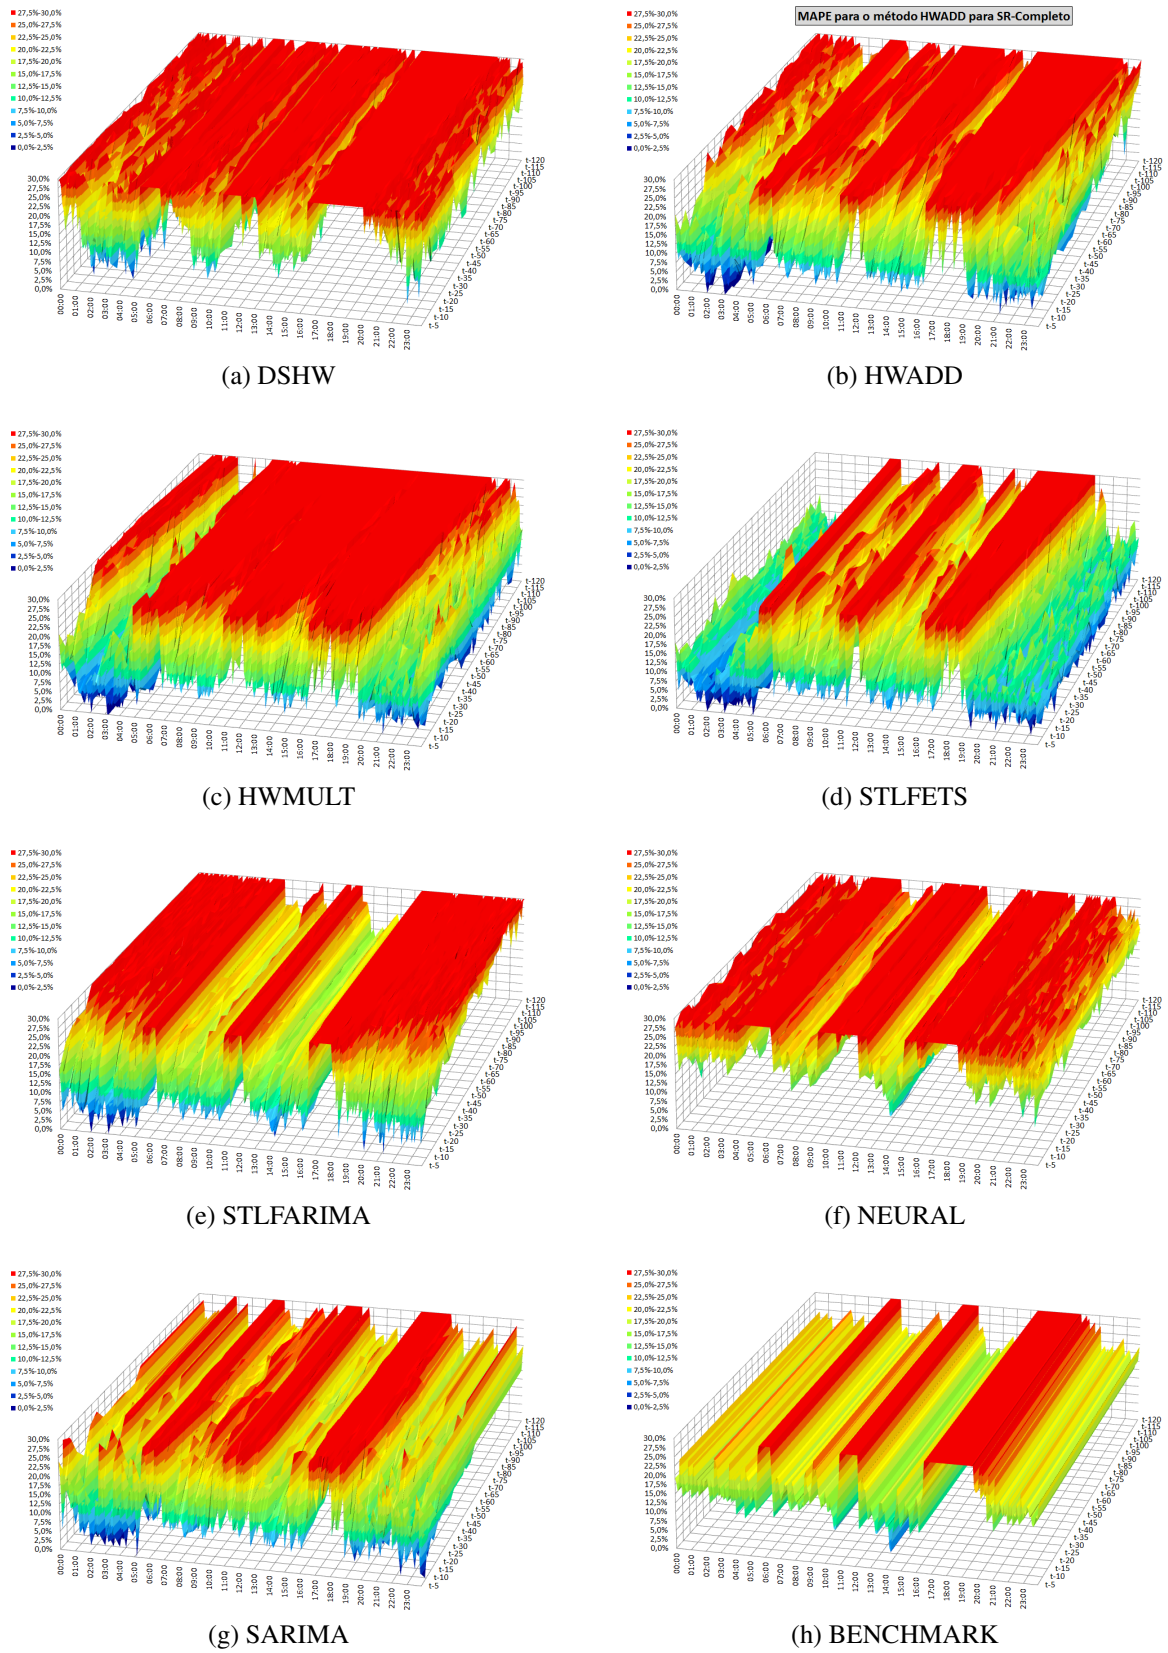


Figura A.12: Relevo dos erros percentuais do consumidor C - Método X Horizonte X Horário

