

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO

Filipe Rissieri Lucini

**MÉTODO PARA IDENTIFICAÇÃO DE QUEDAS DE
CONSUMO ATÍPICAS EM UNIDADES CONSUMIDORAS DE
ENERGIA ELÉTRICA**

Porto Alegre

2010

Filipe Rissieri Lucini

**Método para Identificação de Quedas de Consumo Atípicas em Unidades Consumidoras
de Energia Elétrica**

Dissertação submetida ao Programa de Pós-Graduação em Engenharia de Produção da Universidade Federal do Rio Grande do Sul como requisito parcial à obtenção do título de Mestre em Engenharia de Produção, modalidade Profissional, na área de concentração em Sistemas de Qualidade.

Orientador: Flávio Sanson Fogliatto, *Ph.D.*

Porto Alegre

2010

Filipe Rissieri Lucini

**Método para Identificação de Quedas de Consumo Atípicas em Unidades Consumidoras
de Energia Elétrica**

Esta dissertação foi julgada adequada para a obtenção do título de Mestre em Engenharia de Produção na modalidade Profissional e aprovada em sua forma final pelo Orientador e pela Banca Examinadora designada pelo Programa de Pós-Graduação em Engenharia de Produção da Universidade Federal do Rio Grande do Sul.

Prof. Flávio Sanson Fogliatto, *Ph.D.*

Orientador PPGEP/UFRGS

Prof. Carla Schwengber ten Caten, *Dra.*

Coordenadora PPGEP/UFRGS

Banca Examinadora:

Professora Christine Tessele Nodari, *Dra.* (PPGEP/UFRGS)

Professor José Luis Duarte Ribeiro, *Dr.* (PPGEP/UFRGS)

Professor Leonardo Rocha de Oliveira, *Ph.D.* (PPGAd/PUCRS)

Aos meus pais, João Carlos e Maria Regina,
responsáveis pela minha educação e pelo
estímulo na busca do conhecimento.

AGRADECIMENTOS

Meus sinceros agradecimentos a todos que, direta ou indiretamente, contribuíram para a realização desta dissertação. Especialmente, agradeço:

À minha família, pelo incentivo e apoio durante esta jornada.

A todos os professores e funcionários do Programa de Pós-Graduação em Engenharia de Produção da Universidade Federal do Rio Grande do Sul, pelos conhecimentos compartilhados e pela contribuição na minha formação.

Ao meu orientador, professor Flávio Sanson Fogliatto, pela orientação, incentivo e paciência.

Aos colegas da Rio Grande Energia SA. que colaboraram com a realização desse trabalho. Em especial, agradeço à Eng. Lianete Margot Klauck e ao gerente João Duro Aldavez, pela oportunidade e confiança.

Aos colegas de mestrado, pela convivência e troca de experiências. Em especial, ao colega Claudio Saenger Fortes, pela amizade desde a época de Especialização.

E a Deus por me guiar na realização de mais um objetivo pessoal e profissional.

RESUMO

Esse trabalho tem por objetivo aprimorar a principal atividade das empresas de distribuição no que diz respeito ao combate às perdas comerciais: as inspeções em campo às unidades consumidoras (UCs). Para tanto, é feita a proposição de um método para identificar quedas de consumo atípicas dentro do universo de faturamento de UCs de uma concessionária de energia elétrica. A proposta está fundamentada na análise dos registros históricos de consumo, de modo que os dados considerados atípicos possam ser indicados e as UCs ranqueadas de acordo com a prioridade para as inspeções em campo. Para tanto, propõe-se a utilização combinada de técnicas de previsão de demanda e de estatísticas robustas. A validade do método foi verificada através de um estudo de caso em uma empresa de distribuição de energia elétrica do sul do Brasil. Através do estudo de caso, concluiu-se que o método é capaz de identificar quedas de consumo atípicas, tendo identificado satisfatoriamente 89,38% dos casos avaliados. Ao final do trabalho, são apresentadas sugestões de estudos complementares, de modo a aperfeiçoar o desempenho do método.

Palavras-chave: Distribuição de energia elétrica, perdas comerciais, previsão de demanda.

ABSTRACT

This study aims to enhance the main business of distribution companies regarding to the efforts to avoid non-technical losses, that means, field inspections at the consumer units (CUs). For that, the proposition of an algorithm to identify atypical consumption falls within the universe of PAs billing of an electric facility is made. The proposal is based on the analysis of historical records of consumption, so that the data which are considered atypical can be indicated and the CUs ranked according to their priority for inspections in the field. Combined techniques of demand forecasting and statistics robust are proposed. The validity of the algorithm was verified through a case study in an electric power distribution facility in southern Brazil. Through the case study, it was concluded that the algorithm is able to identify atypical consumption falls, and satisfactorily 89.38% of the cases was identified. At the end of this paper, suggestions for further studies in order to improve the performance of the algorithm are presented.

Keywords: Demand forecast, electric power distribution, non-technical losses.

LISTA DE FIGURAS

Figura 1: Seqüência de execução do método de Box-Jenkins.....	38
Figura 2: Ajuste subjetivo de previsões.....	51
Figura 3: Decomposição de séries temporais.....	53
Figura 4: Combinação de métodos quantitativos e qualitativos.....	55
Figura 5: Desenvolvimento de um método de previsão que integra métodos quantitativos e qualitativos.....	58
Figura 6: Integração entre métodos de previsão – linha pontilhadas indicam possíveis relações.....	59
Figura 7: Esquema de tabelas do banco de dados relacional.....	64
Figura 8: Área de Concessão da RGE.....	68
Figura 9: Evolução da perda comercial na RGE em GWh/ano.....	71
Figura 10: Número de inspeções realizadas na área de concessão da RGE.....	73
Figura 11: Número de períodos de leitura das séries temporais da amostra-piloto.....	74
Figura 12: Distribuição de UCs por classe de consumo.....	75
Figura 13: Energia registrada por classe de consumo no período analisado.....	75
Figura 14: Distribuição das UCs por tipo de fornecimento.....	76
Figura 15: Energia registrada por tipo de fornecimento no período analisado.....	76
Figura 16: Histórico de consumo de uma UC industrial de Flores da Cunha.....	77
Figura 17: Histórico de consumo de uma UC residencial de Flores da Cunha.....	78
Figura 18: Série de referência das 30 UCs selecionadas.....	81
Figura 19: Análise de Autocorrelação da série de referência.....	82
Figura 20: Aba “Método 1”.....	89
Figura 21: Aba “Análise de QCA”.....	90
Figura 22: Aba “Análise Gráfica”.....	92
Figura 23: Manipulação dos mancais de apoio do elemento móvel (disco) do medidor.....	94
Figura 24: <i>Junper</i>	96
Figura 25: Disco travado.....	97
Figura 26: Elo de potencial aberto.....	98
Figura 27: Outras irregularidades.....	99
Figura 28: Série artificial utilizada para testes extremamente sazonais.....	100
Figura 29: Exemplo de série de teste para quedas contínuas.....	100
Figura 30: Exemplo de série de teste para quedas cíclicas.....	101

Figura 31: Exemplo de série de teste para quedas sazonais	102
Figura 32: Comparação entre os valores previstos e a série original para o teste nº 16.....	109
Figura 33: Comparação entre os valores previstos e a série original para o teste nº 64.....	109
Figura 34: Apresentação gráfica do resultado do teste nº1.....	110
Figura 35: Comportamento do método quando ocorre a antecipação de um mês a contar do 35º período.....	112
Figura 36: Comportamento do método quando ocorre o atraso de um mês a contar do 35º período.....	113
Figura 37: Efeitos da ocorrência de QCAs durante o período de calibração do método	113

LISTA DE TABELAS

Tabela 1: Perdas de Energia Elétrica no Brasil – 1970 a 2001.....	14
Tabela 2: Percentual de Perdas na Distribuição de Energia no Brasil – 2005	17
Tabela 3: Tendências comuns e seus tratamentos em métodos qualitativos	27
Tabela 4: Medidas de Acurácia	47
Tabela 5: Decomposição de séries temporais formadas por agrupamentos	79
Tabela 6: Resumo dos dez métodos de previsão com os melhores desempenhos	83
Tabela 7: Resultados dos testes realizados com a série tradicional e com manipulação a partir do 35º período.....	104
Tabela 8: Resultados dos testes realizados com a série tradicional e com manipulação a partir do 44º período.....	105
Tabela 9: Resultados dos testes realizados com a série tradicional e com manipulação a partir do 53º período.....	106
Tabela 10: Resultados dos testes realizados com a série extremamente sazonal e com manipulação a partir do 35º período.....	107
Tabela 11: Resultados dos testes realizados com a série extremamente sazonal e com manipulação a partir do 44º período.....	107
Tabela 12: Resultados dos testes realizados com a série extremamente sazonal e com manipulação a partir do 53º período.....	108
Tabela 13: Resumo dos Resultados Alcançados – MAPE Calibração.....	130
Tabela 14: Resumo dos Resultados Alcançados – MAPE Previsão	131
Tabela 15: Resumo dos Resultados Alcançados – Theil’s U Calibração.....	132
Tabela 16: Resumo dos Resultados Alcançados – Theil’s U Previsão	133

SUMÁRIO

LISTA DE FIGURAS.....	VIII
LISTA DE TABELAS	X
1 INTRODUÇÃO	13
1.1 TEMAS E OBJETIVOS.....	15
1.1.1 Objetivo geral	15
1.1.2 Objetivos específicos.....	15
1.2 JUSTIFICATIVA DO TEMA E OBJETIVOS	16
1.3 MÉTODO DE TRABALHO	18
1.4 DELIMITAÇÕES DO TRABALHO	19
1.5 ESTRUTURA DO TRABALHO	20
2 REFERENCIAL TEÓRICO	22
2.1 MÉTODOS QUALITATIVOS DE PREVISÃO	25
2.1.1 Jogos de Representação	28
2.1.2 Pesquisa de Intenções	28
2.1.3 Método Delphi.....	29
2.2 MÉTODOS QUANTITATIVOS DE PREVISÃO	30
2.2.1 Extrapolação	31
2.2.2 Análise de Regressão.....	43
2.3 MEDIDAS DE ACURÁCIA.....	46
2.4 INTEGRAÇÃO DE MÉTODOS QUALITATIVOS E QUANTITATIVOS	48
2.4.1 Ajuste Subjetivo	50
2.4.2 Decomposição de séries temporais.....	51
2.4.3 Combinação de Previsões.....	54
2.4.4 Desenvolvimento de Métodos de Previsão.....	57
3 MÉTODO PROPOSTO	60
3.1 ENTENDIMENTO DO NEGÓCIO.....	60
3.2 ENTENDIMENTO DOS DADOS	62
3.3 MODELAGEM DAS SÉRIES TEMPORAIS DE CONSUMO DE ENERGIA ELÉTRICA.....	64
3.4 MÉTODO DE DETECÇÃO DE QUEDAS ATÍPICAS DE CONSUMO	65

4 DESCRIÇÃO DO ESTUDO, RESULTADOS E DISCUSSÃO	67
4.1 ENTENDIMENTO DO NEGÓCIO	67
4.2 ENTENDIMENTO DOS DADOS	72
4.3 MODELAGEM DAS SÉRIES TEMPORAIS DE CONSUMO DE ENERGIA ELÉTRICA	80
4.4 MÉTODO DE DETECÇÃO DE QUEDAS DE CONSUMO ATÍPICAS	85
5 CONCLUSÃO	114
REFERÊNCIAS BIBLIOGRÁFICAS	119
ANEXO 1	129

1 INTRODUÇÃO

A partir da década de 90, intensificaram-se os processos de desestatização das empresas de energia elétrica, fato que induziu à concepção de uma nova estrutura institucional, societária e patrimonial do setor elétrico brasileiro. Essa reestruturação teve o objetivo de aumentar a eficiência das atividades de distribuição e transmissão, e também de introduzir um mercado competitivo nas atividades de geração e comercialização, ramos caracterizados como monopólios naturais (ANEEL, 2006).

Para tanto, contratos de concessão foram assinados entre 61 das 64 concessionárias de distribuição de energia elétrica e a União. Nos contratos foram dispostos os compromissos relativos à concessão e ao serviço, sendo estabelecidas questões sobre regularidade, continuidade, segurança, atualidade e qualidade dos serviços prestados (ANEEL, 2006).

Com as reformas, ocorreu a horizontalização do setor, fato que tornou a distribuição uma atividade independente. A eficiência passou a ser o seu foco, sendo buscados meios para garantir a viabilidade econômica da prestação de serviço. Idealmente, buscou-se manter o nível de qualidade, ao menor custo possível, sem onerar encargos desnecessários ou excessivos aos consumidores finais.

Ao órgão regulador ficaram incumbidas as atividades de regular o serviço público de distribuição de energia elétrica e de efetuar as revisões tarifárias periódicas. Neste âmbito, a regulação é colocada de forma a substituir o mercado, permitindo simular condições competitivas, através de um conjunto de incentivos e restrições. Atualmente, a Agência Nacional de Energia Elétrica (ANEEL) utiliza um mecanismo de regulação do tipo *price cap*, onde são estabelecidos individualmente para cada distribuidora os níveis de custos operacionais eficientes. Esses níveis são estabelecidos com base na chamada Empresa de Referência (ER) (ANEEL, 2006).

Este mecanismo de regulação auxilia as distribuidoras em sua própria gestão, pois lhes permite identificar aquelas atividades e processos em que é possível buscar melhorias em relação ao padrão estabelecido pelo regulador. A estrutura da Empresa de Referência foi constituída considerando a definição dos postos de trabalho, a dotação dos recursos humanos e a remuneração dos mesmos, sendo consideradas as seguintes funções básicas (ANEEL, 2006): (a) Direção, Estratégia e Controle; (b) Administração; (c) Finanças; (d) Distribuição; (e) Comercial.

A área Comercial é responsável, dentre outras atividades, pelo gerenciamento e combate às perdas na distribuição. Historicamente, as perdas no Brasil representam 15% da energia comprada pelas distribuidoras, conforme demonstra a Tabela 1 (ELETROBRÁS, 2001).

Tabela 1: Perdas de Energia Elétrica no Brasil – 1970 a 2001

Ano	Perdas (%)
1970	16,3
1980	13,0
1990	13,1
2000	15,7
2001	13,9

Fonte: Eletrobrás, 2001

Em 2005, as perdas foram da ordem de 15% da energia requerida, sendo 32% deste valor referente às perdas comerciais (ARAUJO; SIQUEIRA, 2006). Verifica-se, através do estudo de Salsa (2009), que o percentual de perdas comerciais vem crescendo no Brasil, chegando a aproximadamente 8,0% da receita bruta anual do setor.

Em 2001, devido às condições climáticas desfavoráveis e a falta de alternativas à geração hidrelétrica, ocorreu o racionamento de energia elétrica no Brasil. Estudos de algumas distribuidoras do Estado do Rio de Janeiro verificaram aumentos da ordem de 10% em seus índices de perdas não técnicas, sendo as ligações clandestinas a irregularidade constatada com maior frequência (PAMPLONA, 2002).

Devido a fatores físicos, culturais e sócio-econômicos da sociedade brasileira, é impraticável a aplicação de uma solução única no combate às perdas comerciais. Esse panorama sugere a necessidade de se criarem soluções distintas para cada região, gerando desta forma uma diversidade de soluções criativas e diferenciadas por parte das distribuidoras (ARAUJO, 2007).

1.1 TEMAS E OBJETIVOS

O tema desta dissertação é a aplicação de técnicas de previsão de demanda, associadas a regras do controle estatístico da qualidade. Serão debatidas as principais técnicas de previsão de demanda, análises estatísticas e o uso combinado dessas duas ferramentas. Complementarmente, será realizado um estudo de caso em uma empresa de distribuição de energia elétrica do sul do Brasil, onde serão debatidos os principais tópicos sobre perdas comerciais, tais como características próprias, perfil dos consumidores, histórico de combate às perdas comerciais e outros indicadores.

1.1.1 Objetivo geral

A presente dissertação visa à proposição de um método que auxilie na identificação de quedas de consumo atípicas dentro do universo de faturamento de unidades consumidoras de uma concessionária de energia elétrica.

1.1.2 Objetivos específicos

Constituem objetivos específicos deste trabalho:

- A verificação da aplicabilidade de técnicas de previsão de demanda em séries de consumo de unidades consumidoras de energia elétrica;
- A geração de um *ranking* de priorização para as indicações de quedas de consumo atípicas do método proposto; e
- A verificação da aderência do método proposto às características específicas da empresa de distribuição de energia Rio Grande Energia SA.

1.2 JUSTIFICATIVA DO TEMA E OBJETIVOS

Araujo e Siqueira (2006) realizaram estudo onde foram verificados os custos das perdas comerciais de energia Elétrica para a sociedade brasileira. No estudo foi verificado que se fossem considerados os custos da energia (aquisição, transmissão e distribuição), acrescidos dos valores que deixam de ser arrecadados com a carga tributária, o custo total das perdas comerciais ficaria em torno de R\$ 4,9 bilhões por ano. Esse número demonstra a importância do tema da presente dissertação, bem como o impacto que ele causa nos rendimentos das empresas de distribuição e na sociedade brasileira.

Devido as suas dimensões, a questão das perdas comerciais tornou-se preocupação constante das empresas de distribuição (MACEDO *et al.*, 1993) e dos órgãos reguladores. Lima (2005) aponta para a preocupação da ANEEL em estimar e combater as perdas comerciais de forma precisa, buscando soluções efetivas para combatê-las. Por esse motivo, a Associação Brasileira de Distribuidores de Energia (ABRADEE) adicionou o indicador perdas comerciais ao conjunto de itens de controle a serem utilizados pelas empresas. Para isso, o Comitê de Distribuição (CODI) definiu os critérios para a contabilização da perda de energia nos níveis: global, transmissão e distribuição, fato que possibilitou comparações mais precisas entre as empresas (CODI, 1994).

Dessas comparações pode-se verificar que o fenômeno de perdas comerciais não está restrito somente a uma determinada empresa ou área de concessão. Ele está presente em praticamente todas as distribuidoras de energia, conforme pode ser verificado na Tabela 2. Além disso, verifica-se que esse fenômeno não é exclusividade brasileira. Nesbit (2000) estima perdas comerciais nos Estados Unidos entre 0,5% e 3,5% do faturamento bruto anual do setor. Já Rizvi (2000) informa que os índices de perdas comerciais em sistemas menos eficientes podem se elevar a 35,0% da energia comercializada, com por exemplo no caso de países do sul da Ásia. Esse fato demonstra a importância e a aplicabilidade de pesquisas relacionadas ao combate de perdas comerciais, uma vez que estas podem trazer bons resultados e ser amplamente utilizadas nas diversas empresas de distribuição do setor elétrico.

É importante ressaltar que o Decreto ANEEL nº 4.562, de 2002, art.1º, estabelece que o valor da tarifa está diretamente ligado aos índices de perdas. Desta forma, pode-se concluir que perdas mais baixas acarretam em tarifas reduzidas, ocasionando ganhos para os consumidores.

A presente pesquisa, em especial, vem aprimorar a principal atividade das empresas de distribuição no que diz respeito ao combate às perdas comerciais: as inspeções em campo às unidades consumidoras. Espera-se que os resultados aqui obtidos possibilitem reduzir os custos com inspeções, incrementando a sua efetividade. A redução dos custos é importante para a manutenção e ampliação do serviço de distribuição, pois libera o uso dos recursos para outras atividades.

Tabela 2: Percentual de Perdas na Distribuição de Energia no Brasil – 2005

Concessionárias	PT	PC	PRB	PT	Concessionárias	PT	PC	PRB	PT
AES SUL	4,98	1,27	2,73	9,17	CPFL – Piratininga	5,76	3,93	2,73	13,7
AMPLA	13,3	15,2	2,73	32,8	CSPE	7,99	1,94	2,73	13,6
Bandeirante	7,19	1,22	2,73	14,3	DEMEI – Ijuí	9,35	2,95	0,00	12,3
Boa Vista	10,7	17,8	0,00	28,5	DME	7,17	0,00	0,00	7,17
CAIUÁ	7,67	0,40	2,73	11,0	EEB – Bragantina	4,6	0,24	2,73	8,03
CEAL	14,7	18,9	2,27	35,8	ELEKTRO	4,82	3,02	2,73	12,1
CEB	7,23	2,46	2,74	13,3	ELETROACRE	18,0	23,9	0,00	41,9
CEEE	11,8	4,51	2,73	19,9	ELETROCAR	9,10	0,80	0,00	9,90
CELB	3,82	5,32	2,73	12,8	ELETROPAULO	6,33	8,37	2,73	18,6
CELESC	5,64	1,33	2,74	10,1	ENERGIPE	11,0	4,59	2,72	21,1
CELG	9,96	1,95	2,73	14,6	ENERSUL	15,4	2,89	2,73	22,7
CELPA	17,8	6,7	2,77	27,9	ESCELSA	8,26	5,33	2,74	19,2
CELPE	13,9	18,7	0,00	33,2	FORCEL	2,80	0,00	0,00	2,80
CELTINS	16,4	3,82	2,74	23,5	HIDROPAN	8,02	0,00	0,00	8,02
CEMAR	17,5	21,3	2,73	42,6	IGUAÇU ENERGIA	7,91	1,61	0,00	9,52
CEMAT	12,7	0,93	2,73	17,4	JOÃO CESA	4,44	0,00	0,00	4,44
CEMIG	6,98	1,30	2,73	13,2	LIGHT	6,06	15,7	2,73	27,6
CENF	7,49	1,55	0,00	9,04	MANUAS	10,8	23,6	0,00	34,4
CEPISA	18,5	26,1	2,73	48,6	MOCOCA	10,2	1,84	0,00	12,1
CERON	14,4	29,5	0,00	43,9	MUXFELDT	11,8	0,00	0,00	11,8
CFLCL	11,3	0,78	2,73	16,4	NACIONAL	8,02	0,42	2,73	11,4
CFLO	1,66	0,17	0,00	1,83	PANAMBI	8,02	0,00	0,00	8,02
CHESP	12,0	0,71	0,00	12,7	RGE	9,24	1,05	2,73	13,6
CJE – Jaguari	3,38	1,05	2,73	7,28	SAELPA	19,0	13,5	0,00	35,0
COCEL	7,02	0,00	0,00	7,02	SANTA CRUZ	6,89	1,80	2,73	12,0
COELBA	12,1	6,54	2,73	23,0	SANTA MARIA	13,8	1,00	0,00	14,8
COELCE	11,5	4,27	2,72	18,9	SULGIPE	11,7	3,92	0,00	15,6
COPEL	6,57	1,28	2,87	12,0	UHENPAL	14,2	1,84	0,00	16,0
COSERN	11,1	4,23	2,73	19,2	URUSSANGA	3,12	0,00	0,00	3,12
CPEE	10,6	2,66	2,72	16,4	V. PARANAPANEMA	8,07	0,38	2,73	11,4
CPFL	6,01	2,63	2,73	12,4					

Fonte: ANEEL, 2005. Onde PT é Perda Técnica (%), PC é Perda Comercial (%), PRB é Perda na Rede Básica (%), e, Perda Total (%).

Deve-se atentar ao fato de que estudos sobre a aplicação de técnicas de previsão de demanda para a gestão de perdas comerciais na distribuição de energia elétrica ainda são escassos. Dessa maneira, há espaço para o desenvolvimento de pesquisas aprofundadas sobre o assunto.

1.3 MÉTODO DE TRABALHO

Devido a sua natureza de geração de conhecimentos dirigidos à solução de um problema específico, este trabalho é classificado como uma pesquisa aplicada. Sua abordagem é quantitativa, pois envolve análises numéricas e estatísticas. Neste estudo serão analisados dados e informações referentes à empresa de distribuição Rio Grande Energia SA. (RGE), fato que sugere uma metodologia de estudo de caso.

Conforme Yin (2001), o estudo de caso busca examinar acontecimentos contemporâneos e pode lidar com diversas evidências, tais como: documentos, entrevistas e observações. Ele é tipicamente composto pelas seguintes etapas:

- definição de um projeto de pesquisa, em que se define as questões em estudo, as preposições (se houver), a unidade de análise, a lógica que une os dados às preposições e os critérios para interpretar os resultados;
- desenvolvimento de preposições teóricas, caso o propósito do estudo de caso seja determinar ou testar a teoria;
- coleta de dados, que determinará o sucesso do estudo;
- análise dos dados, que consiste em examinar, categorizar e classificar as informações coletadas; e
- elaboração de relatório para apresentação dos resultados.

O desenvolvimento deste trabalho será realizado a partir de seis etapas. A primeira etapa envolve uma revisão bibliográfica detalhada, contemplando a literatura clássica sobre métodos de previsão de demanda, bem como pesquisas atuais, registradas em congressos e periódicos.

A segunda etapa consiste na elaboração de uma proposta de solução para o problema. Aqui serão analisadas as técnicas de previsão de demanda e as análises estatísticas mais adequadas, sendo sugerida uma proposta de solução.

A terceira etapa irá reunir e organizar os dados referentes às unidades consumidoras da RGE. Desta maneira, será possível estruturar os bancos de dados e também viabilizar as análises pertinentes ao projeto.

A quarta etapa consiste na análise dos bancos de dados e na calibração da proposta de solução do problema. Os bancos de dados serão analisados, de modo a identificar as características específicas da empresa. Desta forma, será possível calibrar a proposta de solução do problema considerando os padrões de comportamentos das unidades consumidoras da RGE.

A quinta etapa irá verificar a validade do método escolhido. Para tanto, serão realizados diversos testes utilizando séries de consumo manipuladas de forma a simular as interferências típicas obtidas em função de irregularidades.

A última etapa envolverá a análise dos resultados das etapas anteriores, bem como a elaboração das conclusões do estudo. Serão avaliadas e sugeridas possibilidades de continuidade do estudo.

1.4 DELIMITAÇÕES DO TRABALHO

Este trabalho será aplicado exclusivamente na empresa de distribuição de energia elétrica Rio Grande Energia SA. (RGE). Por esse motivo, o método desenvolvido irá contemplar somente as características de negócio verificadas na área de concessão da empresa. Cabe ressaltar que as análises e método desenvolvidos nesta dissertação terão seu uso vinculado exclusivamente à atividade de fiscalização na medição, não sendo consideradas as demais ações de combate às perdas comerciais desenvolvidas pela empresa.

Serão contempladas nas análises somente as UCs conectadas à rede de distribuição de baixa tensão e com contrato ativo. Essa delimitação é feita, uma vez que as UCs conectadas à rede de média e alta tensão exigem análises específicas devido às suas características de faturamento.

O desenvolvimento e a análise dos métodos propostos nesta dissertação estarão limitados à disponibilidade de recursos de *software*. Por este motivo, métodos que demandem *softwares* específicos (ex.: redes neurais) para o seu desenvolvimento e análise não serão contemplados. Igualmente, o desenvolvimento de métodos estará limitado aos conhecimentos de programação do autor. Dessa maneira, não entrarão em discussão as linguagens e sistemas que possam vir a otimizar o desempenho do método proposto.

As indicações realizadas pelo método a ser desenvolvido serão analisadas somente em via administrativa, ou seja, nenhuma UC indicada será efetivamente fiscalizada em campo. Por este motivo, durante a validação do método, serão analisadas somente séries que apresentem comportamento previamente conhecido pelo autor.

1.5 ESTRUTURA DO TRABALHO

Este trabalho está organizado em cinco capítulos. No primeiro é feita uma introdução à área onde a pesquisa está inserida. São apresentados os conceitos básicos sobre o sistema elétrico brasileiro, histórico recente, indicadores e dados gerais sobre as perdas na distribuição de energia.

No Capítulo 2 é apresentado o referencial teórico do trabalho. Para tanto, são revisadas as principais obras e publicações referentes às técnicas de previsão de demanda e os seus usos.

O Capítulo 3 está dividido em duas partes. A primeira apresenta as principais características do setor elétrico pertinentes a esse projeto, bem como menciona como o banco de dados deve ser tratado para uma utilização otimizada. A segunda parte apresenta a abordagem utilizada pelo autor para identificar quais são as técnicas de previsão de demanda mais convenientes para a utilização no projeto. Também é apresentada a estrutura fundamental do método de detecção de quedas de consumo atípicas.

De forma semelhante, o Capítulo 4 está dividido em duas partes. A primeira apresenta as características específicas da empresa estudada, bem como analisa a qualidade das informações do banco de dados disponível. A segunda parte apresenta os resultados da aplicação das técnicas de previsão de demanda e também o desempenho verificado do método de detecção de quedas de consumo atípicas.

O último capítulo apresenta as conclusões finais sobre o estudo, sendo evidenciados os resultados obtidos com a aplicação do método proposto. Análises sobre a efetividade do método são debatidas, sendo incluídas sugestões de melhorias e possíveis continuações do estudo.

2 REFERENCIAL TEÓRICO

Previsões de demanda de produtos e serviços vêm sendo utilizadas pelas empresas como um método de auxílio na tomada de decisões, fornecendo informações básicas para o planejamento e controle de diversas áreas das organizações (MURDICK; GEORGOFF, 1993; MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998; BALLOU, 2001). Estudos apontam que a busca pelo desenvolvimento de sistemas de previsão de demanda está ligada a vários fatores, entre eles o aumento da complexidade das organizações e do mercado, a necessidade de sistematizar a tomada de decisões, o avanço no desenvolvimento de métodos de previsão e a facilidade de aplicação prática dos métodos de previsão por parte dos tomadores de decisão (MAKRIDAKIS; WHEELWRIGHT; McGEE *apud* WINKLHOFER; DIAMANTOPOULOS; WITT, 1996).

A acurácia de uma previsão está relacionada à capacidade do método em estimar valores futuros (MAKRIDAKIS; WHEELWRIGHT, HYNDMAN, 1998), sendo utilizada como um importante critério de seleção de métodos de previsão (KAHN, 1998). Previsões acuradas impactam em uma operacionalização eficiente da produção e serviços, possibilitando que as organizações ofereçam melhores serviços aos seus clientes, informações de demandas futuras de matéria-prima mais precisas aos seus fornecedores e um melhor planejamento das estratégias internas (THOMAS, 1987; LYNN; SCHNAARS; SKOV, 1999; KOTLER, 1991; MOON ET AL., 1998; KAHN, 2002).

Os processos preditivos são limitados pela acurácia das suposições nas quais eles se baseiam, sendo, por este motivo, inevitáveis os erros de predição (EVANS, 1982). Kotler (1991) afirma que quanto mais instável for a demanda, mais crítica é a precisão da previsão, sendo necessário um sistema de previsão mais elaborado. A acurácia da previsão é diretamente influenciada pela precisão dos dados de entrada do sistema, da estabilidade no processo gerador dos dados, do horizonte da previsão, de flutuações de demanda e do método de previsão utilizado (ELSAYED; BOUCHER, 1994).

Os padrões de demanda são resultados da variação de demanda com o tempo (BALLOU, 2001), sendo possível a sua classificação em dois grupos: os padrões de demanda regular e de demanda irregular. Os padrões de demanda regular são formados por cinco

componentes (MENTZER; GOMES, 1989; MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998): (a) demanda média para o período (nível); (b) tendência; (c) sazonalidade; (d) fatores cíclicos (ciclos de negócios ou ciclos de vida de serviços ou produtos); e (e) variação aleatória ou residual.

A análise destes componentes revela informações importantes sobre o comportamento da demanda ao longo do tempo. A demanda média informa o nível médio para o período analisado; a tendência representa o movimento da demanda a longo prazo; a sazonalidade refere-se aos picos e vales regulares que se repetem anualmente; os fatores cíclicos representam a variação de longo prazo (mais de um ano) no padrão de demanda; e variações aleatórias são aquelas que não são explicáveis pelos outros componentes (KOTLER, 1991; BALLOU, 2001).

Estatisticamente é possível determinar a parcela referente à variação aleatória da demanda. Para tanto, deve-se subtrair todas as causas conhecidas (média, tendência, sazonalidade e ciclos) da demanda total. Nos casos onde não for possível identificar as causas desta parcela aleatória, a mesma é presumida como puramente aleatória (DAVIS; AQUILANO; CHASE, 2001).

Os padrões de demanda irregular ocorrem nos casos onde existe um elevado grau de incerteza a respeito do momento e nível de ocorrência de demanda, tais como: o padrão de demanda é dominado por pedidos grandes de clientes não-freqüentes, a demanda pode ser derivada da demanda de outros produtos ou serviços, o padrão de demanda pode ser um resultado de dados espúrios ou eventos especiais, entre outros. Em função disto, as previsões para demandas irregulares se tornam particularmente difíceis (BALLOU, 2001).

Por ser um processo cujo domínio é o tempo, a previsão de demanda fornece uma previsão com determinada confiança para casos pontuais ou intervalos de previsão para um momento de tempo definido (KLASSEN; FLORES, 2001). Nos casos onde o padrão de demanda é identificado e não se esperam mudanças repentinas durante o horizonte de previsão, pode-se considerar que os erros são aleatórios, normalmente distribuídos e constantes. Isto possibilita o cálculo de uma previsão dentro de um intervalo de confiança definido (MAKRIDAKIS, 1988). O horizonte de previsão pode ser classificado em: de curto prazo, se o horizonte de previsão é de até três períodos no futuro; de médio prazo, se o horizonte de previsão é de três a vinte períodos no futuro; e de longo prazo, se o horizonte de

previsão considera mais do que vinte períodos no futuro (JOHNSON; KING *apud* WERNER, 2004).

Os métodos de previsão de demanda se dividem em dois grupos principais de abordagem: métodos qualitativos e quantitativos (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998). Os métodos qualitativos de previsão, também chamados de métodos intuitivos ou subjetivos, são aqueles que utilizam primordialmente a capacidade humana de prever a probabilidade do resultado de eventos, baseado na experiência de especialistas ou de um grupo de pessoas. Estes métodos podem ser apoiados por uma análise formal ou não (ARMSTRONG, 1983) e são mais indicados nos casos onde os dados são inadequados ou insuficientes para processar uma análise quantitativa (ARCHER, 1980).

Diversos estudos chegaram à conclusão que, em geral, as empresas preferem os métodos qualitativos em relação aos quantitativos (WHEELWRIGHT; CLARKE, 1976; MCHUGH; SPARKES, 1983; MENTZER; COX, 1984; FILDES; HASTINGS, 1994). Contudo, tais métodos apresentam uma série de desvantagens quando comparados com métodos quantitativos. Devido à incorporação de opiniões de entrevistados e especialistas, os métodos qualitativos são tendenciosos (SPEDDING; CHANN, 2000) e, não raro, as previsões subjetivas geram grandes erros, ocasionando problemas no planejamento e no resultado final das operações corporativas (ALIBAIG; LILLY, 1999; SUBRAHMANYAN, 1998; LAWRENCE *et al.*, 2000).

Os métodos quantitativos de previsão, também chamados de métodos objetivos, são aqueles que utilizam dados históricos para calcular matematicamente extrapolações dos dados futuros (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998) e que se reaplicados por outros analistas, fornecerão previsões idênticas às originais (ARMSTRONG, 1983). Esses métodos são classificados em métodos de séries temporais e métodos causais. Os métodos de séries temporais envolvem a análise estatística dos dados passados da variável a ser prevista. Os métodos causais são baseados na análise estatística de realizações passadas de variáveis relacionadas à variável de interesse para a previsão (ARCHER, 1980).

