



**MINISTÉRIO DA EDUCAÇÃO  
UNIVERSIDADE FEDERAL DO PIAUÍ  
PRÓ-REITORIA DE ENSINO DE PÓS-GRADUAÇÃO  
CENTRO DE TECNOLOGIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA  
CAMPUS UNIVERSITÁRIO PETRÔNIO PORTELA**

**MÁRIO RODRIGUES GOMES MEIRELES FILHO**

**UMA ABORDAGEM PREDITIVA PARA A PRODUÇÃO DE MEL COM BASE EM  
DADOS CLIMÁTICOS**

Teresina  
2022

**MÁRIO RODRIGUES GOMES MEIRELES FILHO**

**UMA ABORDAGEM PREDITIVA PARA A PRODUÇÃO DE MEL COM BASE EM  
DADOS CLIMÁTICOS**

Dissertação apresentada ao Programa de Pós-Graduação (*Strictu Sensu*) em nível de Mestrado em Engenharia Elétrica da Universidade Federal do Piauí, como parte dos requisitos para obtenção do título de Mestre em Engenharia Elétrica.

Orientador Prof. Dr. Aldir Silva Sousa

Teresina  
2022

FICHA CATALOGRÁFICA  
Universidade Federal do Piauí  
Biblioteca Comunitária Jornalista Carlos Castello Branco Serviço  
de Processos Técnicos

M514a Meireles Filho, Mário Rodrigues Gomes.

Uma abordagem preditiva para a produção de mel com base em dados climáticos / Mário Rodrigues Gomes Meireles Filho. – 2022.

80 f.

Dissertação (Mestrado) – Universidade Federal do Piauí, Programa de Pós-Graduação em Engenharia Elétrica, Teresina, 2022.

“Orientador: Prof. Dr. Aldir Silva Sousa.”

1. Produção de mel. 2. Redes Neurais. 3. Clima. 4. Predição.

I. Sousa, Aldir Silva. II. Título.

CDD 621.3

**MÁRIO RODRIGUES GOMES MEIRELES FILHO**

**UMA ABORDAGEM PREDITIVA PARA A PRODUÇÃO DE MEL COM BASE EM  
DADOS CLIMÁTICOS**

Dissertação apresentada ao Programa de Pós-Graduação (*Strictu Sensu*) em nível de Mestrado em Engenharia Elétrica da Universidade Federal do Piauí, como parte dos requisitos para obtenção do título de Mestre em Engenharia Elétrica.

Orientador Prof. Dr. Aldir Silva Sousa

Aprovado em maio de 2022.

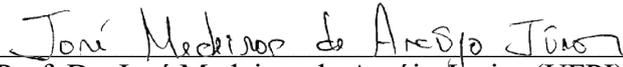
**BANCA EXAMINADORA**

---



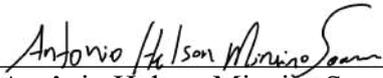
Prof. Dr. Aldir Silva Sousa (UFPI)  
Orientador

---



Prof. Dr. José Medeiros de Araújo Júnior (UFPI)  
Examinador

---



Prof. Dr. Antônio Helson Mineiro Soares (UFPI)  
Examinador

Dedico esse trabalho à minha esposa Joelma Meireles, e aos meus filhos Nathalia e Arthur, que são minhas fontes de inspiração e dedicação.

Aos meus pais Mário Meireles e Carmen Meireles, que com seu amor e dedicação, são o meu porto seguro.

## AGRADECIMENTOS

Nesses anos de mestrado, de muito estudo, esforço e empenho, gostaria de agradecer a algumas pessoas que me acompanharam e foram fundamentais para a realização de mais esse sonho. Por isso, expresso aqui, por meio de palavras sinceras, um pouquinho da importância que elas tiveram, e ainda têm, nesta conquista e a minha gratidão à todas elas.

Primeiramente agradeço à minha esposa Joelma; aos meus filhos Nathalia e Arthur; aos meus pais Mario e Carmen; e aos meus irmãos Marilaque, Socorro, Graça e Joaquim, pela compreensão, ao serem privados em muitos momentos da minha companhia e atenção, e pelo profundo apoio, estimulando-me nos momentos mais difíceis. Obrigado por desejarem sempre o melhor para mim, pelo esforço que fizeram para que eu pudesse superar cada obstáculo em meu caminho e chegar aqui e, principalmente, pelo amor imenso que vocês têm por mim. A vocês, minha família, sou eternamente grato por tudo que sou, por tudo que consegui conquistar e pela felicidade que tenho. Minha gratidão especial ao Prof. Dr. Aldir Silva Sousa, meu orientador e, sobretudo, um querido e grande amigo, pela pessoa e profissional que é. Obrigado por sua dedicação, que o fez, por muitas vezes, deixar de lado seus momentos de descanso para me ajudar e me orientar. E principalmente obrigado por sempre ter acreditado e depositado sua confiança em mim ao longo desses anos. Sem sua orientação, apoio, confiança e amizade, em todo o caminho percorrido até aqui, nada disso seria possível. Um obrigado especial aos amigos e professores Laurielson Alencar e Werton Costa, cujas contribuições foram fundamentais para o desenvolvimento desse trabalho. Quero também agradecer aos amigos e companheiros de mestrado em Engenharia Elétrica, pela inestimável ajuda nas diversas disciplinas e que tanto contribuíram para o conhecimento necessário para o desenvolvimento deste trabalho. Agradeço também aos professores do mestrado em Engenharia que tanto contribuíram com suas habilidades, conselhos, sugestões e interesse em contribuir para o meu desenvolvimento. Agradeço aos membros da CODEVAP (Cooperativa de Desenvolvimento Rural do Vale do Rio Piracuruca LTDA) que me forneceu informações valiosas para o desenvolvimento deste trabalho. Agradeço a todos que direta ou indiretamente colaboraram para que este trabalho se tornasse uma realidade. Agradeço a Deus por me abençoar com tantos presentes divinos, me dando talvez além do que posso merecer. Obrigado, meu pai, por tudo de bom que tenho e que sou. Sem essa força divina, nenhuma conquista seria possível.

*Predição é muito difícil, especialmente se  
for sobre o futuro.*

*Niels Bohr*

## RESUMO

O Estado do Piauí é um dos maiores produtores de mel do Brasil, tendo a apicultura uma grande importância socioeconômica para vários municípios do Estado. Conhecer os fatores que permitam o desenvolvimento da produção melífera, são essenciais para o crescimento econômico, principalmente para a apicultura ligada à agricultura familiar. As mudanças climáticas de uma região são uma das características que interferem diretamente na produção do mel. Desta forma, buscar conhecer como essas alterações podem interferir no resultado do desenvolvimento da apicultura é de fundamental importância para o setor produtivo. O uso de tecnologias de Inteligência Artificial permite a execução de atividades como reconhecimento de padrões e previsões de valores a partir de séries temporais. Neste trabalho foram investigadas combinações de modelos de Redes Neurais (CNN-Dense; GRU-Dense e LSTM-Dense), com o intuito de determinar qual apresenta melhor desempenho na previsão do quantitativo de mel produzido com base nos dados climáticos diários. Neste trabalho, usamos como estudo de casos, dados da região de Piracuruca. As redes estudadas obtiveram resultados nos índices de erro médio quadrático – RMSE (*Root Mean Squared Error*) e desvio padrão da produção inferiores a 3% do valor da produção para um período estudado. Dos modelos propostos no estudo, pode-se destacar o modelo LSTM-Dense, do qual se obteve os melhores resultados nos índices estudados, principalmente no índice R<sup>2</sup>, que representa o coeficiente de determinação, obtendo uma precisão de 99,999% quando comparado aos resultados encontrados da produção pela rede neural com os dados conhecidos da base de teste. Demonstrou-se assim a eficiência no uso dos modelos de Redes Neurais para o reconhecimento de padrões climáticos na previsão da produção de mel.

**Palavras Chaves:** Produção de mel. Redes Neurais. Clima. Previsão. CNN. LSTM. GRU.

## ABSTRACT

The State of Piauí is one of the largest producers of honey in Brazil, with beekeeping having a great socioeconomic importance for several municipalities in the State. Knowing the factors that allow the development of honey production are essential for economic growth, especially for beekeeping linked to family farming. The climatic changes in a region are one of the characteristics that directly interfere in the production of honey. In this way, seeking to know how these changes can interfere with the result of the development of beekeeping is of fundamental importance for the productive sector. The use of Artificial Intelligence technologies allows the execution of activities such as pattern recognition and value predictions from time series. In this work, combinations of Neural Networks models (CNN-Dense; GRU-Dense and LSTM-Dense) were investigated, in order to determine which, one has the best performance in predicting the quantity of honey produced based on daily climate data. In this work, we used data from the Piracuruca region as a case study. The studied networks obtained results in the root mean squared error – RMSE (Root Mean Squared Error) and production standard deviation lower than 3% of the production value for a studied period. Of the models proposed in the study, the LSTM-Dense model can be highlighted, from which the best results were obtained in the studied indices, mainly in the R2 index, which represents the coefficient of determination, obtaining a precision of 99.999% when compared to the results found output by the neural network with the known data from the test base. Thus, it was demonstrated the efficiency in the use of Neural Network models for the recognition of climatic patterns in the prediction of honey production.

**Keywords:** Honey Production. Neural Networks. Climate. Prediction. CNN. LSTM. GRU

## LISTA DE FIGURAS

Figura 1. Percentual da produção de mel por região do Brasil em 2019.....	17
Figura 2. Produção de Mel (Kl) do Piauí nos últimos 10 anos.....	18
Figura 3. Componentes básicos de um neurônio.....	24
Figura 4. Neurônios pré e pós-sinápticos. ....	25
Figura 5. Representação de um RNA.....	28
Figura 6. Exemplo de uma RNA do tipo MLP densa.....	29
Figura 7. <i>Multilayer Perceptron</i> com 3 camadas.....	31
Figura 8. Exemplo de uma rede neural convolucional e suas diferentes camadas.....	32
Figura 9. Exemplo de funcionamento de memória em RNN.....	34
Figura 10. O módulo que se repete em uma RNN contém apenas uma única camada.....	35
Figura 11. O módulo que se repete em uma LSTM contém várias camadas.....	36
Figura 12. Estrutura de um neurônio GRU.....	37
Figura 13. Modelos de Redes RNN e <i>feedforwad</i> .....	39
Figura 14. Localização de Piracuruca no Brasil.....	42
Figura 15. Temperaturas máximas e mínimas médias de Piracuruca.....	42
Figura 16. Abelha <i>Apis Mellifera</i> .....	45
Figura 17. Exportação de Mel 2009 a 2020.....	46
Figura 18. Os sete maiores produtores do Brasil de 2011 a 2019.....	47
Figura 19. Gráfico da produção de mel da Região Nordeste.....	47
Figura 20. Exemplo de topologia da Rede Neural Convolucional e Rede Neural Densa.....	54
Figura 21. RNA LSTM-Densa.....	55
Figura 22. RNA GRU-Densa.....	55
Figura 23. Modelo de Redes RNAs utilizadas.....	60
Figura 24. RNA II- Gráfico da Produção Real e Produção Predita com margens de erro.....	64
Figura 25. RNA I (Predição para 5000 épocas) - Gráfico da Produção Real e Produção Predita com margens de erro.....	65
Figura 26. RNA I (Predição para 10.000 épocas) - Gráfico da Produção Real e Produção Predita com margens de erro.....	66
Figura 27. RNA I (Predição para 20000 épocas) - Gráfico da Produção Real e Produção Predita com margens de erro.....	67

Figura 28. RNA I (Predição para 30000 épocas) - Gráfico da Produção Real e Produção Predita com margens de erro. ....	69
Figura 29. Curva de aprendizado para RNA I 10000 épocas.....	70
Figura 30 - Curva de aprendizado para RNA I 20000 épocas .....	71
Figura 31-Curva de aprendizado para RNA I 30000 épocas. ....	71

## LISTA DE TABELAS

Tabela 1. Tabela de Produção Agrícola da Região - Base de Dados SEBRAE. ....	43
Tabela 2. Tabela de Produção Pecuária da Região - Base de Dados SEBRAE. ....	44
Tabela 3. Representação de parte da Tabela 74 (Produção de origem animal por tipo de produto) da produção anual de mel da cidade de Piracuruca referente ao período estudado.....	51
Tabela 4. Estações Meteorológicas das cidades de Piripiri e Parnaíba. ....	52
Tabela 5 - Métricas utilizadas na RNA - (Épocas livres).....	63
Tabela 6. Métricas utilizadas na RNA – (5000 épocas) .....	64
Tabela 7. Métricas utilizadas na RNA – (10.000 épocas) .....	66
Tabela 8 - Métricas utilizadas na RNA – (20.000 épocas).....	67
Tabela 9. Métricas utilizadas na RNA – (30000 épocas). ....	68
Tabela 10. Métricas utilizada na RNA para todos os modelos testados.....	69

## LISTA DE ABREVIATURAS

<b>A</b>	Ano Leitura
<b>ACC</b>	<i>Accuracy</i>
<b>Adam</b>	<i>Adaptável Momenta Estimativos</i>
<b>BDMEP</b>	Banco de Dados Meteorológicos para Ensino e Pesquisa
<b>CNN</b>	<i>Convolutional Neural Network</i>
<b>CODEVAP</b>	Cooperativa de Desenvolvimento Rural do Vale do Rio Piracuruca Ltda
<b>D</b>	Dia Leitura
<b>DP</b>	Dia Precipitação
<b>GRU</b>	<i>Gated Recurrent Unit</i>
<b>IA</b>	Inteligência Artificial
<b>IBGE</b>	Instituto Brasileiro de Geografia e Estatísticas
<b>INMET</b>	Instituto Nacional de Meteorologia
<b>LSTM</b>	<i>Long Short Term Memory</i>
<b>M</b>	Mês Leitura
<b>MA</b>	Média Aritmética Simples
<b>MLP</b>	<i>Multi Layer Perceptron</i>
<b>MSE</b>	<i>Mean Squared Error</i>
<b>P</b>	Precipitação Total
<b>PD</b>	Produção Dia ou Produtores
<b>PLN</b>	Processamento de Linguagem Natural
<b>PPM</b>	Pesquisa Pecuária Municipal
<b>PR</b>	Ponderação Regional
<b>PS</b>	Pressão
<b>PT</b>	Produção Anual
<b>RMSE</b>	<i>Root Mean Square Error</i>
<b>RNA</b>	Rede Neural Artificial
<b>RNN</b>	<i>Recurrent Neural Networks</i>
<b>SIDRA</b>	Sistema IBGE de Recuperação Automática
<b>TM</b>	Temperatura Média
<b>UR</b>	Umidade Relativa média

**VRNN**      *Vanilla Recurrent Neural Network*  
**VV**        Velocidade do Vento Máxima

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO.....</b>	<b>16</b>
<b>1.1</b>	<b>Objetivo .....</b>	<b>18</b>
<b>1.2</b>	<b>Estrutura do trabalho.....</b>	<b>18</b>
<b>2</b>	<b>REVISÃO LITERÁRIA .....</b>	<b>20</b>
<b>2.1</b>	<b>Redes Neurais.....</b>	<b>20</b>
2.1.1	Histórico .....	21
2.1.2	O Neurônio Biológico.....	24
2.1.3	Redes Neurais Artificiais .....	26
2.1.3.1	<i>Redes Neurais Convolucionais .....</i>	<i>31</i>
2.1.3.2	<i>Redes Neurais Recorrentes.....</i>	<i>33</i>
2.1.3.2.1	<i>Long Short Term Memory.....</i>	<i>35</i>
2.1.3.2.2	<i>Gated Recurrent Unit .....</i>	<i>36</i>
2.1.3.3	<i>Camadas de Rede Profunda Densa .....</i>	<i>38</i>
2.1.4	Séries Temporais .....	38
2.1.5	Estado da arte.....	39
<b>2.2</b>	<b>A cidade de Piracuruca .....</b>	<b>41</b>
2.2.1	O potencial agrícola da região .....	43
<b>2.3</b>	<b>A apicultura.....</b>	<b>44</b>
2.3.1	Produção apícolas .....	45
2.3.2	A exportação .....	46
2.3.3	A produção de mel do Piauí.....	46
2.3.4	As abelhas e o clima .....	48
<b>3</b>	<b>MÉTODOS.....</b>	<b>50</b>
<b>3.1</b>	<b>O objeto de estudo .....</b>	<b>50</b>
<b>3.2</b>	<b>Característica das Bases de Dados .....</b>	<b>50</b>

<b>3.3</b>	<b>Tabelas Climatológicas .....</b>	<b>51</b>
<b>3.4</b>	<b>Implementação .....</b>	<b>53</b>
3.4.1	Desenvolvimento e utilização das RNA.....	53
<b>4</b>	<b>METODOLOGIA E TÉCNICA .....</b>	<b>56</b>
<b>4.1</b>	<b>A Coleta de Dados .....</b>	<b>56</b>
<b>4.2</b>	<b>Tratamento dos dados coletados.....</b>	<b>56</b>
4.2.1	Preenchendo os dados ausentes.....	57
4.2.2	Criação da Tabela de Entrada.....	58
4.2.3	Criação da série temporal.....	58
<b>4.3</b>	<b>Configurando a RNA .....</b>	<b>59</b>
4.3.1	Parâmetros Gerais Considerados.....	60
<b>5</b>	<b>RESULTADOS OBTIDOS .....</b>	<b>62</b>
<b>5.1</b>	<b>Resultado das análises por erro quadrado médio .....</b>	<b>63</b>
<b>5.2</b>	<b>Resultado para 5.000 épocas .....</b>	<b>64</b>
<b>5.3</b>	<b>Resultado para 10.000 épocas .....</b>	<b>65</b>
<b>5.4</b>	<b>Resultado para 20.000 épocas .....</b>	<b>67</b>
<b>5.5</b>	<b>Resultado para 30.000 épocas .....</b>	<b>68</b>
<b>6</b>	<b>CONSIDERAÇÕES FINAIS .....</b>	<b>72</b>
<b>7</b>	<b>TRABALHOS FUTUROS.....</b>	<b>73</b>

## 1 INTRODUÇÃO

O Brasil é uma das maiores referências mundiais no setor do agronegócio (FGV, 2015), tendo um destaque especial na produção de diversos produtos como café, carnes, frangos, laranja, abacaxi e mamão (MUKHIJA, 2021).