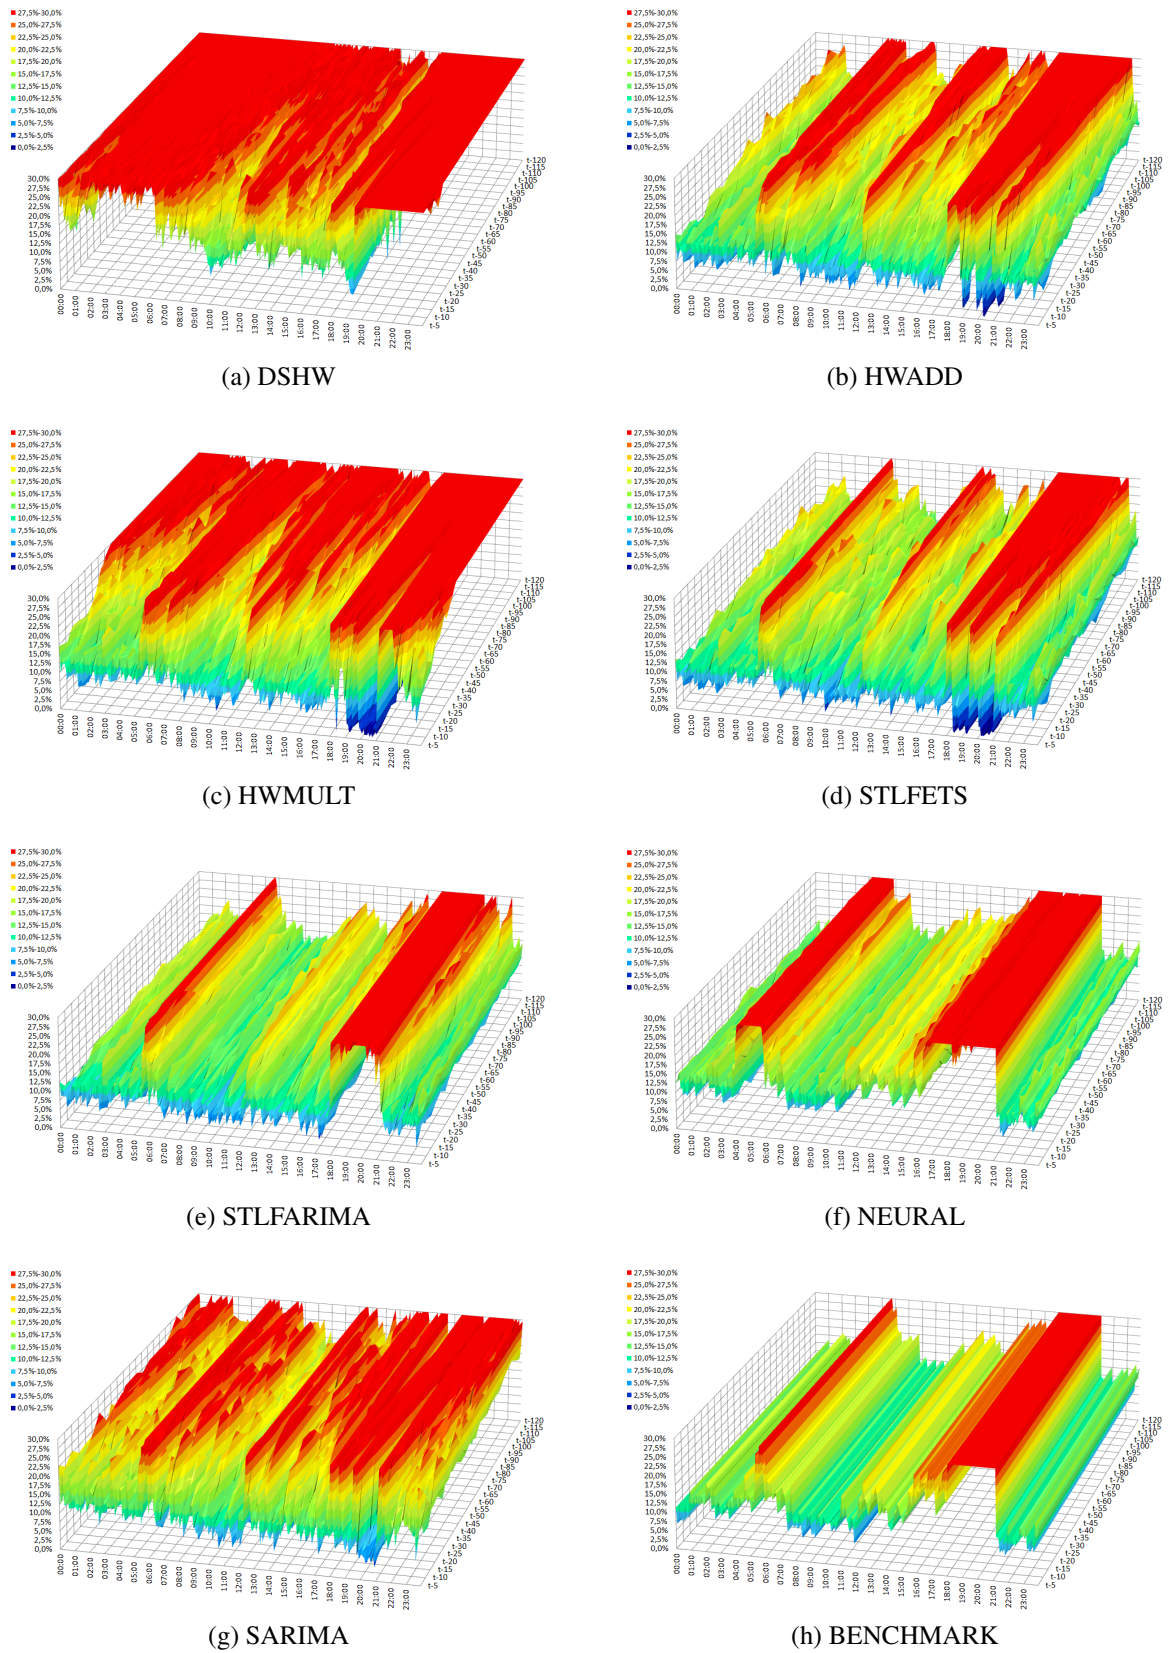


Figura A.13: Relevo dos erros percentuais do consumidor D - Método X Horizonte X Horário

