



UNIVERSIDADE FEDERAL DO CEARÁ  
CENTRO DE TECNOLOGIA  
DEPARTAMENTO DE ENGENHARIA ELÉTRICA  
GRADUAÇÃO EM ENGENHARIA ELÉTRICA

RACHEL MAIA RIBEIRO DE BARROS SANABIO

PREVISÃO DE CARGAS ELÉTRICAS UTILIZANDO  
REDES NEURASIS ARTIFICIAIS MLP

FORTALEZA

2022

RACHEL MAIA RIBEIRO DE BARROS SANABIO

PREVISÃO DE CARGAS ELÉTRICAS UTILIZANDO  
REDES NEURAIAS ARTIFICIAIS MLP

Trabalho de Conclusão de Curso apresentado ao Programa Graduação em Engenharia Elétrica da Universidade Federal do Ceará, como requisito parcial à obtenção do título de Bacharel em Engenharia elétrica.

Orientador: Prof. Dr. Paulo Cesar Marques de Carvalho.

Coorientador: Profa. Ma. Tatiane Carolyne Carneiro

FORTALEZA

2022

Dados Internacionais de Catalogação na Publicação  
Universidade Federal do Ceará  
Biblioteca Universitária  
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

---

- S189p Sanabio, Rachel Maia Ribeiro de Barros.  
Previsão de cargas elétricas utilizando redes neurais artificiais MLP / Rachel Maia Ribeiro de Barros  
Sanabio. – 2022.  
50 f. : il. color.
- Trabalho de Conclusão de Curso (graduação) – Universidade Federal do Ceará, Centro de Tecnologia,  
Curso de Engenharia Elétrica, Fortaleza, 2022.  
Orientação: Prof. Dr. Paulo Cesar Marques de Carvalho.  
Coorientação: Profa. Ma. Tatiane Carolyne Carneiro.
1. Redes Neurais Artificiais. 2. Previsão. 3. Cargas Elétricas. I. Título.

CDD 621.3

---

RACHEL MAIA RIBEIRO DE BARROS SANABIO

PREVISÃO DE CARGAS ELÉTRICAS UTILIZANDO REDES NEURAIAS ARTIFICIAIS  
MLP

Trabalho de Conclusão de Curso apresentado ao Programa Graduação em Engenharia Elétrica da Universidade Federal do Ceará, como requisito parcial à obtenção do título de Bacharel em Engenharia elétrica.

Aprovada em: \_\_\_/\_\_\_/\_\_\_\_\_.

BANCA EXAMINADORA

---

Prof. Dr. Paulo Carvalho (Orientador)  
Universidade Federal do Ceará (UFC)

---

Prof. Ma. Tatiane Carolyne Carneiro  
Universidade Federal do Maranhão (UFMA)

---

Eng. Breno Bezerra Freitas  
Universidade Federal do Ceará (UFC)

A Deus.

Aos meus pais, Robson e Dóris.

## **AGRADECIMENTOS**

Agradeço primeiramente a Deus, pela dádiva da vida e pela capacidade que me foi dada de encarar a vida.

Aos meus pais e à minha família, que me criaram com carinho e dedicação, sempre zelando para que nada me faltasse.

Aos amigos, Cleomon, Duillys, Italo, Otania, Stelamaris e Walter, que estiveram presentes em momentos cruciais da minha vida, e com quem sempre posso contar nas horas boas e ruins.

Aos professores orientadores e, Professor Paulo Carvalho e Tatiane Carlyne pelo tempo, pelo tema e pelas valiosas colaborações e sugestões.

A todos que direta ou indiretamente contribuíram para minha formação pessoal, acadêmica e profissional.

“Lembre-se que as pessoas podem tirar tudo de você, menos o seu conhecimento.” (Albert Einstein)

## RESUMO

Este trabalho faz a comparação de duas Redes Neurais Artificiais para previsão de cargas elétricas futuras à partir de uma série histórica de consumo residencial e uma série histórica de consumo total de energia elétrica no Brasil, com uma rede projetada a partir de um *Toolbox* disponível no *Software* Matlab, e outra implementada através do mesmo *software*. Observando a importância do planejamento energético para concessionárias de energia, agências reguladoras e para o mercado livre de energia, buscando manter o Sistema Interligado Nacional (SIN) preparado para o crescimento do mercado energético. Fazendo uma breve introdução aos conceitos de Neurônio Artificial e Redes Neurais Artificiais (RNAs), também menciona uma breve linha do tempo sobre a evolução da tecnologia de RNAs. Depois, apresenta artigos com tema semelhante, mostrando a eficácia dos métodos usados pelos autores mencionados através da compilação dos dados dos artigos, citando o prazo usado para o horizonte de previsão de cada um deles e mostrando erro calculado, bem como a localidade referente aos dados estudados por cada um. Na metodologia, são caracterizadas as séries históricas. A primeira série histórica consiste de dezessete anos divididos em valores mensais, utilizando cento e oitenta meses como base de treinamento e fazendo a previsão e comparação com uma série de vinte e quatro meses futuros com a rede implementada por *Toolbox*, atingindo MAPE de 3,97% para o consumo residencial e MAPE de 2,9% para o consumo total; para a RNA implementada, a previsão gerada foi de quarenta e um meses fora de ordem cronológica, obtendo MAPE de 3,19% para a série de consumo residencial e 2,19% para o consumo total. A segunda aplicação obteve erros menores que a primeira, se mostrando mais eficaz, devido possivelmente a erro de aproximação estatística, chamado de *overfitting*, em que o modelo do padrão estatístico aplica-se bem a todo o modelo durante o treinamento da RNA, no entanto gera erros maiores quando gera a previsão. A RNA implementada tem melhores parâmetros de controle de entrada e saída do sinal, já que permite um melhor ajuste dos parâmetros de rede, como número de neurônios em cada camada.

**Palavras-chave:** Redes Neurais Artificiais; Previsão; Cargas Elétricas

## ABSTRACT

This work compares two Artificial Neural Networks for forecasting future electrical loads from a historical series of residential consumption and a historical series of total consumption of electric energy in Brazil, with a network designed from a Toolbox available in the Software Matlab, and another implemented using the same software. Noting the importance of energy planning for energy utilities, regulatory agencies and the free energy market, seeking to keep the National Interconnected System (SIN) prepared for the growth of the energy market. Making a brief introduction to the concepts of Artificial Neuron and Artificial Neural Networks (ANNs), it also mentions a brief timeline on the evolution of ANNs technology. It then presents articles with a similar theme, showing the effectiveness of the methods used by the aforementioned authors through the compilation of data from the articles, citing the term used for the forecast horizon of each of them and showing calculated error, as well as the location referring to the data. studied by each. In the methodology, the historical series are characterized. The first historical series consists of seventeen years divided into monthly values, using one hundred and eighty months as a training base and making the forecast and comparison with a series of twenty-four future months with the network implemented by Toolbox, reaching MAPE of 3.97 % for residential consumption and MAPE of 2.9% for total consumption; for the implemented ANN, the forecast generated was forty-one months out of chronological order, obtaining MAPE of 3.19% for the residential consumption series and 2.19% for the total consumption. The second application had smaller errors than the first, proving to be more effective, possibly due to statistical approximation error, called overfitting, in which the statistical pattern model applies well to the entire model during ANN training, however generates larger errors when generating the forecast. The implemented ANN has better signal input and output control parameters, as it allows a better adjustment of network parameters, such as the number of neurons in each layer.

**Keywords:** Artificial Neural Networks; Electrical Loads; Forecast.

## LISTA DE FIGURAS

Figura 1 – Participação percentual dos subsistemas no consumo nacional de energia elétrica prevista para os anos de 2021 e 2025.....	15
Figura 2 – Neurônio biológico.....	18
Figura 3 – Neurônio Artificial, visão de McCulloch-Pitts .....	19
Figura 4 – Modelo de RNA MLP .....	21
Figura 5 – Variação percentual do consumo de energia elétrica no Brasil em 2020 em relação ao ano anterior .....	27
Figura 6 – Consumo total de energia elétrica do setor residencial em 2020.....	28
Figura 7 – Ferramenta de Treinamento de RNAs do Matlab .....	31
Figura 8 – Arquitetura da MLP implementada para a previsão de cargas .....	32

## LISTA DE GRÁFICOS

Gráfico 1 – Consumo de Energia elétrica percentual por setor em 2020.....	14
Gráfico 2 – Dados de Consumo residencial mensal no Brasil de 2004 a 2020, em MWh .....	34
Gráfico 3 – Consumo de energia elétrica Total no Brasil, todas as classes, MWh, 2004 a 2020 .....	34
Gráfico 4 – Consumo residencial no Brasil de 2004 a 2020, normalizado.....	35
Gráfico 5 – Consumo mensal todas as classes, 2004 a 2020 normalizado .....	36
Gráfico 6 – Regressão Linear do consumo residencial.....	37
Gráfico 7 – Regressão linear do consumo de todas as classes no período.....	37
Gráfico 8 – Valores observados vs Valores Previstos .....	40
Gráfico 9 – Previsões e dados reais do consumo mensal de todas as classes, horizonte de 24 meses .....	41
Gráfico 10 – Previsão de 41 meses, fora de ordem cronológica .....	43
Gráfico 11 – Previsões e valores reais para o consumo total de todas as classes no Brasil, fora de ordem cronológica.....	43
Gráfico 12 – Dados de treinamento da RNA vs dados reais .....	45

## LISTA DE TABELAS

Tabela 1 – Resumo dos métodos, Horizonte de previsão, erro e local .....	26
Tabela 2 – Arquitetura da RNA para cada aplicação .....	30
Tabela 3 – Tabela verticalizada de consumo mensal Residencial em MWh, 2011 a 2015 .....	33
Tabela 4 – Consumo Residencial real vs previsto em MWh, 2019 e 2020, Erro Percentual e MAPE.....	39
Tabela 5 – Consumo total real vs previsto em MWh, 2019 e 2020, Erro Percentual e MAPE	40
Tabela 6 – Valores Reais e previstos, fora de ordem cronológica .....	42
Tabela 7 – Comparativo das redes estudadas .....	44

## LISTA DE ABREVIATURAS E SIGLAS

ABNT	Associação Brasileira de Normas Técnicas
ALRPE	<i>Adaptive Learning Recursive Prediction Error Algorithm</i>
CEMIG	Companhia energética de Minas Gerais
CNN	<i>Convolutive neural network</i> (Rede neural convolutiva)
IBGE	Instituto Brasileiro de Geografia e Estatística
MAPE	Erro absoluto percentual absoluto ( <i>Mean Absolute Percentual Error</i> )
MLP	Perceptron Multicamadas(inglês)
NBR	Norma Brasileira Regulamentar
PIB	Produto Interno Bruto
RNA	Rede Neural Artificial
RMSE	Erro médio quadrático ( <i>Root Mean Squared Error</i> )
SARIMA	<i>Seasonal autoregressive integrated moving average</i> (modelo auto-regressivo integrado de médias móveis sazonal)

