

UNIVERSIDADE FEDERAL DE MATO GROSSO DO SUL  
CENTRO DE CIÊNCIAS EXATAS E TECNOLOGIA  
DEPARTAMENTO DE ENGENHARIA ELÉTRICA  
PROGRAMA DE PÓS-GRADUAÇÃO  
MESTRADO EM ENGENHARIA ELÉTRICA

**HÉBER HENRIQUE SELVO DO NASCIMENTO**

**PLANEJAMENTO DE MERCADO DE ENERGIA  
ELÉTRICA NO NOVO MODELO DO SETOR  
ELÉTRICO BRASILEIRO PELA APLICAÇÃO DE  
ANÁLISE DE COMPONENTE PRINCIPAL COMO  
MÉTODO DE COMBINAÇÃO DE PREVISÕES**

Campo Grande – MS  
Agosto-2013

UNIVERSIDADE FEDERAL DE MATO GROSSO DO SUL  
CENTRO DE CIÊNCIAS EXATAS E TECNOLOGIA  
DEPARTAMENTO DE ENGENHARIA ELÉTRICA  
PROGRAMA DE PÓS-GRADUAÇÃO  
MESTRADO EM ENGENHARIA ELÉTRICA

**HÉBER HENRIQUE SELVO DO NASCIMENTO**

**PLANEJAMENTO DE MERCADO DE ENERGIA  
ELÉTRICA NO NOVO MODELO DO SETOR  
ELÉTRICO BRASILEIRO PELA APLICAÇÃO DE  
ANÁLISE DE COMPONENTE PRINCIPAL COMO  
MÉTODO DE COMBINAÇÃO DE PREVISÕES**

Dissertação apresentada para  
obtenção do título de Mestre ao  
Programa de Pós-Graduação em  
Engenharia Elétrica, da Universidade  
Federal de Mato Grosso do Sul, sob  
a orientação do Prof. Dr. Jéferson  
Menguim Ortega.

Área de Concentração: Planejamento  
de Sistemas Elétricos

Campo Grande – MS

Agosto-2013

**PLANEJAMENTO DE MERCADO DE ENERGIA  
ELÉTRICA NO NOVO MODELO DO SETOR  
ELÉTRICO BRASILEIRO PELA APLICAÇÃO DE  
ANÁLISE DE COMPONENTE PRINCIPAL COMO  
MÉTODO DE COMBINAÇÃO DE PREVISÕES**

Héber Henrique Selvo do Nascimento

Esta Dissertação foi julgada adequada para obtenção do Título de Mestre em Engenharia Elétrica, Área de Concentração em Sistemas Elétricos de Potência, e aprovada em sua forma final pelo Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Campo Grande-MS.

-----  
Jéferson Meneguín Ortega, Doutor  
Orientador

-----  
Edson Antonio Batista, Doutor  
Coordenador do Programa de Pós-Graduação em Engenharia Elétrica

Banca Examinadora:

-----  
Jéferson Meneguín Ortega, Doutor  
Presidente

-----  
Jerson Kelman, Ph.D.

-----  
Leandro Sauer, Doutor

-----  
Paulo Irineu Koltermann, Doutor

*“Se queres prever o futuro, estuda o passado”*

Confúcio

*Para minha esposa Letícia e meu filho Eduardo.*

## **AGRADECIMENTOS**

Ao único Deus criador, pelo dom da vida, e pela saúde para poder desenvolver este trabalho.

A minha família, minha amada Letícia e o pequeno Eduardo, pelo apoio, incentivo e compreensão pela minha ausência nos períodos de estudo dedicados a esta dissertação.

Ao meu querido irmão e amigo Thiago Luiz, companheiro de profissão, pelas inúmeras palavras de apoio, companheirismo e inspiração.

Ao meu orientador, Prof. Jeferson Ortega, por acreditar neste tema, tão pouco explorado, pela dedicação, amizade e orientação.

A banca examinadora, em especial ao Prof. Leandro Sauer, que muito contribuiu com a versão final deste trabalho.

A ENERSUL, por permitir utilizar as informações e sistemas que possibilitaram o desenvolvimento deste trabalho, e por me liberar para a apresentação deste tema nos congressos do setor.

Aos inúmeros amigos que fiz trabalhando na área de mercado da Enersul, Michel Itkes, Donato Filho, Paulo César Soares, Ivana Capanema, Regina Sasai, Mirian Gomes, Pedro Jara, Michellini Storck, e outros que, de alguma forma me ensinaram e/ou contribuíram para este trabalho.

Ao meu amigo e gerente Ricard Alves, pelo *coaching* profissional e pelas inspiradoras discussões filosóficas que muito auxiliaram neste trabalho, em especial no que tange a evolução do SEB, e também por sua compreensão nos períodos que tive que me ausentar de minhas funções no trabalho.

Ao Prof. Jerson Kelman, que através de sua larga vivência no setor me auxiliou com contribuições substanciais, mesmo nas poucas e breves conversas que tivemos já na etapa final deste trabalho.

À Universidade Federal de Mato Grosso do Sul, pelo ensino gratuito e de qualidade.

Resumo da Dissertação apresentada à UFMS como parte dos requisitos necessários para a obtenção do grau de Mestre em Engenharia Elétrica

**PLANEJAMENTO DE MERCADO DE ENERGIA ELÉTRICA NO NOVO MODELO DO SETOR ELÉTRICO BRASILEIRO PELA APLICAÇÃO DE ANÁLISE DE COMPONENTE PRINCIPAL COMO MÉTODO DE COMBINAÇÃO DE PREVISÕES**

**Héber Henrique Selvo do Nascimento**

Agosto/2013

Orientador: Jéferson Meneguín Ortega

Área de Concentração: Sistemas Elétricos de Potência

Palavras-chave: Consumo de energia elétrica, previsão, combinação de previsões, análise de componente principal, setor elétrico brasileiro.

Número de Páginas: 100

O presente trabalho descreve a aplicação da técnica de Análise de Componente Principal como uma técnica alternativa de Combinação de Previsões no planejamento de mercado de uma distribuidora de energia elétrica. O método de Combinação de Previsões é proposto como solução para o problema de decisão enfrentado pelos gestores na escolha entre os cenários propostos pelos analistas por ocasião da elaboração do plano decenal da distribuidora de energia elétrica Enersul S. A.

As classes residencial, comercial e industrial foram eleitas para realização dos testes por, efetivamente, comporem juntas a maior parcela do mercado de energia da empresa (74%) e, portanto,

apresentarem maior desafio de ajuste. A opção pela utilização do método proposto mostra-se mais vantajosa na escolha entre as projeções para a composição do cenário que irá nortear a contratação de energia, pois além de obter melhor performance em termos de avaliação do erro de projeção, garante, antecipadamente, um cenário que apresente desvios aceitáveis por congregar características de todos os demais métodos utilizados na combinação.

Abstract of Dissertation presented to UFMS as a partial fulfillment of the requirements for the degree of Master in Electrical Engineering

**ELECTRICAL ENERGY SUPPLY PLANNING IN THE  
NEW BRAZILIAN ELECTRIC SECTOR BY  
APPLICATION OF PRINCIPAL COMPONENT  
ANALYSIS AS A FORECAST COMBINATION  
METHOD**

**Héber Henrique Selvo do Nascimento**

August/2013

Advisor: Jéferson Meneguim Ortega

Area of Concentration: Electric Power Systems

Keywords: Electrical energy consumption, forecast, forecast combination, principal component analysis, Brazilian electricity sector.

Number of pages: 100

This work describes the application of Principal Component Analysis as an alternative technique of Forecast Combination in the market planning of a power distribution company. The Forecast Combination method is proposed as a solution to the decision problem faced by the business managers in choosing among several forecasting scenarios proposed by analysts in the preparation of the ten-year plan of Enersul Inc.

The residential, commercial and industrial consumption classes were chosen to be studied because they compose, together, 74% of Enersul market share, and so, they mean the principal adjustment challenge.



The option made by the application of the present technique shows to be the most useful option, among all the predictions, to hammer out the baseline that will be applied for the power purchase agreements. Besides, it has the better performance in error evaluation, the technique previously ensures a scenario able to perform acceptable errors because it gathers the features of all the other predictions made.

## SUMÁRIO

<b>1</b>	<b>CAPÍTULO – INTRODUÇÃO.....</b>	<b>01</b>
1.1	Generalidades.....	01
1.2	Motivação.....	02
1.3	Objetivos da Tese.....	03
1.3.1	Objetivos Secundários.....	03
1.4	Organização do Trabalho.....	03
1.5	Revisão Bibliográfica.....	05
<b>2</b>	<b>CAPÍTULO – CONTEXTUALIZAÇÃO.....</b>	<b>09</b>
2.1	Histórico do SEB.....	09
2.2	Modelo Intermediário.....	10
2.2.1	A Lei Elizeu Rezende e a Lei Geral das Concessões.....	11
2.2.2	As Primeiras Privatizações.....	12
2.2.3	O Produtor Independente de Energia.....	12
2.3	O Projeto RE-SEB.....	13
2.4	O Racionamento de Energia Elétrica.....	16
2.4.1	Diagnóstico do Racionamento.....	17
2.5	O Modelo Vigente.....	18
2.5.1	O Preço de Liquidação das Diferenças e o Valor Anual de Referência.....	21
2.5.2	Sobre e Subcontratação.....	22
2.5.3	A Necessidade de Assertividade.....	23
2.6	A Importância do Planejamento.....	25
2.6.1	Planejamento Indicativo e Planejamento Determinativo....	26
2.7	Impacto Financeiro da Compra de Energia.....	27
<b>3</b>	<b>CAPÍTULO – MÉTODOS DE PREVISÃO DE MERCADO.....</b>	<b>28</b>
3.1	Séries Temporais e Estacionariedade.....	28
3.2	Métodos Utilizados Pela Distribuidora.....	29
3.2.1	Decomposição de Séries Temporais.....	30
3.2.2	Análise Funcional e Espaços de Hilbert.....	33
3.2.3	Suavização Exponencial de Holt-Winters.....	35
3.2.3.1	Holt Winters Multiplicativo.....	36
3.2.3.2	Holt Winters Aditivo.....	38

3.2.3.3	Inicialização dos Fatores de Suavização.....	38
3.2.3.4	Software de Aplicação.....	39
3.2.4	Modelos Box-Jenkins (ou ARIMA).....	39
3.2.5	Predição de Consumo por Meio de Regressão – PREDICT	42
<b>4</b>	<b>CAPÍTULO – COMBINAÇÃO DE PREVISÕES E ANÁLISE DE</b>	
	<b>COMPONENTE PRINCIPAL.....</b>	<b>45</b>
4.1	A Escolha por Um Cenário.....	45
4.2	Combinação de Previsões (Forecast Combination).....	45
4.3	Análise de Componente Principal.....	46
4.3.1	PCA – Aplicação.....	47
4.3.1.1	Abordagem Algébrica.....	48
4.3.1.2	Abordagem Geométrica.....	49
4.3.2	Decomposição em Valor Singular.....	50
4.3.3	Padronização dos Dados.....	51
4.3.4	Algoritmo de Aplicação.....	52
4.3.5	Função de Aplicação.....	53
<b>5</b>	<b>CAPÍTULO – O MERCADO DA ENERSUL.....</b>	<b>56</b>
5.1	Consistência de Dados e Acompanhamento.....	56
5.2	Composição dos Dados.....	58
5.3	Período de Análise.....	59
5.4	Estrutura de Mercado.....	60
5.4.1	Classe Residencial.....	61
5.4.2	Classe Comercial.....	62
5.4.3	Classe Industrial.....	63
<b>6</b>	<b>CAPÍTULO – DESENVOLVIMENTO.....</b>	<b>65</b>
6.1	Classes de Serviço Estudadas.....	65
6.2	Cenários de Projeção.....	65
6.2.1	Classe Residencial.....	66
6.2.2	Classe Comercial.....	70
6.2.3	Classe Industrial.....	74
6.3	Avaliação de Desempenho.....	76
6.3.1	Período Utilizado Para Avaliação.....	78
6.3.2	Classe Residencial.....	78
6.3.3	Classe Comercial.....	82

6.3.4	Classe Industrial.....	86
6.3.5	Desempenho Global.....	88
6.3.5.1	Representação Gráfica.....	88
6.3.5.2	Composição da Carga para Planejamento.....	89
6.3.5.3	Resultados.....	90
<b>7</b>	<b>CAPÍTULO – CONCLUSÃO.....</b>	<b>92</b>
7.1	Considerações Finais.....	92
7.2	Recomendações para Trabalhos Futuros.....	94
	<b>ANEXO I .....</b>	<b>96</b>
	<b>REFERÊNCIAS BIBLIOGRÁFICAS.....</b>	<b>97</b>

## LISTA DE FIGURAS

<b>Figura 2.1</b>	Síntese do modelo de reestruturação setorial.....	14
<b>Figura 2.2</b>	Capacidade e Consumo no SIN.....	16
<b>Figura 2.3</b>	Ambientes de contratação de energia.....	20
<b>Figura 3.1</b>	Decomposição de Séries Temporais.....	31
<b>Figura 3.2</b>	Modelo de Decomposição Espaços de Hilbert.....	34
<b>Figura 3.3</b>	Representação Gráfica das aproximações.....	35
<b>Figura 3.4</b>	Autocorelação e correlação parcial da série.....	43
<b>Figura 4.1</b>	Aplicação de PCA no MATLAB.....	51
<b>Figura 4.2</b>	Diagrama de blocos da técnica de $FC_{PCA}$ .....	53
<b>Figura 5.1</b>	Etapas do processo de acompanhamento e previsão de mercado.....	56
<b>Figura 5.2</b>	Evolução de mercado da Classe de Serviço Residencial de 2003 a 2011.....	56
<b>Figura 5.3</b>	Participação por Classe de Serviço no Mercado de Vendas da Enersul em 2011.....	58
<b>Figura 5.4</b>	Evolução de mercado da Classe de Serviço Residencial de 2003 a 2011.....	59
<b>Figura 5.5</b>	Evolução de mercado das Classes de Serviço considerando 1996 = 100.....	60
<b>Figura 5.6</b>	Evolução da classe industrial no período de 1996 a 2011... ..	62
<b>Figura 6.1</b>	Consumo anual da classe residencial e os 32 cenários previstos .....	65
<b>Figura 6.2</b>	Consumo anual da classe residencial, cenários previstos e resultado da aplicação da $FC_{PCA}$ .....	68
<b>Figura 6.3</b>	Consumo anual da classe comercial e os 32 cenários previstos.....	69
<b>Figura 6.4</b>	Consumo anual da classe comercial, cenários previstos e resultado da aplicação da $FC_{PCA}$ .....	71
<b>Figura 6.5</b>	Consumo anual da classe Industrial, cenários previstos e resultado da aplicação da $FC_{PCA}$ .....	72
<b>Figura 6.6</b>	Consumo realizado mensal, modelos de predição e $FC_{PCA}$ ...	76
<b>Figura 6.7</b>	Consumo realizado mensal da classe comercial e modelos de predição, inclusive $FC_{PCA}$ .....	80
<b>Figura 6.8</b>	Consumo realizado mensal da classe Industrial e modelos de predição, inclusive $FC_{PCA}$ .....	83
<b>Figura 6.9</b>	União das classes estudadas para os cenários, originalmente, previstos, $FC_{PCA}$ e realizados.....	85
<b>Figura 6.10</b>	Representação da composição da Carga de Planejamento... ..	87

## LISTA DE TABELAS

<b>Tabela 2.1</b>	Receita requerida da Enersul no RT 2011.....	27
<b>Tabela 6.1</b>	Softwares/modelos utilizados na elaboração dos cenários...	64
<b>Tabela 6.2</b>	Autovalores e % da variância explicada do conjunto de cenários.....	66
<b>Tabela 6.3</b>	Autovalores e % da variância explicada do conjunto de cenários para a classe comercial.....	70
<b>Tabela 6.4</b>	Autovalores e % da variância explicada do conjunto de cenários para a classe industrial.....	73
<b>Tabela 6.5</b>	Rank por pontuação dos cenários da classe residencial.....	78
<b>Tabela 6.6</b>	Rank por pontuação dos cenários para a classe comercial...	80
<b>Tabela 6.7</b>	Rank por pontuação dos cenários para a classe industrial...	84
<b>Tabela 6.8</b>	Índices de erro e ganho obtido pela aplicação de $FC_{PCA}$ .....	88
<b>Tabela 7.1</b>	Índices de erro para um caso hipotético de escolha dos cenários pelo <i>board</i> .....	90

## SIGLAS

<b>ACF</b>	Função de Autocorrelação
<b>ACL</b>	Ambiente de Contratação Livre
<b>ACR</b>	Ambiente de Contratação Regulada
<b>ANEEL</b>	Agência Nacional de Energia Elétrica
<b>AR</b>	Auto Regressivo
<b>ARIMA</b>	Auto Regressivo Integrado de Médias Móveis
<b>CCEE</b>	Câmara de Comercialização de Energia Elétrica
<b>CHESF</b>	Companhia Hidrelétrica do São Francisco
<b>CMSE</b>	Comitê de Monitoramento do Setor Elétrico
<b>CNI</b>	Confederação Nacional da Indústria
<b>CO</b>	Centro Oeste
<b>CRC</b>	Conta de Resultados a Compensar
<b>DST</b>	Decomposição de Séries Temporais
<b>EPAM</b>	Erro Percentual Absoluto Médio
<b>EPE</b>	Empresa de Planejamento Energético
<b>FC</b>	<i>Forecast Combination</i> – Combinação de Previsões
<b>HW</b>	Holt Winters
<b>IGP-M</b>	Índice Geral de Preços de Mercado
<b>IPCA</b>	Índice de Preços ao Consumidor Amplo
<b>IPI</b>	Imposto sobre Produto Industrializado
<b>MAE</b>	<i>Mean Absolute Error</i> – Erro Médio Absoluto
<b>MAPE</b>	<i>Mean Absolute Percentage Error</i> – Erro médio absoluto percentual
<b>MG</b>	Minas Gerais
<b>NE</b>	Nordeste
<b>NO</b>	Norte
<b>ONS</b>	Operador Nacional do Sistema Elétrico
<b>PACF</b>	Função de Autocorrelação Parcial
<b>PCA</b>	<i>Principal Component Analysis</i> – Análise de Componente Principal
<b>PIE</b>	Produtor Independente de Energia
<b>PLD</b>	Preço de Liquidação das Diferenças
<b>PND</b>	Plano Nacional de Desestatização
<b>PU</b>	Percentual Unitário
<b>RE-SEB</b>	Reestruturação do Setor Elétrico Brasileiro
<b>RMSE</b>	<i>Root Mean Squared Error</i> – Raiz quadrada do erro médio
<b>SEB</b>	Setor Elétrico Brasileiro
<b>SE</b>	Sudeste

<b>SVD</b>	<i>Singular Value Decomposition</i> – Decomposição em Valor Singular
<b>UBP</b>	Uso do Bem Público
<b>UHE</b>	Usina Hidrelétrica
<b>VEC</b>	Vetor Auto regressivo com Correção de erros
<b>VR</b>	Valor de Referência



## 1. CAPÍTULO - INTRODUÇÃO

### 1.1 Generalidades

Um dos ramos de atividade, dentro do setor elétrico brasileiro, é a prestação de serviço público de distribuição de energia elétrica. Essa atividade, em especial, caracteriza-se por sua estrutura de mercado do tipo monopólio natural.

O monopólio é dito natural por existir um volume de investimentos elevados e constantes e seus retornos crescentes produzem um custo médio inferior quando apenas uma empresa está atuando no mercado. Segundo Newbery (1994), as características típicas de um monopólio natural são:

- i. capital intensivo e economia de escala,
- ii. incapacidade de estocagem da demanda flutuante,
- iii. presença de rendas de localização,
- iv. serviço ou produto essencial para os consumidores,
- v. presença de conexão direta com os consumidores.

A estrutura de mercado e os aspectos regulatórios do Setor Elétrico Brasileiro (SEB) são recentes. Na maior parte da sua existência, o SEB operou, integralmente, como monopólio regulado. A característica de monopólio, adequada à distribuição de energia elétrica, era aplicada sobre toda a cadeia de serviços do setor, até meados de 1995, quando foi promulgada a Lei 9.074 (BRASIL, 1995), introduzindo a competição no ramo de geração e a figura do consumidor livre.

Em 2004, o Setor Elétrico Brasileiro (SEB) passou pela implantação do modelo atual por meio da lei 10.848 (BRASIL, 2004). Entre os principais objetivos do novo modelo, está a garantia de segurança no abastecimento e, por consequência, a garantia de expansão da oferta de energia elétrica. Nesse sentido, o governo instituiu, por meio do decreto 5.163/2004, a contratação obrigatória antecipada e integral da demanda projetada dos distribuidores por meio de regras de contratação que penalizam, severamente, os

desvios entre a carteira de compra nos leilões e o mercado de energia realizado.

A compra de energia para atendimento ao mercado consumidor compõe a maior parcela das despesas de uma concessionária de distribuição, cerca de 40% da receita autorizada da concessionária, portanto, a assertividade no planejamento de compra implica, também, considerável impacto sobre o fluxo de caixa da empresa. Logo, torna-se de suma importância ter boa assertividade na predição do mercado de consumo de energia da distribuidora.

## 1.2 Motivação

Essa necessidade de assertividade tem promovido a busca por novos e diferentes modelos de predição de séries temporais, a fim de diversificar a descrição das diversas classes de consumo e aumentar a confiabilidade entre os cenários. A aplicação de diferentes modelos de previsão gera uma quantidade razoável de cenários, que refletem, por exemplo, as diferenças de aproximação entre os modelos, as possíveis composições de variáveis exógenas, o julgamento subjetivo do analista, etc. Essa diversidade de informações é interessante, tendo em vista que diversas possibilidades de comportamento estão descritas neste *set* de informações. Porém, para o gestor do negócio cria-se um problema de decisão: como extrair a melhor informação das previsões? Qual previsão deve ser escolhida como “cenário-base”?

Um cenário-base, sem aderência à realidade, provoca a aplicação de penalidades financeiras severas, além de impactar o plano de obras da distribuidora, com a construção de subestações desnecessárias ou subdimensionadas, além de desvirtuar a programação de fluxo de caixa, pagamentos e tomadas de empréstimos.

### 1.3 Objetivos da Tese

O objetivo deste trabalho é propor uma ferramenta que afiance ao gestor responsável pelo planejamento de mercado, um cenário que congregue as características mais importantes do conjunto de projeções elaboradas, garantindo, assim, que o cenário proposto apresente boa performance e aderência frente ao mercado realizado.

#### 1.3.1 Objetivos Secundários

- Construir um banco de dados baseado nos diversos cenários de projeção utilizados pela empresa.
- Desenvolver uma metodologia que produza um novo cenário de predição baseado em um conjunto de cenários utilizados, inicialmente, pela empresa.
- Identificar técnicas para avaliação do erro de predição.
- Descrever, resumidamente, a evolução funcional e organizacional do Setor Elétrico Brasileiro – SEB.

### 1.4 Organização do Trabalho

O Capítulo dois apresenta uma contextualização do modelo estrutural vigente no Setor Elétrico Brasileiro, iniciando pelo seu histórico e identificando as mudanças ocorridas durante a sua evolução. Também é demonstrado o modelo de comercialização vigente bem como o porquê da necessidade de assertividade no planejamento energético e o impacto da contratação de energia nos custos da concessionária.

O Capítulo três descreve o processo de acompanhamento do mercado consumidor da distribuidora bem como também os métodos/técnicas de projeção, atualmente, aplicados para elaboração dos cenários de previsão do mercado de energia elétrica para o plano decenal.

O Capítulo quatro traz a fundamentação teórica para aplicação do método de Combinação de Previsões (FC) e a utilização de Análise de Componente Principal (PCA) como técnica de combinação.

O Capítulo cinco descreve o processo de acompanhamento e análise de mercado e contextualiza o mercado de consumo de energia elétrica da Empresa Energética de Mato Grosso Do Sul – ENERSUL como base para realização das projeções.

O Capítulo seis descreve, efetivamente, a aplicação da técnica de PCA para responder a necessidade da “escolha” de um melhor cenário.

O Capítulo sete apresenta as principais conclusões e considerações, juntamente com as propostas para encaminhamento de trabalhos futuros.

A título de esclarecimento, quando neste trabalho for aplicado o termo “dados dentro da amostra”, significa que o resultado do cenário projetado é comparado com a informação que deu origem a este. Quanto ao termo “dados fora da amostra”, é utilizado no caso de comparação do cenário resultante com a informação que este estava, efetivamente, prevendo e ainda era desconhecida, isto é, não estava contida na amostra utilizada para a “formação” do cenário resultante.

Quando da utilização de modelos individuais, sem a aplicação de técnicas de combinação, usualmente, considera-se para classificar a “robustez” de uma previsão, a medição dos desvios “fora da amostra” de cada modelo. Para tal, de uma dada série mensal conhecida, é separado o último período da informação, geralmente, seis ou doze meses, que não é utilizada na formação dos modelos e servirá apenas, ao fim da realização das projeções, para orientar o cenário mais “robusto”. Entretanto, essa orientação não é garantia da escolha do cenário que contém a melhor informação, ao longo prazo, persistindo a incerteza na decisão pelo melhor cenário.

