

**UNIVERSIDADE FEDERAL DE SANTA MARIA
CAMPUS CACHOEIRA DO SUL
CURSO DE ENGENHARIA ELÉTRICA**

Priscila Bernardeli Miranda

**ANÁLISE DO EFEITO DA TEMPERATURA NA PREVISÃO
DE CURTO PRAZO DA DEMANDA DE ENERGIA
ELÉTRICA ATRAVÉS DE REDES NEURAIS**

**Cachoeira do Sul, RS, Brasil
2021**

Priscila Bernardeli Miranda

**ANÁLISE DO EFEITO DA TEMPERATURA NA PREVISÃO DE CURTO
PRAZO DA DEMANDA DE ENERGIA ELÉTRICA ATRAVÉS DE
REDES NEURAIS**

Trabalho de Conclusão de Curso Apresentado ao Curso de Graduação em Engenharia Elétrica, da Universidade Federal de Santa Maria (UFSM) - Campus Cachoeira do Sul, como requisito parcial para obtenção do grau de **Bacharel em Engenharia Elétrica**.

Orientadora: Prof. Dra. Laura Lisiane Callai Dos Santos

Cachoeira do Sul, RS, Brasil
2021

Ficha catalográfica elaborada através do Programa de Geração Automática da Biblioteca Central da UFSM, com os dados fornecidos pelo(a) autor(a).

Miranda, Priscila Bernardeli

Análise do Efeito da Temperatura na Previsão de Curto Prazo da Demanda de Energia Elétrica Através de Redes Neurais / Priscila Bernardeli Miranda - 2021

101 p.; 30 cm

Orientador: Laura Lisiane Callai Dos Santos

TCC (graduado) – Universidade Federal de Santa Maria - Campus Cachoeira do Sul, Curso de Engenharia Elétrica, RS, 2021

1. Engenharia Elétrica 2. Previsão de Demanda 3. Redes Neurais Artificiais.

© 2021

Todos os direitos autorais reservados a Priscila Bernardeli Miranda. A reprodução de partes ou do todo deste trabalho só poderá ser feita com autorização por escrito do autor.

Endereço: Rod. Taufik Germano, Nº 3013, Bairro Passo D'Área, Cachoeira do Sul, RS, Brasil, CEP: 96503-205;

Fone: (51) 991993375;

Endereço Eletrônico: priscilaji-pa@hotmail.com.

Priscila Bernardeli Miranda

**ANÁLISE DO EFEITO DA TEMPERATURA NA PREVISÃO DE CURTO
PRAZO DA DEMANDA DE ENERGIA ELÉTRICA ATRAVÉS DE
REDES NEURAIS**

Trabalho de Conclusão de Curso Apresentado ao Curso de Graduação em Engenharia Elétrica, da Universidade Federal de Santa Maria (UFSM) - Campus Cachoeira do Sul, como requisito parcial para obtenção do grau de **Bacharel em Engenharia Elétrica.**

Aprovado em 23 de Fevereiro de 2021:

Laura Lisiane Callai Dos Santos, Dra. (UFSM)
(Presidente/ Orientadora)

Dion Lenon Prediger Feil, Dr. (UFSM)

Maicon Jaderson Silveira Ramos, Dr. (UFRGS)

Cachoeira do Sul, RS, Brasil
2021

NUP: 23081.015611/2021-38

Prioridade: Normal

Homologação de Ata

010 - Organização e Funcionamento

COMPONENTE

Ordem	Descrição	Nome do arquivo
1	Ata de defesa de trabalho de conclusão de curso (TCC) (125.322)	Folha de aprovação_Priscila.pdf

Assinaturas

23/02/2021 20:33:43

LAURA LISIANE CALLAI DOS SANTOS (PROFESSOR DO MAGISTÉRIO SUPERIOR)

31.04.00.00.0.0 - COORDENAÇÃO ACADÊMICA - UFSM-CS - C_ACA_CampusCS

23/02/2021 20:41:34

DION LENON PREDIGER FEIL (PROFESSOR DO MAGISTÉRIO SUPERIOR)

31.04.00.00.0.0 - COORDENAÇÃO ACADÊMICA - UFSM-CS - C_ACA_CampusCS

24/02/2021 11:44:24

MAICON JADERSON SILVEIRA RAMOS (Pessoa Física)

Usuário Externo (001.***.***.**))



Código Verificador: 542671

Código CRC: f441c525

Consulte em: <https://portal.ufsm.br/documentos/publico/autenticacao/assinaturas.html>



DEDICATÓRIA

A toda minha família.

AGRADECIMENTOS

Agradeço primeiramente aos meus pais, Lindalva Pinheiro Bernardeli e Wilson Miranda da Silva e minha irmã Kamilla Bernardeli Miranda por acreditarem no meu potencial e me incentivarem e apoiarem de maneira incondicional em todas as fases da minha formação como profissional e como ser humano.

A Jéssica Costa Alvim a melhor amiga e parceira que tive nesse período de graduação, tendo paciência e me incentivado em toda essa jornada.

A todos os familiares e amigos que mesmo distantes se fizeram presentes.

A minha orientadora, Laura Lisiane Callai dos Santos, pela colaboração e paciência em todos os momentos da elaboração deste trabalho.

Aos professores do Departamento de Engenharia Elétrica da Universidade Federal de Santa Maria Campus Cachoeira do Sul por sempre tentarem, em cada disciplina ministrada, extrair de nós alunos o melhor.

A todos os meus amigos do curso de graduação, em especial ao Pedro Henrique Elesbão por estar comigo em vários momentos do nosso crescimento profissional.

“We are the change that we seek.
Barack Obama”

RESUMO

ANÁLISE DO EFEITO DA TEMPERATURA NA PREVISÃO DE CURTO PRAZO DA DEMANDA DE ENERGIA ELÉTRICA ATRAVÉS DE REDES NEURAIS

AUTOR: PRISCILA BERNARDELI MIRANDA
ORIENTADORA: LAURA LISIANE CALLAI DOS SANTOS

A previsão de demanda de energia elétrica é uma atividade de grande importância e de caráter decisivo para a operação dos sistemas elétricos de potência. No horizonte de curto prazo, as previsões de consumo de energia ocorrem a partir de minutos, horas e até uma semana a frente e são analisados fatores climáticos que podem influenciar a demanda, com isso obter o melhor perfil instantâneo da carga. Diversas técnicas são aplicadas para previsão de carga, dentre estas, têm-se as redes neurais artificiais, que são sistemas de inteligência computacional não lineares que operam como as redes neurais do cérebro humano e reproduzem características humanas, como generalização, associação, aprendizado e abstração de informações. Na arquitetura *feedforward*, a rede perceptron de multicamadas com o algoritmo de treinamento *Backpropagation*, possui aplicabilidade na previsão de séries temporais e reconhecimento de padrões. Neste contexto, este trabalho propõe a utilização de redes neurais artificiais (RNA), para realizar a previsão de demanda no curto prazo empregando dados reais de consumo(kWh), demanda(kW) e temperatura(C), que demonstram as características da curva de demanda. Para tanto, elaborou-se testes de previsão utilizando redes perceptron de múltiplas camadas, aplicando o algoritmo de treinamento *scaled conjugate gradient backpropagation* (SCGB). A RNA é desenvolvida no software MATLAB[®], com a ferramenta *Neural Network Toolbox* (nntool) aplicada para criar, treinar e apresentar dados para análise de 24 horas á frente. Para o sistema de previsão testado, os resultados demonstraram a eficiência da RNA criada, e curvas de previsão adequadas com valores de erros MSE e MAPE satisfatórios.

Palavras-chave: Previsão de demanda; Sistema de energia; Rede neural artificial; Curto prazo.

ABSTRACT

ARTIFICIAL NEURAL NETWORKS FOR EVALUATING THE EFFECT OF TEMPERATURE ON SHORT-TERM ELECTRICITY DEMAND FORECASTING

AUTHOR: PRISCILA BERNARDELI MIRANDA
ADVISOR: LAURA LISIANE CALLAI DOS SANTOS

Demand forecasting is a crucial and decisive activity for the operation of electrical power systems, thus estimating the adequate load to be supplied. In the short-term horizon, energy consumption forecasts occur from minutes, hours and even a week ahead and climatic factors that can influence demand are analyzed, thereby obtaining the best instant load profile. Several techniques are applied for load prediction, among, there are artificial neural networks, which are non-linear computational intelligence systems that operate like neural networks human brain and reproduce human characteristics, such generalization, association, learning and abstraction information. The feedforward architecture is characterized as the most appropriate model for modeling a system, among the main types of networks with this architecture is the multilayer perceptron with Back-propagation training algorithm, which has applicability in the prediction of time series and standards recognition. In this context, this work proposes a methodology to carry out demand forecast in the short-term using real energy, demand and temperature data, which demonstrate the characteristics of the demand curve profiles. Therefore, a model with artificial multilayer perceptron neural networks is being using the scaled conjugate gradient backpropagation (SCGB) training algorithm. The network is developed using MATLAB[®] software, with Neural Network Toolbox tool (nntool) applied to create, train and present data for analysis 24 hours ahead. For the forecast system tested, the results showed the efficiency of the created ANN, and adequate forecast curves with satisfactory MSE and MAPE error values.

Keywords: Demand forecasting, Power system, Artificial neural network, Short-term.

LISTA DE FIGURAS

Figura 2.1	– Consumo por classes.....	19
Figura 2.2	– Consumo de energia elétrica por equipamento.....	20
Figura 2.3	– Regressão linear entre a temperatura e demanda média de energia elétrica (dados coletados em janeiro de 2019).	24
Figura 2.4	– Regressão linear entre a temperatura e demanda média energia elétrica(dados coletados em julho de 2019).	25
Figura 3.1	– Representação Neurônio Artificial.....	31
Figura 3.2	– Gráfico da função Logística.....	33
Figura 3.3	– Gráfico da função Hiperbólica.....	34
Figura 3.4	– Gráfico da função Gaussiana.....	35
Figura 3.5	– Gráfico da função Linear.....	35
Figura 3.6	– Rede <i>feedforward</i> com uma única camada de neurônios.....	37
Figura 3.7	– Rede <i>feedforward</i> com uma camada oculta e uma camada de saída.....	38
Figura 3.8	– Rede recorrente sem neurônios ocultos.	39
Figura 3.9	– Rede <i>Perceptron</i> de Múltiplas Camadas.....	40
Figura 4.1	– Metodologia de previsão de Carga pela RNA.....	46
Figura 4.2	– Janela de comandos NNtool.	48
Figura 4.3	– Configuração da Rede Neural Artificial.	49
Figura 4.4	– Diagrama da Rede.	49
Figura 5.1	– Janela de Treinamento do estudo.	56
Figura 5.2	– Janela de performance do estudo.....	57
Figura 5.3	– Janela de regressão do estudo.	58
Figura 5.4	– (a) Dados de Fevereiro ; (b) Dados de Agosto.....	60
Figura 5.5	– Projeção de Curva de carga 02/02/2019.....	60
Figura 5.6	– Projeção de Curva de carga 02/08/2019.....	61
Figura 5.7	– Projeção de Curva de carga 28/12/2019.....	62
Figura 5.8	– Projeção de Curva de carga 07/07/2019.....	63
Figura A.1	– Inicialização dos dados de treinamento da RNA.....	74
Figura A.2	– Inicialização dos dados de teste da RNA.....	75
Figura A.3	– Criação da RNA no <i>Scip</i>	75
Figura A.4	– Comando de treinamento da RNA.....	76
Figura A.5	– Janela de Treinamento do exemplo didático.....	76
Figura A.6	– Validação da RNA treinada.....	77
Figura A.7	– Resultado de Regressão da RNA.....	78
Figura A.8	– Utilização da RNA treinada.....	79
Figura A.9	– Resultado do processamento da RNA.....	79

LISTA DE TABELAS

Tabela 5.1 – Parâmetros da RNA no mês de Janeiro	55
Tabela 5.2 – Parâmetros da RNA no mês de Julho	55
Tabela 5.3 – Análise dos indicadores de erros das projeções realizadas.	64

LISTA DE ABREVIATURAS E SIGLAS

ANEEL	Agência Nacional de Energia Elétrica
APE	<i>Absolute Percentage Error</i>
AR5	Quinto Relatório de Avaliação
ARIMA	Modelo Auto-Regressivo Integrado de Médias Móveis
BEN	Balanco Energético Nacional
CCEE	Câmara de Comercialização de Energia Elétrica
EPE	Empresa de Pesquisa Energética
IA	Inteligência Artificial
IPCC	Painel Intergovernamental de Mudanças Climáticas
LF	Lógica Fuzzy
kW	kilowatt
MAPE	<i>Mean Absolute Percentage Error</i>
MLP	<i>Multi Layer Perceptrons</i>
MSE	<i>Mean Square Error</i>
ONS	Operador Nacional do Sistema
PBMC	Painel Brasileiro de Mudanças Climáticas
PMC	Perceptron de Múltiplas Camadas
PDEC	Plano de Desenvolvimento Econômico
PIB	Produto Interno Bruto
PMO	Programa Mensal de Operação
RNA	Rede Neural Artificial
RNAs	Redes Neurais Artificiais
SCGB	<i>Scaled Conjugate Gradient Backpropagation</i>
SEP	Sistema Elétrico de Potência

LISTA DE SÍMBOLOS

a_j	Valor real
β	Constante real
c	Parâmetro de definição do centro da função gaussiana
C°	Temperatura em graus célsius
D	Demanda
D_r	Demanda real
D_o	Demanda Original
e	Função exponencial
Σ	Combinador linear
$g(u)$	Função de ativação
u	Potencial de ativação
σ	Desvio padrão
θ	Limiar de ativação
N	Numero de amostras
x_n	Sinais de entrada
w_n	Pesos sinápticos
y	Sinal de saída
Y_k	valor produzido pelo neurônio de saída

SUMÁRIO

1 INTRODUÇÃO	15
1.1 CONTEXTUALIZAÇÃO	15
1.2 MOTIVAÇÃO E JUSTIFICATIVA	16
1.3 OBJETIVO	17
1.3.1 Objetivo Geral	17
1.3.2 Objetivos Específicos	17
1.4 ORGANIZAÇÃO DOS CAPÍTULOS	18
2 REVISÃO BIBLIOGRÁFICA	19
2.1 CONSUMO DE ENERGIA ELÉTRICA NO BRASIL	19
2.2 PREVISÃO DE DEMANDA DE ENERGIA ELÉTRICA	21
2.3 EFEITO DE TEMPERATURA NO CONSUMO DE ENERGIA ELÉTRICA	23
2.4 TRABALHOS UTILIZANDO REDES NEURAIS	26
2.5 CONSIDERAÇÕES FINAIS DO CAPÍTULO	28
3 REDES NEURAIS ARTIFICIAIS	29
3.1 INTRODUÇÃO	29
3.2 TOPOLOGIA DE REDES NEURAIS ARTIFICIAIS	30
3.3 FUNÇÕES DE ATIVAÇÃO	32
3.3.1 Função Logística	32
3.3.2 Função Tangente Hiperbólica	33
3.3.3 Função Gaussiana	34
3.3.4 Função Linear	35
3.4 ARQUITETURAS DAS RNA	36
3.4.1 Redes <i>Perceptron</i> de múltiplas camadas	39
3.5 APRENDIZADO DAS REDES NEURAIS	41
3.5.1 Algoritmo de retropropagação	42
3.5.1.1 Erros de previsão	43
3.6 CONSIDERAÇÕES FINAIS DO CAPÍTULO	44
4 METODOLOGIA UTILIZADA	46
4.1 CRIAÇÃO DA RNA	47
4.2 TREINAMENTO DA RNA	50
4.3 VALIDAÇÃO DOS DADOS	51
4.4 TESTE DA REDE	52
4.5 CONSIDERAÇÕES FINAIS DO CAPÍTULO	52
5 ESTUDO DE CASO	54
5.1 REDE NEURAL DO ESTUDO DE CASO	54

5.2 PROJEÇÃO DA CURVA DE CARGA	59
5.3 CONSIDERAÇÕES FINAIS DO CAPÍTULO	64
6 CONCLUSÃO	65
6.1 CONSIDERAÇÕES FINAIS	65
6.2 TRABALHOS FUTUROS	66
REFERÊNCIAS	67
APÊNDICES	73
A.1 EXEMPLO DIDÁTICO	74

1 INTRODUÇÃO

1.1 CONTEXTUALIZAÇÃO

Conhecer o comportamento futuro da demanda de energia elétrica é essencial para tomar decisões no Sistema Elétrico de Potência (SEP), o que torna a previsão de carga uma atividade de fundamental importância, inserida na operação e no planejamento do SEP. As análises mais comuns, que dependem da previsão de cargas, são: despacho econômico, fluxo de potência e análise da estabilidade, planejamento da expansão, compra e venda de energia. As pesquisas a cerca da previsão de carga são essenciais para fornecer a energia elétrica aos consumidores de forma segura, confiável e econômica (ALTRAN, 2010).

O aumento da demanda, juntamente com fatores ambientais e técnicos, interfere na qualidade e confiabilidade da energia fornecida. Para resolução desse problema, são considerados condições e cenários futuros de operação. Para atender as exigências operacionais, técnicas e ambientais, as concessionárias de energia elétrica enfrentam diferentes desafios, como as necessidades e preferências dos consumidores, as regras impostas pelas agências reguladoras e o planejamento de suas operações (CCEE, 2018).

O planejamento de operação do sistema elétrico apresenta diversos desafios, isso se deve à evolução dos sistemas de energia elétrica. Para a solução desse problema, são encontradas na literatura diferentes modelos e técnicas, sendo que essas abordagens podem sofrer modificações em relação ao horizonte de planejamento, que podem ser de curtíssimo, curto, médio ou de longo prazo. O planejamento de curto prazo tem impacto expressivo na operação econômica da concessionária, pois, as decisões de despacho de carga são baseadas nestas previsões, tais como, operação econômica da concessionária (MILKEL, 2019).

Segundo Dominguez (2018), o planejamento de operações a curto prazo tem como objetivo garantir o melhor funcionamento dos sistemas de energia elétrica, fornecendo assim, a qualidade, confiabilidade e continuidade da energia entregue, considerando cenários futuros de operação e grandezas climáticas que possuem relevância no horizonte de análise. A programação visa assegurar o desempenho adequado de um sistema de energia elétrica e fornecer um produto de alta qualidade aos usuários finais.

Estudos relacionados ao planejamento de curto prazo demonstram que a temperatura é a variável climática que tem maior influência na previsão de demanda (Genyong; Jingtian, 2009; Moreira, 2015; Wilke, 2019). O efeito dessa variável, sobre a demanda de energia elétrica, pode ocorrer ao longo do dia, e em diferentes estações do ano. Métodos de verificação da interferência da temperatura na demanda da energia elétrica para a previsão da carga, são cada vez mais divulgados.

Os métodos estatísticos (regressão linear múltipla, suavização exponencial, séries temporais estocásticas) e os métodos de inteligência artificial (redes neurais artificiais, lógica difusa, algoritmos genéticos e sistemas especialistas baseados no conhecimento) são os que mais avaliam a interferência da temperatura na previsão de carga (CHEMETOVA, 2018). Os métodos de inteligência artificial, quando comparados com os métodos estatísticos, apresentam algumas vantagens, como maior capacidade em captar a não linearidade entre as variáveis.

Para utilizar métodos como inteligência artificial, dados históricos são variáveis ideais para serem usadas como entrada. Existe uma relação entre a temperatura e o consumo de energia, analisar essas duas variáveis, com ferramentas computacionais sofisticadas, pode se tornar uma técnica eficaz para efetuar as previsões, pois os métodos estatísticos têm a matemática bem desenvolvida, mas possuem dificuldade em lidar com variações climáticas (MEDEIROS, 2016).

Variações na temperatura podem afetar diretamente o consumo de eletricidade quando existe a necessidade de adaptar as temperaturas internas sempre que alteram-se as temperaturas externas. Espera-se que a medida que a temperatura ambiente aumente, o consumo de demanda também aumente, dado que a relação da temperatura com o consumo não é totalmente linear, mas pode ser identificada.

O aumento no consumo não ocorre de forma imediata, pois observa-se uma inércia do sistema a partir das variações na temperatura, ou seja, a medida que altas temperaturas se repetem, o consumo de demanda aumenta com determinado atraso. Sendo identificado como fator externo de maior influência sobre a carga, é preciso analisar o efeito da temperatura ambiente em um sistema de previsão de curvas de carga.

1.2 MOTIVAÇÃO E JUSTIFICATIVA

As variáveis climáticas, econômicas, técnicas e ambientais podem interferir diretamente no consumo de energia elétrica. Nesse contexto, temperatura é o fator climático que mais influencia, assim as projeções de carga devem levar em conta essa variável e seu comportamento em um horizonte de previsão. A temperatura exerce um papel de destaque no sistema elétrico de potência, podendo até alterar o plano de operação já programado, sendo o parâmetro mais importante para a previsão de demanda no curto prazo (MACHADO, 2015).

Inúmeros trabalhos afirmam que a temperatura destaca-se por ser a componente climática mais importante ao prever a demanda de energia no horizonte de curto prazo para o sistema elétrico. As ferramentas para realizar essas previsões se tornam cada vez mais fundamentais, pois, através delas será possível facilitar aferição da carga.

A previsão de carga no horizonte de curto prazo é uma ferramenta muito relevante

para operação do mercado de energia elétrica, por isso, definir um intervalo de tempo da previsão é essencial para obter as melhores decisões. As previsões de curto prazo, que podem ser de alguns minutos, horas ou dias à frente auxiliam, na programação sobre o montante de energia a ser gerado nesse período de tempo para atender, de forma eficiente, os consumidores (AMORIM, 2019).

Dentre os métodos de previsão de carga, a rede neural artificial (RNA) é a ferramenta que mais se destaca quando comparadas a outros métodos de previsão de carga e isso faz com que seja a mais utilizada recentemente. Os trabalhos que aplicam RNAs como técnica para a previsão de demanda no curto prazo demonstram resultados notáveis, em que apresentam performances tão boas ou melhores que as demais técnicas disponíveis

As RNAs têm tido sucesso com a previsão de cargas (KHOTANZAD et al., 1998, FRIZZO, 2019). Devido à habilidade para construção de relacionamentos não lineares entre suas entradas e saídas, através do aprendizado elas não necessitam da identificação de um relacionamento funcional explícito entre cargas passadas, condições climáticas e a carga a ser prevista (BAKIRTZIS, PETRIDIS, et al., 1995). A capacidade de aprender com relação viável entre as entradas do sistema, que são as cargas passadas e condições climáticas, e suas saídas como cargas futuras faz com que as RNAs seja um método adequado para a previsão de carga.

A metodologia para a previsão de demanda de energia elétrica com influência da temperatura a curto prazo proposta neste trabalho, se baseia na utilização de RNAs para intensificar e aperfeiçoar as projeções de carga, com o objetivo de tornar o resultado das previsões mais adequado e eficaz.

1.3 OBJETIVO

1.3.1 Objetivo Geral

O presente trabalho tem como objetivo realizar a previsão de demanda no horizonte de curto prazo para avaliar a influência na mudança de temperatura utilizando RNA.

1.3.2 Objetivos Específicos

Para se alcançar o objetivo geral serão buscados os seguintes objetivos específicos:

- Estudar os modelos de previsão de carga de curto prazo relacionado a variáveis climáticas recentemente publicados.
- Analisar as variações da demanda em relação a temperatura em um determinado

período.

- Levantar dados de demanda de energia elétrica e da temperatura como a principal variável climáticas nesse estudo.
- Elaborar etapas e implementa-las através de uma ferramenta computacional o teste de previsão de carga no curto prazo utilizando RNAs.
- Avaliar os resultados obtidos através da comparação da demanda de energia projetada com a demanda real no período de análise.

1.4 ORGANIZAÇÃO DOS CAPÍTULOS

O trabalho está estruturado em 6 capítulos incluindo este introdutório.

O capítulo 2 apresenta a revisão bibliográfica da literatura nacional e internacional, os principais conceitos, ferramentas e técnicas que auxiliam no desenvolvimento desse trabalho, enfatizando a influência da temperatura na demanda de energia, previsão de carga com o emprego de RNAs e demais modelos de previsão usados e publicados nos últimos anos no horizonte de curto prazo.

No capítulo 3 é apresentado o conceito das RNAs e as suas características, especificando os modelos e arquiteturas de redes existentes, funções de ativação utilizadas, ainda demonstrando as principais equações matemáticas aplicadas para soluções mais eficientes.

O capítulo 4 apresenta a descrição da metodologia utilizada para realizar a previsão de carga no curto prazo, utilizando as redes neurais. A metodologia de desenvolvimento da rede é testada em um exemplo didático para um análise mais correta de seu funcionamento aplicada ao software MATLAB[®], detalhando os procedimentos adotados para realizar a criação, treinamento e a projeção da RNA.

No capítulo 5 é apresentado o estudo de caso. Durante todo o desenvolvimento deste trabalho, ferramentas, métodos, parâmetros e etapas foram mostradas, para serem utilizadas de forma clara aplicadas ao estudo de caso.

No capítulo 6 são apresentadas as considerações finais sobre o desenvolvimento do trabalho e os resultados alcançados a partir do estudo de caso apresentado e os trabalhos que poderão ser desenvolvidos futuramente.

