

**UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”
FACULDADE DE ENGENHARIA
CAMPUS DE ILHA SOLTEIRA**

RENAN FERREIRA FELIX

**PREVISÃO DE PREÇOS DE COMERCIALIZAÇÃO DE ENERGIA ELÉTRICA POR
REDES NEURAS ARTIFICIAIS**

**ILHA SOLTEIRA
2022**



UNIVERSIDADE ESTADUAL PAULISTA
"JÚLIO DE MESQUITA FILHO"
Câmpus de Ilha Solteira

RENAN FERREIRA FELIX

**PREVISÃO DE PREÇOS DE COMERCIALIZAÇÃO DE ENERGIA ELÉTRICA POR
REDES NEURAIS ARTIFICIAIS**

Trabalho de Graduação apresentado à Faculdade de Engenharia de Ilha Solteira-UNESP, como requisito parcial à obtenção do título de Bacharel em Engenharia Elétrica.

Orientadora: Anna Diva Plasencia Lotufo

FICHA CATALOGRÁFICA

Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

F316p Felix, Renan Ferreira.
Previsão de preços de comercialização de energia elétrica por redes neurais artificiais / Renan Ferreira Felix. -- Ilha Solteira: [s.n.], 2022
76 f. : il.

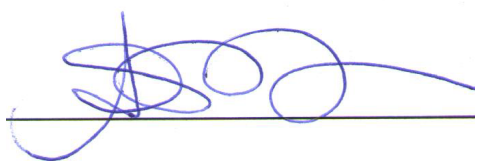
Trabalho de conclusão de curso (Graduação em Engenharia Elétrica) -
Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira, 2022

Orientador: Anna Diva Plasencia Lotufo
Inclui bibliografia

1. Redes neurais artificiais. 2. Previsão de preços de energia elétrica. 3.
Mercado de energia elétrica no Brasil.

ATA DE DEFESA DE TRABALHO DE GRADUAÇÃO

Aos vinte e quatro dias do mês de janeiro do ano de dois mil e vinte e dois, o discente **Renan Ferreira Felix**, matriculado sob o nº 181051281, tendo como banca examinadora a sua orientadora, a Profª. Drª. Anna Diva Plasencia Lotufo, a Doutoranda Danieli Biagi Vilela e o Doutorando Giovanni Panegossi Formaggio, apresentou o Trabalho de Graduação intitulado: "PREVISÃO DE PREÇOS DE COMERCIALIZAÇÃO DE ENERGIA ELÉTRICA POR REDES NEURAIS ARTIFICIAIS" obtendo a nota 9,0 (nove vírgula zero) e conceito APROVADO.



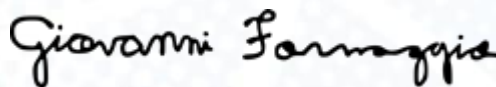
Profª. Drª. Anna Diva Plasencia Lotufo
- orientadora -



Renan Ferreira Felix
- discente -



Doutoranda Danieli Biagi Vilela
- Membro da Banca -



Doutorando Giovanni Panegossi Formaggio
- Membro da Banca -

À memória de meu primo Marcelo Augusto, dedico.

AGRADECIMENTOS

Agradeço primeiramente a Deus por sempre me dar a força necessária para continuar nesta trajetória, mesmo nos momentos mais difíceis.

Agradeço a minha família, em especial a minha mãe Anésia, que sempre compreendeu os meus sonhos, sempre me deu forças, e apoio.

Agradeço à Professora Dra. Anna Diva por me dar a oportunidade de realizar este trabalho, confiar em mim, e sempre me atender com toda a gentileza nos meus momentos de dúvida. Um agradecimento especial ao companheiro Giovanni Formaggio que durante este trabalho me deu um imenso suporte.

Um agradecimento especial a Assistente Social da Unesp de Ilha Solteira Renata Trasse e a Psicóloga Natália Hernandez Carvalho, ambas me deram um apoio muito grande nos meus momentos mais difíceis durante a graduação.

Um agradecimento especial aos donos da Choperia Pimenta, Elson Carneiro e Grasielle Claudino, que mais do que patrões foram como pais para mim, não tenho a menor dúvida que sem eles eu não teria conseguido, serei eternamente grato. Um agradecimento também a toda equipe da Choperia Pimenta, em especial a amiga Kátia Cangussu, que também me acolheu diversas vezes em sua própria casa. Gostaria de agradecer meu primeiro chefe Edney Bonutti, que foi a pessoa que me deu a primeira oportunidade de emprego e também ótimos conselhos sempre.

Um agradecimento aos meus amigos que fizeram da minha trajetória mais leve e divertida. Um agradecimento especial aos amigos da ala 7 do alojamento universitário.

Agradeço a amizade dos companheiros Henrique Cipolli, Gabriel Guirao, Lucas Pelegrino, Leandro Buzo e Silas Marinho. Um agradecimento especial a minha amiga Ana Bruneri, que está do meu lado em todos os momentos de felicidade e também de dificuldades.

Agradeço a FEIS e ao SINTEL, que forneceram a estrutura necessária para que eu pudesse me tornar Engenheiro Eletricista. Um agradecimento especial ao Cursinho Diferencial, um lugar que salvou a minha graduação.

"Respire, acredite e lute"

Kerri Walsh

RESUMO

A energia elétrica é insumo essencial para a economia de qualquer país e para a vida de todos os seus habitantes. A matriz energética brasileira se difere da dos demais países devido a sua característica bastante renovável e variável, por possuir diversas fontes de energia. Na década de 90 ocorreu a separação das atividades de geração, transmissão e distribuição no Brasil, e atualmente a contratação de energia no país está dividida em dois ambientes, o Ambiente de Contratação Livre e o Ambiente de Contratação Regulado. A previsão de preços é uma das tarefas mais importantes para o planejamento e operacionalização dos mercados elétricos no Brasil. O presente trabalho objetiva propor uma abordagem para previsão dos Preços de Liquidação de Diferenças com base na utilização de modelos de redes neurais artificiais. Os dados utilizados para isso, foram os próprios Preços de Liquidação de Diferenças, dias da semana, dias do mês, meses do ano e horário. Todos os dados são disponibilizados em quatro submercados diferentes: Sul, Sudeste, Nordeste e Norte. Neste trabalho utiliza-se os dados do submercado Sudeste de 1 de janeiro de 2020 até 30 de junho de 2021. Para a realização do trabalho utiliza-se a rede neural do tipo Multilayer Perceptron *feedforward*, e dois tipos de treinamento: Levenberg-Marquardt e *Backpropagation* (Gradiente Conjugado Escalonado). Para a avaliação dos resultados obtidos utiliza-se o Mean Absolute Percentage Error (*MAPE*) e ambos os treinamentos são comparados com o objetivo de se propor a técnica mais adequada para a previsão de preços.

Palavras chave: *Backpropagation*. Levenberg-Marquardt. Rede Neural Perceptron Multicamadas. Redes Neurais Artificiais. Preço de Liquidação de Diferenças. Gradiente Conjugado Escalonado.

ABSTRACT

Electric energy is an essential input for the economy of any country and for the life of all its inhabitants. The Brazilian energy matrix differs from that of other countries due to its very renewable and variable characteristics, it has different energy sources. In the 90's, generation, transmission and distribution activities were separated in Brazil, and currently energy contracts in the country are divided into two environments, The Free Contracting Environment and The Regulated Contracting Environment. Price forecasting is one of the most important tasks for planning and operating the electrical markets in Brazil. The present work aims to propose an approach for the Difference Settlement Prices based on the use of Artificial Neural Network models. The data used for this were the Difference Settlement Prices, days of the week, days of the month, months of the year and time. All data is available in four different submarkets: South, Southeast, Northeast and North. In this work, data from the Southeast submarket from January 1, 2020 to June 30, 2021 are used. To carry out the work, the Multilayer Perceptron *feedforward* neural network is used, and two types of training: Levenberg-Marquardt and Backpropagation (Scaled Conjugate Gradient). To evaluate the results obtained, the Mean Absolute Percentage Error (*MAPE*) is used and both trainings are compared with the objective of proposing the most adequate technique for price forecasting.

Keywords: *Backpropagation*. Levenberg-Marquardt. Multilayer Perceptron Neural Network. Artificial Neural Networks. Difference Settlement Price. Scaled Conjugate Gradient.

LISTA DE ILUSTRAÇÕES

Figura 1 - Preço de liquidação de diferenças (Média mensal de janeiro de 2020 até junho de 2021).....	16
Figura 2 - Estrutura do setor elétrico brasileiro.....	25
Figura 3 - Submercados de energia no Brasil.....	28
Figura 4 - Componentes essenciais do neurônio biológico.....	31
Figura 5 - Neurônio artificial de McCulloch e Pitts.....	32
Figura 6 - Modelo de um neurônio artificial com n entradas.....	33
Figura 7 - Função relé.....	34
Figura 8 - Função Lógica <i>threshold</i>	34
Figura 9 - Função sigmóide (1).....	35
Figura 10 - Função sigmóide (2).....	35
Figura 11 - Rede <i>Feedforward</i>	36
Figura 12 - Rede <i>Feedback</i> ou recorrente.....	37
Figura 13 - Arquitetura da RNA Multilayer Perceptron.....	39
Figura 14 - Comportamento dos preços de comercialização de energia elétrica no ano de 2020.....	51
Figura 15 - Comportamento dos preços de comercialização de energia elétrica no ano de 2021.....	52
Figura 16 - Comportamento dos preços de comercialização de energia elétrica em 2020 e 2021.....	52
Figura 17 - Arquitetura da RNA proposta.....	55
Figura 18 - Esquematização da rede utilizada no processo de treinamento.....	58
Figura 19 - Regressão para o treinamento por LM.....	59

Figura 20 - Previsão para o dia 01 de Fevereiro, Segunda - Feira (Previsão mediante algoritmo Levenberg-Marquardt).....	59
Figura 21 - Previsão para o dia 02 de Fevereiro, Terça - Feira (Previsão mediante algoritmo Levenberg-Marquardt).....	60
Figura 22 - Previsão para o dia 03 de Fevereiro, Quarta- Feira (Previsão mediante algoritmo Levenberg-Marquardt).....	60
Figura 23 - Previsão para o dia 04 de Fevereiro, Quinta- Feira (Previsão mediante algoritmo Levenberg-Marquardt).....	61
Figura 24 - Previsão para o dia 05 de Fevereiro, Sexta- Feira (Previsão mediante algoritmo Levenberg-Marquardt).....	61
Figura 25 - Previsão para o dia 06 de Fevereiro, Sábado (Previsão mediante algoritmo Levenberg-Marquardt).....	62
Figura 26 - Previsão para o dia 07 de Fevereiro, Domingo (Previsão mediante algoritmo Levenberg-Marquardt).....	62
Figura 27 - Regressão R treinamento GCE.....	64
Figura 28 - Previsão para o dia 01 de Fevereiro, Segunda - Feira (Previsão mediante algoritmo GCE).....	65
Figura 29 - Previsão para o dia 02 de Fevereiro, Terça - Feira (Previsão mediante algoritmo GCE).....	66
Figura 30 - Previsão para o dia 03 de Fevereiro, Quarta- Feira (Previsão mediante algoritmo GCE).....	66
Figura 31 - Previsão para o dia 04 de Fevereiro, Quinta- Feira (Previsão mediante algoritmo GCE).....	67
Figura 32 - Previsão para o dia 05 de Fevereiro, Sexta - Feira (Previsão mediante algoritmo GCE).....	67
Figura 33 - Previsão para o dia 06 de Fevereiro, Sábado (Previsão mediante algoritmo GCE).....	68

Figura 34 - Previsão para o dia 07 de Fevereiro, Domingo (Previsão mediante algoritmo GCE).....	68
--	----

LISTA DE TABELAS

Tabela 1 - Organização dos dados de entrada da rede.....	54
Tabela 2 - MAPE obtido para treinamento realizado pelo algoritmo LM.....	63
Tabela 3 - MAPE obtido para treinamento realizado pelo algoritmo GCE.....	69
Tabela 4 - Comparação do <i>MAPE</i> médio dos dias para cada algoritmo.....	71

LISTA DE ABREVIATURAS E SIGLAS

ANEEL	Agência Nacional de Energia Elétrica
ARIMA	Auto Regressive Integrated Moving Average
BP	<i>Backpropagation</i>
CCEE	Câmara de Comercialização de Energia Elétrica
CMO	Custo Marginal de Operação
EPE	Empresa de Pesquisa Energética
GCE	Gradiente Conjugado Escalonado
LM	Levenberg-Marquardt
<i>MAPE</i>	Mean Absolute Percentage Error
MLP	Multilayer Perceptron
MME	Ministério de Minas e Energia
ONS	Operador Nacional do Sistema Elétrico
PLD	Preço de Liquidação de Diferenças
RNA	Redes Neurais Artificiais
SARIMA	Seasonal Auto Regressive Integrated Moving Average
SIN	Sistema Interligado Nacional

SUMÁRIO

1 INTRODUÇÃO.....	15
1.1 BREVE REVISÃO BIBLIOGRÁFICA.....	17
1.2 CLASSIFICAÇÃO DA PREVISÃO E FERRAMENTA AVALIADORA DA PREVISÃO.....	19
1.3 OBJETIVOS.....	20
1.4 ORGANIZAÇÃO TEXTUAL.....	21
2 SETOR ELÉTRICO BRASILEIRO.....	23
2.1 CÂMARA DE COMERCIALIZAÇÃO DE ENERGIA ELÉTRICA.....	25
2.2 PREÇO DE LIQUIDAÇÃO DE DIFERENÇAS (PLD).....	27
3 REDES NEURAS ARTIFICIAIS.....	30
3.1 BREVE REVISÃO HISTÓRICA.....	30
3.2 MODELO BIOLÓGICO X MODELO ARTIFICIAL.....	30
3.3 MODELO ARTIFICIAL.....	32
3.4 ESTRUTURA DA REDE NEURAL.....	36
3.5 TREINAMENTO DA REDE NEURAL.....	37
3.6 VANTAGENS DAS REDES NEURAS ARTIFICIAIS.....	37
3.7 REDE NEURAL ARTIFICIAL MULTILAYER PERCEPTRON.....	38
3.7.1 TREINAMENTO POR LEVENBERG-MARQUARDT.....	39
3.7.2 TREINAMENTO POR BACKPROPAGATION.....	41
3.7.2.1 Passo <i>forward</i>.....	42
3.7.2.2 Passo <i>backward</i>.....	43
3.7.3 - GRADIENTE CONJUGADO ESCALONADO.....	44
4 METODOLOGIA E AMBIENTE DE ESTUDO.....	50
4.1 ANÁLISE DO AMBIENTE DE ESTUDO.....	50
4.2 COMPORTAMENTO DOS PREÇOS.....	51

4.3 METODOLOGIA.....	53
5 TESTES E RESULTADOS.....	57
5.1 RESULTADOS DAS PREVISÕES - LM.....	57
5.2 RESULTADOS DAS PREVISÕES - GCE.....	63
6 CONSIDERAÇÕES FINAIS.....	71
REFERÊNCIAS.....	73

1 INTRODUÇÃO

Segundo o anuário estatístico de 2021 da Empresa de Pesquisa Energética (EPE), que leva em consideração dados de 2016 até 2020, com foco em 2020(ano base), em 2018 a capacidade instalada de geração de eletricidade no Brasil foi expandida em 2,7% com contribuição majoritariamente hidrelétrica. De modo geral, os dados mostram a complexidade e a grandeza do setor elétrico no Brasil, e os desafios de realizar previsões nesse contexto, sejam de preço ou de outra natureza (EPE, 2021).