## 1.5 Revisão Bibliográfica

No escopo da redução da incerteza, grande parte dos artigos publicados relaciona a série histórica de mercado com variáveis macroeconômicas, conforme demonstraremos a seguir.

A aplicação da combinação de previsões para resolução de problemas macroeconômicos é extensa. Talvez os estudos de Nelson (1972) e Cooper e Nelson (1975) tenham sido as primeiras aplicações de técnicas de combinação para responder questões relativas a séries temporais econométricas. Esses trabalhos tinham o foco de desenvolvimento de métodos para estudar a eficiência de uma previsão. Esses métodos utilizavam, essencialmente, uma previsão composta (uma previsão resultante de uma combinação de previsões) como *benchmark*. Por meio dessa técnica, eles demonstraram que certas previsões econométricas eram ineficientes por intermédio do senso de que combiná-las com um modelo ARIMA reduzia, significativamente, o erro de previsão. Em Nelson (1972), o autor mede a contribuição incremental de uma previsão por meio da significância da *estatística t* na combinação de previsões com base em regressão linear. Essencialmente, Nelson mede o quanto certas previsões econômicas adicionam informação quando combinadas com um modelo ARIMA. Já, em Cooper e Nelson (1975), desenvolve-se a idéia de um “preditor composto” que observa o valor incremental das previsões por meio da análise da *estatística t* da combinação por regressão.

Em trabalho apresentado no III Congresso Brasileiro de Planejamento Energético, Caio e Bermann (1998) dispõem sobre as metodologias de previsão de mercado frente ao novo perfil de mercado. O artigo destaca o risco, em que incorrem os modelos econométricos, em correlacionar, mecanicamente, o mercado de energia com o desempenho econômico devido à característica dinâmica da economia mundial. Todavia, é destacada a sua aplicabilidade em horizontes de tempo compatíveis com sua base estatística visto que, via de regra, em um espaço de tempo, relativamente, pequeno não ocorrem transformações substanciais na estrutura econômica, social e tecnológica.

Anderson (1973) realiza a predição do consumo residencial de energia elétrica da Califórnia utilizando o período de 1947 a 1969 em função das variáveis rendas *per capita* e custo marginal da eletricidade. Anderson utiliza regressão linear, log-linear, exponencial e as combinações log-linear e exponencial como métodos de predição.

Clemen (1989) é citado por diversos autores e pode ser considerado um marco no tema combinação de previsões. Em seu trabalho, é realizada uma revisão e uma bibliografia anotada com mais de duzentos trabalhos realizados, em diversos campos de conhecimento, em que a combinação de previsões fora aplicada como engenharia, estatística, economia, meteorologia e psicologia. Seus estudos concluem que a assertividade é, virtualmente, sempre melhorada pela combinação de predições individuais. Além disso, é demonstrado que alguns métodos simples de combinação, como a média aritmética, frequentemente possuem um desempenho bom em relação a métodos mais complexos.

Armstrong (1989) dispõe sobre a aplicação de diversos métodos de combinação de previsão e avalia a sua aplicação para longo e curto prazo. Ele argumenta que a combinação de previsões é mais significativa em aplicações de curto prazo, pois o erro é mais significativo neste horizonte e a combinação deveria reduzir sensivelmente a incerteza. Porém, um ponto de vista alternativo, citado pelo próprio autor, sugere que a combinação de previsões é mais favorável em horizontes de longo prazo por reduzir a incerteza. O autor ainda sugere que a combinação de saídas de métodos diferentes deveria produzir resultados superiores à combinação de saídas diferentes de um mesmo método, porém essa suposição não pode ser demonstrada.

Em trabalho apresentado no XXV Encontro Nacional de Engenharia de Produção, Souza e Samohyl (2005) utilizam duas técnicas diferentes de combinação de previsões sobre oito cenários de predição do consumo industrial de energia elétrica do Estado de Santa Catarina. Os cenários são oriundos de modelos de regressão dinâmica, autorregressivo integrado de médias móveis (ARIMA) e suavização exponencial de HoltWinters. O desempenho individual e

das combinações dos modelos foi avaliado por meio do EPAM (erro percentual absoluto médio) e do cálculo do coeficiente U de Theil (coeficiente de desigualdade). As técnicas empregadas para a combinação de previsões foram combinação por regressão e combinação por média aritmética ponderada. Os autores concluem que, para os dados dentro da amostra, o melhor desempenho, em termos de EPAM e U de Theil, foi alcançado pela combinação realizada por meio da técnica de média aritmética ponderada. Porém, para os dados de consumo realizados, fora da amostra, o desempenho do modelo cai significativamente. Os resultados individuais do modelo de suavização exponencial de HoltWinters mostram-se mais robustos.

Martins (2011) utiliza dois métodos diferentes de combinação de previsões sobre séries de produção industrial. Em seu trabalho, é utilizado o método de mínima variância, que consiste em atribuir pesos diferenciados para cada cenário, de acordo com a variância do erro amostral da série, e também o de média aritmética. A conclusão da comparação desses dois métodos demonstra melhores resultados de *Mean Absolute Percentage Error* - MAPE, *Mean Squared Error* - MSE e *Mean Absolute Error* - MAE para o método de mínima variância.

Paiva (2012), buscando traduzir os atributos que indicam qualidade (do ponto de vista do consumidor) em processos de manufatura por soldagem e usinagem, sugere a aplicação uma função representativa que utiliza os autovalores resultantes da aplicação de PCA em um problema de otimização de múltiplas respostas correlacionadas. Sua proposta apresentou resultados satisfatórios em relação à abordagem tradicionalmente empregada pelo setor, que depende de uma escolha subjetiva das funções (atributos) individuais.

Souza et al. (2012) desenvolve uma técnica de FC pela utilização de PCA, similar a aplicada no presente trabalho, para combinar as projeções de consumo de energia elétrica da classe industrial para o estado do Rio Grande do Sul. Os resultados apresentados pela técnica se mostraram melhores que os modelos

individuais, entretanto, poucos modelos individuais foram avaliados e alguns apresentaram desempenho questionável (ARFIMA/AES-Sul).

Pelos bons resultados alcançados, pelos diversos autores que já lançaram mão da combinação de previsões por meio de métodos de análise de variância, pela já experimentada aplicação de PCA no campo de FC, entende-se como importante e necessário o estudo desta uma técnica de combinação de previsões para estudos de planejamento de mercado do SEB.



## 2. CAPÍTULO - CONTEXTUALIZAÇÃO

### 2.1 Histórico do SEB

A história da eletricidade, no Brasil, começa, em 1876, com uma visita do então imperador Dom Pedro II à exposição da Filadélfia, nos Estados Unidos, onde conheceu Thomas Edison. O imperador encomendou, então, um sistema de seis lâmpadas elétricas acionadas por dois dínamos, que substituíram quarenta e seis lampiões a gás na Estação Central do Brasil no Rio de Janeiro (PAIXÃO, 2000).

A primeira aplicação da hidroeletricidade, como serviço público, aconteceu, em 1889, com a instalação da Usina Marmelos, no rio Paraibuna, em Juiz de Fora (MG). Desde então, essa atividade foi caracterizada pelo estabelecimento de pequenas usinas hidrelétricas explorando aproveitamentos sempre próximos a centros urbanos.

Até o advento do código das águas e da constituição de 1934, a regulação do setor era de alçada dos municípios, que concediam as licenças para exploração dos serviços. Nos anos 40, havia uma grande concentração de mercado nas mãos de poucas empresas privadas multinacionais. Até o final dessa década, 98% do abastecimento de energia elétrica eram provenientes do setor privado, em especial Light e Amforp. (TOLMASQUIM, Et Al, 2002).

A falta de ampliação na capacidade instalada incentivou o governo federal a atuar mais, ativamente, no setor, em 1948, com a criação da Companhia Hidrelétrica do São Francisco - CHESF. Em 1961, foi criada a Eletrobrás, com intuito de atuar como *holding*, controlando, inicialmente, CHESF e FURNAS. Devido à latente defasagem entre oferta (geração) e demanda da época, os investimentos dos governos Federal e Estaduais passaram a ser mais robustos.

A intervenção governamental no setor, com a estatização, culminou com a compra, pela União, da Light e da Amforp em 1979. Inicialmente, esse modelo, então de 100% de capital nacional,

possibilitou grandes investimentos advindos de autofinanciamentos, recursos externos e empréstimos internos.

Entre 1973 e 1993, as tarifas eram iguais em todo território nacional, muito embora os custos regionais fossem diferentes. Esse modelo, que não induzia a uma gestão eficiente, apresentou problemas de alto endividamento, empresas deficitárias, além de contribuir para o esgotamento da capacidade de endividamento do Estado.

## 2.2 Modelo Intermediário

No debate econômico e político, no final da década de 1980, o papel do Estado era questionado. Tal discussão passou, também, para o âmbito dos serviços públicos e sua prestação. Desejava-se a menor intervenção possível do Estado, na atividade econômica, inclusive naquela ligada à prestação de serviços públicos. No caso do setor elétrico, a experiência de diversos países sugeria a necessidade de introduzir-se um regime de mercado competitivo, como forma de aumentar a eficiência das empresas de energia elétrica. Dessa forma, em sintonia com o pensamento dominante, entendeu-se necessário impor limites à atuação das estatais, por meio de privatizações, reduzindo, assim, seu poder de mercado e viabilizando um regime competitivo no setor. O processo de reestruturação do SEB foi, então, orientado para o aumento da participação privada, com três objetivos (TOLMASQUIM, 2011):

1. Equacionar o *déficit* fiscal por meio da venda de ativos;
2. Restaurar o fluxo de investimentos para um programa de investimentos;
3. Aumentar a eficiência das empresas de energia.

Com a instituição, em 1990, do Plano Nacional de Desestatização (PND) pela Lei 8.031 (BRASIL, 1990) foi dado início a reforma e preparadas as bases para a privatização das empresas de energia elétrica.

### 2.2.1 A Lei Elizeu Rezende e a Lei Geral das Concessões

O saneamento financeiro das empresas de energia elétrica teve seu início com a Lei 8.631 (BRASIL, 1993), também conhecida como “Lei Elizeu Rezende”, que promoveu um grande encontro de contas das dívidas entre União e estatais do setor por meio do encerramento da deficitária Conta de Resultados a Compensar (CRC) com recursos do Tesouro Nacional.

A mesma Lei introduziu a obrigatoriedade de celebração de contratos de suprimento entre geradores e distribuidores.

Outro dispositivo importante extinguiu a equalização tarifária, na qual a tarifa de energia era única no país, independentemente, das características da área de concessão e dos custos de produção. Também, foi extinto o regime de remuneração garantida, instituindo o regime de “serviço pelo custo” da própria concessionária.

No regime de “serviço pelo custo”, a receita advinda da tarifa deveria atender aos custos operacionais incorridos para a prestação do serviço, acrescidos da garantia de recuperação da depreciação do capital investido e de sua remuneração entre 10% e 12% ao ano (VIEIRA, 2005).

Entre outros dispositivos, a Lei 8.631 incorporou alterações nos mecanismos de comando e controle das empresas, voltados ao estabelecimento de uma filosofia empresarial com orientação comercial (PIRES, 2000).

No início de 1995, foram editadas a Lei Geral das Concessões, Lei 8.987 (BRASIL, 1995), definindo algumas regras gerais para a prestação de serviços públicos, tais como os direitos e obrigações dos concessionários e usuários, a instituição do “serviço pelo preço” (em substituição ao serviço pelo custo) para concessões e

permissões de serviço público, com reajustes e revisões tarifárias, a fim de preservar o equilíbrio econômico-financeiro das concessões.

Essa lei, também, regulamentava, para o setor elétrico, o dispositivo da Constituição Federal, de 1988, estabelecendo que “incumbe ao Poder Público, na forma da lei, diretamente ou sob regime de concessão ou permissão, sempre através de licitação, a prestação de serviços públicos” (BRASIL, 1988).

Embora as Leis 8.631 e 8.987 houvessem promovido alterações operacionais nas empresas, a crise institucional do setor não havia sido dirimida. Havia a necessidade de uma reestruturação em todo o arcabouço do SEB. A introdução de um modelo competitivo nas atividades de geração e comercialização, através da livre contratação, deveria, ainda, enfrentar a desverticalização das empresas que atuavam nas áreas de geração, transmissão e distribuição, mantendo reguladas as tarifas na distribuição e transmissão, devido a sua característica de monopólio natural.

### 2.2.2 As Primeiras Privatizações

Com a edição da Lei das Concessões (Lei 8.987), foi possível iniciar o processo de privatização das elétricas. A primeira privatização do setor foi a da Escelsa – Espírito Santo Centrais Elétricas S.A., com leilão realizado em 12 de junho de 1995. Em 1996, duas outras empresas foram privatizadas. A Light foi arrematada em 21 de maio e a Cerj – Companhia de Eletricidade do Rio de Janeiro, em 20 de novembro. Por meio do Decreto 1.503, de 25 de maio de 1995, as empresas do Grupo Eletrobrás entraram no Programa Nacional de Desestatização (PND).

### 2.2.3 O Produtor Independente de Energia

A Lei 9.074, de 7 de julho de 1995, que estabeleceu normas para a outorga e prorrogações das concessões e permissões de serviços públicos, criou a figura do Produtor Independente de

Energia (PIE), pessoa jurídica ou empresas reunidas em consórcio que recebam concessão ou autorização do poder concedente para produzir energia elétrica destinada ao comércio de toda ou parte de sua energia produzida, por sua conta e risco; o conceito da Rede Básica de Transmissão; o de Consumidor Livre, como sendo aquele que poderia escolher o seu fornecedor de energia elétrica, bem como assegurou o livre acesso aos sistemas de transmissão e distribuição, mediante ressarcimento do custo do transporte envolvido.

### 2.3 projeto RE-SEB

Em 1996, com apoio do Banco Mundial, o Governo Brasileiro, por meio da Secretaria Nacional de Energia, contratou a consultoria inglesa *Coopers & Lybrand* como auxílio técnico aos especialistas do Setor Elétrico Brasileiro na criação do projeto Reestruturação do Setor Elétrico Brasileiro (RE-SEB). Esse projeto definiu o arcabouço conceitual do novo modelo a ser implantado. A proposta de consultoria fez-se sobre um Termo de Referência que definia 34 “questões-chave” de forma que fossem atendidos os seguintes objetivos:

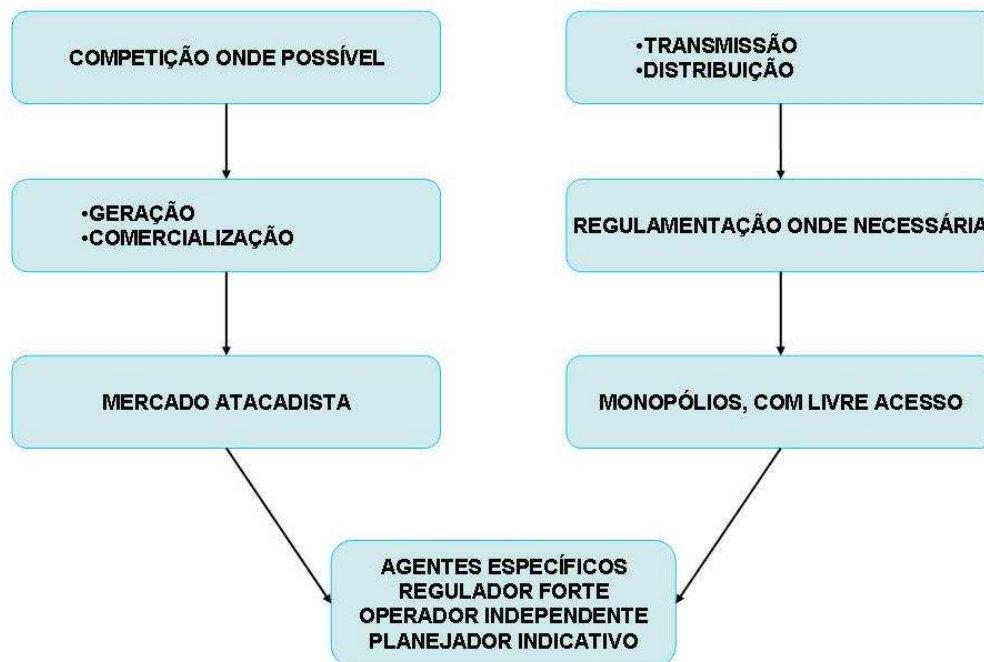
1. Assegurar a oferta de energia;
2. Estimular o investimento no setor;
3. Reduzir o risco para os investidores, garantindo a modicidade das tarifas;
4. Maximizar a competição no setor;
5. Garantir o livre acesso aos produtores independentes;
6. Incentivar a eficiência;
7. Fortalecer o órgão regulador;
8. Assegurar a expansão hidrelétrica;
9. Manter a otimização operacional;
10. Definir novas funções para a Eletrobrás;

11. Adequar a qualidade no fornecimento à necessidade do mercado e a modicidade tarifária.

O relatório consolidado do projeto, publicado, em dezembro de 1997, possuía cerca de duzentas recomendações. Resumidamente, foram indicadas as seguintes necessidades:

- a. Introdução de competição nos segmentos de geração e comercialização de Energia Elétrica;
- b. Criação de mecanismos de defesa da concorrência nos segmentos competitivos como desverticalização e livre acesso às redes com tarifas não discriminatórias;
- c. Desenvolvimento de mecanismos de incentivos nos segmentos com mercado cativos (distribuição e transmissão) que permaneceriam monopolizados.

A concepção desse modelo foi ilustrada por meio da Figura 2.1, divulgada pelos promotores desta reestruturação setorial. (VIEIRA, 2005)



Fonte: Palestra do Prof. Dorel soares Ramos no IEE/USP, 1988 por Vieira (2005).

Figura 2.1 – Síntese do modelo de reestruturação setorial

Para implementação da estrutura proposta pela *Coopers & Lybrand*, concluindo a estrutura para a privatização dos ativos de geração, foi sancionada a Lei 9.648 (BRASIL, 1998), que estabelecia o livre regime de negociação na compra e venda de energia entre concessionários, permissionários e autorizados. Na mesma lei, foi, também, criado o Mercado Atacadista de Energia Elétrica – MAE, instituído mediante Acordo de Mercado. O MAE, tal como criado, caracterizava-se como um mercado livre, cujas regras de participação eram previstas pelos próprios agentes no Acordo de Mercado, contrato multilateral homologado pela Agência Nacional de Energia Elétrica – ANEEL (TOLMASQUIM, 2011).

Em relação à operação do Sistema, a lei criou o Operador Nacional do Sistema Elétrico (ONS), pessoa jurídica de direito privado para executar as atividades de coordenação e controle da operação da geração e da transmissão de energia elétrica no âmbito do Sistema Interligado Nacional (SIN). Entre as suas competências estavam o planejamento e a programação da operação do sistema e o despacho centralizado com o objetivo de otimizar o uso dos recursos hídricos.

Para separar as atividades de geração e transmissão, a lei tratou de determinar que o ato de compra e venda de energia elétrica fosse contratado, separadamente, do acesso e uso dos sistemas de transmissão e distribuição, cabendo à ANEEL estabelecer as tarifas e as condições de contratação.

A Transmissão, responsável pelo transporte dos grandes blocos de energia, atividade com características de monopólio natural, passou a ser atividade, completamente, regulada. A distribuição, responsável pelo transporte de energia até o consumidor final, também, atividade considerada monopólio natural, atividade regulada. Entretanto, foi permitido às distribuidoras atuarem também como comercializadoras.

A comercialização de energia, atividade de compra e venda, passou a ser livre e com preço definido pelo mercado. Essa era desenvolvida por empresas compradoras e vendedoras, os geradores, distribuidores e comercializadores. Dessa forma, a contratação da compra e venda de energia passou a ser

independente da contratação do acesso e uso dos sistemas de transmissão e distribuição (NERY, 2012).

Também foi autorizada a reestruturação da Eletrobrás e das suas subsidiárias, com o objetivo de privatizá-las. A reestruturação da Eletrobrás começou com a cisão da Eletrosul, dando origem a Gerasul, titular de diversas usinas de geração (comprada posteriormente pela Tractebel-Suez), e a Eletrosul, que manteve o nome e deteve os ativos de transmissão da antiga Eletrosul.

Observa-se que essa primeira grande mudança institucional não chegou a ser implementada por completo, pois várias empresas, em especial na geração, continuaram nas mãos das estatais. Houve dificuldades e contestações quanto às primeiras contabilizações e liquidações no MAE. Também, os investimentos esperados para a expansão do sistema não se verificaram da forma desejada (NERY, 2012) dentro do planejamento indicativo.

## 2.4 O Racionamento de Energia Elétrica

A Figura 2.2 mostra a defasagem ocorrida, nos anos 1990, entre a evolução da capacidade instalada e o crescimento da demanda de energia elétrica no Sistema Interligado Nacional.

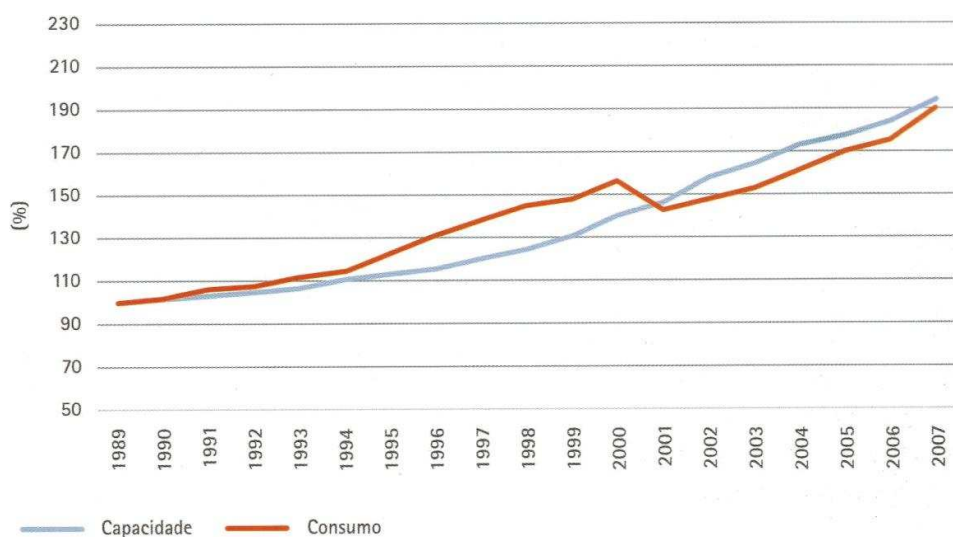


Figura 2.2 - Capacidade e Consumo no SIN (%) (TOLMASQUIM, 2011)



Em abril de 2001, o nível dos reservatórios encontrava-se em torno de 32% da capacidade de armazenamento e o risco de *déficit* superava 15%, dez pontos percentuais acima do nível de risco aceitável (5%).

Evidenciava-se, assim, a necessidade de adotarem-se medidas urgentes para evitar a crise de abastecimento. Para agravar a situação, a inadimplência no MAE era crescente. Verificou-se, ainda, que as garantias físicas estavam superestimadas, o que assegurava a cobertura contratual para as distribuidoras sem a contrapartida de uma nova contratação de energia, necessária para viabilizar a expansão do sistema (TOLMASQUIM, 2011).

Em 1º de junho de 2001, o governo federal decretou o racionamento de energia elétrica nas regiões Sudeste e Centro Oeste, Norte e Nordeste do Brasil. Como medidas de racionamento foram estabelecidas cotas de consumo, aumento tarifário, os bônus e os cortes programados.

Esse evento, que interferiu na vida das pessoas e causou danos à atividade econômica (FALCO, 2004), gerou diversos questionamentos quanto à forma de funcionamento do setor.

#### 2.4.1 Diagnóstico do Racionamento

Por meio de decreto presidencial, em 22 de maio de 2001, foi criada a Comissão de Análise do Sistema Hidrotérmico de Energia Elétrica, com o objetivo de avaliar a política de produção de energia e identificar as causas estruturais e conjunturais do desequilíbrio entre demanda e oferta no prazo de sessenta dias.

Segundo relatório da comissão, a vulnerabilidade do sistema elétrico deveria ter sido identificada, ainda em novembro de 1999, quando a probabilidade de *déficit* energético já poderia ser estimada em 14%. Estando o sistema desequilibrado, desde 1999, a hidrologia desfavorável dos anos seguintes teve apenas o efeito de precipitar a crise (KELMAN, 2001). A real causa do racionamento foi apontada como sendo a não materialização do aumento da oferta de energia, com o atraso da entrada em operação de obras de geração e

transmissão e a ausência de novos empreendimentos de geração. Foi verificado pela comissão que o aumento do consumo de energia correspondeu aos valores previstos e não teve qualquer influência na crise de suprimento.

