

UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**COMPETIÇÃO DE MODELOS PARA PREVISÃO DE
MERCADO DE ENERGIA ELÉTRICA EM CURTO E
LONGO PRAZO**

por

Wlademir Lacerda de Moura

Dissertação submetida ao Programa de Pós-Graduação em Engenharia Elétrica da
Universidade Federal de Pernambuco como parte dos requisitos para a obtenção do grau de
Mestre em Engenharia Elétrica.

ORIENTADOR: Prof. RONALDO R. B. DE AQUINO, D.Sc., UFPE

Recife, dezembro de 2010

© Wlademir Lacerda de Moura, 2010

Catálogo na fonte
Bibliotecária Margareth Malta, CRB-4 / 1198

M929c

Moura, Wladimir Lacerda de.

Competição de modelos para previsão de mercado de energia elétrica em curto e longo prazo / Wladimir Lacerda de Moura. - Recife: O Autor, 2010.

xi, 105 folhas, il., gráfs., tabs.

Orientador: Prof. D.Sc. Ronaldo R. B. de Aquino.

Dissertação (Mestrado) – Universidade Federal de Pernambuco. CTG. Programa de Pós-Graduação em Engenharia Elétrica, 2010.


Inclui Referências Bibliográficas.

1. Engenharia Elétrica. 2. Previsão. 3. Energia Distribuída. 4. Regressão Dinâmica. 5. Inteligência Artificial. 6. Redes Neurais (RNA). 7. Lógica Fuzzy (LF). I. Título.

UFPE

621.3 CDD (22. ed.)

BCTG/2011-044



Universidade Federal de Pernambuco

Pós-Graduação em Engenharia Elétrica

PARECER DA COMISSÃO EXAMINADORA DE DEFESA DE
DISSERTAÇÃO DO MESTRADO ACADÊMICO DE

WLADEMIR LACERDA DE MOURA

TÍTULO

**“COMPETIÇÃO DE MODELOS PARA PREVISÃO DE MERCADO DE
ENERGIA ELÉTRICA EM CURTO E LONGO PRAZO”**

A comissão examinadora composta pelos professores: RONALDO RIBEIRO BARBOSA DE AQUINO, DEESP/UFPE, MARCELO CABRAL CAVALCANTI, DEESP/UFPE e BENEMAR ALENCAR DE SOUZA, DEE/UFCG, sob a presidência do primeiro, consideram o candidato **WLADEMIR LACERDA DE MOURA APROVADO.**

Recife, 20 de dezembro de 2010.

RAFAEL DUEIRE LINS
Coordenador do PPGEE

RONALDO RIBEIRO BARBOSA DE AQUINO
Orientador e Membro Titular Interno

BENEMAR ALENCAR DE SOUZA
Membro Titular Externo

MARCELO CABRAL CAVALCANTI
Membro Titular Interno

*Á Adjair e Dalva, meus pais, pois sem eles
não teria conseguido e às mulheres de
minha vida Walkíria (irmã), Mykaella
(sobrinha) e Karyne (noiva).*

AGRADECIMENTOS

Agradeço a Deus, por ter me mostrado o caminho certo, por ter me dado as oportunidades que tive em minha vida.

Agradeço ao meu pai Adjair pela força que me deu desde o início dos meus estudos até o período da faculdade, não poupando esforços para concretizar meus sonhos e anseios.

Agradeço a minha mãe Dalva por estar sempre presente em minha vida, acompanhando meus passos, me levantando quando preciso e me dando amor, carinho e força em todos os momentos e passagens de minha vida.

Agradeço a minha noiva Karyne, pelo amor e carinho diário e principalmente pela paciência e compreensão nos períodos de maior dedicação os quais foram desprendidos ao longo do curso.

Agradeço a minha irmã Walkiria e a minha sobrinha Mykaella pelo carinho e por colaborarem para que meus dias sejam cada vez mais prazerosos.

Agradeço principalmente ao Prof. Dr. Ronaldo Aquino pela oportunidade que me deu, pela presença constante, pela orientação e pela paciência.

Agradeço aos colegas Tatiana e Marcelo pela paciência, dedicação e ajuda indispensável nas simulações utilizando o MATLAB.

Agradeço a Carlos Frederico, gestor da Unidade de Previsão de Mercado da CELPE, o qual sou subordinado, pela amizade, pelo apoio na liberação para assistir às aulas nos dias de semana, pela ajuda constante e pelo aprendizado diário concretizado através do convívio.

Agradeço a Roberto Velasquez e Humberto Cardim, gerentes do Departamento de Gestão de Mercado – CGM, da Companhia Energética de Pernambuco – CELPE, no período em que estive envolvido no mestrado, por liberarem minha presença nas aulas, pela compreensão e paciência.

Agradeço a Profa. Milde pela disponibilidade e atenção habitual.

Agradeço ao Professor Otoni pela ajuda nas simulações e esclarecimento de dúvidas.

Agradeço a todos os meus professores do mestrado, com ênfase ao Prof. Manoel Afonso.

Agradeço ao amigo Gustavo pelo incentivo, principal responsável pela minha decisão de cursar o mestrado. Agradeço ainda pela ajuda nos trabalhos e pela dedicação nos estudos em grupo.

Por fim, agradeço a todos que auxiliaram a tornar este projeto possível.

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

Competição de Modelos para Previsão de Mercado de Energia Elétrica em Curto e Longo Prazo

Wlademir Lacerda de Moura

Dezembro/2010

Orientador: Prof. RONALDO R. B. DE AQUINO, D.Sc., UFPE

Área de Concentração: Processamento de energia.

Palavras-chave: Previsão, Energia Distribuída, Regressão Dinâmica, Inteligência Artificial, Redes Neurais (RNA), Lógica fuzzy (LF)

Número de Páginas: 114

RESUMO: Após as mudanças ocorridas, com a reestruturação do mercado de energia ao final da década de 90, a previsão de mercado veio ganhando destaque cada vez maior, com ênfase nos processos de planejamento do setor, modicidade tarifária e contratação de energia elétrica, onde se estabelece um limite que caso venha a ser rompido, poderá gerar prejuízos às distribuidoras de energia elétrica. Dessa forma, este trabalho visa encontrar o modelo mais adequado à série histórica de Energia Distribuída da CELPE (Companhia Energética de Pernambuco). Foram feitas simulações para curto prazo, com dados mensais no horizonte de doze meses à frente e longo prazo, com dados anuais e horizonte de quatro anos. Para o curto prazo foram testadas as metodologias de Amortecimento Exponencial, Box & Jenkins, Modelos Estruturais e Redes Neurais Artificiais, sendo testados vários modelos para cada aplicação. No longo prazo as metodologias utilizadas foram as de Regressão Dinâmica e o ANFIS. Ao final foram feitas comparações através do MAPE (Erro Médio Absoluto Percentual), sendo o melhor modelo o que obteve o menor valor de MAPE.

.

Abstract of Dissertation presented to UFPE as part of the requirements to the degree of
Master of Electrical Engineering

Competition Model for Prediction of Electric Power Market in Short and Long Term

Wlademir Lacerda de Moura

December/2010

Supervisor: Prof. RONALDO R. B. DE AQUINO, D.Sc., UFPE

Area of Concentration: Processing Energy.

Keywords: Forecast, Distributed Energy, Dynamic Regression, Artificial Intelligence, Neural Networks (RNA), Fuzzy Logic (FL)

Number of Pages: 114

ABSTRACT: After the changes, with the restructuring of the energy market in the late 90's, the market forecast came increasingly gaining attention, with emphasis on the processes for sector planning, hiring and keeping tariffs of electricity, where establishes a threshold that should they trespass, could lead to financial losses for electricity distributors. Thus, this work aims at finding the most appropriate model to a time series Distributed Energy from CELPE (Energetic Company of Pernambuco). Simulations were made for short term, with monthly data on the horizon of twelve months ahead and long term, with annual data and four-year horizon. For the short term were tested methodologies for Exponential Smoothing, Box & Jenkins, Structural Models and Neural Networks, and tested several models for each application. In the long run the methodologies used were Dynamic Regression and ANFIS. At the end comparisons were made using the MAPE (Mean Absolute Percentage Error), and the best model which had the lowest value of MAPE.

SUMÁRIO

ÍNDICE DE FIGURAS.....	ix
ÍNDICE DE TABELAS	xi
CAPÍTULO 1.....	1
1 Introdução.....	1
1.1 - Motivação.....	1
1.2 - Objetivos do Trabalho.....	3
1.3 - Organização da Dissertação	4
CAPÍTULO 2.....	5
2 - Mercado de Energia Elétrica – Pernambuco.....	5
2.1 - Histórico – Modalidades de consumo	5
2.2 - Mercado por segmentos	6
2.2.1 - Mercado por classe de consumo.....	6
2.3 - Fatores que influenciam o mercado de energia da CELPE.....	8
2.3.1 - Fatores Macroeconômicos	8
2.3.2 - Fatores Demográficos	9
2.3.3 – Fatores Climáticos	11
2.4 – Sazonalidade.....	12
2.4.1 – Definição	12
2.4.2 - Tipos de Sazonalidade.....	12
2.4.3 - Análise da sazonalidade da CELPE	13
CAPÍTULO 3.....	16
3 - Previsão de Carga do Sistema Elétrico	16
3.1 - Sistema Elétrico Brasileiro.....	16
3.2 - O Novo Modelo do Setor Elétrico Brasileiro.....	17
3.2.1 - O Projeto RE-SEB.....	17
3.2.2 - A Reestruturação do Setor Elétrico Brasileiro	20
2.2.1 - Influência das Normas do Setor Elétrico na Previsão de Carga.....	24
3.3 Objetivo da Previsão de Carga	25
3.3.1 - Estudos de Longuíssimo Prazo, com horizonte de até 30 anos.....	26
3.3.2 - Estudos de longo prazo com horizonte de 10 anos	26
CAPÍTULO 4.....	29
4 – Base Teórica.....	29
4.1 – Revisão Bibliográfica dos Modelos de Previsão de Carga.....	29
4.1.1 - Amortecimento Exponencial.....	29
4.1.2 - Box & Jenkins	30
4.1.3 - Modelos Estruturais	30
4.1.4 - Redes Neurais Artificiais na Previsão de Carga.....	31
4.1.5 - Lógica Fuzzy na Previsão de Carga	32
4.1.6 - Sistemas Neuro-Fuzzy na Previsão de Carga.....	33
4.2 – Base Teórica	34
4.2.1 Amortecimento exponencial.....	34
4.2.2 Modelos Box & Jenkins	42
4.2.3 - Modelos Estruturais	45

4.2.4 Regressão Dinâmica	52
4.2.5 Redes Neurais Artificiais.....	55
4.2.6 - Lógica Fuzzy	65
CAPÍTULO 5.....	71
5 - Base de Dados e Softwares utilizados.....	71
5.1 - Energia Distribuída.....	71
5.2 - Tratamento da Série e Escolha do horizonte	71
5.3 - Definições das variáveis causais	74
5.4 - Softwares Utilizados.....	74
5.4.1 - Forecast Pro.....	74
5.4.2 - STAMP	76
5.4.3 - MATLAB.....	78
CAPÍTULO 6.....	79
6 - Comparação entre os Modelos	79
6.1 - Modelos de Curto Prazo	79
6.1.1 - Análise dos resultados dos modelos utilizados no Curto Prazo	80
6.1.2 - Comparações dos Erros dos Modelos de Curto Prazo	88
6.2 - Modelos de Longo Prazo.....	90
6.2.1 - Análise dos resultados dos modelos utilizados no Longo Prazo.....	91
6.2.2 - Comparações dos Erros dos Modelos de Longo Prazo	95
7 - Conclusão	97
8 - Referências Bibliográficas.....	98

ÍNDICE DE FIGURAS

Figura 2. 1 - Participação do consumo por classe – CELPE (jan a out/09).....	6
Figura 2. 2 - Histórico da Participação do consumo – CELPE (residencial, industrial e comercial)	7
Figura 2. 3 – Gráfico da Regressão da Energia distribuída da CELPE x PIB/PE. Fonte: CEPLAN.....	9
Figura 2. 4 - Gráfico da Regressão linear População x Número de clientes faturados	10
Figura 2. 5 - Evolução do número de habitantes por domicílio	11
Figura 2. 6 - Exemplo de série histórica com sazonalidade aditiva	12
Figura 2. 7 - Exemplo de série histórica com sazonalidade multiplicativa	13
Figura 2. 8 – Decomposição da série histórica da CELPE.....	14
Figura 2. 9 – Gráfico do Consumo Médio Residencial x Número de consumidores total..	15
Figura 3. 1 – Estrutura atual do setor elétrico brasileiro	21
Figura 3. 2 - Ambientes de comercialização de energia elétrica.....	22
Figura 3. 3 - Formas de contratação de energia no Ambiente de Contratação Regulada....	23
Figura 3. 4 – Percentual de desvio da carga x contratos e respectivas penalidades	24
Figura 4. 1 – Equações dos métodos baseados no modelo de Amortecimento Exponencial. Fonte: Modelos Estatísticos de Previsão [70]	41
Figura 4. 2 – Tipos de séries (quanto à estacionaridade).....	42
Figura 4. 3 – Decomposição da série de consumo de energia da CELPE em tendência, sazonalidade e ruído	45
Figura 4. 4 – Tipos de tendência.....	46
Figura 4. 5 – Componente de tendência (em vermelho) para série do consumo faturado de energia da classe industrial cativa (em azul) da CELPE – jan/97 a jul/05	47
Figura 4. 6 – Fatores sazonais mensais para série consumo industrial cativo CELPE – Jan/97 a jul/05.....	47
Figura 4. 7 – Série com $q = 2$ - nível nervoso	49
Figura 4. 8 – Série com $q = 0,2$ - nível suave	49
Figura 4. 9 - Série com $q = 0,02$ - nível se aproxima de uma constante	49
Figura 4. 10 – Linha do tempo: Evolução do estudo de Redes Neurais no mundo.....	56
Figura 4. 11 – Neurônio Biológico	58

Figura 4. 12 – Neurônio de McCulloch e Pitts, onde Σ é a soma ponderada das entradas e T a função de ativação	59
Figura 5. 13 – Exemplo de rede de duas camadas.....	59
Figura 5. 14 – Função de ativação degrau, sigmoidal,, gaussiana e linear.....	60
Figura 4. 15 – Fases do algoritmo de back-propagation	62
Figura 4. 16 – Comparações entre os modelos Perceptron e Adalaine	63
Figura 5. 17 – Termo momentum influenciando na velocidade de convergência.....	64
Figura 4. 18 – Sistema ANFIS	69
Figura 5. 1 - Exemplo de outliers e quebras estruturais na série de energia distribuída da CELPE jan/70 a dez/09	72
Figura 5. 2 - Mudança de tendência da série histórica de energia distribuída da CELPE após o período de racionamento de energia elétrica (jun/01 a fev/02).....	73
Figura 5. 3 - Quebra estrutural da série de Energia Distribuída da CELPE após o período de racionamento de energia elétrica (jun/01 a fev/02).....	73
Figura 5. 4 – Tela do Forecast pro.....	76
Figura 5. 5 – Fluxograma do STAMP	77
Figura 5. 6 – Tela do STAMP	78
Figura 6. 1 – Gráfico de Correlação de resíduos	81
Figura 6. 2 – Desagregação da série de energia distribuída da CELPE em nível, tendência, sazonalidade e erro.	83
Figura 6. 3 – Teste de normalidade	84
Figura 6. 4 – Configuração da Rede Neural utilizada	87
Figura 6. 5 – Funções de ativação da camada oculta (tansig) e da camada de saída (logsig)	88
Figura 6. 6 – Correlograma Autocorrelação de resíduos.....	93
Figura 6. 7 – Gráfico Energia Distribuída – Realizada x Prevista utilizando o modelos de Regressão Dinâmica do Forecast.....	93

ÍNDICE DE TABELAS

Tabela 3. 1 - Comparação dos Modelos antes e depois de 1998.....	18
Tabela 6. 1 – Parâmetros de sazonalidade.....	80
Tabela 6. 2 – Comparação dos Modelos Box & Jenkins testados.....	82
Tabela 6. 3 - Comparação dos Modelos Estruturais.....	85
Tabela 6. 4 – Simulações Redes Neurais.....	85
Tabela 6. 5 – Codificação da Sazonalidade com Senos e Cossenos.....	86
Tabela 6. 6 – Resultado dos modelos de RNA – MAPE 2009.....	88
Tabela 6. 7 – Comparação mensal dos MAPEs dos modelos para o ano de 2009.....	89
Tabela 6. 8 – Comparação anual dos MAPEs do modelo do ANFIS.....	95
Tabela 6. 9 – Comparação anual dos MAPEs dos modelos de Longo Prazo.....	96

CAPÍTULO 1

1 Introdução

Este capítulo apresenta a motivação, os objetivos e uma descrição da organização da dissertação.

1.1 - Motivação

Com a estruturação do mercado de energia ao final da década de 90, a previsão de mercado veio ganhando destaque cada vez maior, enveredando por diversos seguimentos, com sua importância enfatizada nos processos de planejamento do setor e na modicidade tarifária. No aspecto micro da concessionária, o foco maior está na questão de contratação de energia onde se estabelece uma margem de segurança que caso venha a ser rompida, poderá gerar prejuízos às concessionárias de energia elétrica. Não menos importante, está também, a questão do planejamento estratégico da empresa, onde nesse contexto as previsões de mercado contribuem para estratégias de negócios e possibilitam direcionar as ações a serem tomadas.

A previsão de carga pode ser classificada em três horizontes, previsão de curto, médio e longo prazo. As previsões de curto prazo geralmente, são referentes ao horizonte de até um mês, e são utilizadas, principalmente, para subsidiar a operação do sistema, orientando órgãos como o Operador Nacional do Sistema – ONS. Um exemplo é o alerta da necessidade de acionamento de usinas térmicas para suprir a uma alta de demanda aliada à restrição de geração hidráulica devido ao baixo nível pluviométrico.

A previsão de curto prazo também pode subsidiar decisões estratégicas da empresa, como intensificar o combate às fraudes de energia, de forma a elevar a energia faturada da concessionária, possibilitando alcance de metas como o índice de perdas ou receita líquida.

No âmbito do médio prazo (de um a cinco anos), as previsões são necessárias para viabilizar o planejamento da expansão do sistema, com medidas que podem ser tomadas durante esse período, como implantação de usinas termelétricas e Pequenas Centrais Hidroelétricas (PCHs). No entanto, sua importância pode ser estendida ao planejamento financeiro da empresa com previsão do seu mercado para os anos seguintes, subsidiando seus respectivos orçamentos. Previsões que abrangem esse horizonte servem ainda, para

“calibrar” a compra de energia, efetivando ajustes necessários com base nos mecanismos disponíveis dentro da regulação do setor. Vale destacar ainda o impacto dessas previsões no cálculo da tarifa, que é reavaliado a cada quatro anos, onde uma previsão acima do valor realizado pode incidir em um aumento de tarifa acima do necessário, provocando desgastes com os consumidores por parte da distribuidora, bem como protestos por parte da população. Por outro lado, uma previsão abaixo do realizado, pode ratificar uma tarifa que não remunere adequadamente a concessionária acarretando em anos de prejuízo.

Por fim, não menos importante, a previsão de longo prazo (acima de cinco anos) é essencial para realização do planejamento da expansão do sistema elétrico. Esses estudos são feitos tanto no âmbito local (estado), quanto no nacional. Para o planejamento do sistema da concessionária, são feitas as chamadas “previsões por barramento”, onde são projetados os mercados por subestações e centros de carga, de forma a apresentar futuros gargalos e necessidades, devido às expansões em determinadas regiões do estado. Um exemplo maior trata-se da região de SUAPE em Pernambuco, onde o crescimento do seu entorno está cima da média estadual, necessitando de uma maior atenção e consequentemente investimentos diferenciados.

No país os estudos de planejamento para o setor são realizados pela Empresa de Pesquisas Energéticas – EPE, através do sistema SIMPLES (Sistema de Informações de Mercado para o Planejamento do Sistema Elétrico), onde cada empresa envia suas previsões no horizonte de dez anos, que posteriormente são consolidadas e agregadas, de forma a se ter uma idéia do mercado nacional futuro. Paralelamente a própria EPE, faz suas previsões que são confrontadas às das concessionárias. Esse estudo possibilita vislumbrar a necessidade de se investir no setor com projetos de maturação longa, como usinas hidroelétricas e construção de linhas de transmissões.

Existem diversos modelos de previsão de carga. Tradicionalmente utilizavam-se métodos estatísticos de análise de série temporais como: regressão linear; amortecimento exponencial e Box Jenkins, que dependendo dos dados a serem analisados se adequasse bem à série.

Outra alternativa é o emprego de modelos não lineares: Rede Neural Artificial; Lógica Fuzzy; Sistemas Neuro-Fuzzy; Árvore de Decisão e Algoritmos Genéticos. A facilidade desses métodos em mapear relações não-lineares complexas tem sido responsável pelo número crescente de aplicações em previsão de carga.

A diversidade de técnicas de projeção de mercado de energia elétrica e a necessidade de resolver problemas práticos de interesse das empresas do setor elétrico foram as principais motivações para a realização deste trabalho.

1.2 - Objetivos do Trabalho

O mestrado iniciado em agosto de 2008 foi motivado pelo trabalho desenvolvido na Companhia Energética de Pernambuco – CELPE, na Unidade de Previsão de Mercado da Unidade de Gestão de Mercado – CMME, do Departamento de Gestão de Mercado – CGM, o qual são realizados estudos de mercado, dentre eles previsões de carga em diversos horizontes e modelos.

Conforme já exposto, na seção 1.1, a previsão de mercado é de grande relevância para estudos de planejamento e expansão, existindo assim, a necessidade de atenção constante, com aperfeiçoamento e aprofundamento dos métodos preditivos mais disseminados.

No entanto, existe dúvida no tocante ao melhor modelo a ser utilizado, e como melhor avaliar o modelo. Hoje a forma mais usual de avaliação de um modelo, como forma de comparação é o MAPE (Erro Médio Absoluto Percentual), que calcula a média dos módulos dos desvios percentuais. De posse dessa ferramenta estatística, pode-se comparar os resultados dos diversos modelos distintos, de forma a escolher o que obteve o menor indicador.

O principal objetivo do trabalho é realizar uma competição de modelos (estatísticos ou de inteligência artificial), possibilitando escolher através do MAPE o que tem o melhor desempenho no médio e longo prazo.

Para o horizonte de médio prazo foram analisados os modelos de Amortecimento Exponencial, Box & Jenkins, Estruturais e Redes Neurais.

No longo prazo foram analisados os modelos de regressão dinâmica comparando-o com um modelo baseado no sistema Neuro-Fuzzy (ANFIS)

Para os modelos de longo prazo foram dispostas as variáveis explicativas PIB (Produto Interno Bruto) e Número de Consumidores.

No âmbito de estudo das redes neurais artificiais existem diversos algoritmos de treinamento. Comparar a capacidade de resposta dos algoritmos de treinamento *Rprop* [1] e o algoritmo *Levenberg-Marquardt* [2,3,4] quando aplicados na previsão de carga elétrica também é um dos objetivos deste trabalho.

1.3 - Organização da Dissertação

Esta dissertação está dividida nos capítulos descritos a seguir:

- **O capítulo 2** – Apresenta uma visão do mercado de energia elétrica da CELPE, a ser analisado, apresentando as principais variáveis que impactam de forma direta e indireta o mercado de energia da concessionária.
- **O capítulo 3** - Apresenta a necessidade da previsão de carga, contextualizando sua importância no modelo do setor elétrico brasileiro em vigor atualmente.
- **O capítulo 4** - Apresenta uma revisão bibliográfica, necessária para a contextualização do problema e do desenvolvimento das soluções propostas pela dissertação, bem como faz um apanhado dos modelos utilizados para a projeção do consumo de energia elétrica (Energia distribuída = mercado cativo + mercado livre), diferenciando-os em dois grupos, médio e longo prazo.
- **O capítulo 5** – Destaca a formatação do banco de dados, como tratamento da série, escolha do horizonte do histórico, elaboração de cenários, projeção das variáveis exógenas e apresenta as ferramentas utilizadas para simulação dos modelos de previsão.
- **O capítulo 6** – Apresenta o resultado dos modelos, com a análise do melhor desempenho.
- **O capítulo 7** – Por fim, apresenta-se a conclusão e perspectivas de trabalhos.

CAPÍTULO 2

2 - Mercado de Energia Elétrica – Pernambuco

Este capítulo apresenta um pouco da caracterização do mercado de energia elétrica de Pernambuco.