As previsões de demanda baseadas em métodos quantitativos são obtidas através da reprodução de padrões reconhecidos na análise de dados históricos de demanda. Contudo, as previsões não devem se limitar a reproduzir um padrão ou tendência passada. É essencial considerar toda informação disponível, incluindo informações de exatidão conhecida como, por exemplo, produção e vendas passadas, e de exatidão desconhecida como, por exemplo,

atividades promocionais e informações concorrentes (REMUS; O'CONNOR; GRIGGS, 1998). O procedimento geral para estimar um padrão de relacionamento, seja de série temporal ou causal, é por meio da aderência a uma função matemática qualquer, de modo a minimizar o componente de erro. Um caso a parte é a previsão de demanda baseada em redes neurais artificiais, que pode ser utilizada tanto para métodos causais, quanto para métodos de séries temporais, porém sem que ocorra a aderência a um método matemático explícito (ANSUJ *et al.*, 1996).

Usualmente, os sistemas de previsão procuram aproveitar simultaneamente os benefícios que os métodos qualitativos e quantitativos fornecem. Os qualitativos podem auxiliar na identificação de novas variáveis, são flexíveis para se adaptar a mudanças e podem identificar eventos especiais e antecipá-los. Os métodos quantitativos possibilitam o trabalho com grande quantidade de dados e fornecem respostas imparciais, sem sofrer influência de opiniões tendenciosas e de pressões sociais para obtenção de consenso (BLATTBERG; HOCH, 1990; GOODWIN, 2002).

Os métodos quantitativos não conseguem prever e incorporar mudanças em padrões de demanda e/ou relações entre variáveis, nem têm condições de identificar se estas mudanças são temporárias ou permanentes. Por este motivo, a incorporação da opinião de especialistas, com o intuito de ajustar as análises quantitativas, é necessária. Desta forma, a previsão subjetiva foca a predição da influência de mudanças em padrões e/ou relações estabelecidas, enquanto as previsões quantitativas se concentram na predição da continuação de tais padrões/relações (MAKRIDAKIS, 1988).

2.1 MÉTODOS QUALITATIVOS DE PREVISÃO

Os métodos qualitativos de previsão têm uma forma estruturada, possibilitando a realização de uma análise subjetiva ao processo analisado. Frequentemente são utilizados em previsões de médio e longo prazo, ou ainda em novas situações onde os dados são limitados e não há histórico disponível (CHAMBERS; MULLICK; SMITH, 1971; GEORGOFF; MURDICK, 1986). Pode-se citar a formulação de estratégias, desenvolvimento de novos produtos e tecnologias com taxa de penetração e aceitação de mercado incerta e também no desenvolvimento de planos de longo prazo. Eles variam em custo e complexidade, sendo

freqüentemente integrados a métodos quantitativos (MAKRIDAKIS; WHEELWRIGHT, HYNDMAN, 1998). Esta combinação normalmente é utilizada para realizar ajustes nas previsões quantitativas de curto prazo (MENTZER; GOMES, 1989).

As previsões resultantes destes métodos vêm diretamente da opinião de entrevistados e de especialistas (ELSAYED; BOUCHER, 1994; ARMSTRONG, 2001a), agregando, desta maneira, conhecimentos prévios sobre os temas. Além disto, pode-se afirmar que este tipo de método adiciona consenso à previsão, uma vez que todas as opiniões dos especialistas são consideradas (SANDERS; MANRODT, 1994; GOODWIN, 2002).

Verifica-se que as opiniões de entrevistados e especialistas são baseadas em argumentos distintos. Enquanto os entrevistados se preocupam com seus planos, metas e expectativas sobre a demanda futura de uma variável (ARMSTRONG; BRODIE, 1999), os especialistas se baseiam no julgamento, intuição, pesquisas, técnicas comparativas, conhecimento técnico, conhecimento sobre análise de dados, procedimentos de previsão e no conhecimento de relações de causa e efeito entre as variáveis (WEBBY; O'CONNOR, 1996; BALLOU, 2001). É comum também a utilização de métodos qualitativos como um segundo passo no processo de análise de séries temporais históricas, sendo alimentada a sua entrada com os resultados de algum método quantitativo (WRIGHT; LAWRENCE; COLLOPY, 1996).

Segundo Kahn (2002), os tomadores de decisões preferem os métodos qualitativos em relação aos quantitativos (KAHN, 2002). A familiaridade com este tipo de método deve-se ao fato de normalmente serem mais simples e muitas vezes intuitivos (SANDERS; MANRODT, 1994; PETERSON; JUN, 1999). Deve-se ressaltar que, geralmente, os responsáveis pelas decisões não estão familiarizados com os métodos quantitativos e o uso de métodos qualitativos gera uma sensação de controle sobre a previsão (SANDERS; MANRODT, 1994; GOODWIN, 2002). De fato, estes são os principais argumentos utilizados quando se deseja justificar o uso de métodos qualitativos para previsão de demanda de uma variável (WINKLHOFER *et al.*, 1996).

Apesar de serem realizadas por analistas experientes e com informações de mercado, as previsões baseadas em métodos qualitativos muitas vezes não possuem bom desempenho (LUXHOJ *et al.*, 1996; SUBRAMANYAN, 2000). Em um estudo, Lawrence *et al.* (2000) sugerem alguns dos possíveis motivos: (a) algumas informações fornecidas pelos especialistas podem não ter valor preditivo; (b) as estimativas podem ser tendenciosas e a interpretação do

relacionamento entre variáveis pode ser ineficaz; (c) pode ocorrer uma sobrecarga de dados que devem ser analisados pelo analista, fazendo com que ele ignore ou atribua pesos errados às variáveis; e (d) podem ocorrer perturbações recentes nas séries temporais, fazendo com que a tendência seja mal interpretada.

Makridakis (1988) indica em seu estudo as tendências mais comuns que afetam os métodos qualitativos de previsão. A Tabela 3 apresenta um quadro com os tipos de tendência indicados, bem como as maneiras de reduzir os seus efeitos.

Tabela 3: Tendências comuns e seus tratamentos em métodos qualitativos

Tipo de tendência	Descrição	Maneiras de reduzir os impactos da tendência
Otimismo	Previsão reflete os desejos dos tomadores de decisão.	Buscar os dados com mais de uma pessoa.
Inconsistência	Incapacidade de aplicar os mesmos julgamentos em situações similares.	Criar regras e formalizar os métodos de julgamento.
Novidades	Os eventos mais recentes são considerados mais importantes, sendo os mais antigos minimizados ou ignorados.	Verificar os fatos fundamentais que afetam a previsão da variável de interesse. Analisar ciclos e sazonalidades.
Correlações ilusórias	Acreditar na existência de relações entre as variáveis ou de padrões de comportamento quando estas não existem.	Verificar a significância estatística dos padrões. Modelar as relações, se possível em termos de mudanças.
Conservadorismo	Não mudar ou mudar lentamente o ponto de vista quando novas informações/evidências estão disponíveis.	Monitorar as mudanças e elaborar procedimentos para atuar quando mudanças significativas são detectadas.
Percepção seletiva	Tendências de verificar problemas baseado na própria experiência.	Buscar os dados com pessoas com experiências diferentes.

Fonte: Adaptado de Makridakis, 1988.

A seguir são apresentados brevemente os métodos qualitativos de previsão de demanda incluídos nesta revisão bibliográfica: (a) Jogos de Representação; (b) Pesquisa de Intenções; e (c) Delphi.

2.1.1 Jogos de Representação

Este método de previsão é usualmente empregado em situações onde duas partes conflitantes interagem, especialmente para casos que envolvem grandes mudanças e existe pouca informação sobre eventos semelhantes no passado (ARMSTRONG, 2001c). Na prática, o método simula as interações entre as partes, oferecendo um melhor entendimento sobre os pensamentos e as reações dos participantes (ARMSTRONG, 1988; ARMSTRONG, 2001a). Entende-se por situações de conflito aquelas onde duas ou mais partes têm objetivos distintos, diferentes estratégias ou competem por um determinado recurso (ARMSTRONG, 1987).

Diversos estudos indicam que os Jogos de Representação são muito mais precisos na previsão de decisões que envolvem partes conflitantes, se comparados a outros métodos. Isto ocorre devido ao grande realismo agregado ao processo de previsão (ARMSTRONG, 1988; ARMSTRONG, 2001a; GREEN, 2002). Embora o procedimento mais efetivo envolva somente a interação de duas partes conflitantes, o método também pode ser aplicado a indivíduos que não interagem diretamente com outros. De forma semelhante, pode-se aplicar o método em situações onde há muitas partes representando diversos pontos de vista, porém este uso é mais complexo (ARMSTRONG, 2001c).

Observa-se que este método vem tendo bons resultados nas áreas militar, jurídica, de psicologia e de negócios (ARMSTRONG, 1987; ARMSTRONG, 2001c), sendo muito aplicado para prever a reação de concorrentes frente à mudanças de estratégia de organizações ou de mudanças de cenários de mercado (ARMSTRONG, 1983).

2.1.2 Pesquisa de Intenções

Entende-se por intenções, as afirmações que os indivíduos fazem sobre seu comportamento futuro ou sobre o comportamento de variáveis que elas podem controlar (ARMSTRONG, 1985). O método procura identificar padrões que podem descrever as preferências dos consumidores e a probabilidade de eles comprarem um determinado produto e/ou serviço, servindo de informação relevante para a previsão de demanda e tomada de decisões (CHAMBERS; MULLICK; SMITH, 1971; HUTH; EPPRIGHT; TAUBE, 1994).

Verifica-se que o método é mais efetivo nos casos onde o evento a ser analisado no processo preditivo tem uma maior importância e também quando os respondentes têm planos sobre a aquisição do produto e/ou serviço pesquisado (ARMSTRONG, 1985). O horizonte de previsão também exerce influência na qualidade do resultado do método. As previsões de curto prazo geralmente são mais acuradas, pois são menos suscetíveis a mudanças na intenção de consumo dos respondentes (CLAWSON *apud* ARMSTRONG, 1985).

As entrevistas são realizadas por telefone, correio (comum ou eletrônico) e pessoalmente. Isto faz com que não haja interação entre os entrevistados, evitando, desta maneira, influência nas respostas (ARMSTRONG, 1985). Para casos onde a previsão é aplicada a novos produtos, sem similares, o método pode se mostrar ineficiente. Tal situação está ligada ao fato de que os consumidores potenciais podem não estar familiarizados com o produto proposto. Nos casos onde existem produtos similares, a pesquisa pode se beneficiar da experiência dos respondentes na compra destes produtos (ARMSTRONG; BRODIE, 1999; MORWITZ, 2001).

2.1.3 Método Delphi

Este método busca reunir o conhecimento e as experiências de diversos especialistas de uma determinada área de forma a se chegar a um consenso sobre a probabilidade e o momento de ocorrência de eventos futuros específicos (GUPTA; CLARKE, 1996; PREBLE, 1983; ROWE; WRIGHT, 1999). Os especialistas não se comunicam durante o processo de previsão ou simplesmente não conhecem os outros participantes, sendo o anonimato um artifício utilizado para evitar conflitos entre grupos (pessoais e políticos) e reduzir a influência de indivíduos ou grupos socialmente dominantes (DALKEY, 1972; GUPTA; CLARKE, 1996; LEMOS; PORTO, 1998; ROWE; WRIGHT, 1999). O método utiliza grupos de especialistas, pois se acredita que opiniões coletivas organizadas de forma adequada são mais eficazes do que o julgamento de um único especialista (WRIGHT; GIOVINAZZO, 2000).

O método consiste em um processo estruturado de aprendizado iterativo, onde os especialistas respondem a uma seqüência de questionários. Entre cada iteração de questionários, um *feedback* controlado é fornecido aos especialistas (DALKEY, 1972). Desta forma, as opiniões anônimas são conhecidas por todos e é dada aos participantes a

oportunidade de alterar suas estimativas iniciais, de explorar novos temas e discutir possíveis incompatibilidades de opiniões (ROWE; WRIGHT, 1999; WRIGHT; GIOVINAZZO, 2000).

Preble (1983) indica alguns dos benefícios deste método, sendo os principais: ausência de resultados tendenciosos, uso eficiente dos julgamentos dos especialistas, resultados de fácil compreensão, comunicação não ambígua entre participantes, e documentação do procedimento. Outros estudos indicam as limitações do método, sendo possível citar: a complexidade de administração do processo, demora na obtenção de resultados, possibilidade de forçar o consenso indevidamente, influência do ponto de vista do mediador através de questionários mal formulados, utilização de técnicas ineficientes para analisar os resultados, falta de critérios na escolha de especialistas, e elevados custos de elaboração (LINSTONE; TUROFF *apud* ARCHER, 1980; PREBLE, 1983; GUPTA; CLARKE, 1996; WRIGHT; GIOVINAZZO, 2000).

Esta técnica tem bons resultados para previsões de médio e longo prazo (GEORGOFF; MURDICK, 1986; YUXIANG; DONGHUA; CHANGGENG *apud* GUPTA; CLARKE, 1996), tendo sido extensamente utilizada no planejamento e análise de estratégias, tanto no setor público, quanto no setor privado. Além de previsão de demanda, o método tem bons resultados em avaliações de projetos, análise de investimentos e planejamento financeiro (GUPTA; CLARKE, 1996).

2.2 MÉTODOS QUANTITATIVOS DE PREVISÃO

A previsão com o uso de métodos quantitativos pode ser aplicada quando (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998): (a) as informações sobre o passado da variável a ser analisada estão disponíveis; (b) as informações possam ser quantificadas em termos matemáticos; e (c) seja possível assumir que alguns aspectos do padrão verificado no passado continuarão a existir no futuro. Esta última colocação é também conhecida com pressuposto da continuidade. A previsão pode ocorrer de duas maneiras distintas: através da análise de séries temporais ou extrapolação, ou através do uso de métodos causais (THOMAS, 1996).

Nos casos onde os métodos de análise de séries temporais são utilizados, a previsão para a demanda futura baseia-se no histórico de demanda da variável em análise (ELSAYED;

BOUCHER, 1994). Para tanto, se considera que os padrões reconhecidos no passado se manterão nos períodos futuros (MAKRIDAKIS, 1988; THOMAS, 1996; WRIGHT; LAWRENCE; COLLOPY, 1996), sendo possível, desta maneira, ajustar um método aos dados passados. Assim, através da extrapolação das tendências e relações existentes no passado, o método irá prever padrões futuros de demanda. Mudanças conhecidas previstas nas variáveis devem ser avaliadas e integradas ao método proposto (ARCHER, 1980).

Métodos causais são freqüentemente utilizados nas previsões de variáveis econômicas dependentes, que são diretamente influenciadas por estimativas de variáveis independentes (ARCHER, 1980; ELSAYED; BOUCHER, 1994). As variáveis dependentes são aquelas compostas pelas estimativas das variáveis causais e das relações entre as variáveis (ARMSTRONG, 1983). Da mesma forma que os métodos de análise de séries temporais pressupõem que os padrões passados se repetiram no futuro, os métodos causais assumem que as relações causais também se manterão (THOMAS, 1996).

Os métodos causais possuem grande aplicabilidade, sendo possível utilizá-los para qualquer horizonte de previsão. Contudo, eles são mais utilizados para previsões de médio e longo prazo. Isto se deve ao fato de que, para horizontes de curto prazo, os métodos de análise de séries temporais possuem uma boa acurácia, sendo os seus custos de implantação e de manutenção inferiores aos verificados nos métodos causais (MURDICK; GEORGOFF, 1993).

Métodos quantitativos são rígidos e consistentes, sendo possível utilizá-los para grandes volumes de dados. Eles diferem entre si quanto ao nível de complexidade, facilidade de uso e análise subjetiva requerida (SANDERS, 1997a). Sua principal desvantagem está na dificuldade de lidar com as mudanças dinâmicas e estruturais das séries temporais. Também se verificam falhas com a caracterização de problemas com dados históricos limitados (SPEDDING; CHANN, 2000).

2.2.1 Extrapolação

Os métodos de previsão de demanda que utilizam técnicas de extrapolação são normalmente utilizados para previsões de curto prazo, exceto em casos onde o padrão dos dados seja extremamente estável. Para tanto, se considera que o padrão existente na série temporal histórica irá se manter no futuro (CHAMBERS; MULLICK; SMITH, 1971;

ARMSTRONG, 2001d). Eles estão divididos em métodos com métodos matemáticos fixos (FMTS – *fixed-model time series*) e métodos com métodos matemáticos ajustáveis ou abertos (OMTS – *open-model time series*) (MENTZER; GOMES, 1989).

Os métodos FMTS são métodos simples, de baixo custo e de fácil entendimento, sendo por este motivo indicados para casos onde existe a necessidade de uma grande frequência de previsões. Eles assumem a existência de padrões nas séries temporais, caracterizados pelas relações entre os componentes que as formam (nível, tendência, sazonalidade, ciclo e erro aleatório). Equações fixas são utilizadas, uma vez que alguns desses componentes podem ser considerados significativos ou não. Pode-se citar como exemplo de métodos FMTS os métodos de Média Móvel e de Suavização Exponencial (MENTZER; GOMES, 1989).

Se comparados aos métodos FMTS, os métodos OMTS são mais complexos, requerendo treinamento intensivo e considerável tempo de análise. Diversas decisões subjetivas devem ser tomadas, fato que implica em acurácia de previsão fortemente ligada às habilidades do usuário do método. Estas características, somadas ao limitado ganho de precisão em relação aos métodos FMTS restringem, de certa forma, a utilização destes métodos no meio empresarial. Este método é indicado para situações em que se deseja obter previsões de demanda quando há pouca informação contextual, mesmo que exista um histórico de demanda substancial. Como exemplo de método OMTS, pode-se citar o método de Box-Jenkins (MENTZER; GOMES, 1989).

2.2.1.1 Média Móvel

Este método é indicado para previsões de curto prazo, com dados históricos irregulares, onde a série temporal não apresenta tendência e sazonalidade. Para sua utilização são necessários poucos dados históricos, fato que, juntamente com suas características de fácil implementação e manutenção, tornam este método popular (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

A lógica de funcionamento deste método é bastante simples. Calcula-se uma média aritmética ou ponderada de um número fixo de k observações que se move conforme se progride na série de dados. A cada novo cálculo, a observação mais antiga é desprezada e é

incluída a observação mais recente da série (CHAMBERS; MULLICK; SMITH, 1971; ACHER, 1980; MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

O número de observações k é determinado de forma que eventuais efeitos de tendência ou sazonalidade sejam suprimidos, permanecendo constante ao longo da análise. Verifica-se que quanto maior a variável k , mais estáveis serão as médias obtidas (MONTGOMERY, 2004). O cálculo da média móvel se desloca através da série temporal até que todos os períodos tenham sido contemplados. Previsões para períodos posteriores à última observação da série temporal serão iguais ao valor da última média calculada (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

Como principal desvantagem deste método, pode-se citar o fato dele não trabalhar bem com séries que apresentam sazonalidade. Isso ocorre já que a previsão para um novo período envolve sempre a adição de novos dados e a desconsideração de dados anteriores (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998; DAVIS; AQUILANO; CHASE, 2001). Para se reduzir estes efeitos, pode-se aplicar o método de média móvel mais de uma vez, fazendo a média das médias. Este artifício gera uma maior estabilidade nos valores obtidos (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

Outra alternativa a este tipo de problema é uso de médias ponderadas. Desta forma é possível incluir e desprezar informações ao cálculo de médias de forma gradual, evitando variações bruscas nos seus valores (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998; KRAJEWSKI; RITZMAN, 2002). Esta alternativa traz a necessidade de conhecimento sobre o comportamento da série para determinar os pesos atribuídos a cada observação considerada (DAVIS; AQUILANO; CHASE, 2001). O uso mais freqüente desse tipo de método é em casos onde se deseja minimizar os efeitos de sazonalidade em dados que servirão de entrada a outras técnicas (PASSARI, 2003).

2.2.1.2 Suavização Exponencial

Dentre todos os métodos de extrapolação disponíveis, a suavização exponencial é o método mais popular e com a melhor relação custo/benefício (ARMSTRONG; BRODIE, 1999). O método consiste na aplicação de uma média ponderada nas observações de uma série temporal, onde os pesos utilizados são determinados por uma progressão geométrica. Pesos

maiores são atribuídos às observações mais recentes e pesos menores às informações mais antigas (ARCHER, 1980).

Os métodos de suavização exponencial se mostram vantajosos quando há a necessidade de previsão de grande volume de itens, pois geralmente são os únicos métodos capazes de indicar resultados com rapidez suficiente para um sistema de previsão de demanda eficaz. Adicionalmente, verifica-se que estes métodos são de simples aplicação, além de possuírem baixo custo de implementação e manutenção (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

São três os principais métodos de previsão de demanda que utilizam a suavização exponencial: (a) Suavização Exponencial Simples; (b) Suavização Exponencial Linear de Holt; e (c) Método de Holt-Winters (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

O método de *Suavização Exponencial Simples* é indicado para realizar previsões em séries temporais onde o padrão assumido apresenta somente os componentes de nível e ruído. Caso os componentes de sazonalidade e/ou tendência estejam presentes nos dados históricos, deve-se buscar por outro método (MENTZER; GOMES, 1989; MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

A formulação matemática do método de Suavização Exponencial Simples aloca um parâmetro de suavização α ao valor observado mais recente e um peso $(1-\alpha)$ à última previsão realizada (que contém o histórico de dados da série temporal).

Quanto mais próximo de 1 for o valor de α , maior a ênfase em demandas recentes e mais sensível o método será às mudanças na série de dados. O valor ótimo de α é obtido através do método dos mínimos quadrados (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

O método de *Suavização Exponencial Dupla* estende a Suavização Exponencial Simples para casos onde as séries temporais apresentam o componente de tendência, mas não apresentam sazonalidade (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998). A previsão indicada pelo método é obtida através da equação (1), sendo esta dependente das equações (2) e (3), responsáveis por indicar as estimativas de nível e de tendência da série temporal, respectivamente. Para tanto, duas constantes de suavização não relacionadas, com

valores entre 0 e 1, devem ser estimadas: α e β (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998; TAYLOR, 2003; RASMUSSEN, 2004).

$$F_{t+m} = L_t + b_t m \quad (1)$$

$$L_t = \alpha Y_t + (1 - \alpha)(L_{t-1} + b_{t-1}) \quad (2)$$

$$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1} \quad (3)$$

onde F_{t+m} é a previsão para o período $t+m$, m é o horizonte de previsão, L_t é a estimativa do nível da série temporal no período t , b_t é a estimativa de tendência da série temporal para o período t e α e β são as constantes de suavização.

A equação (1) é utilizada para se obter a previsão de demanda, sendo obtida da soma do nível da série L_t com a tendência b_t multiplicada pelo horizonte de previsão m . A equação (2) tem a função de ajustar o valor do nível da série L_t em função da tendência do período anterior. De forma semelhante, a equação (3) ajusta a tendência através da diferença entre os últimos dois valores suavizados de nível L_t e L_{t-1} . A tendência do último período ($L_t - L_{t-1}$), modificada pela suavização com β , é adicionada à estimativa anterior da tendência (b_{t-1}) multiplicada por $(1 - \beta)$ (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

O método de *Holt-Winters* é indicado para os casos onde os componentes de tendência linear e sazonalidades estão presentes no padrão de demanda. Existem duas possibilidades de abordagem na utilização deste método, sendo estas vinculadas à forma como é modelada a sazonalidade: forma multiplicativa e forma aditiva. A forma multiplicativa é indicada nos casos onde as séries temporais possuem uma amplitude de sazonalidade que varia conforme a demanda; já a forma aditiva é indicada para os casos onde a amplitude de sazonalidade independe da demanda da série temporal (WINTERS, 1960). Alguns estudos indicam que o método aditivo de Holt-Winters é menos comum que o multiplicativo (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998; HOLT, 2004; RASMUSSEN, 2004).

O método que utiliza a forma multiplicativa possui quatro equações básicas:

$$F_{t+m} = (L_t + b_t m) S_{t-s+m} \quad (4)$$

$$L_t = \alpha \frac{Y_t}{S_{t-s}} + (1 - \alpha)(L_{t-1} + b_{t-1}) \quad (5)$$

$$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1} \quad (6)$$

$$S_t = \gamma \frac{Y_t}{L_t} + (1 - \gamma)S_{t-s} \quad (7)$$

onde s é o número de períodos do ciclo sazonal, S_t é a estimativa do componente sazonal da série temporal no período t , e α , β e γ são as constantes de suavização (assumindo valores entre 0 e 1, não relacionados) (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998; HOLT, 2004; RASMUSSEN, 2004).

De forma semelhante ao método multiplicativo, o método aditivo também possui quatro equações básicas (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998; HOLT, 2004; RASMUSSEN, 2004):

$$F_{t+m} = L_t + b_t m + S_{t-s+m} \quad (8)$$

$$L_t = \alpha(Y_t - S_{t-s}) + (1 - \alpha)(L_{t-1} + b_{t-1}) \quad (9)$$

$$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1} \quad (10)$$

$$S_t = \gamma(Y_t - L_t) + (1 - \gamma)S_{t-s} \quad (11)$$

2.2.1.3 Método de Box-Jenkins

O método de Box-Jenkins (B-J) é um método de previsão complexo, que utiliza um modelo matemático com termos auto-regressivos e de média móvel, buscando identificar a forma do método matemático que melhor se adapta a uma série temporal com n observações (ARCHER, 1980). O método possibilita o uso combinado de métodos, podendo identificar qual a combinação mais adequada para uma determinada situação (WALKER; MCCLELLAND, 1991; BUSINGER; READ, 1999).

Durante seu processamento, o método B-J modela a função de autocorrelação de uma série temporal estacionária com o mínimo de parâmetros possíveis, utilizando uma combinação de autoregressão (AR), integração (I) e média móvel (MA). Desta forma, pode-se dizer que o método geral do método é um método autoregressivo, integrado e de média móvel (ARIMA – *Auto-Regressive / Integrated / Moving-Average*) (WALKER; MCCLELLAND, 1991; BUSINGER; READ, 1999).

A notação geral do método é ARIMA $(p, d, q)(P, D, Q)_s$, onde: (AR) – parcela autoregressiva que modela a relação entre um valor atual e valores passados; (I) – parcela de integração que remove a tendência da série temporal, tornando a série estacionária; (MA) – parcela de média móvel que assume que valores atuais são reflexo de erros de previsão de períodos anteriores; p – ordem máxima dos parâmetros de autoregressão simples; d – número de diferenciações não-sazonais aplicadas para tornar a série temporal estacionária; q – ordem máxima dos parâmetros de média móvel simples; P – ordem máxima dos parâmetros de autoregressão sazonal; D – número de diferenciações sazonais aplicadas para tornar a série temporal estacionária; Q – ordem máxima dos parâmetros de média móvel sazonal; e, s – número de períodos do ciclo sazonal (WALKER; MCCLELLAND, 1991; BUSINGER; READ, 1999).

Em sua operacionalização, o método B-J passa por três etapas distintas até que a modelagem da série temporal analisada esteja concluída. São elas: identificação; estimação e teste, e aplicação. Na primeira fase, o método realiza o ajuste dos dados e a seleção dos métodos que descrevem a série temporal adequadamente. Em seguida, são estimados os parâmetros dos métodos e estes são testados verificando a aleatoriedade dos resíduos. A etapa final consiste no diagnóstico do método com a melhor acurácia. A Figura 1 apresenta o fluxo desta modelagem.

O método B-J percebe as correlações históricas entre os dados da série temporal e as extrapola para períodos futuros. Em situações onde as correlações são fortes, homogêneas e estáveis, este método apresenta melhor desempenho se comparado aos métodos de Suavização Exponencial (BOX; JENKINS; REINSELL, 1994).

O método necessita de uma grande quantidade de informações subjetivas e de pelo menos 48 observações para desenvolver o método matemático (MENTZER; GOMES, 1989). Além disso, a sua aplicação depende da série temporal ser ou não estacionária. Uma série temporal é considerada estacionária quando não há tendência e sazonalidade nos dados, os

valores registrados giram em torno de uma média independentemente do tempo e a variância permanece constante com o decorrer do tempo. Para determinar se a série temporal analisada é estacionária, análises gráficas e analíticas dos coeficientes de autocorreção (ACF) e de autocorrelação parcial (PACF) são realizadas (BOX; JENKINS; REINSELL, 1994).

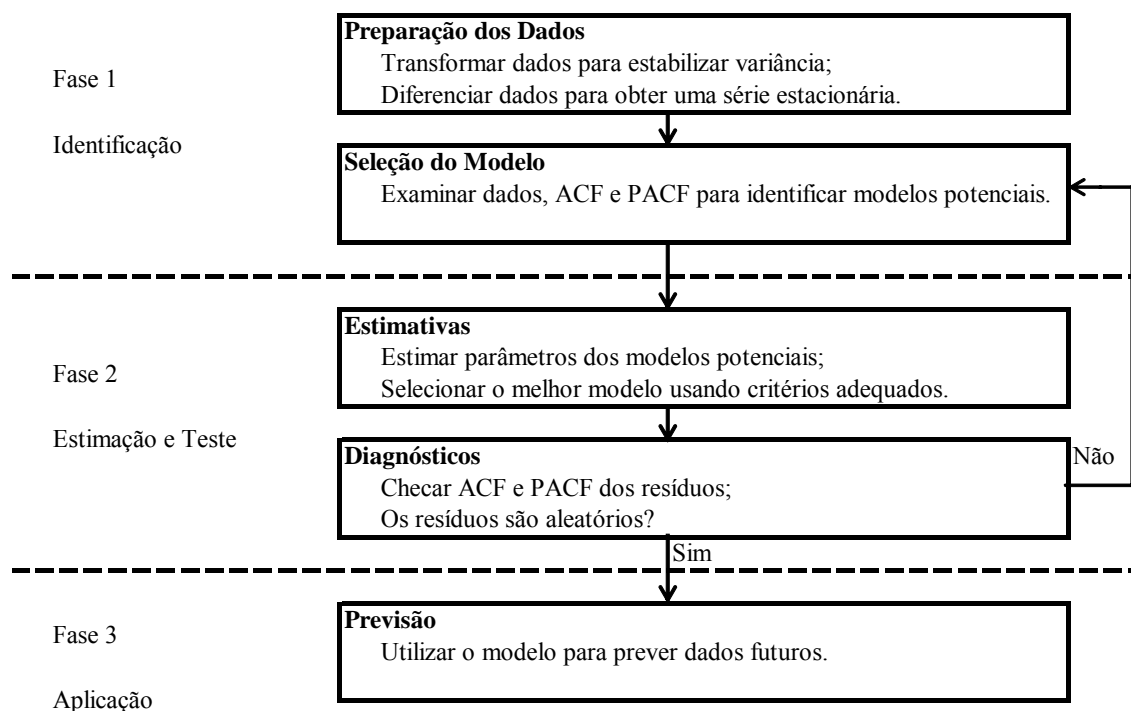


Figura 1: Seqüência de execução do método de Box-Jenkins (Fonte: MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998)

O coeficiente de autocorrelação (r_k) indica a correlação da série temporal com ela mesma e pode ser representado pela equação (12).

$$r_k = \frac{\sum_{t=k+1}^n (Y_t - \bar{Y})(Y_{t-k} - \bar{Y})}{\sum_{t=1}^n (Y_t - \bar{Y})^2} \quad (12)$$

onde r_k é o coeficiente de correlação da observação Y_t com a observação Y_{t-k} , k é a ordem do coeficiente de correlação, Y_t é a demanda observada no período t e \bar{Y} é a média das observações da série temporal.

Autocorrelações parciais são utilizadas para verificar o grau de associação entre Y_t e Y_{t-k} , quando os efeitos de observações de outros períodos são removidos. O coeficiente de autocorrelação parcial de ordem k (α_k) pode ser calculado através de uma regressão da variável Y_t com as observações da mesma variável em períodos passados, conforme demonstra a equação (13). Os coeficientes de autocorrelação parcial (α_k) são as estimativas dos coeficientes b_k da regressão múltipla apresentada na equação (13) (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

$$Y_t = b_0 + b_1 Y_{t-1} + b_2 Y_{t-2} + \dots + b_k Y_{t-k} \quad (13)$$

onde b_k é o coeficiente de regressão múltipla e os demais termos são como definidos na equação (12).

Quando as séries temporais analisadas são estacionárias, os coeficientes ACF e PACF tendem a valores próximos de zero. Nos casos onde a característica estacionária não está presente, estes coeficientes apresentam valores significativamente diferentes de zero para vários períodos de tempo (BOX; JENKINS; REINSELL, 1994).

O uso do método de B-J exige que padrões não estacionários da série analisada sejam removidos. Sendo assim, a série temporal deve ser transformada de modo que a mesma se torne estacionária em relação a sua média e variância. Para tanto, pode-se obter a estacionariedade nas médias através de diferenciação. Já para ajustar a estacionariedade na variância, podem ser realizadas transformações, tais como transformações logarítmicas ou exponenciais (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

A técnica de diferenciação gera uma nova série com $n - 1$ valores, onde cada valor é obtido pela equação (14). Se o resultado desta primeira rodada de diferenciação não tornar a série estacionária, o procedimento deverá ser realizado novamente com os dados obtidos na primeira rodada. Desta forma, a nova série terá $n - 2$ elementos. Em situações reais, verifica-se que geralmente são necessárias até duas diferenciações para tornar as séries temporais estacionárias (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

$$Y_t^d = Y_t - Y_{t-1} \quad (14)$$

onde Y_t^d é o novo valor diferenciado de demanda e Y_t é a demanda observada no período t .

Nos casos onde se verifica um componente sazonal, é mais indicado que sejam utilizadas técnicas de diferenciação sazonais, que comparam uma observação com sua correspondente do ciclo sazonal anterior. Caso a estacionariedade não seja obtida em uma primeira rodada, procede-se com uma diferenciação sazonal de segunda ordem (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

Para melhor descrever a diferenciação, pode-se utilizar um operador substituto B , definido pela equação (15). Um exemplo genérico de uma diferenciação de ordem d é apresentada pela equação (16).

$$B^m Y_t = Y_{t-m} \quad (15)$$

$$Y_t^d = (1 - B)^d Y_t \quad (16)$$

onde B é o operador substituto, m é o horizonte de previsão e d é a ordem de diferenciação.

Tendo conhecimento da equação de transformação que homogeneiza a variação dos dados, bem como a diferenciação necessária para fazer com que os dados se tornem estacionários, deve-se identificar as ordens referentes aos parâmetros de MA simples e sazonal (q e Q) e de AR simples e sazonal (p e P) dos potenciais métodos. Para tanto, utiliza-se os coeficientes de autocorrelação (ACF) para identificar as ordens dos parâmetros de AR (p e P). De forma semelhante, utiliza-se a autocorrelação parcial da série estacionária (PACF) para identificar as ordens dos parâmetros de MA (q e Q) (BOX; JENKINS; REINSELL, 1994).

Em casos onde métodos híbridos estão sendo utilizados (ARMA e ARIMA), os parâmetros das equações podem ser estimados através de um procedimento de otimização não linear, buscando a minimização da soma dos quadrados dos erros. Geralmente, o método dos mínimos quadrados é utilizado em *softwares* que disponibilizam o método de B-J (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

Em seguida, a aleatoriedade dos resíduos (diferença entre a demanda atual e os valores estimados pelo método potencial) é verificada. Espera-se que para resíduos aleatórios, as análises de ACF e PACF não apresentem nenhum coeficiente de autocorrelação ou autocorrelação parcial significativo, fato que sinaliza que o método é apropriado. Caso contrário, outro método deve ser considerado e repetido o processo (MAKRIDAKIS; HIBON, 1997; MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

Uma vez definido o método, o método identifica as correlações históricas entre os dados da série temporal e os extrapola para períodos futuros, sendo obtidas as previsões (MAKRIDAKIS; HIBON, 1997; MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998). Em seguida, os métodos matemáticos correspondentes aos termos AR e MA e os métodos ARMA e ARIMA são apresentados.