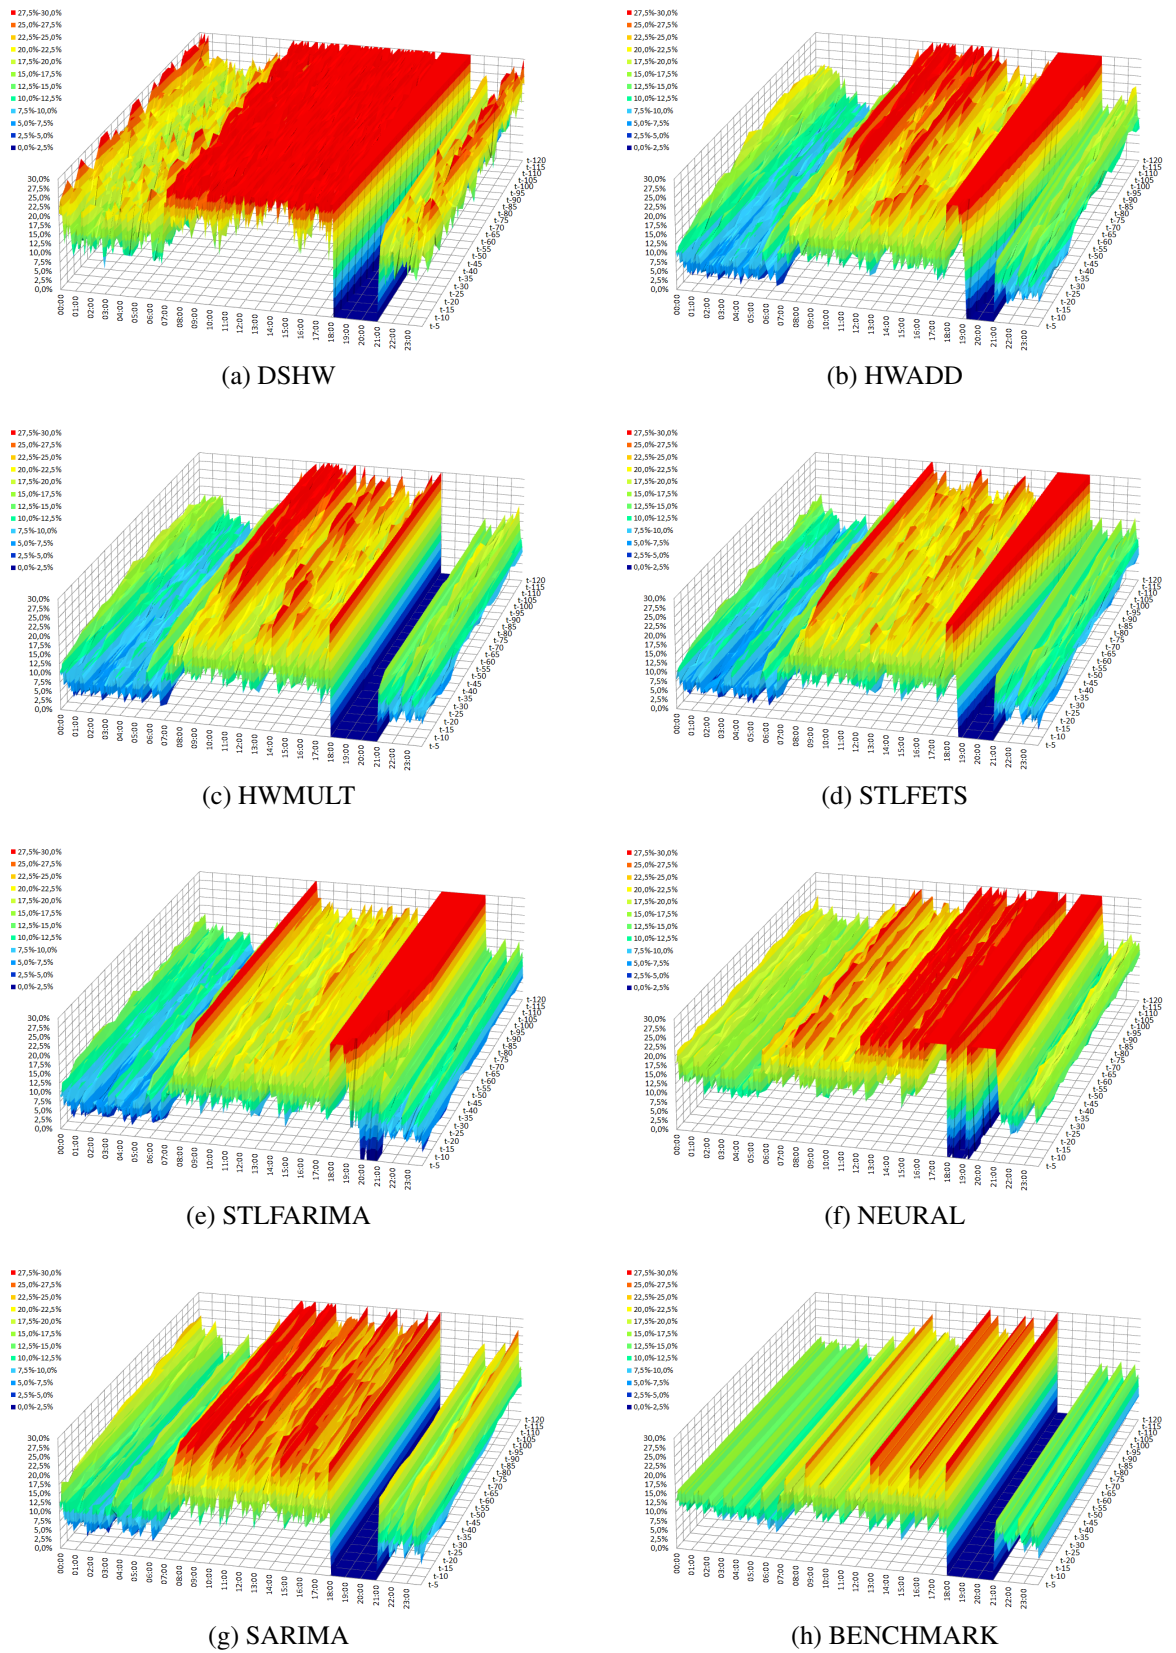


Figura A.14: Relevo dos erros percentuais do consumidor E - Método X Horizonte X Horário