Para entender o contexto que o Brasil está inserido é necessário apresentar alguns dados, como o de que o Brasil é o sétimo país com maior capacidade de geração de energia elétrica no mundo. Com relação a geração hidrelétrica o Brasil sobe para a segunda posição, ficando atrás apenas da China em capacidade de geração de energia. Outro tipo de geração que deve se destacar é a eólica, que fechou o ano de 2020 com um aumento da potência instalada em 37,6% em comparação com o ano anterior. No que diz respeito à eletricidade gerada em um todo, no ano de 2020 foram produzidos 621 TWh, o que representa uma queda de 0,8% com relação a 2019. As maiores quedas percentuais são em relação a geração térmica a carvão (-22,1%), geração a gás natural (-11,1%) e nuclear (-12,9%). O setor industrial continua sendo o protagonista quando a questão é consumo, com 35% do consumo da energia elétrica gerada em 2020, seguido do setor residencial com 31,2% (EPE, 2021).

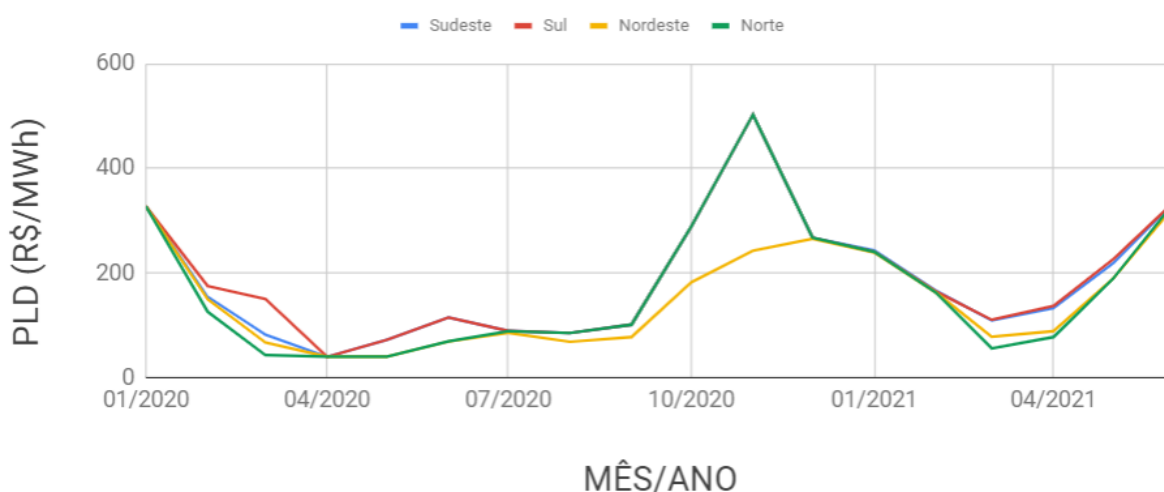
Também com base no anuário estatístico da EPE, o parque gerador brasileiro é massivamente hidrelétrico, em 2020 a geração proveniente de fonte hidráulica no Brasil correspondeu a 63,8% do total. Destaca-se também a geração eólica com 9,2%, e a geração de energia por Biomassa com 9% do total. De modo geral, podemos dizer que a geração de energia é bastante diversificada, com diversas fontes de energia (Hidráulica, Gás Natural, Carvão, Nuclear, Solar, Eólica, Biomassa, etc). Neste contexto, o setor energético brasileiro se difere bastante do europeu, onde a geração é proveniente basicamente de combustíveis fósseis e menos diversificado do que o brasileiro (EPE,2021).

Pode-se concluir pelos parágrafos anteriores, que o setor elétrico brasileiro é bastante diversificado e complexo. A estrutura do setor elétrico brasileiro tem sofrido massivas alterações ao longo dos anos, principalmente no século 20, quando a

eletricidade ganhou status de grande importância no que diz respeito à economia, infraestrutura, política, etc. Em 2004 foi instituído no Brasil, um novo modelo institucional do setor elétrico.

No que diz respeito à contratação de energia elétrica no Brasil (EPE, 2021), existem dois ambientes: O Ambiente de Contratação Regulada (ACR) e o Ambiente de Contratação Livre (ACL). O mercado livre de energia elétrica (ACL), é o ambiente em que os consumidores podem escolher livremente seus fornecedores de energia, atualmente 80% das indústrias no país contratam energia no ACL, e é necessário possuir demanda acima de 500kW para isso. No ACR, opção voltada aos consumidores residenciais e pequenas indústrias, a contratação de energia elétrica é realizada de forma compulsória, e deve ser feita necessariamente pela distribuidora da região. No ACR os preços e tarifas são regulados pela Agência Nacional de Energia Elétrica (ANEEL) que é responsável por controlar e fiscalizar as concessões, permissões e os serviços de energia elétrica (ABRACEEL, 2021). A Figura 1, ilustra a média mensal do Preço de Liquidação de Diferenças (PLD) entre janeiro de 2020 e junho de 2021.

Figura 1 - Preço de liquidação de diferenças (Média mensal de janeiro de 2020 até junho de 2021).



Fonte: Elaboração do próprio autor.

Na Figura 1, é possível observar o PLD para os quatro submercados brasileiros (Sul, Sudeste, Nordeste, Norte). O PLD indica o custo do MWh em curto prazo, e é determinado pela Câmara de Comercialização de Energia Elétrica (CCEE). Desde

2021, o PLD é calculado para cada hora do dia seguinte pelo modelo DESSEM. Na Figura 1 observa-se que o PLD, apresenta grande variação ao longo dos meses do ano, nos quatro submercados, impactando assim diretamente os preços de comercialização praticados entre os agentes do ACL. Sendo assim, justifica-se a necessidade de um modelo de previsão de preços de comercialização de energia confiável em um sistema de livre negociação de energia como o ACL.

1.1 BREVE REVISÃO BIBLIOGRÁFICA

A formação dos preços de energia elétrica no Brasil pode ser complexa, uma vez que a matriz energética no nosso País é bastante ampla, sendo sua principal fonte de geração de energia, a energia hidrelétrica. Este tipo de geração depende de fatores naturais, e passa por grande sazonalidade, além disso outras fontes renováveis e não renováveis compõem a matriz energética no Brasil, como por exemplo a geração eólica, solar, por biomassa, termelétricas, entre outras. Toda essa complexidade na matriz energética brasileira, dificulta a previsibilidade na disponibilidade de energia, e fazem os preços variarem bastante, dificultando também a previsão dos preços de energia elétrica.

Alguns trabalhos na literatura se encarregam de tentar realizar uma previsão dos preços de energia elétrica, e estudam o setor elétrico brasileiro. Este capítulo, tem como objetivo fazer uma breve abordagem, de alguns trabalhos relacionados ao tema de comercialização de energia elétrica, previsão de preços e previsão de carga, destacando os objetivos destes trabalhos e seus resultados.

Santos (2019), faz uma previsão de preços para o mercado livre brasileiro dos quatro submercados (Sudeste, Norte, Nordeste e Sul) utilizando Redes Neurais Artificiais (RNA), comparando com os métodos tradicionais de previsão como o Auto Regressive Integrated Moving Average (ARIMA), Seasonal Auto Regressive Integrated Moving Average (SARIMA) e de suavização exponencial Holt-Winters (HW). Para a realização do trabalho a autora utilizou como dados o PLD dos anos de 2003 até 2019. Como metodologia, a autora utilizou para treino os dados do PLD de 2003 até 2017, dividido em meses, totalizando 176 observações, e utilizou para teste 19 meses (19 observações). A autora prevê os resultados para o primeiro e último mês subsequentes do período de treinamento (1 passo à frente e 19 passos à frente).

No trabalho a autora utilizou quatro métricas de erro, o Mean Absolute percentage error (*MAPE*), o Mean absolute error (*MAE*), o Mean absolute scaled error (*MASE*) e o Root mean square error (*RMSE*). Como resultados, quando a autora faz a previsão para um mês, as redes neurais artificiais obtiveram melhores resultados do que os métodos tradicionais, no entanto a longo prazo, o método HW obteve resultados superiores à previsão realizada por redes neurais artificiais.

Com relação ao mercado Ibérico de energia e previsão de preços, Moreira (2015), publicou um trabalho para previsão de preços de eletricidade, através de uma previsão probabilística utilizando métodos de regressão de quantis. Para a realização da análise probabilística o autor utilizou o histórico dos preços de energia elétrica de Portugal e da Espanha e também outros fatores que influenciam a formação de preços nos países, como por exemplo previsões do consumo de eletricidade, produção de energia eólica que é um fator muito importante no país e gera grande sazonalidade e não linearidade na previsão de preços, velocidade do vento, precipitação, temperatura e irradiância solar. Os dados para o trabalho são relativos a cada uma das 24 horas, do período compreendido entre 1 de janeiro de 2013 e 15 de setembro de 2014, sendo que o conjunto de dados foi dividido em 2013 para treino e 2014 para teste. O objetivo foi realizar uma previsão de curto prazo para cada uma das 24 horas do dia posterior. Como resultados, o autor conseguiu explorar e demonstrar um alto potencial no uso de métodos de regressão de quantis, que representam uma metodologia simples, produzem bons resultados e necessitam de pouco esforço computacional.

Oliveira (2016) buscou fazer uma análise do problema de previsão de demanda de energia elétrica no Brasil, análise que segundo o autor é fundamental para que as geradoras, distribuidoras e comerciantes de energia possam gerenciar as incertezas do mercado. O autor utilizou dois métodos, o primeiro a partir do uso de redes neurais artificiais e o segundo por meio de análises de séries de Fourier. No trabalho, o autor obtém melhores resultados com o uso das redes neurais artificiais e utiliza diversas variáveis endógenas e exógenas, como: Transporte, Balanço Energético, capacidade Industrial, PIB anual, índices setoriais, SELIC, valores tarifários, clima (temperatura, umidade relativa do ar, pressão, etc), cotação do dólar, inflação, capacidade de geração. O autor ressalta que obteve melhores resultados com a utilização de variáveis exógenas, porém apenas com a utilização de variáveis endógenas foi capaz de obter bons resultados de previsão.

Amadeu (2011), realizou uma análise da utilização de modelos de séries temporais, como modelos autoregressivos-AR, modelos autorregressivos com regressores exógenos-ARX e de modelos não lineares (Redes Neurais Artificiais) na predição de Spread a serem aplicados por agentes vendedores no mercado de curto prazo. Em outras palavras, o autor faz uma previsão para o preço de energia para o mercado brasileiro. O trabalho foi realizado com variáveis como: PLD, geração termelétrica, geração hidrelétrica, demanda energética, energia natural afluyente (ENA), energia armazenada e o próprio spread. O trabalho foi realizado com dados relativos ao período de janeiro de 2006 até setembro de 2011. O autor concluiu que os modelos autorregressivos de primeira e segunda ordem tiveram um bom desempenho na predição do Spread. No entanto, os modelos que obtiveram os melhores resultados de previsão, e que apresentaram melhores oportunidades de melhora foram os modelos de redes neurais artificiais.

No seu trabalho intitulado “Formação dos preços de energia convencional nas transações entre agentes no mercado brasileiro”, Sozzi (2015) fez uma abordagem do Spread (ágio e deságio) na formação dos preços de energia praticados entre agentes no curto prazo. Para isso, o autor faz uma análise do mercado de energia brasileiro, destacando os pontos que têm influência direta na formação do Spread da energia convencional. O trabalho sugere um modelo de regressão linear múltipla para a projeção do Spread, para isso, o autor utiliza um banco de dados de cotações de negócios efetivamente realizados no curto prazo no período de janeiro de 2011, até julho de 2014, bem como informações retiradas da CCEE e do Operador Nacional do Sistema Elétrico (ONS). O autor concluiu, que o Spread é um importante fator a ser considerado na formação dos preços, visto que, no período de janeiro de 2011, até julho de 2014, o spread variou entre -4% a +128%, sendo assim, segundo o autor, o Spread possui bastante influência no preço final praticado para o consumidor.

1.2 CLASSIFICAÇÃO DA PREVISÃO E FERRAMENTA AVALIADORA DA PREVISÃO

De modo geral, a previsão por redes neurais artificiais pode ser classificada de acordo com o período em que se está sendo realizada a previsão (LOPES, 2005). Existem quatro tipos de classificação para as previsões:

- Previsão a longo prazo: Realizada no período de alguns meses, podendo chegar a anos.
- Previsão a médio prazo: Previsão que ocorre no período de semanas a meses.
- Previsão a curto prazo: Previsão que ocorre no intervalo de tempo de 30 minutos até algumas horas, podendo chegar até uma semana.
- Previsão a curtíssimo prazo: Previsões que ocorrem até 15 minutos.

Para verificar a robustez, congruência e qualidade das previsões de preço realizadas neste trabalho, e também para verificar qual dos dois treinamentos utilizados apresenta melhor congruência com os valores reais, será utilizada uma ferramenta bastante recorrente na literatura. Será calculado o erro percentual absoluto médio *Mean Absolute Percentage Error (MAPE)* (CARVALHO, 2017).

A equação (1), evidencia o método de cálculo do *MAPE*.

$$MAPE = \frac{1}{N} \times \sum_{h=1}^N \left(\left| \frac{Pr(h) - P_{previsto}(h)}{Pr(h)} \right| \right) \times 100 \quad (1)$$

Sendo:

- N : Número de horas
- $Pr(h)$: Preço real na hora h
- $P_{previsto}(h)$: Preço previsto pela rede na hora h

A qualidade e precisão da previsão, está diretamente atrelada ao valor do *MAPE*, quanto mais baixo for resultado do *MAPE*, maior a qualidade da previsão realizada.

1.3 OBJETIVOS

Levando-se em consideração todos os dados e as informações citadas anteriormente, o objetivo deste trabalho consiste em fazer uma avaliação da capacidade das redes neurais artificiais de atuarem na previsão de preços de curto prazo do mercado de comercialização de energia elétrica brasileiro, mais precisamente neste trabalho do PLD, que é dado em R\$/MWh. A projeção de preços

está diretamente ligada ao PLD, embora os preços praticados entre os agentes possam ser acrescidos de outros parâmetros, como o spread, por exemplo, o PLD é a base para os preços praticados entre os agentes. Como neste trabalho não será abordado estes outros parâmetros que podem compor os preços de comercialização, a previsão do PLD, será vista como a própria previsão de preços de comercialização de energia elétrica. O comportamento de preços de energia no Brasil, possui grande volatilidade, sazonalidade e não linearidade, sendo assim, será avaliado como as redes neurais se comportam para a previsão de preços de comercialização de energia, usando para isso dois tipos de treinamento e fazendo uma comparação entre eles, com o intuito de verificar qual treinamento melhor se enquadra para a realização das previsões propostas. Será usada uma rede neural artificial do tipo Multilayer Perceptron (MLP) *feedforward* e dois tipos de treinamento: *Backpropagation* (Gradiente Conjugado Escalonado) e Levenberg-Marquardt (LM).

Os dados coletados para a realização da previsão, são referentes ao submercado Sudeste, no período de 2020 a 2021. A escolha por realizar a previsão apenas para o submercado Sudeste, se dá devido ao fato de que em grande parte do tempo observado no trabalho, as variações de preço entre os quatro submercados é pequena, sendo assim, optou-se por realizar a previsão apenas para o Submercado Sudeste. É realizada uma previsão horária dos preços (uma hora a frente), para os dias da primeira semana de fevereiro de 2021.