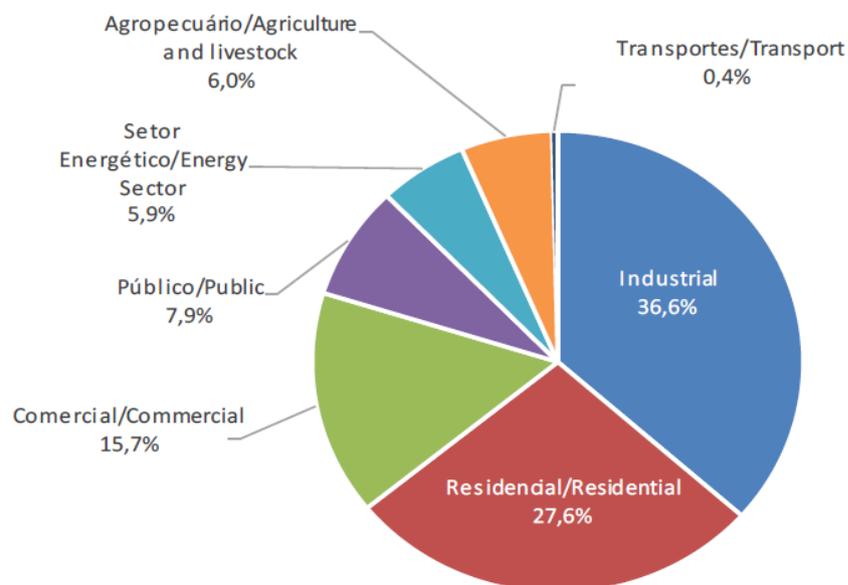
## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	14
1.1	Importância do Estudo	15
1.2	Objetivos Gerais	16
1.3	Objetivos Específicos	16
1.4	Estrutura do Trabalho	17
<b>2</b>	<b>REFERENCIAL TEÓRICO</b>	18
2.1	Uma Breve História das RNA	19
2.2	Multilayer Perceptron	20
2.2.1	<i>Multilayer Perceptron feedforward</i>	20
2.2.2	<i>Mecanismo de retropropagação</i>	21
<b>3</b>	<b>ESTADO DA ARTE</b>	23
<b>4</b>	<b>METODOLOGIAS</b>	27
4.1	Dados Analisados	27
4.1.1	<i>A matriz de consumo de energia do Brasil</i>	27
4.1.2	<i>Consumo Residencial no Brasil</i>	28
4.2	Aplicações	29
4.2.1	<i>Gerada com toolbox</i>	29
4.2.2	<i>Retropropagação com regularização bayesiana</i>	29
4.2.3	<i>RNA programada</i>	31
4.3	Tratamento de dados	32
4.3.1	<i>Normalização dos dados</i>	35
4.3.2	<i>Regressão linear</i>	36
<b>5</b>	<b>RESULTADOS E DISCUSSÕES</b>	39
5.1	Dados da previsão comparados aos dados reais	39
5.1.1	<i>RNA elaborada com toolbox</i>	39
5.1.2	<i>MLP implementada</i>	41
5.2	Avaliação das aplicações	44
<b>6</b>	<b>CONCLUSÃO</b>	47
	SUGESTÕES PARA TRABALHOS FUTUROS	48
	REFERÊNCIAS	49

## 1 INTRODUÇÃO

O Brasil é um país de grandes proporções geográficas, sendo o quinto maior país do mundo em extensão territorial, e o sexto maior país em número populacional. Segundo levantamento da Austin Rating (2021), com base em dados do Fundo Monetário Internacional (FMI), o Brasil ocupa atualmente o 26º lugar no ranking econômico mundial. Como uma das maiores economias do mundo e ainda considerado um país em desenvolvimento. O Brasil precisa de um sistema elétrico robusto e firme, que garanta que todos os setores econômicos sejam atendidos. No Brasil, a matriz de consumo elétrico é dividida em consumidores residenciais, comerciais, industriais, agrícolas e setor público; A Empresa de Pesquisa Energética (EPE) mostra em seus anuários a participação de cada um deles no consumo de eletricidade no Gráfico 1, que detalha a participação percentual de cada setor consumidor no ano de 2020. O Gráfico mostra que os dois setores de maior protagonismo no consumo de energia elétrica são o Industrial, responsável por 36,6% do consumo total de energia elétrica no país, e o residencial, responsável por 27,6% do consumo no mesmo ano.

Gráfico 1 – Consumo de Energia elétrica percentual por setor em 2020



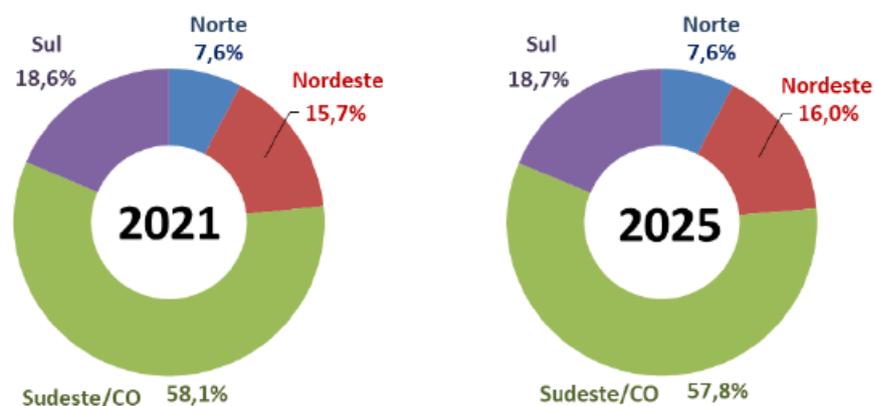
Fonte: Balanço Energético Nacional, EPE,2021.

Existem também subsistemas de distribuição divididos em quatro macroregiões, sendo elas os subsistemas Norte, Nordeste, Sudeste/ Centro-oeste e sul. Esses subsistemas formam o sistema interligado nacional (ONS, 2021).

### 1.1 Importância do Estudo

Para que as necessidades energéticas sejam bem atendidas, é preciso que os órgãos públicos e empresas privadas de gestão energética tenham um bom conhecimento do mercado consumidor de energia, o tipo de demanda que possui e ser capaz de fazer projeções de consumo para planejar o atendimento da demanda elétrica. O Operador Nacional de Sistema (ONS) em conjunto com a Empresa de Pesquisa Energética (EPE) elaboram periodicamente a Previsão de Cargas para o Planejamento Anual da Operação Energética, que faz projeções de carga para um quadriênio, com revisões quadrimestrais. Para a elaboração desse planejamento, são usadas técnicas preditivas que levam em conta o consumo anterior, o crescimento populacional, avanço do PIB no período, entre outros fatores. Através destas publicações, tanto os órgãos reguladores de energia quanto as geratrizes e distribuidoras podem elaborar planos de operação para o mercado futuro. A Figura 1 mostra a participação prevista de cada subsistema para os anos de 2021 e 2025.

Figura 1 – Participação percentual dos subsistemas no consumo nacional de energia elétrica prevista para os anos de 2021 e 2025



Fonte: 2ª Revisão Quadrimestral das Projeções da demanda de energia elétrica do Sistema Interligado Nacional 2021-2025 (ONS, 2021).

O planejamento adequado é essencial para o bom funcionamento do sistema elétrico de um País e primordial para a manutenção do equilíbrio entre oferta e demanda e para a

organização de setores de geração, transmissão e distribuição de energia. As ferramentas de análise de dados e preditivas são aliadas nesse processo, visando a estimativa precisa das demandas futuras à partir de dados anteriores de consumo e perspectivas de crescimento da localidade, como mostrado no Previsão de Cargas para o Planejamento Anual da Operação Energética, elaborado pelo ONS (2021). Vários fatores devem ser analisados visando o entendimento das demandas elétricas em um país, dentre elas, temos: a) o crescimento econômico do período; b) fatores de flutuação econômica; c) instabilidades políticas e sociais; d) alterações climáticas.

A partir de dados estatísticos, é possível estimar a demanda futura usando modelos matemáticos e computacionais, além de ferramentas computacionais de análise, segundo Burden (2008). Dentre estas ferramentas, estão as Redes Neurais Artificiais (RNAs), que podem utilizar dados anteriores para prever o comportamento futuro da demanda, tendo uma ou múltiplas variáveis como entrada. As RNAs são definidas como sistemas de neurônios ligados por conexões sinápticas, com uma ou mais camadas ocultas e com uma camada de saída visando a resolução de problemas não-lineares (Silva et al., 2022). Existem diversos tipos de RNAs, em particular, as redes *Multilayer Perceptron* (MLP) que são RNAs do tipo *feedforward* e que, normalmente, utiliza o algoritmo *Backpropagation* como ferramenta de treinamento.

## 1.2 Objetivos Gerais

Esse trabalho tem como objetivo geral utilizar RNAs MLP para previsão de cargas e fazer um comparativo entre duas redes diferentes, uma implementada usando um *Toolbox* disponível no software Matlab, e outra implementada através do mesmo software, fazendo um comparativo de ambas.

## 1.3 Objetivos Específicos

Como objetivos específicos, utilizar RNAs do tipo MLP para a tarefa de previsão de cargas elétricas do Brasil do setor residencial e todas as classes consumidoras combinadas com dados mensais dos anos 2004 a 2020, fazendo um comparativo entre o desempenho das RNAs através do cálculo do MAPE das previsões geradas.

A RNA gerada a partir do *Toolbox*, separa os dados para aprendizado e teste de modo a gerar um horizonte de previsão de 24 meses em ordem cronológica, usando os dados reais de

2019 e 2020. Na segunda RNA, é feita uma divisão entre os dados de aprendizado e previsão, gerando um horizonte de previsão de 41 meses dispostos fora de ordem cronológica.

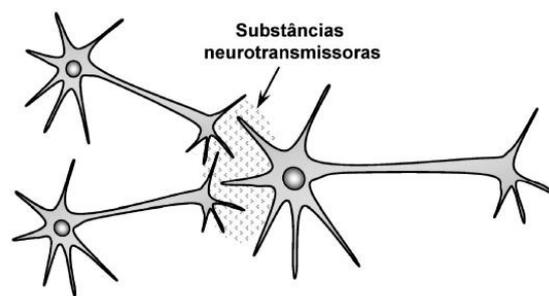
#### **1.4 Estrutura do Trabalho**

Este trabalho está dividido em seções, onde a seção 2 apresenta o referencial teórico relacionado ao tema RNAs, fazendo uma breve introdução sobre seu funcionamento e histórico de desenvolvimento e listando alguns marcos desta técnica; a seção 3 contempla o estado da arte relacionado ao tema de previsão de cargas elétricas, listando estudos similares em que os respectivos autores fazem uso de diferentes tipos de RNA para previsão de cargas elétricas em várias partes do mundo, compilando em uma tabela os autores, anos de publicação, métodos utilizados e seu desempenho; na seção 4 é apresentada a metodologia detalhada, apresentando a arquitetura e funcionamento das RNAs utilizadas, bem como as séries temporais analisadas. Na seção 5 são mostrados os resultados obtidos, sendo mostradas comparações entre os dados reais e os dados previstos pelas RNAs e o MAPE gerado por cada uma delas; A seção 6 apresenta a conclusão; a seção 7 apresenta sugestões para estudos futuros, e na sequência, são apresentadas as referências.

## 2 REFERENCIAL TEÓRICO

Segundo Silva (2010), RNAs tem como objetivo principal imitar o comportamento de uma rede de neurônios, como um mini cérebro, com o objetivo de resolver equações, facilitar tomadas de decisão, ou até mesmo fazer previsões de padrões e comportamentos futuros. Tal qual o aprendizado humano se baseia no conhecimento adquirido com o tempo, uma RNA pode ser treinada para analisar determinado tipo de dado da escolha do programador, e usar o conhecimento passado para chegar a um resultado. A Figura 2 ilustra uma ligação sináptica humana.

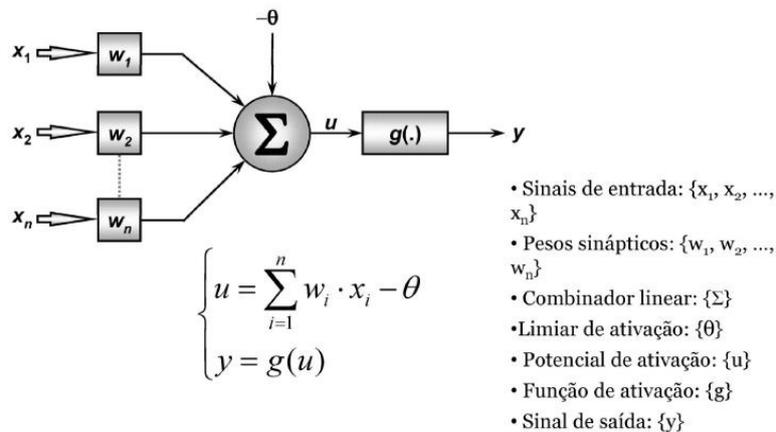
Figura 2 – Neurônio biológico



Fonte: Almeida, J.

Em um cérebro, a informação é passada de um neurônio para outro através de neurotransmissores, que são capazes de propagar-se por extensas cadeias neuronais, e assim acessando centros de memória, monitorando sensações, acionando movimentos e reflexos de maneira muito rápida (O cérebro, em especial o humano, possui cadeias de bilhões de neurônios). O neurônio artificial, por sua vez, recebe informações cedidas pelo usuário/programador e as analisa através de relações matemáticas pré determinadas para alcançar um resultado e, através de sucessivas iterações, ser treinada para alcança-los conforme a necessidade. A Figura 3 mostra a estrutura e função matemática do neurônio artificial criado por McCulloch-Pitts.

Figura 3 – Neurônio Artificial, visão de McCulloch-Pitts



Fonte: Almeida, J.

