



UNIVERSIDADE FEDERAL DE ITAJUBÁ
PROGRAMA DE PÓS-GRADUAÇÃO
EM ENGENHARIA ELÉTRICA

Uma alternativa aos Modelos NEWAVE e DECOMP por meio da Aplicação de
Técnicas de Inteligência Artificial.

Pablo Corrêa Fonseca

Itajubá, abril de 2013.



UNIVERSIDADE FEDERAL DE ITAJUBÁ
PROGRAMA DE PÓS-GRADUAÇÃO
EM ENGENHARIA ELÉTRICA

Pablo Corrêa Fonseca

Uma alternativa aos Modelos NEWAVE e DECOMP por meio da Aplicação de
Técnicas de Inteligência Artificial.

Dissertação apresentada à Universidade Federal de Itajubá
como parte dos requisitos para a obtenção do grau de Mestre
em Ciências em Engenharia Elétrica.

Área de concentração: Automação de sistemas industriais

Orientador: Benedito Isaías de Lima Lopes

Co-orientador: Antonio Carlos Zambroni de Souza

Abril de 2013

Itajubá – MG



UNIVERSIDADE FEDERAL DE ITAJUBÁ
PROGRAMA DE PÓS-GRADUAÇÃO
EM ENGENHARIA ELÉTRICA

Pablo Corrêa Fonseca

Uma alternativa aos Modelos NEWAVE e DECOMP por meio da Aplicação de
Técnicas de Inteligência Artificial.

Tese aprovada por banca examinadora em 29 de abril de
2013, conferindo ao autor o título de Mestre em Ciências em
Engenharia Elétrica.

Banca examinadora:

Prof. Dr. Benedito Isaías Lima Lopes
Prof. Dr. Antonio Carlos Zambroni de Souza
Prof. Dr. Carlos Alberto Murari Pinheiro
Dr. Luiz Claudio de Araujo Ferreira

Itajubá - MG

2013

Agradecimentos

Agradeço aos meus familiares, em especial meus pais Marcos e Selene, pelo apoio às minhas decisões e incentivo dado desde que me recordo. Agradeço também a minha irmã Natália pela amizade e carinho.

Aos meus amigos e companheiros da república Moecana que se tornaram ao longo desses anos uma segunda família, partilhando bons e maus momentos.

Ao meu orientador professor Benedito Isaías de Lima Lopes pela confiança, amizade e conhecimento, essenciais ao desenvolvimento deste trabalho.

Ao professor Antônio Carlos Zambroni de Souza, pela amizade e por toda a ajuda.

A CAPES pelo auxílio financeiro.

Aos amigos Érick Azevedo, Anderson Rodrigo de Queiroz, professor Jose Wanderley Marangon Lima, professor Jamil Haddad, professor Afonso Henrique Moreira Santos e todos aqueles que me proveram oportunidades e conhecimento ao longo desta etapa da minha vida.

Resumo

A estrutura de geração, transmissão e distribuição de energia elétrica no Brasil possui diversas particularidades não encontradas em outras nações. Tais diferenças ocorrem tanto pelas tecnologias utilizadas nas operações, quanto pelas características geográficas do território brasileiro.

A determinação dos preços e tarifas da energia no Brasil é uma atividade complexa, e depende de informações fornecidas por agentes distintos. Este trabalho tem como foco o estudo da formação de um determinado preço de energia elétrica no mercado de curto prazo, também conhecido como preço “spot”.

O preço “spot” é resultado direto da execução dos modelos matemáticos de planejamento empregados: NEWAVE e DECOMP. Ele representa o custo marginal de operação do sistema elétrico para uma condição de despacho ótimo das usinas geradoras ótimas.

O processamento do alto volume de dados requeridos por estes modelos é uma tarefa que demanda um tempo elevado, além de conhecimento específico das centenas de variáveis de entrada, o que de certa forma inviabiliza a utilização em cenários onde a tomada de decisão deve ser ágil, como por exemplo, em leilões de energia.

O conhecimento prévio de valores que este preço pode assumir é uma informação de grande valor estratégico para vários agentes do setor elétrico brasileiro, destacando-se geradores, distribuidores e comercializadores.

Este trabalho propõe uma maneira de se estimar valores futuros do preço “spot” de energia elétrica por meio da análise, utilizando métodos de otimização combinados com redes neurais artificiais.

Abstract

The features of the systems used in generation, transmission and distribution of electrical energy in Brazil have peculiarities not found on similar systems in other nations. Many of these differences occurs because of the technologies used in operations, as well geographical features present only in Brazil.

The determination of energy prices and fares in Brazil is a complex activity, and relies on information provided by different agents. This work focuses on the study of the formation of a certain price in the electricity spot market, price or "spot".

The price of electricity in the Brazilian short-term market, spot price, is obtained by executing two mathematical models: NEWAVE and DECOMP, and represents the marginal cost of operating the electric system in an optimum scenario.

The processing of high volumes of data required by these models is a task that requires considerable time and knowledge of hundreds of input variables, which somehow makes it impossible to use in cases where fast decision must be taken, such as energy auctions.

Prior knowledge of values that this price may assume is valuable strategic information to various agents of the Brazilian electric sector, especially generators, distributors and retailers.

This paper proposes a way to estimate future values of the spot power price through analysis, based on artificial intelligence techniques, of the results given by those models, and also the introduction of some estimated values.

Sumário

Agradecimentos	III
Resumo	V
Abstract	VI
Sumário	VII
Lista de figuras	IX
1. Introdução.....	1
1.1 Objetivo	5
1.2 Metodologia.....	5
1.3 Motivação	6
2. O planejamento, a geração e o preço da energia elétrica no Brasil.....	9
2.1 O parque gerador brasileiro	10
2.2 Planejamento da operação dos sistemas hidrotérmicos	15
2.2.1 O Planejamento anual da operação energética	15
2.2.2 O Programa Mensal de Operação Energética.....	18
2.3 Os Modelos NEWAVE e DECOMP	21
2.4 Custo total e ponto ótimo de operação	24
2.5 Determinação dos custos futuro e imediato.....	28
2.6 Otimização.....	29
2.7 Processamento dos Modelos NEWAVE e DECOMP pela CCEE.....	36
2.8 O Custo marginal de operação e a formação o preço de liquidação das diferenças.....	37
3. Uma proposta complementar aos modelos NEWAVE e DECOMP para melhores projeções usando técnicas de Inteligência Artificial.....	39
3.1 O erro de Projeção do CMO nos modelos NEWAVE e DECOMP	39
3.2 Coleta, análise e pré-processamento dos dados.....	43
3.3 Redes neurais artificiais.....	46
3.4 Treinamento.....	48

3.5	Arquiteturas de redes neurais	49
3.5.1	Arquitetura de rede feed-forward.	52
3.5.2	Arquitetura feed-forward em cascata.	53
3.5.3	Rede com atraso de tempo focado.	53
3.5.4	Rede com atraso de tempo distribuído.	54
3.5.5	Rede de camadas recorrentes.	54
3.5.6	Rede não linear auto regressiva com entrada exógena (NARXnet).	55
3.6	Validação	58
3.1	Resultados do experimento.	60
4.1	Conclusões.	64
4.2	Trabalhos Futuros	66
5.	Bibliografia	68
A.	Resultados obtidos com as arquiteturas de RNA.	72
A.1	Resultados para a arquitetura <i>feed-forward</i>	73
A.2	Resultados para a arquitetura <i>feed-forward</i> em cascata.	74
A.3	Resultados para a arquitetura com atraso de tempo focada.	75
A.4	Resultados para a arquitetura com atraso de tempo distribuído.	76
A.5	Resultados obtidos com a arquitetura de rede recorrente.	77
A.6	Resultados obtidos com a arquitetura de rede NARX.	78

Lista de figuras

Figura 1-1 - Estrutura atual do setor elétrico brasileiro. _____	3
Figura 2-1 - Variação do PLD em relação às projeções. _____	7
Figura 2-2 - Variação do volume de partida em relação às previsões. _____	8
Figura 2-1 - Matriz Energética Brasileira ano base 2011. _____	9
Figura 2-2 - Capacidade instalada de geração elétrica. _____	10
Figura 2-3 - Matriz de geração de energia elétrica no Brasil. _____	11
Figura 2-4 - Geração de eletricidade no mundo em 2009. _____	11
Figura 2-5 Sistema Interligado Nacional – SIN. _____	12
Figura 2-6 - Diversidade Hidrológica do SIN. _____	13
Figura 2-7 - Formação do CMO. _____	20
Figura 2-8 - Modelo de sistema equivalente usado pelo NEWAVE. _____	22
Figura 2-9 - Modelo de interligação do NEWAVE. _____	22
Figura 2-10 - Diferença de representação das usinas entre o modelos NEWAVE e DECOMP. _____	23
Figura 2-11 - Custo do déficit de energia elétrica. _____	25
Figura 2-12 - Representação do custo imediato. _____	25
Figura 2-13 - Custos imediatos e futuros. _____	26
Figura 2-14 - Custo Total. _____	26
Figura 2-15 - Definição do Valor da Água. _____	27
Figura 2-16 - Derivada do custo imediato. _____	27
Figura 2-17 - Definição de estado. _____	29
Figura 2-18 - Definição de trajetória. _____	29
Figura 2-19 - Processamento da PDE. _____	30
Figura 2-20 - Exemplo para a PDDE. _____	31
Figura 2-21 - Custos futuros e valor da água. _____	31
Figura 2-22 - Envoltórias superiores dos custos futuros. _____	32
Figura 2-23 – valor da água no estado A. _____	32
Figura 2-24 - Alteração do nível final de armazenamento para a etapa. _____	33
Figura 2-25 - Síntese do problema de otimização. _____	33
Figura 3-1 - Formato da saída do CMO no processamento do DECOMP. _____	40
Figura 3-2 - Exemplo de erro de projeção do CMO. _____	41
Figura 3-3 - Fluxograma do experimento. _____	42
Figura 3-4 - Captura de tela do programa de extração dos dados. _____	44
Figura 3-5 – Síntese da relevância dos dados de entrada do modelo. _____	45
Figura 3-6 - Estrutura de um neurônio biológico. _____	47
Figura 3-7 - Modelo matemático de um neurônio. _____	47

Figura 3-8 - Exemplo de uma arquitetura estática feed-forward.	49
Figura 3-9 - Exemplo de uma arquitetura LDDN.	50
Figura 3-10 - Exemplo de rede recorrente simples.	51
Figura 3-11 - Gráfico de uma função log-sigmoide.	52
Figura 3-12 - Arquitetura da rede utilizada.	53
Figura 3-13 - Rede feed-forward em cascata utilizada.	53
Figura 3-14 - Arquitetura da rede com atraso de tempo focada utilizada.	53
Figura 3-15 - Arquitetura de rede com atraso de tempo distribuída usada.	54
Figura 3-16 - Arquitetura de camadas recorrentes usada.	54
Figura 3-17 - Estrutura de um modelo NARX.	56
Figura 3-18 - Diagrama de uma rede neural com arquitetura NARX.	57
Figura 3-19 - Arquitetura paralela (esquerda) e série-paralela (direita) de redes NARX.	57
Figura 3-20 - Redes NARX aberta (a) e fechada (b) usadas.	58
Figura 4-1 - Erro de previsão do modelo como um indicador de volatilidade.	61
Figura 4-2 – Melhores resultados obtidos com o experimento.	63
Figura A-1 Resultados obtidos com a arquitetura <i>feed-forward</i> .	73
Figura A-2 Resultados obtidos com a arquitetura <i>feed-forward</i> em cascata.	74
Figura A-3 Resultados obtidos com a arquitetura atraso de tempo focada.	75
Figura A-4 Resultados obtidos com a arquitetura atraso de tempo distribuída.	76
Figura A-5 Resultados obtidos com a arquitetura recorrente.	77
Figura A-6 Resultados obtidos com a arquitetura NARX.	78

Lista de siglas e abreviações

ACL	Ambiente de contratação livre.
ACR	Ambiente de contratação regulado.
ANEEL	Agência nacional de energia elétrica.
BEM	Balanço energético nacional.
CCEE	Câmara de comercialização de energia elétrica.
CEPEL	Centro de pesquisas de energia elétrica.
CMO	Custo marginal de operação.
CMSE	Comitê monitoramento setor elétrico.
CVU	Custo variável unitário.
DECOMP	Planejamento e Operação a Médio Prazo.
EPE	Empresa de pesquisas energéticas.
FCF	Função de custo futuro.
LDDN	Redes digitais dinâmicas em camadas.
MAE	Mercado atacadista de energia elétrica.
MME	Ministério de minas e energia.
MLP	Multi Layer Perceptron, Rede Neural de Multicamadas
NEWAVE	Modelo Estratégico de Geração Hidrotérmica a Subsistemas Equivalentes.
ONS	Operador nacional do sistema elétrico.
PEN	Planejamento anual da operação.
PLD	Preço de liquidação das diferenças.
PMO	Planejamento mensal da operação.
RNA	Rede neural artificial.
SIN	Sistema interligado nacional.
SQL	Linguagem de consulta estruturada.
TDL	Linha de atraso de tempo.

CAPÍTULO 1

1. Introdução

O setor elétrico brasileiro sofreu grandes mudanças a partir da década de 70, com a publicação da Lei nº 5.655/71, que definiu que as tarifas de energia elétrica deveriam ser regidas pelo chamado “custo do serviço”, ou seja, o valor destas tarifas deveria cobrir os custos associados à geração, transmissão e distribuição além de uma remuneração em um patamar entre 10% e 12% ao ano.

No entanto, em função das diferenças dos custos de geração e distribuição nas diversas regiões brasileiras, muitas empresas começaram a apresentar resultados financeiros negativos, o que forçou o governo a criar um mecanismo que possibilitasse a igualdade das tarifas entre as empresas do setor elétrico. Este mecanismo de equalização tarifária foi instituído pelo decreto-lei 1.383/74 que determinava que os consumidores de todas as regiões do país gozassem do mesmo nível tarifário numa mesma classe de consumo, bem como o repasse de recursos das empresas com balanços positivos àquelas com déficits em suas contas.

Neste modelo estatal e verticalizado, as empresas de energia elétrica eram responsáveis tanto pelos trabalhos de geração, quanto pela transmissão e distribuição da energia elétrica, toda atividade relacionada à energia elétrica era um monopólio: os consumidores eram cativos, obrigados a comprar de apenas uma empresa. Além disto, o mercado era totalmente regulado e havia tarifas para todos os segmentos consumidores: industrial, comercial e residencial.

Este modus operandi persistiu até meados da década de 90, quando o setor começava a apresentar sinais de estagnação. Os investimentos, provenientes de recursos públicos, foram reduzidos drasticamente e surgiu então a necessidade de medidas que possibilitassem o aumento da oferta de energia e a revitalização do setor elétrico brasileiro.

O governo federal publicou então a lei nº 8.631/93, que extinguiu a equalização tarifária vigente e instituiu os contratos de suprimento entre agentes geradores e agentes distribuidores.

A entrada em vigor da lei nº 9.074/95 estimulou a participação da iniciativa privada no setor de geração de energia por meio da figura do produtor independente de energia, que

possibilitando que empresas privadas produzissem e comercializassem energia elétrica - atividade antes restrita às empresas estatais. Esta lei também estabeleceu a figura do consumidor livre, que atendendo a certos requisitos, poderia ter a liberdade de escolha do seu fornecedor de energia elétrica. Desta maneira, o mercado, que era totalmente regulado e cativo, passa a considerar consumidores que negociam livremente os termos contratuais para o fornecimento de energia elétrica.

Como consequência da implantação do plano de reestruturação do setor elétrico brasileiro iniciado em 1996, por meio das Leis nº 9.427/96 e nº 9.648/98, dos Decretos nº 2.335/97 e nº 2.655/98 e também da Resolução da ANEEL nº 351/98, foram criados: um órgão regulador (a Agência Nacional de Energia Elétrica – ANEEL), um operador para o sistema elétrico nacional (Operador Nacional do Sistema Elétrico – ONS) e um ambiente para a realização das atividades de compra e venda de energia (o Mercado Atacadista de energia Elétrica – MAE).

No ano de 2001, o setor elétrico sofreu uma grave crise de abastecimento que teve como consequência direta um plano de racionamento e a constatação da necessidade de uma revisão para o aperfeiçoamento do modelo vigente. É então instituído em 2002 um comitê com esta finalidade, que ao final dos trabalhos publicou três relatórios, que sugeriam alterações em diversos segmentos do setor elétrico.

Durante os anos de 2003 e 2004, o governo federal, por meio das leis 10.847/04, 10.848/04 e pelo Decreto nº 5.163/04, instituiu então um novo modelo para o setor elétrico brasileiro.

Entre as principais mudanças deste período destacam-se a criação de um órgão responsável pelo planejamento do setor elétrico em longo prazo (a Empresa de Pesquisa Energética – EPE), uma instituição com a função de avaliar permanentemente a segurança do suprimento de energia elétrica (o Comitê de Monitoramento do Setor Elétrico – CMSE) e uma instituição para dar continuidade às atividades do MAE, relativas à comercialização de energia elétrica no Sistema Interligado (a Câmara de Comercialização de Energia Elétrica - CCEE).

A Figura 1-1, a seguir, representa as instituições do modelo vigente no setor elétrico brasileiro:



Figura 1-1 - Estrutura atual do setor elétrico brasileiro. Fonte: Figura elaborada pelo autor.

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), onde participam os agentes de geração, de comercialização e de distribuição de energia elétrica, e o ambiente de contratação livre (ACL), onde participam agentes de geração, de comercialização, importadores e exportadores de energia e consumidores livres.

Visando garantir a segurança do suprimento da energia elétrica, este novo modelo propõe uma série de medidas a serem observadas pelos agentes, entre elas destacam-se a exigência de contratação de 100% da demanda por parte das distribuidoras e dos consumidores livres e a contratação de usinas hidrelétricas e termelétricas em proporções que assegurem o melhor equilíbrio entre garantia e custo, esse mecanismo de contratação é melhor explicado no capítulo 2.

É notável o crescimento da complexidade do setor elétrico brasileiro ao longo das últimas décadas. O modelo que era antes totalmente centralizado, rígido e controlado passa agora para uma forma onde os agentes possuem mais liberdade em suas decisões, entretanto, torna-se mais evidente a necessidade de planejamento e fiscalização das operações deste setor.

O ONS é o agente responsável pela coordenação e controle da operação das instalações de geração e transmissão de energia elétrica no Sistema Interligado Nacional (SIN), sob a fiscalização e regulação da ANEEL. [1]

O ciclo de planejamento do ONS contempla, entre outros estudos, o planejamento anual da operação elétrica (PEN) e o programa mensal da operação (PMO).

O PEN, como o próprio nome indica, é elaborado anualmente e está sujeito a revisões ocasionadas por fatos relevantes. É constituído de avaliações das condições de atendimento do mercado de energia elétrica do SIN em um horizonte de cinco anos, considerando diferentes cenários de oferta e demanda. Essas avaliações são apresentadas ao Comitê de Monitoramento do Setor Elétrico (CMSE) e à Empresa de Pesquisa Energética (EPE) e fornece a base para a tomada de decisões de antecipação e/ou implantação de empreendimentos de geração e transmissão com o objetivo de ampliar a margem de segurança da operação energética do SIN.

O PMO é elaborado pelo Operador Nacional do Sistema Elétrico com a participação dos agentes interessados. Os estudos, que são realizados a cada mês e revistos semanalmente, são discretizados em etapas semanais e em patamares de carga. Como resultado, fornecem metas e diretrizes a serem seguidos pelos órgãos executivos da programação diária da operação eletroenergética e da operação em tempo real. Além destes resultados, o PMO também fornece o Custo Marginal de Operação do sistema (CMO), que limitados por valores estipulados pela ANEEL são usados pela CCEE para o cálculo do Preço de Liquidação das Diferenças (PLD).

1.1 Objetivo

O objetivo deste trabalho é desenvolver um conjunto de procedimentos validados que permita a criação e o desenvolvimento de um programa computacional capaz de identificar e isolar os fatores influentes diretamente na formação do PLD; fornecendo como saída a previsão do próximo preço do PLD, usando para isto métodos de otimização combinados com técnicas de inteligência artificial.

1.2 Metodologia

Uma vez estabelecido o objetivo do trabalho, pode-se detalhar a metodologia a ser apresentada neste documento:

1. Apresentar os processos e os modelos usados no planejamento da operação do setor elétrico brasileiro (NEWAVE e DECOMP);
2. Apresentar ferramentas de previsão de séries temporais e de técnicas na área de Inteligência Artificial, sobretudo em Redes Neurais Artificiais; e modelos híbridos.
3. Extrair, organizar e processar as informações dos arquivos de entrada e saídas dos programas NEWAVE e DECOMP, de forma a facilitar o trabalho futuro sobre esses dados;
4. Implementar modelos de arquiteturas de Redes Neurais Artificiais, visando às análises e estudos dos programas NEWAVE e DECOMP.
5. Desenvolver a ferramenta computacional abordada capaz de gerenciar automaticamente todo o procedimento desenvolvido, desde a coleta dos dados até a apresentação da previsão. Modelos de previsão de séries temporais e MLPs são usadas nesta etapa.

