

**UNIVERSIDADE DE BRASÍLIA
FACULDADE DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA ELÉTRICA**

**ESTUDO PARAMÉTRICO PARA ESTIMAÇÃO NO CURTO
E MÉDIO PRAZO DO PREÇO SPOT DE ENERGIA
ELÉTRICA UTILIZANDO REDES NEURAS**

GUILHERME PIRES SILVA DE ALMEIDA

ORIENTADOR: PROFº DR. PABLO EDUARDO CUERVO

DISSERTAÇÃO DE MESTRADO EM ENGENHARIA ELÉTRICA

PUBLICAÇÃO: PPGENE.DM 485/2012

BRASÍLIA/DF: JULHO – 2012

UNIVERSIDADE DE BRASÍLIA
FACULDADE DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA ELÉTRICA

ESTUDO PARAMÉTRICO PARA ESTIMAÇÃO NO CURTO E MÉDIO
PRAZO DO PREÇO SPOT DE ENERGIA ELÉTRICA UTILIZANDO
REDES NEURAIS

GUILHERME PIRES SILVA DE ALMEIDA

DISSERTAÇÃO DE Mestrado Acadêmico submetida ao Departamento de Engenharia Elétrica da Faculdade de Tecnologia da Universidade de Brasília, como parte dos requisitos necessários para a obtenção do grau de Mestre.

APROVADA POR:



PABLO EDUARDO CUERVO FRANCO, Dr., ENE/UNB
(ORIENTADOR)



ADOLFO BAUCHSPIESS, Dr., ENE/UNB
(EXAMINADOR INTERNO)



FÁBIO STACKE SILVA, Dr., ANEEL
(EXAMINADOR EXTERNO)

Brasília, 13 de julho de 2012.

FICHA CATALOGRÁFICA

ALMEIDA, GUILHERME PIRES SILVA DE

Estudo Paramétrico para Estimação no Curto e Médio Prazo do Preço Spot de Energia Elétrica Utilizando Redes Neurais [Distrito Federal] 2012.

xiv, 117 p. , 210 x 297 mm (ENE/FT/UnB, Mestre, Dissertação de Mestrado – Universidade de Brasília. Faculdade de Tecnologia).

Departamento de Engenharia Elétrica

1.Preço Spot

2. Comercialização de Energia

3.Mercado Brasileiro

4. Redes Neurais

5. Backpropagatio

REFERÊNCIA BIBLIOGRÁFICA

ALMEIDA, G. P. S. (2012). Estudo Paramétrico para Estimação no Curto e Médio Prazo do Preço Spot de Energia Elétrica Utilizando Redes Neurais. Dissertação de Mestrado em Engenharia Elétrica, Publicação PPGENE.DM-485/2012, Departamento de Engenharia Elétrica, Universidade de Brasília, Brasília, DF, 117 p.

CESSÃO DE DIREITOS

AUTOR: Guilherme Pires Silva de Almeida.

TÍTULO: Estudo Paramétrico para Estimação no Curto e Médio Prazo do Preço Spot de Energia Elétrica Utilizando Redes Neurais.

GRAU: Mestre

ANO: 2012

É concedida à Universidade de Brasília permissão para reproduzir cópias desta dissertação de mestrado e para emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte dessa dissertação de mestrado pode ser reproduzida sem autorização por escrito do autor.

Guilherme Pires Silva de Almeida

Universidade de Brasília - Campus Darcy Ribeiro - Faculdade de Tecnologia

Departamento de Engenharia Elétrica - Brasília – DF - CEP: 70910-900

AGRADECIMENTOS

Agradeço primeiramente a Deus por ter me dado forças e sabedoria para chegar até aqui.

Ao meu orientador, professor Dr. Pablo Eduardo Cuervo pelas orientações sempre muito sábias, pela compreensão e principalmente pela confiança depositada.

A minha esposa Lívia Victorio de Carvalho Almeida e ao meu filho Pedro Henrique Solino Pires de Almeida pela compreensão nos momentos de ausência, pelo carinho e apoio nas horas mais difíceis.

Ao Instituto Federal de Educação, Ciência e Tecnologia de Mato Grosso (IFMT) e a UNB pela realização do Programa MINTER - UNB/IFMT, proporcionando capacitação aos servidores da Rede Federal de Ensino.

Aos colegas de mestrado MINTER UNB/IFMT, pelo companheirismo apresentando durante o cumprimento dos créditos do programa.

Ao amigo professor Dr. Valtemir Emerêncio pelos esclarecimentos e apoio durante a realização das pesquisas.

DEDICATÓRIA

Dedico esse trabalho aos meus pais, minha esposa e meu filho que sempre serviram como fonte de inspiração.

RESUMO
ESTUDO PARAMÉTRICO PARA ESTIMAÇÃO NO CURTO E MÉDIO PRAZO DO PREÇO SPOT DE ENERGIA ELÉTRICA UTILIZANDO REDES NEURAIS.

Autor: Guilherme Pires Silva de Almeida

Orientador: Pablo Eduardo Cuervo

Programa de Pós-graduação em Engenharia Elétrica

Brasília, Julho de 2012

A industrialização dos países, os avanços tecnológicos, o crescimento econômico e a necessidade de se criar um mercado mais competitivo, igualitário e que dê sustentação principalmente para o desenvolvimento industrial, fez com que diversos países reformassem seu modelo de mercado energético. Com o mercado energético movimentando grandes quantidades financeiras, entender e tentar prever o preço da energia em tempos futuros vem despertando o interesse de diversas áreas da ciência. Os produtores e os grandes consumidores, por estarem mais suscetíveis às variações dos preços da energia no mercado spot são os maiores interessados nesse assunto. Hoje no Brasil, o preço da energia elétrica é formado pelo custo marginal de operação (CMO) obtido por um programa de otimização (NEWAVE), sendo assim esse trabalho buscou através da utilização de redes neurais artificiais aplicadas na previsão de preços do mercado spot de Energia Elétrica estimar o preço em tempos futuros. Para validar a rede neural foi reproduzido um experimento com dados do mercado da Califórnia com diferentes variações de tempo. Após validar a rede realizou 3 simulações para o mercado da Califórnia e assim como para o mercado brasileiro, sempre considerando diferentes oscilações do preço. As simulações do mercado brasileiro foram treinadas e testadas com 9 combinações de variáveis, buscando medir a eficiência das variáveis para cada modelo. A utilização das redes neurais com os diferentes parâmetros de treinamento e com as diferentes combinações das variáveis se mostrou de um modo geral eficiente, tendo em vista que as redes convergiram para a previsão das tendências do preço da energia ao longo do período, entretanto, para cenários com maior estabilidade, as redes neurais apresentaram melhores resultados.

Palavras Chaves: Preço Spot, Comercialização de Energia, Mercado Brasileiro, Redes Neurais, Backpropagation

ABSTRACT

PARAMETRIC STUDY FOR ESTIMATING THE SHORT AND MEDIUM TERM ELECTRICITY SPOT PRICE USING NEURAL NETWORKS.

Author: Guilherme Pires Silva de Almeida

Supervisor: Pablo Eduardo Cuervo

Programa de Pós-graduação em Engenharia Elétrica

Brasília, July of 2012

Industrialization in countries, technological advances, economic growth and the need to create a more competitive and equal market which gives support, mainly for industrial development, has led many countries to change their energy market model. As the energy market moves huge financial amounts, understanding and trying to predict the price of energy in future times has aroused the interest of several areas of science. Because of being more susceptible to variations in energy prices in spot market, producers and large-scale consumers are the most interested people in this subject. Nowadays, in Brazil, the price of electricity is formed by the marginal cost of operation obtained by an optimization program (NEWAVE), so we try to estimate the energy prices in future times by using artificial neural networks applied to the spot market energy prices forecast. It was made an experiment with data from Californian market with different time variations to validate the neural network. After validating the network, it was held three simulations for Californian market, always considering different price fluctuations as we do for Brazilian market. Brazilian market simulations were trained and tested with nine combinations of variables, trying to measure the efficiency of the variables for each model. The use of neural networks with different training parameters and with different combinations of variables proved to be generally effective since the network converged to predict the trend in energy prices throughout the period under consideration, however, for scenarios with greater stability, the neural networks showed better results.

keywords: Spot Price, Energy Trading, Brazilian Market, Neural Networks, Backpropagation.

SUMÁRIO

1	INTRODUÇÃO	1
1.1	CONSIDERAÇÕES INICIAIS	1
1.2	JUSTIFICATIVA	3
1.3	MOTIVAÇÃO	3
1.4	OBJETIVOS	4
1.5	METODOLOGIA	4
1.6	ESTRUTURA DA DISSERTAÇÃO	7
2	REVISÃO DE LITERATURA	8
2.1	SETOR ELÉTRICO	8
2.1.1	Setor Elétrico: Cenário Nacional	8
2.1.2	Geração de Energia	9
2.1.3	Transmissão de energia	13
2.1.4	Distribuição	13
2.1.5	Instituições do setor elétrico brasileiro	14
2.1.6	O NOVO MODELO	17
2.2	O MERCADO DE ENERGIA NO BRASIL	21
2.2.1	Ambiente de contratação regulada – ACR	22
2.2.2	Ambiente de contratação livre	23
2.2.3	Contratos de Compra e Venda de Energia	24
2.2.4	Papel da ONS e da CCEE em relação aos contratos	25
2.3	O MERCADO SPOT NO BRASIL	26
2.3.1	O Cálculo do Preço Líquido das Diferenças	28
2.3.2	Newave	29
2.3.3	Decomp	30
3	REDES NEURAIIS ARTIFICIAIS	32
3.1	Rede Neural	32
3.1.1	Arquitetura de Rede Neural Artificial	33
3.1.2	As Camadas da Rede	34
3.1.3	Neurônios na Camada Escondida	35
3.1.4	Normalização dos Dados	35

3.1.5	Desempenho da Rede	36
3.1.6	Perceptron Multicamadas.....	38
3.1.7	Algoritmo de Retropropagação	39
4	RESULTADOS.....	40
4.1	RESULTADOS COM DADOS DO MERCADO DA CALIFÓRNIA	40
4.1.1	Primeira Simulação.....	42
4.1.2	Segunda Simulação	45
4.1.3	Terceira Simulação	47
4.1.4	Quarta Simulação.....	49
4.1.5	Quinta Simulação	52
4.1.6	Sexta Simulação.....	54
4.1.7	Média do Erro	56
4.2	Variações de Amostras para Treinamento e Validação	57
4.2.1	Primeira Amostra.....	58
4.2.2	Segunda Amostra	61
4.2.3	Terceira Amostra	64
4.3	Redes Neurais aplicadas ao Mercado Brasileiro.....	67
4.3.1	Primeiro Cenário.....	69
4.3.2	Segundo Cenário	77
4.3.3	Terceiro Cenário	84
5	CONSIDERAÇÕES FINAIS	92
5.1	Número de vetores de treinamento:	92
5.2	Amostras de dados para treinamento:	93
	REFERÊNCIAS BIBLIOGRÁFICAS	97

LISTA DE TABELAS

TABELA 3.1 NÚMERO DE NEURÔNIOS NA CAMADA ESCONDIDA	35
TABELA 4.1 - DIVISÃO DOS VETORES DE TREINAMENTO E TESTE DA REDE NEURAL.....	42
TABELA 4.2 - RESULTADO DA PRIMEIRA SIMULAÇÃO.....	43
TABELA 4.3 - RESULTADOS DO MAPE 2 % DA SEGUNDA SIMULAÇÃO.....	45
TABELA 4.4 - RESULTADOS DO MAPE 2 % DA TERCEIRA SIMULAÇÃO.	48
TABELA 4.5 - RESULTADOS DO MAPE 2 % DA QUARTA SIMULAÇÃO	50
TABELA 4.6 - RESULTADOS DO MAPE 2 % DA QUINTA SIMULAÇÃO	52
TABELA 4.7 - RESULTADOS DO MAPE 2 % DA SEXTA SIMULAÇÃO	54
TABELA 4.8 - MÉDIA DOS MAPE 2 (%) PARA VARIAÇÃO NO TEMPO.....	56
TABELA 4.9 - RESULTADOS DO MAPE 2 (%) PARA A PRIMEIRA AMOSTRA DE DADOS	59
TABELA 4.10 - RESULTADOS DO MAPE 2 (%) PARA A SEGUNDA AMOSTRA DE DADOS	62
TABELA 4.11 - RESULTADOS DO MAPE 2 (%) PARA A TERCEIRA AMOSTRA DE DADOS	64
TABELA 4.12 - COMBINAÇÕES DAS VARIÁVEIS UTILIZADAS NO TREINAMENTO DA REDE	68
TABELA 4.13 – MELHORES RESULTADOS DO SISTEMA 1.1	69
TABELA 4.14 - MELHORES RESULTADOS DO SISTEMA 1.2	71
TABELA 4.15 - MELHORES RESULTADOS DO SISTEMA 1.3	73
TABELA 4.16 - MELHORES RESULTADOS DO SISTEMA 1.4	75
TABELA 4.17 - MELHORES RESULTADOS DO SISTEMA 2.1	77
TABELA 4.18 - MELHORES RESULTADOS DO SISTEMA 2.2	79
TABELA 4.19 - MELHORES RESULTADOS DO SISTEMA 2.3	81
TABELA 4.20 - MELHORES RESULTADOS DO SISTEMA 2.4	83
TABELA 4.21 - MELHORES RESULTADOS DO SISTEMA 3.1	85
TABELA 4.22 - MELHORES RESULTADOS DO SISTEMA 3.2	87
TABELA 4.23 - MELHORES RESULTADOS DO SISTEMA 3.3	88
TABELA 4.24 - MELHORES RESULTADOS DO SISTEMA 3.4	90

LISTA DE FIGURAS

FIGURA 2.1- ORGANOGRAMA DA NOVA ESTRUTURA INSTITUCIONAL DO SETOR ELÉTRICO ..	15
FIGURA 2.2 - FONTES DE ENERGIA POR ESTADO	20
FIGURA 2.3 - VISÃO GERAL DA COMERCIALIZAÇÃO DE ENERGIA	22
FIGURA 2.4 - ENTRADAS E SAÍDAS DO NEWAVE	30
FIGURA 3.1- REDE COM MÚLTIPLAS CAMADAS	33
FIGURA 4.1 - PREÇO DA ENERGIA NO MERCADO ENERGÉTICO DA CALIFÓRNIA – 01/02/99 À 04/04/99.....	41
FIGURA 4.2 - DADOS DO PERÍODO DE 01/02/99 A 04/04/99	41
FIGURA 4.3 - IMPACTO DO AUMENTO DO NÚMERO DE VETORES DE TREINAMENTO SOBRE O MAPE 2 NA PRIMEIRA SIMULAÇÃO.....	44
FIGURA 4.4 - RESULTADO DA SIMULAÇÃO COM MENOR MAPE 2 (%) DA PRIMEIRA SIMULAÇÃO.....	44
FIGURA 4.5 - IMPACTO DO AUMENTO DO NÚMERO DE VETORES DE TREINAMENTO NO MAPE 2 NA SEGUNDA SIMULAÇÃO	46
FIGURA 4.6 - MELHOR RESULTADO E VARIAÇÃO DO ERRO PARA PREVISÃO DE UMA HORA	47
FIGURA 4.7 - IMPACTO DO AUMENTO DO NÚMERO DE VETORES DE TREINAMENTO NO MAPE 2 NA TERCEIRA SIMULAÇÃO.	48
FIGURA 4.8 - MELHOR RESULTADO E VARIAÇÃO DO ERRO PARA PREVISÃO DE UM DIA.....	49
FIGURA 4.9 - IMPACTO DO AUMENTO DO NÚMERO DE VETORES DE TREINAMENTO NA QUARTA SIMULAÇÃO	51
FIGURA 4.10 - MELHOR RESULTADO E VARIAÇÃO DO ERRO PARA PREVISÃO DE UMA SEMANA	51
FIGURA 4.11 - IMPACTO DO AUMENTO DO NÚMERO DE VETORES DE TREINAMENTO NA QUINTA SIMULAÇÃO	53
FIGURA 4.12 - MELHOR RESULTADO E VARIAÇÃO DO ERRO PARA PREVISÃO DE UM MÊS...53	
FIGURA 4.13 - IMPACTO DO AUMENTO DO NÚMERO DE VETORES DE TREINAMENTO NA SEXTA SIMULAÇÃO	55
FIGURA 4.14 - MELHOR RESULTADO E VARIAÇÃO DO ERRO PARA PREVISÃO DE UM ANO ..55	
FIGURA 4.15 - RESULTADO DAS MÉDIAS (MÉDIAS, MÍNIMOS E MÁXIMOS).....	57
FIGURA 4.16 - DIFERENTES AMOSTRAS DO MERCADO DA CALIFÓRNIA	58
FIGURA 4.17 - PRIMEIRA AMOSTRA DE DADOS	59
FIGURA 4.18 - DIVISÃO DA PRIMEIRA AMOSTRA - TREINAMENTO E TESTE.....	60
FIGURA 4.19 - RESULTADO DO MENOR MAPE 2 % DA PRIMEIRA AMOSTRA COM A VARIAÇÃO DE UMA HORA.....	61
FIGURA 4.20 - SEGUNDA AMOSTRA DE DADOS	61
FIGURA 4.21 - DIVISÃO DA SEGUNDA AMOSTRA PARA TREINAMENTO E TESTE.	62
FIGURA 4.22 - RESULTADO DO MENOR MAPE 2 % DA SEGUNDA AMOSTRA COM A VARIAÇÃO DE UMA HORA	63
FIGURA 4.23 - RESULTADO DO MENOR MAPE 2 % DA SEGUNDA AMOSTRA COM A VARIAÇÃO DE UMA SEMANA.....	63
FIGURA 4.24 - TERCEIRA AMOSTRA DE DADOS	64
FIGURA 4.25 - DIVISÃO DA TERCEIRA AMOSTRA - TREINAMENTO E TESTE	65

FIGURA 4.26 - RESULTADO DO MENOR MAPE 2 % DA TERCEIRA AMOSTRA COM A VARIACÃO DE UMA HORA.....	66
FIGURA 4.27 - RESULTADO DO MENOR MAPE 2 % DA TERCEIRA AMOSTRA COM VARIACÃO DE UMA SEMANA	66
FIGURA 4.28 - PREÇO DO MERCADO SUDESTE E CENTRO OESTE (07/2001 À 04/2012).....	67
FIGURA 4.29 - IMPACTO DA QUANTIDADE DE VARIÁVEL DO PRIMEIRO TESTE NO PRIMEIRO SISTEMA PREVISOR	70
FIGURA 4.30 - RESULTADO DO MELHOR MAPE E MAPE 2 DO PRIMEIRO CASO.....	71
FIGURA 4.31 - EVOLUÇÃO DOS RESULTADOS DO MAPE E MAPE 2 DO SISTEMA 1.2.....	72
FIGURA 4.32 - RESULTADO DA REDE COM MENOR MAPE NO SISTEMA 1.2 DO PRIMEIRO CENÁRIO.	73
FIGURA 4.33 - EVOLUÇÃO DOS RESULTADOS DO MAPE E MAPE 2 DO SISTEMA 1.3.....	74
FIGURA 4.34 - RESULTADO DA REDE COM MENOR MAPE NO SISTEMA 1.3	75
FIGURA 4.35 - EVOLUÇÃO DOS RESULTADOS DO MAPE E MAPE 2 DO SISTEMA 1.4.....	76
FIGURA 4.36 - RESULTADO DA REDE COM MENOR MAPE NO SISTEMA 1.4.....	76
FIGURA 4.37 - EVOLUÇÃO DOS RESULTADOS DO MAPE E MAPE 2 DO SISTEMA 2.1.....	78
FIGURA 4.38 - RESULTADO DA REDE COM MENOR MAPE NO SISTEMA 2.1	78
FIGURA 4.39 - EVOLUÇÃO DOS RESULTADOS DO MAPE E MAPE 2 DO SISTEMA 2.2.....	80
FIGURA 4.40 - RESULTADO DA REDE COM MENOR MAPE NO SISTEMA 2.2	80
FIGURA 4.41 - EVOLUÇÃO DOS RESULTADOS DO MAPE E MAPE 2 DO SISTEMA 2.3.....	82
FIGURA 4.42 - RESULTADO DA REDE COM MENOR MAPE NO SISTEMA 2.3	82
FIGURA 4.43 - EVOLUÇÃO DOS RESULTADOS DO MAPE E MAPE 2 DO SISTEMA 2.4.....	83
FIGURA 4.44 - RESULTADO DA REDE COM MENOR MAPE NO SISTEMA 2.4	84
FIGURA 4.45 - EVOLUÇÃO DOS RESULTADOS DO MAPE E MAPE 2 DO SISTEMA 3.1.....	85
FIGURA 4.46 - RESULTADO DA REDE COM MENOR MAPE NO SISTEMA 3.1	86
FIGURA 4.47 - EVOLUÇÃO DOS RESULTADOS DO MAPE E MAPE 2 DO SISTEMA 3.2.....	87
FIGURA 4.48 - RESULTADO DA REDE COM MENOR MAPE NO SISTEMA 3.2	88
FIGURA 4.49 - EVOLUÇÃO DOS RESULTADOS DO MAPE E MAPE 2 DO SISTEMA 3.3.....	89
FIGURA 4.50 - RESULTADO DA REDE COM MENOR MAPE NO SISTEMA 3.3	89
FIGURA 4.51 - EVOLUÇÃO DOS RESULTADOS DO MAPE E MAPE 2 DO SISTEMA 3.4.....	91
FIGURA 4.52 - RESULTADO DA REDE COM MENOR MAPE NO SISTEMA 3.4	91

LISTA DE SIGLAS

ACL – Ambiente de Contratação Livre
ACR – Ambiente de Contratação Regulada
ANEEL – Agência Nacional de Energia Elétrica
APE – Auto-produtores de Energia
APE-COM – Auto-produtores com Comercialização de Excedente
BCM – Billion Cubic Metres
BNDES – Banco Nacional do Desenvolvimento
CCEE – Câmara de Comercialização de Energia Elétrica
CCVE – Contrato de Compra e Venda de Energia Elétrica
CD – Carga de Demanda
CDE – Conta de Desenvolvimento Energético
CE – Carga de Energia
CEPEL – Centro de Pesquisa de Energia Elétrica
CGH – Centrais Geradoras Hidrelétricas
CMO – Custo Marginal de Operação
CMSE – Comitê de Monitoramento do Setor Elétrico
CNPE – Conselho Nacional de Política Energética
COM – Comercializadores de Energia
EIA – Energy Information Administration
EOL – Usinas Eólicoelétricas.
EPE – Empresa de Pesquisa Energética
FCF – Função de Custo Futuro (FCF).
FCI – Função de Custo Imediato
IBGE – Instituto Brasileiro de Geografia e Estatística
KV – Kilovolt
KW – kilowatt
MAE – Mean Absolute Error
MAE – Mercado Atacadista de Energia – MAE
MAPE – Erro Percentual Médio Absoluto
ME – Mean Error
MME – Ministério de Minas e Energia
MPE – Mean Percentage Error

MSE – Mean Squared Error
Mteo – Million Tonne Of Oil Equivalent
MVA – Mega-volts-àmpere
MWh – Megawatt Hora
ONS – Operador Nacional do Sistema
PCH – Pequenas Centrais Hidrelétricas
PIE – Produtores Independentes
PLD – Prelo Liquido das Diferenças
PMS – Preço Marginal do Sistema
PROINFA – Programa de Incentivo às Fontes Alternativas de Energia Elétrica
REG – Registrados (REG)
SIN – Sistema Interligado Nacional
SP – Serviço Público
UFV – Usinas Fotovoltaicas
UTN – Usinas Nucleares.

1 INTRODUÇÃO

1.1 CONSIDERAÇÕES INICIAIS

A industrialização dos países, os avanços tecnológicos, o crescimento econômico e a necessidade de se criar um mercado mais competitivo, igualitário e que dê sustentação principalmente para o desenvolvimento industrial, fez com que diversos países reformassem seu modelo de mercado energético. Uns preferiram adotar um modelo mais descentralizado onde o preço da energia é definido de acordo com a oferta e a procura (livre concorrência) como, por exemplo, Espanha e Portugal; já outros como o Brasil, adotaram um modelo mais centralizado tendo no estado a figura central do mercado. Neste caso o estado é responsável por fiscalizar a geração, a transmissão, a distribuição e a comercialização da energia elétrica.

O processo de reestruturação do setor elétrico brasileiro começou em meados dos anos 90, sendo que algumas entidades foram criadas, outras tiveram suas funções alteradas e algumas foram até mesmo extintas. Em 1995, a Lei nº 9.074 cria a figura de dois agentes que ainda não existiam no setor brasileiro: o Produtor Independente de Energia e o conceito de Consumidor Livre, aumentando a concorrência no ramo de geração e consumo de energia.

Dando continuidade às mudanças, em 1996 o Ministério de Minas e Energia coordenou o Projeto de Reestruturação do Setor Elétrico Brasileiro que culminou na desverticalização das empresas de energia elétrica. A segmentação buscou dar mais competitividade aos setores de geração e comercialização.

Mesmo com as mudanças já mencionadas, em 2001 o setor enfrentou uma grande crise que resultou em um racionamento de energia elétrica fazendo com que o governo criasse um Comitê de Revitalização do Modelo do Setor Elétrico para propor novas mudanças e corrigir os problemas. As propostas do comitê entraram em vigor nos anos de 2003 e 2004 sustentadas pelas Leis nº 10.847 e 10.848, de 15 de março de 2004, e pelo Decreto nº 5.163, de 30 de julho do mesmo ano. As principais mudanças introduzidas com essas novas leis foram em relação à comercialização de energia, com a criação do Ambiente de

Contratação Regulada (ACR) e o Ambiente de Contratação Livre (ACL).

No Ambiente de Contratação Regulada a contratação é formalizada através de contratos bilaterais regulados, denominados Contratos de Comercialização de Energia Elétrica no Ambiente Regulado (CCEAR) realizado entre os agentes vendedores e os compradores que participam dos leilões de compra e venda de energia elétrica. No Ambiente de Contratação Livre é permitida a livre negociação entre os Agentes Geradores, Comercializadores, Consumidores Livres, Importadores e Exportadores de energia.

A Câmara de Comercialização de Energia Elétrica é o operador do mercado spot brasileiro, centralizando todas as transações de compra e venda de energia, controlando os custos associados diretamente ao despacho econômico. O preço marginal do sistema (PMS) é calculado de forma ex-ante com bases semanais é utilizado como o valor do Preço Líquido das Diferenças – PLD. Hoje o processo completo de cálculo do preço spot consiste na utilização dos modelos computacionais NEWAVE e DECOMP, os quais produzem como resultado o custo marginal de operação de cada submercado, respectivamente em horizonte de tempo mensal e semanal [1].

O mercado energético em todo mundo movimenta grandes quantidades financeiras e entender e tentar prever o preço da energia em tempos futuros vem despertando o interesse de diversas áreas da ciência. Os produtores e os grandes consumidores, por estarem mais suscetíveis às variações dos preços da energia no mercado spot são os maiores interessados nesse assunto.

Diversos estudos estão sendo aplicados no mercado energético, como por exemplo: modelos de otimização estocástica para calcular aversão ao risco no mercado futuro de energia [2], transformadas wavelet para prever o preço spot no espaço de tempo futuro [3], método ARIMA para prever o preço spot [4] e redes neurais para também estimar o preço spot de energia no futuro [5].

Neste trabalho foram utilizadas redes neurais de multicamadas para estimar o preço spot de energia elétrica do mercado brasileiro.

1.2 JUSTIFICATIVA

Em um mercado de eletricidade competitivo, uma acurada previsão dos preços da energia é uma atividade importante para todos os participantes do mercado, quer para o desenvolvimento de estratégias de compra e venda ou para tomada de decisões em futuros investimentos [6].