Segundo Silva (2010), no modelo de neurônio artificial de McCulloch-Pitts, cada sinal de entrada é multiplicado por um peso, representado por  $w_n$ , logo depois os valores são somados uns com os outros, e depois subtraídos de um limiar de ativação ou bias, representado por  $\Theta$ . Logo depois, o valor obtido é comparado com o valor da função de ativação  $g$ , e através do cálculo do erro, pode-se ver se a resposta está dentro do esperado. Se estiver, a rede é considerada treinada, e se não, os valores dos pesos ou do bias devem ser revistos e ajustados. Quando a função de comparação não retorna um erro, a rede é considerada treinada. O neurônio de McCulloch-Pitts é bastante básico e tem um treinamento lento, no entanto foi o primeiro modelo funcional de RNAs.

## 2.1 Uma Breve História das RNA

Em 1958, Frank Rosenblatt cria o Perceptron, um algoritmo capaz de reconhecer padrões baseado em uma rede neural de duas camadas, usando simplesmente adição e subtração. Ele também propôs camadas adicionais com notações matemáticas, mas isso só foi desenvolvido posteriormente. (Silva, 2010)

Em 1980, Kunihiko Fukushima propõe a Neoconitron, uma RNA de hierarquia, multicamada utilizada para o reconhecimento de caligrafia e reconhecimento de padrões. Em 1989, os cientistas conseguiram criar algoritmos que usavam redes neurais profundas, mas os tempos de treinamento para os sistemas eram muito longos, tornando sua aplicação prática impossível. (The Franklin Institute, 2022)

Em 1992, Juyang Weng publica o *Cresceptron*, um método para realizar o reconhecimento de objetos 3-D a partir de cenas desordenadas. Em meados dos anos 2000 o termo “aprendizagem profunda” ou “*Deep learning*” começa a ganhar popularidade após um artigo de Geoffrey Hinton e Ruslan Salakhutdinov mostrar como uma rede neural de várias camadas poderia ser treinada uma camada por vez (Deep, 2018).

Em 2009 acontece o NIPS *Workshop* sobre Aprendizagem Profunda para Reconhecimento de Voz e é descoberto que com um conjunto de dados suficientemente grande, redes neurais não precisam de pré-treinamento e as taxas de erro caem significativamente. (NeurIPS, 2009)

Em 2012 algoritmos de reconhecimento de padrões artificiais alcançam desempenho em nível humano em determinadas tarefas, e o algoritmo de aprendizagem profunda do Google é capaz de identificar gatos. Em 2014, o *Google* compra a *Startup* de Inteligência Artificial chamada *DeepMind*, do Reino Unido, por 400 libras esterlinas. (Veja, 2014).

Em 2014, o *Facebook* coloca a tecnologia de aprendizado profundo chamada ‘*DeepFace*’ em operação para marcar e identificar automaticamente seus usuários em fotografias. Algoritmos executam tarefas superiores de reconhecimento facial usando redes profundas que levam em conta 120 milhões de parâmetros. (TechTudo, 2014).

Em 2016, o algoritmo do *Google DeepMind, AlphaGo*, mapeia a arte do complexo jogo de tabuleiro Go e vence o campeão mundial de Go, Lee Sedol, em um torneio altamente divulgado em Seul. Em 2017 ocorre a adoção em massa do *Deep Learning* em diversas aplicações corporativas e mobile, além do avanço em pesquisas. Todos os eventos de tecnologia ligados a ciência de dados, Inteligência artificial e *Big Data*, apontam *Deep Learning* como a principal tecnologia para criação de sistemas inteligentes. (Gizmodo, 2018).

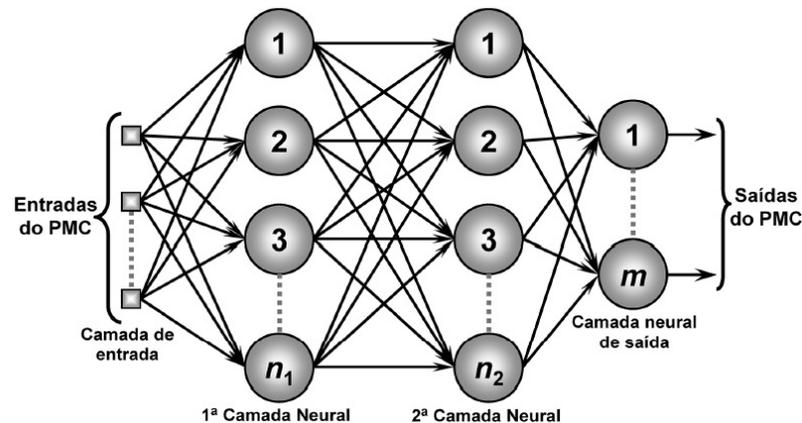
## **2.2 Multilayer Perceptron**

### **2.2.1 *Multilayer Perceptron feedforward***

Segundo Silva (2016, cap V), as redes *Multilayer Perceptron* (MLP) são caracterizadas pela presença de pelo menos uma camada intermediária (escondida) de neurônios, situada entre a camada de entrada e a respectiva camada neural de saída. Segundo o autor, as redes MLP tem grande aplicabilidade prática e pode ser adaptada para diferentes usos.

As redes MLP tem uma arquitetura conhecida como *feedforward*. No treinamento supervisionado, o fluxo de informações na estrutura da rede se inicia na camada de entrada, percorre em seguida as camadas intermediárias, entregando um valor final na camada neural de saída. Em uma rede MLP convencional, não há nenhum tipo de realimentação de valores produzidos pela camada neural de saídas ou pelas camadas neurais intermediárias. A Figura 4 mostra o modelo genérico de uma RNA MLP.

Figura 4 – Modelo de RNA MLP



Fonte: Silva, 2010.

### 2.2.2 Mecanismo de retropropagação

A Retropropagação de erros é uma técnica de aprendizagem de RNAs que utiliza cálculo de derivadas parciais para recalibrar os pesos que multiplicam o valor de entrada do neurônio. Silva (2010) afirma que objetivo do *backpropagation* é otimizar os pesos das RNAs para que possam aprender e mapear corretamente os pares entradas e saídas, apresentados no treinamento, de modo a atingir os resultados mais próximos aos desejados. Para a recalibração dos pesos, podemos utilizar a regra Delta, na qual o novo peso é calculado através do peso antigo subtraído da derivada da função erro multiplicada pela taxa de aprendizagem. A Equação 1 apresenta a forma matemática da regra Delta. A Taxa de Aprendizagem, normalmente está entre 0 e 1 e sua escolha depende dos dados utilizados e da necessidade de cada processo de aprendizagem.

$$w_n = w_i - n * \frac{\partial E}{\partial w_i} \quad (1)$$

Em que  $w_n$  é o novo peso,  $w_i$  o peso anterior,  $E$  a função erro, e  $n$  a taxa de aprendizagem. (Silva, 2010)

### 3 ESTADO DA ARTE

Silva (2010), afirma que RNAs do tipo MLP podem ser utilizadas para uma vasta gama de previsões de séries temporais progressivas. Podendo ser utilizada para previsão de valores de ativos para mercado financeiro, transmissibilidade de doenças em uma população, projeção de vendas de bens, entre outros. As RNAs do tipo MLP também vem sendo usadas para previsão de cargas elétricas em curtíssimo, curto, médio e longo prazos, permitindo assim um melhor planejamento por parte das concessionárias e distribuidoras para atendimento dos clientes, como disse Costa (2019).

O uso de RNAs atualmente é muito amplo, devido a sua adaptabilidade para resolução de problemas diversos. No setor elétrico, é possível utilizar RNAs para projetos de geração de energia de diversos setores, seja através da projeção da incidência solar para projetos fotovoltaicos (Santos, 2019) ou da previsão de ventos para projetos eólicos (Hiruma, 2019); Independentemente do tipo de projeto, para fazê-lo com uma boa precisão, é necessário fazer uma projeção da demanda energética para um determinado período, seja esse período de curtíssimo, médio ou longo prazos, para o correto planejamento e atendimento por parte da concessionária.

Bou (2014) parte da hipótese que a demanda elétrica depende da temperatura registrada em determinada hora do dia, alimentando a rede neural com dados da evolução do consumo de uma região fria dos Estados Unidos da América, nos períodos de agosto a outubro do ano de 2001, a temperatura horária e um coeficiente dependente da temperatura, usado para destacar a característica não linear da série. Desta forma, conseguiu fazer previsões para horizontes curtos, de cerca de uma semana. O menor erro percentual médio obtido foi de 3,41%.

Costa et. al. (2019) faz projeção de carga em curto prazo aplicado a três distribuidoras de energia elétrica do grupo CPFL, presentes nas regiões Sul e Sudeste do Brasil, usando também a hipótese de que a temperatura ambiente influencia a demanda, bem como usando redes diferentes para períodos diferentes do ano, usando uma RNA para os meses de janeiro a novembro, e uma segunda RNA exclusivamente para o mês de dezembro, dada a atipicidade da demanda deste mês causada pelas festas de fim de ano, concomitantemente ao verão no país. Usando dados do período de 2006 a 2017 para treinamento da rede, e testando a rede com dados do ano de 2018 e utilizando cálculo de Erro Médio Absoluto Percentual (MAPE) para comparação, obteve MAPE médio de 2,9% para a distribuidora 1, 2,7% para distribuidora 2, e 3,1% para a distribuidora 3.

Mota & Santos (2019) fez a projeção do consumo de energia elétrica das classes residencial e comercial na área de concessão da CEMIG através dos métodos modelo auto-regressivo integrado de médias móveis normalizado (SARIMA, em inglês) e RNAs do tipo MLP, e testou métodos de combinações das previsões obtidas. As previsões foram feitas para uma série temporal de vinte e quatro meses, usando as próprias amostras para teste da série. Verificou-se que a rede do tipo MLP foi a mais eficiente para a previsão, apresentando MAPE e RMSE menores que o Método SARIMA. Para a classe residencial o métodos SARIMA apresentou MAPE 2,82% e RMSE 4.232.334, e o método MLP obteve MAPE 2,08% e RMSE de 1.235.843. Para Classe comercial, o método SARIMA obteve MAPE 2,72% e RMSE de 3.701, o método MLP obteve MAPE 1,42% e RMSE 1.229.

Kuo & Huang (2017) usou RNAs convolutivas (CNN) para fazer previsões de carga de curto prazo para *smart-grids* com dados do *Electric Reliability Council of Texas*, Texas, EUA. A performance da previsão do algoritmo proposto foi comparada com as performances de outros cinco algoritmos utilizados comumente na previsão de cargas Usando MAPE e erro médio quadrático de variação cumulativa (CV-RMSE) como índices de precisão. Os índices de erro foram baixos, mas ainda mais altos do que uma rede do tipo MLP geraria. O MAPE calculado foi de 9.77%, e o CV-RMSE foi de 11.66%,

Silva et. al. (2021) propõe uma metodologia para previsão em curtíssimo prazo (hora a hora) de geração fotovoltaica (FV) em duas plantas instaladas na região de Fortaleza usando duas RNAs dos tipos MLP e RNA com função de ativação de base radial (RBF), treinando-as com dados coletados durante o ano de 2020. A rede do tipo MLP se mostrou a mais precisa para tal previsão.

Laboissiere & Fernandes (2018) Apresenta uma metodologia baseada em RNAs para previsão de demanda de curtíssimo prazo para aprimorar a operação de *Smart Grids* no mercado de energia da Austrália, e assim garantir maior eficiência do uso de recursos energéticos em cidades inteligentes. Utilizando RNA do tipo MLP, foi possível mostrar a eficácia do modelo MLP para este tipo de previsão, obtendo MAPE entre 0,4% a menos de 3%, dependendo do horário considerado.

Ghomi et. al. (2010) faz previsão de cargas de pico para uma província do Iran utilizando uma RNA tipo MLP sem levar em consideração a previsão do tempo, para assim diminuir o número de variáveis com as quais o MLP lida, facilitando seu treinamento e diminuindo a complexidade da rede. Utilizando apenas valores passados de carga, foi feita comparação entre RNAs do tipo MLP e RBF para este fim. A rede MLP se mostrou mais

eficaz, com erro médio quadrático (MRE) de 1,57%, enquanto a rede RBF obteve MRE de 1,8%.

Saad et. al. (2017) faz uma pesquisa sobre predição de cargas elétrica em sistemas de baixa, média e alta tensão. Usando quatro algoritmos de MLP com diferentes recursos de retropropagação para treinamento e escolhendo o Algoritmo de previsão de aprendizado adaptativo com erro recursivo (ALRPE, em inglês) como o mais preciso, com MSE -33.37.