Para realização deste trabalho, faz-se necessário também entender um pouco mais sobre a estrutura do setor elétrico brasileiro. Este entendimento inclui um breve apanhado sobre a história do setor elétrico brasileiro, o seu desenvolvimento até chegar nos dias atuais, e o mercado de comercialização de energia elétrica no Brasil. Além disso, fez-se necessário fazer uma introdução sobre os conceitos gerais de redes neurais artificiais, e sobre os treinamentos utilizados neste trabalho.

1.4 ORGANIZAÇÃO TEXTUAL

O trabalho está dividido em 6 capítulos no total, que foram divididos da seguinte forma: setor elétrico brasileiro, redes neurais artificiais, metodologia e ambiente de estudo, testes e resultados, e finalizando com as considerações finais.

O capítulo 2, abrange informações sobre a estrutura do setor elétrico brasileiro, fazendo um breve apanhado histórico, e abordando alguns conceitos e instituições importantes para o contexto deste trabalho.

O capítulo 3 trata das redes neurais artificiais de modo geral, explicando conceitos básicos importantes, fazendo um breve apanhado histórico, explicando o tipo de rede neural utilizado neste trabalho, e os treinamentos utilizados no trabalho.

O capítulo 4 apresenta a metodologia utilizada para a criação da rede neural utilizada neste trabalho, e faz uma abordagem e explicação do ambiente de estudo.

O capítulo 5 apresenta os testes e resultados obtidos neste trabalho, os gráficos comparados às previsões realizadas com os valores reais, e também tabelas que apresentam os resultados do *MAPE*, para os dois treinamentos adotados neste trabalho.

O capítulo 6, apresenta as considerações finais deste trabalho, como as principais conclusões tiradas do trabalho e algumas propostas que poderiam ser empregadas em trabalhos futuros, que utilizem a mesma linha de raciocínio deste trabalho.

2 SETOR ELÉTRICO BRASILEIRO

A história da eletricidade no Brasil se inaugurou no final do século 19, inicialmente, participaram deste processo, pequenas empresas privadas nacionais e também municipais, nos primeiros anos do século 20, chegaram as primeiras concessionárias estrangeiras como por exemplo a The São Paulo Light, que adquiriram a maior parte das empresas municipais e nacionais já existentes, o que possibilitou o início do consumo comercial e industrial. No ano de 1920 houve a construção de algumas barragens por parte das empresas privadas instaladas, como a Usina de Cubatão, construída em 1920 pela Light. Neste contexto, é importante também destacar o desenvolvimento da economia cafeeira em São Paulo, fundamental para a consolidação da eletricidade no Brasil, pois dava origem a um conjunto de atividades, como construção de ferrovias e expansão urbana (LORENZO, 2001).

Pode-se dizer então, que as empresas estrangeiras foram primordiais para o desenvolvimento do setor elétrico brasileiro, sendo responsáveis também, por tópicos como fixação de preços, concessões, etc. No ano de 1934, a defesa da intervenção do estado no setor começou a ser debatida, e em 1934 foi promulgado o Código de Águas, que teve a função de regulamentar sobre a propriedade das águas e sua utilização, e dispor sobre a outorga das autorizações e concessões para exploração dos serviços de energia elétrica, incluindo a determinação de tarifas (LORENZO, 2001).

A criação do Código de Águas de 1934, foi a propulsora para a segunda fase da história do setor elétrico brasileiro, marcado pela forte intervenção do Estado nesta área. O governo agiu de forma bastante monopolística no setor, criando empresas, agentes reguladores e financiando empreendimentos de geração de energia elétrica. Em 1952, foi fundado o Banco Nacional de Desenvolvimento Econômico (BNDE), que forneceu empréstimos a empresas do setor de geração elétrica, em 1960, foi fundado o Ministério de Minas e Energia (MME), e em seguida foram fundadas empresas como a Furnas e a Eletrobrás. A Eletrobrás teve um papel decisivo na centralização do planejamento e operação do setor elétrico brasileiro (LORENZO, 2001)

A partir do ano de 1980, em meio a construção da usina de Itaipu, a maior do mundo até então, o governo se viu com o seu modelo estatizante em crise, devido a

ineficiência tarifária, inflação alta, vulnerabilidade, e dívida elevada. Em 1988, foi criada a Revisão Institucional do Setor Elétrico (REVISE) que teve papel fundamental para grandes alterações do setor elétrico na década de 90 (FERREIRA, 2000).

A partir da década de 90, se inicia um período no setor elétrico brasileiro que continua até os dias atuais. Durante o governo do então presidente Fernando Henrique Cardoso, um novo modelo para o setor elétrico foi criado. Foi neste período em que as atividades de geração, transmissão, distribuição e comercialização de energia elétrica foram separadas. Foi criado o Operador Nacional do Sistema Elétrico (ONS), que é responsável pela operação do Sistema Interligado Nacional (SIN). Foi criada a Agência Nacional de Energia Elétrica (ANEEL), a ANEEL está vinculada ao Ministério de Minas e Energia (MME) e tem a função de regular e fiscalizar todo o setor elétrico nacional (SANTOS, 2019). Entre as atividades vinculadas a ANEEL estão:

- Regular a geração, transmissão, distribuição e comercialização de energia elétrica.
- Estabelecer tarifas.
- Fiscalizar diretamente ou mediante convênios com órgãos estaduais, as concessões, as permissões e os serviços de energia elétrica.

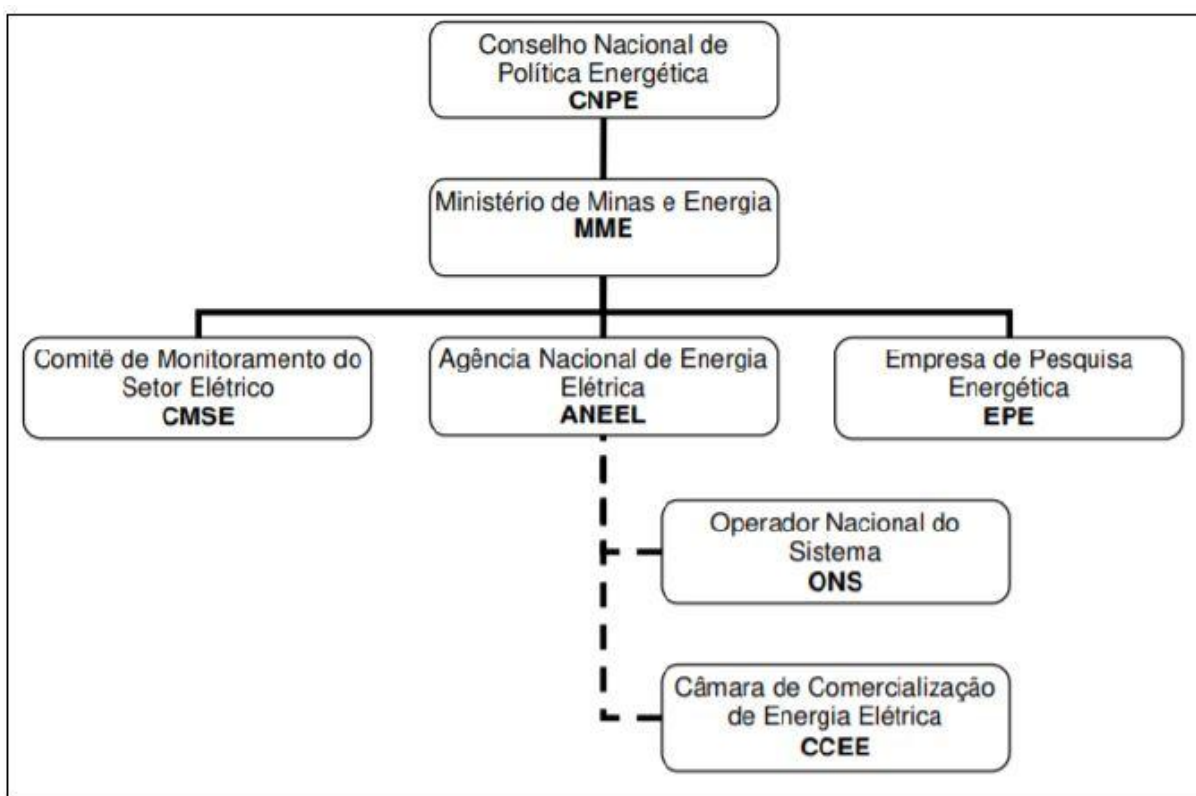
Em março de 2004, foi aprovado um novo modelo para o setor elétrico brasileiro que tinha como premissas, estimular a contratação eficiente de energia elétrica para consumidores regulados, garantir a segurança no suprimento de energia elétrica, estabilizar o mercado, e garantir a inserção social (CUBEROS, 2008). Novas instituições foram criadas, como por exemplo a Empresa de Pesquisa Energética (EPE), que tem por finalidade prestar serviços ao MME na área de estudos e pesquisas para o planejamento energético brasileiro, o Comitê de Monitoramento do Setor Elétrico (CMSE), e a CCEE. Os participantes da CCEE são empresas que atuam em todas as atividades do setor elétrico brasileiro, como geração, transmissão e distribuição de energia elétrica (SANTOS, 2019).

Atualmente os agentes institucionais do governo que atuam no setor de energia elétrica, são organizados da seguinte forma:

- Atividades do Governo: Comissão Nacional de Política Energética; Ministério de Minas e Energia (MME); Comitê de Monitoramento do Setor Elétrico (CMSE);
- Atividades Regulatórias: Agência Nacional de Energia Elétrica (ANEEL)
- Atividades Especiais: Empresa de Pesquisa Energética (EPE); Câmara de Comercialização de Energia Elétrica (CCEE); Operador do Sistema Elétrico (ONS).

A Figura 2 apresenta a estrutura do setor elétrico nacional nos dias atuais.

Figura 2 - Estrutura do setor elétrico brasileiro.



Fonte: Cuberos 2008.

2.1 CÂMARA DE COMERCIALIZAÇÃO DE ENERGIA ELÉTRICA

Entre todas as instituições citadas até aqui neste capítulo, a que demanda mais atenção é a CCEE.

A CCEE, foi criada em 2004, tem como atribuição viabilizar a comercialização de energia elétrica no país (Lei nº 10.848 , 15 de março de 2004 e regulamentada

pelo decreto nº 5.177 de 12 de agosto de 2004). As funções da CCEE incluem administrar o Ambiente de Contratação Regulada de energia elétrica (ACR) e o Ambiente de Contratação Livre (ACL). A CCEE é responsável pela realização de leilões de contratação de energia elétrica, registros firmados entre compradores e vendedores, e contabilização de compra e venda de energia elétrica. Os participantes da CCEE são empresas ligadas à geração, transmissão e distribuição de energia elétrica (SANTOS, 2019).

Existem dois ambientes de contratação de Energia Elétrica no Brasil. O ACR, que é formado por consumidores cativos, podendo ser empresas de geração, concessionárias de distribuição, importadoras e comercializadoras de energia, neste ambiente, a energia elétrica é comprada pelas distribuidoras, através de leilões com preços determinados e regulados pela ANEEL. O consumidor cativo é aquele que só pode comprar energia elétrica pela concessionária responsável pela distribuição em sua região (residências e pequenas empresas) neste tipo de mercado, as tarifas são reguladas pelo governo, cada unidade consumidora paga uma tarifa mensal, e o preço é influenciado pelo sistema de bandeiras tarifárias praticada pela ANEEL. A maior parte do volume de energia consumido no Brasil está vinculado ao ACR, representando mais de 70% do SIN. A seguir estão listadas as formas como uma concessionária de distribuição pode adquirir energia elétrica para atender a sua demanda (SOZZI, 2015).

- Contratos do Programa de Incentivo às Fontes Alternativas de Energia Elétrica (Proinfa).
- Contratos de energia proveniente da usina hidrelétrica de Itaipu.
- Contratos bilaterais anteriores a lei 10.848 (BRASIL, 2004a)
- Contratos de leilões regulados promovidos pela ANEEL.
- Contratos de geração distribuída.

O ACL é o ambiente de contratação livre de energia. Onde os agentes vendedores de energia (geradores e comercializadores de energia) e os agentes compradores de energia (consumidores livres e comercializadores de energia) negociam diretamente as condições de compra e venda de energia elétrica entre si. No ACL, o consumidor mantém dois contratos, sendo um com a distribuidora de energia elétrica, pelo uso das redes de distribuição, e outro com a empresa geradora, que é responsável por vender a energia elétrica. Os contratos são

registrados na CCEE. A principal vantagem do ambiente ACL, é que as empresas podem contratar de quem atende melhor suas expectativas (SOZZI, 2015).

No ACL, pode haver uma diferença entre a energia contratada e a energia consumida pelo agente. Esta diferença deve ser liquidada no mercado de curto prazo e valorada ao PLD, que reflete o custo marginal atual de operação (SANTOS, 2019).

2.2 PREÇO DE LIQUIDAÇÃO DE DIFERENÇAS (PLD)

A CCEE contabiliza as operações de compra e venda de energia elétrica e determina os débitos e créditos dos agentes baseados no preço de liquidação de diferenças. O objetivo do PLD é encontrar a solução ótima de equilíbrio do uso da água e o benefício futuro de seu armazenamento. Existem duas premissas simultâneas quando tratamos da definição do PLD. A primeira seria a máxima utilização da energia hidrelétrica disponível em cada período, pois isto minimiza o preço do combustível, no entanto, esta primeira premissa resulta em maiores riscos e déficits futuros. A segunda premissa é que para aumentar a confiabilidade do fornecimento de energia é necessário manter o nível dos reservatórios o mais elevado o possível, no entanto, isso resulta o acionamento de geração térmica, e portanto, o aumento do custo de operação (CCEE, 2021).

Levando em consideração as premissas citadas anteriormente, se é obtido os Custos Marginais de Operação (CMO). O CMO é obtido com base nas condições hidrológicas, preços de combustível, preços e disponibilidade de equipamentos de geração e transmissão de energia elétrica, demanda de energia, entre outros fatores. A base para o cálculo do PLD é o CMO. O processo de cálculo do PLD, é feito a partir de modelos computacionais, que são o NEWAVE, o DECOMP e o DESSEM, que produzem como resultado o CMO de cada submercado, em base mensal, semanal e diária respectivamente. O CMO, estabelece quanto custa produzir um MWh adicional para o sistema elétrico, portanto o PLD é medido em R\$/MWh. O processo de precificação é definido por submercado (Sul, Sudeste, Nordeste e Norte). A Figura 3, ilustra a divisão dos submercados de energia no Brasil, e seus respectivos estados.

Figura 3 - Submercados de energia no Brasil.



Fonte: Coelho 2017.

O NEWAVE é um modelo computacional utilizado no planejamento operacional da operação de sistemas hidrotérmicos de médio prazo (até 5 anos). O DECOMP é um modelo computacional utilizado no planejamento operacional dos sistemas hidrotérmicos no curto prazo (até 2 meses) até 31 de dezembro de 2020, os valores oficiais do PLD eram calculados com base no modelo DECOMP. O DESSEM é o modelo computacional utilizado no planejamento da operação dos sistemas hidrotérmicos no curtíssimo prazo (até 7 dias). A partir de 1 de janeiro de 2021, os valores oficiais do PLD são calculados com base no modelo DESSEM. Desde o dia 1º de janeiro de 2021, o PLD é calculado para cada hora do dia seguinte, para cada submercado. Antes disso, do período de abril de 2018 até dezembro de 2020, até a efetiva implementação do PLD horário, a CCEE divulgou o

preço horário “sombra” para cada submercado, disponível também para consulta na página eletrônica da CCEE.