- **Processos Auto-regressivos**

O método $AR(p)$ é apresentado na equação (17), sendo esta uma regressão da variável dependente em função de seus valores passados. Esta equação pode ser reescrita em função do operador B , resultando na equação (18), ou ainda em sua forma simplificada, como indicado pela equação (19) (BOX; JENKINS; REINSELL, 1994; MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

$$Y_t = c + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \varepsilon_t \quad (17)$$

$$(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) Y_t = \varepsilon_t \quad (18)$$

$$\phi(B) Y_t = \varepsilon_t \quad (19)$$

onde c é o termo constante, ϕ_t é o coeficiente de auto-regressão do período t , ε_t é o erro aleatório no período t e $\phi(B)$ é um polinômio auto-regressivo de ordem p .

- **Processos de Média Móvel**

O método de média móvel MA(q) realiza a regressão da variável Y_t em função dos erros passados (ε_{t-q}), conforme indicado na equação (20). A sua forma polinomial é apresentada na equação (21) (BOX; JENKINS; REISELL, 1994; MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

$$Y_t = c - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} + \varepsilon_t \quad (20)$$

$$Y_t = \theta(B)\varepsilon_t \quad (21)$$

onde θ_t representa o coeficiente de média móvel do período t e $\theta(B)$ é um polinômio de média móvel de ordem q .

- **Processos ARMA e ARIMA**

Os processos Auto-regressivos e de Média Móvel ARMA(p,q) se baseiam nas características de processos AR(p) e MA(q) de forma combinada, sendo possível a sua modelagem para qualquer série estacionária. Seu método pode ser apresentado através da equação (22) ou ainda em sua forma polinomial, apresentada na equação (23). Verifica-se que os métodos AR(p) e MA(q) podem ser analisados como casos específicos de um método ARMA(p,q), sendo representados pelas notações ARMA($p,0$) e ARMA($0,q$) respectivamente (BOX; JENKINS; REISELL, 1994; MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

$$Y_t = c + \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q} \quad (22)$$

$$\phi(B)Y_t = c + \theta(B)\varepsilon_t \quad (23)$$

Nos casos onde a série temporal necessita de processos de diferenciação para que a estacionariedade seja verificada, utiliza-se o processo ARIMA(p,d,q), apresentado na equação (24). Esta notação também representa o método geral do método B-J não sazonal (BOX;

JENKINS; REINSELL, 1994). Os atributos p , d e q podem assumir valores entre 0, 1 e 2, sendo possível ajustar os métodos para uma grande variedade de métodos de previsão (BOX; JENKINS; REISELL, 1994; MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

$$\phi(B)(1-B)^d Y_t = \theta(B)\varepsilon_t \quad (24)$$

- **Métodos Sazonais**

A versão sazonal da equação (24) é representada pelo método ARIMA $(P,D,Q)_s$. Para tanto, o operador B é substituído pelo operador sazonal B^s , conforme apresentado na equação (25). O método geral sazonal ARIMA $(p,d,q)(P,D,Q)_s$ é apresentado na equação (26). (BOX; JENKINS; REINSELL, 1994; MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

$$\Phi(B^s)(1-B^s)^D Y_t = \Theta(B^s)\varepsilon_t \quad (25)$$

$$\phi(B)\Phi(B^s)(1-B)^d(1-B^s)^D Y_t = \theta(B)\Theta(B^s)\varepsilon_t \quad (26)$$

onde $\Phi(B^s)$ é um polinômio auto-regressivo sazonal de ordem P e $\Theta(B^s)$ é um polinômio de média móvel sazonal de ordem Q .

Em aplicações mais simples, o método envolve somente a análise de uma única variável, ou seja, a extrapolação da série temporal ocorre baseada somente em seu próprio comportamento histórico. Para aplicações mais complexas, são utilizados métodos que consideram o relacionamento existente entre as séries temporais estudadas e outras séries que de alguma forma afetam a série considerada no processo de previsão (ARCHER, 1980).

2.2.2 Análise de Regressão

O método de análise de regressão é um método causal baseado na análise estatística do comportamento histórico de variáveis relacionadas à variável de interesse para a previsão

(ARCHER, 1980). Este método necessita de dados quantitativos como entrada do processo preditivo, além de outras entradas subjetivas necessárias para selecionar as variáveis que afetam a variável de interesse (CHAMBERS; MULLICK; SMITH, 1971; MENTZER; GOMES, 1989). Ele é considerado um dos métodos de previsão mais precisos, porém requer uma grande quantidade de dados para que seja efetivo (MENTZER; GOMES, 1989).

Métodos causais visam estabelecer relações entre a demanda (variável dependente ou a ser prevista) e variáveis internas e/ou externas à organização (variáveis independentes ou explanatórias) que de alguma forma afetam a demanda. As variáveis independentes são analisadas juntamente com a série histórica de demanda visando a identificação do relacionamento entre as variáveis, bem como a intensidade destas relações. Nos casos onde a relação causal é intensa, as variáveis independentes podem ser utilizadas em processos preditivos (MENTZER; GOMES, 1989).

Quando se verifica que existem diversas variáveis explanatórias (X_1, X_2, \dots, X_k) relacionadas à uma variável a ser prevista (Y) e se deseja encontrar uma função que as relacione, é utilizada a Regressão Múltipla. Nos casos onde se tem somente uma variável explanatória, utiliza-se a Regressão Simples, com método apresentado na equação (27).

$$Y_t = \alpha + \beta X_t + \varepsilon_t \quad (27)$$

onde α é o coeficiente linear (ponto que intercepta o eixo y), β é o coeficiente angular (declividade da reta) e ε_t é o erro aleatório no período t (desvio da observação em relação ao método linear).

Em seu processo, o método de regressão múltipla formula uma hipótese relacionando uma variável dependente com diferentes variáveis independentes (ARCHER, 1980). Em seguida, dados para cada variável independente são obtidos, preferencialmente com uma série temporal para cada variável. Uma lista de variáveis que influenciam Y é determinada com base: (i) na experiência de especialistas, (ii) na disponibilidade dos dados, e (iii) em restrições de tempo e custo. Esta lista é “filtrada”, sendo verificadas quais são as variáveis importantes. Para tanto, são utilizados procedimentos formais, tais como regressões de subconjuntos de variáveis, análise de componentes principais de todas as variáveis, entre outros (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

Uma vez verificado que as variáveis independentes influenciam consideravelmente a demanda, elas poderão ser utilizadas para prever valores futuros. Caso se verifique que esta influência é pequena, elas deverão ser excluídas da lista (MENTZER; GOMES, 1989).

A forma funcional do método de regressão é desenvolvida em conjunto com a lista de variáveis candidatas. Em seguida, os parâmetros do método são estimados, valendo-se de dados coletados para este propósito. (MAKRIDAKIS; WHEELWRIGHT; HYNDAMAN, 1998). A forma mais simples do método de regressão múltipla é a forma linear, apresentada na equação (28) (ARCHER, 1980).

$$Y_t = \beta_0 + \beta_1 X_{1,t} + \beta_2 X_{2,t} + \dots + \beta_k X_{k,t} + e_t \quad (28)$$

onde e_t é a estimativa do erro no período t .

Alguns métodos podem ser utilizados para se determinar os valores dos coeficientes β_k da equação de regressão, sendo os mais comuns o método dos mínimos quadrados ordinários, da máxima verossimilhança, dos mínimos quadrados ponderados, dos mínimos quadrados parciais e dos mínimos quadrados generalizados (WERNER, 2004). Normalmente, estes coeficientes são obtidos através de pacotes computacionais (MAKRIDAKIS; WHEELWRIGHT; HYNDAMAN, 1998).

Para obter uma previsão com o método de regressão múltipla, um conjunto de valores futuros das variáveis explanatórias deve ser determinado ($\hat{X}_{k,t}$). Estes valores são aplicados na equação de regressão e um valor de \hat{Y}_t é obtido através da equação (29). A equação (29) baseia-se no pressuposto que as variáveis explanatórias são medidas sem erros. Quando previsões de Y são feitas, elas dependem dos valores de variáveis explanatórias, sendo primordiais previsões precisas destas variáveis (MAKRIDAKIS; WHEELWRIGHT; HYNDAMAN, 1998).

$$\hat{Y}_t = b_0 + b_1 \hat{X}_{1,t} + b_2 \hat{X}_{2,t} + \dots + b_k \hat{X}_{k,t} \quad (29)$$

onde b_k é a estimativa do coeficiente de regressão.

Algumas vezes pode se tornar interessante considerar que as variáveis dependentes e independentes se relacionem de outra forma que não linearmente. Verifica-se que a forma multiplicativa, apresentada na equação (30), é mais comumente utilizada. Outra possibilidade é a representação em uma forma linear logarítmica (ARCHER, 1980).

$$Y_t = b_0 X_1^{b_1} X_2^{b_2} \dots X_k^{b_k} \varepsilon_t \quad (30)$$

No que diz respeito a desempenho, verifica-se que a demanda por grandes quantidades de previsões faz com que o método se torne lento na resposta às mudanças de padrão de demanda ou mudanças nas relações entre as variáveis. Por este motivo, diz-se que quanto maior o número de previsões necessárias no processo preditivo, menos controlável torna-se o método de análise de regressão (MENTZER; GOMES, 1989).

Este método é especialmente recomendado quando se deseja realizar previsões em nível corporativo, o horizonte das previsões é de médio e longo prazo, e estão disponíveis grandes quantidades de informação sobre variáveis causais (MENTZER; GOMES, 1989; MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

2.3 MEDIDAS DE ACURÁCIA

Medidas de acurácia são ferramentas utilizadas na avaliação da precisão dos métodos de previsão de demanda. Através de seu uso é possível selecionar o método com o melhor desempenho ou ainda ajudar na geração de evidências para que o sistema produtivo possa responder rapidamente às mudanças de padrões de demanda e de mercado (KAHN, 1998).

A literatura apresenta diversas maneiras de se medir a acurácia de um sistema de previsão de demanda, sendo comum a apresentação em forma de percentuais de erro absoluto ou erros quadrados (THOMAS, 1996). Os erros dos métodos são indicados baseados em análises de medidas de tendência central, tais como medianas, médias aritméticas e geométricas (ARMSTRONG; COLLOPY, 1992).

A Tabela 4 apresenta as principais técnicas para medir a acurácia de um sistema de previsão de demanda. A seguinte notação é utilizada na tabela: Y_t é o valor de demanda atual no período t , \hat{Y}_t é a previsão de demanda no período t , A é o método de previsão A , B é o

método de previsão B (de maneira geral, se utiliza o método de *Naive*, onde a previsão para o período t é igual ao valor da demanda verificado em $t - 1$) e n é o número de períodos considerados para o cálculo da medida de acurácia.

Tabela 4: Medidas de Acurácia

Sigla	Medida de Acurácia	Equação
ME	<i>Mean Error</i> Erro Médio	$ME = \frac{1}{n} \sum_{t=1}^n Y_t - \hat{Y}_t$
MAE	<i>Mean Absolute Error</i> Erro Absoluto Médio	$MAE = \frac{1}{n} \sum_{t=1}^n Y_t - \hat{Y}_t $
MPE	<i>Mean Percentual Error</i> Erro Percentual Médio	$MPE = \frac{1}{n} \sum_{t=1}^n \frac{Y_t - \hat{Y}_t}{Y_t}$
APE	<i>Absolute Percentual Error</i> Erro Percentual Absoluto	$APE = \left \frac{Y_t - \hat{Y}_t}{Y_t} \right $
MAPE	<i>Mean Absolute Percentual Error</i> Média dos Erros Percentuais Absolutos	$MAPE = \frac{1}{n} \sum_{t=1}^n \left \frac{Y_t - \hat{Y}_t}{Y_t} \right $
MSE	<i>Mean Squared Error</i> Erro quadrático Médio	$MSE = \frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t)^2$
RMSE	<i>Root Mean Squared Error</i> Raiz do Erro Quadrático Médio	$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t)^2}$
GRMSE	<i>Geometric Root Mean Squared Error</i> Raiz da Média Geométrica do Erro Quadrático	$GRMSE = \sqrt[2n]{\prod_{t=1}^n (Y_t - \hat{Y}_t)^2}$
RGRMSE	<i>Relative Geometric Root Mean Squared Error</i> Raiz da Média Geométrica Relativa do Erro Quadrático	$RGRMSE = \frac{\sqrt[2n]{\prod_{t=1}^n (Y_t - \hat{Y}_{t,A})^2}}{\sqrt[2n]{\prod_{t=1}^n (Y_t - \hat{Y}_{t,B})^2}}$
RAE	<i>Relative Absolute Error</i> Erro Absoluto Relativo	$RAE = \left \frac{Y_t - \hat{Y}_{t,A}}{Y_t - \hat{Y}_{t,B}} \right $
MRAE	<i>Mean Relative Absolute Error</i> Média do Erro Absoluto Relativo	$MRAE = \frac{1}{n} \sum_{t=1}^n \left \frac{Y_t - \hat{Y}_{t,A}}{Y_t - \hat{Y}_{t,B}} \right $
GMRAE	<i>Geometric Mean Relative Absolute Error</i> Média Geométrica dos Erros Absolutos Relativos	$GMRAE = \sqrt[2n]{\prod_{t=1}^n \left \frac{Y_t - \hat{Y}_{t,A}}{Y_t - \hat{Y}_{t,B}} \right }$

Fonte: Ringuest e Tang, 1987; Armstrong e Collopy, 1992; Elsayed e Boucher, 1994; Sanders e Ritzman, 1995; Pollock *et al.*, 1999; Rasmussen, 2004; Syntetos e Boylan, 2005.

O nível de acurácia requerido no resultado de uma previsão é um dos fatores mais importantes quando se está avaliando os métodos de previsão. Verifica-se que muitas vezes o custo para melhorar a acurácia de um sistema de previsão pode exceder os benefícios gerados pelos métodos (MENTZER; GOMES, 1989).

O método escolhido para se medir a acurácia de um sistema de previsão de demanda está relacionado com a sua situação de uso (seleção de método ou calibração de um método) e com o número de séries temporais analisadas (ARMSTRONG; COLLOPY, 1992). Diversos autores apresentam estudos indicando os métodos mais adequados para cada situação, porém Armstrong e Collopy (1992) afirmam que o uso combinado de diferentes métodos pode ser utilizado para compensar os defeitos das diferentes medidas.

Elsayed e Boucher (1994) indicam o uso do MAE para cálculos de acurácia. Já Carbone e Armstrong (1982) sugerem que para estudos empíricos a melhor maneira de se medir a acurácia é através do uso do MSE. Uma ressalva é feita quando há comparações entre diferentes séries, pois a medida resultante do uso do MSE depende da escala dos dados apresentados.

Diversos autores apontam o MAPE como o método de medida de acurácia mais utilizado nos casos de estudos empíricos com comparação entre métodos de previsão. Isto, porque ele é menos afetado por valores extremos quando comparado à medidas quadradas, utiliza percentuais de erro e também não depende da unidade dos dados (controle de escala) (BOPP, 1985; LAWRENCE; EDMUNDSON; O'CONNOR, 1986; RINGUEST; TANG, 1987; ARMSTRONG; COLLOPY, 1992; KAHN, 1998).

Para comparações entre métodos, verifica-se que o RMSE tem sido amplamente utilizado (CARBONE; ARMSTRONG, 1982; BOPP, 1985), porém seu uso é desaconselhado na comparação de séries. Quando se analisa poucas séries temporais, o uso do MdRAE é sugerido, sendo seu uso limitado por problemas de interpretação da medida pelos tomadores de decisão. Já para os casos onde são muitas as séries a serem comparadas, é indicado o MdAPE (ARMSTRONG; COLLOPY, 1992).

2.4 INTEGRAÇÃO DE MÉTODOS QUALITATIVOS E QUANTITATIVOS

A acurácia das previsões é afetada por erros na mensuração dos dados, erros aleatórios da previsão, padrões de demanda irregulares, e escolha de métodos que minimizam erros de ajuste à série histórica, mas geram erros em períodos futuros (ASHTON; ASHTON, 1985; BLATTBERG; HOCH, 1990; MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

Verifica-se que, quando dois métodos de previsão de demanda são utilizados para prever a mesma variável e estes indicam previsões semelhantes, o tomador de decisão estará tranqüilo quanto ao valor previsto a ser utilizado. Por outro lado, quando as previsões obtidas são muito distintas, pode-se rejeitar as estimativas e realizar novas previsões, aceitar as duas estimativas como limites inferior e superior de um intervalo de previsão, selecionar somente uma das estimativas, ou tentar integrar os métodos visando chegar a um único valor de previsão (THOMAS, 1987).

Desta forma, a integração de métodos de previsão é freqüentemente utilizada no intuito de melhorar a acurácia das previsões (CHEN; KUNG, 1984; BOPP, 1985). Estudos apresentam evidências de que a integração, em especial de métodos quantitativos e qualitativos, é a melhor maneira para se obter previsões mais acuradas (RINGEST; TANG, 1987; CLEMEN, 1989; BLATTBERG; HOCH, 1990; COLLOPY; ARMSTRONG, 1992).

A integração dos métodos se baseia em duas decisões: (i) a escolha dos métodos de previsão que serão integrados (quantitativos, qualitativos ou ambos); e (ii) a seleção do método de integração (integração subjetiva ou matemática) (MACKAY; METCALFE, 2002). Deve se prestar atenção para que os métodos escolhidos tenham suas previsões baseadas em diferentes considerações e dados. Também é indicado que se evite o uso de métodos com correlação positiva entre os erros de previsão (BUNN; WRIGHT, 1991).

Nos casos onde é importante evitar grandes erros nas previsões e em situações dinâmicas, onde os métodos quantitativos não conseguem agregar aos métodos matemáticos as mudanças internas e externas do ambiente organizacional, é sugerida a integração de análises subjetivas ao processo preditivo (GOODWIN, 2000a; ARMSTRONG, 2001b). Verifica-se que análises subjetivas podem reconhecer eventos especiais nas séries temporais e antecipar a ocorrência de novos eventos futuros (REINMUTH; GUERTS *apud* BUNN; WRIGHT, 1991; GOODWIN, 2000a). A utilização de métodos puramente quantitativos exigiria uma etapa de tratamento da série histórica visando remover os efeitos destes eventos especiais. Este fato acarreta em um aumento dos custos, principalmente nos casos onde muitas previsões são necessárias no curto prazo (GOODWIN, 2002).

As previsões geradas através de métodos qualitativos podem ser baseadas em conhecimento contextual e/ou conhecimento técnico (WEBBY; O'CONNOR, 1996). Verifica-se que o uso de métodos qualitativos baseados em conhecimento contextual possibilita previsões mais acuradas quando comparado com o desempenho dos métodos baseados em conhecimento técnico (SANDERS; RITZMAN, 1995).

As vantagens dos métodos de previsão baseados em conhecimento contextual estão diretamente relacionadas com a variabilidade existente na série temporal analisada. Verifica-se que quanto maior a variabilidade devido a eventos especiais, maior também será a necessidade de intervenções subjetivas no processo preditivo. Em séries onde o padrão de demanda é estável, não se verificam ganhos expressivos de acurácia com a utilização de métodos qualitativos, sendo indicada a integração com métodos de previsão estatística (SANDERS; RITZMAN, 1995).

A principal vantagem da integração de métodos quantitativos com qualitativos é a incorporação de conhecimento sobre a natureza e comportamento das variáveis de interesse no processo preditivo. A qualidade deste conhecimento está relacionada à habilidade do especialista em captar o real significado da informação contextual. A informação contextual geralmente é obtida através de séries temporais, de fontes de informações públicas e/ou de fontes internas da organização (WEBBY; O'CONNOR, 2001).

O uso de estratégias estruturadas para a integração de métodos reduz a ocorrência de resultados tendenciosos e facilita a incorporação de informação contextual à previsão de demanda (WEBBY; O'CONNOR; EDMUNDSON, 2004). Esta integração pode ocorrer com o uso de uma ou da combinação de quatro maneiras: (a) Ajuste subjetivo; (b) Decomposição de séries temporais; (c) Combinação de previsões; e, (d) Desenvolvimento de um método de previsão (WEBBY; O'CONNOR, 1996). A escolha do melhor método de integração dependerá das condições específicas aplicadas a uma determinada situação (GOODWIN, 2002).

2.4.1 Ajuste Subjetivo

O ajuste subjetivo agrega informação contextual à previsão, informação que o método matemático geralmente não considera ou que a série temporal não inclui (WEBBY; O'

CONNOR, 1996). O uso deste método é indicado quando existe um grande conhecimento sobre as variáveis a serem preditas e sobre mudanças que afetarão estas variáveis, quando há situações com alto grau de incerteza, e quando informações contextuais invalidam a suposição de constância dos padrões de demanda passados (WRIGHT; LAWRENCE; COLLOPY, 1996; SANDERS; RITZMAN, 2001).

O método consiste na análise da estimativa quantitativa e seu ajuste em função de fatores contextuais (passado e futuros) para produzir a previsão final, conforme apresentado na Figura 2.




Figura 2: Ajuste subjetivo de previsões (Adaptado de: WEBBY; O'CONNOR, 1996)

Verifica-se que esta alternativa de integração apresenta, na maioria dos casos, o melhor custo/benefício, além de ser uma das mais fáceis de ser implementada. Por outro lado, é importante que os especialistas sejam habilidosos em traduzir corretamente os fatores contextuais para evitar que sejam inseridas informações tendenciosas no processo preditivo (WEBBY; O'CONNOR, 1996).

A eficiência do ajuste subjetivo está diretamente ligada à acurácia da previsão quantitativa. Se a previsão não for precisa, não é indicada a associação de informações contextuais à previsão. Nestes casos, utiliza-se o conhecimento técnico para realizar o ajuste (WEBBY; O'CONNOR, 1996). O uso de um método estruturado para realizar o ajuste diminui a limitação do especialista em considerar um grande volume de informações (SANDERS; RITZMAN, 2001).

2.4.2 Decomposição de séries temporais

Nos casos onde existe um padrão na série temporal analisada, ele pode ser decomposto em seus componentes para ajudar no entendimento do comportamento da série (WEBBY; O'CONNOR, 1996). A decomposição de séries temporais em seus componentes é indicada em casos onde: (i) as séries temporais são afetadas por fatores causais que têm efeitos conflitantes sobre o comportamento da série, (ii) a incerteza é grande, (iii) o domínio de conhecimento pode ser utilizado na decomposição das séries, e (iv) pode-se obter previsões mais acuradas para os componentes do que para a série temporal (ARMSTRONG, 2001d; MacGREGOR, 2001; ARMSTRONG; COLLOPY; YOKUM, 2005).

Durante o processamento dos métodos de decomposição, são identificados os dois componentes que caracterizam as séries temporais: a tendência-ciclo e o fator sazonal. A tendência-ciclo representa as mudanças de longo prazo no nível da série. Na maioria dos procedimentos de decomposição, este componente é tratado como um componente único, porém há alguns métodos que o separam em um componente de tendência e outro de ciclo (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998; BALLOU, 2001).

O método de decomposição de séries temporais realiza a previsão de um elemento de cada vez, buscando, desta forma, reduzir a complexidade do processo preditivo (GOODWIN; WRIGHT, 1994). O método procura remover os efeitos dos fatores contextuais passados da série temporal, gerando uma previsão quantitativa ajustada com fatores contextuais futuros. A informação contextual é inserida no sistema preditivo através de um processo estruturado oferecido pelo método (WEBBY; O'CONNOR, 1996).

A decomposição se realiza em três etapas, sendo que os métodos quantitativos e qualitativos podem operar em qualquer das etapas. Primeiramente, identificam-se os componentes da série histórica pela decomposição. Em seguida, são realizadas previsões a partir das séries decompostas e é realizado o ajuste dos componentes pelo especialista. Por fim, os componentes ajustados são combinados de forma a gerar as previsões finais. A Figura 3 apresenta um diagrama resumido do método (BUNN; WRIGHT, 1991; GOODWIN; WRIGHT, 1994; WEBBY; O'CONNOR, 1996).

Os métodos de decomposição assumem a presença de um padrão e de um elemento de erro ou aleatoriedade na série temporal (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998). Existem diversos métodos matemáticos de decomposição de séries temporais, sendo estes representados de acordo com o método de decomposição utilizado: aditivo ou multiplicativo (ARMSTRONG; COLLOPY; YOKUM, 2005).

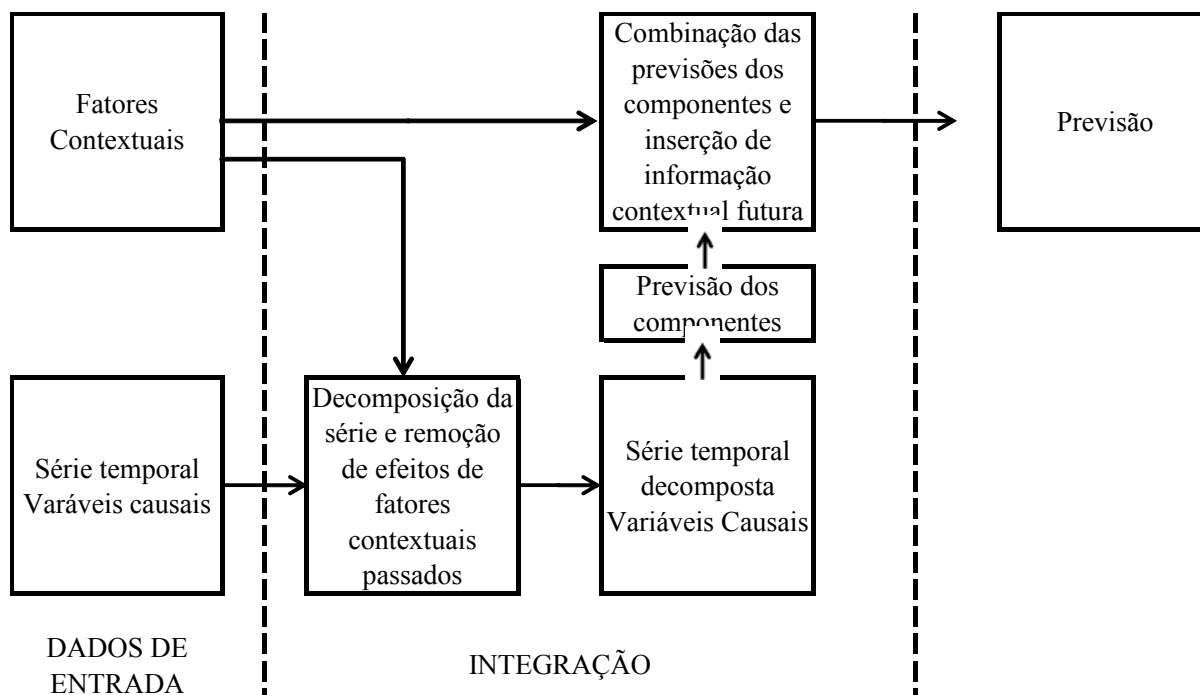


Figura 3: Decomposição de séries temporais (Adaptado de: WEBBY; O'CONNOR, 1996).

A representação mais comum é a aditiva. Nesta forma, os componentes sazonais, tendência-ciclo e irregular são simplesmente adicionados, conforme apresentado na equação (35) (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

$$Y_t = S_t + T_t + E_t \quad (31)$$

onde Y_t é o valor pontual da série temporal no período t , S_t é o componente sazonal no período t , T_t é o componente tendência-ciclo no período t e E_t é o componente irregular (erro) no período t .

Esta modelagem é indicada nos casos onde a magnitude das flutuações sazonais não varia com o nível das séries. Para se utilizar o método aditivo o processo passa por algumas etapas. Na primeira, o componente tendência-ciclo é obtido utilizando a média móvel. Em seguida, os componentes sazonais são determinados. Assumindo que o componente sazonal é constante de ano para ano, calcula-se um valor para cada ciclo sazonal. Por último, o termo irregular é obtido da diferença entre os dados originais da série e a soma da estimativa de

sazonalidade com a tendência-ciclo (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

O método multiplicativo é indicado nos casos onde as flutuações sazonais aumentam e/ou diminuem proporcionalmente com a variação do nível das séries, sendo apresentado pela equação (32) (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

$$Y_t = S_t \times T_t \times E_t \quad (32)$$

As etapas para a utilização do método multiplicativo são semelhantes às do método aditivo, sendo verificada diferença somente na última etapa. Nela, o termo irregular é obtido através da divisão dos dados originais da série pelas estimativas de sazonalidade e tendência-ciclo (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

Os métodos de decomposição apresentam falhas sob a ótica estatística. Apesar disto, eles têm sido empregados com considerável sucesso. A decomposição mostra-se uma ferramenta útil para se entender as séries temporais (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998), sugerindo possíveis causas de variação e ajudando a identificar as suas estruturas. Desta forma, este método auxilia no entendimento dos problemas, facilitando a obtenção de previsões mais acuradas (ARMSTRONG; COLLOPY; YOKUM, 2005).

2.4.3 Combinação de Previsões

O principal motivo pelo qual se realiza combinações de métodos de previsão de demanda é o aumento da acurácia das previsões. Isto ocorre devido à agregação de informações independentes ao processo preditivo, as quais suavizam os erros de cada uma das previsões individuais (ASHTON; ASHTON, 1985; FLORES; WHITE, 1988; WINKLER, 1989). Diversas pesquisas foram realizadas para verificar as diferenças de desempenho de previsões combinadas e individuais. Foi observado que, nas previsões combinadas, houve melhora na acurácia e diminuição na variabilidade da acurácia, quando comparado com as previsões individuais (MAKRIDAKIS; WINKLER, 1983; LAWRENCE; EDMUNDSON;

O'CONNOR, 1986; GEORGOFF; MURDICK, 1986; CLEMEN, 1989; BLATTBERG; HOCH, 1990; HIBON; EVGENIOU, 2005).

Durante o processo de combinação de previsões, pode-se utilizar diferentes dados históricos, diferentes técnicas de coleta e interpretação de dados e métodos distintos de previsões (JICK, 1979; ARMSTRONG, 2001b). Verifica-se que, quanto mais os dados e os métodos forem diferentes e não houver uma alta correlação entre as previsões, melhor será o desempenho da combinação em relação às previsões individuais (SANDERS, 1997b; ARMSTRONG, 2001b).

Nos casos onde se encontram problemas para selecionar o melhor método de previsão de demanda para uma determinada necessidade, uma combinação de previsões normalmente gera uma previsão com melhor acurácia que um método individual (BATES; GRANGER, 1969; GEORGOFF; MURDICK, 1986; HIBON; EVGENIOU, 2005). Nos casos onde a variável a ser prevista tem comportamento instável, podem ocorrer problemas, tais como a perda de precisão da previsão (WEBBY; O'CONNOR, 1996).

A combinação de previsões de demanda depende de três fatores: o método de combinação, a natureza das previsões, e o número de previsões combinadas (GOODWIN; WRIGHT, 1994). A Figura 04 apresenta um diagrama resumido de combinações de métodos qualitativos e quantitativos.

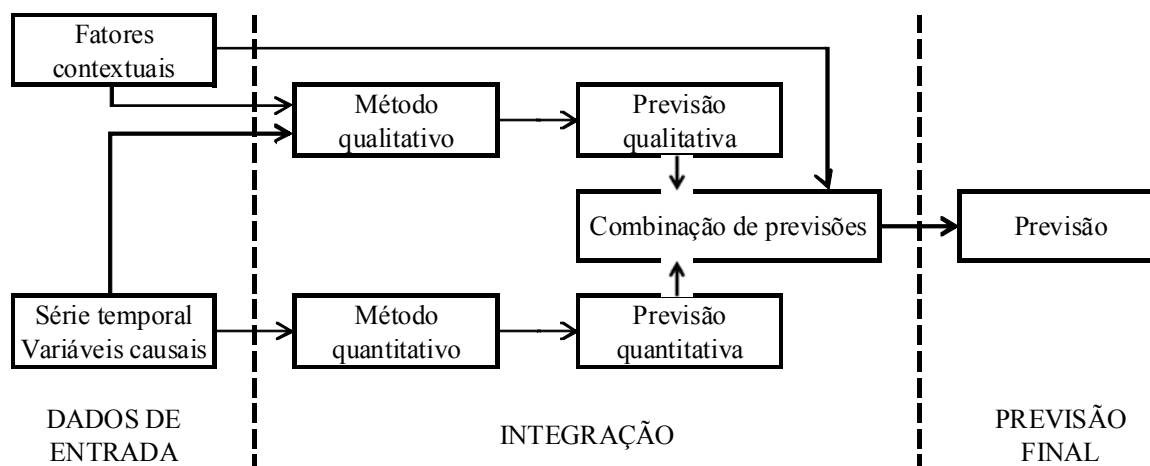


Figura 4: Combinação de métodos quantitativos e qualitativos (Adaptado de: WEBBY; O'CONNOR, 1996)

Existem duas maneiras de se obter combinações de previsões: (a) por métodos qualitativos, baseado na opinião e experiência de especialistas ou grupo de especialistas; e (b) através de métodos quantitativos, que utilizam métodos estatísticos (THOMAS, 1987; WINKLER, 1989; GOODWIN; WRIGHT, 1993; SANDERS; 1997b). Estudos de Lawrence, Edmundson e O'Connor (1986) indicam que as combinações quantitativas resultam em previsões mais acuradas quando comparadas às previsões das combinações qualitativas.

As combinações qualitativas se caracterizam por atribuir a especialistas ou a grupos de especialistas a determinação dos pesos das previsões quantitativas e qualitativas durante o processo de combinação das previsões individuais. Por este motivo, este método pode se tornar tendencioso e atribuir menor representação às previsões quantitativas, podendo inclusive ignorá-las (GOODWIN; WRIGHT, 1994; GOODWIN, 2000a; GOODWIN, 2000b).

Já as combinações quantitativas se caracterizam por gerar previsões finais que são resultado de previsões independentes, resultantes de métodos estatísticos combinados com previsões quantitativas. O método mais simples de combinação quantitativa é a aplicação da média aritmética das estimativas produzidas por cada método individual (ASHTON; ASHTON, 1985; HIBON; EVGENIOU, 2005).

O uso de médias aritméticas é recomendado quando as séries históricas têm alta incerteza e instabilidade, sendo utilizada como ponto de partida para a combinação das previsões (FLORES; WHITE, 1988; WINKLER, 1989; ARMSTRONG; COLLOPY *apud* GOODWIN, 2000b; ARMSTRONG, 2001e). Estudos de Makridakis e Winkler (1983) e Ringuest e Tang (1987) recomendam o uso de médias aritméticas como método de combinação de previsões, exceto nos casos onde há fortes evidências de que um método de previsão em particular tem melhor desempenho para uma dada situação.

Verifica-se que o uso de médias assegura que a previsão combinada vai ter sempre um melhor desempenho se comparada a pior previsão (THOMAS, 1996). Por outro lado, quando houver uma grande disparidade entre os valores de acurácia das previsões, a combinação vai gerar uma previsão com precisão inferior à de melhor previsão (WEBBY; O'CONNOR, 1996).

A média aritmética possui a vantagem de ser operacionalmente simples, contudo não considera a acurácia relativa de cada previsão individual. Esta informação pode ser incorporada através da previsão combinada com média ponderada. Os ganhos de acurácia obtidos com o uso de médias ponderadas, quando comparados com médias aritméticas são

muito pequenos, sendo considerada a combinação por médias aritméticas a solução ideal (ASHTON; ASHTON, 1985). Outros estudos reforçam esta escolha, quando afirmam que as combinações por médias aritméticas são mais precisas do que as médias ponderadas (MAKRIDAKIS; WINKLER, 1983; RINGUEST; TANG, 1987).