Tsakoumis et. al. (2002) comparou redes MLP e Elman para previsão de cargas considerando as cargas como uma série temporal em Thessaloniki, Grécia, concluindo que rede Elman é mais eficiente para a previsão. O menor erro médio quadrático (MSE) para rede MLP foi 3,4%, para rede tipo Elman, o menor MSE foi 1,2%.

Azadeh et. al. (2008) apresenta um estudo de RNA do tipo MLP para previsão de consumo elétrico mensal utilizando procedimentos estocásticos ao invés de séries temporais. Usando dados randômicos gerados pelo computador ao invés de dados reais para melhor visualizar o efeito de distribuições probabilísticas, e assim comparar com uma rede treinada com valores reais de consumo, concluindo que o modelo de previsão série temporal com MLP é o mais adequado para a previsão de cargas. Usando dados do Iran de março de 1994 até fevereiro de 2005, com um total de 131 meses, foi feita a previsão mês a mês. O MAPE da MLP foi de 1,2%.

Amjady & Keynia (2011) fazem previsão de cargas em curtíssimo prazo para dados da cidade de Nova York, EUA, usando uma RNA que leva em consideração flutuações socioeconômicas e ambientais. Como no curto prazo a demanda de carga pode ser muito aleatória, fatores microclimáticos, sociais e econômicos podem ser levados em considerações para melhorar o ajuste de parâmetros da rede, levando a uma rede muito precisa. O MAPE foi 1.39%.

Protasiewicz & Sowiński (2015) utilizou dois algoritmos de redução para melhorar a qualidade da predição de uma rede MLP. Usando algoritmos do tipo OBD (*Optimal Brain Damage*), obtendo MAPE de 0,98% ,e OBS (*Optimal Brain surgeon*) obtendo MAPE de 1,4%. Os modelos foram validados usando dados reais de consumo da rede elétrica da Polônia, fazendo previsões de curtíssimo prazo para horizontes de uma hora e vinte e quatro horas. Os algoritmos melhoraram significativamente a precisão da previsão da rede MLP.

A Tabela 1 resume os principais pontos dos artigos citados.

Tabela 1 – Resumo dos métodos, Horizonte de previsão, erro e local

<b>Autores</b>	<b>Horizonte de Previsão</b>	<b>Recurso previsto</b>	<b>Erro</b>	<b>Local</b>
Bou, 2014	Curtíssimo Prazo	Consumo horário de energia	MAPE 3,41%	Região fria dos EUA
Kuo & Huang, 2017	Curtíssimo Prazo	Consumo horário de energia usando redes CNN	MAPE 9,77%	Texas
Protasiewicz & Sowiński, 2015	Curtíssimo Prazo	Consumo horário de energia	MAPE OBD: 0,95% MAPE OBS: 1,4%	Polônia
Amjady & Keynia, 2011	Curtíssimo prazo	Consumo horário de energia	MAPE: 1,39%	Nova York
Ghomi et. Al., 2010	Curtíssimo prazo	Consumo em horário de pico	RME(MLP): 1,57% RME(RBF): 1,8%	Iran
Laboissiere & Fernandes, 2018	Curtíssimo prazo	Consumo horário de energia	MAPE Máximo: 2,94%	Austrália
Costa et. al., 2019	Curto Prazo	Consumo mensal de energia considerando temperatura	MAPE Distribuidora 1: 2,9% Distribuidora 2: 2,7% Distribuidora 3: 3,1%	Região sul do Brasil
Saad et. al., 2017	Médio Prazo	Consumo e rede de média e Alta tensão	MSE -33.37	Malásia
Mota & Santos, 2019	Longo Prazo	Série temporal de consumo	Residencial: SARIMA: 2,82% MLP: 2,08% Comercial: SARIMA: 2,72% MLP: 1,42%	Região da CEMIG
Tsakoumis et. al., 2002	Longo Prazo	Série temporal de consumo	MSE: 1,2%	Grécia
Azadeh et. al., 2008	Longo Prazo	Série temporal de consumo	MAPE: 1,2%	Iran

Fonte: Artigos supracitados

## 4 METODOLOGIAS

Para parametrizar a RNA, é preciso saber o horizonte de projeção com que se deseja trabalhar. É possível trabalhar com horizontes de curto (até 7 dias), médio (mais de 7 dias e até um mês), e horizonte de longo prazo (após um mês) (Carneiro et al., 2022). Para este estudo, será feita uma projeção de longo prazo realizando a previsão com horizonte de 24 meses em ordem cronológica para a aplicação gerada com *Toolbox*, e horizonte de 41 meses fora de ordem cronológica para a outra aplicação.

### 4.1 Dados Analisados

#### 4.1.1 A matriz de consumo de energia do Brasil

O mercado consumidor de energia elétrica no Brasil é dividido em setores industrial, residencial, comercial, rural, público e iluminação pública, energético e de transportes.

O Balanço Energético Nacional (BEN) também mostra a variação do consumo de energia elétrica em cada setor em relação ao ano anterior, mostrado na Figura 5.

Figura 5 – Variação percentual do consumo de energia elétrica no Brasil em 2020 em relação ao ano anterior



Fonte: BEN, EPE 2021

O consumo total de energia elétrica no país apresentou um perfil de crescimento entre os anos de 2011 e 2014; com a crise econômica que ocorreu posteriormente, houve uma redução no consumo em 2015 e 2016, voltando a crescer de 2017 até 2019, havendo novamente um decréscimo no ano de 2020.

Segundo o Anuário estatístico 2021 da EPE, a redução do consumo de energia nas classes industrial e comercial se deram por influência da pandemia de Covid-19.

#### 4.1.2 Consumo Residencial no Brasil

Anualmente, a Empresa de Pesquisa Energética (EPE) publica o anuário de consumo de energia elétrica do Brasil, com o consumo total de energia do país, assim como o consumo dividido por categoria. Os dados também são divididos por região geográfica e por subsistema elétrico. O consumo é apresentado em duas formas, publicação do tipo almanaque, com infográficos explicativos, e por planilha em Excel. O último Anuário Estatístico de Energia lançado foi o de 2021, que tem como base as estatísticas de consumo de 2020. As estatísticas referentes ao ano de 2021 ainda não estavam consolidadas até a realização do presente estudo. De acordo com o BEN de 2021, o consumo residencial de energia elétrica teve um aumento de 4,05% em 2020, em relação ao ano de 2019, enquanto o setor industrial apresentou um aumento de apenas 0,46% no mesmo período. A Figura 6 mostra o consumo total do setor residencial no ano de 2020.

Figura 6 – Consumo total de energia elétrica do setor residencial em 2020



Fonte: EPE, anuário interativo 2021

No ano de 2020, o consumo do setor residencial correspondeu a 27,6% do consumo total do país, sendo o segundo setor mais expressivo. O consumo do setor residencial, assim como os demais setores, é influenciado por fatores socioeconômicos, como emprego e renda, além de fatores climáticos. O setor residencial apresenta uma tendência de crescimento muito consistente ao longo da série histórica utilizada neste estudo, que compreende os anos de 2004 a 2020. O consumo total, no entanto, apresentou uma queda nos últimos meses da série histórica, impulsionada principalmente pelo decréscimo da atividade industrial, que ocorre desde o ano de 2018.

## **4.2 Aplicações**

### **4.2.1 Gerada com toolbox**

Usando a ferramenta *Toolbox* do Matlab, foi gerada uma RNAs do tipo MLP para previsão de séries temporais, que foi treinada com o algoritmo de otimização Regularização Bayesiana, ou *Bayesian regularization backpropagation* (presente na biblioteca *Deep learning do Software*). As MLP consideradas trabalham com variáveis únicas como entradas (estas são as cargas elétricas do setor residencial e total no Brasil). Considerando apenas a série temporal dos meses anteriores de um período de 17 anos do consumo mensal residencial e total em MWh como entrada. As redes analisam as séries temporais e fazem as previsões utilizando métodos de aproximação estatística. Para o aprendizado das redes foram considerados os anos de 2004 a 2018, e para comparação dos dados foram considerados os anos de 2019 e 2020. A rede faz a previsão da série temporal e a compara com os dados reais da série temporal.

### **4.2.2 Retropropagação com regularização bayesiana**

Segundo Burden (2008), RNAs com regularização bayesiana são mais robustas que redes de retropropagação comuns e podem reduzir significativamente ou até mesmo eliminar a necessidade de validação cruzada extensa. Regularização bayesiana é um processo matemático que converte uma regressão não linear em um problema estatístico do tipo regressão em crista, que facilita o cálculo dos pesos e bias. As vantagens desse tipo de rede são que ela oferece um bom critério de parada para o treinamento e diminui

consideravelmente o número de parâmetros necessários em relação a uma rede neural com retropropagação comum.

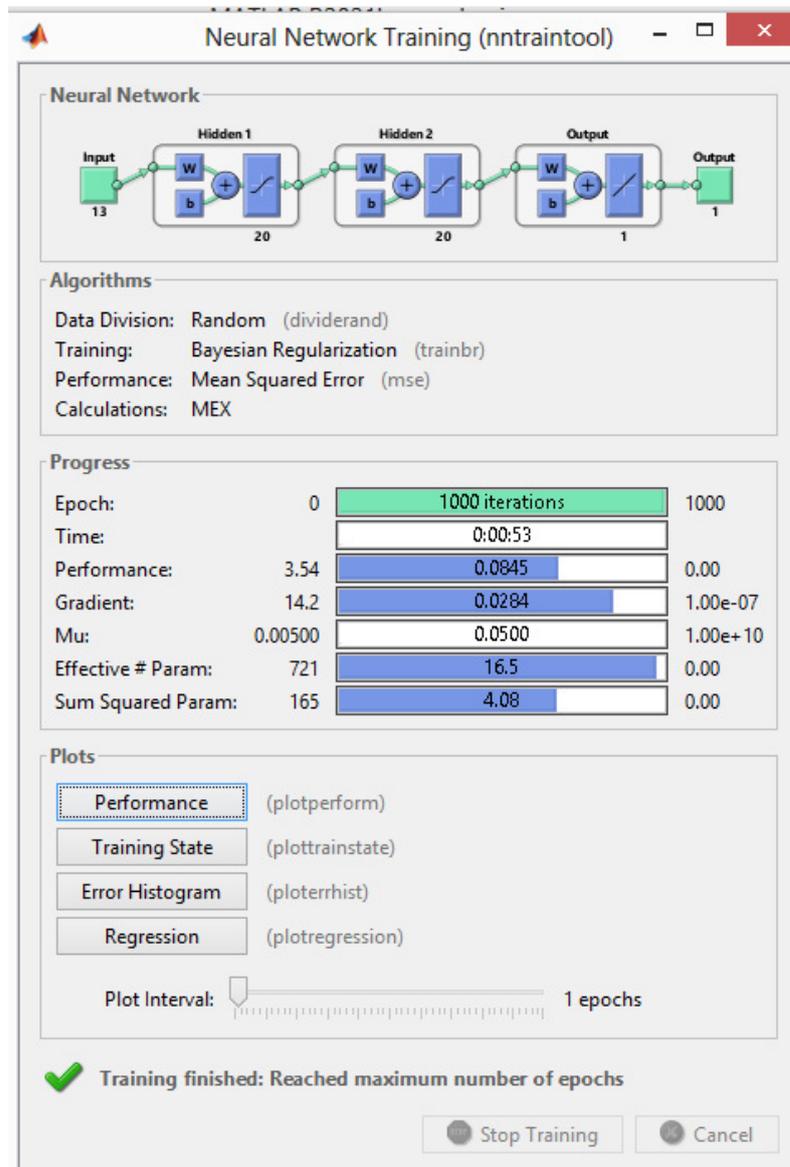
A rede neural artificial projetada para previsão de séries temporais é constituída de duas camadas *feedforward* ocultas com 5 neurônios cada para análise dos dados residenciais, e duas camadas com 9 neurônios cada para análise dos dados de todas as classes consumidoras combinadas, uma de entrada com treze neurônios, e uma de saída com um neurônio. A rede usa o método de retropropagação com regularização bayesiana, com um número máximo de mil épocas de treinamento. O número de épocas de treinamento é limitado, assim como o número de neurônios, para evitar problemas de *overfitting* uma circunstância de memorização excessiva, em que o MLP acaba produzindo respostas que fogem ao padrão. Segundo Silva (2010), o número de neurônios nas camadas também deve ser limitado, pois não necessariamente um número grande de neurônios leva a uma resposta mais precisa. Através da ferramenta de treinamento disponível no *software Matlab*, é possível acompanhar o número de épocas, tempo de treinamento. A Figura 7 mostra a ferramenta de treinamento de RNAs no Matlab, mostrando o número de neurônios em cada camada, o número de épocas realizadas até a finalização do treinamento, o tempo decorrido para o treinamento e o sucesso do treinamento. A Tabela 2 mostra a estrutura da RNA utilizada para os apresentados.