6. Comparar o desempenho das arquiteturas de Redes Neurais Artificiais desenvolvidas, bem como a utilização de sistemas híbridos;
7. Verificar a confiabilidade dos resultados obtidos, por meio de uma análise qualitativa, e validação dos resultados com dados históricos e saídas dos programas atualmente usados;
8. Buscar meios que proporcionem a otimização das técnicas aplicadas no sistema, visando à melhora na execução e eficiência delas; tais meios podem incluir a melhor seleção das variáveis de entrada e também o ajuste dos parâmetros das redes neurais empregadas.

1.3 Motivação

O preço de liquidação das diferenças (PLD), também chamando de preço “spot”, é usado para valorar a energia comercializada no mercado de curto prazo. É, portanto, uma informação estratégica para os agentes do setor elétrico brasileiro. O cálculo é feito com base no custo marginal de operação (CMO), limitado por um piso e um teto estabelecidos anualmente pela ANEEL.

O PLD é produto do processamento dos modelos NEWAVE e DECOMP, modelos que necessitam de um volume grande de dados de entrada, muitas vezes difíceis de serem obtidos, projetados, formatados e compilados em uma plataforma computacional.

Além do PLD vigente para a semana em estudo, a saída do ciclo de processamento destes modelos apresenta uma projeção para os próximos períodos até o final daquele mês.

A cada revisão semanal feita pelo ONS, são modificados alguns parâmetros de entrada do modelo DECOMP, como as previsões de afluências e os volumes de partida dos reservatórios, isso acarreta em um PLD calculado e projeções diferentes daqueles previstos na semana anterior. O gráfico da Figura 1-2 exemplifica o assunto tratado até aqui. Pode-se analisar a evolução, tanto do PLD quanto de suas projeções ao longo do período em destaque.



Figura 1-2 - Variação do PLD em relação às projeções. Fonte: Elaboração do autor.

Neste gráfico é possível verificar o comportamento do preço de liquidação das diferenças ao longo do mês de maio de 2012, e também os valores previstos para cada semana deste mês e a primeira semana de junho.

Observa-se a disparidade entre o preço previsto na semana um, representada pela linha de cor azul, e o preço efetivamente adotado, representado pela linha de cor laranja. Nota-se também que com o avanço das semanas, as previsões continuam ruins em relação ao preço real.

A variação do PLD e discrepância das projeções é consequência direta da revisão dos parâmetros de entrada do modelo DECOMP. O gráfico da Figura 1-3 exemplifica este tipo de ajuste para um, dos vários parâmetros, usados no processamento.

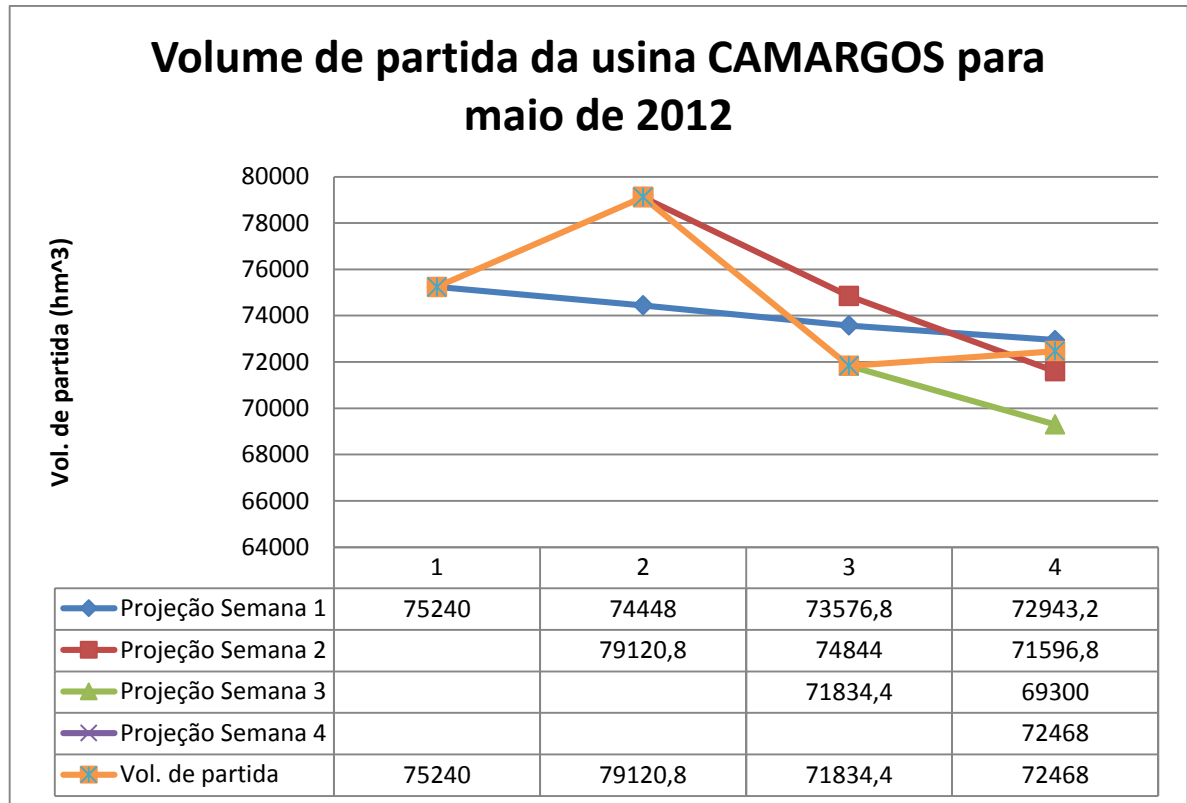


Figura 1-3 - Variação do volume de partida em relação às previsões. Fonte: Elaboração do autor.

Nota-se uma semelhança entre este gráfico do volume de partida da usina Camargos e o gráfico da Figura 1-2. Os valores considerados para o volume de partida no processamento da semana um, desenhados na cor azul, foram sendo atualizados ao longo do mês, ou seja, há também um erro de projeção nos valores que alimentam o modelo.

Com as informações apresentadas, e sabendo-se da existência de técnicas e ferramentas na área de inteligência artificial, capazes de encontrar relações não evidentes entre as variações dos parâmetros de entrada e as alterações nos resultados finais, é forte a motivação em realizar experimentos para definir quais as melhores ferramentas e configurações que se ajustam aos casos documentados e aos resultados finais corrigidos.

CAPÍTULO 2

2. O planejamento, a geração e o preço da energia elétrica no Brasil.

A energia elétrica é hoje uma das principais fontes de energia da matriz energética brasileira, segundo dados do Balanço Energético Nacional publicado pela Empresa de Pesquisas Energéticas. A energia elétrica corresponde a aproximadamente 18% do consumo total de energia dentre todos os componentes que constituem a matriz energética nacional.

A demanda por este tipo de energia aumenta mais rapidamente do que a oferta interna de energia, e deverá crescer em uma razão de cerca de 5,0% ao ano até 2019 [3]. O atendimento a este crescimento implica em grandes investimentos nos sistemas de geração, transmissão e distribuição de energia.




Figura 2-1 - Matriz Energética Brasileira ano base 2011. Fonte: B.E.N. Preliminar EPE 2012.

Além dos altos custos financeiro e social, a expansão do sistema de energia elétrica inevitavelmente causa danos ao meio ambiente, provocados tanto pelas emissões de resíduos

provenientes da geração de usinas termelétricas quanto pelas áreas que são alagadas na construção dos reservatórios de usinas hidrelétricas. O gráfico da Figura 2-2 representa a evolução da capacidade instalada de geração, e o expressivo crescimento da geração termelétrica (mais cara, não renovável e poluente) a partir de meados da década de 90.




Figura 2-2 - Capacidade instalada de geração elétrica. Fonte: BEN 2012

2.1 O parque gerador brasileiro

O Brasil é caracterizado por um sistema de geração elétrica hidrotérmico, com predominância das fontes hidroelétricas. O parque gerador brasileiro conta com um conjunto de 1.029 empreendimentos hidroelétricos, com capacidade de 83.651.970 kW e 1.597 empreendimentos térmicos com capacidade de 32.858.468 kW¹. Além disso, possui duas usinas nucleares e 82 empreendimentos eólicos com capacidades combinadas de 10.177.000 kW. O restante da energia consumida no país provém de contratos de importação (Figura 2-3)

¹ Segundo os dados disponibilizados pela ANEEL por meio do Banco de Informações da Geração - BIG em 28 de fevereiro de 2013.




Figura 2-3 - Matriz de geração de energia elétrica no Brasil. Fonte: Banco de informações da geração - ANEEL

A matriz de geração elétrica nacional se diferencia dos demais sistemas existentes no mundo (Figura 2-4). Este fato de certa forma inviabiliza a importação de modelos de planejamento e controle já existentes em outros países.




Figura 2-4 - Geração de eletricidade no mundo em 2009. Fonte: B.E.N. 2012.

As usinas hidroelétricas estão dispostas em cascata ao longo do curso dos rios, o que faz com que o consumo ou retenção da água em uma barragem afete diretamente as demais unidades geradoras à jusante da mesma. Além disto, o uso da água em uma usina em um determinado período implica em uma menor disponibilidade para o período seguinte, o que pode acarretar o uso de outras fontes que não sejam de origem hidráulica. Essas características demonstram fatores de interdependência espacial e temporal da matriz de geração de energia elétrica brasileira.

A localização das usinas hidrelétricas, normalmente afastadas dos grandes centros de consumo, exigiu o desenvolvimento de um complexo sistema de transmissão, que é também usado para a importação e exportação de energia elétrica. A configuração destas linhas de transmissão impõe restrições em relação ao fluxo de energia entre as principais regiões que compõe o Sistema Interligado Nacional (SIN).

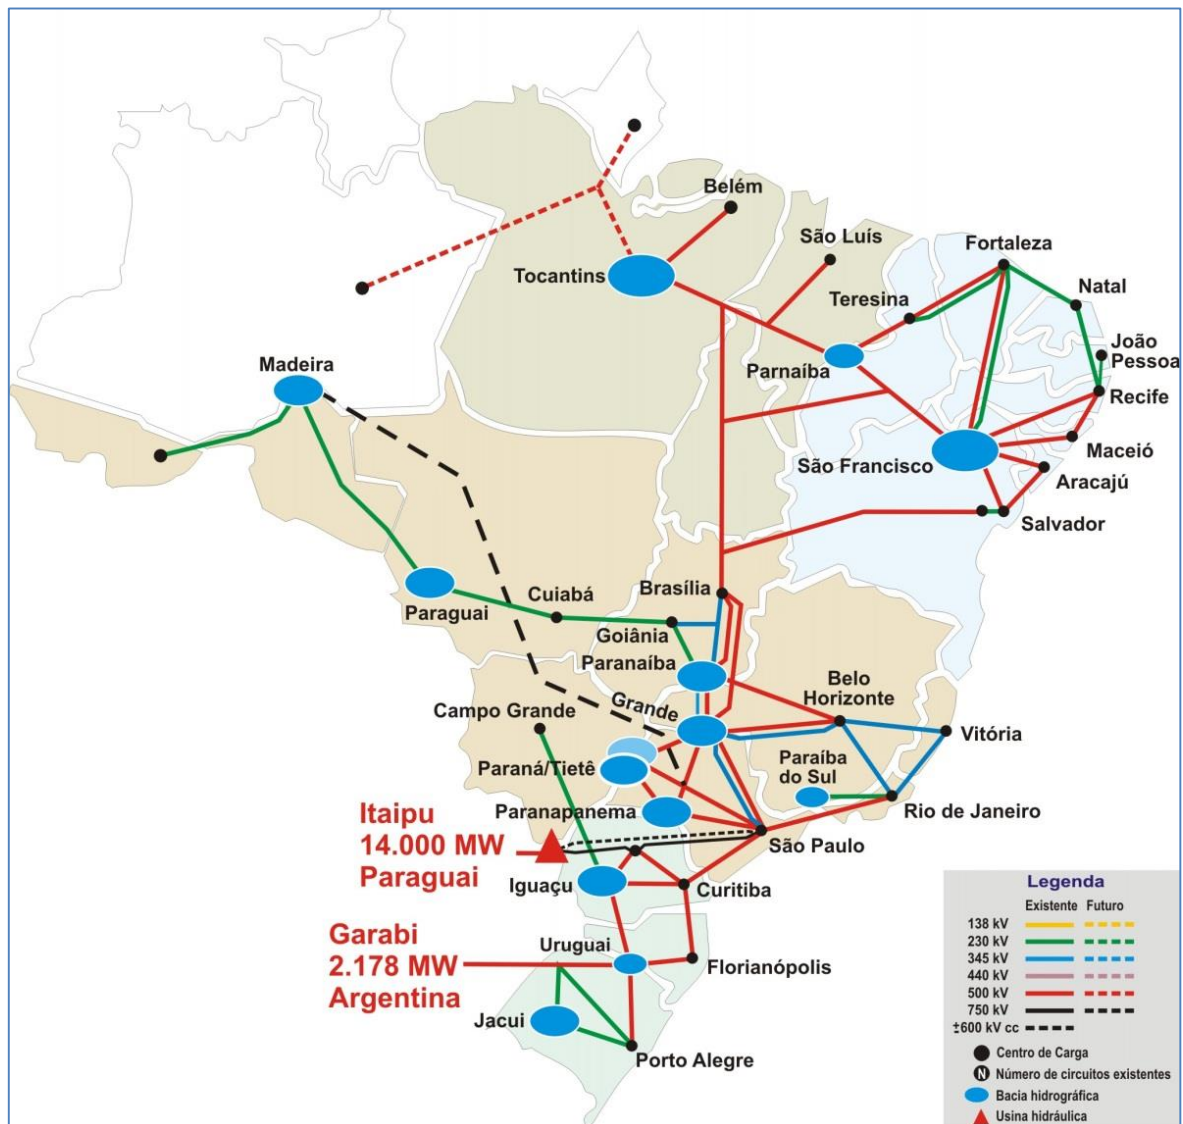


Figura 2-5 Sistema Interligado Nacional – SIN. Fonte: Site do ONS.

O SIN é formado pelas empresas das regiões Sul, Sudeste, Centro-Oeste, Nordeste e parte da região Norte. Apenas 3,4% da capacidade de produção de eletricidade do país encontram-se fora do SIN, em pequenos sistemas isolados localizados principalmente na região amazônica. [4]

A divisão em submercados se dá pela diversidade dos regimes hidrológicos (Figura 2-6) e características próprias, as quais se podem destacar:

- Sudeste/Centro-Oeste: Maior mercado consumidor no Brasil, durante a maior parte do ano importa energia de outras regiões e possui elevada capacidade de armazenamento localizada em múltiplos reservatórios.
- Sul: Armazenamentos com maior volatilidade ao longo do ano; O Intercâmbio de energia com a região Sudeste sofre variações de sentido ao longo do ano, porém a tendência é a de exportar energia.
- Nordeste: Possui uma demanda de energia que vêm aumentando ao longo dos últimos anos; Parte da energia consumida é proveniente das regiões Sudeste e Norte.
- Norte: É exportadora de energia durante a maior parte do ano, essa característica tende a aumentar devido aos novos projetos de geração.

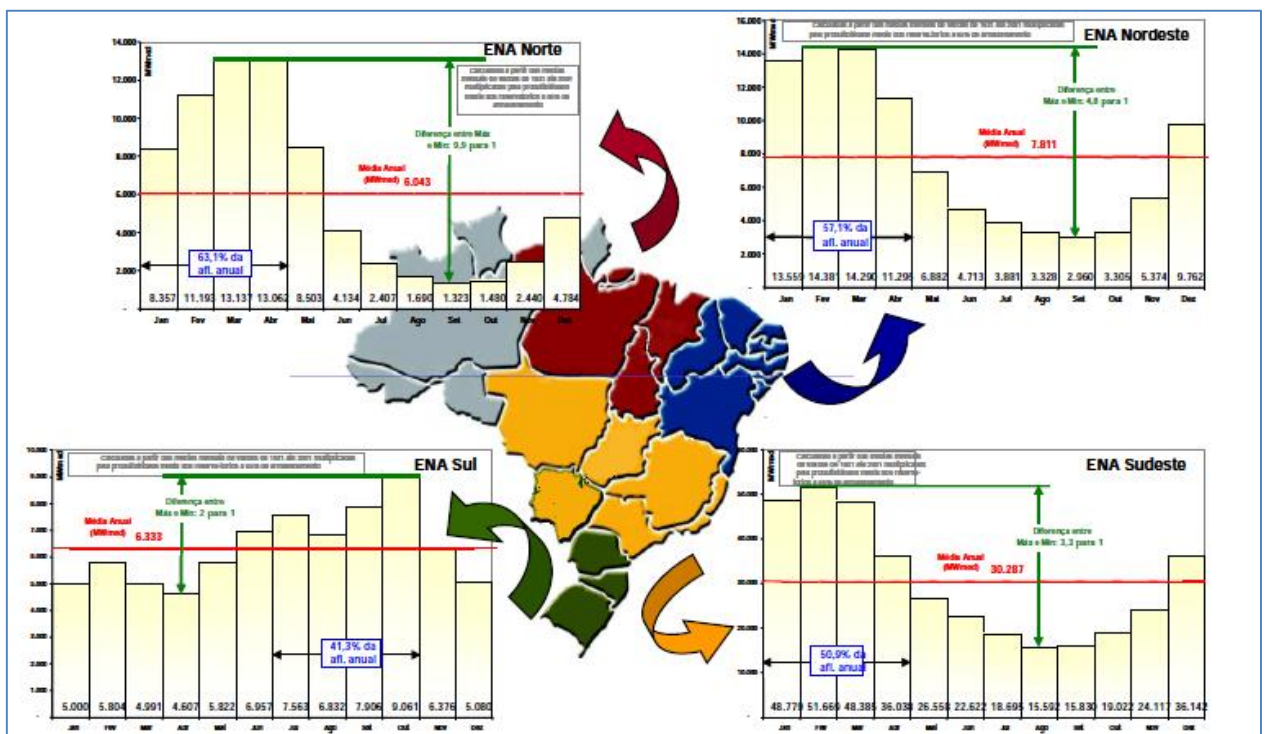


Figura 2-6 - Diversidade Hidrológica do SIN Fonte: Apostila CCEE NEWAVE E DECOMP 2009

O comportamento hidrológico de cada região é refletido diretamente na afluência dos reservatórios, que é um fator com grande importância no estudo e planejamento da operação,

ela impacta na capacidade dos reservatórios em repor a água vertida na geração de energia elétrica.

Por estar diretamente ligada à fatores naturais como o clima, temperatura, quantidade e frequência de chuvas, esta afluência passa por períodos cíclicos de umidade e seca. Este comportamento sazonal é de difícil previsão, e implica em dificuldades na operação e controle do sistema de geração de energia elétrica.

Em suma, o sistema nacional de geração elétrica pode ser definido com as seguintes características:

- É predominantemente hidrelétrico, no entanto possui um grande número de usinas térmicas que compensam o crescimento da demanda;
- A expansão do sistema para suprir a demanda é um desafio, já que representa elevados custos financeiros, sociais e ambientais;
- É distinto de outros sistemas mundiais pelo fato do elevado uso de fontes hidráulicas para geração;
- Possui um sistema de transmissão complexo e de grandes extensões geográficas, sobretudo devido às grandes distâncias entre os centros geradores e os principais centros consumidores;
- Caracterizado por vários potenciais de aproveitamento hidrelétrico ao longo dos mesmos rios com reservatórios fortemente dependentes dos ciclos de afluências;
- É dividido em quatro grandes regiões com características e regimes hidrológicos e pluviométricos diversos.

Considerando-se as características apresentadas, percebe-se a importância do estudo de metodologias de planejamento e controle da operação dos sistemas de energia elétrica que possam proporcionar o aproveitamento máximo das unidades geradoras já existentes, além de um aproveitamento ótimo dos recursos envolvidos na geração.

No Brasil, o Operador Nacional do Sistema Elétrico é o órgão responsável pela coordenação e controle das operações relacionadas à geração e transmissão de energia elétrica

no Sistema Interligado Nacional. Para o exercício destas atividades, o ONS desenvolve uma série de estudos, planos de longo, médio e curto prazo e ações que visam administrar de forma eficaz e eficiente o estoque de energia garantindo o suprimento contínuo em todo o país.

2.2 Planejamento da operação dos sistemas hidrotérmicos

Aliada às dificuldades naturais, como: ordem de grandeza dos sistemas, elevado número de variáveis de entrada, limitação de recursos e incertezas, o planejamento da operação da matriz elétrica brasileira deve contemplar também a coordenação das operações de várias empresas visando encontrar um ponto de operação onde o custo seja o menor possível. O resultado esperado é uma sequência de decisões que busque encontrar este ponto ótimo, além de atender a toda demanda de energia elétrica de forma confiável.

Este tipo de planejamento é um problema de grande porte e complexidade elevada. É necessário subdividir o problema em etapas menores, constituindo então o que é chamado de cadeia de planejamento. O principal critério para esta subdivisão é o tamanho do horizonte de planejamento que deve abranger desde um período de anos à frente quanto à programação diária e acompanhamento em tempo real da operação.

2.2.1 O Planejamento anual da operação energética

O planejamento anual da operação energética (PEN) abrange um horizonte de análise de cinco anos, de maio do primeiro ano a dezembro do quinto ano de estudo, com detalhamento em base mensal. É elaborado anualmente pelo ONS, sendo revisto em função da realização dos Leilões de Energia. Excepcionalmente, pode ainda ser revisto a qualquer tempo na ocorrência de fatos relevantes, tais como mudanças significativas na carga a ser atendida, na oferta de geração, na disponibilidade de combustíveis, no cronograma de obras de transmissão, nos limites de intercâmbio entre subsistemas, e outros. A elaboração de uma revisão segue o mesmo procedimento do estudo anual, podendo ter um escopo menos abrangente.