Para a determinação dos pesos ideais para as previsões individuais, devem-se minimizar os erros da previsão combinada (DEUTSH; GRANGER; TERÄSVIRTA, 1994). Para tanto, as previsões individuais não podem ser tendenciosas, deve existir um padrão estacionário de erros das previsões e o número de dados históricos deve permitir estimar pesos ótimos confiáveis. Verifica-se que, em geral, estes pré-requisitos não são atendidos (BATES; GRANGER, 1969; FLORES; WHITE, 1988; GOODWIN, 2002).

Para se definir o número de previsões que devem ser incorporadas à previsão final, deve-se considerar a relação existente entre o aumento da acurácia e os custos associados à obtenção das previsões individuais (ASHTON; ASHTON, 1985). Os ganhos com o aumento do número de previsões na combinação diminui à medida que a correlação entre as previsões individuais aumenta e pouca informação nova é adicionada (GOODWIN, WRIGHT, 1994). O número ideal de previsões que devem ser combinadas diverge entre os diversos estudos. Armstrong (2001f) sugere que sejam utilizados ao menos cinco métodos distintos, considerando que a taxa de melhoria da acurácia diminui com a adição de mais métodos na combinação. Já Flores e White (1988) sugerem que são necessárias de duas a quatro previsões para a obtenção de maiores ganhos no processo de previsão de demanda.

2.4.4 Desenvolvimento de Métodos de Previsão

O desenvolvimento de métodos de previsão de demanda necessita que informações subjetivas sejam incorporadas nos processos de seleção de variáveis, estimativa de parâmetros, análise de dados e na seleção de métodos de previsão (BUNN; WRIGHT, 1991; GOODWIN, 2002). Alguns métodos automatizam a seleção de métodos e a estimativa de parâmetros, porém a seleção de variáveis é um processo puramente subjetivo (WEBBY; O'CONNOR, 1996). É recomendado que as informações subjetivas sejam utilizadas como *inputs* dos métodos de previsão e não que estas sirvam como ajuste dos resultados finais do processo preditivo (GEORGOFF; MURDICK, 1986). O fluxo resumido do desenvolvimento

de um método de previsão que integra métodos quantitativos e qualitativos é apresentado na Figura 05.




Figura 5: Desenvolvimento de um método de previsão que integra métodos quantitativos e qualitativos (Adaptado de: WEBBY; O'CONNOR, 1996)

Um método estatístico pode ser desenvolvido utilizando séries temporais ou variáveis causais. A informação contextual pode ser incorporada ao método através de duas maneiras: (i) quantificando a informação subjetiva em um método matemático; e/ou (ii) identificando os eventos especiais e agregando a informação no processo de desenvolvimento do método e nas estimativas dos parâmetros do método (WEBBY; O'CONNOR, 1996).

O estudo de Armstrong e Brodie (1999) relaciona o nível de integração entre métodos quantitativos e qualitativos, conforme apresentado na Figura 6. Os métodos de Analogia, Análise Conjunta, *Bootstrapping* Subjetivo, Previsão baseada em regras, Métodos Econométricos e Sistemas Especialistas utilizam métodos de previsão desenvolvidos a partir da integração de análises estatísticas e análises subjetivas (ARMSTRONG; BRODIE, 1999).

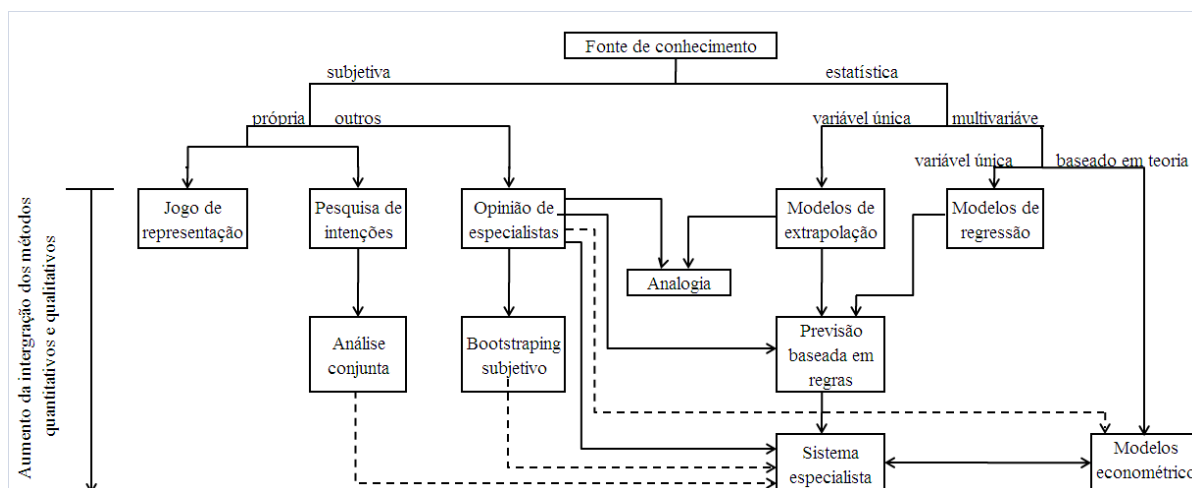


Figura 6: Integração entre métodos de previsão – linha pontilhadas indicam possíveis relações. (Adaptado de: ARMSTRONG; BRODIE, 1999)

Maiores detalhes sobre os métodos podem ser assim obtidos: Analogia (ARMSTRONG; BRODIE, 1999); Análise Conjunta (WITTINK; BERGESTEUN, 2001); *Bootstrapping* Subjetivo (ARMSTRONG, 2001b); Previsão baseada em regras (COLLOPY; ARMSTRONG, 1992; ARMSTRONG; ADYA; COLLOPY, 2001); Métodos Econométricos (CHAMBERS; MULLICK; SMITH, 1971); Sistema Especialista (COLLOPY; ADYA; ARMSTRONG, 2001).

3 MÉTODO PROPOSTO

Neste Capítulo são abordados os principais tópicos para o bom entendimento das atividades e dos dados relacionados às perdas comerciais na distribuição de energia elétrica. Adicionalmente, são apresentados métodos de previsão de demanda e de detecção de quedas de consumo atípicas utilizados nesse estudo. Nesse sentido, o Capítulo está dividido em quatro partes: Entendimento do Negócio, Entendimento dos Dados, Modelagem das Séries Temporais de Consumo de Energia Elétrica, e Apresentação do Método de Detecção de Quedas Atípicas de Consumo.

3.1 ENTENDIMENTO DO NEGÓCIO

Inicialmente cabe apontar alguns conceitos adotados pelo setor elétrico que também são utilizados neste estudo. Em relação às perdas de energia elétrica, denomina-se perda na distribuição o somatório de perda técnica e não técnica (ANEEL, 2008).

Perda técnica constitui a quantidade de energia elétrica, expressa em megawatt-hora por ano (MWh/ano), dissipada em decorrência das leis da Física, relativas aos processos de transporte, transformação de tensão e das perdas inerentes aos equipamentos de medição. Já a perda não técnica é aquela apurada pela diferença entre a perda total e a perda técnica, sendo consideradas todas as demais perdas associadas à distribuição de energia elétrica, tais como furtos de energia, erros de medição, erros no processo de faturamento, unidades consumidoras (UCs) sem equipamento de medição e outros (ANEEL, 2008).

A perda não técnica pode ser subdividida em três partes: *(i)* perdas comerciais, *(ii)* perdas por consumo de ligações clandestinas não acessáveis e *(iii)* outras perdas não técnicas. Conforme a Nota Técnica ANEEL n°290/2008 pode-se defini-las como apresentado na seqüência.

As perdas comerciais estão relacionadas com UCs regulares e são ocasionadas por problemas na medição de faturamento, por intervenção fraudulenta dos consumidores de tais unidades, além de outros problemas típicos superáveis pela gestão comercial das distribuidoras. Já as perdas por consumo de ligações clandestinas não acessáveis estão

relacionadas com o consumo derivado de ligações irregulares em que não se caracteriza a relação contratual do fornecimento de energia elétrica. As outras perdas não técnicas se originam da perda técnica provocada pela própria perda não técnica, e que, para fins pragmáticos, pode ser considerada como parte integrante de (i) e (ii).

A principal ferramenta para a redução das perdas comerciais em uma empresa de distribuição de energia elétrica é o uso de inspeções nas UCs (CABRAL; GONTIJO, 2004; AHMAD; MOHAMAD, 2007). As equipes de inspeção são enviadas a campo para que verifiquem as condições técnicas das medições e identifiquem eventuais irregularidades. Nos casos onde se identifica alguma irregularidade, a unidade consumidora é regularizada e autuada.

Uma vez regularizada, deixa de existir perda comercial naquela unidade consumidora, sendo possível verificar e quantificar os volumes de energia recuperados através da ação. Com vistas ao passado, é realizado o cálculo e a cobrança da energia deixada de ser faturada em função da irregularidade, conforme preconiza a Resolução ANEEL 456/2000. Já com vistas ao presente e ao futuro, pode-se quantizar o volume de energia recuperada em função do incremento verificado no registro de consumo de energia.

Apesar das inspeções em UCs serem uma ferramenta altamente eficaz para a redução das perdas comerciais, fatores como logística e custos operacionais devem ser considerados quando da contratação destes serviços. Em casos extremos, uma baixa efetividade nas inspeções pode originar um custo operacional maior para as empresas do que o próprio montante recuperado com a ação. Desta forma, é intuitivo crer que quanto maior for o índice de efetividade, maiores serão os ganhos das empresas.

A efetividade das inspeções em campo é um índice que pode ser obtido pela razão entre o número de inspeções que identificaram irregularidades com perda comercial e o número total de inspeções. Este índice é amplamente utilizado no setor elétrico, sendo considerado um dos principais indicadores de desempenho das ações de combate às perdas comerciais.

Diversas ações são tomadas pelas empresas de distribuição visando obter o maior índice de efetividade possível. Entre elas, costuma-se acompanhar os históricos de consumo dos clientes, visando identificar variações acentuadas. Desta forma é possível monitorar as UCs buscando identificar comportamentos suspeitos.

Contudo, observa-se em diversas distribuidoras de energia que o uso desta método em sua forma mais simples acarreta em algumas indicações falsas. O caso mais freqüente ocorre nas UCs com consumo tipicamente variável, tais como clientes sazonais (irrigantes, lavouras, casas de praia) e outros. Por este motivo, figurou-se a possibilidade de se adaptar este método e passar a considerar as características próprias de cada unidade consumidora. Desta forma, as análises de variações de consumo poderiam se adaptar às características intrínsecas de cada cliente, realizando uma análise mais completa.

Para tanto, o uso de previsões de consumo para as UCs torna-se interessante, pois é possível realizá-las de acordo com as características de cada cliente e, então, compará-las com os valores efetivamente verificados nos ciclos de leitura. As informações necessárias para realizar tais previsões podem ser facilmente obtidas, pois em sua grande maioria estão presentes nos bancos de dados das empresas. Como principal *input* do método de previsão, pode-se utilizar os registros históricos de consumo. Desta forma, é possível ajustar métodos matemáticos às séries temporais, possibilitando a previsão de consumo para um determinado período futuro. A qualidade dos métodos depende basicamente dos dados disponíveis, sendo importante considerar a duração das séries (número de meses com registro de consumo disponível) e a consistência dos dados (número de valores faltantes e incidências de valores atípicos).

3.2 ENTENDIMENTO DOS DADOS

Sabe-se que as distribuidoras de energia elétrica possuem registros semelhantes no que diz respeito aos dados de suas UCs. Estas informações, por sua vez, podem ser classificadas entre dados cadastrais, informações técnicas e históricos de eventos.

São considerados dados cadastrais todas as informações referentes ao cliente, tais como: nome, CPF/CNPJ, classe, ramo de atividade, etc. As informações técnicas dizem respeito às características técnicas da medição, como por exemplo os equipamentos instalados, circuitos, etc. Entre os históricos de eventos, pode-se citar os registros de leitura e faturamento, ordens de serviço e outros registros que informam algum evento ocorrido na unidade consumidora.

Ordenando os registros de leitura e faturamento, obtêm-se séries temporais de consumo de energia para cada unidade consumidora. Contudo, nesta aplicação, somente os registros de leitura são utilizados para compor as séries temporais. Isto ocorre, pois o uso dos registros de faturamento ocasiona erros em períodos cuja leitura registrada é menor do que a tarifa mínima. Por exemplo, em uma ligação de baixa tensão, monofásica, cuja tarifa mínima é 30 kWh, o registro de faturamento para uma leitura de 13 kWh no mês seria a própria tarifa mínima, ou seja, 30 kWh.

Outra característica que deve receber atenção diz respeito ao calendário de faturamento. Verifica-se que dificilmente o calendário de faturamento segue o calendário civil, sendo verificadas variações entre 27 e 33 dias, conforme regulamentado pela ANEEL (ANEEL, 2000). Esta variação no número de dias pode ocorrer inclusive nos registros de uma mesma unidade consumidora. Por este motivo, torna-se necessário o ajuste do registro de consumo para uma mesma base temporal.

Outra situação que necessita atenção, diz respeito às UC's com contrato ativo que tem seus medidores lidos com intervalos de tempo maiores do que um período de faturamento (usualmente de três em três períodos). Nestes casos, também existe a necessidade de ajustar os registros de consumo para uma mesma base temporal. Neste estudo todos os dados serão ajustados para uma base de 30 dias por período, possibilitando desta forma uma melhor compreensão das informações.

Conforme exposto no Capítulo 2, as séries temporais podem ser decompostas em três componentes principais: tendência, sazonalidade e um componente aleatório. A tendência corresponde ao aumento ou decréscimo do consumo ao longo do tempo. Em alguns casos pode-se verificar que a sazonalidade está presente, pois é possível observar ciclos de consumo que se repetem em períodos similares no tempo. Já a componente aleatória é a responsável pelo ruído presente nas séries. Esta é uma forma interessante de se verificar a qualidade das séries, pois ajuda a identificar a influência das componentes que irão gerar a previsão.

De forma complementar, cabe ressaltar que existem alguns fatos que sabidamente podem afetar o comportamento das UCs. Um exemplo típico é o caso da variação de consumo da classe residencial e industrial em função de férias ou outros afastamentos. Também devem ser consideradas alterações de comportamento em função de aquisição de novos equipamentos, influências econômicas (ocorrência de crises, superávit, etc.) e até ambientais

(secas, chuvas, etc.) do local onde as UCs estão inseridas. Tais fatos não obedecem a uma lógica fixa, podendo ocorrer variações comportamentais ao longo do tempo.

Todos estes dados representam uma quantidade grande de informação, sendo apropriado o seu tratamento através de estruturas de banco de dados. Neste caso em particular, o uso do método relacional de banco de dados é interessante. Desta maneira, se permite aos usuários da informação realizar consultas, reorganizando e utilizando os dados de forma flexível. Esta característica é importante, uma vez que à medida que os métodos de previsão forem sendo desenvolvidos, novas tabelas de relacionamento poderão ser criadas para a obtenção de dados customizados às necessidades da análise. A Figura 07 apresenta o esquema de tabelas aplicável a este trabalho.

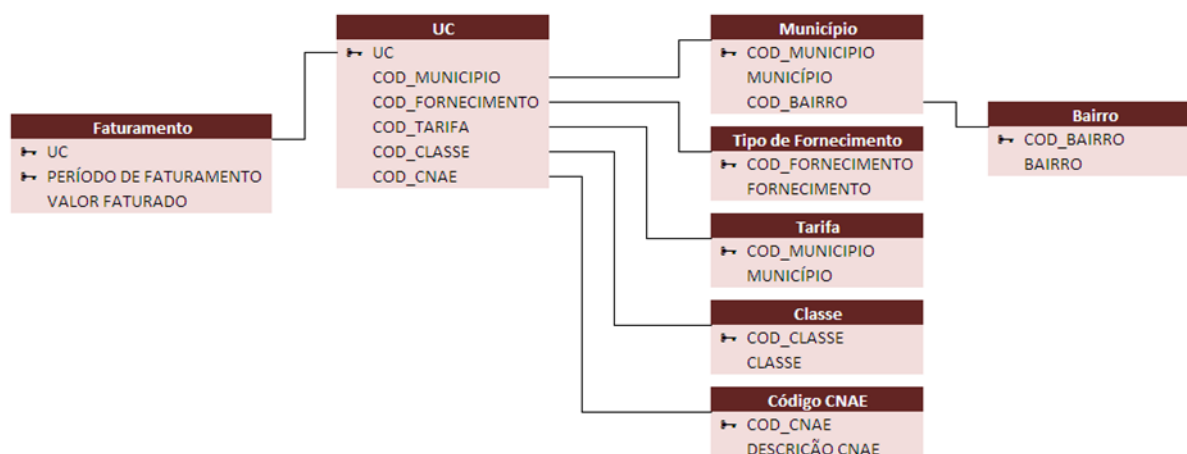


Figura 7: Esquema de tabelas do banco de dados relacional (o símbolo da chave identifica as chaves primárias)

3.3 MODELAGEM DAS SÉRIES TEMPORAIS DE CONSUMO DE ENERGIA ELÉTRICA

Esta seção propõe testar alguns métodos de previsão de demanda apresentados no Capítulo 2, bem como indicar o método com a melhor acurácia dentre os analisados. Paralelamente, propõe verificar se o uso de agrupamentos de UCs é vantajoso em relação às análises individuais, no que diz respeito à obtenção de métodos de previsão mais acurados.

Ao todo, 28 métodos de previsão de demanda são testados. Nota-se que, devido as suas características, eles podem ser facilmente programados em planilhas eletrônicas. Assim,

os testes podem ser realizados sem que haja a necessidade de *softwares* específicos. Neste projeto, o *software* de planilhas eletrônicas utilizado é o *Excel 2007*. Com o auxílio dessa ferramenta, pode-se gerar macros para cada método de previsão, facilitando o trabalho de teste em diversas séries de consumo.

A modelagem é restrita a um único agrupamento de UCs, levando em conta um número pequeno de séries temporais. Desta forma, acredita-se que, uma vez identificado o método com melhor desempenho, pode-se extrapolar a sua estrutura geral para as demais UCs sem que haja perda da qualidade da previsão.

Durante o processo de modelagem, são utilizados os dados de 30 UCs comprovadamente isentas de irregularidades. Visando tornar a análise mais robusta, opta-se por selecionar aleatoriamente UCs que possuam séries temporais completas, ou seja, com 60 registros de leitura em um mesmo contrato. Baseado nos registros das 30 UCs selecionadas, gera-se uma série de referência. Desta forma, é possível realizar a análise de autocorrelação do agrupamento, possibilitando identificar padrões que podem auxiliar nas escolhas e análises dos métodos de previsão de demanda.

Os métodos testados utilizam os períodos 1 a 48 para efetuar as calibrações necessárias, realizando a previsão dos registros de leitura para os períodos 49 a 60. São utilizadas duas medidas de acurácia apresentadas no Capítulo 2, sendo possível criar um *ranking* de desempenho dos métodos testados. O método com a melhor posição neste *ranking* será utilizado na etapa seguinte do projeto, onde é incluída a análise estatística de quedas de consumo atípicas.

3.4 MÉTODO DE DETECÇÃO DE QUEDAS ATÍPICAS DE CONSUMO

O método para detecção de quedas atípicas de consumo de energia elétrica está baseado na comparação estatística dos registros mensais de leitura de consumo com os valores de uma base de referência. A base de referência consiste em uma série temporal de mesmo número de registros que a série a ser analisada. Estes registros são considerados típicos e livres de qualquer tipo de erro de medição. A base de referência é única para cada unidade consumidora e é obtida com o auxílio do método de previsão de demanda mais adequado para este tipo de série temporal.

É importante observar que os primeiros registros da base de referência, quando ainda não existem dados históricos suficientes para realizar a previsão, são obtidos pela repetição dos registros de leitura de consumo. Este fato implica que nos casos onde a queda atípica de consumo ocorrer antes do início das previsões, a capacidade do método de localizar consumos irregulares estará comprometida.

Paralelamente ao cálculo dos valores previstos, são realizados testes estatísticos considerando os valores realizados e previstos. Somente serão considerados atípicos, os registros que forem indicados por todos os testes. Nos casos onde um registro lido for identificado como atípico, ele é substituído pelo valor previsto para o mesmo período. Dessa forma, é garantido que os registros atípicos não irão afetar a previsão dos registros seguintes. Essa análise é realizada a partir do primeiro período previsto da série de referência e se estende até o 60º período.

De forma a auxiliar o tomador de decisão a analisar os diferentes casos de queda de consumo atípica, os resultados são apresentados de forma gráfica. Complementarmente, é gerada uma tabela com informações referentes aos resultados encontrados, bem como é informada a pontuação da análise, de modo a posicionar a UC em um *ranking* de priorização.

Para realizar a validação deste método são verificadas as principais irregularidades encontradas na área de concessão da concessionária. Desta forma, é possível simular a interferência dessas irregularidades, podendo ser comparados os resultados alcançados pelo método com um gabarito.

4 DESCRIÇÃO DO ESTUDO, RESULTADOS E DISCUSSÃO

Neste Capítulo são apresentados e discutidos os resultados obtidos com o desenvolvimento do método de detecção de quedas de consumo atípicas. Nesse sentido, o Capítulo está dividido em quatro partes: Entendimento do Negócio, Entendimento dos Dados, Modelagem das Séries Temporais de Consumo de Energia Elétrica, e Apresentação do Método de Detecção de Quedas Atípicas de Consumo.

4.1 ENTENDIMENTO DO NEGÓCIO

O presente estudo é aplicado à empresa de distribuição de energia elétrica RGE, empresa integrante do Grupo CPFL Energia. A RGE nasceu com a privatização da Companhia Estadual de Energia Elétrica do Rio Grande do Sul (CEEE) em 1997, ficando responsável pela concessão da região norte do estado. Ao todo, 262 municípios são atendidos, representando um universo de mais de 1,2 milhão de unidades consumidoras ativas. Suas principais cidades são: Canela, Gramado e Santo Ângelo, conhecidas por seus atrativos turísticos; Gravataí, pólo industrial da região metropolitana de Porto Alegre; Passo Fundo, região onde se desenvolve a agropecuária; Santa Rosa, região com grande produção agrícola; e Caxias do Sul, cidade onde está localizada a sede da empresa, conhecida como o maior pólo industrial do interior do estado. A área de concessão da empresa é apresentada na Figura 08.

A existência significativa de Perdas Comerciais na RGE é um acontecimento recente. Verifica-se que até 1997, ano da privatização da CEEE, os índices de Perdas Comerciais não eram significativos, o que permitia que a estatal não priorizasse ações para combatê-las. Esse fato possivelmente advinha de questões culturais, pois era forte o sentimento de honra e respeito ao patrimônio público. Por exemplo, escuta-se que era vergonhoso e constrangedor para um cliente e seus familiares quando um veículo da concessionária estacionava em frente à unidade consumidora para efetuar algum serviço ligado à regularização ou corte da medição de energia.

Não se sabe ao certo o que desencadeou o aumento do nível das Perdas Comerciais no Rio Grande do Sul (e por conseqüência na RGE), existem somente algumas especulações.

Uma delas diz respeito ao Plano de Aposentadoria Incentivada (PAI), instalado juntamente com a privatização da CEEE. Outra diz respeito aos reflexos no Rio Grande do Sul do racionamento de energia elétrica ocorrido no Brasil em 2001.




Figura 8: Área de Concessão da RGE

Sobre a primeira hipótese, especula-se que alguns dos colaboradores aposentados pelo plano PAI começaram a oferecer serviços de fraude em medições de energia elétrica. Sabe-se que aproximadamente 4 mil colaboradores foram beneficiados com o PAI, quando se esperava um número não superior a 1,5 mil. Mais tarde, o INSS identificou que alguns processos de aposentadoria do PAI foram fraudados, fato que levou à cassação de diversos benefícios. Como fator agravante, escutava-se na época que apesar de beneficiados pelo plano PAI, diversos colaboradores da CEEE se sentiam magoados e insatisfeitos com a privatização. Cabe ressaltar que grande parte destes tinha conhecimento detalhado sobre o funcionamento e formas de medição, fato que facilitaria a sua ação fraudulenta.

A outra hipótese diz respeito às conseqüências advindas do racionamento de energia elétrica ocorrido no Brasil em 2001. Nesta ocasião, grande parte das concessionárias de

energia do Brasil foi obrigada a definir cotas de consumo mensal para cada uma das suas unidades consumidoras. Os clientes que ultrapassassem essas cotas teriam que pagar multas com altos valores. Para burlar o sistema de cotas, diversas técnicas de fraude nos medidores começaram a ser utilizadas. Acredita-se que tenham surgido verdadeiras quadrilhas que ofereciam esses serviços aos consumidores. No Rio Grande do Sul, o Governo Federal impôs somente a necessidade de uso racional da energia elétrica, não sendo necessário o sistema de cotas. Entretanto, acredita-se que devido à confusão gerada em função do racionamento, essas quadrilhas tenham tido espaço para vender os seus serviços também no Rio Grande do Sul.

Na RGE, as ações de combate às perdas comerciais se iniciaram no segundo semestre de 2002. Naquela ocasião, ainda de forma tímida, algumas equipes foram treinadas para atuar nas atividades de inspeção e regularização de medições de energia. Esse movimento inicial por parte da concessionária não obteve os resultados esperados, sendo verificado um nível crescente de perdas na área de concessão. Por esse motivo, no final do ano de 2004, foi criado o Departamento de Cobrança e Gestão de Perdas Comerciais. Ele tinha o objetivo de tratar exclusivamente de dois temas interdependentes: perdas comerciais e inadimplência.

Até aquele momento se sabia que a perda comercial existia, porém não se tinham informações suficientes para caracterizá-la. Para tanto, encomendou-se junto ao Laboratório de Matemática e Estatística da USP-SP uma análise estatística das medições da área de concessão da RGE. A análise, finalizada no primeiro semestre de 2005, apontou os principais focos de perdas e sinalizou a necessidade de se ampliar o número de equipes de fiscalização e de pessoal de retaguarda comercial. A retaguarda comercial é responsável pelas atividades de planejamento de inspeções, seleção de unidades consumidoras (UCs), despacho de ordens de serviço, controle de resultados, triagem de documentação, cálculo e cobrança de irregularidades, recursos administrativos e outras atividades relacionadas.

Como opção para essa ampliação de pessoal, foi escolhido um método híbrido de trabalho, ou seja, a atuação em conjunto de empregados próprios e terceirizados. Tal escolha foi utilizada tanto para as equipes de fiscalização, quanto para o pessoal de retaguarda comercial. Para garantir a qualidade dos serviços prestados pelos colaboradores terceirizados, foram adotadas auditorias mensais, com possibilidade de penalizações em caso de falha na execução das tarefas.

Ainda como produto da análise estatística apresentada pela USP-SP, foi implantado em 2005 o Plano de Combate às Perdas Comerciais da RGE. O plano estabelecia que, a partir de 2006, a principal ação desenvolvida pela empresa deveria ser a fiscalização das UCs. Para tanto, estimou-se que deveriam ser realizadas 120.000 inspeções por ano (cerca de 10% do número de clientes ativos da RGE), com efetividade média mínima de 12%. Conforme já apresentado, efetividade das inspeções em campo é um índice obtido pela razão entre o número de inspeções que identificaram irregularidades com perda comercial e o número total de inspeções. Dentre as demais ações vinculadas ao plano se encontram: substituição de medidores considerados obsoletos; regularização de ligações clandestinas; certificação das medições de fronteira; instalação de medição em unidades consumidoras com consumo cobrado por estimativa; redimensionamento e adequação de transformadores de corrente à carga utilizada; recadastramento da iluminação pública e outras atividades semelhantes.

Com esse plano, estimava-se que a partir de 2008 a tendência das perdas comerciais na RGE sofreria uma inversão de tendência. Entretanto, verifica-se na Figura 09 que esta inversão veio a ocorrer já no ano de 2006. Importante salientar que os dados anteriores a 2004 não são apresentados na figura em virtude da estimativa de perdas daquela época ser realizada por outro método, fato que poderia introduzir inconsistências na análise. Para efeito de comparação, a perda média nos seis anos contemplados na Figura 09 se aproxima do consumo anual da cidade de Farroupilha, presente na área de concessão da RGE, com 26.695 habitantes (IBGE, 2009). Nos próximos parágrafos é apresentado um resumo das principais ações e acontecimentos que auxiliaram para que esta inversão de tendência fosse antecipada em dois anos.

Em 2005, foi desenvolvido o sistema RGEOS para o Grupo B (baixa tensão), sendo inicialmente implementado em um PDA com a plataforma PalmOS. Entende-se por PDA um computador de dimensões reduzidas com possibilidade de conexão a outros equipamentos e redes. O uso desse equipamento possibilitou que a comunicação entre as equipes de fiscalização e o sistema comercial da empresa fosse muito mais ágil. Por exemplo, ao se encerrar uma ordem de serviço onde foi identificada uma irregularidade, o RGEOS comunica o fato instantaneamente ao sistema comercial da RGE. Dessa forma, a alteração de qualquer dado de cadastro dessa UC irregular é bloqueada instantaneamente até que os débitos referentes à irregularidade sejam negociados. Tal ação se mostrou necessária e importante, visto que nos casos onde o cliente consegue alterar a titularidade da UC, a cobrança dos valores retroativos de energia fica comprometida.

Evolução da Perda Comercial Anualizada na RGE (GWh)




Figura 9: Evolução da perda comercial na RGE em GWh/ano (dado de 2009 utiliza o mês de maio como base) – Fonte: Fórum *Smart Utilities Brazil*, 2009.

O sistema RGEOS sofreu diversas atualizações desde então, sendo disponibilizado atualmente através da plataforma Windows Mobile, atuando também nas inspeções do Grupo A (média e alta tensão). Outro importante ganho proporcionado pelo sistema diz respeito às avaliações e controle das campanhas de fiscalização. Pode-se, por exemplo, realizar uma consulta *online* do índice de efetividade das equipes, possibilitando o remanejamento das ordens de serviço caso se mostre necessário.

Em 2006, com o aumento significativo de pessoal, criou-se o Departamento de Gestão de Vendas, organizado em três Divisões: (i) Perdas Comerciais, responsável pelo combate às perdas comerciais; (ii) de Recuperação de Crédito, responsável pela cobrança das irregularidades, inadimplência e gestão de corte; e (iii), de Poder Público e Projetos Especiais, responsável pela comunicação entre a RGE e os órgãos públicos (principalmente as prefeituras) e também pelos projetos de universalização e regularização de clandestinos. Mediante a criação do departamento, todos os procedimentos foram mapeados e padronizados de forma que a sua operação fosse otimizada.

Em 2007, o Grupo CPFL Energia adquiriu a totalidade das ações da RGE e, por consequência, a sede da empresa foi transferida para Caxias do Sul. Nesse mesmo ano, foi publicado o Manual de Fiscalização e Medição (MFM), padronizando todos os procedimentos

adotados pelas equipes de fiscalização. Já em 2008, o cálculo de irregularidades foi automatizado com base no estudo realizado pelo autor desta dissertação. Também se iniciou a ação de regularização dos clientes clandestinos, através da atuação nos municípios de Passo Fundo e Caxias do Sul. Atualmente, diversas ferramentas diferenciadas são utilizadas, podendo-se citar o controle das perdas por regiões geo-elétricas e o sistema de roteamento das equipes de fiscalização através de GPS.

No que diz respeito às inspeções nas unidades consumidoras, houve diversas evoluções de procedimentos ao longo do tempo. Inicialmente, as inspeções eram feitas de forma aleatória, o que resultava em ordens de serviço pouco efetivas, visto que a estimativa estatística de UCs com perda comercial era inferior a 5%. Na seqüência, foram adotadas técnicas para refino das unidades consumidoras, com vistas a incrementar a efetividade das inspeções.

Foram desenvolvidos métodos que analisavam as características das UCs e indicavam comportamentos considerados suspeitos, tais como: queda da média de consumo anual igual ou superior a 30%; UCs com denúncia de irregularidade ou de fornecimento a terceiros; UCs com consumo abaixo da tarifa mínima, UCs com contrato término e com tendência a auto-religação; e UCs sem incremento de consumo após a regularização de irregularidades, avarias ou substituição de medidores obsoletos.

Utilizando os métodos acima, mais de 600.000 inspeções foram realizadas desde 2002, conforme apresentado na Figura 10. Salienta-se que, no período analisado, a efetividade das inspeções vem se mantendo acima dos 12% propostos em 2005. Entretanto, em 2009 houve uma alteração da proposta para a ação de combate às perdas comerciais. A nova meta, incluída no Plano de Ação, sugere que o número de inspeções seja reduzido para 100.000 ao ano e que ocorra um incremento no índice de efetividade. Desta forma, espera-se compensar a redução do número de inspeções, mantendo ou ampliando o volume de energia recuperada. Para tanto, o presente estudo pretende adicionar inteligência aos métodos utilizados para o planejamento das inspeções nas unidades consumidoras.

4.2 ENTENDIMENTO DOS DADOS

Para a análise do banco de dados (BD) da RGE, optou-se por trabalhar com uma amostra-piloto formada pelos BDs de três municípios distintos, porém com número total de UCs semelhante. Assim, serão contempladas 32.412 UCs na amostra-piloto, distribuídas da seguinte maneira: 10.728 no município de Flores da Cunha, 11.632 em Marau e 10.049 em Três Passos.




Figura 10: Número de inspeções realizadas na área de concessão da RGE

O BD relacional da amostra-piloto foi criado em função das especificações apresentadas no Capítulo 3, sendo geradas 8 tabelas distintas: UC, Município, Bairro, Tipo de Fornecimento, Tarifa, Classe, Código CNAE e Faturamento. Salienta-se que os dados necessários para compor as sete primeiras tabelas estão completos no sistema comercial da RGE (ou seja, não há incidência de itens faltantes).

Para a formação da oitava tabela, de Faturamento, considera-se a janela temporal de 60 períodos existente entre janeiro de 2003 e dezembro de 2007. Nem todas as UCs nos municípios analisados permaneceram com seus contratos ativos durante todo o período analisado. Sendo assim, apesar de não ser a maioria dos casos, não é raro encontrar seqüências sem registros de leitura em função da condição do contrato. Cabe ressaltar que antes de compor a Tabela de Faturamento, os dados originais do sistema comercial da RGE foram ajustados, conforme exposto no Capítulo 3. A Figura 11 apresenta o número de

períodos de leitura das séries temporais existentes na amostra-piloto. Na figura, verifica-se que existe um predomínio de séries completas, com registro para todos os 60 períodos.





Figura 11: Número de períodos de leitura das séries temporais da amostra-piloto


Ao se analisarem os dados da amostra-piloto por município, verifica-se uma boa representação de consumidores nas diferentes classes de consumo, conforme apresentado na Figura 12. Adicionalmente, percebe-se na Figura 13 que o maior volume de energia registrada é verificado na classe residencial. Cabe ressaltar que este estudo aborda somente as ligações em baixa tensão; caso fossem considerados todos os tipos de ligação disponíveis, certamente os maiores volumes de energia estariam nos clientes do Grupo A (média e alta tensão).



Fi

gura 12: Distribuição de UCs por classe de consumo

Ainda referente à Figura 13, ao se analisar cada classe individualmente, verifica-se que existem diferenças consideráveis nos montantes de energia registrada para cada município. Isto ocorre em virtude das diferenças econômicas existentes entre as três cidades.