Para tornar-se competitivo no mercado e obter um aumento na margem de lucro, ou até mesmo procurar mitigar seu risco em relação a prejuízos, é imprescindível para os participantes do mercado, identificarem a tendência do preço spot. Os compradores ou vendedores que reduzirem seu cenário de incerteza poderão tomar decisões mais acertadas em suas negociações, já que na maioria das vezes as utilizações de modelos de previsão apesar de não fornecem o preço exato da energia no futuro, em um mercado com condições normais são capazes de identificarem a tendência de alta ou baixa.

Mesmo com alguns estudos já realizados nessa área, que buscaram fazer uma modelagem da formação do preço de energia elétrica no mercado de curto prazo e o estudo de redes neurais artificiais aplicadas na previsão de preços do mercado spot de Energia Elétrica, novas pesquisas são fundamentais para o aperfeiçoamento das técnicas de previsão do preço spot em especial no mercado brasileiro, para dar suporte aos participantes do mercado de energia em suas tomadas de decisões [7] [8].

1.3 MOTIVAÇÃO

Conseguir estimar o preço da energia elétrica no mercado *spot* em intervalos de tempos futuros pode agregar grande poder de competitividade aos participantes do mercado. Uma ferramenta capaz de prever a tendência do preço da energia faz com que os agentes do mercado planejem de forma melhor seus posicionamentos.

Diante da escassez de estudos do mercado de energia brasileiro, é extremamente importante fazer uma análise mais detalhada do funcionamento das redes neurais com dados deste mercado, introduzir variáveis exógenas como o preço do petróleo no cenário mundial e os dados da atividade industrial brasileira. Realizar uma análise com dados de outros mercados, que possuem uma metodologia totalmente diferente na formação do

preço *spot*. Na maioria das vezes os dados utilizados para a previsão são o preço, a carga do sistema e a energia disponível [9].

1.4 OBJETIVOS

Geral:

Utilizar redes neurais para previsão do preço de energia no mercado spot para auxiliar os agentes (compradores, vendedores e revendedores) em suas tomadas de decisão.

Específicos:

Apresentar uma revisão bibliográfica do setor elétrico, do mercado de energia e das redes neurais.

Realizar a estimação futura do preço de energia no mercado spot da Califórnia e do Brasil através do Backpropagation utilizando variações do Levenberg Marquardt com diferentes parâmetros de treinamento e diferentes variações de tempo.

Estudar como variações do tempo, quantidade de variáveis, tamanho das amostras de treinamento e cenários com grandes oscilações do preço afetam o resultado da previsão.

1.5 METODOLOGIA

Para alcançar os objetivos propostos por este trabalho foram realizados os seguintes procedimentos metodológicos:

Objetivo: Apresentar uma revisão bibliográfica do setor elétrico, do mercado de energia e das redes neurais.

Procedimento: Realizou-se uma extensa revisão bibliográfica nas mais diversas fontes de consulta tais como anais, periódicos, sites, livros, dissertações e teses .

Objetivo: Realizar a estimação futura do preço de energia no mercado spot da Califórnia e do Brasil através do Backpropagation utilizando variações do Levenberg Marquardt com diferentes parâmetros de treinamento e diferentes variações no tempo.

Procedimento: Para realizar a previsão futura foi necessário formar uma base de dados de diversas fontes, tais como:

- 1) Mercado da Califórnia: compreendem dados do Preço, Volume Fornecido e Volume de Demanda do mercado da Califórnia no período de 1998 à 2000 [10].
- 2) Histórico de operação: compreendem dados de Geração de Energia, Carga de Energia, Carga de Demanda, Intercâmbio entre as Regiões, Energia Natural Afluente, Volume Útil dos Principais Reservatórios e Energia Armazenada que estão disponíveis no site da ONS [11]. Todas as informações foram levantadas mensalmente considerando o período de Julho de 2001 até Abril de 2012.
- 3) Instituto Brasileiro de Geografia e Estatística (IBGE): Compreendem dados de Atividade Industrial (Indústrias Extrativa e de Transformação), dentre os quais foram coletadas informações sobre: Índices mensais de produção física da industrial em geral, dados da indústria extrativista e dados da indústria de transformação, que estão disponíveis no site do IBGE, na parte de séries estatísticas e séries históricas [12]. Essas informações também foram levantadas mensalmente considerando o período de julho de 2001 até Abril de 2012.
- 4) Preço do Barril de Petróleo: Foram coletados os preços do Barril de Petróleo BRENT e WTI, disponível no site da EIA [13].
- 5) Comercialização de Energia: Foram coletados dados do Preço de Liquidação das Diferenças (PLD) para o período de Julho de 2001 à Abril de 2012, disponíveis no site da CCEE [14]. A CCEE fornece os valores do PLD para três patamares de carga (pesada, média e leve) cada qual para o submercado do sistema elétrico brasileiro (Norte, Nordeste, Sudeste/Centro-Oeste e Sul). As informações coletadas para este item foram do patamar de carga pesada do submercado Sudeste/Centro-Oeste.

Estas informações foram todas sistematizadas em planilhas eletrônicas.

Para utilizar as redes neurais deve ser utilizados o maior número possível de informações sobre o problema, pois com um número maior de informações os resultados da rede tendem a serem melhores. As redes neurais utilizam dados para treinamento, que serão os dados de entrada, os dados de saída (resultado da rede neural) e o objetivo (target ou alvo). Os dados de entrada para o mercado da Califórnia foram constituídos pelos dados históricos de operação assim como os dados de entrada do mercado brasileiro foi

constituído pelos dados do histórico de operação, dados do Instituto Brasileiro de Geografia e Estatística (IBGE), Preço do Barril de Petróleo e valores do PLD. Os dados do mercado da Califórnia são disponibilizados por hora para todos os dias do ano. Entretanto, os diversos tipos de dados referentes ao mercado brasileiro devem estar padronizados de forma a terem o mesmo número de registros para que estes possam ser utilizados nas estruturas das redes neurais. Com exceção do PLD, cuja informação é disponibilizada semanalmente, todas as demais informações são fornecidas com periodicidade mensal. Portanto, para não reduzir o número de dados (fazendo, por exemplo, uma média dos valores semanais que comporiam o valor mensal, procedimento este que poderia comprometer o resultado da rede), optou-se pela utilização dos valores de referência do PLD semanalmente, sendo necessária a projeção de valores mensais dos demais parâmetros para que tivessem o mesmo número de registros. Desta forma, os dados foram repetidos para todas as semanas de referência do respectivo mês. Este procedimento foi realizado através de um algoritmo criado no MATLAB versão 2011, lendo a planilha com as informações e criando uma planilha única. Utilizando os dados da CCEE foi formulada uma planilha com os dados do PLD para ser utilizada na verificação da eficiência do modelo, comparando com o resultado de saída da rede neural.

A técnica utilizada foi a de deslocamento de janela no tempo, onde o deslocamento é o tempo futuro que se busca prever. Dessa forma os dados de entrada estão sempre defasados em relação ao alvo. Por exemplo, se o objetivo foi prever o valor do PLD da semana 2 (dois), será utilizado como dados de entrada os valores da semana 1 (um) tendo na planilha do PLD somente o valor da semana 2 (dois). O mesmo se aplicou a qualquer outro período de previsão quer seja por hora, diário, semanal, mensal ou anual.

Ainda em relação aos dados do mercado brasileiro, cabe ressaltar que optou-se por fazer um recorte do submercado Sudeste/Centro-Oeste tendo em vista que este é o maior mercado consumidor e suas particularidades refletem as características dos demais mercados.

Foi implementado um algoritmo no MATLAB 11, responsável por fazer todas as simulações e testes das redes com diferentes parâmetros de treinamento e variações de tempo.

Objetivo: Estudar como variações do tempo, quantidade de variáveis, tamanho das amostras de treinamento e cenários com grandes oscilações do preço afetam o resultado da previsão.

Procedimento: Após os treinamentos e testes, os resultados das redes foram tabulados em planilhas eletrônicas e gráficos foram gerados para análise do desempenho das redes mediante os dados apresentados.

1.6 ESTRUTURA DA DISSERTAÇÃO

Para alcançar o objetivo principal desse trabalho foi realizada uma extensa revisão bibliográfica para contextualização do setor elétrico brasileiro e das redes neurais. Sendo assim, o trabalho está estruturado da seguinte forma:

- Capítulo 2 apresenta uma contextualização do setor elétrico brasileiro, sua história, o mercado de energia no Brasil e mercado spot brasileiro;
- Capítulo 3 faz uma revisão bibliográfica sobre redes neurais artificiais, suas características e o algoritmo backpropagation;
- Capítulo 4 realiza uma demonstração sistemática dos resultados, demonstrando via tabelas e gráficos e uma descrição dos resultados obtidos;
- Capítulo 5 apresenta a conclusão final do trabalho.

2 REVISÃO DE LITERATURA

2.1 SETOR ELÉTRICO

2.1.1 Setor Elétrico: Cenário Nacional

O Setor elétrico brasileiro está em constante crescimento, onde mais de 95% da população brasileira tem acesso à rede elétrica [15]. O serviço está presente em 99% dos municípios do país e em 2010 chegou a 68,6 milhões de unidades consumidoras, sendo este número 39% maior que o de 2001, quando o país possuía 49,35 milhões de unidades consumidoras [16].

As unidades consumidoras estão divididas em unidades de classe residencial, setor de comércio, serviços e outras atividades, setor industrial, setor público e setor de agricultura. As unidades residenciais representam a maioria (85,02%), ou seja, 58,3 milhões de unidades, seguidas pelo setor de comércio, serviços e outras atividades com 4,96 milhões (7,23%), ligações rurais com 4,07 milhões (5,93%), setor público com 586,95 mil unidades (0,85%), o setor industrial com 72,3 mil ligações (0,83%), iluminação pública com 76,5 mil (0,11%), e por fim as unidades consideradas de consumo próprio, com 8,4 mil unidades consumidoras (0,01%).

Dentre as fontes de energia, a geração de energia hidráulica é dominante, uma vez que o Brasil é um dos países mais ricos do mundo em recursos hídricos [17]. Buscando aproveitar os recursos hídricos e considerando a extensão territorial do país, o parque gerador brasileiro predominantemente hidráulico teve muito dos seus empreendimentos na geração de energia construídos longe dos grandes centros consumidores, sendo assim necessário o desenvolvimento de um extenso sistema de transmissão. Deste modo, devido ao tamanho e características muitas vezes não encontradas em nenhum outro lugar do mundo o setor elétrico brasileiro pode ser considerado como único em âmbito mundial.

O Sistema Elétrico Nacional é composto pelo Sistema Interligado Nacional (SIN) e pelos Sistemas Isolados [15]. O Sistema Interligado Nacional é formado pelas empresas das regiões Sul, Sudeste, Centro-Oeste, Nordeste e parte da região Norte formando quatro subsistemas denominados: Subsistema Sudeste/Centro-Oeste, Subsistema Sul, Subsistema

Nordeste e Subsistema Norte [18]. O SIN é uma imensa “rodovia elétrica” composta por usinas geradoras, linhas de transmissão e ativos de distribuição [15]. O sistema foi constituído ao longo do tempo por conexões dos sistemas inicialmente restritos ao atendimento exclusivo das regiões de origens. Em 2008, o SIN era composto aproximadamente por 900 linhas de transmissão que juntas somavam 89,2 mil quilômetros nas tensões de 230, 345, 440, 500 e 750 kV.

O SIN abriga 96,6% de toda a capacidade de produção de energia do país. A integração permite que a energia produzida em uma região possa ser despachada pra outra que esteja com seus reservatórios mais baixos, evitando a falta de energia ou aumento do preço.

Apesar do SIN interligar as quatro regiões do Brasil ainda existem alguns sistemas de menor porte que não estão conectados e por isso são chamados de Sistemas Isolados. Tais sistemas estão localizados principalmente na região Norte, nos Estados do Amazonas, Roraima, Acre, Amapá e Rondônia [15], não permitindo o intercambio de energia com outras regiões. Mesmo atendendo somente 3% da população (cerca de 1,3 milhões de consumidores espalhados por 380 localidades) tal sistema abrange uma área de 45% do território brasileiro, sendo composto por apenas 3,4% da capacidade de produção de eletricidade do Brasil. Desta forma, uma das regiões mais ricas em recursos hídricos ainda é abastecida por um sistema isolado, refletindo a falta de investimento no setor e problemas de ordem ambiental. Ademais, como os sistemas isolados estão localizados principalmente na região Amazônica onde temos floresta densa, rios caudalosos e extensos, a dificuldade é maior para construir linhas de transmissão de grande porte.

O Sistema Isolado é composto em sua maior parte por usinas térmicas movidas a óleo diesel e a óleo combustível, sendo que o sistema também é composto por Pequenas Centrais Hidrelétricas (PCH's), Centrais Geradoras Hidrelétricas (CGH's) e termelétricas movidas a biomassa.

2.1.2 Geração de Energia

A geração de energia se dá através de fontes renováveis e não renováveis. Compreendem-se por fontes renováveis as fontes de energia que são disponibilizadas na natureza de forma cíclica, estando entre elas energia hidráulica, biomassa, e outras fontes (energia eólica,

solar, biogás, geotérmica e mar) [19]. Já as fontes não renováveis são aquelas que se encontram na natureza em quantidades limitadas e se extinguem com a sua utilização, estando entre elas gás natural, derivados de petróleo, energia nuclear e carvão mineral ou vegetal.

Em termos mundiais a geração de energia hidráulica tem uma participação na matriz energética pouca expressiva e paradoxalmente tende a diminuir ainda mais nos próximos anos, pois por várias questões vem sendo preferencialmente exploradas fontes não renováveis, sendo que estas terão seu esgotamento a médio e longo prazo. Muitas controvérsias se colocam diante da utilização desta fonte que requer a construção de usinas que geram grandes áreas de alagamento causando importantes impactos ambientais e muitas vezes sociais [15]. No Brasil 81.951.496,23 KW são gerados a partir de fontes hidráulicas, compreendendo 70,68% da energia produzida no país, ao contrário do que se vê no cenário mundial onde em 2009 só 2,3% da energia produzida no mundo foi hidráulica de um total de 12150 Mteos gerados [20], mesmo essa fonte energética produzindo energia limpa e mais barata para o consumidor.

A geração de energia elétrica a partir da biomassa passa pela conversão de diferentes matérias primas como madeira, soja, milho, cana-de-açúcar, e até mesmo rejeitos urbanos e industriais (sólidos ou líquidos, como o lixo) em energia. A geração de energia através de biomassa esbarra na necessidade de uma grande quantidade de biomassa florestal ou uma grande quantidade de biomassa. A produção de etanol em 2010/2011 foi de 27,6 bilhões de litros, tendo um aumento de 7% em relação a 2009/2010 [21].

A produção de energia elétrica através de outras fontes está muitas vezes relacionada ao apoio governamental por meio de programas oficiais que abrangem variáveis como aquisição compulsória por parte das empresas de energia elétrica locais, subsídios, tarifas especiais, desoneração fiscal ou aporte direto de recursos. Dentre as outras fontes destaca-se a energia eólica, fotovoltaica (solar) mar e geotérmica [15].

De maneira geral, o custo de produção ainda é caro. Por exemplo, em 2008, no Brasil, o preço da energia eólica era de R\$ 230,00 por MWh, enquanto o preço da energia hidrelétrica estava em torno dos R\$ 100,00 por MWh. O Brasil tem grande potencial na geração de energia fotovoltaica devido à grande incidência solar e um enorme potencial na

geração de energia eólica principalmente nas regiões Nordeste, Sul e Sudeste [15]. A energia produzida por outras fonte no Brasil é de aproximadamente 1.261.329 kW de potência fiscalizada¹ representando 1,09 % da energia produzida no país.

O gás natural foi a fonte de energia de origem fóssil que teve o maior crescimento no mundo no século XX, sendo que a sua produção passou de 1.226 bcm em 1973 para 3.282 bcm em 2010, tendo um aumento na sua participação na matriz energética mundial de 16% para 20% [15]. A média da produção em 2010 foi de 62,8 milhões de m³/dia, sendo 8,5% maior em comparação a produção do ano de 2009 [22]. Somando a produção nacional à importação diária (34,6 milhões de m³/dia) a participação do gás natural na matriz energética brasileira chegou ao patamar de 10,3%. Houve no ano de 2010 um aumento na demanda dessa fonte energética no mercado interno em função do crescimento de alguns setores da economia.

Em 2009 o carvão foi a segunda maior fonte de energia na matriz energética mundial correspondendo a 27,2 % de toda energia produzida no mundo [23]. Diferente do cenário mundial a geração de energia através da utilização do carvão no Brasil se restringe a 1,3% da energia produzida [22]. O carvão pode ser dividido em dois tipos: o vegetal (obtido através da carbonização da lenha) e o mineral (formado pela decomposição da matéria orgânica durante milhões de anos). A produção, através desta fonte, muitas vezes gera a degradação de grandes extensões de terras e durante o seu consumo emite grandes quantidades de gás carbônico (CO₂). A problemática fica evidenciada tanto na degradação dos elementos da natureza (água, ar, relevo, solo, vegetação e fauna) quanto naqueles da sociedade [24].

Outra possibilidade de geração de energia é a utilização de usinas nucleares, que usam o urânio enriquecido como matéria prima. A energia produzida é considerada como limpa devido à baixa emissão de gás carbônico (CO₂), porém há que se considerarem os dejetos radioativos que precisam ser muito bem armazenados para não causarem acidentes nucleares [15]. O urânio é encontrado em abundância na natureza, garantindo a segurança do suplemento em longo prazo, entretanto, o mercado das usinas nucleares não cresceu muito nos últimos anos, devido a alguns fatores negativos como o alto investimento para

¹ A potência fiscalizada é aferida quando a primeira unidade geradora entra em operação comercial. As porcentagens referem-se à potência fiscalizada.

construção das usinas bem como a relação do enriquecimento do urânio com a construção de bombas atômicas. O processo tecnológico de enriquecimento do urânio é dominado por poucos países e muito fiscalizado em todo mundo, levando até mesmo algumas nações entrarem em conflito. No mundo a utilização de energia nuclear em 2009 representava 5,8% da energia produzida [23]. Já no Brasil, em 2010, representou 2,7% da matriz energética [22].

O petróleo é a fonte de energia mais utilizada no mundo para produção de energia elétrica [23] sendo que 32,8% de toda a energia produzida no mundo provieram-se da sua utilização no ano de 2009. Em contrapartida, no Brasil, essa fonte energética contribuiu apenas com 3,6% da energia gerada em 2010, refletindo a característica da matriz energética brasileira [22]. Com a descoberta da PETROBRÁS de uma imensa reserva de petróleo na camada pré-sal o Brasil fica no mesmo nível dos grandes produtores mundiais, tendo assim autossuficiência no recurso. A expectativa é que em todo o pré-sal tenha mais de 30 bilhões de barris, porém a exploração exigirá elevados investimentos e novos avanços tecnológicos. Como o petróleo é a principal fonte primária da matriz energética mundial o Brasil ficou em situação estratégica com a descoberta na camada do pré-sal [15].

Em relação aos empreendimentos, o Brasil, em julho de 2011, tinha 2.511 empreendimentos em funcionamento, correspondendo a uma capacidade instalada de 116.138.066 KW de potência [25]. Do total de usinas, 180 são hidrelétricas, 1.484 são térmicas abastecidas por fontes diversas como gás natural, biomassa, óleo diesel e óleo combustível, 412 Pequenas Centrais Hidrelétricas (PCH's), 2 nucleares (UTN), 63 centrais geradoras eólicas (EOL), 6 usinas fotovoltaicas (UFV) e 364 centrais geradoras hidrelétricas (CGH's).

O setor elétrico brasileiro conta com 1.327 agentes investindo no mercado de geração de energia que podem atuar em vários destinos. Deste modo, 1.009 atuam como produtores independentes (PIE), 937 registrados (REG), 243 auto-produtores de energia (APE), 93 serviço público (SP), 37 auto-produtores com comercialização de excedente (APE-COM) e 4 comercializadores de energia (COM).

Nos próximos anos o setor tem a expectativa de mais 51.069.551 kW de potência, gerados através de 658 novos empreendimentos, sendo que 149 já estão em fase de construção com previsão de 27.512.723 kW de capacidade.

2.1.3 Transmissão de energia

Como o volume de geração de energia no Brasil é constituído em sua maior parte por usinas hidrelétricas, muitas vezes instaladas longe dos grandes centros consumidores, o Brasil tem um dos maiores sistemas de transmissão de energia do mundo, totalizando aproximadamente 102 mil quilômetros de linhas [26].

Em 2008 esse segmento era composto por 64 concessionárias. Após conseguirem as concessões através de leilões públicos realizados pela ANEEL, as empresas vencedoras são responsáveis pela implantação e operação da rede que liga as usinas às instalações das companhias distribuidoras localizadas junto aos centros consumidores.

As concessões de transmissão são válidas por 30 anos podendo ser prorrogadas por igual período [15]. Em 2008 foi realizado o leilão da maior Linha de Transmissão do mundo (que ainda não está em funcionamento) com uma extensão de 2.400 km que será responsável pela conexão das usinas do complexo do rio Madeira com o Sistema Interligado Nacional.

Diante da necessidade de expansão da rede de transmissão os investimentos no setor não param. Em novembro de 2011 a ANEEL aprovou a realização do leilão de 09 lotes com 11 linhas de transmissão num total de 1.378 quilômetros (Km), e 12 subestações com 4.637 Mega-volts-ampere (MVA) de potência. O custo dos investimentos é de aproximadamente R\$ 1,6 bilhão, com geração de 8,5 mil empregos diretos [27].

2.1.4 Distribuição

As distribuidoras são o elo entre o setor de energia elétrica e a sociedade, sendo responsáveis pela conexão e atendimento ao consumidor, independente do seu porte. Elas não produzem energia, recebendo das companhias de transmissão todo o suprimento destinado ao abastecimento no país. O Brasil em 2011 tinha 63 concessionárias estatais ou privadas compondo o mercado de distribuição e atendendo mais de 61 milhões de unidades consumidoras. O mercado de distribuição de energia brasileiro tornou-se bastante atrativo

financeiramente, atraindo assim investidores de várias partes do mundo. As distribuidoras recebem a energia na tensão que pode variar de 88 kV (quilovolts) a 750 kV e transformam em 127 volts ou 220 volts. Isso para atender usuários de pequeno porte, pois para atender unidades industriais que operam com tensões mais elevadas (de 2,3 kV a 88 kV) as distribuidoras utilizam-se das chamadas redes de subtransmissão que vão direto da subestação da distribuidora [28].

A União, ao celebrar o contrato de concessão, define quais são os direitos e as obrigações da distribuidora que irá explorar o serviço público na área concedida. Como as distribuidoras também têm responsabilidades sociais, elas executam alguns programas de cunho social como o Baixa Renda (com tarifas diferenciadas para consumidores que atendam a determinadas especificidades de consumo e renda), o Luz para Todos (que busca a universalização da energia elétrica) e o programa de regularização das ligações clandestinas (combatendo o acesso ilegal à energia elétrica sem o pagamento da correspondente fatura). As distribuidoras são as responsáveis pela emissão das faturas mensais da energia elétrica consumida.

2.1.5 Instituições do setor elétrico brasileiro

O Ministério de Minas e Energia (MME), com assessoramento do Conselho Nacional de Política Energética (CNPE) e do Congresso Nacional, é responsável pela formulação de políticas para o setor de energia elétrica.

Em 2004, por meio das leis nº 10.847/2004 e nº 10.848/2004 o governo federal implantou o novo modelo do setor elétrico, definindo a nova estrutura institucional do setor elétrico brasileiro. A Figura 2.1 apresenta um organograma da nova estrutura e em seguida a descrição dos órgãos e entidades envolvidas nessa nova conjectura e as suas respectivas funções.

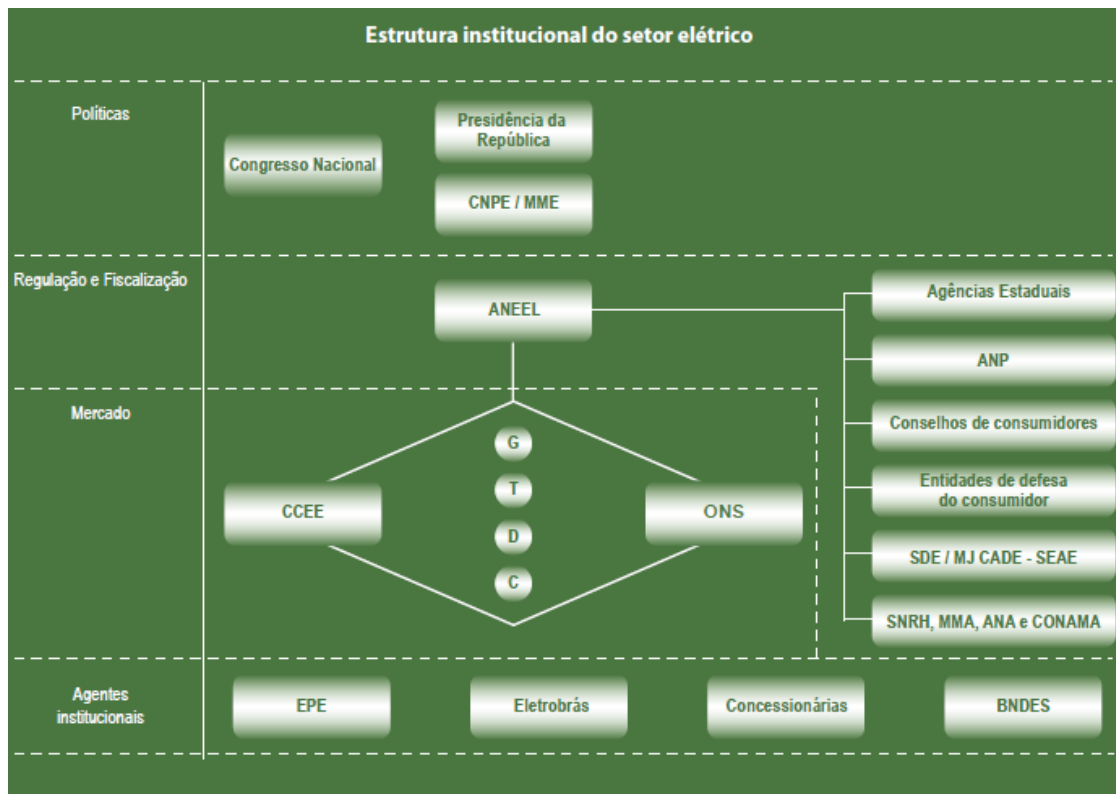


Figura 2.1- Organograma da Nova Estrutura institucional do setor elétrico

Fonte: Adaptado do Atlas de energia elétrica do Brasil [15]

2.1.5.1 Conselho Nacional de Política Energética (CNPE)

O CNPE é um órgão interministerial de assessoramento à Presidência da República, tendo como principais atribuições formular políticas e diretrizes de energia, assegurar o suprimento de insumos energéticos às áreas mais remotas ou de difícil acesso no país, rever periodicamente as matrizes energéticas aplicadas às diversas regiões do país, estabelecer diretrizes para programas específicos como o de uso do gás natural, do álcool, de outras biomassas, do carvão e da energia termonuclear, além de estabelecer diretrizes para a importação e exportação de petróleo e gás natural. [15]

2.1.5.2 Ministério de Minas e Energia (MME)

O MME é o órgão do Governo Federal responsável pela condução das políticas energéticas do país. Suas principais obrigações incluem a formulação e implementação de políticas para o setor energético, de acordo com as diretrizes definidas pelo CNPE. O MME é responsável por estabelecer o planejamento do setor energético nacional, monitorar a

segurança do suprimento do Setor Elétrico Brasileiro e definir ações preventivas para restauração da segurança de suprimento no caso de desequilíbrios conjunturais entre oferta e demanda de energia. [15].