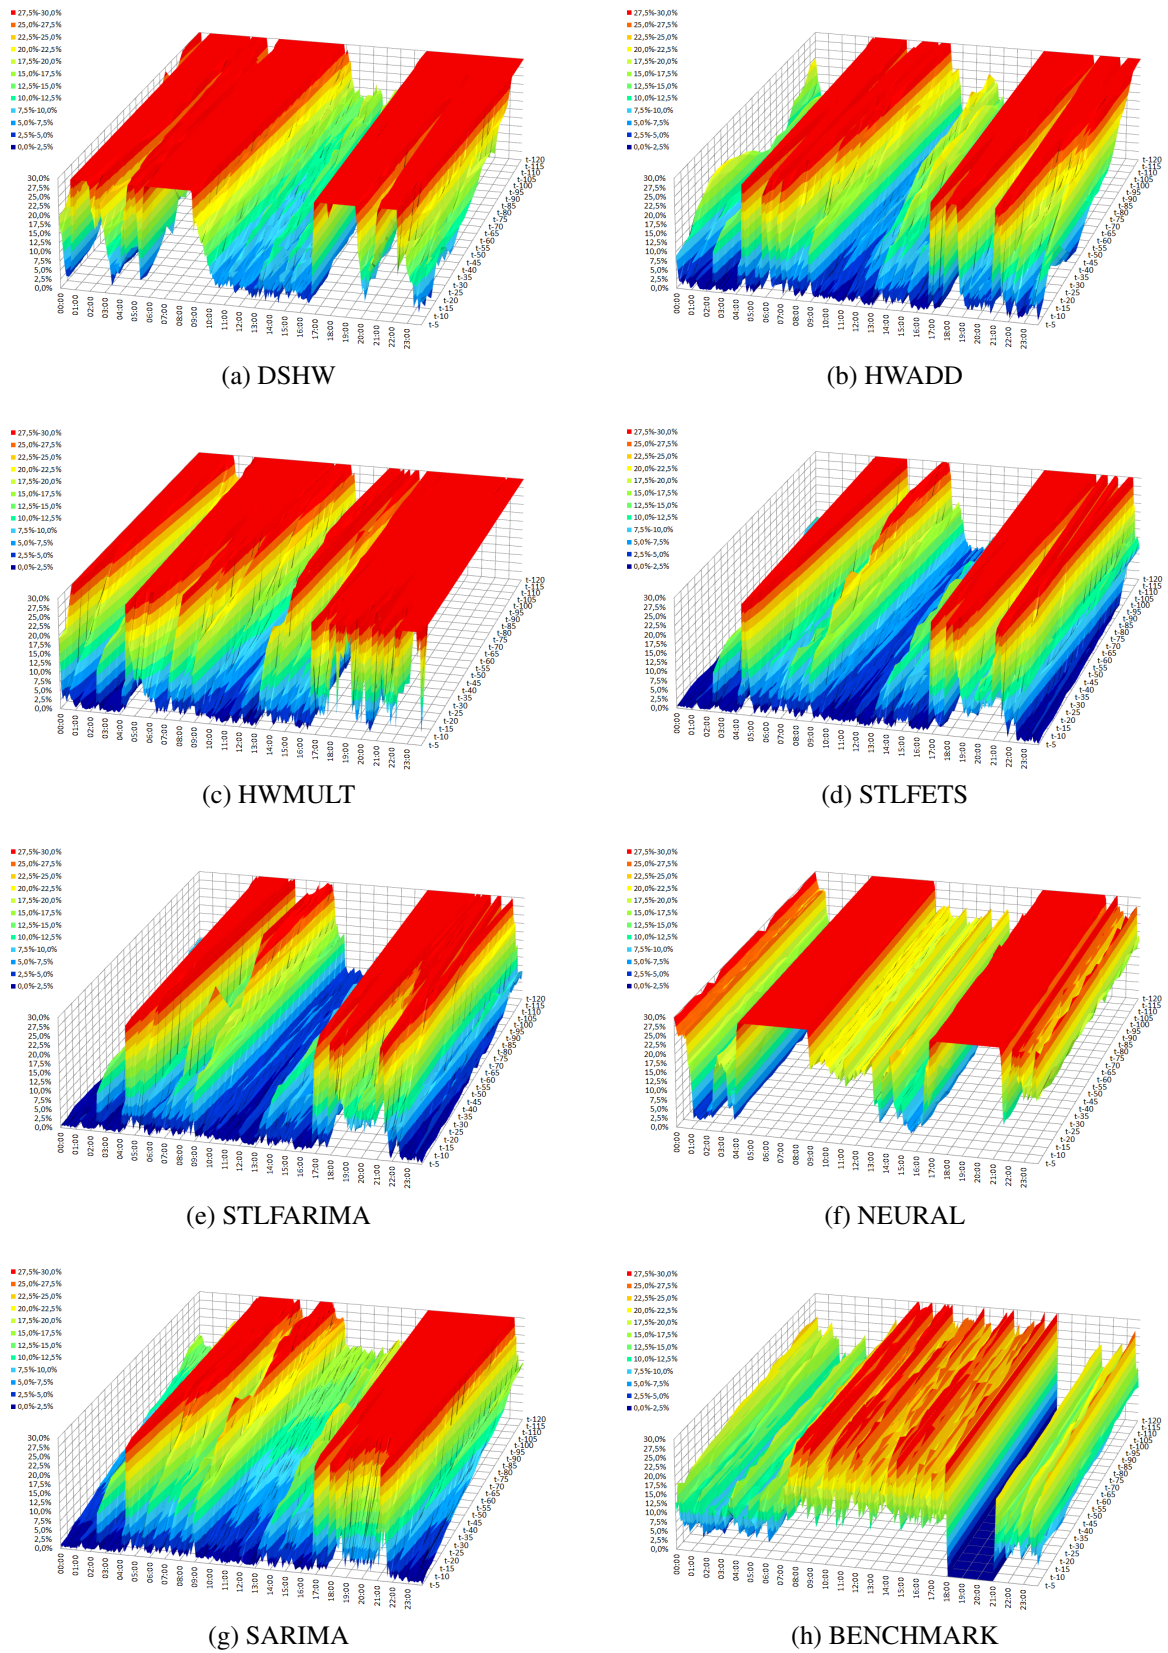


Figura A.15: Relevo dos erros percentuais do consumidor F - Método X Horizonte X Horário