Destaca-se ainda a produção apícola, onde o mel brasileiro é considerado um produto de alta qualidade (USDA, 2020), e ocupando no ano de 2017 a décima primeira posição na produção mundial de mel (VIDAL, 2020), correspondendo a quatro% (4%) das exportações de produção melífera mundial.

Na produção mundial, a China é o maior produtor e exportador de mel, tendo sua produção, em 2016, um total de 131 toneladas exportada, seguido pela Índia com 65 mil toneladas e Argentina, com 63 mil toneladas. O Brasil, que em 2016 ocupava o oitavo lugar em exportação de mel com (24 mil toneladas), em 2020 foi classificado como o quarto maior exportador mundial. Foram 45 mil toneladas de mel, totalizando um valor aproximado de sessenta e oito milhões de dólares aos cofres brasileiros (WITS, 2021).

No mercado brasileiro, a produção de mel é desenvolvida em todo território nacional. Entretanto, o volume produzido tem variado, como indicam as fontes de pesquisa: Censo Agropecuário e Pesquisa Pecuária Municipal (PPM), ambas desenvolvidas pelo Instituto Brasileiro de Geografia e Estatísticas (IBGE). A produção melífera brasileira no ano de 2020 foi declarada em **51.507.862 kg** (cinquenta e um milhões, quinhentos e sete mil, oitocentos e sessenta e dois quilogramas)<sup>1</sup>, sendo essa produção distribuída conforme Figura 1.

A partir da análise das regiões produtoras em 2019, pode-se destacar a região do Paraná como a unidade federativa com maior produção de mel, com 16% da produção nacional, seguido do Rio Grande do Sul com 14%, ambos da região Sul. O Piauí aparece como o terceiro maior produtor de mel do Brasil e o primeiro da região Nordeste, sendo responsável por 11% da produção de mel do Brasil, e com uma produção de cinco milhões de quilogramas de Mel (IBGE, 2020).

A produção apícola depende dos recursos naturais encontrados na região, tendo uma dependência direta das condições climáticas e ambientais dos locais de onde se encontram

---

<sup>1</sup> Fonte: a Tabela 74 do sistema SIDRA do IBGE (IBGE, 2020).

localizadas as colmeias. Dessa forma, pode-se dizer que o Brasil, com suas abundâncias ecológicas e climáticas, possui características excepcionais para o desenvolvimento da produção melífera e ampliação das exportações de produtos como: mel, cera, entre outros (BÖHLKE e PALMEIRA, 2006).

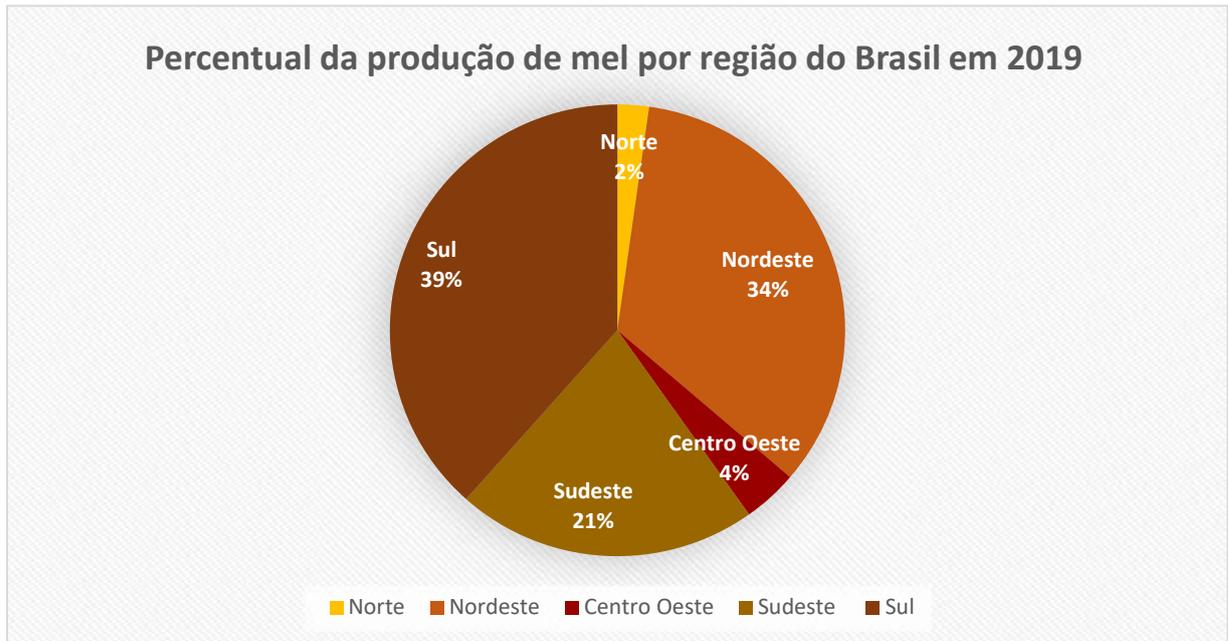


Figura 1. Percentual da produção de mel por região do Brasil em 2019  
Fonte: IBGE (2020).

Assim como nos demais estados do Nordeste, a apicultura piauiense é realizada em sua maioria por agricultores de fazenda familiar e por pequenas comunidades agrícolas, que utilizam o mel como um produto a mais em sua fonte de renda (EMBRAPA, 2014). Essa rentabilidade, torna a apicultura um atrativo para a fixação desses produtores ao campo (BÖHLKE e PALMEIRA, 2006). Deste modo, pode-se dizer que a apicultura desenvolve uma atividade que atende a critérios ecológicos, sociais e econômicos.

A produção gerada por esses apicultores, em sua maioria, é beneficiada por meio de associações ou cooperativas que buscam negociar o mel tanto no mercado interno do Brasil quanto no mercado internacional, como a Cooperativa de Desenvolvimento Rural do Vale do Rio Piracuruca Ltda (CODEVAP) no município de Piracuruca-PI (VIDAL, 2020).

A produção de mel do Piauí, vem se desenvolvendo cada vez mais nos últimos 10 anos, e apesar dessa tendência crescente, observa-se na Figura 2 uma queda nos anos de 2012, 2013 e

2016, os quais foram períodos em que o Estado sofreu com faltas de chuvas e climas quentes, o que demonstra como as condições climáticas interferem diretamente na apicultura.

Apesar da interferência climática, o Piauí tem um grande potencial para a exportação de mel, e a produção apícola do Estado tem grande influência na economia, sociedade e meio ambiente. Sabendo que o impacto do clima da região pode interferir diretamente nas colmeias e na produção do mel, o desenvolvimento de pesquisas sobre a interferência climática na produção de mel tem grande importância para o Estado, principalmente para investimentos econômicos necessários no desenvolvimento do setor.

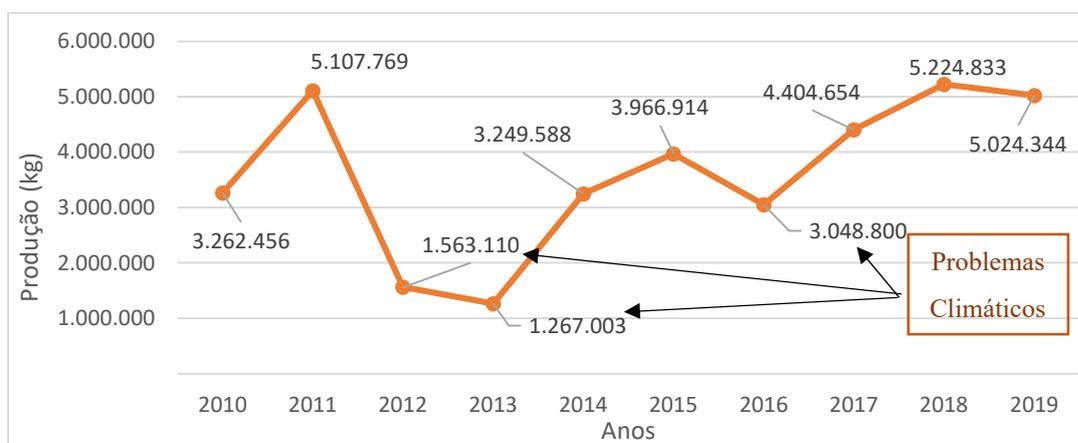


Figura 2. Produção de Mel (Kg) do Piauí nos últimos 10 anos  
Fonte: IBGE (2020).

## 1.1 Objetivo

O trabalho tem como objetivo principal desenvolver metodologias capazes de estimar a produção de mel a partir do estudo de padrões climáticos, permitindo ao apicultor melhorar o planejamento para o desenvolvimento de sua produção. Além disso, objetiva apresentar modelos de redes neurais que possam, com precisão, determinar a predição produtiva do mel.

## 1.2 Estrutura do trabalho

Esse trabalho foi dividido em sete capítulos, a saber:

- No Capítulo 2 é apresentado o embasamento teórico necessário para a condução do trabalho, como conceitos de Redes Neurais, seus tipos e estado da arte na área de pesquisa estudada, além de características do município de Piracuruca, seu clima, e produção apícola.
- O Capítulo 3 apresenta as informações necessárias para o desenvolvimento da pesquisa, como características das Bases de Dados utilizadas e sobre a implementação dos modelos de Redes Neurais escolhidos.
- O Capítulo 4 refere-se à metodologia utilizada, na qual a condução dos experimentos é detalhada, envolvendo a coleta de dados a serem inseridos na rede para as fases de treinamento e teste, explicando a solução proposta.
- O Capítulo 5, os resultados obtidos pelos modelos utilizados nos experimentos são mostrados e uma discussão é tecida, congruente com os objetivos do trabalho.
- As considerações finais são apresentadas no Capítulo 6, evidenciando a contribuição deste trabalho.
- Por fim, o Capítulo 7 aponta direcionamentos para trabalhos futuros.

## 2 REVISÃO LITERÁRIA

Neste capítulo serão apresentadas as visões literárias encontradas e estudadas, as quais serviram de base para a condução da presente pesquisa.

### 2.1 Redes Neurais

Sempre que aprendemos algo, nosso cérebro armazena o conhecimento. O computador usa memória para armazenar informações. Embora ambos armazenem informações, seus mecanismos são muito diferentes. O computador armazena informações em locais específicos da memória, enquanto o cérebro altera a associação dos neurônios. O próprio neurônio não tem capacidade de armazenamento; ele apenas transmite sinais de um neurônio para o outro. O cérebro é uma rede gigantesca desses neurônios, e a associação dos neurônios forma informações específicas (KIM, 2017).

Desde os primórdios da informática, o interesse de pesquisadores é buscar formas de simular a natureza humana no computador, incluindo a forma como pensar e agir, com cada vez mais eficiência. Com o passar dos anos, houve muitos avanços no desenvolvimento de sistemas inteligentes, alguns dos quais incluem tentativas de simular Redes Neurais Biológicas no computador. Segundo Kim (2017), a Rede Neural Artificial (RNA) imita o mecanismo do cérebro. Como o cérebro é composto por conexões de inúmeros neurônios, a RNA é construída com conexões de nós, que são elementos que correspondem aos neurônios do cérebro, e imita a associação dos neurônios, que é o mecanismo mais importante do cérebro, usando o valor do peso.

Muitos pesquisadores projetam redes neurais para o auxílio na busca de soluções para uma variedade de problemas relacionados à predição, otimização, reconhecimento de padrões etc. O uso de RNAs depende da capacidade de adaptá-las ao problema em questão, alterando os pesos sinápticos (aprendizagem) para aumentar sua eficiência.

O estudo de RNAs é um dos ramos da Inteligência Artificial (IA) que mais cresce, atraindo pessoas de diversas áreas do conhecimento, mas nem sempre a pesquisa nessa área esteve em ascensão, como será visto nesta seção. Além do histórico, também serão apresentados conceitos e funcionamento dos neurônios biológicos e das RNAs.

A seguir, será apresentado o histórico das RNAs visando identificar, de forma resumida, o avanço no desenvolvimento de sistemas inteligentes a partir das primeiras pesquisas de IA no campo das RNAs até os dias atuais.

### 2.1.1 Histórico

Os pioneiros da IA estabeleceram uma missão com um propósito de recriar a inteligência humana em uma máquina. Pesquisadores do campo baseado em regras – pesquisadores que buscam resolver problemas aplicando um conjunto de regras programadas de acordo com as informações disponíveis, utilizando os chamados sistemas especialistas – tentavam ensinar os computadores a pensar codificando uma série de regras lógicas: se X, então Y. Essa abordagem funciona bem para jogos simples e bem definidos, mas desmoronava quando o universo de escolhas ou movimentos possíveis se expandia. Para tornar o software mais aplicável a problemas do mundo real, pesquisadores do paradigma baseado em regras procuravam entrevistar especialistas nas questões que estavam sendo abordadas e, em seguida, codificar sua sabedoria na tomada de decisões do programa (LEE, 2019).

De acordo com Lee (2019), no campo das Redes Neurais, em vez de tentar ensinar ao computador as regras que tinham sido dominadas por um cérebro humano, pesquisadores tentaram imitar o próprio cérebro humano. Dado que as teias emaranhadas de neurônios nos cérebros de animais eram a única coisa capaz de criar inteligência como se conhecia, eles imaginaram que deveriam ir direto à fonte. Essa abordagem imita a arquitetura do cérebro, construindo camadas de neurônios artificiais que podem receber e transmitir informações em uma estrutura semelhante às nossas redes de neurônios biológicos. Ao contrário da abordagem baseada em regras, os construtores das redes neurais em geral não fornecem às regras a serem seguidas na tomada de decisões. Eles simplesmente inserem muitos exemplos de um determinado fenômeno (imagens, sons etc.) nas redes neurais e permitem que as próprias redes identifiquem padrões dentro dos dados.

As diferenças entre as duas visões podem ser notadas no modo como elas tratam de um problema simples: identificar se existe um gato em uma imagem. A abordagem baseada em regras tentaria estabelecer regras nos moldes “se-então” para ajudar o programa a tomar uma decisão: “se há duas formas triangulares em cima de uma forma circular, então provavelmente há um gato na foto”. A abordagem da rede neural, ao contrário, alimentaria o programa com

milhões de amostras de fotos rotuladas como gato ou “sem gato”, permitindo que o programa descubra sozinho quais recursos nos milhões de imagem estão mais correlacionados com o rótulo “gato” (LEE, 2019).

Cardon, Müller e Navaux (1994) citam o primeiro trabalho sobre Redes Neurais, que foi realizado no ano de 1943, por McCulloch e Pitts, um estudo sobre o comportamento do neurônio biológico, desenvolvido com o objetivo de criar um modelo matemático. As conclusões desta pesquisa foram de extrema importância para a futura implementação computacional do neurônio formal: (i) a atividade do neurônio é tudo ou nada, ou seja, o neurônio estará no estado ativado<sup>2</sup> se a sua saída ultrapassar um valor limite, caso contrário, ficará no estado de repouso (este princípio originou a função limiar); (ii) a atividade de qualquer sinapse inibitória previne a excitação do neurônio naquele instante: essa afirmação teve importância na construção do neurônio formal a partir do conceito de pesos, ou seja, cada entrada do neurônio terá um valor associado; caso este seja positivo, tenderá a excitar a célula; e caso ele seja negativo, tenderá a inibir.