2.1.5.3 Empresa de Pesquisa Energética (EPE)

Instituída pela Lei nº 10.847/04 e criada pelo Decreto nº 5.184/04, a EPE é uma empresa vinculada ao MME, cuja finalidade é prestar serviços na área de estudos e pesquisas destinadas a subsidiar o planejamento do setor energético. Suas principais atribuições incluem a realização de estudos e projeções da matriz energética brasileira, execução de estudos que propiciem o planejamento integrado de recursos energéticos, desenvolvimento de estudos que propiciem o planejamento de expansão da geração e da transmissão de energia elétrica curto, médio e longo prazo, realização de análises de viabilidade técnico-econômica e socioambiental de usinas, bem como a obtenção da licença ambiental prévia para aproveitamentos hidrelétricos e de transmissão de energia elétrica [15].

2.1.5.4 Comitê de Monitoramento do Setor Elétrico (CMSE)

O CMSE é um órgão criado no âmbito do MME, sob sua coordenação direta, com a função de acompanhar e avaliar a continuidade e a segurança do suprimento elétrico em todo o território nacional. Suas principais atribuições incluem: acompanhar o desenvolvimento das atividades de geração, transmissão, distribuição, comercialização, importação e exportação de energia elétrica; avaliar as condições de abastecimento e de atendimento; realizar periodicamente a análise integrada de segurança de abastecimento e de atendimento; identificar dificuldades e obstáculos que afetem a regularidade e a segurança de abastecimento e expansão do setor; e elaborar propostas para ajustes e ações preventivas que possam restaurar a segurança no abastecimento e no atendimento elétrico [15].

2.1.5.5 Agência Nacional de Energia Elétrica (ANEEL)

A ANEEL foi instituída pela Lei nº 9.247/96 e constituída pelo Decreto nº 2.335/97, com as atribuições de regular e fiscalizar a produção, transmissão, distribuição e comercialização de energia elétrica, zelando pela qualidade dos serviços prestados, pela universalização do atendimento e pelo estabelecimento das tarifas para os consumidores

finais, preservando a viabilidade econômica e financeira dos agentes e da indústria. As alterações promovidas em 2004 pelo modelo vigente do setor estabeleceram como responsabilidade da ANEEL, direta ou indiretamente, a promoção de licitações na modalidade de leilão, para a contratação de energia elétrica pelos Agentes de Distribuição do Sistema Interligado Nacional [15].

2.1.5.6 Operador Nacional do Sistema Elétrico (ONS)

O ONS foi criado pela Lei nº 9.648/98, e regulamentado pelo Decreto nº 2.655/98, com as alterações do Decreto nº 5.081/04, para operar, supervisionar e controlar a geração de energia elétrica no SIN, e administrar a rede básica de transmissão de energia elétrica no Brasil, com o objetivo principal de atender os requisitos de carga, otimizar custos e garantir a confiabilidade do sistema, definindo ainda, as condições de acesso à malha de transmissão em alta-tensão do país. As alterações implantadas a partir de 2004 trouxeram maior independência à governança do ONS, através da garantia de estabilidade do mandato de sua diretoria [15].

2.1.5.7 Câmara de Comercialização de Energia Elétrica (CCEE)

A CCEE, instituída pela Lei nº 10.848/04 e criada pelo Decreto nº 5.177/04, absorveu as funções e estruturas organizacionais e operacionais do extinto Mercado Atacadista de Energia – MAE. Entre suas principais obrigações estão: a apuração do Preço de Liquidação de Diferenças (PLD), utilizado para valorar as transações realizadas no mercado de curto prazo; a realização da contabilização dos montantes de energia elétrica comercializados; a liquidação financeira dos valores decorrentes das operações de compra e venda de energia elétrica realizadas no mercado de curto prazo e a realização de leilões de compra e venda de energia no ACR por delegação da ANEEL [15].

2.1.6 O NOVO MODELO

No Novo Modelo do Setor Elétrico, o Governo Federal, continua responsável pela regulamentação, fiscalização e formulação de políticas para o setor de energia elétrica como atribuição do Poder Executivo federal, por meio do Ministério de Minas e Energia (MME) e com assessoramento do Conselho Nacional de Política Energética (CNPE) e do

Congresso Nacional. No novo modelo ainda foram criadas a Empresa de Pesquisa Energética - EPE, responsável pelo planejamento do setor elétrico em longo prazo, o Comitê de Monitoramento do Setor Elétrico - CMSE, com a função de avaliação contínua e permanente da segurança do suprimento de energia elétrica e a Câmara de Comercialização de Energia Elétrica do Sistema Interligado - CCEE, que veio substituir o MAE – Mercado Atacadista de Energia, relativas à comercialização de energia elétrica no Sistema Interligado. A ANEEL, agência reguladora, e o Operador Nacional do Sistema Elétrico (ONS), responsáveis por coordenar e supervisionar as operações centralizadas do sistema interligado brasileiro foram mantidos [15].

Com a implantação do novo modelo, o mercado ficou mais competitivo com uma crescente necessidade no aumento da produção de energia, o que criou um ambiente ideal para o aumento da participação das Pequenas Centrais Hidrelétricas (PCH's) na geração de energia no país. Nas PCH's tem-se uma menor necessidade de aporte de capital ao empreendedor, com procedimentos de obtenção dos direitos de exploração simplificados, incentivos governamentais, licenciamento ambiental teoricamente mais simples (se comparado as grandes centrais) e significativa atratividade econômica [29].

Com o atual modelo, dois ambientes de contratação distintos foram criados: o ambiente de Contratação Regulada (ACR), do qual participam Agentes de Geração e de Distribuição de energia; e o Ambiente de Contratação Livre (ACL), do qual participam Agentes de Geração², Comercializadores³, Importadores⁴ e Exportadores⁵ de energia e Consumidores Livres⁶ [30].

A geração de energia concentrava-se principalmente nos produtores independentes de caráter privado e em sistemas totalmente isolados. A produção era voltada para atender

² Agentes de Geração podem ser: Concessionárias de Serviço Público de Geração, Produtores Independentes e Autoprodutores

³ Comercializadores - Os Agentes de Comercialização de energia elétrica compram energia através de contratos bilaterais no Ambiente Livre podendo vender energia aos consumidores livres, no próprio ACL, ou aos distribuidores através dos leilões do ACR

⁴ Importadores - São os Agentes do setor que detêm autorização do Poder Concedente para realizar importação de energia elétrica para abastecimento do mercado nacional.

⁵ Exportadores - São os Agentes do setor que detêm autorização do Poder Concedente para realizar exportação de energia elétrica para abastecimento de países vizinhos.

⁶ Consumidores Livres - São os consumidores que, atendendo aos requisitos da legislação vigente, podem escolher seu fornecedor de energia elétrica (agentes de geração e comercializadores) através de livre negociação.

vilas, cidades e indústrias próximas as unidades geradoras. Com as crises no setor o Governo precisou intervir e fazer uma série de mudanças gerando a estatização do setor e por último a criação do novo modelo do setor energético brasileiro.

Deste modo, a produção se concentrou nos grandes empreendimentos, com grandes usinas e até mesmo com a implantação de usinas nucleares. Porém em 1996 o governo através do decreto nº 2.003, regulamenta a produção de energia elétrica por Produtor Independente⁷ e por Autoprodutor⁸ tentando buscar uma maior participação de investidores privados e um maior aproveitamento dos recursos hídricos disponíveis e conseqüentemente aumentar a geração de energia no país [31].

Em 2011 o Brasil chegou ao número de 1.311 produtores independentes e autoprodutores, sendo divididos em 245 autoprodutores, 36 autoprodutores com possibilidade de comercialização de excedente e 1030 produtores independentes.

Em 2002 o governo criou a LEI Nº 10.438 buscando incentivar novos investimentos para produção de energia elétrica. Com essa lei foi criando o Programa de Incentivo às Fontes Alternativas de Energia Elétrica (PROINFA), a Conta de Desenvolvimento Energético (CDE) [32].

O PROINFA foi criado com o objetivo de fomentar empreendimentos de Produtores Independentes Autônomos na geração de energia elétrica produzida com base em fontes eólica, pequenas centrais hidrelétricas e biomassa, podendo financiar os empreendimentos com recursos do BNDES. O Programa inicialmente previa a implantação de 144 usinas, totalizando 3.299,40 MW de capacidade instalada, sendo 1.191,24 MW provenientes de 63 PCHs, 1.422,92 MW de 54 usinas eólicas, e 685,24 MW de 27 usinas a base de biomassa [33].

Diferente dos produtores independentes autônomos, que podem comercializar toda a sua energia por sua conta e risco, os participantes do PROINFA têm que vender toda a sua

⁷ Pessoa jurídica ou empresas reunidas em consórcio que recebem concessão ou autorização do poder concedente, para produzir ENERGIA destinada ao comércio de toda ou parte da ENERGIA produzida, por sua conta e risco, conforme Artigo 11 da Lei nº 9.074, de 07 de julho de 1995 e Decreto nº 2.003, de 11 de setembro de 1996;

⁸ Autoprodutor de Energia Elétrica, a pessoa física ou jurídica ou empresas reunidas em consórcio que recebem concessão ou autorização para produzir energia elétrica destinada ao seu uso exclusivo.

produção para as Centrais Elétricas Brasileiras S.A. (ELETROBRÁS) sendo firmado por contrato com um prazo de 20 anos. Na Figura 3.2 podem ser observados os Estados participantes do Sistema Interligado Nacional que tiveram empreendimentos PROINFA segundo fonte de geração de energia com PCH, Eólica e Biomassa.

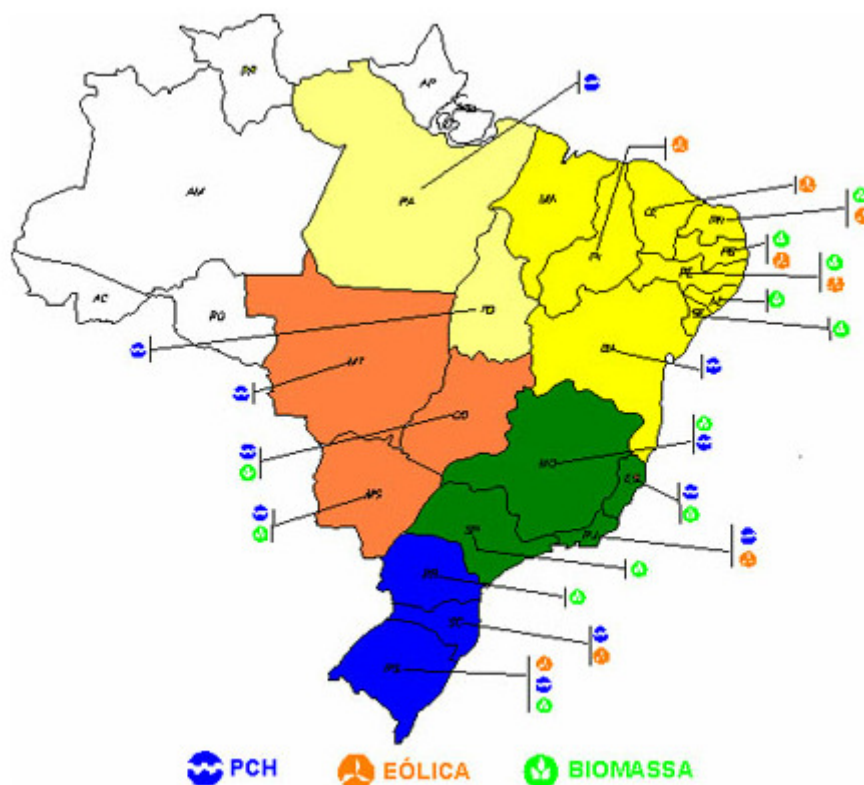


Figura 2.2 - Fontes de Energia Por Estado

Fonte: Adaptado do Site do PROINFA [34]

A região Nordeste devido as suas características naturais como ventos em todo período do ano e características da produção agrícola da região tiveram instalações de usinas eólicas e biomassa, tendo somente na Bahia a instalação de PCH. Já a região Centro-Oeste que possuiu uma grande riqueza hidrográfica e uma forte agricultara teve a implantação de PCH's e usinas de Biomassa. As regiões Sul e Sudeste tiveram os investimentos mais diversificados, tendo instalação de PCH's, usinas de Biomassa e Eólicas, como pode ser observado na Figura 2.2 [35].

2.2 O MERCADO DE ENERGIA NO BRASIL

Nos últimos anos o Setor Elétrico Brasileiro passou por transformações importantes voltadas principalmente para as questões de comercialização de energia. As modificações culminaram na criação de um novo mercado que buscou introduzir um modelo competitivo e que desonera se o poder público dos investimentos em infraestrutura, buscando criar um ambiente capaz de atrair capital privado, aumentar a competitividade e melhorar a qualidade do serviço [36]. Para que as mudanças ocorressem o Governo precisou criar e alterar leis e decretos.

Dentre as leis criadas para esse propósito a que teve um papel determinante foi a Lei nº 10.848/04, onde o governo alterou significativamente o marco regulatório do setor elétrico brasileiro. As regras de comercialização de energia elétrica, as licitações para outorga de concessões, a obrigatoriedade da segmentação de atividades das empresas concessionárias de distribuição de energia elétrica, a relação dos agentes com os chamados consumidores livres e cativos sofreram modificações. A comercialização de energia passou a ser realizada em dois ambientes: ACR - Ambiente de Contratação Regulada e o bilateral ACL - Ambiente de Contratação Livre [37].

Até dezembro de 2010 75,6 % da energia do SIN foi comercializada no ACR enquanto que no mesmo período somente 24,4% foi comercializada na ACL. A Figura 2.3 mostra de uma forma bem simples a existência dos dois mercados concomitantemente [38]:

- a) Ambiente de Contratação Regulada – ACR, nesse ambiente a contratação é formalizada através de contratos bilaterais regulados, denominados Contratos de Comercialização de Energia Elétrica no Ambiente Regulado (CCEAR), visando sempre proteger o consumidor cativo. Os Agentes vendedores⁹ vendem energia para as distribuidoras [39].
- b) Ambiente de Contratação Livre – ACL, os consumidores livres podem comprar energia em quantidade e preço acordado com os geradores e produtores na hora da compra. Uma figura que aparece no ambiente de comercialização é a do agente comercializador que compra energia através

⁹ Agente Vendedor - Agente de Geração, Agente de Comercialização ou Agente de Importação, que seja habilitado em documento específico para este fim.

de contratos bilaterais de curto, médio ou longo prazo ou até mesmo no mercado spot e revende essa energia para seus clientes [40].



Figura 2.3 - Visão Geral da Comercialização de Energia

Fonte: Adaptado da CCEE [21]

2.2.1 Ambiente de contratação regulada – ACR.

Na ACR participam os Agentes Vendedores e os Agentes de Distribuição¹⁰ de energia elétrica. A venda de energia neste ambiente é realizada por meio de leilões promovidos pela ANEEL (que também pode ser representada pela CCEE) e a contratação é formalizada por meio de contratos bilaterais regulados denominados contratos de Energia Elétrica no Ambiente Regulado - CCEAR. Os Agentes de Distribuição para garantir o fornecimento de energia devem adquirir energia das seguintes formas, de acordo com o Decreto nº 5.163/04:

- Contratos regulados, firmados na ACR;
- Contrato de compra e venda de energia proveniente de geração distribuída, de fontes eólicas, pequenas centrais hidrelétricas e biomassa, contratadas na

¹⁰ Agentes de Distribuição realizam atividades orientadas a serviços de rede e de venda de energia aos consumidores com tarifas e condições de fornecimento reguladas pela ANEEL (Consumidores Cativos). Com o novo modelo, os distribuidores têm participação obrigatória no ACR, celebrando contratos de energia com preços resultantes de leilões.

primeira etapa do Programa de Incentivo às Fontes Alternativas de Energia Elétrica “PROINFA” e de Itaipu Binacional.

Não são obrigados a participar dos leilões do ACR e nem cumprir a exigências de desverticalização as distribuidoras de pequeno porte (fornecimento inferior a 500 GWh/ano) e as que atendem aos sistemas isolados.

A desverticalização definiu o que não pode ser realizado pelas companhias distribuidoras como [41]:

- Desenvolver atividades de geração e transmissão;
- Vender energia para consumidores livres fora de sua área de concessão;
- Praticar atividades não condizentes ao objeto da concessão.

Diferente das distribuidoras de grande porte as geradoras de energia elétrica tem uma maior liberdade, podendo vender energia tanto no ACR quanto no ACL.

2.2.2 Ambiente de contratação livre

O mercado livre cria um ambiente extremamente competitivo permitindo a livre negociação entre os agentes geradores, comercializadores, consumidores livres, exportadores e importadores de energia, sendo que os acordos de compra e venda de energia são pactuados por meio de contratos bilaterais. Os vendedores e compradores buscam ter conhecimento dos melhores negócios e produtos.

Na ACL existe liberdade no que tange os volumes de compra e venda de energia e seus respectivos preços, porém certo grau de regulamentação se faz necessário para resguardar o bom funcionamento do ambiente de contratação.

Os consumidores que desejam ser livres para realizarem suas compras de energia através de contratos no ACL, devem ser registrados na CCEE como Agentes, estando sujeitos ao pagamento de todos os encargos, taxas e contribuições setoriais previstas na legislação.

Para mudar de categoria e atuar no consumo livre o consumidor deverá realizar um aviso prévio de até 3 anos, sendo que caso um consumidor livre queira voltar a ser um consumidor cativo o aviso prévio deverá ser de no mínimo 5 anos.

2.2.3 Contratos de Compra e Venda de Energia

O Contrato de Compra e Venda de Energia Elétrica (CCVE) é o instrumento jurídico que oficializa uma relação comercial de compra e venda de energia elétrica. Nesses contratos são especificados a quantidade de energia, prazos, flexibilidades, preços e demais condições comerciais [42].

Os contratos podem ser classificados quanto à sua duração em Contrato de Curto Prazo ou Contrato de Longo Prazo. Os Contratos de Curto Prazo possuem duração de até seis meses e são utilizados para fechamento de balanço e para cobrir incrementos temporários de consumo de energia. Os Contratos de Longo Prazo são contratos firmados entre empresas geradoras e compradores de energia, incluindo as previsões de crescimento de demanda feitas quando da assinatura dos contratos [42].

Os contratos também podem ser classificados em relação a sua modalidade como: Contratos do PROINFA, Contratos de Itaipu, Contratos bilaterais, Contratos de Leilão de Ajuste e Contratos Iniciais.

Os Contratos Bilaterais resultam da livre negociação entre os Agentes, tendo por objetivo estabelecer preços e volumes de energia para as transações de compra e venda de energia elétrica, conforme a legislação/regulamentação vigente, sem a interferência da CCEE. Os montantes de energia destes contratos são registrados na CCEE pelo Agente Vendedor e validados pelo Agente Comprador. Não é necessário informar o preço negociado, pois se entende que isto é sigiloso além de não afetar a liquidação na CCEE [43].

Como já mencionado no capítulo anterior o governo criou o Programa de Incentivos às fontes Alternativas de Energia Elétrica – PROINFA. Os Contratos PROINFA são contratos bilaterais que as empresas distribuidoras e geradoras devem assinar com a ELETROBRÁS, que foi a empresa encarregada da comercialização da energia dos produtores de fontes alternativas devidamente cadastradas no programa, através da CCEE. As quantidades de energia, preços e tarifas dos contratos PROINFA, estão regulados através da Resolução ANEEL 127/2004 [44].

Os contratos Itaipu são celebrados na CCEE pela Eletrobrás. A energia provém da usina de Itaipu que foi construída pelo governo brasileiro em conjunto com o governo do Paraguai. Os contratos de Itaipu são registrados no SCL para representar junto a CCEE a cota de cada agente da energia comercializada na Itaipu Binacional. A partir de 2008, 30 (trinta) concessionárias de distribuição de energia elétrica das regiões Sul, Sudeste e Centro-Oeste passaram a ratear de forma igualitária a parte da energia de Itaipu no qual o Brasil tem direito, correspondendo a um total de 7.730 megawatts médios (MWmed) mensais [39].

Outros contratos existentes no cenário nacional são os Contratos de Leilão de Ajuste e os Contratos Iniciais. O primeiro tem seus montantes anuais de energia sazonalizados pelos Agentes em valores de energia mensal para então serem modulados a cada contabilização e estão previstos no artigo 26 do Decreto nº 5.163, de 30/07/2004, e na Resolução Normativa 162/2005-ANEEL, com redação dada pela Resolução Normativa 277/2007-ANEEL (CCEE, 2010b). Já os Contratos Iniciais foram estabelecidos na Lei nº 9.648/98., tendo seus valores estabelecidos tipicamente em valores anuais médios pela ANEEL. Estes montantes anuais são sazonalizados pelos Agentes em valores de Energia Mensal de Contratos Iniciais, para então serem modulados a cada contabilização.

O modelo elétrico vigente determina a obrigatoriedade de lastro por parte dos agentes do setor na hora de firmar os contratos, isto é, exige a contratação da totalidade da demanda por parte das distribuidoras, comercializadores e consumidores livres, ademais exigem dos agentes vendedores de energia lastro de potência para os contratos de compra e venda [45].

2.2.4 Papel da ONS e da CCEE em relação aos contratos

Como a energia elétrica é um produto que não pode ser armazenado ou estocado ele precisa de equilíbrio instantâneo entre demanda e oferta, a oferta prevista *ex-ante* não necessariamente iguala a demanda observada, fazendo-se necessário o equilíbrio instantâneo em dois pontos: o fornecimento e a contabilização financeira do sistema [45].

O Brasil adota um modelo centralizador, o *Tight Pool*, que caracteriza-se pela existência de uma entidade (no caso do Brasil: Operador Nacional do Sistema Elétrico - ONS) que define o despacho de geração de forma centralizada [43].

A ONS é responsável pela operação do Sistema Interligado Nacional, decidindo quanto ao despacho das usinas por meio da agregação dos empreendimentos de geração e transmissão de forma a impetrar uma gerência mais efetiva do custo de produção de energia [43] [45].

Assim, o objetivo deste modelo é que a energia seja gerada com o menor custo adicional de carga sem comprometer as condições de operação futuras do sistema (essencialmente refletida pelo nível dos reservatórios).

Já a CCEE é responsável pela contabilização e compensação em tempo real das transações. Para isso ela utiliza a ferramenta de *clearing*. Essa ferramenta é baseada nos princípios da ONS que a utiliza para refletir as condições para o atendimento da carga requisitada pela demanda. A CCEE calcula o Preço de Liquidação das Diferenças (PLD), que vai servir como referência para a determinação do preço de energia de curto prazo e para o acerto das diferenças observadas entre a energia contratada e a consumida [45].

A CCEE é responsável por verificar a energia contratada e a energia consumida. A contratação da energia é *ex-ante*, onde se faz uma previsão de consumo, porém pode acontecer que a energia contratada não seja toda consumida ou o contrário onde se consuma mais do que foi contratado, exigindo nos dois casos uma contabilização a *posteriori*. É realizado de forma *ex-post* a totalização de pagamentos e recebimentos de cada agente relativos à energia transacionada [45]. Isso se dá ao agregar os dados de medição e o cálculo da diferença entre os montantes medidos e contratados por agente. Os montantes de energia transacionados e não contratados são então valorados ao Preço de Liquidação das Diferenças (PLD), e se tornam objeto de liquidação na CCEE. Quem gastou mais do que contratou vai ter que comprar energia e quem gastou menos do que foi contratado vai receber o valor referente ao preço do PLD da semana vigente.

2.3 O MERCADO SPOT NO BRASIL.

Diferente de outros países que tiveram seus mercados reestruturados, dentre os quais podemos citar a Espanha que tem a determinação do preço spot por meio do confronto entre as curvas de oferta e de demanda, o Brasil adotou a fórmula de calcular os preços de curto prazo (ou preços “spot”) da energia elétrica através da utilização de modelos computacionais de planejamento da operação. Ao invés de ocorrer um equilíbrio entre a

oferta e a demanda, o preço é baseado no custo marginal de operação calculado dentro do processo de otimização energética buscando garantir o menor custo operacional possível [46].

O Brasil tendo sua matriz energética com predominância de usinas hidrelétricas tem um mercado sujeito à incerteza no preço spot devido à incerteza nas afluições e no valor futuro da água armazenada nos reservatórios. Pode se pensar que o custo de operação de usinas hidrelétricas é nulo, pois não há desembolso para “comprar” a água que está armazenada nos reservatórios, porém o gasto da água hoje pode refletir no preço da energia amanhã.

O planejamento de operação de um sistema hidrotérmico é bastante complexo, existindo uma relação direta entre a decisão tomada no passado ou presente e sua consequência no futuro. Se as águas dos reservatórios forem gastas em excesso e o país passar por um período de estiagem que impossibilite as afluições repor a água dos reservatórios, o custo de operação do sistema no futuro pode ser altíssimo, pois para atender a carga do sistema deverá ser utilizada geração térmica. Por outro lado, utilizando geração térmica em excesso no presente de modo a economizar a água dos reservatórios, e um período de condição hidrológica favorável vier a ocorrer no futuro pode ser necessário verter água dos reservatórios, o que representa um desperdício de energia.

Na operação de um sistema de energia hidrotérmico as decisões tomadas podem ser representadas pela Função de Custo Imediato (FCI) e pela Função de Custo Futuro (FCF). A Função de Custo Imediato representa o uso imediato da água disponível nos reservatórios, por outro lado a Função de Custo Futuro representa a relação de armazenar a água no presente para seu uso no futuro. Quando se economiza água no presente e passa a utilizar mais geração térmica para atender a demanda, ocorre um encarecimento na geração dessa energia, e com isso FCI aumenta, já em contrapartida o FCF diminui caso tenha ocorrido uma economia de água no presente, refletindo em uma redução de geração térmica no futuro para atender a demanda de energia.

Em sistemas hidrotérmicos busca-se uma harmonia entre o consumo ótimo da água armazenada nos reservatórios, mais a utilização de unidades de geração térmicas de forma que o custo de produção de energia no presente não encareça o preço no futuro. Aparece

então o conceito de “custo marginal de oportunidade”. Como já exposto o planejamento de sistemas hidrotérmicos é bastante complexos. Deve-se levar em consideração a utilização das águas dos reservatórios no presente que diminuem o estoque aumentando o custo marginal de oportunidade devido a não possibilidade de utilização dessa água num período futuro de maior escassez.

O melhor sistema deve ser a combinação da utilização de fontes geradoras de menor custo com fontes geradoras de maior custo [45]. A Função de Custo Total - (FCT) é obtida pela soma da Função de Custo Imediato (FCI) e Função de Custo Futuro (FCF). O menor custo global seria obtido pelo ponto mínimo da função de custo total. Este ponto corresponde ao ponto onde a derivada da Função de Custo Total é igual à zero, ou, onde as derivadas das duas primeiras funções em relação ao volume final se igualam em módulo e determinam o “valor da água” utilizada.

2.3.1 O Cálculo do Preço Líquido das Diferenças

O Preço de Liquidação das Diferenças (PLD) é o valor utilizado na compra e a venda de energia no Mercado de Curto Prazo e no Mercado Spot [47].

A CCEE realiza a contabilização mensal das operações ocorridas em seu ambiente de contratação, calculando a posição credora ou devedora de cada cliente. No final dessa contabilização a CCEE tende a zerar as posições de cada agente, ou comprando energia no mercado spot caso ele esteja devendo energia mediante um consumo além do que havia sido contratado, ou vendendo a energia que foi contratada, mas não foi consumida, ocorrendo assim a Liquidação das diferenças.

As decisões tomadas pela ONS para otimização da operação do SIN e a formação de preço do PLD são realizados com base nas informações das condições hidrológicas, na demanda de energia, nos preços dos combustíveis fósseis, no custo de déficit de energia, na entrada de novos projetos e na disponibilidade de equipamentos de geração e transmissão de energia. São esses dados que vão dar subsídios para que a ONS consiga estabelecer o que chamamos de “despacho (geração) ótimo”, onde a combinação entre a geração de energia utilizando usinas hidráulicas e térmicas no presente devem proporcionar um menor preço da energia no futuro.