Fi

gura 13: Energia registrada por classe de consumo no período analisado

A Figura 14 apresenta a distribuição das UCs por tipo de ligação. Nela é possível verificar que a ligação 220V monofásica é amplamente utilizada, sendo responsável pela

grande maioria das ligações. Essa informação procede, já que a grande maioria das UCs da classe residencial utiliza esse tipo de fornecimento.




Figura 14: Distribuição das UCs por tipo de fornecimento

A Figura 15 informa os montantes de energia registrados para cada tipo de fornecimento no período analisado. Percebe-se que o maior volume de energia é registrado através das ligações monofásicas. Entretanto, no município de Flores da Cunha a maior parcela de registro ocorre nas ligações trifásicas.

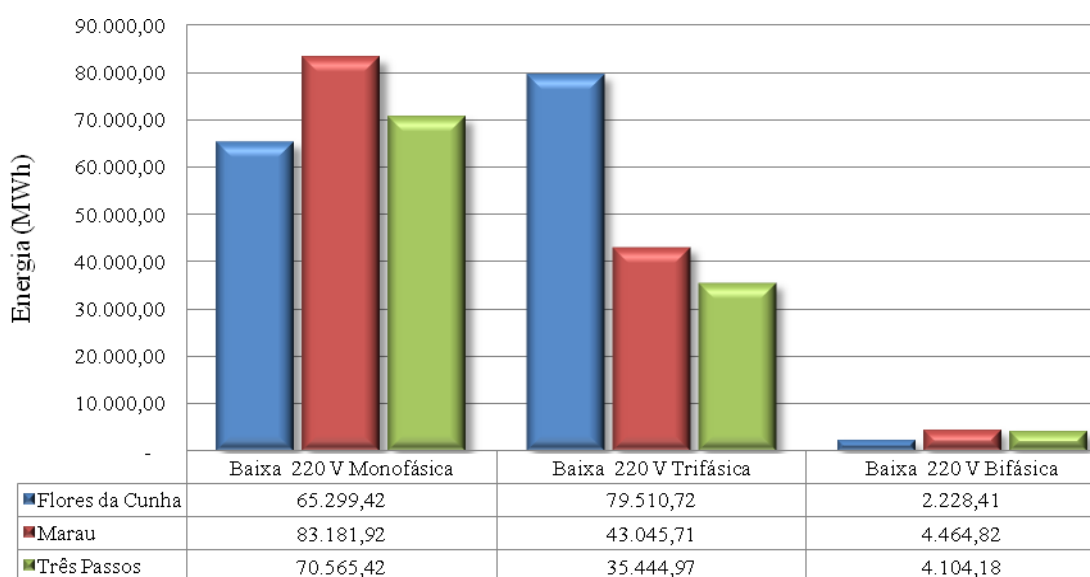


Figura 15: Energia registrada por tipo de fornecimento no período analisado

As séries temporais de consumo podem ser decompostas em três componentes: tendência, sazonalidade e variabilidade aleatória. Para tanto, são utilizados os métodos clássicos de decomposição apresentados no Capítulo 3, sendo possível quantificar a participação de cada componente em determinada série.

Na Figura 16, por exemplo, tem-se a representação de uma série temporal da classe industrial de Flores da Cunha, cujo componente de tendência responde por 42,51%, ao passo que os componentes sazonais e aleatórios contabilizam 43,74% e 13,75%, respectivamente. Já para a série apresentada na Figura 17, representante da classe residencial de Flores da Cunha, o componente de tendência responde por 37,07%, ao passo que os componentes sazonais e aleatórios contabilizam 26,73% e 36,21%, respectivamente.

Série histórica de consumo (kWh)




Figura 16: Histórico de consumo de uma UC industrial de Flores da Cunha

Na proposta deste estudo, a etapa fundamental é a modelagem da previsão de consumo de energia elétrica das UCs. Uma vez disponíveis previsões confiáveis, é possível detectar diferenças significativas entre o consumo previsto e o consumo realizado. Entretanto, sabe-se que métodos de previsão com boa capacidade preditiva somente são obtidos de séries onde o componente aleatório não é dominante. Exemplificando, as chances de se obter um bom método de previsão de demanda são melhores para a série apresentada na Figura 16 do que para a série exemplificada na Figura 17.

Verifica-se que na área de concessão da RGE existem diversas UCs com séries de consumo semelhantes à série apresentada na Figura 17. Tal comportamento se justifica, já que a maioria das UCs pertence à classe residencial que, por sua vez, possui características muito específicas. Normalmente, UCs residenciais apresentam um consumo relativamente baixo, sendo comum a ocorrência de eventos isolados, tais como: férias ou outros afastamentos, aquisições de novos eletrodomésticos e redução ou ampliação do número de moradores.

Série histórica de consumo (kWh)




Figura 17: Histórico de consumo de uma UC residencial de Flores da Cunha

Séries de consumo com componente aleatório predominante tendem a não revelar o padrão médio de consumo do grupo de UCs a que pertencem, se tratadas individualmente. A análise por agrupamentos de UCs, por outro lado, pode revelar a significância média dos componentes da série, levando a métodos de previsão mais confiáveis. Por esse motivo, a escolha correta das variáveis de estratificação e a sua composição são importantes no presente estudo.

A Tabela 5 apresenta a decomposição de algumas séries formadas pelo agrupamento de UCs em função das variáveis de estratificação no município de Flores da Cunha e também a decomposição de três UCs individualmente. Para formar cada série dos agrupamentos, são utilizadas somente UCs com 60 registros de consumo, sendo calculada a média para cada mês, conforme cada agrupamento. Por exemplo, a média para o mês de janeiro de 2006 de todas as UCs da classe residencial forma o valor da classe residencial para aquele período. Igualmente, as UCs decompostas individualmente possuem 60 registros de consumo. Ao se comparar os percentuais obtidos entre as séries agrupadas e as séries individuais das UCs, pode-se facilmente perceber que o uso de agrupamentos reduz significativamente a participação do componente aleatório nas séries.

Tabela 5: Decomposição de séries temporais formadas por agrupamentos

Agrupamento	Tendência	Sazonalidade	Componente aleatório
Tipo de fornecimento			
Monofásico	37,07%	30,80%	32,13%
Bifásico	41,61%	37,55%	20,84%
Trifásico	39,91%	29,69%	30,40%
Classe			
Residencial	39,42%	38,08%	22,50%
Rural	37,41%	36,01%	26,58%
Poder Público	41,84%	39,38%	18,78%
Atividade econômica			
Fabricação de vinho	41,89%	32,39%	25,72%
Produção mista: lavoura e pecuária	40,32%	33,15%	26,53%
Edificações: residenciais e industriais	38,47%	37,47%	24,06%
Bairro			
São Cristóvão	37,09%	40,45%	22,46%
Mato Perso	41,34%	44,01%	14,66%
São José	40,77%	36,73%	22,50%
Bairro e tipo de fornecimento			
Centro – Monofásico	39,30%	39,47%	21,23%
Centro – Bifásico	40,93%	41,08%	17,99%
Centro – Trifásico	39,29%	33,10%	27,61%

Bairro e classe			
Centro – Residencial	39,97%	40,45%	19,58%
Centro – Industrial	40,56%	34,42%	25,02%
Centro – Poder público	41,48%	38,10%	20,42%
Bairro e atividade econômica			
Centro – Edificações: residenciais e industriais	38,25%	41,78%	19,97%
Centro – Lanchonetes e similares	41,88%	29,23%	28,89%
Centro – Manutenção e reparação de veículos	40,36%	36,29%	23,35%
UCs decompostas individualmente			
5148502	35,82%	26,68%	37,50%
5141075	39,12%	22,69%	38,19%
3322457	35,91%	29,36%	34,73%

4.3 MODELAGEM DAS SÉRIES TEMPORAIS DE CONSUMO DE ENERGIA ELÉTRICA

Esta seção tem o intuito de apresentar os resultados da modelagem das séries temporais de consumo de energia elétrica. Ao todo, são testados 28 métodos de previsão de demanda. Para verificar o desempenho das modelagens, são utilizadas 30 séries de consumo de energia elétrica da cidade de Flores da Cunha, participantes do agrupamento Bairro Centro e Tipo de Fornecimento Bifásico. Foram escolhidas somente séries completas e que mantêm o mesmo responsável pela UC durante os 60 períodos considerados. Os períodos 1 a 48 são utilizados para calibrar os métodos, sendo então previstos os períodos 49 a 60.

Complementarmente, é criada uma série de referência, onde o valor de cada período se refere à média dos registros das 30 UCs. A análise da série de referência é importante, uma vez que as observações de seu comportamento auxiliam a identificar padrões e a propor soluções e ajustes para os métodos de previsão de demanda. A Figura 18 apresenta os registros temporais da série de referência.




Figura 18: Série de referência das 30 UCs selecionadas

Para realizar ajustes mais precisos dos métodos de previsão, é interessante conhecer o comportamento das séries de consumo antes que a modelagem inicie. Para tanto, é realizada a análise da série de referência. A série apresentada na Figura 18 não favorece a identificação visual de tendência e de sazonalidade. Por este motivo, é realizada a análise de autocorrelação entre os períodos das séries temporais através da análise gráfica, com coeficientes obtidos através da equação (12). Através dessa análise é possível verificar o padrão de comportamento da série e identificar as relações mais significativas entre os períodos.

Ao realizar a análise, verifica-se que a série original é não-estacionária. Por este motivo é necessária a realização de diferenciações para a correta análise. Para a série em questão, os efeitos não-estacionários são removidos com diferenciação de *lag* 1. A Figura 19 apresenta o gráfico referente à análise de autocorrelação da série de referência após terem sido removidos os efeitos não-estacionários com diferenciação de *lag* 1.




Figura 19: Análise de Autocorrelação da série de referência

Ainda referente à Figura 19, percebe-se que os coeficientes 1 e 12 ultrapassam os limites críticos, sendo classificados como significativos. Com base nestas informações, acredita-se que os períodos $t-1$ e $t-12$ sejam os mais influentes para a formação do período t . Desta forma, caracteriza-se a existência de tendência e também de sazonalidade igual a 12 períodos. Esta informação é perfeitamente coerente, visto que o perfil de consumo varia de acordo com os meses do ano. Ressalta-se que, visualmente, a identificação de tendência e de sazonalidade é muito difícil, sendo fundamental o uso de análise de autocorrelação.

Tendo conhecimento sobre o comportamento das séries, o próximo passo prevê que seja definido o método para medir a acurácia dos métodos testados. Neste estudo, são utilizadas duas medidas de acurácia: MAPE (*Mean Absolute Percentual Error* ou Média dos Erros Percentuais Absolutos) e Theil's U. Ambos são índices percentuais de fácil interpretação, que possibilitam comparações entre métodos e séries diferentes, sem que haja a necessidade de escalas específicas.

Duas verificações são feitas para cada método de previsão, sendo a primeira referente ao intervalo de calibração do método e a segunda ao intervalo de previsão. Desta forma, busca-se encontrar relações entre os melhores desempenhos nos dois intervalos. É

considerado o melhor método de previsão aquele que possui a maior incidência de menores índices de MAPE e Theil's U para o intervalo de previsão.

A Tabela 6 apresenta os 10 métodos de previsão que obtiveram os melhores desempenhos. A tabela completa, com os resultados de todos os métodos é apresentada no Anexo 1. Na Tabela 6 e no Anexo 1, faz-se uso da nomenclatura “Individual” e “Agrupamento” logo após a intitulação do método. Esta é a classificação utilizada pelo autor para apresentar a forma como os coeficientes do método foram obtidos. A nomenclatura “Individual” sinaliza que os coeficientes de cada ensaio de previsão foram obtidos com os valores próprios de cada série. Já a nomenclatura “Agrupamento” sinaliza que os coeficientes foram obtidos para o melhor ajuste à série de referência.

Ainda referente à Tabela 06 e ao Anexo 1, é possível identificar um método intitulado “Próprio”. Esse método foi concebido pelo próprio autor, baseando-se nas observações obtidas através da análise de autocorrelação da série de referência. Como pode ser observado na equação (33), é feita referência a um método $ARIMA(p,1,q)$. Entretanto, ao invés de se utilizar coeficientes numéricos tradicionais para p e q , são inseridos somente os coeficientes classificados como significativos pela análise de autocorrelação. Desta forma, busca-se agregar ao método ARIMA somente as informações pertinentes sobre a série, potencializando o desempenho do método.

$$(1 - \theta_1 B - \theta_2 B^{12})(1 - B)Y_t = c + (1 - \theta_1 B - \theta_2 B^{12})\varepsilon_t \quad (33)$$

Tabela 6: Resumo dos dez métodos de previsão com os melhores desempenhos

Método de Previsão	Equações Utilizadas	Número de UCs onde o método obteve o melhor desempenho	
		MAPE	Theil's U
Média Móvel (n=2)	$F_t = \frac{1}{2} \sum_{i=t-2}^{t-1} Y_i$	C: 0	C: 0
		P: 1	P: 1
		CP: 0	CP: 0
AR(1) Individual	$F_t = c + \theta_1 Y_{t-1} + \varepsilon_t$	C: 0	C: 0
		P: 3	P: 0
		CP: 0	CP: 1
AR(3) Individual	$F_t = c + \theta_1 Y_{t-1} + \theta_2 Y_{t-2} + \theta_3 Y_{t-3} + \varepsilon_t$	C: 0	C: 2
		P: 2	P: 2
		CP: 0	CP: 0

Holt-Winters Individual	$F_{t+m} = (L_t + b_t m) S_{t-s+m}$ $L_t = \alpha \frac{Y_t}{S_{t-s}} + (1 - \alpha)(L_{t-1} + b_{t-1})$	C: 7 P: 5 CP: 0	C: 7 P: 1 CP: 1
Holt-Winters Agrupamento	$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1}$	C: 0 P: 6 CP: 1	C: 1 P: 7 CP: 1
ARIMA(0,1,3) Individual	$(1 - B)Y_t = c + (1 - \theta_1 B - \theta_2 B^2 - \theta_3 B^3)\epsilon_t$	C: 1 P: 1 CP: 0	C: 1 P: 0 CP: 0
ARIMA(3,1,0) Individual	$(1 - \phi_1 B - \phi_2 B^2 - \phi_3 B^3)(1 - B)Y_t = c + \epsilon_t$	C: 0 P: 1 CP: 0	C: 0 P: 1 CP: 0
ARIMA(3,1,3) Individual	$(1 - \phi_1 B - \phi_2 B^2 - \phi_3 B^3)(1 - B)Y_t = c + (1 - \theta_1 B - \theta_2 B^2 - \theta_3 B^3)\epsilon_t$	C: 10 P: 0 CP: 0	C: 8 P: 0 CP: 0
ARIMA(3,1,3) Agrupamento	$(1 - \phi_1 B - \phi_2 B^2 - \phi_3 B^3)(1 - B)Y_t = c + (1 - \theta_1 B - \theta_2 B^2 - \theta_3 B^3)\epsilon_t$	C: 0 P: 1 CP: 0	C: 0 P: 1 CP: 0
Próprio Individual	$(1 - \phi_1 B - \phi_2 B^{12})(1 - B)Y_t = c + (1 - \theta_1 B - \theta_2 B^{12})\epsilon_t$	C: 8 P: 6 CP: 3	C: 5 P: 10 CP: 3

Legenda: C refere-se às ocorrências exclusivas no intervalo de calibração da série; P refere-se às ocorrências exclusivas no intervalo de previsão da série; CP refere-se às ocorrências concomitantes nos intervalos de calibração e de previsão da série.

Conforme a literatura disponível e as análises dos componentes aleatórios das séries, tinha-se a expectativa de que os métodos onde a calibração dos coeficientes era realizada através da série de referência teriam um melhor desempenho. Entretanto, verificou-se exatamente o oposto. Os métodos que obtiveram os melhores desempenhos foram justamente aqueles em que a calibração dos coeficientes foi realizada diferentemente para cada UC.

Como pode ser observado na Tabela 6, o método com o melhor desempenho é o Próprio Individual, com valores de MAPE e Theil's U de 20% e 33,33%, respectivamente, para o intervalo de previsão. Adicionalmente, verifica-se que tanto com relação ao MAPE, quanto ao Theil's U, ele é o método com maior incidência concomitante de melhores desempenhos, quando considerados os intervalos de calibração e de previsão. Baseado nessas observações, conclui-se que o método mais apropriado, dentre os analisados, para ser

utilizado em conjunto com o método de detecção de quedas de consumo atípicas é o Próprio Individual. Ressalta-se que esse método é calibrado de forma distinta para cada UC prevista e que as previsões são realizadas individualmente.

4.4 MÉTODO DE DETECÇÃO DE QUEDAS DE CONSUMO ATÍPICAS

Esta seção tem o objetivo de apresentar os resultados alcançados com o método de detecção de irregularidades. Para tanto, ela é subdividida em duas seções: Desenvolvimento e Calibração, e Validação do Método. Na primeira seção é apresentada a lógica que sustenta o método. Adicionalmente, é apresentada a planilha onde o mesmo foi desenvolvido, bem como os ajustes necessários para obter um desempenho maximizado. Na segunda seção é apresentado e discutido o desempenho do método em uma série de testes propostos pelo autor.

4.4.1 Desenvolvimento e Calibração

A idéia central do método é a detecção de irregularidades na medição de energia elétrica através de comparações estatísticas dos registros mensais de leitura com uma base de referência. A base de referência é uma série temporal que possui as mesmas dimensões da série a ser analisada, ou seja, 60 períodos de duração. Ela é composta por registros de leitura e por previsões de consumo. Os registros referentes aos períodos onde ocorre a previsão são obtidos através do método intitulado “Próprio Individual”. Como parte da série de referência pode depender do método de previsão, é interessante observar as suas características.

O método “Próprio Individual” é uma variação dos métodos ARIMA, tendo sido proposto pelo autor deste estudo. O método proposto utiliza os conceitos de um método $ARIMA(p,1,q)$, onde são considerados somente os períodos indicados como significativos na análise de autocorrelação. Através de uma análise da equação (33), verifica-se que no 14º período ocorre a primeira previsão de consumo de energia elétrica. Por opção do autor, a calibração do método utiliza 12 períodos consecutivos, a contar do primeiro período de previsão. Desta forma, os períodos 14 a 25 são utilizados para calibrar os coeficientes do método, sendo este procedimento repetido para cada UC analisada. Em virtude dessa configuração, a

primeira previsão de consumo, onde as comparações estatísticas podem efetivamente ser realizadas, ocorre no 26º período da série temporal.

Com base nas informações sobre o método utilizado, testes estatísticos podem ser formulados e inseridos no método de detecção de irregularidades. Contudo, somente são classificados como consumos atípicos os períodos onde todos os testes previstos apontam comportamento fora dos padrões estatísticos esperados.

O primeiro teste consiste em uma análise do desvio de previsão. Considera-se desvio de previsão o valor correspondente à diferença entre o valor previsto e o efetivamente lido para um determinado período. O desvio identificado em cada período é utilizado para calcular o Erro Padrão e o Desvio Padronizado, conforme apresentado nas equações (34) e (35).

$$Erro_{padr\ddot{o}n}(t) = \sqrt{\frac{12 \times Erro_{padr\ddot{o}n}(t-1)^2 + desvio(t)^2}{13}} \quad (34)$$

$$Desvio_{padronizado}(t) = \frac{desvio(t)}{Erro_{padr\ddot{o}n}(t-1)} \quad (35)$$

O Erro Padrão é a variável estatística que aponta a diferença esperada entre os valores previstos e os efetivamente realizados para determinado período da série de consumo analisada. Este índice é variável e acompanha as características da série. Já o Desvio Padronizado indica a razão entre o desvio de previsão do período em análise e o Erro Padrão típico da série até aquele momento. Desta forma, tem-se um indicativo do quão distante do esperado foi o desvio de previsão do período em análise. Por exemplo, um Desvio Padronizado representativo indica que o desvio de previsão naquele período foi estatisticamente significativo. Em configuração *default*, são considerados representativos os valores de Desvio Padronizado iguais ou superiores a três.

Como segundo teste, utiliza-se a análise do índice MAPE. Para tanto, são considerados somente os períodos em que houve previsão de consumo, ou seja, do 26º período até o período anterior ao período em análise. São calculados os valores de média e de desvio padrão do MAPE. Por esse motivo, o teste somente é aplicável a partir do 28º período da série temporal. A configuração *default* considera período atípico aquele que apresentar um índice MAPE igual ou superior a $\bar{x} + 3\sigma$, onde \bar{x} e σ são a média e o desvio padrão do

conjunto de índices de MAPE da base de previsão. Como diferencial em relação ao primeiro teste, verifica-se que neste caso as análises não levam em conta os valores absolutos de diferença de previsão e sim os valores percentuais dessa diferença. Desta forma, o método se torna capaz de identificar variações percentuais de erro estatisticamente significativas.

O terceiro teste institui que, em configuração *default*, os registros dos períodos somente são reconhecidos como atípicos quando o desvio de previsão superar $0,3(P_{95} - P_5)$. P_{95} e P_5 são os percentis de 95% e 5%, respectivamente, dos registros da base de referência. Este teste tem a função de evitar que, desvios pequenos sejam identificados como atípicos frente à variação natural dos dados.

O quarto teste verifica o percentual do desvio de previsão. A configuração *default* considera atípicos os períodos onde o desvio de previsão for igual ou superior a 15% do valor previsto. Desta forma, evita-se que, em séries onde o Erro Absoluto é muito pequeno, quedas percentuais de consumo pouco relevantes sejam identificadas como atípicas.

Uma vez determinados os testes a serem aplicados às séries de consumo, pode-se descrever o funcionamento do método de detecção de irregularidades. Ao se iniciar a detecção de irregularidades, o método copia os 25 primeiros registros de leitura para a base de referência. Em seguida, ocorre o ajuste dos coeficientes do método de previsão. Com o método ajustado, o consumo para o período 26 é previsto. Compara-se o consumo previsto com o valor lido para aquele período, sendo identificado o desvio de previsão. Neste momento os testes são aplicados.

Se ao menos um dos testes indicar que o consumo lido é típico, o mesmo é copiado para a base de referência para compor o registro do 26º período. O método identifica a inclusão deste novo registro e o utiliza para prever o consumo do período 27.

Caso todos os testes disponíveis para o período indiquem que o consumo lido é atípico, este registro é copiado para compor a série de registros atípicos. A série de registros atípicos é uma série temporal de 60 períodos, onde os períodos típicos possuem valores iguais a zero e os atípicos assumem o valor do consumo lido. Neste caso, o valor previsto é copiado para a base de referência para compor o registro do 26º período. O método identifica a inclusão deste novo registro e o utiliza para prever o consumo do período 27.

Complementarmente, cabe ressaltar que o Desvio de Previsão do período 26 assume o valor zero. Desta forma, impede-se que o Desvio de Previsão Atípico influencie

negativamente no cálculo do Erro Padrão e do Desvio Padronizado, necessários para a análise do registro de consumo lido do período 27.

A previsão e análise do 27º e dos demais períodos ocorre de forma semelhante. Ao final da análise da UC, tem-se uma relação com todos os períodos cujos consumos foram considerados típicos e atípicos. A apresentação desta informação ocorre de maneira gráfica, visando facilitar a interpretação dos resultados pelo usuário do sistema. Além disto, é gerada uma tabela com informações pertinentes, tais como: número de registros atípicos, montante atípico médio, montante atípico acumulado, média do Desvio Padronizado atípico e índice de priorização.

Este método foi desenvolvido em plataforma Excel 2007. Esta escolha se deu em função da disponibilidade do *software* e da familiaridade do autor com as suas funções. Foram utilizados recursos de fórmulas, macros e também a função *Solver*.

A planilha desenvolvida possui cinco abas distintas. A primeira, intitulada “Entrada de Dados”, possui instruções sobre como realizar a análise de queda de consumo atípica. Também está presente uma tabela onde os dados da série a ser analisada devem ser inseridos. Verifica-se que, nos casos onde o registro de consumo lido é igual a zero, ocorrem erros nas fórmulas da planilha. Por este motivo, foi inserida uma lógica que substitui os registros iguais a zero por 0,1.

A segunda aba, intitulada “Método 1”, apresenta o método de previsão “Próprio Individual” estruturado através de diversas células e fórmulas. É nesta aba que, através da função *Solver*, os coeficientes do método são calibrados de modo a obter o menor índice de MAPE de Calibração possível. Como restrições da função *Solver*, exige-se que os valores dos coeficientes estejam contidos na faixa de -1 a +1 e que os valores de previsão de consumo sejam iguais ou superiores a zero.

Por definição do autor, são utilizados 12 períodos para a calibração do método. Desta forma, busca-se agregar o comportamento de cada período do ano civil à calibração. Em função desta definição, os 25 primeiros períodos são necessários para este procedimento. Observa-se que o método utilizado não realiza previsões para os períodos 1 a 13. Conseqüentemente, não estão disponíveis valores de erro de previsão para estes períodos. Como o método necessita de valores de erro nos tempos $t-1$ e $t-12$, a calibração dos coeficientes relacionados a estes valores ficam prejudicados. Em função disto e, também, evitando estender o período de calibração, valores de erro simulados são calculados para os

períodos 1 a 13. Para tanto, utiliza-se o valor médio do MAPE de Calibração do método. Este índice é multiplicado pelo valor do consumo lido para cada período, compondo desta forma um valor de erro simulado. No caso do método “Próprio Individual” o valor médio do MAPE de Calibração é 7,20%. A Figura 20 apresenta a aba “Método 1”.

n	Yt	naive	Ft	c	Ø1	Ø2	et	MAPE	TEIL-U		
1	228			-0,01	-0,41	0,58	0,43	-0,08	16,42	3,38%	0,5720
2	206	228					14,83				
3	222	206					15,98				
4	237	222					17,06				
5	233	237					16,78				
6	240	233					17,28				
7	290	240					20,88				
8	259	290					18,65				
9	258	259					18,58				
10	253	258					18,22				
11	280	253					20,16				
12	290	280					20,88				
13	226	290					16,27				
14	234	226	234,00				0,00	0,00%	0,00	64,00	
15	256	234	241,23				14,77	5,77%	218,15	484,00	
16	246	256	250,65				-4,65	1,89%	21,65	100,00	
17	297	246	251,19				45,81	15,42%	2098,60	2601,00	
18	262	297	261,83				0,17	0,07%	0,03	1225,00	
19	287	262	306,89				-19,89	6,93%	395,76	625,00	
20	264	287	268,86				-4,86	1,84%	23,60	529,00	
21	286	264	276,52				9,48	3,31%	89,88	484,00	
22	264	286	271,49				-7,49	2,84%	56,03	484,00	
23	301	264	293,49				7,51	2,49%	56,37	1369,00	
24	290	301	290,00				0,00	0,00%	0,00	121,00	
25	259	290	259,00				0,00	0,00%	0,00	961,00	

Figura 20: Aba “Método 1”

A terceira aba, intitulada “Previsão”, possui uma estrutura semelhante à existente na aba “Método 1”. Entretanto, verifica-se que ao invés de conter somente 25 períodos, ela possui todos os 60 períodos da série a ser analisada. É a partir dos valores de previsão apresentados nesta aba que o método realiza as análises de queda de consumo atípica.

A aba seguinte, intitulada “Análise de QCA”, é responsável por realizar todos os testes citados anteriormente e também por indicar quais registros de consumo lido são considerados típicos ou atípicos. A Figura 21 apresenta a aba “Análise de QCA”, onde é possível verificar a sua estrutura e a disposição dos dados.

t	Consumo Lido	Consumo Previsto	Base de Previsão	Erro	QCA?	MAPE Base de Previsão	Coluna Reservada	Base de previsão Colada	Erro Colado	QCA Colado	MAPE Base de Previsão Colado	Coluna Reservada Colada	Erro Padrão	Desvio Padronizado	Soma dos testes	Teste #1	Teste #2	Teste #3	Teste #4
1	620	620	620					620											
2	610	610	610					610											
3	160	160	160					160											
4	145	145	145					145											
5	153	153	153					153											
6	142	142	142					142											
7	140	140	140					140											
8	165	165	165					165											
9	151	151	151					151											
10	142	142	142					142											
11	137	137	137					137											
12	610	610	610					610											
13	620	620	620					620											
14	610	599	610	-11,00		1,80%		610	-11,00		1,80%		3,05						
15	162	165	162	3,00		1,85%		162	3,00		1,85%		3,05						
16	147	151	147	4,00		2,72%		147	4,00		2,72%		3,13						
17	155	158	155	3,00		1,94%		155	3,00		1,94%		3,12						
18	152	147	152	-5,00		3,29%		152	-5,00		3,29%		3,30						
19	161	152	161	-9,00		5,59%		161	-9,00		5,59%		4,04						
20	148	186	148	38,00		25,68%		148	38,00		25,68%		11,23						
21	145	145	145	0,00		0,00%		145	0,00		0,00%		10,79						
22	152	139	152	-13,00		8,55%		152	-13,00		8,55%		10,98						
23	158	147	158	-11,00		6,96%		158	-11,00		6,96%		10,98						
24	610	622	610	12,00		1,97%		610	12,00		1,97%		11,06						
25	620	620	620	0,00		0,00%		620	0,00		0,00%		10,63						
26	610	613	610	3,00	0	0,49%		610	3,00	0	0,49%		10,24	0,28	1	0		0	0
27	161	172	161	11,00	0	6,83%		161	11,00	0	6,83%		10,30	1,07	1	0		0	0
28	148	154	148	6,00	0	4,05%		148	6,00	0	4,05%		10,04	0,58	1	0		0	0
29	145	162	145	17,00	0	11,72%		145	17,00	0	11,72%		10,73	1,69	1	0		0	0
30	153	149	153	-4,00	0	2,61%		153	-4,00	0	2,61%		10,37	-0,37	1	0		0	0
31	142	164	142	22,00	0	15,49%		142	22,00	0	15,49%		11,69	2,12	1	0		0	0
32	140	143	140	3,00	0	2,14%		140	3,00	0	2,14%		11,26	0,26	1	0		0	0
33	165	142	165	-23,00	0	13,94%		165	-23,00	0	13,94%		12,56	-2,04	2	0		0	1
34	151	170	151	19,00	0	12,58%		151	19,00	0	12,58%		13,17	1,51	1	0		0	0

Figura 21: Aba “Análise de QCA”

Nela é possível identificar através de cores todas as informações consideradas para a análise de queda de consumo atípica. Verifica-se que os períodos de calibração estão sinalizados com tons mais escuros, enquanto que os períodos de previsão estão sinalizados com tons mais claros. As células de cor laranja apresentam os dados de consumo lido e previsto para cada período. Estas informações são provenientes das abas “Entrada de Dados” e “Previsão”, respectivamente.

As células de cor verde e roxa apresentam os mesmos números para um mesmo período, com a diferença que as células verdes possuem fórmulas e as células roxas são cópias numéricas das células verdes. Esta cópia numérica é necessária em função de uma particularidade da plataforma Excel. Por configuração *default*, o Excel realiza constantemente os cálculos atrelados às fórmulas inseridas nas células de suas planilhas. Esta característica introduz referências circulares que impossibilitam o processamento do método. Como solução

para este problema, utilizam-se colunas auxiliares, onde a informação das células verdes são copiadas e coladas nas células roxas (“Colar Valores” do menu “Colar Especial” do Excel).

Estão indicadas com a cor azul as células onde ocorrem os testes com os consumos lidos. Quando um teste interpreta uma queda de consumo como atípica, a célula correspondente assume o valor um. Já nos casos onde o consumo é considerado típico, a célula assume o valor zero. Na coluna “Soma dos testes” é apresentada a soma do resultado de todos os testes aplicados. Nos momentos em que esta soma é igual ao número de testes realizados, o consumo do período é considerado atípico. As células que indicam os coeficientes utilizados na calibração de cada um dos quatro testes disponíveis estão sinalizadas com a cor amarela.

A quinta e última aba, intitulada “Análise Gráfica”, apresenta um resumo dos resultados alcançados com a análise de queda de consumo atípica. Nesta aba estão presentes um gráfico e uma tabela com informações sobre a análise. O gráfico possui três representações possíveis. A primeira é uma linha preta, com marcador quadrado inclinado 45 graus. Ela é responsável por indicar os consumos lidos considerados típicos. A segunda é uma linha azul, com marcador circular, sendo esta responsável por apresentar os consumos previstos. A última representação possível é uma linha vermelha, com marcador quadrado. Ela apresenta os consumos lidos que foram considerados atípicos para a série em análise.

A tabela presente na aba “Análise Gráfica” apresenta informações referentes aos dados atípicos. São mencionados o número de registros considerados atípicos, o montante atípico médio e acumulado, a média do Desvio Padronizado Atípico e um índice de priorização. O montante atípico médio é obtido pela média das diferenças entre os consumos lidos atípicos e os consumos previstos. Já o montante atípico acumulado é obtido pela soma de todas as diferenças entre os consumos lidos atípicos e os consumos previstos. A média do Desvio Padronizado Atípico é obtido pela média de todos os valores de Desvio Padronizado nos períodos considerados atípicos. O índice de priorização é obtido pela multiplicação da Média do Desvio Padronizado Atípico pelo Montante Atípico Acumulado, sendo atribuído um único valor para cada série analisada. A Figura 22 apresenta a aba “Análise Gráfica”.

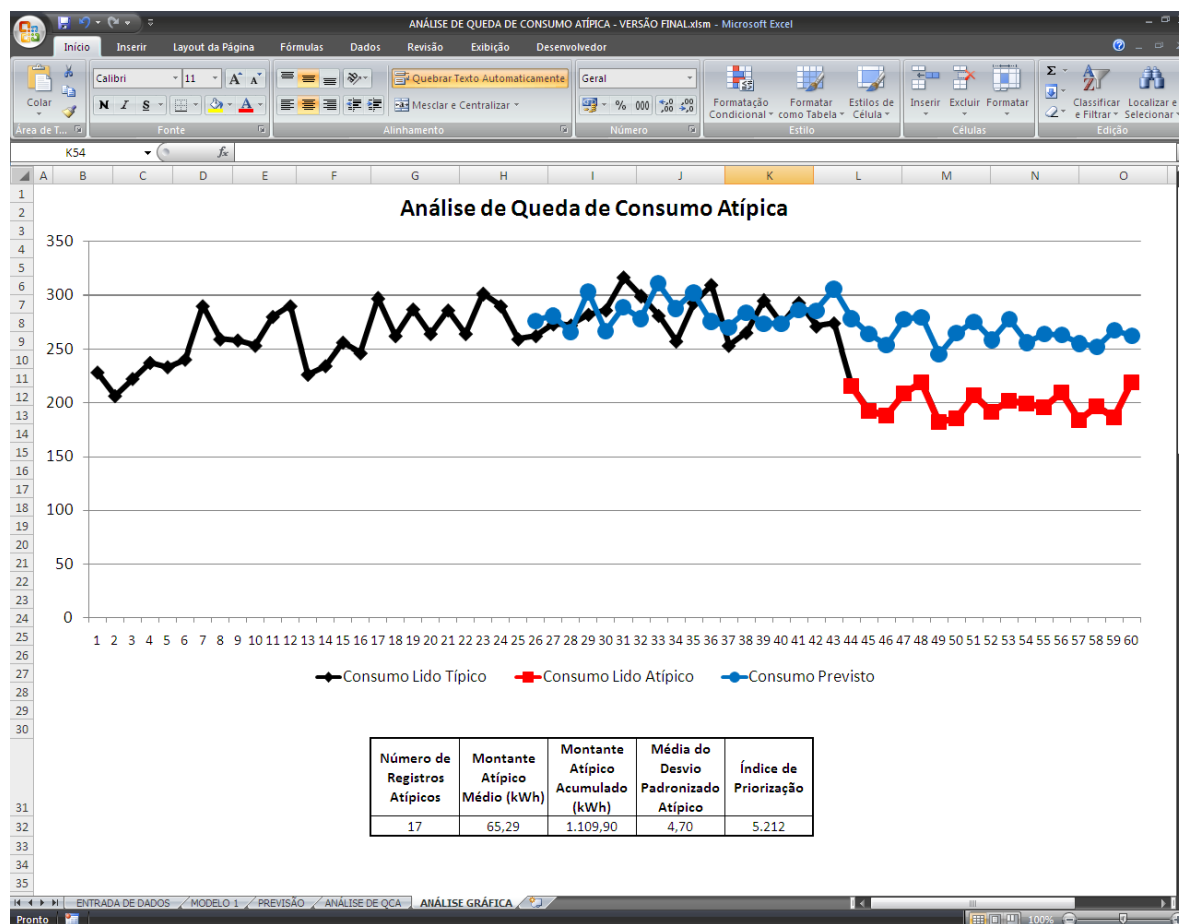


Figura 22: Aba “Análise Gráfica”

Conforme apresentado, os coeficientes dos testes utilizados pelo método possuem uma configuração *default*. Tal configuração é baseada em coeficientes estatísticos consolidados na literatura. Entretanto, esses coeficientes podem ser ajustados de acordo com a preferência do usuário. Por exemplo, caso o usuário deseje tornar o método mais rigoroso, os coeficientes podem ser reduzidos em valores absolutos. Já para os casos onde o usuário desejar que somente as quedas de consumo atípicas muito relevantes sejam indicadas, os coeficientes podem ser ajustados para números de valor absoluto maior.