No ano de 1949, Donald O. Hebb, no livro *Organization of Behavior*, definiu o conceito de atualização de pesos sinápticos. Hebb. concluiu que: (i) numa rede neural a informação é armazenada nos pesos; (ii) o coeficiente de aprendizagem é proporcional ao produto dos valores de ativação do neurônio; (iii) os pesos são simétricos (o peso da conexão de A para B é igual ao da de B para A); e (iv) quando ocorre o aprendizado os pesos são alterados (CARDON, MÜLLER e NAVAU, 1994).

Em 1958, Frank Rosenblatt propôs uma topologia de rede denominada de *Perceptron* ou MLP (do inglês *Multi Layer Perceptron – Perceptrons* de Múltiplas Camadas), a qual possibilitou um aumento de trabalhos relacionados a redes neurais até 1969 (FLECK, TAVARES, *et al.*, 2016). Segundo Cardon e Müller (1994), o *Perceptron* é simples: é um modelo matemático que constitui-se de uma camada de entrada e uma camada de saída: recebe várias entradas e produz uma única saída. A cada entrada existe um peso relacionado, sendo que o valor de saída do neurônio será a soma dos produtos de cada entrada pelo seu respectivo peso. O trabalho de Rosenblatt também estabeleceu a base para os algoritmos de treinamento de modelos não supervisionados e modelos supervisionados. Mais detalhes sobre o *Perceptron* são apresentados na Seção **Erro! Fonte de referência não encontrada..**

---

<sup>2</sup> Entende-se por estado ativado transmitir a saída (transmissão) a outros neurônios da rede.

O trabalho de Rosenblatt instigou um aumento de trabalhos relacionados a redes neurais até 1969. Neste mesmo ano, a publicação de Minsky e Papert mostrou deficiências e limitações do modelo MLP, provocando um desinteresse pelos estudos relacionados às RNAs (FLECK, TAVARES, *et al.*, 2016). Segundo Cardon e Müller (1994), no livro de Minsky e Papert, os autores citam o exemplo de que o *Perceptron* com uma simples camada não poderia simular o comportamento de uma simples função XOR (ou-exclusivo).

Em 1972, Teuvo Kohonen da Universidade de Helsinky definiu um novo modelo de Rede Neural, conhecido como mapa auto-organizável de características. Ao contrário do *Perceptron*, ele não era limitado a valores binários, mas os valores das entradas, dos pesos e das saídas poderiam ser contínuos. Além disso, ao invés da saída da rede ser representada pela atuação de um simples neurônio vencedor (ativado), Kohonen estabeleceu um grande número de neurônios para representar o padrão de entrada, sendo que este número é alcançado pela influência do neurônio vencedor aos seus vizinhos. Em outras palavras, não há apenas um neurônio responsável pela representação do padrão de entrada, mas sim um conjunto de neurônios que interagem entre si. Todavia, a grande importância do trabalho de Kohonen foi ter introduzido um novo paradigma no estudo das Redes Neurais: o aprendizado não supervisionado, segundo o qual a rede não precisa ficar sendo comparada constantemente a um valor de saída durante a fase de aprendizado (CARDON, MÜLLER e NAVAU, 1994).

Em 1982 houve uma nova evolução nos trabalhos das redes neurais iniciado pela criação do modelo de Hopfield, desenvolvido pelo físico John Hopfield. Este modelo se caracteriza por ser do tipo *feedback*, isto é, há uma conexão das entradas com as saídas. Por este motivo, estas redes dificilmente chegam a um estado instável, ou seja, chegará um momento em que a saída, após oscilar entre alguns valores binários, será sempre a mesma para um mesmo padrão de entrada. Hopfield, para demonstrar este fato, utilizou o exemplo de uma função matemática que decresce a cada vez que a rede troca de estado e conseqüentemente, chegará um momento em que esta função alcançará um valor mínimo e não será mais alterada. Este é o momento em que a rede alcançou a estabilidade e vários outros modelos foram criados desde então (CARDON, MÜLLER e NAVAU, 1994).

Durante sua história, as Redes Neurais desfrutaram de breves períodos de destaque, seguidos por um abandono quase total. O que finalmente ressuscitou o campo das redes neurais foram mudanças em duas das principais matérias-primas das quais as Redes Neurais se alimentam, juntamente com um grande avanço técnico. As redes neurais precisam de grandes

quantidades de duas coisas: poder de computação e dados. Os dados “treinam” o programa para reconhecer padrões, fornecendo muitos exemplos, e o poder computacional permite que o programa análise esses exemplos em alta velocidade. Tanto os dados quanto o poder de computação estavam em falta por volta dos anos 1950, mas, nas décadas seguintes, tudo isso mudou (LEE, 2019).

### 2.1.2 O Neurônio Biológico

A origem da teoria de Redes Neurais remonta aos modelos matemáticos e aos modelos de engenharia, de neurônios biológicos. A célula nervosa, ou neurônio, foi identificado anatomicamente e descrito com notável detalhe, pelo neurologista espanhol Ramón y Cajal no século 19 (FERREIRA, 2020). Como qualquer célula biológica, o neurônio é delimitado por uma fina membrana celular que, além da sua função biológica normal, possui determinadas propriedades que são essenciais para o funcionamento elétrico da célula nervosa. A partir do corpo celular, ou soma (o centro dos processos metabólicos da célula nervosa), projetam-se extensões filamentosas, os dentritos e o axônio (KOVÁCS, 2006).

Frequentemente, os dentritos cobrem um volume muitas vezes maior do que o próprio corpo celular e formam uma árvore dentrial (Figura 3). A outra projeção filamentar do corpo celular, o axônio, também referido como fibra nervosa, serve para conectar a célula nervosa a outras do sistema nervoso. O neurônio possui geralmente um único axônio, embora esse possa apresentar algumas ramificações. Em alguns casos estende-se por distâncias comparáveis às dimensões do organismo podendo chegar a vários metros. Alguns tipos de neurônios, a grande maioria dos que constituem o sistema nervoso central dos vertebrados, possuem uma capa segmentada de mielina, que serve para acelerar a transmissão da informação pelo axônio (KOVÁCS, 2006).

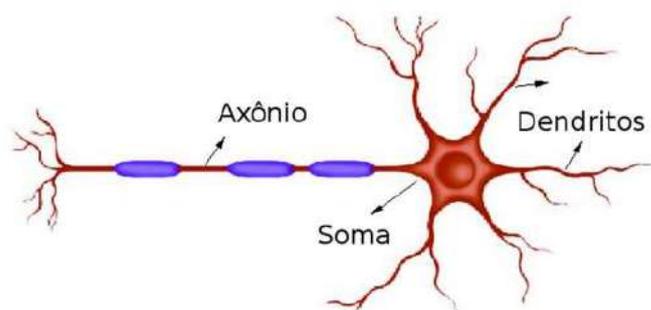


Figura 3. Componentes básicos de um neurônio.  
Fonte: Borges et al. (2015).

Kovács (2006) explica que as manifestações elétricas de neurônios biológicos foram observadas pela primeira vez no século 19 por DuBois Reymond com o auxílio de galvanômetros. O funcionamento dessas células começou a ser melhor entendido com a invenção, no final do século 19 por Crookes, do tubo de raios catódicos e com a sua aplicação à observação da atividade elétrica nervosa, principalmente por Erlanger e Gasser, na década de 1920. Essas investigações lhe renderam o prêmio Nobel de fisiologia em 1944. Nas duas décadas seguintes, como resultado do trabalho de vários pesquisadores, passou-se a entender o neurônio biológico como sendo basicamente o dispositivo computacional elementar do sistema nervoso, que possuía muitas entradas e uma saída. As entradas ocorrem por meio das conexões sinápticas, que conectam a árvore dendrital aos axônios de outras células nervosas. Os sinais que chegam por estes neurônios são pulsos elétricos conhecidos como impulsos nervosos ou potenciais de ação, e constituem a informação que o neurônio processará, de alguma forma, para produzir como saída um impulso nervoso no seu axônio.

Nas sinapses, um neurônio influencia diretamente outro(s) neurônio(s), por meio da transmissão de sinais elétricos ou químicos (BORGES, IAROSZ, *et al.*, 2015). Sinapses são regiões eletroquimicamente ativas, compreendidas entre duas membranas celulares: a membrana pré-sináptica, por onde chega um estímulo proveniente de uma outra célula, e a membrana pós-sináptica, que é a do dendrito (Figura 4). Nesta região intersináptica, o estímulo nervoso que chega à sinapse é transferido à membrana dendrital por meio de substâncias conhecidas como neurotransmissores. O resultado dessa transferência é uma alteração no potencial elétrico da membrana pós-sináptica. Dependendo do tipo de neurotransmissor, a conexão sináptica será excitatória ou inibitória. Uma conexão excitatória provoca uma alteração no potencial da membrana que contribui para a formação de um impulso nervoso no neurônio de saída enquanto que uma conexão inibitória age no sentido oposto (KOVÁCS, 2006).

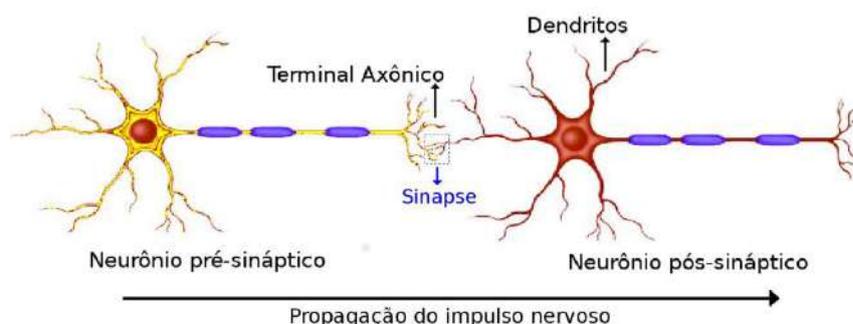


Figura 4. Neurônios pré e pós-sinápticos.  
Fonte: Borges et al. (2015).

### 2.1.3 Redes Neurais Artificiais

Pode-se definir uma RNA como “um processador maciçamente paralelo e distribuído construído de unidades de processamento simples, que tem a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso” (HAYKIN, 2008).

Pode-se dizer que RNAs consistem em um modo de resolver problemas de inteligência artificial. Neste caso, ao invés de tentar programar um computador digital para fazê-lo imitar comportamentos inteligentes (saber jogar xadrez, entender e manter diálogos, traduzir línguas estrangeiras, resolver problemas etc.), procura-se construir algoritmos que simulem as atividades do cérebro e que possam aprender novas tarefas, cometer erros, generalizar e explorar, e muitas vezes superar seu professor. Da mesma forma, esses circuitos neurais artificiais devem ser capazes de se auto alinhar quando expostos a diferentes ambientes, criando suas próprias representações internas e exibindo comportamentos imprevisíveis, e ainda ter comportamentos que nem sempre o ser humano é capaz de prever, assim como o ser humano até hoje não entende completamente a mecânica do próprio cérebro (BARRETO, 2002).

Uma RNA é uma máquina que é projetada para modelar a maneira como o cérebro realiza uma tarefa particular ou uma função de interesse, normalmente implementada utilizando componentes eletrônicos ou simulando por programação em um computador digital. Para alcançarem um bom desempenho, as RNAs empregam uma interligação maciça de células computacionais simples denominadas “neurônios” ou “unidades de processamento” (HAYKIN, 2008).

Haykin (2008) explica que uma RNA se assemelha ao cérebro em dois aspectos: (i) o conhecimento é adquirido pela rede a partir de seu ambiente por meio de um processo de aprendizagem; e (ii) forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido.

O procedimento utilizado para realizar o processo de aprendizagem, é chamado de algoritmo de aprendizagem, cuja função é modificar os pesos sinápticos da rede de uma forma ordenada para alcançar um objetivo de projeto desejado. A modificação dos pesos sinápticos é o método tradicional para o projeto de redes neurais, porém, também é possível programar uma rede neural para modificar sua própria topologia, fazendo uma analogia com os neurônios do cérebro humano que podem morrer e novas conexões sinápticas possam crescer.

Assim, para modelar o comportamento de uma RNA, é necessário entender alguns conceitos: (i) conexões e elementos de processamento que, para Cardon, Müller e Navaux (1994), podem ser vistos como componentes físicos; e (ii) padrões e funções, segundo os mesmos autores, podem ser vistos como componentes “não-físicos”. A combinação de conexões e elementos de processamento cria uma RNA, fazendo uma analogia com um grafo, onde os nodos são os elementos de processamento e as arestas são as conexões. Já os padrões são dados de entrada da rede, uma codificação que corresponde a certa modelagem da realidade de uma aplicação definida para a RNA; e funções são modelos matemáticos utilizados no treinamento e reconhecimento de padrões. Entretanto, os autores explicam que conexões, elementos de processamento, padrões e funções são os componentes básicos de qualquer RNA, mas esta terminologia não é uma regra, uma vez que não há uma norma que defina as denominações e utilização.

Além disso, segundo Cardon, Müller e Navaux (1994), as RNAs não podem operar sem dados, ou seja, são os padrões apresentados a uma RNA. Podem ser valores numéricos ou mesmo caracteres que serão posteriormente transformados em números. A um determinado padrão de entrada corresponde um sinal de saída, sendo que a dimensão (tipo) do padrão de entrada pode ser diferente do padrão de saída.

Uma das principais aplicações de RNAs é o reconhecimento (classificação) de padrões. Por exemplo, em reconhecimento da fala existem tipos diferentes de características envolvidas. Nesta aplicação, o padrão de entrada pode ser uma matriz que contém o caracter, e a saída apenas um número que indica se o caracter foi reconhecido ou não. Assim, temos um padrão de entrada com dimensão diferente do padrão de saída. Além disso, neste caso torna-se essencial um pré-processamento de informações. Isso significa que a seleção e representação correta das características do padrão a ser aplicado pode afetar a performance da rede. Criar o melhor conjunto possível de características como padrão é o primeiro passo para o sucesso de qualquer aplicação em RNAs.

Dessa forma, pode-se distinguir basicamente em dois tipos de funções utilizadas em RNAs: funções para transferência de sinais entre neurônios; e funções para aprendizado de padrões (CARDON, MÜLLER e NAVAUX, 1994). As funções de transferência, também chamadas funções de limiar, são aquelas responsáveis por determinar a forma e a intensidade de alteração dos valores transmitidos de um neurônio a outro.

Santos (2011) explica que uma RNA tem em sua formação básica interconexões (sinapses) entre unidades de processamento (neurônios), as quais permitem o processamento e armazenamento das características presentes nos dados, aprendendo a modelar relações não lineares entre entradas e saídas, e demonstrando um comportamento similar realizado pelo neurônio natural.

Entre as características das RNAs pode se destacar:

- O aprendizado, que ocorre quando ela é treinada com modelos de conhecimento pré-estabelecidos. Esse treinamento tem o objetivo de efetuar ajustes aos pesos sinápticos de forma melhorar os parâmetros de aprendizado do modelo, permitindo a RNA reconhecer uma informação de entrada com os padrões semelhantes aos modelos já estudados;
- A associação, que ocorre quando a rede aprende a reconhecer por associações com os modelos repetidos e já treinados;
- A generalização, que ocorre quando a rede apresenta uma resposta para entradas não vistas, por meio da similaridade por padrões já reconhecidos (OSÓRIO e BITTENCOURT, 2000).

De forma básica, as RNAs podem ser apresentadas por Neurônios, Topologias da conexão e Aprendizado. A RNA, baseada no neurônio biológico, é composta por pesos sinápticos, que tem a função de estudar e ponderar os valores dos dados de entradas com a função de ativação, permitindo uma análise de associação dos valores do resultado com o nível de ativação do neurônio, conforme pode ser observado na Figura 5.

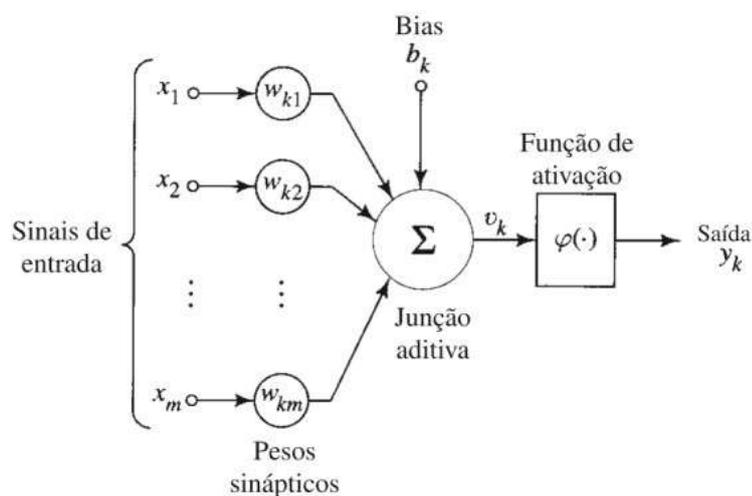


Figura 5. Representação de um RNA.  
Fonte: Haykin (2008).