O preço spot varia de acordo com três patamares de cargas distintos: leve (das 00h01 às 07h00), média (das 07h01 às 18h00 e das 21h01 às 24h00) e pesada (das 18h01 às 21h00). Estes patamares valem para dias úteis, não havendo carga pesada em domingos e feriados nacionais [48]. O cálculo do preço baseia-se no despacho “*ex-ante*”, ou seja, é apurado com base em informações previstas, anteriores à operação real do sistema, considerando-se os valores de disponibilidades declaradas de geração e o consumo previsto de cada submercado.

O valor do PLD é determinado mensalmente para cada semana do mês seguinte e para cada patamar de carga com base no Custo Marginal de Operação - CMO. Todo ano a ANEEL define o valor mínimo e máximo do PLD que vão ser utilizados entre a primeira e última semana do ano em questão. No ano de 2011 esses valores foram de R\$ 12,08/MWh para mínimo e R\$ 689,18/MWh para o máximo e em 2012 os valores foram definidos entre R\$12,20 e R\$ 727,52/MWh [49]. Para auxiliar na tomada de decisão e no cálculo do PLD, a ELETROBRÁS junto com Centro de Pesquisa de Energia Elétrica - (CEPEL) utilizam os modelos computacionais NEWAVE e DECOMP, os quais produzem respectivamente o Custo Marginal de Operação de cada submercado.

A CCEE realiza uma vez por mês o Planejamento Mensal da Operação, reunindo todos os agentes do processo de planejamento, onde ocorre a execução do NEWAVE e do DECOMP para obtenção do PLD [50]. O ONS semanalmente faz uma revisão do processamento do DECOMP considerando mudanças nas previsões hidrológicas, podendo fazer correções no valor do PLD.

2.3.2 Newave

O programa NEWAVE consiste num modelo de otimização que usa Programação Dinâmica Dual Estocástica para determinar o planejamento operacional que minimize o custo da operação em um horizonte de cinco anos. O sistema trabalha com o conceito de reservatórios equivalentes sendo representadas as usinas hidrelétricas de um subsistema em um único reservatório.

O NEWAVE é utilizado para planejar o sistema hidrotérmico brasileiro criando um sistema equivalente composto por quatro subsistemas. Essa técnica reduz a dimensão do

problema facilitando o processamento do NEWAVE. O modelo procura minimizar o custo operacional do sistema, contabilizando o custo presente do combustível das usinas térmicas e o custo futuro da utilização ou não da água.

O NEWAVE fornece os despachos de geração térmica e hidráulica nos subsistemas equivalentes, as trocas de energia entre os sistemas e Função de Custo Futuro. Estes dados são utilizados para alimentar um segundo software utilizado pela ONS chamado DECOMP [50]. A Figura 3.4 apresenta de forma esquematizada as variáveis de entrada do NEWAVE que são utilizadas nos cálculos da política de operação como também as principais variáveis de saída.

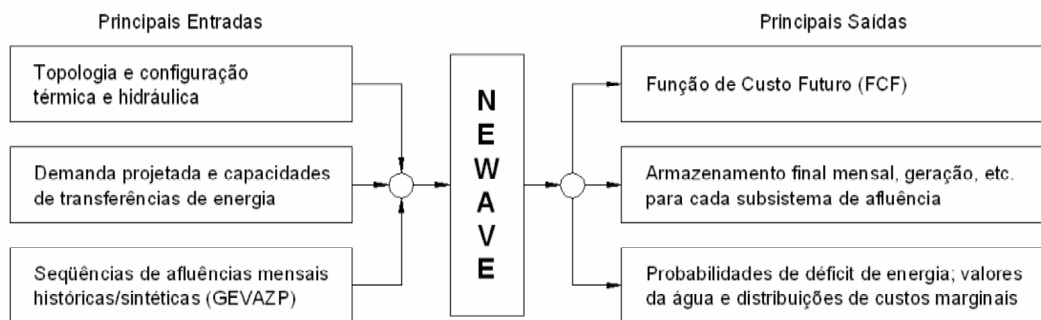


Figura 2.4 - Entradas e Saídas do NEWAVE

Fonte: Adaptado do Queiroz [46]

2.3.3 Decomp

A partir de julho de 2001, começou-se a utilizar mais um sistema para planejamento do sistema hidrotérmico brasileiro, o DECOMP. Diferente do NEWAVE, este programa busca resolver o problema da operação no curto prazo (período de até 12 meses) gerando valores para o preço semanalmente. O DECOMP deve ser executado toda semana com os dados atualizados do setor, diferente do NEWAVE, que é executado uma vez por mês.

O DECOMP decompõe o custo marginal mês a mês pelo NEWAVE em base semanal. Ele está adaptado ao ambiente de elaboração dos programas mensais de operação do sistema brasileiro, seu objetivo principal é determinar as metas de geração de cada usina sujeita a afluições estocásticas, de forma a atender a demanda e minimizar o valor do custo de

operação ao longo do período de planejamento [51]. As usinas têm suas características físicas e suas restrições operacionais representadas em um modelo de programação linear.

3 REDES NEURAIIS ARTIFICIAIS

3.1 Rede Neural

Um dos grandes sonhos dos pesquisadores de diversas áreas é criar estruturas ou máquinas capazes de agir e pensar como o ser humano, que possam tomar decisões mediante a realidade que lhe são expostas e que possam representar perfeitamente o funcionamento do cérebro humano. Para isso muitos estudos têm sido realizados na área de redes neurais, onde os cientistas buscam dar inteligência a essas estruturas compreendendo o que pode ser chamado de inteligência artificial. A utilização de sistemas inteligentes abrange uma vasta área [52]:

- Avaliação de imagens captadas por satélite;
- Classificação de padrões de escrita e de fala;
- Reconhecimento de faces em visão computacional;
- Controle de trens de grande velocidade;
- Previsão de ações no mercado financeiro;
- Identificação de anomalias em imagens médicas;
- Identificação automática de perfis de crédito para clientes de instituições financeiras;
- Controle de aparelhos eletrônicos e eletrodomésticos, como máquinas de lavar roupa , fornos de micro-ondas, geladeiras, cafeteiras, fritadeiras, filmadoras e etc;

A Rede neural pode ser definida como um processador paralelamente distribuído constituído de unidades de processamento simples, tendo a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso [53]. Seu funcionamento se assemelha muito ao do cérebro humano:

- 1 - O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem.
- 2 - Forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido [53].

As redes neurais podem ser utilizadas em diversas aplicações, tanto para resolver simples problemas como aqueles mais complexos. Novas aplicações estão sempre surgindo devido aos grandes avanços tecnológicos nessa área de conhecimento.

3.1.1 Arquitetura de Rede Neural Artificial

A arquitetura da rede neural define quantas camadas a rede possui, o número de variáveis na camada de entrada, o número de camadas escondidas, o número de neurônios em cada camada, a camada de saída, o tipo de conexão existente entre os neurônios e funções de transferência [54] [55] [56] [57].

Conforme o número de camadas a rede pode ser classificada em:

- Rede com uma única camada: nesta arquitetura a rede possui os nós de entrada e a camada de saída, não existindo as camadas ocultas [4].
- Redes com múltiplas camadas: Possui camadas entre os nós de entrada e a camada de saída, sendo essas camadas chamadas de intermediárias ou ocultas (Figura 3.1).




Figura 3.1- Rede Com Múltiplas Camadas

Quanto à conexão entre os nós a rede pode ser classificada como:

- Feedforward ou acíclica: Nesse tipo de redes os sinais são sempre projetados para frente, sendo a saída de um neurônio a entrada para o neurônio localizado na camada posterior a localização do neurônio. Uma rede feedforward com uma única camada escondida, pode se adaptar a qualquer problema de mapeamento de entrada e saída [58] .
- Feedback ou cíclica: Diferente da feedforward o resultado da saída do neurônio serve como entrada para um neurônio localizado em uma camada anterior [58] .

3.1.2 As Camadas da Rede

Independente da estrutura da rede neural adotada a camada de entrada e a camada de saída estarão sempre presentes na rede neural [54]. Já à existência de camadas ocultas dependerá da estrutura adotada [4]. Segue-se uma breve discussão das camadas de entrada, camadas ocultas e de saída:

- Camada de Entrada: recebe os dados com informações do modelo que está sendo aplicada a rede neural. Os dados de entrada muitas vezes precisam ser normalizados para contornar o problema de outliers que podem afetar o resultado da rede [59] [60] [61] [62]. Na previsão de carga de energia, a camada de entrada pode acomodar todos os fatores que afetam o padrão de carga diretamente ou implicitamente, incluindo tipos de dia, de carga, temperatura, umidade e vento [4].
- Camada Oculta: esta camada é formada principalmente por neurônios. O número de neurônios precisa manter um equilíbrio, pois se o número é muito pequeno, a rede pode não encontrar a complexa relação entre entrada e saída e pode ter dificuldade na convergência durante o treinamento e se o número for muito grande, o processo de treinamento seria mais demorado e poderia prejudicar a capacidade da rede neural [4] [57].
- Camada de Saída: responsável pela saída do resultado produzido pela rede neural. Os dados produzidos pela rede devem ser comparados com o alvo

para medir a eficiência da rede [53].

3.1.3 Neurônios na Camada Escondida

A definição do número de neurônios na camada escondida pode ser determinado por regras heurísticas, uma vez que não há nenhum método específico disponível para determinar o número exato de neurônios na camada oculta [4]. O número de neurônios na camada oculta pode variar conforme o número de variáveis da camada de entrada e o número de neurônios da camada de saída [57]. Para definir o número de neurônios da camada oculta pode-se utilizar regras heurísticas como dobrar o número de neurônios da camada de entrada acrescentando mais um neurônio, somar o número de neurônios da camada de entrada com os neurônios da camada de saída ou somar o número de neurônios da camada de entrada com o número de neurônios da camada de saída e dividir por dois [4].

A Tabela 3.1 apresenta o número de neurônios na camada oculta para os três casos citados acima, considerando 5 variáveis de entrada.

Tabela 3.1 Número de Neurônios na Camada Escondida

Regra	Formula	Neurônios	$V_{in}=N^{\circ}$ Variáveis De Entrada	$V_{out}=N^{\circ}$ Variáveis De Saída
1°	$(V_{in} * 2) + 1$	11	5	1
2°	$V_{in} + V_{out}$	6		
3°	$(V_{in} + V_{out})/2$	3		

3.1.4 Normalização dos Dados

O desempenho da rede depende da capacidade de generalização e da capacidade de reconhecer tendências a partir dos dados de treinamento e empregar o conhecimento adquirido para fazer previsões sobre novos dados apresentados à rede [60]. A presença de *outliers* pode afetar negativamente o desempenho da rede, devido à discrepância dos dados de entrada. Para contornar esse problema diversas técnicas são utilizadas, sendo a normalização uma delas [59]. A normalização dos dados de entrada é crucial para melhorar de forma significativa os cálculos da rede e obter bons resultados. Embora um intervalo

para normalização deva ser utilizado, não existe na literatura um procedimento específico para tal definição [61]. O processo de normalização deve ser compatível com as funções de transferência a serem utilizadas nas camadas intermediárias e na camada de saída [63]. O valor de x_n pode ser obtido através da equação (3.1):

$$x_n = \frac{2(x - x_{min})}{(x_{max} - x_{min})} - 1 \quad (3.1)$$

sendo:

x_{max} : valor máximo desejado;

x_{min} : valor mínimo desejado.

3.1.5 Desempenho da Rede

Em redes neurais o termo acuracidade refere-se à capacidade que o modelo de previsão tem em se adaptar a dados que já eram conhecidos, porém em previsões de séries temporais a acuracidade representa a capacidade que o modelo tem em minimizar os erros de uma previsão com dados ainda não conhecidos. O erro (equação 3.2) é a diferença entre uma observação no tempo t e a previsão para o mesmo tempo t [64].

$$\text{Erro} = t_x - \text{saída da rede}_x \quad (3.2)$$

Os valores de t são o alvo da rede neural e a saída da rede é o preço estimado.

Para medir o desempenho da rede, as seguintes equações estatísticas podem ser utilizadas:

Mean Error (ME, Erro Médio):

$$\frac{1}{n} \sum_{t=1}^n e_t \quad (3.3)$$

Mean Absolute Error (MAE, Erro Médio Absoluto) :

$$\frac{1}{n} \sum_{t=1}^n |e_t| \quad (3.4)$$

Mean Squared Error (MSE, Erro Médio Quadrático)

$$\frac{1}{n} \sum_{t=1}^n e_t^2 \quad (3.5)$$

Para comparação de séries temporais com diferentes intervalos de tempo deve-se utilizar uma medida de erro relativa ou percentual [54].

Calcula-se o erro percentual através da seguinte equação:

Percentage Error (PE, Erro Percentual):

$$\left(\frac{V_f - V_a}{Y_t} \right) \times 100 \quad (3.6)$$

Sendo:

V_f = valor da previsão;

Y_t = observação atual para o período t

V_a = valor real.

Através da equação (3.6) definem-se outras duas equações:

Mean Percentage Error (MPE, Erro Médio Percentual) :

$$\frac{1}{n} \sum_{t=1}^n PE_t \quad (3.7)$$

Mean Absolute Percentage Error (MAPE, Erro Médio Percentual Absoluto):

$$\frac{1}{n} \sum_{t=1}^n |PE_t| \quad (3.8)$$

Um grande problema na utilização do MAPE em séries temporais que contém observações de valores iguais a zero, é o cálculo do erro percentual, devido à divisão da equação (3.6) [54] [4]. Para resolver esse problema pode-se utilizar um MAPE alternativo, sendo aqui chamado de MAPE2 [4]. Primeiro calcula-se o valor médio:

$$\bar{V} = \frac{1}{N} \sum_{i=1}^N V_a \quad (3.9a)$$

O APE, APE e MAPE são redefinidos [4]:

$$PE = (V_f - V_a) / \bar{V} * 100\% \quad (3.9b)$$

$$APE = |PE| \quad (3.9c)$$

Mean Absolute Percentage Error 2 (MAPE, Erro Médio Percentual Absoluto 2):

$$\frac{1}{N} \sum_{i=1}^N APE_i \quad (3.9d)$$

3.1.6 Perceptron Multicamadas

As redes Perceptron de múltiplas camadas são aplicadas em diferentes áreas do conhecimento. Entre essas áreas temos os seguintes destaques:

- Aproximação universal de função;
- Reconhecimento de padrões;
- Identificação e controle de processos;
- Previsão de séries temporais;
- Otimização de sistemas.

O processo de treinamento ocorre de forma supervisionada, utilizando o algoritmo de Retropropagação (Backpropagation), que traz uma grande contribuição para o desenvolvimento das redes neurais, resolvendo sistemas bastante complexos [65] [53].

A estrutura da rede Perceptron multicamadas compreende uma cama de entrada que pode ter várias entradas, uma ou mais camadas intermediárias e uma camada de saída como mostra a Figura 3.2, lembrando que os neurônios estão presentes nas camadas intermediárias e na camada de saída.

Para produzir quaisquer mapeamentos, são necessários no máximo duas camadas intermediarias com um número suficiente de neurônios por camada e para aproximar funções contínuas uma camada é mais que o suficiente [66] .

3.1.7 Algoritmo de Retropropagação

O algoritmo de Retropropagação é um método de adaptação de pesos sinápticos das redes neurais feedforward multicamada, baseado no método do gradiente descendente. O ajustes dos pesos são realizados buscando minimizar o erro quadrático da rede. A soma dos erros quadráticos é dada por:

$$\varepsilon^2 = \sum_{i=1}^{ns} \varepsilon_i^2 \quad (3.10)$$

em que:

$$\varepsilon_i = d_i - y_i \quad (3.11)$$

sendo:

d_i = saída desejada do i -ésimo elemento da última camada da rede;

y_i = saída do i -ésimo elemento da última camada da rede dada por:

ns = número de neurônios da última camada da rede.

O ajuste dos pesos utilizando o gradiente descendente pode ser representado matematicamente da seguinte forma:

$$V_i(h + 1) = V_i(h) - \theta_i(h) \quad (3.12)$$

sendo:

$$\theta_i(h) = \gamma (\nabla_i(h)) \quad (3.13)$$

γ = parâmetro de controle da estabilidade ou taxa de treinamento;

h = índice de iteração;

$\nabla_i(h)$ = gradiente do erro quadrático com relação aos pesos do neurônio i ;

$\nabla_i = [w_{0i}, w_{1i}, w_{2i}, \dots, w_{ni}]^T$.

4 RESULTADOS

Este capítulo tem como finalidade apresentar os principais resultados obtidos na utilização das redes neurais artificiais na previsão do preço da energia no mercado spot brasileiro e da Califórnia no curto (uma hora e um dia) e médio prazo (uma semana, um mês e um ano).

A ideia central foi trabalhar com a rede do tipo perceptron multicamadas, utilizando as funções de treinamento Lenvenberg-Marquardt, com as funções de transferência logsig e purelim.

Será apresentada uma análise dos resultados obtidos com aplicação das redes neurais nos dois mercados de energia (Brasil e Califórnia) para diferentes intervalos de amostras de dados, diferentes variações de tempo e mudanças nas variáveis de entrada. Para demonstrar os resultados será realizada a comparação, tanto de forma numérica quanto gráfica, dos diferentes intervalos de dados e as variações do tempo no futuro. Em quase todos os treinamentos foram utilizados os mesmos parâmetros de configuração, mudando somente em alguns casos específicos o tamanho da amostra de treinamento e validação. Essa alteração ocorreu para analisar os resultados da mudança desses valores. Para se chegar aos parâmetros utilizados foram realizados muitos testes para ajustar a rede através da análise do comportamento dos resultados, pois não tem nenhum método determinístico para escolha dos tais parâmetros [67].

4.1 RESULTADOS COM DADOS DO MERCADO DA CALIFÓRNIA

Para validar a rede neural, buscou-se no primeiro momento reproduzir um estudo de caso já publicado [9]. No entanto, como o estudo em questão não informa qual o tempo futuro previsto (hora, dia, semana, mês e ano), foram reproduzidas seis previsões com diferentes variações de tempo.

Foram coletados dados reais do mercado de energia da Califórnia, compreendendo o período de 01/01/1999 à 31/12/1999, representados por um total de 8761 amostras sendo uma para cada hora do dia. A Figura 3.1 apresenta de forma gráfica o preço histórico no intervalo de tempo supracitado.




Figura 4.1 - Preço da energia no mercado energético da Califórnia – 01/02/99 à 04/04/99

Nos dados disponíveis realizou-se um recorte que vai de 01/02/1999 à 04/04/1999 como pode ser visto na figura 3.1. Sendo estabelecida a semana do dia 29/03 à 04/04 como teste da rede e os dados de treinamento foram variando de uma a oito semanas conforme Tabela 4.1. A figura 4.2 representa os dados que compreendem o recorte realizado.




Figura 4.2 - Dados do Período de 01/02/99 a 04/04/99

A Tabela 4.1 mostra a divisão dos vetores de treinamento e o vetor de teste, usados para medir o desempenho da rede com os dados do mercado da Califórnia em relação ao número de vetores. O intervalo utilizado foi entre o período de 01/02/99 a 04/04/99.

Tabela 4.1 - Divisão dos vetores de treinamento e teste da rede neural

Caso N°	Vetores de Treinamento	Dif. Dias	Vetor de Teste
1	22/3 à 28/3	7 (1)	29/3 à 4/4 (7)
2	15/3 à 28/3	14 (2)	
3	8/3 à 28/3	21 (3)	
4	1/3 à 28/3	28 (4)	
5	22/2 à 28/3	35 (5)	
6	15/2 à 28/3	42 (6)	
7	8/2 à 28/3	49 (7)	
8	1/2 à 28/3	56 (8)	

Nota: (7) numero de vetores

Para definição do número de neurônios na camada escondida foi utilizado o método descrito no item 3.1.4, e com os dados de entrada as redes ficaram com 11,6 e 3 neurônios na camada oculta. Foram realizados para cada caso cinco simulações com cada número de neurônios (11, 6 e 3) na camada oculta, e os resultados organizados e apresentados em tabela: número de casos, os intervalos dos vetores de treinamento, a diferença de dias, o vetor de teste, a média das quinze simulações e o valor mínimo e máximo das simulações.

A partir de agora serão apresentadas 6 simulações com diferentes variações de tempo:

- Primeira Simulação: Sem Variação do tempo;
- Segunda Simulação: Predição em uma hora a frente;
- Terceira Variação: Predição em um dia a frente;
- Quarta simulação: Predição em uma semana a frente;
- Quinta simulação: Predição em um mês a frente;
- Sexta simulação: Predição em um ano a frente.

4.1.1 Primeira Simulação

Nessa primeira simulação os dados do alvo não sofreram nenhum deslocamento no tempo em relação aos dados de entrada, processo semelhante ao realizado em [68].

É possível observar na tabela 4.2 que os mínimos do MAPE 2 foram muito próximos de zero.

Tabela 4.2 - Resultado da Primeira Simulação

Caso N°	Vetores de Treinamento	Dif. Dias	Vetor de Teste	Teste MAPE 2 (%)		
				Média	Mínimo	Máximo
1	22/3 à 28/3	7		0,0285	0,0004	0,1278
2	15/3 à 28/3	14		0,0230	0,0004	0,0903
3	8/3 à 28/3	21		0,0163	0,0005	0,0642
4	1/3 à 28/3	28	29/3 à 4/4	0,0162	0,0003	0,0826
5	22/2 à 28/3	35		0,0143	0,0008	0,0282
6	15/2 à 28/3	42		0,0218	0,0002	0,0933
7	8/2 à 28/3	49		0,0252	0,0007	0,1147
8	1/2 à 28/3	56		0,0280	0,0006	0,1247

No entanto, o aumento do número de vetores deve ter um ponto de equilíbrio, pois a utilização de 7 a 8 vetores de treinamento ocasionou uma piora nos resultados. Isto acontece porque a rede com mais vetores tem que ajustar seus pesos para um número maior de dados de entrada/saída, os quais podem não refletir os dados de teste.

Os melhores resultados ocorreram nos casos 4 e 5, sendo que o caso 5 teve uma média menor caracterizando-se como a melhor escolha para esse modelo. Entretanto, mesmo o sexto caso apresentando uma média maior que o caso 5, ele obteve o menor mínimo de todos os casos.

De acordo com a Figura 4.3, o MAPE 2 começa a cair com acréscimo do número de vetores de treinamento até o caso 5, porém, a partir do caso 6, esse valor começa a subir decorrente do aumento do número de vetores de treinamento.

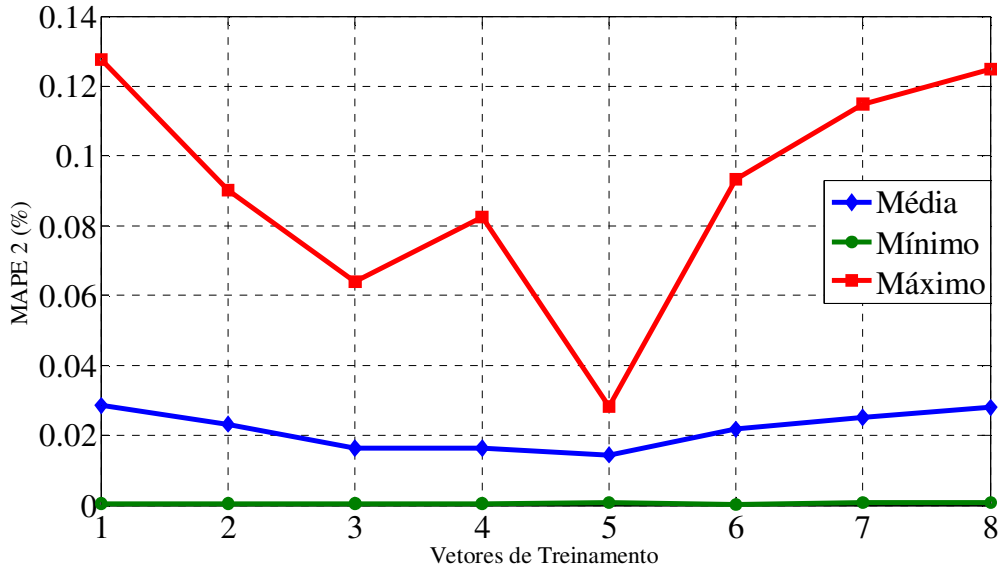


Figura 4.3 - Impacto do aumento do número de vetores de treinamento sobre o MAPE 2 na primeira simulação.

Para representar graficamente os resultados da saída da rede neural, foi escolhida a rede do caso 5 que produziu o menor mínimo. A Figura 4.4 mostra a precisão acurada da rede, apresentando quase que uma sobreposição das linhas do alvo e da saída.




Figura 4.4 - Resultado da simulação com menor MAPE 2 (%) da primeira simulação

4.1.2 Segunda Simulação

A segunda simulação foi composta pelos mesmos casos da Tabela 4.1, porém o preço alvo da energia utilizada sofreu um deslocamento no tempo em uma hora, e os resultados das simulações podem ser observados na Tabela 4.3.

Tabela 4.3 - Resultados do MAPE 2 % da Segunda Simulação.

Caso Nº	Vetores de Treinamento	Dif. Dias	Vetor de Teste	Teste MAPE 2 (%)		
				Média	Mínimo	Máximo
1	22/3 à 28/3	7		9,3176	7,8102	16,6111
2	15/3 à 28/3	14		8,6244	7,6967	9,7345
3	8/3 à 28/3	21		7,7349	6,8143	8,9927
4	1/3 à 28/3	28	29/3 à 4/4	7,6998	6,6401	9,4171
5	22/2 à 28/3	35		7,4408	6,6040	8,7792
6	15/2 à 28/3	42		7,5539	6,9602	8,4138
7	8/2 à 28/3	49		7,6401	7,0044	8,9865
8	1/2 à 28/3	56		7,8330	7,1949	9,0897

Dos oito casos testados, o que apresentou melhor resultado foi o quinto caso com uma melhor média (7,44%), o menor mínimo (6,60 %) e um máximo (8,77 %) próximo da média, o que caracteriza uma maior existência de bons resultados. Nesse cenário, o primeiro caso gerou o pior resultado (16,61 %), o que pode ser reflexo da pequena quantidade de dados utilizados no treinamento ou pela baixa qualidade dos dados apresentados em relação ao teste da rede. De acordo, com a proximidade dos resultados entre o caso 2 e 7, conclui-se que a rede responde bem a previsão do preço da energia com um deslocamento do alvo em uma hora.

A evolução dos resultados da média, do mínimo e do máximo MAPE 2 da segunda simulação são representados graficamente pela Figura 4.5. Os valores começaram mais altos no primeiro caso, principalmente o valor máximo que foi acima dos 16 %, porém até o terceiro caso ocorre uma redução dos valores, e estes se mantiveram praticamente estáveis até o último caso.




Figura 4.5 - Impacto do aumento do número de vetores de treinamento no MAPE 2 na segunda simulação

O gráfico com a saída da rede que teve o menor (caso 5) MAPE 2 é demonstrado na Figura 4.6 (a) e (b). Na figura 4.6 (a) observa-se que a rede neural composta por 6 neurônios na camada oculta conseguiu de forma eficiente prever o resultado da rede, apresentando a saída muito próxima do alvo, tendo, porém mais dificuldade para prever as maiores oscilações de alta e de baixa do preço.

Após o teste da rede neural, é possível calcular o erro da previsão, sendo este, resultado da subtração da saída da rede pelo preço realizado. A variação do erro da rede neural que teve o menor mínimo no caso 5 pode ser observada na Figura 4.6 (b) Observa-se que na maior parte dos resultados, a variação do preço não chegou a U\$5,00, entretanto, nos períodos de maior oscilação o erro chegou à U\$10,00.