2.1 - Histórico – Modalidades de consumo

Em 08/10/1968 a Portaria nº 670 do Ministério de Minas e Energia (MME) passou a operacionalizar as Condições Gerais de Fornecimento de Energia elétrica, prevista no Decreto nº 41.019 (27/02/1957). Posteriormente o DNAEE (criado em 1968) editou outras Portarias que vieram a alterar a portaria nº 670. Atualmente a Resolução ANEEL nº 456 (de 29/11/2000) é o documento básico que trata desse assunto, e o Art. 20º, trata da classificação dos consumidores em classe de consumo (residencial, industrial, comercial, rural, poder público, iluminação pública, serviço público, consumo próprio).

Cada classe de consumo possui características distintas e conforme o Art. 18º da mesma resolução, os consumidores deverão ser cadastrados de acordo com a sua atividade exercida, e alocados na classe mais adequada.

Ainda conforme a resolução ANEEL 456, o Art. 6º, estabelece os critérios para escolha da tensão de fornecimento do cliente. No estado de Pernambuco existem consumidores atendidos em baixa tensão (220 V ou 380 V), média tensão (13,8 kV) e alta tensão (69 kV e 230 kV).

Os consumidores atendidos em “média” ou “alta tensão” poderão optar por tarifas diferenciadas, de acordo com sua modelagem de carga (formato da curva e sazonalidade), optando por tarifas convencionais, horosazonais¹ azul ou verde.

O Art. 63 da Resolução ANEEL 456, estabelece critérios para reconhecimento da sazonalidade para fins de faturamento.

¹ Modalidade tarifária horosazonal = Caracteriza-se por apresentar preços diferenciados de demanda e consumo de energia elétrica de acordo com as horas do dia (ponta e fora ponta) e períodos do ano (seco e úmido).

2.2 - Mercado por segmentos

2.2.1 - Mercado por classe de consumo

A classe de consumo mais representativa da CELPE é a residencial que participa com 35,7% da Energia Distribuída (Mercado cativo + mercado livre) no período de janeiro a outubro/09, seguida da industrial (24,3%) e comercial (19,5%), conforme o gráfico apresentado na **Figura 2.1**.




Figura 2. 1 - Participação do consumo por classe – CELPE (jan a out/09)

Ao longo das últimas quatro décadas observa-se uma movimentação das participações das classes, com aumento da residencial, comercial e rural e queda da participação industrial.

A **Figura 2.2** apresenta a evolução das três principais classes, com destaque para três períodos distintos. Nos anos de 1970 a 1993, observa-se uma tendência de queda de participação da classe industrial em detrimento do crescimento das classes residencial e em menos intensidade da comercial. Essa situação se configura, em parte pela expansão do número de consumidores, corroborada pela intensificação do programa de universalização dos serviços de energia elétrica pelo governo de Pernambuco, principalmente nas décadas de 1980 e 1990. Outro fator que pode ter contribuído para esse desempenho, foi a migração

da população rural para os grandes centros urbanos, evidenciada na década de 1970, tendo como consequência o aumento de consumidores em regiões já eletrificadas, além da decadência do setor sucroalcooleiro na década de 1980 e 1990, que teve reflexos no desempenho da indústria pernambucana, fortemente influenciada pelo setor.




Figura 2. 2 - Histórico da Participação do consumo – CELPE (residencial, industrial e comercial)

Outro período a ser destacado é delimitado entre os anos de 1994 e 2000. Esses anos foram marcados pela estabilização da economia, proporcionada pelo “plano real”. Com inflação baixa, abertura do mercado (início dos anos 90) e aumento da renda do trabalhador, houve uma “corrida” às lojas para compra de aparelhos eletrodomésticos, arrefecendo o consumo comercial e, por conseguinte da classe residencial.

Em contra partida a classe industrial continuava em franco declínio no que diz respeito à participação no mercado de energia elétrica. Novas fontes se tornavam atrativas, como o gás-natural. O setor ainda amargava um período de decadência com o fechamento de várias indústrias do setor têxtil e sucroalcooleiro.

Correndo por fora, a classe comercial passou a apresentar ganho em participação, calcada na queda da participação da classe industrial e no surgimento de grandes empreendimentos como shoppings centers e lojas de departamentos. Nada mais do que 6 shoppings centers foram inaugurados nesse período. Antes disso existia apenas um shopping no estado e nesse mesmo período inaugurou sua quarta expansão.

A partir de 2001 a evolução da participação das três classes se estabiliza, em parte devido às consequências do racionamento de energia elétrica que perdurou de maio/2001 a

fevereiro/2002. Nesse período a maioria dos consumidores foi obrigada a reduzir o consumo de energia elétrica em 20%, fato que incentivou medidas de racionalização e efficientização de energia, por parte do cliente, com aumento de posses de equipamentos mais eficientes, inclusive inserindo o hábito de aquisição de equipamentos com o selo PROCEL (Programa Nacional de Conservação de Energia Elétrica).

Paralelamente as indústrias e o comércio também tomaram suas medidas de efficientização. No entanto, o setor industrial pernambucano, passou a sofrer um processo de diversificação, com a implantação de novos empreendimentos, possibilitando o surgimento de novos pólos como o naval, petroquímico e eólico. Essa movimentação de novas indústrias, principalmente na área de SUAPE, vem possibilitando uma retomada do setor industrial no estado, o que deverá provocar no médio prazo um aumento da participação da classe perante as outras.

2.3 - Fatores que influenciam o mercado de energia da CELPE

Alguns fatores são decisivos para explicar o comportamento do consumo de energia:

- Fatores exógenos: fatores macroeconômicos, demográficos e climáticos.
- Fatores endógenos: recuperação de perdas, calendário de leitura.

2.3.1 - Fatores Macroeconômicos

São fatores que dependem da situação macroeconômica do país e do estado. Medidas contracionistas ou expansionistas adotadas pelos governos impactam diretamente nos indicadores, como renda, produção industrial, vendas no comércio, taxa de desemprego. A alteração nessas variáveis pode provocar reflexos diretos e indiretos no consumo de energia das diversas classes de consumo.

2.3.1.1 – Renda

O nível de renda da população impacta consumo de energia para praticamente todas as classes de consumo, com ênfase na classe residencial, afetando-a de duas formas: de maneira direta, pois com o aumento da renda per capita, a população passa a adquirir novos

bens de consumo, dentre eles, bens duráveis como eletrodomésticos, residências; etc. e de forma indireta, pois com o aumento das aquisições de bens, tem-se aumento nas vendas no comércio (aumento do consumo comercial), que por sua vez requisita da indústria (aumento do consumo industrial) maior produção do produto, que por consequência solicita mais matéria-prima (aumento do consumo rural/industrial), desencadeando aumento de oferta de emprego, aumentando a competição por mão-de-obra, elevando os salários e aumentando a renda. Com esse aumento, o consumidor passa a adquirir novos bens, dentre eles eletro intensivos, elevando o consumo da classe residencial.

Vários indicadores de renda podem ser correlacionados com o consumo de energia elétrica, a exemplo da renda disponível, PIB (produto interno bruto), PNB (produto nacional bruto), renda nominal, renda do trabalhador, renda por domicílio, etc.

A **Figura 2.3** apresenta um estudo de elasticidade da energia distribuída versus o PIB de Pernambuco. Verifica-se uma elasticidade de 1,78%, ou seja, caso o PIB cresça 1% a energia distribuída deverá crescer em média 1,78%.




Figura 2. 3 – Gráfico da Regressão da Energia distribuída da CELPE x PIB/PE. Fonte: CEPLAN

2.3.2 - Fatores Demográficos

São fatores relacionados ao crescimento populacional e ao número de habitantes por domicílios. O aumento populacional e consequentemente o aumento no número de domicílios têm relação direta com elevação do número de clientes, que por sua vez tem relação diretamente proporcional com o aumento do consumo.

2.3.2.1 - População

Essa variável afeta diretamente o número de clientes da CELPE e, por conseguinte o consumo de energia. No entanto, cabe ressaltar, que a série de crescimento populacional é bastante comportada, de baixa variância e boa previsibilidade.

A **Figura 2.4** apresenta uma regressão linear utilizando como variável dependente o número de clientes faturados e a variável independente a população do estado de Pernambuco. Verifica-se um poder de explicação do modelo na ordem de 99,69%.

O aumento no número de clientes faturados tem como consequência o aumento do consumo CELPE.




Figura 2. 4 - Gráfico da Regressão linear População x Número de clientes faturados

2.3.2.2 - Número de domicílios

O número de domicílios afeta mais diretamente o número de clientes do que a população, pois cada domicílio representa um consumidor CELPE, enquanto que a população deverá ser dividida pelo fator “número de pessoas residentes por domicílio”. Da mesma forma da população, essa é uma variável bastante estável.

2.3.2.3 - População por Domicílio

O padrão demográfico pernambucano manteve-se, até meados do século 20, relativamente estável com elevadas taxas de fecundidade total entre 7 e 9 filhos em média por mulher, refletindo a concepção de família numerosa típica de sociedades agrárias.

- A **Figura 2.5** apresenta a evolução do número de pessoas por domicílio (população/domicílios), onde se pode verificar uma tendência de decréscimo ao longo do tempo, em função da racionalização do número de filhos, que de acordo com o estudo divulgado pelo IBGE, caiu de 6,3 até 1960, para 1,8 em 2006.

Em consonância com a redução da taxa de fecundidade verifica-se uma redução no número de habitantes por domicílio que no início da década de 1970, chegou a ser de 5,3 habitantes por domicílio, encerrando 2008 com apenas 3,5.

A diminuição no número de habitantes por domicílio pode contribuir para a redução no consumo médio residencial.




Figura 2. 5 - Evolução do número de habitantes por domicílio

2.3.3 – Fatores Climáticos

São fatores relacionados ao clima, como temperatura média, máxima e mínima,

além do índice pluviométrico. Essas são variáveis de extrema importância para entender o comportamento de curto prazo do mercado de energia, principalmente os das classes residencial comercial, rural e poder público.

2.4 – Sazonalidade

2.4.1 – Definição

Entende-se como sazonalidade flutuações de uma série temporal² que se repetem em períodos máximos de até um ano, estando associada a:

- Variações climáticas ao longo de um ano (estações do ano);
- Convenções sociais (Carnaval, Páscoa, Natal, Dias das Mães, São João, e outros feriados regionais).

2.4.2 - Tipos de Sazonalidade

2.4.2.1 - Sazonalidade Aditiva

É indicada para séries nas quais a amplitude sazonal permanece homogênea ao longo do tempo, conforme **Figura 2.6**.




Figura 2. 6 - Exemplo de série histórica hipotética com sazonalidade aditiva

² Uma série temporal, também denominada série histórica, é uma seqüência de dados obtidos em intervalos regulares de tempo durante um período específico (Everitt BS. The Cambridge dictionary of statistics in the medical sciences. Cambridge: Cambridge University Press; 1995)

2.4.2.2 - Sazonalidade Multiplicativa

É indicada para séries nas quais a amplitude sazonal cresce/decrece ao longo do tempo, ou seja, existe uma dependência da sazonalidade sobre a tendência, conforme **Figura 2.7**.




Figura 2. 7 - Exemplo de série histórica hipotética com sazonalidade multiplicativa

Pode-se observar que a reta ajustada apresenta uma inclinação diferente de zero em relação ao eixo das abscissas, indicando uma dependência da sazonalidade sobre a tendência e confirmando a adequabilidade de um modelo multiplicativo para o relacionamento dos componentes da série.

2.4.3 - Análise da sazonalidade da CELPE

A **Figura 2.8** apresenta a decomposição da série histórica (1) da CELPE em quatro componentes: Nível (2), erro (3), tendência (4) e sazonalidade (5).




Figura 2. 8 – Decomposição da série histórica da CELPE

Decompondo-se a série histórica da Energia Distribuída de CELPE em componentes de nível, tendência, sazonalidade e erro, verifica-se a presença de sazonalidade multiplicativa. Esse fato decorre basicamente de dois fatores:

1. Acréscimo mensal de clientes;
2. Aumento do consumo médio residencial devido a novas posses de equipamentos elétricos.

A subseção 2.4.2.2 é evidenciada pela **Figura 2.9** do consumo médio residencial, o qual apresenta tendência de crescimento, apesar da baixa sofrida no período de racionamento de energia elétrica nos anos de 2001 e 2002. Após o racionamento nota-se uma retomada na tendência de crescimento do consumo médio residencial.




Figura 2. 9 – Gráfico do Consumo Médio Residencial x Número de consumidores total

Portanto, conclui-se que o consumo de energia elétrica no longo prazo, depende principalmente das variáveis exógenas relacionadas à renda e à demografia. Já no curto prazo as variáveis climáticas são a que apresentam relevância para o impacto na série de energia.

CAPÍTULO 3

3 - Previsão de Carga do Sistema Elétrico

A previsão de carga do sistema elétrico é de grande relevância para os agentes do setor elétrico. Neste capítulo apresentaremos o sistema elétrico brasileiro, a reestruturação do setor e os objetivos da previsão de carga.

3.1 - Sistema Elétrico Brasileiro

A energia elétrica entrou em território brasileiro no final do século XIX, através da concessão para a exploração da iluminação pública, dada pelo Imperador D. Pedro II a Thomas Edison. Em 1930, a potência instalada no Brasil era de aproximadamente 350 MW, em usinas hoje consideradas de pequeno porte, pertencentes a indústrias e a Prefeituras Municipais, na maioria hidroelétricas operando a “fio d’água” ou com pequenos reservatórios. Em meados de 1939, no governo de Getúlio Vargas, foi criado o Conselho Nacional de Águas e Energia, órgão de regulamentação e fiscalização, mais tarde substituído pelo Departamento Nacional de Águas e Energia Elétrica – DNAEE – ligado ao Ministério de Minas e Energia. A primeira metade do século XX representa a fase de consolidação da geração de eletricidade como propulsora da economia e como sendo um fator estratégico para a nação.

A partir do término da Segunda Guerra Mundial, o sistema elétrico nacional ganhou uma maior evolução com a construção da primeira grande usina, a de Paulo Afonso I, com a potência de 180 MW, seguida pelas usinas de Furnas, Três Marias e outras, com grandes reservatórios de regularização plurianual.

O sistema elétrico nacional foi edificado a partir dos anos 60 e baseou-se na geração hidroelétrica. O conjunto de usinas distribuído pelo país criou um sistema de elevada confiabilidade e relativa previsibilidade.

No final da década de 60, foi criado o Grupo de Coordenação de Operação Interligada, tomando corpo o sistema nacional interligado.

Antes de 1998 o sistema elétrico brasileiro era formado por dois grandes sistemas interligados, o sistema Sul/Sudeste/Centro-Oeste, interligado pelas principais distribuidoras de energia elétrica destas regiões; e o sistema Norte/Nordeste, integrado

pelas principais distribuidoras da região Nordeste e parte da região Norte. Atualmente, com a implantação da linha de transmissão Norte/Sul, estes dois sistemas foram interligados.

A coordenação do sistema interligado está a cargo do Operador Nacional do Sistema – ONS, cuja a finalidade é garantir a qualidade e a viabilidade econômica do suprimento de energia elétrica, além de garantir o livre acesso à rede básica.

Com tamanho e características particulares, o sistema de produção e transmissão de energia elétrica do Brasil é um sistema hidrotérmico de grande porte, com forte predominância de usinas hidrelétricas e com múltiplos proprietários. O Sistema Interligado Nacional – SIN é formado pelas empresas das regiões Sul, Sudeste, Centro-Oeste, Nordeste e parte da região Norte.

3.2 - O Novo Modelo do Setor Elétrico Brasileiro

3.2.1 - O Projeto RE-SEB

Iniciou-se em 1996, através do Projeto de Reestruturação do Setor Elétrico Brasileiro (Projeto RE-SEB), a criação de um novo modelo, sob a supervisão da Secretaria de Energia do Ministério de Minas e Energia, almejando dar mais eficiência à indústria, estimulando a competição no mercado e atraindo capitais para promover a expansão do setor [1].

As principais propostas do Projeto RE-SEB foram [2]:

- O governo federal deveria atuar prioritariamente na formulação de políticas para o setor;
- Criação de um órgão regulador, a Agência Nacional de Energia Elétrica (ANEEL), responsável pela regulação, fiscalização, concessão e mediação do mercado de energia elétrica;
- Criação de um operador para o sistema elétrico nacional, o Operador Nacional do Sistema Elétrico (ONS), responsável pela programação, otimização e coordenação do despacho centralizado da geração e uso da rede de transmissão.

- Criação de um ambiente para o registro das transações de compra e venda de energia elétrica, o Mercado Atacadista de Energia (MAE), com a atribuição de contabilizar e liquidar os contratos no mercado de curto prazo.
- As atividades de geração e comercialização de energia elétrica seriam inseridas num ambiente competitivo, mas a distribuição e transmissão permaneceriam como monopólios naturais sob forte regulação.

A conclusão do Projeto RE-SEB foi em agosto de 1998, com a definição do arcabouço conceitual e institucional do Setor Elétrico do Brasil.

A **Tabela 3.1** a seguir resume as principais diferenças entre o modelo antes de 1998 e o modelo após 1998.

Tabela 3. 1 - Comparação dos Modelos antes e depois de 1998

Modelo antes de 1998	Modelo após 1998
Financiamento através de recursos públicos	Financiamento através de recursos públicos (BNDES) e privados
Empresas verticalizadas	Empresas divididas por atividades: Geração, Transmissão, Distribuição e Comercialização
Empresas predominantemente estatais	Abertura para empresas privadas
Monopólios - Competição inexistente	Competição na geração e comercialização
Consumidores Cativos	Consumidores livres e cativos
Tarifas reguladas em todos segmentos	Preços livremente negociados na geração e comercialização

Novas funções foram criadas em função da reforma do setor, modificando o conteúdo e a forma de outras atividades.

A alteração de papel do Estado no setor de energia, deixando de ser o executor para se tornar regulador e fiscalizador, refletiu na criação de um órgão responsável por criar as normas e fiscalizar as atividades do Setor Elétrico.

No período entre 1990 e 2002, com o advento das privatizações, parte considerável das empresas de distribuição, representada por cerca de 80% de toda a energia distribuída,

e uma parcela das empresas geradoras, cerca de 20% da energia gerada no país, foi adquirida pela iniciativa privada [5].

Assim, foi instituída pela Lei nº 9427 de 26 de dezembro de 1996 e constituída pelo Decreto nº 2335 de 6 de outubro de 1997 a ANEEL, autarquia vinculada ao Ministério de Minas e Energia (MME), que tem por finalidade regular e fiscalizar a produção, transmissão, distribuição e comercialização de Energia Elétrica, zelando pela qualidade dos serviços prestados, pela universalidade de atendimento aos consumidores e pelo estabelecimento das tarifas para os consumidores finais, preservando, sempre, a viabilidade econômica e financeira dos Agentes e da indústria [6].

O Operador Nacional do Sistema - ONS foi criado pela Lei nº 9.648 de 27 de maio de 1998 e pelo Decreto nº 2655 de 2 de julho de 1998, para operar, supervisionar e controlar a geração de energia elétrica no Sistema Interligado Nacional e administrar a rede básica de transmissão de energia no Brasil, com a finalidade de atender os requisitos de carga, otimizar custos e garantir a confiabilidade do sistema, definindo ainda as condições de acesso à malha de transmissão em alta tensão do país [7].

O MAE (Mercado Atacadista de Energia), ambiente virtual, criado pela Lei nº 9648 de 27 de maio de 1998 e pelo Decreto nº 2655 de 2 de julho de 1998, como um mercado auto-regulado, foi instituído através da assinatura de um contrato de adesão multilateral (Acordo de Mercado), com a finalidade de viabilizar a comercialização de energia elétrica por meio de Contratos Bilaterais e do Mercado de Curto Prazo, promovendo a livre concorrência e a ampla competição entre as empresas que executam os serviços de energia elétrica no Sistema Interligado Nacional. A ASMAE era a Administradora de Serviços do Mercado Atacadista de Energia Elétrica, uma sociedade civil de direito privado, braço operacional do MAE e empresa autorizada da ANEEL [7].

Em 2001, a falta de investimento ao longo dos anos nas áreas de geração e transmissão aliada ao ciclo de crescimento do consumo de energia, em decorrência de um ciclo de crescimento econômico sustentável, a partir da segunda metade da década de 1990 e um regime hidrológico desfavorável nos anos anteriores, contribuíram fortemente para a decretação de racionamento nas Regiões Sudeste, Centro-Oeste, Nordeste e Norte em 2001 [8].

O racionamento de energia vigorou no período de 1º de junho de 2001 a 28 de fevereiro de 2002, para as regiões Sudeste, Centro-Oeste e Nordeste. Na região Norte, o racionamento durou menos tempo, iniciou-se em 15 de agosto de 2001 e encerrou-se em 31 de dezembro de 2001 [8].

Após o fim do racionamento, o setor apresentou um excesso de oferta e a elevação de tarifas. Essas tarifas, no entanto, foram em geral insuficientes para remunerar distribuidoras e geradores. As empresas do setor passaram a apresentar prejuízos e algumas enfrentaram sérias dificuldades econômico-financeiras. A falta de perspectivas e a insegurança sobre o futuro prejudicaram e paralisaram novos investimentos [9].

Todos os problemas destacados geraram uma série de indagações sobre o rumo que o setor elétrico estava trilhando. Objetivando adequar o modelo em fase de implantação, foi instituído em 2002 o Comitê de Revitalização do Modelo do Setor Elétrico, resultando em um conjunto de propostas de alterações no setor elétrico brasileiro, como a reestruturação do MAE, através da Lei nº 10433, de 24 de abril de 2002, transformando a instituição ASMAE em pessoa jurídica de direito privado, com a denominação MAE, e terminando com a sua auto-regulamentação [10].

3.2.2 - A Reestruturação do Setor Elétrico Brasileiro

Entre os anos de 2003 e 2004 o Governo Federal implementou os alicerces de um novo modelo para o Setor Elétrico Brasileiro, amparado pelas Leis nº 10847 e 10848, de 15 de março de 2004 e pelo Decreto nº 5163, de 30 de julho de 2004 [11], que visam dar maior confiabilidade ao suprimento de energia elétrica, à modicidade tarifária e à universalização do atendimento.

Com o advento do novo modelo algumas instituições foram criadas:

- **Comitê de Monitoramento do Setor Elétrico (CMSE)**

Função: Avaliar permanentemente a segurança do suprimento de energia elétrica, atuando no âmbito do MME;

Lei nº 10848/2004 sendo regulamentado pelo Decreto nº 5175 de 06 de agosto de 2004 [12].

- **Câmara de Comercialização de Energia Elétrica (CCEE)**

Função: Suceder as atividades do MAE, relativas à comercialização de energia elétrica no sistema interligado;

Lei nº 10848/2004 e regulamentado pelo Decreto nº 5177 de 12 de agosto de 2004 [13].

- **Empresa de Pesquisa Energética (EPE)**

Função: Responsável pelo planejamento do setor elétrico no longo prazo;

Lei nº 10847/2004 e regulamentada pelo Decreto nº 5184 de 16 de agosto de 2004 [14].

A **Figura 3.1** exibe como ficou a nova estrutura do setor elétrico brasileiro.




Figura 3. 1 – Estrutura atual do setor elétrico brasileiro

A regulamentação da comercialização de energia, as alterações nos processos de outorga de concessões e autorizações para geração de energia elétrica, foram possíveis através do Decreto 5163 [11].

As relações comerciais entre os agentes participantes da CCEE são regidas predominantemente por contratos de compra e venda de energia [15].

Quanto à comercialização de energia, foram criados dois ambientes para celebração de contratos de compra e venda de energia, o Ambiente de Contratação Regulada (ACR), do qual participam Agentes Vendedores e Agentes de Distribuição de energia elétrica, e o Ambiente de Contratação Livre (ACL), do qual participam Agentes de Geração, Comercialização, Importadores e Exportadores de energia, e Consumidores Livres. Conforme mostrado na **Figura 3.1** [16].

No ACL os acordos de compra e venda de energia são pactuados por meio de contratos bilaterais, havendo livre negociação entre os Agentes Geradores, Comercializadores, Consumidores Livres, Importadores e Exportadores de energia.

A contratação no ACR é formalizada através de contratos bilaterais regulados, denominados Contratos de Comercialização de Energia Elétrica no Ambiente Regulado (CCEAR), celebrados entre Agentes Vendedores (comercializadores, geradores, produtores independentes ou autoprodutores) e Compradores (distribuidores) que participam dos leilões de compra e venda de energia elétrica [16].

A **Figura 3.2** apresenta os dois ambientes de comercialização de energia elétrica discriminados anteriormente, onde: G (geradores); D (distribuidores); CL (clientes livres) e COM (comercializadores) [16].