O relatório, ainda indicou o superdimensionamento do montante de energia assegurada dos contratos iniciais, que substituíram os contratos entre geradores e distribuidores a partir de 1999. Esses contratos cobriam 100% das necessidades das distribuidoras, no período de 1999 a 2001, isto é, não havia incentivos econômicos para que as distribuidoras contratasse uma oferta adicional para compensar o desequilíbrio estrutural entre oferta e demanda. A falta de expansão da oferta física levou ao uso excessivo dos estoques de água nas hidrelétricas e ao racionamento (TOLMASQUIM, 2011).

As lições da crise e o diagnóstico de suas causas pavimentaram o caminho para a construção do modelo vigente, iniciado em 2004.

## 2.5 O Modelo Vigente

Em 2004, com a efetiva implantação do modelo vigente por meio da lei 10.848, cada ramo da cadeia de serviço, da geração até a distribuição, passa a pertencer a empresas distintas. Essa nova característica setorial, mais a figura do consumidor livre, introduzida pela lei 9.074/1995, introduziram uma significativa competição nos ramos de geração e comercialização de energia elétrica.

Nessa segunda grande mudança, pretendeu-se formar um modelo misto, com participação estatal e privada. Restaurou-se o papel de poder concedente ao Ministério de Minas e Energia – MME e a responsabilidade pelo planejamento da expansão do setor de energia elétrica foi retomada pelo Estado. Reforçaram-se as funções de regulação mediação e fiscalização da ANEEL, reformulou-se a governança do ONS, com ênfase na sua independência, criaram-se a Empresa de Pesquisa Energética (EPE), com a finalidade de prestar serviços na área de estudos e pesquisas destinadas a subsidiar o

planejamento do setor energético e o Comitê de Monitoramento do Sistema Elétrico (CMSE), com o objetivo de monitorar, permanentemente, as condições de oferta e do desempenho do sistema, instituiu-se a Câmara de Comercialização de Energia Elétrica (CCEE) como sucessora do MAE e com atribuições adicionais.

As atividades de distribuição passaram a ser, completamente, reguladas e foi vedado aos agentes de distribuição exercer atividades de geração, transmissão, venda de energia a consumidores livres ou qualquer outra estranha ao objeto de sua concessão. Entretanto, as bases regulatórias para a transmissão foram mantidas.

Outra importante alteração promovida, em 2004, foi a mudança no critério utilizado para concessão de novos empreendimentos de geração. Até então, o vencedor da licitação seria aquele que realizasse a proposta de maior valor pela outorga (Uso do Bem Público - UBP). De certa forma, o valor empregado para o pagamento do UBP era componente do preço de venda da sua energia. No modelo vigente, passou a vencer os leilões o investidor que oferecesse o menor preço para venda da energia produzida pelas futuras usinas, contribuindo, assim, para a modicidade tarifária.

É possível afirmar que o novo modelo diferencia-se dos anteriores por visar a três principais alvos do serviço de público de eletricidade, quais sejam: segurança no abastecimento, modicidade tarifária e universalização dos serviços de energia elétrica. Para tanto, quatro macro medidas foram tomadas: criação de dois ambientes de contratação e consequente modificação do modo de contratação de energia, por parte das distribuidoras, retomada no planejamento do setor, criação de programas efetivos de universalização e reorganização institucional.

Como os dois principais objetivos deste conjunto, modicidade tarifária e segurança de suprimento, são conflitantes, em sua essência. O modelo busca atingi-los por meio da segmentação do mercado de demanda e do mercado de oferta.

A fim de garantir a expansão da oferta, o governo instituiu a contratação obrigatória antecipada e integral da demanda projetada dos distribuidores e segmentou o mercado de demanda em dois ambientes: o Ambiente de Contratação Regulada (ACR) e o Ambiente de Contratação Livre (ACL), como ilustra a Figura 2.2 que representa a contratação de energia no ACR e as relações contratuais no ACL. A figura 2.3, publicada em (TOLMASQUIM, 2011) destaca, também, a contratação da Energia de Reserva.



Figura 2.3 – Ambientes de contratação de energia  
(TOLMASQUIM, 2011)

O ACR tem seu funcionamento em forma de *pool* de compra no qual os agentes compradores são os distribuidores e, por consequência, os consumidores ditos “cativos”, atendidos, exclusivamente, pelo distribuidor local, com tarifas e condições de fornecimento reguladas pela ANEEL. Os agentes vendedores são os comercializadores, geradores, produtores independentes e autoprodutores que participam dos leilões regulados de energia elétrica.

No ACL, a negociação de preço e montantes é livre, entre os agentes, devendo apenas o montante negociado, entre as partes, ser registrado pela CCEE para fins de contabilização e liquidação. Esse ambiente abriga os geradores, os importadores e exportadores de energia elétrica, os consumidores ditos “livres”, aptos a comprar energia de qualquer fornecedor, e os comercializadores, que podem

comprar energia de qualquer fornecedor e vendê-la a qualquer comprador, exceto os consumidores cativos.

Esse modelo define regras de contratação que penalizam a empresa em caso de desvio, entre a energia contratada nos leilões do Ambiente de Contratação Regulada (ACR), e a energia, efetivamente, contabilizada. O Decreto nº 5.163 de 30 de julho de 2004, no seu artigo 2º, obriga os agentes distribuidores a garantir o atendimento a 100% do seu mercado de energia por meio de contratos registrados na CCEE e homologados pela ANEEL.

### 2.5.1 O Preço de Liquidação das Diferenças e o Valor Anual de Referência

A cada semana, o Preço de Liquidação das Diferenças (PLD) é determinado pela CCEE para cada patamar de carga (leve, médio e pesado) e para cada submercado (Sul, Sudeste, Centro Oeste, Norte e Nordeste). O PLD tem como base o Custo Marginal de Operação que é gerado pelos modelos computacionais *Newave* e *Decomp*, utilizados pelo ONS para o planejamento da operação do SIN, cujo processo de cálculo é efetuado com base em informações previstas de disponibilidade de usinas e previsão de consumo (mercado). É limitado por um preço mínimo e por um preço máximo, definidos, anualmente, por resolução da ANEEL.

O Valor Anual de Referência (VR) é o limite de repasse às tarifas dos consumidores cativos do custo de aquisição de energia elétrica proveniente de geração distribuída e da energia contratada nos leilões de ajuste e/ou energia nova pelas distribuidoras. O seu valor corresponde à média dos preços dos leilões A-5<sup>1</sup> e A-3<sup>2</sup>, ponderado pelos respectivos volumes contratados, conforme a equação (2.1).

$$VR = \frac{VL5 \cdot Q5 + VL3 \cdot Q3}{Q5 + Q3} \quad (2.1)$$

<sup>1</sup> A-5: Leilão de energia nova executado no ano "A" para início do suprimento em 5 anos

<sup>2</sup> A-3: Leilão de energia nova executado no ano "A" para início do suprimento em 3 anos

Onde:

VL5, VL3: Preços médios de compra nos leilões A-5 e A-3,

Q5, Q3: Quantidades de energia contratada nestes leilões.

A definição do Valor Anual de Referência está prevista no Decreto nº 5.163/2004, com alterações promovidas pelo Decreto nº 5.911/2006.

### 2.5.2 Sobre e Subcontratação

Para que os distribuidores possam decidir livremente sobre suas estratégias de contratação sem colocar em risco o atendimento às diretrizes de modicidade tarifária e garantia de suprimento, o modelo estabelece uma estrutura de incentivos que combina penalidades pela não contratação integral da carga (subcontratação) com limites de repasse de preços e quantidades de energia adquirida (para o caso de sobrecontratação) às tarifas de fornecimento ao consumidor final.

Em caso de sobrecontratação, com excedente de até 3% dos contratos de compra sobre a carga de energia verificada, a distribuidora é autorizada a repassar o excedente contratual para a tarifa de energia. Caso o excedente seja superior a 3%, essa diferença deve ser liquidada no mercado de curto prazo a custo de Preço de Liquidação das Diferenças (PLD). O prejuízo econômico vem do caso de o preço de PLD ser inferior ao preço médio dos contratos de compra de energia firmados. Caso o PLD seja superior ao preço médio de contratação, a diferença (neste caso uma vantagem auferida) é captada e revertida para a modicidade tarifária.

O caso de subcontratação gera, ainda, maior risco financeiro para a distribuidora, pois o agente deve comprar a energia que faltou para cobrir o seu mercado, a preço de PLD. Já, a ANEEL reconhece para o repasse, na tarifa, somente preços de compra com

valores iguais ou inferiores ao VR. Ademais, o agente é multado por meio da valoração da diferença entre a energia verificada e a cobertura contratual a preço de PLD ou VR, aplicando o qual apresentar maior valor. Assim, cada MWh sem cobertura contratual implica dois custos: um de repasse, dados pela diferença entre a compra ao PLD e o repasse pelo menor valor entre VR e PLD; outro da multa, pelo maior valor entre o PLD e o VR.

Posto isto, percebe-se certa assimetria na penalização pelo erro de planejamento: o regulador penaliza mais severamente o erro pela “falta” que o erro pelo “excesso”. Esta assimetria na penalização reflete, na realidade, a busca pela garantia de suprimento.

### 2.5.3 A Necessidade de Assertividade

Conforme exposto, as regras do modelo vigente penalizam, severamente, os desvios, especialmente, no caso de subestimação do potencial de crescimento do mercado. Dito isso, já é possível verificar quão é necessária a assertividade nas rotinas de planejamento de mercado e contratação de energia, pois uma indicação incorreta pode gerar significativos prejuízos para a distribuidora.

Não obstante a isso, a compra de energia para atendimento ao mercado consumidor, compõe a maior parcela das despesas de uma concessionária de distribuição, cerca de 40% da receita autorizada da concessionária visa atender a essa demanda. O planejamento da compra implica considerável impacto sobre o caixa da empresa. Aliado a isso, existe o fato de que, em geral, o mercado planejado é insumo para o planejamento estratégico da empresa como um todo.

Não menos importante, nas revisões tarifárias periódicas promovidas pela ANEEL, a projeção do mercado de energia elétrica tem influência direta no reposicionamento tarifário. O reposicionamento tarifário é o resultado da razão entre a receita requerida (em R\$) e a receita verificada (em R\$). A receita verificada corresponde à receita que seria auferida aplicando as

tarifas vigentes ao mercado projetado. Como a receita requerida é calculada na revisão, qualquer desvio na receita verificada traduz-se em um reposicionamento distinto do necessário para a manutenção do equilíbrio econômico-financeiro da concessionária. (ANEEL/SRE, 2007)

Essa necessidade de assertividade tem promovido a busca por novos e diferentes modelos de predição de séries temporais, a fim de diversificar a descrição das diversas classes de consumo e aumentar a confiabilidade entre os cenários. Entre os modelos de previsão mais aplicados estão o Auto Regressivo de Médias Móveis (ARIMA), Vetor Auto Regressivo Com Correção de Erros (VEC) (STORCK, 2008), Suavização Exponencial de *Holt-Winters* (SAMOHYL & SOUZA, 2005), Redes Neurais Artificiais (CONDE, G. et al, 2007), Modelos de Decomposição de Séries Temporais (SAPANKEVYCH, N.I. & SANKAR, R., 2009), etc.

A aplicação desta gama de opções gera uma quantidade razoável de cenários de previsão, que refletem, por exemplo: as diferenças de aproximação entre os modelos, as possíveis composições de variáveis exógenas, o julgamento subjetivo do analista, etc. Essa diversidade de informações é interessante, tendo em vista que diversas possibilidades de comportamento estão descritas neste *set* de informações. Porém, para o gestor do negócio, criam-se problemas de decisão: como extrair a melhor informação das previsões? Qual previsão deve ser escolhida como cenário- base?

Para apoio, nessa tomada de decisão, usualmente, o gestor orienta-se pela sua experiência e pelos desvios “dentro da amostra” de cada modelo. Entretanto, diversos autores, entre eles Ashley (2003), afirmam que a aplicação desse tipo de metodologia só é conclusiva quando utilizados, ao menos 100(cem) dados fora da amostra, o que se torna impraticável no caso de séries mensalizadas, pois seria o equivalente a abrir mão de mais de oito anos de informação. Portanto, o bom desempenho de um modelo no passado, não é garantia de um bom desempenho futuro.

Nesse contexto, este trabalho apresenta uma metodologia capaz de compor um novo cenário de previsão com base na saída



dos diversos modelos de predição. De uma perspectiva teórica, a não ser que fosse possível identificar, previamente, um modelo individual que gerasse menores erros de predição que os seus competidores, a combinação de projeções (*Forecast Combination – FC*) oferece ganhos de diversificação que torna mais atrativo combinar cenários individuais do que depositar a confiança nos resultados de um único modelo (TIMMERMANN, 2005). Isto é, a idéia principal, em torno da aplicação deste método, é traduzir toda a informação contida nos cenários propostos em uma nova série que, necessariamente, apresentará maior confiabilidade na sua aplicação.

## 2.6 A Importância do Planejamento

A energia elétrica relaciona-se com todos os setores produtivos. Por consequência, as decisões referentes a esse insumo produzem efeitos nos diversos domínios da economia. Como a tomada de decisão no sistema elétrico tem relação de longo prazo, é necessário vislumbrar o horizonte futuro como suporte para tal decisão.

Na sociedade moderna, o planejamento tornou-se uma ferramenta fundamental para o bom desempenho de qualquer atividade socioeconômica. Não obstante, temos verificado a aplicação dessa ferramenta nas mais diversas áreas do conhecimento humano. Com o mote de sustentabilidade vivido nos dias atuais, planejar torna-se, ainda, mais necessário, visto que, um dos objetivos do bom planejador é evitar desperdícios e custos desnecessários.

No setor elétrico, onde o uso de capital é intensivo, os investimentos iniciais são elevados e o retorno é de longo prazo. A aplicação das técnicas corretas de planejamento é imperativa. Planeja-se para assegurar a continuidade no abastecimento e ou suprimento de energia ao menor custo, com o menor risco e com os menores impactos socioeconômicos e ambientais para a sociedade.

Dito de outra forma, a falta de planejamento energético pode causar elevação nos custos ou causar a degradação na qualidade da

prestação do serviço, tal como ocorrido durante o plano de racionamento imposto aos consumidores do SE, CO e NE do SIN, no início da década passada.

Também, pode-se dizer, intuitivamente, que a inadequabilidade do exercício de planejamento aumenta a percepção de “risco regulatório” dos agentes, o que é, extremamente, prejudicial para continuidade do aporte de investimentos privados no setor. Afinal, a ausência de um ambiente regulatório adequado, com regras estáveis, claras e concisas é um obstáculo ao investidor privado.

### 2.6.1 Planejamento Indicativo e Planejamento Determinativo

Na perspectiva da oferta, o planejamento da expansão, no caso do setor elétrico brasileiro, é indicativo na maior parte das situações e determinativo em algumas circunstâncias específicas (BAJAY, 2001). Este equilíbrio entre diferentes escolas de planejamento coexiste objetivando a evolução na busca pela competição e, ao mesmo tempo, a proposição de metas de desenvolvimento estrutural alinhadas com as políticas energéticas vigentes, em especial a de segurança na continuidade do fornecimento.

O planejamento indicativo assemelha-se à teoria econômica neoliberal, onde se supõe que as forças de mercado devem manter o equilíbrio entre oferta e demanda no longo prazo. Casos como (CLARK & LUND, 2001) demonstram que esta alternativa de planejamento pode gerar desequilíbrios entre oferta e demanda devido a expectativas de valorização do preço dos energéticos.

O planejamento determinativo encontra paralelo na escola *Keynesiana*, assumindo o papel intervencionista do governo no planejamento do sistema, determinando a oferta das obras de cunho estrutural para o atendimento à demanda de energia elétrica. No Brasil, existem os casos recentes dos aproveitamentos hidrelétricos do rio Madeira e da UHE Belo Monte, que devido a sua relevância foram tratados como casos determinativos pelo governo federal.

### 2.7 Impacto Financeiro da Compra de Energia

Para quantificar o impacto da compra de energia, dentro das despesas na operação de uma distribuidora, tomaremos como exemplo o caso do reajuste tarifário anual de 2011 da Empresa Energética de Mato Grosso do Sul S.A. – ENERSUL. Na nota técnica nº 71/2011-SRE/ANEEL, o regulador homologa as tarifas para o reajuste tarifário anual de 2011 com base na composição de receita requerida da Tabela 2.1.

	ENCARGOS SETORIAIS	R\$ 168.421.840,53
PARCELA A	TRANSPORTE DE ENERGIA	R\$ 90.478.536,07
	ENERGIA COMPRADA TOTAL	R\$ 469.669.788,44
PARCELA B	CUSTO DE DISTRIBUIÇÃO	R\$ 541.949.393,31
	RECEITA REQUERIDA	R\$ 1.270.519.558,35

Tabela 2.1 – Receita requerida da Enersul no RT 2011

Pela análise do exposto, depreendemos que o custo com a contratação de energia toma cerca de 40% da receita total de uma distribuidora. Por essa perspectiva, percebe-se que pequenos desvios (da ordem de 0,5% a 1,5%) geram grandes impactos de caixa para a empresa. Apenas por isso, já é justificável a necessidade de modelos de predição que possuam elevado grau de precisão. Há, ainda, a vantagem da redução do risco de exposição a penalidades por sub ou sobre contratação além de que, por causa da evolução de mercado ser a variável de entrada do plano de expansão da empresa, a correta indicação do cenário futuro proporciona investimentos prudentes e, por consequência, modicidade tarifária.

### 3. CAPÍTULO – MÉTODOS DE PREVISÃO DE MERCADO

#### 3.1 Séries Temporais e Estacionariedade

Uma série temporal é qualquer conjunto de informações ordenado no tempo. Podem ser exemplos de séries temporais:

- i. Cotações diárias da Bolsa de Valores;
- ii. Precipitação atmosférica mensal na cidade de Campo Grande;
- iii. Valores anuais do PIB brasileiro;
- iv. Consumo de energia elétrica mensal do estado de Mato Grosso do Sul.

Para auxiliar no entendimento das disposições deste capítulo, é importante discorrer sobre o principal conceito dentro do estudo de séries temporais, a estacionariedade.

A suposição mais frequente que se faz a respeito de uma série temporal é a de que ela é estacionária, ou seja, ela desenvolve-se no tempo, aleatoriamente, ao redor de uma média constante, refletindo alguma forma de equilíbrio estável (MORETTIN, P. A. & TOLOI, C. M. C., 2006).

Entretanto, a maioria das séries práticas, entre elas o consumo de energia elétrica, séries econômicas, financeiras, apresentam alguma forma de não estacionariedade. Assim, séries como de consumo de energia elétrica apresentam, em geral, tendências, sendo o caso mais simples aquele em que a série “flutua” ao redor de uma reta, com inclinação positiva ou negativa (tendência linear).

Para alguns procedimentos de análise estatística de séries temporais, é necessário que os dados originais sejam transformados a ponto de formarem séries estacionárias. A transformação mais comum consiste em tomar diferenças sucessivas da série original, até obter-se uma série estacionária (MORETTIN, P. A. & TOLOI, C. M. C., 2006).

A primeira diferença de  $Z_{(t)}$  é definida por:

$$\Delta Z_{(t)} = Z_{(t)} - Z_{(t-1)} \quad (3.1)$$

A segunda diferença é:

$$\Delta^2 Z_{(t)} = \Delta[\Delta Z_{(t)}] \quad (3.2)$$

De modo geral, a  $n$ -ésima diferença de  $Z_{(t)}$  é:

$$\Delta^n Z_{(t)} = \Delta[\Delta^{n-1} Z_{(t)}] \quad (3.3)$$

Por experiência, sabe-se que, em situações normais, é suficiente tomar uma ou duas diferenças para que a série de consumo de energia elétrica torne-se estacionária.

### 3.2 Métodos Utilizados Pela Distribuidora

Não há nenhuma diretriz da agência reguladora ou do poder concedente quanto a que métodos devem ser utilizados na elaboração das previsões de mercado. Sendo assim, os agentes de mercado são livres para utilizarem, desenvolverem, aplicarem os mais diversos métodos. Atualmente, em geral, as distribuidoras de energia elétrica utilizam métodos de regressão múltipla, utilizando modelos abertos por classes de consumo e/ou nível de tensão.

Entretanto, em 2007, a ANEEL (ANEEL/SRE, 2007) indicou em nota técnica a metodologia de projeção de mercado que seria aplicada nas revisões tarifárias para validação das projeções de mercado informadas pelas distribuidoras no segundo ciclo de revisão tarifária. Nesse documento, o órgão regulador divulga a aplicação da metodologia Box-Jenkins para seus estudos. Essa metodologia parte

do pressuposto de que o comportamento de uma determinada série pode ser, em grande parte, explicado por informações contidas na própria série. Dessa forma, um modelo Box-Jenkins tradicional não possui nenhuma variável explicativa. Dado que o método é aplicado para validação dos ciclos tarifários (4 e 5 anos), a utilização dessa metodologia gerou diversas críticas, entre os especialistas do setor, por ser um método mais adequado ao longo prazo (previsões acima de 10 anos) que ao médio (mais de um ano) e curto prazo (inferior a um ano).

A Enersul vem desenvolvendo seus métodos de projeção de mercado, em especial a partir de 2004, quando a projeção de mercado passou a ter papel de maior relevância dentro do Setor Elétrico.

Em especial, para elaboração das projeções do plano decenal da distribuidora (mercado de energia elétrica 10(dez) anos à frente), são feitas diversas “rodadas” de simulações com diferentes métodos e *softwares*. A seguir, estão descritos os métodos, atualmente, aplicados na elaboração do plano decenal.

### 3.2.1 Decomposição de Séries Temporais (DST)

A primeira rodada de projeção é elaborada por meio da técnica de decomposição de séries temporais, que consiste em realizar a descrição das componentes da série por análise dos seus dados passados. Com base na descrição de suas componentes, é inferido o seu comportamento futuro. Essa é uma técnica, relativamente, simples e barata, pois não necessita de nenhum *software* dedicado para sua aplicação. Pode ser realizado com apoio do *Microsoft Excel* e seu pacote estatístico.

Segundo MORETTIN e TOLOI (MORETTIN, P. A. & TOLOI, C. M. C., 2006) considera-se que uma série temporal  $Z_t$  pode ser descrita como a soma de três componentes não observáveis:

$$Z_t = T_t + S_t + a_t \quad (3.4)$$

Em que:

$T_t$  Representa a tendência;

$S_t$  Representa a sazonalidade;

$a_t$  Componente aleatória de média zero e variância constante.

Para realização da análise, primeiramente, a série de consumo é decomposta pela análise de sua tendência por meio do pacote estatístico do *software Microsoft Excel*. O Excel utiliza a técnica de mínimos quadrados para “traçar” uma regressão linear sobre a série de dados, o que pode ser examinado nos blocos (01) e (02) da Figura 3.1:

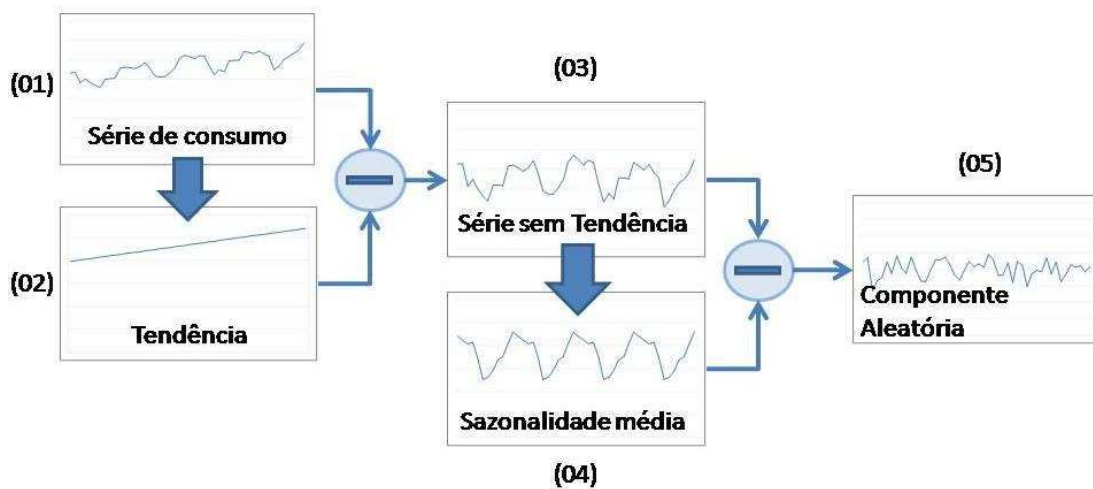


Figura 3.1 – Decomposição de Séries Temporais

Após a extração da tendência, é analisada a sazonalidade média (bloco 04) da série resultante (bloco 03). A sazonalidade é determinada pelo cálculo dos coeficientes sazonais, que são a representatividade de uma determinada observação dentro de um período típico determinado. Na análise de séries mensais de

consumo, existe um coeficiente sazonal para cada mês do ano (período de 12 observações). A equação (3.5) demonstra o cálculo da sazonalidade de cada período anual.

$$S_{ij} = \frac{O_{ij}}{\sum_{i=1}^{12} O_{ij}} \quad (3.5)$$

Em que:

$i$  Mês

$j$  Ano

$S_{ij}$  Coeficiente Sazonal do mês  $i$  do ano  $j$

$O_{ij}$  Observação referente ao mês  $i$  do ano  $j$

Os coeficientes sazonais demonstram o perfil em percentual unitário (PU, de cada ano observado, porém, é necessário determinar uma sazonalidade típica para utilização posterior na recomposição da série). Conforme demonstra a equação (3.6), uma curva de sazonalidade média é formada com base na média aritmética dos pesos sazonais de cada ano.

$$S_{i\text{méd}} = \frac{\sum_{j=1}^n S_{ij}}{n} \quad (3.6)$$

Em que:

$S_{i\text{méd}}$  Coeficiente sazonal médio do mês  $i$

$n$  Número de períodos (anos) observados na série

A informação resultante da extração da sazonalidade média (bloco 04) da série sem tendência (bloco 03) é a componente aleatória (bloco 05), isto é, uma componente que não pode ser descrita ou explicada. Em uma decomposição bem executada, a



componente aleatória deve possuir média zero e distribuição normal, isto é, deve ser estacionária.