Figura 4.6 - Melhor Resultado e Variação do Erro para Previsão de Uma Hora

4.1.3 Terceira Simulação

A divisão dos dados da terceira simulação foi realizada conforme demonstrado na Tabela 4.1, no entanto o alvo sofreu um deslocamento no tempo na ordem de 1 dia ou 24 horas. Diferente do que ocorreu na primeira e segunda amostra e no trabalho [9], o melhor resultado da terceira simulação foi no caso 2, como pode ser observado na Tabela 4.4. Apesar de poucos vetores de treinamento, a média (12,61 %) e o mínimo (9,96 %) atingiram os menores valores, porém o valor máximo (15,93 %) foi o segundo maior MAPE 2 dos 8 casos, ficando somente atrás do máximo (17,58 %) do primeiro caso.

Tabela 4.4 - Resultados do MAPE 2 % da Terceira Simulação.

Caso Nº	Vetores de Treinamento	Dif. Dias	Vetor de Teste	Teste MAPE 2 (%)		
				Média	Mínimo	Máximo
1	22/3 à 28/3	7		14,0887	11,61811	17,58627
2	15/3 à 28/3	14		12,6161	9,968384	15,93517
3	8/3 à 28/3	21		12,86849	11,80635	13,74997
4	1/3 à 28/3	28	29/3 à 4/4	13,0358	12,15688	13,89003
5	22/2 à 28/3	35		12,94331	12,45493	14,11207
6	15/2 à 28/3	42		12,8158	12,16305	13,82949
7	8/2 à 28/3	49		12,78563	12,42583	13,10705
8	1/2 à 28/3	56		13,04863	12,44126	13,89512

Os resultados apresentados na Tabela 4.4 podem ser vistos graficamente na Figura 4.7. Os valores (média, mínimo e máximo) apresentaram uma redução no segundo e terceiro caso, mantendo-se estabilizados até o oitavo caso, exceto o valor máximo que apresentou uma queda no sétimo acompanhado de uma alta no oitavo caso.

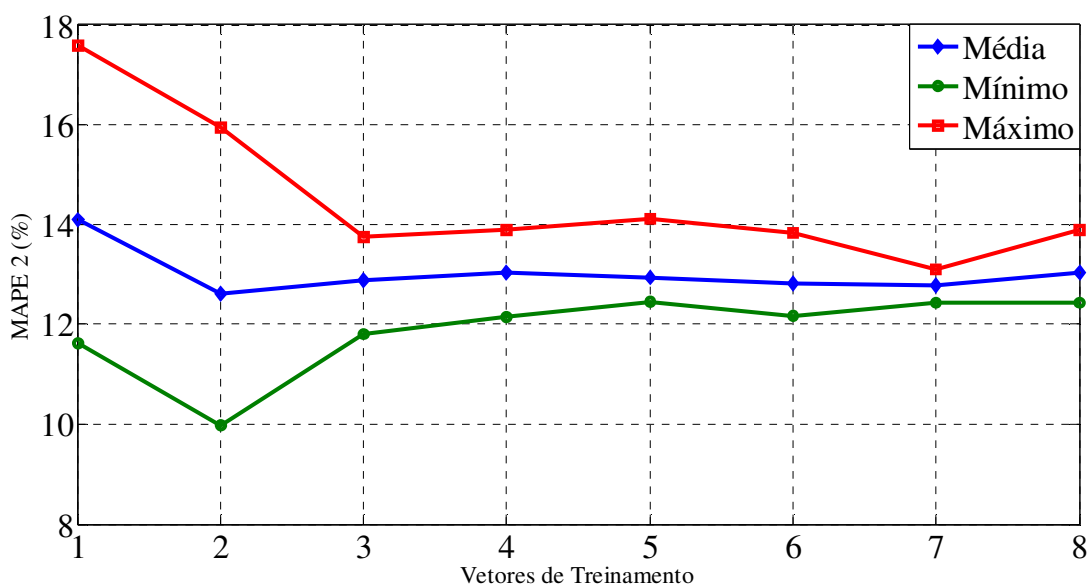


Figura 4.7 - Impacto do Aumento do Número de Vetores de Treinamento no MAPE 2 na Terceira Simulação.

Na terceira simulação, o melhor MAPE 2 (menor mínimo) resultou de uma rede com 6 neurônios na camada oculta, e o preço estimado e o realizado podem ser observados na Figura 4.8 (a).

O desempenho do sistema predictor não foi o desejado, ou seja, não ocorrendo uma superposição das duas linhas, mas, no entanto pode ser considerado como um bom resultado, tendo em vista que as linhas (Preço Realizado/Saída da Rede) preservam a estacionariedade das realizações bem próximas, ocorrendo em poucas horas (maiores oscilações) um pequeno distanciamento. O erro do sistema pode ser observado na Figura 4.8 (b). De um modo geral a variação do preço ficou em torno de U\$ 5,00 ocorrendo em poucos pontos extrapolação desse valor (U\$ 10,00).




Figura 4.8 - Melhor Resultado e Variação do Erro para Previsão de Um Dia

4.1.4 Quarta Simulação

Na quarta simulação o sistema predictor utilizou o alvo com um deslocamento futuro em uma semana que se comparado em horas da uma diferença de 168 horas à frente. De forma análoga as simulações anteriores, os dados foram divididos conforme demonstrado na Tabela 4.1. Os resultados do teste MAPE 2 dos 8 casos da quarta simulação, podem ser analisados na Tabela 4.5.

Depois de realizadas as simulações dos 8 casos, constatou-se que os melhores resultados foram no segundo caso, com os 3 melhores valores (média (12,03 %), mínimo (10,74 %) e máximo (12,90 %)). O melhor resultado não se baseia somente pela presença do menor MAPE 2, mas sim pela proximidade do valor máximo com a menor média, caracterizando a existências de um número maior de bons resultados.

Tabela 4.5 - Resultados do MAPE 2 % da Quarta Simulação

Caso Nº	Vetores de Treinamento	Dif. Dias	Vetor de Teste	Teste MAPE 2 (%)		
				Média	Mínimo	Máximo
1	22/3 à 28/3	7		13,68219	13,31528	14,3548
2	15/3 à 28/3	14		12,03431	10,74041	12,90252
3	8/3 à 28/3	21		12,89359	12,19814	13,39519
4	1/3 à 28/3	28	29/3 à 4/4	13,0405	12,43763	14,88936
5	22/2 à 28/3	35		13,22173	12,58726	15,17453
6	15/2 à 28/3	42		13,28346	12,06036	13,89327
7	8/2 à 28/3	49		13,51959	12,80538	15,31463
8	1/2 à 28/3	56		13,85618	13,39967	14,56124

Na quarta simulação as redes neurais responsáveis pelos resultados do mínimo e máximo MAPE 2 foram formadas por 3 neurônios na camada oculta.

Para análise gráfica da evolução dos MAPE 2 em relação o incremento de vetores de treinamento, os resultados da Tabela 4.5 foram representados na Figura 4.9.

Os resultados apresentaram no primeiro caso um movimento de queda, mas nos casos seguintes confirmou-se uma tendência de alta, sendo que, no sexto caso, tanto o máximo como o mínimo apresentaram uma pequena queda, que foi corrigida nos casos seguintes com os valores do oitavo caso sendo superiores aos do primeiro.




Figura 4.9 - Impacto do Aumento do Número de Vetores de Treinamento na Quarta Simulação

A projeção do preço da energia, mais os dados estimados com a rede de menor MAPE 2 da quarta simulação são demonstrados graficamente na Figura 4.10 (a). Os resultados da rede acompanharam com certa distância as tendências do preço, principalmente nas maiores oscilações. Como pode ser observado na Figura 4.10 (b), a variação do erro na maior parte do tempo foi de U\$5,00, principalmente nas últimas 60 horas.




Figura 4.10 - Melhor Resultado e Variação do Erro Para Previsão de Uma Semana

4.1.5 Quinta Simulação

De forma análoga as demais simulações já apresentadas até agora, os dados também foram divididos conforme demonstrado na Tabela 4.1, e os testes realizados com o alvo buscando a estimativa de um mês à frente. Os resultados obtidos são apresentados na Tabela 4.6.

Tabela 4.6 - Resultados do MAPE 2 % da Quinta Simulação

Caso Nº	Vetores de Treinamento	Dif. Dias	Vetor de Teste	Teste MAPE 2 (%)		
				Média	Mínimo	Máximo
1	22/3 à 28/3	7		19,12356	16,36179	21,83457
2	15/3 à 28/3	14		20,1332	19,17775	22,77188
3	8/3 à 28/3	21		20,53384	19,22286	21,82632
4	1/3 à 28/3	28	29/3 à 4/4	19,89066	19,07739	21,34183
5	22/2 à 28/3	35		20,52398	19,74226	20,96059
6	15/2 à 28/3	42		21,65128	20,75219	22,89972
7	8/2 à 28/3	49		21,96557	20,74542	22,68851
8	1/2 à 28/3	56		21,91339	21,41442	22,36191

A análise destes dados mostra que ao contrário do que ocorreu nas simulações anteriores, o primeiro caso teve o menor MAPE 2 médio. De modo geral os resultados desta simulação foram muito próximos um dos outros, com diferenças em torno de 3 pontos percentuais entre os MAPE 2, mínimo, médio e máximo.

A figura 4.11 demonstra o impacto do número de vetores de treinamento no MAPE 2 (mínimo, médio e máximo).

De maneira geral, observa-se uma tendência de alta do MAPE 2 mínimo com o acréscimo de vetores, passando de 16,46 % (com 1 vetor) para 21,41% (com 8 vetores). Do mesmo modo, embora menos expressiva, percebe-se uma tendência geral de alta em relação ao MAPE 2 médio (19,12 % a 21,91 %) com o acréscimo de vetores. Essa tendência de alta menos expressiva no MAPE 2 médio se deve a influência do MAPE 2 máximo que apresentou uma queda entre os vetores 2 e 5.




Figura 4.11 - Impacto do Aumento do Número de Vetores de Treinamento na Quinta Simulação

Através da figura 4.12 (a) pode-se ter uma dimensão do resultado da rede neural que teve o menor MAPE 2 para esse modelo, sendo representado graficamente à saída da rede mais o preço da energia (rede formada por uma estrutura neural com 11 neurônios na camada oculta).




Figura 4.12 - Melhor Resultado e Variação do Erro Para Previsão de Um Mês

Os resultados das 100 primeiras horas foram melhores que as demais horas, com as linhas que representam a saída da rede e a do preço realizado mais próximas uma da outra. O erro

na maior parte dos resultados foi de U\$5,00, conforme apresentado na Figura 4.12 (b), entretanto, em alguns pontos de maior oscilação do preço (Figura 4.12 (a)) a variação passou dos U\$10,00.

4.1.6 Sexta Simulação

Os vetores de treinamento como o vetor de teste da sexta simulação foram também divididos conforme a Tabela 4.1. A previsão teve um grau de incerteza maior que as simulações anteriores, pois o modelo utilizou preço alvo da energia num período futuro de um ano à frente.

A Tabela 4.7 apresenta os resultados dos oitos casos com a média das cinco simulações por caso e o valor mínimo e o valor máximo do MAPE 2. Mesmo com um intervalo de um ano a rede respondeu bem no primeiro caso tendo 8,45 % de mínimo, 15,75 % de média, e 17,89 % no maior MAPE 2. Dessa forma o primeiro caso mostrou-se como o melhor resultado para o modelo proposto.

Tabela 4.7 - Resultados do MAPE 2 % da Sexta Simulação

Caso Nº	Vetores de Treinamento	Dif. Dias	Vetor de Teste	Teste MAPE 2 (%)		
				Média	Mínimo	Maximo
1	22/3 à 28/3	7		15,75031	8,452024	17,89708
2	15/3 à 28/3	14		41,92617	37,31806	44,28819
3	8/3 à 28/3	21		42,38061	39,87672	44,93457
4	1/3 à 28/3	28	29/3 à 4/4	42,62238	40,31211	44,48387
5	22/2 à 28/3	35		41,94744	39,46547	44,62354
6	15/2 à 28/3	42		40,05814	39,03992	41,46817
7	8/2 à 28/3	49		39,28297	37,45628	40,49431
8	1/2 à 28/3	56		26,63451	25,5493	28,08579

A evolução dos resultados durante os 8 vetores de treinamento pode ser analisada na Figura 4.13.

O modelo atingiu um ponto de estabilidade na faixa dos 40 %, o primeiro caso apresentou os menores valores, que subiram no segundo caso, mantendo-se estabilizados até o quinto, quando os resultados entraram numa tendência de queda até o oitavo caso.

A Figura 4.14 (a) e (b) apresenta graficamente o resultado do menor MAPE 2 da sexta simulação, tendo a linha que representa a saída da rede na maior parte da amostra bem próximo do preço da energia realizada, com pequeno distanciamento nas maiores oscilações de preço.

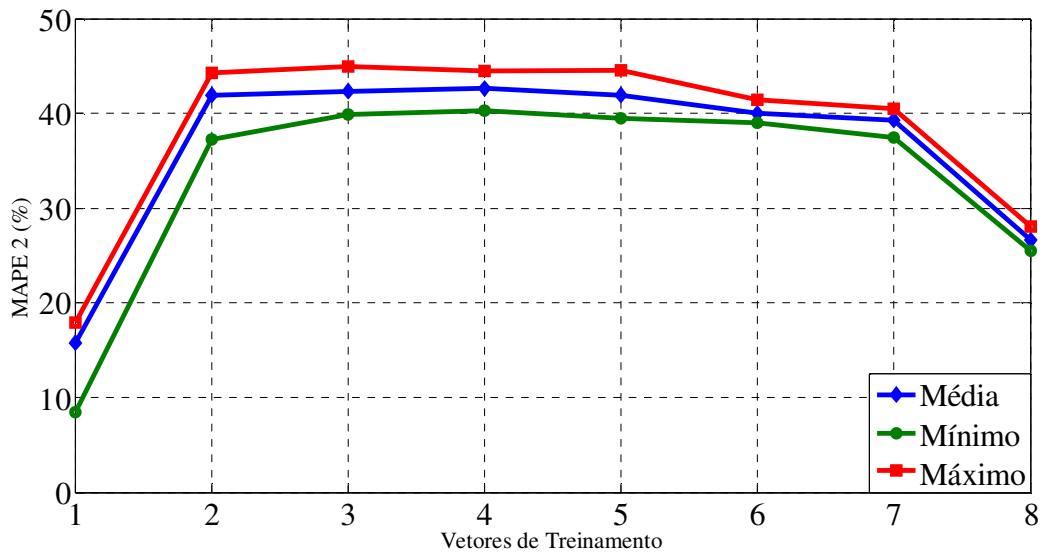


Figura 4.13 - Impacto do Aumento do Número de Vetores de Treinamento na Sexta Simulação





Figura 4.14 - Melhor Resultado e Variação do Erro Para Previsão de Um Ano

As rede com menor e maior MAPE 2 foram formadas por 11 neurônios na camada oculta. Observa-se que a maior parte da variação do erro apresentando na Figura 4.14 (b) foi de U\$5,00, entretanto, em alguns pontos essa variação chegou a U\$10,00, sendo que na hora que o alvo foi 0 o erro atingiu sua máxima ficando próximo dos U\$20,00.

4.1.7 Média do Erro

Através da Tabela 4.8, é possível observar a média dos testes MAPE 2 em relação aos valores médios, mínimos e máximos encontrados nas seis simulações para as diferentes variações de tempo. Com a variação do tempo as médias vão aumentando, no entanto a variação de uma hora apresenta uma quantidade maior de redes com mínimos menores que das outras variações.

Tabela 4.8 - Média dos MAPE 2 (%) para Variação No Tempo

Simulação	Variação do Tempo	Média Teste MAPE 2 (%)		
		Média	Mínimo	Maximo
1 ^a	Sem Variação	0,021674	0,000501	0,090713
2 ^a	Um Hora	7,980568	7,090601	10,00307
3 ^a	Um Dia	13,02531	11,87935	14,51315
4 ^a	Uma Semana	13,19144	12,44302	14,31069
5 ^a	Um Mês	20,71693	19,56176	22,08567
6 ^a	Um Ano	36,32532	33,43373	38,28444

É possível observar na Figura 4.15 a evolução dos resultados das médias do teste MAPE 2 nas seis simulações realizadas. O gráfico demonstra o aumento dos valores do teste MAPE 2 conforme a variação do tempo. Quanto mais distante do alvo maiores são os valores, sendo que sem variação o resultado foi quase 0 e com a previsão de um ano os valores superaram os 30%.

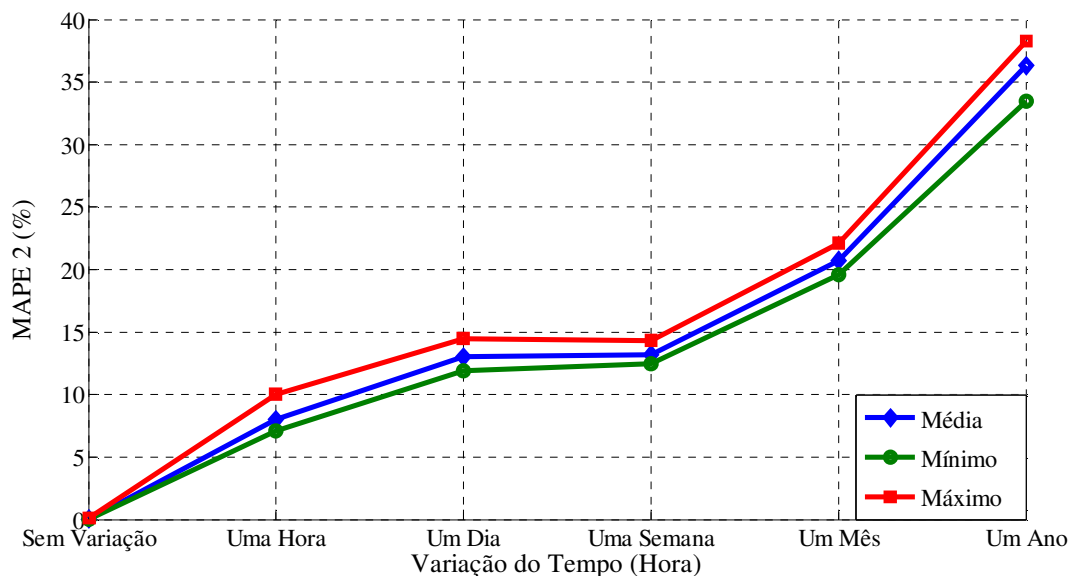


Figura 4.15 - Resultado das médias (Médias, Mínimos e Máximos)

4.2 Variações de Amostras para Treinamento e Validação

A seguir, serão apresentados os resultados, gráficos e numéricos das 12 simulações realizadas com diferentes amostras de dados e variações no tempo. A metodologia utilizada para definir as estruturas neurais segue o modelo proposto [9].

Os dados utilizados foram do mercado da Califórnia referente ao ano de 1999 (01/01/99 à 31/12/99). Para o treinamento e teste da rede, realizou-se a separação dos dados em 3 amostras conforme Figura 4.16, sendo duas com grandes oscilações de preço da energia e a última abrangendo quase todo universo de dados exceto a última semana do ano de 1999 (Para deslocar o alvo em uma semana no tempo a última semana não pode ser usada).

As amostras foram então denominadas pelos números 1, 2 e 3, separadas por ponto que correspondem às respectivas simulações (1, 2, 3 ou 4). Deste modo, tem-se, por exemplo, 3.2 indicando a 3ª amostra e a 2ª simulação.

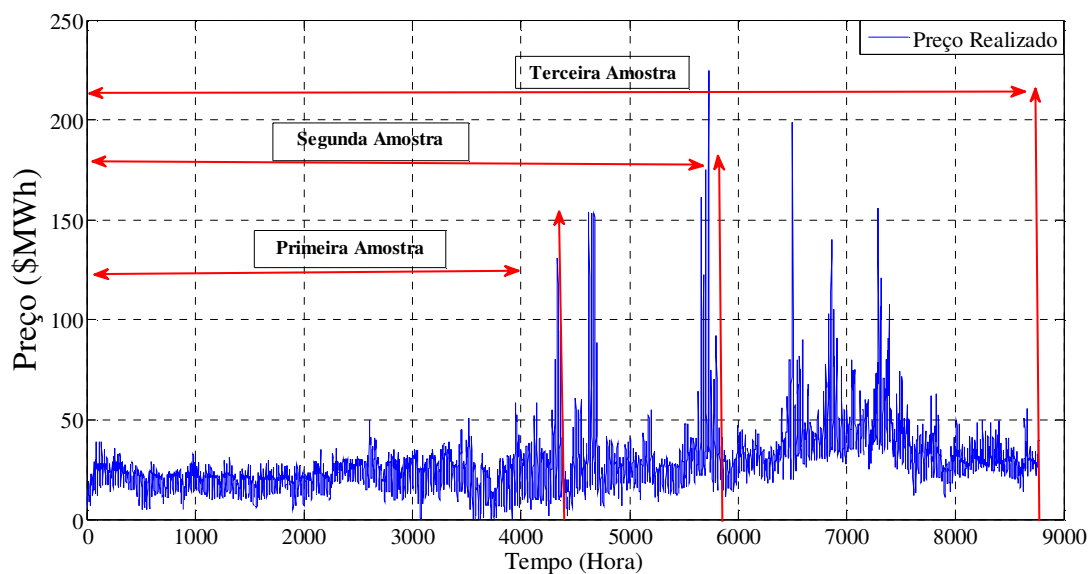


Figura 4.16 - Diferentes Amostras do mercado da Califórnia

Para cada amostra foram realizados 4 simulações com parâmetros diferentes. A primeira simulação utilizou todos os dados de treinamento com o alvo variando uma hora, a segunda utilizou só a última semana dos dados separados para treinamento com a variação do alvo também em uma hora, já a divisão dos dados para treinamento da rede na terceira e a quarta simulação seguiu o mesmo padrão da primeira e a segunda simulação, porém a variação do alvo foi de uma semana. Cada simulação compreende a criação e execução de 15 redes neurais, através do método [9].

4.2.1 Primeira Amostra

A primeira amostra de dados foi com 4369 horas (01/01/1999 até 02/07/1999), compreendendo a primeira grande oscilação do preço da energia. A representação gráfica da amostra, com o período dos dados utilizados para treinamento e teste encontra-se na Figura 4.17.




Figura 4.17 - Primeira Amostra de Dados

Para a primeira amostra de dados, foram realizadas 4 simulações com os diferentes parâmetros de treinamento e os resultados apresentados na Tabela 4.9.

Tabela 4.9 - Resultados do MAPE 2 (%) Para a Primeira Amostra de Dados

Amostra	Simulação	MAPE 2 (%)			Variação do Tempo	Tamanho da Amostra
		Média	Mínimo	Máximo		
1 ^a	1	17,87	16,25	19,44	Uma hora	Toda amostra
	2	26,54	13,77	37,85	Uma hora	Última semana
	3	33,58	28,39	40,59	Uma semana	Toda amostra
	4	43,27	24,98	52,74	Uma semana	Última semana

É possível observar que o menor (13,77 %) MAPE 2 das simulações com variação de uma hora foi na simulação 1.2, mesmo assim a simulação não pode ser definida como melhor sistema predictor, pois seu máximo (37,85 %) foi alto, implicando numa maior média (26,54 %). Entretanto, a simulação 1.1 (estrutura neural com 6 neurônios na camada oculta) apresentou uma menor distância entre o mínimo (16,25 %) e máximo (19,44 %) gerando uma média (17,87 %) menor. Quanto à variação do alvo em uma semana, a simulação 1.3 pode ser considerada como a melhor, pois mesmo não tendo o menor (24,98 %) MAPE 2 (simulação 1.4), sua média (33,58 %) e seu máximo (40,59 %) foram menores que os da

simulação 1.4 e o seu mínimo (28,39 %) foi menor que a sua própria média apresentando indícios de melhores resultados.

Durante a apresentação das simulações, a divisão dos dados de treinamento e teste dos melhores resultados de cada variação de tempo será representada graficamente.

A Figura 4.18 (a) apresenta toda a primeira amostra, sendo que na Figura 4.18 (b) estão os dados de treinamento e na Figura 4.18 (c) o preço da energia nos dados do teste.

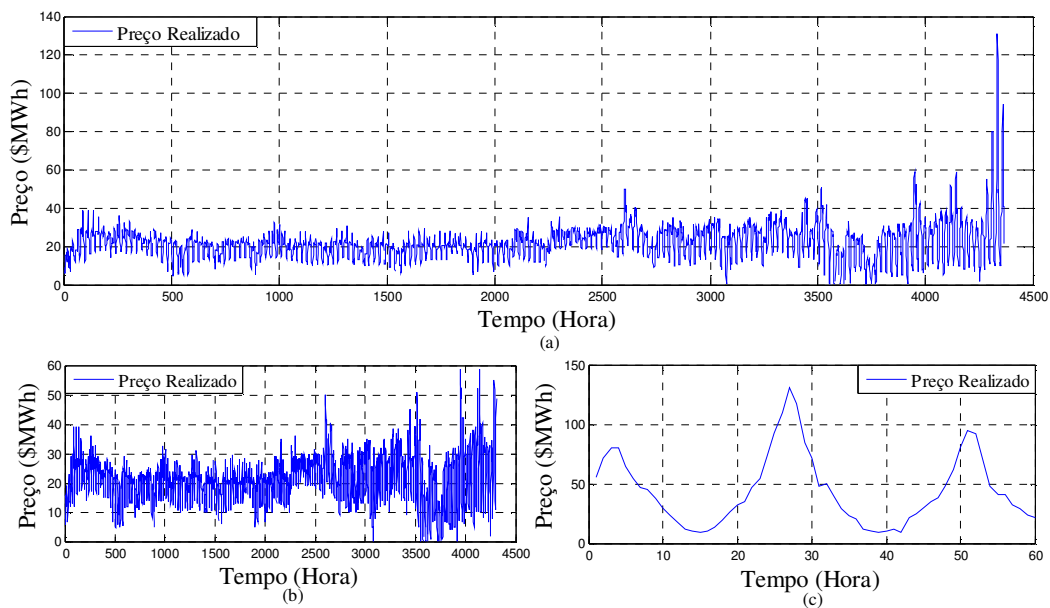


Figura 4.18 - Divisão da Primeira Amostra - Treinamento e Teste

Através da Figura 4.19, pode-se observar graficamente o resultado da rede neural com menor (16,25 %) MAPE 2 % da simulação 1.1. Mesmo com uma grande oscilação do preço da energia durante o teste, e o deslocamento do alvo em uma hora, a rede conseguiu acompanhar a tendência de alta e de baixa, com as linhas que representam a saída da rede e o preço da energia realizada se tocando em alguns pontos.




Figura 4.19 - Resultado do Menor MAPE 2 % da Primeira Amostra Com a Variação de Uma Hora

4.2.2 Segunda Amostra

Na segunda amostra de dados (Figura 4.20) às oscilações foram bem maiores que as oscilações da primeira, os preços chegaram a U\$200,00.




Figura 4.20 - Segunda Amostra de Dados

Os resultados das simulações realizadas com a segunda amostra podem ser observados na Tabela 4.10. Os melhores resultados para as simulações com alvo deslocado no tempo em uma hora, foram obtidos na simulação 2.1, com a menor média (16,26%), o menor mínimo (14,06%) e o menor máximo (19,44%) MAPE 2. Com uma semana de treinamento a simulação 2.2 atingiu um mínimo (17,94 %) próximo da média da simulação 2.1, entretanto, o valor máximo (42,83 %) foi maior que o dobro da simulação 2.1 (Máximo 2.1 = 19,44 %).

Tabela 4.10 - Resultados do MAPE 2 (%) Para a Segunda Amostra de Dados

Amostra	Simulação	MAPE 2 (%)			Variação do Tempo	Tamanho da Amostra
		Média	Mínimo	Máximo		
2 ^a	1	16,26	14,06	19,44	Uma hora	Toda amostra
	2	33,13	17,94	42,83	Uma hora	Última semana
	3	41,74	34,07	48,03	Uma semana	Toda amostra
	4	49,25	37,06	64,67	Uma semana	Última semana

Para as simulações com variações de uma semana, a utilização de toda a amostra para treinamento mostrou-se mais eficiente, a melhor simulação foi a 2.3 com os resultados (média (41,74 %), mínimo (34,07%) e máximo (48,03 %)) menores que os da simulação 2.4, que teve valores maiores (média (49,25%), mínimo (37,06%) e máximo (64,67%)). A separação dos dados para treinamento e simulação (2.1 e 2.3), encontra-se representado graficamente na Figura 4.21 (a), (b) e (c).