Os dados e informações utilizados nos estudos para o planejamento anual da operação energética também são empregados no processamento do modelo de médio prazo para atualização da função de custo futuro, no âmbito da elaboração do Programa Mensal de

Operação – PMO. Assim, visando garantir o uso de informações atualizadas, esses dados e informações são revisados periodicamente. [5]

O objetivo do PEN é definir quais são as parcelas de geração hidráulica e térmica que definem o ponto ótimo de operação, além de realizar o diagnóstico de desempenho do SIN, verificando o atendimento a todos os critérios e padrões definidos pelos Procedimentos de Rede.

Os dados utilizados para o processamento do modelo são enviados pelos agentes e fornecidos pelo próprio NOS, conforme a Tabela 1:

Tabela 1- Dados de entrada do PEN

Dado	Fonte	Atualização
Armazenamentos iniciais previstos por reservatório;	ONS	Mensal
Volumes de espera por reservatório;	ONS	Anual
Séries históricas de vazões naturais médias mensais;	ONS	Anual
Valores dos usos consuntivos da água e valores de evaporação;	ONS	Anual
Energias naturais afluentes e vazões naturais verificadas e previstas;	ONS	Mensal
Restrições operativas hidráulicas dos aproveitamentos,	ONS	Anual
Relação e regime de operação dos intercâmbios internacionais existentes	ONS	Quadrimestral
Previsão consolidada da carga global de energia e carga de demanda por patamar e por subsistema;	ONS	Quadrimestral
Atualização para os dois primeiros meses do horizonte de estudo da previsão de carga de energia e carga de demanda;	ONS	Mensal
Limites de transmissão entre as diversas áreas elétricas do SIN e cronograma de obras de transmissão que impactam esses limites;	ONS	Quadrimestral
Geração mínima por razões de confiabilidade elétrica das usinas termoeletricas;	ONS	Quadrimestral
Valores apurados de taxa equivalente de indisponibilidade forçada e taxa equivalente de indisponibilidade programada;	ONS	Anual
Curvas de aversão a risco e penalidade por violação da curva de aversão a risco;	ONS	Anual
Taxa de desconto a ser utilizada nos modelos para cálculo do valor presente dos custos;	ANEEL	Anual
Função de custo do déficit;	ANEEL	Anual
Penalidade por violação de uso múltiplo da água.	ANEEL	Anual
Informações sobre a situação dos novos empreendimentos de geração do SIN;	ANEEL	Mensal
Cronograma de enchimento do volume morto de novos reservatórios do SIN;	ANEEL	Mensal
Cronograma de expansão de unidades geradoras de usinas do SIN;	ANEEL	Mensal
Dados técnicos dos novos empreendimentos de geração do SIN;	ANEEL	Mensal

Relação das usinas termoeletricas vendedoras nos Leilões de Energia, com seus respectivos montantes de energia contratados e preços associados;	ANEEL	Na ocorrência do leilão de energia
CVU - custo variável unitário (R\$/kW) das usinas termoeletricas vendedoras nos Leilões de Energia.	CCEE	Mensal
Cronograma de conversão de combustível de UTEs	Agentes de geração	Quadrimestral
Cronograma de manutenção	Agentes de geração	Quadrimestral
Atualização do cronograma de manutenção de unidades geradoras de UTEs para os primeiros doze meses do horizonte de estudo	Agentes de geração	Mensal
Geração máxima Mensal de energia de UTEs	Agentes de geração	Quadrimestral
Suprimentos previstos de energia e de demanda para a ANDE	Comercializador de Itaipu	Quadrimestral
Atualização para os dois primeiros meses do horizonte de estudo dos suprimentos previstos de energia e de demanda para a ANDE.	Comercializador de Itaipu	Mensal
Consumo interno da UHE Itaipu associado ao setor de 50Hz	Comercializador de Itaipu	Quadrimestral
Disponibilidade de potência e de energia da UHE Itaipu para o SIN	Comercializador de Itaipu	Quadrimestral
Montantes líquidos máximos e mínimos de energia e potência disponíveis para importação ou exportação	Agentes de Importação e exportação	Quadrimestral
Custos variáveis associados aos suprimentos	Agentes de Importação e exportação	Quadrimestral

Após o processamento do modelo, o resultado do Plano Anual de Operação Energética apresenta os seguintes itens:

- Análise dos custos marginais de operação;
- Benefícios marginais de interligações;
- Riscos de não atendimento à carga de energia, com análise da profundidade e duração dos déficits associados;
- Estimativas dos montantes de intercâmbios internacionais;
- Estimativas de geração térmica, que considerem aspectos de segurança eletroenergética do SIN, de forma a subsidiar a formação de estoques mínimos operacionais e estoques estratégicos de combustíveis, tendo em vista a logística de compra, estocagem e distribuição;
- Estimativas dos custos totais de operação;
- Estimativas dos intercâmbios entre subsistemas;
- Evolução do armazenamento dos subsistemas;
- Probabilidades de violação das curvas de aversão a risco;
- Balanço de energias asseguradas;
- Balanço de ponta determinístico;

- Recomendações de adequação dos cronogramas de manutenção de unidades geradoras aos resultados do estudo, quando houver necessidade;

A partir destes resultados é então possível definir ações para solucionar os problemas identificados no horizonte de estudo, bem como avaliar o benefício das novas obras na operação do sistema, além de indicar providências para antecipações de obras e também para contornar eventuais atrasos de cronogramas.

É também possível a indicação de medidas operativas para que a operação atenda aos padrões e critérios estabelecidos nos Procedimentos de Rede, identificar as restrições elétricas que impeçam a adoção de políticas energéticas que assegurem o menor custo da operação, além de Subsidiar o Poder Concedente na tomada de decisões.

2.2.2 O Programa Mensal de Operação Energética

O Programa Mensal de Operação Energética, como o nome indica, é elaborado mensalmente pelo ONS em reunião conjunta com os agentes pertinentes e tem as suas revisões feitas em regime semanal. Os estudos fornecem parâmetros e diretrizes eletro energéticas de curto prazo que otimizam o uso dos recursos de geração e transmissão do Sistema Interligado Nacional.

Para o planejamento de curto prazo, o horizonte é de até 12 meses, o objetivo nesta etapa é definir as metas de geração de cada usina do sistema, bem como os intercâmbios de energia entre cada subsistema.

As semanas compreendidas no estudo – semanas operativas – correspondem ao período que se inicia à 0h00min do sábado e termina às 24h00min da sexta-feira subsequente e abrangem todos os dias do mês a que se refere o estudo, podendo também incluir dias dos meses adjacentes.

Para este estudo são usados dados provenientes do PEN, e é também feita a atualização semanal dos dados de entrada do sistema. [5]:

- Oferta de energia considerando novos empreendimentos de geração e cronograma de enchimento do volume morto;
- Volumes de partida individuais de cada reservatório expressos em percentuais dos volumes úteis;
- Despachos mensais de energia em MWmed das usinas hidrelétricas e térmicas;

- Cronograma de manutenção das usinas para o primeiro mês de estudo;
- Suprimentos previstos de energia para a Administración Nacional de Eletricidad – ANDE, em base Mensal;
- Previsão de vazões naturais médias semanais e mensais;
- Previsão das energias naturais afluentes;
- Volume de espera para controle de cheias;
- Volume de uso da água dos reservatórios;
- Reserva de potência operativa, quando necessário;
- Carga ativa semana e Mensal de energia;
- Duração em horas dos patamares de carga;
- Limites elétricos de transmissão entre subsistemas;
- Geração mínima, por razões de confiabilidade elétrica, das usinas;
- Curvas de aversão a risco, as mesmas utilizadas no PEN;
- CVU em R\$/MWh das usinas termoeletricas vendedoras;

Após o processamento do modelo, o PMO apresenta as seguintes informações como resultado:

- Despacho de geração individualizado, por patamar de carga e seu valor médio semanal, das usinas hidrelétricas e termoeletricas;
- Despacho de geração por patamar de carga e seu valor médio semanal da usina de Itaipu, para suprimento ao SIN, discretizada nos setores de 50Hz e 60Hz;
- Disponibilidade de geração média semanal das usinas hidroelétricas;
- Níveis de meta de armazenamento dos reservatórios, ao final de cada semana operativa;
- Energia média vertida turbinável e não turbinável, por patamar de carga e seus valores médios semanais;
- Balanço operativo de carga de demanda instantânea por subsistema, em base semanal;
- Condições de atendimento à carga de demanda do SIN;
- Cronogramas de manutenção de unidades geradoras hidroelétricas e termoeletricas;
- Custos marginais de operação, em base semanal, por subsistema e por patamar de carga;

- Balanços de energia por subsistemas, em base semanal;
- Intercâmbios de energia entre os subsistemas, por patamar de carga e média semanal; e
- Intercâmbios internacionais por patamar de carga e média semanal. [5]

É válido destacar neste ponto que um dos principais resultados apresentados pelo PMO é o Custo Marginal de Operação (CMO), que representa o custo, depois de atendido todo o consumo, necessário para atender a um MW de carga adicional em cada região do no SIN. O recurso utilizado para a geração deste MW extra é o que define o CMO, conforme pode ser visto na Figura 2-7:

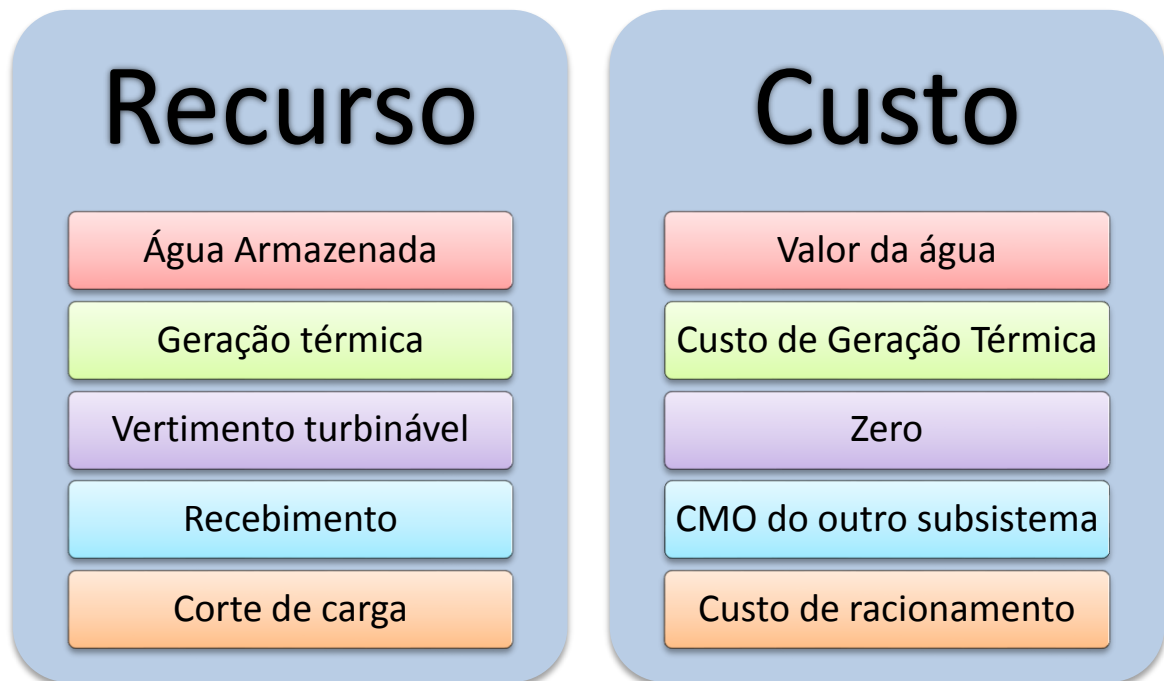


Figura 2-7 - Formação do CMO Fonte: Elaboração do autor.

Pelo fato da geração no Brasil ser predominantemente hidroelétrica, na maioria das vezes o CMO acaba sendo o próprio valor da água armazenada. A definição deste valor da água está descrita na seção mais à frente, que trata da montagem do problema de otimização.

O CMO, limitado por um teto e um piso definidos anualmente pela ANEEL irá definir o Preço de Liquidação das Diferenças, que é efetivamente o preço da energia elétrica no mercado de curto prazo.

Desta forma, o mercado brasileiro difere de outros mercados que passaram por um processo de reestruturação no que tange a formação de preços de curto prazo. Enquanto

nestes mercados o preço decorre de um equilíbrio entre oferta e demanda, no Brasil ele é função do CMO calculado no processo de otimização energética. O processo de cálculo do PLD é detalhado em seções futuras deste trabalho.

2.3 Os Modelos NEWAVE e DECOMP

As tarefas de processamento da vasta quantidade de dados de entrada apresentados anteriormente a fim de obter-se o planejamento estratégico das operações e o CMO são auxiliadas por dois programas em particular: O NEWAVE e o DECOMP.

O NEWAVE (Modelo Estratégico de Geração Hidrotérmica a Subsistemas Equivalentes) é um programa de otimização desenvolvido pelo CEPEL, que resolve os problemas de planejamento da operação interligada de sistemas hidrotérmicos empregando a técnica de programação dinâmica dual estocástica.

Esta técnica permite considerar o intercâmbio entre os subsistemas como uma variável de decisão, evita a discretização do espaço de estados, permite o uso de um modelo comum de vazões sintética e calcula os custos marginais do sistema.

O modelo é utilizado para um amplo espectro de estudos de planejamento, como [6]:

- Informações sobre o consumo de combustível;
- Estudos de políticas comerciais;
- Estudos de política tarifária;
- Estudos de política de racionamento;
- Estudos de gerenciamento da demanda e realimentação ao planejamento da expansão.

O NEWAVE representa os geradores termelétricos de maneira individualizada, e os geradores hidrelétricos de forma agregada em reservatórios equivalentes de energia. Ou seja, todos os reservatórios de um submercado são agrupados em um só reservatório com uma única usina, cuja capacidade de geração é igual à soma das capacidades de geração de todas as usinas hidrelétricas componentes daquele submercado.



Figura 2-8 - Modelo de sistema equivalente usado pelo NEWAVE Fonte: Apostila CESE - NEWAVE

Tal simplificação é conveniente já que os estudos envolvendo o NEWAVE têm como principal objetivo obter índices plurianuais de atendimento ao consumo dentre outras informações que irão subsidiar decisões quem envolvem, por exemplo, os cronogramas de obras de expansão da geração e transmissão.

Além deste modelo simplificado de reservatório equivalente, o NEWAVE representa as conexões entre os subsistemas por meio de limites de intercâmbio e um nó fictício em Imperatriz, que conecta as regiões Norte, Nordeste e Sudeste. Tal arranjo pode ser observado na Figura 2-9

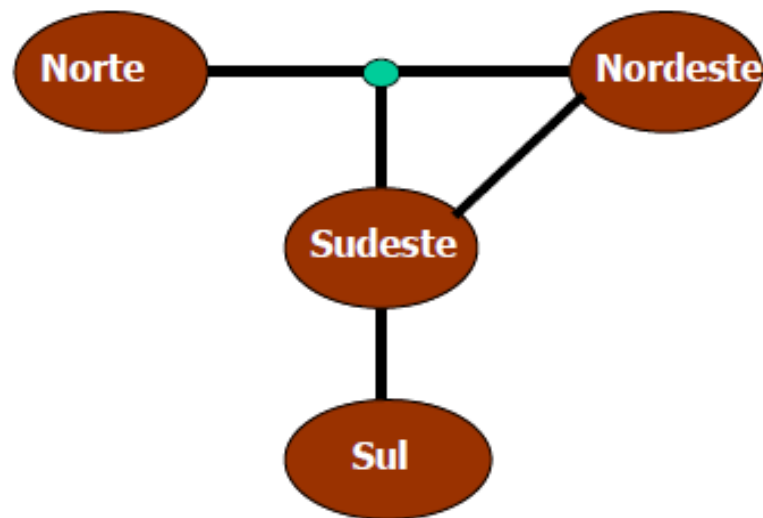


Figura 2-9 - Modelo de interligação do NEWAVE. Fonte: Apostila NEWAVE CCEE 2009

Um dos principais resultados obtido nos estudos com modelo NEWAVE é a função de custo futuro. Através desta função é feito o acoplamento com o modelo de curto prazo. Isto compatibiliza as diretrizes de operação de curto prazo com a política de operação de médio e longo prazo.

O modelo DECOMP é aplicado no planejamento da operação de sistemas hidrotérmicos a curto prazo e está adaptado ao ambiente de elaboração dos programas mensais de operação do sistema brasileiro.

A função do DECOMP é determinar de forma individual as metas de geração de cada usina, de forma a atender a demanda e minimizar o valor esperado do custo de operação ao longo do período de planejamento. O modelo está formulado como um problema de programação linear, representando as características físicas e as restrições operativas das usinas hidroelétricas de forma individualizada [6]. Ou seja, ao contrário do modelo NEWAVE, o modelo DECOMP passa a representar cada usina de forma individual, conforme a Figura 2-10:

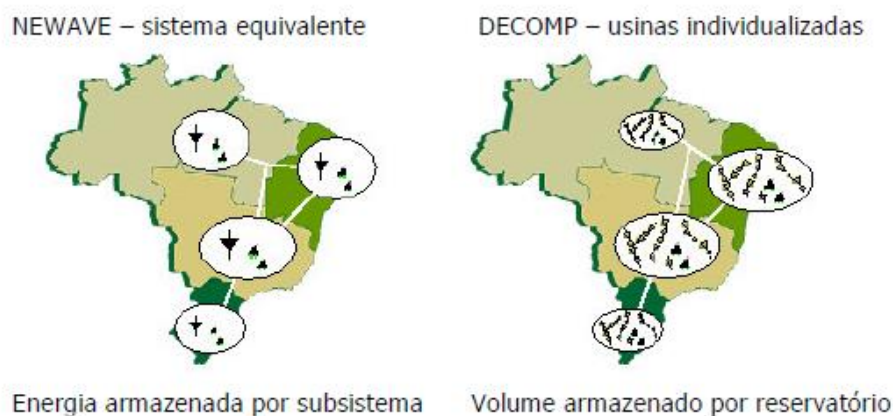


Figura 2-10 - Diferença de representação das usinas entre o modelos NEWAVE e DECOMP. Fonte: Apresentação NEWAVE e DECOMP CCEE 2009

O modelo possibilita a otimização energética para cada usina considerando um amplo conjunto de recursos, dos quais se destacam:

- Produtibilidade variável com a altura da queda;
- Representação do tempo de viagem da água;
- Evaporação, irrigação e transposição de vazões;
- Geração em pequenas bacias;
- Contratos de importação e exportação de energia;
- Representação da interligação em Ivaiporã;
- Enchimento de volume morto;
- Configuração dinâmica;
- Volumes de espera para amortecimento de cheias;
- Indisponibilidade das usinas geradoras;
- Restrições hidráulicas para otimização de algumas operações;

- Restrições elétricas: limites mínimos e máximos de geração em hidrelétricas, termelétricas e conjuntos de aproveitamentos, incluindo fluxo nas interligações;

Nos estudos realizados com o DECOMP, o primeiro mês é dividido em etapas semanais, e as afluências nestas semanas são consideradas como conhecidas, para as demais etapas do estudo, as informações de afluência necessárias são fornecidas pela função de custo futuro, calculada pelo programa NEWAVE na primeira semana operativa do mês.

2.4 Custo total e ponto ótimo de operação

Mantendo o seu objetivo de assegurar o fornecimento de energia a toda carga prevista, o ONS controla o despacho de energia de todos os agentes geradores, inclusive das usinas termelétricas, que apresentam o custo de operação diretamente relacionado ao consumo de combustível, tal custo é chamado custo de geração térmica e é proporcional ao montante de energia gerada.

Para os casos onde a demanda não é atendida, existe também um custo relacionado ao racionamento ou falta de energia, chamado custo de déficit.

O custo de déficit é uma função determinada pela ANEEL e está relacionado à profundidade do corte de carga, pois é intuitivo que cortes de carga menores trazem menos impactos e podem ser facilmente gerenciados, enquanto cortes de carga mais profundos trazem maiores prejuízos como pode ser observado no gráfico Figura 2-11.