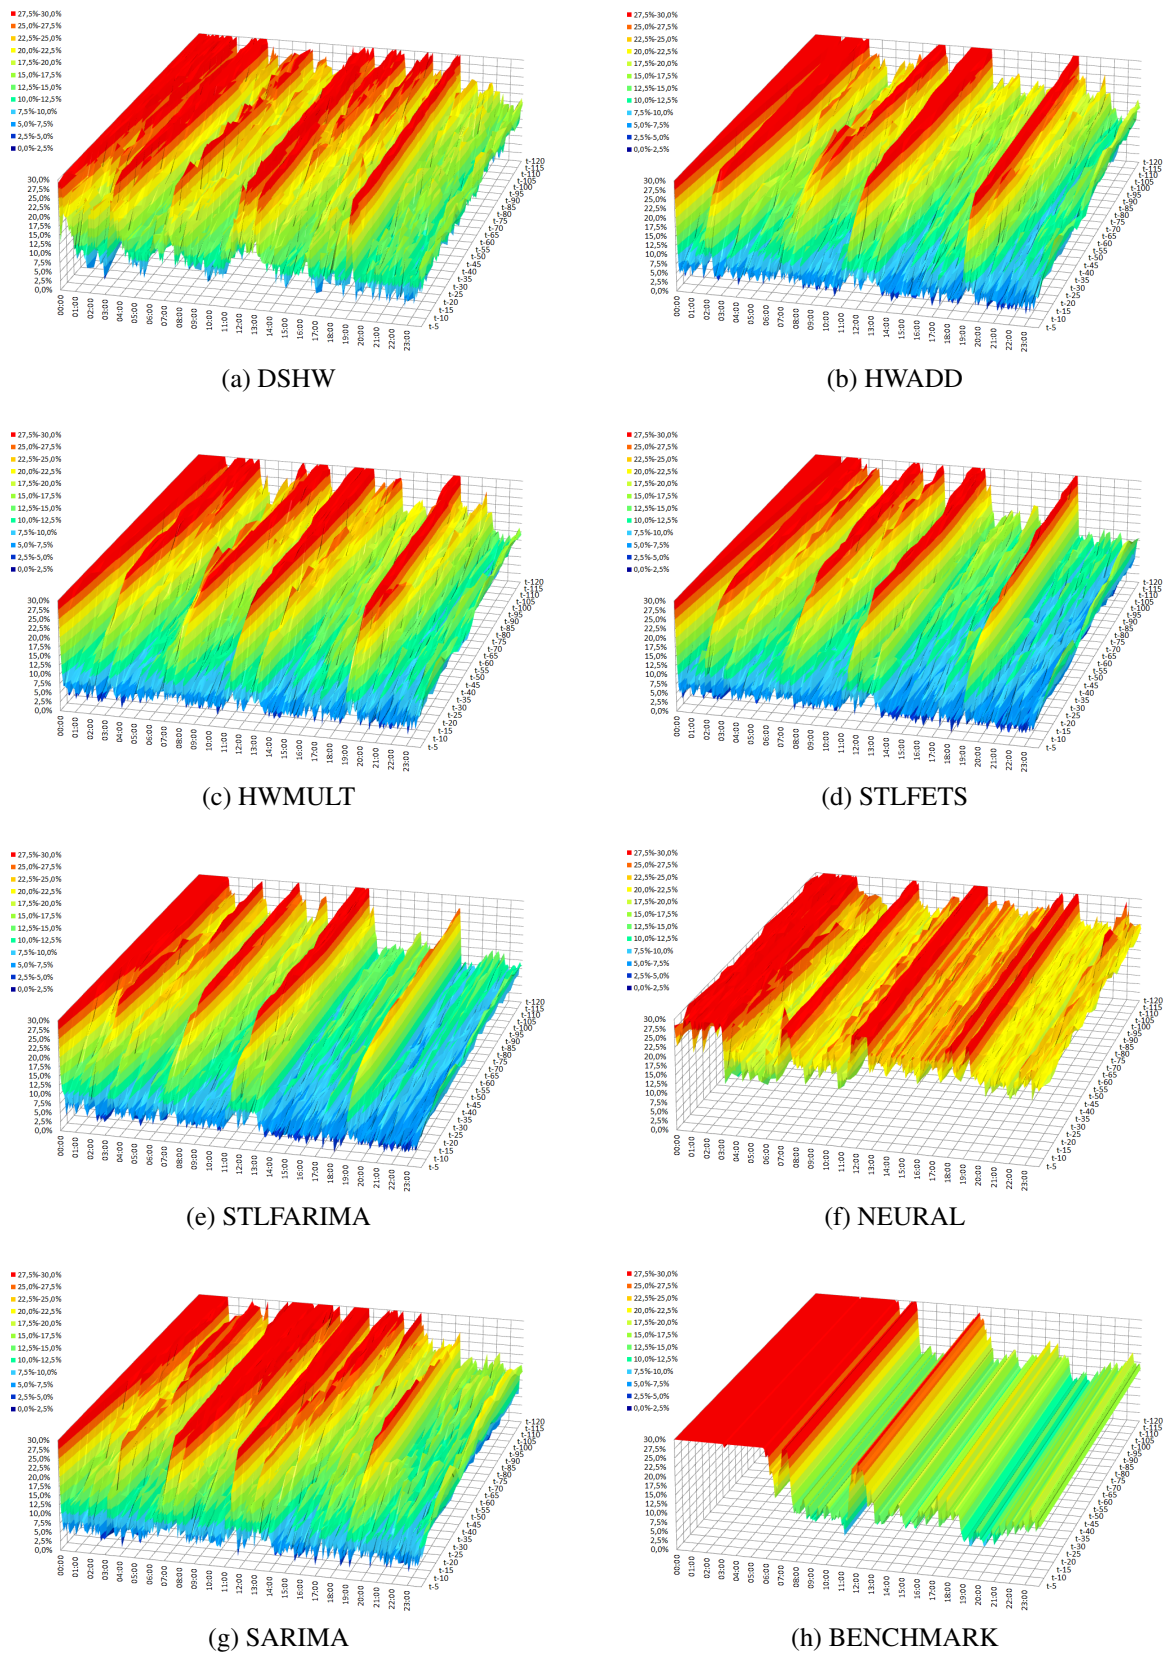


Figura A.16: Relevo dos erros percentuais do consumidor G - Método X Horizonte X Horário



Figura A.17: Legenda de cores dos mapeamentos dos métodos com menor erro em cada hora e horizonte




Figura A.18: Consumidor A1: Mapeamento dos métodos com menor erro em função do horário e horizonte de previsão




Figura A.19: Consumidor A2: Mapeamento dos métodos com menor erro em função do horário e horizonte de previsão




Figura A.20: Consumidor B: Mapeamento dos métodos com menor erro em função do horário e horizonte de previsão




Figura A.21: Consumidor C: Mapeamento dos métodos com menor erro em função do horário e horizonte de previsão




Figura A.22: Consumidor D: Mapeamento dos métodos com menor erro em função do horário e horizonte de previsão




Figura A.23: Consumidor E: Mapeamento dos métodos com menor erro em função do horário e horizonte de previsão




Figura A.24: Consumidor F: Mapeamento dos métodos com menor erro em função do horário e horizonte de previsão




Figura A.25: Consumidor G: Mapeamento dos métodos com menor erro em função do horário e horizonte de previsão

ANEXO B – Tabelas e gráficos com resultados do capítulo 4

Horiz	HWMULT	AVG	SELECT	AVG2	SELECT2	REG2	AVG3	Ingênuo
t-5	5,1%	9,7%	6,4%	5,4%	5,1%	5,0%	5,1%	4,7%
t-10	6,5%	10,2%	7,5%	6,5%	6,5%	6,2%	6,4%	6,3%
t-15	7,2%	10,6%	8,0%	7,1%	7,2%	6,8%	7,0%	7,4%
t-20	7,8%	10,7%	8,5%	7,6%	7,7%	7,2%	7,4%	8,4%
t-25	8,5%	10,9%	9,0%	7,9%	8,2%	7,8%	7,9%	9,5%
t-30	9,1%	11,2%	9,7%	8,4%	8,6%	8,3%	8,3%	10,6%
t-35	9,9%	11,5%	10,0%	8,9%	8,9%	9,2%	8,9%	11,9%
t-40	10,4%	11,8%	10,6%	9,5%	9,4%	10,0%	9,3%	13,1%
t-45	10,7%	11,9%	10,9%	9,6%	9,6%	10,5%	9,4%	14,1%
t-50	11,2%	12,2%	11,3%	9,9%	10,0%	11,2%	9,6%	15,1%
t-55	11,8%	12,6%	11,8%	10,4%	10,8%	12,0%	10,2%	16,5%
t-60	12,4%	13,0%	12,7%	11,0%	11,4%	12,7%	10,6%	17,9%
t-65	12,8%	13,2%	13,0%	11,3%	11,7%	13,0%	10,6%	18,9%
t-70	13,3%	13,5%	13,5%	11,8%	12,3%	13,8%	10,8%	20,1%
t-75	13,8%	13,8%	14,1%	12,1%	12,7%	14,4%	11,0%	21,3%
t-80	14,2%	14,2%	14,4%	12,4%	13,0%	15,1%	11,4%	22,4%
t-85	14,7%	14,6%	14,8%	12,8%	13,6%	16,1%	11,8%	23,7%
t-90	15,0%	14,9%	15,4%	13,3%	13,5%	16,7%	12,2%	24,9%
t-95	15,4%	15,2%	15,5%	13,7%	13,7%	17,2%	12,4%	25,9%
t-100	15,8%	15,5%	15,8%	14,0%	14,1%	17,8%	12,8%	27,1%
t-105	16,3%	16,0%	16,4%	14,5%	14,6%	18,3%	13,1%	28,4%
t-110	16,8%	16,3%	16,9%	14,9%	14,9%	18,9%	13,3%	29,8%
t-115	17,2%	16,7%	16,8%	15,3%	15,3%	19,3%	13,5%	31,0%
t-120	17,5%	17,0%	17,6%	15,5%	15,6%	19,8%	13,5%	32,2%