A topologia da RNA representa a forma ou modelo como os neurônios se conectam. De forma geral, como representado na Figura 6, os neurônios estão divididos em três ou mais camadas, sendo a primeira de entrada, que são representadas pelas quantidades de informações que são imersas da rede, e a última camada, de saída, que representa dados de saídas da RNA e, ficando no meio, a camada intermediária, que pode conter uma ou mais camadas ocultas (OSÓRIO e BITTENCOURT, 2000). O fluxo de dados segue por meio da recepção dos neurônios da camada de entrada, que recebe os pesos da baía de cada neurônio, seguindo pelas camadas intermediárias até chegar na camada de saída (HAYKIN, 2008).

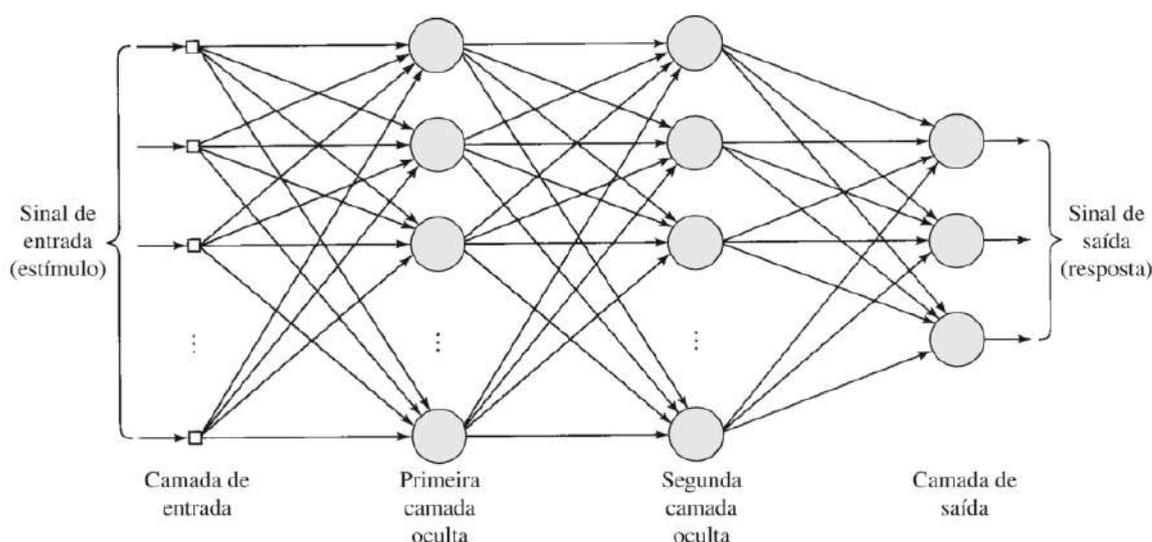


Figura 6. Exemplo de uma RNA do tipo MLP densa  
Fonte: Haykin (2008).

O aprendizado é a etapa em que a RNA é programada para o reconhecimento de padrões, por meios de valores já apresentados à rede, podendo ser realizado de duas maneiras diferentes: por treinamento supervisionado, quando a rede é alimentada por valores de entrada e seus respectivos valores de saídas, que são os valores desejados; e por treinamento não supervisionado, no qual a rede estima valores de saída por maiores semelhanças (FLECK, TAVARES, *et al.*, 2016).

O algoritmo do *Perceptron* é um classificador linear binário em sistemas com aprendizado supervisionado (BIERMANN, 2019). O *Perceptron*, conforme exemplo que pode ser visto na Figura 5, é construído em torno de um neurônio não linear, isto é, o modelo de McCulloch-Pitts de um neurônio, que consiste em um combinador linear seguido por um limitador abrupto realizando a função sinal. O nó aditivo do modelo neuronal calcula uma combinação linear das entradas aplicadas às suas sinapses e incorpora um *bias* aplicado

externamente. A soma resultante, isto é, o campo local induzido, é aplicado ao limitador abrupto. Correspondentemente, o neurônio produz uma saída igual a +1 se a entrada do limitador abrupto for positiva e -1 se for negativa (HAYKIN, 2008).

Segundo Biermann (2019), dado um conjunto de valores binários de entrada, denominado por  $x_1, x_2, \dots, x_n$ , o Perceptron produz uma saída binária  $\hat{y}$ . Também são utilizados os seguintes dois parâmetros: conjunto de pesos,  $\omega_1, \omega_2, \dots, \omega_n$  e um número real  $b$ , denominado *bias*. O valor de saída do algoritmo se dá por:

$$\hat{y} = \begin{cases} 0, & \text{se } W \cdot X > 0 \\ 1, & \text{se } W \cdot X \leq 0 \end{cases}$$

onde  $W$  e  $X$  são matrizes que contém os valores de  $\omega$  e  $x$  respectivamente e

$$W \cdot X = \sum_{i=1}^n \omega_i x_i$$

O valor de *bias* representa a inclinação de um neurônio ser ativado, ou seja, quanto maior for o seu valor, maior é a chance da saída de seu *perceptron* ser 1 (BIERMANN, 2019).

Já a rede *Multilayer Perceptron* (rede de múltiplas camadas) consiste de um conjunto de unidades sensoriais (nós de fonte) que constitui a camada de entrada, uma ou mais camadas ocultas de nós computacionais e uma camada de saída também constituída de nós computacionais. O sinal de entrada se propaga pela frente através da rede, camada por camada (HAYKIN, 2008).

Biermann (2019) explica que uma rede com apenas uma camada só pode representar funções linearmente separáveis, portanto para que problemas mais complexos possam ser resolvidos, são utilizadas redes com múltiplas camadas.

A Figura 7 mostra uma representação de uma rede com três camadas, sendo duas pertencentes ao conjunto das *Hidden Layers*, com 4 e 3 unidades de neurônios cada, e uma última de uma unidade de neurônio pertencente à *Output Layer*. (BIERMANN, 2019).

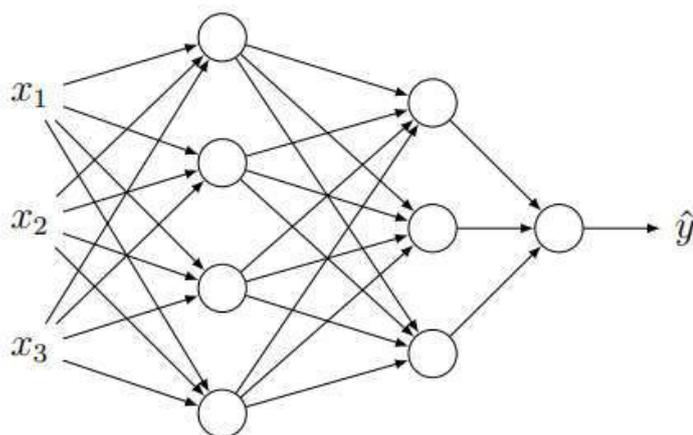


Figura 7. *Multilayer Perceptron* com 3 camadas.  
Fonte: Biermann (2019).

### 2.1.3.1 Redes Neurais Convolucionais

Redes Neurais Convolucionais (CNN, do inglês *Convolutional Neural Network*) é uma Rede Neural profunda especializada em reconhecimento de imagens e muito utilizada também em trabalhos de predição de séries temporais. Essa técnica exemplifica o quão significativo é o aprimoramento das camadas profundas para o processamento de informações. Na verdade, é uma técnica antiga, desenvolvida nas décadas de 1980 e 1990. No entanto, foi esquecida por um tempo, pois era impraticável para aplicações do mundo real, pois sua arquitetura de camada profunda foi uma barreira que dificultou o processo de treinamento. No entanto, desde que o Aprendizado Profundo (DL, do inglês *Deep Learning*) foi introduzido como solução para esse problema, o uso da CNN conquistou os campos de visão computacional (KIM, 2017).

Dessa forma, uma CNN é uma variação das redes de *Perceptrons* de Múltiplas Camadas, inspirada no processo biológico de processamentos de dados visuais. De maneira semelhante aos processos tradicionais de visão computacional, uma CNN é capaz de aplicar filtros em dados, mantendo a relação de vizinhança entre seus dados ao longo do processamento da rede (VARGAS, PAES e VASCONCELOS, 2016).

Segundo Albawi, Mohammed e Al-Zawi (2017), a CNN leva esse nome por conta da operação linear matemática entre matrizes chamada convolução. A CNN tem várias camadas, conforme pode-se observar na Figura 8, incluindo camada convolucional (*convolutional*), também camada de agrupamento (*pooling*) e camada totalmente conectada (*fully-connected*).

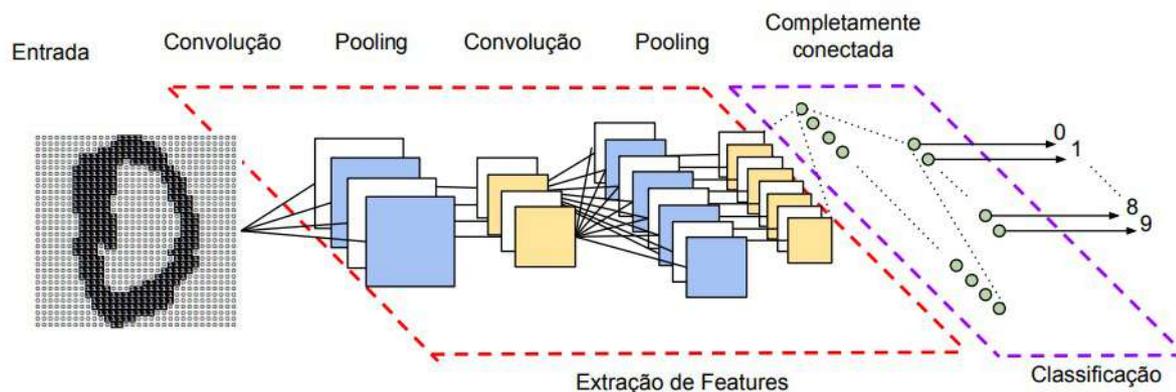


Figura 8. Exemplo de uma rede neural convolucional e suas diferentes camadas.  
 Fonte: Vargas, Paes e Vasconcelos (2016).

Uma camada de convolução é composta por diversos neurônios, cada um responsável por aplicar um filtro em um pedaço específico da imagem. Pode-se imaginar cada neurônio sendo conectado a um conjunto de *pixels* da camada anterior e que a cada uma dessas conexões se atribui um peso. A combinação das entradas de um neurônio, utilizando os pesos respectivos de cada uma de suas conexões, produz uma saída passada para a camada seguinte. Os pesos atribuídos às conexões de um neurônio podem ser interpretados como uma matriz que representa o filtro de uma convolução de imagens no domínio espacial (conhecido também como *kernel* ou máscara) (VARGAS, PAES e VASCONCELOS, 2016).

Segundo Vargas, Paes e Vasconcelos (2016), enquanto na formulação de *perceptrons* clássica um neurônio é conectado a todos os neurônios da camada anterior, dito completamente conectado, nas CNNs apenas um subconjunto de entradas é conectado a cada neurônio. Os neurônios da mesma camada são agrupados em mapas. Além disso, um mapa é produzido pelo agrupamento das saídas de neurônios que juntos cobrem uma parte da imagem que tenha sido processado com um filtro em comum. Para que um conjunto de neurônios de um determinado mapa aplique o mesmo filtro em diferentes posições da imagem, é feito um compartilhamento dos pesos durante o processo de treinamento. Tal compartilhamento diminui significativamente o número de parâmetros a serem aprendidos e o tempo de treinamento da rede, conseqüentemente.

Os autores ainda explicam que é comum, logo após a convolução, aplicar uma função de ativação. A função de ativação presente em cada neurônio é responsável por aplicar uma transformação nos dados recebidos. Normalmente, utiliza-se funções com algum grau de não-linearidade. A não linearidade das camadas intermediárias permite que as aplicações sucessivas

dessas distorções (resultado da transformação dos dados) tornem as categorias de saída linearmente separáveis.

A função da camada de agrupamento (*pooling*) é reduzir a dimensionalidade dos dados na rede, agrupando um conjunto de dados. A camada totalmente conectada é responsável por traçar um caminho de decisão a partir das respostas dos filtros vindos das camadas anteriores, para cada classe de resposta. As próximas camadas da rede fazem o papel dos algoritmos de aprendizado de máquina tradicionalmente aplicadas para classificar os dados ou aplicar algum tipo de regressão. (VARGAS, PAES e VASCONCELOS, 2016).

Quando se deseja realizar uma tarefa de classificação, é acrescentada após o conjunto das camadas de convolução e *pooling* ao menos uma camada totalmente conectada. Esta camada é responsável por traçar um caminho de decisão a partir das respostas dos filtros vindos das camadas anteriores, para cada classe de resposta. Depois, o último passo é a classificação. Essa camada é fundamental no treinamento, pois influencia no aprendizado dos filtros e consequentemente no resultado da rede. (VARGAS, PAES e VASCONCELOS, 2016).

A vantagem de se utilizar CNN é reduzir o número de parâmetros em uma RNA. Além disso, é possível detectar e reconhecer recursos independentemente de suas posições na imagem. Assim, pesquisadores e desenvolvedores passaram a abordar modelos maiores para resolver tarefas complexas, o que não era possível com as RNAs clássicas (ALBAWI, MOHAMMED e AL-ZAWI, 2017).

### 2.1.3.2 Redes Neurais Recorrentes

Redes Neurais Recorrentes (RNN, do inglês *Recurrent Neural Network*) são uma classe de modelos de aprendizado de máquina supervisionados, feitos de neurônios artificiais com um ou mais *loops* de *feedback*. Os *loops* de realimentação são ciclos recorrentes ao longo do tempo ou sequência. O treinamento de uma RNN de forma supervisionada requer um conjunto de dados de treinamento de pares de entradas-alvo. O objetivo é minimizar a diferença entre os pares de saída e alvo (ou seja, o valor da perda) otimizando os pesos da rede (SALEHINEJAD, SANKAR, *et al.*, 2018).

Uma RNN visa fazer previsões sobre dados sequenciais, utilizando uma arquitetura baseada em memória. Segundo Salehinejad et al., (2018), a RNN é capaz de modelar dados sequenciais para reconhecimento e predição de sequências e é feita de estados ocultos de alta

dimensão com dinâmica não linear. A estrutura de estados ocultos funciona como a memória da rede, e o estado da camada oculta de cada vez é condicionado ao seu estado anterior. Essa estrutura permite que as RNNs armazenem, lembrem e processem sinais complexos passados por longos períodos. As RNNs podem mapear uma sequência de entrada para a sequência de saída no passo de tempo atual e prever a sequência no próximo passo de tempo.

Uma Rede Neural convencional atua como uma função de mapeamento, na qual uma única entrada é associada a uma única saída. Nela, duas entradas não compartilham conhecimento e cada uma se move em apenas uma direção, começando nos nós de entrada, passando pelos nós ocultos e terminando nos nós de saída. Já uma RNN usa um estado de memória adicional. Observando a Figura 9, quando uma entrada A (palavra “eu”) é adicionada, a rede produz uma saída B (palavra “amor”) e armazena informações sobre a entrada A no estado de memória. Quando a próxima entrada A (palavra “amor”) é adicionada, a rede produz a saída associada B (palavra “para”) com a ajuda do estado da memória. Em seguida, o estado da memória é atualizado usando informações da nova entrada A. Esta operação é repetida para cada entrada. Com esse método, as previsões dependem não apenas da entrada atual, mas também dos dados anteriores (KOSTADINOV, 2018).

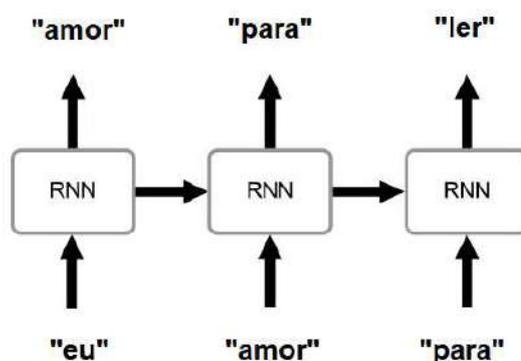


Figura 9. Exemplo de funcionamento de memória em RNN.  
Fonte: adaptada de Kostadinov (2018).

As RNNs foram introduzidas pela primeira vez na década de 1980 com a invenção da rede Hopfield. Mais tarde, em 1997, Hochreiter e Schmidhuber propuseram um modelo avançado de RNN, a Memória de Curto e Longo Prazo (LSTM, do inglês *Long Short Term Memory*), que visa resolver alguns problemas do modelo de RNN mais simples (KOSTADINOV, 2018). A LSTM está apresentada na Subseção a seguir.