3 REDES NEURAIS ARTIFICIAIS

Este capítulo do trabalho tem como objetivo fornecer um embasamento teórico essencial utilizado para o desenvolvimento deste trabalho. Neste capítulo será feita uma abordagem geral dos conceitos de redes neurais artificiais, uma breve revisão histórica, uma abordagem do modelo do neurônio artificial com destaque para a rede perceptron, e dos algoritmos de treinamento utilizados no trabalho.

3.1 BREVE REVISÃO HISTÓRICA

O trabalho pioneiro, que marcou o início da era moderna das redes neurais artificiais, foi realizado por McCulloch e Pitts (1943). McCulloch foi um psiquiatra e neuroanatomista, Pitts um prodígio matemático que se associou a McCulloch em 1942. O clássico trabalho dos dois cientistas descreveu um cálculo lógico das redes neurais que unifica os estudos de neurofisiologia e da lógica matemática (HAYKIN, 2001).

Ainda na década de 1940, houve a publicação do livro “*The Organization of Behavior*”, que foi escrito por Donald Hebb, e introduziu o conceito da aprendizagem Hebbiana. As décadas seguintes trouxeram trabalhos importantes, na década de 1950 surgiram as redes baseadas em reforço, desenvolvidas por Minsky em 1951, e na década de 1960 Rosenblatt publicou o livro intitulado “*Principles of Neurodynamics*”, que introduziu as redes denominadas *perceptrons*. Na década de 1970 foi desenvolvido o algoritmo de treinamento que se tornaria o mais popular entre as redes neurais, o *Backpropagation* (*retropropagação*), proposto por Werbos em 1974, e redescoberto por Rumelhart, Hinton e Williams em 1986. Este algoritmo renovou o interesse entre os pesquisadores, e expandiu as pesquisas na área de redes neurais (LOPES, 2005).


3.2 MODELO BIOLÓGICO X MODELO ARTIFICIAL

O nosso cérebro é sem dúvida o órgão mais fantástico e mais complexo que possuímos, o crescente interesse no entendimento do seu funcionamento ao longo dos anos, e a vontade por simulá-lo levou ao desenvolvimento e aperfeiçoamento das redes neurais.

Sabe-se que o sistema nervoso possui mais de 100 bilhões de neurônios, estes mesmos podem realizar interconexões com cerca de outros 10 mil neurônios, na biologia esta conexão entre os neurônios é conhecida como rede neuronal, estas conexões são responsáveis pelas atividades do sistema nervoso (ALTRAN, 2010).

O neurônio biológico é formado basicamente por quatro partes principais: o corpo Celular, que é a parte central do neurônio, a sinapse, que nada mais é do que a conexão entre dois neurônios, mais precisamente entre a terminação axônica de um neurônio e dendrito do outro, a sinapse é responsável pelo controle do fluxo de informações, o dendrito, que é a parte responsável do neurônio biológico que recebe as informações ou impulsos nervosos dos demais neurônios, tem a funcionalidade de conduzir estes impulsos nervosos ao corpo celular, o axônio, que pode medir desde 0,1 milímetros até 1 metro, o axônio no seu final se divide e forma os dendritos, estes se ligam aos demais neurônios por meio das sinapses (LOTUFO; MINUSSI, 2008). A Figura 4, ilustra os principais componentes do neurônio biológico.

Figura 4 - Componentes essenciais do neurônio biológico.



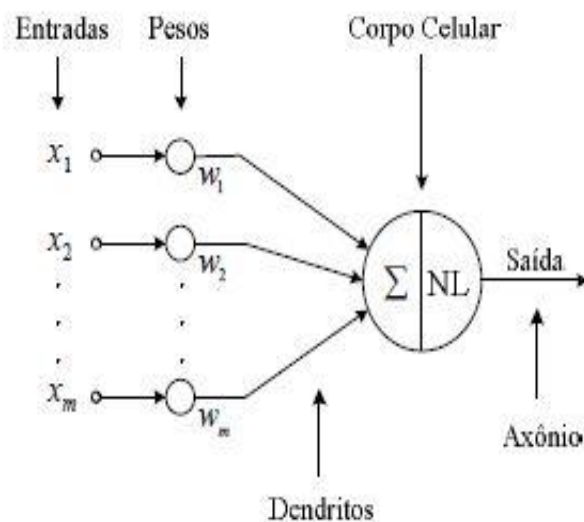
Fonte: Lotufo e Minussi (2008).

3.3 MODELO ARTIFICIAL

Assim como no cérebro humano, que possui o neurônio biológico como modelo central, as redes neurais possuem o neurônio artificial (LOPES, 2005). As principais características do modelo biológico que as redes neurais tentam reproduzir são a capacidade de conhecimento através de experiências ou treinamento (processamento paralelo maciço), a transmissão de informações e interligação de neurônios por meio de conexões sinápticas, e também a capacidade de generalização, que podemos interpretar como a capacidade da rede neural de fornecer em tempo real saídas com uma razoável precisão para as entradas que não participaram da fase de treinamento (LOPES, 2005; ALTRAN, 2010).


Na Figura 5, é mostrado o modelo do neurônio artificial formulado por McCulloch e Pitts (1943). O neurônio artificial faz uma simplificação do neurônio biológico.

Figura 5 - Neurônio artificial de McCulloch e Pitts



Fonte: Lopes (2005).

Na Figura 6, é representado o modelo básico de um neurônio artificial com n entradas. A função $f(s)$ é uma função não linear conhecida como função de ativação.

Figura 6 - Modelo de um neurônio artificial com n entradas

Fonte: Lopes (2005).

O processo de treinamento do neurônio artificial, se desenvolve em quatro etapas principais (LOPES, 2005). O conjunto de entradas x_1, x_2, \dots, x_n representam as entradas que são aplicadas ao neurônio artificial, estas entradas são multiplicadas pelos pesos w_1, w_2, \dots, w_n . As entradas multiplicadas são aplicadas ao bloco somatório Σ , este bloco somatório representa o corpo celular biológico. Por fim, tem-se o valor de (*bias*), se a soma das entradas for maior que o valor de w_0 , o neurônio é ativado, e assim, temos um pulso na saída, se a soma não for maior do que w_0 , o neurônio então, não é ativado, o peso w_0 , tem como função ponderar uma entrada arbitrária $x_0 = +1$, que é o nível de controle da saída do neurônio (LOPES, 2005).

Os sinais de entrada x_1, x_2, \dots, x_n , são combinados com os pesos associados w_1, w_2, \dots, w_n . fornecendo a saída intermediária s , apresentada na equação (2) (HAYKIN, 2001).

$$s = \sum_{i=1}^n x_i w_i + x_0 w_0 \quad (2)$$

w_0 é o peso, conhecido também como “bias”.

Tem-se que a saída do neurônio é calculada por meio da aplicação da função de ativação na saída intermediária s , isso é apresentado na equação (3).


$$y = f(s) \quad (3)$$

As figuras de 7 a 10 ilustram as funções de ativação mais conhecidas e utilizadas na literatura.

- Função Relé →

$$f(s) = \begin{cases} +1, & \text{se } s \geq 0 \\ -1, & \text{se } s < 0 \end{cases}$$

Figura 7 - Função relé




Fonte: Lotufo e Minussi (2008).

A função relé aparece na literatura de forma recorrente. No entanto a função relé é inadequada para os treinamentos caracterizados por métodos de otimização determinísticos, isto porque, esses métodos utilizam derivadas de funções, sendo assim, para os treinamentos que utilizam os métodos de otimização determinísticos a função relé acaba sendo inadequada, devido ao fato de ser uma função não diferenciável (LOTUFO; MINUSSI, 2008).

- Lógica *threshold* →

Figura 8 - Função Lógica *threshold*.




Fonte: Lotufo e Minussi (2008)

- Função sigmóide (1) →

$$f(s) = \frac{1 - e^{-\lambda s}}{1 + e^{-\lambda s}}$$

Figura 9 - Função sigmóide (1).




Fonte: Lotufo e Minussi (2008)

- Função sigmóide (2) →

$$f(s) = \frac{1}{1 + e^{-\lambda s}}$$

Figura 10 - Função sigmóide (2)



Fonte: Lotufo e Minussi (2008).

As funções do tipo sigmóide possuem a vantagem com relação às funções do tipo relé, pois são contínuas e podem apresentar derivada simples. Sendo assim, as funções sigmoidais podem ser empregadas em sistemas binários e também contínuos.

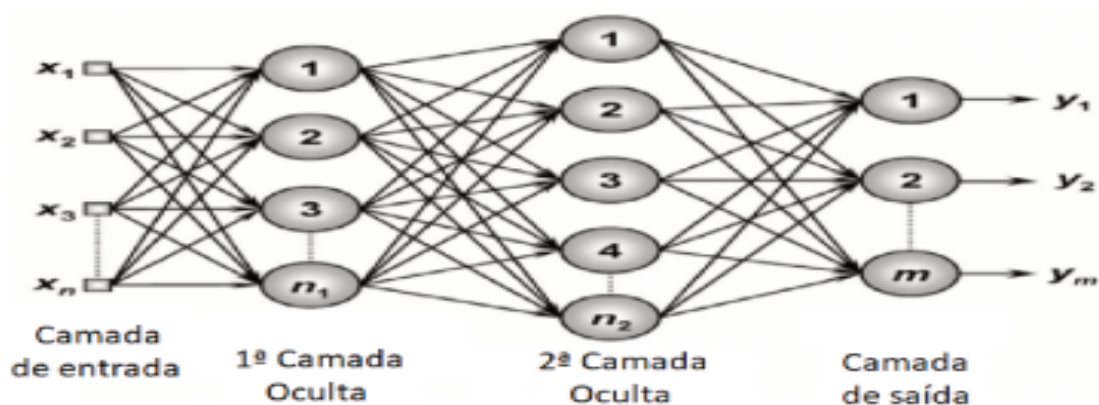
3.4 ESTRUTURA DA REDE NEURAL

A arquitetura de uma RNA é definida basicamente pelo número de camadas e pelo número de neurônios em cada camada, bem como na camada de entrada e na camada de saída. Uma RNA pode ser de camada simples, onde o sinal de entrada é propagado diretamente para a camada de saída, ou multicamadas, possuindo assim camadas escondidas, onde ocorre um maior processamento dos dados (ROCHA, 2019). De modo geral, existem dois tipos de arquiteturas principais:

- Redes *feedforward*: São redes unidirecionais, podendo ser de camada simples ou multicamadas, nas redes do tipo *feedforward*, não existem laços de realimentação.
- Redes recorrentes ou *feedback*: As redes do tipo *feedback*, são redes que possuem laços de retroalimentação, sendo assim, as conexões de retroalimentação permitem que os neurônios de uma determinada camada, recebam dados de um neurônio pertencente a sua camada, ou pertencente a uma camada posterior.

As Figuras (11) e (12) ilustram uma rede do tipo *feedforward* e *feedback* respectivamente.

Figura 11 - Rede *Feedforward*



Fonte: Rocha (2019).

Figura 12 - Rede *Feedback* ou recorrente

Fonte: Rocha (2019).

3.5 TREINAMENTO DA REDE NEURAL

Entre as várias características das redes neurais, uma das mais importantes sem dúvida é a capacidade de aprender e melhorar o seu desempenho, para isso a rede deve ser treinada, de forma que um conjunto de dados de entrada produza uma ou mais saídas desejadas ou esperadas. A seguir são apresentados os principais tipos de treinamento (LOPES, 2005).

- **Treinamento Supervisionado:** Este tipo de treinamento exige a presença de um agente externo (tutor ou professor) em sua fase de aprendizado. O treinamento Supervisionado necessita de um vetor de entrada e um vetor alvo ou saída desejada.
- **Treinamento Não-Supervisionado:** Neste tipo de treinamento não se tem o agente externo (tutor ou professor) na fase de aprendizado. O conjunto de treinamento necessita exclusivamente dos dados de entrada.
- **Treinamento Híbrido:** Neste tipo de treinamento existe uma alternância entre o treinamento supervisionado e treinamento não-supervisionado.

3.6 VANTAGENS DAS REDES NEURAIIS ARTIFICIAIS

As redes Neurais possuem como uma de suas principais características a capacidade de generalização, que é a capacidade de responder de maneira

adequada a novas situações a partir de experiências passadas (treinamento) (LOPES, 2005). Podemos citar como as principais vantagens das redes neurais artificiais (HAYKIN, 2001).

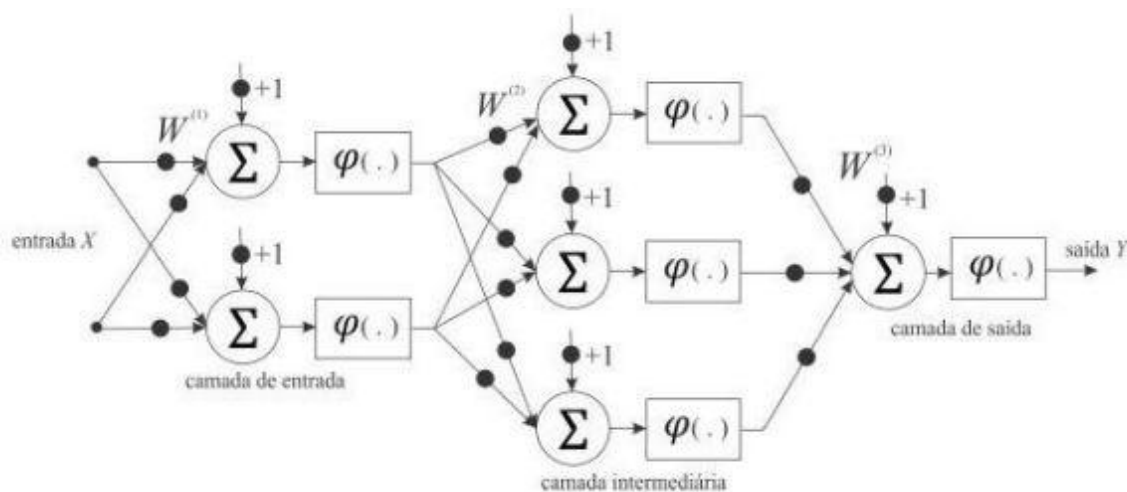
- **Aprendizado e generalização:** É a capacidade que a RNA tem de entregar resultados por meio de experiências passadas e armazenamento de conhecimento.
- **Processamento Paralelo:** O processamento é responsável por fazer as tarefas mais complexas serem executadas com maior velocidade.
- **Não linearidade:** É uma propriedade importante que faz com que as redes neurais não se limitem a sinais de entradas lineares.
- **Versatilidade:** Amplas aplicações, e em diversas áreas de atuação.
- **Robustez:** É uma propriedade importante que faz com que a rede seja capaz de processar dados com ruídos, anormalidades, dados incompletos, etc.

3.7 REDE NEURAL ARTIFICIAL MULTILAYER PERCEPTRON

Em 1958, foi proposta a rede neural artificial Perceptron de camada simples, para a classificação e reconhecimento de padrões, esta rede é eficiente para a resolução de problemas lógicos linearmente separáveis como o que acontece nas operações lógicas AND e OR, no entanto é ineficiente para resolver problemas e mapeamentos mais complexos (MULLER, 2018; ROSENBLATT, 1958).