Figura 3. 2 - Ambientes de comercialização de energia elétrica

Se considerarmos “A” como o ano previsto para o início do suprimento de energia elétrica adquirida pelos Agentes de Distribuição nos leilões de energia, o cronograma para a realização dos leilões é o seguinte [11]:

- No quinto ano anterior ao ano “A” (chamado ano “A” - 5), é realizado o leilão para compra de energia de novos empreendimentos de Geração, com repasse integral do valor de aquisição da energia elétrica às tarifas dos consumidores finais [16];
- No terceiro ano anterior ao ano “A” (chamado ano “A” - 3), é realizado o leilão para aquisição de energia de novos empreendimentos de Geração (energia nova), com repasse total do valor de aquisição da energia elétrica às tarifas dos consumidores finais. No entanto o montante correspondente é limitado a dois por cento da carga do agente de distribuição comprador ocorrida no ano “A-5” ;

- No ano que antecede o ano “A” (chamado ano “A” - 1), é realizado o leilão para aquisição de energia de empreendimentos de Geração existentes (energia velha), com repasse total do montante financeiro de aquisição da energia elétrica às tarifas dos consumidores finais limitado a energia correspondente a um por cento da carga verificada no ano anterior ao da declaração de necessidade do agente de distribuição comprador [16].

A **Figura 3. 3** ilustra as formas de contratação de energia no Ambiente de Contratação Regulada.




Figura 3. 3 - Formas de contratação de energia no Ambiente de Contratação Regulada

Dessa forma as concessionárias de energia elétrica devem contratar, através de leilões promovidos pelo MME, 100% de seu mercado.

Na possibilidade da distribuidora contratar mais do que 103% da sua carga, ela assumirá o risco da energia comercializada no curto prazo.

Caso a contratação fique entre 100% e 103% da sua carga, haverá um repasse aos consumidores finais, das perdas ou os ganhos por liquidação das sobras no mercado de curto prazo, através da tarifa.

Por fim, se houver uma contratação de menos do que 100% da sua carga, a energia adquirida no curto prazo será repassada às tarifas considerando o valor mínimo entre o PLD e o Valor Anual de Referência (VR), onde este é calculado pela ANEEL em função dos preços realizados nos leilões para o ACR, e adicionalmente será aplicada uma

penalidade. A penalidade é calculada pela multiplicação do montante de energia comprada no curto prazo pelo valor máximo entre o PLD e o VR [16].

A **Figura 3.4** resume o que foi explicado acima.




Figura 3. 4 – Percentual de desvio da carga x contratos e respectivas penalidades

2.2.1 - Influência das Normas do Setor Elétrico na Previsão de Carga

Com o advento do novo modelo, foram criadas regras que estabelecem os procedimentos e requisitos para o fornecimento de informações das previsões de carga por parte das concessionárias. Citaremos as obrigações de cada um dos agentes envolvidos.

A ANEEL estabelece que as informações de carga a serem fornecidas pelas concessionárias se dividem entre:

- Aquelas que servirão para o desenvolvimento de estudos de planejamento da operação elétrica de curto e médio prazo;
- Aquelas que servirão para permitir ajustes nos dados de carga.

No âmbito da previsão de carga o novo setor elétrico, através da ANEEL, criou algumas obrigações para as empresas distribuidoras, como:

- Reunir e processar as informações de previsão de carga dos acessantes, estabelecendo rotinas de análise e de consistência dos dados, de modo a atender aos seus processos internos e aos Procedimentos de Rede;
- Estabelecer os prazos de fornecimento e as rotinas de atualização das informações, de maneira a atender aos seus processos internos e aos Procedimentos de Rede;
- Estabelecer os meios de comunicação e a padronização dos arquivos eletrônicos que permitam a transferência dos dados de carga dos acessantes;

- Analisar as informações de carga enviadas pelos acessantes e verificar a consistência das mesmas;
- Interagir com os acessantes quando da necessidade de se obter esclarecimentos ou informações complementares relativas aos dados de carga.

3.3 Objetivo da Previsão de Carga

A energia elétrica é um insumo fundamental para o desenvolvimento de qualquer país, por isso se faz necessário estudos de planejamento de longo, médio e curto prazo. O planejamento é um método que visa otimizar o processo de decisões. O Brasil é um país de grande extensão territorial, possuindo uma complexa configuração energética, que constitui o Sistema Interligado Nacional - SIN, que é operado pelo Operador Nacional do Sistema - ONS. Por ser um país em desenvolvimento, a demanda de energia elétrica está bastante atrelada ao crescimento do Produto Interno Bruto (PIB).

O planejamento da expansão do sistema elétrico nacional é estruturado considerando as características do Sistema Elétrico Brasileiro, destacando-se a geração com predominância hidrelétrica. No entanto ao longo dos anos nota-se uma maior diversificação da matriz energética, com ênfase para a instalação de usinas termoeletricas e fontes alternativas complementares como a eólica, solar e biomassa. As termoeletricas atendem uma demanda de curto prazo e apresentam custo inicial menor e tempo de execução do projeto mais curto, além de estarem próximas aos grandes centros. A intensificação de seu uso ocorreu com maior força no início dos anos 2000, em consequência do racionamento de energia elétrica ocorrido entre os anos de 2001 e 2002. Já as fontes alternativas são uma opção que caminha em consonância com os princípios ambientais que estão cada vez mais em destaque.

A extensa dimensão territorial do país proporciona ainda, uma importante diversidade regional, que vai desde o clima a aspectos culturais, que aliados à necessidade de participação de diversos agentes públicos e privados, de forma direta e indireta, nas atividades relacionadas com o suprimento de energia elétrica e ao tempo de maturação dos projetos, corroboram com a necessidade de realização de estudos para subsidiar o planejamento do sistema em diversos horizontes.

3.3.1 - Estudos de Longuíssimo Prazo, com horizonte de até 30 anos

- Busca analisar as estratégias de desenvolvimento do sistema elétrico, a composição futura do parque gerador, os principais troncos e sistemas de transmissão, estabelecendo um programa de desenvolvimento tecnológico e industrial e promovendo inventários de bacias hidrográficas. São definidas as diretrizes para os estudos de médio e curto prazo e determinados os custos marginais de expansão em longo prazo.

3.3.2 - Estudos de longo prazo com horizonte de 10 anos

- **Subsidiar o planejamento do sistema elétrico** - Subsidiar o Plano Decenal de Expansão de Energia (PDE) proporciona importantes sinalizações para orientar as ações de decisões relacionadas ao equacionamento do equilíbrio entre as projeções de crescimento econômico do país, seus reflexos nos requisitos de energia elétrica e no tocante à necessidade de expansão da oferta, em base técnica, econômica e ambientalmente sustentável. Esse plano é revisto anualmente, onde as previsões de mercado são reavaliadas, em seguida, o programa de obras de geração e transmissão é ajustado ao mercado previsto levando-se em conta as restrições físicas, financeiras, legais e sócio-ambientais. Dessa forma propicias-se modicidade tarifária, através de um processo de planejamento que possa orientar futuras ações governamentais e fornecer uma correta sinalização aos agentes do setor elétrico brasileiro, para induzir uma alocação eficiente dos investimentos.
- **Subsidiar estudos para a revisão tarifária das concessionárias de energia elétrica** - Atender a Resolução Normativa n.º 234, de 31 de outubro de 2006 [17], em conformidade com a Nota Técnica 292/2008 – SER/ANEEL [18], que estabelece os conceitos gerais, as metodologias aplicáveis e os procedimentos iniciais para o segundo ciclo de revisões tarifárias periódicas das concessionárias de distribuição de energia elétrica.

Este regulamento estabeleceu que o cálculo do fator X^3 seria função dos componentes X_a e X_e , o primeiro refletindo a aplicação do Índice de Preços ao Consumidor Amplo – IPCA – para o componente mão-de-obra da Parcela B (custos gerenciáveis) da concessionária e o segundo refletindo os ganhos de produtividade esperados em função da mudança de escala do negócio, tanto pelo aumento do consumo dos consumidores existentes, como pelo aumento do número de consumidores atendidos na área de concessão.

Para o cálculo do componente X_e , o método escolhido foi o de fluxo de caixa descontado (FCD), do tipo forward looking. Este método busca determinar os efeitos no fluxo de caixa da empresa derivados da maior produtividade na gestão da concessionária de distribuição devido às mudanças na escala do negócio, que decorrem do crescimento do mercado atendido (maior consumo ou conexão de novos clientes na área atendida). No FCD também são considerados os investimentos estimados para atender o crescimento previsto, tanto do consumo em MWh quanto do número de consumidores.

Para que a metodologia FCD seja utilizada, é necessário estimar algumas variáveis. São elas receita, custos operacionais, investimentos e base de remuneração. A receita é obtida a partir do produto entre o mercado de energia previsto para o período tarifário, desagregado por classe de consumo, e a tarifa do Ano-teste. Neste sentido, como é necessário estimar o consumo futuro de energia elétrica na área de concessão da empresa, **é indispensável que as projeções de consumo sejam as mais próximas da realidade** e que guardem coerência com os investimentos estimados, pois erros nas mesmas impactam o cálculo do Fator X.

Outro impacto da projeção de mercado é que o mercado estabelecido para o ano-teste 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\$), ambas calculadas para o ano-teste. A receita verificada

³ Fator X – Mecanismo que prevê a redução da incidência do Índice Geral de Preços de Mercado (IGP-M) nas tarifas cobradas dos consumidores. Para a definição do Fator X são considerados os ganhos de produtividade da concessionária, a avaliação da empresa pelos consumidores no Índice Aneel de Satisfação do Consumidor (IASC) e a variação do item mão-de-obra.

corresponde à receita que seria auferida aplicando as tarifas vigentes ao mercado projetado para o ano-teste. Como a receita requerida é calculada na revisão, mantendo a neutralidade da Parcela A e estabelecendo novos valores para a Parcela B, qualquer desvio na receita verificada se traduz em um reposicionamento distinto do necessário para a manutenção do equilíbrio econômico-financeiro da concessionária.

- **Subsidiar o planejamento estratégico das concessionárias de energia elétrica** – Planejamento estratégico da empresa, refere-se a questões decisivas, cujos resultados são importantes para a sua sobrevivência. Estratégia é o "caminho", o melhor modo de implementar os projetos (evitando maiores riscos). Neste sentido, todo planejamento deve ter uma estratégia, sendo o estudo de mercado um dos fatores mais importantes para a viabilização do planejamento estratégico.

O estudo de mercado é um conjunto de atividades voltadas para antever a venda e o preço de produtos, sejam bens ou serviços. Deste modo é possível estimar as receitas futuras, através das projeções de consumo de energia e compará-las com os custos previamente estabelecidos, a fim de definir a viabilidade do projeto/negócio.

Dessa forma, podemos concluir que a previsão de consumo de energia elétrica (ou carga elétrica), é de suma importância para se planejar a expansão do sistema elétrico. No âmbito da concessionária de energia elétrica, a previsão se torna ainda mais relevante, pois além do seu planejamento físico e econômico/financeiro, ela servirá para se construir uma modicidade financeira e principalmente será determinante para a aquisição dos montantes de energia elétrica a serem arrematados em leilões, podendo pagar penalidade caso exista déficit ou sobra além do determinado por lei.

CAPÍTULO 4

4 – Base Teórica

Para realizar a competição de modelos de previsão de carga elétrica foi necessário pesquisar em diversos periódicos da área. Iremos apresentar agora um resumo dos mais tradicionais modelos de previsão de carga publicados, bem como uma breve explicação sobre os modelos estatísticos de séries temporais e de inteligência artificial utilizados na modelagem do sistema

4.1 – Revisão Bibliográfica dos Modelos de Previsão de Carga

Atualmente existe uma grande diversidade de modelos de previsão de carga, dentre eles destacam-se os modelos auto-regressivos multiplicativos, modelos dinâmicos lineares e modelos não-lineares [19,20,21]. São também bastante difundidos os modelos ARIMA [20], modelos estruturais [22] e o uso das funções de transferências de Box & Jenkins [19].

Na década de 90 com a retomada dos estudos na área de inteligência artificial, passamos a ter sistemas cuja especialidade são as previsões de cargas [23].

4.1.1 - Amortecimento Exponencial

Um dos métodos bastante difundidos para previsão de carga é o método de Amortecimento Exponencial, que apesar de simplória é uma metodologia bastante adequada para alguns tipos de séries temporais.

O método de amortecimento exponencial simples pode ser entendido como uma generalização da equação de média móvel simples [24,25].

Vários são os trabalhos na área de previsão de mercado de energia elétrica, que utilizaram o modelo de Amortecimento Exponencial. Alguns utilizam essa metodologia para modelar períodos atípicos como o racionamento de energia elétrica ocorrido em 2001/2002 [26], outros tratam da previsão de carga propriamente dita [27].

4.1.2 - Box & Jenkins

A metodologia Box & Jenkins [24,28,29] é um pouco mais complexa do que a aplicada aos modelos de Amortecimento Exponencial. Ela é amplamente difundida em estudos de projeção utilizando séries temporais, onde diversos trabalhos serviram como base para formatação da idéia inicial dessa dissertação [30,31,32,33,34,35], sendo alguns ligados diretamente ao aspecto da previsão de carga elétrica/mercado de energia [31,32] e outros que serviram apenas de subsídio para verificar a aplicabilidade do modelo de Box & Jenkins e comprovar sua versatilidade [30,33,34].

O modelo Box & Jenkins pode ser utilizado não só da forma univariada, como também da forma multivariada. Em 2008 a Companhia Energética de Pernambuco – CELPE, iniciou os preparativos para o processo de revisão tarifária a qual foi submetida em 2009 [35]. Dentre os processos a serem trabalhados, estava à previsão de mercado de energia elétrica [36,37], na qual foram utilizados modelos causais [37] e univariados [36] para prever o mercado por classe de consumo, sendo o modelo Box & Jenkins um dos escolhidos para classe residencial.

Vale ressaltar que a metodologia Box & Jenkins é uma das indicadas pela ANEEL [38] para servir como validação metodológica, para o segundo ciclo de revisão tarifária, das previsões de mercado enviadas pelas concessionárias de energia elétrica.

4.1.3 - Modelos Estruturais

A metodologia de Modelos Estruturais [39,40] surgiu como uma alternativa aos modelos Box & Jenkins. Em tais modelos, a série é decomposta em termos da tendência, do ciclo, da sazonalidade e de um componente irregular.

Os modelos estruturais foram bastante difundidos a partir do final da década de 1980 e início da década de 1990. Alguns estudos podem ser destacados como previsão do preço spot (Preço de uma transação no mercado à vista) de energia elétrica [41]. No entanto, sua aplicabilidade vai de modelos de previsão de séries temporais como ferramenta de decisão de compra e venda de contratos futuros de boi gordo [42] a modelos de previsão para número semanal de adultos hospedados em hotéis [43], evidenciando uma grande diversidade de aplicação

4.1.4 - Redes Neurais Artificiais na Previsão de Carga

Conforme apresentado em algumas publicações [44,45,46,47,48], o método de previsão de carga utilizando redes neurais é bastante eficiente. Uma rede neural possibilita o mapeamento linear da carga elétrica, extraindo as características mais complexas das séries, o que incentivou os pesquisadores.

Pode-se estudar os modelos de previsão com base nas redes neurais através dos seguintes aspectos: tipos de entradas, horizontes de previsão, arquitetura da rede e como é realizada a previsão horária.

Geralmente o próprio histórico de carga, já é uma boa entrada para as redes neurais e por isso muitos autores utilizam este tipo de entrada [44,49]. No entanto, devido à existência de uma perceptiva relação entre a temperatura e o consumo de energia elétrica, alguns pesquisadores têm estudado a utilização de variáveis climáticas na entrada, tais como temperatura, umidade relativa, e índice pluviométrico [50,51].

Dentre as variáveis explicativas, o tipo de entrada mais encontrado nos modelos de redes neurais em relação às variáveis meteorológicas é a temperatura. Em alguns casos, os valores de temperatura são previstos e então utilizados na previsão de carga, acarretando um maior erro na previsão [47,48]. Há estudos que mostram a previsão de carga utilizando somente dados de temperatura, nestes casos o horizonte máximo é uma hora à frente [52].

O estudo de caracterização de carga, através da análise do perfil da curva de carga, constata uma interessante relação entre o consumo de energia elétrica e a hora do dia. Geralmente o horário de ponta ocorre no mesmo horário, para todos os dias úteis da semana. Algumas melhoras do desempenho da rede, puderam ser proporcionadas pela utilização das informações sobre a hora do dia como entrada para a rede neural [53,54,55].

O dia da semana é outro fator levado em consideração nas previsões de carga de curto prazo, independente da região ou do seguimento a curva de carga tem um comportamento diferenciado nos dias úteis, nos fins de semana e nos feriados.

Algumas pesquisas utilizam na entrada da rede neural esta informação para melhorar os resultados de previsão [50]. Outra opção é dividir os dados conforme o perfil e criar uma rede para cada dia da semana [51,52].

Quanto ao horizonte de previsão, a grande maioria dos trabalhos contempla a previsão em curtíssimo prazo (10 minutos a 1 hora à frente) para utilização em pré-despacho de energia. Um bom número de publicações é voltado para a previsão em curto

prazo (um a sete dias à frente). Estudos em previsão de carga horária em médio e longo prazo são mais difíceis de serem encontrados [56,57,58,59].

Quanto ao aspecto da arquitetura podemos fazer as seguintes considerações:

- Quanto ao número de camadas ocultas:

Em geral as pesquisas utilizam redes neurais com apenas uma camada oculta, porém há trabalhos que comparam as redes neurais com uma única camada oculta com as de duas camadas e chegando a conclusão de que as de uma camada oculta proporcionam melhores resultados [60].

- Número de neurônios na camada oculta:

Bons resultados foram alcançados utilizando uma quantidade de neurônios superior a quantidade de entradas [57,58], da mesma forma que outras pesquisas chegaram a conclusões satisfatórias utilizando uma quantidade de neurônios inferior ao número de entradas [49,61].

A escolha do número de neurônios na camada oculta normalmente é um critério de escolha do próprio pesquisador. No entanto, vale ressaltar o critério da parcimônia, pois redes com muitos neurônios na camada oculta podem demandar um maior volume de tempo para serem treinadas e utilizam um conjunto de entrada com muitos padrões. Já as redes com poucos neurônios podem não aprender o comportamento da série.

- Número de neurônios na camada de saída:

A questão do número de neurônios na camada de saída é bastante relativa. Alguns trabalhos contam com 24 saídas para prever a curva diária [45,55,57], outros só possuem uma saída e realizam previsões separadas para cada hora [62]. Há ainda aqueles que criam redes com apenas uma saída, prevêm o consumo de uma hora e utilizam este consumo na previsão da hora seguinte [63].

4.1.5 - Lógica Fuzzy na Previsão de Carga

Na Lógica Fuzzy aplicada à previsão de carga, as regras são determinadas em decorrência dos dados numéricos históricos de carga e das análises dos especialistas [63,46,64].

Uma das grandes dificuldades da utilização de sistemas fuzzy na previsão de carga é justamente o processo de criação das regras, pois podem ocorrer redundâncias que deixem o problema com um grau de complexidade maior e com demora na solução.

Geralmente os trabalhos publicados que utilizam lógica fuzzy, são para horizonte de curtíssimo prazo (10 minutos).

4.1.6 - Sistemas Neuro-Fuzzy na Previsão de Carga

A análise dos sistemas neuro-fuzzy é realizada a partir de suas características fuzzy e de aprendizado. A primeira engloba a escolha do modelo fuzzy, a função de pertinência a ser utilizada, a divisão do espaço de entrada/saída e o método de defuzzificação. Já a segunda requer a definição quanto ao modo de apresentação dos padrões, à estrutura a ser utilizada e ao método de aprendizagem dos parâmetros.

Alguns trabalhos se baseiam em sistemas cujas redes neurais e a lógica fuzzy do sistema não têm nenhuma relação [65].

Existem estudos [66] sobre utilização das redes neurais para classificação, agrupamento dos dias com curvas de carga semelhantes, aplicação de inferência estatística e aperfeiçoamento da previsão utilizando como dados de entradas informações de temperatura.

Em [63] é propôs um sistema que gera uma rede neural de inferência fuzzy para previsão de carga elétrica para o período de um dia. O modelo classifica as variáveis de entrada e saída que fornecem a localização inicial das funções de pertinência e os valores iniciais dos consequentes das regras através das redes de Kohonen. Posteriormente a localização e os pesos das funções de pertinência bem como os parâmetros dos consequentes através do método do gradiente descendente são calculados de forma sucessiva.

Já em [46] é utilizado um sistema de rede neural fuzzy, com uma rede neural de três camadas, para previsão horária de carga em curto prazo. Inicialmente o sistema fuzzy possuía apenas uma regra que era criada a partir do primeiro par “entrada-saída” do conjunto de treinamento. Posteriormente ao treinamento da rede são criadas novas regras e os parâmetros das funções de pertinência são ajustados. Para o treinamento é utilizado o método do gradiente descendente.

Outros modelos de previsão são os sistemas paralelos, ou seja, sistemas que utilizam mais de uma técnica para realizar a previsão. Pode-se encontrar esse tipo de modelagem em [65] onde foi trabalhado um modelo híbrido (rede neural e lógica fuzzy) que prevê às 24 horas do próximo dia. Em um primeiro momento o histórico da carga foi atualizado em relação à demanda atual da carga, posteriormente tentou-se traçar o perfil da

carga dos dias diferentes por meio de uma rede de Kohonen. Por fim, a previsão da carga para o dia atual é obtida então usando a memória auto-associativa da rede neural. Um processador paralelo fuzzy faz exame de variáveis tais como o tipo do dia, o tempo e o feriado.

Outros modelos híbridos integram as características das redes neurais com as dos sistemas fuzzy. Em [64] é realizado o treinamento da rede, e posteriormente é feita a previsão da carga horária. Em um segundo momento o sistema fuzzy altera esta previsão considerando a temperatura e atipicidade dos dias feriados. Análises das variações de consumo em relação à temperatura são realizadas de forma a subsidiar a geração de um sistema fuzzy.

Os sistemas neuro-fuzzy também podem ser utilizados para realizar a previsão de dias anômalos (feriados, sábado, domingo) [67]. Dessa forma pode-se inserir o conhecimento do especialista, gerando variáveis de entrada que usem este conhecimento, possibilitando mais informações para subsidiar a previsão.

Os modelos neuro-fuzzy possuem limitação quanto ao número de entradas que pode ser utilizado. Isso ocorre devido à combinação de regras e o particionamento em forma de grade. A maioria dos sistemas neuro-fuzzy existentes, NEFCLASS [68], ANFIS [69], utiliza particionamento em grade.

4.2 – Base Teórica

4.2.1 Amortecimento exponencial

Podemos definir uma série temporal como um conjunto de observações de uma dada variável, ordenadas em conformidade com um parâmetro de tempo, normalmente em intervalos iguais, e que apresentam uma correlação entre eles. A idéia da análise, então, é estimar uma equação matemática que expresse a dependência serial dos dados passados possibilitando a projeção destes.

Dessa forma segue uma descrição do método de amortecimento exponencial. Considera-se que o conjunto de observações $Z_1, Z_2, \dots, Z_T$ seja uma série temporal de tamanho “T”.

Caso esta série represente um conjunto de dados de determinada empresa cuja demanda mensal seja mais ou menos constante no seu nível ao longo do tempo, ou seja, não ocorrem mudanças significativas no nível de venda com o tempo, podemos utilizar a seguinte equação de previsão:

$$Z_t = a(T) + \varepsilon_t \quad (4.1)$$

Onde:

Z_t = venda no período t ($t = 1, 2, \dots, T$);

$a(T)$ = parâmetro representativo do nível médio das vendas no instante T ;

ε_t = erro de previsão e $\varepsilon_t \sim N(0, \sigma^2)$.

Devido ao fato desse produto (nível de venda) ser mais ou menos constante, a estimativa ($\hat{a}(T)$) para o parâmetro “a” na **Equação 4.1** apresenta exatamente uma projeção para o produto em análise. Portanto, vale ressaltar que este parâmetro pode ser estimado de diversas formas:

- **Método Ingênuo (Naive)**

Nesse modelo a previsão feita usando a série até o instante t , para os próximos τ instantes, é simplesmente repetir o último valor observado da série.

$$\hat{Z}_t(\tau) = Z_t, \tau = 1, 2, \dots \quad (4.2)$$

Onde:

$\hat{Z}_t(\tau)$: previsão para Z_T , τ passos-à-frente (previsão de $Z_{T+\tau}$ feita no instante T);

Z_T : último dado disponível

τ : horizonte de previsão

Esse modelo tem o problema de ser muito simples e só deve ser aplicado na falta de dados

- **Média**

$$\hat{a}(t) = \bar{Z}_t = \frac{1}{t} \sum_{i=1}^t Z_i ; \quad (4.3)$$

- **Média Móvel Simples (não sazonal)**

$$\text{Média móvel de tamanho } n: \hat{a}(t) = M_t = \frac{Z_t + Z_{t-1} + \dots + Z_{t-n+1}}{n} \quad (4.4)$$

Ainda:

$$M_t = M_{t-1} + \frac{Z_t - Z_{t-n}}{n} \quad (4.5)$$

Em que podemos chamar M_t de $\hat{a}(t)$ e M_{t-1} de $\hat{a}(t-1)$, que são respectivamente os estimadores do nível “a” calculados nos instantes t e $t-1$.