2 REVISÃO BIBLIOGRÁFICA

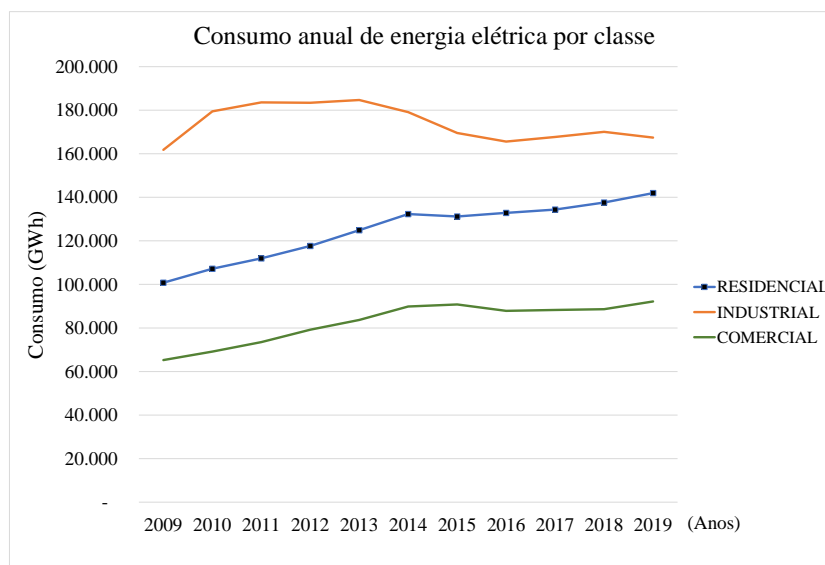
O capítulo apresenta a revisão bibliográfica da literatura nacional e internacional, referentes ao consumo de energia elétrica enfatizando a influência da temperatura na demanda de energia, previsão de carga com o emprego de RNAs e demais modelos de previsão usados e publicados nos últimos anos no horizonte de curto prazo.

2.1 CONSUMO DE ENERGIA ELÉTRICA NO BRASIL

O consumo de eletricidade no Brasil, em 2018, foi de 535,4 TWh. Nos setores residencial, industrial e comercial, esse consumo foi cerca de 25,4%, 37,5% e 16,9%, respectivamente do total no país, onde ocorreu a evolução de 1,4% do ano anterior (EPE, 2019). De acordo com a Agência Nacional de Energia Elétrica (ANEEL, 2008), o desenvolvimento econômico e a qualidade de vida de uma sociedade esta diretamente ligado a evolução no consumo de energia elétrica.

A energia elétrica é essencial para garantir o bem estar e conforto da sociedade, sendo fundamental no setor industrial, comercial e residencial. A Figura 2.1 mostra que a evolução do consumo de energia foi mais expressiva no setor residencial em um período de análise de dez anos, entre 2009 e 2019 no Brasil (EPE, 2019).

Figura 2.1 – Consumo por classes




Fonte: Adaptado de (EPE, 2019).

O consumo de energia elétrica representa tanto o progresso dos setores industrial, comercial e de serviços, quanto a capacidade da população para adquirir bens e serviços mais tecnológicos, como automóveis, eletrodomésticos e eletroeletrônicos que exigem acesso à rede elétrica e pressionam o consumo de energia elétrica.

De acordo com o último relatório de planejamento PDE (2020), a evolução do consumo residencial de energia está associada ao crescimento no número de consumidores juntamente com o aumento de equipamentos eletrodomésticos adquiridos nas residências.

A Figura 2.2 apresenta a evolução do consumo de energia dos equipamentos mais utilizados nas residências. Com uma projeção de 10 anos, é mostrado que a demanda pode estar direta ou indiretamente associada ao desenvolvimento econômico e a qualidade de vida.

Figura 2.2 – Consumo de energia elétrica por equipamento



Fonte:PDE 2027 (EPE, 2018).

Nas investigações feitas por Heringer(2010), a projeção do mercado de energia no Brasil era baseada em fatores de crescimento econômico e demográfico, apresentando que o crescimento da economia está intimamente relacionado com o consumo de energia. Ao relatar a realidade do consumo de energia elétrica no Brasil, mostrou também o comportamento da eletricidade em função da variação do produto interno bruto.

A eletricidade desempenha um papel cada vez mais importante na economia mundial. O desenvolvimento da sociedade e o crescimento das atividades econômicas impactam de forma significativa a demanda por eletricidade. As empresas utilizam a energia elétrica como um fator de produção, enquanto o bem-estar das famílias dependem, direta ou indiretamente do consumo de eletricidade (KHEIRKHAH et al., 2013).

Um aspecto importante, relacionado ao consumo de energia elétrica, é o conforto térmico, que expressa como a temperatura compromete o bem-estar de uma pessoa. Em-

bora este conforto de cada indivíduo dependa também de outros fatores, são as mudanças de temperatura ambiente, que afetam diretamente o metabolismo do corpo humano, alterando a sensação de conforto (PARKPOOM, et al., 2004).

É evidente que a temperatura afeta a demanda de energia elétrica e que é necessário desenvolver modelos de previsão de carga que resulte o mínimo de erros, e assim realizar a melhor projeção de demanda que será utilizada para atender as necessidades dos consumidores.

2.2 PREVISÃO DE DEMANDA DE ENERGIA ELÉTRICA

A previsão de demanda de energia elétrica é essencial para expansão do setor elétrico, verificação do comportamento das classes de consumo e apoio na contratação de energia nos leilões. Segundo os procedimentos e critérios estabelecidos nos procedimentos de rede adotados pela ANEEL, as empresas de distribuição são obrigadas a fornecer o Programa Mensal de Operação (PMO) ao Operador Nacional do Sistema (ONS), que regularmente realiza revisões semanais que incorporam informações atualizadas sobre o estado do sistema, as condições meteorológicas e as previsões de carga (ONS, 2020).

O objetivo de uma projeção de demanda é apresentar, para as geradoras, transmissoras e distribuidoras de energia elétrica, a evolução no consumo. Com isso, é possível projetar mudanças e ampliações do sistema elétrico e sua capacidade de operação. Uma previsão detalhada se torna importante na escolha de decisão para novos investimentos em infraestrutura, o que resulta na melhora dos serviços prestados aos consumidores (BURILLO et al., 2019).

Os órgãos reguladores e às concessionárias de energia utilizam a previsão da demanda para manter uma infraestrutura confiável em condições de aumento ou queda de consumo, ocasionado pela variação da temperatura. A previsão de demanda é utilizada para dar suporte à tomada de decisões por meio de análises quantitativas, ou seja, refere-se essencialmente ao comportamento da demanda do mercado futuramente (REIS et. al, 2015).

Para desenvolver trabalhos com a finalidade de elaborar um sistema predictor de demanda elétrica, torna-se necessário que se apresente o conhecimento prévio da demanda em várias regiões do sistema e os fatores que podem ter influência no mesmo, para que opere de modo seguro, econômico e confiável (HANDSCHIN; DÖRNEMANN, 1988; NOSE-FILHO, 2011).

A exatidão do modelo predictor está diretamente relacionada a fatores ambientais, como temperatura. A importância de considerar outras informações durante a previsão de carga foi observado no trabalho realizado por Ke, Jiang e Lu (2016), mostrando previsões com menos de 1% de erro, justificando essa precisão não só com a qualidade da técnica

utilizada, mas também com o conjuntos de dados conhecidos e de qualidade.

Em geral, as previsões de carga devem ser realizadas em um amplo intervalo de tempo, que podem ser classificados em previsões de curtíssimo, curto, médio e longo prazo. Para operação e controle economicamente eficientes dos sistemas de energia, a previsão de carga deve ser feita para períodos de tempo com duração variável.

Nas pesquisas realizadas por Klein (2014), encontram-se as definições de horizontes de previsão, de acordo com o planejamento de operação do sistema. Assim, têm-se os seguintes horizontes:

- **Longo prazo** - Com previsão de 1 a 5 anos à frente em que é avaliado a quantidade de consumo, planejando diminuir o custo operacional de longo prazo e minimizando a necessidade de utilização das fontes térmicas, de acordo com as necessidades da regulamentação e obras de expansão;
- **Médio prazo** - Para uma previsão de 1 mês à frente até um 1 ano , trata-se da programação de operações de suprimentos e manutenção de combustível com a definição de um cronograma para realizar a revisão e estabelecer os contratos de suprimentos de energia e potência, tornando-se a base para os preços de médio prazo;
- **Curto prazo** - Realiza uma projeção que estabelece as regiões de demanda de no mínimo 1 hora à frente até 1 semana. Representa um grande potencial de economia para operações econômicas e seguras de sistemas de energia. Faz-se a programação da operação, com objetivo de atender as previsões de médio prazo.
- **Curtíssimo prazo** - Consiste na previsão que possui um horizonte que pode variar de alguns minutos a 1 hora à frente, sendo caracterizado por identificar condições perigosas de operação e análise momentânea de eventualidades, facilitando a realização de ações preventivas.

As metodologias para previsão de demanda progrediram muito no decorrer dos anos. Todas as técnicas são desenvolvidas da melhor maneira em condições normais, no entanto, deixam a desejar em situações onde ocorrem mudanças inesperadas nos parâmetros do ambiente. A previsão de carga no horizonte de curto prazo é encontrada em maior número de trabalhos publicados com a utilização de uma variedade de métodos propondo diversas soluções (LI; WANG; GOEL, 2015; KHWAJA, et al., 2017; MILKE, 2019).

Em sua análise, Souza (2013) afirma que, para a previsão de demanda de energia elétrica no horizonte de curto prazo, o fator mais importante é a relação entre a demanda e a temperatura. No horizonte de curto prazo, as técnicas de previsão de carga são classificadas em dois tipos, de acordo com Souza (2013):

- Técnicas estatísticas: séries de modelo temporais de Box-Jenkins, como Modelo Auto-Regressivo Integrado de Médias Móveis (ARIMA), regressão linear, modelos adaptativos.
- Técnicas baseadas em sistemas inteligentes: São metodologias fundamentadas na inteligência artificial, como Lógica Fuzzy (LF), Redes Neurais Artificiais (RNA), e modelos híbridos empregando as duas técnicas.

Na previsão de curto prazo, limitações e dificuldades podem ser encontradas devido à forte ligação do comportamento da curva de demanda em função da temperatura. Diante disso, o trabalho proposto utiliza a técnica de RNAs para a previsão de carga no horizonte de curto prazo. A função que relaciona a temperatura com a carga é claramente não linear, uma das principais motivações para usar as RNAs, já que podem lidar facilmente com relacionamentos não lineares (HIPPERT, 2001; MARIN, 2018).

Enfim, acredita-se que, a implementação de técnicas para a projeção de demanda de energia a curto prazo, possa ser utilizada como ferramenta para que as empresas de distribuição de energia gerenciem e dimensionem, de forma eficiente, o sistema, obtendo um melhor planejamento energético. Com isso, é essencial o estudo e avaliações contínuas no comportamento da temperatura (MILKE, 2019).

2.3 EFEITO DE TEMPERATURA NO CONSUMO DE ENERGIA ELÉTRICA

A oferta de energia do país pode ser diretamente afetada pelas mudanças climáticas, sendo assim necessário um planejamento para a segurança energética. Como a demanda de eletricidade é continuamente influenciada pela temperatura ambiente, é provável que haja um impacto nos padrões de demanda e a magnitude do impacto dependerá dos padrões de uso de eletricidade na ausência de mudanças climáticas (PARKPOOM, et al. 2004).

As variáveis climáticas como, temperatura, umidade relativa do ar e a velocidade do vento apresentam grande relevância em termos de seus efeitos sobre a demanda de energia, devido a sua relação com o conforto térmico. Estudos de previsão de demanda consideram a influência destas variáveis (PIRES, 2016; ELJAZZAR;HEMAYED, 2016; MUZAFFAR; AFSHARI, 2018).


Dentre os fatores climáticos mencionados, a temperatura é um dos fatores que mais influencia para o aumento do consumo de energia elétrica, devido a necessidade do consumo de ar condicionado, refrigerador ou aquecedor e chuveiro elétrico (SWARUP, SATISH, 2002). À medida que os países em desenvolvimento melhoram seu padrão de vida, o uso de ar condicionado e outro consumo dependente do clima pode aumentar sua sensibilidade em relação as mudanças climáticas. Uma mínima variação na temperatura já

é suficiente para gerar uma mudança significativa no consumo de energia (PIRES, 2016).

A variação climática diminui o fornecimento de energia, e o clima quente aumenta a demanda de energia com a utilização das tecnologias de climatização. Vários estudos tem previsto um incremento gradual na demanda de energia em consequência das mudanças climáticas (QUIRÓS, 2018).

A Figura 2.3 e a Figura 2.4 apresentam a regressão linear entre as variáveis de temperatura e demanda média, no qual o valor de R^2 , chamado de coeficiente de determinação ou regressão múltipla, indica a porcentagem de quanto a variável de demanda é dependente da variável de temperatura. O valor de R^2 pode variar de 0 a 1, e quanto mais próximo de 1, maior é a indicação de que o modelo proposto é adequado para descrever o fenômeno de correlação entre as variáveis (BERNARDON, 2010). Os dados de demanda média analisados são de uma concessionária de energia localizada na região sul do Brasil.

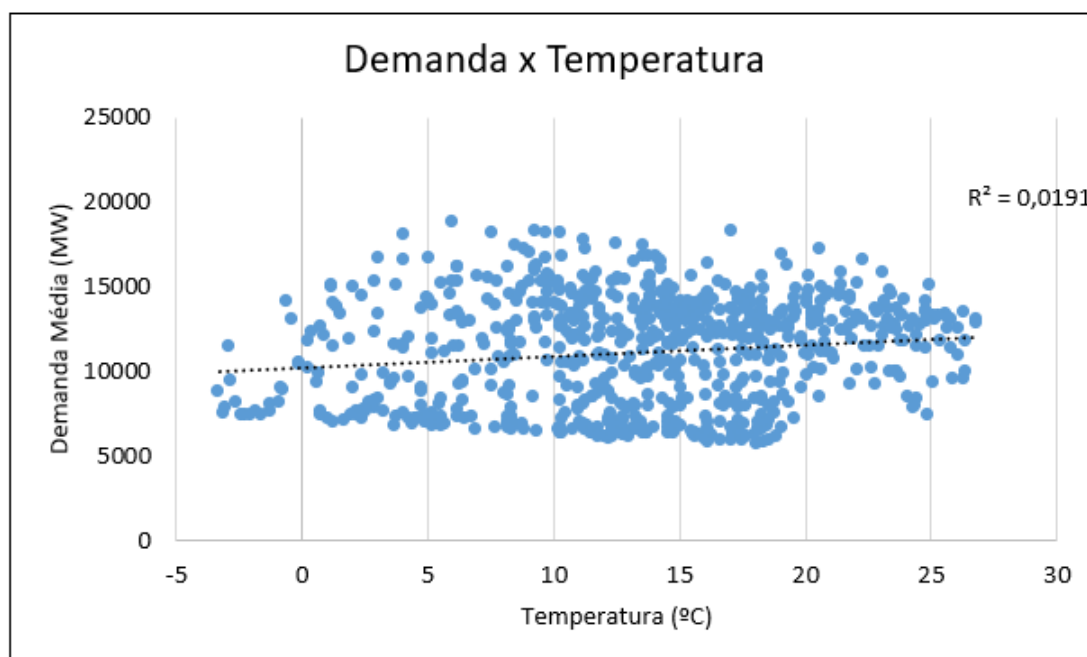
Figura 2.3 – Regressão linear entre a temperatura e demanda média de energia elétrica (dados coletados em janeiro de 2019).



Fonte: Autora (2020).

Os pontos na Figura 2.3 representam dados de temperatura e demanda média de energia elétrica de todo o mês de janeiro de 2019, com intervalo integralizado de 60 minutos, sendo o mês que registrou as maiores temperaturas em todo o ano e a linha contínua é a linha tendência de uma variável em relação à outra. Nos dados em análise, pode-se perceber que a temperatura teve uma correlação positiva entre a demanda elétrica, com $R^2=0,3097$, ou seja, à medida que a temperatura aumenta, a carga também aumenta.

Figura 2.4 – Regressão linear entre a temperatura e demanda média energia elétrica (dados coletados em julho de 2019).



Fonte: Autora (2020).

Na Figura 2.4, as variáveis de temperatura e demanda média de energia elétrica, medidas em todo o mês de julho de 2019, com intervalo integralizado de 60 minutos, referindo-se o mês que registrou as menores temperaturas em todo o ano e a linha contínua é a linha tendência de uma variável em relação à outra. A porcentagem do coeficiente de determinação $R^2=0,0191$, apesar de inferior a análise de Figura 2.3, o valor é positivo e novamente confirma que a temperatura ambiente afeta o nível de demanda de energia elétrica.

O coeficiente R^2 apresentou valor significativo apenas no mês de maiores temperaturas, confirmando assim, que a temperatura ambiente afeta o nível de demanda de energia elétrica, sendo um fator muito importante a ser considerado no método de previsão da demanda de energia elétrica para o curto prazo.

No trabalho de Ramírez-Sandí e Quirós-Tortós (2018) foi analisada a influência da temperatura com o aumento do uso de ar condicionados. Com isso, os autores perceberam que a demanda de energia possuía elevações entre às 11 e 14 horas, o que foi considerado como previsível devido ao aquecimento durante o dia que costuma ser maior nesse período.

Por fim, pode-se perceber a importância de realizar pesquisa e fomentar estudos sobre a demanda e consumo de energia elétrica que levem em conta o fator climático, como é o caso desse trabalho, verificando e modelando, da melhor forma, a análise das suas variáveis determinantes. Para se obter a melhor modelagem, se faz necessário utilizar

o método mais adequado para cada sistema e seu horizonte de projeção.

Os métodos estatísticos ainda são aplicados e estudados para a previsão de carga e possuem vantagem com a base matemática bem elaborada e desenvolvida, porém existe a dificuldade de tratar as variações significativas nos dados climáticos como a temperatura. Portanto, para o desenvolvimento de um modelo de projeção confiável, faz-se necessário uma análise detalhada das variáveis climáticas que influenciam no comportamento da demanda, tendo como opção as RNAs, que são utilizadas por executar dados não-lineares.

2.4 TRABALHOS UTILIZANDO REDES NEURAI

Nos últimos anos diversas pesquisas tem sido realizadas sobre aplicação de técnicas de inteligência artificial no problema de previsão de carga no horizonte de curto prazo. Assim como nesse trabalho, diversos estudos desenvolveram metodologias de previsão avaliando a influência da temperatura na demanda para obter o melhor comportamento futuro da carga.

O trabalho realizado por Lopes (2005), utiliza RNAs com treinamento usando algoritmo retropropagação baseada na arquitetura ART denominada rede neural RT&ARTMAP nebulosa. A inclusão desta estrutura de redes neurais produziu melhores resultados se comparado à rede neural retropropagação convencional sendo à resolução do problema de previsão de carga global de curto-prazo, 24 horas à frente, considerando dados analógicos como os valores da carga elétrica, temperatura, entre outros.

As análises para a aplicação de RNAs realizadas por Paschoalino et al. (2007), observaram que esse método está dentro do contexto da inteligência artificial, na previsão de demanda de energia elétrica no Brasil. Seu principal objetivo foi medir a performance da RNA frente ao comportamento não-linear e não-sazonal das séries históricas de consumo de energia elétrica entre os anos de 1982 a 2003, utilizando o ano de 2001 para validação dos resultados. A técnica utilizada foi RNA de Elman associada a um algoritmo de aprendizado supervisionado *backpropagation*. Enfim, foram calculados os erros médios quadráticos de cada modelo investigado, alcançando resultados na ordem de 0,02%.

Em Campos (2008), o autor analisa o uso de Rede Neuro-Fuzzy e RNAs, com a qual faz a previsão, de energia elétrica para curto, médio e longo prazo, em que seu desempenho é medido por indicadores. A Rede Neuro-Fuzzy se mostrou, segundo o autor, um melhor comportamento na previsão em médio prazo. Entretanto, a RNA respondeu com maior eficácia na predição em curto prazo, no caso um ano.

Para fazer a previsão de cargas elétricas em um período de 24 e 48 horas a frente, considerando-se os dados históricos de uma companhia do setor elétrico, Alves (2013) propôs uma rede neural híbrida composta pelo método de regressão linear com seleção de variáveis *stepwise* juntamente com a RNA perceptron multicamadas com o algoritmo

backpropagation.

Din e Marnerides (2017) realizaram previsões de carga no curto prazo utilizando RNAs através da aplicação de dois modelos: *feedforward Deep Neural Network* (FF DNN) e *Recurrent Deep Neural Network* (R DNN), visando comparar o seu desempenho computacional. O método foi avaliado utilizando dados reais de 4 anos, realizando projeções para um horizonte de dias e semanas. A abordagem proposta do trabalho é realizar previsões precisas, a qual é considerada crítica e necessária a centros de operações de distribuição de energia elétrica.

O artigo de Kwon (2018) propõe uma análise da previsão da carga de curto prazo usando algoritmo de RNA de acordo com a normalização e seleção dos dados de entrada dias da semana. A carga passada, a temperatura anterior e temperatura do dia de previsão são usado como dados de entrada para a previsão de curto prazo e a normalização dos dados de entrada e seleção de dados de entrada é feito para dois dias para o algoritmo proposto.

O trabalho desenvolvido por Milke (2019), apresentou uma proposta de previsão da curva de carga diária para um dia à frente aplicado a dados reais de energia, demanda e temperatura. Essas variáveis representaram da melhor maneira o comportamento da carga no curto prazo, com isso foi implementado um modelo desenvolvido com RNA perceptron de múltiplas camadas utilizando o algoritmo de aprendizagem *Levenberg Marquardt*. Os resultados encontrados foram satisfatórios de acordo com a metodologia utilizada.

O trabalho elaborado por Sharma (2020), propõe a combinação das vantagens da lógica difusa de RNA para prever a carga do dia seguinte. O conjunto de dados de demanda em um período entre os anos de 2013 a 2014. Observa-se que, em termos de precisão, o modelo híbrido Fuzzy- RNA supera seu equivalente na RNA. Concluíram que o uso da lógica nebulosa com o modelo RNA conseguiu obter maior precisão através de mapeamento eficiente dos parâmetros como a temperatura na mudança na demanda de carga.

A utilização das RNAs tem se mostrado muito eficiente na projeção de previsões de curto prazo para aferição de cargas em sistemas elétricos, sendo projetadas em diferentes algoritmos de treinamentos e aplicadas aliadas a outras ferramentas e metodologias, conseguiram obter resultados adequados.

Nesse trabalho a metodologia testada tem como objetivo encontrar o menor erro possível durante o processo de desenvolvimento da RNA, para obter curvas de previsão da carga mais próximas das que o sistema irá entregar. Para isso será aplicado o algoritmo *backpropagation* (SCGB), que teve a menor taxa de erro em trabalhos anteriores (Kasac et al., 2011; Hassan, 2013; Khadse, 2017), treinado no *software* MATLAB®.

2.5 CONSIDERAÇÕES FINAIS DO CAPÍTULO

Neste capítulo introduziu-se sobre o consumo de carga relacionando os impactos causados pela variação de temperatura, juntamente com uma análise sobre o comportamento da demanda de energia associada a temperatura.

Abordou-se ainda uma revisão bibliográfica da previsão de carga no curto prazo utilizando RNA, demonstrando sua aplicação, as técnicas que podem ser utilizadas nesse estudo, suas metodologias, e os trabalhos mais relevantes e recentemente publicados na literatura especializada.

3 REDES NEURAIS ARTIFICIAIS

Neste capítulo são apresentadas as redes neurais artificiais, uma técnica de inteligência artificial (IA) para a previsão de demanda de energia elétrica, visando à qualidade no processo de planejamento do sistema elétrico. Maior ênfase é dada para rede perceptron de múltiplas camadas (PMC), por ser o método escolhido para a previsão de demanda neste trabalho.

3.1 INTRODUÇÃO

Desde o final da década de 1950, os modelos de inteligência computacional alcançaram níveis significativos, muito além do que se foi esperado. O surgimento de uma máquina que tivesse a capacidade de realizar atividades iguais ou mais complexas que as feitas pelo cérebro humano, se tornava cada vez mais viável. A possibilidade de máquinas dominarem todas as tarefas até então atribuídas ao homem, causava muito entusiasmo na época (SIQUEIRA, 2009). Nos últimos anos os estudos para desvendar o funcionamento do cérebro vem aumentando. A partir daí, pesquisadores já se sentiram estimulados em adentrar em uma nova área da ciência.

Os métodos de IA forneceram aos pesquisadores formas de codificar conhecimento humano em uma técnica computacional e determinar o comportamento de um sistema baseado apenas no seus dados reais. Os principais métodos da IA (RNA e Lógica Fuzzy) tem sido muito usados, com resultados, na maioria das vezes, melhor que as técnicas matemáticas tradicionais (GUIRELLI, 2006; Perez, 2017).

A pesquisa em RNAs tem sua história desde de 1940 com o trabalho de McCulloch e Pitts (1943), em que foi proposto o primeiro neurônio artificial. Tratava-se de um modelo matemático que criava o neurônio biológico como uma unidade de processamento, sendo descrito por um conjunto de n entradas, as quais são multiplicadas por um determinado peso e em seguida, os resultados são somados e comparados a um limite inicial.

Uma RNA pode ser definida como uma ferramenta na qual foi projetada para reproduzir o funcionamento do cérebro humano. Abordado por Haykins (2008), as soluções que aplicam RNAs trazem grande motivação desde o início de seus estudos, devido a sua associação ao cérebro, mostrando semelhanças em sua capacidade de organização e seus componentes estruturais, conhecidos como neurônios, de modo a realizar cálculos complexos.

A RNA é um conjunto de neurônios artificiais em que existe uma interconexão para gerar uma ou mais saídas a partir de uma ou mais entradas. Dentro das possíveis áreas de aplicação das RNAs, mencionam-se sistemas de previsão, em que o objetivo consiste em considerar valores futuros de um processo, devido a sua capacidade de aprendizado e

generalização, o que torna a técnica utilizada capaz de realizar a aproximação de funções não lineares e a previsão de um conjunto de dados (HAYKIN, 2001).