### 2.1.3.2.1 Long Short Term Memory

Segundo Pereira (2017), Redes LSTM são um tipo especial de RNN, capazes de aprender dependências de longo prazo. Elas foram introduzidas inicialmente por Hochreiter e Schmidhuber em 1997 e funcionam muito bem em uma grande variedade de problemas (PEREIRA, 2017). As redes LSTM possuem as mesmas propriedades das redes RNN convencionais, entretanto possuem a capacidade de armazenar informações por longos períodos ao processar uma sequência temporal. Os pontos de memória de uma rede LSTM são denominadas células. As células são capazes de carregar informações até o final de uma sequência ou identificar as informações que devem ser esquecidas pela rede a partir de alguma etapa de processamento (SANTOS, 2019).

Todas as RNNs têm a forma de uma cadeia de módulos que se repetem em uma Rede Neural. Em uma RNN padrão, esse módulo tem uma estrutura bem simples, como por exemplo uma camada com a função *tanh* conforme a Figura 10, na qual  $x_t$  é a entrada da rede no momento  $t$ ,  $h_t$  é a saída da célula no instante  $t$ .

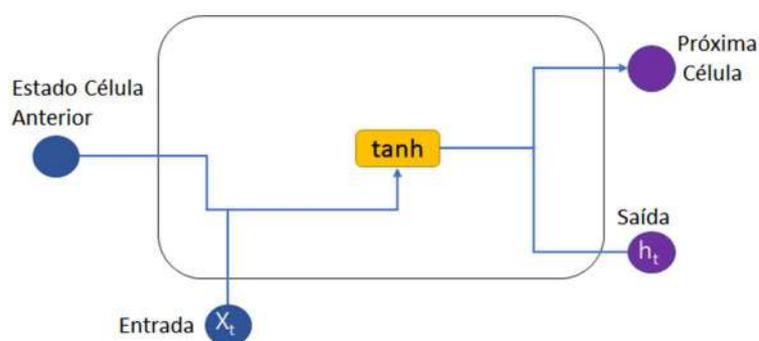


Figura 10. O módulo que se repete em uma RNN contém apenas uma única camada.  
Fonte: Própria adaptado de Pereira (2017).

As LSTM, segundo Pereira (2017), também possuem essa estrutura de cadeia, mas o módulo que se repete possui uma estrutura diferente. Ao invés de ter apenas uma única camada de uma Rede Neural, existem quatro, que interagem de uma maneira bastante específica. A Figura 11 apresenta visualmente este conceito, que demonstra a estrutura temporal das LSTM.

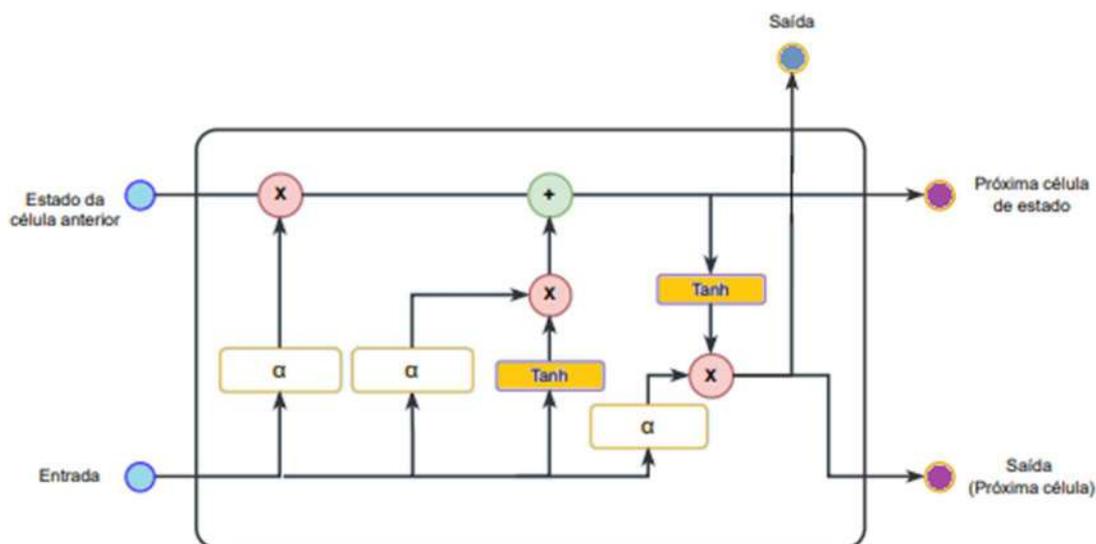


Figura 11. O módulo que se repete em uma LSTM contém várias camadas.  
 Fonte: Própria adaptado de Pereira (2017).

Se a informação de entrada será memorizada na célula ou não é uma decisão tomada por um *gate* de entrada. O *gate* de saída define se a informação será descartada no momento  $t$ . O estado de processamento será memorizado na célula e os dados de saída serão processados pelo *gate* de saída. Por meio desse design de células, as redes LSTM conseguem aprender dependências de longo prazo a partir de dados com estrutura temporal. Em geral, as redes LSTM possuem bons resultados para previsões temporais (GREFF et al., 2016, citado por SANTOS, 2019).

Outro tipo de RNN é a Unidade Recorrente Fechada (GRU, do inglês *Gated Recurrent Unit*), apresentada na Subseção a seguir.

#### 2.1.3.2.2 *Gated Recurrent Unit*

A GRU pode ser considerada uma versão simplificada de uma LSTM. A GRU incorpora muitos dos mesmos conceitos, mas possui um número muito menor de parâmetros (pesos) e, portanto, pode treinar mais rapidamente em um tamanho constante de camada oculta.

De acordo com Kostadinov (2018), o principal objetivo da GRU é produzir excelentes resultados em sequências longas. Ela consegue isso modificando a célula RNN padrão com a introdução de portas de atualização e redefinição. Esta rede funciona da mesma forma que um modelo RNN normal em termos de entradas, estados de memória e saídas. A principal diferença

está nas especificidades da célula em cada etapa de tempo. A Figura 12 apresenta uma única célula GRU.

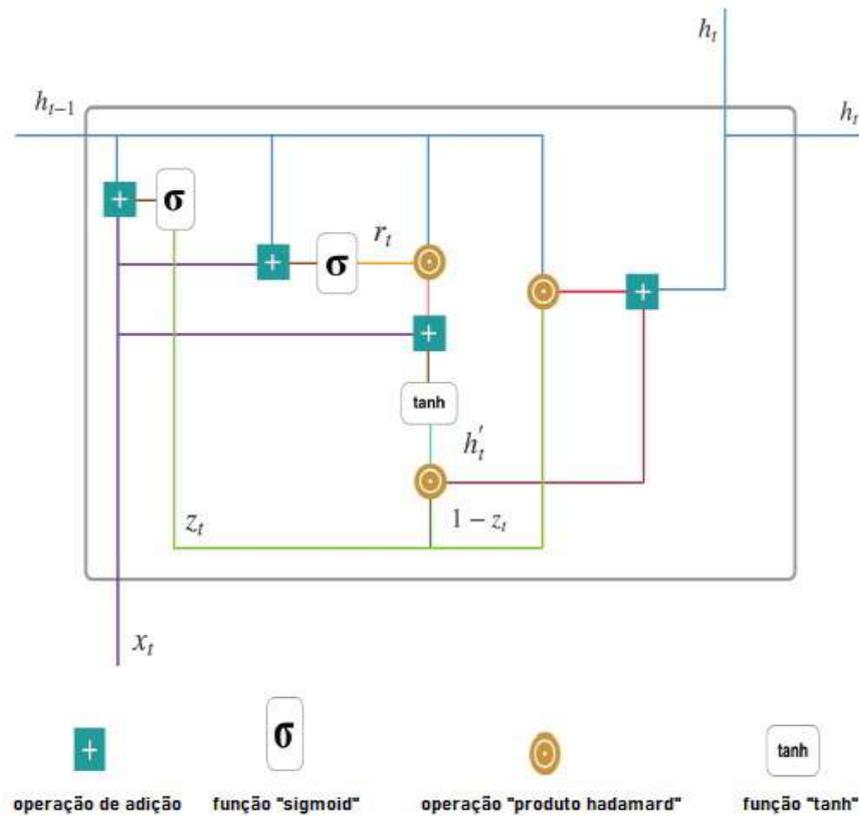


Figura 12. Estrutura de um neurônio GRU.  
Fonte: adaptado de Kostadinov (2018).

A GRU captura adaptativamente as dependências em diferentes escalas de tempo, baseando-se apenas em duas portas, atualizando e redefinindo o seu conteúdo na unidade de memória recorrente. A célula aceita  $x_t$  e  $h_{t-1}$  como entradas, onde  $x_t$  é uma representação vetorial da palavra de entrada na escala de tempo  $t$ ,  $h_{t-1}$  é o estado de memória da etapa anterior  $t-1$ . Além disso, a célula emite o estado de memória calculado da etapa atual  $t$ . O objetivo desse estado de memória intermediário é passar informações por todas as etapas de tempo e manter ou descartar o conhecimento. Dentro dessa célula GRU, os cálculos visam decidir quais informações devem ser repassadas ou eliminadas (KOSTADINOV, 2018).

Cada neurônio contém duas portas, uma porta de redefinição  $Z_t$  (*reset gate*) e uma porta de atualização  $r_t$  (*update gate*). O transporte das informações de estados ocultos anteriores para

o estado atual é controlado por meio da porta de atualização. Quanto maior o valor da porta de atualização  $Z_t$ , mais informações são preservadas dos estados anteriores. Já a porta de redefinição  $r_t$  controla até que ponto as informações dos estados anteriores são ignoradas. Quanto menor o valor desta porta, mais informações são ignoradas. As dependências de curto e longo prazo são associadas a ativação das portas de redefinição e atualização, respectivamente (SANTOS, 2021).

A GRU é mais simples em termos de arquitetura, o que torna as redes compostas por essas unidades mais fáceis de treinar, mas sua capacidade de inferência pode ser reduzida de acordo com a complexidade dos dados.

#### 2.1.3.3 Camadas de Rede Profunda Densa

Uma camada de RNA densa é uma camada totalmente conectada, geralmente utilizada para alterar a dimensionalidade da saída da camada anterior. Nesse tipo de rede todos os neurônios de uma camada são conectados com as entradas das camadas mais internas, sendo uma camada usada nos estágios finais da rede neural (SOUTO, FIGUEIREDO e OLIVEIRA, 2020).

#### 2.1.4 Séries Temporais

As chamadas Séries temporais são um conjunto de informações observáveis que tem relações temporais, tendo como características a dependência de cada ponto com seus pontos adjacentes (SOUZA, 2008). Por exemplo, dentro das tabelas climáticas, em cada item do conjunto analisado, pode-se encontrar uma série temporal discreta, por serem realizadas em intervalos de tempos específicos (hora em hora, por mês, por ano).

Séries Temporais são sequências de dados que tem relações temporais entre os pontos observados. A característica fundamental de uma série temporal é que os pontos observados adjacentes são necessariamente dependentes (OLIVEIRA, 2012, citado por ALMEIDA, 2019). Assim, uma das maneiras de estudo comportamental de uma série temporal é por meio da modelagem de suas dependências (ALMEIDA, 2019), sendo a modelagem a condição para ser possível a realização de previsões de valores futuros, bem como a geração de sequência equiprováveis.

### 2.1.5 Estado da arte

São inúmeras as aplicações para as RNAs. Suas propriedades as tornam possíveis de serem aplicadas a múltiplos domínios, como predição, otimização, controle de sistemas etc. No campo da predição de dados climáticos – parte do escopo da presente pesquisa –, a aplicação de modelos baseados nas RNAs tem despertado o interesse de pesquisadores.

Os estudos de Hseih e Tang (1998), Guimarães *et al.* (2009) e Meneses Júnior (2012) apresentam a utilização de RNA como uma das principais ferramentas encontradas de IA que podem implementar uma modelagem para dados climáticos. Dos modelos de RNAs utilizados para predição de séries temporais, destaca-se os do tipo *feedforward* com treinamento *backpropagation* de um passo adiante (*one-step-ahead prediction*); Pode-se também destacar as RNN, que apesar das semelhanças com as redes *feedforward*, elas armazenam os valores recentes de suas decisões que servem como reentradas de dados para os processamentos posteriores, sendo por isso também muito utilizada para séries temporais mais longas, conforme Figura 13.

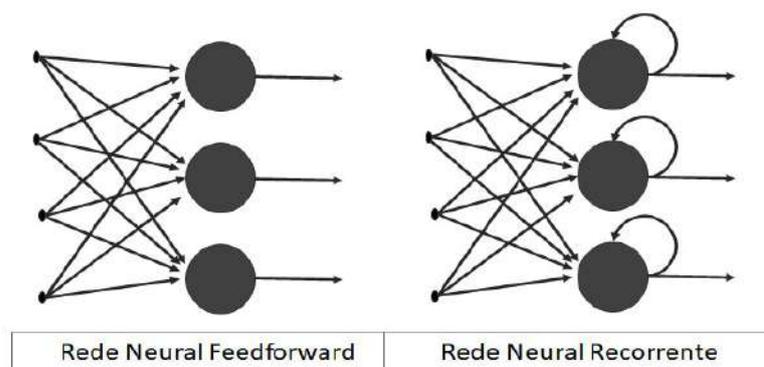


Figura 13. Modelos de Redes RNN e *feedforwrad*.  
Fonte: Autores.

Adicionalmente, podem ser encontrados diversos estudos que consideram a predição de dados climáticos, por exemplo, no envolvimento à produtividade do milho (SOUZA, 2021; GUIMARÃES, ASSAD, *et al.*, 2009), na predição de geração de energia (CUNHA e SOBEL, 2021), e na previsão de infestações de insetos (SOUZA, 2019).

Souza (2021) construiu modelos de rede MLP para a predição da produtividade do milho no Vale do Paranapanema, São Paulo, considerando parâmetros de desenvolvimento, condições climáticas e balanço hídrico. As variáveis da base de dados foram divididas em três bases com

a mesma quantidade de dados, mas com variáveis distintas. A primeira base contém os dados agrônômicos, a segunda os dados climáticos e de balanço hídrico, e, a terceira, tanto as variáveis agrônômicas quanto as climáticas. Os modelos conseguiram identificar variáveis importantes durante o estágio de desenvolvimento da planta e observou-se que as variáveis climáticas e de balanço hídricos merecem devida atenção.

Guimarães (2019) avaliou Redes Neurais *Perceptrons Multilayer Perceptron*, *Random Forest* e *Extreme Gradient Boosting*, e comparou com um modelo de estimativa de produtividade, utilizando dados climáticos e referentes ao solo adquiridos de estações meteorológicas. O modelo de aprendizado de máquina *Extreme Gradient Boosting* obteve o melhor desempenho. Os outros dois modelos, embora tenham apresentado desempenho inferiores, conseguiram realizar estimativas de 95% de acurácia.

Cunha e Sobel (2021) avaliaram o uso de RNAs como método para a predição de geração de energia fotovoltaica no Nordeste brasileiro. Para isso foram coletados e pré-processados os dados climáticos e de geração de energia. Após processados, os resultados de predição obtidos por meio das redes MLP e *Long Short-Term Memory* (LSTM) foram comparados com os do método linear clássico ARIMA (*Autoregressive Integrated Moving Average*), observando-se o bom resultado obtido pelas redes neurais como ferramentas para predição de energia fotovoltaica.

Souza (2019) propôs a criação de um modelo de previsão de infestações de pragas nas lavouras utilizando RNN, baseando-se em alterações climáticas, e com propósito de informar a presença insetos nas plantações com uma antecedência de uma semana, baseando-se nos dados meteorológicos da semana anterior. Sendo utilizado uma rede LSTM, que como resultado, foi capaz de prever o número de insetos e não mais uma classificação binária indicando se haverá ou não uma infestação.

Outro estudo que considera dados climáticos em previsões, é o de Zhang e Kabuba (2017). Os autores utilizaram o modelo GRU para prever o fluxo de tráfego urbano considerando características meteorológicas e dados de tráfego. Na GRU foram usados 500 neurônios na camada oculta para fins de treinamento. Gráficos foram plotados para analisar a precisão do modelo com e sem dados de condições climáticas. Como resultado, a precisão da previsão é melhorada e a perda de previsão é diminuída quando são considerados os dados de condições meteorológicas.

Existem estudos que consideram a utilização de RNN para predições. Como exemplo, no trabalho de Vasco (2020) foram comparados os modelos VRNN, LSTM e GRU na predição dos valores de ações de empresas, treinados com 3 *datasets* de ações diferentes encontrados na bolsa de valores brasileira. De acordo com o autor, conforme novas tecnologias surgem, são feitos estudos da acurácia dos diferentes tipos de modelos disponíveis, muitas vezes usando mais de uma técnica, com a finalidade de diminuir o erro dos modelos e por consequência aumentar a precisão das predições. Como resultado do trabalho de Vasco (2020), foi identificado que os modelos GRU e LSTM obtiveram resultados semelhantes, com um desempenho um pouco melhor do GRU, e o VRNN conseguiu detectar padrões nos dados, mas não com tanta precisão quantos os outros.