O problema da média e da média móvel é que em ambos os casos os dados tem o mesmo peso. O método de amortecimento exponencial surgiu para corrigir esta “deficiência”, tornando possível dar pesos diferenciados aos dados com ênfase à “idade” da informação.

A idéia da metodologia é construir um “sistema” o qual possa reestimar os parâmetros do modelo a cada período de tempo introduzindo a informação mais atual. Ao final do período T , tem-se duas informações disponíveis:

- A estimativa de “a” feita no final do período anterior $\hat{a}(T-1)$;
- O último dado disponível $Z(T)$;

De posse dessas informações pode-se calcular uma estimativa atualizada do nível de venda: $\hat{a}(T)$. Como forma de subsidiar a solução do sistema, faz-se uma modificação na estimativa velha ($\hat{a}(T-1)$) do nível por uma fração do erro de previsão resultante do uso desta estimativa para o dado mais recente. Sabendo que o erro de previsão no último período pode ser definido como $\varepsilon(T) = Z(T) - \hat{a}(T-1)$:

$$\hat{a}(T) = \hat{a}(T-1) + \alpha [Z(T) - \hat{a}(T-1)] \quad (4.6)$$

$$\hat{a}(T) = \alpha Z(T) + (1 - \alpha)\hat{a}(T-1) \quad (4.7)$$

Dado que $\hat{a}(T) \equiv S_T$, como forma de simplificar. Reescrevendo a **Equação 4.7**, tem-se que:

$$S_T = \alpha Z_T + (1 - \alpha) S_{T-1} \quad (4.8)$$

Onde:

S_T = valor amortecido da série;

α = constante de amortecimento ou hiperparâmetro (número entre 0 e 1).

A **Equação 4.8** (conhecida como modelo de Brown) indica concepção do método de amortecimento exponencial, onde para se fazer uma atualização automática do parâmetro “a”, que representa o nível de vendas na **Equação 4.1**, será feita uma combinação convexa (a soma é igual a 1), onde é dado um peso α para o “presente” (último dado) e um peso $(1 - \alpha)$ para o “passado” (estimativa anterior para o nível. Pode ser obtida de várias maneiras: média, média móvel)⁴.

O método de amortecimento exponencial possibilita dar pesos diferentes com base na “idade” da informação. Por exemplo, para séries com maior variância pode-se dar um peso mais alto para informações mais atuais. No entanto, para séries com menor variância pode-se utilizar os mesmos pesos tanto, para dados presentes quanto para os dados passados. Um aperfeiçoamento deste modelo pode ser feito quando se insere os parâmetros de tendência e sazonalidade, para modelar uma série temporal específica. Esses parâmetros são atualizados sempre conservando a premissa de dar pesos diferenciados para “presente” e “passado”:

$$\alpha * \text{Presente} + (1 - \alpha) * \text{Passado} \quad (4.9)$$

Conforme já citado, a **Equação 4.1** pode ser utilizada para modelar o comportamento de uma série que apresente um comportamento mais ou menos constante, sem grandes oscilações no nível. No entanto, este modelo não é adequado para uso em séries com alterações de nível. ou seja, na presença de um componente de tendência.

⁴ MONTGOMERY & JOHNSON (1990). Suponha que se esteja trabalhando com dados mensais de janeiro de 1994 a dezembro de 2009. A **Equação (5,7)** informa que a atualização do parâmetro de nível (portanto a previsão para o dado de janeiro de 2010, dado que o modelo para as vendas é constante) será feita dando-se um peso α para o dado de dezembro e um peso $(1 - \alpha)$ para a última estimativa feita para o dado de dezembro de 2009 (feita em novembro de 2009)

Para uma série que apresente oscilações no nível com o tempo, um modelo mais adequado é aquele representado na **Equação 4.10** a seguir:

$$Z_t = a_1(T) + a_2(T)\tau + \varepsilon_t \quad (4.10)$$

Onde:

Z_t = último dado disponível

$a_1(T)$: parâmetro de nível no instante T;

$a_2(T)$: parâmetro de tendência no instante T;

τ : tendência;

T: variável tempo (T = 1, 2, ..., T sendo t a quantidade de dados existentes);

ε_t : erro de previsão e $\varepsilon_t \sim N(0, \sigma^2)$.

Um sistema de atualização paramétrica semelhante ao ocorrido na **Equação 4.8** será implementado nos parâmetros da **Equação 4.10**. Este modelo é chamado de Holt-2Parâmetros. Os parâmetros são atualizados de acordo com as **Equações 4.11 e 4.12**:

$$\hat{a}_1(T) = \alpha * Z_t + (1 - \alpha) * [\hat{a}_1(T-1) + \hat{a}_2(T-1)] \quad (4.11)$$

$$\hat{a}_2(T) = \beta * [\hat{a}_1(T) - \hat{a}_1(T-1)] + (1 - \beta) * [\hat{a}_2(T-1)] \quad (4.12)$$

As equações acima contêm a mesma premissa até então utilizada de ponderação pelo “presente” e “passado” para se fazer a atualização dos parâmetros. No entanto, nesse caso, são usadas uma constante de amortecimento (α) para o parâmetro de nível (a_1) e outra (β), para o parâmetro de tendência (a_2).

A atualização do parâmetro de nível é feita dando uma ponderação α para o dado real mais atual e um peso $(1 - \alpha)$ para a estimativa mais atual feita para o nível que é composta por: $\hat{a}_1(T-1)$, estimativa feita para o nível no instante anterior (T-1), mais $\hat{a}_2(T-1)$, que é a estimativa feita para a tendência também no instante anterior (T-1) (**Equação 4.11**). Como agora existem dois parâmetros é feita a diferença “nível mais tendência”, que equivale à taxa de crescimento, resultando exatamente em uma estimativa de um novo nível, onde (T-1) indica que este cálculo foi feito no passo anterior. Ou seja, na atualização do parâmetro de nível, dá-se um peso para o dado mais recente e um outro peso para um valor estimado para este nível quando se estava no momento anterior (portanto, “passado”).

Na atualização do parâmetro de tendência (**Equação 4.12**), é dado um peso β para a diferença entre a atual estimativa do nível (**Equação 4.11**) e a última estimativa do nível (feita no instante anterior T-1). Variação de nível caracteriza um componente de tendência ou taxa de crescimento. Dessa forma é dado um peso β para esta estimativa “presente” do parâmetro de tendência e um peso $(1 - \beta)$ para a última estimativa da tendência feita no passo anterior (T-1).

A proposta visa desenvolver um modelo autoprojeto ou univariado. Portanto faz-se necessário que todas as componentes de uma série sejam modeladas. Até o momento, foram abordadas as estimativas de dois parâmetros (nível e tendência). No entanto, existe a possibilidade de haver um comportamento periódico da Energia Distribuída, ou seja, dependendo do mês, existe uma queda ou uma elevação. Esse fator é denominado por “sazonalidade”. Em outras palavras a série de vendas do produto analisado pode apresentar uma certa sazonalidade, ou seja, uma influência provocada por determinados períodos do ano sobre seu nível. Para esse caso o modelo que mais se ajusta pode ser o da **Equação 5.13**:

$$Z_t = (a_1(T) + a_2(T) * t) * \rho_t + \varepsilon_t \quad (4.13)$$

Onde:

Z_t = último dado disponível.

$a_1(T)$: parâmetro de nível no instante T;

$a_2(T)$: parâmetro de tendência no instante T;

T: variável tempo (T = 1, 2, ..., T sendo t é a quantidade de dados existentes);

ρ_t : fator sazonal referente ao período t;

ε_t : erro de previsão e $\varepsilon_t \sim N(0, \sigma^2)$.

Este modelo é chamado de Holt-Winters. A **Equação 4.13** absorveu um novo parâmetro para assimilar o efeito da sazonalidade na Energia Distribuída. Esse procedimento de atualização paramétrica é semelhante ao expresso na **Equação 4.8** e deverá ser empregado para atualizar de forma sequencial os parâmetros do modelo:

$$\hat{a}_1(T) = \alpha * \frac{Z_t}{\hat{\rho}_t(T-1)} + (1 - \alpha) * [\hat{a}_1(T-1) + \hat{a}_2(T-1)] \quad (4.14)$$

$$\hat{a}_2(T) = \beta * [\hat{a}_1(T) - \hat{a}_1(T-1)] + (1 - \beta) * [\hat{a}_2(T-1)] \quad (4.15)$$

$$\hat{\rho}_t(T) = \gamma * \frac{Z_t}{\hat{\rho}_t(T-1)} + (1-\gamma) * [\hat{\rho}_t(T-1)] \quad (4.16)$$

Onde:

Z_t = último dado disponível;

$\hat{\alpha}_1(T)$: estimativa do parâmetro de nível no instante T;

$\hat{\alpha}_2(T)$: estimativa do parâmetro de tendência no instante T;

T: variável tempo ($t = 1, 2, \dots, T$ sendo T a quantidade de dados existentes);

α_t : constante de amortecimento para o nível referente ao período t;

β_t : constante de amortecimento para a tendência referente ao período t;

ρ_t : fator sazonal referente ao período t.


Dessa forma, verificas-se que o nível estimado é função da observação mais recente, do fator sazonal estimado no instante anterior (mesmo mês do ano anterior) e das estimativas anteriores do nível e da tendência. A expressão $Z_t/\rho_t(T-1)$ refere-se à observação no instante T dessazonalizada. A **Equação 4.15**, demonstra que a tendência estimada é função dos níveis estimados em T e T-1 e da taxa de crescimento estimada anteriormente. A **Equação 4.16**, apresenta a essência do método de amortecimento exponencial, que se refere à atualização dos parâmetros do modelo atribuindo pesos correlacionados à “idade da informação”, ponderando “presente” e “passado” de forma diferente. Esta equação demonstra que o fator sazonal correspondente ao período T depende do fator sazonal correspondente ao mesmo período no ano anterior e da última observação. Vale salientar que o fator sazonal de um certo “mês”, só é atualizado uma vez por ano, ao receber o dado referente àquele “mês”. Por fim, totalizam-se ao todo três constantes de amortecimento (α , β e γ), uma para cada parâmetro (nível, tendência e sazonalidade) a ser atualizado.

Existem procedimentos de otimização implementados nos softwares que permitem a determinação dos valores das constantes de amortecimento. Vale ressaltar que cada constante de amortecimento possui apenas um valor associado e este valor é calculado com base no histórico de dados analisados. Enfim, pode-se afirmar que a constante de amortecimento é uma quantidade fixa que é utilizada para atualizar os parâmetros de forma sequencial. Portanto este conceito caracteriza o método de amortecimento exponencial como um modelo onde, a cada instante de tempo, a cada dado real novo, é feita uma atualização dos parâmetros do modelo com base nas equações descritas anteriormente. No

entanto, os fatores responsáveis por esta atualização são exatamente as constantes de amortecimento ou hiperparâmetros.

A **Figura 4.1** apresenta um resumo dos vários modelos que utilizam a metodologia de amortecimento exponencial, sempre apresentando um gráfico com a série temporal e a equação que mais se ajusta à característica da série.

MÉTODO DE AMORTECIMENTO DE BROWN - NÍVEL




EQUAÇÃO DO MODELO

$$Z_t = a + \varepsilon_t$$

EQUAÇÃO DE ATUALIZAÇÃO PARAMÉTRICA

$$\hat{a}_1(T) = \alpha * Z(T) + (1 - \alpha) * \hat{a}_1(T-1)$$

MÉTODO DE AMORTECIMENTO DE HOLT 2 PARÂMETROS - NÍVEL E TENDÊNCIA



EQUAÇÃO DO MODELO


$$Z_t = a_1 + a_2 * t + \varepsilon_t$$

EQUAÇÃO DE ATUALIZAÇÃO PARAMÉTRICA

$$\hat{a}_1(T) = \alpha * Z(T) + (1 - \alpha) * \hat{a}_1(T-1)$$

$$\hat{a}_2(T) = \beta * \left[\hat{a}_1(T) - \hat{a}_1(T-1) \right] + (1 - \beta) * \left[\hat{a}_2(T-1) \right]$$

MÉTODO DE AMORTECIMENTO DE WINTERS - NÍVEL E SAZONALIDADE



EQUAÇÃO DO MODELO


$$Z_t = a_1 * \rho_t + \varepsilon_t$$

EQUAÇÃO DE ATUALIZAÇÃO PARAMÉTRICA

$$\hat{a}_1(T) = \alpha * \frac{Z_T}{\rho_t(T-1)} + (1 - \alpha) * \left[\hat{a}_1(T-1) \right]$$

$$\hat{\rho}_1(T) = \gamma * \frac{Z_T}{\hat{a}_1(T)} + (1 - \gamma) * \left[\hat{\rho}_1(T-1) \right]$$

MÉTODO DE AMORTECIMENTO DE HOLT WINTERS - NÍVEL TENDÊNCIA E SAZONALIDADE



EQUAÇÃO DO MODELO

$$Z_t = (a_1 + a_2 * t) * \rho_t + \varepsilon_t$$

EQUAÇÃO DE ATUALIZAÇÃO PARAMÉTRICA

$$\hat{a}_1(T) = \alpha * \frac{Z_T}{\rho_t(T-1)} + (1 - \alpha) * \left[\hat{a}_1(T-1) + \hat{a}_2(T-1) \right]$$

$$\hat{a}_2(T) = \beta * \left[\hat{a}_1(T) - \hat{a}_1(T-1) \right] + (1 - \beta) * \left[\hat{a}_2(T-1) \right]$$

$$\hat{\rho}_1(T) = \gamma * \frac{Z_T}{\hat{a}_1(T)} + (1 - \gamma) * \left[\hat{\rho}_1(T-1) \right]$$

Figura 4.1 – Equações dos métodos baseados no modelo de Amortecimento Exponencial. Fonte: Modelos Estatísticos de Previsão [70]

4.2.2 Modelos Box & Jenkins

4.2.1.1 - Fundamento Teórico

Pode-se expressar a relação entre variáveis através de uma equação matemática da forma:

$$Y_t = \beta_0 + \beta_1 X_{1t} + \beta_2 X_{2t} \dots + \beta_k X_{kt} + \varepsilon_t \quad (4.17)$$

Onde Y é a variável a ser prevista (variável “dependente”) e os X’s são as variáveis causais ou explicativas.

O procedimento inicial é levantar o histórico de todas estas variáveis e estimar a relação entre cada uma delas e a variável dependente. Esta relação é medida pelo coeficiente de regressão (betas). Esta estimação é feita utilizando um procedimento matemático chamado MQO (Mínimos Quadrados Ordinários).

Dessa forma o modelo de Box & Jenkins, também será um modelo de regressão, entretanto sem as variáveis causais.

Para trabalhar com um modelo de Box & Jenkins, faz-se necessário que o processo em que estamos trabalhando seja estacionário de segunda ordem, ou seja, apresente média e variância constante para qualquer t.

A **Figura 5.2** apresenta os diversos casos de não estacionaridade.




Figura 4. 2 – Tipos de séries (quanto à estacionaridade)

O operador B, conhecido como o “backward shift operator”, bastante usado por Box & Jenkins na descrição dos modelos, é definido como:

$$B^k Z_t = Z_{t-k} \quad (4.18)$$

Ou seja, essa notação é apenas uma forma diferente de escrever, por exemplo:

$$B^1 Z_t = Z_{t-1} \quad (4.19)$$

$$B^2 Z_t = Z_{t-2} \quad (4.20)$$

$$B^3 Z_t = Z_{t-3} \quad (4.21)$$

Para entender melhor o modelo de Box & Jenkins imagine Z_t como uma série estacionária de segunda ordem. A modelagem propõe modelos lineares para Z_t , conhecidos como ARIMA (p,d,q). Abaixo segue alguns casos particulares:

- **AR(p) = modelo autoregressivo de ordem p**

$$\text{AR (1): } Z_t = \Phi_1 Z_{t-1} + a_t, \quad (1 - \Phi_1 B) Z_t = a_t \quad (4.22)$$

$$\text{AR (2): } Z_t = \Phi_1 Z_{t-1} + \Phi_2 Z_{t-2} + a_t, \quad (1 - \Phi_1 B - \Phi_2 B^2) Z_t = a_t \quad (4.23)$$

$$\text{AR (p): } Z_t = \Phi_1 Z_{t-1} + \Phi_2 Z_{t-2} + \dots + \Phi_p Z_{t-p} + a_t, \quad (1 - \Phi_1 B - \Phi_2 B^2 - \dots - \Phi_p B^p) Z_t = a_t \quad (4.24)$$

No entanto, esse modelo possui um problema, pois se a ordem do modelo cresce, teremos muitos hiperparâmetros Φ_i ; $i = 1 \dots, p$ para estimar, o que exigirá séries de tamanhos elevados, nem sempre disponíveis. A solução para esse caso é reduzir a ordem “p” da parte “AR” através de defasagens no ruído branco.

- **MA(q) = modelo de médias móveis de ordem q**

$$\text{MA (1): } Z_t = a_t - \theta_1 a_{t-1}, \quad Z_t = (1 - \theta_1 B) a_t \quad (4.25)$$

$$\text{AR (2): } Z_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2}, \quad Z_t = (1 - \theta_1 B - \theta_2 B^2) a_t \quad (4.26)$$

$$\text{AM (q): } Z_t = a_t - \theta_1 Z_{t-1} - \theta_2 Z_{t-2} - \dots - \theta_q Z_{t-q}, \quad Z_t = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) a_t \quad (4.27)$$

- **ARMA(p,q) = modelo autoregressivo de ordem p e médias móveis de ordem q**

$$\text{ARMA (1,1): } Z_t - \Phi_1 Z_{t-1} = a_t - \theta_1 a_{t-1},$$

$$(1 - \Phi_1 B) Z_t = (1 - \theta_1 B) a_t \quad (4.28)$$

$$\text{ARMA (2,2): } Z_t - \Phi_1 Z_{t-1} + \Phi_2 Z_{t-2} = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2}$$

$$(1 - \Phi_1 B - \Phi_2 B^2) Z_t = (1 - \theta_1 B - \theta_2 B^2) a_t \quad (4.29)$$

$$\text{ARMA (p,q): } Z_t - \Phi_1 Z_{t-1} + \Phi_2 Z_{t-2} + \dots + \Phi_p Z_{t-p} = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q}$$

$$(1 - \Phi_1 B - \Phi_2 B^2 - \dots - \Phi_p B^p) Z_t = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) a_t \quad (4.30)$$

No entanto, em séries não estacionárias na média, antes de modelar a série, faz-se necessário, produzir a sua estacionariedade através da diferenciação da série original, ou seja, produzir uma série não estacionária homogênea⁵. Desta forma, se Z_t é uma série não estacionária, procurar-se-á transformá-la na série X_t não estacionária homogênea.

4.2.1.2 – Modelos SARIMA

Na prática os processos raramente são estacionários apresentando muitas vezes componentes sazonais. Atentos a esse fato, Box & Jenkins adaptaram seus modelos para séries temporais com componentes sazonais (SARIMA), conforme modelagem apresentada na **Equação 5.31**:

$$\phi(B)\Phi(B^S)\nabla^D\nabla^d Z_t = \theta(B)\Theta(B^S)a_t \quad (4.31)$$

Onde:

$\phi(B)$: operador não sazonal auto-regressivo

ϕ_i : parâmetro auto-regressivo não-sazonais

$\nabla^D = (1 - B)^d$: operador diferença não sazonal de ordem d

$\Phi(B^S)$: operador sazonal auto-regressivo

Φ_i = parâmetros auto-regressivo sazonais

$\nabla_S^D = (1 - B^S)^D$: operador diferença sazonal de ordem D

$\theta(B)$: operador não sazonal de média móveis

θ_i : parâmetros de médias móveis não sazonais

$\Theta(B^S)$: operador sazonal de médias móveis

Θ_i = parâmetros de médias móveis sazonais

⁵ A não estacionariedade homogênea exclui os processos de comportamento explosivos e/ou altamente não lineares (Souza & Camargo, 1996).

4.2.3 - Modelos Estruturais

O modelo estrutural decompõe uma série temporal através de suas componentes que podem ser interpretáveis, a exemplo da tendência, sazonalidade e ciclo, conforme apresentado na **Figura 4.3**.




Figura 4. 3 – Decomposição da série de consumo de energia da CELPE em tendência, sazonalidade e ruído

Algebricamente, os modelos estruturais efetuam a seguinte decomposição de uma série temporal:

$$y_t = m + s_t + c_t + e_t \quad (4.32)$$

Onde:

y_t = Série temporal; m_t = Tendência; s_t = Sazonalidade; c_t = Ciclo; e_t = Irregular;

Em complementação ao modelo é importante que seja especificado, através de equações, a forma de evolução de cada uma das componentes m_t , s_t e c_t . Dessa forma, o modelo estrutural é formado por dois tipos de equações:

- As equações das observações que expressam a série y_t em relação às componentes de interesse.
- As equações do estado que especificam a evolução de cada uma das componentes utilizadas na equação das observações.

Podemos denominar como fatos estilizados de uma série temporal as suas componentes, que em princípio, são estocásticas (**Figura 4.4 – B**), onde seus coeficientes evoluem ao longo do tempo, diferentemente das componentes deterministas, cujos coeficientes são estáticos. Assim sendo, os Modelos Estruturais são providos de maior flexibilidade em capturar mudanças dinâmicas de uma série [22].




Figura 4.4 – Tipos de tendência

No caso da demanda de carga elétrica a análise da tendência permite entendermos a evolução da série de forma mais clara, separando as componentes sazonais e os eventos espúrios conforme exemplifica a **Figura 4.5**.




Figura 4. 5 – Componente de tendência (em vermelho) para série do consumo faturado de energia da classe industrial cativa (em azul) da CELPE – jan/97 a jul/05

Pode-se obter o gráfico no tempo do fator sazonal de cada mês, conforme **Figura 4.6**.




Figura 4. 6 – Fatores sazonais mensais para série consumo industrial cativo CELPE – Jan/97 a jul/05

4.2.3.1 – Tendência

A tendência é uma componente de baixa frequência, que apresenta maior suavidade quando estimada. Em séries de carga elétrica, geralmente estão associadas a fatores como o crescimento populacional, o desenvolvimento econômico e o aquecimento da temperatura global.

Nos modelos estruturais existem vários tipos de modelos de tendência estocástica:

- **Modelo de nível local**

Considere, inicialmente, o modelo mais simples possível, onde a tendência é uma constante m , fixa no tempo.

$$y_t = m + e_t \quad (4.33)$$

Esse modelo serve apenas para representar séries aleatórias com média não-nula m . A idéia é fazer “ m ” variar no tempo:

$$y_t = m_t + e_t \quad (4.34)$$

No entanto, a componente m_t , não pode ser determinista, devido ao fato de, por hipótese, em modelos estruturais, a tendência ser estocástica. Outro fator importante é que deve representar adequadamente séries “não-estacionárias” e ser de fácil manuseio [22].

Será usado o processo denominado de “passeio aleatório” Para calcular o m_t :

$$y_t = m_t + e_t \quad e_t \sim N(0, \sigma^2) \quad (4.35)$$

$$m_t = m_{t-1} + \eta_t \quad \eta_t \sim N(0, 2\sigma\eta) \quad (4.36)$$

O modelo descrito nas **Equações 4.35 e 4.36**, é conhecido como modelo de nível local. A variação da tendência m_t é ditada pelo valor de q , a razão sinal ruído:

$$q = \sigma_\eta^2 / \sigma^2 \rightarrow \sigma_\eta^2 = q \sigma^2 \quad (4.37)$$

Se q tiver elevado valor, a tendência tem grandes variações, conforme **Figura 4.7**.




Figura 4. 7 – Série típica com $q = 2$ - nível nervoso

Se q tiver baixo valor, a tendência tem variações pequenas, conforme Figura 4.8.




Figura 4. 8 – Série típica com $q = 0,2$ - nível suave

Se q tiver baixo valor, a tendência tem variações pequenas, conforme Figura 4.9.




Figura 4. 9 - Série típica com $q = 0,02$ - nível se aproxima de uma constante

- **Modelo de tendência linear local**

Um aperfeiçoamento do modelo de nível local é o modelo de tendência linear local, onde considera-se primeiramente um modelo com tendência linear determinista:

$$m_t = a + b_t \quad (4.38)$$

No entanto, esse modelo tem certas limitações, pois várias séries podem apresentar mudanças irregulares na sua direção de crescimento. Portanto, é inadequada a utilização da tendência com padrão fixo no tempo.