Tabela 2 – Arquitetura da RNA para cada aplicação

Aplicação	Camada	Quantidade	Número de Neurônios
<b>Residencial</b>	Entrada	1	13
	Ocultas	2	5
	Saída	1	1
<b>Total</b>	Entrada	1	14
	Ocultas	2	9
	Saída	1	1

Fonte: A autora.

Figura 7 – Ferramenta de Treinamento de RNAs do Matlab

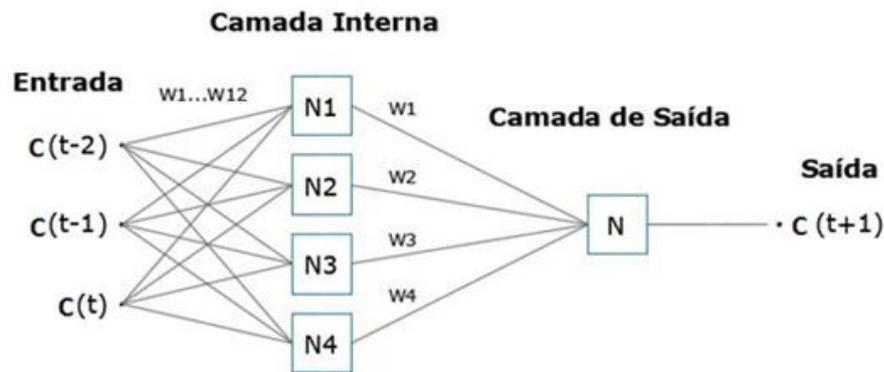


Fonte: Matlab.

### 4.2.3 RNA programada

A segunda Rede Neural, utilizada para comparação de resultados, também foi implementada através do *software Matlab*, utilizando equacionamentos matemáticos adicionados pelo autor ao invés de um *Toolbox* pré-programado. Na Figura 8 é possível ver a arquitetura da MLP implementada.

Figura 8 – Arquitetura da MLP implementada para a previsão de cargas



Fonte: A Coorientadora

A MLP implementada apresenta como entradas um atraso de tempo de um mês ( $C(t-1)$ ,  $C(t)$ ) e prever um mês a frente ( $C(t+1)$ ). Com 4 neurônios na camada oculta e taxa de aprendizagem de 0,55 as cargas residenciais foram previstas. A mesma arquitetura foi utilizada para os dados do Setor residencial e para os dados de todas as classes consumidoras combinadas.

#### 4.3 Tratamento de dados

Com os dados de consumo disponibilizados pela EPE, foi criada uma nova Tabela de dados de consumo residencial verticalizada, apenas com o consumo total mensal do Brasil desta categoria consumidora. Pegando os anos de 2004 a 2020, totaliza-se 204 meses, sendo 180 meses utilizados para o treinamento da rede e 24 para previsão e comparação com os dados reais. Ou seja, serão considerados os anos de 2004 a 2018 para treinamento, e 2019 e 2020 para comparação com a previsão realizada pela rede. A Tabela 3 mostra o consumo residencial mensal no Brasil no período de 2011 a 2015, em MWh, com o total anual consumido a cada ano, como exemplo do formato dos dados lidos pelo programa.

Tabela 3 – Tabela verticalizada de consumo mensal Residencial em MWh, 2011 a 2015

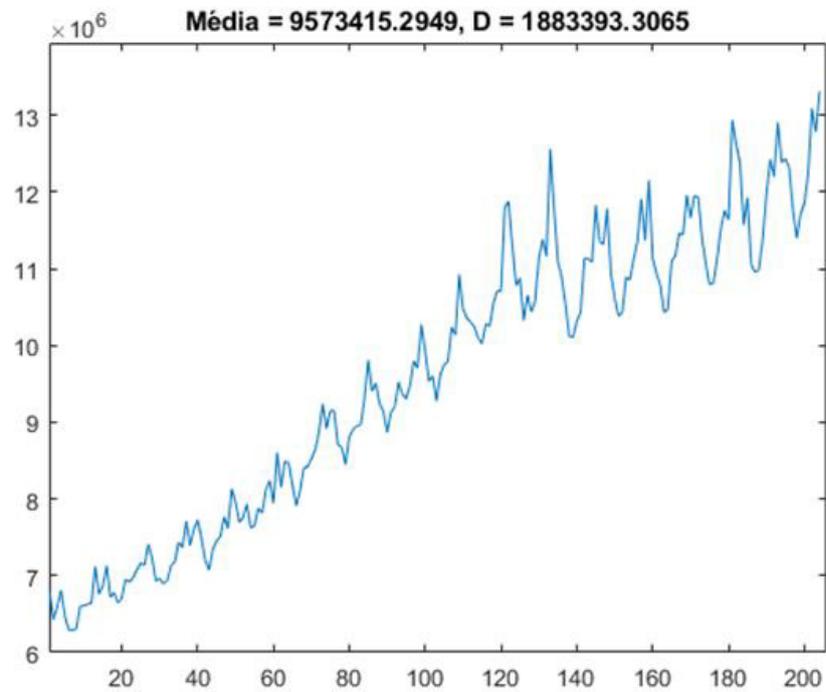
<b>Mês\Ano</b>	<b>2011</b>	<b>2012</b>	<b>2013</b>	<b>2014</b>	<b>2015</b>
<b>JAN</b>	9.810.199	9.800.236	10.924.885	11.798.319	12.558.302
<b>FEV</b>	9.405.182	9.704.925	10.474.529	11.878.858	11.780.261
<b>MAR</b>	9.507.847	10.270.603	10.356.996	11.288.501	11.098.110
<b>ABR</b>	9.236.686	9.928.135	10.301.585	10.780.340	10.889.663
<b>MAI</b>	9.137.821	9.532.019	10.241.914	10.877.148	10.541.785
<b>JUN</b>	8.867.816	9.604.890	10.092.191	10.321.869	10.112.848
<b>JUL</b>	9.128.445	9.274.297	10.022.335	10.656.938	10.110.752
<b>AGO</b>	9.201.316	9.621.637	10.280.497	10.440.492	10.312.915
<b>SET</b>	9.523.959	9.748.529	10.251.165	10.575.615	10.436.503
<b>OUT</b>	9.364.967	9.787.981	10.545.296	11.140.609	11.133.353
<b>NOV</b>	9.303.323	10.239.385	10.710.888	11.382.391	11.131.741
<b>DEZ</b>	9.483.105	10.133.212	10.705.681	11.160.770	11.083.535
<b>ANO</b>	111.970.666	117.645.850	124.907.962	132.301.850	131.189.768

Fonte: EPE(2021)

Como é possível ver na Tabela 3, o consumo residencial de energia elétrica no Brasil apresenta um padrão via de regra crescente.

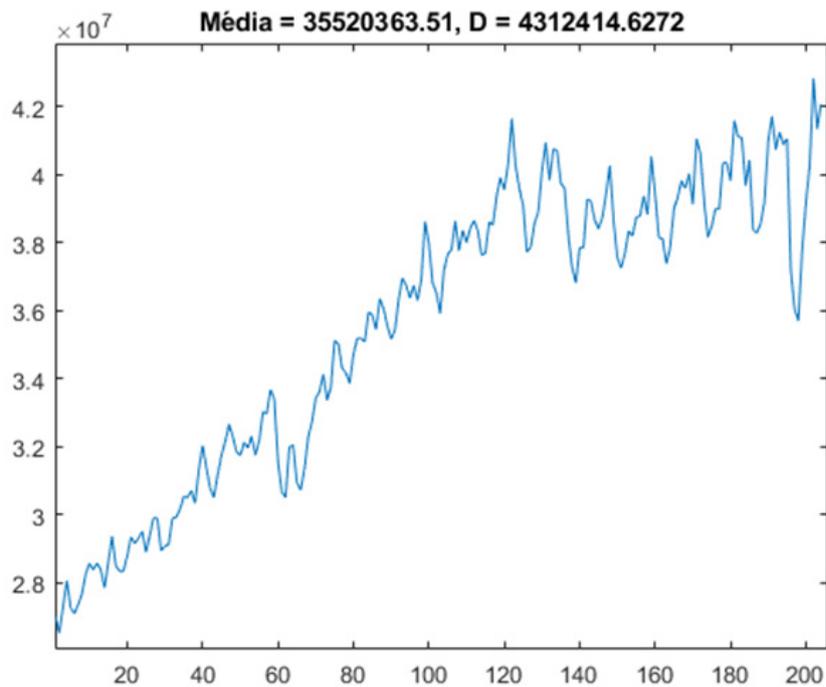
Os dados de consumo dos anos de 2004 a 2020 são então dispostos de forma gráfica para visualização da série histórica. Os meses são numerados sequencialmente, sendo o mês 1 equivalente ao mês de janeiro de 2004, e o mês 204 equivalente ao mês de dezembro de 2020, como mostrado no Gráfico 2. A rede Neural então separa os dados em dados para treinamento e dados para previsão e comparação, sendo utilizados os 180 meses iniciais, equivalentes aos anos de 2004 a 2018 para treinamento, e os dados de 2019 e 2020 para previsão e comparação com a série real, compreendendo assim um período de oito anos para a série de treinamento, e dois anos para a série de previsão. O Gráfico 2 apresenta a média da série histórica como 9.573.415,2949 MWh a cada mês, e o desvio padrão sendo 1.883.393,3065. O Gráfico 3 mostra o consumo total de todas as classes consumidoras no Brasil no mesmo período em MWh, com média 35.520.363,51 e desvio padrão 431.241,6272.

Gráfico 2 – Dados de Consumo residencial mensal no Brasil de 2004 a 2020, em MWh



Fonte: EPE (2021)

Gráfico 3 – Consumo de energia elétrica Total no Brasil, todas as classes, MWh, 2004 a 2020

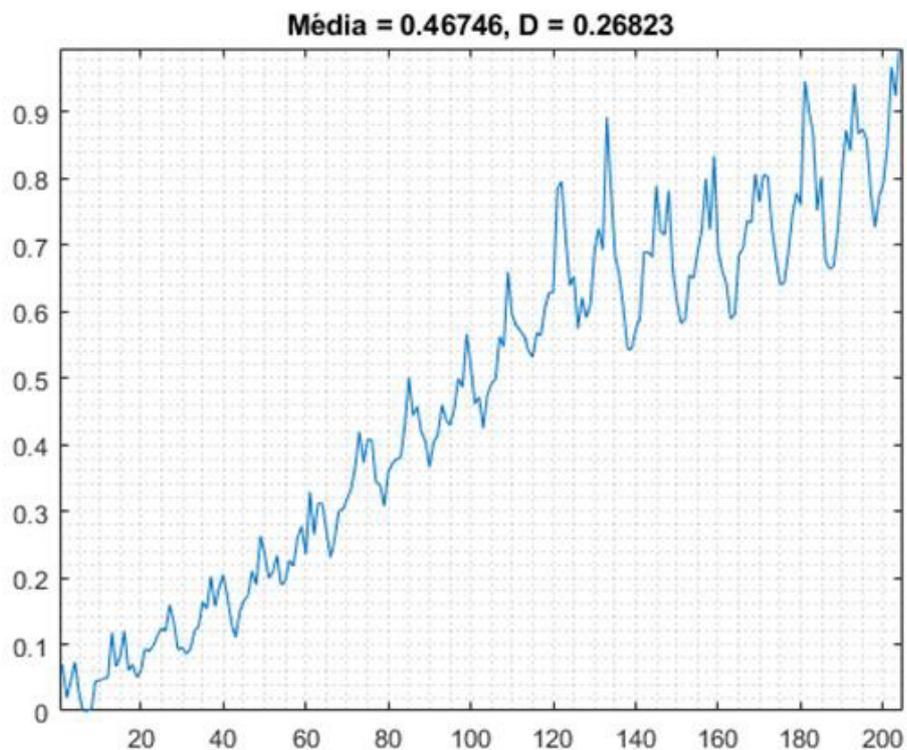


Fonte: EPE(2021)