Para a solução de problemas mais complexos necessitamos usar outros tipos de redes neurais, como a rede neural MLP, que se enquadra como uma das mais flexíveis e versáteis com relação a aplicabilidade (SILVA, 2012). As redes MLP, possuem pelo menos uma camada intermediária (ou escondida) de neurônios entre as camadas de entrada e de saída, sendo que o sinal de entrada se propaga para a frente, camada por camada. As camadas escondidas, tem a função de capacitar a rede para aprender e realizar tarefas complexas, extraíndo de forma progressiva informações dos vetores de entrada (HAYKIN, 2001). A Figura 13 ilustra a arquitetura da RNA do tipo Multilayer Perceptron.

Figura 13 - Arquitetura da RNA Multilayer Perceptron.



Fonte: Haykin (1994).

A rede apresentada acima é do tipo *feedforward*, o sinal de entrada é combinado com os pesos sinápticos e propagados através da rede camada por camada. Os símbolos $\varphi(\cdot)$ são as funções de ativação não lineares dos neurônios.

3.7.1 TREINAMENTO POR LEVENBERG-MARQUARDT

Para o aprendizado e generalização confiável da relação de entrada e saída, a RNA precisa de um processo de treinamento adequado. Neste trabalho serão utilizados os treinamentos do tipo Levenberg-Marquardt e *Backpropagation* (Gradiente Conjugado Escalonado). Neste tópico será abordado um pouco mais profundamente o treinamento de Levenberg-Marquardt.

O algoritmo LM utiliza gradiente de segunda ordem, que se baseia na determinação das derivadas de segunda ordem do erro quadrático em relação aos pesos, isso é uma diferença considerável em relação ao algoritmo de treinamento *Backpropagation* (BP), que utiliza as derivadas de primeira ordem (SILVA, 2012).

O algoritmo de treinamento por LM consiste em um aperfeiçoamento do método Gauss-Newton, que é uma variante do método de Newton (SAMI e SONI, 2002). O treinamento LM (BARBOSA et al, 2005) faz a aproximação para a matriz Hessiana mostrada na equação (4), determinada em função da matriz Jacobiana, contendo as primeiras derivadas dos pesos em função dos pesos sinápticos.

$$H = \frac{\partial^2 E_R(W)}{\partial W^2} \quad (4)$$

$E_R(W)$ é definido de acordo com a equação (5).

$$E_R(W) = \frac{1}{n} \sum_{i=1}^n (y_i - y_{ei})^2 \quad (5)$$

$$J(W) = \frac{\partial e(W)}{\partial W} \quad (6)$$

sendo:

H = matriz hessiana;

J = matriz jacobiana;

$E_R(W)$ = erro relativo da comparação entre as saídas;

$e(W)$ = erro absoluto da comparação das saídas;

$$e(W) = \sum_{i=1}^n (y_i - y_{ei}) \quad (7)$$

sendo:

y_i = saída fornecida pela rede;

y_{ei} = valor exato correspondente à saída da rede;

O processo de determinação da matriz Jacobiana é relativamente mais simples que o processo de determinação da matriz Hessiana. Sabendo que, para uma rede neural, o desempenho do treinamento pode ser expresso em função da soma dos erros quadráticos, a matriz Hessiana pode ser expressa pela equação (8) (BARBOSA et al, 2005).

$$H = J^T(W)J(W) \quad (8)$$

O método de Newton atualiza os pesos de acordo com a equação (9):

$$W(k + 1) = W(k) - H^{-1}g_k \quad (9)$$

onde g_k pode ser expresso conforme a equação (10).

$$g_k = 2J^T(W)e(w) \quad (10)$$

O algoritmo de treinamento de Levenberg-Marquardt faz a atualização dos pesos, se baseando na expressão do método de Newton, realizando as modificações para a determinação da matriz Hessiana, mostrada na equação (11).

$$W(k + 1) = W(k) - [J^T(W)J(W) + \mu_k I]^{-1} J^T(W)e(W) \quad (11)$$

sendo:

I = matriz identidade

μ_k = constante do método de Levenberg-Marquardt

O parâmetro μ_k Tem a função de ajustar a aproximação de forma a utilizar a rápida convergência do método de Newton, evitando passos longos que possam levar a um erro de convergência, funcionando assim como um fator de estabilização (BARBOSA et al, 2005).

3.7.2 TREINAMENTO POR BACKPROPAGATION

O algoritmo de treinamento *Backpropagation* (BP), utiliza em seu método tradicional o método do gradiente descendente para o ajuste dos pesos sinápticos, sendo assim quando mencionado o treinamento *Backpropagation* ou a sigla BP, refere-se ao método do gradiente descendente, que é o método tradicional do algoritmo *Backpropagation*. De fato, no trabalho, além do algoritmo LM, utilizou-se uma adaptação do algoritmo BP conhecida como *Backpropagation* (Gradiente Conjugado Escalonado) ou somente Gradiente Conjugado Escalonado (GCE), o

algoritmo GCE será melhor abordado na seção 3.7.3. No algoritmo de treinamento por BP, os erros observados nas camadas escondidas são resultados dos erros da camada de saída, ou seja, neste algoritmo de treinamento os erros são propagados na direção inversa, por isso o nome retropropagação (*backpropagation*) (LOPES, 2005).

O treinamento da rede neural usando o algoritmo *Backpropagation* possui dois passos: um passo para frente (*forward*) e um passo para trás (*backward*). Na sequência serão apresentados esses passos, *forward* e *backward*, que descrevem a rede neural artificial MLP com o algoritmo de treinamento BP (HAYKIN, 2001; WIDROW; LEHR, 1990).

3.7.2.1 Passo forward

1) Inicialmente um conjunto de entradas X é apresentado, então o sinal resultante é propagado pela rede. A saída linear resultante é dada pela equação (12) (HAYKIN, 2001; WIDROW; LEHR, 1990).

$$s = \sum_{i=1}^m w_i x_i + b \quad (12)$$

onde:

w_i : *i-ésimo* peso sináptico

x_i : *i-ésima* entrada

b : peso corresponde às “bias”

m : número total de entradas.

s : saída linear

Sendo que, a saída não linear de cada neurônio pode ser expressa por meio da equação (13) (HAYKIN, 2001; WIDROW; LEHR, 1990).

$$y_j(n) = \varphi_j(s_j(n)) \quad (13)$$

onde :

$y_j(n)$: saída não linear do j -ésimo neurônio da iteração n ;

φ_j Função não linear.

2) O erro da rede neural na camada de saída da n –ésima iteração é dada através da equação (14).

$$e_j(n) = d_j(n) - y_j(n) \quad (14)$$

onde:

d_j : j -ésima saída desejada;

y_j : j -ésima saída calculada pela rede neural.

3) É feito o cálculo do gradiente local $\delta_j(n)$ referente a última camada através do erro gerado na camada de saída e da derivada do erro através da equação (15) (HAYKIN, 2001; WIDROW E LEHR, 1990).

$$\delta_j(n) = e_j(n)\varphi'_j(s_j(n)) \quad (15)$$

Sendo que, a função φ escolhida deve ser uma função diferenciável.

3.7.2.2 Passo *backward*

4) É calculado o gradiente local $\delta_j(n)$ de cada neurônio das camadas anteriores por meio da equação (16) (HAYKIN, 2001; WIDROW; LEHR, 1990).

$$\delta_j(n) = \varphi'_j(s_j(n)) \sum_k \delta_k(n)w_{kj}(n) \quad (16)$$

onde:

j : índice do neurônio da camada atual;

k : índice do neurônio da camada imediatamente posterior.

5) Ajustar os pesos sinápticos, após o cálculo de cada gradiente local (HAYKIN, 2001; WIDROW; LEHR, 1990).

$$\Delta w_{ji}(n) = \eta \delta_j(n) y_j(n) \quad (17)$$

sendo (η) a taxa de aprendizagem da rede.

A adaptação dos pesos é feita por meio da equação (18) (HAYKIN, 2001; WIDROW; LEHR, 1990).

$$w_{ji}^{k+1}(n) = w_{ji}^k(n) + \Delta w_{ji}(n) \quad (18)$$

É medido o erro instantâneo $\varepsilon(n)$ para cada padrão apresentado à rede (HAYKIN, 2001; WIDROW; LEHR, 1990).

$$\varepsilon(n) = \frac{1}{2} \sum_{j \in C} e_j^2(n) \quad (19)$$

sendo C o conjunto de todos os neurônios da camada de saída.

O algoritmo continua até que todos os padrões sejam apresentados à rede e formem uma época. O algoritmo irá convergir quando o erro médio dos erros instantâneos alcançar uma tolerância pré-estabelecida (HAYKIN, 2001; WIDROW; LEHR, 1990).

$$\varepsilon_{med} = \frac{1}{N} \sum_{n=1}^N \varepsilon(n) \quad (20)$$

onde N representa o número total de padrões apresentados à rede.

3.7.3 - GRADIENTE CONJUGADO ESCALONADO

O algoritmo *Backpropagation* (Gradiente Conjugado Escalonado), ou somente Gradiente Conjugado Escalonado (GCE), é um algoritmo que é uma adaptação de ordem mais elevada do que o do tipo *Backpropagation* com gradiente descendente e foi desenvolvido por Moller (1993). Os algoritmos de ordem mais elevada, utilizam informações mais complexas, com o objetivo de se melhorar o desempenho dos

treinamentos realizados se comparados ao algoritmo BP (gradiente descendente). Diferentemente dos demais métodos de segunda ordem, o GCE não utiliza busca unidimensional para se realizar a determinação da taxa de aprendizagem, sendo assim, o número de avaliações da função custo é reduzido, diminuindo o esforço computacional. As funções custo, são funções que medem o desempenho da rede, no caso deste trabalho a função custo utilizada é apresentada na equação (1). O algoritmo GCE é também uma versão melhorada do algoritmo Gradiente Conjugado (GC), sendo que o algoritmo GC é um algoritmo que é reconhecido por ser aplicável em problemas de larga escala, por isso faz-se uma breve abordagem sobre o algoritmo GC para depois expor as melhorias do algoritmo GCE com relação ao algoritmo GC (ALMEIDA, 2007; ROCHA, 2019).

No treinamento realizado por meio do algoritmo *Backpropagation* em que o ajuste dos pesos é realizado pelo método gradiente descendente, o ajuste dos pesos se dá na direção em que a função custo decresce mais rápido, mesmo assim, a velocidade de convergência neste caso não é rápida. No algoritmo BP, a taxa de aprendizagem η_k é fixa durante todo o treinamento, a taxa de aprendizagem η_k é utilizada para determinar o tamanho dos pesos (ROCHA, 2019). Quando trata-se do algoritmo GC, tem-se um algoritmo de segunda ordem, que é visto como um algoritmo intermediário entre os algoritmos de primeira ordem e o algoritmo de Newton, de modo geral o objetivo do algoritmo GC é de aumentar a velocidade da taxa de convergência geralmente lenta do algoritmo BP e evitar custos com a manipulação da matriz Hessiana como ocorre no método de Newton (ALMEIDA, 2007).

No algoritmo BP, o ajuste dos pesos é realizado na direção onde a função custo irá decrescer mais rapidamente (negativo do gradiente), mesmo assim a velocidade de convergência do algoritmo BP não é rápida. No algoritmo GC a minimização da função custo ocorre ao longo de direções conjugadas, por conta disso, normalmente a convergência no algoritmo GC é mais rápida que no algoritmo BP. Como citado anteriormente no algoritmo BP a taxa de aprendizagem é fixa durante todo o processo, e a taxa de aprendizagem é aplicada aos pesos, que é utilizada para determinar o tamanho do passo do algoritmo, sendo assim, no algoritmo BP o passo é fixo, enquanto que no algoritmo GC o passo é ajustado a

cada iteração. No algoritmo GC, o passo é determinado a cada iteração por meio de um procedimento de busca em linha (ALMEIDA, 2007).

Assim como no algoritmo BP, na primeira iteração o algoritmo GC também realiza as buscas na direção da descida mais íngreme ($P_0 = -g_0$, negativo do gradiente). O passo η é então calculado pelo procedimento de busca em linha. Após o cálculo do passo, os pesos são então atualizados de acordo com a equação (21).

$$w_{k+1} = w_k + \eta_k P_k \quad (21)$$

Na sequência, as próximas direções são calculadas de forma que as direções anteriores sejam conjugadas, sendo assim, a nova direção faz uma combinação do sentido da descida mais íngreme com a direção anterior da busca atual, de acordo com a equação (22).

$$P_k = -g_0 + \beta_k P_{k-1} \quad (22)$$

Na equação (22), g_0 representa o vetor do gradiente local da função custo em relação ao vetor de pesos w . O cálculo de β_k , pode ser realizado de muitas maneiras, e é utilizado para a determinação da busca de P_k , sem necessariamente ter que fazer cálculos da matriz Hessiana, o algoritmo GC é repetido até que o critério de parada desejado seja atendido. No entanto, mesmo o algoritmo GC sendo mais rápido que o algoritmo BP, ele ainda exige o esforço computacional da busca em linha (ROCHA, 2019).

Sendo assim, para contornar o problema da busca em linha, evitando altos custos computacionais, utiliza-se como alternativa o algoritmo GCE, que foi o algoritmo de fato utilizado neste trabalho, além do algoritmo LM. Ao invés de se realizar uma busca em linha, o algoritmo GCE utiliza uma aproximação da matriz hessiana. É necessário, que esta aproximação realizada no algoritmo GCE seja sempre positiva, logo como propõe Moller (1993), é adicionado um termo $\lambda_k P_k$ na expressão que estima a hessiana (ROCHA, 2019). Logo, tem-se então a equação (23).

$$sk = \frac{\xi'(w_k + \eta_k P_k) - \xi'(w_k)}{\eta_k} + \lambda_k P_k \quad (23)$$

O ajuste de λ_k é realizado a cada iteração com base no valor de $\delta_k = P_k^T \xi''(w_k) P_k$, indicando então se a hessiana será positiva ou negativa, se $\delta_k \leq 0$, λ_k aumenta e sk é calculado novamente, no algoritmo GCE existe um parâmetro σ que deve ser definido pelo usuário, e que ajuda a estimar a aproximação da segunda derivada (ALMEIDA, 2007; ROCHA, 2019). Na sequência serão detalhadas as etapas conforme Moller (1993), propôs para o funcionamento do algoritmo GCE.