Na sua forma mais geral, uma RNA é uma máquina projetada para modelar o caminho em que o cérebro executa uma tarefa ou função específica, fazendo a comunicação de dados entre seus neurônios. O benefício em utilizar as RNAs é a capacidade de desenvolver um treinamento, a rede é treinada de maneira que um conjunto de entrada produza o conjunto de saída desejada, ou pelo menos coerente. Geralmente, os padrões de entrada são dados das cargas atuais e passadas e a saída é composta por valores da carga futura (LOPES, 2005).

As RNAs também possuem grande capacidade de se adaptar e improvisar, isto é, elas são capazes de resolver problemas que não fazem parte da base de conhecimento fornecida durante o seu treinamento, o que transforma a RNA em uma poderosa ferramenta para a resolução de diversos problemas. No entanto, as maiores dificuldades do uso das RNAs são a escolha da topologia da rede, que não segue uma teoria exata, e a dificuldade na interpretação dos conceitos aprendidos pela RNA (BORDIGNON, 2012).

Uma das topologias mais utilizadas é a rede PMC, por ser uma topologia simples e de grande potencial para implementação computacional, podendo diminuir as dificuldades de interpretação dos conceitos da RNA. Com um número de elevadas possibilidades de aplicações em diversos problemas e diversas área e possuindo grande aplicabilidade foi a escolha para o desenvolvimento deste trabalho.

3.2 TOPOLOGIA DE REDES NEURAIIS ARTIFICIAIS

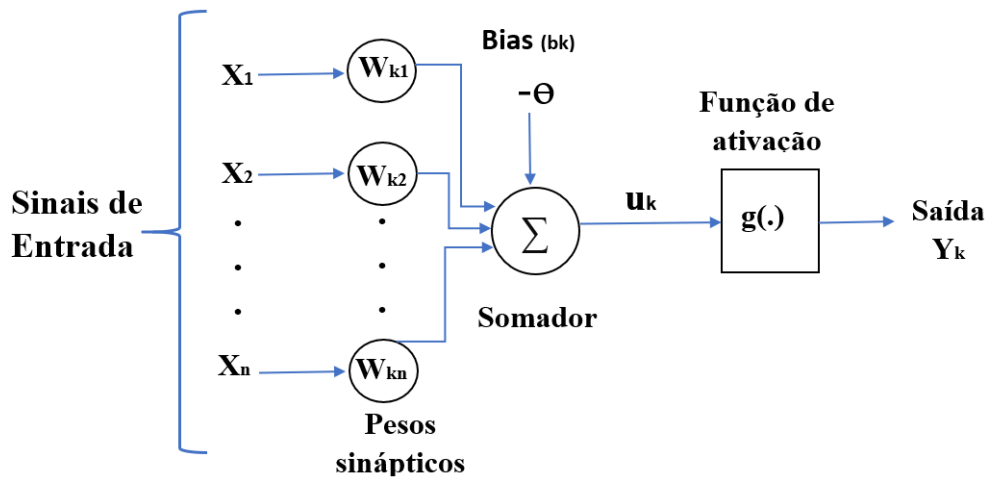
Para se classificar as topologias de RNAs, não existe norma a ser seguida, apenas diferenças entre elas. Pode-se realizar uma distinção entre os modelos por meio de características básicas, como a entrada e a forma de conexão, ou até mesmo o tipo de aprendizado. A caracterização de uma RNA é principalmente dada pela sua topologia, pelas características dos nós ou pelas regras de treinamento (DA SILVA; SPATTI; FLAUZINO, 2016).

A RNA obtém sua força na computação através de sua estrutura distribuída e sua capacidade de aprender e assim generalizar. Generalização refere-se à produção razoável de RNA saídas para entradas não encontradas durante o treinamento. Esses dois processos de informações e recursos possibilitam às RNAs encontrar soluções para problemas complexos que não possuem um tratamento adequado (SILVA, 2015).

Um neurônio é uma unidade de processamento de informações que é fundamental para a operação de uma RNA. A Figura 3.1 mostra o modelo de um neurônio, que forma a base para projetar uma grande família de RNAs. A partir desse diagrama proposto por McCulloch e Pitts, na década de 40, Haykin (2008) identificou três elementos básicos do

modelo neural.

Figura 3.1 – Representação Neurônio Artificial



Fonte: Adaptado de HAYKIN (2008).

O modelo de neurônio mostrado na Figura 3.1 é associado a uma estrutura inicial, representado pelos sinais de entrada X_1, X_2, \dots, X_n , pesos sinápticos dos neurônios $W_{k1}, W_{k2}, \dots, W_{kn}$, fator bias b_k , também chamado de limiar de ativação θ , que tem o papel de aumentar ou diminuir o grau de liberdade da rede. A função de ativação faz a tradução dos sinais de entrada para sinais de saída, e sua função é definir a ativação de saída do neurônio k , transformando a entrada da rede. A função de ativação $g(u)$ define a saída de um neurônio em termos de u , quando u é maior ou igual a 0, $g(u)$ será igual 1, caso u seja menor do que 0, então $g(u_k)$ será igual a 0 (HAYKIN, 2008).

A equação (3.1) e a equação (3.2) resumem o resultado produzido pelo neurônio artificial em termos matemáticos proposto por McCulloch e Pitts (1943).

$$u_k = \sum_{i=1}^n (w_i \times x_i) - \theta \quad (3.1)$$

$$y_k = g(u_k) \quad (3.2)$$

O potencial de ativação u_k é basicamente o somatório do produto das entradas com os pesos sinápticos atribuídos nas camadas da RNA. Os pesos W_{kn} e o limiar θ são ajustados para responder à operação da função de ativação escolhida. O sinal de saída y_k é o resultado da entrada do potencial de ativação para a função de ativação. A função de ativação trata-se de uma função matemática aplicada à combinação linear entre as variáveis de entradas e pesos, para definir a associação entre entradas e saídas de cada

neurônio da rede (HAYKIN, 2001).

3.3 FUNÇÕES DE ATIVAÇÃO

A função de ativação representa o efeito que a entrada interna e o estado atual de ativação exercem na definição do próximo estado de ativação da unidade. Tendo em vista a simplicidade desejada para as unidades processadoras, geralmente define-se seu estado de ativação como uma função algébrica da entrada interna atual, independente de valores passados do estado de ativação ou mesmo da entrada interna (HAYKIN, 2008).

A função de ativação de uma RNA tem como finalidade fornecer uma saída equivalente a saída de um neurônio, o qual não é linearmente dependente de suas entradas, restringindo a amplitude de saída do neurônio. Tal função pode assumir várias formas dentre os dois grupos principais, isto é, funções parcialmente diferenciáveis e funções totalmente diferenciáveis (ALTRAN, 2010).

As funções de ativação parcialmente diferenciáveis apresentam pontos do qual as derivadas de primeira ordem são inexistentes, possuindo as principais funções: degrau, degrau bipolar e rampa simétrica. Já as funções de ativação totalmente diferenciáveis são aquelas cujas derivadas de primeira ordem existem e são conhecidas em todos os pontos de seu domínio e definição, tendo quatro funções principais: função logística, função tangente hiperbólica, função gaussiana e função linear (DA SILVA; SPATTI; FLAUZINO, 2016 ; HAYKIN, 2001; MILKE, 2019).

Nesse trabalho serão apresentadas apenas as funções totalmente diferenciáveis. As funções de ativação são escolhidas em função da necessidade do problema em que a rede esteja trabalhando. As mais utilizadas são a função logística, função tangente hiperbólica, função gaussiana e função linear.


3.3.1 Função Logística

Na função logística, a saída sempre implicará em um valor real positivo, definido entre 0 e 1, conforme a equação (3.3) (DA SILVA et al., 2016).

$$g(u) = \frac{1}{1 + e^{-\kappa u}} \quad (3.3)$$

Tomando κ como uma constante real agregada ao nível de inclinação da função logística ao seu ponto de inflexão. A Figura 3.2 representa a projeção da função logística em relação a variação do parâmetro de inclinação κ .

Figura 3.2 – Gráfico da função Logística



Fonte: MILKE, (2019).

A função logística da Figura 3.2 funciona de forma binária, sendo uma boa forma de modelar esse comportamento, já que assume valores apenas entre 0, quando não é ativado, e 1 na ativação. No entanto, se analisar sua derivada, observa-se que ela satura para valores acima de 5 e abaixo de -5. Com essas derivadas tendendo a zero, a propagação do gradiente se perde nesses pontos, causando dificuldades no treinamento da rede (GOODFELLOW et al., 2016).


3.3.2 Função Tangente Hiperbólica

A função tangente hiperbólica apresenta seu resultado da função de ativação com um intervalo real entre -1 e 1 e sua expressão é apresentada na equação (3.4) (DA SILVA et al., 2016).

$$g(u) = \frac{1 - e^{-\beta u}}{1 + e^{-\beta u}} \quad (3.4)$$

Considerando β associado ao nível de inclinação da função tangente hiperbólica em relação ao seu ponto de inflexão. A Figura 3.3 representa o gráfico da função tangente hiperbólica para diversos valores impostos ao parâmetro β .

Figura 3.3 – Gráfico da função Hiperbólica



Fonte: MILKE, (2019).

A função tangente hiperbólica é a que mais se aproxima de uma função identidade, sendo assim uma alternativa mais viável do que a logística para ativar as camadas ocultas das RNAs. Pode-se ver na Figura 3.3 que as saturações ainda estão presentes (GOODFELLOW et al., 2016).


3.3.3 Função Gaussiana

A função de ativação gaussiana apresenta a saída do neurônio e produz resultados iguais para os valores de potencial de ativação u que estejam posicionados na mesma distância que o seu centro, sendo que a curva deste é simétrica representada pela equação (3.5) (DA SILVA et al., 2016).

$$g(u) = e^{-\frac{(u-c)^2}{2\sigma^2}} \quad (3.5)$$

Sendo a variável c o parâmetro que define a função gaussiana e σ refere-se ao desvio padrão, ou seja, o quanto dispersada está a sua curva em relação ao ponto médio da função. O gráfico da função gaussiana é representado pela Figura 3.4.

Figura 3.4 – Gráfico da função Gaussiana



Fonte: MILKE, (2019).

A curva da função de ativação gaussiana da Figura 3.4 possui ótima capacidade de aproximar qualquer função contínua por meio de uma combinação linear entre funções gaussianas. A determinação da forma da gaussiana definida pelo (σ), a posição dos seus centros (c) e o número de neurônios é o que define o quão aproximado irá ser o ajuste da função desejada (GOODFELLOW et al., 2016).


3.3.4 Função Linear

A função linear gera resultados de saída idênticos aos valores do potencial de ativação (u), a expressão é apresentada na equação (3.6) (DA SILVA et al., 2016).

$$g(u) = u \quad (3.6)$$

O gráfico da função linear é representado pela Figura 3.5.

Figura 3.5 – Gráfico da função Linear



Fonte: MILKE, (2019).

A ativação da função linear apresentada na Figura 3.5 é mais eficiente do que as funções logística, tangente hiperbólica e gaussiana, e é uma das descobertas que contribuiu de forma significativa para a utilização da inteligência artificial. Essa não linearidade é um ótimo exemplo de como a simplicidade pode ser extremamente poderosa. A desvantagem da função linear é a perda de informações durante o treinamento, isso acontece quando a soma ponderada antes de aplicar a ativação linear se torna negativa, fazendo com que a unidade produza zero (GOODFELLOW et al., 2016).

A descrição do neurônio e suas funções permite compreender melhor o que compõem uma RNA. Na sequência são abordadas as arquiteturas de RNAs existentes. A resolução dos problemas pelas redes está correlacionado diretamente com a arquitetura escolhida e para cada uma dessas arquiteturas deve estar associada um treinamento, sendo uma das mais importantes qualidades das estruturas.

3.4 ARQUITETURAS DAS RNA

Uma RNA pode ser dividida, essencialmente, em três partes: a camada de entrada, camada oculta e camada de saída. A camada de entrada possui a função de receber a informação, normalmente normalizada em relação às faixas de variação dinâmica, obtendo a melhor precisão. As camadas ocultas possuem a responsabilidade de extrair as características associadas ao processo, recebendo as informações da camada anterior. Já a camada de saída é responsável pela apresentação dos resultados finais, a partir do processamento de camadas anteriores (DA SILVA et al., 2016).

O relacionamento entre as camadas de entrada e saída possui a capacidade de generalizar as soluções e aprender a partir da apresentação dos padrões do sistema. O modo pelo qual os neurônios de uma RNA são organizados está intimamente ligada com o algoritmo de aprendizado usado para treinar a RNA. Com isso, o aprendizado dos algoritmos usados na arquitetura de uma RNA é completamente estruturado. As arquiteturas de rede são em geral de três classes fundamentalmente diferentes (HAYKIN, 2008).


De acordo com Capitanio (2019), as arquiteturas da RNA, considerando correlação e organização dos neurônios, e ainda a constituição de suas camadas, podem ser divididas em:

- (a) Redes *Feedforward* de camada simples;
- (b) Redes *Feedforward* de camadas múltiplas;
- (c) Redes recorrentes.

Em uma RNA em camadas simples, os neurônios são organizados com apenas uma camada. Há uma camada de entrada de nós de origem que é projetada diretamente em

uma camada de saída de neurônios, mas não vice-versa. Assim, essa rede é estritamente de tipo *feedforward*, ilustrada na Figura 3.6 para quatro nós nas camadas de entrada e saída (HAYKIN, 2008).

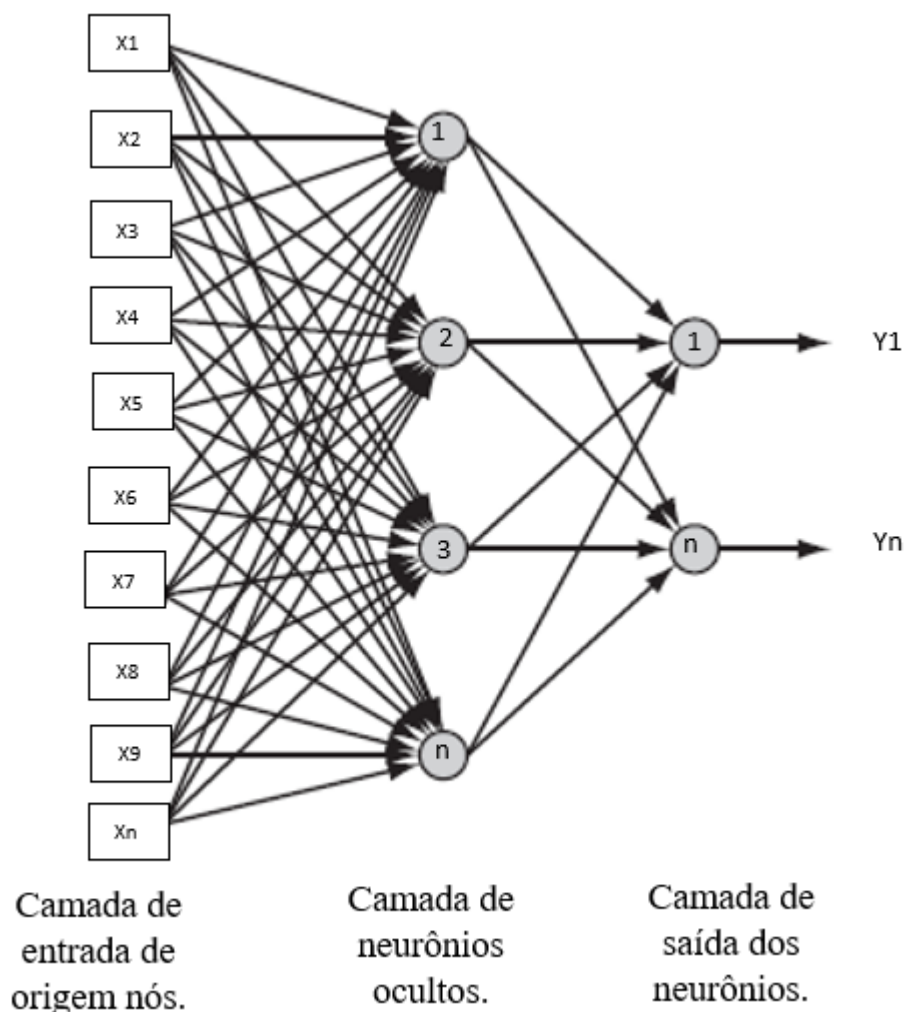
Figura 3.6 – Rede *feedforward* com uma única camada de neurônios



Fonte: Adaptado de HAYKIN, (2008).

A rede de camada simples da Figura 3.6 mostra que a camada de entrada de origem de nós tem a mesma quantidade de nós de saída na sua arquitetura. Normalmente, esta arquitetura é aplicada para problemas de filtragem linear e classificação de padrões.

Redes de *feedforward* de camadas múltiplas é a segunda classe de uma RNA *feedforward*. A distinção é feita pela presença de uma ou mais camadas ocultas, como apresentado na Figura 3.7, cujos nós de computação são correspondentemente chamados de unidades ocultas. O termo oculto refere-se ao fato de que essa parte do sistema neural não é visto diretamente da entrada ou da saída da RNA (HAYKIN, 2008).

Figura 3.7 – Rede *feedforward* com uma camada oculta e uma camada de saída.

Fonte: Adaptado de HAYKIN, (2008).

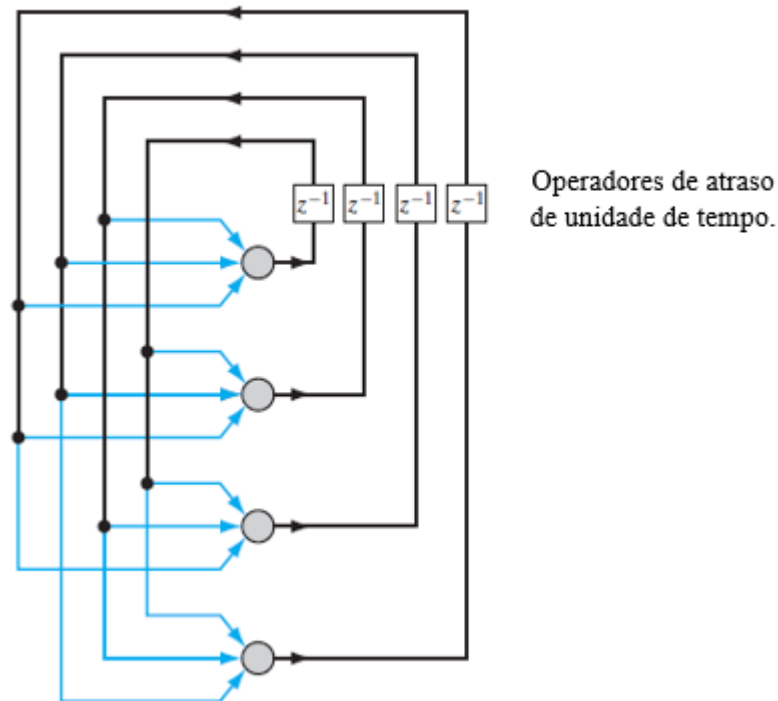
O número de camadas ocultas em uma rede multicamadas é relacionada, geralmente, com a complexidade do problema e tem sido aplicada em diferentes problemas combinatórios e na solução de diversas tarefas, como processamento de informações, reconhecimento de padrões, previsões de tempo, problemas de classificação, processamento de imagens, previsões de atividades sísmicas e outros (SHAH & GHAZALI, 2011).

O tipo mais recente de arquitetura de RNA são as redes recorrentes, que possuem uma retroalimentação. Uma rede recorrente pode consistir em uma única camada de neurônios com cada neurônio retornando seu sinal de saída às entradas de todos os outros neurônios, qualificando-as para processos mais eficientes de informações, ou seja, sistemas variantes no tempo, como previsão de séries temporais, otimização, controle de processos, entre outros (HAYKIN, 2008).

Esse processo de retroalimentação é mostrado na Figura 3.8, com a RNA contendo

uma camada de neurônios e operadores de atraso de unidade de tempo.

Figura 3.8 – Rede recorrente sem neurônios ocultos.



Fonte: Adaptado de HAYKIN, (2008).

A Figura 3.8 apresenta o tipo de rede que contém realimentação entre neurônios de camadas diferentes. Suas principais aplicações são em sistemas dinâmicos, memória associativa, previsão, otimização e em controle (HAYKIN, 2001).

Dentre todas as características das RNAs, uma das mais importantes é a habilidade de aprender e com isso melhorar seu desempenho. A rede é treinada de maneira que um conjunto de entrada produza o conjunto de saída desejada, ou ao menos uma saída consistente (MENDES & CARVALHO, 1997).

No contexto de RNA, aprendizagem ou treinamento corresponde ao processo de ajuste dos parâmetros livres da rede, através de um mecanismo de apresentação de estímulos ambientais, conhecidos como padrões.

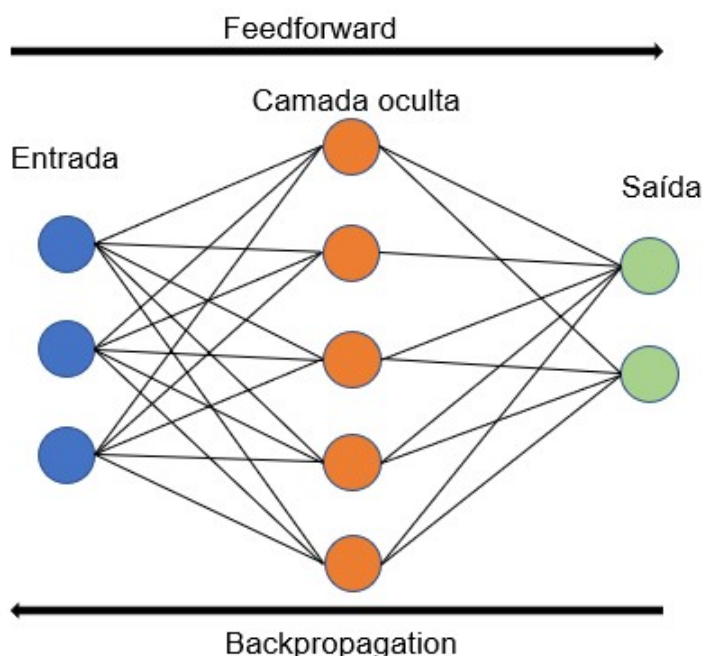
3.4.1 Redes *Perceptron* de múltiplas camadas

As redes Perceptron Multicamadas (PMC) fazem parte da arquitetura de redes feedforward de múltiplas camadas. Para realizar o processamento da informação considera-se o sentido através das ligações sinápticas entre os neurônios das camadas que estão na

sequência. Essa arquitetura consiste em uma rede neural de várias camadas, que desempenha a mesma função, nas entradas, e na saída de uma rede neural básica. A vantagem principal é devido à soma dos pesos nas camadas intermediárias, melhorando o processo de cálculo desses pesos (MARQUES, 2018).

A Figura 3.9, apresenta de forma simples, a estrutura de uma PMC, que é caracterizada por pelo menos uma camada oculta de neurônios, situadas entre a camada de entrada e a camada de saída. A RNA tem a capacidade de aprender a partir de seu ambiente e melhorar o seu desempenho por meio de aprendizagem, processo iterativo de ajuste de pesos, para ponderar as entradas que serão utilizadas no sistema. A PMC é a arquitetura adequada para o sistema de previsão de demanda que será testado.

Figura 3.9 – Rede *Perceptron* de Múltiplas Camadas



Fonte: Autora, (2020).

A rede da Figura 3.9 possui a topologia alimentada para frente (*Feedforward*), onde o fluxo de informação é sempre da camada de entrada para a camada de saída. O avanço para frente é chamado de propagação (*Feedforward*), onde os neurônios de entrada são aplicadas aos neurônios ocultos e os neurônios ocultos são aplicadas como entradas dos neurônios da camada final, obtendo então a resposta da rede. O passo para trás (*Backpropagation*) tem a finalidade de ajustar os pesos sinápticos, por meio do cálculo do erro realizado na camada de saída.

A escolha da melhor arquitetura para um sistema de previsão utilizando RNAs, está relacionada com o tratamento dos dados, que não são linearmente separáveis. A precisão obtida e a implementação da função, dependem do número de neurônios utilizados nas

camadas. As redes neurais artificiais são muito eficientes na aprendizagem de padrões em dados com ruído, incompletos e que podem conter dados contraditórios. Também são eficientes onde o comportamento das variáveis do problema em questão não podem ser facilmente descritos em uma função.

A conexão entre os neurônios da rede acontece por meio dos ajustes de pesos, assim, toda a aprendizagem obtida pelo processamento dos neurônios da camada intermediária é armazenada nos próprios pesos, sendo realizado dentro do processo de treinamento supervisionado. O algoritmo de aprendizado nesta arquitetura da rede é denominado do *backpropagation* ou algoritmo de retropropagação do erro (DA SILVA; SPATTI; FLAUZINO, 2016).

3.5 APRENDIZADO DAS REDES NEURAIAS

A RNA têm a capacidade de aprender a partir de seu ambiente e melhorar o seu desempenho por meio da aprendizagem. O algoritmo de aprendizagem é uma metodologia empregada na realização do processo de aprendizagem, o qual tem a atribuição de modificar os pesos sinápticos da RNA para atingir o objetivo do trabalho. Modificar os pesos sinápticos é a metodologia tradicional para projetar Redes Neurais Artificiais.