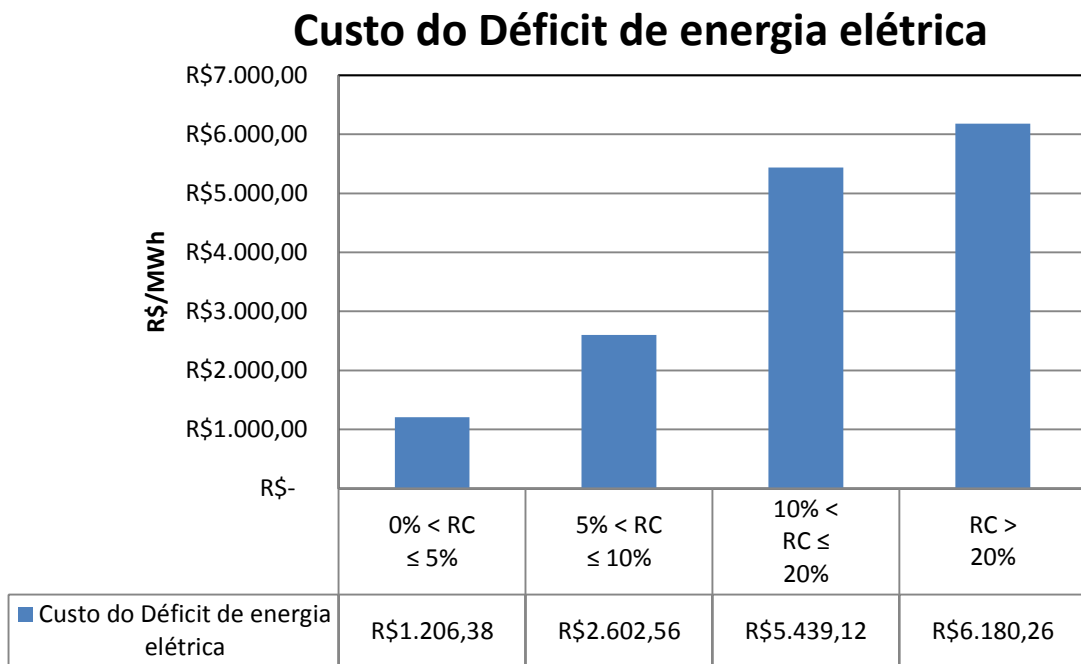


Figura 2-11 - Custo do déficit de energia elétrica Fonte: RESOLUÇÃO HOMOLOGATÓRIA No 1.247, DE 13 DE DEZEMBRO DE 2011.

Os custos de geração térmica e o custo de déficit compõe uma parcela do custo total denominada imediato. O custo imediato reflete decisões tomadas no presente e está relacionada diretamente com o preço dos combustíveis consumidos em caso de despacho das usinas térmicas. Pode-se representar a curva de custo imediato para o despacho de uma usina hidroelétrica com o gráfico da Figura 2-12:




Figura 2-12 - Representação do custo imediato. Fonte: Apostila NEWAVE CCEE 2009

Analogamente, existe uma parcela do custo total que reflete o impacto futuro das decisões tomadas. Pelo fato da água ser um recurso natural renovável e dependente unicamente das afluições, o seu custo imediato é zero. Afinal, usar a água armazenada em um reservatório para atender a toda demanda não consome nenhum combustível.

No entanto, quando o reservatório atingir o seu nível mínimo, a demanda terá que ser atendida por fontes termoeletricas durante todo o enchimento do volume da barragem. Este custo referente à decisão de usar exclusivamente água para o atendimento da carga é denominado custo futuro, e pode ser traçada conforme o gráfico da Figura 2-13.




Figura 2-13 - Custos imediatos e futuros. Fonte: Apostilas CCEE

Pela predominância da hidroeletricidade no sistema brasileiro, que causa interdependência no tempo, conforme mencionado anteriormente, o custo futuro é influenciado pelas decisões tomadas no presente.

O custo total é então definido como sendo a soma do custo imediato e do custo futuro. Traçando a curva do custo total, é notável a existência de um ponto ótimo de operação, onde o custo total é mínimo (Figura 2-14).

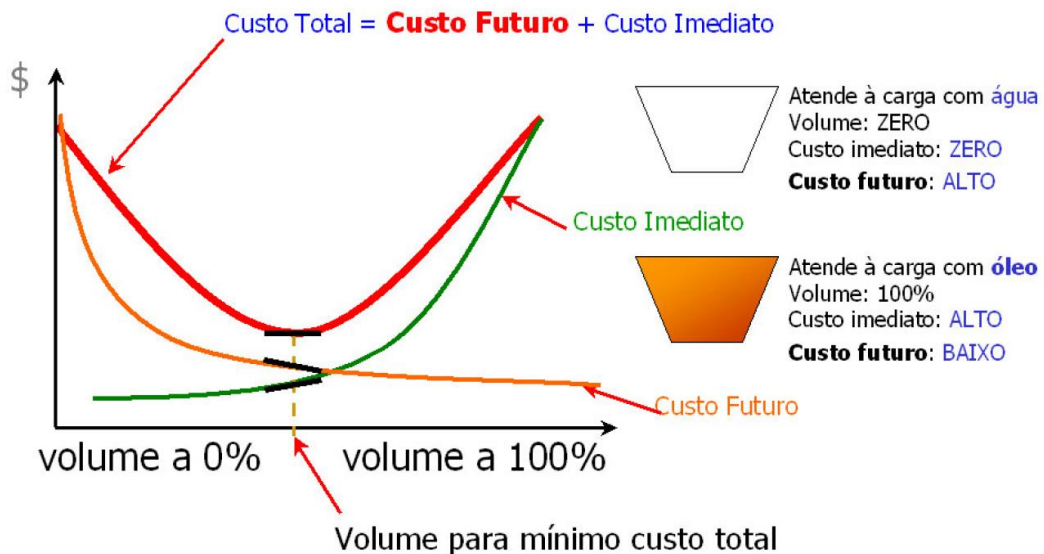


Figura 2-14 - Custo Total. Fonte: Apostilas CCEE

Portanto, toda a estratégia de operação pode-se resumir em tomar decisões no presente para que o reservatório tenha como meta chegar, ao final do mês, no volume que garanta o menor custo total.

Um fato interessante observado é que a soma das inclinações das curvas de custo imediato e custo futuro no ponto ótimo de operação se anulam. Ou seja, a soma das derivadas destas curvas é zero quando o custo total é mínimo. No entanto, o que representam estas inclinações?

A inclinação da curva de custo futuro, ou Função de Custo Futuro (FCF), varia em função do volume armazenado. A derivada desta função é conhecida como o valor da água (Figura 2-15).




Figura 2-15 - Definição do Valor da Água. Fonte: apostilas CCEE

A curva de custo imediato representa, em ordem crescente, os custos de geração térmica e déficit. A inclinação da curva para cada volume atingido ao fim do mês representa ao custo combinado de geração térmica e déficit necessário para se atingir aquele volume armazenado (Figura 2-16).




Figura 2-16 - Derivada do custo imediato. Fonte: Apostilas CCEE

Conhecendo-se a Função de custo futuro, obtida pelo processamento do NEWAVE, e os custos de geração térmica e de déficit, o despacho de energia a ser definido pelo ONS, que corresponde ao menor custo de operação, é aquele obtido ao se igualar o valor da água ao custo de geração da usina térmica mais cara que estiver sendo acionada.

A definição deste despacho ótimo deve respeitar os limites de transmissão entre os submercados, os efeitos do déficit de energia e as restrições hidráulicas e elétricas de forma a atender a carga prevista para o período.

2.5 Determinação dos custos futuro e imediato

A determinação do custo imediato para um dado período é simples: ele é o custo referente ao valor das despesas do acionamento de certas usinas, e está relacionado diretamente ao valor do combustível e à tecnologia da usina. Estes valores são informados à ANEEL e estão à disposição do ONS para os estudos de planejamento.

Determinar o custo futuro com precisão já é uma atividade bem mais complexa e susceptível a incertezas, já que este custo depende das aflúências que irão ocorrer nos rios onde se encontram as usinas hidroelétricas. Tais vazões são parâmetros não controláveis e possuem um baixo grau de exatidão em suas previsões.

Mesmo com este baixo grau de exatidão, a única saída para a previsão do comportamento destas aflúências foi elaborar de um modelo estatístico, cujo objetivo é prever uma série temporal de vazões históricas medidas desde o ano de 1931.

As séries temporais de vazões médias possuem um comportamento estatístico periódico, ou seja, características como a média, variância e estruturas de auto correlação apresentam características periódicas dependentes não apenas do intervalo de tempo entre as observações, mas também do período observado. O estudo de séries que apresentam este tipo de comportamento é feito por meio de modelos auto regressivos periódicos de ordem p (PAR(p)). A literatura sobre tais modelos é farta e dentre os autores pode-se destacar [7] e [8].

O modelo PAR (p) define que aflúências futuras dependem de aflúências passadas no mesmo local, em até p períodos anteriores, sendo que o valor do parâmetro p reflete o caráter sazonal do regime de chuvas. Em suma; o valor do parâmetro p no modelo estatístico varia ao longo do ano, para cada período mensal.

Com o modelo estatístico para a previsão das aflúências é possível definir a função de custo futuro sorteando um número elevado de hipóteses de aflúências com base no modelo PAR(p), e acompanhar a evolução dos estados do sistema dentro de um determinado período de tempo.

A definição de estado para os programas de planejamento é dada pelo nível de armazenamento dos reservatórios e também da aflúência anterior (Figura 2-17).




Figura 2-17 - Definição de estado. Fonte: apostilas CCEE

Cada conjunto de estados sorteados ao longo de vários períodos forma uma trajetória, o custo futuro é dado então pelo custo médio destas trajetórias (Figura 2-18).




Figura 2-18 - Definição de trajetória. Fonte: Apostila CCEE NEWAVE e DECOMP 2009

2.6 Otimização

Modelos de otimização são utilizados quando há a necessidade de se encontrar a melhor solução para um problema que possui um objetivo predeterminado. Tais modelos envolvem a determinação de valores para um conjunto de parâmetros de decisão que irão maximizar ou minimizar uma função objetivo, sujeita a restrições.

Para o problema apresentado, é possível usar programação dinâmica estocástica (PDE) para a obtenção de um ponto ótimo de operação. A PDE incorpora a aleatoriedade dos fenômenos naturais à programação dinâmica clássica, determinística [9]. Para tal, define-se o nível de armazenamento de água em cada barragem como sendo um estado, e uma etapa como um intervalo do período de tempo a ser estudado.

Considera-se também que a hipótese do nível de armazenamento em qualquer estado futuro depende apenas do valor atual da vazão. Ou seja, considera-se que as probabilidades

de vazões afluentes aos reservatórios sejam Markovianas, onde o estado do sistema em qualquer estágio depende somente do estado do sistema no estágio anterior e das probabilidades condicionais calculadas regressivamente [9].

A Figura 2-19 demonstra como a programação dinâmica estocástica pode ser usada para se encontrar o conjunto de decisões que garantem que a operação do sistema seja ótima, bem como o custo futuro em cada estado calculado seja ótimo.

A partir de cada estado é adotada a decisão do melhor custo. Em um procedimento no sentido inverso do tempo, chega-se ao estágio inicial, em que a decisão a ser tomada e o custo total que ela acarreta, são ótimos.

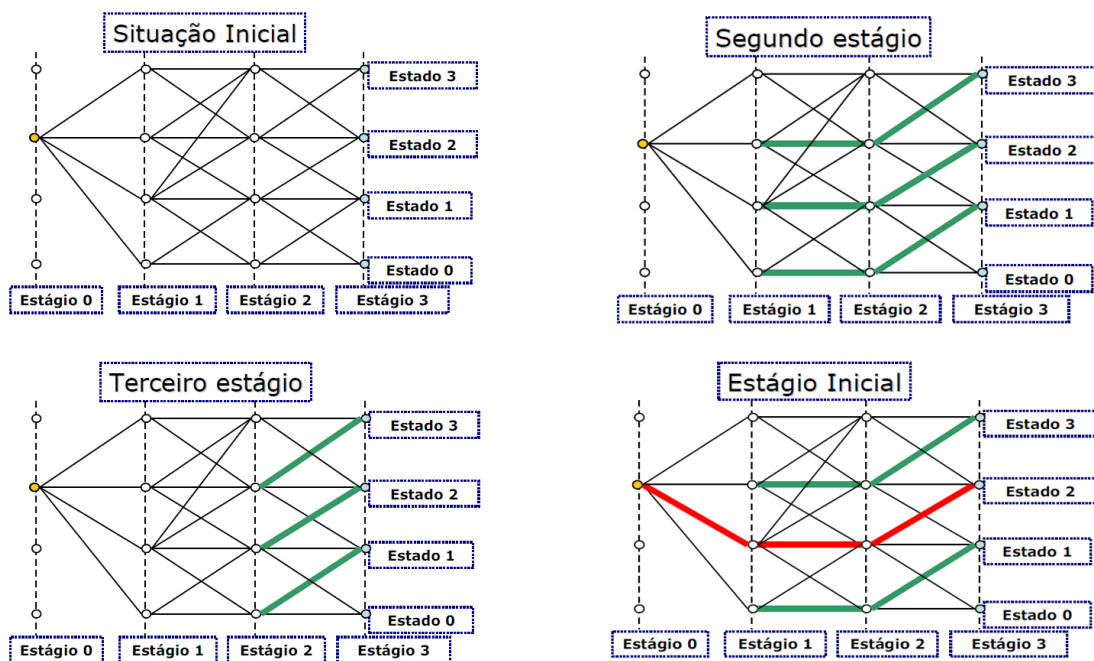


Figura 2-19 - Processamento da PDE. Fonte: CCEE

O exemplo da Figura 2-19 foi montado para apenas um único reservatório, ao longo de algumas etapas. Para o caso de mais reservatórios o número de estados cresce exponencialmente. Por exemplo, para 100 níveis de armazenamento, o cálculo para dois reservatórios teria 10^4 estados, para três reservatórios 10^6 estados e para dez reservatórios seriam 10^{20} estados.

Esta explosão do número de estados é conhecida como maldição da dimensionalidade e dificulta o uso da programação dinâmica estocástica em problemas como este, onde é preciso planejar a operação de múltiplos reservatórios interdependentes. No entanto é possível contornar este problema usando um número muito reduzido de estados, enquanto se mantém a possibilidade de se fazer um bom planejamento.

A redução do número de estados ocorre pela divisão do problema original em subproblemas, tal técnica foi introduzida pelo matemático J. F. Benders em 1962 [10], e passou a ser conhecida como Programação Dinâmica Dual Estocástica (PDDE).

Em compensação à redução do número de estados, é necessário calcular agora a taxa de variação do custo futuro nas vizinhanças do estado calculado, ou seja, calcula-se a derivada do custo futuro, neste problema também conhecida como valor da água.

Tomando-se as envoltórias superiores das retas que representam as derivadas é possível definir a função de custo futuro. Para melhor entendimento deste conceito é apresentado o exemplo a seguir.

Supondo-se conhecidos os custos futuros para os estados A e B, qual seria o custo futuro de outro estado qualquer V?



Figura 2-20 - Exemplo para a PDDE. Fonte: Apostila NEWAVE CCEE 2009

Para a utilização da PDDE, além do conhecimento dos custos futuros, é necessário também saber o valor da água. A Figura 2-21 representa esses valores em função do nível de armazenamento de um dado reservatório.




Figura 2-21 - Custos futuros e valor da água. Fonte: Apostila NEWAVE CCEE 2009

Conhecida também taxa de variação nas vizinhanças destes pontos, pode-se traçar uma curva sobre as envoltórias superiores das derivadas conforme a Figura 2-22:




Figura 2-22 - Envoltórias superiores dos custos futuros. Fonte: Apostila NEWAVE CCEE 2009

Pode-se escrever que encontrar o custo futuro em um ponto V , usando as envoltórias superiores, conforme a Figura 2-22 da seguinte forma:

$$\text{Minimizar } CF(V) \text{ tal que: } \begin{cases} CF(V) \geq CF(B) + (V - B) \frac{dB}{dV} \\ CF(V) \geq CF(A) + (V - A) \frac{dA}{dV} \end{cases} \quad \text{Equação 2.1}$$

A função de custo futuro, já citada anteriormente, pode melhor definida como um conjunto de inequações de reta capazes de fornecer o custo futuro para qualquer estado pesquisado. Por meio dela é também possível otimizar cada uma das trajetórias, em cada uma das etapas, conforme o exemplo a seguir:

Supondo que a carga em uma determinada etapa fosse atendida exclusivamente por geração hidráulica, ao final desta o nível de armazenamento se encontraria no estado A , que de acordo com a FCF apresenta um valor da água de $R\$ -15,00 R\$/\Delta$.




Figura 2-23 – valor da água no estado A . Fonte: Apostila NEWAVE CCEE 2009.

Em contraposição, há a possibilidade de acionamento de uma usina térmica com um custo de geração de $R\$ 10,00/\Delta$. Com este cenário é melhor então poupar água e gastar combustível, ou seja, a quantidade de água usada para a geração é diminuída e o nível final de armazenamento ao final da etapa sobe, passando do estado A para o estado B , onde o valor da água é agora de $R\$ -10,00/\Delta$.




Figura 2-24 - Alteração do nível final de armazenamento para a etapa. Fonte: Apostila NEWAVE CCEE 2009

Neste ponto é interessante destacar o fato de que equilíbrio entre o valor da água, que é a derivada do custo futuro, e o custo de geração das térmicas, que é a derivada do custo imediato, corresponde à premissa inicial de minimização do custo total, mostrado na Figura 2-24.

A formulação final do problema que os modelos do CEPTEL devem otimizar, além de atender a função de custo futuro visando à minimização do custo total deve contemplar também o balanço hídrico e o atendimento da carga, as restrições do uso múltiplo das águas e as restrições elétricas (Figura 2-25).



Figura 2-25 - Síntese do problema de otimização. Fonte: Elaboração do autor.

As equações a seguir representam matematicamente o problema a ser resolvido:

Função de custo futuro:

$$\begin{aligned} CF(V) &\geq CF(B) + (V - B) B' \\ CF(V) &\geq CF(A) + (V - A) A' \end{aligned} \quad \text{Equação 2.2}$$

Onde:

- A, B são estados;
- V é o estado final de armazenamento da etapa;
- A' e B' são derivadas da FCF nos pontos A e B, equivalentes ao valor da água nos respectivos pontos.

Balço Hídrico:

$$N_F = N_I + A - G_H - V \quad \text{Equação 2.3}$$

Onde:

- N_F = Nível Final
- N_I = Nível Inicial
- A = Afluência
- G_H = Geração Hidroelétrica
- V = Vertimento

Atendimento de Carga:

$$G_H + G_T + R - F + D = C \quad \text{Equação 2.4}$$

Onde:

- G_H = Geração Hidroelétrica
- G_T = Geração Termoelétrica
- R = Recebimentos
- F = Fornecimentos
- D = Déficit
- C = Carga

Restrição de uso múltiplo das águas:

Controle de Cheias:

$$Nível_{Final} \leq Nível_{MAX} \text{ para controle de cheias} \quad \text{Equação 2.5}$$

Defluência Mínima:

$$G_H + Vertimento \geq DefMin \quad \text{Equação 2.6}$$

Onde:

- G_H = Geração Hidroelétrica;
- $DefMin$ = Defluência mínima a ser respeitada;

Retiradas para uso consuntivo (irrigação, abastecimento, etc.):

$$Afluencia_{final} = Afluencia_{Bruta} - Retiradas \quad \text{Equação 2.7}$$

Restrições Elétricas:

$$Intercâmbio (x \rightarrow y) \leq Fluxo Máximo (x \rightarrow y) \quad \text{Equação 2.8}$$

Geração máxima por usina:

$$G_U \leq G_{U MAX} \quad \text{Equação 2.9}$$

Onde:

- G_U = Geração de uma usina individual
- $G_{U MAX}$ = Geração máxima da usina.

Geração máxima para um conjunto de usinas:

$$G_{Conj} \leq G_{MAX Conj} \quad \text{Equação 2.10}$$

Onde:

- G_{Conj} = Geração de um conjunto de usinas
- $G_{MAX\ Conj}$ = Geração máxima de um conjunto de usinas

Definidas as equações que modelam o problema, os modelos NEWAVE e DECOMP usam algoritmos iterativos próprios para a resolução deste tipo de problema. Não será detalhado neste trabalho o funcionamento de cada um destes algoritmos de varredura.

2.7 Processamento dos Modelos NEWAVE e DECOMP pela CCEE

Tanto o ONS quanto a CCEE usam os modelos computacionais NEWAVE e DECOMP, no entanto o objetivo de cada instituição é distinto. O ONS realiza os estudos com o objetivo de encontrar a melhor sequência de operações que irão suprir a demanda de forma segura e com o menor custo possível.

Já a CCEE visa calcular o Preço de Liquidação das Diferenças, o PLD, por patamar de carga e submercado. Por causa destes diferentes objetivos, a CCEE realiza algumas alterações nos dados de entrada recebidos do ONS. Os dados do NEWAVE são alterados mensalmente, enquanto que os do DECOMP são atualizados semanalmente.

As alterações que são feitas pela CCEE são:

- São descartados os dados de disponibilidade provenientes de unidades geradoras em fase de testes; e
- São retirados os dados de restrições operativas internas de cada submercado.

Há a necessidade do tratamento, pois as restrições internas aos submercados e eventuais gerações de usinas em testes não são considerados na formação do PLD.

As restrições internas são desconsideradas porque, para fins de comercialização, a energia deve ser tratada como uniformemente disponível em todos os pontos de consumo dentro do submercado, ou seja, são desprezadas quaisquer gerações motivadas por essas restrições.

Já quanto à questão das usinas em fase testes, considera-se que toda a energia gerada visa atender as necessidades de ajuste de equipamentos e verificação de funcionamento da própria usina. Somente depois de feita a solicitação de início de operação, que deve ser após a

conclusão da operação em testes, a energia produzida pela unidade geradora passará a ser considerada na formação do PLD.

Tratados os dados do NEWAVE, a CCEE realiza o processamento do modelo, obtendo assim a função de custo futuro necessária para o encadeamento com o modelo de curto prazo DECOMP. A execução do NEWAVE é restrita à semana que antecede a primeira semana de cada mês.