Tabela B.1: Consumidor A1: MAPE dos métodos de combinação e métodos de avaliação




Figura B.1: Consumidor A1: MAPE dos métodos de combinação e métodos de avaliação

Horiz.	SARIMA	AVG	SELECT	AVG2	SELECT2	REG2	AVG3	Ingênuo
t-5	5,1%	5,6%	5,2%	4,4%	4,3%	4,3%	4,2%	4,0%
t-10	5,7%	6,0%	6,1%	5,1%	5,0%	4,8%	4,7%	5,0%
t-15	6,0%	6,2%	6,5%	5,4%	5,4%	5,1%	5,0%	5,8%
t-20	6,3%	6,5%	6,9%	5,9%	5,7%	5,4%	5,3%	6,5%
t-25	6,5%	6,6%	7,3%	6,0%	5,8%	5,6%	5,5%	7,3%
t-30	6,8%	6,9%	7,5%	6,5%	6,1%	6,0%	5,7%	8,2%
t-35	7,1%	7,2%	7,8%	6,6%	6,3%	6,4%	6,0%	9,1%
t-40	7,3%	7,3%	8,1%	6,9%	6,4%	6,6%	6,1%	9,8%
t-45	7,7%	7,5%	8,4%	7,0%	6,7%	7,0%	6,5%	10,7%
t-50	8,0%	7,8%	8,8%	7,4%	7,1%	7,4%	6,8%	11,7%
t-55	8,3%	8,1%	9,3%	7,7%	7,2%	7,5%	7,0%	12,6%
t-60	8,6%	8,3%	9,5%	8,0%	7,3%	7,8%	7,3%	13,6%
t-65	8,7%	8,4%	10,1%	8,3%	7,3%	8,0%	7,4%	14,3%
t-70	8,8%	8,6%	10,2%	8,3%	7,3%	8,1%	7,4%	15,0%
t-75	9,0%	8,9%	10,7%	8,8%	7,6%	8,5%	7,7%	16,0%
t-80	9,0%	8,9%	10,7%	8,9%	7,6%	8,6%	7,8%	16,7%
t-85	9,3%	9,1%	11,0%	9,0%	7,9%	8,8%	8,0%	17,6%
t-90	9,5%	9,4%	11,3%	9,4%	8,1%	9,0%	8,0%	18,4%
t-95	9,6%	9,6%	11,9%	9,6%	8,3%	9,3%	8,2%	19,2%
t-100	9,8%	9,9%	12,3%	10,0%	8,9%	9,6%	8,5%	20,1%
t-105	9,8%	10,0%	12,2%	10,0%	8,7%	9,6%	8,6%	20,8%
t-110	9,9%	10,2%	12,8%	10,3%	8,8%	9,8%	8,8%	21,6%
t-115	9,9%	10,4%	12,8%	10,5%	9,1%	9,8%	8,9%	22,4%
t-120	10,0%	10,6%	12,7%	10,6%	9,3%	10,1%	9,0%	23,2%

Tabela B.2: Consumidor A2: MAPE dos métodos de combinação e métodos de avaliação




Figura B.2: Consumidor A2: MAPE dos métodos de combinação e métodos de avaliação

Horiz.	STLFARIMA	AVG	SELECT	AVG2	SELECT2	REG2	AVG3	Ingênuo
t-5	18,8%	29,0%	21,9%	38,3%	21,0%	21,0%	18,3%	15,2%
t-10	23,1%	33,9%	29,1%	52,7%	27,5%	30,1%	23,8%	22,6%
t-15	27,4%	37,0%	35,7%	70,2%	32,2%	37,6%	27,8%	32,2%
t-20	31,5%	39,9%	37,2%	87,0%	38,4%	42,4%	32,2%	42,1%
t-25	35,0%	42,2%	41,2%	104,5%	40,1%	44,2%	35,5%	51,8%
t-30	38,4%	45,0%	44,7%	118,9%	42,8%	45,4%	38,4%	61,6%
t-35	41,4%	47,0%	46,3%	130,7%	44,6%	48,4%	41,2%	72,3%
t-40	43,2%	49,8%	49,1%	154,8%	47,0%	49,3%	43,3%	82,3%
t-45	46,1%	52,9%	58,7%	169,2%	50,1%	53,5%	46,2%	92,6%
t-50	47,2%	55,2%	63,5%	182,6%	52,4%	53,1%	48,5%	103,5%
t-55	47,6%	56,1%	64,6%	204,6%	52,7%	52,9%	49,1%	114,8%
t-60	48,5%	58,2%	66,9%	222,2%	55,7%	52,7%	48,9%	124,7%
t-65	49,3%	59,3%	72,3%	216,2%	56,8%	51,8%	50,3%	132,4%
t-70	49,5%	60,4%	68,7%	213,2%	57,6%	50,7%	50,3%	137,3%
t-75	49,3%	67,0%	74,9%	307,9%	55,1%	50,7%	54,7%	141,2%
t-80	49,7%	62,4%	76,4%	241,6%	52,4%	51,1%	49,6%	145,8%
t-85	50,2%	64,6%	80,3%	271,3%	52,5%	53,1%	49,4%	151,5%
t-90	50,7%	66,0%	82,3%	263,8%	52,4%	53,6%	49,9%	156,9%
t-95	50,8%	67,7%	85,7%	260,8%	53,1%	54,8%	51,6%	163,3%
t-100	51,6%	69,2%	83,8%	265,4%	53,3%	55,3%	50,8%	169,4%
t-105	52,0%	71,2%	92,2%	273,0%	53,4%	55,0%	51,0%	176,3%
t-110	52,2%	74,2%	87,5%	278,9%	52,2%	54,8%	51,1%	181,2%
t-115	51,8%	76,0%	86,0%	293,2%	50,5%	54,8%	50,7%	186,8%
t-120	52,4%	77,2%	89,6%	288,1%	50,2%	54,1%	51,0%	192,2%