O tipo de aprendizagem é determinado pela forma de ajuste dos pesos (HAYKIN, 2008). A aprendizagem de uma RNA é composta por procedimentos, os quais os parâmetros se adaptam para o desenvolvimento de uma atividade estabelecida. O ajuste dos parâmetros da rede é feito de forma iterativa, na qual a RNA preserva a informação que a rede obteve durante o processo de treinamento. Os métodos de treinamento podem ser divididos em: aprendizado não supervisionado e aprendizado supervisionado (BINOTI, 2010).

No aprendizado não supervisionado não há um agente externo para supervisionar o processo, ficam disponíveis para a rede somente os padrões de entrada. Nele, a rede processa as entradas e, detectando suas regularidades, tenta, progressivamente, estabelecer representações internas para codificar características e classificá-las automaticamente. Este tipo de aprendizado só pode ser utilizado quando existe redundância nos dados de entrada, para que se consiga identificar padrões em tais dados (FERNEDA, 2006).

No aprendizado supervisionado existe um supervisor externo que disponibiliza à RNA tanto os valores de entrada quanto os valores de saída esperados. Este é o tipo de aprendizado mais comum para treinamento das RNA. Nele, a rede compara o valor de saída calculado com o valor esperado e avalia o erro decorrente das diferenças entre ambos. Se existir alguma diferença, os pesos sinápticos são modificados de forma a minimizar o erro e encontrar a melhor relação entre as informações de entrada e saída (FIORIN et al, 2011).

A capacidade de aprendizado de uma RNA é sua característica mais importante a partir de um ambiente. Um conjunto de dados pré-estabelecido de regras bem definidas para a solução de um problema de aprendizagem é denominado algoritmo de treinamento. Não existe um algoritmo de aprendizagem único para o projeto de RNAs. Em vez disso, obtém-se um conjunto de ferramentas representado por uma variedade de algoritmos de treinamento, cada qual oferecendo vantagens específicas (CRUZ, 2009).

Essas características contribuem para esse algoritmo ser muito utilizado no ambiente de previsões. Porém, sua convergência é excessivamente lenta e às vezes não se observa a convergência, em especial quando há a inserção de uma base de dados de entrada muito grande (AMORIM, 2019).

Na fase de aprendizado de uma RNA, os pesos atribuídos nessa rede são ajustados através de um algoritmo apropriado a sua estrutura. A RNA baseada no uso do algoritmo de retropropagação trata-se de um treinamento supervisionado sendo composta por várias camadas de neurônios dispostos em paralelo e possui sua função de ativação contínua. Essa estrutura possibilita a execução de tarefas de reconhecimento de padrões, diagnósticos, previsões, entre outras tarefas.

3.5.1 Algoritmo de retropropagação

O algoritmo de retropropagação, também chamado de algoritmo de *backpropagation*, é um dos mais utilizados para realizar aprendizado de redes de camadas múltiplas, em que o fluxo de dados é apenas no sentido da saída. Quando um sinal entra na rede, ele passa pelos neurônios e é produzida uma saída, que é comparada com o sinal desejado e estipula-se um valor de erro.

Esse valor de erro passa a se propagar em sentido contrário, da saída para a entrada, alterando os valores de pesos das sinapses para que se tenha uma resposta mais coerente. Para esses novos valores nas sinapses, um novo erro é calculado e continua-se o ciclo de treinamento, que vai encerrar quando atingir um valor predeterminado de épocas ou uma quantidade de erro máxima (RUFINO, 2017).

O *backpropagation* surgiu em 1974, e desde então surgiram diversas variações do algoritmo. A pesquisa apresentada por Khadse, Chaudhari e Borghate (2017) compara o desempenho de diferentes algoritmos: *Levenberg-Marquardt* (LM), *conjugate gradient backpropagation* (CGB), *scaled conjugate gradient backpropagation* (SCGB), *one-step secant* (OSS), *gradient descent with momentum* (GDM), *Bayesian regularization* (BR), *gradient descent with adaptive learning rate* (GDX), e foi apresentado que o método SCGB apresenta um melhor desempenho, com uma menor taxa de erro, entre estes algoritmos de treinamento. A utilização de mais de um desses treinamentos juntos pode ser ainda mais eficiente, e também tornar o processo mais lento e mais caro.

O *Backpropagation* é o algoritmo de treinamento para redes perceptrons de múltiplas camadas mais conhecido. O algoritmo *Scaled Conjugate Gradient Backpropagation* (SCGB) é uma versão mais rápida do algoritmo *Backpropagation*, em que as derivadas parciais de segunda ordem são utilizadas para alterar a taxa de aprendizado (MOLLER, 1993; FRIZZO, 2019).

O algoritmo *Scaled Conjugate Gradient Backpropagation* (SCGB) é uma classe de algoritmo mostrada como apropriada para problemas de otimização não-linear e de larga escala, em que possui uma grande quantidade de dados para analisar. O método do gradiente pode ser classificado como um método de primeira ordem, já que utiliza apenas a informação do gradiente da função de erro para ajustar os pesos da rede (CASTRO, 1998). O treinamento da rede neural é um problema de minimização não linear, no qual os pesos da rede são modificados iterativamente para minimizar os erros entre os valores de saída desejados e reais para todos os nós de saída sobre todos os padrões de entrada

3.5.1.1 Erros de previsão

O método mais comum usado para o ajustar os pesos é a retropropagação. Neste modelo de algoritmo, os pesos são ajustados para minimizar a diferença quadrática entre a saída do modelo e a saída desejada para uma observação no conjunto de dados. O erro de previsão é a diferença entre o valor previsto dos dados de saída dependente no tempo e o observado na previsão. Dessa forma, o ajuste dos pesos realizado na rede ocorre quando o erro encontrado ao quadrado é propagado para a camada de entrada (MIKEL, 2019).

O algoritmo de treinamento é usado para encontrar os pesos que minimizam alguma medida geral de erro, como os erros quadráticos médios (MSE). Portanto, o treinamento da rede é na verdade, um problema de minimização não linear total para um problema de previsão de série temporal.

Para a previsão de séries temporais, deve-se medir a eficácia do algoritmo usando indicadores para verificar sua variabilidade. Os indicadores mais utilizados nesse processo de previsão são: *Mean Squared Error* (MSE), *Mean Absolute Percentage Error* (MAPE), *Absolute Percentage Error* (APE%).

O erro (MSE), é um índice que mede se os valores estimados estão acima ou abaixo dos reais. Se positivo, os valores estimados estão frequentemente abaixo do real, e se negativo, os valores estimados estão acima do real, sendo calculado pela equação (3.7) (ALMEIDA, 2018).

$$MSE = \frac{1}{N} \times \sum_{j=1}^N (a_j - y_j)^2 \quad (3.7)$$

Em que a variável a_j significa o valor real, y_j o valor resultante de saída, N é o

número de amostras das previsões.

O erro (APE) mostrado na equação (3.8), assim como o MSE avalia o erro absoluto da previsão, porém possui uma perspectiva independente da escala do erro da previsão (ALMEIDA, 2018).

$$APE(\%) = \frac{D_o - D_r}{D_o} \times 100 \quad (3.8)$$

Em que D_o significa o valor de demanda original e D_r o valor da demanda real, em seguida o índice é multiplicado por cem para se obter a porcentagem.

O erro MAPE avalia a magnitude do módulo do erro percentual, no qual consiste na média dos erros absolutos percentuais, ou seja, o somatório dos erros percentuais absolutos, dividido pelo período utilizado para previsão. É calculado pela equação (3.9), em que o N o período analisado (ALMEIDA, 2018).

$$MAPE = \frac{1}{N} \times \sum_N APE \quad (3.9)$$

A equação (3.9), para um dado conjunto de treinamento, representa uma medida de desempenho da rede neural. A qualidade da previsão é mensurada pela média absoluta dos erros percentuais e o objetivo do processo de treinamento é justamente minimizar o esse erro MAPE.

O processo de treinamento é interrompido em determinado momento por alguns fatores inseridos ou característicos da rede que está sendo processada (MIKEL, 2019). Os critérios mais usuais de parada da rede neural, são: o número de épocas inseridas para o treinamento, o erro gerado a partir da iterações realizadas pela rede e a parada antecipada.

A parada pelo valor do erro, uma das mais utilizadas, faz com que o algoritmo encerre o treinamento uma vez que o erro encontrado pela rede fique abaixo de um valor pré-definido. Para que isso ocorra, é considerado que o algoritmo de retro-propagação convergiu quando a variação do erro quadrático de uma época para a outra atingir um valor suficientemente pequeno.

3.6 CONSIDERAÇÕES FINAIS DO CAPÍTULO

O capítulo estendeu-se sobre as RNAs, sua história e desenvolvimento tecnológico, as técnicas e conceitos aplicados, foram também apresentadas as principais arquiteturas, funções de ativação, processo de aprendizagem da RNA e os tipos de algoritmos utilizados e os erro que podem ser encontrados.

Foi escolhida a arquitetura PMC para a rede utilizada na realização das previsões de carga deste trabalho. O algoritmo de treinamento da rede foi o *Scale Conjugate Gradiente*, muito utilizado quando se deseja ajustar um modelo a um conjunto de dados experimentais para realizar aproximações globais e confiáveis, com menor tempo e menores

taxas de erro.

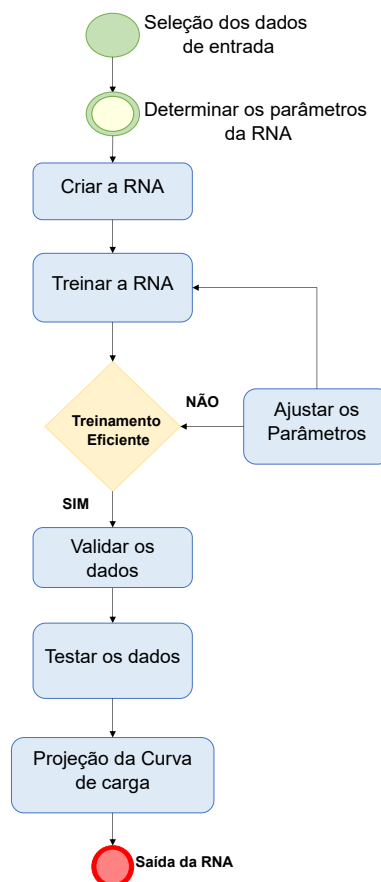
O capítulo seguinte apresenta a metodologia proposta nesse trabalho com o desenvolvimento de uma ferramenta computacional elaborada no ambiente MATLAB[®] utilizado para executar a RNA para previsão de carga a curto prazo.

4 METODOLOGIA UTILIZADA

As previsões realizadas no horizonte de curto prazo são importantes para orientar o planejamento da operação do sistema de energia elétrica e garantir a estabilidade entre produção e o consumo dessa energia. As análises em curto prazo podem apresentar resultados semelhantes e até superiores em comparação às previsões de curtíssimo, médio e longo prazo. A qualidade na previsão de carga, utilizando técnicas de inteligência artificial, está diretamente relacionada com a escolha de variáveis que mais modificam o comportamento da carga.

Deste modo, é apresentada a metodologia para realizar a previsão de demanda no horizonte de curto prazo. Essa metodologia é baseada em RNA's utilizando a arquitetura perceptron de múltiplas camadas com algoritmo de treinamento Backpropagation ou algoritmo de retropropagação do erro, já implementado em MATLAB[®]. A Figura 4.1 apresenta um fluxograma da solução testada neste trabalho.

Figura 4.1 – Metodologia de previsão de Carga pela RNA



Fonte: Autora, (2020).

Cada etapa realizada, de acordo com fluxograma da Figura 4.1, é essencial para o

funcionamento correto e satisfatório da rede neural criada. Os aspectos práticos referentes à implementação da rede perceptron de multicamadas orientam todo o projeto da rede.

Para projetar a RNA com objetivo de solucionar o problema proposto, é necessário seguir um fluxo de trabalho com seis etapas principais. Anterior a essas seis etapas, é necessário realizar uma etapa de pré criação da rede, onde são obtidos os dados para desenvolvimento desse fluxo.

A pré-criação da rede é um conjunto de dois passos importantes do processo de desenvolvimento de redes neurais artificiais. O primeiro passo é a coleta dos dados, que geralmente ocorre fora do ambiente MATLAB[®]. O segundo passo, a separação em um conjunto de treinamento e um conjunto de testes, esta tarefa requer uma análise cuidadosa sobre o problema para diminuir possíveis erros nos dados. Além disso, os dados coletados devem ser significativos e cobrir amplamente o problema.

Para o primeiro passo os dados foram organizados em demanda, consumo e temperatura, utilizados como dados históricos para a análise, na sequência separados em planilhas, em seguida carregados no MATLAB[®]. Com esses dados devidamente selecionados e inseridos ao programa, se realiza o segundo passo, em que os dados são separados em treinamento e teste para assim iniciar a criação da rede neural.

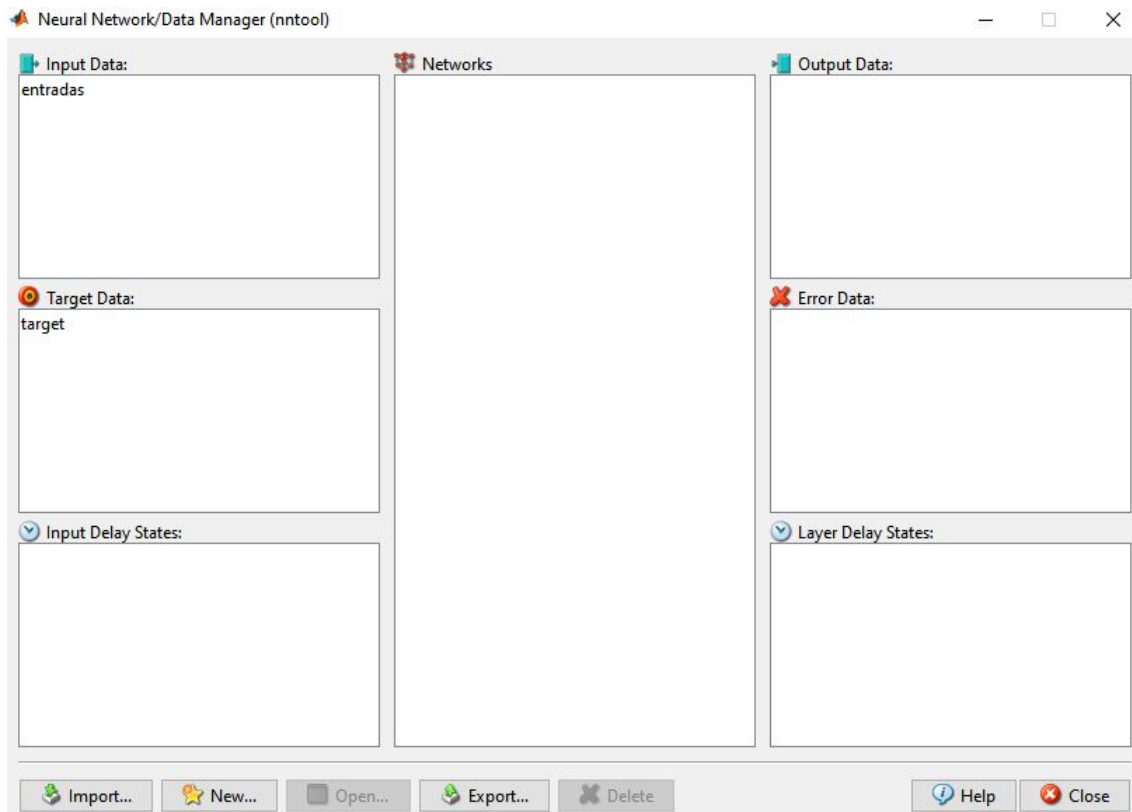
4.1 CRIAÇÃO DA RNA

A criação da rede neural artificial, é a primeira etapa de trabalho já dentro do ambiente MATLAB[®]. De acordo com a metodologia, na Figura 4.1, inicialmente são selecionados os dados de entrada, que neste trabalho são dados de consumo de energia (kWh) com intervalo de integralização da curva de carga a ser projetada (60 minutos) e dados de temperatura máxima (°C) e temperatura mínima (°C), disponibilizados por uma estação meteorológica. Também são inseridos os dados demanda média (kW), que serão o alvo (target), que a rede busca atingir em sua projeção.

Essas variáveis estão organizadas no *software Microsoft Excel* e são importadas para janela de comando do MATLAB[®]. Posteriormente, inicia-se a Interface Gráfica do Usuário (GUIs) de redes neurais (Neural Network Toolbox) no ambiente MATLAB[®]. Com os dois primeiros passos de pré-criação, coleta e separação dos dados finalizado, esses dados são separados em dois tipos de amostras.

A criação e configuração da RNA é executada, com o uso da interface gráfica *Neural Network Toolbox* (NNTool), a qual permite importar, criar, utilizar e exportar dados de redes neurais. O acesso ao NNTool começa quando a linha de comando NNTool é digitada na janela de comandos do MATLAB[®]. Uma janela denominada *Network/ Data Manager* é aberta, conforme a Figura 4.2 .

Figura 4.2 – Janela de comandos NNtool.



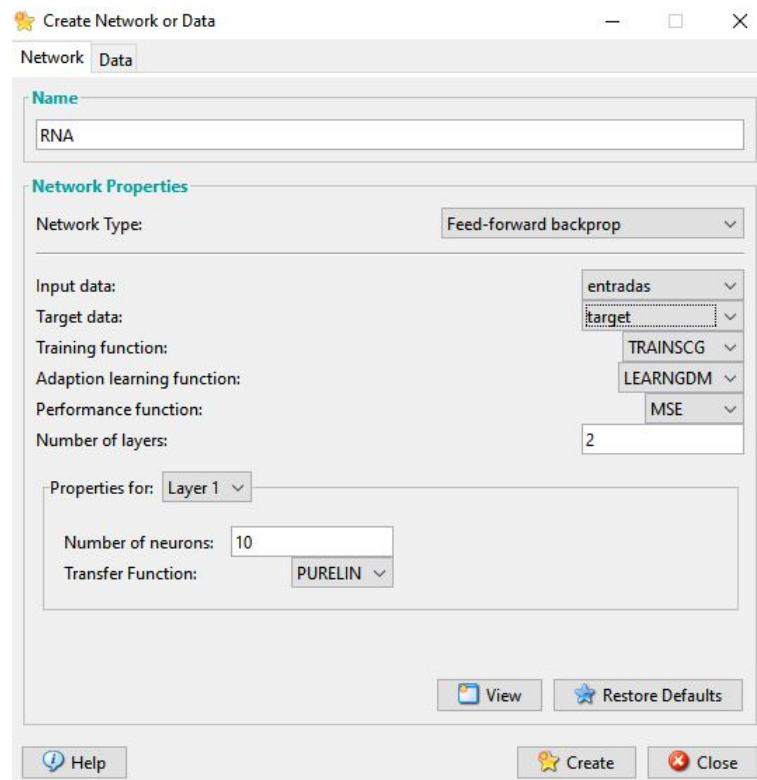
Fonte: MATLAB[®], (2020).

Na interface apresentada na Figura 4.2, são importados os dados que já estão dentro do MATLAB[®], para o sistema de criação da rede neural. A planilha de amostra de entradas do *Excel* é inserida no "*Input Data*", já a planilha amostra target, é adicionada no "*Target Data*". Após esses procedimentos é iniciada a criação da rede, com a determinação de alguns parâmetros.

A configuração de toda a rede é moldada pela determinação de seus parâmetros, iniciando uma fase de definição da RNA. Essa seleção para o treinamento da rede com o algoritmo escolhido é pouco compreendido por quem está analisando o treinamento, visto que não se sabe a função que os dados vão assumir dentro da rede, quando pequenas diferenças nestes parâmetros podem levar a grandes alterações tanto no tempo de treinamento como na generalização obtida.

A configuração da rede é o primeiro passo na etapa de criação. Na Figura 4.3 são selecionados os dados de entrada e target já importados em colunas para o MATLAB[®], nessa janela são determinados os parâmetros importantes da rede, como: tipo da rede, função de treinamento, função de adaptação de aprendizado, número de camadas, número de neurônios por camada e o tipo de função de ativação aplicada para a criação da RNA e o seu treinamento.


Figura 4.3 – Configuração da Rede Neural Artificial.



Fonte: Adaptado MATLAB[®], (2020).

Com os parâmetros devidamente selecionados, a rede é criada e gerado um diagrama a partir das configurações estabelecidas, como apresentado na Figura 4.4.

Figura 4.4 – Diagrama da Rede.



Fonte: Adaptado MATLAB[®], (2020).

O diagrama da Figura 4.4 exibe exatamente como a rede foi configurada. Uma camada de entrada com 3 dados, uma camada oculta de 10 neurônios, uma camada de 1 neurônio de saída e a saída da rede. A quantidade de camadas também influencia os resultados, porém a realização de alguns testes e pesquisas demonstram que para a

maioria dos problemas, uma camada oculta é suficiente. A partir dessa configuração o treinamento da rede é iniciado.

O sistema de treinamento é executado quando as amostras de entrada e alvo são associadas dentro da rede. Após essa associação, se torna uma única amostra de treinamento, que é fracionada em diferentes porcentagens, essa separação é a terceira etapa da atividade. A primeira parcela é do próprio treinamento, que possui 70% dos dados, estes são apresentados à rede durante o treinamento, e a rede é ajustada de acordo com seu erro.

A segunda parte é a validação, no qual normalmente são atribuídos 15%, usados para medir a generalização da rede e para interromper o treinamento quando a generalização parar de aperfeiçoar. E por fim, a parcela de teste, que assim como a validação, obtêm 15% dos dados, eles não têm efeito sobre o treinamento, portanto, fornecem uma medida independente do desempenho da rede durante e após o treinamento.

A distribuição dessas porcentagens dos dados para o treinamento pode ser aleatória ou padrão. Nessa etapa, pode haver a redistribuição dos dados, e na sequência a escolha dos pesos sinápticos e o tipo de aprendizado, obtendo eficiência na etapa de treinamento, buscando o melhor resultado para a saída.

Uma etapa fundamental na implementação de redes neurais artificiais é o treinamento. Este processo deverá ser configurado de modo que a rede aprenda uma tarefa com êxito. Então deve-se desenvolver os passos anteriores com o máximo de eficácia, para aproveitar toda a disponibilidade da etapa de treinamento.

4.2 TREINAMENTO DA RNA

A segunda etapa é o treinamento da rede, de acordo com a Figura 4.1. Nesta fase, conforme o algoritmo de treinamento escolhido, são ajustados os pesos das conexões da rede. Normalmente, os valores iniciais dos pesos da rede são números aleatórios uniformemente distribuídos, em um intervalo definido. É importante considerar, na inicialização da rede, o modo de treinamento e o tempo de treinamento para realizar os ajustes necessários.

Para efetuar esses ajustes, parâmetros de treinamento também são estabelecidos na RNA. Inicialmente é definido se a aprendizagem do treinamento é supervisionada ou não-supervisionada. Em seguida são inseridas características, como: número máximo de épocas de treinamento, erro desejado, número de iterações que aparecem na tela, taxa de aprendizado e o tempo máximo para o treinamento. Todos esses fatores são processados a partir do algoritmo escolhido.

Ao iniciar o treinamento, o algoritmo escolhido para a RNA neste trabalho foi o retropropagação do erro com o *Scale Conjugate Gradiente* (SCG), por possuir um bom

desempenho no processo de treinamento. Esse algoritmo será responsável por adequar a RNA para que ela possa desempenhar sua função. O treinamento se inicia quando os pesos sinápticos e valores de polarização estiverem corretamente ajustados. Esse é um processo que leva um determinado tempo para ser realizado, dependendo da capacidade de processamento do computador utilizado.

Com a criação da RNA, o algoritmo do (SCGB) inicia o treinamento, este algoritmo ocupa menos memória e resulta em uma menor quantidade de erros e por isso tende a realizar um maior número de iterações durante seu treinamento. A aprendizagem inicia no momento em que os dados são inseridos na entrada, a rede passa a alterar seus parâmetros, de polarização e suas sinapses.

Concluído o treinamento, são visualizados todas as variáveis de progresso utilizadas na simulação, o número de iterações realizadas, o tempo de simulação, a performance e o número de validações que foram necessárias, obtendo, assim, o desempenho do treinamento, comparando os valores de entrada com o valor alvo de demanda do período testado, obtendo a estrutura de teste para futuras projeções do sistema proposto.

Com o treinamento apresentando um bom desempenho com erros aceitáveis e respostas adequadas, pode ser iniciada a validação. Caso contrário, deve-se iniciar novamente o treinamento da rede, ajustando seus parâmetros iniciais.

4.3 VALIDAÇÃO DOS DADOS

Na etapa de validação, em que segue o fluxo da Figura 4.1, compondo 15% da parcela de treinamento da rede, é observado a capacidade de generalização da RNA, podendo obter a melhor configuração da rede. Durante esta etapa, o conjunto de validação é utilizado para determinar a performance da rede com dados utilizados. Essa performance só pode ser observada quando o processo de treinamento é encerrado.

O treinamento pode encerrar em três hipóteses: pela quantidade de iterações do treinamento, por um valor de erro mínimo aceitável ou no caso do *Toolbox* de redes neurais do MATLAB[®] encontrar um incremento no erro durante a validação. Quando o erro de validação aumenta o seu número de iterações, o processo de treinamento para imediatamente. Com isso, a performance da rede pode ser exibida, apresentando os erros de treinamento, erros de validação e erros de teste e, posteriormente, deve validar a rede ou retornar o processo de treinamento para atingir o seu melhor desempenho.

A performance da rede, medida nesta fase, é uma boa indicação de sua performance real. Devem ser considerados ainda outros testes como análise do comportamento da rede utilizando entradas especiais e análise dos pesos atuais da rede, pois se existirem valores muito pequenos, as conexões associadas podem ser consideradas insignificantes e assim serem eliminadas.