### 4.3.1 Normalização dos dados

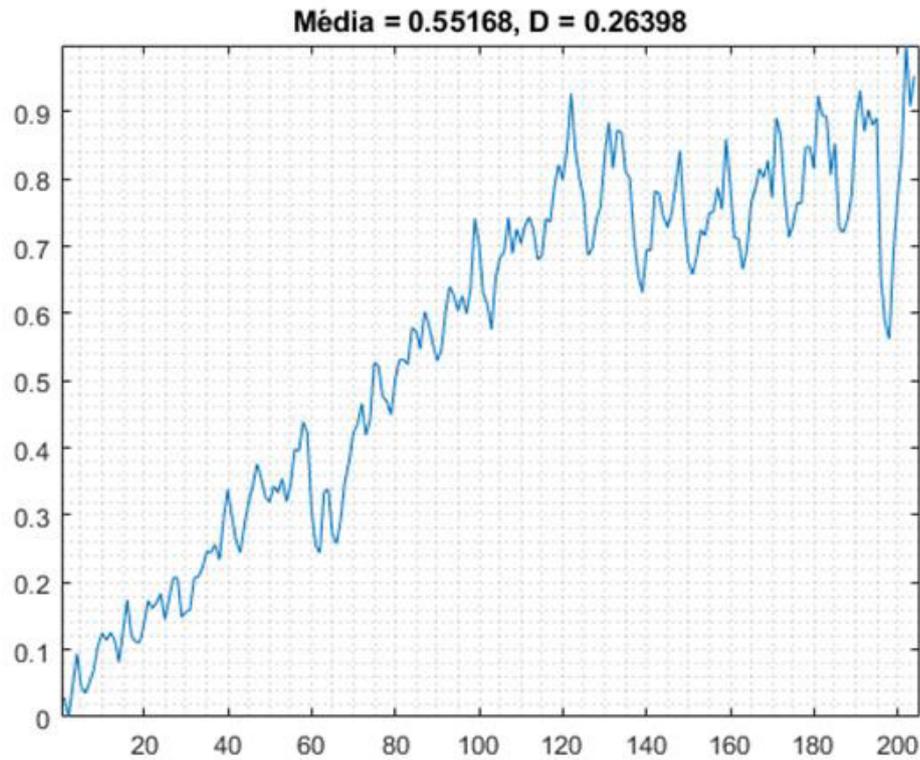
Os dados então são normalizados, para minimizar redundâncias e assim melhorar a consistência dos cálculos da rede sobre o banco de dados. A distribuição normalizada do consumo residencial pode ser vista no Gráfico 4, mantendo-se a relação dos meses, sendo o mês 1 Janeiro de 2011, e o mês 120, dezembro de 2020. O Gráfico 5 mostra o mesmo para o consumo total.

Gráfico 4 – Consumo residencial no Brasil de 2004 a 2020, normalizado



Fonte: EPE(2021)

Gráfico 5 – Consumo mensal todas as classes, 2004 a 2020 normalizado

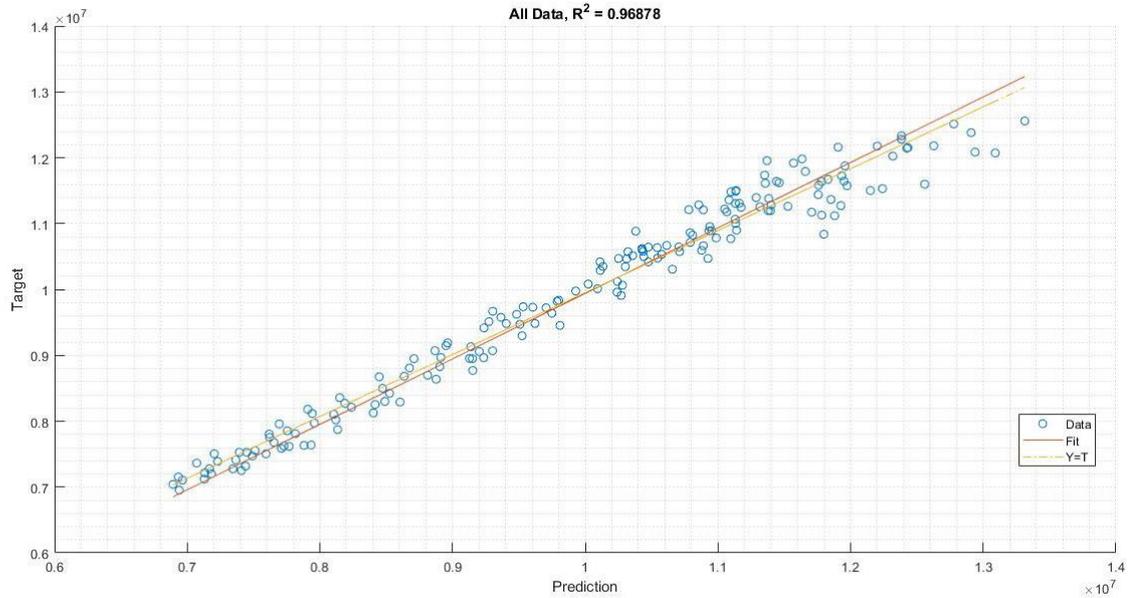


Fonte: Matlab

#### 4.3.2 Regressão linear

A análise de regressão linear é usada para previsão de valores de uma variável com base no valor de outra. Essa forma de análise estima os coeficientes de uma equação linear envolvendo uma ou mais variáveis dependentes. A regressão linear ajusta os valores da amostra sobre uma reta, minimizando discrepâncias entre valores de saída previstos e valores reais. Assim, o modelo de regressão linear facilita a previsão de dados e melhora a precisão dos resultados. O Gráfico 6 mostra a regressão linear obtida para a série histórica analisada.

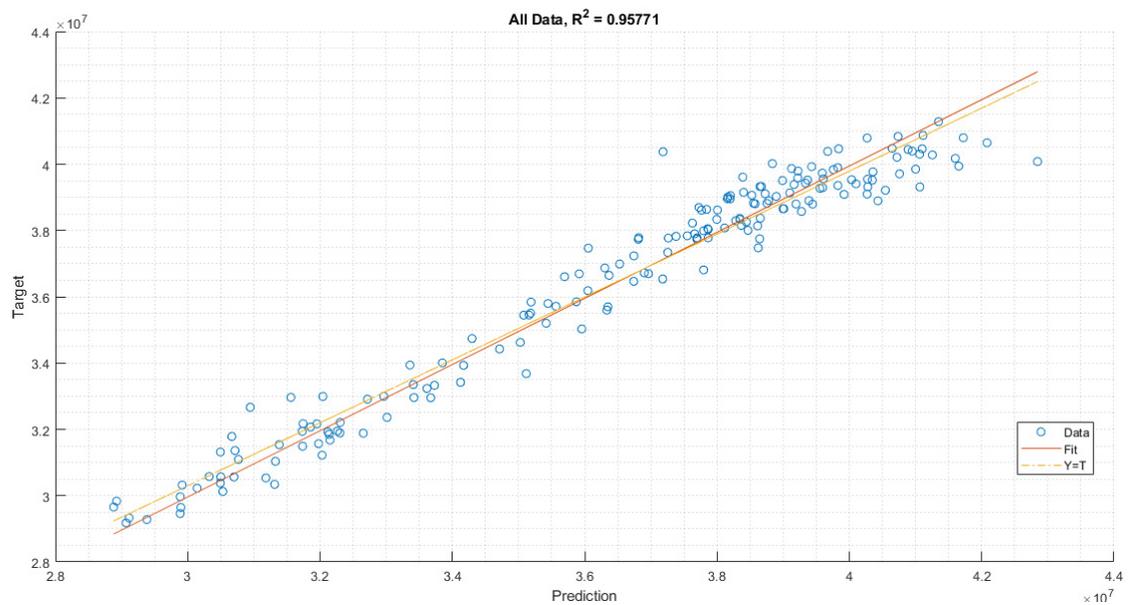
Gráfico 6 – Regressão Linear do consumo residencial



Fonte: A Autora

O Gráfico 7 mostra a regressão linear da série histórica para todas as classes no mesmo período.

Gráfico 7 – Regressão linear do consumo de todas as classes no período



Fonte: A autora

O algoritmo usa a regressão linear para parametrizar as retas entre os valores de consumo, para então fazer o cálculo dos erros e a retropropagação para recalculer os pesos, e então fazer novamente a previsão da série temporal, até o limite estabelecido de mil épocas.

## 5 RESULTADOS E DISCUSSÕES

Após a inserção dos dados nas redes do tipo MLP, é feito o treinamento da rede através de sucessivas iterações, usando o método de retropropagação com regularização bayesiana (na aplicação do *Toolbox*), até o total de mil épocas, quando o programa interrompe a sequência de treinamento e executa a sequência de previsão, então comparando os dados previstos com os dados reais de vinte e quatro meses, correspondentes aos anos de 2019 e 2020. A seguir, os resultados de saída da rede serão mostrados.

### 5.1 Dados da previsão comparados aos dados reais

#### 5.1.1 RNA elaborada com toolbox

A Tabela 4 mostra os resultados calculados para os dados residenciais de 2019 e 2020 do setor residencial comparados com os dados reais medidos para a aplicação usando *Toolbox*, respectivamente. Os dados foram obtidos através da análise do Gráfico de saída produzido pela RNA gerada com *Toolbox*. A Tabela 5 mostra os resultados obtidos para todas as classes consumidoras combinadas.

Tabela 4 – Consumo Residencial real vs previsto em MWh, 2019 e 2020, Erro Percentual e MAPE

Ano	2019		Erro Percentual	2020		Erro Percentual
	Real	Previsto		Real	Previsto	
<b>Janeiro</b>	12.938.100	11.923.100	7,845047	12.908.500	12.204.300	5,45532
<b>Fevereiro</b>	12.626.700	12.039.700	4,648879	12.383.200	12.266.100	0,945636
<b>Março</b>	12.384.000	12.313.700	0,567668	12.431.900	12.213.700	1,755162
<b>Abril</b>	11.947.500	11.569.500	3,163842	12.318.400	11.989.700	2,668366
<b>Mai</b>	11.926.600	11.151.900	6,495565	11.755.900	11.370.900	3,274951
<b>Junho</b>	11.050.300	11.050.300	0	11.396.000	11.081.800	2,757108
<b>Julho</b>	10.952.300	10.820.900	1,199748	11.706.500	11.119.900	5,010891
<b>Agosto</b>	10.987.000	10.710.000	2,521161	11.851.800	11.303.800	4,62377
<b>Setembro</b>	11.379.200	11.111.600	2,351659	12.240.400	11.548.300	5,654227
<b>Outubro</b>	11.973.100	11.417.000	4,644578	13.090.100	11.892.700	9,147371
<b>Novembro</b>	12.423.700	11.714.300	5,710054	12.777.900	12.093.600	5,35534
<b>Dezembro</b>	12.200.700	11.851.300	2,86377	13.312.700	12.431.300	6,620746
<b>MAPE</b>						3,97%

Fonte: A Autora

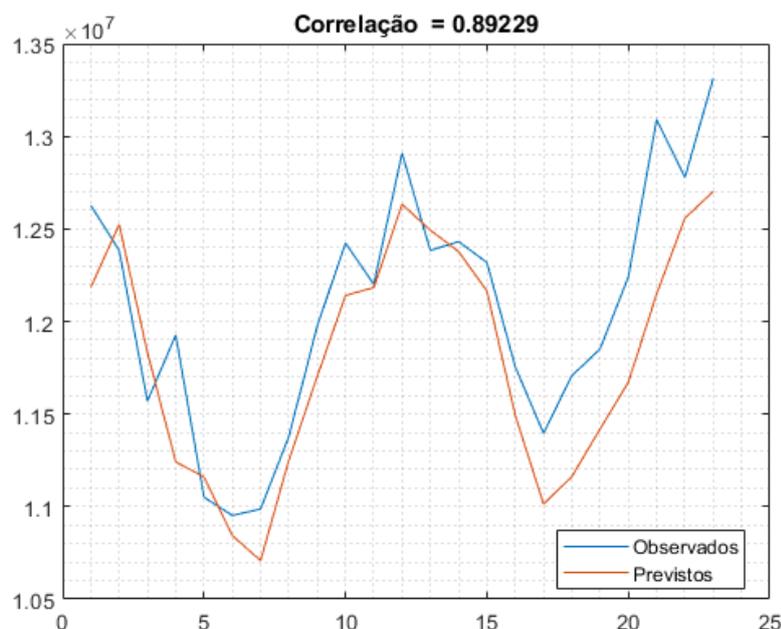
Tabela 5 – Consumo total real vs previsto em MWh, 2019 e 2020, Erro Percentual e MAPE