A calibração dos testes proposta pelo autor é realizada analisando as indicações de consumos típicos e atípicos para a previsão de séries sabidamente isentas de irregularidades. Para tanto, os coeficientes dos testes realizados são reduzidos em termos absolutos até o limiar entre a indicação de valores típicos e atípicos. Desta forma, busca-se alcançar valores para os coeficientes que tornem os testes rigorosos, porém sem que ocorram indicações de quedas de consumo atípicas, provenientes dos componentes aleatórios das séries de consumo.

Sendo assim, o resultado da calibração proposta pelo autor indica que para o primeiro e segundo testes, os coeficientes devem ser iguais a 2,5. O coeficiente do terceiro teste deve ser igual a 0,15, enquanto que o coeficiente do quarto teste deve ser 15%. Esta configuração é utilizada pelo autor para a validação do método na seção 4.4.2.

4.4.2 Validação do Método

A validação do método é focada às reais necessidades da empresa analisada. Por esse motivo, todos os procedimentos adotados para a análise de desempenho do método consideram as características das irregularidades mais frequentes na área de concessão da RGE. O principal objetivo desta seção é investigar a validade do método, promovendo-o a ferramenta de análise da equipe de planejamento de inspeções da RGE se o resultado for satisfatório.

As principais irregularidades encontradas na RGE estão relacionadas às manipulações e adulterações de medidores de energia elétrica. O caso mais comum é a manipulação da posição dos mancais de apoio do elemento móvel (disco), correspondendo a 25% de todas as irregularidades identificadas na área de concessão da empresa.

Em um medidor de energia eletro-mecânico existem dois mancais: o inferior e o superior. Esses componentes têm a função de sustentar e posicionar verticalmente o eixo do disco. Uma vez que um ou ambos os mancais sejam movidos de suas posições originais de fábrica, é possível ocorrer contato entre o disco e os demais componentes do medidor. O atrito gerado entre esses componentes impede que o disco gire livremente, resultando num registro de consumo de energia elétrica inferior ao real.

O percentual de erro que esta irregularidade pode proporcionar à contabilização de energia depende do atrito estabelecido em função da nova posição dos mancais, podendo variar de 0% a 100%. Os casos mais frequentes possuem atrito suficiente para impedir o registro de baixas demandas de energia e impedir parcialmente o registro de demandas mais elevadas. Como exemplo de baixa demanda, pode-se citar a energia requerida por uma lâmpada incandescente de 60 Watts. Da mesma forma, pode-se citar um chuveiro elétrico como fonte de demanda mais elevada. Muito embora essa configuração seja a mais comum, há diversas ocorrências de manipulação em mancais que impedem totalmente o registro de

consumo de energia elétrica, mesmo nos casos onde existem demandas elevadas. De forma geral, o percentual de erro que é inserido através das irregularidades é igual ou superior a 20%.

Outra característica importante dessa irregularidade diz respeito a sua dificuldade de manipulação periódica. Isto ocorre, pois, mesmo em uma situação onde o responsável pela irregularidade tente reverter a fraude, dificilmente se conseguirá restabelecer a posição original dos mancais. Em função disso, é comum que a irregularidade se mantenha ativa e inalterada até que a situação da medição seja regularizada pela concessionária. Nestes casos, é comum a substituição do medidor fraudado por um equipamento novo. A Figura 23 ilustra um caso de mancal rebaixado.




Figura 23: Manipulação dos mancais de apoio do elemento móvel (disco) do medidor

O segundo caso mais freqüente, correspondente a 16% das irregularidades identificadas na área de concessão da RGE, diz respeito a utilização de *jumpers* (conexões elétricas) entre os bornes de entrada e de saída dos medidores. São chamados bornes de entrada os componentes onde são fixados os condutores (fios) de energia elétrica provenientes da rede de distribuição da concessionária. Já os componentes chamados bornes de saída são os locais onde são fixados os condutores (fios) de energia elétrica provenientes da instalação interna da unidade consumidora.

Os *jumpers* são feitos com o auxílio de condutores independentes e extras à medição regular. Uma vez que um *jumper* é instalado em uma determinada fase do medidor, a corrente elétrica identifica uma opção de caminho para percorrer no percurso compreendido entre a rede de distribuição e a instalação elétrica do cliente. Em função disso, a corrente demandada

pela carga do cliente percorre dois caminhos distintos: o circuito interno do medidor e o circuito criado pelo *jumper*, sendo que toda a corrente elétrica que percorrer o circuito criado pelo *jumper* não será contabilizada no consumo de energia da UC (somente será registrada a parte da corrente que percorrer o circuito interno do medidor).

O percentual de erro que essa irregularidade pode proporcionar à contabilização de energia varia basicamente em função da combinação dos seguintes elementos: número de fases do medidor, resistência ôhmica do(s) condutor(es) utilizado(s), distribuição da carga do cliente entre as fases conectadas e número de fases em que foi instalado o *jumper*. Por exemplo, nos casos onde o condutor utilizado para fazer a conexão possui resistência ôhmica igual à resistência do circuito interno do medidor, o erro de medição para a fase em questão é de aproximadamente 50%.

Diferentemente dos casos de manipulação nos mancais, essa irregularidade pode ser facilmente desfeita. Para tanto, basta desconectar o *jumper* dos bornes de entrada e saída do medidor. Apesar disto, o caso mais freqüente de *jumper* ocorre em ligações monofásicas, onde a irregularidade é mantida após a sua instalação. Figura 24 ilustra um caso de *jumper* em uma medição monofásica.

Outro tipo de irregularidade bastante comum, correspondente a 15% das irregularidades identificadas na área de concessão da RGE, diz respeito à utilização de objetos com o intuito de travar o elemento móvel do medidor. Para realizar esta irregularidade, a tampa do medidor é violada, dando acesso ao elemento móvel do medidor. A violação pode ocorrer através do rompimento dos lacres do medidor ou através da quebra ou perfuração da sua tampa. Uma vez realizado o acesso ao elemento móvel, o responsável pela irregularidade dispõe de diversas opções para travar o disco. Os casos mais freqüentes utilizam arames, prendedores de roupa, gravetos e pedras; a Figura 25 apresenta duas situações onde o disco foi travado.




Figura 24: *Jumper* – Fio azul ligado entre os bornes de entrada e saída de fase do medidor monofásico

O percentual de erro que esta irregularidade proporciona à contabilização de energia é de 100%. Isto ocorre, pois, uma vez travado o disco, o medidor se torna incapaz de registrar qualquer consumo de energia.

De forma semelhante aos *jumpers*, essa irregularidade pode ser facilmente desfeita; para tanto, basta retirar o objeto que está travando o disco. Em virtude disso, é comum a ocorrência de manipulações na irregularidade. As manipulações podem ocorrer durante um mesmo ciclo de faturamento, resultando em registros parciais de consumo de energia, ou durante períodos maiores, caracterizando a chamada irregularidade “pipoca” (oscilação cíclica nos registros de consumo, provenientes das manipulações).

Para exemplificar o funcionamento dessa configuração de irregularidade, podem-se citar os casos onde o disco é travado e destravado em intervalos iguais ou superiores a um ciclo de faturamento. Durante o(s) ciclo(s) em que o disco estiver travado, o registro será igual a zero. Já no(s) ciclo(s) em que o disco estiver livre, o registro será igual ao consumo real da UC. Desta forma, ocorre uma oscilação entre valores reais consumidos e consumos iguais a zero.




Figura 25: Disco travado – à esquerda, prendedor de cabelo trava o disco; à direita, arame é inserido através de orifício na tampa do medidor, travando o disco

O quarto caso mais freqüente, correspondente a 13% das irregularidades identificadas na área de concessão da RGE, diz respeito a manipulação dos elos de potencial dos medidores. Elo de potencial é o componente do medidor de energia responsável por conectar o borne de entrada à bobina de tensão. É através da bobina de tensão que o medidor afere a tensão existente entre as fases e o neutro. Para registrar corretamente o consumo de energia, o medidor precisa da informação da(s) tensão(ões) e da(s) corrente(s) elétrica(s). Uma vez aberto o elo de potencial para determinada fase, o medidor será incapaz de registrar o consumo de energia proveniente da ligação desta fase com a carga do cliente.

O percentual de erro que esta irregularidade pode proporcionar à contabilização de energia varia basicamente em função da combinação dos seguintes elementos: número de fases do medidor, distribuição da carga do cliente entre as fases conectadas, número de elos de potencial abertos e tensão das fases. Por exemplo, um medidor trifásico conectado a uma carga distribuída igualmente entre as fases, onde a tensão das três fases é igual e existem dois elos de potencial aberto, terá um erro aproximado de -66,67%.

Esta irregularidade também pode ser manipulada. Para tanto, basta reconectar o elo de potencial, colocando-o em sua posição original. Entretanto, a sua manipulação em intervalos de tempo não é comum na área de concessão da RGE. Na maioria dos casos

identificados, uma vez realizada a irregularidade, a mesma é mantida. A Figura 26 apresenta um caso de irregularidade por abertura do elo de potencial.



Figura 26: Elo de potencial aberto

Outras irregularidades menos comuns também podem ser citadas; por exemplo: *(i)* inversão das conexões dos condutores de entrada e de saída do medidor; *(ii)* ligações diretas da rede; *(iii)* desvios nos condutores de ligação; *(iv)* adulteração dos circuitos dos medidores eletrônicos; *(v)* adulteração das engrenagens ou de outros componentes internos; e *(vi)* exclusão de componentes internos. A Figura 27 ilustra três dessas irregularidades.

Conforme apresentado, diversas irregularidades estão presentes na área de concessão da RGE. Entretanto, as alterações de comportamento provenientes das quatro irregularidades mais comuns, correspondentes a 69% das ocorrências, são conhecidas. Por esse motivo, essas alterações são simuladas de modo a verificar a capacidade do método de identificá-las. Para tanto, a série “tradicional” apresentada na Figura 18 é manipulada. Para cada tipo de alteração de comportamento proposta, o método é testado três vezes. Na primeira, a série é manipulada a partir do 35º período. Na seguinte, a manipulação ocorre a partir do 44º período. A última manipulação ocorre a partir do 53º período. Busca-se assim verificar se o momento de início

da irregularidade compromete de alguma forma a capacidade do método de prever registros futuros e identificar a existência de consumos atípicos.



Figura 27: Outras irregularidades – à esquerda, inclusão de circuito eletrônico para a manipulação remota do funcionamento do medidor; ao centro, ligação direta da rede de distribuição; à direita, adulteração das engrenagens do medidor

De forma complementar, uma série de consumo extremamente sazonal é testada. Para tanto, é criada uma série artificial com 60 registros de consumo, apresentada na Figura 28.

Três tipos principais de alterações de comportamento são testados: quedas contínuas, quedas cíclicas e quedas sazonais. Nos testes de quedas contínuas, é inserido o efeito do erro a partir do ponto de início da manipulação até o final da série. Os erros simulados nesses testes variam de -20% a -100% do valor registrado para cada período. A Figura 29 apresenta uma série utilizada nos testes, onde está presente uma queda de 40%, a partir do período 44.




Figura 28: Série artificial utilizada para testes extremamente sazonais




Figura 29: Exemplo de série de teste para quedas contínuas

Os testes de quedas cíclicas, projetadas para verificar a capacidade do método de identificação de irregularidades “pipoca”, são realizados com um e dois períodos irregulares. Em ambos os casos, utiliza-se um período de intervalo entre as manipulações. De forma semelhante ao caso anterior, é inserido o efeito do erro a partir do ponto de início da manipulação até o final da série. Os erros utilizados nas manipulações correspondem aos valores típicos desse tipo de irregularidade, ou seja, 33%, 50%, 66% e 100%. A Figura 30 apresenta um exemplo de série utilizada, onde se verifica uma queda cíclica de dois períodos, erro de 50% e início no período 35.




Figura 30: Exemplo de série de teste para quedas cíclicas

Por fim, os testes de quedas sazonais verificam a capacidade do método de identificar os casos onde os picos sazonais de consumo são manipulados. Também nesses testes, o efeito do erro é inserido a partir do ponto de início da manipulação até o final da série. Os erros utilizados são os mesmos dos testes de quedas contínuas. A Figura 31 apresenta um exemplo, onde se verifica uma queda sazonal com erro de 50% e início no período 35.




Figura 31: Exemplo de série de teste para quedas sazonais

Para facilitar o entendimento, optou-se por apresentar os resultados em seis tabelas distintas. As tabelas são formadas pelas combinações de início da manipulação (períodos $t=35$, $t=44$ e $t=53$) e tipo de série manipulada (série tradicional e série extremamente sazonal). Cada tabela apresenta os resultados e os valores esperados (gabarito) para cada um dos itens avaliados nos testes relacionados. Dessa forma, é possível verificar a qualidade das informações disponibilizadas pelo método. Para formar os valores que compõe o gabarito, são verificadas as diferenças entre os valores reais das séries e os valores manipulados para cada teste. Por exemplo, em um teste de queda contínua em que a manipulação dos registros começa no 53º período, os períodos 53 a 60 são considerados portadores de quedas de consumo atípicas. Desta forma, o gabarito aponta a existência de oito quedas de consumo atípicas. Nos itens em que o valor apresentado corresponde a um montante de energia, a formação do gabarito ocorre de forma semelhante. São verificadas as diferenças entre os valores reais da série e os valores manipulados para cada teste.

As seguintes informações são disponibilizadas: número de identificação do teste (Nº), descrição, número de registros atípicos (QCA), montante atípico médio (MAM) e acumulado (MAA) e ordem de priorização (OP). Utiliza-se o índice “A” para os dados correspondentes ao método e “G” para os dados referentes ao gabarito.

É importante mencionar que a ordem de priorização utilizada pelo método busca identificar casos onde há maior probabilidade de existir irregularidades, atrelado ao maior montante atípico acumulado; ou seja, casos onde exista concomitantemente um grande montante de energia não faturada e uma grande probabilidade de existência de irregularidades. Já o gabarito está priorizado em função da ordem decrescente dos montantes de energia acumulada, ou seja, o teste que ocupa o primeiro lugar na lista de priorização é aquele que possui o maior montante atípico acumulado. Essa configuração é utilizada, porque, idealmente, o método deveria indicar a mesma probabilidade de existência de irregularidade para todos os testes, sendo definido o posicionamento no *ranking* em função do montante atípico acumulado.

A Tabela 07 apresenta os resultados dos testes realizados na série com comportamento tradicional e com início das manipulações no 35º período. Verifica-se que o método identificou corretamente 343 dos 358 registros atípicos de consumo, correspondendo a um percentual de acerto de 95,81%. O único teste a apresentar falha na identificação de QCAs foi o nº1, correspondente a uma queda de 20%, onde o método identificou somente 11 dos 26 registros atípicos. Analisando os dados e os resultados dos testes aplicados ao ensaio nº1, verificou-se que em determinados períodos, o valor realizado foi semelhante ao valor previsto, gerando valores de Desvio Padronizado inferiores ao de referência. Em consequência, o método considerou aqueles períodos como típicos, vindo a alterar negativamente a capacidade do método de identificar QCAs.

No que diz respeito aos montantes atípicos acumulados, o método apontou por 12 vezes valores superiores aos reais, chegando a diferenças de até +16,76%, como apresentado pelo teste nº 28. No outro sentido, o método indicou por cinco vezes valores inferiores aos reais, chegando a diferenças de até -50,41%, como indicado pelo teste nº1. Entretanto, quando o teste nº 1 é desconsiderado, a diferença máxima fica igual a -10,80%, como indicado pelo teste nº 40. Como informação adicional, tem-se que a média absoluta do percentual de diferenças é igual a 5,36%. Considerando os montantes atípicos acumulados totais de energia, o método apresentou um erro de apenas 8 kWh, correspondente a 0,01% do valor de gabarito.

Tabela 7: Resultados dos testes realizados com a série tradicional e com manipulação a partir do 35º período

Nº	Descrição	QCA-A	QCA-G	MAM-A	MAM-G	MAA-A	MAA-G	OP-A	OP-G
1	Queda 20%	11	26	66	57	730	1.472	17	16
4	Queda 30%	26	26	88	85	2.294	2.208	14	13
7	Queda 40%	26	26	117	113	3.030	2.944	11	10
10	Queda 50%	26	26	145	142	3.766	3.680	8	7
13	Queda 60%	26	26	173	170	4.502	4.415	7	6
16	Queda 70%	26	26	201	198	5.237	5.151	5	5
19	Queda 80%	26	26	230	226	5.973	5.887	3	3
22	Queda 90%	26	26	258	255	6.709	6.623	2	2
25	Queda 100%	26	26	286	283	7.443	7.356	1	1
28	Pipoca (n=1)	13	13	109	93	1.414	1.211	15	17
31	Pipoca (n=1)	13	13	155	140	2.020	1.817	13	14
34	Pipoca (n=1)	13	13	200	184	2.601	2.398	10	12
37	Pipoca (n=1)	13	13	295	279	3.835	3.633	6	8
40	Pipoca (n=2)	18	18	86	96	1.544	1.731	16	15
43	Pipoca (n=2)	18	18	134	144	2.410	2.598	12	11
46	Pipoca (n=2)	18	18	180	190	3.241	3.429	9	9
49	Pipoca (n=2)	18	18	278	289	5.006	5.193	4	4
TOTAL		343	358			61.754	61.746		

Ao analisar os dois índices de priorização, verifica-se que existem 11 divergências entre o método e o gabarito. A maior diferença encontrada ocorre nos testes nº 28, 34 e 37, onde existe uma diferença de duas posições no *ranking*.

Análises semelhantes podem ser feitas nas Tabelas 08 a 12. A Tabela 08 apresenta os resultados dos testes realizados na série com comportamento tradicional e com início das manipulações no 44º período.

Tabela 8: Resultados dos testes realizados com a série tradicional e com manipulação a partir do 44º período

Nº	Descrição	QCA-A	QCA-G	MAM-A	MAM-G	MAA-A	MAA-G	OP-A	OP-G
2	Queda 20%	1	17	62	57	62	967	17	16
5	Queda 30%	17	17	73	85	1.245	1.450	14	13
8	Queda 40%	17	17	102	114	1.728	1.933	12	10
11	Queda 50%	17	17	130	142	2.212	2.417	9	7
14	Queda 60%	17	17	159	171	2.695	2.900	7	6
17	Queda 70%	17	17	187	199	3.178	3.383	5	4
20	Queda 80%	17	17	215	227	3.662	3.866	3	3
23	Queda 90%	17	17	244	256	4.145	4.350	2	2
26	Queda 100%	17	17	272	284	4.627	4.831	1	1
29	Pipoca (n=1)	8	8	88	93	704	742	16	17
32	Pipoca (n=1)	8	8	134	139	1.075	1.113	13	14
35	Pipoca (n=1)	8	8	179	184	1.431	1.469	10	12
38	Pipoca (n=1)	8	8	273	278	2.187	2.225	6	8
41	Pipoca (n=2)	11	11	91	94	997	1.029	15	15
44	Pipoca (n=2)	11	11	137	140	1.511	1.544	11	11
47	Pipoca (n=2)	11	11	182	185	2.005	2.038	8	9
50	Pipoca (n=2)	11	11	278	281	3.054	3.087	4	5
	TOTAL	213	229			36.519	39.344		

A Tabela 9 apresenta os resultados dos testes realizados na série com comportamento tradicional e com início das manipulações no 53º período. Já a Tabela 10 apresenta os resultados dos testes realizados na série com comportamento extremamente sazonal e com início das manipulações no 35º período.

Tabela 9: Resultados dos testes realizados com a série tradicional e com manipulação a partir do 53º período

Nº	Descrição	QCA-A	QCA-G	MAM-A	MAM-G	MAA-A	MAA-G	OP-A	OP-G
3	Queda 20%	8	8	58	57	461	455	17	16
6	Queda 30%	8	8	86	85	689	683	14	13
9	Queda 40%	8	8	115	114	916	910	11	10
12	Queda 50%	8	8	143	142	1.144	1.138	8	7
15	Queda 60%	8	8	171	171	1.371	1.365	7	6
18	Queda 70%	8	8	200	199	1.599	1.593	5	4
21	Queda 80%	8	8	228	228	1.826	1.820	3	3
24	Queda 90%	8	8	257	256	2.054	2.048	2	2
27	Queda 100%	8	8	285	284	2.280	2.274	1	1
30	Pipoca (n=1)	4	4	101	91	405	366	16	17
33	Pipoca (n=1)	4	4	147	137	588	549	13	14
36	Pipoca (n=1)	4	4	191	181	763	724	10	11
39	Pipoca (n=1)	4	4	284	274	1.136	1.097	6	8
42	Pipoca (n=2)	5	5	90	95	452	474	15	15
45	Pipoca (n=2)	5	5	138	142	689	711	12	12
48	Pipoca (n=2)	5	5	183	188	917	939	9	9
51	Pipoca (n=2)	5	5	280	284	1.400	1.422	4	5
TOTAL		108	108			18.690	18.568		

A Tabela 11 apresenta os resultados dos testes realizados na série com comportamento extremamente sazonal e com início das manipulações no 44º período. Por fim, a Tabela 12 apresenta os resultados dos testes realizados na série com comportamento extremamente sazonal e com início das manipulações no 53º período.

Tabela 10: Resultados dos testes realizados com a série extremamente sazonal e com manipulação a partir do 35º período

Nº	Descrição	QCA-A	QCA-G	MAM-A	MAM-G	MAA-A	MAA-G	OP-A	OP-G
52	Sazonal 20%	7	7	120	123	842	858	9	9
55	Sazonal 30%	7	7	182	184	1.271	1.287	8	8
58	Sazonal 40%	7	7	243	245	1.700	1.716	7	7
61	Sazonal 50%	7	7	304	306	2.129	2.145	6	6
64	Sazonal 60%	7	7	365	368	2.558	2.574	5	5
67	Sazonal 70%	7	7	427	429	2.987	3.003	4	4
70	Sazonal 80%	7	7	488	490	3.416	3.432	3	3
73	Sazonal 90%	7	7	549	552	3.845	3.861	2	2
76	Sazonal 100%	7	7	610	613	4.273	4.289	1	1
	TOTAL	63	63			23.021	23.165		

Tabela 11: Resultados dos testes realizados com a série extremamente sazonal e com manipulação a partir do 44º período

Nº	Descrição	QCA-A	QCA-G	MAM-A	MAM-G	MAA-A	MAA-G	OP-A	OP-G
53	Sazonal 20%	4	4	123	123	493	490	9	9
56	Sazonal 30%	4	4	185	184	738	735	8	8
59	Sazonal 40%	4	4	246	245	983	980	7	7
62	Sazonal 50%	4	4	307	306	1.228	1.225	6	6
65	Sazonal 60%	4	4	368	368	1.473	1.470	5	5
68	Sazonal 70%	4	4	430	429	1.718	1.715	4	4
71	Sazonal 80%	4	4	491	490	1.963	1.960	3	3
74	Sazonal 90%	4	4	552	551	2.208	2.205	2	2
77	Sazonal 100%	4	4	613	612	2.453	2.450	1	1
	TOTAL	36	36			13.257	13.230		

Tabela 12: Resultados dos testes realizados com a série extremamente sazonal e com manipulação a partir do 53º período

Nº	Descrição	QCA-A	QCA-G	MAM-A	MAM-G	MAA-A	MAA-G	OP-A	OP-G
54	Sazonal 20%	1	1	112	122	112	122	9	9
57	Sazonal 30%	1	1	173	183	173	183	8	8
60	Sazonal 40%	1	1	234	244	234	244	7	7
63	Sazonal 50%	1	1	295	305	295	305	6	6
66	Sazonal 60%	1	1	356	366	356	366	5	5
69	Sazonal 70%	1	1	417	427	417	427	4	4
72	Sazonal 80%	1	1	478	488	478	488	3	3
75	Sazonal 90%	1	1	539	549	539	549	2	2
78	Sazonal 100%	1	1	600	610	600	610	1	1
TOTAL		9	9			3.204	3.294		

É importante informar que este trabalho está apoiado em um projeto de P&D da ANEEL realizado através de uma parceria da RGE com a UFRGS. Como fruto dessa parceria, foi desenvolvido um software que operacionaliza um método de detecção de quedas de consumo atípicas. Apesar das duas pesquisas – P&D e a pesquisa aqui apresentada – terem resultado em métodos distintos, os resultados foram semelhantes e promissores.

De modo geral, o desempenho do método proposto por este estudo se mostrou satisfatório, sendo capaz de identificar todas as QCAs simuladas com erros percentuais iguais ou superiores a 30%. Verificou-se também que mesmo nas séries onde as QCAs iniciavam no 35º período, o método foi capaz de manter os valores de previsão coerentes com a série analisada. A Figura 32 apresenta a série do teste nº 16, onde é possível verificar a coerência entre os valores previstos e a série original.




Figura 32: Comparação entre os valores previstos e a série original para o teste nº 16

Igualmente satisfatórios foram os resultados obtidos para as análises das séries extremamente sazonais. Verifica-se que nestes casos, a coerência das previsões é ainda maior, possivelmente em função das características das séries analisadas. A Figura 33 apresenta a série do teste nº 64, onde é possível verificar graficamente o resultado da análise do método.

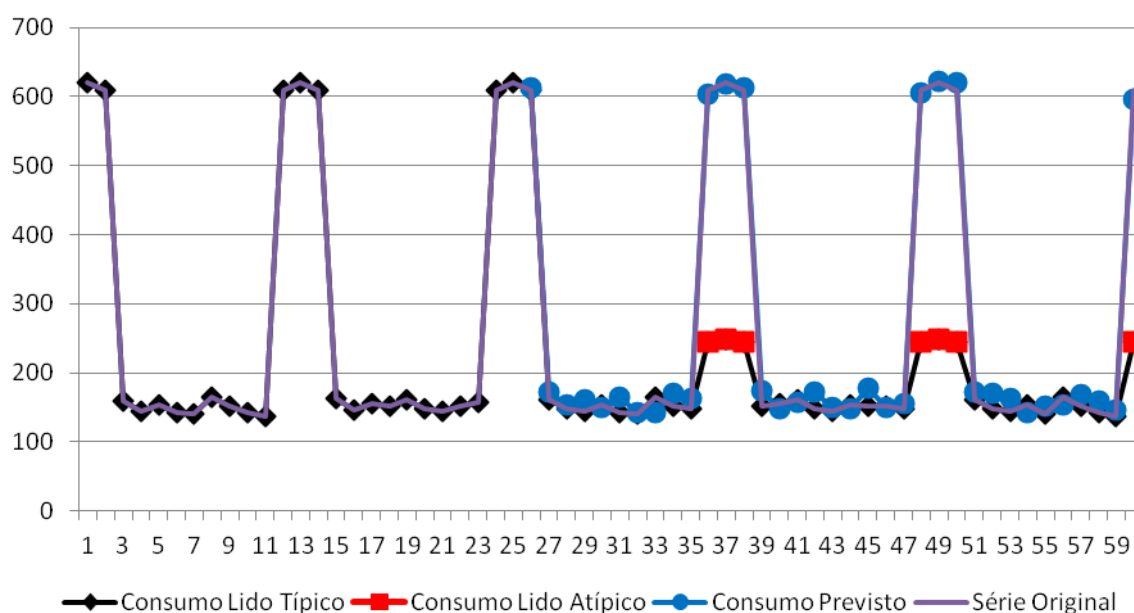


Figura 33: Comparação entre os valores previstos e a série original para o teste nº 64

Entretanto, verifica-se que o método apresentou dificuldades para identificar quedas de consumo atípicas quando o percentual de erro simulado era pequeno. No caso de erro percentual de 20% (testes de nºs 1, 2, 3, 52, 53 e 54), o método indicou corretamente somente 32 das 63 QCAs indicadas pelo gabarito, correspondendo a um percentual de acerto de apenas 50,79%. Apesar disto, pelo menos uma QCA foi indicada para cada teste, demonstrando que o método é capaz de detectar, mesmo que com algum atraso, as alterações nos padrões de consumo de energia elétrica. A Figura 34 apresenta graficamente o resultado do teste nº 1, onde somente 11 dos 26 registros atípicos foram identificados. Percebe-se que após alguns períodos, o método deixa de identificar os registros como QCAs, ajustando-se aos valores irregulares.




Figura 34: Apresentação gráfica do resultado do teste nº1

Algumas considerações e particularidades do método merecem destaque. A primeira diz respeito ao tipo de priorização proporcionado pelo método. O modo de priorização desenvolvido e testado busca identificar casos onde há maior probabilidade de existir irregularidades, atrelado ao maior montante atípico acumulado; ou seja, casos onde exista um grande volume de energia não faturada devido às irregularidades, independentemente da

média de kWh não registrada mensalmente. Entretanto, há situações em que é mais interessante para a distribuidora recuperar montantes iguais ou menores de energia do passado e garantir que uma fonte grande de perdas comerciais seja regularizada. Neste caso, o cálculo do índice de priorização deve ser alterado, passando a ser obtido pela multiplicação da Média do Desvio Padronizado Atípico pelo Montante Atípico Médio. Um exemplo desta situação é descrita a seguir.

O cliente A possui um consumo de 100 kWh mensais, sendo que somente 50 kWh são contabilizados e faturados pela distribuidora em função de uma irregularidade. A irregularidade desse cliente foi realizada há cinco anos, existindo assim há 60 períodos de faturamento e compondo um montante atípico acumulado de 3.000 kWh. Em função da irregularidade, que possui um percentual de erro de 50%, o valor Médio do Desvio Padronizado Atípico é relativamente grande.

O cliente B possui um consumo de 40.000 kWh mensais, dos quais somente 37.000 kWh são contabilizados e faturados pela distribuidora em função de uma irregularidade. Diferentemente da irregularidade do cliente A, esta foi realizada há somente um período de faturamento, fato que compõe um montante atípico acumulado igual ao do cliente A, ou seja, 3.000 kWh. O percentual de erro que esta irregularidade proporciona é muito inferior ao identificado na irregularidade do cliente A, o que acarreta em um valor Médio do Desvio Padronizado Atípico inferior em relação ao identificado anteriormente.

Nos dois casos, têm-se montantes atípicos acumulados iguais, porém como o valor médio do desvio padronizado atípico do cliente A é maior, ele tem uma maior probabilidade de ser atípico, sendo priorizado pelo método. Pode-se perceber que, neste caso, é mais interessante para a distribuidora regularizar primeiro o cliente B. Essa afirmativa está fundamentada na observação de que, no próximo período de faturamento, o cliente B deixará de pagar outros 3.000 kWh, enquanto que na medição do cliente A somente 50 kWh não serão contabilizados.

Outro ponto importante que deve ser ressaltado diz respeito às análises de séries extremamente sazonais. O método considera que as séries são estáveis, ou seja, mantêm inalterados os seus meses de referência de alta e baixa temporada. Entretanto, sabe-se que eventualmente ocorrem atrasos ou antecipações destes períodos como, por exemplo, os casos de antecipações de safras em UCs rurais. A Figura 35 apresenta o resultado da análise de uma série extremamente sazonal, onde foi simulada a antecipação de um mês a contar do 35º

período. Pode-se perceber que o método responde de forma equivocada a esse tipo de incidência, indicando, inclusive, a ocorrência de queda de consumo atípica.




Figura 35: Comportamento do método quando ocorre a antecipação de um mês a contar do 35º período

De forma semelhante, a Figura 36 apresenta o resultado da análise onde foi simulado o atraso de um mês a contar do 35º período. Pode-se perceber que, igualmente nesse caso, o método responde de forma equivocada, sendo apontados dois registros como sendo quedas de consumo atípicas.

Além disso, é importante informar que o desempenho do método proposto está fortemente relacionado ao momento em que ocorrem as QCAs. Conforme já exposto, quando QCAs ocorrem após o início das previsões de consumo, ou seja, a partir do 26º período, o método é plenamente eficaz para identificá-las. Entretanto, caso a QCA ocorra antes do 26º, ou seja, durante o período de calibração do método de previsão, a análise do método estará comprometida. A Figura 37 apresenta os efeitos que uma QCA, do tipo queda contínua, com redução de 40% dos valores de registro e com início no 5º período, introduz na análise do método.




Figura 36: Comportamento do método quando ocorre o atraso de um mês a contar do 35º período




Figura 37: Efeitos da ocorrência de QCAs durante o período de calibração do método

5 CONCLUSÃO

Nos últimos anos, diversas alterações ocorreram no setor elétrico brasileiro. Uma das mais importantes foi o movimento de privatização das companhias de distribuição de energia elétrica. Atrelado a esse movimento, o órgão regulatório condicionou o funcionamento das empresas, de modo que a prestação dos serviços fosse focada na eficiência operacional. Neste sentido, a Agência Nacional de Energia Elétrica (ANEEL) definiu, através Do estabelecimento de um benchmark operacional denominado Empresa de Referência, níveis eficientes para cada função de operação das distribuidoras de energia elétrica do Brasil. A área Comercial das empresas foi incumbida, dentre outras atividades, do gerenciamento e combate às perdas na distribuição.

A perda na distribuição é composta por diversos componentes, dentre os quais se destacam as perdas comerciais. Perdas comerciais podem estar relacionadas aos clientes regulares ou irregulares das distribuidoras, sendo comum o desenvolvimento de ações para o seu combate. A atividade de inspeção nas medições de energia elétrica é a ação mais popular de combate às perdas comerciais entre as concessionárias de energia elétrica. Por este motivo, é interessante que sejam utilizados mecanismos que otimizem essa atividade, reduzindo os seus custos operacionais.

Nesta dissertação foi proposto um método que auxiliasse na identificação de quedas de consumo atípicas (QCAs) dentro do universo de faturamento de unidades consumidoras (UCs) de uma concessionária de energia. De forma secundária, buscou-se verificar a aplicabilidade de técnicas de previsão de demanda em séries de consumo de UCs de energia elétrica, bem como a geração de um *ranking* de priorização para as indicações de QCAs do método proposto. Igualmente, buscou-se verificar se o método proposto seria capaz de aderir às características específicas da empresa de distribuição de energia Rio Grande Energia S.A. Percebe-se que os objetivos secundários são subprodutos necessários para formar o objetivo principal: os dois primeiros são necessários para formar o método, e o último é necessário para a sua validação.