Para obter menores erros através de uma configuração mais eficiente, a rede deve ser novamente treinada com valores de entrada e saída esperados, e realizar testes com dados diferentes dos utilizados nas fases anteriores. Por fim, a validação da rede é concluída e apresenta-se os resultados do treinamento tornando-se possível a etapa de teste da rede.

4.4 TESTE DA REDE

Após a fase de treinamento e validação, é realizada a etapa de testes, Figura 4.1, com dados que ainda não foram apresentados à rede. Dessa forma, assegura-se que a rede apenas não memorizou o conjunto de treinamento, mas aprendeu os padrões gerais envolvidos em sua aplicação, mostrando que ocorreu a generalização na etapa de validação.

Novamente no ambiente NNtool do MATLAB[®], são inseridos dados armazenados em planilhas do *Excel*. Os dados de teste estão separados, assim como as amostras de entrada, em consumo, temperatura máxima e temperatura mínima. Diferente dos dados das amostras de entrada que foram utilizadas nas etapas anteriores, os dados de teste possuem um intervalo de acordo com o período de previsão que está sendo realizado.

De acordo com cada problema proposto em um sistema de previsão, é selecionado uma quantidade de dados para ser aplicado em todas as etapas anteriores, no qual a rede neural testada é executada de forma efetiva dentro da ferramenta NNToll. Diante disso, a rede retorna os dados de previsão para que a curva de carga possa ser projetada.

Contudo para questão de entendimento de cada etapa dentro do *software*, a visão é limitada em relação a manipulação da estrutura da rede. Para isso elaborou-se um exemplo didático, apresentado no apêndice "A" desse trabalho, para exemplificar entendimento de cada etapa.

4.5 CONSIDERAÇÕES FINAIS DO CAPÍTULO

Neste capítulo demonstrou-se a proposta da metodologia e a estruturação utilizada no sistema de previsão de carga no curto prazo. A partir da topologia escolhida e os procedimentos realizados, propõe-se passos e etapas para que o desenvolvimento da RNA atenda os objetivos do trabalho.

A metodologia é iniciada na etapa de pré seleção, em seguida demonstrando a etapa de criação da rede e os passos dessa criação. A partir dessa criação são desenvolvidas as etapas de treinamento, validação e testes, que desenvolvem toda a estrutura da rede, para realizar as projeções dos dados.

A topologia foi apresentada em etapas executadas dentro do *Neural Network Toolbox* (NNTool) do ambiente MATLAB[®]. Para enfatizar o desenvolvimento da metodolo-

gia de rede e seus procedimentos, também descreveu-se um exemplo didático para melhor entendimento prático de cada etapa que é apresentado no apêndice "A".

5 ESTUDO DE CASO

Para realizar a previsão de carga com a metodologia apresentada no capítulo 4, foram testadas diferentes ferramentas no ambiente MATLAB[®], a ferramenta NNtool e a programação de linhas de código no Script. Para a quantidade e tipo de variáveis utilizados neste trabalho, a utilização da ferramenta NNtoll foi mais eficiente no modelo de previsão.

Os dados empregados para o desenvolvimento da rede e para o teste, são de uma distribuidora de energia elétrica do noroeste do estado do Rio Grande do Sul. Para a aplicação da metodologia de previsão de carga de curto prazo, analisou-se valores referentes ao ano 2019, que estão armazenados no *software Microsoft Excel*, contendo os meses de janeiro e julho.

São selecionados os dois meses que possuem a maior e menor temperatura, respectivamente. Esses valores estão organizados em quatro colunas, com intervalos de 1 hora, demanda média de energia (kW), consumo de energia(kWh), temperatura máxima (°C) e temperatura mínima (°C), usados para etapas de treinamento, validação e teste da rede, a fim de realizar a avaliação do comportamento dos fatores que conseguem influenciar na demanda do sistema de energia. Estes dados de treinamento são apresentados no apêndice "B" deste trabalho, na Tabela B.1, apresentando o consumo e as temperaturas máximas e mínimas como dados de entrada e a demanda como alvo.

Nesse estudo, aplicou-se a arquitetura perceptron de múltiplas camadas, assim como no exemplo do capítulo 4, empregando-se o algoritmo (SCGB). Essa estrutura constitui-se dos seguintes nós: uma camada de entrada que possui 3 amostras, um grupo de neurônios organizados em duas camadas ocultas e uma camada de saída, que apresentará os valores de previsão dos dados inseridos na rede.

5.1 REDE NEURAL DO ESTUDO DE CASO

O estudo de caso apresentado segue as etapas da metodologia mostrada na Figura 4.1. Com o objetivo de iniciar a simulação da rede para o processo de previsão de carga, é necessário iniciar as etapas de treinamento e testar a rede com valores históricos, assim, a rede inicia o processo de aprendizagem e reconhece o padrão da curva de carga e qual a influência das demais variáveis em seu comportamento. Com os parâmetros da Tabela 5.1 para o mês de janeiro e a Tabela 5.2 para julho atribuídos a rede, o treinamento para as curvas de carga são iniciadas.

Tabela 5.1 – Parâmetros da RNA no mês de Janeiro

Parâmetros	Dados
Amostras de entrada	3
Camada Oculta 1	10
Camada oculta 2	1
Função de ativação da camada 1	Linear
Função de ativação da camada 2	Logística
Numero de iterações	104
Algoritmo de treinamento	Trainscg

Fonte: Autora, (2021).

Tabela 5.2 – Parâmetros da RNA no mês de Julho

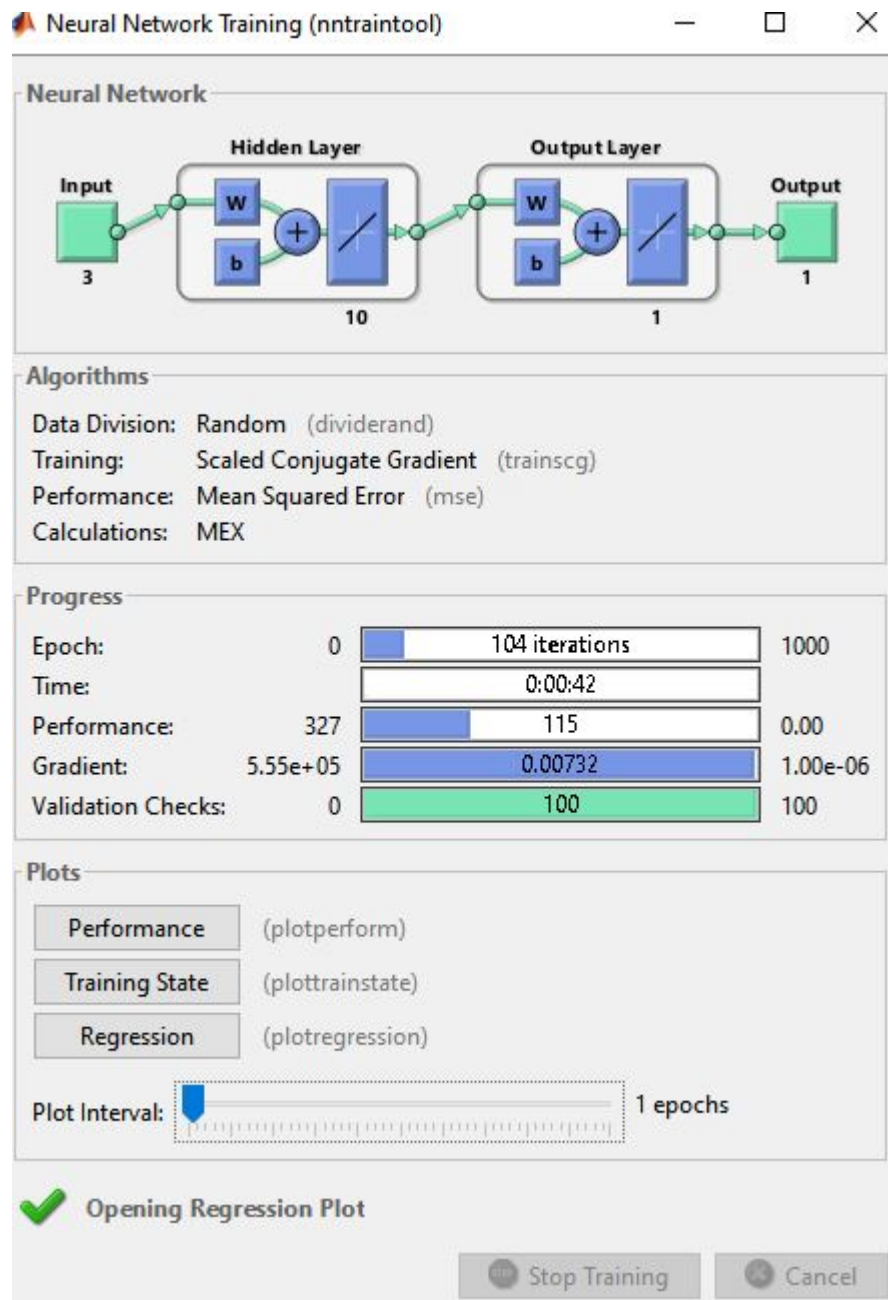
Parâmetros	Dados
Amostras de entrada	3
Amostras de saída	1
Camada Oculta 1	10
Camada oculta 2	1
Função de ativação da camada 1	Linear
Função de ativação da camada 2	Logística
Numero de iterações	76
Algoritmo de treinamento	Trainscg

Fonte: Autora, (2021).

As etapas apresentadas serão apenas referentes ao mês de janeiro, pois os dados obtidos para o mês de julho são similares. Vale salientar que o desenvolvimento de uma RNA varia de acordo com o problema em questão e o objetivo de cada projeto. Nesse trabalho, o objetivo é realizar uma previsão de demanda de 24 horas a frente do dia de teste, obtendo assim uma demanda prevista de acordo com os dados históricos, e com um MSE bem próximo de zero, dentro dos critérios definidos, e para isso alguns ajustes são feitos para melhorar esse desempenho da rede.

Após ser iniciada com os devidos parâmetros, a rede conclui sua etapa de treinamento, retornando seus dados de aprendizado para serem utilizados na etapa de validação, testes e previsão, seguindo o fluxo proposto na metodologia da Figura 4.1. A janela de treinamento da Figura 5.1 tem como objetivo apresentar a utilização correta das escolhas dos parâmetros iniciais, além disso, apresentar a estrutura gerada pela rede para desenvolver a metodologia de previsão.

Figura 5.1 – Janela de Treinamento do estudo.



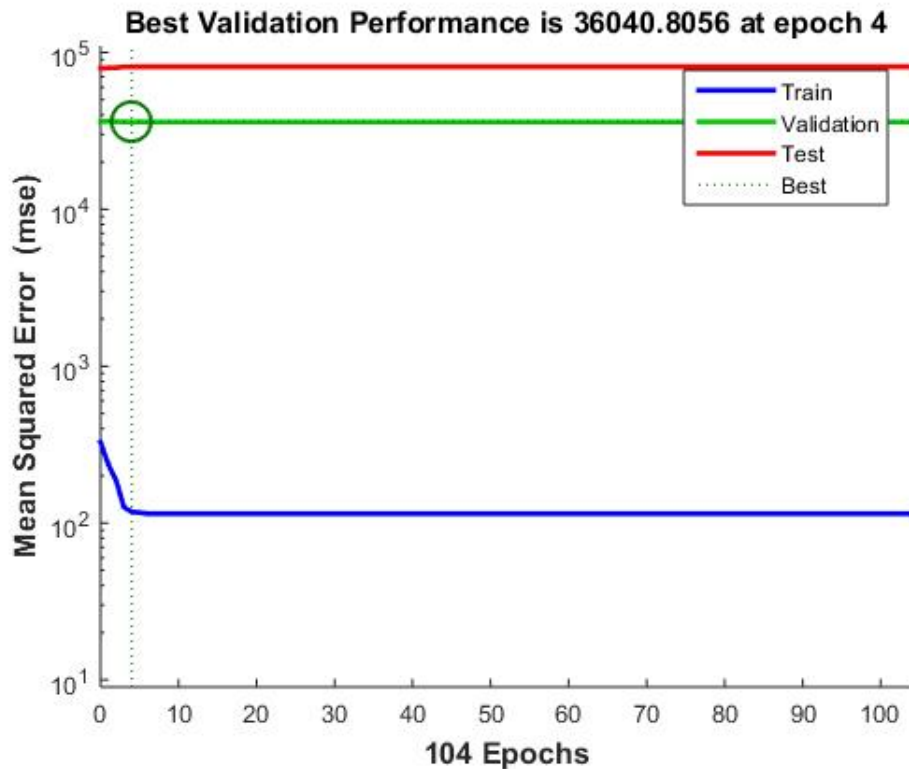
Fonte: Adaptado MATLAB[®], (2021).

O primeiro detalhe apresentado na janela de treinamento da Figura 5.1, é a estrutura criada na rede e que foi utilizada no seu processo de treinamento. Em seguida é exibido informações sobre o algoritmo de treinamento *Scale Conjugate Gradiente*, utilizado para otimizar a aprendizagem, o número de iterações que a rede realizou para atingir o critério de parada pré-definido, o tempo de treinamento, a performance e demais parâmetros envolvidos neste processo.

A partir dos dados de progresso do treinamento e dos parâmetros inicialmente

testados, a janela de treinamento também retorna a performance da rede, Figura 5.2, e a regressão, Figura 5.3, das etapas de treinamento, validação e teste, e uma regressão geral de todos os processos validados pela rede.

Figura 5.2 – Janela de performance do estudo.



Fonte: Adaptado MATLAB[®], (2021).

A Figura 5.2 mostra a representação gráfica da performance da rede após o término do treinamento, sendo possível observar que a RNA atingiu o critério de parada pré-definido 1×10^{-2} em 104 épocas.

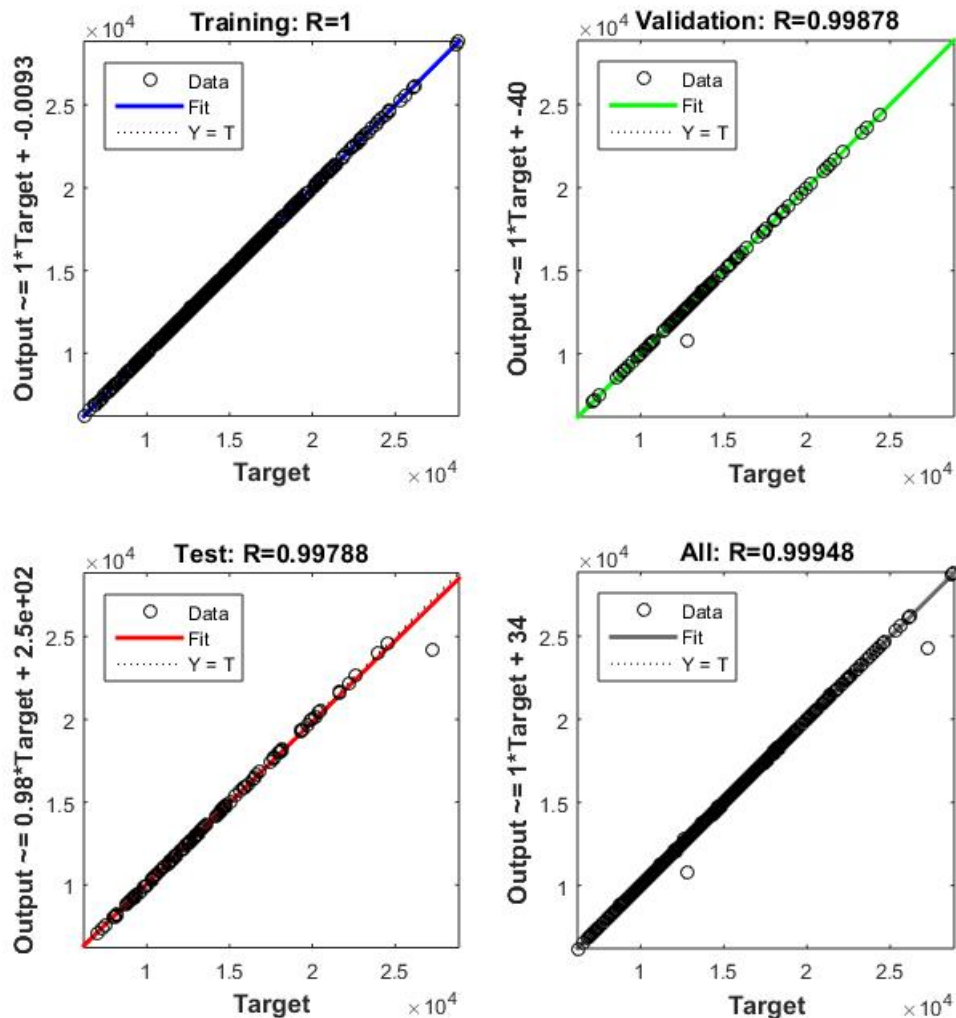
Neste estudo, o resultado apresentado é satisfatório devido as seguintes observações:

- O erro médio quadrático final é pequeno, igual a 1×10^{-2} ;
- O erro do conjunto de testes e de validação têm características semelhantes;
- Nenhum ajuste significativo ocorreu na iteração 4, onde ocorre o melhor desempenho de validação.

O desempenho apresentado pela rede nessa etapa é uma boa indicação da performance real da RNA, possibilitando assim, analisar a regressão da rede. Devido a previsão de dados mais complexos, são realizadas regressões múltiplas para cada época testada no treinamento.

Para ser efetiva a regressão, os valores devem estar entre 0 e 1, projetando a regressão linear de cada etapa proposta na metodologia da Figura 4.1, em que os conjuntos de dados foram separados em 70% de dados de treinamento, 15% de dados de validação e 15% de dados de teste.

Figura 5.3 – Janela de regressão do estudo.



Fonte: Adaptado MATLAB[®], (2021).

A Figura 5.3 apresenta, nas quatro análises, a plotagem entre a saída da rede versus o alvo (Target) com círculos abertos. O melhor ajuste linear é indicado pela linha tracejada e o ajuste perfeito, em que a saída é igual ao alvo, é indicado pela linha contínua em azul, verde, vermelho e preto. A quarta regressão mostrada "All" é equivalente a regressão de todos os conjuntos de dados juntos, sem a separação inicial de 70%, 15% e 15%, em que é possível notar a importância de realizar a separação dos conjuntos. Com essa separação,

o processo de treinamento atingiu o ajuste perfeito durante o treinamento da rede.

Para a regressão de treinamento com $R=1$, e as demais projeções que possuem a regressão próximo a 1, indicam que o modelo proposto é adequado para validar os testes realizados com todos os conjuntos de dados. Após efetuado o treinamento da RNA, o passo seguinte é a simulação da mesma, perante os pesos encontrados.

A projeção da curva de carga é a última etapa realizada dentro da rede, de acordo com a metodologia exposta na Figura 4.1. Portanto assim como o conjunto de dados é separado para desenvolver todas as etapas da rede, para a projeção de carga também ocorre uma separação. Um conjunto de dados teste de projeção é inserido dentro da rede no momento de sua criação, porém somente é utilizado quando a etapa de previsão é iniciada.

Quando é iniciada a etapa de projeção de carga, o conjunto de dados teste separado no processo de treinamento da rede se torna a nova camada de entrada, e o novo conjunto teste inserido torna-se o novo target da rede, fazendo com que a rede incie a simulação, encontrando como resultado, os dados de demanda prevista.

Os dados de teste de previsão que são inseridos após o treinamento da rede, estão separados conforme o problema proposto. Com os resultados obtidos na projeção do conjunto de testes, apontando-se como adequado, a próxima etapa é organizar os dados para a projeção de curva de carga para 24 horas a frente.

5.2 PROJEÇÃO DA CURVA DE CARGA

A projeção da curva de carga desse estudo é gerada a partir de um novo conjunto de dados para testes, apresentado pela Figura 5.4, se tornando a nova camada de entrada da rede já treinada. A Figura 5.4 (a), apresenta a organização dos dados referente as 24 horas do dia 01/02/2019, e a Figura 5.4 (b) apresenta os dados referente as 24 horas do dia 01/08/2019, em que as variáveis x_1 , x_2 e x_3 representam os dados de consumo(kWh), temperatura máxima($^{\circ}\text{C}$) e temperatura mínima($^{\circ}\text{C}$), respectivamente.

As colunas dessas variáveis, que estão no excel, são importadas para janela de comando do MATLAB[®] como entrada de teste, posteriormente é iniciado o processo de simulação da rede. A etapa de simulação é realizada no bloco de projeção da curva de carga mostrado na Figura 4.1.

Iniciando a simulação da rede, em que os dados gerados a partir do aprendizado obtido no treinamento da rede são associados a nova camada de entrada, é obtido como resposta desse processamento, os dados previstos de demanda, possibilitando, assim, realizar as projeções das curvas de carga, como exibido nas Figuras 5.5 e 5.6.

Consumo (kWh)	Temperatura Max (°C)	Temperatura Min (°C)
16829,07	23,1	22,8
15735,4	22,8	22,4
15069,48	22,6	22,4
14368,2	22,4	22,1
13799,55	22,2	21,7
13720,49	21,7	21,3
14529,84	21,4	21,2
18924,69	21,2	20,8
20800,16	20,9	20,4
20836,65	22,8	20,9
21550,74	24,8	22,8
19368,48	27,1	24,8
22654,68	29,4	27,1
25079,25	31,1	29,3
24500,77	32	30,1
23395,69	32,4	31,5
19778,69	32,2	28,5
15581,61	30,3	28,2
14848,54	28,9	28,2
14918,89	28,2	26,9
15190,77	26,9	25,7
15011,42	25,7	24,5
14976,97	24,5	23,9
14332	24,1	23,6

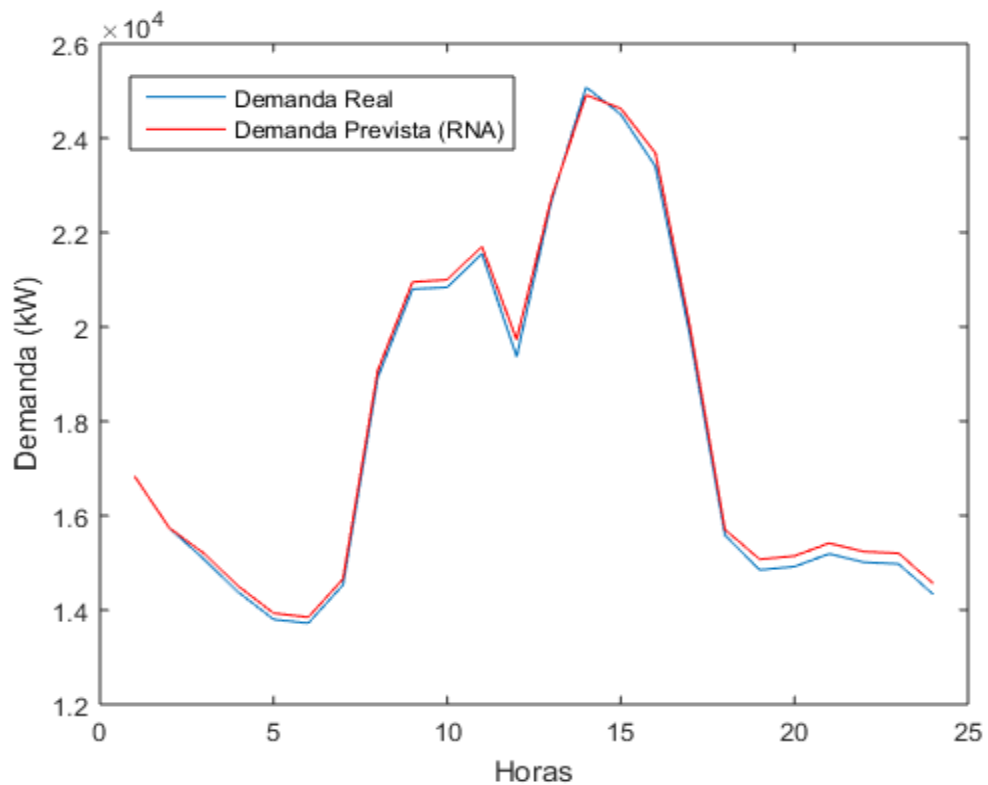
(a)

Consumo (kWh)	Temperatura Max (°C)	Temperatura Min (°C)
2054,995453	17,2	16,4
1585,566521	16,4	16,1
1359,267632	16,4	16,2
1253,568771	16,4	15,9
1241,850655	16,2	16
1287,90316	16,1	15,7
1639,305901	16,2	15,7
2050,833557	16	15,7
2185,038498	15,8	15
2249,12059	18,4	15,8
2453,071777	21,5	18,4
2954,955154	24,2	21,5
2369,953766	25,8	24,3
2272,773224	26,9	25,8
2484,525833	27,4	26,4
2329,458603	27,9	27,1
1893,088272	28	27,1
2336,142899	27,4	25,9
3928,700531	25,8	23,3
4442,68222	23,3	20,7
3840,197021	20,7	19,1
3342,86676	19,1	15,4
2810,912628	15,4	12,3
1808,188705	12,3	11

(b)

Figura 5.4 – (a) Dados de Fevereiro ; (b) Dados de Agosto.

Figura 5.5 – Projeção de Curva de carga 02/02/2019.




Fonte: Autora, (2021).

A Figura 5.5 demonstra a previsão da curva de carga do dia 02/02/2019, com dados integralizados em intervalos de 1 hora. Para o treinamento da RNA, foi considerado as variáveis históricas no período do dia 01/01/2019 a 31/01/2019, resultando em 743 amostras. Após retornar os valores previstos, realizou-se a normalização desses valores para obter os índices de erro.