Existem diversos outros trabalhos de que utilizam a RNA como forma de predição, que serviram como base para o desenvolvimento dos modelos utilizados para aprendizado, métricas, e desenvolvimento dos resultados, podendo citar Raikar *et al.* (2016), na predição da profundidade de varreduras; Mendes *et al.* (2017), na predição de radiação solar global; Alves (2018), na predição de desempenho de estações convencionais de tratamento de água; e Souza (2008), na predição de séries temporais com Filtro de Kalman e evolução diferencial.

## 2.2 A cidade de Piracuruca

O município de Piracuruca está localizado no norte do Estado do Piauí, como observado na Figura 14, na latitude 03° 55' 41" sul e a uma longitude 41° 42' 33" oeste, a uma altitude de 60 metros. A população estimada em 2020 é de 28.874 pessoas (IBGE, 2021). A cidade tem como limites: ao norte os municípios de Cocal e Caraúbas do Piauí; ao sul com Brasileira, Batalha e São João da Fronteira; a oeste com Batalha, São José do Divino e Caraúbas do Piauí; e a leste os municípios Cocal dos Alves e São João da Fronteira e mais municípios do Estado do Ceará.



Figura 14. Localização de Piracuruca no Brasil.  
Fonte: IBGE (2022).

O município de Piracuruca, apresenta um clima quente tropical, com temperaturas mínimas em média de 23°C e temperaturas médias máximas em torno de 37°C, apresenta ainda um regime pluviométrico médio anual entre 800mm a 1600mm, com chuvas em cerca de 5 a 6 meses com maior precipitação e o restante de estações seca, tendo seus meses mais úmidos entre os meses de fevereiro a junho e os meses mais quentes de outubro a dezembro, conforme Figura 15 (WP, 2021).

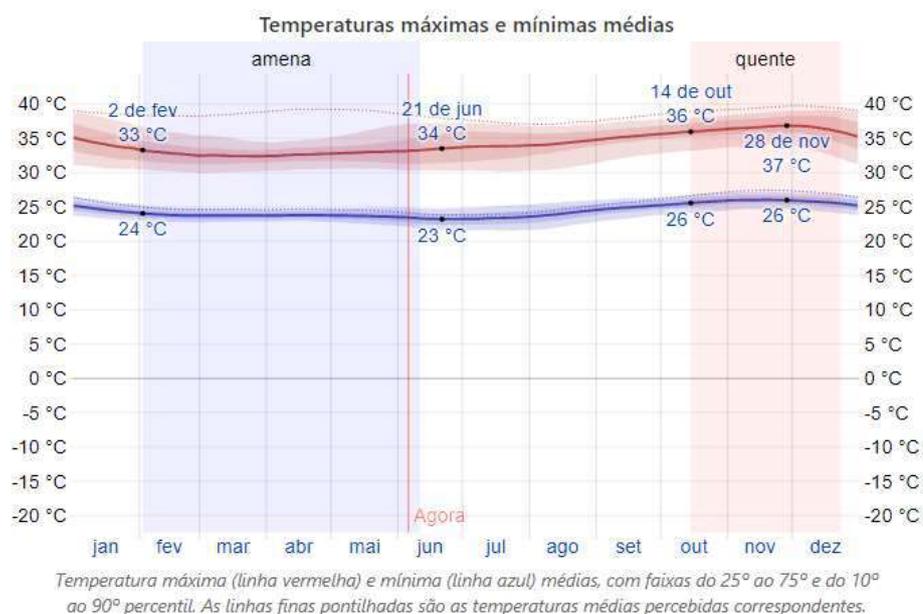


Figura 15. Temperaturas máximas e mínimas médias de Piracuruca.  
Fonte: WP (2021).

### 2.2.1 O potencial agrícola da região

Com um potencial no setor primário devido a sua biodiversidade natural, a cidade se destaca pelas diversidades de vegetação, variando em diversos biomas de vegetação como áreas de mata, cerrado, carrasco e caatinga, tendo uma característica de sustentabilidade das mais variadas culturas, em decorrência de seus solos aluviais com área de massapê (PMP, 2020).

Essas condições proporcionam ao município as características necessárias para um grande potencial agrícola na região, tendo a cajucultura uma das principais fontes geradoras de empregos e renda, deixando a cidade como um dos maiores produtores de castanha de caju da região norte do Estado (PMP, 2020). Também é desenvolvido na região o cultivo de várias outras culturas agrícolas conforme descrito na Tabela 1.

Tabela 1. Tabela de Produção Agrícola da Região - Base de Dados SEBRAE.

<b>AGRICULTURA (Ano 2019)</b>		
<b>Culturas</b>	<b>Produção (t)</b>	<b>Valor (R\$ mil)</b>
Arroz	212	201
Banana	375	661
Cana de Açúcar	31	78
Castanha de Caju	429	944
Feijão	107	975
Goiaba	36	7
Mandioca	1.620	454
Milho	1.070	834

Fonte: IBGE (2019).

Outra fonte de extrativismo muito importante para a região é a da cera da carnaúba, sendo essa uma atividade que tanto no presente como no passado teve grande importância na atividade agrícola do Piauí (PMP, 2020).

O município de Piracuruca, conforme Tabela 2, apresenta ainda um grande destaque na produção apícola, devido principalmente às boas floradas das formações típicas de plantas da caatinga (RIBEIRO, 2020) e semiáridos nordestinos, que ocorrem basicamente de leste a sudeste do Estado, tornando a região propícia para o desenvolvimento da apicultura, da criação de pequenos animais, principalmente caprinos e ovinos, e para a produção de frutas (OLIVEIRA, 2000).

Tabela 2. Tabela de Produção Pecuária da Região - Base de Dados SEBRAE.

PECUÁRIA (Ano 2019)		
Culturas	Unidade	Quantidade
Bovino	Cabeça	146.365
Caprino	Cabeça	23.125
Ovino	Cabeça	7.791
Suíno	Cabeça	17.395
Leite Vaca	mil l	1.486
Mel de abelha	Kg	60.158
Pesca - Tambaqui	Kg	88.000
Pesca - Tilápia	Kg	98.000
Soja	Kg	14.000

Fonte IBGE (2019).

O destaque nessa produção apícola ocorre principalmente pelo crescimento de produtores ligados à produção familiar, que inserem a apicultura como forma de complementação da renda familiar (OMAR e SABBAG, 2011).

Desta forma, a apicultura, tornando-se um dos métodos de inclusão econômica e uma alternativa de emprego e renda, por reunir os requisitos necessários à sustentabilidade e fixação do homem ao campo, e ter impacto positivos no campo social, econômico e ambiental (ARRUDA, BOTELHO e CARVALHO, 2011).

### 2.3 A apicultura

As abelhas têm uma importância fundamental para o ecossistema global. Sua contribuição principal é no desenvolvimento da vida vegetal, permitindo uma maior diversidade genética por meio da polinização das plantas, sendo considerado em muitos ecossistemas, como o mais importante agente polinizador (DUTRA, 2016).

A apicultura brasileira é realizada principalmente pela subespécie conhecida como *Apis mellifera* (Figura 16) ou abelha africanizada. Esta espécie tem características mais rústicas, resistentes às doenças, prolíferas e produtividade elevada, se adaptaram bem nas diversidades dos climas do Brasil, e principalmente aos climas semiáridos do Nordeste (SOMBRA, 2018), sendo hoje muito encontrada pelos apicultores piauienses.



Figura 16. Abelha *Apis Mellifera*.  
Fonte: Embrapa Meio Norte (2008).

Além das *Apis Mellifera*, na região semiárida, é comum encontrar abelhas do tipo sem ferrão, também conhecidas como abelhas nativas ou abelhas indígenas, como a manduri (*Melipona asilvai*), mandaçaia (*Melipona mandacaia*) e a mosquito (*Plebeia sp.*), espécie utilizada principalmente para produção de mel. O produtor que utiliza esse tipo de abelhas é chamado de meliponicultor.

### 2.3.1 Produção apícolas

Além da polinização, podem-se destacar diversos produtos produzidos pelas abelhas que ganharam importância para o ser humano. Produtos como mel, pólen, própolis, geleia real, néctar, apitoxina (veneno da abelha) e ceras, são de grande importância para o agronegócio mundial (VIDAL, 2020), (FGV, 2015) e (EMBRAPA, 2007). Esses produtos são utilizados tanto no consumo como na indústria (farmacêutica, de cosméticos ou alimentício) (ALMEIDA e CARVALHO, 2009). Esses produtos são detalhados a seguir.

- O mel é implementado tanto na alimentação, por ter alto valor energético e nutritivo, como no setor medicamentoso, para o desenvolvimento de medicamentos e cosméticos;
- O pólen é usado como suplemento alimentar e como medicamento;
- As própolis vêm se destacando em medicamentos para tratamento de diversas doenças respiratórias e para cicatrização;
- A geleia real, com seu valor energético e nutricional, é usada na produção de medicamentos por conter hormônios, vitaminas, aminoácidos, enzimas, lipídios e outras substâncias que agem sobre o processo de regeneração celular;
- O néctar, assim como o mel, é utilizado tanto para medicamento como no desenvolvimento suplemento alimentar;

- A apitoxina é desenvolvida a partir do veneno contido no ferrão e vem sendo comercializada para a criação de medicamentos;
- A cera é utilizada para tratamentos cosméticos e na indústria para fabricação de polimentos e impermeabilizações.

### 2.3.2 A exportação

A apicultura brasileira encontra-se presente como um dos principais segmentos de exportação do agronegócio brasileiro (FAO, 2019). Tendo o mel, segundo Almeida e Carvalho (2009), Usda (2020) e Vidal (2020), como um importante destaque entre os produtos destinados ao mercado externo, permitindo ao Brasil se tornar um dos principais produtores. Observando a Figura 17, pode-se observar que no ano de 2020 as exportações apresentaram um aumento em 50% referente ao ano de 2019, tendo exportado 45.600 (quarenta e cinco mil e seiscentos) toneladas (GLOBO, 2021).

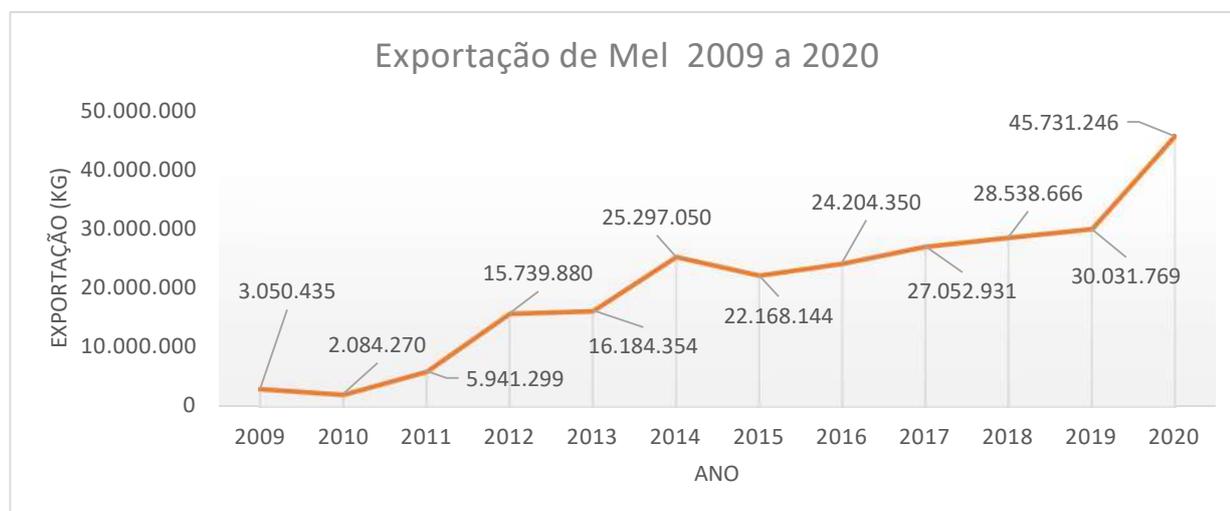


Figura 17. Exportação de Mel 2009 a 2020.  
Fonte: adaptado de Comex Stat (2021).

### 2.3.3 A produção de mel do Piauí

O trabalho de Vidal (2020) apresenta o Piauí com um potencial na produção e exportação de mel (Figura 18). No Nordeste brasileiro, o Estado tem se mantido nos últimos

anos como maior produtor da região e ficando entre os quatro maiores produtores do Brasil no ano de 2019 (Figura 19).

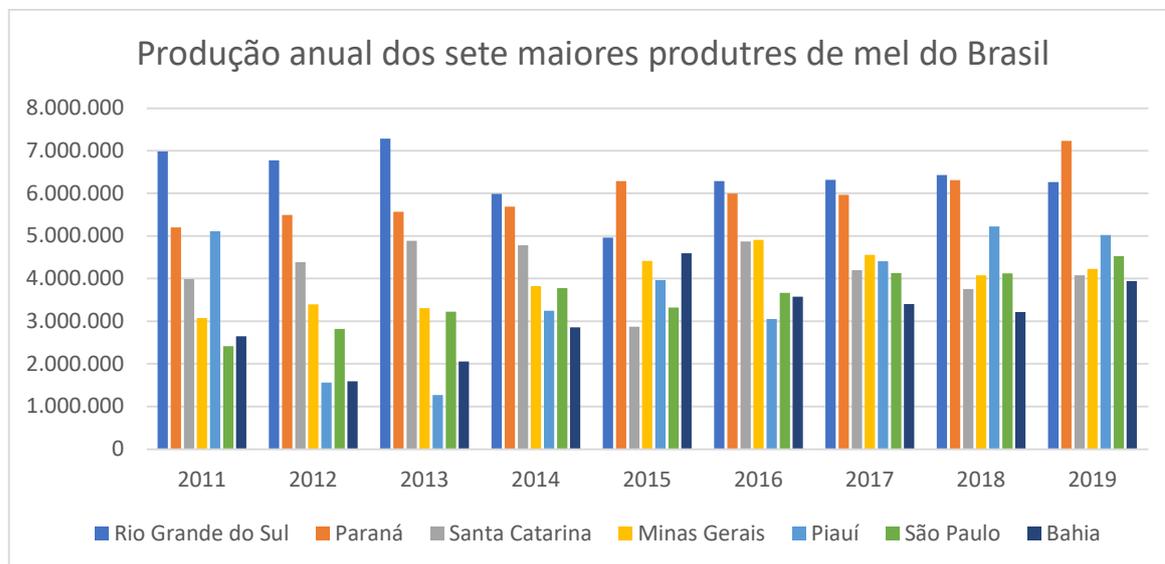


Figura 18. Os sete maiores produtores do Brasil de 2011 a 2019  
Fonte: Autores, com base em IBGE (2020).

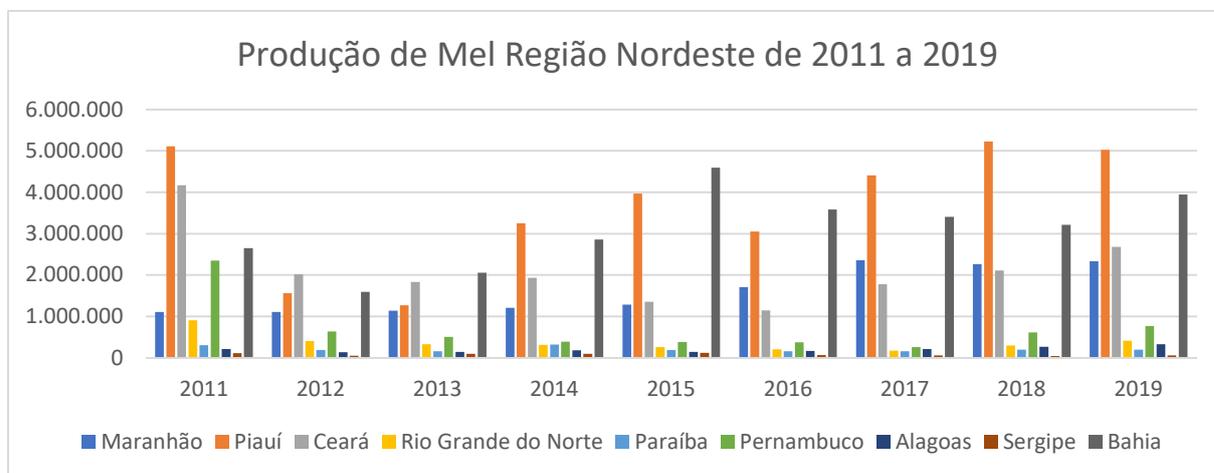


Figura 19. Gráfico da produção de mel da Região Nordeste  
Fonte: Autores com base em (IBGE, 2020)

Neste contexto, o município de Piracuruca, na região norte do Piauí, vem se destacando e desenvolvendo sua produção apícola, tornando-se importante região produtora e exportadora.