Com a série, inteiramente, decomposta, passa-se ao processo de previsão, este depende, exclusivamente, da sensibilidade do analista que, com base na análise da tendência da taxa de evolução do consumo e a sua percepção dos cenários futuros, determina uma nova trajetória de evolução anual (curva de tendência futura). Essa curva de tendência futura pode ser também a extrapolação da tendência realizada no passado.

De posse de uma curva de tendência futura determinada, faz-se a recomposição da série mensalizando, a sua trajetória anual com base nos pesos calculados para a curva de sazonalidade média.

### 3.2.2 Análise Funcional e Espaços de Hilbert

A empresa utiliza um *software* desenvolvido pela consultoria Engenho (Rio de Janeiro) como um trabalho de previsão de mercado iniciado em 2003, e que foi implantado com sucesso em diversas empresas do Setor Elétrico. Esse modelo busca o “entendimento” da dinâmica de mercado, a partir de suas variáveis explicativas, utilizando ferramentas baseadas em análise funcional evolutiva e Espaços de Hilbert com dimensão finita (SZCZUPAK, J. et al, 2007). A previsão é realizada a partir da projeção das variáveis explicativas e de seu impacto na explicada.

Um dos pontos interessantes do algoritmo desenvolvido é a característica evolutiva do seu processo. Erros que, eventualmente, podem ocorrer não são tratados como “anomalias” ou “pontos fora da curva”. O modelo busca analisar e absorver os comportamentos imprevistos da série.

A análise funcional é aplicada, usualmente, a problemas de otimização. Ela pode ser aplicada em base estatística ou determinística associada a Espaços de Hilbert de dimensão finita. Pode-se referir-se aos membros do Espaço de Hilbert, como vetores, sequências de dados, como cargas, temperaturas, índices econômicos, ou até mesmo as próprias componentes da série

temporal. Idealmente, o Espaço de Hilbert considerado é um espaço métrico completo e sua solução ótima satisfaz a Condição de Ortogonalidade e o Teorema da Projeção (PINTO, 2008), conforme demonstrado na Figura 05.

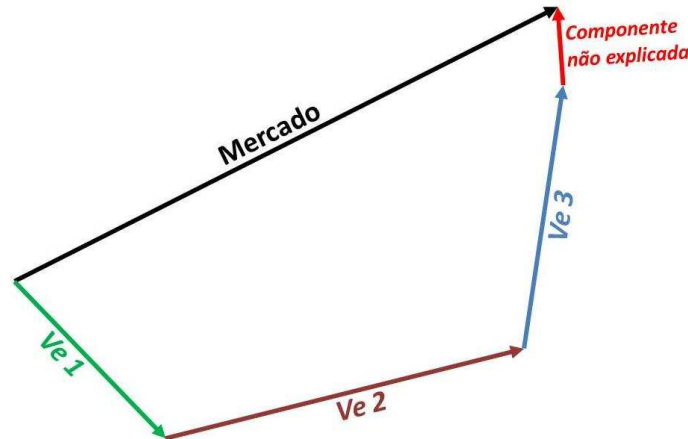


Figura 3.2 – Modelo de Decomposição Espaços de Hilbert.

Para aplicação do modelo, é confeccionada uma base de dados com possíveis variáveis que possam descrever, adequadamente, o comportamento do consumo de energia elétrica (mercado), tais como: indicadores demográficos, evolução da renda, evolução da tarifa de energia, produção industrial, PIB, balança comercial, IGP-M, IPCA, dados climatológicos, etc.

O analista deve selecionar, do banco de dados, um número parcimonioso de variáveis que julgue serem adequadas à descrição que deve ser feita. O processo é sequencial. O vetor mercado vai sendo explicado, iterativamente, a partir das variáveis explicativas selecionadas e gerando resíduos, por construção, independentes das variáveis já utilizadas (PINTO, 2008).

A figura 3.3, adaptada de (PINTO, 2008), ilustra a aplicação do método para decomposição do vetor mercado ( $V_m$ ) em um caso hipotético de um espaço finito de três variáveis explicativas ( $V_1$ ,  $V_2$  e  $V_3$ ). Pode-se verificar a sucessão de aproximações realçando a decomposição do vetor mercado em uma soma de aproximações (projeções) e um resíduo (erro) final.

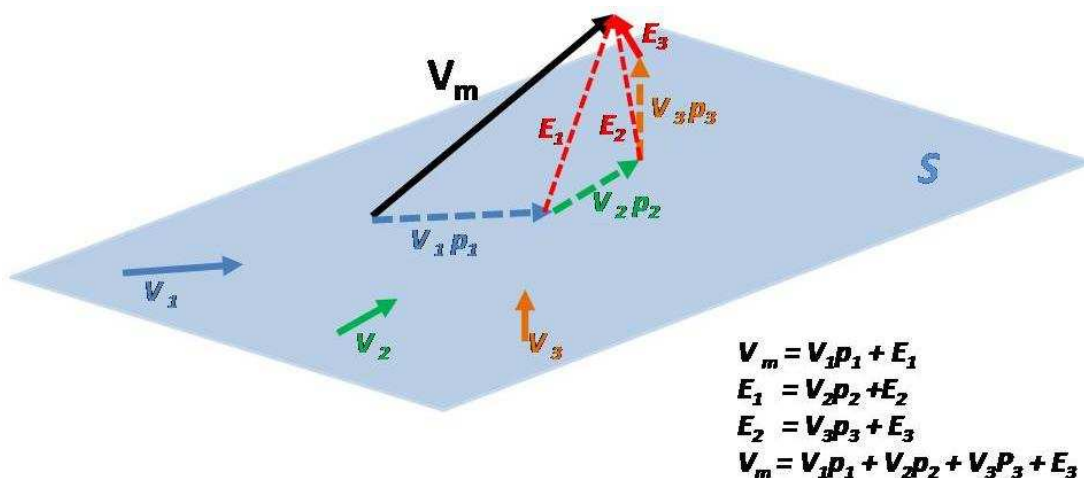


Figura 3.3 – Representação Gráfica das aproximações

O objetivo do método não é alcançar a propriedade matemática do espaço completo, isto é, resíduo final zero. A meta é que a incerteza no resíduo  $\mathbf{E}_3$  seja, suficientemente, pequena para ser considerada implícita à dinâmica de mercado, ou aderente às regras setoriais.

O processo pode ser realizado até mesmo pelas suas próprias componentes temporais (tendência e sazonalidade) mais um erro associado à aproximação (componente não explicada).

Nesse ciclo de projeções, devido à escassez de cenários futuros para as variáveis explicativas, a empresa pautou-se pela aplicação do método univariado, utilizando as próprias componentes da série como os vetores de decomposição.

### 3.2.3 Suavização Exponencial de *Holt-Winters*

O método de *Holt-Winters* (HW) é uma técnica determinística de previsão que faz parte de um conjunto de modelos abrangido pelo Método de Amortecimento Exponencial (MAE), empregado para modelar tendência e sazonalidade existentes na série temporal.

Na prática, o MAE distingue-se dos modelos de regressão linear, pois o seu objetivo não é ajustar uma reta aos dados. A todo instante, busca-se determinar a melhor reta, ou seja, uma reta para

cada instante de tempo, enquanto, no problema de regressão, pretende-se definir a melhor reta que passa por todos os pontos.

O destaque para o método de *Holt Winters*, dentro dos demais métodos do MAE, é que este é parametrizado de forma a poder modelar séries com efeito sazonal. Para tal, a série temporal original é “corrigida” de seu efeito sazonal que depois é “devolvido” a série via fatores sazonais.

No método de *Holt Winters*, a correção do efeito da sazonalidade é feita via fatores que representam o efeito sazonal, os fatores sazonais. Esses fatores podem ser incorporados aos modelos por meio da divisão ou da subtração dos valores da série temporal pelos seus respectivos fatores sazonais.

Quando o efeito da sazonalidade é retirado e incorporado à série, por meio de divisão e multiplicação, respectivamente, dos valores da série temporal pelos fatores sazonais, o método é denominado multiplicativo. O método multiplicativo é bem aderente a séries cuja variância dos fatores sazonais aumenta ou decresce com o nível da série.

Quando o efeito da sazonalidade é retirado e incorporado à série por meio de subtração e adição, respectivamente, dos valores da série temporal pelos fatores sazonais o método, é denominado aditivo. O método aditivo adapta-se aos casos de séries bem comportadas cuja variabilidade dos fatores é constante.

Na prática, quando a amplitude da variação de uma determinada série varia com a evolução desta, por exemplo, as amplitudes aumentam à medida que o nível da série aumenta, o modelo que apresenta melhor adaptação é o multiplicativo. Nos casos em que a amplitude apresenta comportamento mais homogêneo, o modelo aditivo costuma apresentar melhor descrição, isto é, melhores resultados.

### 3.2.3.1 *Holt Winters* Multiplicativo

Considerando uma série sazonal de período  $m$ . A variante mais usual da equação 3.4 dada para o método de *Holt Winters* considera o fator sazonal  $S_t$  como multiplicativo, enquanto que a tendência permanece aditiva, isto é,

$$Z_{(t)} = L_t S_t + T_t + a_t \quad (3.7)$$

Para a descrição matemática do método de *Holt Winters* multiplicativo, consideramos que o modelo que gera a série temporal seja dado pela equação (3.7). Logo, a estimação dos fatores desse método pode ser dada pelas seguintes expressões;

$$L_t = \alpha \left( \frac{z_t}{S_{t-m}} \right) + (1-\alpha)(L_{t-1} + T_{t-1}) \quad (3.8)$$

$$T_t = \beta(L_t - L_{t-1}) + (1-\beta)T_{t-1} \quad (3.9)$$

$$S_t = \gamma \left( \frac{z_t}{L_t} \right) + (1-\gamma)S_{t-m} \quad (3.10)$$

$$Z_{t+n} = (L_t + nT_t)S_{t-m+\text{mod}(n-1,m)+1} \quad (3.11)$$

Em que:

$L_t$  Componente de nível;

$T_t$  Componente de tendência;

$S_t$  Componente de sazonalidade;

$m$  Período sazonal;

$h$  Horizonte de previsão;

$n$  1, 2, ..., h;

$mod(n,m)$  Resto da divisão de n por m;

$Z_{t+n}$  Previsão dada pelo método;

$\alpha$  ( $0 < \alpha < 1$ ) Constante de suavização da componente de nível ( $L_t$ );

$\beta$  ( $0 < \beta < 1$ ) Constante de suavização da componente de tendência ( $T_t$ );

$\gamma$  ( $0 < \gamma < 1$ ) Constante de suavização da componente de sazonalidade ( $S_t$ ).

### 3.2.3.2 Holt Winters Aditivo

O procedimento anterior pode ser modificado para tratar com situações em que o fator sazonal é aditivo, como descrito na equação (3.4).

Assim, as estimativas do fator sazonal, nível e tendência da série são dados por:

$$L_t = \alpha (Z_t - S_{t-m}) + (1-\alpha)(L_{t-1} + T_{t-1}) \quad (3.12)$$

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \quad (3.13)$$

$$S_t = \gamma(Z_t - L_t) + (1 - \gamma)S_{t-m} \quad (3.14)$$

$$Z_{t+n} = L_t + T_t + F_t + a_t \quad (3.15)$$

A determinação das constantes de suavização ( $\alpha$ ,  $\beta$ ,  $\gamma$ ) é realizada de modo a tornar mínima a soma dos quadrados dos erros de ajustamento aos dados dentro da amostra (MORETTIN, P. A. & TOLOI, C. M. C., 2006).

### 3.2.3.3 Inicialização dos Fatores de Suavização

Considerando que, na prática, a primeira amostra da série temporal é para  $t = 1$ , os valores  $L_1$  e  $T_1$  são funções de  $L_0$  e  $T_0$ . Como não existe amostra da série para  $t = 0$ , faz-se necessário inicializar  $L_1$  e  $T_1$ . Uma das maneiras mais populares é descrita como sendo;

$$L_m = \frac{1}{m}(x_1 + x_2 + \dots + x_m) \quad (3.16)$$

$$T_m = \frac{1}{m}\left(\frac{x_{m+1}-x_1}{m} + \frac{x_{m+2}-x_2}{m} + \dots + \frac{x_{m+m}-x_m}{m}\right) \quad (3.17)$$

$$S_1 = \frac{x_1}{L_1}, S_2 = \frac{x_2}{L_2}, \dots, S_m = \frac{x_m}{L_m} \quad (3.18)$$

### 3.2.3.4 Software de Aplicação

O *software* utilizado para aplicação da técnica de *Holt Winters* foi o pacote estatístico *Minitab* na sua versão 14, que possui boa capacidade de análise, além de apresentar possibilidade de expansão com uma linguagem simples de macros e rotinas. A ENERSUL já possuía licenças do *software*, o que possibilitou a sua aplicação.

### 3.2.4 Modelos *Box-Jenkins* (ou ARIMA)

Nos modelos *Box-Jenkins*, parte-se do pressuposto que o comportamento da série é, em sua maioria, explicado por informações contidas na própria série, isto é, é um modelo que não faz uso de variáveis explicativas ( $X_t$ ), sendo incluído no rol dos modelos, essencialmente, univariados (BOX, G.E.P & JENKINS, G.M, 1976).

A metodologia *Box-Jenkins* requer que a série seja estacionária. Uma série é dita estacionária se suas média e

variância são constantes, ao longo do tempo, e o valor da covariância, entre dois períodos de tempo, depende apenas da distância ou defasagem, entre os dois períodos, e não do período de tempo efetivo em que a covariância é calculada, ou seja, as propriedades do processo não são afetadas por uma mudança na origem do tempo. O conceito de estacionariedade é importante em um contexto de projeção, pois, por definição, quando a série é estacionária, as propriedades estatísticas como média, variância e autocorrelação observadas no passado são as mesmas no futuro.

Assim, os modelos ARIMA não requerem, necessariamente, outras variáveis e pressupõe-se que o passado da própria série captura a maior parte de todas as informações relevantes para explicar o seu comportamento, por meio de um conjunto de componentes. Dessa forma, um modelo *Box-Jenkins* tradicional não tem nenhuma variável explicativa, exceto pela constante.

O *software* de suporte utilizado para a montagem dos cenários ARIMA foi o *Eviews*. No *Eviews*, pode-se resumir o método ARIMA por algumas fases. A primeira consiste na identificação do modelo, por meio da análise dos correlogramas (funções *autocorelated function* – ACF, e *partial autocorrelation function* - PACF), demonstrado logo a seguir. O segundo passo consiste na escolha do tipo de modelo a ser usado (AR(p), MA(q), ARMA(p,q) ou ARIMA(p,d,q)); deve-se usar somente o número suficiente de termos AR e MA de modo a ajustar os resíduos.

Após a escolha e estimação do modelo, que é feita, em geral, por mínimos quadrados não lineares, deve-se verificar se há a ocorrência de coluna em algum *lag* do correlograma dos resíduos que o modelo não foi capaz de ajustar. Caso exista, o modelo deve ser reespecificado.

Um processo autorregressivo de ordem p, ou  $AR_{(p)}$ , ocorre quando a série no período  $t$  depende, unicamente, dos seus valores nos períodos anteriores e de um termo aleatório.

Para uma série de Consumo de Energia Elétrica ( $C_t$ ), em primeira diferença, o processo autorregressivo pode ser escrito, genericamente, como em (3.19):



$$\Delta C_{(t)} = \delta + \theta_1 \Delta C_{(t-1)} + \theta_2 \Delta C_{(t-2)} + \dots + \theta_p \Delta C_{(t-p)} + \varepsilon_t \quad (3.19)$$

No *Eviews*, os parâmetros  $\delta$ ,  $\theta_1$ ,  $\theta_2$ , ...,  $\theta_n$ , em (3.19) são estimados por mínimos quadrados ordinários.

Uma das formas para determinar-se a ordem  $p$  de defasagens do processo autorregressivo é pela análise da função de autocorrelação parcial (PACF), que consiste na sequência de correlações entre  $(Y_t$  e  $Y_{t-1})$ ,  $(Y_t$  e  $Y_{t-2})$ , e assim por diante, desde que os efeitos das defasagens anteriores permaneçam constantes. Um processo AR possui uma ACF declinante e uma PACF truncada, exatamente, na ordem do processo. Assim, deve-se escolher a mais alta defasagem, com autocorrelação parcial significativa, como a ordem do AR.

Um processo de médias móveis de ordem  $q$ , ou  $MA_{(q)}$ , ocorre quando a série no período  $t$  depende de uma média móvel dos termos de erro corrente e passado. Genericamente, para a variável Consumo de Energia Elétrica em primeira diferença temos:

$$\Delta C_{(t)} = \mu + e_t + \theta \alpha_1 e_{(t-1)} + \theta \alpha_2 e_{(t-2)} + \dots + \alpha_q e_{(t-q)} \quad (3.20)$$

No *Eviews*, os parâmetros de (3.20) são estimados pelo método não linear de mínimos quadrados. Modelos  $MA_{(q)}$  e  $ARMA_{(p,q)}$  devem ser estimados por processos recursivos, pois os erros (choques) passados, que são variáveis independentes no modelo, não são observáveis.

Se, finalmente, a série possui características tanto de um processo autorregressivo como de um processo de média móvel, então, trata-se de um processo  $ARMA_{(p,q)}$  e pode ser escrito da seguinte forma:

$$\Delta C_{(t)} = \delta + \theta_1 \Delta C_{(t-1)} + \theta_2 \Delta C_{(t-2)} + \dots + \theta_p \Delta C_{(t-p)} + \varepsilon_t + e_t + \theta \alpha_1 e_{(t-1)} + \theta \alpha_2 e_{(t-2)} + \dots + \alpha_q e_{(t-q)} \quad (3.21)$$

O processo  $ARMA_{(p,q)}$  tem as funções de autocorrelação e de autocorrelação parcial combinadas dos dois processos, ou seja, apresenta tanto uma ACF declinante como uma PACF declinante. Além disso, conforme discutido, como a série de Consumo de Energia Elétrica necessita de diferenciação para tornar-se estacionária, ela será, então, integrada de ordem  $d$  (é o número de diferenças necessárias) e o processo passa a ser dito  $ARIMA_{(p,d,q)}$ .

Em resumo, a metodologia consiste na identificação do padrão  $ARIMA_{(p,d,q)}$  da série temporal, por meio da verificação dos correlogramas amostrais da série, seguida pela estimação dos modelos e verificação do diagnóstico. O diagnóstico pós-estimação faz-se necessário, pois a análise das ACF e PACF pode não ser suficiente para determinar, corretamente, o melhor modelo a ser aplicado.

O melhor modelo  $ARIMA_{(p,d,q)}$  é aquele que é capaz de explicar todas as relações entre a variável e seus valores passados e erros passados, ou seja, os resíduos não podem ser autocorrelacionados. De posse do melhor modelo, são realizadas, então, as previsões futuras, que para o método *Box-Jenkins*, geralmente, apresentam melhor desempenho no Curto Prazo (CAIO, L.S. & BERMANN, C., 1998).

### 3.2.5 Predição de Consumo por meio de Regressão – *Predict*

O Sistema de Suporte à Decisão para Estimação de Cargas e Modelagem de Dependência em Sistemas Elétricos (*Predict*) permite, também, antecipar a tomada de decisões por intermédio da exploração de cenários projetados por meio de redes bayesianas, que são modelos gráficos de dependência probabilística. O *Predict* aborda a simulação do consumo pela regressão e faz sua correlação e análise de dependências. O *software* é fruto de um projeto de Pesquisa e Desenvolvimento (P&D) patrocinado pela CELPA e Rede Energia desenvolvido por meio da UFPA e ELUCID (REGO, L.P. et al, 2009).

Usualmente, as ferramentas estatísticas realizam projeções pelo uso de regressão linear da série como um todo, porém, a abordagem realizada pelo *software Predict* é aplicada de maneira diferente. Como, da análise da série de consumo original, os analistas consideraram seu comportamento muito “explosivo” por não conseguirem alcançar a estacionariedade trabalhando com a série de forma integral, buscaram uma abordagem diferente de análise (ROCHA, CLAUDIO A.; SANTANA, ÁDAMO L.; FRANCÊS, CARLOS R. et. al., 2006). A série única de dados mensalizados é particionada em doze séries anuais correspondentes aos meses de janeiro a dezembro. Com o particionamento das séries, a propriedade de estacionariedade foi, então, alcançada, conforme demonstrado no correlograma da figura 3.4, extraída de (ROCHA, CLAUDIO A.; SANTANA, ÁDAMO L.; FRANCÊS, CARLOS R. et. al., 2006):

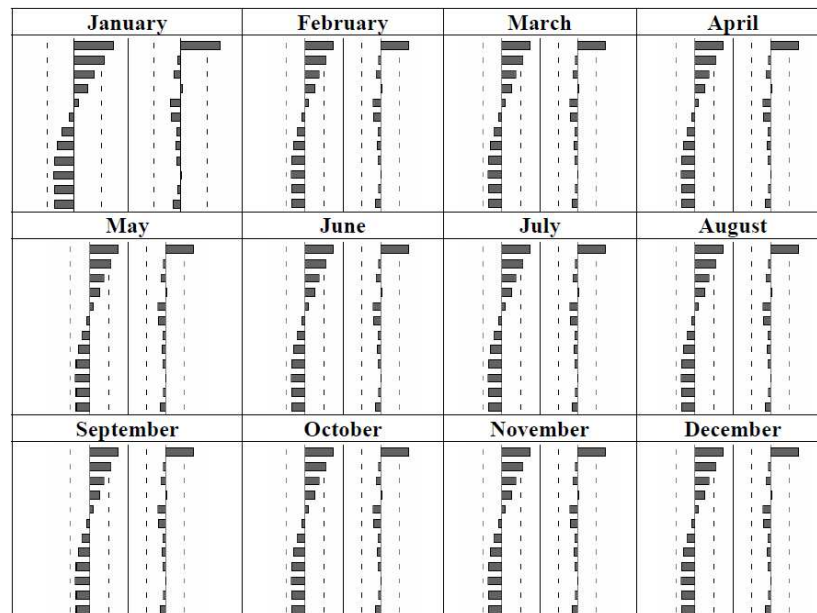


Figura 3.4 – Autocorelação e correlação parcial da série com os dados particionados, em meses, de janeiro a dezembro.

A solução aplicada para o modelo linear utilizado para realizar a predição da série foi atingida com o método dos mínimos quadrados ordinários. O modelo linear aplicado pode ser definido pela equação (3.22):

$$Z_t = \alpha + \beta Y_t + a_t \quad (3.22)$$

Em que:

$Z_t$  é o valor da série temporal no instante  $t$ ;

$\alpha$  é o coeficiente linear da regressão;

$\beta_t$  é o coeficiente angular da regressão;

$Y_t$  é o valor da variável tempo no instante “ $t$ ”, e  $a_t$  caracteriza o erro aleatório.

Os estimadores estabelecidos para realizar a predição dos valores futuros de energia utilizam-se da análise de regressão múltipla, baseados na análise do valor do consumo obtido, previamente, no período de 1991 até 2011, e de uma variável, quantificando a tendência anual obtida por meio de análise fatorial.

Na aplicação prática dessa técnica, percebeu-se inconsistência nos resultados. A tendência linear das séries previstas costuma apresentar comportamento “explosivo”, ou exponencial, tanto com coeficientes positivos como negativos, comportamento este que não pode ser esperado para as séries de consumo de energia elétrica de um mercado com taxas de crescimento já consolidadas. Provavelmente, essa característica deve-se, basicamente, a dois fatores; (a) o particionamento da série integral em frações mensais, o que na prática, isola o comportamento de cada mês, tornando-o independente dos meses adjacentes, isto é, muito diferente do que se verifica no mundo real. (b) O período de análise inclui o período pré-acionamento, que como explicado, anteriormente, não pode ser utilizado nas análises atuais do mercado de energia no SEB.