1. Escolha os vetores de pesos w_1 e também os escalares $\sigma > 0$, $\lambda_1 > 0$, e $\overline{\lambda_1} = 0$;
2. Faça $P_1 = r_1 = -\xi'$, $k = 1$ e sucesso = verdade;
3. Se sucesso = verdade, calcule a informação de segunda ordem

$$\sigma_k = \frac{\sigma}{|P_k|} \quad (24)$$

$$sk = \frac{\xi'(w_k + \sigma_k P_k) - \xi'(w_k)}{\sigma_k} \quad (25)$$

$$\delta_k = P_k^T s_k \quad (26)$$

4. Escalone s_k :

$$s_k = s_k + (\lambda_k - \overline{\lambda_k}) P_k \quad (27)$$

$$\delta_k = \delta_k + (\lambda_k - \overline{\lambda_k}) |P_k|^2 \quad (28)$$

5. Se $\delta_k \leq 0$, faça a matriz hessiana ser definida positiva:

$$sk = sk + (\lambda_k - 2\frac{\delta_k}{|P_k|^2})P_k \quad (29)$$

$$\overline{\lambda_k} = 2(\lambda_k \frac{\delta_k}{|P_k|^2}) \quad (30)$$

$$\delta_k = -\delta_k + \lambda_k |P_k|^2, \lambda_k = \overline{\lambda_k} \quad (31)$$

6. Calcule o passo:

$$\mu_k = P_k^T r_k \quad (32)$$

$$\eta_k = \frac{\mu_k}{\delta_k} \quad (33)$$

7. Para se obter uma melhor aproximação da informação de segunda ordem, é necessário calcular o fator de aproximação Δ_k , que ainda ajuda a estimar mais precisamente o aumento de λ_k :

$$\Delta_k = \frac{2\delta_k [\xi(w_k) - \xi(w_k - \eta_k P_k)]}{\mu_k^2} \quad (34)$$

8. Se $\Delta_k \geq 0$ então, uma redução no erro pode ser feita:

$$w_{k+1} = w_k + \eta_k P_k \quad (35)$$

$$r_{k+1} = -\xi'(w_{k+1}) \quad (36)$$

$$\overline{\lambda_k} = 0, \text{ sucesso} = \text{verdade}. \quad (37)$$

a) se $k \bmod N = 0$ então reinicie o algoritmo:

$$P_{k+1} = r_{k+1} \quad (38)$$

se não, crie uma nova direção conjugada:

$$\beta_k = \frac{|r_{k+1}|^2 - r_{k+1} r_k}{\mu_k} \quad (39)$$

$$P_{k+1} = r_{k+1} + \beta_k P_k \quad (40)$$

b) Se $\Delta_k \geq 0.75$ então, reduza o parâmetro escalonado : $\lambda_k = 0.5\lambda_k$

9. se a redução do erro não for possível: $\lambda_k = \overline{\lambda_k}$, sucesso=falso;

10. se $\Delta_k < 0.25$ então, incremente o parâmetro escalonado : $\lambda_k = 4\lambda_k$;

11. se a direção de descida mais íngreme $r_k \neq 0$ então, defina $k = k + 1$ e volte para o passo (3). Se não, encerre e retorne w_{k+1} como sendo o mínimo desejado.

Mesmo o treinamento do algoritmo GCE possuindo várias etapas de cálculo, como indica o pseudocódigo acima, de modo geral é um algoritmo que apresenta bom desempenho em comparação ao algoritmo BP, com relação ao erro de treinamento, esforço computacional e tempo de processamento (ALMEIDA,2007; ROCHA, 2019).

4 METODOLOGIA E AMBIENTE DE ESTUDO

Neste capítulo será mostrada uma estruturação e embasamento sobre o método adotado e parâmetros utilizados para realização da previsão dos preços de comercialização de energia elétrica.

4.1 ANÁLISE DO AMBIENTE DE ESTUDO

A escolha do ambiente de estudo que proporcionou os dados necessários para a realização deste trabalho, foi feita a partir de um banco de dados aberto proveniente da internet. O site da CCEE fornece todos os dados necessários para a realização deste trabalho.

Na aba “o que fazemos”, na subseção “preços”, disponível no endereço eletrônico da página em questão, é possível encontrar o PLD por sub-região. No endereço eletrônico da página em questão, encontra-se os dados divididos diariamente e apresentados de 0 até 23 horas, dentro de um respectivo dia. Pode-se filtrar o período que se deseja observar, podendo ser 1 dia, ou até anos. Para o banco escolhido, foram coletados dados, partindo do dia 01 de janeiro de 2020 até o dia 30 de junho de 2021. Este foi o período necessário de coleta para se fazer um treinamento adequado da rede, dependendo do número de neurônios e de camadas escondidas, além disso, este período se aproxima um pouco mais dos dias atuais, portanto são dados mais recentes e que já estão dentro de um cenário de pandemia do Covid-19. O banco de dados escolhido contém informações necessárias para a realização do trabalho, como dia, mês, hora e preço de comercialização de energia elétrica.

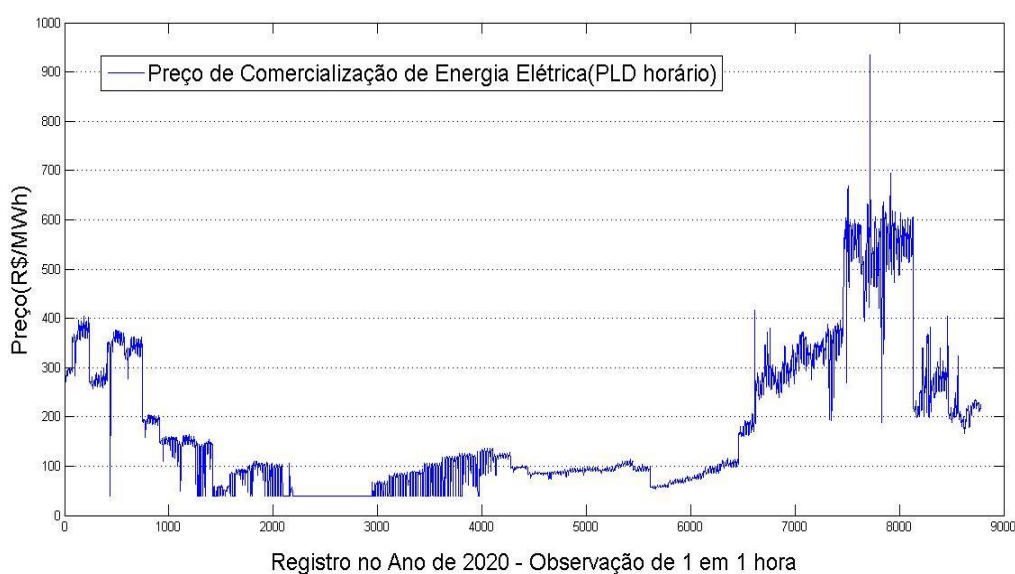
O período de amostras utilizado no trabalho é o mesmo que é fornecido pelo site da CCEE, ou seja, as amostras são fornecidas de 1 em 1 hora, sendo assim, em um dia, existem 24 amostras(0 até 23 horas), no total somando-se os anos de 2020 e 2021, levando-se em consideração que cada dia tem 24 amostras, e que em 2021 utiliza-se apenas 6 meses, o total de amostras para a realização do trabalho foi de 13128 amostras, sendo 8784 para 2020 e 4344 para 2021.

4.2 COMPORTAMENTO DOS PREÇOS

Tratando-se do banco de dados escolhido, pôde-se observar que no período escolhido de 18 meses, os preços de comercialização de energia estavam congruentes o suficiente para se fazer o treinamento da rede, foi possível observar um padrão razoável dentro deste período, que não foi possível observar em períodos menores.


Com objetivo de ilustrar melhor o comportamento dos preços de comercialização de energia elétrica no período referente aos dados utilizados, julgou-se importante a representação gráfica dos mesmos. As figuras a seguir de 14 a 16, representam os gráficos de preço de comercialização de energia elétrica (PLD) para o ano de 2020 e 2021, respectivamente. No eixo das abcissas, a marcação 0 corresponde à primeira amostra, ou início do ano (0 horas de 1 de janeiro de 2020 ou 2021). O eixo das coordenadas corresponde ao PLD para determinado ponto do eixo das abcissas. A Figura 14, ilustra o PLD no ano 2020, a Figura 15 ilustra o PLD em 2021 até o dia 30 de junho, por fim a Figura 16 ilustra o PLD no ano de 2020 e 2021 conjuntamente.

Figura 14 - Comportamento dos preços de comercialização de energia elétrica no ano de 2020



Fonte: Elaboração do próprio autor.

Figura 15 - Comportamento dos preços de comercialização de energia elétrica no ano de 2021



Fonte: Elaboração do próprio autor.

Figura 16 - Comportamento dos preços de comercialização de energia elétrica em 2020 e 2021.



Fonte: Elaboração do próprio autor.

A Figura 14, ilustra o PLD no ano de 2020, da primeira hora de janeiro até a última hora de 31 de dezembro. Os preços são registrados de hora em hora, totalizando-se assim, para o ano de 2020 completo, 8784 amostras, pois 2020 é um ano bissexto, onde o mês de fevereiro tem 29 dias, ao invés de 28.

A Figura 15, ilustra o PLD até 30 de junho do ano de 2021, da primeira hora de janeiro até a última hora de 30 de junho. Os preços são registrados de hora em hora, totalizando assim, para o ano de 2021 até a metade, 4344 amostras.

Por fim, a Figura 16, ilustra o PLD de 2020 e 2021 juntos. Como dito anteriormente, os preços são registrados de 1 hora em 1 hora, totalizando neste caso 13128 amostras. É possível observar que os preços seguem um padrão com bastante variabilidade, possuindo um padrão tanto de acréscimo quanto de decréscimo no tempo, o que dificulta o aprendizado da RNA, pois como os dados possuem um padrão bastante variável, a RNA acaba precisando de uma quantidade maior de dados para aprender, isso é um fator que leva a necessidade do grande número de amostras para a realização deste trabalho. A alta variação nos preços poderia ser explicada por fatores como estação do ano, umidade, tipo de geração de energia, entre outros.

4.3 METODOLOGIA

Esta parte do trabalho tem como objetivo, a demonstração da metodologia, ou seja, qual o procedimento utilizado para se realizar a previsão de preços proposta neste trabalho.

1. Criação dos conjuntos de dados de entrada e saída.

Para estruturar os dados de entrada do trabalho, levou-se em conta: dias da semanas, meses, horário, final de semana ou dia útil, dia do mês, PLD, totalizando assim 6 variáveis de entrada. O preço de comercialização para cada horário, como já explicado anteriormente, foi obtido na página eletrônica da CCEE. O preço (PLD) é dado em R\$/MWh.

Para mostrar como os dados das variáveis de entrada foram organizados, criou-se a Tabela 1.

Tabela 1 - Organização dos dados de entrada da rede.

Dia do Mês	Dias da Semana	Mês	Horário	Dia de trabalho	Preço (R\$/MWh)
1	Domingo	Fevereiro	0	0	100
1	Domingo	Fevereiro	1	0	150
1	Domingo	Fevereiro	2	0	120
.
.
.
31	Segunda-Feira	Dezembro	23	1	200

Fonte: Elaboração do próprio autor.

2- Formato do padrão de entrada e saída da RNA.

O conjunto de dados de entradas da RNA foi composto pelas seguintes variáveis:

- . **Mês:** [1...12] de janeiro a dezembro;
- . **Dia da Semana:** [1...7] de Domingo a Sábado;
- . **Dia do Mês:** [1...31] podendo variar de acordo com o mês;
- . **Horário:** [0...23] de 0 horas até 23 horas;
- . **Dia de trabalho:** [0 ... 1] Codificação Binária para indicar se determinado dia é útil para trabalho, ou não. De Segunda a Sexta recebe o código 1, Sábado e Domingo recebem o código 0. Esta entrada não estava no banco de dados original, e foi acrescentada com o objetivo de se melhorar os resultados obtidos.
- . **Preço de Comercialização de energia elétrica (PLD) na hora h :** Preço de comercialização de energia elétrica (PLD) em (R\$/MWh) na hora h ;

O conjunto de saída da RNA é dado por:

- . **Preço de Comercialização de energia elétrica (PLD) $h+1$:** Preço de comercialização de energia elétrica (PLD) em (R\$/MWh) para a próxima hora $h+1$.

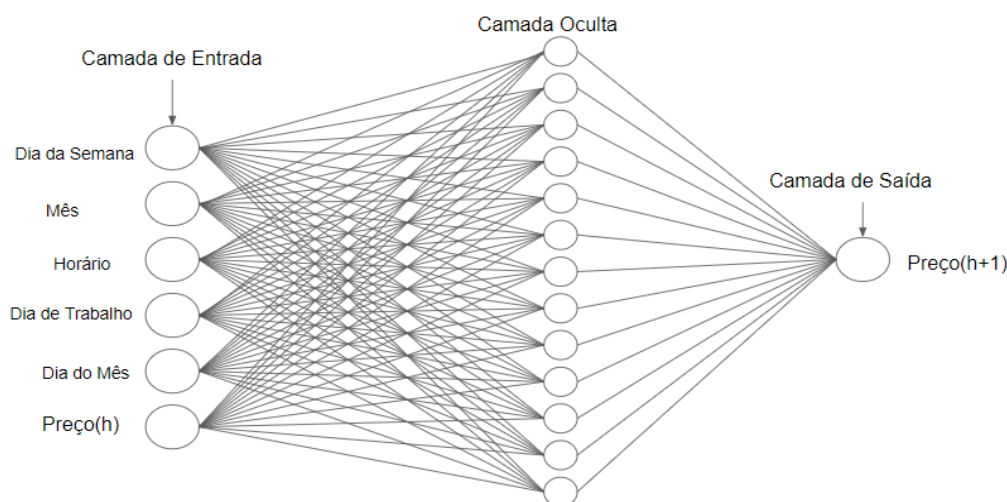
3 - Criação do conjunto de treinamento e teste.

Para realização do trabalho, optou-se por fazer uma divisão do banco de dados na proporção de 70% para treinamento da RNA, e de 30% para teste, seguindo assim um padrão de divisão bastante utilizado na literatura. Sendo assim, o banco de dados que possui 13128 amostras no total, foi dividido em 9192 amostras para treino da rede, e 3936 amostras para testes. Trazendo essa informação para o aspecto de data, então o treinamento começa na data de 01/01/2020 em uma quarta-feira às 0 horas, e termina na data de 17/01/2021, no domingo às 23 horas. As amostras restantes são para testes, que vão do dia 18/01/2021, segunda-feira, até o dia 30/06/2021, quarta-feira. Para a realização da previsão escolheu-se uma semana dentro do período de testes, mais especificamente, a primeira semana de fevereiro de 2021, de segunda-feira até domingo, escolheu-se uma semana inteira com o objetivo de se observar o resultado da previsão em dias úteis e também no fim de semana.

Sendo assim, as matrizes de entrada e saída do treinamento, possuem, respectivamente, as dimensões 6 x 9191 e 1 x 9191. E as matrizes de entrada e saída para teste possuem, respectivamente, as dimensões 6 x 3935 e 1 x 3935. A Figura 17, ilustra a arquitetura da RNA utilizada.

4 Seleção da arquitetura da RNA.

Figura 17 - Arquitetura da RNA proposta



Fonte: Elaboração do próprio autor.

A RNA deste trabalho é composta por 6 neurônios na camada de entrada, 13 neurônios na camada escondida e 1 neurônio na camada de saída, assim como mostra a Figura 17, com função de ativação tipo tangente hiperbólica (*tansig*). A escolha da função de ativação (*tansig*) se deu por esta função apresentar melhor performance no treinamento se comparada a função de ativação *logsig*.

5-Avaliação do desempenho da previsão de preços.

Esta última parte, tem como objetivo mostrar o método de avaliação do desempenho da previsão, esta parte então mede a confiabilidade do trabalho, comparando a saída real com a saída prevista pela RNA. Para avaliar os resultados, como dito anteriormente, utilizou-se o erro percentual absoluto médio *MAPE*, mostrado na equação (1).

5 TESTES E RESULTADOS

Este capítulo abordará os testes, e também os resultados obtidos neste trabalho, para cada um dos algoritmos de treinamento citados anteriormente: Levenberg-Marquardt e *Backpropagation* (Gradiente Conjugado Escalonado).

O programa utilizado neste trabalho, para se fazer o treinamento dos dados, os testes, e a previsão proposta foi o Matlab, com a caixa de ferramentas *nntool* (*toolbox*). Além de ter sido feita a divisão dos dados citada anteriormente que é de 70% para treino e 30% para teste, o software tem um recurso muito interessante, que é a divisão dos dados de maneira aleatória, isso garante que para cada teste obtém-se um resultado diferente, garantindo assim, maior robustez ao trabalho.