Este crescimento se dá, principalmente pelos trabalhos de incentivo à fixação do homem ao campo, melhorando sua qualidade de vida e fornecendo apoio e incentivo a ampliação de produção melífera da região (ARRUDA, BOTELHO e CARVALHO, 2011), feitos por cooperativas, ao auxiliá-los na comercialização de seus produtos tanto para o mercado local,

como na exportação por meio de empresas especializadas no mercado internacional (VIDAL, 2020).

#### 2.3.4 As abelhas e o clima

Segundo Almeida (2008), as abelhas são animais as quais o metabolismo e as atividades sofrem influências diretas de suas temperaturas corpóreas, e que dependem diretamente da temperatura do ambiente ao qual habitam. Quando em temperaturas mais elevadas, por exemplo durante o dia, suas atividades são estimuladas, quando em temperaturas mais “amenas”, elas inibem ou até mesmo podem paralisar suas atividades.

Alencar (2005) e Santos, Domingos, *et al.* (2017) explicam que as abelhas, assim como outros insetos com organização social, têm como grande desafio a realização da homeostase da colônia, ou manutenção da temperatura do ninho, em níveis relativamente constantes. Segundo Schwitzer, Nombé e Boussim (2013) e Sombra (2018), as colmeias devem manter sua temperatura entre 33° e 36° C, com média de 34,5° C. Apesar das colmeias serem consideradas heterotérmicas, o que permite se adaptarem a diferentes tipos de ambientes, suas colônias podem sofrer perdas ou mesmo extinção, quando manejadas em condições climáticas adversas.

Os trabalhos de Tavares, Costa e Azevedo (2012) e Souza (2015) apresentam que as abelhas operárias, realizam a termorregulação interna da colônia pelo calor endotérmico. Aglomerando-se no centro do ninho, elas podem aumentar ou reduzir a temperatura interna pelos batimentos de suas asas, ou através da evaporação de néctar diluído ou de água transportadas para as células da colônia (SENAR, 2011).

Temperaturas na colmeia acima de 36°C por longos períodos, pode ser prejudicial a fase de larva das abelhas (SCHWITZER, NOMBRÉ e BOUSSIM, 2013) e podem provocar a morte ou desenvolvimento anormal da cria, com a produção de indivíduos com problemas físicos, gerando consequência na vida adulta das abelhas. Longos períodos com temperaturas acima de 38° C, pode provocar o derretimento dos favos de cera e deformar os alvéolos, o que pode causar enxameação (abandono ou migração) das abelhas, fenômeno que ocorre principalmente nos períodos mais secos do ano (ALENCAR, 2005).

O artigo de Schwitzer, Nombé e Boussim (2013) demonstra que temperaturas inferiores a 13°C podem afetar o forrageamento da colmeia, pela não saída das abelhas em busca de

alimentos. Outro fator muito comum em temperaturas baixas é a cristalização do mel, que pode ocorrer em temperaturas entre 10° C e 18° C (FUNVERDE, 2018).

Como a sensibilidade das abelhas está em diferenças mínimas de temperatura, fatores ambientais podem exercer influências diretamente sobre a colmeia. Entre eles pode-se destacar: a precipitação, o volume pluviométrico, velocidade do vento, umidade relativa do ar, entre outros (ALENCAR, 2005). Neste sentido, os trabalhos de Lopes (2020), Tavares, Costa e Azevedo (2012) e Karl Crailsheim (1999) demonstram a sensibilidade das abelhas às mudanças climáticas. Trabalhos como o de Langoswska, Zawilak, *et al.* (2016); Holmes (2002), Schwitzer, Nombé e Boussim (2013), Conte e Navajas (2008) e Clarke (2018) buscaram analisar o impacto da interferência climática na produção de mel, utilizando a regressão linear sobre fatores climáticos e analisando as mudanças climáticas e como elas interferem diretamente na produção mel.

### 3 MÉTODOS

Neste Capítulo são apresentados os métodos utilizados no desenvolvimento do trabalho, os quais incluem a descrição do objeto de estudo, da base de dados considerada na pesquisa, apresentando suas características e das Tabelas Climatológicas, contendo informações obtidas de estações climáticas automáticas.

#### 3.1 O objeto de estudo

Dentre os diversos produtos que podem ser encontrados no agronegócio ligados à apicultura, o mel foi o escolhido, pelo seu destaque na economia do Estado do Piauí. Como delimitação, para análise de dados, foi escolhida a cidade de Piracuruca por apresentar-se como destaque na exportação de mel pelos municípios da região norte, e pela disposição da cooperativa de produtores da região em disponibilizar seus dados (produtores locais), para o estudo em questão.

Os dados da produção utilizados na pesquisa foram extraídos de uma compilação dos dados oficiais do IBGE, obtidos por meio do Censo de Agro Pecuário dos anos de 2006 e 2017 (IBGE, 2017), com a base de produtores da cooperativa CODEVAP, e da base de dados do sistema SIDRA referente à produção de Mel no Município de Piracuruca (IBGE, 2020), além dos metadados oficiais das estações meteorológicas do Instituto Nacional de Meteorologia (INMET) (INMET, 2020).

#### 3.2 Característica das Bases de Dados

A base de dados do sistema SIDRA, apresentada na Tabela 3, fornece toda a produção de mel da cidade de Piracuruca, iniciando no ano de 1975, com uma produção de 11.560 kg, até o ano de 2019, no qual obteve 60.158 kg. Um crescimento significativo para a produção do Piauí. O Município teve sua maior produção no ano de 2017, no qual foi comercializado um total de 166.540 kg, e teve sua menor produtividade no ano de 1998 com 3.696 kg. Sua produção média dos últimos 10 anos foi de 123.074 toneladas, apesar da queda de produção no ano de 2018, no qual sua produção teve uma diminuição de 79% devido a uma infestação de lagartas. Houve um crescimento no ano de 2019, significando uma retomada na produção com um crescimento de mais de 100% em comparação com o ano anterior.

Para o desenvolvimento desta pesquisa, foram utilizados apenas os dados referentes ao período de 2006 a 2019, devido à utilização dos dados dos produtores encontrados no censo agropecuário de 2006 e 2017. Esse foi o primeiro marco delimitativo para o desenvolvimento da tabela de produção. As informações referentes aos produtores que ficaram em aberto nos anos subsequentes ao censo foram preenchidas por informações recolhidas da cooperativa CODEVAP, responsável na região pela coleta e venda de mel dos produtores da região.

Tabela 3. Representação de parte da Tabela 74 (Produção de origem animal por tipo de produto) da produção anual de mel da cidade de Piracuruca referente ao período estudado.

<b>Tabela 74 - Produção de origem animal, por tipo de produto</b>	
<b>Variável - Produção de origem animal (Quilogramas)</b>	
<b>Município: Piracuruca</b>	
<b>Ano</b>	<b>Produção em Kg</b>
2010	73.265
2011	153.286
2012	122.629
2013	106.628
2014	153.917
2015	158.534
2016	151.400
2017	166.540
2018	34.579
2019	60.158
2020	90.450

Fonte: IBGE (2020).

### 3.3 Tabelas Climatológicas

Para os dados das características climatológicas, foram utilizadas informações obtidas das estações climáticas automáticas do INMET da cidade de Parnaíba-PI, denominada neste trabalho de Estação 1, e da cidade de Piripiri-PI, denominada Estação 2, que são disponibilizados no Banco de Dados Meteorológicos para Ensino e Pesquisa (BDMEP) (Tabela 4). A Estação 1 contém dados do período de 05/02/2003 a 01/03/2021, e a Estação 2 do período de 30/08/2007 a 01/03/2021. A escolha dessas estações ocorreu por não ser possível encontrar informações de estações meteorológicas na cidade de Piracuruca, ficando, dessa forma, as

estações das cidades de Parnaíba e Piri-piri como as estações com informações geograficamente mais próximas do município estudado.

Tabela 4. Estações Meteorológicas das cidades de Piri-piri e Parnaíba.

<b>Nome: PARNAÍBA - Estação 1</b>	<b>Nome: PIRIPIRI - Estação 2</b>
Código Estação: A308	Código Estação: A335
Latitude: -3.08666666	Latitude: -4.276047
Longitude: -41.78305554	Longitude: -41.794568
Altitude: 52.11	Altitude: 157.89
Situação: Operante	Situação: Operante
Data Inicial: 2003-02-05	Data Inicial: 2007-08-30
Data Final: 2021-03-01	Data Final: 2021-03-01
Periodicidade da Medição: Horaria	Periodicidade da Medição: Horaria

Fonte: INMET (2020).

Os dados são compostos por informações diárias colhidas de hora em hora, durante vinte quatro horas por dia, nas duas estações, sendo armazenados as informações de:

- Data medição;
- Hora medição;
- Precipitação total (mm);
- Precipitação Horária (mm);
- Pressão atmosférica ao nível da estação horária (mb);
- Pressão atmosférica reduzido nível do mar (mb);
- Pressão atmosférica max.na hora anterior. (mb);
- Pressão atmosférica min. Na hora anterior (mb);
- Radiação global (kj/m<sup>2</sup>);
- Temperatura da CPU da estação (°c);
- Temperatura do ar - bulbo seco, horária (°c);
- Temperatura do ponto de orvalho (°c);
- Temperatura máxima na hora ant. (°c);
- Temperatura mínima na hora ant. (°c);
- Temperatura orvalho máx. Na hora anterior. (°c);
- Temperatura orvalho min. Na hora anterior (°c);
- Tensão da bateria da estação (v);
- Umidade relativa Máx. Na hora anterior (%);

- Umidade relativa Min. Na hora anterior. (%);
- Umidade relativa do ar, horaria (%);
- Vento, direção horaria (gr) ;
- Vento, rajada máxima (m/s) e
- Vento, velocidade horaria(m/s).

### 3.4 Implementação

As RNs destacam-se como modelos não-lineares gerais com capacidade de aprendizado considerando padrões complexos presentes em conjuntos de dados, e por isso são muito utilizadas para predição de séries temporais (SOUZA, 2008). RNAs são consideradas métodos computacionais que se adaptam e aprendem a realizar e reconhecer determinados comportamentos, ou execução de tarefas por análise de um conjunto modelos de dados. A seguir, é apresentada a implementação e análise das RNAs para o objeto de estudo proposto.

#### 3.4.1 Desenvolvimento e utilização das RNA

As RNAs utilizadas neste trabalho foram implementadas com pacotes da biblioteca *Keras*, específicos para RNAs, disponível para a linguagem de programação *Python*. Sendo utilizados os modelos CNN e RNN.

As CNN se popularizaram na classificação de imagens e a detecção de objetos, sendo também aplicada para a extração de características úteis de um conjunto de dados iniciais. Essas redes consistem geralmente em utilização de operações convolucionais para extraírem as características úteis da entrada por meio da produção de *feature maps* e camadas de *pooling*, tendo como objetivo a redução dimensional dos *feature maps* e camadas de conexão, que servirão como representação das classes iniciais no final da rede (SOUZA, 2020), (CARVALHO, CARVALHO, *et al.*, 2018).

Para utilização deste tipo de redes dentro do estudo, foram utilizadas, no algoritmo da RNA, as funções *Conv2D* e *MaxPooling2D*, ambas da biblioteca *Keras*. Sendo criado um modelo que utilizar uma camada do tipo CNN e outra camada do tipo densa, que é usada nos estágios finais da rede neural. (Figura 20).

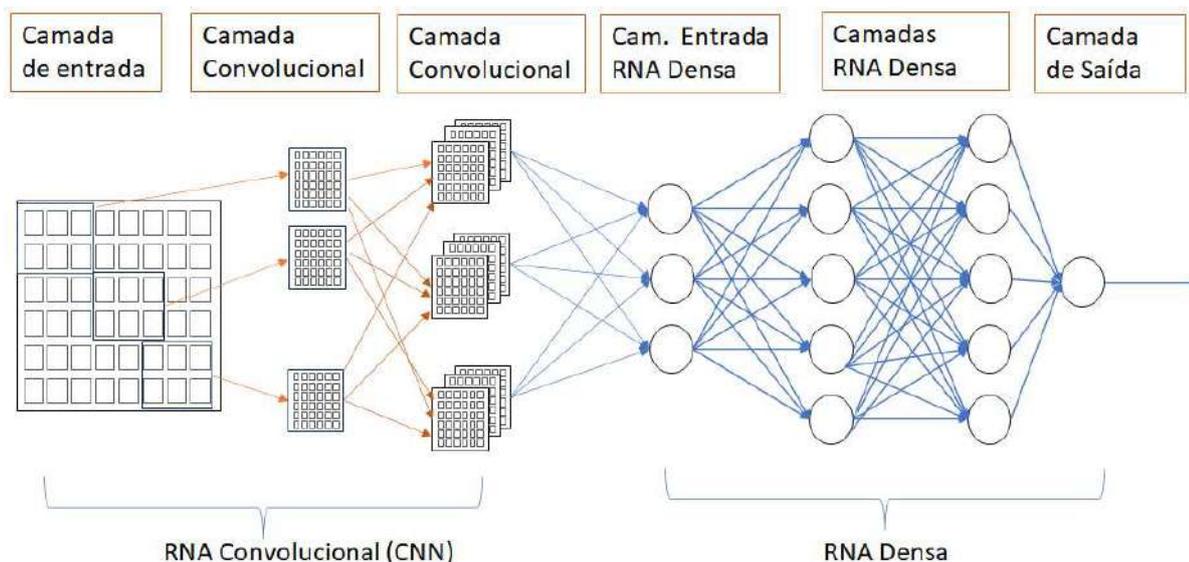


Figura 20. Exemplo de topologia da Rede Neural Convolutiva e Rede Neural Densa  
Fonte: Autor.

As redes RNN trabalham com arquitetura de redes de camadas, projetadas para o reconhecimento de padrões de sequência de dados, com as características de existência de ocorrências de conexões recorrentes entre as camadas de dados. Por essa realimentação das entradas elas apresentam uma característica comportamental temporal, e por trabalhar com a capacidade de memória, dados passados, apresentam-se como ideais para trabalhos relacionados às séries temporais (CARVALHO, CARVALHO, *et al.*, 2018).

Pode-se destacar nas RNNs sua capacidade de oferecer em seus resultados saídas diferentes baseadas nas entradas em memória. Isso demonstra uma facilidade para memórias adaptativas a situações de entradas e aos valores históricos temporais já apresentados.

Alguns dos modelos de RNN são as redes LSTM, apresentadas na Seção 2.1.3.2.1, que permitem trabalhar com memória de longo prazo, sendo uma solução para problemas de dependências de longo prazo de séries temporais nas redes RNN. As LSTM podem trabalhar com diversas camadas, melhorando a robustez da rede, na qual a saída de uma camada serve como entrada da próxima camada (ALMEIDA, 2019).

Também foi aplicado neste trabalho uma RNA com camadas LSTM com a saída servindo de entrada para as camadas do tipo densa, conforme demonstrado na Figura 21.

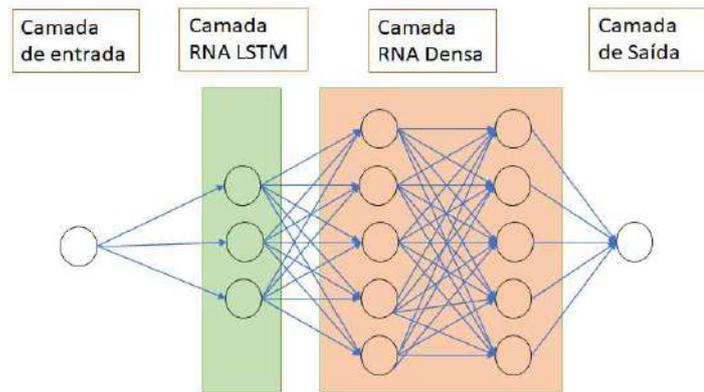


Figura 21. RNA LSTM-Densa.  
Fonte: Autor.

Outro modelo de RNN, é a GRU, detalhado na Seção 2.1.3.2.2. Esse tipo de rede é considerado como um modelo similar as LSTM por trabalharem buscando solução para o problema de memória de longo prazo por meio da utilização mecanismos que regulam o fluxo de informações denominadas portas, que aprendem a reconhecer quais sequências de fluxos são importantes e com relevâncias para o desenvolvimento da série temporal.

Sua estrutura possibilita a captura adaptativa das dependências de sequência de dados, sem descartar as informações anteriores da sequência já analisada. Os portões são responsáveis pela regulamentação do fluxo de informação a serem mantidos ou descartados a cada período ou etapa de tempo.

Outra RNN utilizada neste na RNA deste trabalho foi uma camadas GRU na qual a saída serve de entrada para as camadas do tipo densa, conforme demonstrado na Figura 22.