Ano	2019		Erro Percentual	2020		Erro Percentual
	Real	Previsto		Real	Previsto	
<b>Janeiro</b>	41.601.000	41.305800	0,709598	41.305.800	40.321.000	2,263257
<b>Fevereiro</b>	41.113.400	40.957.500	0,379195	40.957.500	41.265.500	0,923254
<b>Março</b>	41.121.800	41.121.800	0	41.121.800	41.062.100	0
<b>Abril</b>	39.673.500	40.976.600	3,28456	40.976.600	41.108.400	10,55311
<b>Mai</b>	40.432.500	38.728.300	4,214926	38.728.300	36.712.900	1,827536
<b>Junho</b>	38.388.600	38.944.000	1,446784	38.944.000	35.131.300	1,581143
<b>Julho</b>	38.282.000	37.253.000	2,687947	37.253.000	34.939.200	7,559206
<b>Agosto</b>	38.574.500	39.522.600	2,457841	39.522.600	38.350.900	2,077892
<b>Setembro</b>	39.193.700	38.495.600	1,781154	38.495.600	41.082.900	2,006212
<b>Outubro</b>	41.001.500	40.820.200	0,442179	40.820.200	41.062.600	4,158322
<b>Novembro</b>	41.722.300	41.425.700	0,710891	41.425.700	36.305.500	12,19548
<b>Dezembro</b>	41.292.600	40.736.600	1,346488	40.736.600	39.677.900	5,710653
<b>MAPE</b>						3,97%

Fonte: A Autora

O Gráfico 8 mostra os dados reais (Observados) em azul, e a previsão da RNA (Previstos) em laranja, em MWh. Os meses são numerados sequencialmente, sendo o mês 1 correspondente a janeiro de 2019, e o mês 24 correspondendo a dezembro de 2020.

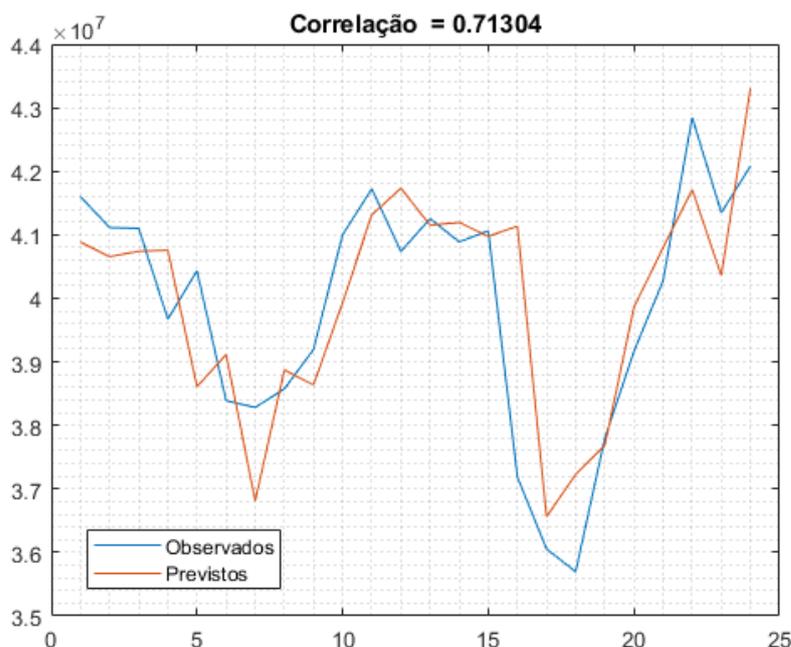
Gráfico 8 – Valores observados vs Valores Previstos



Fonte: A autora

O Gráfico 9 mostra algumas das saídas da rede comparadas a série histórica de consumo mensal de todas as classes no mesmo período, focando um horizonte de previsão de 24 meses.

Gráfico 9 – Previsões e dados reais do consumo mensal de todas as classes, horizonte de 24 meses



Fonte: EPE e Matlab

### 5.1.2 MLP implementada

Nos Gráfico 10 e 11 são mostrados os resultados obtidos com a MLP implementada, sendo o Gráfico 10 a os pares de previsão e valores reais para o setor residencial, e o Gráfico 11 para os pares de previsão de valores reais de todas as classes. Nesta MLP, os meses não seguem uma cronicidade temporal, portanto, não é possível dizer os anos correspondentes de cada par de dados previstos e observados. Isso ocorreu pois, após a montagem da planilha de pares entradas-saídas, os pares foram embaralhados visando melhorar o desempenho do modelo.

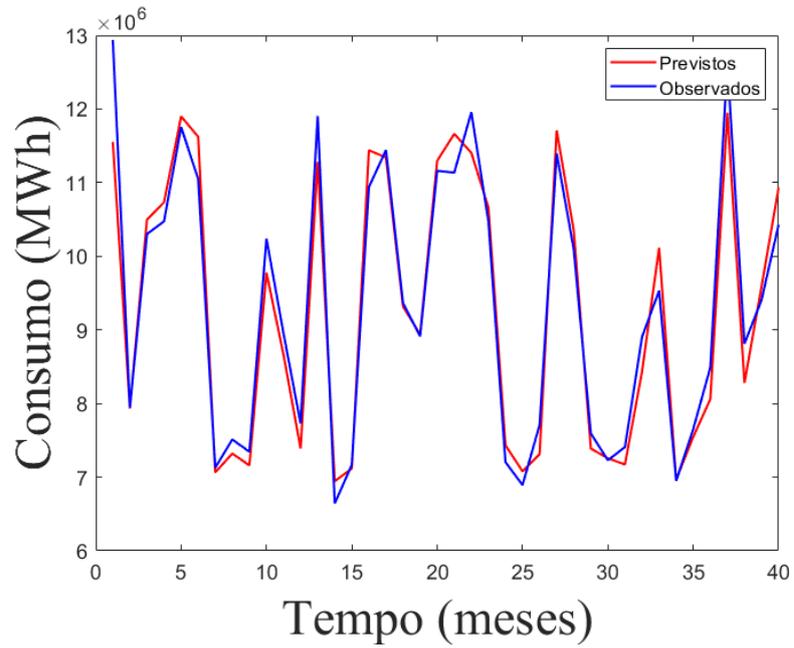
Para esta MLP, foram produzidos os pares de valores reais e previstos (Tabela 6)

Tabela 6 – Valores Reais e previstos, fora de ordem cronológica

<b>Observados</b>	<b>Previstos</b>	<b>Observados</b>	<b>Previstos</b>	<b>Observados</b>	<b>Previstos</b>
12.938.073,15	11.552.566,48	11.135.480	11.662.971,27	7.653.505,2	7.547.376,97
7.942.689,4	7.931.156,976	11.957.246,49	11.404.938,55	8.489.683	8.059.032,15
10.301.585	10.497.048,15	10.475.249	10.662.855,96	12.626.667,78	11.948.640,24
10.474.529	10.733.414,76	7.204.161	7.433.382,597	8.812.297	8.279.559,156
11.755.901,77	11.900.058,84	6.892.915,39	7.078.012,59	9.405.182	9.588.137,483
11.050.316,56	11.623.059,67	7.710.353	7.311.595,243	10.428.729	10.930.755,99
7.128.370,58	70.645.481,86	11.395.964,93	11.709.396,43	7.653.505,2	7.547.376,97
7.511.776	7.320.395,969	10.092.191	10.350.148,46	8.489.683	8.059.032,15
7.344.516	7.159.870,11	7.594.317	7.387.963,161	12.626.667,78	11.948.640,24
10.239.385,17	9.777.762,111	11.395.964,93	11.709.396,43	8.812.297	8.279.559,156
8.951.048	8.660.568,685	10.092.191	10.350.148,46	9.405.182	9.588.137,483
7.728.826	7.389.019,678	7.594.317	7.387.963,161	10.428.729	10.930.755,99
11.905.635	11.282.521,35	11.395.964,93	11.709.396,43		
6.643.371,33	6.944.996,867	10.092.191	10.350.148,46		
7.167.632,08	7.118.408,718	7.594.317	7.387.963,161		
10.939.059	11.439.205,75	7.229.825,78	7.256.806,358		
11.441.479	11.341.863,9	7.408.516,95	7.171.699,829		
9.364.967	9.317.060,649	8.903.996	8.433.341,481		
8.912.339	8.939.411,053	9.532.019,14	10.114.527,69		
11.160.770	11.296.192,61	6.949.354,66	6.966.842,586		
<b>MAPE</b>	<b>3,19%</b>				

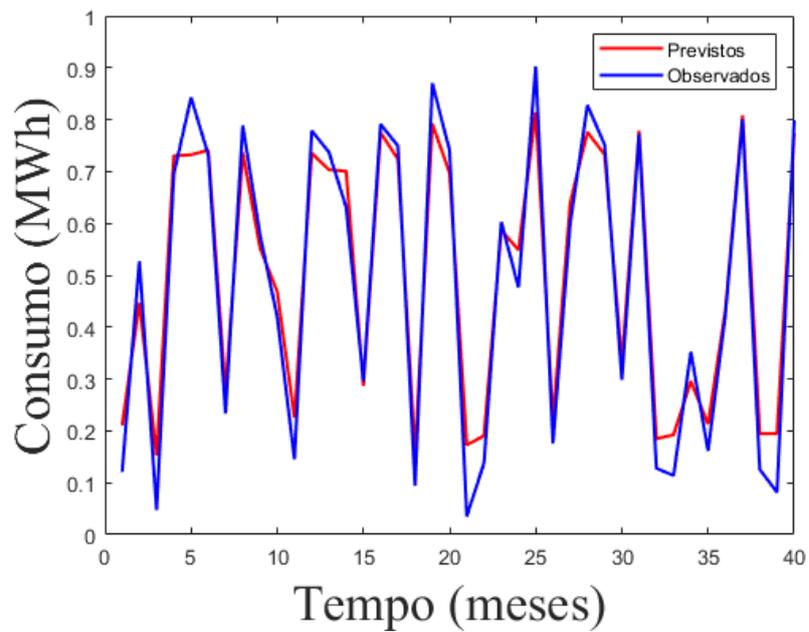
Fonte: A Autora

Gráfico 10 – Previsão de 41 meses, setor residencial, fora de ordem cronológica



Fonte: Matlab

Gráfico 11 – Previsões e valores reais para o consumo total de todas as classes no Brasil, fora de ordem cronológica



Fonte: Matlab

## 5.2 Avaliação das aplicações

Foi utilizada a métrica do Erro Médio Percentual Absoluto, que tem sigla em inglês MAPE e que é calculado por meio da Equação 2 (Haykin, 2007).

$$\text{MAPE} = \frac{1}{n} * \sum_{i=1}^n \frac{|Ri - Pi|}{|Ri|} * 100 \quad (2)$$

Em que  $Ri$  é o valor real e  $Pi$  é o valor calculado pela RNA.

Considerando as duas aplicações na previsão de cargas residenciais e as duas aplicações na previsão de cargas elétricas totais, a Tabela 7 apresenta os MAPE obtidos para cada aplicação.