Nesse sentido, o estudo realizou uma revisão bibliográfica sobre os tópicos fundamentais para o seu desenvolvimento. Essa revisão contou com informações de 123

publicações, das quais 78 correspondem a artigos publicados em periódicos. Baseado nesse levantamento, deu-se continuidade ao atendimento dos objetivos previamente apresentados.

Inicialmente, buscou-se verificar a aplicabilidade de técnicas de previsão de demanda em séries de consumo de UCs de energia elétrica. Ao todo, foram testados 28 métodos de previsão de demanda utilizando a plataforma *Excel 2007*. As medidas de acurácia MAPE e Theil's U foram utilizadas para verificar e comparar o desempenho dos métodos. Para cada método, foram realizadas 30 previsões de consumo utilizando séries de consumo reais. Os períodos 1 a 48 foram utilizados para calibrar os coeficientes de métodos que contemplavam uma etapa de calibração, sendo destinados os períodos 49 a 60 para a efetiva previsão de consumo.

Ao final da verificação de aplicabilidade dos métodos, o relatório apresentado no Anexo 1 foi obtido. Pode-se perceber que, entre os períodos avaliados (de calibração e de previsão), 11 dos 28 métodos obtiveram o melhor desempenho em pelo menos uma das medidas de acurácia. Esse fato indica que cada UC possui características distintas das demais, o que possibilita a aderência a métodos também distintos de previsão de demanda. Em linhas gerais, pode-se afirmar que os métodos são capazes de realizar previsões de consumo satisfatórias. Verifica-se que a média das melhores medidas de MAPE e Theil's U nas 30 séries analisadas, considerando os períodos de calibração e de previsão, foram, 6,41% e 0,7141 e 7,94% e 0,7224, respectivamente.

Para atender o objetivo de geração de um *ranking* de priorização para as indicações de QCAs, levaram-se em conta duas informações relacionadas às análises estatísticas do método: a probabilidade de existência de irregularidade e o Montante Atípico Acumulado (MAA) de energia identificado. A primeira delas foi associada à média do desvio padronizado dos registros atípicos, visto que quanto maior for o registro dessa variável, maior é a probabilidade de existência de irregularidade. A segunda é obtida pela soma das diferenças entre os valores previstos e os efetivamente lidos para cada um dos registros considerados atípicos.

As duas variáveis foram relacionadas de forma multiplicativa. Dessa forma, tem-se que o índice de priorização é diretamente proporcional à probabilidade de existência de QCAs e também ao MAA. Assim, para formar o *ranking* de priorização, as séries analisadas devem ser dispostas em ordem decrescente dos índices de priorização obtidos. As séries que

ocuparem as primeiras posições serão aquelas a serem priorizadas em fiscalizações das medições em campo.

Para desenvolver o método de identificação de QCAs foi necessário escolher um método de previsão de demanda. Para tanto, optou-se por utilizar o método que obteve o maior número de melhores medidas de acurácia, correspondendo ao método proposto pelo autor deste trabalho, com os coeficientes calibrados individualmente. Esse método obteve o melhor desempenho em 13 medidas para o período de calibração, sendo cinco medidas MAPE e oito Theil's U, e 16 medidas para o período de previsão, sendo seis medidas MAPE e 10 Theil's U. Adicionalmente, verificou-se que o método apresentou o melhor desempenho concomitantemente em ambos os períodos em seis oportunidades, sendo três delas em cada medida de acurácia.

O método foi implantado em uma planilha *Excel 2007*, tendo os seus elementos principais distribuídos em cinco abas distintas. Para realizar as análises, foram utilizados recursos como a função *Solver* e macros. A sua idéia central está baseada na comparação estatística entre os registros de leitura e os valores previstos pelo método de previsão. Para cada período previsto são realizados quatro testes, cada um executando uma análise diferente. Somente são considerados atípicos os registros em que os quatro testes sinalizam a existência de QCA. Os registros considerados atípicos são substituídos da base de previsão por seus valores previstos. Ao final da série, são indicados graficamente os períodos considerados atípicos. Adicionalmente, é apresentada uma planilha com as estatísticas relacionadas ao método, incluindo o seu índice de priorização.

Uma vez desenvolvido o método de identificação de QCAs, verificou-se a sua capacidade de aderência às características específicas da empresa de distribuição de energia Rio Grande Energia SA. Para tanto, solicitou-se da empresa informações referentes às irregularidades mais freqüentes encontradas em campo. Foi feita uma relação das mesmas, sendo identificadas suas características específicas como, por exemplo, o percentual de redução de consumo típico e a possibilidade de manipulação periódica da irregularidade.

De posse dessas informações, foram feitas manipulações em uma série típica da distribuidora de energia, de modo que os efeitos das irregularidades fossem simulados. Para cada tipo de irregularidade, foram realizadas três análises com o método, sendo que em cada uma delas os efeitos foram simulados a partir de um período distinto. Dessa forma, buscou-se

identificar se o momento de início da irregularidade poderia afetar o desempenho do método. Adicionalmente, foram realizadas análises em séries de consumo extremamente sazonais.

Ao todo, foram analisadas 84 séries manipuladas, das quais 30 tinham a característica de serem extremamente sazonais. Para verificar o desempenho do método, os resultados foram comparados a um gabarito. Desse modo, verificou-se que o método obteve um excelente desempenho, tendo identificado 774 dos 866 registros atípicos simulados, correspondendo a um percentual de 89,38% de acerto.

Verificou-se em determinadas análises que alguns registros simulados foram semelhantes aos valores previstos, gerando índices de desvio padronizado inferiores ao limítrofe para a indicação de QCA. Como consequência, o método considerou aqueles períodos típicos, vindo a alterar negativamente a capacidade do método de identificar QCAs.

No quesito MAA, o método foi capaz de identificar 156.550 kWh dos 161.529 kWh atípicos previstos no gabarito, correspondendo a 96,92% de acerto. Verifica-se que a diferença encontrada se dá em função da não indicação de algumas QCAs.

As irregularidades simuladas durante a validação do método correspondem a 69% dos casos identificados na RGE. Por esse motivo, e também considerando os índices de desempenho apresentados, conclui-se que o método é plenamente capaz de identificar as principais irregularidades praticadas na empresa, sendo o seu resultado satisfatório.

É importante ressaltar o aspecto inovador que esse método introduz na atividade de fiscalização das medições, visto que usualmente as análises de QCAs nas distribuidoras são realizadas considerando somente comparações entre os valores de consumo efetivamente registrados. Diferentemente, o método considera as características próprias de cada UC, utilizando essas informações para realizar previsões de consumo que serão estatisticamente comparadas com os registros de leitura.

Conforme apresentado, foi possível identificar que alguns métodos de previsão de demanda se adaptaram melhor a determinadas séries de consumo. Por esse motivo, sugere-se que possa ser ampliada a análise dos métodos de previsão de demanda, buscando identificar outros métodos que também apresentem bons resultados. Complementarmente, pode ser desenvolvido um método que identifique qual método se adapta melhor a determinado perfil de consumo. Dessa forma, seria possível utilizar sempre o método com o melhor desempenho para cada perfil de UC.

Adicionalmente, algumas particularidades do método devem ser consideradas. No caso de análises de séries fortemente sazonais, o método considera que os meses de referência de alta e baixa temporada das séries se mantêm inalterados. Essa característica pode induzir a erros de análise, visto que, eventualmente, ocorrem atrasos ou antecipações destes períodos. Em virtude destas observações, recomenda-se prudência no seu uso para a análise desse tipo de série. Sugere-se que seja desenvolvida uma melhoria do método, de modo que o mesmo identifique e trate esse tipo de ocorrência. A adaptação deve contemplar os casos em que ocorrem atrasos e antecipações nos períodos sazonais, sem prejudicar a capacidade do método de identificar QCAs.

Outra particularidade diz respeito ao momento do início das irregularidades. Verificou-se que o método possui desempenho satisfatório somente nos casos onde a irregularidade se inicia após o 26º registro. Por esse motivo, sugere-se que seja desenvolvida uma alternativa para que os casos onde a irregularidade se inicia antes do 26º período também seja contemplada.

É importante ressaltar que os resultados satisfatórios do método foram obtidos em séries simuladas, sendo interessante validar também o método com fiscalizações em campo. Nesse sentido, o método deverá ser ajustado, de modo que as informações do histórico de eventos das UCs também sejam consideradas. Por exemplo, as informações do resultado de uma fiscalização já realizada devem ser consideradas, visto que elas certamente trazem dados pertinentes à análise.

Por fim, se verifica que as perdas na distribuição de energia elétrica constituem um assunto amplo, complexo e ainda pouco estudado. Por esse motivo, acredita-se que haja espaço para desenvolver outras pesquisas, dentre elas: análise do ponto ótimo de perdas comerciais, análise georeferenciada das perdas comerciais, análise de comportamento das UCs por *clusters* e outras.

REFERÊNCIAS BIBLIOGRÁFICAS

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA (ANEEL). Resolução nº 456/2000. **Condições Gerais de Fornecimento de Energia Elétrica**. Brasília, DF, Brasil, 2000.

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA (ANEEL). Apresentação Institucional. **Audiência Pública Comissão de Defesa do Consumidor**. Câmara dos Deputados, Brasília, DF, Brasil, 2005.

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA (ANEEL). Nota Técnica nº 262/2006-SER/SFF/SRC/SFE/ANEEL. **Segundo Ciclo de Revisão Tarifária Periódica das Concessionárias de Distribuição de Energia Elétrica do Brasil – Aprimoramento das Metodologias**. Brasília, DF, Brasil, 2006.

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA (ANEEL). Nota Técnica nº 290/2008-SER/ANEEL. **Metodologia de Tratamento Regulatório para Perdas Não Técnicas de Energia Elétrica**. Brasília, DF, Brasil, 2008.

AHMAD, A. R.; MOHAMAD, A. M. Intelligent System for Detection of Abnormalities and Probable Fraud by Metered Customers. **19th International Conference on Electricity Distribution**. Vienna, Austria, 21-24 de Maio, 2007.

ALIBAIG, S.; LILLY, B. Updating Your Forecasting System: Wisconsin Tissue's Experience. **The Journal of Business Forecasting Methods & Systems**. v. 18, n. 3, p. 13-18, 1999.

ANSUJ, A. P.; CAMARGO, M. E.; RADHARAMANAN, R. PETRY, D. G. Sales Forecasting Using Time Series and Neural Networks. **Computers and Industrial Engineering**. v. 31, n. 1, p. 421-425, 1996.

ARAUJO, A. C. M. **Perdas e Inadimplência na Atividade de Distribuição de Energia Elétrica no Brasil**. Tese (Doutorado em Ciências de Planejamento Energético). Universidade Federal do Rio de Janeiro – UFRJ, Rio de Janeiro, RJ, Brasil, 2007.

ARAUJO, A. C. M.; SIQUEIRA, C. A. Considerações Sobre as Perdas na Distribuição de Energia Elétrica no Brasil. In: Seminário Nacional de Distribuição de Energia Elétrica. **Anais XVII SENDI**. Belo Horizonte, MG, Brasil, 2006.

ARCHER, B. Forecasting Demand: Quantitative and Intuitive Techniques. **International Journal of Tourism Management**. v. 1, n. 1, p. 5-12, 1980.

ARMSTRONG, J. S. Strategic Planning and Forecasting Fundamentals. In: ALBERT, K. **The Strategic Management Handbook**. New York: MacGraw Hill, 1983.

ARMSTRONG, J. S. **Long-rang Forecasting**. 2. ed. New York: John Wiley & Sons, 1985.

ARMSTRONG, J. S. Forecasting Methods for Conflict Situations. In: WRIGHT, G.; AYTON, P. **Judgment Forecasting**. New York: John Wiley & Sons, 1987.

ARMSTRONG, J. S. Research Needs in Forecasting. **International Journal of Forecasting**. v. 4, n. 3, p. 449-465, 1988.

ARMSTRONG, J. S. **Principles of Forecasting: a Handbook for Researchers and Practitioners**. Boston: Kluwer Academic Publishers, 2001a.

ARMSTRONG, J. S. Selecting Forecasting Methods. In: ARMSTRONG, J. S. **Principles of Forecasting: a Handbook for Researchers and Practitioners**. Boston: Kluwer Academic Publishers, 2001b.

ARMSTRONG, J. S. Role Playing: A Method to Forecast Decisions. In: ARMSTRONG, J. S. **Principles of Forecasting: a Handbook for Researchers and Practitioners**. Boston: Kluwer Academic Publisher, 2001c.

ARMSTRONG, J. S. Extrapolation for Time-series and Cross-sectional Data. In: ARMSTRONG, J. S. **Principles of Forecasting: a Handbook for Researchers and Practitioners**. Boston: Kluwer Academic Publishers, 2001d.

ARMSTRONG, J. S. Standards and Practices for Forecasting. In: ARMSTRONG, J. S. **Principles of Forecasting: a Handbook for Researchers and Practitioners**. Boston: Kluwer Academic Publishers, 2001e.

ARMSTRONG, J. S. Combining Forecasts. In: ARMSTRONG, J. S. **Principles of Forecasting: a Handbook for Researchers and Practitioners**. Boston: Kluwer Academic Publishers, 2001f.

ARMSTRONG, J. S.; ADYA, M.; COLLOPY, F. Ruled-based Forecasting: Using Judgmental in Time-series Extrapolation. In: ARMSTRONG, J. S. **Principles of Forecasting: a Handbook for Researchers and Practitioners**. Boston: Kluwer Academic Publishers, 2001.

- ARMSTRONG, J. S.; BRODIE, R. J. Forecasting for Marketing. In: HOOLEY, G. J.; HUSSEY, M. K. **Quantitative Methods in Marketing**. 2. ed., London: International Thompson Business Press, 1999.
- ARMSTRONG, J. S.; COLLOPY, F. Error Measures for Generalizing About Forecasting Methods: Empirical Comparisons. **International Journal of Forecasting**. v. 8, n. 1, p. 69-80, 1992.
- ARMSTRONG, J. S.; COLLOPY, F.; YOKUM, J. T. Decomposition by Causal Forces: a Procedure for Forecasting Complex Time Series. **International Journal of Forecasting**. v. 21, n. 1, p. 25-36, 2005.
- ASHTON, A. H.; ASHTON, R. H. Aggregating Subjective Forecasts: Some Empirical Results. **Management Science**. v. 31, n. 12, p. 1499-1508, 1985.
- BALLOU, R. H. **Gerenciamento da Cadeia de Suprimentos: Planejamento, Organização e Logística Empresarial**. 4. ed., Porto Alegre: Bookman, 2001.
- BATES, J. M.; GRANGER, C. W. J. The Combination of Forecasts. **Operational Research Quarterly**. v. 20, n. 4, p. 451-468, 1969.
- BLATTBERG, R. C.; HOCH, S. J. Database Models and Managerial Intuition: 50% Model + 50% Manager. **Management Science**. v. 36, n. 8, p. 887-899, 1990.
- BOPP, A. E. On Combining Forecasts: Some Extensions and Results. **Management Science**. v. 31, n. 12, p. 1492-1498, 1985.
- BOX, G. E. P.; JENKINS, G. M.; REINSELL, G. C. **Time Series Analysis: Forecasting and Control**. New Jersey: Prentice Hall, 1994.
- BRASIL. Decreto nº 4.562, de 31 de dezembro de 2002. Diário Oficial da República Federativa do Brasil, Poder Executivo, Brasília, DF, 31 de dezembro de 2002, seção 1, p. 3.
- BUNN, D.; WRIGHT, G. Interaction of Judgemental and Statistical Forecasting Methods: Issues & Analysis. **Management Science**. v. 37, n. 5, p. 501-518, 1991.
- BUSINGER, M. P.; READ, R. R. Interaction of Judgemental and Statistical Forecasting Methods: Issues & Analysis. **Management Science**. v. 37, n. 5, p. 501-518, 1991.
- CABRAL, J. E.; GONTIJO, E. M. Fraud Detection in Electrical Energy Consumers Using Rough Sets. **IEEE International Conference on Systems, Man and Cybernetics**. CD-ROM, 2004.

CARBONE, R.; ARMSTRONG, J. S. Evaluation of Extrapolative Forecasting Methods: Results of a Survey of Academicians and Practitioners. **Journal of Forecasting**. v. 1, n. 2, p. 215-217, 1982.

CENTRAIS ELÉTRICAS BRASILEIRAS (ELETROBRAS). Mercado de Energia Elétrica: Relatório Analítico: Ciclo 2001. Rio de Janeiro: Eletrobrás, 2001.

CHAMBERS, J. C.; MULLICK, S. K.; SMITH, D. D. How to Choose the Right Forecasting Technique. **Harvard Business Review**. v. 49, July-August, p. 45-57, 1971.

CHEN, K.; KUNG, S. Synthesis of Qualitative and Quantitative Approaches to Long-range Forecasting. **Technological Forecasting and Social Change**. v. 26, n. 3, p. 255-266, 1984.

CLEMEN, R. T. Combining Forecasts: a Review and Annotated Bibliography. **International Journal of Forecasting**. v. 5, n.4, p. 559-583, 1989.

COLLOPY, F.; ADYA, M.; ARMSTRONG, J. S. Expert Systems for Forecasting. In: ARMSTRONG, J. **Principles of Forecasting: a Handbook for Researchers and Practitioners**. Boston: Kluwer Academic Publishers, 2001.

COLLOPY, F.; ARMSTRONG, J. S. Ruled-based Forecasting: Development and Validation of an Expert System Approach to Combining Time Series Extrapolations. **Management Science**. v. 38, n. 10, p. 1394-1414, 1992.

COMITÊ DE DISTRIBUIÇÃO (CODI). Resolução nº 26, de 17 de novembro de 1994. In: Relatório CODI-3.2.19.34.0: Método para Determinação, Análise e Otimização das Perdas Técnicas em Sistemas de Distribuição. Rio de Janeiro: CODI, 1996. Anexo E.

DALKEY, N. C. Delphi. In: MARTINO, J. P. **An Introduction to Technological Forecasting**. New York: Gordon & Breach Publishers, 1972.

DAVIS, M.; AQUILANO, N.; CHASE, R. **Fundamentos da Administração da Produção**. Porto Alegre: Bookman, 2001.

DEUTSH, M.; GRANGER, C. W. J.; TERÄSVIRTA, T. The Combination of Forecasts Using Changing Weights. **International Journal of Forecasting**. v. 10, n. 1, p. 47-57, 1994.

ELSAYED, E.; BOUCHER, T. **Analysis and Control of Production Systems**. 2. ed., New Jersey: Prentice-Hall, 1994.

EVANS, J. Psychological Pitfalls in Forecasting. **Futures**. v. 14, n. 4, p. 258-265, 1982.

FILDES, R.; HASTINGS, R. The Organization and Improvement of Market Forecasting. **Journal of Operational Research Society**. v. 45, p. 1-16, 1994.

FLORES, B. E.; WHITE, E. M. A Framework for the Combination of Forecasts. **Journal of the Academy of Marketing Science**. v. 16, n. 3-4, p. 95-103, 1988.

GEORGOFF, D. M.; MURDICK, R. G. Manager's Guide to Forecasting. **Harvard Business Review**. v. 64, n. 1, p. 110-120, 1986.

GOODWIN, P. Improving the Voluntary Integration of Statistical Forecasts and Judgement. **International Journal of Forecasting**. v. 16, n. 1, p. 85-99, 2000a.

GOODWIN, P. Correct or Combine? Mechanically Integrating Judgmental Forecasts with Statistical Methods. **International Journal of Forecasting**. v. 16, n. 2, p. 261-275, 2000b.

GOODWIN, P. Integrating Management Judgment and Statistical Methods to Improve Short-term Forecasts. **Omega**. v. 30, n. 2, p. 127-135, 2002.

GOODWIN, P.; WRIGHT, G. Improving Judgmental Time Series Forecasting: a Review of the Guidance Provided Research. **International Journal of Forecasting**. v. 9, n. 2, p. 147-161, 1993.

GOODWIN, P.; WRIGHT, G. Heuristic, Biases and Improvement Strategies in Judgmental Time Series Forecasting. **Omega**. v. 22, n. 6, p. 553-568, 1994.

GREEN, K. Forecasting Decisions in Conflict Situations: A comparison of Game Theory, Role Playing and Unaided Judgment. **International Journal of Forecasting**. v. 18, n. 3, p. 321-344, 2002.

GUPTA, U.; CLARKE, R. Theory and Application of Delphi Technique: A Bibliography (1975 – 1994). **Technological Forecasting and Social Change**. v. 53, n. 2, p. 185-211, 1996.

HIBON, M.; EVGENIOU, T. To Combine or Not to Combine: Selecting Among Forecasts and Their Combinations. **International Journal of Forecasting**. v. 21, n. 1, p. 15-24, 2005.

HOLT, C. C. Forecasting Seasonals and Trends by Exponentially Weighted Moving Averages. **International Journal of Forecasting**. v. 20, n. 1, p. 5-10, 2004.

HUTH, L. W.; EPPRIGHT, R. D.; TAUBE, M. P. The Indexes of Consumer Sentiment and Confidence: Leading or Misleading Guides to Future Buyer Behavior. **Journal of Business Research**. v. 29, n. 3, p. 199-206, 1994.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). Indicadores Populacionais. Disponível em: <http://www.ibge.gov.br>. Acesso em 23/03/2009.

JICK, T. D. Mixing Qualitative and Quantitative Methods: Triangulation in Action. **Administrative Science Quarterly**. v. 24, n. 11, p. 602-611, 1979.

KAHN, K. Benchmarking Sales Forecasting Performance Measures. **The Journal of Business Forecasting**. Winter, p. 19-23, 1998.

KAHN, K. An Exploratory Investigation of New Product Forecasting Practices. **The Journal of Product Innovation Management**. v. 19, n. 2, p. 133-143, 2002.

KLASSEN, R.; FLORES, B. Forecasting Practices of Canadian Firms: Survey Results and Comparisons. **International Journal of Production Economics**. v. 70, n. 2, p. 163-174, 2001.

KOTLER, P. **Marketing Management: Analysis, Planning, Implementation and Control**. New Jersey: Prentice-Hall, 1991.

KRAJEWSKI, L. J.; RITZMAN, L. P. **Operations Management: Strategy and Analysis**. 6. ed., New Jersey: Prentice-Hall, 2002.

LAWRENCE, M. J.; EDMUNDSON, R. H.; O'CONNOR, M. J. The Accuracy of Combining Judgement and Statistical Forecasts. **Management Science**. v. 32, n. 12, p. 1521-1532, 1986.

LAWRENCE, M. J.; EDMUNDSON, B. H.; O'CONNOR, M. J.. A Field Study of Sales Forecasting Accuracy and Processes. **Amsterdam European Journal of Operational Research**. v. 122, n. 1, p. 151, 160, 2000.

LEMOS, D. L.; PORTO, A. C. Technological Forecasting Techniques and Competitive Intelligence: Tools for Improving the Innovation Process. **Industrial Management & Data Systems**. v. 98, n. 7, p. 330-337, 1998.

LIMA, Davi Antunes. Convergência Tarifária: Remédio Regulatório para o Livre Acesso. Brasília: ANEEL, 2005. 16 p. (Textos para discussão, n. 2).

LUXHOJ, J. T.; RISS, J. O.; STENSALLE, B. A Hybrid Econometric-Neural Network Modeling Approach for Sales Forecasting. **Amsterdam International Journal of Production Economics**. n. 43, p. 175-192, 1996.

- LYNN, G.; SCHNAARS, S.; SKOV, R. Survey of New Product Forecasting Practices in Industrial High technology and Low Technology Businesses. **Industrial Marketing Management**. v. 28, n. 6, p. 565-571, 1999.
- MACEDO, W. E. *et al.* Avaliação das Perdas Elétricas no Sistema de Distribuição da SAELPA. In: CICLO PALESTRAS DE DISTRIBUIÇÃO DE ENERGIA ELÉTRICA, 2. ed, Olinda, PE, 1993.
- MacGREGOR, D. J. Decomposition for Judgmental Forecasting and Estimation. In: ARMSTRONG, J. **Principles of Forecasting: a Handbook for Researchers and Practitioners**. Boston: Kluwer Academic Publishers, 2001.
- MACKAY, M. M.; METCALFE, M. Multiple Methods Forecast for Discontinuous Innovations. **Technological Forecasting & Social Change**. v. 69, n. 3, p. 221-232, 2002.
- MAKRIDAKIS, S. Metaforecasting: Ways of Improving Forecasting Accuracy and Usefulness. **International Journal of Forecasting**. v. 4, n. 3, p. 467-491, 1988.
- MAKRIDAKIS, S.; HIBON, M. ARMA Models and the Box-Jenkins Methodology. **Journal of Forecasting**. v. 16, n. 3, p. 147-163, 1997.
- MAKRIDAKIS, S.; WHEELWRIGHT, S.; HYNDMAN, R. **Forecasting: Methods and Applications**. 3. ed., New York: John Wiley & Sons, 1998.
- MAKRIDAKIS, S.; WINKLER, R. Averages of Forecasts: Some Empirical Results. **Management Science**. v. 29, n. 9, p. 987-996, 1983.
- MCHUGH, A. K.; SPARKES, J. R. The Forecasting Dilemma. **Management Accounting**. n. 61, p. 30-34, 1983.
- MENTZER, J. T.; COX Jr., J. E. Familiarity, Application and Performance of Sales Forecasting Techniques. **Journal of Forecasting**. n. 3, p. 27-36, 1984.
- MENTZER, J. T.; GOMES, R. Evaluating a Decision Support Forecasting System. **Industrial Marketing Management**. v. 18, n. 4, p. 313-323, 1989.
- MONTGOMERY, D. C. **Introdução ao Controle Estatístico da Qualidade**. 4. ed., Rio de Janeiro: Livros Técnicos e Científicos Editora, 2004.
- MOON, M.; MENTZER, J.; SMITH, C.; GARVER, M. Seven Keys to Better Forecasting. **Business Horizons**. v. 41, n. 5, p. 44-52, 1998.

- MORWITZ, V. G. Methods for Forecasting from Intentions Data. In: ARMSTRONG, J. **Principles of Forecasting: a Handbook for Researchers and Practitioners**. Boston: Kluwer Academic Publishers, 2001.
- MURDICK, R. R.; GEORGOFF, D. M. Forecasting: a Systems Approach. **Technological Forecasting and Social Change**. v. 44, n. 1, p. 1-16, 1993.
- NESBIT, B. Thieves Lurk: the Sizeable Problem of Stolen Electricity. **Electrical world**. v. 214, n. 5, p. 31, Sep./Oct., 2000.
- PAMPLONA, N. Cresce o Furto de Eletricidade no Rio. **Folha de São Paulo**. n. 58523, São Paulo, SP, 2002.
- PASSARI, A. F. L. **Exploração de Dados Atomizados para Previsão de Vendas no Varejo Utilizando Redes Neurais**. Dissertação (Mestrado em Administração). Universidade de São Paulo, São Paulo, 2003.
- PETERSON, R. T.; JUN, M. Forecasting Sales in Wholesale Industry. **The Journal of Business Forecasting Methods & Systems**. v. 18, n. 2, p. 15-18, 1999.
- PREBLE, J. Public Sector Use of the Delphi Technique. **Technological Forecasting and Social Change**. v. 23, n.1, p. 75-88, 1983.
- RASMUSSEN, R. On Time Series Data and Optimal Parameters. **Omega**. v. 32, n. 2, p. 111-120, 2004.
- REMUS, W.; O'CONNOR, M. GRIGGS, K. The Impact of Information of Unknown Correctness on Judgmental Forecasting Process. **International Journal of Forecasting**. v. 14, n. 3, p. 313-322, 1998.
- RINGUEST, J. L.; TANG, K. Simple Rules for Combining Forecasts: Some Empirical Results. **Socio-Economic Planning Science**. v. 21, n. 14, p. 239-243, 1987.
- RIZVI, M. Pakistan Gets Switched on. **Development Magazine on Global Issues**. n. 71, 2000.
- ROWE, G.; WRIGHT, G. The Delphi Technique as a Forecasting Tool: Issues and Analysis. **International Journal of Forecasting**. v. 15, n. 4, p. 353-375, 1999.
- SALSA, C. Perdas na Distribuição de Energia Elétrica no Brasil. **Portal Ecodebate**. Disponível em: <http://www.ecodebate.com.br/2009/03/02/perdas-na-distribuicao-de-energia-eletrica-no-brasil-artigo-de-carol-salsa>. Acesso em 23/03/2009.

- SANDERS, N. R. The Status of Forecasting in Manufacturing Firms. **Production and Inventory Management Journal**. v. 25, n. 5, p. 32-35, 1997a.
- SANDERS, N. R. The Impact of Task Properties Feedback on Time Series Judgmental Forecasting Tasks. **Omega**. v. 25, n. 5, p. 135-144, 1997b.
- SANDERS, N. R.; MANRODT, K. Forecasting Practices in US Corporations: Survey Results. **Interfaces**. v. 24, n. 2, p. 92-100, 1994.
- SANDERS, N. R.; RITZMAN, L. P. Bringing Judgment into Combination Forecasts. **Journal of Operations Management**. v. 13, n. 4, p. 311-321, 1995.
- SANDERS, N. R.; RITZMAN, L. P. Judgmental Adjustment of Statistical Forecasts. In: ARMSTRONG, J. S. **Principles of Forecasting: a Handbook for Researchers and Practitioners**. Boston: Kluwer Academic Publishers, 2001.
- SPEEDING, T. CHAN, K. Forecasting Demand and Inventory Management Using Bayesian Time Series. **Integrated Manufacturing Systems**. v. 11, n. 5, p. 331-339, 2000.
- SUBRAHMANYAN, S. **An Explonatory Empirical Study on How Pricing and Inventory Decisions are Made in a Simulated Environment**. Research Paper Series, Faculty of Business Administration, National University of Singapore, Maio, RPS, p. 98-123, 1998.
- SUBRAHMANYAN, S. Using Quantitative Models for Setting Retail Prices. **Journal of Product and Brand Management**. v. 9, n. 5, p. 304-320, 2000.
- SYNTETOS, A.A., BOYLAN, J.E., The accuracy of intermittent demand estimates. **International Journal of Forecasting**. v. 21, p. 303-314, 2005.
- TAYLOR, J. W. Exponential Smoothing with a Damped Multiplicative Trend. **International Journal of Forecasting**. v. 19, n. 4, p. 715-725, 2003.
- THOMAS, R. J. Forecasting New Product Market Potential: Combining Multiple Methods. **The Journal of Product Innovation Management**. v. 4, n. 2, p. 109-119, 1987.
- THOMAS, R. J. Estimating Demand for Services: Issues in Combining Sales Forecasts. **Journal of Retailing and Consumer Services**. v. 3, n. 4, p. 241-250, 1996.
- WALKER, K. B.; McCLELLAND, L. A. Management Forecasts and Statistical Prediction Model Forecasts in Corporate Budgeting. **Journal of Accounting Research**. v. 29, n. 2, p. 371-381, 1991.

WEBBY, R. O'CONNOR, M. Judgmental and Statistical Time Series Forecasting: a Review of the Literature. **International Journal of Forecasting**. v. 12, n. 1, p. 91-118, 1996.

WEBBY, R.; O'CONNOR, M. Judgmental Time-Series Forecasting Using Domain Knowledge. In: ARMSTRONG, J. S. **Principles of Forecasting: a Handbook for Researchers and Practitioners**. Boston: Kluwer Academic Publishers, 2001.

WEBBY, R.; O'CONNOR, M.; EDMUNDSON, B. Forecasting Support Systems for the Incorporation of Event Information: an Empirical Investigation. **International Journal of Forecasting**. v. 21, n. 3, p. 411-423, 2004.

WERNER, L. **Um modelo composto para realizar previsão de demanda através da integração da combinação de previsões e do ajuste baseado na opinião**. Tese (Doutorado em Engenharia de Produção), Departamento de Engenharia de Produção e Transportes, Universidade Federal do Rio Grande do Sul, 2004.

WHEELWRIGHT, S.; CLARKE, D. Corporate Forecasting: Promise and Reality. **Harvard Business Review**. v. 54, p. 40-64, 1976.

WINKLER, R. L. Combining Forecasts: a Philosophical Basis and Some Current Issues. **International Journal of Forecasting**. v. 5, n. 4, p. 605-609, 1989.

WINKLHOFER, H.; DIAMANTOPOULOS, A.; WITT, S. Forecasting Practice: a Review of the Empirical Literature and an Agenda for Future Research. **International Journal of Forecasting**. v. 12, n. 2, p. 193-221, 1996.

WINTERS, P. R. Forecasting Sales by Exponentially Weighted Moving Average. **Management Science**. v. 6, p. 324-342, 1960.

WITTINK, D. R.; BERGESTUEN, T. Forecasting with Conjoint Analysis. In: ARMSTRONG, J. S. **Principles of Forecasting: a Handbook for Researchers and Practitioners**. Boston: Kluwer Academic Publishers, 2001.

WRIGHT, G.; LAWRENCE, M.; COLLOPY, F. The Role and Validity of Judgment in Forecasting. **International Journal of Forecasting**. v. 12, n. 1, p. 1-8, 1996.

WRIGHT, J.; GIOVINAZZO, R. Delphi – Uma Ferramenta de Apoio ao Planejamento Prospectivo. **Caderno de Pesquisas em Administração**. São Paulo, v. 1, n. 12, p. 54-65, 2000.

YIN, R. K. Estudo de caso – Planejamento e Métodos. 2. ed., Bookman, Porto Alegre, 2001.

ANEXO 1

O presente anexo apresenta os resultados para as medidas de acurácia MAPE e Theil's U de todos os métodos de previsão de demanda avaliados durante esse estudo. Os dados foram reunidos em quatro tabelas, de modo a facilitar a interpretação dos dados. As Tabelas 13 e 14 apresentam os dados de calibração e de previsão para a medida MAPE. Já os dados de calibração e previsão referentes à medida Theil's U são apresentados nas Tabelas 15 e 16, respectivamente.

Para facilitar o entendimento dos dados, utiliza-se um sistema de cores, onde as linhas em azul claro apresentam os resultados obtidos para o período de calibração das séries. Já as linhas rosa apresentam os dados obtidos para o período de previsão. As células marcadas com as cores verde e vermelho apresentam os melhores desempenhos dentre todos os métodos de previsão para as UCs nos períodos de calibração e previsão, respectivamente.