Os dados de previsão da rede neural foram padronizados para o intervalo de -1 a 1, pelo processo de normalização dos dados. O desempenho do treinamento da rede, considerando as equações (3.7), (3.8) e (3.9), apresentou um índice de erro MSE de 0,10 % e um MAPE de 0,20%.

Figura 5.6 – Projeção de Curva de carga 02/08/2019.




Fonte: Autora, (2021).

A Figura 5.6 demonstra a previsão da curva de carga do dia 02/02/2019 com dados integralizados em intervalos de 1 hora. Para o treinamento da RNA foi considerado as variáveis históricas no período do dia 01/07/2019 a 31/07/2019, resultando em 743 amostras. O desempenho do treinamento da rede apresentou um índice de erro MSE de 0,77 % e um MAPE de 3,34%, de acordo com os cálculos realizados com as equações 3.7, 3.8 e 3.9.

Para obter mais detalhes do comportamento e eficiência da RNA, também foram realizadas projeção para o dia 28/12/2019, que representa o dia com maiores temperaturas do ano, apresentado na Figura 5.7.

Figura 5.7 – Projeção de Curva de carga 28/12/2019.

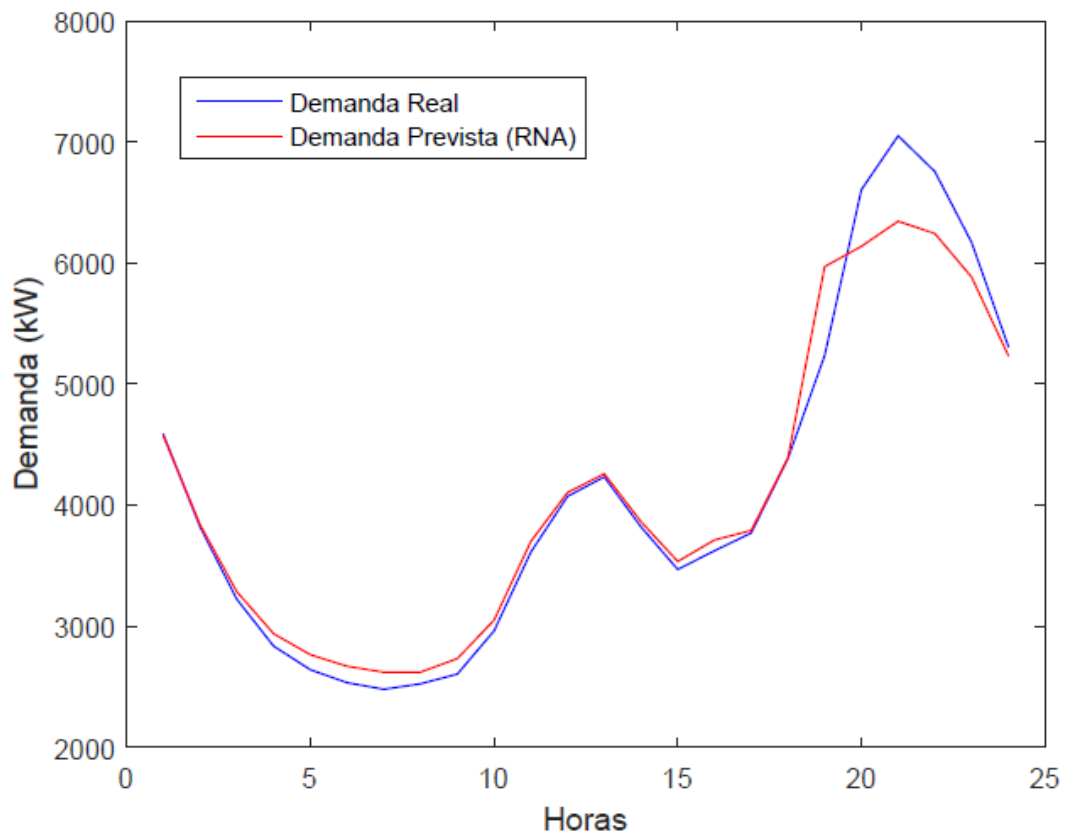


Fonte: Autora, (2021).

Na Figura 5.7 é obtida a projeção da curva de carga do dia 28/12/2019, com dados integralizados em intervalos de 1 hora. Assim, como na projeção realizada na Figura 5.5 os índices de erros obtidos na previsão foram baixos, mostrando a eficiência da rede treinada, retornando um MSE de 0,80% e um MAPE de 1,14%. Além de ser o dia mais quente do ano, o dia 28/12/2019 é em um sábado, o que se torna o fim de semana mais um fator de influência, que pode modificar o comportamento da demanda.

O comportamento da projeção de curva de carga apresentado na Figura 5.8, representa a previsão para o dia 07/07/2019, sendo o dia com as menores temperaturas de todo o ano. Esse dia utilizado para realizar a previsão também é durante um final de semana.

Figura 5.8 – Projeção de Curva de carga 07/07/2019.



Fonte: Autora, (2021).

A partir de Figura 5.8 é mostrada a projeção da demanda do dia 07/07/2019. Para realizar essa projeção foram utilizados os dados de teste obtidos no processo de treinamento da RNA foi considerado as variáveis históricas. O desempenho do treinamento da rede apresentou um índice de erro MSE de 2,27 % e um MAPE de 3,87%. O dia utilizado nessa previsão marcou as menores temperaturas durante todo o ano e durante as 24 horas ocorreu uma variação brusca na temperatura, o que impactou diretamente o comportamento da carga, e que também foi identificado durante o processamento da rede, aumenta assim os índices de erros.

Realizou-se o teste com diferente dias em períodos do ano, analisando os dias mais quentes e mais frios de 2019 em relação a quantidade de demanda real. Nos dias dos meses que apresentam temperaturas menores, como em julho e agosto, a demanda é maior, e nos meses de fevereiro e dezembro, em que as temperaturas são maiores, conseqüentemente a demanda é menor. Mostrando assim, que a utilização de equipamentos de aquecimento do ambiente nos períodos de menores temperaturas, alteram significativamente o comportamento da demanda, comprovando a interferência direta do comportamento da carga

com a variação da temperatura.

Através da comparação dos valores projetados pelo sistema com os valores reais da curva de carga, pode ser visualizado o comportamento do desempenho da simulação. Esse estudo de caso confirmou a precisão do algoritmo SCGB escolhido, mostrando que as redes neurais MLP são capazes de fornecer bons resultados.

Tabela 5.3 – Análise dos indicadores de erros das projeções realizadas.

Dias de Curvas Projetadas	MSE	MAPE
02/02/2019	0,10%	0,20%
02/08/2019	0,77%	3,34%
28/12/2019	0,80%	1,14%
07/07/2019	2,27%	3,87%

Fonte: Autora, (2021).

A Tabela 5.3 contém os dias utilizados para realizar a previsão de demandada, também mostra os resultados dos índices de erros encontrados nas projeções das curvas de carga com a RNA desenvolvida. Analisou-se que os melhores resultados dependem do comportamento histórico da curva de demanda e de um treinamento eficiente. Desta maneira, sistemas que possuem uma curva de carga diária semelhante, sem muitas variações, apresentam uma melhor eficiência durante o treinamento, logo melhores resultados nas projeções.

Através da análise dos erros foi possível verificar que o método de previsão de demanda testado se adequou com as características de sazonalidade. Além disso, os valores de MSE e MAPE apresentaram resultados satisfatórios, o que faz com que o método testado seja uma opção vantajosa para esse sistema de previsão.

5.3 CONSIDERAÇÕES FINAIS DO CAPÍTULO

Neste capítulo foram apresentados os resultados da previsão de carga no curto prazo de acordo com o estudo de caso, utilizando os dados históricos reais de consumo, demanda e temperatura. Com o sistema predictor testado, foi possível comprovar que as variáveis de consumo, demanda e temperatura utilizadas nas simulações têm forte impacto no comportamento da carga.

Através dos testes realizados, percebeu-se que os valores dos parâmetros usados para treinamento, relativo aos melhores resultados, para os dois meses testados, são equivalentes.

6 CONCLUSÃO

6.1 CONSIDERAÇÕES FINAIS

A previsão de demanda de energia elétrica é essencial para estabelecer o funcionamento adequado do sistema elétrico. Para isso, são realizados estudos e desenvolvimento de metodologias para elaborar previsões com maior qualidade e confiabilidade, utilizando técnicas para resolução de problemas reais de previsão em diferentes horizontes de análises.

Ferramentas computacionais, tais como RNAs, são objetos de estudos em todo o mundo e estão em constante aperfeiçoamento dos modelos propostos para a evolução da previsão de carga. As RNAs têm se mostrado muito eficientes na projeção de previsões de curto prazo para cargas elétricas, aplicando diferentes topologias aliadas a ferramentas e metodologias para obter resultados satisfatórios.

Neste trabalho realizou-se o desenvolvimento de testes, para elaborar uma previsão de demanda de curto prazo com influência da variável de temperatura, utilizando dados históricos. Como ferramenta para realizar esses testes, aplicou-se redes neurais artificiais, a qual foi estruturada no MATLAB[®] para executar a previsão.

Inicialmente neste trabalho, discorreu-se as características mais importantes do comportamento não-linear de uma curva de carga, e os fatores que influenciam esse comportamento. Na sequência, foram apresentados horizontes em que são realizadas previsões futuras dessas curvas de demanda, de acordo com as influências sofridas. Também apresentou-se alguns trabalhos já publicados sobre as ferramentas e metodologia de previsão proposta neste trabalho.

Mostrou-se uma explicação teórica a respeito das Redes Neurais Artificiais, iniciando pelo princípio de desenvolvimento da IA, base de criação da RNA, expandindo-se ao estudo das diversas funções de ativação, arquiteturas, métodos de aprendizado, algoritmos e erros obtidos e aplicado à RNA. Apresentou-se ainda uma visão detalhada da arquitetura de rede Perceptron de Múltiplas Camadas (MLP), aplicada no processo de aprendizagem das redes, juntamente com o algoritmo *backpropagation* (SCGB) utilizado neste estudo.

De acordo com o que foi exposto, apresentou-se uma metodologia e todas as etapas necessárias e passos usados para utilização dessa metodologia. Como isso, expô-se a manipulação dos dados aplicados a metodologia, e como eles foram manuseados dentro do MATLAB[®], desde a programação no Script, até a criação a partir do *toolbox*.

Foram treinadas diversas configurações de redes para obter um melhor resultado, pelo método da tentativa e erro, no qual se obtivesse a menor média do erro quadrático (MSE), teria a melhor configuração. Em todas as redes foram testadas a arquitetura

Multilayer Perceptron (MLP), no qual foi utilizado o algoritmo Backpropagation (SCGB). Para todas as redes e modelos, a função de ativação da camada oculta foi linear e para a camada de saída foi a função de ativação logística.

Com todos os parâmetros escolhidos de acordo com as melhores respostas nos primeiros processamentos da RNA, realizou-se a criação, o treinamento, a validação e os testes da rede, encontrando porcentagens de erro com valores pequenos, mostrando que a rede teve um desenvolvimento eficiente baseado em seus conjuntos de dados. Com isso, aplicado a um estudo de caso, a rede foi testada para projetar a curva de carga do sistema.

Elaborou-se um estudo de caso para realizar a previsão de demanda, com horizonte de projeção para 24 horas à frente. A partir dos treinamentos já realizados pela rede e os resultados obtidos, foi possível a realização de teste com um conjunto de dados de dois meses distintos. Os treinamentos foram realizados com dados do mês de janeiro e julho, por representarem através de análises estatísticas temperaturas que influenciaram de forma expressiva a curva de carga nos 31 dias desses meses.

Os resultados obtidos e apresentados pelas curvas projetadas no estudo de caso, comprovam a eficácia da rede com os parâmetros escolhidos. A melhor resposta de previsão ocorreu no mês de fevereiro, apresentando MSE de 0,10% e MAPE de 0,20%. Dessa maneira, as Redes Neurais Artificiais constituem-se numa técnica eficiente no que se refere à identificação e previsões de sistemas não-lineares, com a possibilidade de aplicações nas mais diversas áreas do conhecimento.

6.2 TRABALHOS FUTUROS

Baseado neste trabalho e considerando os resultados obtidos, como trabalhos futuros propõe-se a implementação das RNA tendo em vista novos testes com diferentes arquiteturas e algoritmos para observar o comportamento da rede. Desenvolver um algoritmo no *Script* do MATLAB[®], com a manipulação dos parâmetros da rede de forma a se tornar mais eficiente do que a ferramenta *toolbox* já oferecida.

Realizar previsões com diferentes conjuntos de dados para obter projeções com horizontes de curtíssimo, médio e longo prazo e inserir ao estudo outras variáveis para avaliar suas influências sobre demanda de energia, podendo alcançar planejamentos de curva cada vez mais exatos, contribuído para o desenvolvimento do SEP.

REFERÊNCIAS

Abdel-Aal, R. E., Al-Garni, A. Z., Al-Nassar, Y. N. (1997). **Modelling and forecasting monthly electric energy consumption in eastern Saudi Arabia using abductive networks.**Energy, 22(9), 911-921.

Agência Nacional de Energia Elétrica (Brasil). **Atlas de energia elétrica do Brasil / Agência Nacional de Energia Elétrica.** 3. ed. Brasília : Aneel, 2008.

ALMEIDA, Lucas Gonçalves Martins de. Multi-Layer Perceptron para previsão de demanda do setor automobilístico no Brasil. 2018. 59 f. Trabalho de Conclusão de Curso Bacharelado em Engenharia de Produção - Universidade Tecnológica Federal do Paraná. Ponta Grossa, 2018.

ALTRAN, A. B. **Sistema Inteligente para Previsão de Carga Multinodal em Sistemas Elétricos de Potência.** Tese (Doutorado em Engenharia) - Universidade Estadual Paulista - Faculdade de Engenharia, Ilha Solteira, 2010.

ANDRADE, L. C. M. **Abordagem Neurofuzzy para Previsão de Demanda de Energia Elétrica no Curtíssimo Prazo.** Dissertação (Mestrado de Engenharia Elétrica) -Escola de Engenharia de São Carlos - Universidade de São Paulo Programa de Engenharia Elétrica, São Carlos, 2010.

ANDRADE, T. ; Lobão, W. (1997). **Elasticidade renda e preço da demanda residencial de energia elétrica no Brasil.** Rio de Janeiro: IPEA (Texto para Discussão, n. 489).

AMORIM, A.J.**Previsão de carga multinodal formulada via rede neural baseada na Teoria da Ressonância Adaptativa com treinamento direto e reverso /**Aline Jardim Amorim.-Ilha Solteira:[s.n],2019.88f.:il.

BEECHER, J. A.; KALMBACH, J. A. **Climate change and energy. U.S. National Climate Assessment Midwest Technical Input Report.** 2012.

BERNARDON, Daniel.P. *Análise do efeito de variáveis climáticas sobre a evolução da demanda de energia elétrica.* XVIII Congresso Brasileiro de Automática, 16 set. 2010.

BINOTI, M. L. M. S. **Redes neurais artificiais para prognose da produção de povoamentos não desbastados de eucalipto.** 2010. 64 f. Dissertação (Mestrado em Ciência Florestal)- Universidade Federal de Viçosa, Viçosa, MG, 2010.

BORDIGNON, S. **Metodologia para previsão de carga de curtíssimo prazo considerando variáveis climáticas e auxiliando na programação de despacho de pequenas centrais hidrelétricas.** Dissertação (Mestrado em Engenharia Elétrica)- Universidade Federal do Pampa, Alegrete, 2012.

Brasil, Ministério de Minas e Energia, Empresa de Pesquisa Energética. **Plano Decenal de Expansão de Energia 2027** / Ministério de Minas e Energia. Empresa de Pesquisa Energética. Brasília: MME/EPE, 2018.

Brasil, Ministério de Minas e Energia, Empresa de Pesquisa Energética. **Plano Decenal de Expansão de Energia 2020** / Ministério de Minas e Energia. Empresa de Pesquisa Energética. Brasília: MME/EPE, 2011 2 v.: il.1. Energia_Brasil. 2. Política Energética_Brasil 3. Recursos Energéticos_Brasil.

BURILLO, D., Chester, M. V., Pincetl, S., Fournier, E. D., & Reyna, J. (2019). **Forecasting peak electricity demand for Los Angeles considering higher air temperatures due to climate change**. Applied Energy, 236, 1-9.

CAMPOS, R. J. **Previsão de séries temporais com aplicações a séries de consumo de energia elétrica**. 2008. 110 f. Dissertação (Mestrado em Engenharia Elétrica)-Universidade Federal de Minas Gerais. Belo Horizonte, 2008.

CAIO, Leonardo Santos. **Análise das Metodologias de Previsão de Mercado de Energia Elétrica: Relações Macroeconômicas e o Novo Perfil de Planejamento no Ambiente Pós-Privatização**. 1998. Dissertação (Mestrado em Energia) - Energia, Universidade de São Paulo, São Paulo, 1998.

CARVALHO, Monara Pereira da Rosa. **Previsão de demanda de um prédio universitário por redes Neurais Artificiais** /Morana Pereira da Rosa Carvalho.– Ilha Solteira -SP:[s.n],2017 . 62f.:il. Disertação (mestrado) Universidade estadual Paulista. Faculdade de engenharia de Ilha Solteira. Área de conhecimento: Automação 2017.

CASARIN, K. V. **Relação entre a demanda de energia elétrica e temperatura: Metodologia para previsão de carga utilizando simulação numérica de Tempo**. 2018. 63 f. Dissertação (Mestrado em Meteorologia) Universidade Federal de Santa Maria, Santa Maria, 2018.

CRUZ, R. M. Santa. "**Análise e Otimização de Superfícies Seletivas de Frequência Utilizando Redes Neurais Artificiais e Algoritmos de Otimização Natural**" , Tese de Doutorado, Universidade Federal do Rio Grande do Norte, Natal[RN],2009.

CHEMETOVA, S.R., Santos, P. and Ventim-Neves, M. (2017). **Short Term Load Forecasting in Smart Grids: Case Study of the City of Évora**. Journal of Information Systems Engineering & Management, 2(3), 18.

DA SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais para Engenharia e Ciências Aplicadas: fundamentos teóricos e aspectos práticos**. Artliber , 2ª edição, São Paulo, 2016.

DIN, Ghulam & Marnerides, Angelos. (2017). **Short term power load forecasting using Deep Neural Networks**. 594-598. 10.1109/ICCNC.2017.7876196.

DILLON, T. S., Sestito, S., & Leung, S. (1991). Short term load forecasting using an adaptive neural network. **International Journal of Electrical Power & Energy Systems**, 13(4), 186192. doi:10.1016/0142-0615(91)90021-m.

DOMINGUEZ, Melgar Ozy Daniel. **Planejamento de curto prazo de redes de distribuição de energia elétrica considerando incertezas na geração e demanda**-Tese (doutorado) - Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira. Área de conhecimento: Automação, 2018.

EPE , **Balanco Energético Nacional 2019**: Ano base 2018 / Empresa de Pesquisa Energética. - Rio de Janeiro : EPE, 2019.

FERNEDA, E. **Redes neurais e sua aplicação em sistemas de recuperação de informação**. Ci. Inf., Brasília, v.35, n. 1, p.25-30, 2006.

FIORIN, D. V.; MARTINS, F. R.; SCHUCH, N. J.; PEREIRA, E. B. **Aplicações de redes neurais e previsões de disponibilidade de recursos energéticos solares**. Revista Brasileira de Ensino de Física, v. 33, n. 1, p. 1309, 2011.

FRIZZO, L. A. Aplicação de Redes Neurais Artificiais na Identificação de Sistemas Não-lineares: Estudo de Caso em Motor de Indução Trifásico. 2019. Trabalho de Conclusão de Curso. Curso de Engenharia Elétrica, Universidade Regional do Noroeste do Estado do Rio Grande do Sul ? UNIJUÍ, Ijuí, 2019.

GENYONG, C. and S. Jingtian, **Study on the methodology of short-term load forecasting considering the accumulation effect of temperature**. 2009 International Conference on Sustainable Power Generation and Supply, Nanjing, 2009, pp. 1-4.

GUIRELLI, Cleber Roberto. **Previsão da Carga de Curto Prazo de Áreas Elétricas através de Técnicas de Inteligência Artificial**- Tese (Doutorado) Escola Politécnica da Universidade de São Paulo. Departamento de Engenharia de Energia e Automação Elétricas, 2006.

HAYKIN, S. **Redes Neurais: princípio e prática**. 2. ed. Porto Alegre: Bookman, 2001.

HAYKIN, S. **Neural networks: a comprehensive foundation**. Canada: Pearson, 1999. 823 p.2008.

HAYKIN, S. **Neural Networks and Learning Machines**. 3. ed. New Jersey: Prentice Hall, 2009.

HERINGER,R.M."**Análise e projeção do mercado de energia elétrica no Brasil**".**Monografia em Engenharia Elétrica**. Escola de Engenharia de São Carlos da Universidade de São Paulo,SP,2010.

IPCC - PAINEL INTERGOVERNAMENTAL DE MUDANÇAS CLIMÁTICAS. AR5 Quinto Relatório de Avaliação do IPCC, 2013.

- KLEIN, Leonardo Pitta. **PREVISÃO DE DEMANDA DE ENERGIA ELÉTRICA E APLICAÇÃO NO HORIZONTE DE CURTO PRAZO**. 2014. 113 f. TCC (Graduação) - Curso de Engenharia Elétrica, Departamento de Engenharia Elétrica, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2014. Cap. 2.
- KHADSE, C. B.; CHAUDHARI, M. A.; BORGHATE, V. B. **Electromagnetic Compatibility Estimator Using Scaled Conjugate Gradient Backpropagation Based Artificial Neural Network**. IEEE Transactions on Industrial Informatics, v. 13, n. 3, Junho 2017.
- K. S. Swarup and B. Satish, "Integrated ANN approach to forecast load," in **IEEE Computer Applications in Power**, vol. 15, no. 2, pp. 46-51, April 2002.
- KHEIRKHAH, A.; AZADEH, A.; SABERI, M.; AZARON, A.; SHAKOURI, H., **Improved estimation of electricity demand function by using of artificial neural network, principal component analysis and data envelopment analysis**. Computers & Industrial Engineering, v. 64, n. 1, p. 425-441, Jan. 2013.
- KHWAJA, AS, Zhang, X., Anpalagan, A. e Venkatesh, B. (2017). **Redes neurais aprimoradas para melhor previsão de carga elétrica de curto prazo. Pesquisa sobre sistemas de energia elétrica**.
- KWON, B. R. Park, S. Jo e K. Song, "Análise de previsão de carga de curto prazo usando algoritmo de rede neural artificial de acordo com a normalização e seleção de dados de entrada em dias da semana", 2018 IEEE PES Asia-Pacific Power and Energy Engenharia Civil (APPEEC) , Kota Kinabalu, 2018, pp. 280-283.
- LI, S., Wang, P., & Goel, L. (2015). **Short-term load forecasting by wavelet transform and evolutionary extreme learning machine**. Electric Power Systems Research, 122, 96103.
- LOPES, M. L. M.; "Desenvolvimento de Redes Neurais para Previsão de Cargas Elétricas de Sistemas de Energia Elétrica". Tese (Doutorado) Universidade Estadual Paulista "Julio de Mesquita Filho", Faculdade de Engenharia, Ilha Solteira, Dez. 2005.
- Medeiros, Romero & Winkeler, Bruno & Villanueva, Juan Moises & Molina, Yuri & Macedo, Euler & Macedo, Helon. (2016). **Previsão de demanda a médio prazo aplicada em dados reais do sistema de distribuição: uma comparação entre RNA e Lógica Fuzzy**. Revista Principia - Divulgação Científica e Tecnológica do IFPB. p75-85.
- MCCULLOCH, W. e Pitts, W. (1943). "A Logical Calculus of Ideas Immanent in Nervous Activity", Bulletin of Mathematical Biophysics 5: 115-133.
- MCNEIL, M. A.; LETSCHERT, V. E. **Future air conditioning energy consumption in developing countries and what can be done about it: The potential of efficiency in the residential sector**. eScholarship - Open Access Publications from the University of California, Lawrence Berkeley National Laboratory, p. 1-14, 2008.

MILKE, Tafarel Franco. **Metodologia para previsão de carga no horizonte de curto prazo utilizando redes neurais/** Tafarel Franco Milke.-2019. Dissertação(mestrado) ? Universidade Federal de Santa Maria, Centro de Tecnologia, Programa de Pós Graduação em Engenharia Elétrica, RS, 2019.

MOLLER, Martin Fodslette. **A Scaled Conjugate Gradient Algorithm for Fast Supervised Learning. Neural Networks**, v. 6, n. 4, p. 525-533, 1993.

MOREIRA, M. Olinto,1986- **Um estudo de caso para a previsão de carga de médio e longo prazo brasileira/** Max olinto Moreira-Campinas, SP:[s,n],2015. Dissertação (mestrado)- Universidade Estadual de Campinas, Faculdade de Engenharia de Computação, 2015.

ONS,Operador Nacional do Sistema. **Programa Mensal de Operação Energética (PMO)**. 2020. Elaborado por ONS.

PASCHOALINO, F. F. et al. **Previsão de demanda de energia elétrica no Brasil**. In XVIII SIMPÓSIO DE PESQUISA OPERACIONAL E LOGÍSTICA DA MARINHA, 2007, Rio de Janeiro. Anais [...].Rio de Janeiro: SPOLM, 2007.

PARKPOOM, S.; Harrison, G. P.; Bialek, J. W., 2004,"**Climate change impact on electrivity demand-** Proceeding of 39th University Power Engineering Conference - UPEC2004, Vol. 2, pp. 1342-1346.