Tabela 7 – Comparativo das redes estudadas

<b>Aplicação</b>	<b>MAPE (%)</b>
MLP <i>Toolbox</i> Residencial	3,97
MLP Residencial	3,19
MLP <i>Toolbox</i> Total	2,97
MLP Total	2,25

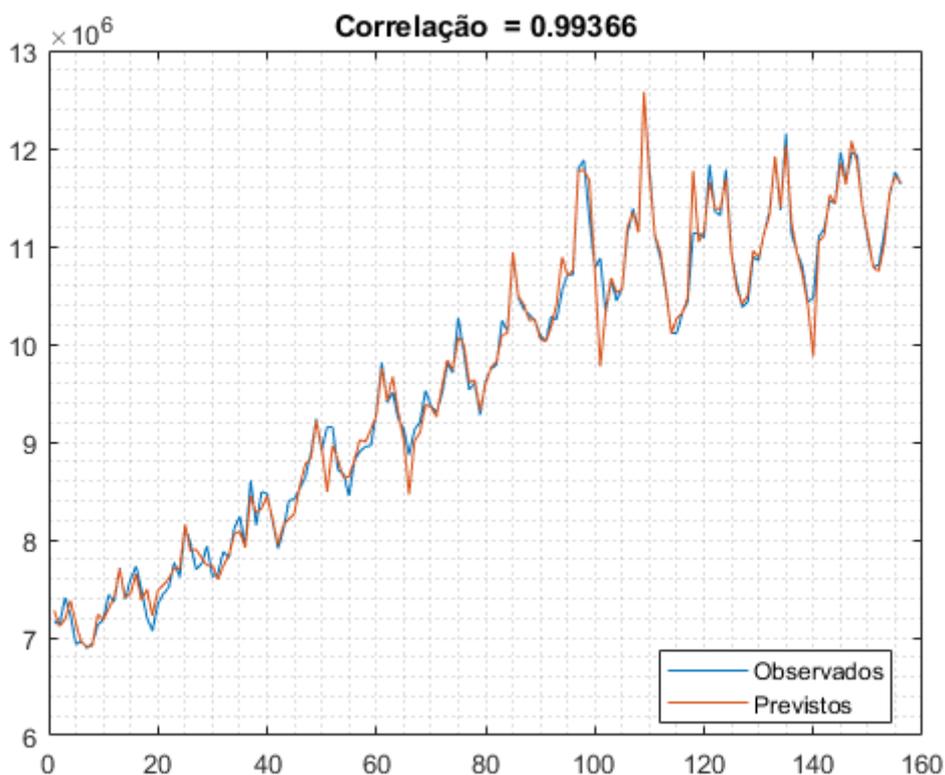
Fonte: A autora

Comparativamente, a RNA programada produziu resultados mais próximos aos valores reais, no entanto, a capacidade de previsão de uma RNA se torna melhor quanto maior a quantidade de dados para aprendizado se tenha. Para a série histórica escolhida de valores mensais, uma série histórica com pouco menos de duzentos valores gerou uma previsão menos precisa do que seria obtido com uma série histórica com quantidade maior de elementos.

A melhor precisão da RNA implementada em relação à desenvolvida com *Toolbox* possivelmente se deu pelo fato do *Toolbox* utilizar de cálculos de aproximação estatística, enquanto a RNA implementada usa cálculos estabelecidos pelo desenvolvedor da aplicação, o que a torna mais específica para aplicação proposta, sendo assim melhor calibrada para as unidades de medida utilizadas. O *Toolbox* é uma ferramenta de desenvolvimento bastante útil, no entanto, é mais generalista, e feita para se adaptar automaticamente aos dados de entrada.

A aplicação gerada com *Toolbox* permite ajustar o número de neurônios nas camadas ocultas, mas não permite ajustar o número de neurônios da camada de entrada ou de saída, e sempre ajusta o número de neurônios da camada de entrada automaticamente, de acordo com o número de dados de entrada; Silva (2010) comenta em seu livro que o número excessivo de neurônios, o ajuste inadequado da taxa de aprendizagem ou um mau ajuste dos pesos pode incorrer num problema chamado de *overfitting*, que é um termo estatístico que descreve o que ocorre quando um modelo estatístico se ajusta muito bem ao conjunto de dados anteriormente observados, mas se mostra ineficaz para prever novos resultados, como é possível ver no Gráfico 12, que mostra os dados de treinamento da RNA implementada com *Toolbox* com dados do setor residencial.

Gráfico 12 – Dados de treinamento da RNA vs dados reais



Fonte: A Autora

A RNA programada, no entanto, pode ter todos os parâmetros ajustados de acordo com a necessidade do modelo, e isso melhora a qualidade dos resultados. Por não usar aproximações estatísticas, problemas de *overfitting* são atenuados.

Os resultados obtidos pela rede obtiveram boa precisão em relação aos valores reais dos anos analisados, mas vale salientar que RNAs podem ser mais ou menos precisas de acordo com o número de variáveis que usa, ajuste do número de neurônios para entrada, camadas ocultas e saídas. O modelo utilizado usa apenas a série temporal de consumo como variável de entrada; utilizando outras variáveis, como histórico de temperatura, histórico de chuvas, feriados, entre outros, seria possível fazer uma análise ainda mais precisa, visto que a sazonalidade e fatores ambientais influenciam o consumo de variados setores. Em particular, o ano de 2020 teve uma mudança comportamental para o setor residencial inesperada: com o acontecimento da pandemia de Sars-Cov-2, que se estendeu pelo ano de 2021 e ainda sem previsão de término, muitos usuários migraram de escritórios comerciais para home office, o que configurou um aumento inesperado no consumo elétrico do setor residencial. Esta migração de usuários ainda não é uma tendência confirmada, pois o cenário instável da pandemia não permite ainda dizer com certeza se estes usuários permanecerão em home office ou se retornarão aos escritórios. Mesmo sob este panorama incerto, a rede neural artificial MLP apresentou resultados consistentes e satisfatórios.

## 6 CONCLUSÃO

As RNAs Artificiais vem sendo usadas há mais de vinte anos como método de modelagem matemática para problemas diversos, sendo um deles a previsão de séries temporais. Como mecanismo de previsão de séries temporais, as RNAs também são úteis para previsão de cargas elétricas. Para previsão de cargas do setor residencial do Brasil para um horizonte de dois anos, a RNA utilizada apresentou um MAPE de 3,97% para o consumo residencial, e uma MAPE de 2,9% para o consumo de todas as classes. A rede implementada obteve MAPE de 3,19% para o setor residencial e 2,25% para o consumo total.

A RNA implementada com Toolbox se mostrou menos precisa para obter previsões para este modelo, pois apresentou erro de *overfitting* devido ao uso de aproximações estatísticas pelo *Toolbox* do programa Matlab. O *Toolbox* visa facilitar a construção de programas, mas sua natureza generalista pode não atender as necessidades específicas do problema proposto, como o valor alto das variáveis analisadas, na ordem de milhões de MWh.

A RNA implementada por Toolbox também não permite que todos os parâmetros de rede sejam manipulados pelo usuário, diminuindo a possibilidade de customização da RNA. Já a RNA implementada tem seus parâmetros de rede calibrados para a magnitude dos valores utilizados, e também tem um melhor controle e refinamento dos parâmetros de rede, tornando suas saídas mais precisas. As RNAs utilizadas se mostraram ferramentas úteis para a previsão de consumo de energia elétrica, sendo a rede implementada um pouco mais precisa que a rede gerada com o *Toolbox* do Matlab, podendo esta ser refinada para obter resultados melhores.

## SUGESTÕES PARA TRABALHOS FUTUROS

Para trabalhos futuros, pode-se desenvolver uma rede implementada por *Toolbox* mais precisa nas previsões utilizando mais variáveis, como a mudança de estação climática, temperatura, o possível acontecimento de eventos comemorativos, rotatividade turística, sendo também possível adicionar os cálculos específicos para RNAs, criando uma rede mista.

## REFERÊNCIAS

AMJADY, Nima; KEYNIA, Farshid. A new neural network approach to short term load forecasting of electrical power systems. **Energies**, v. 4, n. 3, p. 488-503, 2011..

AZADEH, A.; GHADERI, S. F.; SOHRABKHANI, S. A simulated-based neural network algorithm for forecasting electrical energy consumption in Iran. **Energy policy**, v. 36, n. 7, p. 2637-2644, 2008.

BOU, Angel Santiago Fernandez · **Previsão De Carga Elétrica No Curto Prazo Com Redes Neurais** , Engevista, V. 16, n. 1, p.91-101, 2014

BURDEN, Frank; WINKLER, Dave. Bayesian regularization of neural networks. **Artificial neural networks**, p. 23-42, 2008.

Carneiro, T. C., de Carvalho, P. C. M., Alves dos Santos, H., Lima, M. A. F. B., & Braga, A. P. D. S. (2022). **REVIEW ON PHOTOVOLTAIC POWER AND SOLAR RESOURCE FORECASTING: CURRENT STATUS AND TRENDS**. *Journal of Solar Energy Engineering*, 144(1).

COSTA, Valéria Nunes, et al. **Redes Neurais Artificiais Aplicadas na Projeção de Carga de Curto prazo**, XXV Seminário Nacional de Produção e Transmissão de energia elétrica, Belo Horizonte, 2019

DA SILVA, Ivan Nunes; SPATTI, Danilo Hernane; FLAUZINO, Rogério Andrade. *Redes neurais artificiais para engenharia e ciências aplicadas-curso prático*. São Paulo: Artliber, 2010.

DE BARROS SILVA, André Wagner et al. Methodology Based on Artificial Neural Networks for Hourly Forecasting of PV Plants Generation. **IEEE Latin America Transactions**, v. 20, n. 4, p. 659-668, 2022.

DEEP Learning Book: Capítulo 2 – Uma Breve História das Redes Neurais Artificiais. 2018. disponível em: <http://deeplearningbook.com.br/uma-breve-historia-das-redes-neurais-artificiais/>, acesso em: 17 dez 2021

EPE. **Balanco Energético Nacional 2021 – Ano base 2020: Relatório Final**. 2021.

Gizmodo, 2018

Disponível em: <https://gizmodo.uol.com.br/documentario-alphago/>

Acesso em: 15/01/2022

GHOMI, Mohammad; GOODARZI, Mahdi; GOODARZI, Mahmood. **Peak load forecasting of electric utilities for west province of iran by using neural network without weather information**. *In: 2010 12th International Conference on Computer Modelling and Simulation*. IEEE, 2010. p. 28-32.

HAYKIN, Simon. **Redes neurais: princípios e prática**. Bookman Editora, 2007.

KUO, Ping-Huan; HUANG, Chiou-Jye. **A High Precision Artificial Neural Networks Model For Short-Term Energy Load Forecasting**. *Energies*, v. 11, n. 1, p. 213, 2018.

LABOISSIERE, Leonel A.; FERNANDES, Ricardo AS. **Redes Neurais Artificiais Aplicadas À Previsão De Demanda De Energia Elétrica No Horizonte De Curtíssimo Prazo Para Cidades Inteligentes**. ISSN 2447-8326. V.1, 2018

MOTA, D.D., SANTOS, T.R. **Projeção Do Consumo De Energia Elétrica Das Classes Residencial E Comercial Na Área De Concessão Da Cemig**, XXV SNPTEE seminário nacional de produção e transmissão de energia elétrica, Belo Horizonte, 2019

NIPS, Conferência 2009, Disponível em: <https://nips.cc/Conferences/2009>  
Acesso em: 15/01/2022

ONS. Previsão de Cargas para o Planejamento Anual da Operação Energética- 2020 a 2016. <http://www.ons.org.br/> acesso em 28/01/2022

PROTASIEWICZ, Jaroslaw; SOWIŃSKI, Jakub S. Improvement of MLP models for forecasting electrical energy consumption using OBD and OBS methods. In: **2015 IEEE International Conference on Industrial Technology (ICIT)**. IEEE, 2015. p. 1526-1531.

SAAD, Z. et al. **Short-term load forecasting of 415V, 11kV and 33kV electrical systems using MLP network**. In: 2017 International Conference on Robotics, Automation and Sciences (ICORAS). IEEE, 2017. p. 1-5.

Silva, A. W. B., Freitas, B. B., de Alencar Filho, C. L., de Freitas, C. D., de Sousa Junior, E. A., de Castro, E. S., ... & Carneiro, T. C. (2022). **METHODOLOGY BASED ON ARTIFICIAL NEURAL NETWORKS FOR HOURLY FORECASTING OF PV PLANTS** Generation. *IEEE Latin America Transactions*, 20(4), 659-668.

**TechTudo**, 2018

Disponível em: <https://www.techtudo.com.br/noticias/2014/03/facebook-melhora-reconhecimento-facial-e-chega-quase-ao-nivel-humano.ghtml>  
Acesso em: 15/01/2022

TSAKOUMIS, A. C.; VLADOV, S. S.; MLADENOV, V. M. **Electric load forecasting with multilayer perceptron and Elman neural network**. In: 6th Seminar on Neural Network Applications in Electrical Engineering. IEEE, 2002. p. 87-90.

UNIVERSIDADE FEDERAL DO CEARÁ. Biblioteca Universitária. **Guia de normalização de trabalhos acadêmicos da Universidade Federal do Ceará**. Fortaleza, 2013.

**Veja**, 2014

Disponível em: <https://veja.abril.com.br/tecnologia/google-compra-startup-de-inteligencia-artificial-deepmind/>  
Acesso em: 15/01/2022