Admitindo que esses coeficientes variem no tempo, o modelo possui maior flexibilidade para interpretar os movimentos da série.

A tendência de um modelo estrutural é representada por uma equação do tipo

$$m_t = a_t + b_t t \quad (4.39)$$

Podemos assumir evoluções do tipo:

$$a_t = a_{t-1} + \eta_{t1} \quad (4.40)$$

$$b_t = b_{t-1} + \eta_{t2} \quad (4.41)$$

onde η_{t1} e η_{t2} são choques aleatórios.

Tecnicamente, um modelo estrutural com tendência estocástica é representado pelas seguintes equações:

$$y_t = m_t + \varepsilon_t \quad (4.42)$$

$$m_t = m_{t-1} + b_{t-1} + \eta_t \quad (4.43)$$

$$b_t = b_{t-1} + \xi_t \quad (4.44)$$

Onde:

m_t = tendência

y_t = inclinação

As oscilações em m_t e b_t são causadas por η_t e ξ_t , respectivamente.

- **Estimação de um Modelo Estrutural**

Para estimar um modelo estrutural deve-se:

- ✓ estimar as componentes do modelo: tendência, sazonalidade etc.
- ✓ estimar os parâmetros fixos do modelo: as variâncias dos choques, períodos dos ciclos, coeficientes dos regressores/intervenções etc.

A implementação computacional desses processos de estimação é um processo bastante elaborado, implementado através dos seguintes algoritmos:

- ✓ filtro de Kalman e o algoritmo de suavização: estimam as componentes do modelo;
- ✓ algoritmo de otimização não-linear em conjunção com o filtro de Kalman: estimam os parâmetros fixos do modelo.

4.2.3.2 – Sazonalidade

O termo sazonalidade pode ser designado a flutuações de uma série temporal que se repetem em períodos de até um ano, podendo estar associadas a:

- clima: temperatura, índice de chuvas, incidência de ventos;
- convenções sociais (Carnaval, Páscoa, Dia das Mães, São João, Natal, dentre outros).

Definimos com S o período de sazonalidade:

- $S = 2$ para séries bi-anuais;
- $S = 4$ para séries trimestrais;
- $S = 12$ para séries mensais;
- $S = 52$ para séries semanais;
- $S = 365$ para séries diárias.

Em modelos estruturais existem dois procedimentos para se capturar as flutuações sazonais de uma série:

- Variáveis dummy
- Funções trigonométricas

4.2.4 Regressão Dinâmica

4.2.4.1 – Introdução

A regressão dinâmica é um dos modelos estatísticos mais usuais em estudos de previsões de séries temporais. Basicamente a finalidade do modelo é descrever uma série como função de seu histórico e de outras variáveis que possam explicar o comportamento da variável que se quer prever, podendo estas variáveis estar defasadas ou não no tempo. O modelo de regressão dinâmica concilia a dinâmica de séries temporais e o efeito de variáveis explicativas.

A princípio os modelos de regressão dinâmica deverão ser trabalhados supondo que atendam a algumas determinações. Uma delas é a características dos erros “gerados” pelo modelo: média zero, variância constante, distribuição Normal e independência (resíduos descorrelatados). Na prática, os resíduos em geral tendem a possuir correlações positivas, e erros positivos tendem a ser seguidos por outros também positivos (idem para os resíduos negativos).

Consequências da autocorrelação dos resíduos são:

- Os parâmetros encontrados por mínimos quadrados podem não ser tendenciosos, porém não possuem variância mínima.
- Os estimadores da variância e dos erros padrões dos coeficientes da regressão possuem valores abaixo dos verdadeiros (subestimados), podendo dar uma falsa impressão de precisão dos estimadores. Como consequência os intervalos de confiança para os parâmetros da regressão e os testes de hipóteses relacionados a estes intervalos perdem a validade.

Dessa forma o problema de autocorrelação dos erros leva, em geral, a inúmeras conclusões inverossímeis.

A palavra “dinâmica” especifica um modelo de regressão ao qual existe uma estrutura de dependência de uma série temporal.

Os modelos de regressão dinâmica são geralmente utilizados quando há uma estrutura de dependência entre a variável de interesse (dependente) e variáveis causais (independente) e, ao mesmo tempo, quando a estrutura de correlação da série dependente (série a ser explicada) indicar que não podemos supor a independência dos erros [24].

Na regressão dinâmica a estimação dos parâmetros é realizada através de mínimos quadrados ordinários (MQO)⁶ envolvendo um procedimento iterativo com vários estágios.

Vale destacar ainda que nos modelos de regressão dinâmica, a variável dependente (endógena) é explicada não só por seus valores históricos, como também pelos dados atuais e históricos de variáveis causais (exógenas).

Por fim, em modelos de regressão dinâmica, as variáveis exógenas são tratadas como “números fixos” e não como variáveis aleatórias.

4.2.4.2 – Estrutura

Os modelos de regressão dinâmica em geral são representados pela equação:

$$\varphi(B)Y_t = \beta x_t + \varepsilon_t \quad (4.45)$$

onde:

Y_t = variável dependente (endógena) no instante t

β = vetor de coeficientes das variáveis causais, que será estimado por mínimos quadrados

x_t = vetor de variáveis causais (exógenas) no instante t

ε_t = ruído aleatório do modelo. Suposição: ε_t são independentes e distribuídos com densidade $N(0, \sigma^2)$

$\varphi(B)$ = polinômio autoregressivo de ordem p , isto é:

$\varphi(B) = 1 - \varphi_1 B - \varphi_2 B^2 - \dots - \varphi_p B^p$ sendo B o operador de atraso

A estrutura do modelo de regressão dinâmica considera como elementos x_t , variáveis causais e suas respectivas defasagens.

Se por um lado o polinômio $\varphi(B)$ inserido flexibiliza esta classe de modelos, por outro lado dificulta a busca por um modelo adequado. Se $\varphi(B) = 1$, as variáveis dependentes não são defasadas, e as variáveis causais impactam diretamente no valor da variável endógena, tornando o modelo de simples entendimento. Em contrapartida, quando $\varphi(B) \neq 1$, o modelo pode ser usado para representar relações bastante complicadas.

A grande diferença entre os modelos de Regressão Dinâmica e os modelos ARIMA, já citados na seção anterior, consiste nos efeitos de variáveis causais através do termo βx_t , inclusos nos modelos de regressão dinâmica. Os modelos ARIMA univariados

⁶ Dudewicz & Mishra (1998) – Mínimo Quadrado Ordinário é uma metodologia de otimização matemática que procura o melhor ajustamento para um conjunto de dados tentando minimizar a soma dos quadrados das diferenças entre a curva ajustada e os dados (resíduos).

de Box e Jenkins, não absorvem esses efeitos. Apenas os valores históricos de Y_t e a defasagem da série de erros são inseridos na modelagem e projeção da série Y_t .

4.2.4.3 – Construção

De maneira geral, na econometria, os modelos possuem uma estrutura baseada em considerações teóricas e o problema está basicamente na estimação dos parâmetros do modelo já conhecido.

Normalmente, os modelos de regressão dinâmica são construídos através da estratégia bottom-up, ou seja, de um modelo simples ao modelo mais complexo e apropriado. Em um modelo de regressão dinâmica é necessário, além das escolhas das variáveis a fazerem parte do modelo, a determinação das defasagens destas variáveis.

Vale destacar ainda que o modelo adequado deve contar com a significância dos parâmetros e com uma estrutura “lógica” do modelo. Por exemplo, consumo de energia industrial geralmente é afetado pela produção física da indústria. O aumento de produção tende a aumentar o consumo de energia da classe industrial. Caso o modelo de regressão formulado para explicar o consumo de energia elétrica industrial, pela produção física da indústria, apresente um coeficiente negativo para a variável produção industrial, existe algo incoerente, pois a relação apontada pelo modelo não é fidedigna, mesmo estando estatisticamente correto. Portanto, na escolha de um modelo de regressão, não é necessário apenas encontrar um ajuste de parâmetros adequado, mas estudar a coerência da estimação dos coeficientes.

As saídas dos modelos de regressão dinâmica não dependem apenas dos valores históricos da série, mas também dos valores estimados para as variáveis causais. Se as projeções destas variáveis exógenas não forem assertivas, o modelo irá gerar previsões não apropriadas.

Assim, como forma de mitigar o erro, os modelos de regressão dinâmica trabalham com a possibilidade de elaboração de cenários viabilizando estudos relacionais das variáveis dependentes em relação a variáveis explicativas, através de cenários para as variáveis causais.

Existe ainda, a possibilidade de uso, nos modelos de regressão dinâmica das chamadas variáveis dummy ou variáveis de intervenção. Essas variáveis são normalmente padronizadas como 1 (ocorre o fato relevante) e 0 (fora deste período da ocorrência do

fato). Assim há a possibilidade de se modelar situações atípicas como, falta de energia e racionamentos de energia.

Outro aspecto a ser considerado nos modelos de regressão dinâmica é a sazonalidade da série, incorporando-a ao modelo, ao invés de supor que a série será previamente dessazonalizada. Vale salientar ainda, que podemos tratar a sazonalidade de duas formas: via dummies sazonais ou de forma direta, através de defasagens na variável dependente ou nos erros estruturados.

4.2.5 Redes Neurais Artificiais

4.2.5.1 – Introdução

As redes neurais artificiais (RNAs), tiveram o grande impulso ao final da década de 1980, conforme linha do tempo exemplificada na **Figura 4.10**. Essa forma de computação não-algorítmica é caracterizada por sistemas que, em alguns aspectos, se assemelham a estrutura do cérebro humano. Por não ser baseada em regras, a computação neural possibilitou uma alternativa à computação algorítmica convencional.

RNAs são sistemas paralelos distribuídos, compostos por unidades de processamento simples (neurônios artificiais) que calculam determinadas funções matemáticas (normalmente não-lineares). Tais unidades são dispostas em uma ou mais camadas e interligadas por um grande número de conexões, geralmente unidirecionais. Geralmente essas conexões são associadas a pesos, os quais acumulam o conhecimento adquirido pelo modelo e servem para ponderar a entrada de cada neurônio da rede [71].

A resolução de problemas por meio de RNAs é bastante interessante, já que a forma como estes são representados internamente pela rede cria a possibilidade de um desempenho superior ao dos modelos usuais. Em RNAs, o procedimento convencional passa inicialmente por uma fase de aprendizagem, em que um conjunto de exemplos é dado para a rede, a qual extrai as características suficientes para apresentar a informação fornecida. Essas características são utilizadas em seguida para gerar respostas para o problema [71].

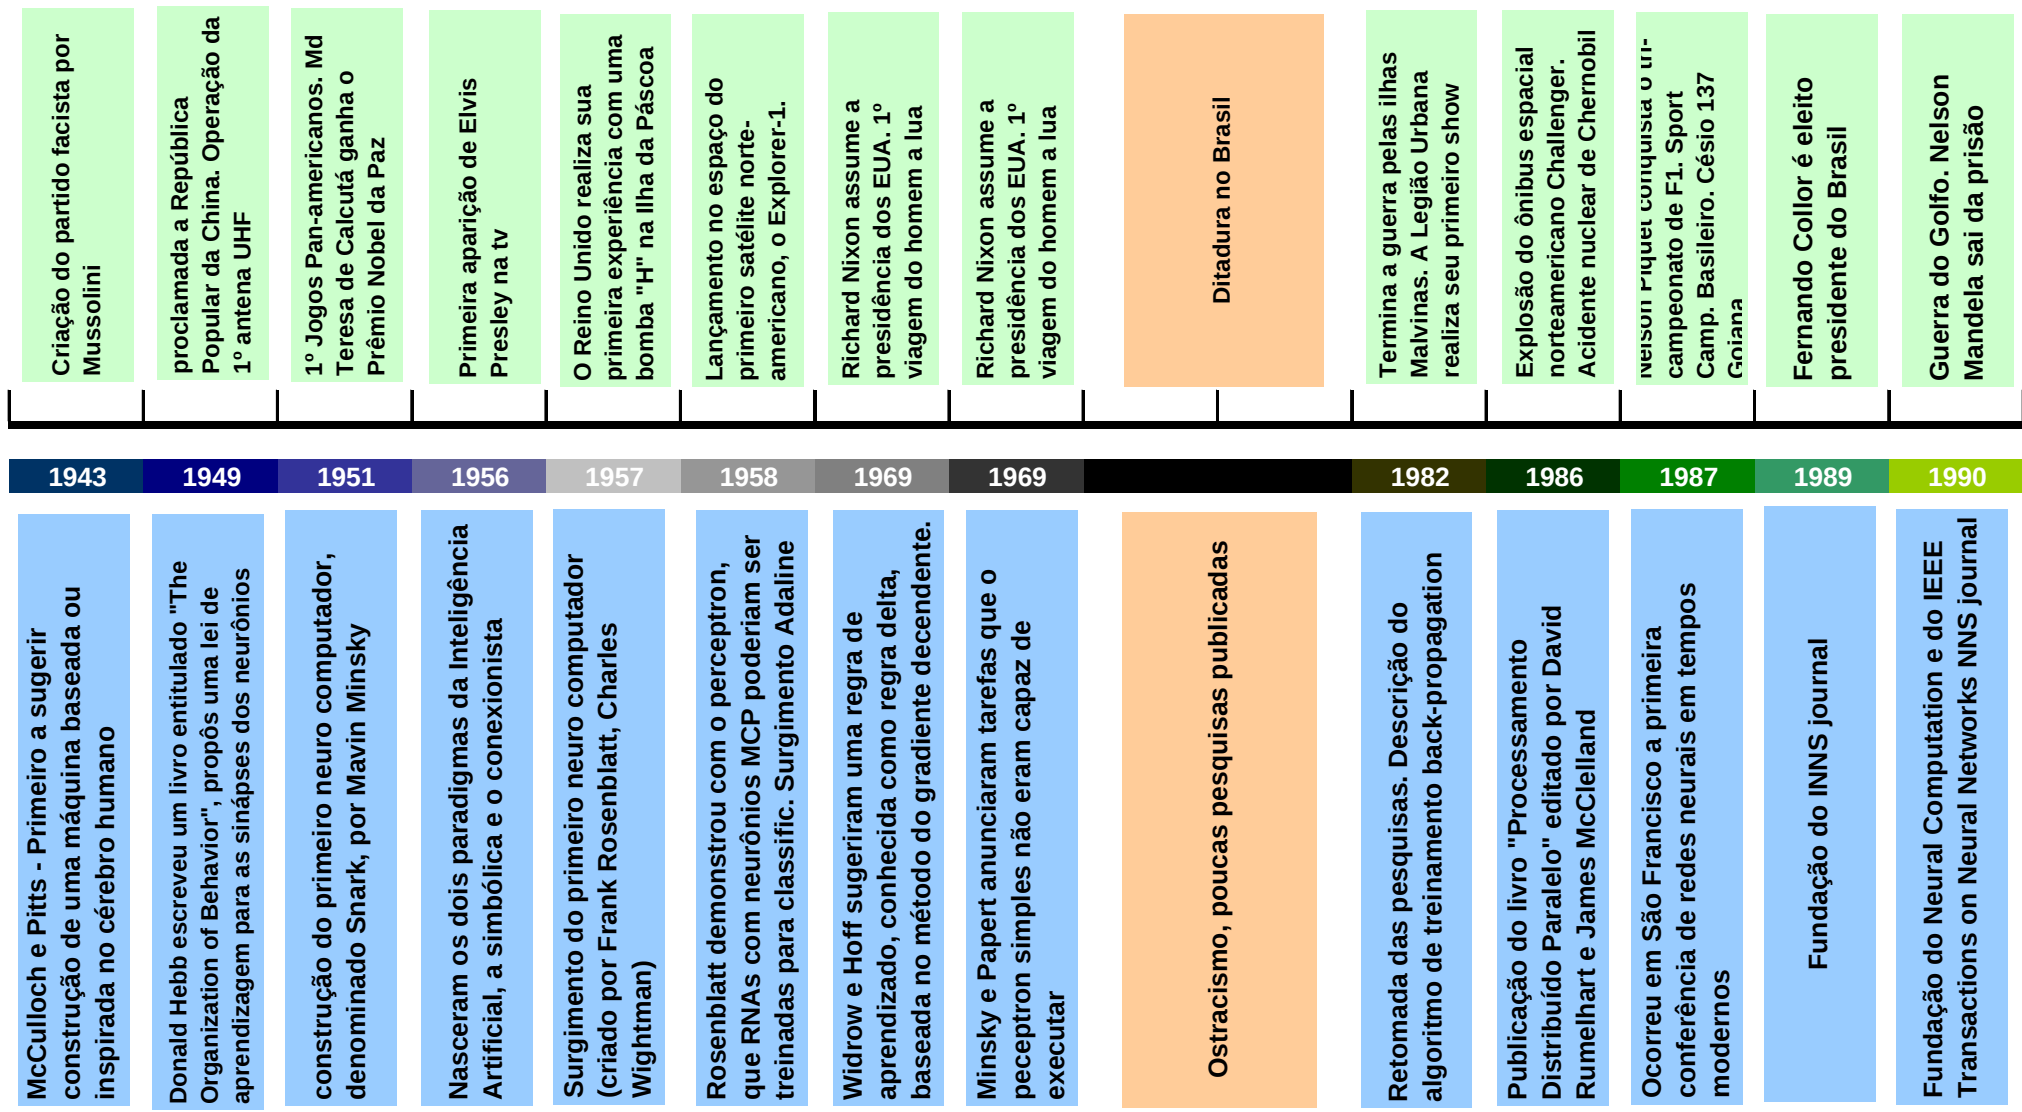


Figura 4. 10 – Linha do tempo: Evolução do estudo de Redes Neurais no mundo

4.2.5.2 – Neurônios Biológicos x Neurônios Artificiais

O neurônio biológico **Figura 4.11** é uma célula que ao ser estimulada em uma entrada gera uma saída que é enviada a outros neurônios. Esta saída irá depender da força de cada uma das entradas e da magnitude da conexão associada a cada entrada (sinapse). Uma sinapse pode excitar um neurônio, aumentando sua saída, ou inibi-lo, diminuindo sua saída.

Os neurônios biológicos são divididos, de maneira simplificada em três seções:

- Dendritos: Têm a função de receber as informações, ou impulsos nervosos, oriundos de outros neurônios e conduzi-las até o corpo celular;
- Corpo Celular: É onde a informação é processada e novos impulsos são gerados.
- Axônios: Responsável pela transmissão dos impulsos gerados no corpo celular a outros neurônios




Figura 4. 11 – Neurônio Biológico

Warren McCulloch e Walter Pitts [1] foram os pioneiros, com o primeiro modelo artificial de um neurônio biológico (**Figura 4.12**), em 1943. No entanto o neurônio de McCulloch e Pitts (MCP) foi proposto com pesos fixos, ou seja, não-ajustáveis, limitados apenas a implementar funções linearmente separáveis, restringindo sua utilização.

Após várias pesquisas chega-se a uma rede neural artificial constituída de vários neurônios artificiais que estão altamente conectados [71,72]. O neurônio artificial é uma estrutura lógico-matemática que procura simular a forma, o comportamento e as funções de um neurônio biológico. Assim sendo, os dendritos foram substituídos por entradas, cujas ligações com o corpo celular artificial são realizadas através de elementos chamados de peso (simulando as sinapses). Os estímulos captados pelas entradas são processados

pela função de soma, e o limiar de disparo do neurônio biológico foi substituído pela função de transferência [56] ou função de ativação.




Figura 4. 12 – Neurônio de McCulloch e Pitts, onde Σ é a soma ponderada das entradas e T a função de ativação

Combinando diversas células (neurônios artificiais) pode-se formar a rede neural artificial. As entradas que simulam uma região de obtenção de estímulos, podem ser conectadas em diversos neurônios, resultando, assim, em diversas saídas, representadas cada uma por um neurônio específico. Em comparação com o sistema biológico, essas conexões, representam o contato dos dendritos com outros neurônios, criando assim as sinapses. A função da conexão é tornar o sinal de saída de um neurônio em um sinal de entrada de outro, além de orientar o sinal de saída para o mundo externo. As diferentes opções de conexões entre as camadas de neurônios podem gerar n números de arquiteturas diferentes [73], a exemplo da **Figura 4.13**.




Figura 5. 13 – Exemplo de rede de duas camadas

4.2.5.3 – Funções de Ativações

As funções de ativação têm a responsabilidade de gerar a saída do neurônio a partir dos valores de suas entradas e pesos. A função de ativação de um neurônio utilizada no modelo MCP é do tipo degrau, conforme **Figura 5.14 A**.




Figura 5. 14 – Função de ativação degrau, sigmoidal,, gaussiana e linear

4.2.5.4 – Número de Camadas

Nesse trabalho foram utilizadas RNAs de múltiplas camadas (MLP, *multilayer perceptron*), constituídas de uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída, **Figura 5.13**.

O processamento realizado por cada neurônio de uma camada especifica é definido pela associação dos processamentos realizados pelos neurônios da camada anterior que estão ligados a ele [71]. As funções implementadas entre a primeira camada intermediária e a camada de saída, se tornam cada vez mais complexas. Essas funções são responsáveis pela segregação do espaço de decisão.

- Primeira camada intermediária: Cada neurônio contribui com retas para a formação da superfície no espaço de entrada [71];
- Segunda camada intermediária: cada neurônio combina as retas descritas pelos neurônios da camada anterior conectados a ele;
- Camada de saída: cada neurônio forma regiões que são combinações definidas pelos neurônios conectados da camada anterior.

Ao existir um número relativamente grande de unidades intermediárias, é possível formar agregações internas para qualquer conjunto de padrões de entrada [71].

4.2.5.5 – Número de Neurônios

O número de neurônios de cada camada está diretamente relacionado ao seu desempenho, com ênfase à sua capacidade de generalização.

Consequências do superdimensionamento no número de neurônios na camada oculta:

- Causará um aumento linear no número total de parâmetros da rede;
- Um aumento no número de soluções possíveis para se alcançar a solução de um determinado problema, pois a rede com maior número de parâmetros incluirá todas as soluções dos modelos de menor complexidade mais aquelas devido aos parâmetros complementares;
- Quanto maior o número de parâmetros, mais difícil é, a busca pelas soluções que se aproximam da função geradora dos dados;
- O aumento do número de neurônios, o percentual de soluções boas é cada vez menor em relação ao número de todas as outras soluções possíveis.

4.2.5.6 – Treinamento

Para o treinamento das redes o algoritmo mais popular é o back-propagation, que é basicamente dividido em duas fases (**Figura 4.15**):

- Fase forward: utilizada para definir a saída da rede para um dado padrão de entrada;
- Fase backward: utiliza a saída desejada e a saída fornecida pela rede para atualizar os pesos de suas conexões.




Figura 4. 15 – Fases do algoritmo de back-propagation

O ajuste dos pesos feito pelo algoritmo back-propagation é baseado na regra delta proposta por Widrow e Hoff em 1960, utilizada para o treinamento de redes Adaline.

O algoritmo de treinamento Adalaine é baseado na intensidade e no sinal do gradiente de erro para obter a direção e o valor do ajuste a ser aplicado ao vetor de pesos. Este algoritmo é conhecido como Regra Delta [71].

A Regra Delta baseia-se no princípio de que o objetivo do treinamento é minimizar o valor da função quadrática do erro. Portanto é desejável que o ajuste a ser aplicado no vetor de pesos seja de forma tal que se aproxime do valor mínimo da função de erro. Essa direção pode ser obtida através do gradiente da função. Em virtude do gradiente seguir a mesma direção da maior variação de erro, o ajuste dos pesos deverá seguir na direção contrária a dele.

A principal diferença entre os modelos Perceptron e Adalaine está no fato do Perceptron ser caracterizado como um separador linear e o Adalaine como um aproximador linear de funções. Esses modelos camada única são geralmente aplicados a problemas de

natureza diferente, sendo o Perceptron utilizado na classificação de padrões e o Adalaine na aproximação de funções.

A **Figura 4.16** apresenta um comparativo entre os dois modelos.

	PERCEPTRON	ADALAINÉ
Introduzido por	Frank Rosenblatt	Bernad Widrow e Marcian Hoff
Ano	1958	1960
Nº de Camadas	Uma Camada	Uma Camada
Equação	$w(n+1) = w(n) + nex$	$w(n+1) = w(n) + nex$
Operações	Linear e Não-Lineares	Puramente Linear
Polarização	Portas de Limiar	Gradiente Descendente
Característica	Separador Linear	Aproximador Linear
Utilização	Classificação de padrões	Aproximador de funções

Figura 4. 16 – Comparações entre os modelos Perceptron e Adalaine

A principal dificuldade no treinamento de redes MLP com algoritmo back-propagation está relacionada à sua sensibilidade às características de erro, o que dificulta a sua convergência em regiões de baixo gradiente e de mínimos locais.