Semanalmente o ONS envia à CCEE os decks do DECOMP, e estes recebem um tratamento similar ao dado ao deck do NEWAVE: São excluídas as restrições internas aos submercados e desconsiderados os montantes de geração em teste.

Recebidos e tratados os dados do DECOMP, a CCEE executa o processamento do modelo, e obtém como um dos resultados o CMO, base do cálculo do PLD.

Os PLDs são calculados no resultado dos CMOs do primeiro estágio de cada execução do DECOMP e tem base semanal, inclusive em casos aonde a semana operativa venha avançar a fronteira do mês de apuração.

2.8 O Custo marginal de operação e a formação o preço de liquidação das diferenças.

Segundo o inciso VI do Artigo segundo do decreto 5.177/2004 é função da câmara de comercialização de energia elétrica fazer a contabilização do total de energia elétrico comercializado no Sistema Integrado Nacional e também realizar a liquidação financeira dos montantes decorrentes da compra e venda de energia elétrica no mercado de curto prazo.

Para o cálculo do valor dos deste montantes liquidados no mercado de curto prazo, a CCEE utiliza o Preço de Liquidação das diferenças.

O PLD é então definido por semana, patamar de carga e submercado, a partir do respectivo CMO, para a primeira semana do horizonte de planejamento, da seguinte forma:

$$PLD_{s,p,w} = \min(\max(CMO_{s,p,w}, PLD_{MIN}), PLD_{MAX}) \quad \text{Equação 2.11}$$

Onde:

- $PLD_{s,p,w}$ é o preço de liquidação das diferenças do submercado “s”, patamar “p” e semana “w”.
- $CMO_{s,p,w}$ é o custo marginal de operação calculado pelo DECOMP no estágio um para o submercado “s”, patamar “p” e semana “w”.

- PLD_{MIN} é o valor mínimo que o PLD pode assumir definido anualmente pela ANEEL.
- PLD_{MAX} é o máximo valor que o PLD pode alcançar definido anualmente pela ANEEL

Existe ainda a ideia de PLD horário, que atualmente é definido como sendo igual ao PLD do patamar a qual a hora pertence. Ou Seja:

$$PLD_{H,s,j} = PLD_{s,p,w}, \forall j \in p, w \quad \text{Equação 2.12}$$

Onde:

- $PLD_{H,s,j}$ é o Preço de Liquidação das Diferenças Horário para o submercado “s” e hora “j”
- $PLD_{s,p,w}$ é o preço de liquidação das diferenças do submercado “s”, patamar “p” e semana “w”.

O PLD mínimo é calculado com base na estimativa do custo variável de operação da usina hidrelétrica de Itaipu Binacional, considerando o rateio da energia cedida do Paraguai ao Brasil, valorado pela média geométrica diária das Cotações de Fechamento PTAX do dólar americano, publicadas pelo Banco Central, no período de 1º de dezembro do ano anterior até 30 de novembro do ano do cálculo.

Já o PLD máximo corresponde ao menor valor entre o PLD máximo do ano anterior corrigido pela variação do Índice Geral de Preços - Disponibilidade Interna (IGP-DI) e o preço estrutural da usina termelétrica mais cara, com capacidade instalada maior que 65 MW, incluída no Programa Mensal de Operação Eletroenergética do Operador Nacional do Sistema para o mês de dezembro do ano corrente, já que o valor de janeiro só estará disponível na última semana de dezembro [11].

CAPÍTULO 3

3. Uma proposta complementar aos modelos NEWAVE e DECOMP para melhores projeções usando técnicas de Inteligência Artificial.

No capítulo anterior, foi explicado como funcionam as etapas do planejamento da operação no setor elétrico brasileiro, e também demonstrado como funcionam os modelos e ferramentas aplicadas neste planejamento.

Nesta seção é apresentada uma proposta para minimização dos erros da projeção de curto prazo, dos modelos NEWAVE e DECOMP, por meio da aplicação de redes neurais artificiais. Em conjunto com esta proposta é também descrito, o experimento realizado para validação da técnica proposta. Os resultados deste experimento são apresentados no capítulo 4.

Como ferramenta de modelagem, utilizou-se o programa MATLAB na versão R2012a devido à facilidade proporcionada nas atividades de programação e desenvolvimento dos modelos de redes neurais artificiais necessários. A extração das informações a partir dos decks de preço fornecidos pela CCEE utilizou um software escrito pelo autor. A análise e manipulação do grande volume de dados foram feitas em um banco de dados construído no Microsoft SQL Server 2008 R2.

3.1 O erro de Projeção do CMO nos modelos NEWAVE e DECOMP

No capítulo anterior foi citado que uma das saídas do processamento dos modelos NEWAVE e DECOMP é o custo marginal de operação. Tal informação é apresentada em um dos relatórios de saída resultante da execução dos dois modelos. O formato do relatório de saída, bem como as projeções para as semanas seguintes do estudo, pode ser vistos na Figura 3-1.

```

148 PMO MAIO/2011- JUNHO/2011 - REV 0 - FCF COM CAR - VALOR ESPERADO
149
150 CUSTO MARGINAL DE OPERACAO ($/MWh)
151 X-----X-----X-----X-----X-----X
152 Ssis Sem_01 Sem_02 Sem_03 Sem_04 Sem_05
153 X-----X-----X-----X-----X-----X
154 Pat_1 15.94 15.69 15.56 15.58 15.65
155 Pat_2 15.62 15.51 15.46 15.49 15.56
156 Pat_3 15.31 15.10 15.09 14.95 15.29
157 Med_SE 15.54 15.38 15.33 15.30 15.47
158 Pat_1 15.94 15.69 15.56 15.49 15.65
159 Pat_2 15.62 15.51 15.46 15.49 15.56
160 Pat_3 15.31 15.10 15.08 14.95 15.29
161 Med_S 15.54 15.38 15.33 15.29 15.47
162 Pat_1 15.94 15.69 15.56 15.58 15.65
163 Pat_2 15.62 15.51 15.46 15.49 15.56
164 Pat_3 15.38 15.10 15.09 14.95 15.29
165 Med_NE 15.57 15.38 15.33 15.30 15.47
166 Pat_1 15.94 15.69 15.56 15.58 15.65
167 Pat_2 15.62 15.51 15.46 15.49 15.56
168 Pat_3 15.31 15.10 15.08 14.95 15.29
169 Med_N 15.54 15.38 15.33 15.30 15.47
170 Pat_1 15.94 15.69 15.56 15.58 15.65
171 Pat_2 15.62 15.51 15.46 15.49 15.56
172 Pat_3 15.31 15.10 15.08 14.95 15.29
173 Med_FC 15.54 15.38 15.33 15.30 15.47
174 X-----X-----X-----X-----X-----X
175 Patamares de carga: 1 - Pesada, 2 - Media, 3 - Leve

```

Figura 3-1 - Formato da saída do CMO no processamento do DECOMP. Fonte: deck de preços CCEE.

O preço definido na coluna *Sem_01* é o preço que efetivamente é adotado para a semana seguinte ao processamento para o cálculo do PLD, as demais colunas são projeções realizadas pelos modelos para as demais semanas do mês.

No entanto, estas previsões dificilmente coincidem com os valores reais calculados para as semanas seguintes. Isto ocorre, sobretudo por conta das revisões semanais dos parâmetros de entrada dos programas de otimização, dentre os quais se podem destacar:

- Previsão de carga.
- Volume de partida dos reservatórios.
- Previsão de afluências.
- Limites de fluxo e intercâmbio.
- Energia Natural Afluyente.

No gráfico da Figura 3-2 este erro de projeção pode ser observado, note que o comportamento do CMO é bem diferente daquele estimado pelas quatro projeções semanais.




Figura 3-2 - Exemplo de erro de projeção do CMO. Fonte: Elaboração do autor.

Por meio da análise de todas as variações dos dados revisados semanalmente, e fazendo a correlação com os erros de projeção do modelo, seria possível aplicar uma técnica de inteligência artificial que possibilitasse a redução destes erros de projeção?

A fim de obter a resposta para esta pergunta, foi realizado o experimento que está sintetizado no fluxograma da

Figura 3-3, e descrito ao longo deste capítulo. Os resultados são apresentados no Capítulo 4.

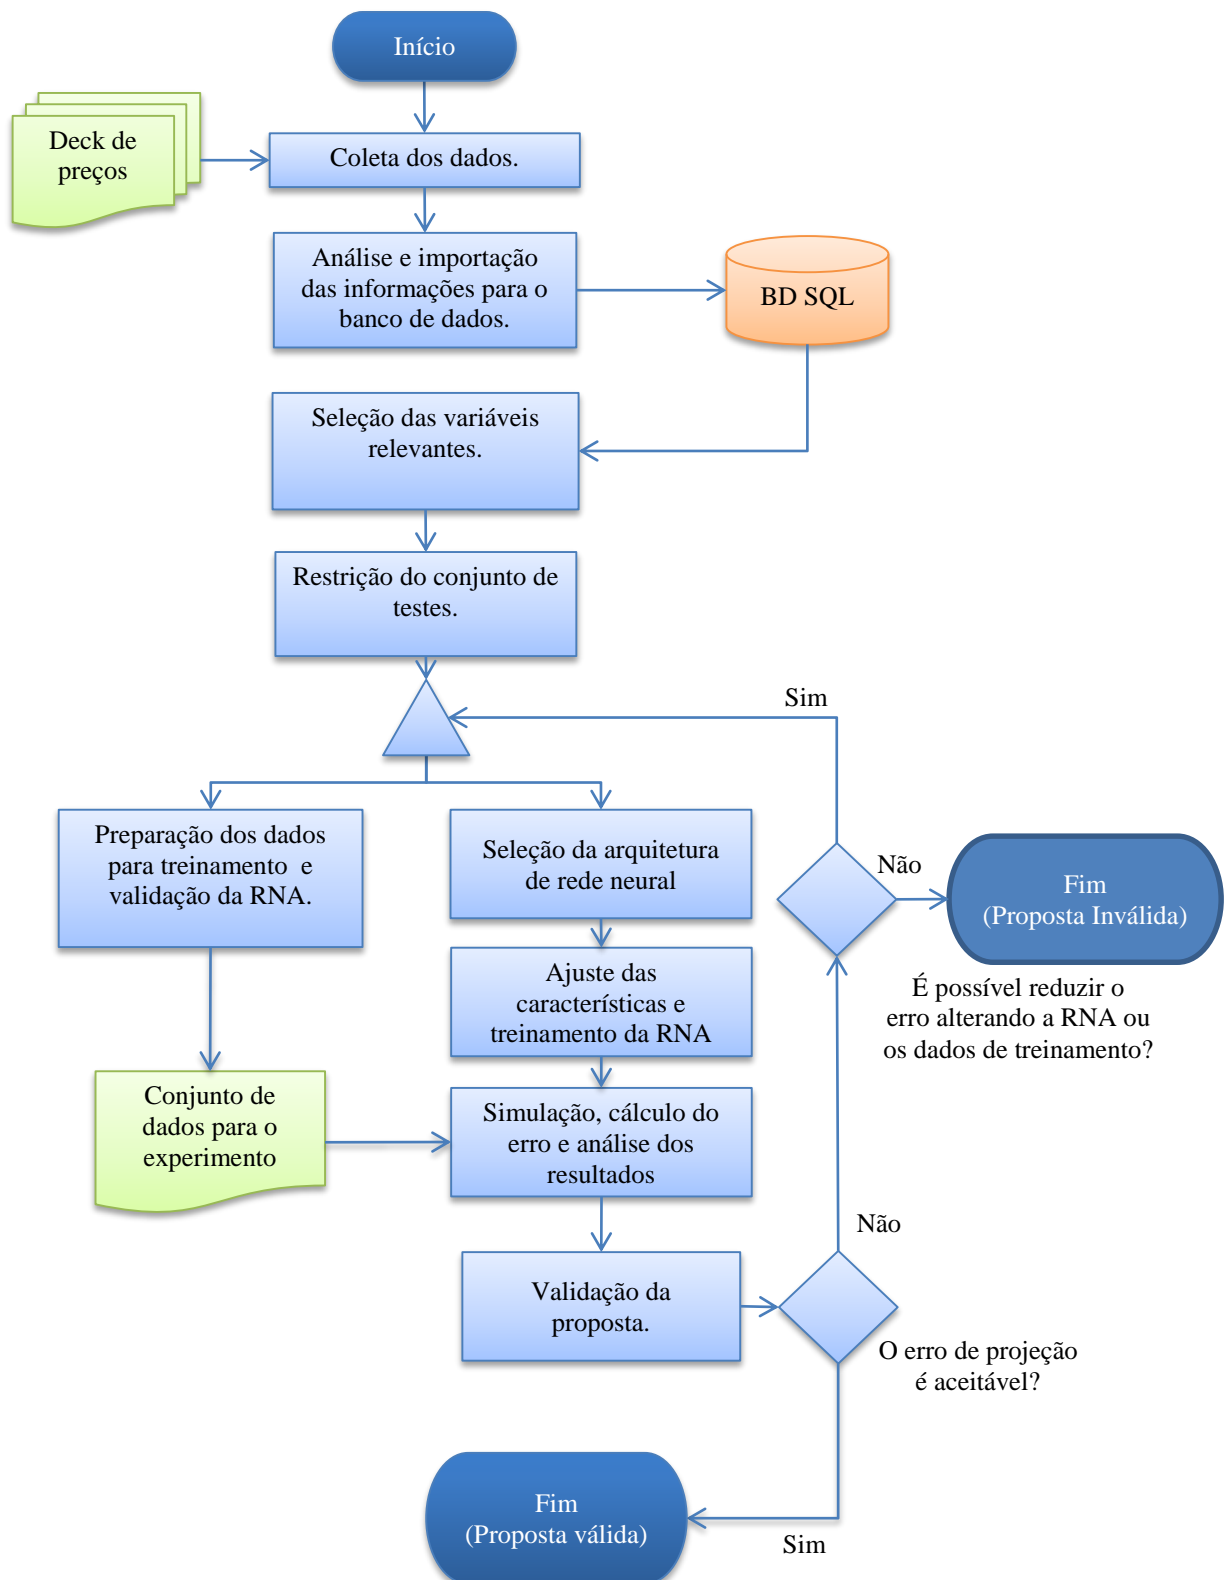


Figura 3-3 - Fluxograma do experimento. Fonte: Elaboração do autor.

3.2 Coleta, análise e pré-processamento dos dados.

Para a realização dos estudos necessários foi necessário coletar todos os dados de entrada utilizados pelos modelos NEWAVE e DECOMP dos, pelo menos, últimos cinco anos. Os dados são disponibilizados pela CCEE por meio de arquivos de texto compactados denominados “*decks* de preços”.

Tais *decks* contêm todas as informações de entrada dos modelos em arquivos tanto no formato texto, que pode ser abertos em qualquer editor de texto, quanto em formatos binários, que não podem ser lidos desta maneira. Além dos dados de entrada, a CCEE disponibiliza também os resultados da execução dos modelos por meio de extensos relatórios no formato texto (TXT).

A composição dos arquivos disponibilizados em cada deck semanal pode ser vista na Tabela 2:

Tabela 2 - Arquivos disponibilizados no deck de preços pela CCEE.

Arquivo	Descrição	Modelo
HIDR.DAT	Dados de cadastro das usinas	NEWAVE/DECOMP
VAZOES.DAT	Dados de vazões naturais históricas	NEWAVE
POSTOS.DAT	Cadastro com os nomes e anos inicial e final dos registros dos postos fluviométricos	NEWAVE
CASO.DAT	Descrição do estudo	NEWAVE
ARQUIVOS.DAT	Nomes dos arquivos utilizados pelo programa	NEWAVE
DGER.DAT	Dados gerais	NEWAVE
SHIST.DAT	Séries Históricas de afluência	NEWAVE
SISTEMA.DAT	Dados dos subsistemas	NEWAVE
PATAMAR.DAT	Dados de patamares de mercado	NEWAVE
EAFPAST.DAT	Energias Afluentes dos meses anteriores	NEWAVE
CONFHD.DAT	Dados de configuração hidroelétrica	NEWAVE
EXPH.DAT	Dados de expansão hidroelétrica	NEWAVE
MODIF.DAT	Dados de alteração de características hidroelétricas	NEWAVE
CONFT.DAT	Dados da configuração termoeétrica	NEWAVE
TERM.DAT	Dados das usinas termoeétricas	NEWAVE
CLAST.DAT	Dados das classes térmicas	NEWAVE
EXPT.DAT	Dados de expansão termoeétrica	NEWAVE
MANUTT.DAT	Dados de manutenções programadas das termoeétricas	NEWAVE
CURVA.DAT	Dados das curvas de aversão a risco	NEWAVE
PENALID.DAT	Arquivo com penalidades	NEWAVE
DSVAGUA.DAT	Arquivo com os desvios de água	NEWAVE
MLT.DAT	Valores mensais da vazão média de longo termo histórico.	DECOMP
VAZOES.XXX	Conjunto de cenários de afluências para o período estudado.	DECOMP
CASO.DAT	Nome do arquivo lista	DECOMP
DADGER.XXX	Dados gerais do estudo	DECOMP
LOSS.DAT	Arquivo com fatores de perda	DECOMP

RELATO	Relatórios de dados e relatórios de operação para todos os estágios semanais	DECOMP
RELATO2	Relatórios de dados e relatórios de operação para todos os estágios mensais	DECOMP
SUMARIO	Tabelas com resumo da operação nas semanas do mês inicial do estudo	DECOMP

Não estão detalhados neste trabalho os conteúdos de cada arquivo do deck de preços, entretanto tal informação pode ser encontrada nos documentos elaborados pela CCEE [12] e [2].

O próximo passo para a realização do experimento foi definir quais, e como as informações seriam importadas. Todos os arquivos disponibilizados pela CCEE totalizavam cerca de oito gigabytes de dados em cerca de seis mil e quinhentos arquivos, sendo que boa parte destes estavam em formato binário, o que impossibilitava o acesso para alguém que não possuísse o programa interpretador do arquivo.

Felizmente, o arquivo RELATO e RELATO2 apresentam algumas destas informações binárias já decodificadas, em formato de tabelas de resultados, graças a este fato foi possível escrever um programa capaz de automaticamente ler e interpretar todas as informações dos diversos arquivos e gravar os resultados em um banco de dados relacional. A Figura 3-4 exibe uma captura de tela da execução do programa desenvolvido.

```

var mes = Int32.Parse(Regex.Match(file, @"DC\d{6}", RegexOptions.IgnoreCase).Value.Substring(6));
var semana = Int32.Parse(Regex.Match(file, @"sem\s*-\?s*\d", RegexOptions.IgnoreCase).Value.Replace("-", "").Substring(3));
var estagio = 0;

if (ano < 2007) continue;
// log.DebugFormat("{0}/{1}/S{2}",
Console.WriteLine(String.Format(
var fileReader = new StreamReader

String line = String.Empty;
Int32 lineNumber = 0;
bool hasReachedRelatorioDaOperacao;
bool hasReadEstagio = false;
bool shouldRecord = false;

IEnumerable<String> text = fileRe
var textf = text.Skip(0);
var E = textf.GetEnumerator();

while (E.MoveNext())
{
    line = E.Current;
    Console.Title = String.Format
    if (Regex.Match(line, @"^s*FI
    {
        hasReachedRelatorioDaOper
        log.Debug(" OPERACAO O

    }
}

if (hasReachedRelatorioDaOper
{
    if ((shouldRecord == fal
        shouldRecord = true;
2007/1/51
  