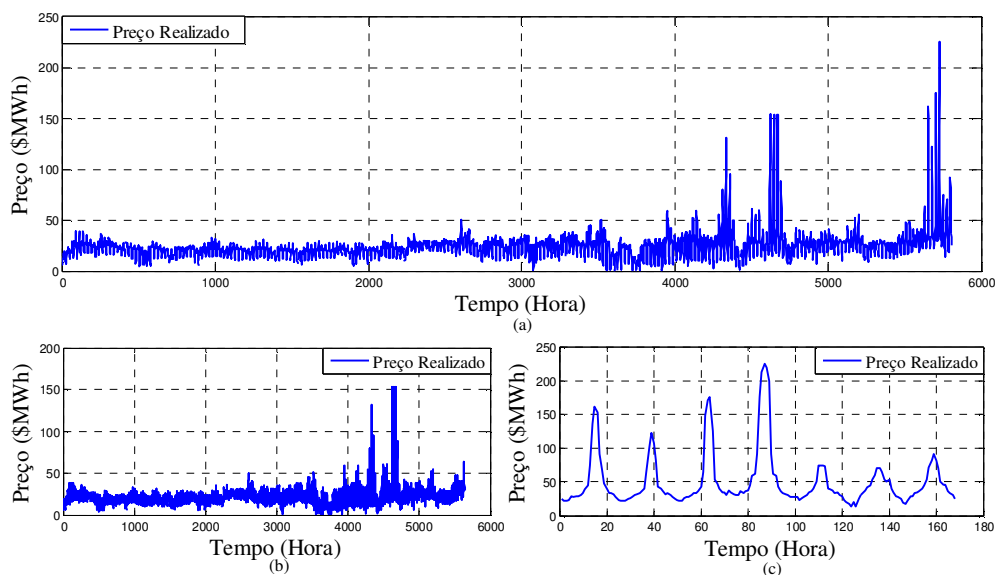


Figura 4.21 - Divisão da Segunda Amostra Para Treinamento e Teste.

O resultado da rede neural com o mínimo MAPE 2 da simulação 2.1 (11 neurônios na camada oculta) pode ser observado na Figura 4.22, o resultado foi próximo do desejado, ocorrendo quase que uma superposição das linhas que representam a saída da rede e o preço realizado.




Figura 4.22 - Resultado do Menor MAPE 2 % da Segunda Amostra Com a Variação De Uma Hora

A rede com melhor MAPE 2 da simulação 2.3 (estrutura neural com 11 neurônios na camada oculta) pode ser observada na Figura 4.23




Figura 4.23 - Resultado do Menor MAPE 2 % da Segunda Amostra Com a Variação de Uma Semana

4.2.3 Terceira Amostra

A terceira amostra foi selecionada com o objetivo de testar a capacidade de previsão das redes neurais com o maior número possível de informação. A representação gráfica da amostra utilizada pode ser observada através da Figura 4.24.




Figura 4.24 - Terceira Amostra de Dados

O alvo da terceira amostra apresenta um preço com oscilações mais discretas, impactando positivamente nos resultados das simulações realizadas, como apresentado na Tabela 4.11.

Tabela 4.11 - Resultados do MAPE 2 (%) Para a Terceira Amostra de Dados

Amostra	Simulação	MAPE 2 (%)			Variação do Tempo	Tamanho da Amostra
		Média	Mínimo	Máximo		
3 ^a	1	12,87	6,58	17,20	Uma hora	Toda amostra
	2	9,50	7,99	11,81	Uma hora	Última semana
	3	23,55	20,34	25,84	Uma semana	Toda amostra
	4	10,99	9,94	12,26	Uma semana	Última semana

Através da tabela 4.11, é possível observar que a simulação 3.2 é a melhor escolha para o modelo com variação de do alvo em uma hora. Mesmo não tendo o menor mínimo entre as

simulações (simulação 3.1 MAPE 2 = 6,58 %), seu conjunto de resultados foi melhor, com uma média (9,50 %) próxima do mínimo (7,99 %) e ao mesmo tempo do máximo (11,81 %) sinalizando a existência de melhores resultados. Para as simulações com variação do alvo em uma semana, a simulação 3.4 apresentou melhores resultados, com os valores próximos da simulação 3.1.

As divisões de dados para treinamento e teste das simulações 3.2 e 3.4 são representadas pela Figura 4.25, sendo toda a amostra de dados representada pela Figura 4.25 (a), os dados de treinamento pela Figura 4.25 (b) e os dados utilizados no teste pela a Figura 4.25 (c).

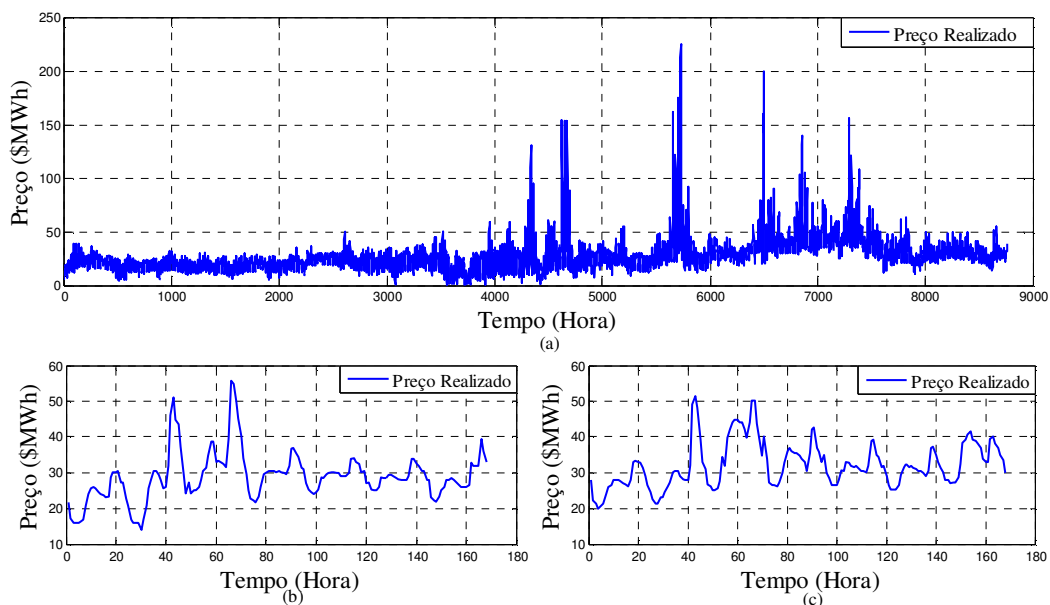


Figura 4.25 - Divisão da Terceira Amostra - Treinamento e Teste

A representação gráfica do resultado da rede com menor MAPE 2 da simulação 3.2 (rede neural com 6 neurônios na camada oculta) é mostrado através das Figura 4.26. O preço estimado esteve próximo do preço realizado, com alguns pontos apresentando pequenos distanciamentos.




Figura 4.26 - Resultado do Menor MAPE 2 % da Terceira Amostra Com a Variação de Uma Hora

Através da Figura 4.27 é possível observar graficamente o resultado da rede neural com menor MAPE 2 entre as simulações (simulações 3.3 e 3.4) com o alvo uma semana à frente.




Figura 4.27 - Resultado do Menor MAPE 2 % da Terceira Amostra Com Variação de Uma Semana

A rede com 11 neurônios na camada oculta conseguiu de um modo geral acompanhar a tendência do preço, exceto em torno do período de 80 a 100 horas e nas horas finais.

4.3 Redes Neurais aplicadas ao Mercado Brasileiro

Deste ponto em diante serão abordados os resultados das redes neurais aplicadas aos dados do mercado brasileiro, mais especificamente com dados do submercado sudeste e centro oeste. Foram selecionados 3 cenários (amostras), como apresentados na Figura 4.28, e treinadas com diferentes parâmetros de configuração e dados de treinamento.




Figura 4.28 - Preço do Mercado sudeste e centro oeste (07/2001 à 04/2012).

Os cenários foram então denominados pelos números 1,2 e 3, separados por ponto que correspondem aos respectivos sistemas previsores (1, 2, 3 e 4). Deste modo, tem-se, por exemplo, 1.1 indicando 1º cenário e o 1º sistema previsor.

Os sistemas previsores foram treinados da seguinte forma:

- 1º Toda a amostra de treinamento com a variação do alvo em uma semana;
- 2º As últimas 14 semanas do treinamento com a variação do tempo em uma semana;
- 3º Toda a amostra de treinamento com a variação do tempo em quatro semanas;
- 4º As últimas 14 semanas do treinamento com a variação do tempo em quatro semanas.

Os dados utilizados para treinamento formam um total de 18 variáveis, sendo estas extraídas dos sistemas da CCEE (1), da ONS (9), do IBGE (6) e a EIA(2), referentes ao período de 01/07/2001 à 06/04/2012. Para o treinamento da rede foram realizados 9 combinações (9 casos) com as 18 variáveis, conforme demonstrado na Tabela 4.12, sendo que as variáveis da CCEE e da ONS foram fixas em 8 casos (caso 2 ao caso 9).

Tabela 4.12 - Combinações das variáveis utilizadas no treinamento da rede

N° Casos	CCEE	ONS	Gasto de Energia	Atividade Industrial	EIA
1*	X	X			
2	X	X			
3	X	X			X
4	X	X		X	
5	X	X	X		
6	X	X	X		X
7	X	X		X	X
8	X	X	X	X	
9*	X	X	X	X	X

A definição do número de neurônios na camada oculta, para treinamento e teste seguiu o método proposto [9], calculando o número de neurônios de acordo com a quantidade de dados de entrada (3 diferentes quantidade de neurônio). O procedimento de treinamento para cada sistema foi repetido 5 vezes para cada um dos 3 valores de neurônios na camada oculta, resultando em 15 redes neurais para cada caso (9 casos), após os testes (15 simulações), foram calculadas as médias e identificados os valores mínimos e máximos do MAPE e MAPE 2 e as quantidades de neurônios na camada de entrada, na camada oculta e na de saída conforme apresentado na Tabela 4.13. As amostras foram separadas em treinamento e teste, sendo que a amostra de teste é formada pelas últimas 7 semanas de cada cenário e a de treinamento pelas semanas restantes.

Na apresentação dos resultados, optou se em demonstrar todas as simulações realizadas no sistema 1.1, porém para os demais sistemas previsores apresentou somente os 3 melhores resultados de cada sistema.

4.3.1 Primeiro Cenário

4.3.1.1 Primeiro sistema previsor (1.1)

O objetivo do primeiro sistema previsor foi medir o desempenho das redes neurais com as 9 combinações de variáveis, conforme apresentado na Tabela 4.12.

O sistema utilizou toda a amostra de treinamento e variou o alvo uma semana no tempo, os resultados do sistema podem ser analisados na Tabela 4.13. A rede com menor MAPE e MAPE 2 foi no sexto caso, com uma estrutura neural de 31 neurônios na camada oculta.

Tabela 4.13 – Melhores Resultados do sistema 1.1

N° Casos	Estrutura Neural	Teste MAPE %			Teste MAPE 2 %		
		Média	Mínimo	Máximo	Média	Mínimo	Máximo
1*	5-11-1	25,57	17,27	47,09	20,19	16,01	40,06
2	10-6-1	40,21	21,71	78,11	29,40	17,69	50,10
3	12-7-1	43,11	21,97	109,97	35,49	17,43	68,84
4	13-27-1	35,80	18,78	56,44	36,33	16,47	64,39
5	13-14-1	54,04	19,13	124,95	37,49	12,92	155,92
6	15-31-1	45,89	12,36	113,80	35,75	12,65	78,96
7	15-8-1	37,12	18,70	122,95	31,03	16,51	64,79
8	16-9-1	83,13	21,88	226,95	63,31	16,49	183,68
9	18-10-1	85,28	28,52	225,49	69,22	24,85	117,65

* Utilização do PLD, Energia Armazenada, ENA, CE e CD

Conforme os resultados apresentados na Tabela 4.13, as variáveis utilizadas no primeiro caso proporcionaram os melhores resultados em relação aos demais, com a menor média e o menor máximo.

A Figura 4.29 (a) representa graficamente os resultados do MAPE e a Figura 4.29 (b) os resultados do MAPE 2 para as 9 combinações de variáveis. Como mostra as Figuras 4.29 (a) e (b), as simulações que utilizaram as maiores quantidade de variáveis no treinamento apresentaram os piores desempenhos entre as previsões (MAPE 16 variáveis =83,13 % de

média, 18 variáveis = 85,28 % de média e MAPE 2 16 variáveis = 63,31 % de média e 18 variáveis = 69,22 % de média).

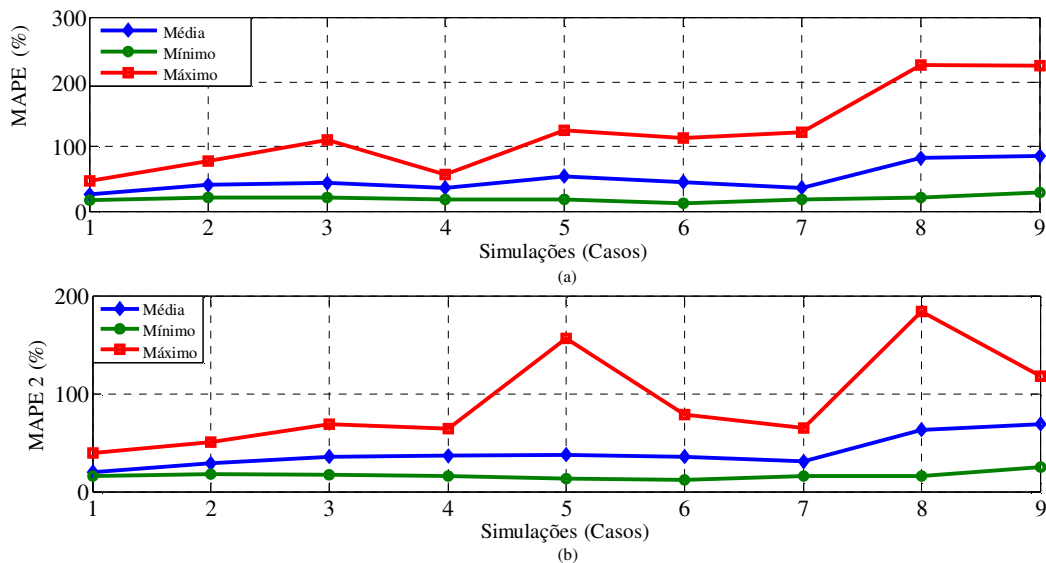


Figura 4.29 - Impacto da quantidade de variável do primeiro teste no primeiro sistema predictor

Um dos fatores que podem ter contribuído para os menores valores nos primeiros casos foram as quantidades de variáveis utilizadas no treinamento, tendo em vista que o primeiro caso foi treinado com 5 variáveis (CCEE (PLD), ONS (E_armaz, ENA, CE e CD)) resultando na menor média (25,57 %) e o menor mínimo (17,27 %) para o MAPE e para o MAPE 2 (média= 20,19 % e mínimo 16,01 %).

Mesmo num cenário com grade oscilação de preço, a rede conseguiu aproximar o preço estimado do realizado, como mostra a Figura 4.30 (a). O preço alvo utilizado no teste da rede, variou bastante nas 7 semanas, saindo de R\$12,2 para R\$98,47, no entanto só em dois pontos a rede apresentou um erro maior que R\$10,00, como pode ser observado na Figura 4.30 (b) que representa graficamente o erro entre a saída da rede e o preço estimado.




Figura 4.30 - Resultado do melhor MAPE e MAPE 2 do primeiro caso

4.3.1.2 Segundo Sistema Previsor (1.2)

O segundo sistema previsor foi realizado com as mesmas variáveis utilizadas no primeiro sistema (Tabela 4.12) e a variação do tempo em uma semana, porém o treinamento foi realizado com as últimas 14 semanas. Os melhores resultados do sistema podem ser observados na Tabela 4.14.

Tabela 4.14 - Melhores resultados do sistema 1.2

N° Casos	Estrutura Neural	Teste MAPE %			Teste MAPE 2 %		
		Média	Mínimo	Máximo	Média	Mínimo	Máximo
1	5-3-1	97,61	36,28	246,65	64,75	23,21	129,61
2	10-21-1	86,98	32,69	188,11	71,22	22,35	149,38
4	13-27-1	116,10	31,51	236,33	73,73	21,28	138,81

No sistema 1.2, os resultados foram piores que os resultados do sistema 1.1. A redução dos dados de treinamento mostrou-se ineficiente para o modelo. O segundo caso pode ser considerado como melhor sistema para o modelo em estudo, mesmo considerando que o caso número 4 apresenta o menor MAPE e o MAPE 2 (31,51 % e 21,28% respectivamente), entretanto, a menor média do MAPE (86,98 %) foi a menor entre os casos testados. A rede neural com menor mínimo do segundo caso é formada por 10

neurônios na camada de entrada, 21 na camada oculta é 1 neurônio na camada de saída da rede.

A Figura 4.31 (a) e (b) apresenta em forma de gráfico os resultados do MAPE e MAPE 2 para os 9 casos simulados. Observa-se que mesmo altos, os valores médios e mínimos se mantiveram estabilizados, diferente do valor máximo que passou de 400 % no quinto caso.

Os altos valores do máximo representam um nível grande de incerteza ao modelo, jogando a média do sistema para cima, pois os resultados dos valores mínimos não ficaram tão distantes do sistema previsor 1.1.

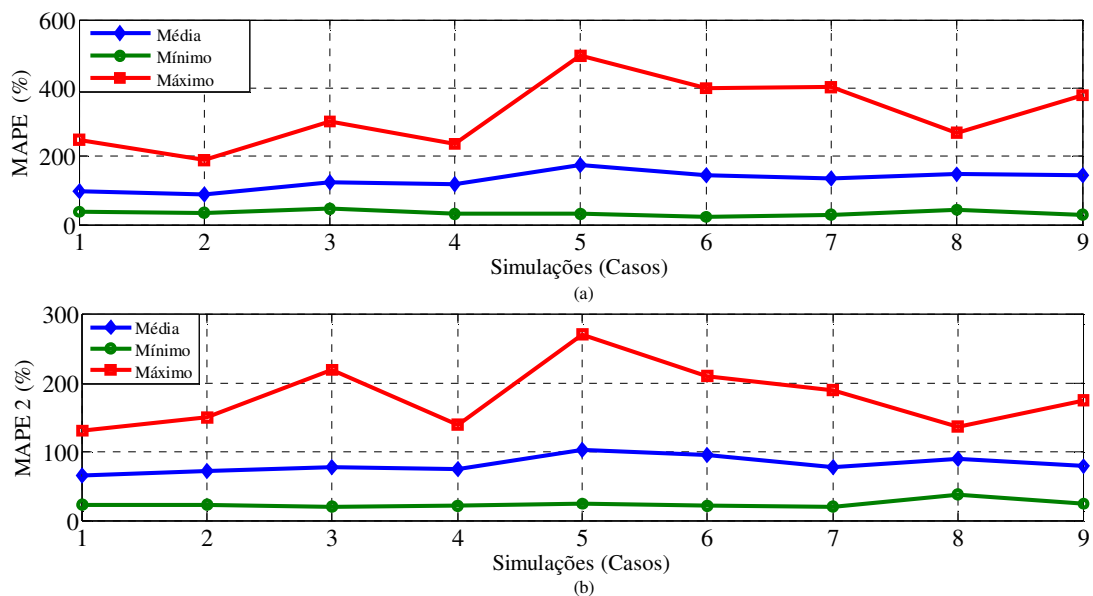


Figura 4.31 - Evolução dos resultados do MAPE e MAPE 2 do sistema 1.2

Os resultados da rede com menor MAPE do sistema 1.2 pode ser analisado na Figura 4.32 (a) e o erro na Figura (b).

Mesmo com um MAPE alto, a rede conseguiu acompanhar a tendência de alta dos preços, porém a variação do erro passou de R\$20,00 no intervalo de 7 semanas utilizadas no teste da rede. Mesmo com um tempo de processamento menor o 1.2 mostrou-se menos eficiente em relação as previsões dos sistema 1.1, que apresentaram um MAPE menor.




Figura 4.32 - Resultado da rede com menor MAPE no sistema 1.2 do primeiro cenário.

4.3.1.3 Terceiro Sistema Previsor (1.3)

O sistema 1.3 utilizou as variáveis e toda a amostra de treinamento de forma análoga ao sistema 1.1, porém com o deslocamento do alvo no futuro em quatro semanas.

Quando mais distante a previsão está do preço realizado, maior é a incerteza do sistema previsor, entretanto, no referido sistema a variação de 1 para 4 semanas (1 mês) não piorou os resultados (apresentados na Tabela 4.15), já que o MAPE mínimo encontrado no caso 1 (6,47 %) foi menor que as simulações realizadas com variação de uma semana para o mercado da Califórnia (Tabela colocar) e o MAPE mínimo (11,40 %) referente ao mercado espanhol [69].

Tabela 4.15 - Melhores resultados do sistema 1.3

Nº Casos	Estrutura Neural	Teste MAPE %			Teste MAPE 2 %		
		Média	Mínimo	Máximo	Média	Mínimo	Máximo
1	5-3-1	29,97	6,47	104,99	34,03	5,78	125,16
4	13-27-1	41,55	6,79	65,09	40,78	6,94	70,34
7	15-8-1	40,48	19,43	71,74	42,84	18,26	69,07

Portanto, o melhor sistema previsor para esse modelo foi o primeiro caso, com a menor média (29,97 %) e o menor mínimo (6,47 %), sendo a estrutura da rede composta por 5

neurônios na camada de entrada, 3 neurônios na camada oculta e uma na camada de saída. A média dos MAPE médios do sistema 1.3 foi 69,07 %.

A evolução do MAPE e MAPE 2 podem ser observados através das Figuras 4.33 (a) e (b). O pior resultado do MAPE no sistema foi no quinto caso, apresentando o maior MAPE médio (172,77%). Os valores da média e do mínimo do MAPE de uma forma geral se mantiveram estabilizados. O incremento de variáveis no treinamento tendeu a piorar os resultados da rede exceto nos casos 4, 6 e 7 (Figuras 4.33 (a) e (b)).

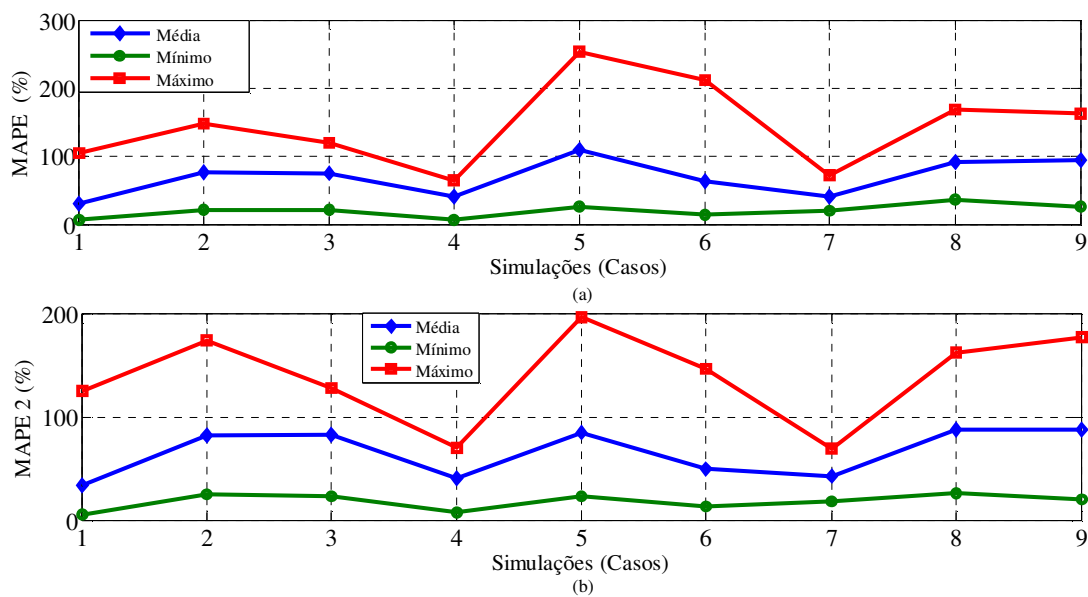


Figura 4.33 - Evolução dos resultados do MAPE e MAPE 2 do sistema 1.3

A Figura 4.34 apresenta em forma de gráfico a saída da rede neural, considerando o tempo de teste e o preço realizado (Figura 4.34 (a)) e a variação do erro entre os dois (Figura 4.34 (b)). O sistema 1.3 apresentou seu melhor resultado na quinta semana, tendo a variação do erro próxima de 0. A variação máxima do erro foi de + ou - R\$10,00 na quarta e sétima semana respectivamente.

É interessante também ressaltar que as linhas da Figura 4.34 (a) estiveram muito próximas durante quase todo teste, apresentando uma boa capacidade de previsão e acompanhamento da tendência do mercado.




Figura 4.34 - Resultado da rede com menor MAPE no sistema 1.3

4.3.1.4 Quarto sistema predictor (1.4)

O quarto sistema predictor utilizou a combinação das variáveis apresentadas na Tabela 4.12, tendo por objetivo a previsão de quatro semanas (1 mês) a frente, entretanto, diferente do terceiro sistema predictor, os dados de treinamento foram restritos apenas as últimas 14 semanas. Os melhores resultados do sistema 1.4, podem ser observados na Tabela 4.16. O primeiro caso apresentou o melhor resultado, com a menor média (45,92 %) do MAPE, menor mínimo (16,97 %) e máximo (83,24 %) entre os casos testados. A estrutura neural referente ao menor mínimo foi de 5 neurônios na camada de entrada, 3 na camada escondida e 1 na saída.

Tabela 4.16 - Melhores resultados do sistema 1.4

N° Casos	Estrutura Neural	Teste MAPE %			Teste MAPE 2 %		
		Média	Mínimo	Máximo	Média	Mínimo	Máximo
1	5-3-1	45,92	16,97	83,24	41,55	18,46	74,17
2	10-21-1	66,03	29,90	124,30	57,24	22,64	101,80
4	13-7-1	66,31	29,72	121,35	55,66	23,70	92,97

A evolução dos resultados do sistema 1.4 pode ser analisada graficamente através da Figura 4.41. De maneira geral os valores médios foram piores que o sistema predictor 1.3,

sendo que a média dos MAPE médios foi de 81,02 % no sistema 1.4 e 69,07 % no sistema 1.3. Nesse sistema o melhor resultado da rede correspondeu ao primeiro caso (Figura 4.35).




Figura 4.35 - Evolução dos resultados do MAPE e MAPE 2 do sistema 1.4

Em relação a Figura 4.36 (a), observa-se que as linhas que representam a saída da rede e o preço realizado se tocam em 2 pontos contribuindo para uma menor variação do erro (próximo de 0) nas semanas 2 e 4 (Figura 4.36 (b)).




Figura 4.36 - Resultado da rede com menor MAPE no sistema 1.4

O erro desse sistema variou aproximadamente entre R\$20,00 e R\$40,00, portanto foi pior que o sistema previsor anterior (1.3).

4.3.2 Segundo Cenário

O segundo cenário utilizou uma amostra do universo de dados do mercado brasileiro com o preço da energia mais estabilizado, sem grandes oscilações. Foram separadas as últimas 7 semanas do segundo cenário para teste da rede e as demais semanas foram utilizadas para o treinamento. O treinamento das redes para os 4 sistemas previsores foram realizados com as combinações das variáveis conforme Tabela 4.12.