PIRES, Camilla Leimann. **Metodologia para previsão de carga e geração no horizonte de curtíssimo prazo**. 2016. 98 f. Dissertação (Doutorado) - Curso de Engenharia Elétrica, Programa de Pós-graduação em Engenharia Elétrica, Universidade Federal de Santa Maria (UFSM,RS), Santa Maria, 2016. Cap. 2.

PBMC, 2016: **Mudanças Climáticas e Cidades. Relatório Especial do Painel Brasileiro de Mudanças Climáticas** [Ribeiro, S.K., Santos, A.S. (Eds.)]. PBMC, COPPE- UFRJ. Rio de Janeiro, Brasil. 116p.

Rufino, M. Pereira. **Implementação de uma Rede Neural Artificial para Classificação de Sinais Mioelétricos**.Monografia (Curso de Graduação em) Campus I - UFPB / Universidade Federal da Paraíba.Engenharia Elétrica,2017.

RAMÍREZ-Sandí S.e J. Quirós-Tortós, "**Avaliando os efeitos das mudanças climáticas na demanda de eletricidade das redes de distribuição**", Conferência e Exposição de Transmissão e Distribuição de PES IEEE 2018 - América Latina (T&D) , Lima, 2018, pp. 1-5.

SHARMA, S. RK Agrawal e MM Tripathi, "**Sinergismo de redes neurais recorrentes e lógica nebulosa para previsão de carga de energia a curto prazo**", Quarta Conferência Internacional de 2020 sobre Metodologias e Comunicação da Computação (ICCMC) , Erode, Índia, 2020, pp. 165- 169.

- SILVA, Carlos, A. **Implementação de uma matriz de neurônios dinamicamente reconfigurável para descrição de topologias de redes neurais artificiais multilayer perceptrons**. 2015. 83 p. Tese (Doutorado) - Programa de Pós-graduação em Engenharia Elétrica da UFRN, Natal-RN, 2015.
- SINGH, A., & Sahay, K. B. (2018). **Short-Term Demand Forecasting by Using ANN Algorithms**. 2018 International Electrical Engineering Congress (iEECON).
- SHAH, H. ; GHAZALI, R. Prediction of Earthquake Magnitude by an improved ABC-MLP. *Developments in E-systems Engineering* . 2011. P.6.
- XINDA Ke, Anjie Jiang, & Ning Lu. (2016). **Load profile analysis and shortterm building load forecast for a university campus**. 2016 IEEE Power and Energy Society General Meeting (PESGM).
- WILKE, Ana Luiza Dors. **Relação entre demanda de energia elétrica e temperatura para concessionárias do rio grande do sul**. / Ana Luiza Dors Wilke.- 2019. Dissertação (mestrado) - Universidade Federal de Santa Maria, Centro de Ciências Naturais e Exatas, Programa de Pós-Graduação em Meteorologia, RS, 2019.

APÊNDICES

Apêndice A – Exemplo Didático

A.1 EXEMPLO DIDÁTICO

Para exemplificar o funcionamento de uma rede neural para previsão de dados quaisquer, foi elaborado um exemplo didático, detalhando as linhas de programação realizada em MATLAB[®]. A programação de linhas de código no *Script* do MATLAB[®] possibilita uma manipulação mais compreensível dos dados. Apesar de mais trabalhosa do que a ferramenta oferecida pelo *software*, a programação de cada etapa também apresenta como a RNA funciona passo a passo.

Para iniciar a etapa de criação da RNA, os dados de entrada e target são inseridos, e nesse exemplo também é introduzida a função de saída da rede. A Figura A.1 apresenta as linhas de código que em se insere os pontos de entrada na rede.

Figura A.1 – Inicialização dos dados de treinamento da RNA

```
#-----
# dados de treinamento
entrada= [-1:0.05:1];
saida=0.5*entrada.^3+0.5*sin(10*entrada);

#-----
```

Fonte: Autora, (2021).

Nesse exemplo, é trabalhado um número menor de dados de entrada, que são inseridos como pontos na programação. A função de saída de uma RNA normalmente é desconhecida, porém, nesse exemplo, a função seno é utilizada para apresentar o funcionamento da rede de forma didática. Dessa maneira, é feita uma regressão simples, onde possui apenas uma entrada e uma única saída da rede. No entanto, a grande vantagem de utilizar redes neurais em problemas mais complexos, é a possibilidade de obter regressões múltiplas.

Os valores de entrada e saída de rede são separados inicialmente em três parcelas, em que são utilizadas nas etapas de criação e treinamento da rede, apresentados na Figura A.1. Também ocorre uma separação para a etapa de teste, no qual são usados como um nojo conjunto de dados para realizar os testes finais e no processo de validação da rede.

Figura A.2 – Inicialização dos dados de teste da RNA

```
# dados para teste de rede
entrada_rede=[-0.95:0.0032:0.95];
saida_referencia=0.5*entrada_rede.^3+0.5*sin(10*entrada_rede);
#-----
```

Fonte: Autora, (2021).

A Rede é criada dentro de um laço for, onde são realizadas as iterações que são geradas pela própria rede. No processo de criação dentro do laço, a função "(minmax)" realiza a normalização dos dados de entrada. Essa normalização é efetuada para que a RNA possa obter um aprendizado de rede mais rápido, transformando todos os atributos de valores reais para apenas um intervalo, esses intervalos são normalmente de 0 a 1 ou de -1 a 1.

Na sequência, são distribuídos os números de camadas e números de neurônios por camadas, assim com as suas respectivas funções de ativação, como é apresentado na Figura A.3. E por fim, é definido o algoritmo que será utilizado para o processamento da rede. O algoritmo utilizado nesse exemplo é o (SCGB), apresentado pela função "trainscg".

Figura A.3 – Criação da RNA no *Scrip*

```
#criação da RNA-----
for i=1:n_redes
net{i}=newff(minmax(entrada),[10,10,10,1],
{'logsig','logsig','logsig','purelin'},'trainscg');

#definição de parâmetros
netf{i}.trainParam.epochs = 5000;
netf{i}.trainParam.goal = 1e-10;
netf{i}.trainParam.lr= 0.01;

# Divisão de Dados
net{i}.divideParam.trainRatio = 70/100;
net{i}.divideParam.valRatio = 15/100;
net{i}.divideParam.testRatio = 15/100;
#-----
```

Fonte: Autora, (2021).

Dentro do laço, em que são realizadas as iterações, estão inseridos os parâmetros mais importantes para o processo de treinamento da rede, como apresentado nas linhas de código da Figura A.3, onde são determinados parâmetros como: Número máximo de épocas de treinamento, erro desejado e taxa de aprendizagem. Esses campos são

preenchidos de modo a atender o sistema de previsão, pode ser realizado a quantidades de treinamento que for necessário. Juntamente com os parâmetros inseridos na rede, dentro do laço é realizada a divisão dos dados em porcentagens de treinamento, validação e teste.

Para finalizar o laço, inicia-se a etapa de treinamento da rede, com a linha de código da Figura A.4.

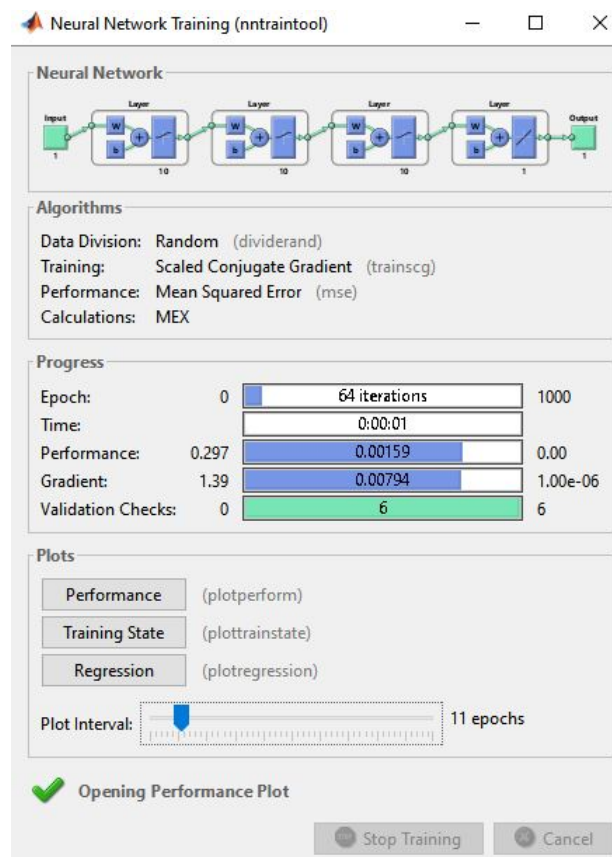
Figura A.4 – Comando de treinamento da RNA

```
#Treinamento da RNA
net{i}=train(net{i},entrada,saida)
end
#-----
```

Fonte: Autora, (2021).

Através dessa programação, é possível treinar a rede neural. O processo de execução é iniciado pela botão "RUN" do MATLAB®, em seguida é aberta a janela de treinamento, na Figura A.5, mostrando todos os detalhes da programação.

Figura A.5 – Janela de Treinamento do exemplo didático




Fonte: Adaptado MATLAB®, (2021).

A janela de treinamento nesse exemplo demonstra todas as variáveis de progresso utilizadas na simulação, que são: o número de iterações realizadas, a performance e o número de validações que foram necessárias, também mostra a arquitetura formada na programação com suas camadas e quantidade de neurônios, e o algoritmo que processou o treinamento da rede *feedforward*, (SCGB) por possuir um bom desempenho no processo de treinamento.

O treinamento é encerrado quando encontra um erro no processo de validação da rede, como ocorreu quando o erro de validação aumentou para seis iterações, ocorrendo na 58ª iteração. Com o processo de treinamento encerrado, foi gerada a tela da Figura A.5, por meio dessa janela de treinamento clicou-se na opção "Performance" localizada na parte inferior da janela, em que foi exibida uma plotagem dos erros de treinamento, erros de validação e os erros de teste, como mostra a Figura A.6, em que exibe as curvas de treinamento validação e teste realizados pela rede.

Figura A.6 – Validação da RNA treinada



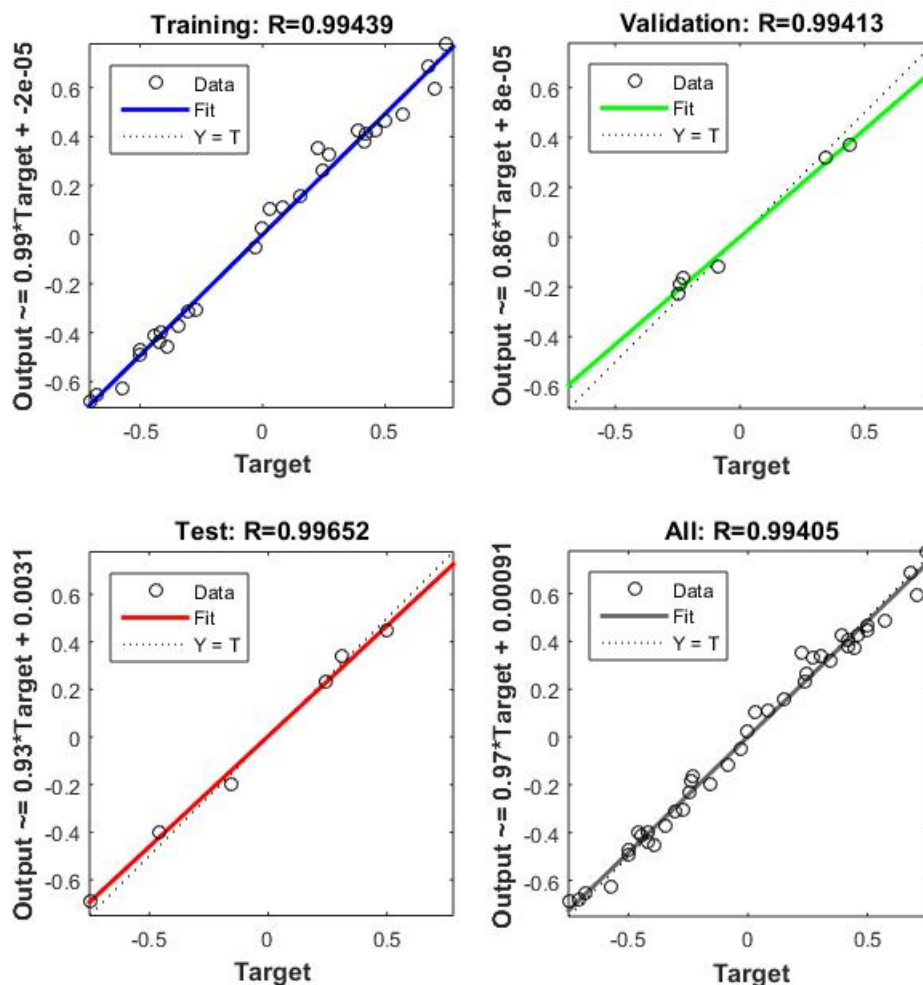
Fonte: Adaptado MATLAB®, (2021).

Com essa resposta de performance da rede, o resultado apresentado é razoável, pois o erro quadrático médio é pequeno. Esses erros de previsão consistem na diferença entre os valores reais e os previstos, o que mostra que o conjunto de dados da etapa de validação e teste tem propriedades semelhantes. Nessa simulação, nenhum ajuste significativo foi

realizado na iteração 58, no qual ocorreu o melhor desempenho da validação

Com esses resultados obtidos, e com a separação prévia que foi realizada na programação para a divisão dos dados em treinamento, validação e teste em porcentagens de 70%, 15% e 15%, respectivamente, a regressão simples da Figura A.7 pode ser considerada.

Figura A.7 – Resultado de Regressão da RNA



Fonte: Adaptado MATLAB®, (2021).

A regressão linear gerada por uma RNA, pode ser simples ou múltipla, evidenciando a relação da resposta das variáveis como uma função linear de alguns parâmetros. Nesse exemplo gerou-se uma regressão linear simples, para expressar a relação entre as variáveis inseridas e geradas pela rede nas linhas de código. A variável R que expressa o valor da regressão, possui um intervalo de 0 a 1, e quanto mais próximo de 1 esse valor de regressão, maior é a relação entre os dados da rede, e mais eficiente se tornam os processos dentro da rede, para ser usada como modelo de previsão.

Após a etapa de treinamento e validação, a rede é utilizada para avaliar e testar os dados. Para ser usada nessas próximas etapas, a rede entra em outro 'for', por meio de um novo índice criado, cada resultado da rede é adicionado dentro desse índice 'j'. Na continuação das linhas de programação, Figura A.8, mostra como a rede treinada é aplicada ao índice 'j'.

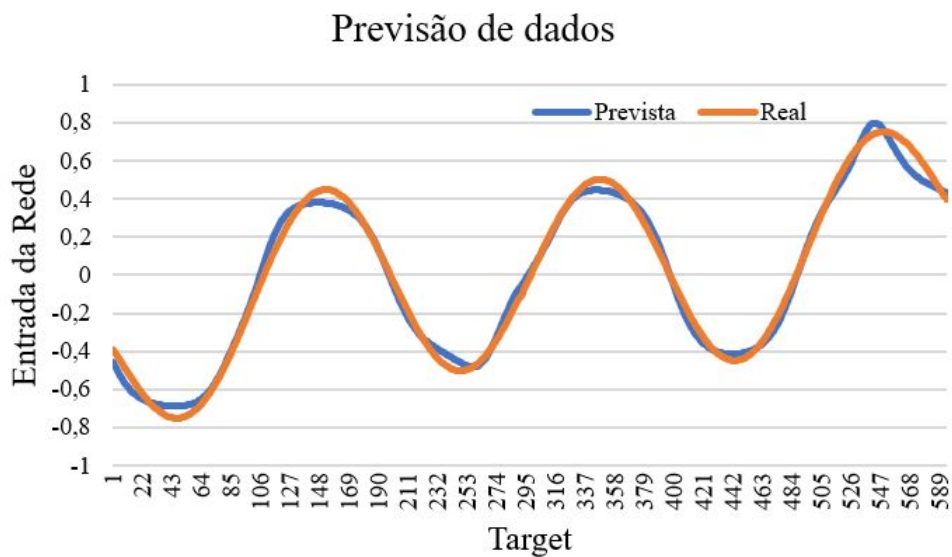
Figura A.8 – Utilização da RNA treinada

```
# Utilização da Rna treinada
for j=1:n_redes
saida_rede=[saida_rede;net{j}(entrada_rede)];
end
# -----
```

Fonte: Autora, (2021).

A Figura A.9 apresenta o gráfico plotado a partir das linhas de códigos de criação e treinamento da rede. A curva de cor laranja é a função de entrada e saída de referência inserida na rede, podendo ser observado o valor real de um sistema qualquer. Já a curva em cor azul, é o resultado da simulação com todos os processos da RNA, em que se comporta como a previsão de valores de um sistema qualquer.

Figura A.9 – Resultado do processamento da RNA



Fonte: Autora, (2021).

A aproximação das curvas é satisfatória para esse exemplo didático, entretanto,

em um sistema de previsão mais complexo como o proposto nesse trabalho, outras manipulações da rede devem ser realizadas, para obter uma aproximação mais eficiente, para que os dados realmente comprovem o comportamento do sistema.

Apêndice B – Dados de Treinamento

Consumo (MWh)	Temp Max (°C)	Temp Min (°C)	Demanda(MW)
13625,88182	24,6	24,1	13625,88
14286,76847	24,6	24,3	14296,77
13908,14093	24,3	23,9	13908,14
13242,812	24	23,7	13242,81
12683,94896	23,7	23,6	12683,95
11921,83512	23,7	23,2	11921,84
10983,13049	23,3	23,2	10983,13
10795,73344	23,9	23,2	12795,73
10792,25659	26,5	23,9	10792,26
10572,23824	28,8	26,5	10572,24
10359,65283	29,9	28,6	10359,65
10184,38032	31,7	29,6	10184,38
10820,20818	33	31,7	10820,21
12083,60907	33,3	32,8	12083,61
12792,80758	34,1	33,2	12592,81
13100,53342	34,4	33,6	13100,53
13054,43616	34,9	33,7	13054,44
12906,74241	34,2	32,7	12906,74
13167,75869	32,8	31,8	13167,76
14931,20388	31,8	30,2	14931,2
17790,68191	30,2	28,7	17790,68
19409,60942	28,8	28,2	19409,61
19293,95477	28,2	27,5	19293,95
18183,89829	27,5	26,7	18183,9
16908,33245	26,8	26,2	16908,33
16026,41836	26,2	25,9	16026,42
15324,91517	25,9	25,5	15324,92
14702,09618	25,5	25,2	14702,1
14257,44138	25,2	25,1	14257,44
13664,47586	25,1	24,9	13664,48
14625,96693	24,9	24,7	14625,97
18267,34393	26,6	24,8	18267,34
19627,57599	27,1	26,4	19627,58
20505,02714	29,6	27,1	20505,03

21208,85181	30,8	29,6	21208,85
19200,99159	32,9	30,8	19200,99
22049,36381	34,1	32,9	22049,36
24235,84257	34,6	32,9	27235,84
23996,60752	35,2	34,1	23996,61
23313,34432	35,6	35,1	23313,34
21664,13685	35,8	33,6	21664,14
17351,97715	35,3	34,7	17351,98
15986,93383	35,1	34,3	15986,93
16554,15757	34,3	32,6	16554,16
18973,36989	32,6	30,4	18973,37
20375,16575	30,4	28,6	20375,17
20518,11241	28,6	27,3	20518,11
19240,994	27,3	27,1	19240,99
18016,54224	27,1	26,3	18016,54
17119,14836	26,6	26,2	17119,15
16267,3603	26,3	25,9	16267,36
15363,00193	25,9	25,5	15363
14779,6391	25,6	25,1	14779,64
14328,67487	25,1	24,4	14328,67
15081,7917	24,7	24,3	15081,79
18832,06008	26,3	24,6	18832,06
20351,63622	28,4	26,3	20351,64
20082,89901	28,7	27,7	20082,9
19246,48346	27,6	24,3	19246,48
16416,53174	26,8	24,8	16416,53
17511,61775	25,2	24,5	17511,62
18657,27855	24,5	22,7	18657,28
17786,75819	23,6	22,1	17786,76
17039,15771	22,2	21,8	17039,16
15686,52964	22	21,8	15686,53
12747,50152	22,3	21,9	12747,5
11878,80554	23	22,3	11878,81
12489,79847	22,9	22,7	12489,8
13053,30064	22,8	22,4	13053,3
13302,67795	22,7	22,4	13302,68
12628,71892	22,7	22,4	12628,72

11756,58031	22,4	22,2	11756,58
10818,21413	22,4	22,2	10818,21
9948,828089	22,2	20,6	9948,828
9466,17342	20,6	20,3	9466,173
9024,354929	20,3	20,1	9024,355
8991,011995	20,2	19,7	8991,012
9392,309141	19,7	19,6	9392,309
11078,22441	19,7	19,4	11078,22
13999,30935	20,9	19,4	13999,31
15209,09375	22,7	20,9	15209,09
15890,77919	24,8	22,7	15890,78
16713,88643	26,3	24,8	16713,89
14594,8485	27,6	26,3	14594,85
16555,85625	28,3	27	16555,86
18893,33268	28,9	28	18893,33
18863,02736	29,1	28,5	18863,03
18412,01753	29,1	28,4	18412,02
16466,42177	28,8	28,4	16466,42
13738,14869	28,6	27,6	13738,15
12924,33348	27,8	26,9	12924,33
13072,44517	26,9	25,4	13072,45
13642,7032	25,4	23,8	13642,7
13166,93175	23,8	22,5	13166,93
12639,04802	22,6	22	12639,05
11777,48718	22,1	21,7	11777,49
10810,85238	21,7	21,2	10810,85
10245,0024	21,3	20,8	10245
9706,469837	20,8	20,6	9706,47
9237,922306	20,7	20,2	9237,922
9010,664589	20,3	19,7	9010,665
8820,168579	19,8	19,4	8820,169
9420,020988	19,4	19,3	9420,021
11296,04787	20,7	19,3	11296,05
12387,48067	22,9	20,7	12387,48
12925,01014	24,3	22,9	12925,01
13247,76473	26,8	23,9	13247,76
11798,33659	27,7	26,8	11798,34

12621,90897	28,8	27,4	12621,91
13749,50719	29,9	28,6	13749,51
13962,7936	31,3	29,8	13962,79
13654,58412	31,7	30,6	13654,58
13040,73912	31,9	30,6	13040,74
12882,28885	32	31,3	12882,29
12997,99253	31,8	30	12997,99
13157,88921	30	28,4	13157,89
14472,2235	28,4	26,4	14472,22
14115,19115	26,4	25,6	14115,19
13960,51084	25,6	25,1	13960,51
13639,50495	25,1	24,2	13639,5
12846,78976	24,2	23,3	12846,79
12080,47388	23,3	22,8	12080,47
11562,54078	22,8	22,6	11562,54
11314,57269	22,6	22,3	11314,57
10956,16322	22,6	22,3	10956,16
10147,73078	22,4	22,2	10147,73
9557,063929	22,7	22,2	9557,064
10065,70839	25	22,6	10065,71
10425,92893	25,4	24,9	10425,93
10837,04484	27,3	25,1	10837,04
11365,39207	29,1	27,3	11365,39
10614,2975	29,1	27,8	10614,3
10652,41422	29,7	27,9	10652,41
11656,57035	30,4	28,7	11656,57
12205,81226	30,8	29,4	12205,81
12368,65116	30,9	30,1	12368,65
12487,18205	30,9	30,4	12487,18
12680,52199	30,4	29,9	12680,52
12975,2632	30,3	29,3	12975,26
14479,04004	29,3	27,9	14479,04
15773,92526	27,9	26,3	15773,93
16115,0454	26,3	24,6	16115,05
15900,48318	24,7	23,9	15900,48
14785,11168	24,1	23,8	14785,11
13720,91944	24,4	24,1	13720,92

12793,10686	24,3	24,1	12793,11
12096,57213	24,1	23,8	12096,57
11535,45099	23,9	23,7	11535,45
11430,67854	24,6	23,8	11430,68
11695,1918	24,7	24,4	11695,19
13036,78021	24,8	24,5	13036,78
16317,92445	25,2	24,6	16317,92
17525,83713	25,8	25,2	17525,84
18249,68617	27,2	25,8	18249,69
18141,99774	28,8	27,1	18142
14396,75067	28,8	22	14396,75
15323,46296	22,9	21,8	15323,46
16598,82469	23,2	22,2	16598,82
16350,54177	22,6	22,1	16350,54
16115,21735	23,4	22,6	16115,22
15104,80196	24	23,4	15104,8
12282,40991	24,7	23,9	12282,41
11158,39952	24,8	24	11158,4
11770,76116	24,3	23,3	11770,76
12791,56989	23,3	22,3	12791,57
12914,86133	22,3	21,1	12914,86
12092,28143	21,1	20,3	12092,28
10895,89516	20,7	20,3	10895,9
10116,51386	20,8	20,6	10116,51
9559,200325	21,2	20,7	9559,2
9258,048212	21,2	20,8	9258,048
8900,504887	20,9	20,7	8900,505
8946,315815	20,7	20,1	8946,316
9560,666225	20,1	19,6	9560,666
11339,90896	19,9	19,4	11339,91
13998,51038	20,6	19,9	13998,51
15078,56449	21,8	20,6	15078,56
15592,50632	23,6	21,8	15592,51
16301,58264	25,1	23	16301,58
13972,8877	27,4	25,1	13972,89
16528,48438	28,8	27,2	16528,48
18707,39664	29	27,6	18707,4