## CAPÍTULO 4 – COMBINAÇÃO DE PREVISÕES E ANÁLISE DE COMPONENTE PRINCIPAL

### 4.1 A Escolha por Um Cenário

A eleição dos cenários é aqui tratada como o principal problema a ser resolvido. Em linhas gerais, a escolha do cenário é feita por um *board* de gestores da empresa que utiliza a sua *expertise* para avaliar, de forma empírica, qual cenário proposto possui maior probabilidade de realização. Percebe-se que a tomada de decisão atual é baseada em “quanto” o comportamento futuro de um determinado cenário está aderente ao seu comportamento passado. Essa análise é feita, usualmente, sobre os dados de consumo integralizados em período anual.

Frequentemente, durante as reuniões do *board*, o analista responsável pela elaboração dos cenários é questionado quanto à possibilidade da elaboração de um “novo cenário” que congregue características de dois ou mais cenários apresentados, a fim de potencializar a sua possibilidade de ocorrência. É importante destacar que essa sugestão do gestor reflete, na realidade, a sua aversão ao risco e a preocupação de, escolhendo, entre cenários diferentes de previsão, não possuir informações sobre o futuro ou sobre qual cenário, por mais que se apresente consistente no momento atual, apresentará a melhor performance.

Frente a essa necessidade, a metodologia de *Forecast Combination* (FC), que já vem sendo aplicada por meio de diversas técnicas (ARMSTRONG, 1989), pode ser utilizada de forma a captar o comportamento (variância) dos diversos cenários propostos e concatená-los em uma nova série numérica.

### 4.2 Combinação de Previsões (*Forecast Combination*)

A combinação de previsões (*Forecast Combination* – FC) é um método, frequentemente, empregado em estudos empíricos, a fim de

produzir resultados melhores que os resultados individuais de cada modelo (ARMSTRONG, 1989).

A menos que fosse possível de identificar-se “ex-ante”, um cenário em particular que gerasse erros menores que os demais, é mais confiável buscar ganhos de diversificação, do que depositar a confiança sobre a previsão de um único modelo.

O método de FC foi introduzido, originalmente, em 1969, por Bates e Granjer (BATES, 1969) e, desde então, passou a ser visto como uma forma simples e efetiva de trazer robustez e melhorar a performance das projeções em relação aos modelos individuais. Como resultado, FC é utilizado, largamente, em bancos, setor privado e estudos acadêmicos (CLEMEN, 1989). O desafio continua na busca pelo consenso de qual técnica de FC oferece os melhores benefícios.

Neste trabalho será feita a aplicação de uma técnica de FC em particular, a Análise de Componente Principal (*Principal Component Analysis* - PCA), sobre diversos cenários de consumo de energia elétrica, oriundos de diversos modelos de predição, a fim de compor um cenário-base que contemple os pontos fortes de cada modelo e produza resultados melhores, com menor índice de erro dentre os demais.

#### 4.3 Análise de Componente Principal

A PCA foi desenvolvida, originalmente, por Karl Pearson, em 1901, como uma ferramenta de otimização geométrica em um trabalho no qual se buscava encontrar as retas e planos que melhor se ajustassem a um dado conjunto de pontos em um espaço n-dimensional (JOLLIFFE, 2002). Outros autores, como Hotteling (1936), Thurstone (1931) e Bryant & Atchley (1975), citando o trabalho de Pearson, desenvolveram a PCA, em linhas similares, entretanto, esses autores estavam mais preocupados com a sua aplicação para análise fatorial.

Os comentários de Pearson sobre os cálculos feitos, 50 anos antes da ampla disponibilidade de computadores, são interessantes.

Ele afirma que os seus métodos “podem ser, facilmente, aplicados a problemas numéricos” e, embora ele concorde que os cálculos podem se tornar “pesados” na aplicação para quatro ou mais variáveis, ele sugere que esses são ainda bastante viáveis (JOLLIFFE, 2002).

Uma descrição mais atualizada sobre PCA cita que esta consiste em aplicar-se, sobre um determinado conjunto de variáveis, possivelmente, correlacionadas, sucessivas transformações ortogonais, a fim de se obter um conjunto de variáveis, linearmente, independentes chamadas de Componentes Principais – CP (ARAÚJO, W.O. & COELHO, C. J., 2009).

Em linha com o trabalho de Hotelling (1936), pode-se dizer, ainda, que a PCA é um modelo fatorial no qual os fatores são baseados na variância total.

A idéia mais difundida, atualmente, nas aplicações em engenharia, para a técnica de PCA, é reduzir a dimensão de um conjunto de dados correlacionados para facilitar a sua análise. Esse tipo de aplicação é, largamente, utilizado na análise de sinais, em que a redução da dimensão dos dados é necessária, ao mesmo tempo em que a extração da informação relevante do conjunto de dados não deve ser descartada.

Do exposto, as Componentes Principais, resultantes da aplicação de PCA, podem ser entendidas como uma forma de “resumo” da variância (informação) total contida no conjunto de dados. Assim, como será visto mais a diante, o presente trabalho apresenta a idéia de que este “resumo” pode ser aplicado para traduzir a informação total do conjunto de dados em um único cenário (combinação de projeções). O que, de certa forma, concentra a aplicação da técnica de PCA neste trabalho, no campo da análise fatorial.

#### 4.3.1 PCA – Aplicação

Para discorrer sobre a aplicação de PCA, no presente trabalho, será feita a consideração da aplicação da técnica sobre um conjunto

de dados similar ao utilizado, composto por informações de 32 cenários de previsão ( $x_j$ ) com 126 amostras (leituras mensais) de cada cenário, compondo, assim, a Matriz  $\mathbf{X}_{[126, 32]}$ .

#### 4.3.1.1 Abordagem Algébrica

De posse da matriz  $\mathbf{X}$ , devem ser encontradas diferentes combinações dos cenários de forma a produzir 32 índices  $\mathbf{z}_j$ , não correlacionados, que descrevam a variação nos dados. Esses índices  $\mathbf{Z}_j$  são as componentes principais e a ausência de correlação entre eles (ortogonalidade) indica que estes medem diferentes “dimensões” da informação implícita ao conjunto de cenários.

O primeiro componente principal ( $\mathbf{Z}_1$ ) é, então, a combinação linear dos cenários  $\mathbf{X}_j$  conforme (4.1), de forma que varie tanto quanto o possível.

$$Z_1 = a_{11} X_1 + a_{12} X_2 + \dots + a_{1\ 32} X_{32} \quad (4.1)$$

Contanto que:

$$a_{11}^2 + a_{12}^2 + a_{13}^2 + \dots + a_{1\ 32}^2 = 1 \quad (4.2)$$

A restrição, em (4.2), é introduzida porque se isso não é feito, então,  $Var(Z_1)$  pode ser aumentada e fazer, simplesmente, crescer qualquer um dos valores  $a_{1j}$ .

O segundo componente principal ( $\mathbf{Z}_2$ ) é, então, a combinação linear dos cenários  $\mathbf{X}_j$ , conforme (4.3), de forma que varie o máximo possível, contanto que seja atendida a restrição em (4.4).

$$Z_2 = a_{21} X_1 + a_{22} X_2 + \dots + a_{2\ 32} X_{32} \quad (4.3)$$

$$a_{21}^2 + a_{22}^2 + a_{23}^2 + \dots + a_{2\ 32}^2 = 1 \quad (4.4)$$

A condição de ortogonalidade entre  $\mathbf{Z}_1$  e  $\mathbf{Z}_2$ , também, deve ser atendida e as componentes devem ter correlação zero.



A terceira componente principal ( $Z_3$ ) é, então, a combinação linear dos cenários  $X_j$ , conforme (4.5), de forma que varie o máximo possível, contanto que seja atendida a restrição em (4.6).

$$Z_3 = a_{31} X_1 + a_{32} X_2 + \dots + a_{332} X_{32} \quad (4.5)$$

$$a_{31}^2 + a_{32}^2 + a_{33}^2 + \dots + a_{332}^2 = 1 \quad (4.6)$$

A condição de ortogonalidade entre  $Z_1$ ,  $Z_2$  e  $Z_3$ , também, deve ser atendida e as componentes devem ter correlação zero entre si. Posteriores componentes principais são definidas continuando da mesma maneira. Como, no caso de aplicação existem 32 cenários de projeção, teremos 32 componentes principais, de forma que a componente principal  $Z_{32}$  é, então, a combinação linear dos cenários  $X_j$ , conforme (4.7), de forma que varie o máximo possível contanto que seja atendida a restrição em (4.8).

$$Z_{32} = a_{321} X_1 + a_{322} X_2 + \dots + a_{3232} X_{32} \quad (4.7)$$

$$a_{321}^2 + a_{322}^2 + a_{323}^2 + \dots + a_{3232}^2 = 1 \quad (4.8)$$

A ausência de correlação entre as componentes significa que cada uma mede uma dimensão diferente do conjunto de dados, isto é, cada uma mede uma informação diferente de cada cenário de projeção.

#### 4.3.1.2 Abordagem Geométrica

A abordagem algébrica descrita acima, também, pode ser descrita de um ponto de vista geométrico. Consideremos que as equações em (4.1), (4.3), (4.5) e (4.7), e denotemos por  $Z$  o vetor cujo  $j$ -ésimo elemento,  $Z_j$ , corresponde a  $j$ -ésima CP, com  $j$  representando os cenários propostos, 32 no total. Então,

$$Z = A^T X \quad (4.9)$$

Portanto, as CPs são definidas pela transformação linear ortogonal de  $\mathbf{X}$ , em que  $\mathbf{A}$  é a matriz ortogonal cuja  $j$ -ésima coluna,  $\alpha_j$ , é o  $j$ -ésimo autovetor de  $\Sigma$ .

A Matriz  $\Sigma$  é a matriz de covariância de  $\mathbf{X}$ , em que o elemento  $(i, j)$  representa a covariância entre os cenários  $i$  e  $j$  de  $\mathbf{X}$  quando  $i \neq j$  e a variância do cenário  $j$  quando  $i = j$ .

De forma análoga, temos, também, pelas restrições postas por (4.2), (4.4), (4.6) e (4.8) que

$$\Sigma \mathbf{A} = \mathbf{A} \Lambda \quad (4.10)$$

Outra forma de expressar (4.10) seria

$$\Sigma = \mathbf{A} \Lambda \mathbf{A}^T \quad (4.11)$$

Em que  $\Lambda$ , é uma matriz diagonal cujo  $j$ -ésimo, elemento de sua diagonal é o  $j$ -ésimo autovalor de  $\Sigma$ ,  $\lambda_i$ , e  $\lambda_i = \text{var}(\alpha_i^T x) = \text{var}(z_i)$ . Isto é, os autovalores de  $\Sigma$  são, na realidade, a variância dos elementos de  $\mathbf{Z}$ .

Em resumo, a resolução de um problema de PCA consiste na busca pelos autovalores e autovetores da matriz de covariância dos dados (no caso cenários) em análise.

#### 4.3.2 Decomposição em Valor Singular - SVD

Dada a matriz  $\mathbf{X}_{[126, 32]}$ , composta pelos cenários propostos, esta pode também ser escrita da seguinte forma:

$$\mathbf{X} = \mathbf{U} \mathbf{L} \mathbf{A}^T \quad (4.12)$$

Em que;

- i.*  $\mathbf{U}$ ,  $\mathbf{A}$  são matrizes ortonormais com dimensões  $[126 \times r]$  e  $[32 \times r]$ , respectivamente, de forma que  $\mathbf{U}^T \mathbf{U} = \mathbf{I}$ , e,  $\mathbf{A}^T \mathbf{A} = \mathbf{I}$
- ii.*  $\mathbf{L}$  é uma matriz diagonal

iii.  $r$  é o rank de  $\mathbf{X}$ , isto é, 32.

A importância da SVD para PCA é dupla, primeiramente, a SVD é tida como um método computacionalmente muito eficiente para determinar as CPs. Está claro que, se pudermos encontrar  $\mathbf{U}$ ,  $\mathbf{L}$  e  $\mathbf{A}$  que satisfaçam a equação (4.12), então  $\mathbf{A}$  e  $\mathbf{L}$  nos darão os autovetores e as raízes quadradas dos autovalores de  $\mathbf{X}^T\mathbf{X}$ , e, por conseguinte os desvios padrões das componentes principais. Como se fosse um bônus, temos em  $\mathbf{U}$  uma versão em escala dos CPs scores (JOLLIFFE, 2002).

A segunda virtude da SVD é que esta provê esclarecimentos adicionais sobre o que a PCA realmente faz e nos dá meios úteis de representar os seus resultados algébrica e graficamente.

O algoritmo de aplicação utilizado para o problema proposto, descrito na seção

#### 4.3.3 Padronização dos dados

A aplicação da matriz de covariância em PCA gera um efeito indesejado sobre as CPs. Como, naturalmente, existem diferenças de amplitude entre os cenários em análise, aqueles cenários com maior amplitude tendem a dominar as primeiras CPs (JOLLIFFE, 2002).

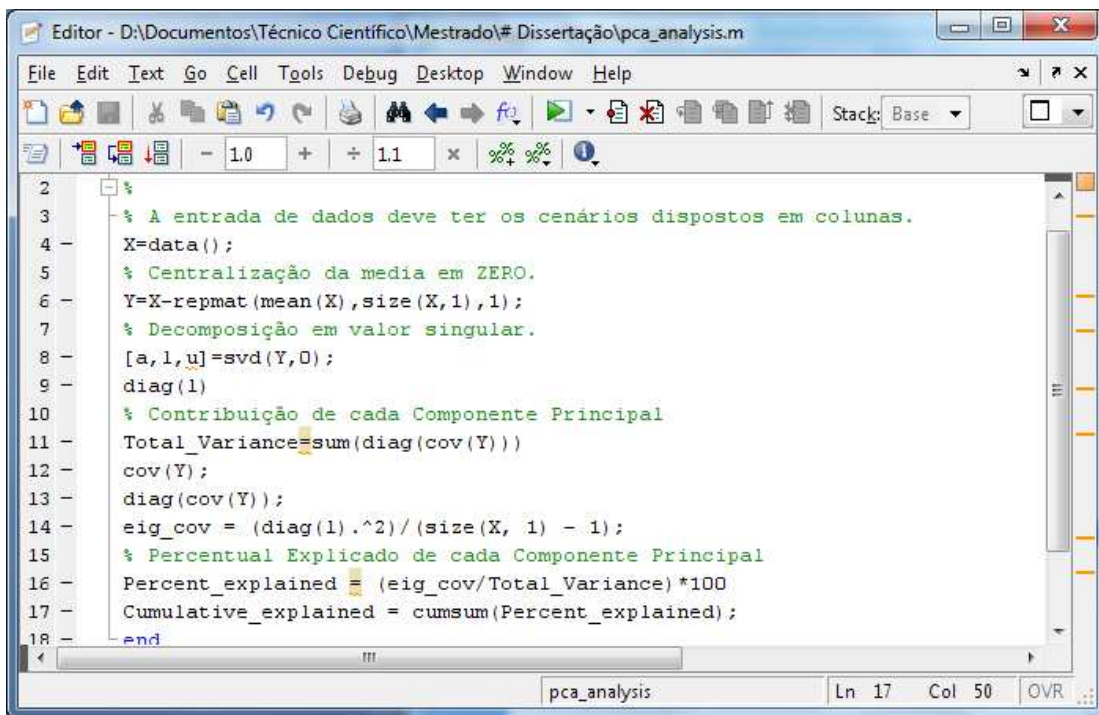
Usualmente, para resolverem-se problemas que envolvam a análise de diferentes unidades de medidas, as variáveis são padronizadas pela sua correspondente variância. Dessa forma, a matriz de covariância  $\Sigma$  passa a ser uma matriz de correlação. A vantagem de aplicação desse método está no caso da necessidade de comparação dos resultados da aplicação de PCA sobre diferentes conjuntos de dados. Entretanto, a aplicação da padronização pela variância não é sempre necessária para o caso de conjuntos de dados medidos na mesma unidade (JOLLIFFE, 2002).

Portanto, buscando padronizar os dados em uma mesma “base” a, fim de reduzir o efeito de concentração sobre as primeiras CPs, os dados foram padronizados centrando a sua média em zero, conforme

descrito no algoritmo da Figura 4.1. Essa técnica, padronização por média zero, já havia sido aplicada com sucesso em (ORTEGA, J.M., PINTO J.O., MILLER, L.L., 2007).

#### 4.3.4 Algoritmo de Aplicação

O sistema de suporte para a aplicação de PCA sobre o conjunto de previsões foi desenvolvido no *software* MATLAB. Abaixo, na Figura 4.1, é descrito a rotina utilizada:



```

Editor - D:\Documentos\Técnico Científico\Mestrado\# Dissertação\pca_analysis.m
File Edit Text Go Cell Tools Debug Desktop Window Help
Stack: Base
- 1.0 + ÷ 1.1 × %>% %>
2 %
3 % A entrada de dados deve ter os cenários dispostos em colunas.
4 X=data();
5 % Centralização da media em ZERO.
6 Y=X-repmat(mean(X),size(X,1),1);
7 % Decomposição em valor singular.
8 [a,l,u]=svd(Y,0);
9 diag(l)
10 % Contribuição de cada Componente Principal
11 Total_Variance=sum(diag(cov(Y)))
12 cov(Y);
13 diag(cov(Y));
14 eig_cov = (diag(l).^2)/(size(X,1) - 1);
15 % Percentual Explicado de cada Componente Principal
16 Percent_explained = (eig_cov/Total_Variance)*100
17 Cumulative_explained = cumsum(Percent_explained);
18 end
pca_analysis Ln 17 Col 50 OVR

```

Figura 4.1 – Aplicação de PCA no MATLAB

Na linha 6 é feita a padronização da matriz dos cenários pela sua média, conforme descrito na seção 4.3.3.

Na linha 8 é chamada a função para Decomposição em Valor Singular – SVD.

Com base no total da variância e a variância de cada CP é calculado o percentual de variância explicada, na linha 16. Com o

percentual de cada componente é então calculado o percentual cumulativo explicado (linha 17).

#### 4.3.5 Função de Aplicação

Para a finalidade do trabalho desenvolvido a PCA apresenta dois aspectos importantes. O primeiro é a capacidade de gerar variáveis de saída para o conjunto de cenários que sejam independentes. É importante lembrar que esta independência é obtida utilizando-se a relação de dependência representada pelas correlações, conforme demonstrado na seção 4.3.1.1.

O segundo aspecto está em se poder gerar uma função representativa do conjunto de respostas. É uma prática comum em problemas de otimização múltipla buscar uma função singular que condense todas as funções objetivo (PAIVA, 2006).

O presente trabalho é uma adaptação desta metodologia para o método de combinação de previsões, onde a função singular realiza a condensação dos cenários estudados. Mais especificamente, a técnica de PCA é utilizada para extrair os autovalores de um conjunto de cenários de previsão para utilizá-los como pesos relativos formando um novo cenário composto por todas as diferentes especificações dos modelos de previsão utilizados na geração destes.

Como o método de FC é na realidade a utilização de uma função singular que combine os cenários de previsão propostos, há a necessidade de se adotar um modelo aditivo ponderado para tal singularização. Para tal, é proposta, na equação (4.12) uma adaptação da técnica apresentada por Paiva (2006), e também já aplicada em Souza et al. (2012), que será chamado de  $FC_{PCA}$ .

Assim, são criadas funções intermediárias, que chamaremos de  $F_i$ , com  $i$  variando de 1 a 32. Conforme descrito pela equação (4.12), cada  $F_i$  é o produto entre a transposição vetor  $A_i$  (que representa os coeficientes da  $CP_i$ ) e a transposição do conjunto de cenários propostos, o que gera um novo vetor  $F_i$ . Desta forma, a ponderação

das funções  $F_i$  é baseada na composição de cada componente principal.

$$F_i = \mathbf{A}_i^T * \mathbf{X}^T \quad (4.12)$$

Sendo assim, são gerados 32 vetores  $F_i$ , representando a projeção dos componentes principais sobre os cenários propostos. Esta informação deve ser agora, singularizada em um único vetor, o que é feito pela função aditiva ponderada demonstrada na equação (4.13) onde cada  $F_i$  é representado pelo respectivo autovalor da matriz de covariância ponderado pelo total da variância do conjunto (somatório dos autovalores).

$$FC_{PCA} = \sum_{i=1}^n \left( \frac{\lambda_i * F_i}{\sum_{i=1}^n \lambda_i} \right) \quad (4.12)$$

Em que;

$\lambda_i$     Autovalor  $i$   
 $n$       Número de cenários

Dessa forma, conforme descrito na figura 4.2, o algoritmo da Figura 4.1 é aplicado sobre o conjunto de cenários de projeção de forma a extrair as componentes principais, a informação de variância total explicada, autovetores e autovalores do conjunto.

Os índices das componentes principais são utilizados na representação de cada componente para o conjunto de dados.

Os autovalores são, então, utilizados como variável de entrada na equação (4.13), que por vez produz um único cenário, resultante da aplicação da *PCA* sobre os cenários originais.

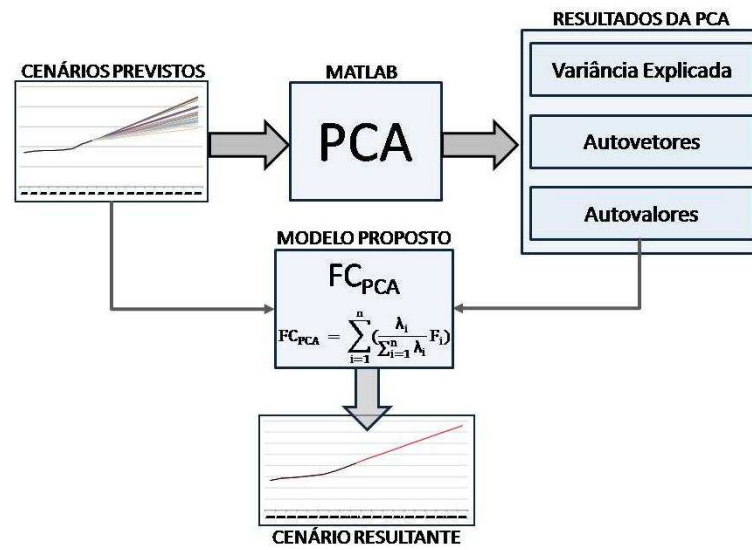


Figura 4.2: Diagrama de blocos da técnica de  $FC_{PCA}$

## CAPÍTULO 5 - O MERCADO DA ENERSUL

### 5.1 Consistência de Dados e Acompanhamento

Todo o trabalho de acompanhamento e consolidação das informações de consumo de energia, número de consumidores e receita (faturamento em R\$) é realizado na Gerência de Planejamento de Mercado. Esse processo envolve a manipulação e tratamento de uma massa de dados significativa, por tratar-se das informações técnicas e comerciais de mais de 800.000 clientes.

A empresa utiliza sistemas de suporte para essa tarefa, entre eles o *Utilities Expert* (UECom) e o *Discoverer*. O *Discoverer* nada mais é que um *software* de *Business Intelligence* dedicado à confecção de relatórios e *data mining* em uma base de dados paralela a do sistema comercial.

Os relatórios extraídos desses sistemas são comparados entre si em diferentes aberturas de informação, como por exemplo, classe de consumo, nível de tensão, município, localidade, tipo de ligação, etc., sendo realizadas diversas consistências a fim de assegurar a integridade da informação.

Esse acompanhamento é armazenado em base mensal no servidor de dados da empresa, e é dividido em: tipo (medido/faturado) classe de serviço, nível de tensão, município/localidade, ramo de atividade.

Juntamente com as informações de mercado, são armazenadas informações de variáveis macroeconômicas como índices inflacionários, PIB, evolução de renda, variáveis demográficas e informações climatológicas como temperatura e chuvas. Em sua maioria, esses dados são obtidos pela internet. Uma fonte fidedigna de indicadores macroeconômicos é o *site* do Instituto de Pesquisa Econômica Aplicada – IPEA, o IPEADATA ([www.ipeadata.gov.br](http://www.ipeadata.gov.br)), que congrega informações macroeconômicas, regionais e sociais.

As informações meteorológicas são adquiridas de duas fontes distintas: um sistema de coleta de medições climáticas (temperatura,



chuvas e umidade relativa) próprio da concessionária e informações do Instituto Nacional de Meteorologia – INMET ([www.inmet.gov.br](http://www.inmet.gov.br)).

O cruzamento entre as informações do mercado consumidor e as variáveis macroeconômicas, climatológicas e demográficas auxilia no entendimento e consistência dos dados de mercado, além de subsidiar a alta direção com relatórios analíticos do desempenho de mercado e receita da área de concessão.

Todo esse processo de acompanhamento e análise provê a equipe técnica de bons subsídios para aplicação nos estudos de projeção, sejam estes de curto, médio ou logo prazo.

O armazenamento dos cenários de consumo de energia projetados e, também, da consequente receita (R\$) assimilada pelo cenário-base, foi sistematizada no servidor de dados da empresa. A opção pela utilização do servidor de dados deve-se pela facilidade de compartilhamento com as demais áreas envolvidas e, também, pela segurança no acesso a esses dados. Para um determinado usuário ter acesso ao servidor deve ser seguida uma rotina de autorizações que envolvem o aval dos executivos da empresa, e para o acesso a uma determinada pasta reservada a uma área específica da empresa, o usuário deve solicitar autorização ao gestor responsável por esta área.