Tabela B.3: Consumidor B: MAPE dos métodos de combinação e métodos de avaliação




Figura B.3: Consumidor B: MAPE dos métodos de combinação e métodos de avaliação

Horiz.	SARIMA	AVG	SELECT	AVG2	SELECT2	REG2	AVG3	Ingênuo
t-5	15,0%	22,3%	16,2%	12,8%	14,9%	17,7%	13,5%	12,1%
t-10	17,6%	24,9%	21,7%	17,4%	20,2%	26,7%	18,5%	19,4%
t-15	19,6%	26,9%	23,9%	19,4%	23,9%	30,3%	22,0%	27,0%
t-20	21,4%	28,5%	28,3%	22,6%	27,3%	32,1%	24,1%	35,9%
t-25	22,9%	30,4%	29,8%	23,8%	29,7%	36,1%	26,2%	43,9%
t-30	23,9%	31,3%	29,3%	25,1%	31,7%	39,3%	27,9%	51,5%
t-35	24,6%	33,4%	29,2%	25,7%	31,4%	42,0%	27,9%	59,1%
t-40	25,5%	34,3%	33,2%	27,5%	31,9%	44,5%	28,6%	67,0%
t-45	26,1%	35,5%	33,0%	28,8%	32,8%	45,4%	29,2%	75,1%
t-50	26,5%	36,6%	36,6%	31,0%	32,5%	46,3%	29,8%	83,7%
t-55	26,8%	38,7%	38,3%	32,9%	32,8%	46,5%	30,1%	92,0%
t-60	26,9%	40,3%	40,8%	33,9%	32,9%	47,5%	30,6%	101,0%
t-65	27,4%	41,2%	41,2%	35,6%	32,5%	47,6%	31,6%	108,8%
t-70	27,5%	42,7%	41,9%	37,5%	32,5%	47,2%	31,3%	117,2%
t-75	27,5%	44,0%	41,9%	40,0%	32,7%	46,8%	31,2%	125,1%
t-80	27,6%	44,5%	41,5%	38,7%	33,0%	47,1%	30,8%	130,5%
t-85	27,6%	45,9%	44,4%	41,0%	32,9%	47,2%	31,5%	137,2%
t-90	27,6%	48,7%	44,2%	39,2%	33,3%	47,1%	32,0%	144,0%
t-95	27,7%	48,7%	46,4%	41,6%	33,0%	46,6%	31,5%	150,3%
t-100	27,6%	49,6%	44,1%	39,2%	32,6%	46,1%	31,6%	157,4%
t-105	27,6%	50,5%	45,2%	41,4%	32,1%	46,4%	31,7%	164,3%
t-110	27,7%	51,3%	45,6%	41,1%	32,5%	46,4%	32,5%	170,7%
t-115	27,7%	51,6%	45,3%	42,1%	32,5%	47,3%	32,8%	177,1%
t-120	27,7%	53,4%	49,1%	45,7%	32,7%	48,4%	32,7%	184,0%

Tabela B.4: Consumidor C: MAPE dos métodos de combinação e métodos de avaliação




Figura B.4: Consumidor C: MAPE dos métodos de combinação e métodos de avaliação

Horiz.	BENCH	AVG	SELECT	AVG2	SELECT2	REG2	AVG3	Ingênuo
t-5	25,6%	22,7%	12,9%	11,4%	15,3%	18,5%	14,8%	18,0%
t-10	25,6%	26,7%	17,7%	16,0%	18,6%	23,9%	18,7%	32,4%
t-15	25,6%	28,4%	20,6%	19,9%	21,7%	28,9%	21,3%	44,7%
t-20	25,6%	32,0%	23,8%	23,2%	24,8%	33,4%	24,6%	59,2%
t-25	25,6%	34,3%	27,1%	26,3%	25,9%	35,0%	26,0%	72,4%
t-30	25,6%	36,3%	28,9%	28,7%	27,2%	37,0%	28,1%	84,6%
t-35	25,6%	38,6%	32,4%	31,6%	31,0%	39,6%	29,7%	98,1%
t-40	25,6%	40,7%	34,0%	35,9%	33,3%	44,2%	31,4%	110,5%
t-45	25,6%	42,4%	39,0%	37,7%	32,4%	44,5%	33,2%	121,2%
t-50	25,6%	44,8%	38,3%	42,2%	35,0%	45,4%	34,0%	133,2%
t-55	25,6%	46,4%	43,4%	44,3%	36,3%	46,8%	33,9%	145,2%
t-60	25,6%	48,8%	46,0%	48,4%	36,1%	47,4%	34,2%	156,8%
t-65	25,6%	51,3%	49,2%	52,6%	34,6%	48,7%	34,1%	168,8%
t-70	25,6%	53,9%	57,1%	58,1%	35,0%	48,2%	34,4%	180,0%
t-75	25,6%	55,0%	69,0%	63,1%	34,5%	49,5%	34,9%	190,7%
t-80	25,6%	56,9%	65,4%	67,6%	33,9%	49,7%	34,9%	201,9%
t-85	25,6%	58,6%	69,6%	70,9%	34,6%	50,9%	35,5%	213,6%
t-90	25,6%	62,4%	76,6%	77,9%	35,5%	52,1%	36,5%	225,0%
t-95	25,6%	61,5%	77,2%	75,7%	36,2%	56,6%	39,2%	235,8%
t-100	25,6%	64,8%	77,5%	81,7%	36,1%	58,9%	39,8%	247,1%
t-105	25,6%	65,3%	76,9%	79,8%	36,5%	56,5%	36,2%	257,8%
t-110	25,6%	64,9%	76,9%	77,1%	37,1%	56,8%	36,7%	267,7%
t-115	25,6%	66,6%	72,4%	74,1%	38,1%	54,4%	36,2%	277,5%
t-120	25,6%	67,3%	76,4%	75,3%	38,9%	56,6%	34,5%	287,6%

Tabela B.5: Consumidor D: MAPE dos métodos de combinação e métodos de avaliação




Figura B.5: Consumidor D: MAPE dos métodos de combinação e métodos de avaliação

Horiz.	STLFARIMA	AVG	SELECT	AVG2	SELECT2	REG2	AVG3	Ingênuo
t-5	18,8%	29,0%	21,9%	38,3%	21,0%	21,0%	18,3%	15,2%
t-10	23,1%	33,9%	29,1%	52,7%	27,5%	30,1%	23,8%	22,6%
t-15	27,4%	37,0%	35,7%	70,2%	32,2%	37,6%	27,8%	32,2%
t-20	31,5%	39,9%	37,2%	87,0%	38,4%	42,4%	32,2%	42,1%
t-25	35,0%	42,2%	41,2%	104,5%	40,1%	44,2%	35,5%	51,8%
t-30	38,4%	45,0%	44,7%	118,9%	42,8%	45,4%	38,4%	61,6%
t-35	41,4%	47,0%	46,3%	130,7%	44,6%	48,4%	41,2%	72,3%
t-40	43,2%	49,8%	49,1%	154,8%	47,0%	49,3%	43,3%	82,3%
t-45	46,1%	52,9%	58,7%	169,2%	50,1%	53,5%	46,2%	92,6%
t-50	47,2%	55,2%	63,5%	182,6%	52,4%	53,1%	48,5%	103,5%
t-55	47,6%	56,1%	64,6%	204,6%	52,7%	52,9%	49,1%	114,8%
t-60	48,5%	58,2%	66,9%	222,2%	55,7%	52,7%	48,9%	124,7%
t-65	49,3%	59,3%	72,3%	216,2%	56,8%	51,8%	50,3%	132,4%
t-70	49,5%	60,4%	68,7%	213,2%	57,6%	50,7%	50,3%	137,3%
t-75	49,3%	67,0%	74,9%	307,9%	55,1%	50,7%	54,7%	141,2%
t-80	49,7%	62,4%	76,4%	241,6%	52,4%	51,1%	49,6%	145,8%
t-85	50,2%	64,6%	80,3%	271,3%	52,5%	53,1%	49,4%	151,5%
t-90	50,7%	66,0%	82,3%	263,8%	52,4%	53,6%	49,9%	156,9%
t-95	50,8%	67,7%	85,7%	260,8%	53,1%	54,8%	51,6%	163,3%
t-100	51,6%	69,2%	83,8%	265,4%	53,3%	55,3%	50,8%	169,4%
t-105	52,0%	71,2%	92,2%	273,0%	53,4%	55,0%	51,0%	176,3%
t-110	52,2%	74,2%	87,5%	278,9%	52,2%	54,8%	51,1%	181,2%
t-115	51,8%	76,0%	86,0%	293,2%	50,5%	54,8%	50,7%	186,8%
t-120	52,4%	77,2%	89,6%	288,1%	50,2%	54,1%	51,0%	192,2%