Para realização do treinamento da rede, utilizou-se um banco de dados que corresponde ao período de janeiro de 2020 até Junho de 2021, com o objetivo de se fazer a previsão horária de preços de comercialização de energia elétrica para a primeira semana de fevereiro de 2021. Durante o processo de testes para este trabalho, foram realizadas outras tentativas para a escolha do tamanho do banco de dados, como por exemplo, de se utilizar banco de dados menores, correspondente a dois meses de dados, e também com banco de dados maiores, correspondente a três anos de dados, por exemplo. A escolha pelo banco de dados deste trabalho, se deu por este apresentar a melhor performance. O objetivo de se fazer a previsão para a primeira semana de fevereiro de 2021, foi o de mostrar os resultados para uma semana completa, incluindo sábado e domingo, além disso, o mês de fevereiro de 2021 começa exatamente numa segunda-feira, o que foi bastante conveniente para a apresentação dos resultados. Para avaliar o desempenho da RNA, e o quanto a previsão se aproxima dos valores reais de preço de comercialização de energia elétrica (PLD), aplicou-se o *MAPE*, para cada dia previsto, e para os dois tipos de treinamento, GCE e LM. Neste trabalho foi realizado um treinamento supervisionado, requerendo assim, uma quantidade significativa de dados para o processo de aprendizagem.


5.1 RESULTADOS DAS PREVISÕES - LM

Como já citado anteriormente, para a realização da previsão deste trabalho, contou-se com um total de 13128 amostras, sendo 9192 para treinamento da RNA e

3936 para teste. Como citado nos tópicos anteriores, o banco de dados é retirado da página eletrônica da CCEE. No caso deste trabalho, não são excluídos dados, de dias, semanas ou meses que por acaso não se enquadram dentro do padrão estabelecido.

A rede utilizada conta com 6 neurônios na entrada, que representam os dados de entrada(dias da semana, mês, dia do mês, preços, dia de trabalho, horário) 13 neurônios na chamada camada escondida e um neurônio de saída, funções de ativação do tipo sigmóide 1(*tansig*). A esquematização da rede está sendo ilustrada na Figura 18. É importante ressaltar que chegou-se à estrutura final da rede, após alguns testes, fazendo algumas alterações no número de camadas escondidas, e também no número de neurônios das camadas escondidas. Observou-se um melhor desempenho e *MAPE* mais baixo com a função de ativação *tansig* ao invés das funções de ativação *logsig* e *purelin*, o *MAPE* também foi menor utilizando-se somente uma camada escondida com 13 neurônios nela, ao invés de se utilizar camadas escondidas adicionais.

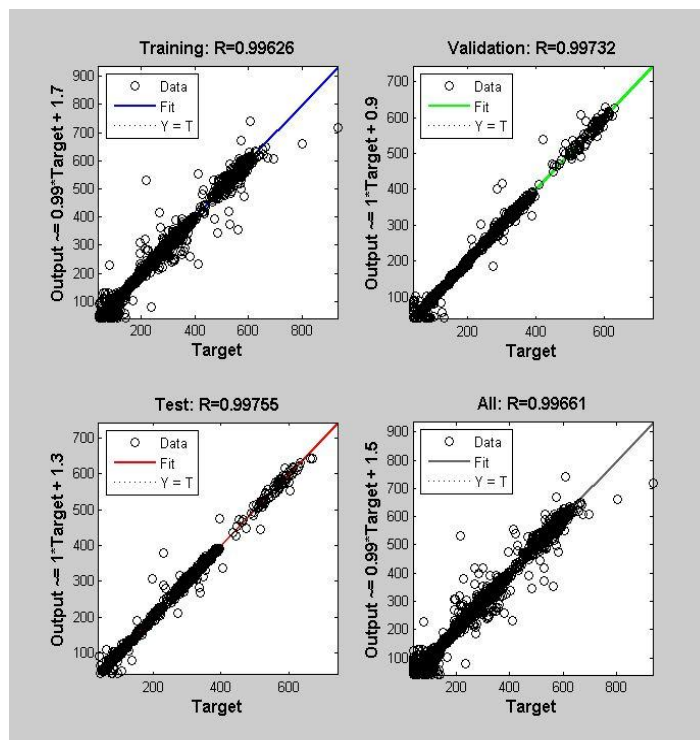
Figura 18 - Esquematização da rede utilizada no processo de treinamento



Fonte: *Toolbox* Matlab.

A regressão R é uma correlação entre a saída resultante do treinamento e a saída real. Um valor próximo a 1, indica uma correlação próxima à realidade, enquanto que um valor para a regressão R, distante de 1, pode indicar um distanciamento da realidade, o treinamento por LM, obteve como resultado para a regressão R, aproximadamente 0,99. A Figura 19 ilustra o resultado da regressão R. O tempo de treinamento para o algoritmo LM foi de 65 segundos e o treinamento parou após 110 iterações.


Figura 19 - Regressão para o treinamento por LM



Fonte: *Toolbox* Matlab.

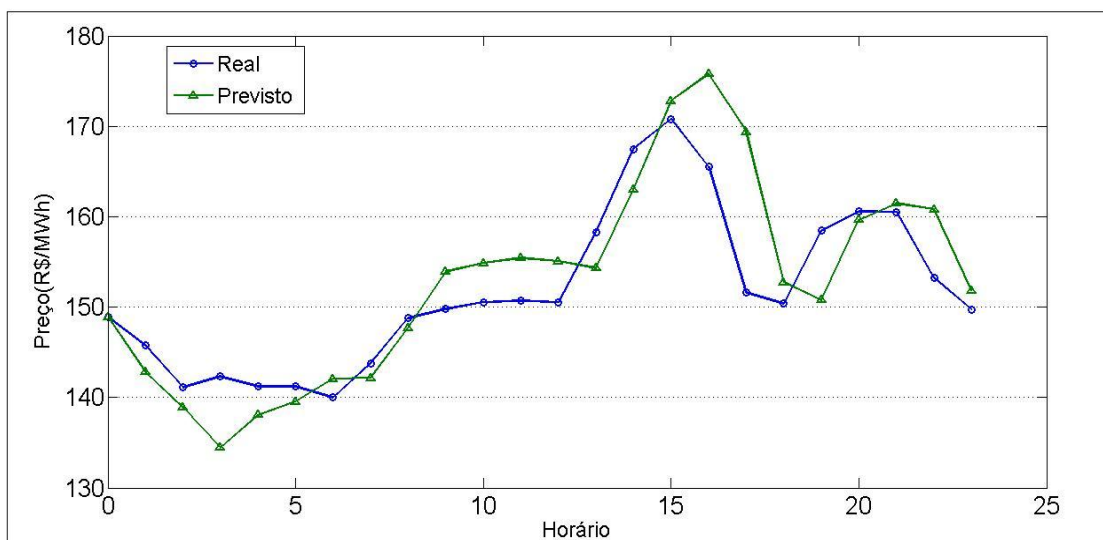
Realizado o treinamento da rede neural esquematizada na Figura 18, prosseguiu-se com a etapa de simulação. As figuras de 20 a 26, ilustram as previsões de preço horária para a primeira semana de fevereiro do ano de 2021.

Figura 20 - Previsão para o dia 01 de Fevereiro, Segunda - Feira (Previsão mediante algoritmo Levenberg-Marquardt)




Fonte: Elaboração do próprio autor.

Figura 21 - Previsão para o dia 02 de Fevereiro, Terça - Feira (Previsão mediante algoritmo Levenberg-Marquardt)




Fonte: Elaboração do próprio autor.

Figura 22 - Previsão para o dia 03 de Fevereiro, Quarta- Feira (Previsão mediante algoritmo Levenberg-Marquardt)




Fonte: Elaboração do próprio autor.

Figura 23 - Previsão para o dia 04 de Fevereiro, Quinta- Feira (Previsão mediante algoritmo Levenberg-Marquardt)




Fonte: Elaboração do próprio autor.

Figura 24 - Previsão para o dia 05 de Fevereiro, Sexta- Feira (Previsão mediante algoritmo Levenberg-Marquardt)



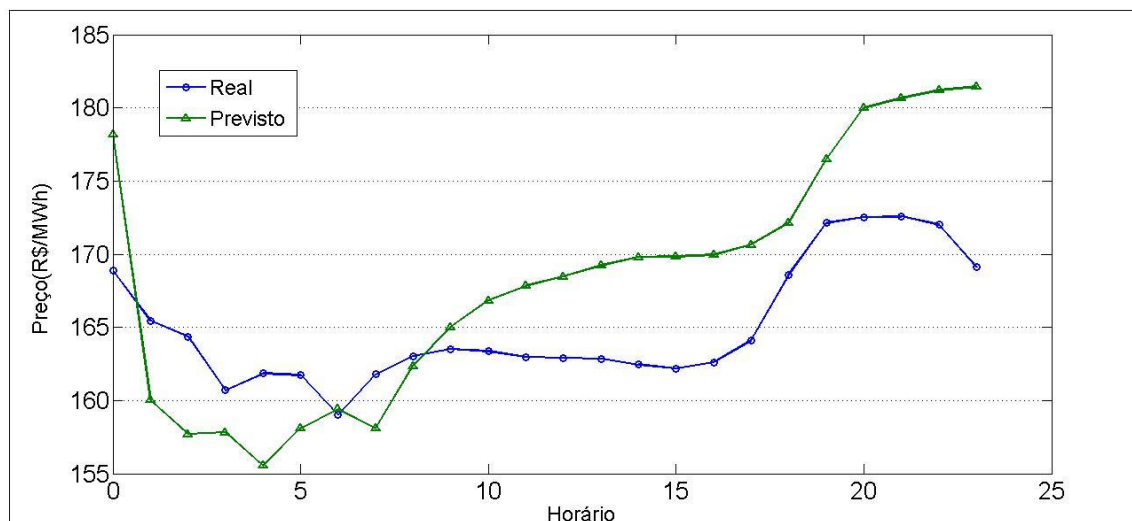
Fonte: Elaboração do próprio autor.

Figura 25 - Previsão para o dia 06 de Fevereiro, Sábado (Previsão mediante algoritmo Levenberg-Marquardt)



Fonte: Elaboração do próprio autor.

Figura 26 - Previsão para o dia 07 de Fevereiro, Domingo (Previsão mediante algoritmo Levenberg-Marquardt)



Fonte: Elaboração do próprio autor.

Utilizando-se a fórmula apresentada na equação (1), foi possível calcular o MAPE e assim verificar o erro percentual absoluto médio para o treinamento feito

pelo algoritmo LM. Como são realizadas sete previsões, construiu-se a Tabela 2, para fazer a apresentação dos resultados.

Tabela 2 - *MAPE* obtido para treinamento realizado pelo algoritmo LM

Dia do Mês	Dias da Semana	Mês	<i>MAPE</i> (%)
1	Segunda-Feira	Fevereiro	2,35
2	Terça-Feira	Fevereiro	2,75
3	Quarta-Feira	Fevereiro	2,68
4	Quinta-Feira	Fevereiro	3,08
5	Sexta-Feira	Fevereiro	1,48
6	Sábado	Fevereiro	3,76
7	Domingo	Fevereiro	3,37
Média	-----	-----	2,75

Fonte: Elaboração do próprio autor.

É possível observar, a partir da Tabela 2, que a média do *MAPE* obtido para todos os dias foi de 2,75%. Outro fator importante a ser observado é que ao analisar-se as figuras começando pela Figura 20 até a Figura 26, observa-se que na maior parte do tempo, os valores previstos de preços usando o algoritmo de Levenberg-Marquardt estão um pouco acima dos valores reais, quando tratamos de previsão no âmbito financeiro, essa característica pode ser interessante, quando se busca o lucro financeiro.

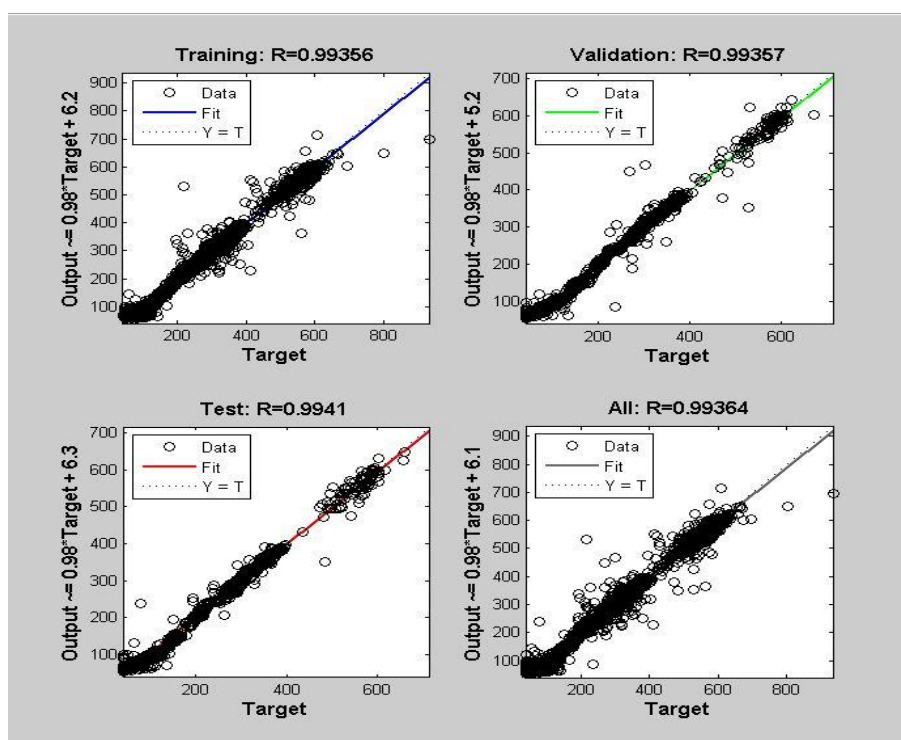
5.2 RESULTADOS DAS PREVISÕES - GCE

Esta parte do trabalho abordará os resultados obtidos para o treinamento realizado utilizando-se o algoritmo GCE. Inicialmente o objetivo foi de se utilizar o método padrão do algoritmo BP: gradiente descendente. No entanto, depois de alguns testes, concluiu-se que para este trabalho, empregando-se o banco de dados descrito nas seções anteriores, o método padrão encontrou muita dificuldade para convergir, treinar e encontrar uma relação aceitável entre entrada e saída, mesmo com uma quantidade de dados grande. Segundo Moller (1993), o algoritmo possui uma taxa de conversão baixa, por esse método ser baseado em uma aproximação

linear do erro em questão, e depender de parâmetros que precisam ser especificados pelos usuários, estes fatores podem explicar o insucesso do uso do gradiente descendente neste trabalho. Sendo assim, buscando contornar o problema que foi obtido com o algoritmo *Backpropagation* do tipo gradiente descendente, e ainda assim cumprir um dos objetivos deste trabalho que é realização do treinamento por *Backpropagation*, utilizou-se o algoritmo de treinamento *Backpropagation* (Gradiente Conjugado Escalonado) descrito na seção 3.7.3. Utilizando-se o algoritmo GCE, foi possível prosseguir com os objetivos do trabalho e realizar assim a previsão de preços proposta.

As condições aplicadas foram iguais às utilizadas no treinamento por LM, utilizou-se uma RNA, com 6 neurônios na entrada, com uma camada escondida com 13 neurônios, e função de ativação do tipo sigmóide 1. Assim como para o treinamento realizado por Levenberg-Marquardt, a regressão R teve um valor de aproximadamente 0,99. A Figura 27 ilustra o resultado para a regressão R do treinamento GCE, o treinamento realizado pelo algoritmo GCE durou 13 segundos e parou após 171 iterações.