Uma forma de minimizar esse problema é considerar efeitos de segunda ordem para o gradiente descendente.

Algumas abordagens que podem ser utilizadas tanto para acelerar o algoritmo quanto para reduzir os efeitos dos mínimos locais [71]:

- Utilizar taxa de aprendizado decrescente
- Utilizar um termo momentum
- Adicionar ruídos aos dados

A inclusão do termo momentum na expressão de ajuste dos pesos adiciona inércia ao aprendizado, resultando em uma elevação da velocidade de convergência em regiões de

descida da superfície de erro, já que o atual ajuste será sempre adicionado a uma parcela do ajuste imediatamente anterior, conforme **Figura 5.18**.



4.2.5.7 – Algoritmo Resilient Propagation (Rprop)

O algoritmo *Rprop* [1] apresenta uma maior eficiência no quesito aprendizagem, pois tem uma adaptação do peso baseada no gradiente local. Diferentemente do algoritmo do gradiente descendente com momento (*GDM*), a adaptação do *Rprop* não tem influência do comportamento da intensidade do gradiente da função erro.

Tem como grande vantagem a não necessidade de uma boa escolha dos parâmetros a fim de garantir a convergência, pois existe um processo de otimização deste algoritmo, onde cada peso será alterado individualmente através de um valor adaptativo Δw_{kj} .

4.2.5.8 – Algoritmo Levenberg-Marquardt

Esse algoritmo é considerado como o método mais rápido para treinamento de redes *feedforward backpropagation*, desde que a rede possua uma quantidade moderada de pesos sinápticos a fim de tornar o problema exequível. Para acelerar o treinamento da rede este algoritmo baseia-se na determinação das derivadas de segunda ordem do erro quadrático em relação aos pesos, diferindo do algoritmo *backpropagation* tradicional que considera as derivadas de primeira ordem.

4.2.6 - Lógica Fuzzy

A lógica fuzzy é uma generalização da lógica booleana que admite valores entre o falso e o verdadeiro, admitindo a figura do “talvez”.

A lógica difusa geralmente está associada ao uso de uma teoria de conjuntos fuzzy.

A construção de um modelo fuzzy simples é feita através da associação de um valor $\mu(p)$ a uma proposição p , representando o grau de veracidade dessa proposição, sendo que $\mu(x)$ é uma função cujo conjunto imagem está entre 0 e 1. Caso p seja verdadeiro, deverá representar o valor 100%, caso p seja falso deverá representar ao valor 0%. Assim, a lógica amplifica a lógica booleana, pois permite uma infinidade de valores.

4.2.6.1 – Raciocínio fuzzy

O raciocínio fuzzy pode ser dividido nas etapas abaixo:

- Fuzzificação (Transformação das variáveis do problema em valores fuzzy)
- Aplicação dos operadores fuzzy
- Aplicação da implicação
- Combinação de todas as saídas fuzzy possíveis
- Transformação do resultado fuzzy em um resultado nítido, a defuzzificação.

Primeiramente, para cada valor de entrada é associada uma função de pertinência, de forma a proporcionar a obtenção do grau de veracidade da proposição, determinando o grau de pertinência de cada conjunto e limitando o valor da entrada entre 0 e 1.

Posteriormente são aplicados os operadores fuzzy. Os operadores usados na lógica fuzzy são AND e OR, conhecidos como operadores de relação. São utilizados para a definição do grau máximo e mínimo de pertinência do conjunto. Em seguida é aplicado o operador de implicação, possibilitando a definição do peso no resultado e remontando a função, criando a hipótese de implicação.

No quarto passo ocorre a combinação de todas as saídas em um único conjunto fuzzy, algo semelhante ao processo de união e intersecção. O último passo é a ‘defuzzificação’ que consiste em retornar os valores, obtendo um valor numérico dentro da faixa estipulada pela lógica fuzzy.

4.2.6.2 – Adaptive Neuro-Fuzzy Inference System (ANFIS)

O modelo neuro fuzzy mais comum é o sistema ANFIS (Adaptive Network-based Fuzzy Inference System), baseado na equivalência funcional, sob certas restrições, entre as redes RBF (Radial Basic Function) e os sistemas fuzzy do tipo TSK (Takagi-Sugeno-Kang). A utilização de operadores continuamente diferenciáveis nos sistemas TSK possibilita utilizar algoritmos de otimização baseados no método do gradiente para a adaptação dos parâmetros.

4.2.6.3 – Equivalência entre um Modelo Fuzzy TSK e uma Rede RBF

O modelo fuzzy foi proposto por Takagi & Sugeno (1985), Sugeno & Kang (1988) no qual a saída é calculada diretamente sem defuzzificação. Em um modelo fuzzy TSK, as conclusões das regras são funções das variáveis de entrada; para um modelo de entrada simples as regras são descritas na forma:

$$\text{If } x = A_i \text{ then } y = \varphi_i(x) \quad (4.46)$$

Onde A_i é um conjunto fuzzy sobre o universo da variável x e $\varphi_i(x)$ é a saída de uma regra i , normalmente uma função polinomial da variável de entrada x .

Para uma entrada $x(t)$, a saída $y(t)$ de um modelo TSK é calculada como uma soma ponderada das saídas de cada regra:

$$y(t) = \frac{\sum \mu_{A_i}(x(t)) \varphi_i(x(t))}{\sum \mu_{A_i}(x(t))} \quad (4.47)$$

Nos modelos TSK chamados de primeira ordem, as funções de saída são funções lineares da variável de entrada $\varphi_i(x) = \theta_i^1 x + \theta_i^0$. No modelo simplificado, ou de ordem zero, as conclusões associadas a cada regra são constantes e $\varphi_i(x) = \theta_i$. Nesse caso a saída pode ser calculada como:

$$y(t) = u(t) \cdot \theta \quad (4.48)$$

Onde $\theta = (\theta_1, \dots, \theta_n)$ é o vetor com as conclusões de cada regra. O vetor contendo os valores de ativação da entrada a cada regra é calculado como:

$$y(t) = \frac{(\mu_{A_1}(x(t)), \dots, \mu_{A_n}(x(t)))}{\sum \mu_{A_i}(x(t))} \quad (4.49)$$

A extensão dos resultados acima para modelos de entradas múltiplas é direta. Uma entrada multidimensional $x_t = (x_1(t), \dots, x_p(t))$ é tratada como a combinação de entradas unidimensionais em sentenças do tipo:

$$x_1(t) = A_{i1} \text{ and } x_2(t) = A_{i2} \text{ and } \dots \text{ and } x_p(t) = A_{ip} \quad (4.50)$$

representada pela função de pertinência multidimensional $\mu_{A_i}(x(t))$, definida pela conjunção de funções de pertinência unidimensionais como:

$$\mu_{A_i}(x(t)) = \prod_{j=1 \dots p} \mu_{A_{ij}}(x_j(t)) \quad (4.51)$$

Assumindo funções de pertinência de base radial, como funções gaussianas, por exemplo, a equação:

$$u(t) = \frac{(\mu_{A_i}(x(t)), \dots, (\mu_{A_M}(x(t)))}{\sum \mu_{A_i}(x(t))} \quad (4.52)$$

pode ser escrita como:

$$u(t) = \frac{(\varphi_1(x(t)), \dots, (\varphi_M(x(t)))}{\sum \varphi_i(x(t))} \quad (4.53)$$

Onde o denominador $\sum \varphi_i(x(t))$ visa normalizar a saída no intervalo $[0,1]$.

As funções gaussianas, ou funções de base radial, de uma forma geral podem ser vistas como funções de pertinência. Comparando as equações acima, pode-se concluir que um modelo TSK pode ser implementado por uma rede RBF na qual a saída das unidades intermediárias são normalizadas. Apoiando-se nessa equivalência, o sistema ANFIS foi desenvolvido como um modelo TSK que poderia ser interpretado como uma rede RBF. No sistema ANFIS, o conhecimento de um especialista poderia servir para inicializar uma rede RBF, cujos parâmetros seriam em seguida adaptados numericamente. Desta maneira, os resultados do ANFIS seriam melhores que os resultados obtidos com uma rede RBF, pois a configuração inicial já estaria mais próxima do resultado final em virtude da introdução do conhecimento do especialista. O sistema ANFIS é representado a seguir.

4.2.6.4 – O Modelo ANFIS

A idéia do sistema ANFIS é implementar um modelo fuzzy do tipo TSK numa rede neural. Sem perda de generalidade, considere um modelo TSK de primeira ordem descrito por duas regras como:

$$\text{If } x = A_1 \text{ and } y = B_1 \text{ then } \varphi_1 = \theta_{11}x + \theta_{12}y + \theta_{13} \quad (4.54)$$

$$\text{If } x = A_2 \text{ and } y = B_2 \text{ then } \varphi_2 = \theta_{21}x + \theta_{22}y + \theta_{23} \quad (4.55)$$

O sistema ANFIS correspondente ao modelo definido pela equação anterior, é representado pela **Figura 4.19** em que as unidades na mesma camada tem funções similares, conforme descrito a seguir.

Camada 1 – As saídas das unidades desta camada são valores de pertinência das entradas em relação aos termos (conjunto fuzzy) nas premissas das regras:

$$O_{11} = \mu_{A1}(x) \quad O_{13} = \mu_{B1}(y) \quad (4.56)$$

$$O_{12} = \mu_{A2}(x) \quad O_{14} = \mu_{B2}(y) \quad (4.57)$$

Geralmente, as funções de pertinência utilizadas são as funções gaussianas definidas pela equação:

$$\varphi_i(x(t)) = e^{-\frac{\|x(t) - \rho_i\|^2}{\rho^2}} \quad (4.58)$$

que por serem continuamente diferenciáveis, permite que os parâmetros que definem o centro e o suporte da função sejam otimizados na fase de adaptação. Os parâmetros que definem as funções de pertinência são chamados parâmetros da premissa.

Camada 2 – A saída das unidades desta camada são os valores da ativação das regras. Haverá tantas unidades na camada 2 quanto o número de regras e o operador $\prod$ realiza a função de um operador conjuntivo nos sistemas fuzzy, agregando as saídas das camadas anteriores. Geralmente o operador–produto é utilizado, o que permite que o sistema seja continuamente diferenciável favorecendo a otimização dos parâmetros.

$$O_{21} = u_1 = \mu_{A1}(x) \cdot \mu_{B1}(y) \quad (4.59)$$

$$O_{22} = u_2 = \mu_{A2}(x) \cdot \mu_{B2}(y) \quad (4.60)$$

Camada 3 – As saídas das unidades desta camada são os valores normalizados dos valores de ativação das regras:

$$O_{31} = \bar{u}_1 = \frac{u_1}{u_1 + u_2} \quad (4.61)$$

$$O_{32} = \bar{u}_2 = \frac{u_2}{u_1 + u_2} \quad (4.62)$$

Camada 4 – As saídas das unidades desta camada representam a contribuição de cada regra na saída total e são calculadas pelo valor da função no mesmo consequente da regra ponderada pelo valor normalizado de ativação da regra.

$$O_{41} = \bar{u}_1 \phi_1 \quad (4.63)$$

$$O_{42} = \bar{u}_2 \phi_2 \quad (4.64)$$

No modelo TSK de primeira ordem como o definido pelas regras anteriores, os parâmetros que definem os consequentes das regras, chamados de parâmetros dos consequentes, ocorrem linearmente na saída de cada regra, permitindo sua adaptação pelo método dos mínimos quadrados.

Camada 5 – Nesta camada, a saída parcial de cada regra é somada para o cálculo da saída total, produzindo a saída do modelo TSK definido pelas regras iniciais.

$$O_i^5 = \sum \bar{w}_i \cdot f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (4.65)$$




Figura 4. 18 – Sistema ANFIS

A Adaptação dos parâmetros do ANFIS é feita em duas etapas: na primeira os parâmetros (lineares) dos consequentes das regras são adaptados pela solução de um problema de mínimos quadrados; na segunda etapa, os parâmetros das premissas, que definem as funções gaussianas (funções de pertinência do modelo TKS) são adaptados por meio do algoritmo do gradiente.

A aplicação do algoritmo do gradiente para adaptação das funções gaussianas é possível, pois as funções gaussianas utilizadas no ANFIS são contínuas e possuem derivadas contínuas. Entretanto, como o algoritmo do gradiente busca a minimização do erro sobre os pontos do conjunto de treinamento, o resultado obtido após a otimização pode dificultar sua interpretação como funções de pertinência.

Como as funções de pertinência representam conceitos linguísticos relevantes numa determinada aplicação, a deformação das funções de pertinência visando a melhor adaptação a um conjunto de treinamento não tem sentido, uma vez que o resultado pode não ser interpretável. Utilizando-se funções de pertinência triangulares definidas em discretizações normalizadas, a interpretação de cada conceito é garantida.

Com base nos modelos apresentados, procurou-se construir a melhor previsão de mercado no curto e longo prazo. Nos modelos de curto prazo o determinante é o próprio histórico, ou seja, os modelos são construídos com base apenas no seu próprio passado. Já os modelos de longo prazo, as variáveis exógenas como PIB e população, são importantes para explicar o comportamento do mercado de energia elétrica no período.

CAPÍTULO 5

5 - Base de Dados e Softwares utilizados

O capítulo apresenta um detalhamento sobre o tratamento da série a ser utilizada nas projeções. Trata ainda das ferramentas que foram utilizadas para o desenvolvimento das previsões, procurando dar uma visão geral da concepção dos softwares, apresentando suas vantagens e limitações.

5.1 – Energia Distribuída

Denomina-se “Energia Distribuída”, toda a energia fornecida aos consumidores finais da concessionária, distribuídos nas diversas classes de consumo (residencial, industrial, comercial, rural, poder público, iluminação pública, serviço público e consumo próprio), independentemente se o consumidor é cativo da empresa ou compra energia no mercado livre.

Para a determinação da energia distribuída o que interessa é o fato do consumidor estar ligado à rede da distribuidora, ou seja, a questão é física e não contratual.

5.2 – Tratamento da Série e Escolha do horizonte

A CELPE possui disponível, o histórico da Energia Distribuída, no período de janeiro de 1970 até os dias atuais, sem interrupção da série.

No entanto, vale salientar que ao longo dos anos, alguns fatores externos influenciaram o comportamento dessas variáveis e em certos casos acarretaram variações extremas, refletindo na estrutura da série. Nesses casos esses períodos são tratados de forma diferenciada, recebendo o nome de Outliers. Em casos mais graves, pode haver uma quebra estrutural da série, como ocorreu no período de racionamento de energia elétrica em 2001, onde o nível foi alterado resultando em um tratamento especial dos dados, de forma a poder se trabalhar com os números.




Figura 5.1 - Exemplo de outliers e quebras estruturais na série de energia distribuída da CELPE jan/70 a dez/09

A **Figura 5.1** apresenta a série de energia distribuída de janeiro de 1970 a dezembro de 2009. Os pontos em destaques são exemplos de Outliers na série com ênfase a algumas perturbações na metade dos anos 80 e na quebra estrutural da série provocada pelo racionamento de energia elétrica, iniciado em junho de 2001, que teve como consequência o deslocamento do nível da série.

No entanto, vale salientar que ao longo da série existem vários outros outliers que devem ser tratados (geralmente por variáveis do tipo dummy).

Em virtude da mudança comportamental do mercado ao longo dos anos, em especial a partir da segunda metade da década de 1990, em função da implantação do plano real, que dinamizou a economia estimulando o aumento da demanda, procurou-se utilizar um histórico mais recente que procurasse explicar melhor o mercado atual. Com o advento do racionamento de energia, que perdurou de junho de 2001 a fevereiro de 2002, a série passou a ter um deslocamento de nível, que implicou em uma tomada de decisão importante: utilizar para as previsões mensais (curto prazo) a série a partir de 1995 (primeiro ano após a implantação do plano real) ou iniciar a partir de 2003 (primeiro ano após o racionamento de energia). Optou-se pelo segundo caso, pois se verificou que além da questão do nível, houve uma mudança de tendência, com visível aumento do seu coeficiente angular.

Conforme a **Figura 5.2**, o ângulo β é maior que o ângulo α .




Figura 5. 2 - Mudança de tendência da série histórica de energia distribuída da CELPE após o período de racionamento de energia elétrica (jun/01 a fev/02)

Dado que a escolha do horizonte a ser estudado foi a partir de janeiro de 2003, não foi necessário realizar tratamento do histórico em virtude do racionamento de energia. Dessa forma, no período de estudo não foi necessário o tratamento do histórico de forma a se trabalhar os outliers da série, até mesmo porque nos sete anos de estudo não houve grandes oscilações atípicas que pudessem comprometer o resultado da previsão.

Para as previsões anuais de longo prazo (10 anos à frente), foi utilizado todo o histórico anual, sendo assim, necessária a modelagem do período do racionamento de energia elétrica.




Figura 5. 3 - Quebra estrutural da série de Energia Distribuída da CELPE após o período de racionamento de energia elétrica (jun/01 a fev/02)

Vale ressaltar que as previsões de longo prazo foram feitas através de uma base de dados anual iniciada em 1970. Assim como no modelo mensal, foi necessária a inserção de

uma variável dummy para modelar o período referente ao racionamento de energia elétrica, compreendido entre jun/01 e fev/02.

5.3 – Definições das variáveis causais

Conforme apresentado no **capítulo 2**, algumas variáveis exógenas possuem excelente correlação com o consumo de energia, com ênfase na temperatura (curto prazo) e Produto Interno Bruto (PIB) no longo prazo.

Entretanto, mesmo ciente da importância de algumas variáveis na explicação do comportamento do mercado de energia elétrica, nem todas podem ser utilizadas para subsidiar sua projeção, pois, apesar de certos casos possuírem um histórico adequado, existe um grau de dificuldade relevante em se obter a projeção dessas variáveis, em função da sua não disponibilidade.

Para as projeções de longo prazo, onde foram utilizadas as variáveis causais como forma de explicar o mercado de energia, aproveitaram-se as séries disponíveis que possuíam estimativas futuras, com destaque para o PIB, população e número de domicílios.

O histórico dessas variáveis foi adquirido por meio do IBGE (Instituto Brasileiro de Geografia e Estatística) e pelo CONDEPE (Agência Estadual de Planejamento e Pesquisas de Pernambuco).

5.4 – Softwares Utilizados

5.4.1 - Forecast Pro

O Forecast pro é um software para análise e previsão de séries temporais. Suas principais vantagens são:

- Funciona sob diversas versões do Windows;
- É de fácil utilização;
- Exige poucos recursos de hardware;
- Permite entrada de dados em formato Excel (entre outros) e exportação de gráficos e resultados;
- Permite a identificação automática de modelos;

- Possibilita o ajuste de modelos univariados⁷ e multivariados⁸;
- Possui bom módulo de diagnóstico de modelos;
- É bastante difundido no mundo todo.

Esse software foi utilizado, basicamente, para os métodos de Amortecimento Exponencial, Box & Jenkins e Regressão Dinâmica.

Amortecimento Exponencial:

A maior dificuldade na aplicação do método de amortecimento exponencial está na escolha das constantes de amortecimento. No entanto, o Forecast Pro ajusta os modelos automaticamente com constantes de amortecimento otimizadas.

Box & Jenkins:

Os modelos Box & Jenkins são modelos mais sofisticados do que os de Amortecimento Exponencial, pois usam a correlação entre as observações em diversos instantes. Sendo assim a sua estrutura é um pouco mais complicada. Contudo, o Forecast Pro identifica automaticamente a estrutura de modelos ARIMA, evitando o passo mais complicado da análise.

Regressão Dinâmica:

Nesse tipo de modelo, a variável de interesse é explicada pelos seus valores passados e também por valores passados e presentes de outras variáveis. O Forecast Pro (**Figura 5.4**) possibilita ajustes de Regressão Dinâmica, sugerindo a inclusão ou exclusão de variáveis.

O ajuste do modelo é feito numa sequência de passos, geralmente partindo de uma estrutura simples e inserindo novas variáveis, que podem estar defasadas ou não, a cada novo estágio.

Esse tipo de modelo geralmente produz melhores resultados em comparação com os modelos univariados, quando existem variáveis explicativas relevantes. No entanto,

⁷ Modelos univariados – A série temporal é explicada (prevista) apenas pelos seus valores passados.

⁸ Modelos multivariados – A série temporal é explicada (prevista) pelos seus valores passados e também pelos valores passados de outras variáveis.

nesse contexto, faz-se necessária a previsão das variáveis causais, o que pode ser uma dificuldade.

Outra vantagem dos modelos causais, é que eles permitem a compreensão sobre quais variáveis afetam diretamente a variável de interesse, e qual o efeito destas variáveis explicativas.




Figura 5. 4 – Tela do Forecast pro

5.4.2 - STAMP

STAMP é um módulo do programa GiveWin (**Figura 5.6**), o qual lê dados, transforma dados, e produz gráficos. Este software foi desenvolvido por Andrew C. Harvey [39], Jurgan A. Doornik, Neil Shephard e Siem Jan Koopman [40]. No GiveWin os dados podem ser digitados diretamente na planilha do programa ou lidos diretamente do Excel.

O software STAMP é basicamente utilizado para previsão através de modelos estruturais, onde é possível decompor a série temporal através de componentes que são interpretáveis, a exemplo da sazonalidade, ciclo e tendência. A componente de nível pode ou não existir; caso exista ela pode ser fixa ou estocástica.

O STAMP possibilita a avaliação de um modelo estrutural através dos seguintes procedimentos (**Figura 5.5**):

- Diagnósticos: investiga se os pressupostos assumidos para os erros do modelo são observados na prática.
- Medidas de aderência (goodness of fit): investigam a qualidade do ajuste do




Figura 5. 5 – Fluxograma do STAMP

A estimação no módulo STAMP é baseada na metodologia de espaço de estado e filtro de Kalman⁹. Pode-se otimizar o modelo através dos métodos de máxima verossimilhança, máxima verossimilhança controlada ou restringir os valores dos parâmetros.

O STAMP possibilita ainda analisar as intervenções, classificando-as de outlier ou de efeitos tendências.

⁹ Filtros de Kalman são bastante difundidos na álgebra linear e no modelo oculto de Markov. A modelagem da base dos sistemas dinâmicos é realizada através da cadeia de Markov formada por operadores lineares influenciados por um ruído gaussiano. O estado do sistema é representado como um vetor de números reais. A cada tempo incremental discreto, um operador linear é aplicado ao estado de forma a gerar um novo estado, com um ruído associado a ele, e opcionalmente alguma informação dos controles no sistema se eles são conhecidos. Então, outro operador linear agregado a mais ruído gera a saída visível do estado oculto.




Figura 5.6 – Tela do STAMP

5.4.3 - MATLAB

MATLAB é um software voltado para o cálculo numérico. O MATLAB integra cálculo com matrizes, análise numérica, processamento de sinais e construção de gráficos, com a vantagem dos problemas e soluções serem apresentados apenas como eles são matematicamente descritos, ao contrário da programação usual [74].

O MATLAB é um sistema interativo onde o elemento básico de informação é uma matriz adimensional. Esse sistema possibilita a resolução de vários tipos de problemas numéricos em um pequeno espaço de tempo.

O software MATLAB, a partir de fevereiro de 2001, possibilitou, através do seu toolbox a integração de vários tipos de redes neurais com o ambiente matricial.

O funcionamento do modelo de rede neural tem como base o treinamento, quando é apresentado à rede uma sequência de padrões e a classe a que estes pertencem.

Por fim, vale ressaltar, que os softwares, são apenas ferramentas que devem ser utilizadas de forma correta, com uma base de dados adequada e trabalhada, de maneira que possa proporcionar a melhor estimativa possível da variável em questão.

CAPÍTULO 6

6 – Comparação entre os Modelos

O capítulo 6 apresenta o resultado das previsões de energia distribuída da CELPE, comparando os resultados obtidos através dos diversos modelos de curto prazo (dados mensais) e mais à frente de longo prazo (dados anuais). Os modelos serão comparados através de uma medida de erro em comum, que será o MAPE (Erro Médio Absoluto Percentual), sendo o melhor modelo o que obtiver o menor desvio.

6.1 – Modelos de Curto Prazo

Para os modelos de curto prazo foram feitas previsões de um mês à frente, utilizando os modelos de Amortecimento Exponencial, Box & Jenkins, Estrutural e Redes Neurais. Essas previsões foram baseadas apenas no próprio histórico, com base mensal iniciada em janeiro/2003 e com término em dezembro/2008. Essa escolha baseou-se em alguns fatores:

- Iniciando o histórico a partir de janeiro/2003, expurgam-se alguns períodos de quebras estruturais, como a implantação do plano real no meio da década de 1990 e o racionamento de energia elétrica ocorrido no período de junho/2001 a fevereiro/2002;
- As características do mercado da CELPE, vêm sofrendo alterações gradativas ao longo do tempo, com o surgimento de novos equipamentos elétricos mais eficientes, bem como o surgimento de novos mercados, como os shopping centers na década de 1980, lojas de conveniência na década de 1990 e lan-houses nos anos 2000. A classe industrial, também vêm sofrendo reformulações, com a decadência do setor sucroalcooleiro e o surgimento de novos ramos como a indústria naval e de refino de petróleo.
- Alguns históricos demasiadamente longos podem provocar estatísticas enviesadas, por apresentarem características como resíduos correlatados.