```

Reading line 3494: 2 0.00 220.00 82.72 0.00 220.00 82.72 0.00 220.00 82.72

C:\DEV\Working\DecompParser\Parser\Parser\bin\Debug\Inputs\DC200605\Relato e sumário	- sem3\RELATO.RV2
C:\DEV\Working\DecompParser\Parser\Parser\bin\Debug\Inputs\DC200605\Relato e sumário	- sem4\RELATO.RV3
C:\DEV\Working\DecompParser\Parser\Parser\bin\Debug\Inputs\DC200606\Relato e sumário	- sem1\RELATO.RV0
C:\DEV\Working\DecompParser\Parser\Parser\bin\Debug\Inputs\DC200606\Relato e sumário	- sem2\RELATO.RV1
C:\DEV\Working\DecompParser\Parser\Parser\bin\Debug\Inputs\DC200606\Relato e sumário	- sem3\RELATO.RV2
C:\DEV\Working\DecompParser\Parser\Parser\bin\Debug\Inputs\DC200606\Relato e sumário	- sem4\RELATO.RV3
C:\DEV\Working\DecompParser\Parser\Parser\bin\Debug\Inputs\DC200606\Relato e sumário	- sem5\RELATO.RV4
C:\DEV\Working\DecompParser\Parser\Parser\bin\Debug\Inputs\DC200607\Relato e sumário	- sem1\RELATO.RV0
C:\DEV\Working\DecompParser\Parser\Parser\bin\Debug\Inputs\DC200607\Relato e sumário	- sem2\RELATO.RV1
C:\DEV\Working\DecompParser\Parser\Parser\bin\Debug\Inputs\DC200607\Relato e sumário	- sem3\RELATO.RV2
C:\DEV\Working\DecompParser\Parser\Parser\bin\Debug\Inputs\DC200607\Relato e sumário	- sem4\RELATO.RV3
C:\DEV\Working\DecompParser\Parser\Parser\bin\Debug\Inputs\DC200608\Relato e sumário	- sem1\RELATO.RV0
C:\DEV\Working\DecompParser\Parser\Parser\bin\Debug\Inputs\DC200608\Relato e sumário	- sem2\RELATO.RV1
C:\DEV\Working\DecompParser\Parser\Parser\bin\Debug\Inputs\DC200608\Relato e sumário	- sem3\RELATO.RV2
C:\DEV\Working\DecompParser\Parser\Parser\bin\Debug\Inputs\DC200608\Relato e sumário	- sem4\RELATO.RV3
C:\DEV\Working\DecompParser\Parser\Parser\bin\Debug\Inputs\DC200609\Relato e sumário	- sem1\RELATO.RV0
C:\DEV\Working\DecompParser\Parser\Parser\bin\Debug\Inputs\DC200609\Relato e sumário	- sem2\RELATO.RV1
C:\DEV\Working\DecompParser\Parser\Parser\bin\Debug\Inputs\DC200609\Relato e sumário	- sem3\RELATO.RV2
C:\DEV\Working\DecompParser\Parser\Parser\bin\Debug\Inputs\DC200609\Relato e sumário	- sem4\RELATO.RV3
C:\DEV\Working\DecompParser\Parser\Parser\bin\Debug\Inputs\DC200609\Relato e sumário	- sem5\RELATO.RV4
C:\DEV\Working\DecompParser\Parser\Parser\bin\Debug\Inputs\DC200610\Relato e sumário	- sem1\RELATO.RV0
C:\DEV\Working\DecompParser\Parser\Parser\bin\Debug\Inputs\DC200610\Relato e sumário	- sem2\RELATO.RV1
C:\DEV\Working\DecompParser\Parser\Parser\bin\Debug\Inputs\DC200610\Relato e sumário	- sem3\RELATO.RV2
C:\DEV\Working\DecompParser\Parser\Parser\bin\Debug\Inputs\DC200610\Relato e sumário	- sem4\RELATO.RV3
C:\DEV\Working\DecompParser\Parser\Parser\bin\Debug\Inputs\DC200611\Relato e sumário	- sem1\RELATO.RV0
C:\DEV\Working\DecompParser\Parser\Parser\bin\Debug\Inputs\DC200611\Relato e sumário	- sem2\RELATO.RV1
C:\DEV\Working\DecompParser\Parser\Parser\bin\Debug\Inputs\DC200611\Relato e sumário	- sem3\RELATO.RV2
C:\DEV\Working\DecompParser\Parser\Parser\bin\Debug\Inputs\DC200611\Relato e sumário	- sem4\RELATO.RV3
C:\DEV\Working\DecompParser\Parser\Parser\bin\Debug\Inputs\DC200611\Relato e sumário	- sem5\RELATO.RV4
C:\DEV\Working\DecompParser\Parser\Parser\bin\Debug\Inputs\DC200612\Relato e sumário	- sem1\RELATO.RV0
C:\DEV\Working\DecompParser\Parser\Parser\bin\Debug\Inputs\DC200612\Relato e sumário	- sem2\RELATO.RV1
C:\DEV\Working\DecompParser\Parser\Parser\bin\Debug\Inputs\DC200612\Relato e sumário	- sem3\RELATO.RV2
C:\DEV\Working\DecompParser\Parser\Parser\bin\Debug\Inputs\DC200612\Relato e sumário	- sem4\RELATO.RV3
C:\DEV\Working\DecompParser\Parser\Parser\bin\Debug\Inputs\DC200701\Relato e Sumário	- sem1\RELATO.RV0

Figura 3-4 - Captura de tela do programa de extração dos dados. Fonte: Elaboração do autor.

A importação das informações para um banco de dados relacional tornou muito mais eficiente o processo de manipulação deste grande volume de informações. Por meio de

consultas escritas em SQL (Structured Query Language), uma linguagem de programação destinada à bancos de dados relacionais, foi possível escrever algoritmos capazes de agrupar informações e calcular alguns indicadores estatísticos simples como média e desvio padrão de cada variável ao longo do tempo, bem como número de alterações dentro de um mesmo período de tempo.

O objetivo desta análise foi determinar quais eram as variáveis de entrada que sofriam revisões semanais mais relevantes ao longo de um mesmo mês. A Figura 3-5 sintetiza de forma visual os resultados, que de certa forma já eram esperados, devido aos processos descritos no capítulo 2.

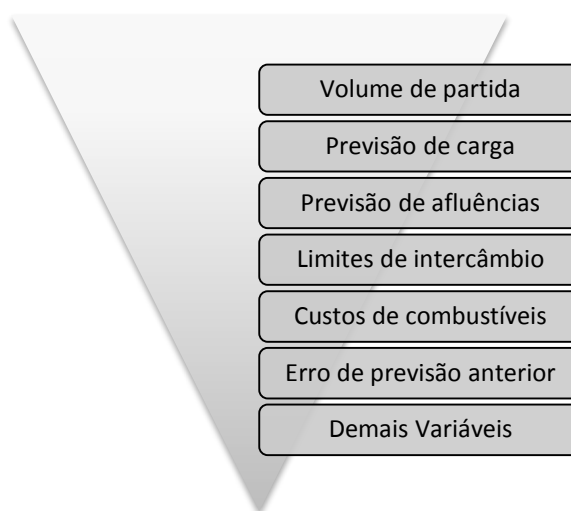


Figura 3-5 – Síntese da relevância dos dados de entrada do modelo. Fonte: Elaboração do autor.

Mesmo com a redução do número de variáveis proporcionado pela análise dos dados, ainda havia um alto volume de informações heterogêneas, que tornava difícil a elaboração e o treinamento de um modelo neural inicial para o experimento.

Visando contornar esta situação, um subconjunto dos dados foi selecionado para a criação dos dados do experimento. Foram separadas as informações referentes à região Sudeste/Centro-oeste, apenas para o patamar de carga média, em um período de cinco anos: de 2007 a 2012.

Por fim, as informações deste subconjunto de dados de teste foram pré-processadas de forma a introduzir no modelo matemático algumas características julgadas relevantes pelo autor, dentre estes ajustes é válido destacar que:

- O volume de partida dos reservatórios, dado em percentual do volume de útil, foi convertido para hectômetros cúbicos de água. Assim é levada em conta a diferença do tamanho de cada reservatório.

- Foi adicionada uma coluna aos dados de entrada que representa o erro do preço do PLD em relação ao preço da previsão da primeira semana.
- Foi também adicionada uma coluna, de forma análoga a anterior, porém representando a diferença entre o PLD e a previsão da semana anterior.
- Foram removidos os períodos onde o valor do CMO calculado pelo modelo ficou em zero.
- Foram removidos reservatórios que permaneceram vazios durante todo o período de estudo.
- Foram removidas variáveis que não sofreram variação ao longo do período estudado.

O resultado dos processos citados foi compilado em um arquivo de texto com valores separados por vírgulas (CSV), e então importados no MATLAB para o início da construção do modelo de RNA, e posterior verificação da validade da proposta.

3.3 Redes neurais artificiais.

Esta seção tem a finalidade de destacar tópicos importantes na área de redes neurais artificiais e a aplicação deste tipo de técnica para a solução do problema proposto neste trabalho. Não serão discutidas aqui questões filosóficas pertinentes, nem detalhado o funcionamento do cérebro humano. É apresentado a seguir é uma visão geral do assunto, com foco nos tipos de arquitetura testados para a validação da proposta apresentada.

Redes neurais artificiais são modelos matemáticos inspirados pelo estudo do funcionamento das redes neurais biológicas. A Figura 3-6 ilustra a estrutura de um neurônio biológico e também o processo de sinapse ocorrendo entre duas células cerebrais (de cores vermelha e salmão).




Figura 3-6 - Estrutura de um neurônio biológico. Fonte: Domínio Público

Inspirados pela observação da fisiologia básica e do funcionamento do cérebro humano, em 1943, os primeiros pesquisadores da área, Warren McCulloch e Walter Pits, propuseram um modelo de um neurônio artificial em que cada neurônio era caracterizado como “ligado” ou “desligado”. Para estar “ligado”, este neurônio deveria receber um número suficiente de estímulos de neurônios vizinhos. A Figura 3-7 ilustra o modelo básico deste neurônio artificial.




Figura 3-7 - Modelo matemático de um neurônio. Fonte: <http://commons.wikimedia.org/wiki/File:ArtificialNeuronModel.png>

De maneira simplificada, o neurônio artificial “dispara” quando uma combinação linear (dada pela função de transferência Σ) das entradas X_n , ponderadas pelos respectivos pesos W_n , excedem um limiar imposto pela função de ativação φ .

A função de ativação φ pode impor um valor limite fixo para ativação, caso o qual o neurônio artificial é chamado de perceptron, ou por uma função logística de ativação

normalizável e derivável, caso às vezes denominado perceptron sigmoide. A escolha de qualquer uma destas funções da ativação não linear, em conjunto com uma arquitetura multicamadas, assegura uma propriedade importante das redes neurais artificiais: A capacidade de representar e aproximar qualquer função não linear.

A partir deste modelo, McCulloch e Pitts sugeriram que qualquer função computável, assim como todos os conectivos lógicos (E, OU, NÃO, etc...), poderiam ser computados por uma rede de neurônios multicamadas. No mesmo artigo de 1943, eles também indicaram que este tipo de modelo poderia aprender. [13].

3.4 Treinamento

Uma rede neural é apenas um conjunto de neurônios artificiais interconectados. O que realmente determina a qualidade das respostas que ela é capaz de fornecer é a forma como é realizado, e a qualidade do treinamento aplicado.

O processo de treinamento de uma rede neural pode ser encarado como um problema de minimização do erro global de uma função multivariada que é dependente do valor dos pesos das entradas de cada neurônio.

Durante o treinamento, é necessário utilizar algum método numérico de otimização para o ajuste dos pesos, e medir o desempenho das redes através de uma função de desempenho.

Para o treinamento foram testadas as seguintes funções de treinamento:

- Levenberg-Marquardt backpropagation (LM).
- Regulagem Bayesiana (BR).
- Gradiente Conjugado Escalado backpropagation (SCG).
- Backpropagation Resiliente (RP).

A função escolhida para o ajuste dos pesos, por apresentar melhor performance, foi o gradiente conjugado escalado (SCG), proposto por Møller em 1991 [14]. Assim como outros algoritmos de treinamento de redes neurais, esta função utiliza uma técnica denominada como algoritmo de *Backpropagation* (ou propagação reversa, em tradução livre). Este algoritmo é computado com base na regra da cadeia, estudada em cálculo, e esta detalhado no capítulo 11 de [15].

Como função para medir o desempenho da rede durante o processo de treinamento, foi utilizado o erro quadrático médio entre as saídas x e as e os valores esperados t , dado pela expressão:

$$F = \frac{1}{N} \sum_{i=1}^N e_i^2 = \frac{1}{N} \sum_{i=1}^N (t_i - x_i)^2 \quad \text{Equação 3.1}$$

3.5 Arquiteturas de redes neurais

Dentre as diversas características que tornam distintas duas configurações de redes neurais artificiais, destacam-se a topologia, ou arquitetura, e as características individuais de cada neurônio que a constitui. Existem duas topologias básicas de redes neurais artificiais:

Uma rede estática tem todas as suas conexões somente em uma direção, o que permite subdividir os neurônios em camadas. Este tipo de rede forma um grafo acíclico direcionado em que cada neurônio recebe a entrada a partir da saída dos neurônios da camada anterior.

Esta é a mais simples das configurações que uma rede pode incorporar. Uma rede com este tipo de arquitetura representa uma função de suas entradas, sendo assim, não possui estados internos, a não ser pelos pesos de cada entrada de cada neurônio. A Figura 3-8 exemplifica este tipo de arranjo para uma rede de três camadas, onde os pontos menores representam os neurônios da camada de entrada.




Figura 3-8 - Exemplo de uma arquitetura estática feed-forward. Fonte: <http://commons.wikimedia.org/wiki/File:MultiLayerNeuralNetwork.png>

Por sua vez, redes dinâmicas possuem conexões que proporcionam alguma forma de realimentação e/ou atraso de sinais. Isto faz com que a rede se comporte como um sistema dinâmico podendo atingir condições de estabilidade, instabilidade e até mesmo comportamentos caóticos.

As arquiteturas de redes dinâmicas exploradas neste trabalho pertencem a uma classe de redes dinâmicas chamadas de redes digitais dinâmicas em camadas (LDDN). Cada camada nessa classe de redes tem como características:

- Um conjunto de matrizes de pesos de entrada, que podem ser saídas de outras camadas ou entradas de dados externas, uma função para combinar a matriz de pesos com a entrada da camada (normalmente uma multiplicação simples de matrizes), e uma linha de atraso de tempo².
- Um vetor de polarização,
- Uma função usada para combinar as saídas das diversas funções de peso com a polarização para produzir a entrada (normalmente uma função de soma).

A Figura 3-9 é um exemplo de uma rede dinâmica de três camadas, a primeira camada possui três conjuntos de pesos associados: Um conjunto de pesos de entrada, um peso associados à camada um e um peso associado à camada três. Os pesos relacionados às camadas possuem linhas de atraso de tempo (TDL) associadas.

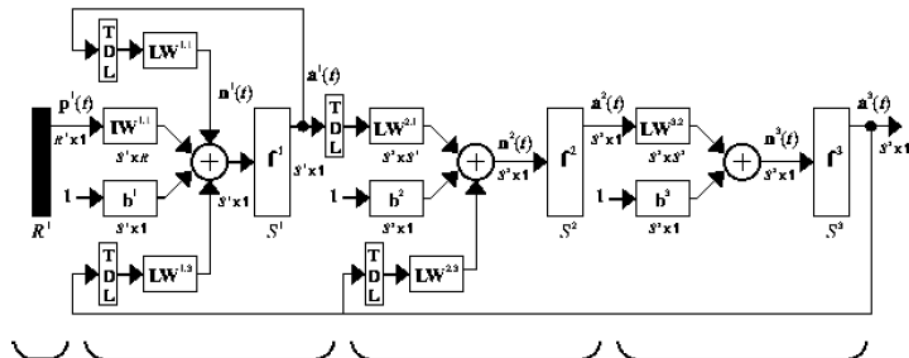


Figura 3-9 - Exemplo de uma arquitetura LDDN. Fonte: Guia do toolbox de redes neurais do MATLAB [16].

Em arquiteturas de redes dinâmicas a saída não depende mais somente da entrada atual, mas também do valor atual das entradas, dos valores passados das entradas e das saídas, e dos estados internos da rede. Este tipo de rede suporta uma memória de curto prazo, o que as aproxima do modelo de funcionamento do cérebro, e permite que sejam treinadas para aprender padrões sequenciais, ou variantes no tempo. Como consequência direta o processo de treinamento torna-se mais complexo.

O treinamento de redes dinâmicas é análogo ao utilizado em redes estáticas, podem-se empregar os mesmos algoritmos baseados em cálculo de gradientes, no entanto o desempenho

² Uma linha de atraso de tempo é um conjunto sequencial de atrasos, com saídas disponíveis após cada unidade de atraso. Como exemplo para um vetor [1 2 3 4 5] uma linha de atraso de tempo de três períodos (t-1, t-2 e t-4) forneceria, para o quinto elemento, os valores [4 3 1].

de tais métodos quando empregados neste tipo de arquitetura podem ser bem diferentes, além de que o cálculo do gradiente exige uma forma mais elaborada.

Considere uma rede recorrente simples como a da Figura 3-10.




Figura 3-10 - Exemplo de rede recorrente simples. Fonte Manual do usuário do toolbox de redes neurais MATLAB. [16]

A rede pode ser matematicamente descrita como:

$$a(t) = iw_L p(t) + lw_{i,j} a(t - 1) \quad \text{Equação 3.2}$$

Onde:

- $a(t)$ é a saída atual da rede;
- iw_L é o vetor de pesos associados à entrada;
- $lw_{i,j}$ é a matriz de pesos associada à camada;
- $a(t - 1)$ é saída, com um atraso de um período.

Observa-se que os pesos possuem dois efeitos diferentes na saída da rede. O primeiro é direto, pois uma mudança nos pesos causa uma mudança imediata na saída no período de tempo atual. O segundo efeito é indireto, pois algumas das entradas da camada, como por exemplo $a(t - 1)$ também são funções dos pesos.

Para se considerar este efeito indireto, deve-se usar uma técnica para o cálculo do gradiente denominada *backpropagation* dinâmica, que é computacionalmente mais intensa, exigindo portanto um tempo maior para o treinamento [17], [18] [19]. Este fato pode ser contornado empregando-se programação paralela às redes neurais, que são estruturas inerentemente paralelas. Desta forma é possível empregar múltiplos núcleos de processamento disponíveis em quase todos os processadores modernos (CPUs) e também em processadores de placas de vídeo (GPUs).

Para o experimento desenvolvido foram testadas seis tipos de topologias de redes disponíveis no *toolbox* de redes neurais do MATLAB. As arquiteturas foram treinadas com os mesmos conjuntos de dados e inicialização aleatória dos pesos, e os resultados obtidos

comparados. As arquiteturas descritas nos itens 3.5.1 e 3.5.2 são estáticas, enquanto as dos itens 3.5.3, 3.5.4, 3.5.5 e 3.5.6 são dinâmicas.

3.5.1 Arquitetura de rede feed-forward.

A rede do tipo feed-forward é constituída de uma ou mais camadas intermediárias (ou ocultas) de neurônios artificiais, que possuem a função de ativação do tipo log-sigmoide (Figura 3-11) exceto pela camada de saída, cuja função de ativação é linear.

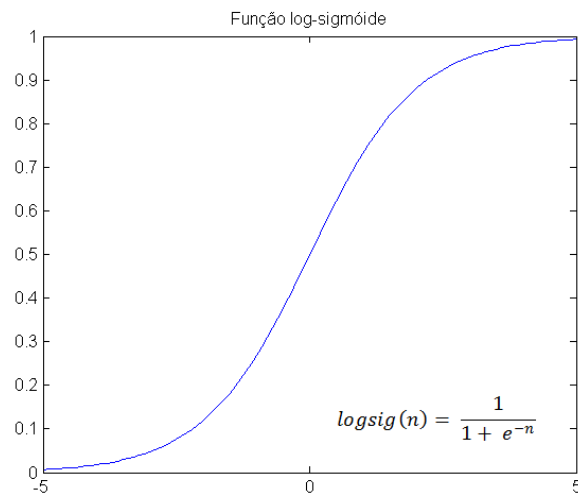


Figura 3-11 - Gráfico de uma função log-sigmoide. Fonte: Elaboração do autor.

As várias camadas de neurônios sigmóides permitem que a rede aprenda relações não lineares entre os vetores de entrada e saída, enquanto a camada de neurônios lineares melhor se adapta para problemas de aproximação de funções. [16]

Este tipo de rede pode ser utilizado como um aproximador universal de funções, ela é capaz de se adaptar de forma eficaz a qualquer função com um número finito de descontinuidades, desde que haja um número suficiente de neurônios nas camadas intermediárias. Esta característica foi provada pelo matemático George Cybenko em seu artigo publicado em 1989. [20]

A Figura 3-12 representa a arquitetura da rede feed-forward usada no experimento, com 18 sinais de entrada, e apenas um valor de saída. Foi utilizada uma rede com três camadas intermediárias de contendo 30, 50 e 3 neurônios respectivamente.




Figura 3-12 - Arquitetura da rede utilizada. Fonte: Elaboração do autor.

3.5.2 Arquitetura feed-forward em cascata.

Redes do tipo *feed-forward* em cascata apresentam as mesmas características das redes *feed-forward*, Entretanto cada camada apresenta também uma ligação entre os neurônios de entrada, além das camadas anteriores.

Assim como a rede *feed-forward*, este tipo de rede pode aproximar qualquer função com um número finito de descontinuidades entre valores de entrada e saída, desde que haja neurônios suficientes nas camadas intermediárias.




Figura 3-13 - Rede feed-forward em cascata utilizada. Fonte: Elaboração do autor.

3.5.3 Rede com atraso de tempo focado.

Este é o tipo mais simples de arquiteturas de rede dinâmicas. A partir de uma rede *feed-forward*, é adicionado uma linha de atraso de tempo na camada de entrada. Ela é parte de uma família de redes denominadas focadas pelo fato da característica dinâmica aparecer apenas na primeira camada.

Este tipo de arquitetura se adequa bem aos problemas de previsão de séries temporais, e tem a característica interessante de só possuir o atraso na primeira camada, este fato permite que o treinamento da rede seja mais rápido, pois não há realimentação ou parâmetros ajustáveis.

Na Figura 3-14 pode-se observar a arquitetura de rede experimentada, observa-se um atraso mínimo de um período e um máximo de dois períodos na primeira camada, isso significa que: é possível iniciar o treinamento apenas a partir do terceiro valor da série temporal, e que o tipo da previsão é para o próximo período.




Figura 3-14 - Arquitetura da rede com atraso de tempo focada utilizada. Fonte: Elaboração do autor.

3.5.4 Rede com atraso de tempo distribuído.

A rede descrita no item 3.5.3 possui a linha de atraso de tempo apenas na primeira camada intermediária. Em contraste, a arquitetura de rede com atraso de tempo distribuído possui linhas de atraso de tempo em cada camada da rede neural. Esta arquitetura de rede já foi empregada com sucesso em detecção de fonemas a partir de um sinal sonoro [21].