18598,35674	28,9	27,9	18598,36
18025,5276	28,4	27,4	18025,53
16710,39567	27,4	25,8	16710,4
13691,28413	26,6	25,8	13691,28
12560,26765	27	26,5	12560,27
12805,87143	27,1	26,4	12805,87
14136,22155	26,4	25	14136,22
14374,68049	25	24,3	14374,68
14018,23776	24,9	24,3	14018,24
12681,7204	24,7	24,5	12681,72
11563,47229	24,6	24,2	11563,47
10801,81639	24,3	23,9	10801,82
10330,63758	24,1	23,4	10330,64
10064,84464	23,6	23,4	10064,84
10037,55276	23,5	23,3	10037,55
10610,81097	24	23,4	10610,81
12153,38705	23,9	23,8	12153,39
15013,01476	24,1	23,8	15013,01
16288,14886	24	23,8	16288,15
16658,80973	24,1	23,7	16658,81
16889,21734	24,6	23,7	16889,22
13745,40739	25	23,8	13745,41
14239,42374	23,7	21,8	14239,42
9930,173295	21,8	20,3	9930,173
11946,8769	23,3	20,5	11946,88
12302,28093	24,6	23,3	12302,28
11747,42769	25,4	24,2	11747,43
9995,77636	25,4	25,1	9995,776
9475,956734	25,7	24,3	9475,957
9803,253906	24,4	23,6	9803,254
10555,57657	23,7	23,1	10555,58
10470,22794	23,1	22,5	10470,23
10034,97189	23,9	22,5	10034,97
9136,352188	23,9	23,7	9136,352
8374,528366	23,8	23,3	8374,528
8004,011642	23,7	23,3	8004,012
7671,78009	23,7	23,1	7671,78

7548,850327	23,1	22,5	7548,85
7513,241192	22,8	22,4	7513,241
8125,151489	23,4	22,7	8125,151
9206,095642	23,9	23,2	9206,096
11502,42027	23,8	23,7	11502,42
12345,39104	23,9	23,6	12345,39
12767,97728	24,3	23,6	12767,98
12910,37366	24,4	23,3	12910,37
10728,34298	26,4	23,7	10728,34
12094,26939	27,6	25,8	12094,27
14246,44878	28,1	27,4	14246,45
14707,7826	28,8	27,7	14707,78
14872,29959	30,2	28,8	14872,3
14050,28828	30,2	29,6	14050,29
11522,12878	29,7	28,9	11522,13
10930,0052	29,6	28,2	10930,01
11512,40363	28,2	26,9	11512,4
11837,43441	26,9	25,4	11837,43
11584,47033	25,4	23,4	11584,47
11466,97929	23,4	22,4	11466,98
10533,46288	22,4	21,8	10533,46
9535,763275	21,9	21,5	9535,763
8913,680893	21,9	21,7	8913,681
8552,287109	21,9	21,7	8552,287
8153,986435	21,8	21,3	8153,986
7979,16082	21,3	20,9	7979,161
8348,390297	20,9	20,3	8348,39
9049,38781	20,4	20,1	9049,388
11249,48724	20,4	20	11249,49
12208,89424	22,2	20,4	12208,89
12649,78487	23,9	22,2	12649,78
13212,4967	26,6	23,9	13212,5
11427,92635	28,6	26,5	11427,93
13162,45054	29,9	28,6	13162,45
14874,78313	30,2	28,6	14874,78
12615,16677	29,8	25,8	12615,17
12324,61837	25,8	22,1	12324,62

11406,64658	23,9	22,2	11406,65
9848,024071	25,9	23,8	9848,024
9524,147354	26,9	25,9	9524,147
9700,195557	26,7	24,8	9700,196
10655,91158	24,8	23,6	10655,91
10322,50891	23,6	23	10322,51
10045,06462	23	22,8	10045,06
9436,967415	22,8	22,5	9436,967
8580,042961	22,7	22,4	8580,043
7940,720284	22,5	21,8	7940,72
7524,044815	21,9	21,4	7524,045
7216,091698	21,4	21,1	7216,092
7085,122688	21,2	21,1	7085,123
7211,183033	21,2	21,1	7211,183
7337,819347	21,1	20,9	7337,819
8450,772026	21,4	21,1	8450,772
8957,958645	22,3	21,4	8957,959
9520,721092	24,1	22,3	9520,721
9676,280029	25,5	24,1	9676,28
8816,351028	26,8	25,4	8816,351
8993,924614	26,4	25,5	8993,925
9684,047966	28,3	26,4	9684,048
9908,161636	29,2	28,3	9908,162
9627,954666	29,2	27,8	9627,955
9356,998405	28,2	27,9	9356,998
9660,243736	28,3	27,9	9660,244
9693,01387	27,9	26,8	9693,014
9914,13192	26,8	26,3	9914,132
10519,91653	26,3	23,6	10519,92
10093,75422	23,6	22,6	10093,75
9774,738556	22,6	22,2	9774,739
9273,240715	22,3	22,1	9273,241
8610,42028	22,2	21,8	8610,42
8176,89753	21,9	21,7	8176,898
7740,2537	21,8	21,6	7740,254
7438,011597	21,6	21,3	7438,012
7208,261894	21,3	20,9	7208,262

6870,545788	21,1	20,7	6870,546
6205,347519	20,7	20,3	6205,348
6580,418381	21,8	20,3	6580,418
7032,397621	23,3	21,7	7032,398
7442,649849	27	23,3	7442,65
7956,593292	28,4	26,9	7956,593
7780,075638	30,3	28,4	7780,076
8107,217743	31,3	30,2	8107,218
8833,991402	32	31,3	8833,991
9304,001419	32,3	31,2	9304,001
9389,20372	32,3	31	9389,204
9491,974968	32,7	31,7	9491,975
9714,451988	33,2	32,5	9714,452
10004,94061	33,1	30,8	10004,94
10711,46577	30,8	25,7	10711,47
12598,29733	25,8	24,4	12598,3
13042,88835	24,5	24,2	13042,89
10777,8223	24,4	22,3	10777,82
10783,57922	22,3	21,7	10783,58
9578,717041	21,7	21,1	9578,717
8958,068863	21,3	20,7	8958,069
8572,060349	21,2	20,8	8572,06
8197,173096	21,5	21,2	8197,173
8076,094017	21,4	21,2	8076,094
8259,264091	21,2	20,8	8259,264
8800,381779	20,9	20,6	8800,382
11170,7126	21,4	20,6	11170,71
12283,66452	23,4	21,4	12283,66
13131,22227	25,6	23,4	13131,22
13984,74998	27,3	25,6	13984,75
12553,81593	29,4	27,4	12553,82
14543,19033	29,8	29,1	14543,19
16627,36564	31	29,8	16627,37
16648,34291	31,8	30,8	16648,34
16468,47952	31,5	30,8	16468,48
15363,75646	31,4	30,3	15363,76
11992,7897	30,4	28,4	11992,79

11137,53872	28,4	26,1	11137,54
11571,67648	26,1	25,4	11571,68
12588,93397	25,7	24,2	12588,93
13169,20939	24,2	23,7	13169,21
12633,22422	23,8	23,6	12633,22
11706,68255	23,7	23,6	11706,68
10821,3341	23,8	23,6	10821,33
9869,916679	23,7	23,2	9869,917
9383,593765	23,2	22,7	9383,594
9039,528099	22,7	22,4	9039,528
8806,628426	22,4	22	8806,628
9001,773048	22	21,4	9001,773
9751,461952	21,8	21,5	9751,462
12353,21313	23	21,8	12353,21
13567,22463	24,3	22,9	13567,22
14370,75585	26,6	24,3	14370,76
14948,17178	29,2	26,3	14948,17
13124,51691	30,1	29	13124,52
15336,87303	31,4	29,9	15336,87
17461,42862	31,9	31,3	17461,43
17467,72373	32	31,1	17467,72
17291,79573	33	31,7	17291,8
16528,41278	33,6	32,1	16528,41
13430,01185	33,7	31,5	13430,01
12112,299	31,6	30,7	12112,3
12341,95358	30,7	27,8	12341,95
13236,17418	27,8	26,1	13236,17
13525,13052	25,9	23,3	13525,13
13602,63908	23,6	22,9	13602,64
12742,29405	23,1	22,9	12742,29
11693,49781	23,2	23	11693,5
10918,79178	23,1	22,9	10918,79
10288,46732	23,1	22,8	10288,47
9830,530647	22,8	22,4	9830,531
9556,410812	22,9	22,5	9556,411
9807,565712	22,8	22,5	9807,566
10230,98735	22,7	22,3	10230,99

12426,60761	23,1	22,6	12426,61
13826,60332	24	22,7	13826,6
12412,19366	24	22,8	12412,19
13120,59933	22,7	21,7	13120,6
10679,09902	22,1	21,8	10679,1
11520,34035	22,5	21,8	11520,34
14187,44901	26,3	22,4	14187,45
15137,22494	28,5	26,3	15137,22
15763,60855	30,2	28,4	15763,61
14962,0142	31,2	30,2	14962,01
13092,14875	31,4	30,3	13092,15
13409,24583	30,4	26,5	13409,25
13575,0682	26,4	21,8	13575,07
13666,38526	22,6	21,8	13666,39
13347,12509	22,3	22	13347,13
12728,90015	22,2	22	12728,9
11759,30659	22,3	22,1	11759,31
10953,30795	22,2	21,8	10953,31
11638,06956	21,9	21,7	11638,07
13934,72795	21,8	21,6	13934,73
13274,2179	21,9	21,7	13274,22
9180,602463	22,5	21,8	9180,602
13627,84961	22,3	22,2	13627,85
16001,4744	22,2	21,7	16001,47
19341,26231	22,8	21,7	19341,26
21379,76369	25,7	22,8	21379,76
23025,32774	28,1	25,6	23025,33
24671,25529	30,3	28,1	24671,26
22352,86526	31,7	30,2	22352,87
26073,558	32,8	31,2	26073,56
28846,43239	33	32,1	28846,43
28667,5537	32,4	31,3	28667,55
26161,42612	32,1	27,4	26161,43
23819,93445	27,4	23,8	23819,93
21183,92819	24,4	23,3	21183,93
19672,60971	23,4	22,7	19672,61
19451,17273	22,8	21,8	19451,17

20200,96947	21,8	21,4	20200,97
18622,94069	21,8	21,3	18622,94
17534,86098	22,2	21,8	17534,86
15892,05325	22,3	21,9	15892,05
14378,23503	22,4	21,9	14378,24
13219,75742	22	21,1	13219,76
12536,33249	21,4	21,2	12536,33
12082,64836	21,4	21,2	12082,65
11949,40498	21,3	21,1	11949,4
12637,34457	21,1	20,8	12637,34
14134,84869	20,9	20,6	14134,85
18000,00301	21,6	20,9	18000
19627,51407	23,1	21,6	19627,51
20450,51337	25	23,1	20450,51
20973,13757	25,2	24,6	20973,14
16427,47095	24,9	23,1	16427,47
17407,9227	23,1	22,8	17407,92
19692,25728	23,3	22,8	19692,26
19119,80943	23,3	22,4	19119,81
18697,87616	23,4	22,5	18697,88
17640,5546	24,3	23,3	17640,55
15716,40108	24,8	24,2	15716,4
15870,57676	25,3	24,6	15870,58
16832,87388	25,1	24,5	16832,87
17714,35811	24,5	23,8	17714,36
16634,88728	23,9	23,1	16634,89
15434,02947	23,1	22,6	15434,03
14037,6682	22,6	22,3	14037,67
12620,14275	22,4	21,7	12620,14
11404,60243	21,8	20,7	11404,6
10518,27819	20,7	19,9	10518,28
9931,520943	19,9	19,4	9931,521
9743,141464	19,5	18,9	9743,141
9840,966629	18,9	18,6	9840,967
10265,7636	18,7	18,6	10265,76
12068,42117	18,7	18,5	12068,42
12948,4669	19,1	18,4	12948,47

13371,28307	20,2	19,1	13371,28
13948,80658	22,4	20,2	13948,81
12629,69755	23,6	21,7	12629,7
12335,58473	24,2	21,9	12335,58
12661,73504	24,4	23,6	12661,74
12876,51166	24,6	23,8	12876,51
12980,22202	24,1	22,1	12980,22
12935,44189	23,8	22,8	12935,44
13538,23743	23,9	23,4	13538,24
13851,42966	23,7	22,7	13851,43
14696,66599	22,9	22,2	14696,67
16142,67188	22,2	21,4	16142,67
14689,08845	21,4	20,4	14689,09
13424,72063	20,4	19,3	13424,72
11835,43892	19,3	18,7	11835,44
10510,74184	18,7	18,1	10510,74
8772,859558	18,1	17,8	8772,86
7449,703331	17,8	17,7	7449,703
7296,751846	17,7	17,4	7296,752
7223,43589	17,4	16,8	7223,436
7105,063354	17,2	16,8	7105,063
6891,233528	17,3	17	6891,234
7491,667435	19,1	17,1	7491,667
8093,450897	21,3	19,1	8093,451
8849,360191	23,4	20,8	8849,36
9333,587158	24,2	22,4	9333,587
8864,548042	24,9	24,1	8864,548
8468,920883	26,8	24,4	8468,921
8777,019592	26,9	25,6	8777,02
9099,470566	27,7	26,4	9099,471
9362,396469	28,6	26,9	9362,396
9795,717369	28,8	26,9	9795,717
10150,93609	28,1	26,7	10150,94
10256,18121	27,9	27,1	10256,18
11088,39035	27,7	25,2	11088,39
12815,10493	25,2	23,6	12815,1
12361,56154	23,6	22,2	12361,56

11490,99634	22,2	21,2	11491
10336,04179	21,2	20,7	10336,04
9375,446014	20,8	20,4	9375,446
8825,285271	20,4	19,8	8825,285
8437,699127	19,9	19,2	8437,699
8133,201294	19,3	18,7	8133,201
8175,528809	18,9	18,6	8175,529
8852,150345	18,6	18,3	8852,15
10350,27232	18,4	17,9	10350,27
13159,66165	19,4	17,8	13159,66
14589,0658	21,6	19,2	14589,07
15635,97195	24,7	21,6	15635,97
16210,17113	26,3	24,6	16210,17
14085,40265	27,3	25,8	14085,4
15865,88608	28,3	26,5	15865,89
18195,55653	28,9	27,9	18195,56
18475,63765	29,4	28,7	18475,64
18127,13605	29,8	28,4	18127,14
17155,67274	30,1	29,3	17155,67
13988,74052	30,3	28,8	13988,74
12600,9624	29,9	29,3	12600,96
12875,63853	29,7	27,5	12875,64
14401,54343	28,2	24,3	14401,54
14300,57545	24,3	21,6	14300,58
13508,99521	21,6	20,4	13509
11946,69376	20,6	19,8	11946,69
10830,87086	19,8	18,8	10830,87
10012,37914	18,8	18,3	10012,38
9427,302017	18,5	17,8	9427,302
8994,609413	17,8	16,9	8994,609
8838,078026	16,9	16,6	8838,078
9277,006378	16,7	16,2	9277,006
10837,76984	16,2	15,9	10837,77
13931,79959	17,8	16	13931,8
15351,55803	22,8	17,8	15351,56
16603,70273	26,1	22,8	16603,7
17577,71228	29,2	26,1	17577,71

15338,50833	30,8	29,2	15338,51
17936,99814	31,2	30,4	17937
20978,31438	31,9	30,9	20978,31
21345,87965	32,5	31,7	21345,88
21348,70105	33,4	32,4	21348,7
20149,78928	33,9	32,9	20149,79
16042,26828	34	32,9	16042,27
14781,75972	33,7	32,9	14781,76
15261,53223	33,4	32,4	15261,53
17384,95387	32,5	28,1	17384,95
18224,53986	28	25,9	18224,54
18056,9716	25,9	24,9	18056,97
16808,66127	24,9	24,3	16808,66
15518,91402	24,3	23,3	15518,91
14229,70363	23,3	22,8	14229,7
13382,83759	22,8	22,2	13382,84
12705,69162	22,2	21,8	12705,69
12285,80188	21,8	21,6	12285,8
12533,11002	21,8	21,4	12533,11
13378,79198	21,8	21,5	13378,79
17086,29018	22,4	21,5	17086,29
18846,67938	25,6	22,4	18846,68
19763,72269	29,4	25,6	19763,72
19994,66872	30,4	29,2	19994,67
17715,60553	31,3	30,2	17715,61
20884,60837	32,2	31,1	20884,61
23582,7047	33,2	31,9	23582,7
23201,44241	33,1	32,7	23201,44
22435,41333	33,2	32,6	22435,41
20576,08835	32,6	29	20576,09
15435,28743	29	24,8	15435,29
14082,8098	24,8	24,2	14082,81
14317,16742	24,2	23,2	14317,17
12377,0707	23,2	22,3	12377,07
13773,49457	22,4	20,9	13773,49
13094,71933	21,2	20,9	13094,72
12057,87178	21,2	20,9	12057,87

11339,54892	21	20,8	11339,55
10619,45316	21,2	20,8	10619,45
10250,83691	21,3	21,1	10250,84
9942,019913	21,3	21,1	9942,02
9861,846489	21,2	20,5	9861,846
10324,79257	20,6	19,8	10324,79
11512,95856	19,8	19,6	11512,96
14458,39326	20,3	19,7	14458,39
15899,02771	21,5	20,2	15899,03
16694,51381	24,6	21,5	16694,51
17462,96983	27,6	24,6	17462,97
15032,02667	28,9	27,6	15032,03
17707,64429	29,7	28,9	17707,64
20490,04591	30,5	29,7	20490,05
20469,33359	31	29,8	20469,33
20620,7231	31,1	30,2	20620,72
19298,07765	31,5	30,3	19298,08
15352,74039	31,6	30,7	15352,74
13950,72832	31,2	30,3	13950,73
14202,88913	30,4	28,3	14202,89
15854,45386	28,3	26,3	15854,45
16244,6286	26,3	25,3	16244,63
15999,90904	25,4	24,3	15999,91
14767,19247	24,3	23,6	14767,19
13641,82915	23,6	22,9	13641,83
12690,50468	23	22,4	12690,5
11983,18553	22,4	22,2	11983,19
11402,4073	22,2	21,9	11402,41
11105,8468	21,9	21,8	11105,85
11228,49525	21,9	21,7	11228,5
12242,71671	21,7	21,2	12242,72
15859,97285	23,1	21,2	15859,97
17585,62236	25,8	23,2	17585,62
18413,98837	27,3	25,8	18413,99
18701,73772	28,8	27,3	18701,74
16392,78796	30,1	28,6	16392,79
19033,36087	30,8	29,7	19033,36

21797,89349	31,2	30,6	21797,89
21429,95836	32	31,2	21429,96
20920,36519	32,3	31,1	20920,37
19219,30846	32,4	31,3	19219,31
15660,14551	32,3	30,8	15660,15
14736,56355	31,9	30,8	14736,56
14931,06876	31,1	29,8	14931,07
16402,78822	29,8	27,3	16402,79
16297,38162	27,3	25,7	16297,38
16436,12265	25,7	24,7	16436,12
15989,23943	24,7	23,7	15989,24
14901,82985	23,7	23,3	14901,83
13761,19318	23,4	22,9	13761,19
12875,97047	23	22,3	12875,97
12146,23782	22,4	21,7	12146,24
11579,80655	21,8	21,7	11579,81
11381,01106	22,1	21,4	11381,01
11215,22791	21,5	21,3	11215,23
13274,44052	24,2	21,4	13274,44
14288,20793	26,2	24,2	14288,21
14499,94653	27,7	26,2	14499,95
14951,42944	28,8	27,6	14951,43
13305,71721	30,2	28,7	13305,72
14241,2403	31,3	30,2	14241,24
15599,3609	31,8	31,1	15599,36
15672,05688	32,6	31,8	15672,06
14915,58102	33,2	31,8	14915,58
13956,28439	33,1	31,6	13956,28
13964,21239	33,7	32,3	13964,21
13660,08563	32,4	31,9	13660,09
14038,99294	32	29,8	14038,99
15690,31061	29,8	26,8	15690,31
15767,33907	26,8	24,9	15767,34
15821,76817	25	24,8	15821,77
15685,46115	24,8	23,8	15685,46
14736,44122	23,8	22,9	14736,44
13845,0692	22,9	22,2	13845,07

13081,56294	22,3	21,8	13081,56
12312,14601	21,7	21,2	12312,15
11713,90216	21,2	20,9	11713,9
11041,60254	21,2	20,9	11041,6
10132,10865	21,1	20,6	10132,11
10766,43177	23,5	20,7	10766,43
11044,17467	26,5	23,5	11044,17
11250,54015	27,7	26,3	11250,54
11678,07031	29,4	27,7	11678,07
11318,48837	30,7	29,2	11318,49
11791,9037	31,6	30,6	11791,9
12785,3894	32,2	31,4	12785,39
13229,5309	32,8	32,1	13229,53
13429,10966	33,3	32,7	13429,11
13569,00664	34	32,9	13569,01
13933,83147	33,8	33	13933,83
13582,39085	33,2	32,1	13582,39
14357,85977	32,6	30	14357,86
16799,15439	30,1	26,3	16799,15
17991,50694	26,2	24,9	17991,51
18216,7596	24,9	24	18216,76
17066,51616	24	23,2	17066,52
15753,63116	23,2	22,6	15753,63
14684,80226	22,6	22,2	14684,8
13800,40601	22,4	22,1	13800,41
13071,09183	22,1	21,9	13071,09
12533,4948	22,3	22,1	12533,49
12463,10661	22,2	22	12463,11
13537,16473	22,2	21,6	13537,16
17579,79503	23,4	21,5	17579,8
19316,12984	26,3	23,4	19316,13
19938,91156	27,8	26,3	19938,91
20408,91811	29,2	27,8	20408,92
17489,12708	30	28,9	17489,13
20459,99341	30,9	29,8	20459,99
21306,55384	31,6	30,4	21306,55
22607,48964	32,1	30,9	22607,49

22511,78435	32,4	30,9	22511,78
21212,73273	32,4	30,7	21212,73
17025,45634	32,4	30,5	17025,46
15388,88452	31,4	30,3	15388,88
15917,5632	31,6	31,3	15917,56
18406,22682	31,4	28,1	18406,23
19488,78836	28,1	25,7	19488,79
19337,58533	25,7	24,4	19337,59
18069,51448	24,4	23,7	18069,51
16754,56056	23,8	23,3	16754,56
15607,33206	23,3	22,7	15607,33
14642,43669	23,2	22,8	14642,44
13998,93239	23,2	22,5	13998,93
13325,40405	22,6	22,3	13325,4
13404,50298	22,6	21,9	13404,5
14282,35295	21,9	20,9	14282,35
18180,1689	22,3	21	18180,17
19692,89317	23,7	22,3	19692,89
20605,62271	27,2	23,7	20605,62
21141,93822	29,2	27,2	21141,94
18487,35184	31,4	29,2	18487,35
21624,84448	32,4	31,3	21624,84
24359,74852	33,1	32,2	24359,75
23966,52467	33,6	32,3	23966,52
23582,94505	33,8	33,2	23582,95
22185,2061	34,1	33,4	22185,21
17565,03096	34,1	33	17565,03
16013,35811	33,2	31,8	16013,36
16402,30017	32,3	31,3	16402,3
18720,21916	31,3	28,8	18720,22
19941,03551	28,7	27	19941,04
20192,70107	27	25,2	20192,7
18817,10141	25,3	24,7	18817,1
17412,00995	24,7	23,6	17412,01
16294,51299	23,8	23,6	16294,51
15509,04733	23,6	23,3	15509,05
14658,97433	23,4	23,2	14658,97

14198,33331	23,4	23,1	14198,33
14132,63727	23,2	22,7	14132,64
14908,66026	22,7	21,7	14908,66
18777,50966	22,8	21,6	18777,51
20978,0293	26,9	22,8	20978,03
21673,31688	28,7	26,9	21673,32
22185,51407	30,3	28,7	22185,51
19644,12268	31,8	30,3	19644,12
22662,39378	33,1	31,8	22662,39
25286,3636	33,4	32,7	25286,36
24620,35811	33,1	32,7	24620,36
24163,90393	33,7	32,6	24163,9
22909,61827	34,7	33,2	22909,62
18200,90714	34,6	32,7	18289,91
16594,15433	33,1	32,7	16594,15
17265,86823	32,9	31,4	17265,87
19337,67517	31,4	28,2	19337,68
20270,44476	28,4	27	20270,44
20409,07532	27	25,7	20409,08
19170,79477	25,7	25,1	19170,79
17880,0034	25,1	24,2	17990,1
16824,59019	24,2	23,5	16824,59
16108,05623	23,9	23,5	16108,06
15304,00763	23,7	23,2	15304,01
14792,68245	23,3	22,7	14792,68
14541,5826	22,9	22,4	14541,58
15124,93381	22,9	22,3	15124,93
19305,1797	23,2	22,1	19305,18
21060,94855	26,3	23,2	21060,95
21862,76909	28,8	26,3	21862,77
22534,82062	30,4	28,8	22534,82
20165,04224	32,5	30,4	20165,04
23337,24149	33,9	32,4	23337,24
25600,49261	34,7	33,7	25600,49
24588,29448	35,3	32,9	24588,29
24400,91435	35,7	34,8	24400,91
22885,31177	35,6	35,2	22895,31

18196,23708	35,4	34,8	18196,24
16947,34862	36,2	35,2	16947,35
17529,21761	35,8	34,7	17526,22
19781,49115	34,7	29,9	19781,49
20192,92715	29,9	27,1	20192,93
17374,02121	27,1	24,2	17374,02

Fonte: Autora, (2021).