Para análise da qualidade dos modelos, foi feita uma comparação do MAPE ao longo de todo o ano de 2009 (último ano totalmente realizado). Portanto o ano de 2009 não foi utilizado nas previsões.

6.1.1 – Análise dos resultados dos modelos utilizados no Curto Prazo

Como já relatado anteriormente, foram utilizados para efeito de comparação os modelos de Amortecimento Exponencial, Box & Jenkins, Estrutural e de Redes Neurais. Todos com o mesmo período de histórico.

6.1.1.1 – Amortecimento Exponencial

Para a série da CELPE foi utilizado o modelo de Holt-Winters, que possui três componentes (nível, tendência e sazonalidade multiplicativa), todas presentes na série histórica de energia distribuída da CELPE.

Foram utilizadas uma equação de previsão para cada mês do ano, como forma de captar a sazonalidade da série:

- Para o mês de janeiro $\Rightarrow (812.820 + 2675,1 t) \times 1,03883 + \varepsilon_t$ (6.1)

$\downarrow$ $\downarrow$ $\downarrow$
 Parâmetro de nível Parâmetro de tendência Parâmetro de sazonalidade

A **Tabela 6.1**, apresenta os parâmetros de sazonalidade utilizados na equação para cada mês do ano.

Tabela 6. 1 – Parâmetros de sazonalidade

Mês	γ
Jan	1,03883
Fev	0,99424
Mar	1,03965
Abr	1,00784
Mai	1,01105
Jun	0,96650
Jul	0,95097
Ago	0,94622
Set	0,95698
Out	1,01767
Nov	1,02856
Dez	1,04908

A estatística de Ljung-Box com $p = 0,4063$, indica que não se rejeita a hipótese nula de resíduos descorrelatados, para um nível de significância¹⁰ de 95%.




Figura 6. 1 – Gráfico de Correlação de resíduos

O R-square (R^2), representa o quanto o modelo explica a variação da energia distribuída. Nesse caso o resultado foi bastante consistente, explicando 92,57%. No entanto, é aconselhável analisar o Adjusted R-square (R^2 Ajustado), que penaliza as equações com um grande número de parâmetros, utilizando o critério da parcimônia. Nesse caso o resultado também é muito bom, explicando 92,36% da variação da demanda através do modelo.

O MAPE do modelo (dentro da amostra)¹¹ foi de 1,86%. No entanto, ao expurgar da série o ano de 2009 e tentar prevê-lo, o MAPE (fora da amostra ou de teste)¹² ficou em 3,48%.

6.1.1.2 – Box & Jenkins

Dentro da própria metodologia Box & Jenkins, foram testados vários modelos, sendo escolhido o que atendesse o conjunto de três aspectos (menor MAPE, melhor ajuste e todas as variáveis significantes a um nível de significância de 95%).

¹⁰ Em Estatística, um resultado é significativo, se for improvável que tenha ocorrido por acaso, caso uma determinada hipótese nula seja verdadeira, mas não sendo improvável caso a hipótese base seja falsa.

¹¹ MAPE dentro da amostra: MAPE calculado em cima dos valores históricos, cada valor da série é recalculado através da equação de previsão calculada e comparado com o real valor da série. O MAPE dentro da amostra é a média desses desvios absolutos.

¹² MAPE fora da amostra: Diferença entre os valores previstos em um determinado período e o valor efetivamente ocorrido, o MAPE é a média desses desvios absolutos.

Como forma a atender ao critério da parcimônia, primeiramente foram testados os modelos mais simples.

Posteriormente foram inseridos parâmetros que possibilitassem um melhor ajuste do modelo com foco na minimização do MAPE.

Tabela 6. 2 – Comparação dos Modelos Box & Jenkins testados

Modelo	R2	MAPE	Possui variável não significativa (*)	Erro 2009
ARIMA(0,1,1)*(0,1,0)	90,46%	2,04%	Não	5,76%
ARIMA(1,1,0)*(1,1,0)	92,43%	1,68%	Não	5,24%
ARIMA(1,1,1)*(1,1,1)	93,88%	1,44%	Sim	4,05%
ARIMA(1,1,1)*(1,1,0)	94,03%	1,41%	Não	4,19%

(*) 95% de nível de significância

Dessa forma o modelo escolhido foi o ARIMA(1,1,1)*(1,1,0), ou seja:

- AR(1) = Modelo autoregressivo de ordem 1. ($Z_t = \phi_1 Z_{t-1} + a_t$)
- I(1) = Primeira diferença. ($Z_t - Z_{t-1}$)
- MA (1) = Modelo médias móveis de ordem 1 ($Z_t = a_t - \theta_1 a_{t-1}$)
- SAR(1) = ($Z_t = \phi_1 Z_{t-12} + a_t$)
- SI(1) = ($Z_t - Z_{t-12}$)
- SMA = 0

Esse modelo foi escolhido por obedecer aos critérios de escolhas estabelecidos, comentados anteriormente.

6.1.1.3 – Modelos Estruturais

Inicialmente para realizar as previsões através do modelo estrutural, optou-se por trabalhar com o ln da série, devido a quatro aspectos que foram levados em consideração:

- **Lineariza o modelo:** transforma um modelo originalmente multiplicativo, que não pode ser estimado no STAMP, em um modelo aditivo, que pode ser estimado.

- **Estabiliza a variância dos resíduos:** os diagnósticos do modelo aditivo podem indicar que os resíduos possuem variância que cresce/decrece com o tempo. Trabalhar com o $\ln$ da série pode eliminar este comportamento indesejável.
- **Traz normalidade aos resíduos:** se os resíduos de um modelo para y_t possuem distribuição assimétrica, então pode ocorrer que os resíduos do modelo par $\ln y_t$ tenham distribuição aproximadamente simétrica, possuindo assim melhores propriedades.
- **Facilita a interpretação das componentes:** se y_t é a série de carga, então o modelo estrutural para $\ln(y_t)$ terá as seguintes características.

A **Figura 6.2** apresenta a decomposição da série em tendência e inclinação, Sazonalidade e componente irregular.




Figura 6. 2 – Desagregação da série de energia distribuída da CELPE em nível, tendência, sazonalidade e erro.

A forma escolhida para tratar a sazonalidade nos modelos estruturais foi por variáveis dummy (ver **item 4.2.3.2**), essa modelagem consiste na idéia de que o coeficiente de cada dummy representa o fator sazonal do mês. Esse modelo é denominado “Modelo Estrutural Básico”.

A **Figura 6.3** apresenta o teste abaixo atesta a normalidade dos resíduos e do parâmetro tendência:




Figura 6.3 – Teste de normalidade

A tendência utilizada no modelo é do tipo estocástica, ou seja, ajustada através do modelo tendência linear local (STAMP). Já a sazonalidade encontrada é do tipo aditiva.

Vale destacar que antes de chegar a esse modelo, onde inicialmente, as variáveis foram convertidas em Logaritmo Neperiano e a sazonalidade tratada na forma de variáveis dummies, haviam sido testados mais três modelos, totalizando quatros modelos simulados:

- Variáveis convertidas em LN e Sazonalidade Trigonométrica
- Variáveis convertidas LN e Sazonalidade Dummy
- Sazonalidade Trigonométrica
- Sazonalidade Dummy

No entanto, a simulação que obteve maior êxito foi a já destacada anteriormente (variáveis convertidas em LN e sazonalidade dummy).

A **Tabela 6.3** apresenta os resultados obtidos nos quatro modelos estudados:

Tabela 6. 3 - Comparação dos Modelos Estruturais

Modelo	Erro 2009	Mape 2009
LN Sazonalidade Trigonométrica	-2,76%	4,27%
LN Sazonalidade Dummy	-2,52%	3,99%
Sazonalidade Trigonométrica	-2,80%	4,25%
Sazonalidade Dummy	-2,97%	4,21%

(*) 95% de nível de significância

Como forma de medir a assertividade do modelo optou-se por duas estratégias. A primeira trata-se do erro acumulado no ano de 2009, ou seja, é feita a previsão para o ano de 2009 comparando o resultado, com o que de fato ocorreu no ano. O segundo estudo é feito com a média dos erros mensais absolutos no ano de 2009. Em ambos os casos a simulação utilizando a conversão das variáveis em LN e sazonalidade baseada em variáveis dummies, foi a que obteve o melhor desempenho.

6.1.1.4 – Redes Neurais

Finalmente, foram feitas simulações baseadas no modelo de Redes Neurais Artificiais, utilizando o software MATLAB.

Foram simulados oito modelos distintos, conforme **Tabela 6.4**.

Tabela 6. 4 – Simulações Redes Neurais

Algoritmo	Início do Histórico	Nº Neurônios
LM	1970	3
LM	2003	3
RPROP	1970	3
RPROP	2003	3
LM	1970	5
LM	2003	5
RPROP	1970	5
RPROP	2003	5

Para os modelos com três neurônios na camada de entrada foram utilizados a energia distribuída do mês anterior e duas codificações para reconhecimento do mês, como forma de captar um regime sazonal. Já para os modelos com cinco neurônios na camada de entrada foram utilizados os três meses antecessores e duas codificações para reconhecimento do mês.

A forma utilizada para representação dos meses, considera dois neurônios com funções de seno e cosseno, cujos valores são fixados pelas seguintes expressões:

$$\text{Neurônio1} = \text{Seno}(2,0 * \pi * N / T) \quad (6.13)$$

$$\text{Neurônio2} = \text{Cosseno}(2,0 * \pi * N / T) \quad (6.14)$$

Onde N varia de 1(janeiro) a 12 (dezembro) e T é o período que, nesse caso, é 12, conforme **Tabela 6.5**.

Tabela 6. 5 – Codificação da Sazonalidade com Senos e Cossenos

Meses	Neurônio 1	Neurônio 2	Ordem
Jan	0,5	0,866	1
Fev	0,866	0,5	2
Mar	1	0	3
Abr	0,866	-0,5	4
Mai	0,5	-0,866	5
Jun	0	-1	6
Jul	-0,5	-0,866	7
Ago	-0,866	-0,5	8
Set	-1	0	9
Out	-0,866	0,5	10
Nov	-0,5	0,866	11
Dez	0	1	12

Posteriormente foi feita a normalização dos dados através da fórmula:

$$X_{ni} = [b(X_i - X_{\min}) - a(X_i - X_{\max})] / (X_{\max} - X_{\min}) \quad (6.15)$$

Onde:

X_{ni} = Energia distribuída no ano i normalizada

X_i = Energia distribuída no ano i

$X_{\max}$ = Energia distribuída máxima da série

$X_{\min}$ = Energia distribuída mínima da série.

$a = 0$

$b = 1$

Posteriormente à normalização dos dados, os mesmos foram embaralhados e separados em três conjuntos:

- Conjunto de treinamento
- Conjunto de validação
- Conjunto de teste

Dentre os modelos simulados o critério de escolha foi o que obteve o menor MAPE. Dessa forma o a simulação com cinco neurônios na camada de entrada e histórico a partir de 1970. Posteriormente ainda foram feitas simulações com normalização utilizando a variável “a” da **Eq. 8.15** como -1 e como 0. Sendo essa última a que obteve melhor resultado.




Figura 6. 4 – Configuração da Rede Neural utilizada

Onde:

ED-1 = Energia distribuída do mês anterior

ED-2 = Energia distribuída de dois meses atrás

ED-3 = Energia distribuída de três meses atrás

SEN e COS = De acordo com a **tabela 6.5**

Portanto, o melhor modelo foi o que apresentou a seguinte configuração:

- Cinco neurônios na camada de entrada (ED-1, ED-2, ED-3, SEN e COS);
- Histórico mensal iniciado a partir de jan/1970, excluindo os anos de 2001 e 2002, devido ao racionamento de energia elétrica;
- Normalização de 0 a 1 (a e b, conforme **Equação 6.15**);
- Metodologia LM;
- Dezenove neurônios na camada oculta;
- Função de ativação: tansig (tangente hiperbólica) na camada oculta e logsig (sigmóide logística) na camada de saída;




Figura 6. 5 – Funções de ativação da camada oculta (tansig) e da camada de saída (logsig)

Tabela 6. 6 – Resultado dos modelos de RNA – MAPE 2009

MAPE 2009	03 Entradas				05 Entradas		
	03-08 RP	70-08 RP	03-08 LM	70-08 LM	03-08 RP	03-08 LM	70-08 LM
jan	3,17	5,13	3,07	1,87	3,00	9,60	7,59
fev	3,15	6,56	5,00	2,98	0,74	6,64	3,72
mar	0,39	4,74	1,54	5,07	1,65	10,46	2,76
abr	10,25	7,10	11,63	9,91	3,36	8,32	5,95
mai	8,99	9,39	4,69	7,29	3,51	2,85	4,76
jun	2,42	6,99	2,40	4,37	3,73	0,17	0,16
jul	2,15	4,05	1,70	0,66	6,16	2,47	0,21
ago	5,84	2,84	1,17	5,07	7,77	5,86	1,72
set	4,79	5,70	0,27	4,25	4,13	2,13	1,14
out	4,16	8,51	5,63	0,55	5,03	1,23	0,74
nov	4,51	6,05	4,23	5,78	7,02	1,00	0,31
dez	16,26	14,32	9,91	13,33	16,55	9,08	9,52
média	5,51%	6,78%	4,27%	5,10%	5,22%	4,98%	3,22%

6.1.2 - Comparações dos Erros dos Modelos de Curto Prazo

Após diversas simulações realizadas, dentre as quatro metodologias testadas, foram escolhidos os modelos que obtiveram menor MAPE no ano teste de 2009.

Verificou-se que a metodologia de Rede Neural utilizando o algoritmo LM, foi o modelo que obteve a maior quantidade de melhor desempenho na competição mensal, ou seja, apresentou cinco meses com menor desvio, tendo os melhores desempenhos em janeiro, fevereiro, março, junho e novembro. O modelo Box & Jenkins apresentou o menor MAPE mensal em apenas um mês: maio. Já a Modelo Estrutural e o Amortecimento Exponencial, obtiveram melhor desempenho em apenas três ocasiões, agosto, setembro e dezembro para o primeiro e abril, julho e outubro para o segundo. No entanto, ao tirarmos a média mensal (MAPE acumulado), verificamos que o melhor desempenho ficou com a metodologia de Rede neural (LM) seguida do Amortecimento Exponencial.

Tabela 6. 7 – Comparação mensal dos MAPEs dos modelos para o ano de 2009

MAPE 2009	Amortecimento Exponencial	Box & Jenkins	Modelo Estrutural	Redes Neurais
jan	9,47	9,24	10,34	7,59
fev	6,69	6,18	8,25	3,72
mar	6,62	4,46	8,14	2,76
abr	0,18	1,43	1,22	5,95
mai	2,34	1,39	4,22	4,76
jun	1,53	1,03	2,95	0,16
jul	0,10	0,37	2,22	0,21
ago	3,23	4,05	1,42	1,72
set	2,14	4,93	0,75	1,14
out	0,27	2,12	1,41	0,74
nov	1,17	2,89	0,45	0,31
dez	7,98	12,15	6,53	9,52
média	3,48%	4,19%	3,99%	3,22%

Vale destacar os elevados desvios, principalmente no primeiro trimestre do ano, em função de alguns fatores a serem expostos:

- Esse período compreendeu a fase mais aguda da crise econômico/financeira mundial que assolou o mundo ao final de 2008 e início de 2009, tendo maior repercussão, nas classes industrial e rural, principalmente nos setores voltados à demanda externa;

- As classes residencial e comercial, tiveram influencia negativa da troca da empresa responsável pela fiscalização e formatação dos processos de fraudes. Dessa forma houve uma considerável redução da energia recuperada no período, devido ao processo de adaptação da nova empresa. Vale ressaltar que mais de 80% da energia recuperada devido à fiscalização de consumidores fraudadores é reintegrada a essas duas classes.
- Calendário de faturamento desfavorável no período, com menor quantidade de dias de faturamento em relação a igual período do ano anterior.

Em contrapartida dezembro também apresentou elevado desvio. No entanto, a direção foi contrária a do primeiro trimestre, ou seja, houve uma elevação de mercado em função do calendário e da recuperação de perdas acima da média no mês.

Ou seja, são fatores endógenos e exógenos que de certa forma influenciaram negativamente no resultado da energia distribuída da CELPE no período.

6.2 – Modelos de Longo Prazo

Para as simulações de longo prazo, entende-se que são necessárias inserções de variáveis exógenas, de forma a tentar captar oscilações ocasionadas por fatores externos como, políticas econômicas (fiscais e monetárias), expansões de novas indústrias, crises políticas, econômicas e/ou financeiras, períodos de contingência (a exemplo do racionamento de energia elétrica), dentre outras.

Para o trabalho específico foram utilizadas como variáveis explicativas o PIB de Pernambuco e o número de clientes.

A inserção, no longo prazo, dessas variáveis, são de suma importância, pois modelos univariados, são incapazes de prever uma quebra estrutural ocasionada por alteração de alguma variável exógena.

Ainda foi utilizada uma componente autoregressiva da própria Energia Distribuída com uma defasagem de um passo (ano).

No longo prazo, optou-se por realizar simulações utilizando duas metodologias distintas:

- Regressão Dinâmica
- ANFIS

6.2.1 – Análise dos resultados dos modelos utilizados no Longo Prazo

A seguir serão apresentadas as simulações para projeção de longo prazo (anual), que nesse caso abrangeram duas metodologias distintas (Regressão Dinâmica e ANFIS).

6.2.1.1 – Regressão Dinâmica

Inicialmente, para os modelos de Regressão Dinâmica, preferiu-se trabalhar com a série transformada, utilizando o ano de 2005 como ano base, igualado a 100 e os anos subsequentes e consequentes (no caso das variáveis causais) calculados a partir dessa base. Esse procedimento foi necessário pelo seguinte fato:

Quando a série é estacionária, os resultados da estatística tradicional são válidos, caso contrário pode ocorrer o problema de estimadores viesados, comprometendo, consequentemente, a validade dos resultados.

Variáveis cujas médias e variâncias mudam com o tempo são chamadas de não estacionárias ou variáveis com raiz unitária. Além disso, a revolução da raiz unitária também mostrou que a estimação pelos métodos clássicos, tal como o método dos mínimos quadrados ordinários (OLS), para estimar relacionamentos entre variáveis que contenham raiz unitária, leva a resultados incorretos. Isto é conhecido como problema de regressão espúria, ou seja, quando temos um alto R^2 sem uma relação significativa entre as variáveis.

Variáveis cujas médias mudam com o tempo são conhecidas como variáveis não estacionárias ou variáveis que possuem raiz unitária. O número de diferenças necessárias para que uma série se torne estacionária é conhecido como ordem de integração da série. Se uma série deve ser diferenciada d vezes antes de tornar-se estacionária, então ela contém d raízes unitárias e é dita ser integrada de ordem d . Os testes de raízes unitárias são capazes de detectar se a série foi suficientemente diferenciada para se tornar estacionária. A incorreta identificação de ordem de integração (ou número de raízes unitárias) pode conduzir ao que ficou denominado de regressão espúria, ou seja, apesar dos testes estatísticos do modelo de regressão apresentarem-se significativos, os seus resultados não têm significado econômico.

Posteriormente aplicou-se logaritmo Neperiano na série, como forma de minimizar ou extinguir o problema de Heterocedasticidade, que decorre do fato da série de dados apresentar variâncias distintas para todas as observações, contrariando o postulado estatístico de Homocedasticidade (variância das observações constante). Vale ressaltar que

heterocedasticidade não elimina as propriedades de inexistência de viés e consistência dos estimadores de MQO, no entanto, eles deixam de ter variância mínima e eficiência, ou seja, não são os melhores estimadores lineares não-viesados.

Feitos esses ajustes, ainda foram consideradas duas variáveis dummies, uma para modelar o racionamento de energia elétrica ocorrido na Região Nordeste no ano de 1987 e outra para modelar o período de racionamento ocorrido em 2001.

Destaque para o elevado poder de explicação do modelo (R^2 ajustado = 0,997). Ressaltando ainda o MAPE de apenas 0,6%.

A equação do modelo foi a seguinte:

$$\begin{aligned} \ln(ED_t) = & 0,673 \ln(ED_{t-1}) + 0,189 \ln(NC_t) + 0,146 \ln(PIBPE_t) - 0,111 \\ & RACION_01 - 0,064 RACION_87 \end{aligned} \quad (6.16)$$

Onde:

ED_t = Energia distribuída da CELPE no ano t

ED_{t-1} = Energia distribuída da CELPE no ano t-1

NC_t = Número de consumidores faturados da CELPE no ano t

$PIBPE_t$ = Produto Interno Bruto para o estado de Pernambuco no ano t em R\$

$RACION_01$ = Dummy racionamento de energia elétrica 2001

$RACION_87$ = Dummy racionamento de energia elétrica 1987

Outros pontos a serem destacados no modelo:

- Todas as variáveis foram significantes a um nível de significância de 95%;
- Os sinais das variáveis estão de acordo com o a direção que se esperava, conforme capítulo 2;
- O problema de heterocedasticidade foi eliminado em função das transformações iniciais, trabalhadas na série (mudança de base e transformação logarítmica);
- Essas transformações possibilitaram a estacionaridade da série;
- Não existe problema de multicolinearidade entre as variáveis explicativas. Ou seja, possuem pouca correlação entre si.
- Os resíduos estão todos descorrelatados, conforme teste DW e Ljung Box. Conforme, **figura 6.6:**




Figura 6. 6 – Correlograma Autocorrelação de resíduos

Para que exista correlação de resíduos, ao menos uma barra vetical deveria ultrapassar a linha tracejada.

Já a **figura 8.7**, apresenta de forma gráfica como o modelo está bem ajustado. Com destaque para o entendimento da linha vermelha (previsão), em relação aos anos de quebras estruturais (acionamento de energia elétrica de 1987 e 2001), ratificando o excelente poder de explicação do modelo refletido na estatística R2-Ajustado:




Figura 6. 7 – Gráfico Energia Distribuída – Realizada x Prevista utilizando o modelos de Regressão Dinâmica do Forecast.

6.2.1.2 – ANFIS

Assim como no modelo de regressão dinâmica, no ANFIS foi utilizado o histórico anual de Energia Distribuída, PIB e Número de Clientes a partir de 1970, sendo as duas

últimas utilizadas como variáveis de entrada em conjunto com a energia distribuída do ano anterior.

Inicialmente os dados foram normalizados de acordo com a **Equação 6.17**;

$$X_{ni} = [b(X_i - 0,9X_{\min}) - a(X_i - 1,1X_{\max})]/(1,1X_{\max} - 0,9 X_{\min}) \quad (6.17)$$

Onde:

X_{ni} = Energia distribuída no ano i normalizada

X_i = Energia distribuída no ano i

$X_{\max}$ = Energia distribuída máxima da série

$X_{\min}$ = Energia distribuída mínima da série.

$a = 0$

$b = 1$

Posteriormente a base de dados foi dividida em:

- Conjunto de Treinamento;
- Conjunto de Teste;
- Conjunto de Validação.

Sendo o percentual para divisão a depender da quantidade de saída da simulação e do tamanho do conjunto de treinamento utilizado. No geral, foram feitos testes com conjunto de treinamento oscilando entre 25 a 30 observações e o restante distribuído nos outros dois conjuntos.