Figura 27 - Regressão R treinamento GCE



Fonte: Elaboração do próprio autor.


Observa-se que para o treinamento por *Backpropagation* (Gradiente Conjugado Escalonado), é necessário um número maior de iterações para o algoritmo convergir, isto ocorre ao algoritmo GCE por este fazer uma retropropagação do erro, no entanto o tempo de treinamento foi menor do que para o treinamento por LM. Realizado o treinamento da rede neural esquematizada na Figura 18 prosseguiu-se com a etapa de simulação. Assim como feito para o treinamento realizado mediante o algoritmo Levenberg-Marquardt, para o algoritmo GCE construiu-se as ilustrações que apresentam os valores reais e previstos dos preços de comercialização, e a qualidade da previsão foi observada a partir do *MAPE*. As figuras de 28 a 34 ilustram as previsões de preço horária mediante algoritmo GCE para a primeira semana de fevereiro de 2021.

Figura 28 - Previsão para o dia 01 de Fevereiro, Segunda - Feira (Previsão mediante algoritmo GCE)



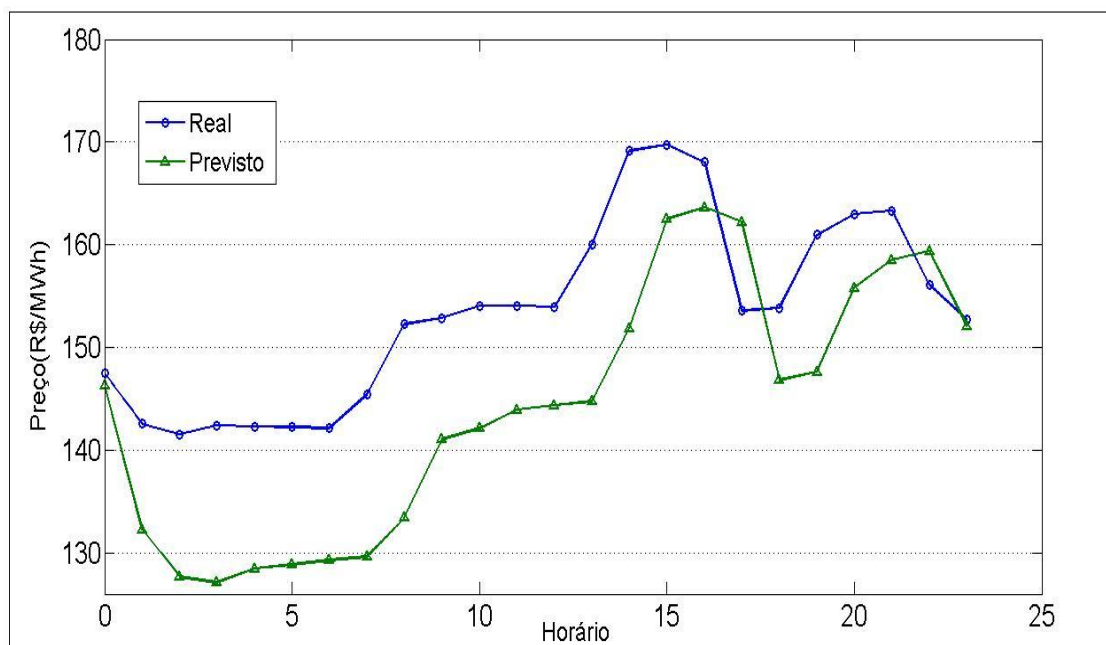
Fonte: Elaboração do próprio autor.

Figura 29 - Previsão para o dia 02 de Fevereiro, Terça - Feira (Previsão mediante algoritmo GCE)




Fonte: Elaboração do próprio autor.

Figura 30 - Previsão para o dia 03 de Fevereiro, Quarta- Feira (Previsão mediante algoritmo GCE)




Fonte: Elaboração do próprio autor.

Figura 31 - Previsão para o dia 04 de Fevereiro, Quinta- Feira (Previsão mediante algoritmo GCE)




Fonte: Elaboração do próprio autor.

Figura 32 - Previsão para o dia 05 de Fevereiro, Sexta - Feira (Previsão mediante algoritmo GCE)




Fonte: Elaboração do próprio autor.

Figura 33 - Previsão para o dia 06 de Fevereiro, Sábado (Previsão mediante algoritmo GCE)



Fonte: Elaboração do próprio autor.

Figura 34 - Previsão para o dia 07 de Fevereiro, Domingo (Previsão mediante algoritmo GCE)



Fonte: Elaboração do próprio autor.

Utilizando-se a fórmula apresentada na equação (1), foi possível calcular o *MAPE* e assim verificar o erro percentual absoluto médio para o treinamento feito pelo algoritmo GCE. Assim como para o algoritmo LM, como são realizadas sete previsões, construiu-se a Tabela 3, para fazer a apresentação dos resultados.

Tabela 3 - *MAPE* obtido para treinamento realizado pelo algoritmo GCE

Dia do Mês	Dias da Semana	Mês	<i>MAPE</i> (%)
1	Segunda-Feira	Fevereiro	6,64
2	Terça-Feira	Fevereiro	6,78
3	Quarta-Feira	Fevereiro	6,79
4	Quinta-Feira	Fevereiro	6,32
5	Sexta-Feira	Fevereiro	5,04
6	Sábado	Fevereiro	4,11
7	Domingo	Fevereiro	11,59
Média	-----	-----	6,64

Fonte: Elaboração do próprio autor.

Ao contrário da previsão realizada por meio do algoritmo de treinamento de Levenberg-Marquardt que obteve um *MAPE* de 2,75%, no treinamento realizado por *Backpropagation* (Gradiente Conjugado Escalonado) o *MAPE* médio obtido foi de 6,64%, o que é consideravelmente mais alto do que o *MAPE* anterior (previsão por Levenberg-Marquardt). Outro fator importante a ser observado é que ao contrário dos resultados obtidos pelo treinamento por LM, se analisarmos as figuras de 28 a 34, iremos concluir que a previsão de preços está quase sempre abaixo dos valores reais, o que não é um bom aspecto do ponto de vista financeiro.

Para a previsão realizada mediante o algoritmo GCE, mesmo quando foram realizados os testes utilizando banco de dados maiores, não foi obtido um *MAPE* muito mais satisfatório do que o apresentado aqui, o mesmo se enquadra quando foram realizados testes para banco de dados menores. Pode-se concluir que o algoritmo de treinamento por *Backpropagation* (Gradiente Conjugado Escalonado), não é o mais adequado para previsão de preços de comercialização de energia elétrica para as condições deste trabalho, sendo assim, dentro do ambiente de

estudo utilizado para este trabalho, pode-se concluir que o treinamento por Levenberg-Marquardt se mostra mais adequado.

6 CONSIDERAÇÕES FINAIS

Este trabalho teve como objetivo geral, apresentar resultados comparativos de previsão de preços de comercialização de energia elétrica utilizando dois algoritmos diferentes no treinamento. Foi utilizada uma classe de rede pertencente à rede MLP (Multilayer Perceptron), adotando-se especificamente a *feedforward backpropagation*.

A média do *MAPE* obtido para a semana avaliada, ficou abaixo dos 10% para os dois algoritmos de treinamento utilizados neste trabalho, no caso do treinamento por Levenberg-Marquardt o *MAPE* ficou abaixo dos 5%. Sendo assim, observa-se uma qualidade razoavelmente melhor da previsão realizada mediante algoritmo de Levenberg-Marquardt. A Tabela 4, apresenta uma comparação dos valores da média do *MAPE* entre os dois algoritmos utilizados neste trabalho.

Tabela 4 - Comparação do *MAPE* médio dos dias para cada algoritmo.

Método de Treinamento	<i>MAPE</i> médio (%)
Levenberg-Marquardt	2,75
GCE	6,64

Fonte: Elaboração do próprio autor.

Como é possível visualizar a partir da Tabela 4, vemos que o treinamento realizado por Levenberg-Marquardt obteve melhores resultados do que o treinamento realizado mediante algoritmo GCE. Outra consideração importante, é que se analisar-se as figuras de 20 a 26, será possível ver que a previsão por Levenberg-Marquardt na maior parte do tempo, apresentou valores acima dos valores reais de preço, o que do ponto de vista financeiro, por se tratar de uma previsão de preços, é uma característica boa, enquanto as figuras de 28 a 34 mostram que as previsões realizadas mediante o algoritmo GCE, de forma geral estão abaixo dos valores reais de preço, o que não é uma característica boa do ponto de vista financeiro.

Sendo assim, com os resultados obtidos neste trabalho, pode-se dizer que uma previsão de preços, utilizando-se redes neurais artificiais mediante algoritmo de

Levenberg-Marquardt, seja mais adequada e confiável, do que a previsão realizada mediante algoritmo GCE. A rede também não conta com entradas externas, como temperatura, umidade, ou outras variáveis que poderiam influenciar negativamente ou positivamente os resultados obtidos. Sendo assim, como proposta para trabalhos futuros, que venham a possuir a mesma linha conceitual, seria interessante a utilização de banco de dados relativamente menores do que o utilizado neste trabalho, e a inserção de mais variáveis de entrada, como temperatura e umidade, por exemplo.

REFERÊNCIAS

ALMEIDA, Leandro Maciel. **Uma metodologia de busca por Redes Neurais Artificiais quase-ótimas**. 2007. 114f. Tese (Mestrado), Centro de Ciências Exatas e da Natureza, Centro de Informática, Universidade Federal de Pernambuco, Recife, 2007.

Associação Brasileira dos Comercializadores de Energia Elétrica (ABRACEEL). **Relatório anual de energia de 2017**. Distrito Federal, 2018.

ALTRAN, A.B. **Sistema inteligente para previsão de carga multinodal em sistemas elétricos de potência**. 2010. 86 f. Tese (Doutorado), Faculdade de Engenharia, Universidade Estadual Paulista "Júlio de Mesquita Filho"– UNESP, Ilha Solteira, 2010.

AMADEU, Jefferson Rampazo. **Desenvolvimento de Modelos para a Previsão de Spread do Preço de Energia Elétrica no Mercado de Curto Prazo**. Monografia (Graduação) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2011.

BARBOSA, A. H.; FREITAS, M. S. R.; NEVES, F. A. **Confiabilidade estrutural utilizando o método de Monte Carlo e redes neurais**. Escola de Minas, Ouro Preto, v. 58, n. 3, p. 247-255, 2005.

BROWN, R. E. Impact of Smart Grid on Distribution System Design. **IEEE Power Engineering Society General Meeting**, Piscataway, p. 1-4, 2008.

CCEE. **Formação de Preço de Liquidação das Diferenças (PLD)**. Desenvolvido por Câmara de Comercialização de Energia Elétrica, Brasília, 2021.

CARVALHO, M.P.R. **Previsão de demanda de um prédio universitário por redes neurais artificiais**. 2017. 62f. Dissertação (Mestrado em Engenharia Elétrica) – Faculdade de Engenharia, Universidade Estadual Paulista "Júlio de Mesquita Filho" – UNESP, Ilha Solteira, 2017.

COELHO, R. **O que é o PLD – Preço de Liquidação das Diferenças?** GRUGEEN, Florianópolis, 2017. Disponível <<http://grugeen.eng.br/o-que-e-opld-preco-de-liquidacao-das-diferencas/>>; acesso em 20 de outubro de 2019.

CUBEROS, Fábio Luiz. **Novo modelo institucional do setor elétrico brasileiro: análise dos mecanismos de mitigação de riscos de mercado das distribuidoras.** Dissertação (Mestrado em Sistemas de Potência) - Escola Politécnica, Universidade de São Paulo, São Paulo, 2008.

Empresa de Pesquisa Energética (EPE). **Anuário estatístico de energia elétrica 2021.** Distrito Federal, 2021.

FERREIRA, Carlos Kawall Leal. **Privatização do setor elétrico no Brasil.** In: PINHEIRO, Armando Castelar; FUKASAKU, Kiichiro (Ed.). A privatização no Brasil: o caso dos serviços de utilidade pública. Rio de Janeiro: Banco Nacional de Desenvolvimento Econômico e Social, 2000. p. 179-220.

HAYKIN, S. **Neural networks: a comprehensive foundation.** Upper Saddle River: Prentice-Hall, 2001.

LOPES, M. L. M. **Desenvolvimento de redes neurais para previsão de cargas elétricas de sistemas de energia elétrica.** 2005. 169 f. Tese (Doutorado) – Faculdade de Engenharia, Universidade Estadual Paulista "Júlio de Mesquita Filho", Ilha Solteira, 2005.

LORENZO, Helena Carvalho. **O setor elétrico brasileiro: passado e futuro.** Perspectivas: Revista de Ciências Sociais, v. 24/25, 2001/2002.

LOTUFO, A. D. P.; MINUSSI, C. R. **Redes neurais - introdução e principais conceitos.** Ilha Solteira: Departamento de engenharia elétrica - Unesp, 2008. Apostila.

MOLLER, M. F. A scaled conjugate gradient algorithm for fast supervised learning. **Neural networks**. Aarhus, Vol. 6, p. 525-533, 1993.

MOREIRA, Rui Felipe Costa. **Previsão Probabilística dos Preços de Energia Elétrica do Mercado Ibérico de Eletricidade**. Tese de Mestrado em Modelação, Análise de Dados e Sistema de Apoio à Decisão. Faculdade de Economia, Universidade do Porto. Porto, 2015.

MÜLLER, M. R. **Análise de desempenho da rede neural artificial artmap fuzzy aplicada para previsão multi-step de cargas elétricas em diferentes níveis de agregação**. 2018. 97 f. Tese (Doutorado) – Faculdade de Engenharia, Universidade Estadual Paulista “Júlio de Mesquita Filho”, Ilha Solteira, 2018.

OLIVEIRA, Evandro Lopes. **Previsão de demanda de energia elétrica com redes neurais artificiais e análise por série de Fourier**. Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica - Universidade Federal de Minas Gerais, 2016.

RANGANATHAN, A. **The Levenberg-Marquardt algorithm**. [S.l: s.n.], 2004. 5p.

ROCHA, Karoline da. **Sistema de apoio à decisão na classificação de imagens histológicas em epitélio oral displásico ou não displásico**. 2019. 114 f. Dissertação (Mestrado). Universidade Federal de Santa Catarina - Centro Tecnológico. Florianópolis, 2019.

ROSENBLATT, F. “The perceptron: A probabilistic model for information storage and organization in the brain,” *Psychological Review*, Vol. 65, 1958.

SAINI, L. M.; SONI, M. K. Artificial neural network based peak load forecasting using Levenberg-Marquardt and quasi-Newton methods. *IEEE Proceedings on Generation, Transmission and Distribution*, New York, v. 149, n. 5, p. 578- 584, 2002.

SANTOS, Nathália Rodrigues. **Redes Neurais para a previsão de preços de energia no mercado livre brasileiro**. Monografia (Graduação). Universidade

Federal de São Paulo - Escola Paulista de Política Econômica e Negócios. Osasco, 2019.

SILVA, T.A.A. **Previsão de cargas elétricas através de um modelo híbrido de regressão com redes neurais**. 2012. 62 f. Dissertação (Mestrado em Engenharia Elétrica) – Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2012.

SOZZI, G. **Formação do preço da energia convencional nas transações entre agentes no mercado de curto prazo brasileiro**. Dissertação (Mestrado) – Escola Politécnica da Universidade de São Paulo. São Paulo, 2015.