A Figura 5.1 demonstra as etapas do processo de acompanhamento e previsão de mercado como descrito:

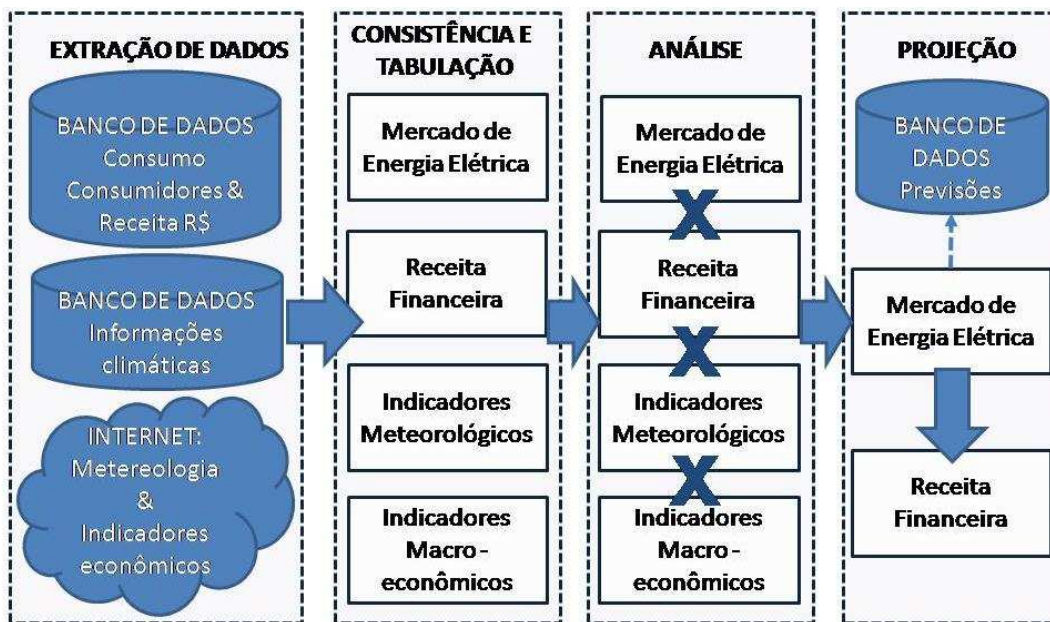


Figura 5.1: Etapas do processo de acompanhamento e previsão de mercado

## 5.2 Composição dos Dados

Na composição dos dados informados, é expurgado o efeito da migração de clientes para o Ambiente de Contratação Livre (ACL) por meio da subtração do seu consumo da série de consumo total da classe.




Figura 5.2 – Evolução de mercado da Classe de Serviço Residencial de 2003 a 2011

Verifica-se que a classe industrial apresenta uma “quebra estrutural”, em 2009, causada pela crise do *subprime* que atingiu, especialmente, a produção industrial brasileira (CNI, 2009).

### 5.3 Período de Análise

Conforme já explicitado no Capítulo 02, em abril de 2001, o nível dos reservatórios do SIN encontrava-se em torno de 32% da sua capacidade de armazenamento e o risco de *déficit* superava 15%, ou seja, dez pontos percentuais acima do risco aceitável para o SIN, que é de 5% (cinco). Dessa forma, no dia 1 de julho de 2001, foram adotadas medidas urgentes, pelo governo, com objetivo de reduzir o consumo de energia no sistema para evitar um colapso. O racionamento foi estabelecido por intermédio de cotas e cortes no fornecimento de energia, com a pretensão de reduzir o consumo total entre 20% e 30%.

Essas medidas, além de exercerem um efeito contracionista sobre a economia, alteram os hábitos do uso de energia elétrica de forma radical, causando uma redução histórica do nível de Consumo de Energia Elétrica, que ficaram 7% abaixo das previsões de mercado. Com o término do período de racionamento, o consumo não atingiu, imediatamente, os mesmos patamares anteriores com retorno à normalidade acontecendo gradativamente.

Devido a esse fato, o trabalho foca seus estudos no período pós-acionamento, isto é, a partir de janeiro de 2003. Esse tipo de consideração já foi aplicado em outros estudos (STORCK, 2008) e diversos trabalhos foram realizados a respeito do impacto do racionamento sobre o comportamento do consumidor (FALCO, 2004), em especial o residencial, que performa um novo comportamento em relação ao período pré-crise.

#### 5.4 Estrutura de Mercado

Com apoio da Enersul, foi acessado o banco de dados de mercado com as séries históricas de consumo de energia elétrica da área de concessão. O banco de dados está estruturado com informações de consumo medido e consumo faturado<sup>3</sup> em kWh, com periodicidade mensal e abertura por classe de serviço<sup>4</sup> e nível de tensão. Dado ao fato do consumo medido representar melhor o ponto de operação dos consumidores (por descartar os limites mínimos de faturamento) e por ser este o parâmetro utilizado nos estudos da Enersul, optou-se por trabalhar com essa informação.

A informação histórica do consumo medido de energia elétrica do mercado cativo da Enersul é um dado público e está disponibilizada, neste trabalho, em base mensal no ANEXO I – Séries Históricas de Mercado Medido.

A participação das classes de serviço, no mercado de vendas da Enersul, é demonstrada na figura 5.3:




Figura 5.3 - Participação por Classe de Serviço no Mercado de Vendas da Enersul em 2011

<sup>3</sup> Sempre que o Consumo Medido, aplicável ao faturamento mensal, de uma unidade consumidora do grupo B for inferior aos limites mínimos do custo de disponibilidade do sistema elétrico é aplicável o custo de disponibilidade para aquela situação (Art. 98 Resolução Normativa ANEEL 414/2010). O consumo, considerando esta regra, é chamado de Consumo Faturado.

<sup>4</sup>As classes de serviço obedecem ao disposto no Art. 5 da Resolução Normativa ANEEL 414/2010 e são: Residencial, Comercial, Industrial, Rural, Poder Público, Serviço Público, Iluminação Pública e Consumo Próprio.

Percebe-se que a classe com maior participação é a classe residencial, com 35% do mercado de vendas, seguido logo mais pelas classes comercial (24%), industrial (15%) e rural (11%). As demais classes representam um total de 15% do mercado.

#### 5.4.1 Classe Residencial

Conforme exposto pela Figura 5.3, a classe residencial possui a maior participação no mercado de vendas da Enersul. Portanto, a assertividade da sua projeção é a que toma maior preocupação dos analistas entre todas as classes de serviço.

A Figura 5.4, que representa a classe residencial, apresenta particularidades interessantes de desempenho no período de 2003 a 2010. Da sua análise percebem-se dois períodos distintos de evolução:

- 2003 a 2008: Período de crescimento moderado com taxa de evolução média geométrica de +2,2%;
- 2008 a 2010: Período de forte expansão, registrando uma taxa média de evolução de +9,9% ao ano.




Figura 5.4 – Evolução de mercado da Classe de Serviço Residencial de 2003 a 2011

#### 5.4.2 Classe Comercial

As três classes com maior participação no mercado de vendas da ENERSUL são residencial, comercial e industrial e essas três classes representam cerca de 75% do mercado de vendas da empresa. Dentre estas, a classe comercial apresenta o segundo melhor desempenho global, porém seu último período de expansão (2.009 a 2.011) é o mais robusto dentre as três classes. Da sua análise percebem-se três períodos distintos de evolução (Figura 5.5):

1. 1996 a 2000: Taxa média de evolução anual de +7,9%. Esse comportamento foi interrompido pelo racionamento de 2001;
2. 2002 a 2008: Período de crescimento mais moderado com taxa média de evolução anual de +3,6%;
3. 2009 a 2011: Novo período de forte expansão, registrando uma taxa média de evolução de 9,6% ao ano.




Figura 5.5 – Evolução de mercado das Classes de Serviço considerando 1996 = 100

Na Figura 10, as séries foram todas colocadas na mesma base, fazendo o ponto correspondente a 1996 = 100 para poder comparar suas diferentes evoluções.

Em complemento, no período 2007 a 2011, seis clientes saíram do mercado cativo da classe comercial da Enersul para o Ambiente de Contratação Livre, representando um consumo médio de 2GWh/mês. O consumo cativo desses clientes, no período em que sua energia era adquirida da concessionária, foi expurgado da série de consumo total a fim de que esta refletisse apenas a informação do comportamento dos clientes cativos da empresa.

#### 5.4.3 Classe Industrial

Das três classes com maior participação no mercado da Enersul, a classe industrial é a menos representativa, com 15% das vendas de energia em 2011. Entretanto, conforme se pode verificar, na figura 10, essa classe é a que apresenta a melhor evolução entre as três no período pós-acionamento. Entre os anos de 2002 e 2005, em que as classes residencial e comercial apresentaram um cenário de estagnação, a classe industrial evoluiu a uma taxa geométrica de 7,7% a.a.

Verifica-se, na Figura 11, que esse crescimento pujante é interrompido, em 2006, com a crise da pecuária causada pela febre aftosa que culminou com a restrição da importação de carne bovina produzida, no Mato Grosso do Sul, por parte de alguns países como Rússia, Chile e Inglaterra. Essa restrição causou uma queda de US\$ 190 milhões nas exportações brasileiras (SILVA, T. G. R & MIRANDA, S. H. G., 2007), das quais o Mato Grosso do Sul foi o principal estado afetado. A indústria local, cujo setor mais eletro intensivo era o de frigoríficos, foi o ramo econômico mais afetado, impacto demonstrado pelo arrefecimento no consumo da classe industrial.




Figura 5.6 – Evolução da classe industrial no período de 1996 a 2011

O crescimento é retomado, em 2007 e 2008, anos que apresentaram taxa média de crescimento de 11,3%, marcando um processo consistente de industrialização do estado e a entrada de novos ramos de atividade, como a celulose, e o fortalecimento da indústria de metalurgia e extração mineral. Porém, a crise do *subprime* (CNI, 2009), em 2009, novamente, causou uma quebra dessa tendência. Entretanto, verifica-se uma retomada no desempenho do consumo da classe industrial nos, anos de 2010 e 2011 (Figura 5.6), apresentando taxas de evolução da ordem de 8%.

Todas essas “quebras” conjunturais na classe industrial, por si só, criam certa dificuldade de descrição para os modelos matemáticos. Aliado a essa dificuldade, ainda existe a questão da migração de grandes blocos de consumo para o ACL, fato existente, também, na classe comercial, porém, que se apresenta com maior intensidade na classe industrial. Cerca de 40% da energia distribuída a consumidores da classe industrial, em 2011, eram oriundos pelo Ambiente de Comercialização Livre. Para evitar descontinuidades causadas pela migração desses blocos de energia para o ACL, foi retirado da série de consumo industrial todo o histórico do consumo cativo dos clientes que optaram pela contratação de energia no ambiente livre até 2011.



## CAPÍTULO. 6 - DESENVOLVIMENTO

### 6.1 Classes de Serviço Estudadas

Conforme exposto no Capítulo 5, as classes de serviço residencial, comercial e industrial, juntas, representam um total de 74% do mercado de vendas da ENERSUL. Posto isso, é evidente que a preocupação com a assertividade repouse, essencialmente, sobre essas classes. Há, também, o fato de que, não somente a representatividade das demais classes seja pequena, mas o seu valor absoluto (consumo kWh), também, é pequeno, fato este que causa, não raramente, comportamento explosivo para essas séries.

É fato que séries com comportamento explosivo são de difícil tratamento, e sua propriedade de estacionariedade, dificilmente, é atingida. Portanto, as classes, rural, poder público, iluminação pública, serviços públicos e consumo próprio, normalmente, são analisadas à parte, com metodologias próprias, amparadas por estudos de campo. Essas classes não serão abordadas no presente trabalho.

### 6.2 Cenários de Projeção

Na elaboração do plano decenal da empresa, realizado, anualmente, entre os meses de agosto e outubro, para a preparação das projeções para as classes de serviço estudadas (residencial, comercial e industrial), foram utilizados todos os *softwares* de projeção disponibilizados pela empresa (descritos no Capítulo 03).

O resultado do plano decenal dá subsídios ao planejamento orçamentário da companhia e contempla atender, sobretudo, as demandas setoriais de planejamento elétrico e energético (EPE- Empresa de Planejamento Energético & ONS - Operador Nacional do Sistema).

As simulações (projeções) são realizadas por diversas vezes em cada software de forma que seja obtido um número de seis cenários plausíveis (de possível realização) para cada modelo

estudado. A avaliação das simulações é feita com base na análise das taxas de incremento das projeções frente às taxas históricas das séries de consumo, os cenários que não demonstram um mínimo de aderência são descartados.

Conforme demonstra a Tabela 6.1, exceto pelos *softwares* “Proj” e “Predict”, dos quais foi possível empregar apenas um cenário, cada *modelo* deu origem a seis diferentes cenários de predição de consumo, totalizando um universo de 32 cenários para cada classe de serviço para proceder à aplicação da técnica de FC.

Software	Origem	Modelo	Cenários
Eviews	Comercial	ARIMA	6
		Holt Winters Aditivo	6
		Holt Winters Multiplicativo	6
Minitab	Comercial	Holt Winters Aditivo	6
Engenho	Desenvolvido via P&D	Hilbert Spaces	6
Predict	Desenvolvido via P&D	Redes Neurais Artificiais (RNA)	1
Proj	Desenvolvimento Interno	Decomposição de ST	1
<b>Total de Cenários</b>			<b>32</b>

Tabela 6.1 – *Softwares*/modelos utilizados na elaboração dos cenários

### 6.2.1 Classe Residencial

A Figura 6.1 demonstra, em função do tempo, a disposição dos cenários resultantes da previsão do mercado de consumo residencial de cada software/modelo utilizado. Destaca-se o distanciamento entre as séries, especialmente, no final do horizonte (2021) em que a abertura do “cone de projeções” chega a 791,5 GWh, o que representaria um desvio hipotético de 54%, no caso da escolha pelo cenário mais “pessimista” e a realização do mais “otimista”.




Figura 6.1 – Consumo anual da classe residencial (preto) e os 32 cenários previstos

Com a aplicação da técnica de PCA, por meio do algoritmo descrito, anteriormente, na Figura 4.1, foram encontrados os seguintes autovalores e a explicação da variância total conforme demonstrado na Tabela 6.2:

Eigenvalues	% da Variância Explicada
1.133.900,00	98,4490
128.000,00	1,2536
43.200,00	0,1430
31.100,00	0,0739
18.000,00	0,0247
16.400,00	0,0206
14.000,00	0,0151
8.900,00	0,0061
7.800,00	0,0046
6.200,00	0,0030
5.500,00	0,0023
4.700,00	0,0017
3.200,00	0,0008
2.900,00	0,0006
2.600,00	0,0005
1.300,00	0,0001
1.300,00	0,0001
900,00	0,0001
700,00	0,0000
500,00	0,0000
400,00	0,0000
400,00	0,0000
200,00	0,0000
100,00	0,0000
100,00	0,0000
0,00	0,0000
0,00	0,0000
0,00	0,0000
0,00	0,0000
0,00	0,0000
0,00	0,0000
0,00	0,0000
0,00	0,0000

Tabela 6.2 – Autovalores e % da variância explicada do conjunto de cenários

É possível avaliar que, ao considerar apenas um dos cenários, a maior parte da variância (98%) é contemplada. Isso pode ser explicado pelo fato de que o conjunto de previsões aqui estudado é composto, unicamente, por modelos univariados, diferentes entre si, mas que utilizam apenas o seu comportamento passado para descrever o futuro. Dessa forma, ao examinarmos a equação (3.4), percebemos que as componentes  $T_t$  e  $S_t$  pouco se podem diferenciar

entre os modelos, pois, apesar da aplicação de diferentes técnicas para descrevê-las, estas são oriundas de uma mesma série de dados (modelos univariados). Assim, a diferença entre a informação de variância extraída pela aplicação de *PCA* é oriunda, basicamente, da componente aleatória  $a_t$ . Na prática, verifica-se que, apesar da pouca variância explicada ao se incluir os demais cenários, essa informação é importante e não deve ser descartada, pois possibilita que o novo cenário agregue a informação dos demais cenários, impedindo que este se baseie apenas na informação de uma única série, que pode estar equivocada para um dado período do tempo.

Portanto, o objetivo deste trabalho, com a aplicação de *PCA*, não é realizar a opção por um determinado cenário, mas sim conceber um novo cenário que agregue as características de todos os modelos propostos.

A equação (4.12) foi aplicada sobre o conjunto de cenários propostos juntamente com os componentes principais encontrados. A equação (6.1) demonstra a aplicação da primeira componente principal sobre o conjunto de cenários propostos para a classe residencial.

$$\begin{aligned}
 F_i = & -0,1281 * RESADD2007 + 0,1670 * res_{2008} - 0,2251 * RESADD2008 + \\
 & 0,0541 * RESADD2006 + 0,5046 * HWA2008 + 0,3840 * res_{2007} + 0,0041 * \\
 & RESMULT2008 + 0,0133 * RESMULT2007 - 0,3548 * RESMULT2004 - 0,1377 * \\
 & RESADD2004 + 0,1962 * RESADD2005 + 0,0714 * RESMULT2006 - 0,1563 * \\
 & RESADD2003 + 0,0939 * HWA2007 + 0,1166 * HWA2006 + 0,0872 * Decomp - 0,1773 * \\
 & ARIMA2007 + 0,0302 * RESMULT2005 - 0,0347 * ARIMA2006 - 0,0150 * ARIMA2005 + \\
 & 0,0130 * ARIMA2003 - 0,1845 * RESMULT2003 + 0,1699 * res_{2006} - 0,1149 * \\
 & ARIMA2004 - 0,0868 * ARIMA2008 - 0,1926 * HWA2004 - 0,1538 * HWA2003 + 0,1 * \\
 & HWA2005 + 0,0768 * RN - 0,0672 * res_{2005} + 0,1354 * res_{2004} + 0,1996 * res_{2003}
 \end{aligned}
 \tag{6.1}$$

Sendo assim, procede-se a aplicação de (4.13) para realizar a combinação das projeções. Verifica-se, pelo exame da equação (6.2), cada cenário resultante,  $F_i$ , sendo multiplicado pelo coeficiente correspondente na Tabela 6.2.

A fim de simplificar a demonstração, dividimos cada autovalor por 100.000. Assim, temos a expressão (6.2) para o cenário resultante ( $FC_{PCA}$ ):

$$\begin{aligned}
 FC_{PCA} = & \frac{1,1339}{1,4323} * F_1 + \frac{0,1280}{1,4323} * F_2 + \frac{0,0432}{1,4323} * F_3 + \frac{0,0311}{1,4323} * F_4 + \frac{0,0180}{1,4323} * F_5 + \frac{0,0164}{1,4323} * F_6 + \\
 & \frac{0,0140}{1,4323} * F_7 + \frac{0,0089}{1,4323} * F_8 + \frac{0,0079}{1,4323} * F_9 + \frac{0,0062}{1,4323} * F_{10} + \frac{0,0055}{1,4323} * F_{11} + \frac{0,0047}{1,4323} * F_{12} + \frac{0,0032}{1,4323} * \\
 & F_{13} + \frac{0,0029}{1,4323} * F_{14} + \frac{0,0026}{1,4323} * F_{15} + \frac{0,0013}{1,4323} * F_{16} + \frac{0,0013}{1,4323} * F_{17} + \frac{0,0009}{1,4323} * F_{18} + \frac{0,0007}{1,4323} * F_{19} + \\
 & \frac{0,0005}{1,4323} * F_{20} + \frac{0,0004}{1,4323} * F_{21} + \frac{0,0004}{1,4323} * F_{22} + \frac{0,0002}{1,4323} * F_{23} + \frac{0,0001}{1,4323} * F_{24} + \frac{0,0000}{1,4323} * F_{25} + \\
 & \frac{0,0000}{1,4323} * F_{26} + \frac{0,0000}{1,4323} * F_{27} + \frac{0,0000}{1,4323} * F_{28} + \frac{0,0000}{1,4323} * F_{29} + \frac{0,0000}{1,4323} * F_{30} + \frac{0,0000}{1,4323} * F_{31} + \\
 & \frac{0,0000}{1,4323} * F_{32}
 \end{aligned} \tag{6.2}$$

O cálculo dessa equação, para cada amostra das séries do conjunto de previsões e sua posterior integralização em período anual, resultou no cenário exposto pela Figura 6.2:




Figura 6.2 – Consumo anual da classe residencial, cenários previstos e resultado da aplicação da  $FC_{PCA}$  (vermelho)

### 6.2.2 Classe Comercial

A Figura 6.3 demonstra, em função do tempo, a disposição dos cenários resultantes da previsão do mercado de consumo comercial de cada *software*/modelo utilizado. O distanciamento entre as séries, especialmente, no final do horizonte (2021), em que a abertura do “cone de projeções” chega a 674,6 GWh, o que representaria um desvio hipotético de 38%, no caso da escolha pelo cenário mais “pessimista” e a realização do mais “otimista”.




Figura 6.3 – Consumo anual da classe comercial (preto) e os 32 cenários previstos

Da análise do gráfico, destaca-se o comportamento do cenário ARIMA2008, resultante da aplicação de uma modelagem ARIMA com dados, de 2008 a 2011, no Minitab. O cenário apresentou comportamento “explosivo” como consequência do curto período amostral, considerado apenas a partir de janeiro de 2008. Como já demonstrado no Capítulo 5, a classe comercial apresentou um comportamento muito distinto, no período 2009 a 2011, com expansão média de 9,6% ao ano. Como a modelagem ARIMA é univariada e não havia elementos históricos, no período analisado,

que “suavizassem” seu comportamento, a previsão apenas refletiu o comportamento explosivo da amostra.

Com a aplicação da técnica de *PCA*, por meio do algoritmo descrito na Figura 4.1, foram encontrados autovalores e explicação da variância total, conforme demonstrado na Tabela 6.3:

Eigenvalues	% da Variância Explicada
843.120,00	98,0116
110.020,00	1,6691
35.730,00	0,1760
26.670,00	0,0981
11.510,00	0,0183
8.830,00	0,0107
6.550,00	0,0059
5.470,00	0,0041
4.980,00	0,0034
3.140,00	0,0014
2.270,00	0,0007
1.500,00	0,0003
1.050,00	0,0002
890,00	0,0001
530,00	0,0000
450,00	0,0000
330,00	0,0000
260,00	0,0000
240,00	0,0000
150,00	0,0000
100,00	0,0000
60,00	0,0000
30,00	0,0000
10,00	0,0000
0,00	0,0000
0,00	0,0000
0,00	0,0000
0,00	0,0000
0,00	0,0000
0,00	0,0000
0,00	0,0000
0,00	0,0000
0,00	0,0000
0,00	0,0000

Tabela 6.3 – Autovalores e % da variância explicada do conjunto de cenários para a classe comercial



A exemplo da equação (6.1), as equações (4.12) e (4.13) foram aplicadas sobre o conjunto de cenários propostos para a classe comercial e os autovalores encontrados para calcular a proporção total de variância explicada por cada CP. Verifica-se, por seu exame, cada cenário sendo multiplicado pelo coeficiente correspondente na Tabela 6.3.

A fim de simplificar a demonstração, dividimos cada autovalor por 100.000. Dessa forma, temos a expressão (6.2) para o cenário resultante ( $FC_{PCA}$ ) da classe Comercial:

$$\begin{aligned}
 FC_{PCA} = & \frac{8,4312}{10,6389} * F_1 + \frac{1,1002}{10,6389} * F_2 + \frac{0,3573}{10,6389} * F_3 + \frac{0,2667}{10,6389} * F_4 + \frac{0,1151}{10,6389} * F_5 + \\
 & \frac{0,0883}{10,6389} * F_6 + \frac{0,0655}{10,6389} * F_7 + \frac{0,0547}{10,6389} * F_8 + \frac{0,0498}{10,6389} * F_9 + \frac{0,0314}{10,6389} * F_{10} + \frac{0,0227}{10,6389} * F_{11} + \\
 & \frac{0,0150}{10,6389} * F_{12} + \frac{0,0105}{10,6389} * F_{13} + \frac{0,0089}{10,6389} * F_{14} + \frac{0,0053}{10,6389} * F_{15} + \frac{0,0045}{10,6389} * F_{16} + \frac{0,0033}{10,6389} * F_{17} + \\
 & \frac{0,0026}{10,6389} * F_{18} + \frac{0,0024}{10,6389} * F_{19} + \frac{0,0015}{10,6389} * F_{20} + \frac{0,0010}{10,6389} * F_{21} + \frac{0,0006}{10,6389} * F_{22} + \frac{0,0003}{10,6389} * F_{23} + \\
 & \frac{0,0001}{10,6389} * F_{24} + \frac{0,0000}{10,6389} * F_{25} + \frac{0,0000}{10,6389} * F_{26} + \frac{0,0000}{10,6389} * F_{27} + \frac{0,0000}{10,6389} * F_{28} + \frac{0,0000}{10,6389} * F_{29} + \\
 & \frac{0,0000}{10,6389} * F_{30} + \frac{0,0000}{10,6389} * F_{31} + \frac{0,0000}{10,6389} * F_{32} \qquad (6.3)
 \end{aligned}$$

O cálculo dessa equação, para cada amostra das séries do conjunto de previsões e sua posterior integralização em período anual, resultou no cenário exposto pela Figura 6.4:




Figura 6.4 – Consumo anual da classe comercial, cenários previstos e resultado da aplicação da  $FC_{PCA}$  (vermelho).