Foram realizadas várias simulações. No entanto serão destacadas as seguintes:

- Base 1- Utilizando como entrada:
PIBPE_t, NC_t, ED_{t-1}
- Base 2 - Utilizando como entrada:
PIBPE_t, ED_{t-1}
- Base 3 - Utilizando como entrada:
NC_t, ED_{t-1}
- Base 4 - Utilizando como entrada:
ED_{t-1}

Onde:

$PIBPE_t$ = Produto Interno Bruto para o estado de Pernambuco no ano t em R\$

ED_{t-1} = Energia distribuída da CELPE no ano t-1

NC_t = Número de consumidores faturados da CELPE no ano t

Para cada base serão apresentadas duas simulações:

- Conjunto de treinamento com 25 observações
- Conjunto de treinamento com 30 observações

Os anos de 2006 a 2009 foram utilizados como teste, de forma a possibilitar o cálculo do MAPE nesse período. A **tabela 6.8** apresenta um resumo dos resultados das simulações

Tabela 6. 8 – Comparação anual dos MAPEs do modelo do ANFIS

MAPE Ano	Conjunto de Treinamento 1-25				Conjunto de Treinamento 1-30			
	Base 1	Base 2	Base 3	Base 4	Base 1	Base 2	Base 3	Base 4
2006	3,50%	5,18%	1,92%	9,93%	7,66%	3,49%	3,46%	2,08%
2007	3,22%	4,24%	0,28%	7,35%	7,09%	3,85%	2,00%	0,25%
2008	6,76%	4,51%	2,69%	9,58%	10,06%	2,59%	3,96%	2,11%
2009	7,23%	5,80%	3,26%	12,36%	9,33%	0,51%	2,37%	5,04%
Média	5,18%	4,93%	2,04%	9,81%	8,54%	2,61%	2,95%	2,37%

O melhor resultado foi o obtido através da simulação com a Base 3, utilizando um conjunto de treinamento com 25 observações. Entretanto, a simulação com a Base 2 e um conjunto de treinamento com 30 observações foi a que obteve melhor resultado para o ano de 2009.

6.2.2 - Comparações dos Erros dos Modelos de Longo Prazo

Após encontrar o melhor modelo aplicado nas duas metodologias mencionadas (Regressão Dinâmica e ANFIS), foi feita uma comparação entre ambas de forma a encontrar o modelo que tenha obtido o menor MAPE dos últimos quatro anos.

Enfim, a tabela 8.7 apresenta um resumo dos melhores modelos aplicados às projeções de Longo Prazo. Os destaques em azul, são referentes ao menor MAPE dentre os modelos no respectivo ano analisado.

O melhor desempenho dentre os três modelos destacados, ficou com a metodologia de Regressão Dinâmica que foi minimizando os desvios a medida que o horizonte da previsão foi aumentando, chegando a um MAPE médio de 1,5% em quatro anos. Esse modelo obteve o melhor resultado no ano de 2008. Já o ANFIS (Base 3) com 25 observações para treinamento, obteve melhor resultado nos dois primeiros anos iniciais, e ficou com o segundo menor MAPE médio (2,04%). Por fim, o ANFIS (Base 2) com 30 observações para treinamento foi o que obteve o desempenho mais fraco dentre os três. No entanto, obteve o menor desvio no ano de 2009, conforme **Tabela 6.9**.

Tabela 6. 9 – Comparação anual dos MAPEs dos modelos de Longo Prazo

MAPE 2009	Regressão Dinâmica	ANFIS Base 3 (25)	ANFIS Base 2 (30)
2006	3,8%	1,92%	3,5%
2007	1,1%	0,28%	3,9%
2008	0,6%	2,69%	2,6%
2009	0,5%	3,26%	0,5%
Média	1,50%	2,04%	2,61%

Dessa forma, o **Capítulo 6**, apresentou os resultados de cada modelo de curto e longo prazo, bem como os softwares utilizados para cada simulação. No **Capítulo 7**, serão apresentadas as considerações finais, com ênfase para as conclusões obtidas após o a análise dos resultados das simulações apresentadas.

7 – Conclusão

O presente trabalho procurou apresentar, diversas opções de modelos para previsão da energia distribuída da CELPE (mercado cativo + mercado livre), no horizonte de curto prazo (mensal, até um ano à frente) e longo prazo (anual), comparando ao final os MAPEs obtidos para cada simulação, de forma a tornar os modelos comparáveis e classificar de acordo com o desempenho obtido.

Inicialmente foram feitas as projeções de curto prazo, utilizando cinco metodologias diferentes, porém todas univariadas: Amortecimento Exponencial, Box & Jenkins, Modelos Estruturais, Redes Neurais Artificiais (RPROP e LM), dentre essas a Rede Neural LM foi a que obteve melhores resultados na comparação do MAPE.

Posteriormente, foi feito o confronto de duas metodologias de multivariadas de longo prazo, onde na ocasião o modelo de Regressão Dinâmica, apresentou um melhor resultado em detrimento da metodologia ANFIS. Ressaltando que ambos utilizaram as mesmas variáveis exógenas (PIB e número de clientes).

Para trabalhos futuros recomenda-se testar modelos multivariados no curto prazo, utilizando variáveis explicativas, a exemplo da renda média e da produção industrial. No entanto, a dificuldade seria formar um histórico adequando, em função das constantes mudanças metodológicas de apuração dos institutos responsáveis pela divulgação dos dados, bem como a incerteza desses componentes no futuro. Outra melhoria a ser implantada, corresponde a inserção do calendário de faturamento nos modelos, de forma a representar melhor as oscilações decorrentes das oscilações de números de dias mensais faturados por cliente que de acordo com a Resolução 456 da ANEEL não devem ser menor do que 27 dias ou maior do que 33 dias.

No longo prazo as melhorias estão concentradas nas escolhas das variáveis, onde poderiam ser testadas outras entradas tanto exógenas (variáveis econômicas, demográficas e sociais), quanto endógenas (recuperação de perdas, eficiência energética e programas de cortes de clientes).

Pode-se destacar ainda, a possibilidade de montagem de clusters, agrupando as empresas que possuem séries semelhantes em virtude da estrutura de mercado parecida. Após os agrupamentos haveria a possibilidade de generalizar o melhor modelo para o grupo de concessionárias. No entanto, seria necessária a aquisição das séries de energia distribuída de todas as empresas estudadas, o que poderia ser um fator dificultador.

8 - Referências Bibliográficas

- [1] McCulloch, W. S. e Pitts, W. A logical calculus of the ideas immanent in nervous activity. Bulletin of Mathematical Biophysics, vol. 5, (pp.115-133),1943.
- [2] Levenberg, K. "A Method for the Solution of Certain Problems in Least Squares." Quart. Appl. Math. 2, 164-168, 1944.
- [3] Marquardt, D. "An Algorithm for Least-Squares Estimation of Nonlinear Parameters." SIAM J. Appl. Math. 11, 431-441, 1963.
- [4] Gill, P. E. and Murray, W. "Algorithms for the solution of the nonlinear least-squares problem", SIAM J. Numer. Anal. 15 [5] 977-992, 1978.
- [5] PAIXÃO, Lindolfo Ernesto. Memórias do projeto RE-SEB. São Paulo: Massao Ohno Editor, 2000.
- [6] BRASIL, Lei nº 9.427 de 26 de dezembro de 1996. Institui a Agência Nacional de Energia Elétrica - ANEEL, disciplina o regime das concessões de Serviços Públicos de Energia Elétrica, e dá outras providências. Diário Oficial da República Federativa do Brasil, Brasília, seção 1, p. 28653, 1996.
- [7] BRASIL, Lei nº 9.648 de 27 de maio de 1998. Altera dispositivos das Leis 3.890-A de 25.04.1961; 8.666 de 21.06.1993, 8.987 de 13.02.1995; 9.074 de 07.07.1995; 9.427 de 26.12.1996, e autoriza o Poder Executivo a promover a reestruturação da Centrais Elétricas Brasileiras S.A - ELETROBRÁS e de suas subsidiárias e dá outras providências. Diário Oficial da República Federativa do Brasil, Brasília, seção 1, v. 136, p. 1, 1998.
- [8] CASTRO, Marco Aurélio Lenzi. Análise dos Riscos de uma Distribuidora Associados à Compra e Venda de Energia no Novo Modelo do Setor Elétrico. Brasília, 2004. Dissertação (Mestrado em Engenharia Elétrica) – Faculdade de Tecnologia, Universidade de Brasília.
- [9] TORRES, Rodrigo Corrêa. Avaliação de Portfólios de Contratos de Compra e Venda de Energia Elétrica: Uma Abordagem pela Teoria de Opções. Rio de Janeiro, 2006. Dissertação (Mestrado em Engenharia Industrial) – Pontifícia Universidade Católica do Rio de Janeiro.
- [10] BRASIL, Lei nº 10.433 de 24 de abril de 2002. Autoriza a criação do Mercado Atacadista de Energia Elétrica - MAE, pessoa jurídica de direito privado, submetido a autorização, regulamentação e fiscalização da ANEEL, com a finalidade de viabilizar as transações de compra e venda de energia elétrica nos sistemas interligados. Diário Oficial da República Federativa do Brasil, Brasília, seção 1, v. 139, n. 79, p. 23, 2002.

[11] BRASIL, Decreto nº 5.163 de 30 de julho de 2004. Regulamenta a comercialização de energia elétrica, o processo de outorga de concessões e de autorizações de geração de energia elétrica, e dá outras providências. Diário Oficial da República Federativa do Brasil, Brasília, seção 1, v. 141, n. 146-A, p. 1, 2004.

[12] BRASIL, Lei nº 10.848 de 15 de março de 2004. Dispõe sobre a comercialização de energia elétrica, altera as Leis 5.655 de 20.05.1971, 8.631 de 04.03.1993, 9.074 de 07.07.1995, 9.427 de 26.12.1996, 9.478 de 06.08.1997, 9.648 de 27.05.1998, 9.991 de 24.07.2000, 10.438 de 26.04.2002, e dá outras providências. Diário Oficial da República Federativa do Brasil, Brasília, seção 1, v. 141, n. 51, p. 2, 2004.

[13] BRASIL, Decreto nº 5.177 de 16 de agosto de 2004. Autoriza a criação da Câmara de Comercialização de Energia Elétrica - CCEE, sob a regulação e fiscalização da ANEEL, e dispõe sobre sua organização, atribuições e funcionamento, regulamentando os arts. 4º e 5º da Lei 10.848 de 15.03.2004, bem como revoga os arts. 12 e 19 de Decreto 2.655 de 02.07.1998. Diário Oficial da República Federativa do Brasil, Brasília, seção 1, v. 141, n. 157, p. 5, 2004.

[14] BRASIL, Decreto nº 5.184 de 16 de agosto de 2004. Cria a Empresa de Pesquisa Energética - EPE, vinculada ao Ministério de Minas e Energia - MME, bem como aprova o Estatuto Social da mesma, e dá outras providências. Diário Oficial da República Federativa do Brasil, Brasília, seção 1, v. 141, n. 158, p. 5, 2004.

[15] CCEE – Câmara de Comercialização de Energia Elétrica, informações técnicas obtidas por meio de seu site: www.ccee.com.br em 01/09/06.

[16] NEVES FILHO, Flávio José Cavalcanti. Metodologia para Avaliação de Riscos na Contratação de Energia de uma Distribuidora. Recife, 2006. Monografia (Pós-Graduação em Engenharia Elétrica) – Escola Politécnica de Pernambuco, Universidade de Pernambuco - UPE.

[17] ANEEL, Agência Nacional de Energia Elétrica. Resolução 234/2006 SRE/ANEEL. Brasília, 2006.

[18] ANEEL, Agência Nacional de Energia Elétrica. Nota Técnica 292/2008 SRE/ANEEL. Brasília, 2008.

[19] Cho, M.Y.; Hwang, J.C.; Chen, C.S. Customer short term load forecasting by using ARIMA Transfer Function Model Energy Management and Power Delivery, 1995. In: Proceedings of EMPD '95, 1995 International Conference on Nov. 1995 vol.1, p. 317 – 322.

[20] Tang, W.K.; Wong, M.H.; Wong, Y.K. et al. Load forecasting by fuzzy neural network in Box-Jenkins models. In: Systems, Man, and Cybernetics, 1998. 1998 IEEE International Conference on Oct. 1998, vol.2, p. 11-14.

- [21] Cavallini, A.; Mazzanti, G.; Montanari, G.C.; Inference of a continuous auto-regressive model for the forecasting of nonstationary stochastic processes deriving from energy demand in electrical networks. In: Electrotechnical Conference, 1996. MELECON 96, 8th Mediterranean on May 1996, vol 2, p.726 – 729.
- [22] FERNANDES, Cristiano. Previsão de Fatos Estilizados de Séries de Consumo de Energia Elétrica Utilizando o Software STAMP. Rio de Janeiro, 2006. PUC-Rio – Neoenergia.
- [23] Lee, K.Y.; Park, J. H. Short-Term Load Forecasting Using an Artificial Neural Network, *IEEE Transactions on Power Systems*, Vol. 7, No 1, May 1992.
- [24] ZANINI, Alexandre. Redes Neurais e Regressão Dinâmica: Um Modelo Híbrido para Previsão de Curto Prazo de Demanda de Gasolina Automotiva no Brasil. Rio de Janeiro, abril 2000. Dissertação (Mestrado em Engenharia Elétrica) – Programa de Pós-Graduação em Engenharia Elétrica da PUC/Rio.
- [25] DONALD, Bowersonx; BIXBY, Cooper e DAVID, Closs. Gestão Logística de Cadeia de Suprimentos . New York: McGraw-Hill, 2002.
- [26] FERREIRA, Marcelo Pieri. Estimativa dos Efeitos do Racionamento nas Previsões de Carga Elétrica. Rio de Janeiro, 2004. Dissertação (Mestrado em Engenharia Elétrica) – Programa de Pós-Graduação em Engenharia Elétrica da PUC-Rio.
- [27] MIRANDA, Cristina Vidigal. Previsão de Dados de Alta Frequência para Carga Elétrica Usando Holt-Winters com dois Ciclos. Rio de Janeiro, 2007. Dissertação (Mestrado em Engenharia Elétrica) – Programa de Pós-Graduação em Engenharia Elétrica da PUC-Rio.
- [28] BOX, G. E. P.; JENKINS, G. M.. Time Series Analysis, Forecasting and Control. San Francisco, Holden-Day, 1994.
- [29] SOUZA, R. C., CAMARGO, M. E., Análise e Previsão de Séries Temporais : Os Modelos ARIMA. SEDIGRAF, 1996.
- [30] BALTAR, Bruno de Paula. Análise Temporal dos Preços da Commodity Cobre Usando o Modelo Box & Jenkins. Rio de Janeiro, 2009. Dissertação (Mestrado em Engenharia Elétrica) – Programa de Pós-Graduação em Administração de Empresas da PUC-Rio.
- [31] J.A.C.Bacellar Júnior. Previsão de cargas ativa e reativa baseada na metodologia de Box & Jenkins para séries temporais. Juiz de Fora, 2003. Dissertação (Mestrado em Engenharia Elétrica) – Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Juiz de Fora – UFJF.

- [32] FALCO, Gláucia de Paula. Técnicas Univariadas Aperfeiçoadas para a Previsão de Curtíssimo Prazo a partir de Dados Horários. Rio de Janeiro, 2005. Dissertação (Mestrado em Engenharia Elétrica) – Programa de Pós-Graduação em Engenharia Elétrica da PUC-Rio.
- [33] BALLINI, Rosângela. Análise e previsões de vazões utilizando modelos de series temporais, redes neurais e redes neurais nebulosas. Campinas, 2000. Tese (Doutorado em Engenharia Elétrica) – Programa de Pós-Graduação em Engenharia Elétrica da UNICAMP.
- [34] WERNECK, Roberto Freitas. Análise e Previsão de Demanda numa Empresa de Distribuição de Medicamentos. Juiz de Fora, 2007. Monografia (Graduação em Engenharia de Produção) – UFJF.
- [35] CELPE, Companhia Energética de Pernambuco. Relatório de Manifestação de Mercado de Energia Elétrica – Novas Projeções de Mercado: Critérios, Premissas e Projeções (Anexo I) – Versão 3. Recife, 2009.
- [36] BARBIERO, Claudia Correia de Moraes. Séries Temporais: Um Estudo de Previsão para a Receita Operacional da ECT – Empresa Brasileira de Correios e Telégrafos. Florianópolis, 2007. Monografia (Mestrado em Engenharia de Produção) – Programa de Pós-Graduação em Engenharia Elétrica da UFSC.
- [37] CELPE, Companhia Energética de Pernambuco. Relatório de Manifestação de Mercado de Energia Elétrica – Novas Projeções de Mercado: Critérios, Premissas e Projeções (Anexo I) – Versão 2. Recife, 2009.
- [38] ANEEL, Agência Nacional de Energia Elétrica. Anexo IV, Nota Técnica 351/2007 SER/ANEEL. Brasília, 2007.
- [39] Harvey, A. C. (1989), Forecasting, Structural Time Series Models and the kalman Filter. Cambridge University Press.
- [40] Durbin, J. and Koopman S.J. (2001), Time Series Analysis by State Space Methods Oxford University Press.
- [41] SOUZA, Rodrigo Lage. Modelagem Estrutural Aplicada a previsão do Preço Spot de Energia Elétrica do Brasil. Rio de Janeiro, 2003. Dissertação (Mestrado em Engenharia Elétrica) – Programa de Pós-Graduação em Engenharia Elétrica da PUC-Rio.
- [42] BRESSAN, Aureliano Angel, LIMA, João Eustáquio. Modelos de previsão de preços aplicados aos contratos futuros de boi gordo na BM&F. Belo Horizonte, 2002. Artigo para “Nova Economia”.

- [43] PITACAS, Maria Isabel. Estudos Comparativos e Métodos de Previsão Aplicação à Série do Número Semanal de Adultos Alojados num Hotel. Porto/Portugal, 1999. Dissertação (Mestrado em Estatística) – Programa de Mestrado da Faculdade de Ciências da Universidade do Porto.
- [44] Lee, K.Y.; Park, J. H. Short-Term Load Forecasting Using an Artificial Neural Network, *IEEE Transactions on Power Systems*, Vol. 7, No 1, May 1992.
- [45] Bakirtzis, A.G.; Petridis, V.; Kiartzis, S.J. et al. A Neural Network Short Term Load Forecasting Model for the Greek Power System, *IEEE Transactions on Power Systems*, Vol. 11, No 2, May 1996
- [46] Bakirtzis, A.G.; Theocharis, J.B.; Kiartzis, S.J. et al. Short Term Load Forecasting Using Fuzzy Neural Networks, *IEEE Transactions on Power Systems*, Vol. 10, No 3, Maio 1995.
- [47] Khotanzad, A; Rohani, R. A.; Maratukulam, D. et al. A Neural-Network-Based Electric Load Forecasting System, *IEEE Transactions on Neural networks*, vol. 8, no. 4, 1997, pp. 835-845.
- [48] Khotanzad, A; Rohani, R. A.; Maratukulam, D. ANNSTLF - Artificial Neural Network Short-Term Load Forecaster - Generation Three, *IEEE Transactions on Power Systems*, Vol. 13, No 4, p. 1413-1422 , November 2002.
- [49] Peng T.M., Hubele N.F., Karady G.G., An Adaptative Neural Network Approach To One-Week Ahead Load Forecasting, *IEEE Transaction On Power System*, Vol. 8, No 3, Novembro 1993.
- [50] Chen S., Yu D.C., Mooghaddamjo A. R., Weather Sensitive Short-Term Load Forecasting Using Nonfully Connected Artificial Neural Network, *IEEE Transaction On Power System*, vol 7, No 3, August 1992
- [51] Papalexopoulos A.D., Hao S., Peng T., An Implementation Of A Neural Network Based Forecasting Model For The SEM, *IEEE Transaction On Power System*, Vol. 9, No 4, Agosto 1994.
- [52] Park D.C., El-Sharkawi M.A., Marks II R. J., Atlas L.E., Damborg M.J., Electric Load Forecasting Using An Artificial Neural Network, *IEEE Transaction On Power System*, Vol. 6, No 24, Maio 1991.
- [53] Zebulum R. S., Guedes K., Vellasco M.M., Pacheco M.A., Short-Term Load Forecasting Using Neural Nets, *Lecture Notes in Computer Science 930, From Natural to Artificial Neural Computation*, Springer-Verlag, *Proceedings of the International Workshop on Artificial Neural Networks, (IWANN'95)*, pp. 1001 – 1008, Torremolinos (Málaga), Espanha, 7-9 de Junho

- [54] Ribeiro Neto L. S., Zebulum R. S., Vellasco M., Pacheco M.A., "Very Short Term Load Forecasting System Using Neural Networks", ISF'97 - The Seventeenth Annual International Symposium on Forecasting, pp. 51, Barbados, Junho 19-21, 1997.
- [55] R. R. B. de Aquino, A. A. Ferreira, G. B. Silva, et al, "Previsão de Carga Horária em Médio Prazo Utilizando Redes Neurais com Foco na Previsão dos Feriados", VII CBRN – Congresso Brasileiro de Redes Neurais, ISSN: 1808-8589, Natal 2005.
- [56] SILVA, Geane Bezerra. Sistema Híbrido de Previsão de Carga Elétrica em Curto Prazo Utilizando Redes Neurais Artificiais e Lógica Fuzzy. Recife, 2006. Dissertação (Mestrado em Engenharia Elétrica) – Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Pernambuco -UFPE.
- [57] R. R. B. de Aquino, A. A. Ferreira, G. B. Silva, et al, "Previsão de Carga Horária em Médio Prazo Utilizando Redes Neurais com Foco na Previsão dos Feriados", VII CBRN – Congresso Brasileiro de Redes Neurais, ISSN: 1808-8589, Natal 2005.
- [58] R. R. B. de Aquino, A. A. Ferreira, et al, "Previsão de Carga em Curto e Médio Prazo Utilizando Redes Neurais Artificiais: Uma Aplicação ao Sistema CELPE", SENDI - XVI Seminário Nacional de Distribuição de Energia Elétrica, Brasília 2004.
- [59] Gavrilas, M. L.; Ciutea, I; Tanasa, C., Medium-Term Load Forecasting With Artificial Neural Network Models, In: CIRED 2001 Conference Publication, June 2001, p. 18-21.
- [60] Lee, K.Y.; Park, J. H. Short-Term Load Forecasting Using an Artificial Neural Network, *IEEE Transactions on Power Systems*, Vol. 7, No 1, May 1992.
- [61] Chan, Z.S.H.; Ngan, H.W.; Fung, Y.F.; et al. An Advanced Evolutionary Algorithm for Load Forecasting with the Kalman Filter. In: Advances in Power System Control, Operation and Management, 2000. APSCOM-00. 2000 International Conference on 30 Oct.-1 Nov. 2000, vol 1, p. 134 - 138 vol.
- [62] Lu C.N., Wu H.T., Vemuri S., Neural Network Based Short-Term Load Forecasting, *IEEE Transaction On Power System*, Vol. 8, No 1, Fevereiro 1993.
- [63] Mori, H.; Itagaki. A Fuzzy Inference Neural Network Based Method for Short-term Load Forecasting, In: Neural Networks IEEE International Joint Conference (July, 2004) Proceedings, on July 2004 vol.3, p. 2403 – 2406.
- [64] Kim, K.H.; Park, J.K.; Hwang, K.J. et al. Implementation of Hybrid Short-term Load Forecasting System Using Artificial Neural Networks and Fuzzy Expert Systems, *IEEE Transactions on Power Systems*, Vol. 10, No 2, August 1995.
- [65] Srinivasan, D.; Tan, S.S.; Chang, C.S. et al. Parallel Neural Network-Fuzzy Expert System Strategy For Short-term Load Forecasting: System Implementation And

Performance Evaluation. IEEE Transactions on Power Systems, Vol. 14, No 3, August 1999.

[66] Papadakis, S. E.; Theocharis, J. B.; Kiartzis, S. J. et al. A Novel Approach to Short-term Load Forecasting using Fuzzy neural networks, IEEE Transactions on Power Systems, vol. 13, no. 2, 1998, pp. 480-492.

[67] Kim, K.H.; Youn, H.S.; Kang, Y.C. et al. Short-Term Load Forecasting for Special Days in Anomalous Load Conditions Using Neural Networks. IEEE Transactions on Power Systems, Vol. 15, No 2, August 1999.

[68] Kruse R., Detlef Nauck , NEFCLASS-A Neuro-Fuzzy Approach for the Classification of Data”, Proc. of the 1995 ACM Symposium on Applied Computing, Nashville.

[69] Jang, J.R., ANFIS : Adaptive-Network-Based Fuzzy Inference System, Electric Power Systems Research, IEEE Transactions on systems Vol. 23, No 3, 1993, pp. 169-176.

[70] SOUZA, Reinaldo Castro; ZANINI, Alexandre. Modelos Estatísticos de Previsão. Apostila do Curso de Mercado de Energia Elétrica. NC ENERGIA. Recife, maio 2005.

[71] BRAGA, Antônio; CARVALHO, André; LUDERMIR, Teresa. Redes Neurais Artificiais: Teoria e Aplicações. Rio de Janeiro: LTC, 2000.

[72] Haykin, S., 1999. Redes Neurais: Princípios e Prática. ARTMED Editora S. A.

[73] TAFNER, Malcon Anderson. Redes Neurais Artificiais: Aprendizado e Plasticidade. 1998. Revista Cérebro & Mente – Universidade Estadual de Campinas.

[74] GRUPO PET, Engenharia Elétrica. Curso de Matlab. Mato Grosso do Sul. Universidade Federal do Mato Grosso do Sul – UFMS – Departamento de Engenharia.