A Figura 3-15 representa a arquitetura de rede utilizada nesta etapa do experimento, ela possui uma linha de atraso de tempo na primeira camada intermediária de quatro períodos, nas segunda e terceira camadas existe um atraso de oito períodos e na camada de saída um atraso de dois períodos.




Figura 3-15 - Arquitetura de rede com atraso de tempo distribuída usada. Fonte: Elaboração do autor

3.5.5 Rede de camadas recorrentes.

Neste tipo de arquitetura, existe um loop de realimentação em cada camada da rede, exceto pela última. Uma versão simplificada deste tipo de arquitetura foi proposta por Elman [22].

Em sua estrutura original havia apenas duas camadas e a função de ativação utilizada era a tangente-sigmoide na camada intermediária e uma função linear na última camada. Com base na arquitetura de Elman, a rede de camadas recorrentes foi generalizada para ter um número arbitrário de camadas intermediárias e qualquer função de ativação.

A Figura 3-16 exibe a configuração da rede utilizada no experimento, foram usadas três camadas intermediárias com linhas de atrasos de tempo de quatro períodos. Todas as funções são log-sigmoides com exceção da última que é uma função linear.




Figura 3-16 - Arquitetura de camadas recorrentes usada. Fonte: Elaboração do autor.

3.5.6 Rede não linear auto regressiva com entrada exógena (NARXnet).

A rede NARX é uma rede dinâmica e recorrente, com conexões de realimentação envolvendo diversas camadas da rede neural. Este tipo de arquitetura é baseado nos modelos ARMAX, normalmente utilizados em modelagem de séries temporais. Logo, para compreender este tipo de arquitetura é necessário entender como funciona um modelo não linear auto regressivo.

Modelos auto regressivos são modelos estocásticos normalmente empregados, em estudos estatísticos e em processamento de sinais, para modelar e prever vários tipos de fenômenos naturais. Este tipo de modelo utiliza os valores passados de uma série temporal para prever os valores futuros da mesma.

Um modelo não linear ARMAX pode ser visto como a extensão de um modelo linear. Um modelo linear SISO³ ARMAX tem a seguinte estrutura:

$$\begin{aligned} y(t) + a_1 y(t-1) + a_2 y(t-2) + \dots + a_{na} y(t-na) \\ = b_1 u(t) + b_2 u(t-1) + \dots + b_{nb} u(t-nb+1) \\ + e(t) \end{aligned} \quad \text{Equação 3.3}$$

Este tipo de modelo implica que a saída atual $y(t)$ é dada como uma soma ponderada dos valores passados de saída e do valor atual e passados dos valores exógenos de entrada $u(t)$. Reescrevendo a Equação 3.3 como um produto tem-se:

$$y_p(t) = [-a_1, -a_2, \dots, -a_{an}, b_1, b_2, \dots, b_{nb}] * [y(t-1), y(t-2), \dots, y(t-na), u(t), u(t-1), \dots, u(t-nb-1)]^T \quad \text{Equação 3.4}$$

Na Equação 3.4, os termos $y(t-1), y(t-2), \dots, y(t-na), u(t), u(t-1), \dots, u(t-nb-1)$ são variáveis de entrada e saída desfasadas, denominadas regressores. O modelo linear ARX faz a previsão da saída atual y_p como uma soma ponderada de seus regressores.

Esta estrutura linear do modelo ARX pode ser estendida para criar uma forma não linear: Ao invés de usar a soma ponderada, que representa o mapeamento linear, o modelo não linear ARX (NARX) possui uma função não linear de mapeamento mais flexível:

$$y_p(t) = f(y(t-1), y(t-2), \dots, y(t-na), u(t), u(t-1), \dots, u(t-nb-1)) \quad \text{Equação 3.5}$$

³ Modelos SISO (Single Input Single Output) são modelos que apresentam apenas uma única entrada e uma única saída.

Onde a função f é não linear, e cuja entradas são os regressores do modelo.

Regressores do modelo NARX podem ser tanto variáveis atrasadas de entrada e saída, quanto expressões não lineares mais complexas destas variáveis, como exemplo: $y(t - 2)^2 * u(t - 1)$, $\tan(u(t - 1))$, etc.

A Figura 3-17 representa o diagrama de blocos de um modelo NARX em um cenário de simulação.

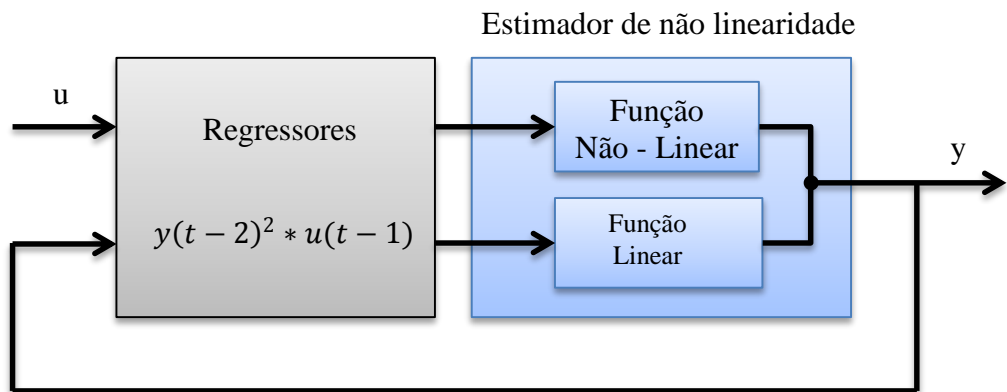


Figura 3-17 - Estrutura de um modelo NARX. Fonte: Elaboração do autor.

O cálculo da saída do modelo ARMAX ocorre em dois estágios:

1. São calculados os regressores da entrada atual e valores passados das entradas e saídas.
2. O bloco estimador de não linearidade mapeia os regressores até a saída do modelo usando uma combinação de funções lineares e não lineares. Este bloco pode usar funções lineares e não lineares em paralelo. Por exemplo:

$$F(x) = L^T(x - r) + d + g(Q(x - r)) \quad \text{Equação 3.6}$$

- Onde x é um vetor dos regressores;
- $L^T(x) + d$ é a saída do bloco de função linear, e é afim quando $d \neq 0$;
- $g(Q(x - r))$ representa a saída do bloco de função não linear;
- r é a média dos regressores r ;
- Q é a matriz de projeção relacionada à convergência das iterações.

A forma exata de $F(x)$ depende da escolha da do bloco estimador de não linearidade. Ajustar o modelo ARX a série temporal em estudo, envolve o cálculo dos valores dos parâmetros L, r, Q, d , além de outros parâmetros de g .

Apresentada a estrutura deste modelo, é possível desenvolver uma rede neural artificial do tipo NARX substituindo-se o bloco estimador de não linearidade por uma rede neural artificial apta a aproximar a função f .

Na Figura 3-18 pode-se observar um diagrama da rede resultante desta substituição, neste exemplo uma rede neural do tipo *feed-forward* de duas camadas é usada para a aproximação. Este arranjo também permite um modelo ARX vetorial, onde a entrada e a saída do modelo podem ser multidimensionais.

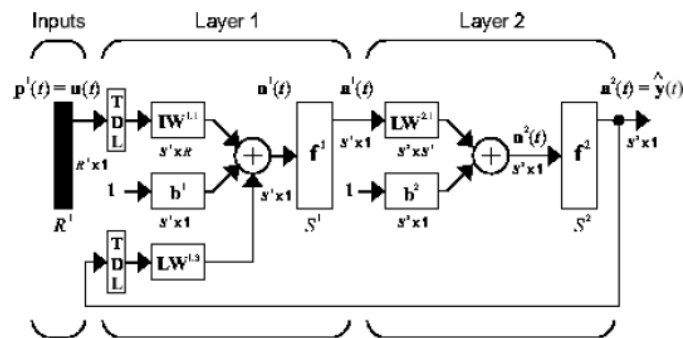


Figura 3-18 - Diagrama de uma rede neural com arquitetura NARX. Fonte: Guia do usuário MATLAB do toolbox de Redes Neurais.

Redes do tipo NARX possuem muitas aplicações, sobretudo a previsão de séries temporais e a criação de filtros não lineares.

É interessante destacar uma característica deste tipo de rede muito útil nas rotinas de treinamento. Pode-se considerar a saída da rede NARX como uma estimativa do valor de saída da série temporal que se deseja prever. Esta saída é realimentada na entrada da rede como padrão da arquitetura de modelos NARX, conforme pode ser visto na parte esquerda da Figura 3-19. Devido ao fato de que a verdadeira saída está disponível durante o treinamento da rede, é possível criar a arquitetura série-paralela mostrado à direita da mesma Figura 3-19.




Figura 3-19 - Arquitetura paralela (esquerda) e série-paralela (direita) de redes NARX. Fonte: Guia do usuário MATLAB do toolbox de Redes Neurais.

A arquitetura série-paralela possui duas vantagens para o treinamento da rede:

1. A saída verdadeira que está disponível é mais precisa do que a estimativa da rede, isso proporciona um treinamento mais preciso.

2. Este tipo de arquitetura é *feed-forward*, portanto não possui laços de realimentação, logo algoritmos estáticos de treinamento podem ser utilizados, o que torna esta etapa muito mais rápida e computacionalmente eficiente.

Após o treinamento da rede, é possível “fechar” a mesma, de tal forma a obter uma arquitetura recorrente. Desta forma é possível obter previsões sobre os valores seguintes.

A Figura 3-20 exibe as arquiteturas de rede utilizadas para o treinamento (a) e predição (b) no experimento.




Figura 3-20 - Redes NARX aberta (a) e fechada (b) usadas. Fonte: Elaboração do autor.

3.6 Validação

As seções anteriores detalharam o experimento, desde a coleta das informações até a definição das arquiteturas a serem testadas. Para comparar e validar os resultados obtidos com cada arquitetura, cada uma delas foi treinada e simulada com o mesmo conjunto de dados por dez vezes sequenciais.

Para medir o desempenho das redes umas perante as outras se usou o erro médio percentual absoluto, dado pela expressão da Equação 3.7:

$$E = \frac{100\%}{n} \sum_{t=1}^n \left| \frac{A_t - P_t}{A_t} \right|$$

Equação 3.7

Onde:

- A é o valor atual, e
- P é o valor previsto pela rede.
- n é a quantidade de amostras.

Os resultados deste experimento, assim como a conclusão do trabalho são apresentadas a seguir, no capítulo 4.

CAPÍTULO 4

3.1 Resultados do experimento.

Conforme estabelecido na metodologia de realização do experimento no capítulo três, o treinamento e simulação da resposta, para o conjunto de dados selecionado, foram realizados dez vezes sequenciais para cada arquitetura de rede proposta.

Os conjuntos de treinamento e teste foram os mesmos para todas as arquiteturas testadas. O conjunto de teste compreendia um período de trinta semanas, da 17ª até a 46ª semana de 2010, enquanto o conjunto de treinamento abrangia desde a 2ª semana de 2007 até a 6ª semana de 2010.

A diferença de valores do conjunto de teste e o resultado das redes foi calculada pelo erro médio percentual absoluto (Equação 3.7). A Tabela 3 apresenta este erro para os três melhores resultados de cada arquitetura testada: *feed-forward* (FF), *feed-forward* em cascata (CFF), atraso de tempo focado (FTD), atraso de tempo distribuído (DTD), recorrente (RC) e NARX.

Tabela 3 – Resultados obtidos inicialmente.

Melhores Resultados	FF	CFF	FTD	DTD	RC	NARX
1º	26,93%	20,27%	36,42%	53,21%	32,55%	50,23%
2º	29,75%	23,63%	53,26%	54,34%	41,70%	57,57%
3º	36,53%	25,69%	57,07%	60,14%	46,67%	69,56%
Média	31,07%	24,20%	48,92%	55,89%	40,31%	59,12%

Como comparativo, a previsão dada pelos modelos NEWAVE e DECOMP, sem o uso da técnica proposta neste trabalho e no mesmo intervalo do conjunto usado para teste do resultado das redes neurais apresenta um erro médio absoluto de 56,03%. Observa-se que a maioria dos resultados é próxima ou menor do que aqueles obtidos sem o uso da técnica proposta. A melhor arquitetura para esta etapa dos testes foi a *feed-forward* em cascata, que apresentou um erro médio de previsão de 24,20 %.

Seguindo a metodologia proposta para o experimento, após esta rodada de testes e análise dos resultados obtidos, foram feitas alterações nos arquivos de entrada e também em

alguns parâmetros da rede tais como número de neurônios nas camadas intermediárias, tempo de atrasos de realimentação, taxa de aprendizado da rede e critérios de parada do treinamento.

Os resultados após estas alterações permaneceram próximos aos da Tabela 3, no entanto uma alteração que trouxe significativa melhora foi a introduzir o erro da previsão de uma semana dos próprios modelos NEWAVE e DECOMP aos dados de entrada. O Gráfico da Figura 3-21 ilustra este erro, nele está traçado na cor verde o PLD real, e nas barras de cor preta o erro da projeção dos modelos.




Figura 3-21 - Erro de previsão do modelo como um indicador de volatilidade. Fonte: Elaboração do autor.

Com a introdução destes erros como entrada, os resultados obtidos foram significativamente mais precisos para algumas arquiteturas, a Tabela 4 apresenta os resultados obtidos após esta modificação dos parâmetros de entrada.

Tabela 4 – Resultados após introdução do erro de previsão aos parâmetros de entrada.

Melhores Resultados	FF	CCF	FTD	DTD	RC	NARX
1º	23,05%	17,80%	33,83%	45,37%	19,04%	39,80%
2º	23,41%	25,77%	60,83%	57,44%	26,43%	51,05%
3º	25,96%	25,79%	61,57%	59,81%	38,05%	58,48%
Média	24,14%	23,12%	52,08%	54,21%	27,84%	49,78%

Observa-se uma significativa melhora da precisão para as arquiteturas *feed-forward* e recorrente. A arquitetura *feed-forward* em cascata não apresentou melhora significativa, mas mesmo assim continuou sendo a mais precisa.

Uma das possíveis explicações para este fenômeno vem da análise técnica clássica, amplamente utilizada na previsão de preços de ações em bolsas de valores e fundamentada na teoria de Dow [23], que diz que todas as informações necessárias para a previsão do valor futuro de um determinado preço estão contidas nele e em seus valores passados.

Na análise técnica clássica, são usados indicadores como médias móveis e osciladores, para se evidenciar características que não podem ser observadas diretamente a partir da série temporal, ao incluir dentre as variáveis de entrada o erro de previsão do próprio modelo, este passou a se comportar como um indicador de volatilidade do PLD. O gráfico da Figura 3-21 exibe bem esta informação, nota-se um aumento do erro de forma proporcional ao aumento da volatilidade do PLD.

Observa-se que a arquitetura que apresentou melhores resultados, tanto antes quanto depois da introdução de novos parâmetros de entrada, foi a *feed-forward* em cascata. A Figura 3-22 exibe o resultado dos treinamentos dos melhores casos aferidos (azul claro) em contraste com o preço real do PLD (verde) e com a previsão dada pelos modelos NEWAVE e DECOMP (vermelho). Além disto, o melhor caso está destacado (linha pontilhada azul escura) e a média de todas as previsões está traçada na cor laranja.




Figura 3-22 – Melhores resultados obtidos com o experimento. Fonte: Elaboração do autor

Nota-se a proximidade entre os pontos obtidos como resultado de cada um dos três melhores testes do experimento, o valor real do PLD e a previsão dada pelos modelos. Isto é um indicativo de que a técnica proposta neste trabalho é válida, pois as redes são foram capazes de detectar padrões no conjunto de treinamento e reproduzi-los neste conjunto de teste composto por trinta semanas, até então desconhecido para elas.

É possível obter um resultado ainda melhor tomando-se a média de todas as previsões, incluindo as dadas pelos modelos NEWAVE e DECOMP, para esta curva o erro médio percentual absoluto calculado é de 21.84%, menos da metade do obtido apenas com a previsão dada pelos modelos oficiais.

CAPÍTULO 5

4.1 Conclusões

As características geográficas e econômicas do Brasil contribuíram para a constituição de um sistema de geração, transmissão e distribuição de energia elétrica único no mundo. Pelo fato de possuir o parque gerador composto predominantemente por usinas hidroelétricas e térmicas é necessário um planejamento preciso que proporcione uma energia elétrica de qualidade.

Os modelos empregados atualmente suprem as necessidades de planejamento da operação do sistema elétrico nacional, no entanto não o fazem da maneira mais eficaz. Devido à idade da tecnologia empregada na programação de tais modelos, fazer modificações de forma a aproveitar o avanço das tecnologias de hardware, sobretudo processamento paralelo, tornou-se uma tarefa não trivial.

A conexão direta entre o resultado obtido a partir dos modelos NEWAVE e DECOMP e fatores naturais de difícil previsão, principalmente a quantidade de chuvas em certas regiões geográficas, fazem com que as previsões acerca deste resultado sejam muito voláteis, e percam a validade em um prazo muito curto. Fazendo-se necessário um novo processamento com parâmetros de entrada atualizados.

O elevado tempo computacional, requerido para a obtenção tanto dos resultados, quanto das previsões, aliado à grande quantidade de parâmetros de entrada, torna demasiado complexo o emprego destes modelos em situações onde são necessários resultados rápidos, e/ou um grande número de simulações.

A proposta deste trabalho foi desenvolver uma técnica e uma ferramenta computacional capaz de produzir previsões de curto prazo para o valor do PLD de forma mais rápida e com uma precisão igual, ou melhor, a partir do mesmo conjunto de informações disponibilizadas oficialmente pelos agentes responsáveis.

Observando os resultados obtidos com o experimento, em um intervalo de trinta semanas, conclui-se que a técnica proposta é válida, e que o seu emprego em conjunto com os modelos NEWAVE e DECOMP atinge o objetivo proposto de forma satisfatória e

computacionalmente mais eficiente, facilitando assim a obtenção de uma informação estratégica para vários dos agentes do setor elétrico brasileiro.

A solução proposta neste trabalho não visa, de forma alguma, substituir o uso dos modelos oficiais, mas sim de complementá-los e permitir o uso em situações que antes não seriam possíveis. Como exemplo é possível citar atividades de planejamento das estratégias para leilões de energia elétrica, estudos de prospecção de clientes realizados pelas comercializadoras de energia elétrica, análise de riscos de investimentos, entre outros. Nestes casos o tempo necessário para obtenção dos resultados, bem como a facilidade para se simular um possível cenário são cruciais, e praticamente inviáveis se executadas apenas com o uso dos modelos disponíveis.

Muito da agilidade proporcionada pela técnica proposta se dá pelo emprego de redes neurais artificiais. Dadas as suas características inerentemente paralelas, é possível o uso de programação concorrente tanto para o treinamento, quanto para a simulação dos resultados. São raras as soluções, no setor eletro-energético brasileiro, que fazem uso deste tipo de programação, que aliado à queda do preço de processadores de múltiplos núcleos, proporciona uma forma eficaz e de baixo custo de se reduzir drasticamente o tempo computacional requerido, e é também capaz de simplificar o escalonamento de hardware, caso seja necessário maior poder de processamento.

A execução das atividades propostas neste trabalho, também trouxe benefícios indiretos de grande valor, como por exemplo, a criação de uma ferramenta automática para a coleta e processamento das informações disponibilizadas, e também a organização destas em um banco de dados relacional. O pré-processamento do alto volume de dados torna-se mais rápido e preciso. E a criação deste banco de dados facilita a manipulação dos dados para outros tipos de análises, que poderão servir de base para novos estudos.

O levantamento e observação dos diversos parâmetros de entrada trazem também, como resultado indireto deste trabalho, o entendimento do grau de importância de certas variáveis para o estabelecimento do PLD. De forma análoga, é possível estender as técnicas e ferramentas desenvolvidas com a finalidade de detectar a influência de outras variáveis em resultados fornecidos por diversos outros sistemas empregados no planejamento de operações. Como exemplo cita-se o cálculo do risco de déficit de energia, dos níveis finais de cada reservatório, do nível de uso dos sistemas de transmissão, dentre outros.

A ferramenta desenvolvida para o estabelecimento, teste e validação de cada arquitetura de rede neural proposta permitiu mensurar a aptidão de cada arranjo para a resolução do problema proposto de forma automática. Esta mesma metodologia também pode

ser empregada para a solução de outros tipos de problemas semelhantes. Se combinada com técnicas de algoritmos genéticos, ou outras técnicas de otimização, ela pode evoluir para se tornar um gerador de redes neurais com arquitetura e parâmetros ótimos.

Segundo o observado nos resultados do experimento, a introdução de um novo parâmetro, que indiretamente indicava a volatilidade dos preços, melhorou o desempenho das arquiteturas testadas, é interessante realizar um trabalho para descobrir que outros tipos de indicadores podem melhorar este tipo de previsão. Como ponto de partida, pode-se empregar indicadores mais simples como conjuntos de médias móveis e indicadores de tendência.

Os resultados obtidos neste trabalho tiveram como base exclusivamente os dados oficiais disponibilizados pela CCEE em seu site, não foram utilizados nenhum dos dois modelos oficiais para processamento devido à restrição de licença dos mesmos por parte do CEPTEL. Caso obtenha-se acesso aos mesmos, pode se usar a mesma técnica de projeto e análise de experimentos empregada por Queiroz em [24] para a criação do conjunto de treinamento. Conforme demonstrado por ele, o emprego deste tipo de técnica remove simulações desnecessárias e aperfeiçoa o treinamento da rede neural. Combinada com as técnicas desenvolvidas neste trabalho se produziriam resultados mais precisos do que os obtidos.