4.3.2.1 Primeiro sistema previsor (2.1)

O primeiro sistema (2.1) foi treinado com a variação do tempo em uma semana. Os 3 melhores resultados do sistema 2.1 podem ser observados na Tabela 4.17.

Tabela 4.17 - Melhores resultados do sistema 2.1

N° Casos	Estrutura Neural	Teste MAPE %			Teste MAPE 2 %		
		Média	Mínimo	Máximo	Média	Mínimo	Máximo
1	5-11-1	5,79	2,56	10,23	5,89	2,65	10,11
5	13-7-1	18,76	5,33	38,04	18,87	5,95	38,39
8	16-33-1	20,59	4,92	77,17	20,57	6,01	74,32

Após as simulações este sistema chegou-se a resultados melhores em relação aos já encontrados nas simulações com os dados do mercado da Califórnia bem como os dados do Brasil apresentados no primeiro cenário, além de resultados melhores dos que os publicados em outros trabalhos [9], [69] [70] e [3].

O incremento de variáveis no treinamento apresentou uma piora nos resultados da média como pode ser observado na Figura 4.37, no entanto, não foi determinante para definição dos piores resultados. Por exemplo, o oitavo caso que com 16 variáveis alcançou o terceiro melhor resultado (Tabela 4.17). Com uma estrutura neural de 5 neurônios na camada de entrada , 11 na camada oculta e 1 na de saída, o primeiro caso obteve o menor MAPE

mínimo do sistema. No sistema 2.1 o primeiro caso alcançou o melhor resultado, menores MAPE (média, mínimo e máximo). A média dos MAPE médio neste sistema foi de (31,11%), portanto melhor que todos os outros sistemas. Isso é esperado considerando que a amostra não tem grandes oscilações de preços, mostrando que neste cenário hipotético a utilização da rede neural é mais eficiente.

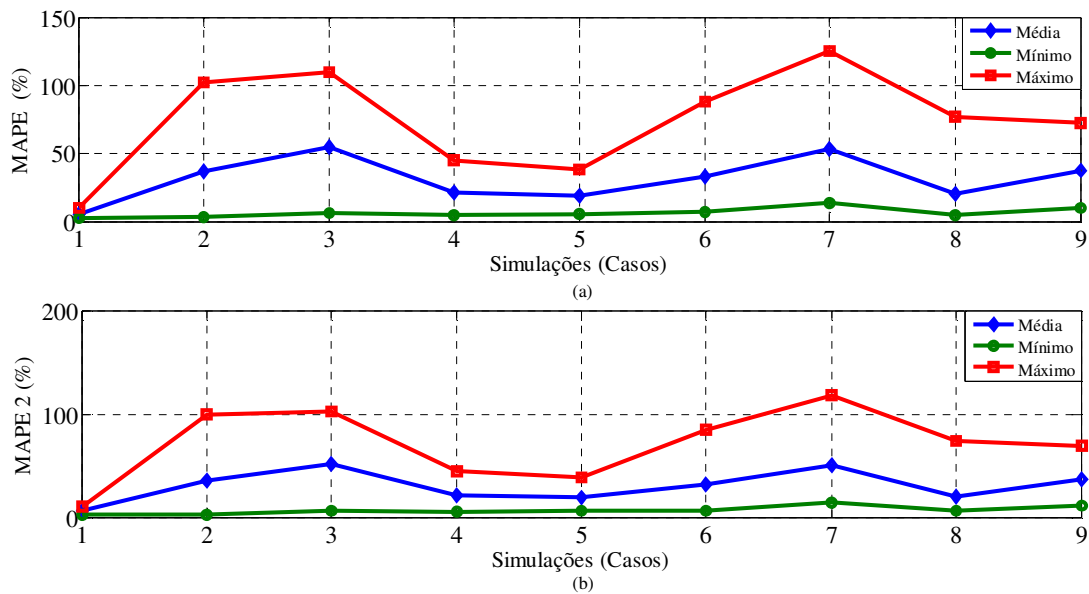


Figura 4.37 - Evolução dos resultados do MAPE e MAPE 2 do sistema 2.1

Através da Figura 4.38 (a) pode se observar o resultado da saída da rede com o preço realizado, e na Figura 4.38 (b) o erro entre a subtração dos 2 valores.

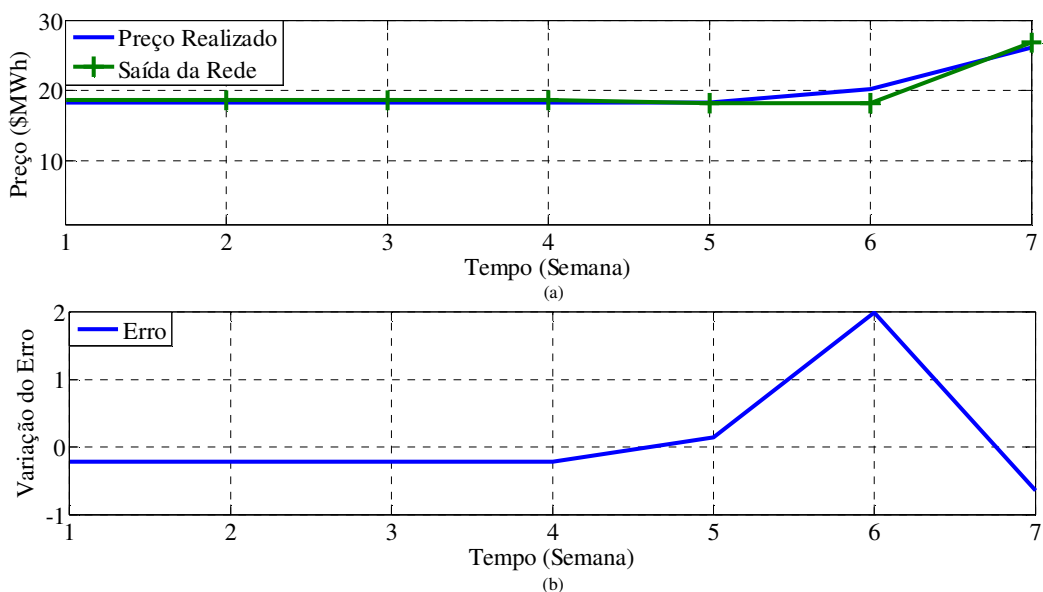


Figura 4.38 - Resultado da rede com menor MAPE no sistema 2.1

A Figura 4.38 (a) apresenta quase que uma superposição das duas linhas com um pequeno distanciamento na sexta semana do teste, que gerou uma diferença (erro) de R\$ 2,00. Do mesmo modo, este resultado apresenta-se influenciado pela pequena oscilação do preço durante o treinamento que contribuiu para o melhor desempenho da rede.

4.3.2.2 Segundo Sistema predictor (2.2)

No sistema 2.2 do segundo cenário, o objetivo do alvo foi de uma semana a frente e o treinamento realizado com as 14 últimas semanas da amostra de treinamento. A Tabela 4.18 apresenta os 3 melhores resultados do sistema.

Tabela 4.18 - Melhores resultados do sistema 2.2

N° Casos	Estrutura Neural	Teste MAPE %			Teste MAPE 2 %		
		Média	Mínimo	Máximo	Média	Mínimo	Máximo
1	5-11-1	9,24	1,73	34,90	8,87	1,74	32,89
2	10-21-1	14,88	2,80	21,74	14,56	3,03	21,28
8	16-9-1	18,96	6,22	37,52	18,72	6,20	37,48

O melhor MAPE médio foi no primeiro caso (9,24%), com uma rede neural com 11 neurônios na camada oculta. Através da Figura 4.39 pode ser observar a evolução dos resultados com o aumento do número de variáveis. Conforme mostra a tabela 4.18, o acréscimo de variáveis tendeu a piorar o resultado. Entretanto, o aumento do número de variáveis não foi determinante para definição do pior resultado, sendo que o terceiro caso (com 12 variáveis) teve o MAPE médio maior que o oitavo caso (com 16 variáveis). Entretanto, destaca-se, que os casos que utilizaram as variáveis da EIA apresentaram maiores médias do MAPE (caso 3, 6, 7 e 9), portanto pioraram o resultado da rede para este cenário. A média dos MAPE médio neste sistema foi de 23,61%, sendo melhor que sistema anterior mesmo utilizando menos dados no treinamento.

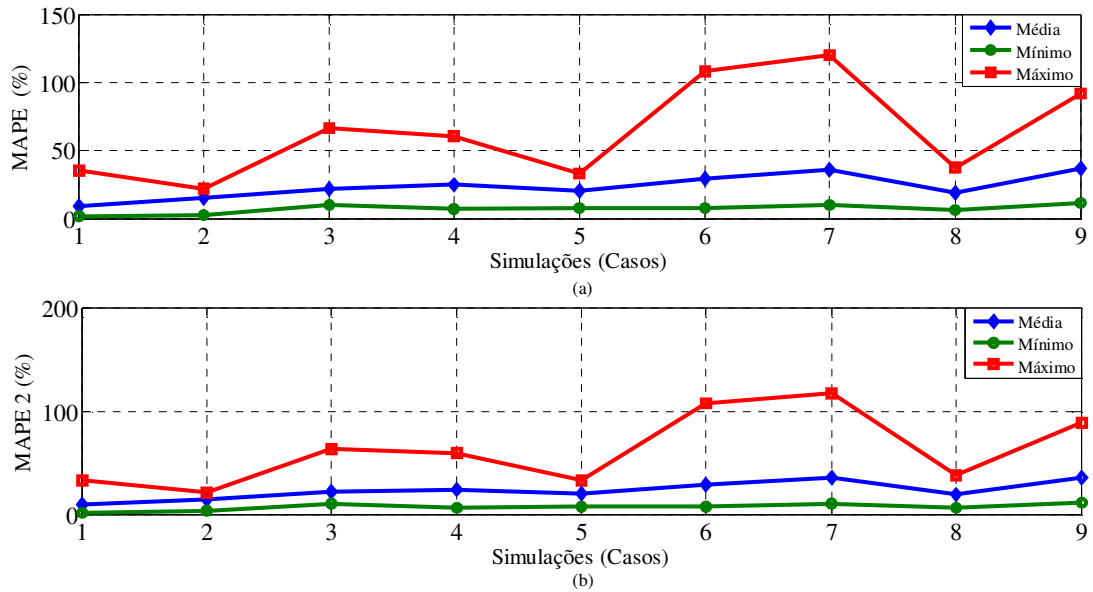


Figura 4.39 - Evolução dos resultados do MAPE e MAPE 2 do sistema 2.2

A Figura 4.39 mostra que os resultados da média e do mínimo se mantiveram praticamente estabilizados.

O melhor resultado do primeiro caso do sistema 2.2 é representado graficamente pela Figura 4.40.




Figura 4.40 - Resultado da rede com menor MAPE no sistema 2.2

As linhas que representam a saída da rede e o preço realizado apresentam-se quase que sobrepostas (Figura 4.40 (a)) representando uma variação do erro próxima de zero (Figura

4.40 (b)). Neste sistema a maior variação do erro ocorreu na quinta semana (R\$1,36), chegando a apenas R\$0,50 na sexta e sétima semana do teste.

4.3.2.3 Terceiro Sistema Previsor (2.3)

O terceiro sistema previsor do segundo cenário, também chamado de sistema 2.3, foi treinado com a combinação de variáveis apresentado na Tabela 4.12, e o deslocamento do alvo no tempo em 1 mês ou quatro semanas.

Para o sistema 2.3, os melhores resultados foram nos casos 1,2 e 6, sendo o primeiro caso o melhor entre os três com os menores MAPE (médio, mínimo e máximo), resultado de uma rede neural com 5 neurônios na camada de entrada e 3 na camada de saída.

Diferente dos dois sistemas anteriores, os resultados não foram tão satisfatórios como os das simulações 2.1 e 2.2 podendo ter relação com a maior variação do alvo do teste (já que o preço do alvo apresenta um preço maior que do treinamento (Figura 4.42, (a))). A média dos MAPE médios foi de 77,49%. Os melhores resultados do sistema 2.2 são apresentados na Tabela 4.19.

Tabela 4.19 - Melhores resultados do sistema 2.3

N° Casos	Estrutura Neural	Teste MAPE %			Teste MAPE 2 %		
		Média	Mínimo	Máximo	Média	Mínimo	Máximo
1	5-3-1	32,39	15,75	86,02	37,08	18,26	81,06
2	10-6-1	56,68	24,89	136,80	53,95	26,41	100,64
6	15-8-1	64,71	27,31	130,21	63,58	31,23	117,63

A evolução de todos os casos do terceiro sistema previsor pode ser observada na Figura 4.41 (a) e (b). As simulações que apresentaram os piores resultados foram nos casos 4 e 9, tendo por combinação de variáveis os dados da CCEE, ONS e Gasto de Energia (caso 4) e a utilização de todas as variáveis (caso 9).




Figura 4.41 - Evolução dos resultados do MAPE e MAPE 2 do sistema 2.3

A representação gráfica do resultado da rede com menor MAPE do sistema 2.3, pode ser observado através da Figura 4.42 (a). O preço realizado variou aproximadamente R\$25,00 nas 7 semanas utilizadas no teste da rede (4.42 (a)). A maior variação do erro foi de R\$16,00 na sexta semana que teve o maior preço para o período (Figura 4.48 (b)).




Figura 4.42 - Resultado da rede com menor MAPE no sistema 2.3

4.3.2.4 Quarto sistema predictor (2.4)

No quarto sistema predictor as simulações foram realizadas com as mesmas variáveis do sistema 2, no entanto o treinamento foi realizado com as últimas 14 semanas com a variação do alvo em 4 semanas. Os melhores resultados do sistema 2.4 estão apresentados na Tabela 4.20.

Tabela 4.20 - Melhores resultados do sistema 2.4

N° Casos	Estrutura Neural	Teste MAPE %			Teste MAPE 2 %		
		Média	Mínimo	Máximo	Média	Mínimo	Máximo
1	5-3-1	33,73	12,26	65,13	34,10	13,89	58,18
3	12-13-1	44,20	12,36	125,25	39,00	12,51	92,76
5	13-27-1	50,42	11,05	156,02	43,47	12,43	125,20

O primeiro caso obteve a melhor média do MAPE (33,73 %) e entre todos os casos, sendo que neste caso houve a utilização das variáveis da CCEE e de 4 variáveis da ONS, com uma estrutura neural de 13 neurônios na camada de entrada e 27 neurônios na camada oculta com 1 na de saída. A média dos MAPE médios foi de 57,09%.

A evolução dos resultados da média, mínimo e máximo do MAPE e MAPE 2, podem ser analisados na Figura 4.43 (a) e (b).




Figura 4.43 - Evolução dos resultados do MAPE e MAPE 2 do sistema 2.4

A combinação das variáveis do primeiro caso tem se mostrado mais eficiente, apresentando os melhores resultados em todos os sistemas previsores realizados no segundo cenário. Uma tendência que vêm se mantendo nos sistemas previsores (2.1, 2.2 e 2.3) é a estabilidade dos valores médios e mínimos com os valores máximos realizando grandes oscilações.

Os resultados da rede com menor MAPE e MAPE 2 do sistema predictor 2.4 pode ser analisado através dos gráficos apresentados nas Figuras 4.44 (a) e (b).

A rede teve mais dificuldades em prever a tendência do preço da quarta à sétima semana, gerando uma maior variação do erro nesses pontos. Com o preço variando R\$25,00 o erro máximo aproximou-se de R\$10,00.




Figura 4.44 - Resultado da rede com menor MAPE no sistema 2.4

4.3.3 Terceiro Cenário

O terceiro cenário utilizou uma amostra de dados do período de 07/2001 à 02/2008 com grande oscilação do preço da energia no mercado brasileiro. De forma análoga aos cenários 1 e 2, foram realizados 4 sistemas previsores treinados conforme as combinações das variáveis apresentadas na Tabela 4.12. Da amostra de dados foram selecionadas as últimas 7 semanas para teste e as outras para o treinamento da rede.

4.3.3.1 Primeiro sistema predictor (3.1)

O primeiro sistema predictor foi treinado com toda a amostra de treinamento e a variação do alvo em uma semana. A Tabela 4.21 apresenta os três melhores resultados do sistema predictor 3.1, sendo o sétimo caso o melhor modelo com os menores valores.

Tabela 4.21 - Melhores resultados do sistema 3.1

N° Casos	Estrutura Neural	Teste MAPE %			Teste MAPE 2 %		
		Média	Mínimo	Máximo	Média	Mínimo	Máximo
7	15-8-1	30,77	13,89	45,83	29,75	16,31	44,11
9	18-19-1	31,80	14,75	50,76	24,39	13,69	36,34
8	16-33-1	35,02	18,85	63,70	27,36	15,95	53,75

O menor MAPE (13,89 %) foi resultado de uma rede neural com 15 neurônios na camada de entrada, 8 na camada oculta e 1 na camada de saída. A média do MAPE médio para o sistema 3.1 foi 39,33 %.

A evolução dos resultados MAPE e MAPE 2 do sistema 3.1 podem ser analisados nas Figuras 4.45 (a) e (b).




Figura 4.45 - Evolução dos resultados do MAPE e MAPE 2 do sistema 3.1

Nesse cenário de grandes oscilações a utilização de todas as variáveis apresentou melhores resultados nos MAPE e MAPE 2. Os resultados do caso 9, por exemplo, foram menores que os resultados do segundo caso que utilizou somente os dados da CCEE e da ONS.

Através da Figura 4.46 (a), pode se observar a projeção dos resultados da rede com menor MAPE e MAPE 2 para o sistema 3.1.

Mesmo com uma alta variação do preço da energia no período testado, a rede conseguiu acompanhar as tendências do preço, exceto na primeira semana, como pode ser observado na Figura 4.46 (b), sendo que a variação do erro foi muito alta, com o valor próximo de R\$250,00. Já nas duas últimas semanas a variação foi menor que R\$5,00.




Figura 4.46 - Resultado da rede com menor MAPE no sistema 3.1

4.3.3.2 Segundo sistema previsor (3.2)

Para o segundo sistema previsor, somente as últimas 14 semanas da amostra de treinamento foram utilizadas e a variação do alvo se manteve em uma semana.

A Tabela 4.22 apresenta os três melhores resultados das simulações realizadas no sistema 3.2, no qual o segundo caso apresenta-se como o melhor sistema para o modelo, apresentando a menor média e mínimo para o MAPE e MAPE 2. A média dos MAPE médios para o sistema 3.2 foi 100,11 %.

Tabela 4.22 - Melhores resultados do sistema 3.2

N° Casos	Estrutura Neural	Teste MAPE %			Teste MAPE 2 %		
		Média	Mínimo	Máximo	Média	Mínimo	Máximo
2	10-6-1	61,62	20,59	116,68	47,25	19,97	86,64
1	5-11-1	61,77	24,36	103,61	52,95	23,62	94,89
3	12-13-1	92,27	26,35	192,61	70,40	20,58	152,31

As simulações do sistema 3.2 podem ser observadas através das Figuras 4.47 (a) e (b), que apresentam graficamente a evolução dos resultados.




Figura 4.47 - Evolução dos resultados do MAPE e MAPE 2 do sistema 3.2

Os valores mínimos foram mais ou menos estáveis, com um discreto crescimento para o MAPE médio. Seguindo o padrão adotado nas demais simulações, o resultado da rede com menor MAPE e MAPE 2 foram apresentados na Figura 4.48 (a) e (b).

A rede com 10 neurônios na camada de entrada e 6 na oculta conseguiu acompanhar a tendência de alta e baixa do preço, porém não conseguiu estimar com precisão, apresentando da segunda a quinta semana uma variação do erro de aproximadamente R\$100,00.




Figura 4.48 - Resultado da rede com menor MAPE no sistema 3.2

4.3.3.3 Terceiro sistema predictor (3.3)

O terceiro sistema predictor foi treinado com a mesma amostra de dados utilizada no sistema 3.1, entretanto, a variação do tempo passou de uma para 4 semanas. A Tabela 4.23 reuniu os melhores resultados do sistema 3.3, com o melhor resultado ocorrendo no sexto caso, apresentando a menor média para o MAPE e MAPE 2.

Tabela 4.23 - Melhores resultados do sistema 3.3

N° Casos	Estrutura Neural	Teste MAPE %			Teste MAPE 2 %		
		Média	Mínimo	Máximo	Média	Mínimo	Máximo
6	15-8-1	116,94	35,29	268,95	94,70	43,61	190,82
1	5-3-1	149,13	32,78	385,29	131,56	43,65	327,11
7	15-16-1	171,43	78,68	419,52	131,30	69,40	292,95

Os valores do MAPE médio e mínimo se mantiveram mais ou menos estáveis durante o treinamento, conforme observado nas Figuras 4.49 (a) e (b).

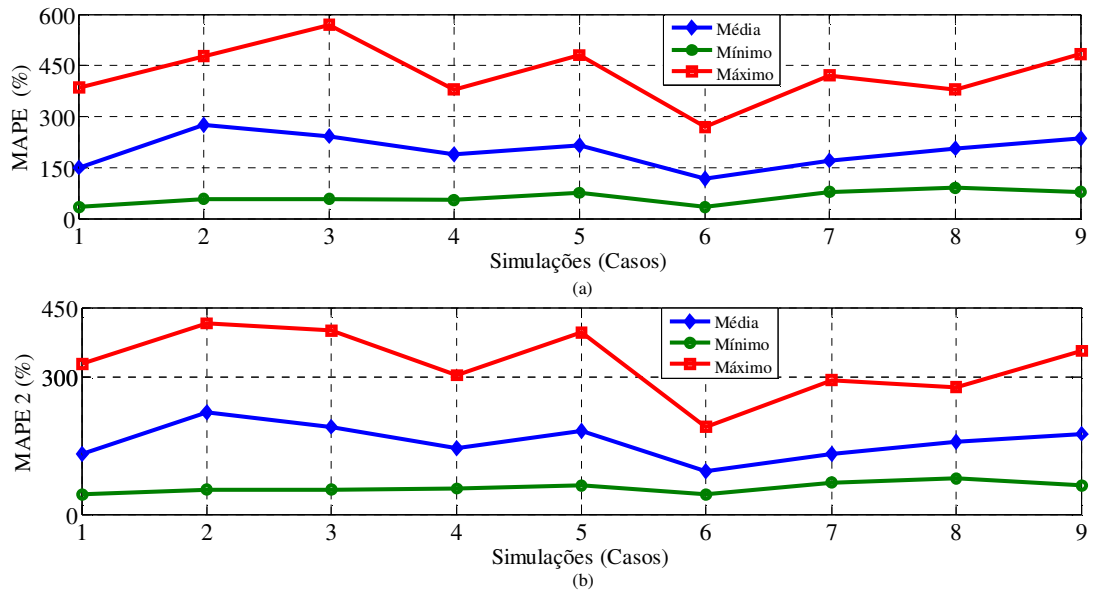


Figura 4.49 - Evolução dos resultados do MAPE e MAPE 2 do sistema 3.3

Observa-se que a variação do tempo de 4 semanas aumentou a média dos resultados em comparação com as médias do sistema 3.1, o sistema apresentou um nível maior de incerteza, decorrente do tempo de deslocamento combinado com a variação do preço. O valor médio do MAPE médio foi 200,34 %.

A projeção do preço estimado com o preço realizado da rede com menor MAPE e MAPE 2 do caso 6 pode ser observado na Figura 4.50 (a) e (b).




Figura 4.50 - Resultado da rede com menor MAPE no sistema 3.3

A rede com uma estrutura neural com 15 neurônios na camada de entrada, 8 na de camada oculta e 1 na camada de saída, apresentou uma grande variação de erro na primeira e última semana, mas entre a terceira e sexta semana a previsão esteve mais próxima do preço realizado.

4.3.3.4 Quarto sistema Previsor (3.4)

O sistema 3.4 utilizou as últimas 14 semanas da amostra de treinamento do sistema anterior (sistema 3.3), mantendo a variação do tempo em 4 semanas.

A Tabela 4.24 apresenta os melhores resultados do sistema, no qual o primeiro caso pode ser definido como melhor sistema para o modelo aplicado, devido aos seus menores resultados. Os casos que apresentaram os melhores resultados são os mesmos casos do sistema 3.3 mudando só a posição do melhor resultado que antes foi o sexto caso e agora foi o primeiro. A combinação das variáveis utilizadas nesses casos se mostram melhores para a variação de 4 semanas e um cenário com alta variação do preço.

Tabela 4.24 - Melhores resultados do sistema 3.4

N° Casos	Estrutura Neural	Teste MAPE %			Teste MAPE 2 %		
		Média	Mínimo	Máximo	Média	Mínimo	Máximo
1	5-6-1	74,21	26,10	139,81	72,64	18,90	122,05
6	15-31-1	104,09	27,45	177,22	87,93	35,83	144,39
7	15-16-1	100,08	27,36	175,90	83,18	32,87	143,74

Semelhante ao sistema 3.3, o aumento da quantidade de variáveis no treinamento promoveu uma piora nos resultados, exceto para os casos 6 e 7, como pode ser observados nas Figuras 4.51 (a) e (b).

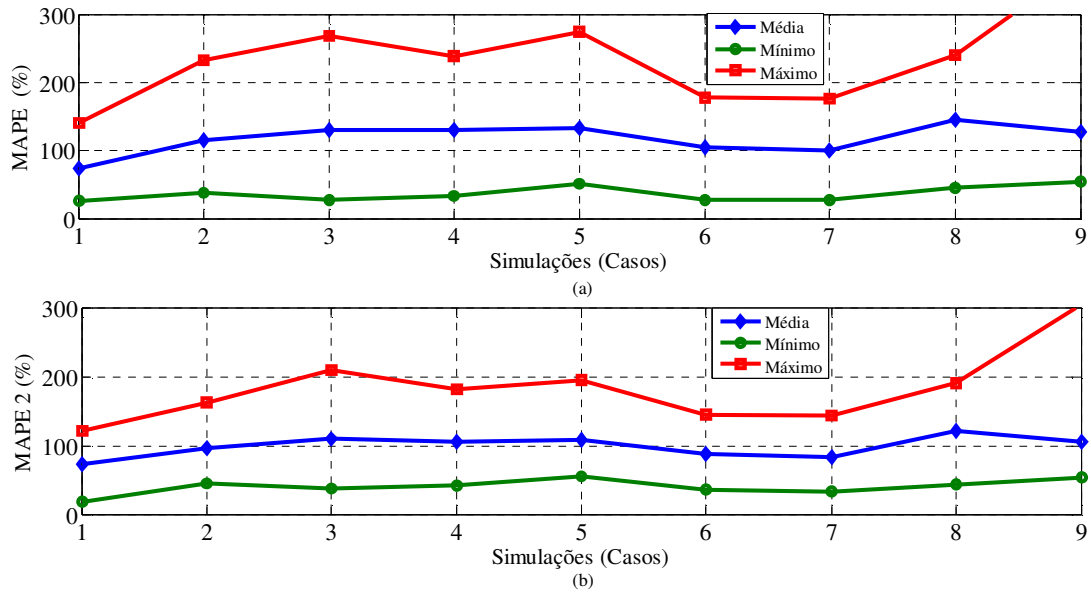


Figura 4.51 - Evolução dos resultados do MAPE e MAPE 2 do sistema 3.4

Através da Figura 4.52 (a), pode se observar a rede que proporcionou o melhor resultado no primeiro caso, sendo esta formada por 5 neurônios na camada de entrada, 6 na camada oculta e 1 na de saída. A rede neural apresentou a maior variação do erro nas semanas 4, 5 e 7, sendo que nesta última a variação foi maior que R\$100,00, como pode ser observado na Figura 4.52 (b).




Figura 4.52 - Resultado da rede com menor MAPE no sistema 3.4

5 CONSIDERAÇÕES FINAIS

A previsão do preço de energia elétrica é fundamental para os participantes do mercado de energia, especialmente no mercado SPOT, como forma de se tornarem mais competitivos. Para isso a técnica de previsão com a utilização de redes neurais vem se mostrando bastante promissora, sendo realizados vários estudos para melhorar a sua aplicação.