### 6.2.3 Classe Industrial

A Figura 6.5 demonstra, em função do tempo, a disposição dos cenários resultantes da previsão do mercado de consumo Industrial de cada *software*/modelo utilizado e, também, do cálculo resultante de  $FC_{PCA}$  para a classe industrial (em vermelho). Graficamente, pode-se verificar que a aplicação dos modelos dessa classe apresentam resultados mais heterogêneos, ao longo prazo, do que os resultados verificados para as classes anteriores. Isso devido à existência de diversas “quebras” estruturais no histórico da série, como já descrito no Capítulo 5, seção 5.4.3.

O distanciamento entre as séries, especialmente, no final do horizonte (2021), chega a 284,9 GWh, o que representaria um desvio hipotético de 33%, no caso da escolha pelo cenário mais “pessimista” e a realização do mais “otimista”.




Figura 6.5 – Consumo anual da classe Industrial, cenários previstos e resultado da aplicação da  $FC_{PCA}$  (vermelho)

Os autovalores e explicação da variância total encontrados pela aplicação de PCA sobre os cenários propostos, utilizados no cálculo da  $FC_{PCA}$  para a classe industrial, são demonstrados na Tabela 6.4:

Eigenvalues	% da Variância Explicada
366.550	97,6332
41.980	1,2808
31.700	0,7305
17.540	0,2236
8.410	0,0513
7.290	0,0387
4.790	0,0166
3.510	0,0089
2.950	0,0063
2.450	0,0044
2.030	0,0030
1.370	0,0014
960	0,0007
530	0,0002
490	0,0002
320	0,0001
250	0,0000
200	0,0000
180	0,0000
80	0,0000
70	0,0000
20	0,0000
10	0,0000
0	0,0000
0	0,0000
0	0,0000
0	0,0000
0	0,0000
0	0,0000
0	0,0000
0	0,0000
0	0,0000
0	0,0000
0	0,0000
0	0,0000

Tabela 6.4 – Autovalores e % da variância explicada do conjunto de cenários para a classe industrial

### 6.3 Avaliação de Desempenho

Para avaliar o desempenho do cenário proposto pela  $FC_{PCA}$ , foram levantadas três das medidas de desempenho mais utilizadas para avaliar técnicas estatísticas de previsão (DIEBOLD, F. X. & LOPEZ, J. A., 1996): o Erro Percentual Médio Absoluto (*Mean*

*Absolute Percentage Error - MAPE*) (6.4), a Raiz Quadrada do Erro Médio (*Root Mean Squared Error – RMSE*) (6.5) e o Erro Médio Absoluto (*Mean Absolute Error - MAE*) (6.6):

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{x_i - \hat{x}_i}{x_i} \right| * 100 \quad (6.4)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (x_i - \hat{x}_i)^2}{n}} \quad (6.5)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |x_i - \hat{x}_i| \quad (6.6)$$

Em que:

$x_i$  Consumo de Energia Elétrica observado no mês "i"

$\hat{x}_i$  Previsão para o Consumo de Energia Elétrica para o mês "i"

Observa-se que, enquanto a medida *MAPE* fornece uma orientação relativa (%) sobre o quanto o modelo está errando, as medidas *MAE* e *RMSE* mostram o desvio absoluto (em kWh). O *RMSE* apresenta uma propriedade interessante: devido a sua característica quadrática, este é mais sensível aos desvios com maior amplitude, penalizando a série de predição quando esta apresenta pontos com ajuste deficiente. As medidas *MAPE* e *MAE* são, possivelmente, mais aplicadas nesse tipo de avaliação (longo prazo), por realizar uma análise totalizada da série, o que é interessante nos casos em que as penalizações, por desvio de projeção, são realizadas em prazos maiores, como no caso da compra de energia elétrica, em que a avaliação do desvio é anual.

Para comparar o desempenho geral, entre os diversos modelos com base nas três medidas de desempenho apresentadas (*MAPE*, *MAE* e *RMSE*), foi utilizado o produto dos resultados de *MAPE*, *MAE* e *RMSE* para gerar uma "pontuação". O produto (multiplicação) das medidas foi escolhido por ser equivalente à aplicação da propriedade associativa entre estas.

Sendo assim, a pontuação de cada cenário( $i$ ) é dada por:

$$Pontuação_i = \frac{MAPE_i * MAE_i * RMSE_i}{1.000} \quad (6.7)$$

### 6.3.1 Período utilizado para avaliação

Embora os estudos de Ashley (ASHLEY, 2003) indiquem ser necessária uma amostra com mais de 100 elementos para tomar-se uma decisão conclusiva a cerca da assertividade de um ou outro modelo, essa indicação é para o caso da escolha por um modelo “*ex-ante*” e verificação do impacto de seus resultados. Como, no caso, a proposta deste trabalho é pela aplicação da  $FC_{PCA}$ , queremos, agora, considerando já a realização do período de aplicação do método, medir o seu desempenho e comparar com os cenários, originalmente, propostos e com o cenário, originalmente, escolhido pela distribuidora. Para tanto, entendeu-se que uma análise com período da amostra, iniciando logo após a realização dos estudos até a finalização do ano posterior (onde uma nova sequência de estudos já teria sido realizada), embora com uma amostra pequena (18 meses), seria bem adequada por refletir o real impacto produzido pela opção de utilizar a  $FC_{PCA}$  como cenário-base.

Logo, como as séries de predição têm início em julho de 2011, foram utilizados os dados realizados de consumo do período de julho de 2011 a dezembro de 2012 para a avaliação do erro.


### 6.3.2 Classe Residencial

A Figura 6.6 demonstra o comportamento mensal dos 32 cenários e da  $FC_{PCA}$  (vermelho), frente ao consumo realizado da classe residencial (preto). Pode-se verificar um comportamento irregular (não foi descrito por nenhum modelo) no consumo verificado a partir do mês de março de 2012. Em março de 2012, o consumo registrou incremento de +10,7% sobre março de 2011. Esse

comportamento é explicado, nomeadamente, pelas elevadas temperaturas registradas no período, registrando uma média de temperaturas máximas +8,1% acima do mesmo período do ano anterior. É perceptível, por meio da análise gráfica, que nenhum dos modelos aqui apresentados, foi capaz de prever essa anomalia.

O ano de 2012 foi, excepcionalmente, um ano de difícil descrição. Logo após o elevado consumo registrado no mês de março, ocorre uma súbita contração, no período entre abril e julho, para, então, ocorrer uma nova retomada de crescimento no último semestre. Destaque para o consumo registrado no mês de dezembro, que ficou 15,1% acima do consumo registrado no mesmo mês do ano anterior.

Deve-se evidenciar que, usualmente, quando os modelos prevêem taxas explosivas como essa, são, imediatamente, descartados pelos analistas, pelo risco elevado que se incorre em utilizar taxas, raramente, encontradas no histórico da série. Entretanto, para a aplicação de FC, todos os elementos, mesmo os explosivos, são importantes, pois, se há uma probabilidade de ocorrência estes devem contribuir para o cenário final.



Com base na pontuação calculada por (6.7), os cenários foram ranqueados do melhor para o pior resultado. A Tabela 6.5 demonstra o resultado dos 32 modelos estudados mais a  $FC_{PCA}$ . É possível verificar que a técnica proposta,  $FC_{PCA}$ , atingiu o melhor desempenho com base na pontuação, o que significa que possui o melhor desempenho, levando em conta a associação das medidas. A  $FC_{PCA}$ , também, foi a melhor na avaliação MAPE (2,823%) e apresentou o segundo melhor desempenho de MAE (3.172 MWh).

O modelo que obteve o melhor desempenho avaliado pelo RMSE, *RESADD2008*, teve um desempenho, consideravelmente, mais fraco nas medidas de MAE e MAPE, colocando-o em quarto lugar no índice geral.

Os modelos *RESADD2008* e *res\_2008* obtiveram bons valores de MAPE e MAE e o *res\_2008* apresentou um desempenho muito bom medido pelo RMSE:



Rank	Pontuação	Software	Modelo/ Cenário	MAPE (%)	MAE (MWh)	RMSE (MWh)
1	14.908	FC <sub>PCA</sub>	FC <sub>PCA</sub>	2,823	3.178	1.662
2	15.517	Eviews HW	RESMULT2008	2,828	3.172	1.730
3	16.908	Engenho	res_2008	3,126	3.486	1.551
4	17.152	Eviews HW	RESADD2008	3,218	3.556	1.499
5	20.603	Eviews HW	RESMULT2006	2,844	3.225	2.246
6	20.712	Minitab	HWA2008	3,387	3.805	1.607
7	29.791	Eviews HW	RESADD2007	3,591	4.137	2.005
8	32.920	Eviews HW	RESMULT2004	3,458	4.000	2.380
9	34.913	Eviews HW	RESMULT2007	3,535	4.066	2.429
10	37.285	Engenho	res_2007	3,701	4.276	2.356
11	37.671	Eviews HW	RESADD2006	3,870	4.505	2.161
12	57.324	Minitab	HWA2007	4,126	4.787	2.902
13	62.168	Excel	Decomp	4,423	5.118	2.746
14	65.747	Eviews HW	RESADD2005	4,471	5.225	2.814
15	74.719	Eviews HW	RESADD2004	4,637	5.452	2.955
16	80.437	Minitab	HWA2006	4,620	5.388	3.231
17	81.875	Eviews	ARIMA2008	4,237	4.937	3.915
18	83.402	Eviews HW	RESADD2003	4,716	5.538	3.193
19	84.255	Eviews HW	RESMULT2005	4,631	5.375	3.385
20	93.862	Eviews	ARIMA2007	4,321	5.069	4.286
21	114.640	Eviews HW	RESMULT2003	5,096	5.902	3.812
22	119.634	Engenho	res_2006	5,020	5.826	4.091
23	141.075	Eviews	ARIMA2005	5,020	5.903	4.761
24	146.999	Eviews	ARIMA2003	5,105	5.992	4.806
25	147.206	Eviews	ARIMA2006	5,155	6.036	4.731
26	173.696	Eviews	ARIMA2004	5,509	6.450	4.889
27	183.096	Minitab	HWA2005	5,806	6.752	4.670
28	194.276	Minitab	HWA2004	5,986	6.980	4.650
29	206.856	Minitab	HWA2003	6,057	7.061	4.837
30	390.093	Predict	RN	7,706	8.732	5.797
31	419.621	Engenho	res_2005	7,380	8.458	6.723
32	828.348	Engenho	res_2004	9,335	10.596	8.374
33	1.046.454	Engenho	res_2003	10,085	11.423	9.084

Tabela 6.5 – Rank por pontuação dos cenários da classe residencial

Embora a  $FC_{PCA}$  apresente o melhor desempenho na pontuação geral, a grande vantagem de sua aplicação é de poder garantir, antes da avaliação de desempenho, que o cenário resultante trará a melhor composição de informação possível. Essa característica da combinação de previsões é muito importante do ponto de vista do tomador de decisões, pois este não possui a informação do futuro em mãos para aplicar as medidas de desempenho e optar pelo melhor cenário.

Como exemplo, cita-se que o cenário escolhido pelo *board* de gestores, na ocasião da elaboração dessas previsões, havia sido o *res\_2007*, que ficou em décimo colocado com base na pontuação geral e apresentou um MAPE de 3,7%. Esse cenário havia sido escolhido, pois, na ocasião, com base nos desvios dentro da amostra, mostrava-se ser a melhor opção.

### 6.3.3 Classe Comercial

A classe comercial apresenta resultados interessantes. Conforme pode ser avaliado na Figura 6.7, a exemplo da classe residencial, ocorreu um “descolamento” no comportamento da classe a partir do mês de julho de 2012. Nesse momento, a classe “foge” do seu comportamento habitual e, a partir do mês de setembro, assume um nível de realização superior, o que foi previsto apenas pelo modelo *ARIMA2008*. Esse modelo, do *software Eviews*, devido a sua descrição, conforme já exposto no capítulo 6.2.2, foi o que melhor aproximou-se do comportamento explosivo da série nesse período, entretanto, não consegue descrever, integralmente, os momentos de “desaquecimento” do consumo.

A exemplo da classe residencial, os meses de novembro e dezembro de 2012 registraram crescimentos de 17,4% e 14,6% respectivamente.

Por esse tipo de comportamento, em que a aplicação de técnicas de FC torna-se interessante, o cenário resultante consegue congrega as características de todo o universo de projeções, portanto, reduzindo o risco (erro) da série.




Figura 6.7 - Consumo realizado mensal da classe comercial e modelos de predição, inclusive  $FC_{PCA}$  (em vermelho)

Esse comportamento, a exemplo da classe residencial, é explicado, nomeadamente, pelas elevadas temperaturas registradas no período, com uma média de temperaturas máximas +8,1%. Deve, também, ser citado o efeito da política anticíclica do governo federal que envolveu a redução do IPI da linha branca para o período. O principal efeito dessa política foi um aquecimento do comércio varejista, em especial dos magazines e *shopping centers*.

Com base na pontuação calculada por (6.7), os cenários foram ranqueados do melhor para o pior resultado. A Tabela 6.4 demonstra o resultado dos 32 modelos estudados mais a  $FC_{PCA}$ . É possível verificar que o método aqui proposto,  $FC_{PCA}$ , atingiu o segundo melhor desempenho tanto na pontuação proposta como nos demais métodos de avaliação do erro (MAPE, MAE e RMSE).

Curiosamente, como pode ser avaliado da tabela 6.6, para a classe comercial, o desempenho medido pelas diferentes formas de avaliação foi equivalente para todos os modelos, com melhor desempenho para o  $ARIMA2008$ . Por questões já descritas aqui, a

predição desse modelo apresentou comportamento “explosivo” e, justamente, por isso, foi a que mais se aproximou do realizado. Entretanto, o comportamento, tal como realizado, do consumo da classe comercial, deve-se a fatos conjunturais e não estruturais. Por isso, as elevadas taxas de crescimento não se devem sustentar no médio e/ou longo prazo.

Logo, podemos afirmar que, embora o comportamento do modelo *ARIMA2008* cause estranheza à primeira avaliação (Figura 6.4) por distanciar-se dos demais modelos, sua participação na Combinação de Previsões é importante, pois, aqui, certamente, forneceu uma componente que auxiliou a  $FC_{PCA}$  a atingir a segunda melhor colocação no *ranking*.

Dito isso, novamente, destaca-se o ponto forte da aplicação de  $FC_{PCA}$ , pois, ainda que não apresente o melhor desempenho, ela certamente, apresenta a melhor garantia de um bom desempenho.

Utilizando o caso da classe comercial, como exemplo, certamente, o analista, ao buscar por um cenário individual para seu cenário base, descartaria o modelo *ARIMA2008*, por “destoar” dos demais cenários e do comportamento passado da série como um todo. Tal fato colocá-lo-ia em uma posição desconfortável na realização da série, conforme verificamos. Entretanto, utilizando a Combinação de Previsões, todos os cenários são ponderados e o erro e, portanto, o risco é reduzido.

Rank	Pontuação	Software	Modelo/ Cenário	MAPE (%)	MAE (MWh)	RMSE (MWh)
1	15.371	Eviews	ARIMA2008	2,8	2.057	2.657
2	26.216	FC <sub>PCA</sub>	FC <sub>PCA</sub>	3,3	2.529	3.178
3	29.652	Eviews	ARIMA2007	3,4	2.633	3.322
4	31.950	Engenho	comc_2008	3,5	2.738	3.355
5	49.419	Minitab	ACOM2007	4,0	3.152	3.924
6	50.816	Minitab	ACOM2008	4,0	3.208	3.912
7	63.604	Holt Winters	MULT2008	4,5	3.462	4.103
8	66.847	Holt Winters	ADD2008	4,5	3.529	4.250
9	66.945	Holt Winters	ADD2007	4,4	3.497	4.339
10	67.866	Eviews	ARIMA2005	4,4	3.507	4.352
11	70.990	Minitab	ACOM2006	4,5	3.540	4.482
12	79.107	Eviews	ARIMA2004	4,7	3.696	4.572
13	84.142	Holt Winters	MULT2007	4,8	3.768	4.633
14	88.748	Eviews	ARIMA2003	4,9	3.858	4.712
15	92.732	Excel	Decomp	5,2	3.974	4.521
16	92.936	Holt Winters	ADD2006	4,9	3.901	4.839
17	94.542	Eviews	ARIMA2006	5,0	3.935	4.833
18	119.673	Holt Winters	MULT2006	5,4	4.246	5.203
19	123.370	Engenho	comc_2007	5,4	4.326	5.238
20	133.249	Minitab	ACOM2005	5,6	4.413	5.419
21	143.053	Holt Winters	ADD2005	5,7	4.528	5.527
22	150.478	Minitab	ACOM2004	5,8	4.600	5.655
23	152.491	Holt Winters	ADD2004	5,8	4.623	5.675
24	156.062	Holt Winters	ADD2003	5,9	4.660	5.714
25	159.559	Minitab	ACOM2003	5,9	4.697	5.748
26	192.766	Holt Winters	MULT2005	6,4	5.005	6.040
27	212.904	Holt Winters	MULT2004	6,6	5.202	6.176
28	218.401	Holt Winters	MULT2003	6,7	5.243	6.240
29	315.249	Engenho	comc_2006	7,6	6.012	6.874
30	631.210	Engenho	comc_2005	9,7	7.635	8.488
31	778.358	Predict	RN	10,6	8.192	8.951
32	942.535	Engenho	comc_2004	11,2	8.777	9.554
33	1.124.502	Engenho	comc_2003	11,9	9.322	10.099

Tabela 6.6 – Rank por pontuação dos cenários para a classe comercial

Como exemplo, cita-se que o cenário escolhido pelo *board* de gestores, na ocasião da elaboração dessas previsões, havia sido o *Decomp*, que ficou em décimo quinto colocado com base na pontuação geral e apresentou um MAPE de 5,2%. Esse cenário havia sido escolhido, pois, na ocasião, com base nos desvios dentro da amostra, mostrava-se ser a melhor opção.


Logo, embora a  $FC_{PCA}$  não apresente o melhor desempenho, na pontuação geral, a grande vantagem de sua aplicação é de poder

garantir, antes da avaliação de desempenho, que o cenário resultante trará a melhor composição de informação possível.

### 6.3.4 Classe Industrial

A classe industrial, também, apresentou resultados muito bons. Conforme pode ser avaliado na Figura 6.8, os dados realizados da série tiveram seu comportamento bem descrito pela  $FC_{PCA}$ .

A exemplo das classes residencial e comercial, ocorrem alguns pontos de “descolamento”, em junho e outubro de 2012, em que o consumo assume comportamentos bem distintos do comportamento geral descrito por todos os modelos de previsão.



Também, para a classe industrial, os cenários foram ranqueados do melhor para o pior resultado com base na pontuação calculada por (6.7). A Tabela 6.7 demonstra o resultado dos 32

modelos estudados mais a  $FC_{PCA}$ . É possível verificar que o método aqui proposto,  $FC_{PCA}$ , atingiu o melhor desempenho, tanto na pontuação proposta, como nos demais métodos de avaliação do erro (MAPE, MAE e RMSE).

Interessante, também, é citar que, os modelos que melhor descreveram o comportamento da classe industrial foram os do tipo “Amortização Exponencial de *Holt Winters*”.

Rank	Pontuação	Software	Modelo/ Cenário	MAPE (%)	MAE (MWh)	RMSE (MWh)
1	4.342	$FC_{PCA}$	$FC_{PCA}$	2,5	1.161	1.484
2	5.201	Holt Winters	ADD2006	2,7	1.240	1.551
3	5.830	Holt Winters	ADD2007	2,8	1.271	1.654
4	5.833	Holt Winters	ADD2005	2,8	1.279	1.654
5	6.689	Minitab	HWA_2006	2,9	1.377	1.660
6	7.108	Holt Winters	ADD2003	3,0	1.383	1.715
7	7.635	Holt Winters	MULT2006	3,1	1.421	1.739
8	7.944	Holt Winters	MULT2007	3,1	1.418	1.813
9	8.405	Holt Winters	MULT2005	3,1	1.431	1.906
10	9.147	Holt Winters	ADD2004	3,3	1.511	1.857
11	9.815	Engenho	indc_2006	3,3	1.574	1.876
12	9.951	Eviews	ARIMA2007	3,3	1.583	1.879
13	10.419	Minitab	HWA_2007	3,4	1.597	1.920
14	12.186	Holt Winters	MULT2003	3,6	1.656	2.056
15	13.170	Eviews	ARIMA2003	3,7	1.746	2.044
16	13.518	Eviews	ARIMA2008	3,7	1.761	2.064
17	15.253	Excel	Decomp	3,8	1.796	2.230
18	15.472	Holt Winters	ADD2008	3,9	1.814	2.169
19	15.676	Holt Winters	MULT2004	3,9	1.809	2.225
20	16.180	Minitab	HWA_2005	3,9	1.868	2.196
21	16.792	Minitab	HWA_2003	4,0	1.884	2.243
22	16.939	Holt Winters	MULT2008	4,0	1.843	2.288
23	18.389	Eviews	ARIMA2004	4,1	1.956	2.277
24	20.471	Predict	RN	4,3	2.026	2.347
25	21.148	Eviews	ARIMA2005	4,3	2.046	2.393
26	22.803	Minitab	HWA_2004	4,4	2.084	2.486
27	23.123	Engenho	indc_2005	4,5	2.118	2.447
28	25.722	Engenho	indc_2007	4,6	2.189	2.552
29	34.390	Engenho	indc_2003	5,1	2.417	2.800
30	40.053	Minitab	HWA_2008	5,4	2.565	2.877
31	40.521	Engenho	indc_2004	5,4	2.548	2.966
32	42.309	Eviews	ARIMA2006	5,4	2.585	3.016
33	50.359	Engenho	indc_2008	5,8	2.750	3.170

Tabela 6.7 – Rank por pontuação dos cenários para a classe industrial

Felizmente, para a classe industrial, o cenário escolhido pelo *board* de gestores, na ocasião da elaboração destas previsões, havia sido o *ADD2006*, que ficou em segundo colocado com base na pontuação geral e apresentou um MAPE de 2,7%.

### 6.3.5 Desempenho Global

Nesta seção, o intuito é estimar o possível ganho global que poderia ter sido obtido pela aplicação da  $FC_{PCA}$  na previsão de mercado.

#### 6.3.5.1 Representação Gráfica

Na busca dessa compreensão, foram unidos os cenários resultantes da aplicação de  $FC_{PCA}$  para cada classe estudada, neste trabalho, e comparados com a união dos cenários, efetivamente, utilizados como “cenário-base” pela empresa. Como *benchmarking*, foi utilizado o somatório do mercado, efetivamente, realizado para as classes residencial, comercial e industrial. A representação gráfica destas considerações pode ser verificada na Figura 6.9:




Figura 6.9 – União das classes estudadas para os cenários, originalmente, previstos (azul),  $FC_{PCA}$  (vermelho) e realizados (preto)



### 6.3.5.2 Composição da Carga para Planejamento

Deve-se esclarecer que essa representação é uma simplificação do problema real, pois, para representar a totalidade do mercado de vendas de uma distribuidora, ainda é necessário contemplar as cinco demais classes de serviço que foram omitidas, neste trabalho, que representam 26% do mercado, conforme a figura 5.3.

Além do mais, a carga de energia que é, efetivamente, aplicada para os estudos de planejamento elétrico e energético, ainda carece de dois elementos:

1. Energia em trânsito;
2. Perdas;
  - a. Perdas Técnicas;
  - b. Perdas Comerciais.

A energia em trânsito nada mais é que a energia entregue a clientes livres e outros agentes de distribuição. O somatório das parcelas Mercado de Vendas e Energia em Trânsito compõe o que é, costumeiramente, chamado de Energia Distribuída.

O processo do cálculo de perdas é iterativo. A Energia distribuída é variável de entrada para os estudos de perdas técnicas, que são estimadas para cada um dos cenários de planejamento (cenário-base, cenário otimista e cenário pessimista) por meio de estudos de *load flow*. Então, com base nas metas regulatórias e no plano orçamentário da empresa, que define as ações que serão tomadas para redução das perdas comerciais, é definido o índice de perdas comerciais. Agora, com uma carga global definida, a etapa de estudos de *load flow* é, novamente, executada, a fim de obterem-se resultados mais ajustados de perdas técnicas.