Tabela B.6: Consumidor E: MAPE dos métodos de combinação e métodos de avaliação




Figura B.6: Consumidor E: MAPE dos métodos de combinação e métodos de avaliação

Horiz.	STLFARIMA	AVG	SELECT	AVG2	SELECT2	REG2	AVG3	Ingênuo
t-5	5,4%	26,5%	5,2%	4,3%	4,4%	4,2%	4,2%	3,7%
t-10	9,3%	26,2%	11,2%	8,9%	9,4%	9,9%	8,1%	7,8%
t-15	13,0%	29,7%	13,7%	12,7%	13,2%	15,6%	12,1%	12,4%
t-20	16,0%	30,6%	19,7%	17,3%	17,2%	22,1%	15,8%	17,0%
t-25	18,3%	34,7%	24,3%	23,5%	21,4%	27,3%	20,3%	21,6%
t-30	20,4%	39,8%	30,4%	29,3%	24,8%	32,8%	23,9%	26,3%
t-35	22,3%	39,6%	31,2%	24,9%	27,6%	36,3%	26,0%	31,0%
t-40	24,3%	45,3%	35,2%	27,6%	30,4%	40,3%	28,9%	35,6%
t-45	26,3%	46,7%	30,6%	37,3%	33,3%	44,3%	31,0%	40,2%
t-50	28,2%	46,6%	35,4%	32,8%	36,1%	47,1%	32,9%	44,8%
t-55	30,3%	45,5%	35,4%	29,6%	39,0%	50,2%	35,8%	49,5%
t-60	32,4%	55,8%	40,8%	32,3%	34,5%	53,8%	37,7%	54,4%
t-65	34,2%	50,8%	38,5%	31,5%	36,3%	56,5%	40,1%	59,3%
t-70	35,7%	53,2%	40,5%	34,7%	38,0%	58,8%	41,2%	64,3%
t-75	37,0%	55,4%	49,9%	37,2%	39,9%	61,1%	41,1%	69,3%
t-80	38,2%	65,4%	53,1%	39,6%	41,1%	62,9%	42,3%	74,5%
t-85	39,3%	80,6%	54,9%	40,8%	42,3%	65,0%	43,0%	79,7%
t-90	40,4%	67,6%	54,6%	42,0%	43,4%	68,0%	45,9%	85,0%
t-95	41,3%	68,2%	51,3%	45,4%	45,3%	69,6%	46,9%	90,2%
t-100	42,2%	68,2%	49,1%	41,6%	48,2%	71,1%	48,3%	95,5%
t-105	43,1%	71,1%	53,2%	45,0%	52,3%	72,2%	49,7%	100,7%
t-110	44,1%	77,3%	52,4%	48,3%	53,2%	72,6%	51,6%	106,0%
t-115	44,9%	78,3%	56,2%	47,1%	54,2%	72,7%	53,6%	111,4%
t-120	45,8%	81,2%	56,3%	48,9%	54,9%	74,4%	54,6%	116,7%

Tabela B.7: Consumidor F: MAPE dos métodos de combinação e métodos de avaliação




Figura B.7: Consumidor F: MAPE dos métodos de combinação e métodos de avaliação

Horiz.	STLFARIMA	AVG	SELECT	AVG2	SELECT2	REG2	AVG3	Ingênuo
t-5	6,7%	8,4%	7,6%	6,7%	6,6%	6,5%	6,4%	5,9%
t-10	8,7%	9,6%	9,8%	8,8%	8,7%	8,5%	8,4%	8,4%
t-15	10,0%	10,4%	10,9%	10,0%	9,9%	10,0%	9,6%	10,1%
t-20	11,1%	11,1%	12,1%	11,0%	11,0%	11,2%	10,6%	11,6%
t-25	12,1%	11,7%	13,2%	12,0%	11,9%	12,1%	11,5%	13,0%
t-30	12,9%	12,3%	13,8%	12,5%	12,8%	12,7%	12,1%	14,4%
t-35	13,7%	12,8%	14,7%	13,1%	13,9%	13,6%	12,8%	15,7%
t-40	14,4%	13,3%	15,2%	13,9%	14,6%	14,3%	13,4%	16,9%
t-45	15,0%	13,7%	16,0%	14,7%	15,1%	14,8%	14,0%	18,0%
t-50	15,4%	14,0%	16,3%	15,2%	15,5%	15,1%	14,6%	19,0%
t-55	15,9%	14,4%	16,8%	15,9%	16,2%	15,8%	15,0%	20,0%
t-60	16,3%	14,7%	17,5%	16,2%	16,6%	16,1%	15,3%	21,0%
t-65	16,7%	15,0%	17,6%	16,5%	17,5%	16,4%	15,6%	21,8%
t-70	17,1%	15,3%	18,1%	16,7%	17,7%	16,8%	15,9%	22,6%
t-75	17,6%	15,7%	18,2%	17,1%	17,8%	17,3%	16,3%	23,5%
t-80	18,0%	16,0%	18,7%	17,4%	18,1%	17,7%	16,5%	24,3%
t-85	18,3%	16,3%	19,0%	17,8%	18,6%	18,1%	16,8%	25,0%
t-90	18,6%	16,6%	19,4%	18,2%	18,9%	18,4%	17,2%	25,6%
t-95	18,9%	16,8%	20,2%	18,6%	19,2%	18,6%	17,4%	26,1%
t-100	19,1%	17,0%	20,3%	18,8%	19,2%	18,6%	17,6%	26,6%
t-105	19,4%	17,2%	20,2%	18,8%	19,1%	19,1%	17,9%	27,1%
t-110	19,6%	17,5%	20,6%	19,2%	19,3%	19,4%	18,0%	27,4%
t-115	19,8%	17,7%	20,8%	19,7%	19,6%	19,5%	18,1%	27,8%
t-120	20,0%	18,0%	21,2%	19,6%	20,1%	20,0%	18,2%	28,2%

Tabela B.8: Consumidor G: MAPE dos métodos de combinação e métodos de avaliação




Figura B.8: Consumidor G: MAPE dos métodos de combinação e métodos de avaliação