A utilização de redes neurais é baseada no treinamento de dados históricos, ligados direta ou indiretamente a formação do preço. Tem como vantagens a grande habilidade de aprendizagem, identificando características marcantes da série temporal, apresentando grande capacidade de generalização. O backpropagation foi o algoritmo de escolha por ser amplamente difundido na utilização para a previsão de cargas de energia e preço, além de ser referencia em termos de precisão e muito utilizado para solução de problemas reais.

A análise dos resultados foi realizada através de gráficos e curvas, bem como a utilização do Erro Percentual Médio Absoluto (MAPE) com a comparação de valores reais do preço e os valores estimados através da rede neural.

A rede neural foi validada com a reprodução de um estudo de caso já publicado [9] referente ao mercado da Califórnia (01/01/1999 à 31/12/1999), sendo realizadas seis previsões diferentes sendo cinco com variações de tempo (hora, dia, semana, mês e ano) e uma sem variação.

Em relação ao Mercado da Califórnia obtiveram-se as seguintes conclusões:

5.1 Número de vetores de treinamento:

- A previsão sem variação de tempo (previsão do presente) apresentou os melhores resultados, sendo o MAPE 2 próximo de 0. As médias dos MAPE 2 foram de 0,009 %, 0,002 % e 0,023 % para a média, mínimo e máximo respectivamente, mostrando portanto a eficiência do algoritmo.
- Das previsões com variação de tempo, os melhores resultados foram os simulados para uma hora a frente, tendo o melhor MAPE 2 médio em 7,44%. O modelo consegue acompanhar a tendência do preço, apresentando a menor variação entre o

preço realizado e o preço estimado (+/- U\$ 5,00) com a variação de uma hora, o que é esperado pois a energia não sofre uma variação muito grande neste intervalo de tempo, fato mais sujeito a ocorrer nas demais variações de tempo. Entretanto, mesmo para as demais variações (dia, semana, mês e ano) o modelo ainda apresenta uma capacidade de prever a tendência, entretanto, apresenta uma maior variação do erro.

- É interessante frisar que os melhores resultados de treinamento neste mercado, foram os obtidos com 3 a 5 vetores de treinamento (1 vetor de treinamento corresponde a 1 semana). Essa afirmação só não é verdadeira para a variação de um ano, na qual apenas com 1 vetor apresentou o melhor resultado, podendo ser resultado da sazonalidade.

5.2 Amostras de dados para treinamento:

- Dentre os modelos treinados com as três diferentes amostras de dados (toda amostra de dados, amostra com pequena oscilação e amostra com a maior oscilação de preço), o que apresentou melhor resultado foi o que utilizou para treinamento a última semana de toda amostra de dados, com variação de tempo em uma hora a frente (menor MAPE 2 médio = 9,50 %), o que pode estar relacionado ao mesmo padrão de comportamento entre o preço utilizado para treinamento e teste, já que trata-se da menor variação de tempo (1 hora). No entanto, o treinamento com a última semana com alvo em uma semana a frente também apresentou bons resultados, com MAPE médio próximo da variação de 1 hora (10,99%) possivelmente ligada aos mesmos fatores.
- Para a previsão de período com grande oscilação do preço a utilização de toda amostra de treinamento, se mostrou mais eficiente, tanto para variação de uma hora como para a variação de uma semana.

Após a validação da rede, aplicou-se o algoritmo na realidade do Mercado Brasileiro, com dados do submercado sudeste e centro oeste. Foram selecionadas 3 cenários: 1º cenário (toda amostra de dados), 2º cenário (período sem grande oscilação de preço), e 3º cenário (período com grandes oscilações). Estes cenários foram treinados com diferentes parâmetros de configuração (tamanho da amostra de treinamento e variação do tempo) e

dados de treinamento. Os dados utilizados para treinamento foram formados através de variáveis extraídas dos sistemas da CCEE (1), da ONS (9), do IBGE (6) e a EIA (2), referentes ao período de 01/07/2001 à 06/04/2012. Para o treinamento da rede foram realizados 9 combinações (9 casos) com as 18 variáveis. Em relação ao Mercado Brasileiro obtiveram-se as seguintes conclusões:

- No 1º Cenário o melhor resultado foi encontrado no primeiro sistema predictor com a utilização de toda amostra para treinamento (menor MAPE médio = 25,57%) com variação de uma semana e a utilização de 5 variáveis (1º caso) como dados de entrada, sendo eles o PLD, Energia armazenada, ENA, CE e CD. Tais variáveis apresentaram, portanto, mais eficientes para a formação do preço. De modo diverso, a utilização das 18 variáveis (caso 8) piorou o desempenho, aumentando o MAPE médio que chegou a 85,28%. A utilização de 14 semanas da amostra para treinamento mostrou-se menos eficiente apresentando um MAPE médio de 97,61%. Com a variação de 4 semanas a frente o melhor resultado foi no sistema predictor 1.3, apresentando um MAPE médio de 29,97% no primeiro caso, sendo treinado com toda a amostra de treinamento. As combinações de variáveis que apresentaram as melhores combinações foram no caso 1, 4 e 7. Os sistemas predictores 1.1 e 1.3 aplicados a primeira amostra de dados se mostraram capazes de acompanhar as tendências do preço, porém apresentando variações de erro em algumas horas.
- No 2º Cenário (dados sem grandes variações), os resultados foram dentro do esperado. Em todos os sistemas predictores deste cenário (2.1, 2.2, 2.3 e 2.4) os menores MAPE médios foram sempre encontrados no 1º caso (5,79%, 9,24%, 32,39% e 33,73% respectivamente) que representam a combinação das variáveis PLD, Energia armazenada, ENA, CE e CD, as quais independentes do alvo apresentaram maior eficiência na estimação do preço. Entretanto, os melhores resultados (menores MAPE) foram com variação do alvo em uma semana, sendo que a dilatação do alvo teve impacto bastante negativo no resultado. Ressalta-se ainda que as variáveis da CCEE, ONS, Consumo de Energia e Atividade Industrial, também parecem estar ligadas a melhoria dos sistemas predictores (expresso pelos bons resultados no caso 8 em ambos os sistemas 2.1 e 2.2). Assim, num cenário de maior estabilidade, a rede conseguiu estimar com mais precisão o preço exceto com

a variação do tempo em 4 semanas, quando o preço do alvo já não apresentava a mesma estabilidade do preço utilizado no treinamento.

- No 3º Cenário, a estimação do preço da energia usando redes neurais para o período de grande oscilação do mercado brasileiro, mostrou menor eficiência, apresentando um maior distanciamento entre o preço previsto e o realizado. Isso foi especialmente demonstrado na dificuldade da rede em estimar preços que não foram previamente conhecidos durante o treinamento (grandes oscilações). O sistema predictor com melhor resultado foi o 3.1 (toda amostra com variação de 1 semana), com o sétimo caso apresentando o menor MAPE médio (30.77 %), mínimo (13,89 %) e máximo (45,83). De uma forma geral, o maior número de variáveis apresentaram os melhores resultados - casos 7 (CCEE, ONS, Petróleo), 8 (CCEE, ONS, Consumo de Energia e Atividade Industrial) e 9 (todas as variáveis). Nesse cenário, para variação em uma semana, a diminuição da amostra de treinamento trouxe efeitos negativos para a previsão. Assim, o sistema 3.2 (14 semanas de treinamento com variação de 1 semana no alvo) apresentou os MAPE médios com valores bem mais altos do que os apresentados pelo sistema 3.1, tendo, portanto, menor precisão na estimação do preço. Deste modo, mesmo acompanhando a tendência do preço, o sistema apresentou uma variação de erro muito elevada. Ao contrário, quando a variação do alvo passou para 4 semanas, a diminuição da amostra trouxe efeitos positivos para os sistema previsores, diminuindo os MAPE médios melhorando a previsão. Observa-se que as redes para esse cenário de grande oscilação, conseguem prever a tendência do preço, mas não conseguem uma precisão do preço estimando nas altas variações.

A utilização das redes neurais com os diferentes parâmetros de treinamento e com as diferentes combinações das variáveis se mostrou de um modo geral eficiente, tendo em vista que as redes convergiram para a previsão das tendências do preço da energia ao longo do período. Para cenários com maior estabilidade, as redes neurais apresentaram melhores resultados.

Um fator que se acredita impactar negativamente na qualidade do resultado das redes neurais para o mercado brasileiro é a metodologia utilizada pelas controladoras do mercado para formação do preço. Este é fornecido mensalmente para cada semana do mês subsequente, diferente do que ocorre nos mercado da Califórnia, da Espanha e Portugal,

cujos valores são fornecidos por hora para cada dia do ano [71]. Com um maior número de amostras (Mercado da Califórnia) as a redes neurais conseguiram melhores resultados se comparados com os resultados do mercado brasileiro, além do que as variáveis sendo apresentadas por hora representam melhor a variação do preço no instante seguinte.

Mesmo este trabalho não tendo o intuito de substituir as técnicas e métodos usados pela CCEE e ONS para a formação do preço no mercado spot brasileiro, considera-se que vem a colaborar com a estimação do preço no mercado Spot, como forma de dar subsídio aos participantes do mercado em suas tomadas de decisão.

Por fim é válido ressaltar que a utilização das redes neurais para a previsão do preço da energia no mercado spot não funciona como uma “receita de bolo”, já que para a aplicação prática um dos fatores que determinantes na qualidade dos resultados é a experiência acumulada no cenário aplicado. Como foi observado para cada cenário, diferentes variações (tempo de treinamento, alvo, combinações das variáveis) podem ser empregados com maior ou menor eficácia.

Portanto, recomenda-se a realização de novos estudos que busquem selecionar outras combinações de variáveis que possam apresentar uma melhor correlação com a formação do preço do mercado spot. Além disso, outros tipos de redes neurais devem ser testadas para verificar sua aplicabilidade ao Mercado Brasileiro, bem como medindo sua eficiência interna (resultados estimados x realizados) e externa (comparação com outras redes, a exemplo da backpropagation).

Um maior número de estudos com o uso das redes neurais aplicada ao nosso mercado deve evoluir para o desenvolvimento de ferramentas para aplicação destas redes, de modo que, por exemplo, possam ser selecionados os dados de entrada e realizadas as previsões para a estimação.

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] F. T. MASUKAWA, “Avaliação de Critérios de Risco na Negociação de Contratos Bilaterais de Energia em Centrais Hidrelétricas de Pequeno Porte – PCH.,” *Dissertação de Mestrado em Engenharia Elétrica, Publicação PPGENE.DM – 448/11, Departamento de Engenharia Elétrica, UNB*, p. 52, 2011.
- [2] S. Pineda e A. J. Conejo, “Scenario reduction for risk-averse electricity trading,” *IET Gener. Transm. Distrib.*, vol. 4, p. 694–705, 2010.
- [3] N. M. Pindoriya, S. N. Singh e S. K. Singh, “An Adaptive Wavelet Neural Network-Based Energy Price Forecasting in Electricity Markets,” *IEEE Transactions On Power Systems*, vol. 23, 2008.
- [4] M. Z. Z. Y. Y. N. NI, G. Li e Y. Nie, “Electricity price forecasting with confidence-interval estimation through an extended ARIMA approach,” *Generation, Transmission and Distribution, IEE Proceedings-*, vol. 153, pp. 187 - 195, 2006.
- [5] A. R. Queiroz, F. A. Oliveira, P. P. Balestrassi e J. W. M. Lima, “Simulating Electricity Spot Prices in Brazil Using Neural Network and Design of Experiments,” *Power Tech, 2007 IEEE Lausanne*, pp. 2029 - 2034 , 2007.
- [6] C. Y. Tee, J. B. Cardell e G. W. Ellis, “Short-Term Load Forecasting Using Artificial,” *North American Power Symposium (NAPS)*, pp. 1 - 6, 2009.
- [7] J. R. C. Pires, “Modelagem da Formação do Preço de Energia Elétrica no Mercado de Curto Prazo.,” *Tese Apresentada à Divisão de Pós-Graduação da Instituto Tecnológico de Aeronáutica como Parte dos Requisitos para Obtenção do Título de Mestre em Ciência no Curso de Engenharia Aeronáutica e Mecânica, na Área de Produção.*, 2003.
- [8] A. L. Rodrigues, “Redes Neurais Artificiais Aplicadas na Previsão de Preços Do Mercado Spot de Energia Elétrica.,” *Dissertação apresentada ao Programa de Pós graduação em Energia da Universidade de São Paulo (Escola Politécnica/Faculdade de Economia e Administração / Instituto de Eletr. e Energia/ Instituto de Física) para a obtenção do título de Mestre em Energia*, 2009.
- [9] M. SHAHIDEHPOUR, H. YAMIN e Z. LI, *Market Operatioms In Electric Power Systems Forecasting, Scheduling, and Risk Management*, Canada : IEEE PRESS, 2002.
- [10] U. O. C. E. Institute, “Unconstrained Market Clearing Prices and Quantities in PX Day-Ahead Market,” *University of California Energy Institute*, 20 03 2001. [Online].

- Available: http://www.ucei.berkeley.edu/datamine/px_umcp.html. [Acesso em 20 08 2011].
- [11] ONS, “Operador Nacional do Sistema Elétrico,” [Online]. Available: www.ons.org.br. [Acesso em 01 03 2011].
- [12] IBGE, “Séries Estatísticas e Séries Históricas,” [Online]. Available: <http://serieestatisticas.ibge.gov.br>. [Acesso em 01 04 2011].
- [13] EIA, “PETROLEUM & OTHER LIQUIDS,” [Online]. Available: http://www.eia.gov/dnav/pet/pet_pri_spt_s1_d.htm. [Acesso em 09 04 2011].
- [14] CCEE, “Câmara de Comercialização de Energia Elétrica,” [Online]. Available: <http://www.ccee.org.br>.
- [15] ANEEL, “Atlas de Energia Elétrica do Brasil 3ª Edição,” *Atlas de Energia Elétrica do Brasil*, n. 3ª Edição, 2008.
- [16] ANEEL, “Notícias,” 2011a. [Online]. Available: http://www.aneel.gov.br/aplicacoes/noticias/Output_Noticias.cfm?Identidade=3751&id_area=90. [Acesso em 21 03 2011].
- [17] J. GOLDEMBERG e O. LUCON, “Energia e meio ambiente no Brasil,” *SciELO Estudos Avançados*, vol. 21, 2007.
- [18] ONS, “O que é o SIN - Sistema Interligado Nacional,” 2011. [Online]. Available: http://www.ons.org.br/conheca_sistema/o_que_e_sin.aspx. [Acesso em 13 03 2011].
- [19] R. C. d. Costa e C. P. T. Prates, “O Papel das Fontes Renováveis de Energia no Desenvolvimento do Setor Energético e Barreiras à sua Penetração no Mercado,” *BNDES Setorial*, vol. 21, p. 5.30, 2005.
- [20] EIA, “Outlook 2011 Annual Energy,” *EIA*, 2011.
- [21] MDIC, “Ministério do Desenvolvimento, Indústria e Comércio Exterior,” 2011. [Online]. Available: <http://www.mdic.gov.br/sitio/interna/interna.php?area=2&menu=999>. [Acesso em 21 03 2011].
- [22] E. d. E. EPE, “Balanço Energético Nacional 2011: Ano base 2010,” Rio de Janeiro, 2011.
- [23] EIA, “Key World Energy STATISTICS,” *IEA statistics*, 2011.
- [24] T. M. GONÇALVES e F. D. A. MENDONÇA, “Impactos, Riscos e Vulnerabilidade Socioambientais da Produção do Carvão em Criciúma/Sc (Brasil),” *R. RA E GA - O*

Espaço Geográfico em Análise, n. 14, pp. 55-65, 2007.

- [25] ANNEL, “BIG - Banco de Informações Gerências - Capacidade de Geração do Brasil,” ANNEL - Agência Nacional de Energia Elétrica, 2011. [Online]. Available: <http://www.aneel.gov.br/aplicacoes/capacidadebrasil/capacidadebrasil.asp>. [Acesso em 07 20 2011].
- [26] S. A. Energia, “Energia,” 2011. [Online]. Available: http://www.santoantonioenergia.com.br/site/portal_mesa/pt/energia/transmissao/transmissao.aspx. [Acesso em 03 04 2011].
- [27] ANEEL, “Últimas Notícias,” 2011b. [Online]. Available: http://www.aneel.gov.br/aplicacoes/noticias/Output_Noticias.cfm?Identidade=4992&id_area=90. [Acesso em 20 12 2011].
- [28] T. A. VERBOSKI, “Proposta e Simulação de Um Algoritmo de Designação Otimizado para Despacho de Equipes de Atendimento de Uma Empresa de Energia Elétrica,” *Dissertação apresentada ao Curso de Pós-Graduação em Métodos Numéricos em Engenharia, Departamento de Matemática, Setores de Tecnologia e Ciências Exatas, UFPA, como parte das exigências para obtenção do título de Mestre em Ciências.*, 2010.
- [29] F. A. M. d. FARIA, “Metodologia de Prospecção de Pequenas Centrais Hidrelétricas,” *Dissertação apresentada à Escola Politécnica da Universidade de São Paulo para obtenção do título de mestre em Engenharia.*, 2011.
- [30] J. M. VIEIRA, E. SODRÉ, N. LEAL, D. F. GUEDES, F. ALVES e G. H. S. MELO, “Uma Análise de Competitividade para Geração de Energia Elétrica,” *XIII Eriac Décimo Terceiro Encontro Regional Iberoamericano de Cigré*, maio 2009.
- [31] ANEEL, “DECRETO Nº 2.003, DE 10 DE SETEMBRO DE 1996,” 1996. [Online]. Available: <http://www.aneel.gov.br/cedoc/dec19962003.pdf>. [Acesso em 10 04 2011].
- [32] ANEEL, “LEI Nº 10.438, DE 26 DE ABRIL DE 2002,” 2002. [Online]. Available: <http://www.aneel.gov.br/cedoc/lei200210438.pdf>. [Acesso em 2 03 2011].
- [33] M. d. M. e. E. MME, “Proinfa - Programa de Incentivo às Fontes Alternativas de Energia Elétrica,” 2011. [Online]. Available: <http://www.mme.gov.br/programas/proinfa/>. [Acesso em 12 05 2011].
- [34] MME, “Proinfa - Programa de Incentivos as Fontes Alternativas de Energia Elétrica,” 2011. [Online]. Available: http://www.mme.gov.br/programas/proinfa/menu/programa/mapa_fontes_por_estado.html. [Acesso em 12 08 2011].

- [35] M. d. M. e. E. MME, “Mapa de Fontes por Estado,” 2011b. [Online]. Available: http://www.mme.gov.br/programas/proinfra/menu/programa/mapa_fontes_por_estado.html. [Acesso em 12 05 2011].
- [36] D. Capetta, “Sistema de Medição Para Faturamento e o Mercado de Energia Elétrica: Uma Visão Crítica do Referencial Regulatório,” *Dissertação apresentada à Escola Politécnica da Universidade de São Paulo para obtenção do título de Mestre em Engenharia Elétrica.*, p. 167, 2009.
- [37] G. D. S. C. MAGALHÃES, “Comercialização de Energia Elétrica no Ambiente de Contratação Livre: Uma Análise Regulatório-Institucional a Partir dos Contratos de Compra e Venda de Energia Elétrica,” *Dissertação apresentada ao Programa de Pós-Graduação em Energia da Universidade de São Paulo para obtenção do título de Mestre em Energia.*, 2009.
- [38] A. C. F. Machado, “Estratégias de Comercialização para Integração de Mercados,” *Workshop – Integração de Mercados de Energia Elétrica e Formação de Preços*, p. 62, 04 03 2011.
- [39] CCEE, “Visão Geral das Operações na CCEE Versão 2011,” Brasília, 2011.
- [40] F. G. CLÍMACO, “Gestão de Consumidores Livres de Energia Elétrica,” *Dissertação apresentada ao Programa de Pós Graduação em Energia da Universidade de São Paulo (Escola Politécnica / Faculdade de Economia e Administração / Instituto de Eletrotécnica e Energia / Instituto de Física) para obtenção do título de Mestre em Ene*, p. 113, 2010.
- [41] F. G. CLÍMACO, “Gestão de Consumidores Livres de Energia Elétrica,” *Dissertação apresentada ao Programa de Pós-Graduação em Energia da Universidade de São Paulo para obtenção do título de Mestre em Energia.*, 2010.
- [42] A. V. P. TONELLI, “Modelo Computacional para Gestão de Riscos na Comercialização de Energia Elétrica,” *Universidade Federal de Itajubá. Dissertação de Mestrado Integrante do Programa de Pós-Graduação Strictu-Sensu em Engenharia da Energia*, p. 149, 2006.
- [43] F. A. D. OLIVEIRA, “Estratégia de Comercialização de Energia Elétrica Através da Otimização de Portfólios de Contratos Utilizando Projetos de Experimentos de Mistura,” *Tese apresentada ao programa de pós-graduação da Universidade Federal de Itajubá como parte dos requisitos para a obtenção do título de Doutor em Ciências em Engenharia Elétrica.*, 2009.
- [44] J. C. M. SÁNCHEZ, “Estudo da Negociação de Contratos Bilaterais de Energia em Sistemas Predominantemente Hidráulicos,” 2008.

- [45] R. D. B. RODRIGUES, “Gerenciamento de Risco no Setor Elétrico Brasileiro Através do Uso De Derivativos,” *Tese apresentada ao Corpo Docente do Instituto de Economia da Universidade Federal do Rio de Janeiro como parte dos requisitos necessários à obtenção do título de MESTRE em Ciências Econômicas.*, 2007.
- [46] A. R. d. Queiroz, “Simulação de Custos Marginais em Mercado de Energia Elétrica Utilizando Redes Neurais,” *Dissertação apresentada à Universidade Federal de Itajubá como parte dos requisitos para a obtenção do grau de Mestre em Ciências em Engenharia Elétrica*, 2007.
- [47] C. M. d. S. Júnior, “Metodologia Para Representação Detalhada dos Custos de Aquisição de Energia e Repasses Tarifários no Fluxo de Caixa das Empresas Distribuidoras: Um Enfoque Probabilístico,” *Disertação apresentada à Escola Politécnica da Universidade de São Paulo para a obtenção do título de Mestre em Engenharia.*, 2008.
- [48] D. C. d. P. Silva, L. C. Theodoro e R. G. Ferreira, “O Mercado de Energia Com Ênfase nas Fontes de Energia Alternativa,” *Anais dos Trabalhos de Diploma Universidade Federal de Itajubá Engenharia Elétrica*, 2007.
- [49] ANNEL, “ANNEL,” 2011d. [Online]. Available: http://www.aneel.gov.br/aplicacoes/noticias/Output_Noticias.cfm?Identidade=5017&id_area=90. [Acesso em 30 03 2012].
- [50] J. E. G. Lopes, “Modelo de Planejamento da Operação de Sistemas Hidrotérmicos de Produção de Energia Elétrica,” *Tese apresentada à Escola Politécnica da Universidade de São Paulo para obtenção do título de Doutor em Engenharia*, 2007.
- [51] F. L. D. d. Deus, “Geração de Cenários de Energia Natural Afluyente Através da Adoção da Metodologia do Hipercubo Latino,” *Dissertação de Mestrado apresentada ao Programa de Pós-graduação em Planejamento Energético, COPPE, da Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários à obtenção do título de Mestre em Planejamento Energético.*, 2010.
- [52] I. N. d. Silva, D. H. Spatti e R. A. Flauzino, *Rede Neurais Artificiais para engenharia e ciências aplicadas.*, São Paulo: Artliber, 2010.
- [53] S. Haykin, *Redes Neurais Princípios e Prática*, 2º EDIÇÃO ed., Porto Alegre: BOOKMAN, 2001.
- [54] H. A. KIRSTEN, “Comparação Entre os Modelos Holt-Winters e Redes Neurais para Previsão de Séries Temporais Financeiras,” *Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Produção e Sistemas da Pontifícia Universidade Católica do Paraná como requisito parcial para obtenção do título de*

Mestre em Engenharia de Produção e Sistemas., 2009.

- [55] M. A. A. Hasin, S. Ghosh e M. A. Shareef, “An ANN Approach to Demand Forecasting in Retail Trade in Bangladesh,” *International Journal of Trade, Economics and Finance*, vol. 2, 2011.
- [56] A. SKABAR e I. CLOETE, “Investigation Of The Effect Of Training And Prediction Window Sizes On Neural Financial Prediction Models,” *Proceedings of the Second International Conference on Machine Learning and Cybernetics*, 2003.
- [57] H. Shayeghi, H. A. Shayanfar e G. Azimi, “STLF Based on Optimized Neural Network Using PSO,” *World Academy of Science, Engineering and Technology*, 2009.
- [58] T. Parisini e R. Zoppoli, “Neural Networks for Feedback Feedforward Nonlinear Control Systems,” *IEEE TRANSACTIONS ON NEURAL NETWORKS*, vol. 5, 1994.
- [59] K. Liano, “Robust Error Measure for Supervised Neural Network Learning With Outliers,” *IEEE TRANSACTIONS ON NEURAL NETWORKS*, vol. 7, 1996.
- [60] T.-C. Lu, J.-C. Juang e G.-R. Yu, “On-line Outliers Detection by Neural Network with Quantum Evolutionary Algorithm,” *IEEE*, 2007.
- [61] J. Sola e J. Sevilla, “Importance of Input Data Normalization for the Application of Neural Networks to Complex Industrial Problems,” *IEEE TRANSACTIONS ON NUCLEAR SCIENCE*, vol. 44 , 1997.
- [62] P. Qingle, “Sample Normalization Algorithm of Neural Network Based on Fuzzy Rough Set Theory,” *International Congress Image and Signal Processing - CISP*, n. 2, 2009.
- [63] I. CHISSOLUCOMBE, “Uso de Técnicas de Inteligência Artificial na Estimativa de Deslocamentos e Danos Induzidos por Escavações Subterrâneas,” *Tese de Doutorado Submetida ao Departamento de Engenharia Civil e Ambiental da Universidade de Brasília Como Parte dos Requisitos Necessários Para a Obtenção do Grau de Doutor.*, 2009.
- [64] S. G. MAKRIDAKIS, S. C. WHEELWRIGHT e R. J. HYNDMAN, “Forecasting: methods and applications,” *Hardcover*, n. 3, 1998.
- [65] P. J. Werbos, “Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences,” *PHD-Thesis - Harvard University*, 1974.
- [66] G. CYBENKO, “Approximation by Superpositions of Sigmoidal Function Mathematics of Control, Signals, and Systems, and Systems,” vol. 22, pp. 303-314,

1989.

- [67] A. B. Altran, “Aplicação de Funções de ase Radial em Problemas de Previsão de Cargas Elétricas via Redes Neurais,” *Dissertação submetida ao Programa de Pós-graduação em Engenharia Elétrica da Faculdade de Engenharia de Ilha Solteira - UNESP, para Obtenção do título de Mestre em Engenharia Elétrica.*, p. 112, 2005.
- [68] E. W. T. Ferreira, “Sistema de detecção de intrusão com abordagem baseada em processamento digital de sinais e redes neurais para redes de computadores,” *Tese de Doutorado apresentado ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Uberlândia, como requisito parcial para obtenção do título de Doutor em Ciências.*, 2009.
- [69] V. M. Mendes, H. M. Pousinho e J. P. Catalao, “Neural Networks and Wavelet Transform for Short-Term Electricity Prices Forecasting,” *Intelligent System Applications to Power Systems - IEEE*, n. 15, 2009.
- [70] H. M. I. Pousinho, V. M. F. Mendes e J. P. S. Catalão, “Wavelet-Neuro-Fuzzy Approach for Predicting Short-Term Electricity Prices in a Competitive Market,” *7th Mediterranean Conference and Exhibition on Power Generation, Transmission, Distribution and Energy Conversion*, n. 7, 2010.
- [71] OMEL, Operador del Mercado Ibérico de Energía, [Online]. Available: <http://www.omel.es/inicio>. [Acesso em 14 07 2011].