A Carga de Planejamento, também, é, usualmente, conhecida como “*Requisitos do Sistema*” por representar, efetivamente, a energia que flui pelo sistema de distribuição da empresa. O processo da sua composição, descrito acima, está representado na

figura 6.10, onde o processo iterativo do cálculo de perdas técnicas está representado no traço segmentado:

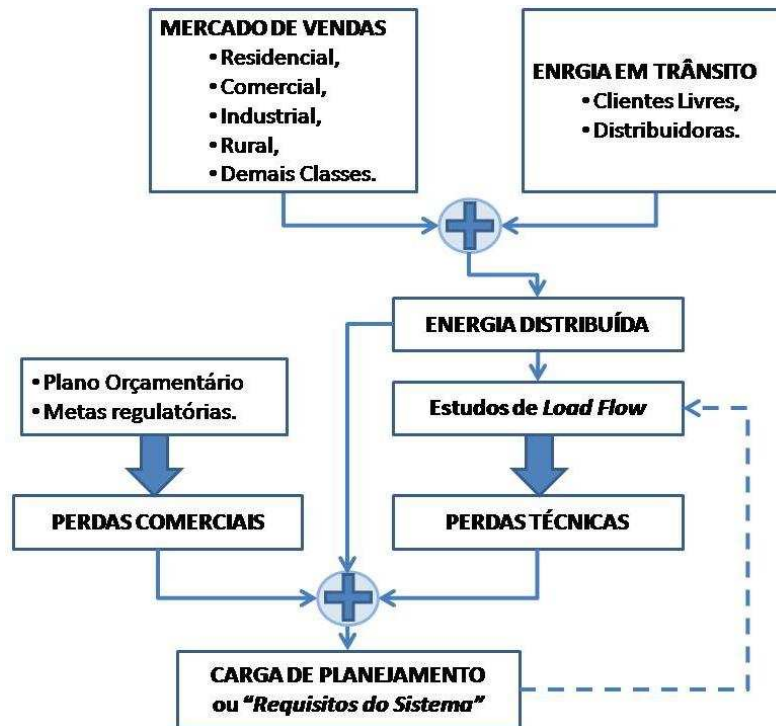


Figura 6.10 – Representação da composição da Carga de Planejamento

### 6.3.5.3 Resultados

Tendo esclarecido a composição da carga de planejamento, é importante entender quantitativamente o impacto que a melhora da assertividade na previsão do mercado pode produzir na composição dos requisitos de carga. Para tal, buscou-se demonstrar na Tabela 6.8 o ganho de assertividade que seria promovido pela aplicação de  $FC_{PCA}$  no ciclo de projeções em questão.

A Tabela 6.8 considera o cenário-base utilizado pela Enersul, chamado aqui de “Previsto” e a união dos cenários obtidos pela  $FC_{PCA}$ , demonstrados na seção 6.3.5.1. Os indicadores de erro  $MAPE$ ,  $RMSE$  e  $MAE$  foram calculados para os dados realizados,

dentro e fora da amostra, isto é, para o período de julho/2011 a dezembro/2012, 18 (dezoito) meses de avaliação.

Verifica-se, em termos de *MAPE*, um incremento de 0,62p.p., na assertividade, que pode ser traduzido em um ganho de 78 GWh considerado o mercado realizado nesse período. Outra informação importante é a sensível melhora, também, no *RMSE*, o que indica que a aplicação da  $FC_{PCA}$  para previsões de médio e curto prazo, também, pode apresentar resultados interessantes, pois, conforme já descrito na seção 6.3, a característica quadrática do *RMSE* privilegia o ajuste ponto a ponto das séries.

Em última análise, percebe-se que, para os índices *MAPE*, *MAE* e *RMSE* foi alcançada uma melhora significativa do erro, da ordem de 20%. Considerando o erro medido em MWh para o período, a redução foi de 71%.

Indicador	$FC_{PCA}$	Previsto	Diferença	Ganho (%)
MAPE (%)	2,44	3,06	0,62	-20%
RMSE	7.564	9.604	2.040	-21%
MAE	5.826	7.449	1.622	-22%
Total (MWh)	31.755	110.117	78.362	-71%

Tabela 6.8 – Índices de erro para a  $FC_{PCA}$ , as previsões utilizadas, originalmente, pela empresa, e o ganho obtido pela aplicação de  $FC_{PCA}$

## CAPÍTULO. 7 – CONCLUSÃO

### 7.1 Considerações Finais

Este trabalho apresentou uma metodologia que traz luz a um dos maiores problemas de decisão para os gestores responsáveis pelo planejamento de mercado das distribuidoras de energia elétrica: “Como determinar um cenário-base, dado um conjunto de projeções de mercado proposto sem possuir informações que assegurem qual modelo trará os melhores resultados?”. Nesse sentido, foi desenvolvida uma metodologia de *Forecast Combination*, baseada na aplicação da técnica de *PCA*, de forma que a informação da variância total do conjunto de dados é representada por meio de autovalores que, por sua vez, compõem um novo cenário que, conforme demonstrado, pode, seguramente, ser utilizado como cenário-base, representando toda a informação do conjunto.

O resultado verificado na aplicação da técnica proposta foi muito satisfatório, e corrobora com a grande maioria dos estudos já feitos na utilização do método de *Forecast Combination* como forma de garantir a assertividade de uma projeção.

O ajuste (erro) alcançado pelos cenários resultantes da  $FC_{PCA}$  ficou, em média, 21% melhor que o ajuste anterior, resultante dos cenários escolhidos pelo *board* da empresa. Essa sensível melhora, no ajuste, foi, também, atestada na diferença medida em MWh, que atingiu 78,3 GWh.

Em linha com os excelentes resultados atingidos, é importante destacar, também, que o ganho da aplicação de combinação de previsões vai muito além da melhora de assertividade. Sem a aplicação de  $FC_{PCA}$ , temos que escolher, às cegas, um modelo em detrimento de outros. Fazendo isso, sempre haverá informação útil que é descartada, podendo ser, inclusive, trocada por informação indesejada. Pela aplicação de  $FC_{PCA}$ , toda a informação do conjunto é utilizada, tanto a “informação boa” quanto a “informação ruim” e a combinação é feita de tal forma que o resultado final apresenta a performance mais confiável o possível.

Apesar dos resultados obtidos para o caso em estudo contribuírem de forma intensa para a defesa da  $FC_{PCA}$ , seria possível, no universo de possibilidades, que a assertividade não apresentasse melhora tão significativa quanto à verificada, ou, talvez, pudesse ser até reduzida. Isso posto, por que a assertividade, neste trabalho, foi medida em relação ao cenário, originalmente, escolhido e haveria a possibilidade do cenário original ser ainda superior, no que tange o ajuste, ao cenário proposto pela  $FC_{PCA}$ .

Para exemplificar, imaginemos uma situação hipotética em que os cenários escolhidos pelo *board*, para as classes residencial e comercial houvessem sido, respectivamente, os cenários *RESMULT2008* e *ARIMA2008* e para a classe industrial fosse mantido o cenário *ADD2006*. Essa seria a situação ótima, pois o *board* teria escolhido *ex-ante*, os cenários apresentariam o melhor ajuste no futuro e a escolha pelo cenário resultante da  $FC_{PCA}$  apresentaria resultados inferiores, do ponto de vista de desempenho, conforme demonstrado na Tabela 7.1:

Indicador	$FC_{PCA}$	Previsto	Diferença	Ganho (%)
MAPE (%)	2,44	2,21	-0,23	10%
RMSE	7.564	6.705	-859	13%
MAE	5.826	5.144	-682	13%
Total (MWh)	31.755	22.452	-9.303	41%

Tabela 7.1 – Índices de erro para um caso hipotético de escolha dos cenários pelo *board*.

Contudo, a situação como descrita é hipotética, e ampara-se nos estudos de ASHLEY (ASHLEY, 2003) para afirmar-se que se trata de uma probabilidade muito remota de ocorrência. Permita-se dizer – um caso de muita sorte.

Logo, aqui se evidencia a pujante vantagem da aplicação da  $FC_{PCA}$ : “garantir, não o melhor, mas, seguramente, um bom desempenho para o seu resultado”. Dessa forma, o risco enfrentado pelo gestor, no momento da tomada de decisão, pode ser, seguramente, reduzido.

Entretanto, como em qualquer aplicação sistêmica, para assegurar bom desempenho para a “saída” não se pode perder de vista o conceito “*garbage in garbage out*” (LIDWELL et al., 2012), isto é, os resultados da aplicação serão tão confiáveis quanto as suas informações de entrada (no caso, os cenários). Portanto, a fase de inspeção dos cenários gerados pelas simulações antes da aplicação da  $FC_{PCA}$ , como descrito na Seção 6.2, é importante e não pode ser descartada. E, por mais poderoso que seja o ferramental estatístico aplicado nesta inspeção, nada substitui a expertise do analista preparado e experimentado com as séries em análise.

## 7.2 Recomendações para Trabalhos Futuros

Alcançar uma assertividade de 100% do mercado projetado é virtualmente impossível, portanto, outra preocupação do tomador de decisão, além de buscar a maior assertividade possível, é também poder justificar o erro por meio das premissas adotadas. Entendendo que o problema de assimetria na penalidade por erro de contratação exposta na seção 2.5.2 direciona o tomador de decisão na preferência do “erro pelo excesso”, uma complementação significativa a este trabalho poderia ser uma ferramenta probabilística que, ao ser aplicada sobre o set de cenários originais, indicasse aqueles que contribuem com o maior risco de “subdimensionamento” do mercado. Em teoria, com o expurgo destes cenários, e por consequência suas componentes, o novo set indicaria uma situação mais otimista que a original.

Como tal ferramenta, sugere-se uma variação dos estudos de Nelson (1972) onde se faria uma aplicação iterativa da  $FC_{PCA}$ , inicialmente sobre o conjunto original de dados dando origem a um cenário “*benchmark*”. Este cenário “*benchmark*” seria utilizado para avaliar o desvio padrão dos demais cenários em relação a este e assim expurgar do conjunto aqueles que oferecessem maior risco a estratégia de planejamento (erro pelo excesso). Então, de posse de um novo conjunto, que em tese teria um número menor de cenários prejudiciais a estratégia de planejamento, seria aplicada novamente

a  $FC_{PCA}$  originando um cenário com maior confiabilidade e com viés de “otimismo”.

Como extensão do presente trabalho também podem ser desenvolvidas pesquisas que abordem aplicação de técnicas de  $PCA$  sobre o conjunto de variáveis de entrada de metodologias de projeção baseadas em variáveis exógenas tais como, macroeconomia, clima, tarifas de energia, etc. Assim, o conjunto inicial poderia ser avaliado e reduzido em sua dimensão, abreviando a influência do erro inerente à projeção das variáveis de entrada e reduzindo o esforço humano e computacional na manipulação dessas variáveis.

## ANEXO I – SÉRIES HISTÓRICAS DE MERCADO MEDIDO

### Classe de Consumo Industrial (MWh)

ANO	JAN	FEV	MAR	ABR	MAI	JUN	JUL	AGO	SET	OUT	NOV	DEZ
2000	37.069	37.251	46.699	44.691	52.902	54.004	53.374	54.798	52.449	55.546	52.159	47.943
2001	49.376	50.175	57.001	52.991	55.153	48.847	50.433	51.681	49.987	49.494	52.085	47.363
2002	50.893	47.282	56.574	54.927	55.587	57.356	57.518	57.857	58.631	57.165	57.160	58.400
2003	49.738	49.099	55.694	51.274	57.848	54.865	53.841	58.575	53.934	55.024	51.735	61.416
2004	45.147	43.235	47.832	58.006	43.289	52.377	49.777	52.218	47.299	48.074	44.884	46.858
2005	36.315	36.314	40.427	43.682	42.871	40.639	41.232	41.873	39.856	37.075	35.611	35.553
2006	30.934	34.183	36.415	38.628	35.832	38.244	38.229	37.488	37.411	35.910	35.932	37.064
2007	32.212	36.117	40.784	40.785	39.865	39.532	38.183	40.067	41.282	37.830	38.568	39.105
2008	33.854	39.973	43.008	43.392	43.977	42.564	44.676	48.852	46.389	43.929	43.853	40.507
2009	33.496	38.879	39.752	40.890	37.918	39.702	39.245	40.605	40.023	40.351	41.676	43.205
2010	38.783	41.438	42.273	47.967	42.788	46.695	45.561	47.291	46.121	43.735	43.963	44.320
2011	41.360	45.713	45.320	49.605	44.896	45.018						

### Classe de Consumo Residencial (MWh)

ANO	JAN	FEV	MAR	ABR	MAI	JUN	JUL	AGO	SET	OUT	NOV	DEZ
2000	83.853	84.417	79.651	83.240	78.151	71.421	73.199	70.143	78.195	80.216	87.155	82.575
2001	92.100	89.334	84.772	87.818	80.150	61.661	53.236	56.170	61.472	59.766	62.459	62.315
2002	67.065	65.329	70.014	73.957	71.398	63.868	60.822	64.245	68.173	74.344	76.082	79.820
2003	81.869	76.315	77.364	72.232	69.470	63.472	64.251	65.145	64.318	72.096	73.392	76.628
2004	80.730	76.690	77.317	77.306	75.146	65.193	64.373	72.582	71.590	77.085	76.773	79.475
2005	80.885	75.889	85.036	83.654	75.635	73.222	66.080	66.729	71.048	72.614	78.620	77.051
2006	79.656	80.593	78.270	79.723	71.559	67.337	68.251	71.464	71.188	76.546	83.101	82.359
2007	83.312	79.705	80.404	85.888	75.457	65.533	68.153	67.041	75.386	82.472	79.895	79.950
2008	83.532	83.805	76.482	78.520	74.287	71.274	69.193	77.973	78.786	79.032	89.794	90.800
2009	89.955	88.827	91.150	95.513	89.282	81.087	79.955	80.642	84.448	89.367	98.875	102.823
2010	101.186	99.109	102.447	101.977	91.094	82.728	87.832	85.486	97.177	97.692	97.769	106.969
2011	105.528	104.352	107.607	104.051	101.910	87.803						

### Classe de Consumo Comercial (MWh)

ANO	JAN	FEV	MAR	ABR	MAI	JUN	JUL	AGO	SET	OUT	NOV	DEZ
2000	47.068	47.337	47.631	47.813	47.172	41.421	40.249	39.601	45.631	46.142	48.692	48.094
2001	51.629	51.125	51.696	53.864	49.040	37.199	30.534	33.705	38.545	36.301	38.723	39.585
2002	40.180	40.832	43.633	46.616	46.051	39.192	36.740	40.081	43.998	43.906	47.032	48.511
2003	48.396	46.381	48.487	48.796	43.736	39.259	39.857	41.747	42.621	45.997	47.542	48.614
2004	48.962	49.662	49.101	52.385	46.922	41.806	40.616	47.262	49.327	50.812	48.635	53.734
2005	52.167	49.338	55.648	56.341	50.951	46.248	44.705	42.188	47.484	46.755	49.523	51.542
2006	53.482	53.478	53.592	57.386	47.288	42.484	45.642	48.526	48.139	49.998	53.514	55.727
2007	53.807	53.505	54.852	60.102	51.980	43.800	45.981	46.257	52.418	55.003	54.311	54.483
2008	53.670	52.876	57.221	54.336	51.520	44.492	44.766	53.883	57.447	54.244	61.617	60.910
2009	59.020	57.459	59.689	64.995	58.588	51.592	50.047	53.161	56.455	58.817	64.859	69.415
2010	65.213	65.856	70.154	71.716	62.655	52.585	56.556	59.613	65.712	64.405	64.889	71.048
2011	70.247	70.588	72.865	76.251	70.053	61.832						



## REFERÊNCIAS BIBLIOGRÁFICAS

- AIOLFI, M. et al. (Junho de 2010). *Forecast Combinations*. Banco de Mexico Working Papers . Mexico: Banco de Mexico.
- ANDERSON, K.P (1973). *Residential energy use: an econometric analysis*. The Rand Corporation.
- ANEEL. (28 de Agosto de 2007). *Resolução Normativa 277*.
- ANEEL/SRE. (2007). *Nota Técnica n° 351/2007-SRE/ANEEL*.
- ARAÚJO, W.O. & COELHO, C. J. (2009). *Análise de Componentes Principais (PCA)*. Anápolis: UniEVAGÉLICA.
- ARMSTRONG, J. (1989). *Combining Forecasts: The End of the Beginning or the Beginning of the End?*. International Journal of Forecasting .
- ASHLEY, R. (2003). *Statistically significant forecasting improvements: how much out-of sample data is likely necessary?* International Journal of Forecasting.
- BAJAY. S.V. (2001). *Energia no Brasil: Os próximos dez anos*.
- BATES, J. &. (1969). *The Combination of Forecasts*. *Operations Research Quarterly* .
- BOX, G.E.P & JENKINS, G.M. (1976). *Time Series Analysis Forecasting and Control*. Holden-Day .
- BRASIL. (1988). *CONSTITUIÇÃO DA REPÚBLICA FEDERATIVA DO BRASIL DE 1988*.
- BRASIL. (15 de 03 de 2004). *LEI N 10.848, DE 15 DE MARÇO DE 2004. Dispõe sobre a comercialização de energia elétrica, altera as Leis n°s 5.655, de 20 de maio de 1971, 8.631, de 4 de março de 1993, 9.074, de 7 de julho de 1995, 9.427, de 26 de dezembro de 1996, 9.478, de 6 de agosto de 1997, e dá outras providências*. BRASIL.
- BRASIL. (12 de 04 de 1990). *LEI N° 8.031, DE 12 DE ABRIL DE 1990. Cria o Programa Nacional de Desestatização, e dá outras providências*.
- BRASIL. (4 de MARÇO de 1993). *LEI N° 8.631, DE 4 DE MARÇO DE 1993. Dispõe sobre a fixação dos níveis das tarifas para o serviço público de energia elétrica, extingue o regime de remuneração garantida e dá outras providências*.
- BRASIL. (13 de 02 de 1995). *LEI N° 8.987, DE 13 DE FEVEREIRO DE 1995. Dispõe sobre o regime de concessão e permissão da prestação de serviços públicos previsto no art. 175 da Constituição Federal, e dá outras providências*.
- BRASIL. (7 de 7 de 1995). *LEI N° 9.074, DE 7 DE JULHO DE 1995. Estabelece normas para outorga e prorrogações das concessões e permissões de serviços públicos e dá outras providências*. BRASIL.
- BRASIL. (27 de 05 de 1998). *LEI N° 9.648, DE 27 DE MAIO DE 1998. Autoriza o Poder Executivo a promover a reestruturação da Centrais Elétricas Brasileiras - ELETROBRÁS e de suas subsidiárias e dá outras providências*.

- CAIO, L.S. & BERMANN, C. (1998). *Análise das Metodologias de Previsão de Mercado de Energia Elétrica Face ao Novo Perfil de Planejamento no Ambiente Pós Privatização*. III Congresso Brasileiro de Planejamento Energético.
- CLARK II, W.W. & LUND, H. (2001) *Civic markets: the case of the California Energy Crisis*. Int. J. Global Energy Issues. 16° Edição. UK: Inderscience.
- CLEMEN, R. T. (1989). *Combining Forecasts: A review and Annotated Bibliography*. International Journal of Forecasting (5), 559-583.
- CNI, C. N. (15 de junho de 2009). *Crise Global: Impacto nos BRICs Foi Intenso e Diferenciado*. Notas Econômicas .
- CONDE, G. et al. (2007). *Performance Evaluation of Short and Long Term Load Forecasting Models: a Case Study in the Amazonian Power Suppliers*. Proceedings of SPIE Optics East .
- COOPER, J.P., and NELSON, CR. (1975). *The ex-ante prediction performance of the St. Louis and FRB-MIT-PENN econometric models, and some results on composite predictions*. Journal of Money, Credit and Banking (7), 1-32.
- DIEBOLD, F. X. & LOPEZ, J. A. (1996). *Forecast evaluation and combination*. National Bureau of Economic Research (NBER) Working Paper n. T0192 . Cambridge: Available at: <http://ssrn.com/abstract=225136>.
- FALCO, G. P.; (2010). *O Perfil Econômico do Consumidor Residencial de Energia Elétrica no Período Entre 1994-2003*. Revista das Faculdades Integradas Vianna Junior . Volume 01 Número 01.
- HAIR, J.F.JR., ANDERSON, R.E., TATHAM, R.L., BLACK, W.C., *Análise Multivariada de Dados*. 5ª Edição. São Paulo: Bookman, 2005.
- JOLLIFFE, I. (2002). *Principal Component Analysis - II Edition*. Aberdeen: Springer.
- KELMAN, J. (2001). *Relatório da Comissão de Análise do Sistema Hidrotérmico de Energia Elétrica*. Brasília.
- LIDWELL, W., HOLDEN, K., BUTLER, J. (2010). *Universal Principles of Design, Revised and Updated: 125 Ways to Enhance Usability, Influence Perception, Increase Appeal, Make Better Design Decisions*. 2° Edição Revisada. Minneapolis, MN: Rockport Publishers.
- MARTINS, V. L. (2011). *Comparação de Combinações de Previsões Correlacionadas e Não Correlacionadas Com Suas Previsões Individuais: Um Estudo Com Séries Industriais*. Dissertação de Mestrado . Porto Alegre: UNIVERSIDADE FEDERAL DE RIO GRANDE DO SUL.
- MORETTIN, P. A. & TOLOI, C. M. C. (2006). *Análise de Séries Temporais - II Edição Revista e Ampliada*. São Paulo: Edgard Blucher.
- NELSON, C. (1972). *The Prediction Performance Of The F.R.B.-M.I.T.-PENN Model Of The U.S. Economy*. American Economic Review (62), 902-917.

NERY, E. (2012). *Mercados e Regulação de Energia Elétrica*. Rio de Janeiro: Interciência.

ORTEGA, J.M., PINTO J.O., MILLER, L.L., (2007). *Avaliação e Determinação de Perdas Oriundas do Intercâmbio de Energia do Sistema Interliga-do Sul/Sudeste no Sistema Enersul*. MPSI

PAIVA, A.P., (2006). *Metodologia de Superfície de Resposta e Análise de Componentes Principais em Otimização de Processos de Manufatura com Múltiplas respostas Correlacionadas*. Tese de Doutorado do Instituto de Engenharia Mecânica da Universidade Federal de Itajubá.

PAIXÃO, L. E. (2000). *Memórias do Projeto RE-SEB: A história da concepção da nova ordem institucional do setor elétrico brasileiro*. São Paulo: Massao Ohno.

PINTO, L. (2008). *Previsão Evolutiva de Carga Incluindo a Análise de Riscos*. X EDAO – Encontro Para Debates de Assuntos de Operação. São Paulo.

PIRES, J. C. (2000). *Desafios da Reestruturação do Setor Elétrico Brasileiro*. Textos para Discussão BNDES n° 76 .

REGO, L.P. et al. (2009). *Predict - Sistema de Suporte à Decisão para Estimativa de Cargas e Modelagem de Dependência em Sistemas Elétricos*. P&D - Revista de Pesquisa e Desenvolvimento da ANEEL , 98 - 100.

SAMOHYL & SOUZA. (2005). *Combinação de previsões em séries temporais do consumo industrial de energia elétrica em Santa Catarina*. XXV Encontro Nac. de Eng. de Produção. Porto Alegre.

SAPANKEVYCH, N.I. & SANKAR, R. (2009). *Time Series Prediction Using Support Vector Machines: A Survey*. IEEE Computational Intelligence Magazine .

SILVA, T. G. R & MIRANDA, S. H. G. (29 de 01 de 2007).

[http://www.agrolink.com.br/aftosa/artigo/a-febre-aftosa-e-os-impactos-economicos-no-setor-de-carnes\\_50719.html](http://www.agrolink.com.br/aftosa/artigo/a-febre-aftosa-e-os-impactos-economicos-no-setor-de-carnes_50719.html). Acesso em 19 de 03 de 2013, disponível em Agrolink.

SOUZA, A. M., SOUZA, F.M., FERREIRA, N., MENEZES, R.; (2011). *Electrical Energy Supply for Rio Grande do Sul, Brazil, Using Forecast Combination of Weighted Eigenvalues*, *GEPROS - Gestão da Produção, Operações e Sistemas*, UNESP, n° 3, Jul-Set/2011, p. 23-39.

STORCK, M. C. (2008). *Projeção Mensal da Demanda de Energia Utilizando VEC e Estimativa BOX –JENKINS Para os Parâmetros*. Dissertação de Mestrado . Vitória, Espírito Santo: FUCAPE.

SZCZUPAK, J. et al. (2007). *Previsão Inteligente de Mercados de Energia: Mais Que Repetir o Passado, Antecipar o Futuro*. XIX SNTPEE - SEMINÁRIO NACIONAL DE PRODUÇÃO E TRANSMISSÃO DE ENERGIA ELÉTRICA. Rio de Janeiro.

TIMMERMANN, A. (2005). *Forecast Combinations*. University of California .

TOLMASQUIM, Et Al. (2002). *Empresas do Setor Elétrico Brasileiro: Estratégias e Performances*. Rio de Janeiro: Cenergia.

TOLMASQUIM, M. T. (2011). *Novo Modelo do Setor Elétrico Brasileiro*. Rio de Janeiro: Synergia.

VIEIRA, J. (2005). *Energia Elétrica como Antimercadoria e sua Metamoforse no Brasil: A Reestruturação do Setor e as Revisões Tarifárias*. Tese de Doutorado . São Paulo.