4.2 Trabalhos Futuros

Após estas considerações ficam como sugestões para trabalhos futuros:

- O uso das técnicas e ferramentas aqui propostas, e seu conseqüente aprimoramento, para a previsão de outras grandezas ligadas ao planejamento da operação do sistema elétrico nacional.
- Verificação dos efeitos causados, caso sejam empregados, indicadores já difundidos em análise técnica sobre o conjunto dos dados de entrada.
- O emprego de ferramentas externas para gerar um conjunto de treinamento otimizado, visando melhorar o desempenho das previsões fornecidas pelas pela ferramenta produzida neste trabalho.
- A evolução dos algoritmos usados na automação da criação, testes e validação de resultados das redes neurais desenvolvidos, de forma a criar um sistema capaz de produzir RNAs otimizadas para problemas específicos.

- O emprego de modelos Neuro-fuzzy ao invés de Redes Neurais Artificiais e comparação com os resultados obtidos neste trabalho.

5. Bibliografia

1. OPERADOR NACIONAL DO SISTEMA ELÉTRICO (BRASIL). o que é o ons. **Site ONS**, 28 fevereiro 2012. Disponível em: <http://www.ons.org.br/institucional/o_que_e_o_ons.aspx>. Acesso em: 28 fevereiro 2012.
2. CÂMARA DE COMERCIALIZAÇÃO DE ENERGIA ELÉTRICA (BRASIL). **Guia Treinamento NEWAVE - DECOMP**. São Paulo. 2009.
3. MINISTÉRIO DE MINAS E ENERGIA (BRASIL). **Plano Decenal de Expansão de Energia 2019**. Brasília. 2010.
4. OPERADO
R NACIONAL DO SISTEMA ELÉTRICO (BRASIL). O que é o SIN. **Site do ONS**, 2012. Disponível em: <http://www.ons.org.br/conheca_sistema/o_que_e_sin.aspx>. Acesso em: 2012 dez. 06.
5. OPERADOR NACIONAL DO SISTEMA ELÉTRICO. Procedimentos de rede. **Site do ONS**. Disponível em: <<http://extranet.ons.org.br/operacao/prdocme.nsf/principalPRedeweb?openframeset>>. Acesso em: 13 dez. 2012.
6. CENTRO DE PESQUISAS DE ENERGIA ELÉTRICA (BRASIL). Descrição dos programas. **Site do Centro de Pesquisas do setor elétrico - CEPEL**. Disponível em: <<http://www.cepel.br/servicos/descprog.shtm>>. Acesso em: 19 dez. 2011.
7. HIPEL, K. W. & M. A. I. **Time Series Modelling of Water Resources and Environmental Systems**. Amsterdam: Elsevier, 1994.
8. MACEIRA, M. E. P. & D. J. M. **The use of PAR (p) model in the stochastic dual dynamic programming optimization scheme used in the operation planning of the Brazilian hydropower system**. 8th International Conference on Probabilistic Methods Applied to Power Systems. Ames, Iowa: Iowa State University.
9. BARROS, M. T. L. A programação Dinâmica Aplicada à Engenharia de Recursos Hídricos. In: PORTO, R. L. E. A. **Técnicas quantitativas para o gerenciamento de Recursos Hídricos 1ed.** [S.l.]: ABRH-EUFRGS, 1997. p. 239-303.
10. BENDERS, J. F. Partitioning procedures for solving mixed-variables programming problems. In: _____ **Numer. Math.** **4,3**. [S.l.]: [s.n.], 1962. p. 238-252.
11. SMARTENERGYONLINE.COM.BR. Smart Energy | Aneel define limites para preço do PLD em 2012. **Smart Energy Online**, 15 dez. 2011. Disponível em: <<http://www.smartenergyonline.com.br/article.php?a=1474>>. Acesso em: 18 set. 2012.
12. CÂMARA DE COMERCIALIZAÇÃO DE ENERGIA ELÉTRICA (BRASIL). **Guia Prático de Utilização Modelo NEWAVE - Versão 15**. São Paulo. 2009.

13. RUSSEL, S.; NORVIG, P. **Artificial Intelligence: A Mordern Approach** 3rd Ed. New Jersey: Prentice Hall, 2010. ISBN ISBN 13: 978-0-13-604259-4.
14. MØLLER, M. F. A Scaled Conjugate Gradient Algorithm for Fast Supervised Learning. **Neural Networks**, 6, pp. 525-533, 1993.
15. HAGAN, M. T. . H. B. D. A. M. H. B. **Neural Network Design**. Boston, MA : PWS Publishing, 1996.
16. MATHWORKS. **Neural Network Toolbox: User's Guide (r2012a)**. [S.l.]: [s.n.], 2102.
17. DE JESÚS, O. . A. M. T. H. **Backpropagation Through Time for a General Class of Recurrent Network**. Proceedings of the International Joint Conference on Neural Networks. Washington, DC: [s.n.]. 2001.
18. DE JESÚS, O. . A. M. T. H. **Forward Perturbation Algorithm for a General Class of Recurrent Network**. Proceedings of the International Joint Conference on Neural Networks. Washington, DC: [s.n.]. 2001.
19. DE JESÚS, O. . A. M. T. H. **Backpropagation Algorithms for a Broad Class of Dynamic Networks**. IEEE Trasactions on Neural Networks. [S.l.]: [s.n.]. 2007.
20. CYBENKO, G. Approximations by superpositions of sigmoidal functions. **Mathematics of Control, Signals , and Systems 2 (4), 303-314**, 1989.
21. WAIBEL, A. . T. H. G. H. K. S. A. K. J. L. **Phoneme recognition using time-delay neural networks**. IEEE Transactions on Acoustics, Speech, and Signal Processing. [S.l.]: [s.n.]. 1989.
22. ELAN, J. L. Finding structure in time. **Cognitive Science**, 14, 1990.
23. BROWN, S. J. . K. A. A. G. W. N. The Dow Theory: William Peter Hamilton's Track Record Re-Considered., 23 Janeiro 1998. Acesso em: 08 fev. 2013.
24. QUEIROZ, A. R. D. **SIMULAÇÃO DE CUSTOS MARGINAIS EM MERCADO DE ENERGIA ELÉTRICA UTILIZANDO REDES NEURAI**S. Itajubá: Universidade Federal de Itajubá. 2007.
25. E.H. MAMDANI. Application of fuzzy Algorithms for Control of Simple dynamic Plants. **Proc. IEE**, p. Vol.121:12, pp.1585-1588., 1974.
26. WANG, A.-P.; LIAO, H.-Y.; CHANG, T.-H. **Adaptive Neuro-fuzzy Inference System on Downstream Water Level Forecasting**. Fifth International Conference on Fuzzy Systems and Knowledge Discovery. Chung-Li: [s.n.].
27. VO, M. T. **INCREMENTAL LEARNING USING THE TIME DELAY NEURAL NETWORK**, Pittsburgh, PA.
28. COLNET B., M. J. **BEARING ESTIMATION WITH TIME-DELAY NEURAL NETWORKS**, Nancy. FRANCE.
29. J.Y. TIAN, J. Q. L. **Apnea Detection Based on Time Delay Neural Network**. Shanghai, China: [s.n.]. 2005.
30. J. C. RESTON FILHO, C. M. A. E. R. C. L. O. **Pricing Analysis in the Brazilian Energy Market: a Decision Tree Approach**. Bucharest, Romania: IEEE Bucharest Power Tech Conference. 2009.
31. LONG ZHANG1 BINQI HU, T. C. Y. Z. Y. Z. S. L. **Price of Electric Futures Forecasting Based on**

- Error Correction Model.** Changsha, China: Changsha University of Science and Technology.
32. L., V. **ANÁLISE MULTIVARIADA DA TEORIA À PRÁTICA.** Santa Maria, RS, Brasil: [s.n.], 2005.
 33. CÂMARA DE COMERCIALIZAÇÃO DE ENERGIA ELÉTRICA (BRASIL). **Regras de Comercialização - Formação do Preço de Liquidação das Diferenças (PLD) (ANEXO).** [S.l.]: [s.n.]. 2012.
 34. EMPRESA DE PESQUISA ENERGÉTICA (BRASIL). Rio de Janeiro. 2012. (CDU 620.9:553.04(81)).
 35. CÂMARA DE COMERCIALIZAÇÃO DE ENERGIA ELÉTRICA (BRASIL). **InfoPLD.** São Paulo, SP. 2010.
 36. BRASIL. **LEI No 5.655, DE 20 DE MAIO DE 1971.** Brasília - DF: [s.n.]. 1971.
 37. MINISTÉRIO DE MINAS E ENERGIA (BRASIL). **Matriz Energética Nacional 2030.** Brasília, DF. 2007. (CDU 620.91(81)).
 38. CENTRO DE PESQUISAS DE ENERGIA ELÉTRICA (BRASIL). **Modelo DECOMP - Manual de Referência.** [S.l.]. 2004.
 39. EMPRESA DE PESQUISA ENERGÉTICA (BRASIL). **Resenha Mensal do Mercado de Energia,** Rio de Janeiro, n. Ano V, Número 49, 2011.
 40. CASTRO N. J., L. A. L. S. **Preço spot de eletricidade: teoria e evidências do caso brasileiro.** [S.l.]: Universidade Federal do Rio de Janeiro. 2010.
 41. DERAKHSHANI R., S. S. A. C. **Continuous Time Delay Neural Networks for Detection of Temporal Patterns in Signals.** Morgantown, WV: West Virginia University.
 42. FILHO, S. S. PLANEJAMENTO DA OPERAÇÃO DE SISTEMAS HIDROTÉRMICOS, Campinas, SP, 1 No 2.
 43. JENQ-NENG HWANG, H. L. C.-J. W. **A Limited Feedback Time-Delay Neural Network.** Seattle, WA: University of Washington.
 44. LIPO WANG, K. K. T. A. Z. L. **Predicting Time Series with Wavelet Packet Neural Networks.** Singapore: Nanyang Technological University.
 45. LIU D., M. A. N. **Sparsely Interconnected Neural Networks for Associative Memories With Applications to Cellular Neural Networks.** IEEE TRANSACTIONS ON CIRCUITS AND SYSTEMS-I1 ANALOG AND DIGITAL SIGNAL PROCESSING. [S.l.]: [s.n.]. 1994.
 46. N. M. PINDORIYA, S. N. S. S. K. S. **An Adaptive Wavelet Neural Network-Based Energy Price Forecasting in Electricity Markets.** IEEE TRANSACTIONS ON POWER SYSTEMS. [S.l.]: [s.n.]. 2008.
 47. RC LEME, J. T. P. B. A. Z. D. S. P. S. **A Study of Electricity Price Volatility for the Brazilian Energy Market.** Itajubá, MG: [s.n.].
 48. S. B. CHEN, L. W. A. Q. L. W. **Self-Learning Fuzzy Neural Networks for Control of Uncertain Systems With Time Delays.** IEEE TRANSACTIONS ON SYSTEMS, MAN, AND CYBERNETICS—PART B: CYBERNETICS. [S.l.]: [s.n.]. FEBRUARY 1997.
 49. WEIGEND, A. S. . A. N. A. G. E. . **Time Series Prediction: Forecasting the Future and Understanding the Past.** [S.l.]: Addison-Wesley, 1994.
 50. AGENCIA NACIONAL DE ENERGIA ELÉTRICA. **BIG - Banco de Informações da Geração.** Disponível

em: <<http://www.aneel.gov.br/aplicacoes/capacidadebrasil/capacidadebrasil.asp>>. Acesso em: 28/02/2012.

ANEXO A

A. Resultados obtidos com as arquiteturas de RNA.

Neste apêndice, estão dispostos de forma sequencial os gráficos obtidos como resultados do experimento descrito no capítulo 3.

A inclusão deste apêndice teve como única finalidade, exibir os resultados obtidos para as arquiteturas de redes testadas, não é feita nenhum tipo de análise aprofundada em relação a estes resultados.

Cada resultado é apresentado em um gráfico com as respostas para um conjunto de testes, não usados durante a etapa de treinamento, e também um histograma que demonstra a dispersão dos erros de previsão.

Nos gráficos das respostas, as linhas pontilhadas em azul claro representam as saídas de cada geração da arquitetura de RNA testada, a linha pontilhada em azul escura é a resposta da melhor geração produzida. Para auxílio na comparação, a linha verde representa o PLD real, enquanto a linha vermelha representa a projeção obtida com os modelos NEWAVE e DECOMP.

No histograma, as barras em verde representam a contagem e a magnitude dos erros de projeção dos modelos NEWAVE e DECOMP, enquanto as barras azuis representam as mesmas informações para a melhor geração da arquitetura testada.

A.1 Resultados para a arquitetura *feed-forward*.

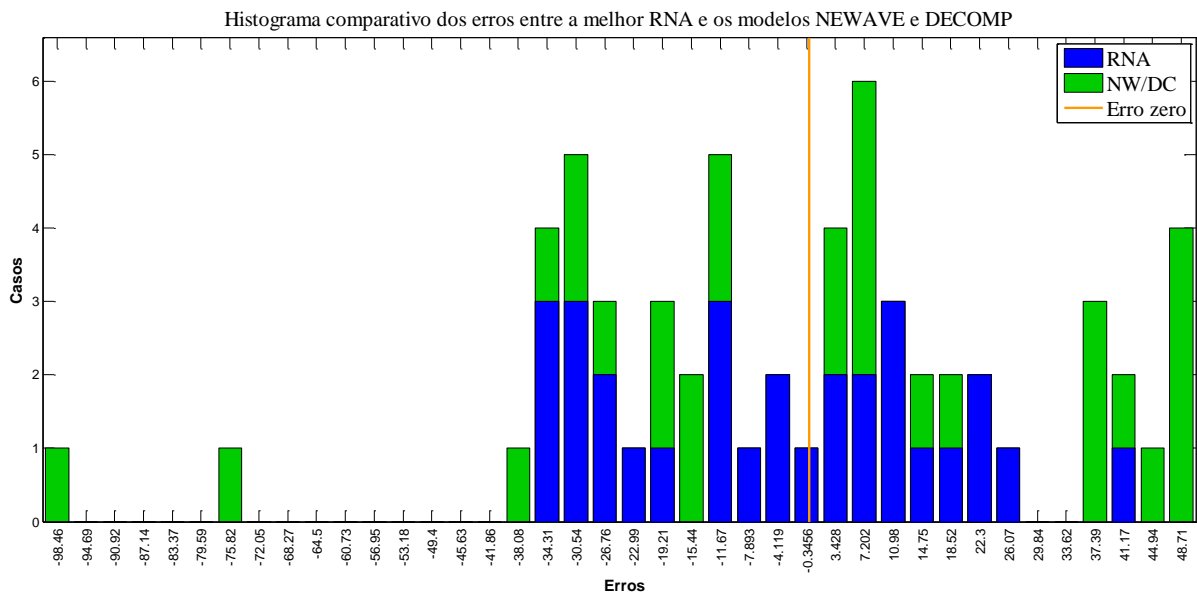



Figura A-1 Resultados obtidos com a arquitetura *feed-forward*. Fonte: Elaboração do autor.

A.2 Resultados para a arquitetura *feed-forward* em cascata.

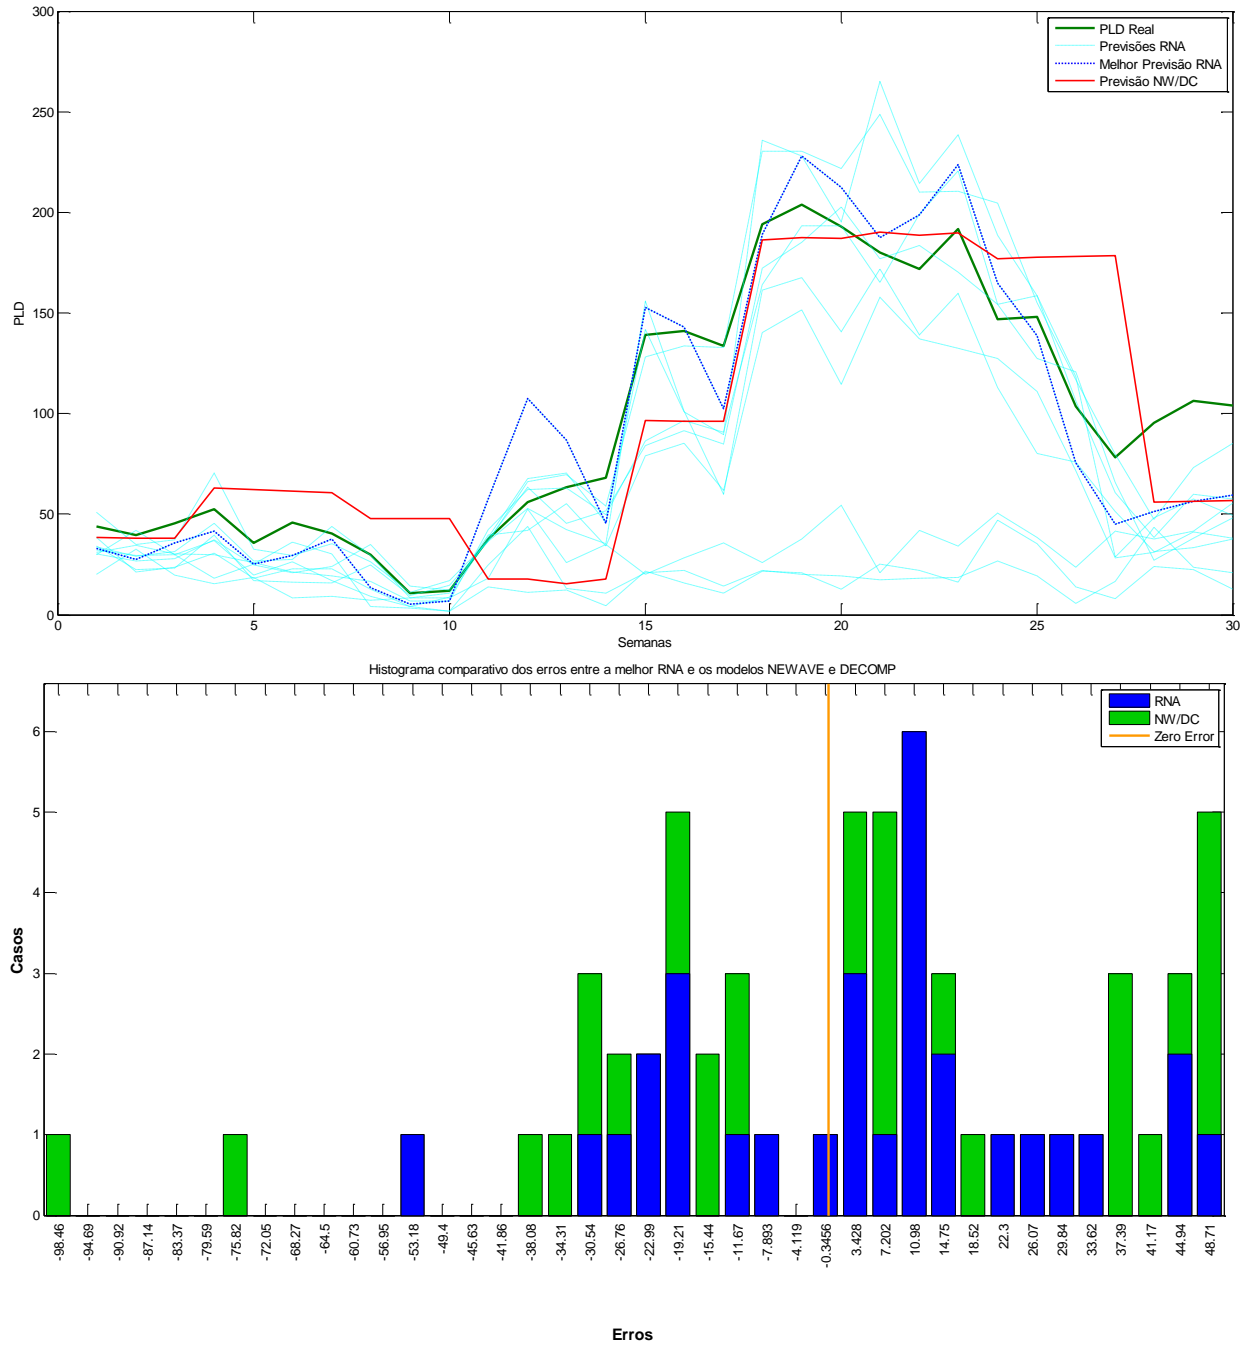


Figura A-2 Resultados obtidos com a arquitetura *feed-forward* em cascata. Fonte: Elaboração do autor.

A.3 Resultados para a arquitetura com atraso de tempo focada.




Figura A-3 Resultados obtidos com a arquitetura atraso de tempo focada. Fonte: Elaboração do autor.

A.4 Resultados para a arquitetura com atraso de tempo distribuído.




Figura A-4 Resultados obtidos com a arquitetura atraso de tempo distribuída. Fonte: Elaboração do autor.

A.5 Resultados obtidos com a arquitetura de rede recorrente.




Figura A-5 Resultados obtidos com a arquitetura recorrente. Fonte: Elaboração do autor.

A.6 Resultados obtidos com a arquitetura de rede NARX.




Figura A-6 Resultados obtidos com a arquitetura NARX. Fonte: Elaboração do autor.