Tabela 13: Resumo dos Resultados Alcançados – MAPE Calibração

	Naive	Média Móvel (n=2)	Média Móvel (n=3)	Média Móvel (n=6)	AR(1) Individual	AR(1) Agrupamento	AR(1) Individual	AR(1) Agrupamento	SES Individual	SES Agrupamento	Holt Individual	Holt Agrupamento	Holt-Winters Individual	Holt-Winters Agrupamento
UC01	21,12%	25,65%	32,12%	43,79%	20,48%	106,09%	18,55%	54,25%	31,10%	33,95%	21,64%	36,39%	32,69%	12,61%
UC02	15,70%	17,64%	22,45%	30,30%	12,90%	17,86%	11,27%	22,67%	17,60%	30,69%	17,60%	33,17%	12,90%	15,21%
UC03	9,82%	11,11%	13,64%	18,91%	9,43%	52,29%	9,00%	21,85%	9,78%	52,29%	10,84%	16,12%	9,09%	9,50%
UC04	8,25%	7,51%	8,70%	11,01%	7,08%	75,43%	6,63%	32,71%	7,68%	20,05%	9,07%	11,13%	5,17%	4,81%
UC05	15,85%	17,65%	19,65%	24,80%	14,75%	32,72%	13,05%	21,37%	20,05%	20,05%	16,95%	27,13%	8,59%	8,60%
UC06	7,68%	6,01%	6,13%	7,03%	5,69%	120,32%	5,55%	51,74%	5,81%	6,18%	7,86%	8,23%	3,72%	87,01%
UC07	7,54%	6,51%	7,68%	8,93%	6,48%	45,25%	5,65%	20,13%	7,71%	7,71%	7,63%	9,28%	4,67%	4,75%
UC08	16,15%	17,09%	18,28%	23,15%	15,28%	42,09%	15,10%	22,80%	16,12%	18,27%	17,75%	25,44%	12,66%	12,57%
UC09	7,53%	6,57%	6,83%	8,37%	6,08%	72,32%	5,97%	31,57%	6,63%	6,63%	7,43%	8,53%	5,23%	6,09%
UC10	7,31%	5,62%	5,55%	5,89%	5,01%	123,98%	4,91%	53,25%	5,04%	5,55%	7,22%	7,57%	4,18%	5,93%
UC11	10,51%	8,36%	5,31%	5,44%	7,95%	28,66%	6,85%	14,07%	7,36%	7,43%	8,41%	7,38%	8,74%	8,97%
UC12	6,85%	6,26%	6,07%	6,08%	5,47%	108,80%	5,27%	46,59%	5,61%	5,82%	7,11%	6,82%	4,43%	4,57%
UC13	7,72%	6,26%	6,07%	6,08%	5,47%	108,80%	5,27%	46,59%	5,61%	5,82%	7,11%	6,82%	4,43%	4,57%
UC14	9,49%	10,88%	12,18%	16,74%	9,37%	115,83%	9,07%	52,70%	9,42%	14,32%	9,72%	12,72%	25,61%	26,57%
UC15	8,48%	6,88%	7,22%	9,00%	6,53%	34,65%	6,24%	15,81%	7,00%	7,34%	8,77%	9,38%	7,09%	7,19%
UC16	7,86%	7,20%	6,97%	6,60%	6,72%	51,49%	5,99%	21,44%	6,34%	6,35%	8,11%	8,25%	5,16%	5,18%
UC17	7,16%	6,30%	6,63%	7,45%	5,62%	52,96%	5,45%	22,86%	6,45%	6,50%	6,78%	7,80%	4,55%	4,51%
UC18	5,52%	4,35%	4,42%	4,51%	4,51%	57,65%	4,13%	24,19%	4,48%	4,70%	5,68%	5,88%	5,62%	5,74%
UC19	5,93%	4,60%	4,43%	4,70%	4,72%	38,76%	4,07%	16,39%	4,52%	4,52%	5,78%	5,89%	4,73%	4,79%
UC20	9,27%	8,53%	8,25%	7,84%	7,34%	7,98%	7,29%	7,96%	8,00%	8,01%	9,41%	9,95%	5,43%	5,87%
UC21	12,97%	13,18%	14,18%	16,51%	12,08%	53,22%	11,45%	24,81%	12,76%	14,27%	13,79%	15,85%	11,74%	52,10%
UC22	17,93%	15,44%	14,25%	15,37%	12,45%	20,60%	10,85%	12,26%	13,37%	14,01%	19,54%	20,89%	10,08%	10,13%
UC23	12,13%	10,52%	10,94%	10,24%	9,70%	48,04%	8,91%	23,39%	9,72%	9,82%	12,29%	12,93%	9,55%	9,57%
UC24	12,66%	12,40%	13,98%	17,91%	10,87%	12,14%	9,97%	12,98%	12,94%	13,55%	14,15%	18,66%	11,25%	13,34%
UC25	13,96%	11,08%	11,29%	11,48%	10,94%	25,89%	9,82%	16,57%	10,70%	10,70%	10,65%	12,32%	11,62%	12,49%
UC26	12,10%	10,22%	11,02%	11,39%	9,66%	32,06%	8,64%	17,86%	10,00%	10,27%	11,07%	12,25%	10,35%	10,69%
UC27	8,07%	5,65%	5,58%	4,88%	4,88%	144,57%	4,34%	61,64%	5,48%	5,63%	7,83%	8,13%	4,91%	4,91%
UC28	4,80%	4,21%	4,08%	4,29%	4,49%	34,28%	3,81%	14,89%	4,13%	4,42%	4,62%	4,75%	6,54%	6,72%
UC29	9,47%	7,71%	7,56%	6,18%	7,75%	7,33%	6,46%	7,38%	7,23%	7,57%	9,81%	10,03%	4,68%	7,41%
UC30	9,81%	9,98%	10,24%	11,07%	8,99%	29,27%	9,13%	13,83%	9,25%	9,67%	10,36%	11,11%	9,11%	9,10%
ARIMA(0,1,1) Individual	21,43%	35,38%	20,89%	46,59%	20,73%	23,45%	20,42%	40,17%	21,46%	37,90%	19,75%	100,20%	13,61%	27,67%
ARIMA(0,1,1) Agrupamento	15,99%	32,83%	13,62%	30,40%	20,39%	16,41%	12,11%	26,99%	14,31%	28,04%	9,81%	90,45%	13,37%	22,64%
ARIMA(1,0,1) Individual	9,78%	16,62%	9,01%	20,39%	11,99%	16,41%	9,32%	17,21%	15,89%	8,82%	16,10%	16,10%	8,57%	14,67%
ARIMA(1,0,1) Agrupamento	7,68%	9,11%	7,00%	11,36%	7,25%	8,10%	6,88%	10,24%	7,98%	10,11%	6,07%	37,96%	5,87%	8,71%
ARIMA(0,1,3) Individual	15,50%	20,15%	13,05%	25,84%	13,64%	17,76%	13,79%	23,08%	14,19%	22,34%	13,66%	42,23%	9,61%	17,96%
ARIMA(0,1,3) Agrupamento	5,77%	6,65%	5,64%	7,65%	6,55%	6,80%	5,68%	6,13%	6,31%	7,18%	4,44%	37,45%	4,94%	6,42%
ARIMA(1,0,3) Individual	6,88%	7,99%	5,99%	9,27%	6,19%	8,12%	6,11%	8,74%	8,56%	8,56%	4,64%	38,00%	4,09%	6,62%
ARIMA(1,0,3) Agrupamento	16,06%	18,31%	14,95%	24,52%	14,54%	15,74%	15,24%	22,01%	15,25%	20,65%	13,57%	21,44%	11,36%	15,89%
ARIMA(0,1,1) Individual	6,60%	7,27%	6,31%	8,83%	7,06%	7,77%	5,89%	7,83%	7,06%	7,99%	5,85%	36,72%	6,23%	7,18%
ARIMA(0,1,1) Agrupamento	5,10%	6,05%	5,35%	6,52%	6,22%	6,45%	5,21%	5,72%	6,22%	6,30%	3,12%	30,44%	4,69%	5,76%
ARIMA(1,1,1) Individual	7,36%	7,65%	7,39%	8,21%	10,90%	16,75%	7,39%	7,69%	7,58%	7,97%	6,95%	12,12%	5,88%	6,67%
ARIMA(1,1,1) Agrupamento	4,71%	5,71%	4,66%	5,93%	6,01%	6,13%	5,29%	5,60%	6,14%	6,14%	4,12%	23,85%	4,72%	5,85%
ARIMA(0,1,1) Individual	5,43%	6,00%	5,95%	6,79%	6,65%	7,96%	5,70%	6,13%	5,94%	6,32%	4,82%	53,50%	4,62%	6,16%
ARIMA(0,1,1) Agrupamento	9,27%	15,75%	8,94%	16,82%	9,84%	17,12%	9,13%	14,18%	9,35%	15,38%	9,09%	36,82%	9,82%	15,13%
ARIMA(1,1,1) Individual	6,85%	7,72%	6,46%	9,58%	7,15%	7,92%	6,74%	8,29%	6,79%	7,95%	4,95%	25,45%	6,52%	7,82%
ARIMA(1,1,1) Agrupamento	6,31%	6,26%	5,75%	6,34%	7,35%	7,93%	6,15%	6,65%	6,61%	6,61%	4,95%	24,23%	4,53%	5,48%
ARIMA(0,1,1) Individual	4,26%	6,58%	5,78%	7,64%	6,71%	7,31%	6,05%	7,07%	6,26%	7,07%	4,71%	39,84%	4,15%	5,97%
ARIMA(0,1,1) Agrupamento	4,47%	4,79%	4,00%	4,22%	4,97%	4,73%	4,22%	4,97%	5,00%	5,00%	3,78%	39,84%	4,15%	5,97%
ARIMA(0,1,1) Individual	4,90%	4,59%	4,30%	4,91%	4,92%	4,49%	4,22%	4,55%	4,40%	4,73%	3,26%	19,60%	3,48%	4,03%
ARIMA(0,1,1) Agrupamento	7,96%	7,96%	7,38%	8,65%	10,77%	15,24%	7,95%	8,62%	7,48%	8,06%	7,36%	19,60%	3,48%	4,03%
ARIMA(1,1,1) Individual	12,33%	14,57%	12,32%	18,25%	11,95%	13,99%	12,33%	16,25%	12,65%	15,02%	8,60%	118,50%	11,43%	15,95%
ARIMA(1,1,1) Agrupamento	12,86%	14,10%	12,56%	16,02%	29,19%	43,15%	12,43%	14,94%	12,41%	14,59%	11,29%	116,68%	11,29%	14,07%
ARIMA(0,1,1) Individual	9,55%	10,20%	9,24%	11,77%	13,29%	14,61%	9,64%	10,97%	9,83%	11,09%	8,21%	95,15%	9,01%	10,65%
ARIMA(0,1,1) Agrupamento	11,77%	14,05%	10,42%	18,63%	12,46%	13,65%	11,51%	16,76%	11,43%	15,03%	10,02%	131,7%	8,99%	12,14%
ARIMA(1,1,1) Individual	10,44%	11,11%	9,52%	13,06%	13,78%	15,91%	10,22%	12,19%	10,86%	11,68%	8,60%	120,83%	10,21%	11,87%
ARIMA(1,1,1) Agrupamento	10,00%	10,76%	9,57%	12,93%	12,09%	13,38%	9,51%	11,41%	10,16%	11,31%	7,59%	83,26%	9,53%	11,11%
ARIMA(0,1,1) Individual	5,47%	6,16%	5,20%	5,95%	7,00%	7,98%	4,99%	5,42%	4,99%	5,76%	4,20%	54,42%	3,95%	5,82%
ARIMA(0,1,1) Agrupamento	4,06%	4,58%	3,93%	4,13%	4,26%	4,35%	3,91%	4,07%	4,07%	4,35%	3,93%	11,31%	3,01%	3,18%
ARIMA(0,1,1) Individual	7,99%	7,67%	5,68%	7,73%	13,24%	17,86%	7,15%	7,54%	6,29%	7,24%	5,47%	8,91%	5,18%	6,69%
ARIMA(0,1,1) Agrupamento	9,29%	9,78%	8,74%	11,24%	10,82%	10,71%	9,20%	10,71%	9,20%	10,60%	7,94%	8,89%	8,58%	10,64%

Tabela 14: Resumo dos Resultados Alcançados – MAPE Previsão

	Naive	Média Móvel (n=2)	Média Móvel (n=3)	Média Móvel (n=6)	AR(1) Individual	AR(1) Agrupamento	AR(1) Individual	AR(1) Agrupamento	SES Individual	SES Agrupamento	Holt Individual	Holt Agrupamento	Holt-Winters Individual	Holt-Winters Agrupamento
UC01	17,85%	25,27%	32,97%	46,95%	99,97%	17,65%	22,67%	60,27%	35,50%	37,09%	19,06%	38,59%	24,00%	24,62%
UC02	18,26%	22,87%	24,42%	31,23%	19,40%	17,54%	19,33%	24,99%	18,11%	25,37%	23,47%	26,64%	12,41%	14,74%
UC03	8,55%	10,45%	12,75%	18,75%	11,03%	46,78%	7,05%	17,18%	8,40%	46,78%	9,94%	16,42%	11,39%	12,77%
UC04	9,40%	9,63%	11,47%	14,42%	9,44%	73,11%	9,22%	33,07%	9,22%	11,69%	8,77%	11,69%	8,63%	5,62%
UC05	15,33%	20,73%	21,95%	26,51%	14,96%	29,43%	14,58%	22,80%	20,97%	21,05%	17,84%	24,30%	15,35%	15,55%
UC06	8,20%	7,35%	8,17%	10,47%	8,10%	116,00%	7,21%	50,82%	8,50%	8,73%	7,58%	8,57%	18,52%	7326,85%
UC07	9,09%	9,01%	10,85%	13,72%	9,19%	38,91%	7,75%	17,09%	8,95%	11,06%	8,72%	11,01%	6,86%	10,06%
UC08	19,61%	20,75%	22,02%	23,90%	15,80%	38,99%	19,13%	21,21%	19,82%	20,33%	22,27%	23,85%	23,74%	24,83%
UC09	7,25%	7,94%	9,31%	11,69%	8,12%	68,98%	8,03%	30,96%	8,04%	9,59%	7,75%	9,14%	6,45%	20,49%
UC10	7,86%	6,50%	6,97%	8,86%	7,54%	116,96%	8,23%	51,08%	7,88%	7,37%	7,32%	6,46%	26,30%	
UC11	9,53%	5,46%	7,79%	9,25%	7,95%	126,70%	6,89%	55,21%	7,30%	8,11%	8,51%	8,64%	5,69%	8,37%
UC12	6,44%	5,46%	5,99%	6,44%	7,70%	97,23%	8,22%	42,57%	7,40%	7,05%	6,69%	6,74%	6,32%	4,43%
UC13	7,11%	7,41%	8,00%	8,22%	7,00%	119,93%	7,89%	52,33%	8,36%	9,28%	8,48%	9,36%	11,24%	8,22%
UC14	8,83%	7,83%	8,39%	11,34%	8,32%	119,93%	7,89%	52,33%	8,36%	9,28%	8,48%	9,36%	11,24%	8,22%
UC15	9,53%	7,94%	7,78%	11,11%	8,27%	28,32%	7,38%	13,93%	7,96%	9,22%	9,07%	9,22%	7,17%	7,68%
UC16	7,96%	6,21%	5,55%	5,31%	6,57%	47,15%	5,48%	21,90%	5,46%	5,33%	6,64%	6,48%	3,49%	3,49%
UC17	6,85%	7,01%	8,16%	10,65%	8,32%	38,66%	8,23%	17,62%	8,74%	8,90%	6,94%	8,08%	7,63%	7,54%
UC18	5,37%	4,73%	5,23%	6,75%	5,10%	22,97%	5,01%	22,97%	5,68%	4,94%	4,94%	5,45%	5,64%	5,21%
UC19	6,49%	4,64%	4,94%	6,38%	5,18%	33,79%	5,02%	15,51%	5,10%	5,39%	4,88%	5,10%	6,33%	5,98%
UC20	12,21%	9,12%	8,32%	10,98%	9,43%	9,69%	9,14%	8,32%	9,36%	9,73%	9,72%	9,67%	9,17%	18,06%
UC21	20,40%	24,45%	28,20%	33,35%	19,57%	37,64%	27,93%	31,64%	22,55%	27,45%	20,30%	31,81%	33,79%	1401,69%
UC22	23,82%	19,76%	17,57%	21,22%	16,10%	19,30%	15,01%	15,29%	19,13%	18,10%	23,77%	21,87%	11,61%	11,47%
UC23	12,25%	10,53%	10,80%	11,27%	9,92%	48,02%	8,74%	22,67%	9,77%	9,81%	12,18%	12,78%	8,36%	8,31%
UC24	19,75%	14,55%	14,10%	13,97%	17,18%	14,51%	14,54%	13,25%	13,88%	13,28%	18,04%	15,68%	21,54%	65,84%
UC25	15,41%	13,79%	14,37%	18,12%	11,40%	26,30%	11,75%	20,08%	14,45%	14,25%	13,45%	16,24%	21,07%	28,24%
UC26	15,84%	13,70%	12,98%	13,47%	12,05%	26,45%	11,55%	16,00%	12,35%	11,93%	13,71%	15,74%	8,93%	8,64%
UC27	8,03%	6,73%	7,12%	6,54%	7,51%	135,34%	7,59%	58,64%	6,14%	6,28%	7,64%	6,98%	4,67%	4,71%
UC28	4,55%	3,07%	3,30%	3,97%	4,33%	36,01%	3,69%	14,28%	3,42%	3,49%	3,98%	3,66%	3,76%	4,05%
UC29	9,75%	7,22%	7,42%	9,00%	8,21%	7,55%	8,35%	7,03%	7,07%	8,07%	7,95%	8,18%	11,00%	53,63%
UC30	11,31%	11,77%	11,57%	10,82%	8,84%	31,71%	8,65%	14,00%	10,12%	9,44%	11,05%	12,81%	8,61%	8,77%
ARIMA(0,1,1) Individual	18,71%	39,31%	19,46%	52,15%	18,43%	31,29%	21,01%	43,00%	18,15%	41,52%	25,45%	372,08%	20,34%	35,64%
ARIMA(0,1,1) Agrupamento	18,33%	25,54%	21,73%	33,28%	23,28%	61,36%	22,82%	28,72%	18,12%	27,85%	20,64%	378,38%	13,70%	26,94%
ARIMA(1,1,3) Individual	8,45%	16,03%	7,72%	20,92%	7,91%	18,76%	7,65%	16,52%	8,51%	15,22%	7,57%	47,21%	7,30%	14,11%
ARIMA(1,1,3) Agrupamento	9,60%	12,21%	7,26%	15,05%	11,12%	8,91%	7,87%	13,43%	9,39%	13,00%	16,33%	158,02%	7,47%	12,00%
ARIMA(1,1,1) Individual	14,33%	21,43%	19,09%	28,89%	13,44%	21,51%	15,25%	24,86%	14,23%	23,24%	15,21%	180,13%	7,60%	21,58%
ARIMA(1,1,1) Agrupamento	8,50%	9,14%	7,84%	10,95%	9,21%	8,11%	7,19%	9,55%	8,24%	9,51%	8,19%	153,64%	6,14%	8,84%
ARIMA(1,1,1) Individual	8,68%	11,19%	9,14%	14,29%	10,25%	8,90%	8,65%	12,86%	8,77%	12,28%	11,09%	146,15%	7,63%	11,16%
ARIMA(1,1,1) Agrupamento	19,68%	20,42%	19,66%	25,74%	21,20%	26,31%	20,43%	23,51%	20,10%	21,75%	24,45%	30,05%	19,33%	20,65%
ARIMA(1,1,1) Individual	8,05%	10,08%	6,14%	12,19%	7,21%	7,17%	7,55%	10,67%	7,20%	10,61%	8,58%	155,44%	7,86%	9,79%
ARIMA(1,1,1) Agrupamento	7,44%	7,83%	7,10%	9,16%	8,55%	7,73%	7,68%	7,97%	8,55%	8,16%	14,58%	121,15%	6,19%	7,69%
ARIMA(1,1,1) Individual	8,19%	8,00%	8,07%	9,49%	9,54%	15,51%	7,99%	8,41%	7,82%	8,30%	7,98%	27,38%	6,30%	7,56%
ARIMA(1,1,1) Agrupamento	6,75%	6,55%	9,97%	7,56%	6,40%	6,63%	6,28%	6,74%	6,20%	6,91%	7,98%	96,81%	5,83%	6,45%
ARIMA(1,1,1) Individual	6,92%	6,92%	7,28%	8,05%	8,87%	8,54%	6,67%	7,27%	6,46%	7,25%	7,54%	219,54%	5,55%	6,71%
ARIMA(1,1,1) Agrupamento	8,56%	9,15%	8,56%	11,94%	9,12%	15,03%	8,53%	10,17%	8,71%	9,96%	8,83%	136,33%	8,13%	9,19%
ARIMA(1,1,1) Individual	7,78%	9,35%	7,90%	11,55%	10,96%	8,71%	7,81%	8,98%	7,81%	9,24%	18,02%	95,68%	7,59%	8,50%
ARIMA(1,1,1) Agrupamento	6,68%	5,72%	9,59%	8,81%	7,77%	6,88%	6,41%	6,41%	5,79%	5,79%	7,40%	96,88%	4,25%	5,80%
ARIMA(1,1,1) Individual	7,72%	8,93%	7,88%	11,02%	7,49%	7,88%	6,68%	9,43%	6,74%	9,56%	14,44%	155,53%	9,34%	8,54%
ARIMA(1,1,1) Agrupamento	5,07%	5,82%	5,77%	7,01%	6,07%	5,27%	6,10%	6,08%	6,08%	6,08%	4,87%	103,97%	4,26%	5,62%
ARIMA(1,1,1) Individual	5,26%	5,45%	5,16%	6,58%	6,81%	5,66%	5,29%	5,64%	5,91%	5,91%	4,34%	77,25%	4,24%	5,48%
ARIMA(1,1,1) Agrupamento	9,38%	9,71%	8,65%	11,46%	12,64%	9,57%	10,05%	9,57%	9,86%	9,86%	8,95%	20,55%	6,57%	8,98%
ARIMA(1,1,1) Individual	22,65%	27,09%	23,41%	35,38%	19,08%	19,88%	24,22%	33,68%	21,50%	30,62%	24,38%	456,41%	19,80%	30,60%
ARIMA(1,1,1) Agrupamento	16,55%	18,91%	17,07%	23,80%	34,55%	59,05%	17,29%	20,07%	19,32%	17,00%	16,90%	525,25%	15,81%	17,99%
ARIMA(1,1,1) Individual	9,92%	10,61%	18,88%	12,05%	15,84%	10,23%	10,65%	11,56%	10,78%	10,78%	14,76%	441,01%	9,73%	10,44%
ARIMA(1,1,1) Agrupamento	16,99%	13,15%	13,93%	14,74%	22,17%	19,93%	16,13%	15,27%	16,83%	13,35%	14,17%	11,70%	17,11%	13,93%
ARIMA(1,1,1) Individual	13,42%	16,02%	19,74%	19,91%	15,87%	13,91%	13,95%	16,93%	13,46%	13,85%	19,96%	556,60%	15,35%	15,04%
ARIMA(1,1,1) Agrupamento	12,34%	11,89%	11,28%	14,59%	16,78%	15,18%	13,53%	13,91%	12,34%	12,30%	12,64%	349,28%	12,40%	12,74%
ARIMA(1,1,1) Individual	6,21%	6,84%	6,36%	6,93%	8,02%	8,50%	6,59%	7,14%	6,58%	7,17%	5,87%	224,60%	5,67%	7,41%
ARIMA(1,1,1) Agrupamento	3,75%	3,55%	3,48%	4,13%	5,55%	4,13%	3,74%	3,58%	3,60%	3,72%	3,72%	41,75%	2,63%	3,38%
ARIMA(1,1,1) Individual	7,48%	7,92%	13,55%	9,14%	12,60%	13,03%	7,61%	8,08%	7,92%	7,92%	15,51%	19,79%	6,70%	6,87%
ARIMA(1,1,1) Agrupamento	11,28%	9,42%	9,45%	10,90%	11,50%	10,41%	10,34%	10,16%	9,56%	10,46%	13,66%	9,75%	8,67%	10,30%

Tabela 15: Resumo dos Resultados Alcançados – Theil's U Calibração

	Média Móvel (n=2)		Média Móvel (n=3)		Média Móvel (n=6)		AR(1)		AR(1)		AR(3)		SES		SES		Holt		Holt-Winters	
	Naive	Individual	Individual	Aggrupamento	Individual	Aggrupamento	Individual	Aggrupamento	Individual	Aggrupamento	Individual	Aggrupamento	Individual	Aggrupamento	Individual	Aggrupamento	Individual	Aggrupamento	Individual	Aggrupamento
UC01	1,0000	1,1686	1,3701	1,7663	0,9495	3,3630	0,8158	1,8707	1,5482	1,4168	1,0287	1,5501	0,7319	0,7305						
UC02	1,0000	1,2901	1,5131	1,8160	0,8588	0,9325	0,8103	1,4309	1,6980	1,6980	1,5217	1,0831	0,9225	0,9584						
UC03	1,0000	1,1380	1,3376	1,7940	0,9575	4,4908	0,9599	2,1805	1,0000	4,4908	1,1244	1,5217	0,9225	0,9584						
UC04	1,0000	0,9931	1,0738	1,2929	0,8927	7,5445	0,8869	3,4050	0,6883	1,0702	1,1577	1,3816	0,6668	0,6664						
UC05	1,0000	1,1588	1,3368	1,6567	0,9404	2,1866	0,9066	1,5489	1,2830	1,2860	1,2066	1,7539	0,6855	0,6854						
UC06	1,0000	0,8690	0,8704	0,9598	0,7794	13,6547	0,7896	6,0034	0,8069	0,8505	1,1441	1,2206	0,5559	17,9936						
UC07	1,0000	0,9304	1,0154	1,1866	0,9312	2,4021	0,8666	1,5466	0,9400	1,0407	1,0894	1,2566	0,7125	0,7193						
UC08	1,0000	1,0857	1,2083	1,4759	0,9076	2,4930	0,9714	1,5466	1,1852	1,1852	1,1655	1,5105	0,9736	0,9563						
UC09	1,0000	0,9594	0,9680	1,1305	0,8632	8,0975	0,8737	3,9538	0,9349	0,9636	1,0832	1,1973	0,7178	0,8268						
UC10	1,0000	0,8544	0,8241	0,8538	0,7435	14,6933	0,7524	6,4884	0,7119	0,7903	1,1185	1,1885	0,6503	0,8462						
UC11	1,0000	0,8837	0,8001	0,8132	0,7402	2,4384	0,7324	1,3024	0,8038	0,8036	0,8707	0,9133	0,7008	0,8066						
UC12	1,0000	0,8607	0,8341	0,8447	0,7307	16,6920	0,7403	7,2241	0,7434	0,7941	1,0522	1,0868	0,6720	0,6809						
UC13	1,0000	0,8703	0,8342	0,8465	0,7701	12,2584	0,7392	5,2544	0,8084	0,8032	1,0023	1,0153	0,6927	0,6933						
UC14	1,0000	1,0290	1,1268	1,3556	0,9656	8,0756	0,9805	3,6580	0,9896	1,2219	1,0020	1,1935	1,7700	1,8326						
UC15	1,0000	0,8947	0,9367	1,0887	0,8641	3,5761	0,8485	1,7890	0,9080	0,9382	1,0964	1,1976	0,8813	0,8883						
UC16	1,0000	0,9392	0,8869	0,8582	0,8775	5,3608	0,8076	2,3365	0,8396	0,8401	1,0443	1,0554	0,7219	0,7240						
UC17	1,0000	0,9198	0,9435	1,0677	0,8474	6,2311	0,8361	2,7780	0,9601	0,9682	0,9980	1,1085	0,6743	0,6687						
UC18	1,0000	0,8568	0,8658	0,9509	0,8960	8,6080	0,8633	3,7334	0,9760	0,9964	1,0614	1,2250	1,0592	1,1505						
UC19	1,0000	0,8567	0,8272	0,8554	0,8661	5,6273	0,7485	2,5046	0,8225	0,8359	1,0842	1,0892	1,0126	1,0186						
UC20	1,0000	0,9609	0,9105	0,9450	0,8004	0,7879	0,8147	0,8680	0,8965	0,9020	0,9679	1,0153	0,6193	0,6382						
UC21	1,0000	1,0335	1,0869	1,2928	0,9116	3,4030	0,9014	1,7598	0,9796	1,0716	1,1307	1,2362	0,8791	0,8448						
UC22	1,0000	0,9628	0,8870	0,9099	0,7826	1,1641	0,8501	0,9019	0,8733	0,8703	1,1210	1,2002	0,5341	0,5350						
UC23	1,0000	0,9339	0,9929	1,0459	0,8863	3,2910	0,8711	1,6818	0,9353	0,9409	1,0506	1,1251	0,8797	0,8796						
UC24	1,0000	0,9531	1,0320	1,1957	0,8930	0,8654	0,8314	0,9760	0,9964	1,0136	1,0614	1,2250	1,0592	1,1505						
UC25	1,0000	0,8664	0,9074	0,9593	0,8213	1,4846	0,7865	1,0396	0,8531	0,8534	0,8636	0,9583	0,8720	0,8696						
UC26	1,0000	0,8849	0,9348	1,0123	0,8520	2,1065	0,8129	1,2441	0,8981	0,9118	0,9427	1,0231	0,8526	0,8465						
UC27	1,0000	0,9756	0,9596	0,8855	0,6587	15,3103	0,6152	6,7676	0,7016	0,7251	1,1542	1,2665	0,7139	0,7129						
UC28	1,0000	0,8995	0,8996	0,9187	0,7411	0,7565	0,8298	2,5783	0,8973	1,0409	1,0006	0,9873	1,9959	1,9726						
UC29	1,0000	0,9197	0,8512	0,8811	0,7411	0,7565	0,8298	2,5783	0,8973	1,0409	1,0006	0,9873	1,9959	1,9726						
UC30	1,0000	1,0235	1,0513	1,1126	0,9037	2,6275	0,9018	1,4715	0,9775	1,0227	1,0610	1,1282	0,8449	0,8448						
ARIMA(0,1,1)	ARIMA(0,1,1)	ARIMA(0,1,1)	ARIMA(0,1,1)	ARIMA(0,1,1)	ARIMA(0,1,1)	ARIMA(0,1,1)	ARIMA(0,1,1)	ARIMA(0,1,1)	ARIMA(0,1,1)	ARIMA(0,1,1)	ARIMA(0,1,1)	ARIMA(0,1,1)	ARIMA(0,1,1)	ARIMA(0,1,1)	ARIMA(0,1,1)	ARIMA(0,1,1)	ARIMA(0,1,1)	ARIMA(0,1,1)	ARIMA(0,1,1)	ARIMA(0,1,1)
UC01	1,0006	1,4379	0,9983	1,7916	0,9653	1,1109	0,9656	1,6421	1,0183	1,5242	0,9726	4,0022	0,7068	1,2325						
UC02	0,9754	1,7938	0,9637	1,8593	1,6168	3,4008	0,9671	1,7640	0,9549	1,6582	0,8124	5,8124	0,8491	1,3720						
UC03	1,0012	1,5683	0,9677	1,8787	1,1146	1,4211	0,9959	1,6147	1,0047	1,5467	0,9862	1,4423	0,9346	1,3240						
UC04	0,9727	1,0787	0,9805	1,3555	0,9443	0,9692	0,9465	1,2467	0,9731	1,1782	0,8860	4,8397	0,8623	1,0625						
UC05	0,9992	1,2964	0,9331	1,6846	0,9915	1,2486	1,0120	1,5505	0,9761	1,4593	1,0136	3,0510	0,7987	1,2706						
UC06	0,7999	0,8994	0,8198	1,0127	0,9600	0,9737	0,8531	0,9440	0,8791	0,9543	0,6492	5,3754	0,7703	0,8819						
UC07	0,9394	1,0618	0,8877	1,2267	0,8925	1,0538	0,9198	1,1297	1,0382	1,1297	0,6734	5,2589	0,6817	0,9124						
UC08	1,0069	1,1950	1,0042	1,5058	0,9562	1,0032	1,0169	1,3903	1,0087	1,3056	0,9657	1,3365	0,9115	1,2213						
UC09	0,9360	0,9786	0,9584	1,1774	0,9744	0,9744	0,9011	1,0864	0,9746	1,0514	0,9166	5,1672	0,9129	0,9887						
UC10	0,7277	0,8324	0,7924	0,9637	0,9607	0,9704	0,8380	0,8504	0,8504	0,8578	0,4983	4,5580	0,7526	0,8312						
UC11	0,8040	0,8066	0,7910	0,8372	1,0312	1,5996	0,7867	0,7857	0,8196	0,8152	0,7581	1,1374	0,8437	0,7601						
UC12	0,9188	0,8541	0,7195	0,8937	0,9406	0,9288	0,8302	0,8612	0,8428	0,9047	0,6849	3,7223	0,8005	0,8543						
UC13	0,7699	0,8114	0,8478	0,8917	0,9599	1,0853	0,8313	0,8425	0,8372	0,8634	0,7075	6,7882	0,7248	0,8232						
UC14	0,9864	1,3082	0,9939	1,4397	0,9997	1,4538	0,9967	1,2604	0,9864	1,2873	0,9685	2,9441	0,9402	1,1442						
UC15	0,9163	0,9494	0,8809	1,1499	0,9441	0,9584	0,9168	1,0523	0,8960	0,9951	0,7938	3,1887	0,8939	0,9774						
UC16	0,8267	0,8110	0,7968	0,8145	0,9619	0,9671	0,8478	0,8499	0,8505	1,0205	1,0205	3,4891	0,8909	0,7694						
UC17	0,9188	0,9619	0,8737	0,9517	0,9731	1,0430	0,9027	1,0404	0,9196	1,0116	0,7311	5,9285	0,6446	0,8802						
UC18	0,8576	0,8870	0,8158	0,9597	0,9181	0,9469	0,8440	0,8576	0,9086	1,0166	0,9086	4,8677	0,7897	0,8936						
UC19	0,8126	0,8131	0,7922	0,8524	0,9058	0,9468	0,8125	0,8653	0,8320	0,8409	0,6306	3,5810	0,7668	0,8363						
UC20	0,8949	0,9002	0,8282	0,8523	1,0824	1,4665	0,9300	0,9300	0,9129	0,9129	0,8557	1,0640	0,6958	0,9091						
UC21	0,9799	1,0792	0,9735	1,5585	1,0557	1,1410	0,9655	1,2318	0,9829	1,1559	0,7842	10,0443	0,9584	1,1430						
UC22	0,8926	0,8680	0,8037	0,9142	1,4861	2,0202	0,9200	0,8952	0,8643	0,8768	0,8649	5,8618	0,7346	0,8711						
UC23	0,9385	0,9457	0,9127	1,0770	1,0925	1,2083	0,9301	1,0735	0,9463	1,0039	0,8668	8,6199	0,9341	0,9924						
UC24	0,9501	1,0171	0,8607	1,2610	0,9076	0,9478	0,9459	1,1580	0,9445	1,0809	0,8538	0,9464	0,9265	1,1777						
UC25	0,8580	0,8512	0,7318	0,8810	0,9995	1,0703	0,8458	0,9657	0,8639	0,8759	0,7394	8,7167	0,9005	0,9176						
UC26	0,8984	0,9232	0,8392	1,0380	0,9936	1,0776	0,8858	0,9993	0,9103	0,9490	0,7741	6,8110	0,9036	0,9349						
UC27	0,7060	0,7759	0,6987	0,7790	1,0274	1,0602	0,7053	0,7455	0,7055	0,7705	0,5697	7,4987	0,5871	0,7743						
UC28	0,8728	1,0760	0,9073	1,0176	0,9094	1,0869	0,9150	0,9790	0,8761	0,9947	0,9103	2,2813	0,8792	0,8478						
UC29	0,8726	0,8978	0,6890	0,8695	1,3597	1,7515	0,8481	0,8542	0,7884	0,8468	0,6555	0,9497	0,6599	0,8244						
UC30	0,9732	1,0237	0,9190	1,1661	1,0597	1,1722	0,9610	1,1180	0,9425	1,0680	0,8706	0,9542	0,8231	0,9878						