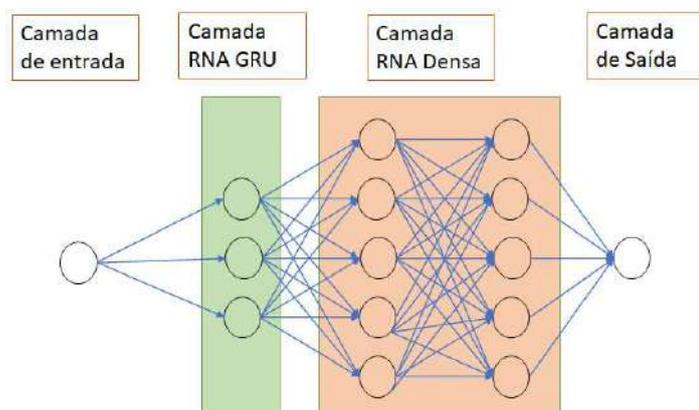


Figura 22. RNA GRU-Densa.  
Fonte: Autor.

## 4 METODOLOGIA E TÉCNICA

Para a condução desta pesquisa foi utilizada a IA por meio de Redes Neurais, com o objetivo de encontrar a perspectiva da produção de mel da cidade de Piracuruca, considerando as características climáticas encontradas em um determinado tempo e região. Para isso, utilizou-se uma base de dados com as informações das séries temporais das tabelas climáticas e de produção do mel.

### 4.1 A Coleta de Dados

Conforme citado anteriormente, utilizaram-se as bases de dados de produção, informadas anualmente e enviadas ao órgão competente pelas cooperativas, indústria e apicultores da região. Adicionalmente, foram utilizadas as tabelas dos censos agrícolas realizados nos anos de 2006 e 2017, considerando a quantidade de produtores da região de Piracuruca.

Das informações recolhidas do INMET, foram utilizados os metadados das estações automáticas climatológicas dos municípios de Piripiri e Parnaíba, e tratados conforme apresentado na seção a seguir.

### 4.2 Tratamento dos dados coletados

Das tabelas de dados de produção e produtores, foram analisadas as informações contidas e criada uma tabela de integralização dos dois conjuntos de informações. Dessa união, delimitou-se a base de pesquisa no período de 2006 a 2019. Essa limitação ocorreu pelo fato de as informações de produtores utilizados nesta pesquisa estarem vinculadas ao censo agropecuário de 2006.

Das tabelas de dados climáticos, os dados analisados apresentaram diversos campos existentes que não eram significativos, sendo então tais campos removidos da tabela. Foram encontradas, na distribuição dos dados remanescentes, diversas linhas com ausência de dados em suas colunas. Os métodos de preenchimentos de falhas utilizados estão discutidos em Bier e Ferraz (2017). As técnicas escolhidas, por apresentarem os melhores resultados para preencher tais lacunas, compõem-se de Média Aritmética Simples (MA) – Equação 1 – e de Ponderação Regional (PR) – Equação 2, como explicado na Subseção 4.2.1.

#### 4.2.1 Preenchendo os dados ausentes

Efetuiu-se a transferência das informações recolhidas das estações do BDMEP para uma base de dados para análise e criação de índices diários. Um programa foi desenvolvido para o preenchimento dos dados faltantes e aplicado o algoritmo referente à Equação 1 para os preenchimentos de dados dentro do mesmo intervalo de tempo na mesma cidade, ou o algoritmo referente à Equação (2) quando utilizado mais de uma cidade para o cálculo de preenchimento dos dados nulos, considerando o seguinte critério para cada campo, conforme descrito a seguir.

1. Coletar todas as informações do item referente ao dia e horário dos dados faltantes.
2. Das informações coletadas no item 1, encontra-se a média; a partir das fórmulas matemáticas da média aritmética simples (Equação 1) para o conjunto de todos os valores para as informações de dia e hora que são semelhantes, considerando todo o conjunto de dados da mesma tabela, ou utilizado a equação de PR (Equação 2) para obtenção dos dados pelas cidades próximas;
3. Dos dados encontrados do item 2, verifica-se que o dado encontrado está dentro do desvio médio padrão para o período.
4. Utiliza-se os dados dentro do desvio médio padrão.

A Equação 1 descreve a técnica MA:

$$Dx = \frac{1}{n} \sum_{i=1}^n Di \quad (1)$$

Na qual,  $Dx$  é o dado horário faltante a ser estimado para a estação teste,  $Di$  é o dado ocorrido na estação naquele dia e hora de ordem ‘ $i$ ’ no dia e hora de ocorrência da falha na estação e ‘ $n$ ’ o número de dias utilizados no cálculo.

A Equação 2 descreve a técnica PR:

$$Dx = \frac{1}{n} \sum_{i=1}^n \frac{Mx}{Mi} Di \quad (2)$$

Na qual  $Dx$  é o dado diário faltante a ser estimado para a estação teste,  $Di$  é o dado ocorrido na estação vizinha de ordem 'i' no dia de ocorrência da falha na estação teste;  $Mx$  o dado médio diário da estação teste;  $Mi$  o dado médio diário da estação vizinha de ordem 'i' e 'n' o número de estações vizinhas utilizadas no cálculo.

#### 4.2.2 Criação da Tabela de Entrada

Após análise, correção e limpeza da base climática, foi criada uma tabela com a integração das tabelas climáticas e produção, sendo essa tabela a base para o desenvolvimento dos dados de entradas da RNA, contendo a tabela 5193 registros e os seguintes campos diários:

- ✓ (A) Ano (Ano Leitura)
- ✓ (M) Mês (Mês Leitura)
- ✓ (D) Dia (Dia Leitura)
- ✓ (DP) Dia Precipitação (Informa 1 se teve precipitação no dia e 0 se não)
- ✓ (PT) Precipitação Total (Informa a quantidade de precipitação do dia, encontrado pela soma de todas as horas de precipitação no dia)
- ✓ (PS) Pressão atmosférica (média das pressões do dia),
- ✓ (TM) Temperatura média (média das temperaturas do dia),
- ✓ (VV) Velocidade do Vento Máxima (Velocidade máxima do dia)
- ✓ (UR) Umidade Relativa média (Umidade Relativa média do dia)
- ✓ (PD) Produtores (Quantidade de Produtores no ano)
- ✓ (PD) Produção dia (Estimativa da Produção diária, Produção Ano / Qtd dias do Ano)
- ✓ (P) Produção Anual (Produção encontrada na Tabela 74)

Sendo utilizado desses campos apenas os parâmetros (M, D, DP, PT, PS, TM, VV, UR, PD) para a entrada de dados na série temporal.

#### 4.2.3 Criação da série temporal

Pode-se definir uma série temporal como uma coleção de dados armazenados e observados de forma sequencial ao longo de um intervalo de tempo, sendo essencial a ordem dos dados definidos no sistema temporal. Nessa dissertação foi trabalhada a série temporal do tipo muitos para um, na qual a série é composta por vários conjuntos de entradas para uma saída. Na série temporal deste trabalho são formadas  $n$  observações sucessivas de várias

variáveis, representado uma entrada de um dia, na qual cada dia podemos apresentar por  $y(t_1)$ ,  $y(t_2), \dots, y(t_n)$ , coletada em um intervalo de tempo discreto de um dia.

Os valores  $y_t$  são compostos por um conjunto de variáveis conforme representação abaixo.

$$y(t) = \{M, D, DP, PT, PS, TM, VV, UR, PD\}$$

Foi estimado um período de 45 dias para a série temporal na análise da produção ( $n = 45$ ). Este tempo é referente ao tempo estimado para o desenvolvimento das abelhas da fase de larva até a fase em que ocorre a produção de mel (EMBRAPA, 2007), representado pela sequência  $\{y_1, y_2, \dots, y_n\} = \{\sum PD(l..n)\}$ , o que gerou uma tabela de sequência temporal com 450 nós de entrada e uma saída com a produção deste período com um período de tempo que vai de 2006 a 2019. Aplicando o conceito de memória aos dados temporais, criando a tabela com um total de 4.782 linhas de dados a serem analisadas pela rede.

### 4.3 Configurando a RNA

Definido os dados de entrada da RNA, foram implementados modelos com múltiplas camadas, na linguagem programação Python 3.0 e aplicado às principais bibliotecas de ferramentas (*Jupyter Matplotlib, Pandas, Tensorflow e Keras*), direcionadas para treinamento de máquina (*machine learning*), que permitiram o desenvolvimento de um ambiente virtual encapsulado o qual foram construídos quatro tipos de arquiteturas de redes, conforme Figura 23.

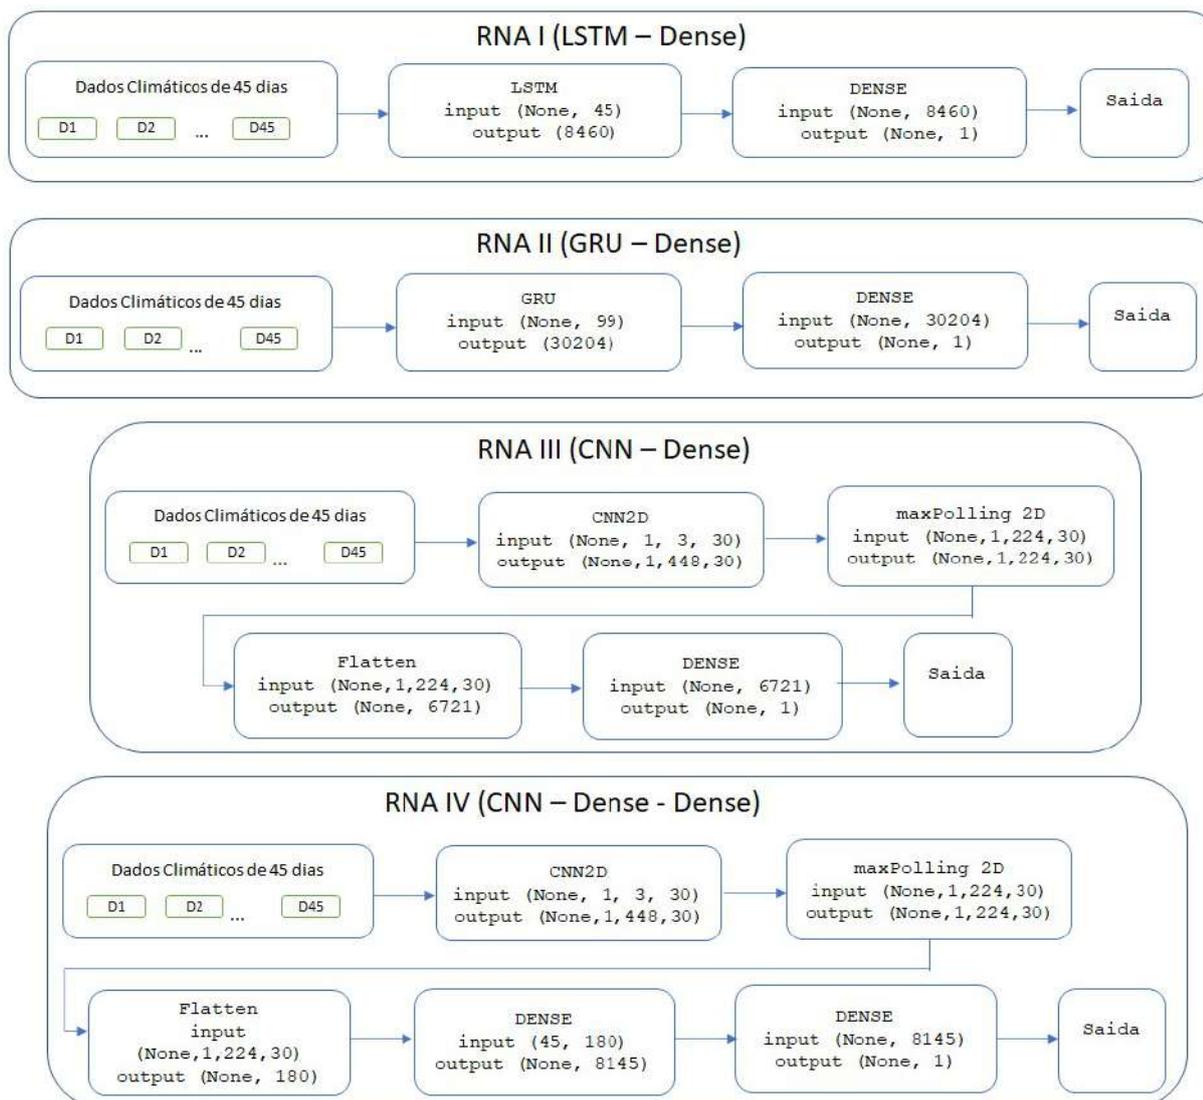


Figura 23. Modelo de Redes RNAs utilizadas.  
 Fonte: Autor, baseada no retorno do modelo *Keras*.

#### 4.3.1 Parâmetros Gerais Considerados

- a) Algoritmo de otimização:
  - **Adam** (*Adaptive Moment Estimation*)
- b) Função de perda:
  - **MSE** (*Mean Squared Error*)
- c) Função de desempenho, para fins de avaliação:
  - **RMSE** (*Root Mean Square Error*)
- d) Taxa de aprendizado utilizado:
  - Foram testadas as taxas de aprendizados entre 0.1 e 0.0001, sendo a taxa de aprendizados de 0.01 a que apresentou os melhores resultados, e por isso utilizado para a aplicação no treinamento da rede;

e) Critério de parada:

- Foi estabelecido o número máximo de épocas de 30.000, decrementando para 20.000, 10.000 e 5.000 épocas, com a análise dos dados obtidos. Foi executado um treinamento com critério de parada para o índice de aprendizado, quando se mantiver imperceptível por mais de 100 épocas.

f) A divisão dos dados (Treinamento e Teste)

- Foram divididos em dois conjuntos: **Treinamento** e **Teste**, com distribuição com 80% e 20% respectivamente, conforme conjunto de sequência temporal, não sendo utilizado o embaralhamento das informações obtidas.
  - O Conjunto de Treinamento ficou com os 3.056 primeiros espaços tempo.
  - O Conjunto de Testes ficou com os 764 registros do intervalo.

## 5 RESULTADOS OBTIDOS

Os modelos neurais foram treinados com os dados resultantes descritos na Seção 4.2. Com relação à rede configurada conforme os parâmetros descritos na Seção 4.3.1, o resultado do treinamento pode ser encontrado nas Tabelas 5 a 9, nas quais estão apresentados os valores das métricas de desempenho: tempo de treinamento, desvio padrão, *Mean Square Error* (MSE) *Root Mean Square Error* (RMSE), *Accuracy* (ACC) e Coeficiente de determinação R<sup>2</sup>.

- **Tempo de treinamento:** representa o tempo de execução do treinamento da rede até que satisfaça o critério de parada. Neste trabalho foram utilizados vários critérios de paradas, conforme descrito:
  - Primeiramente utilizou-se o critério de parada por erro quadrado médio, o qual finaliza a execução do aprendizado no caso da rede ficar estagnada por mais de 100 épocas consecutivas, buscando evitar um *overfitting* da rede, que ocorre quando a rede deixa de aprender e não melhora seu desempenho;
  - O segundo critério de parada utilizado foi pela análise da rede por um determinado número de épocas, evitando assim um *underfitting* da rede, que ocorre quando a rede finaliza o treinamento sem atingir o seu melhor desempenho. Foram estabelecidas inicialmente 5000 épocas, progredindo para 10.000, 20.000 e 30.000 épocas. O que determinou a parada no critério de 30000 épocas foi o resultado do índice de RMSE, o qual não apresentou uma melhora de desempenho para esse estudo, tendo, inclusive, uma regressão em comparação com o índice encontrado para 20000 épocas.
- **Desvio Padrão:** apresenta o desvio padrão da produção predita para os modelos testados, buscando analisar se apresentou os melhores desvios padrões dos valores resultantes;
- **MSE:** foi analisado o resultado do erro quadrado médio dos modelos testados, buscando encontrar as melhores evoluções de aprendizado;
- **RMSE:** a análise permite encontrar os menores valores de erro aceito para os valores preditos, apresentando as menores faixas de erros aceitos para cada modelo.

- **ACC:** esse índice busca apresentar a precisão do aprendizado dos modelos testados em relação para análise dos valores preditos.
- **Coefficiente de determinação R2:** Como forma de comparar e avaliar a qualidade dos modelos apresentados, foram comparados os resultados obtidos da produção na fase de teste, com os valores da produção real dos dados de teste, permitindo assim qualificar o quanto os valores obtidos estão próximos dos valores reais.

### 5.1 Resultado das análises por erro quadrado médio

Nestes testes o critério de parada foi apenas pela estagnação por 100 épocas do erro quadrado médio, o qual apresentou para os modelos os dados apresentados na Tabela 5.

Tabela 5 - Métricas utilizadas na RNA - (Épocas livres).

Modelo RNA	Épocas	Tempo (m)	Desv. Pad. (Kg)	RMSE (kg)	MSE	ACC	R2 %
RNA I por erro quadrado médio	1.094	19,18	230,52	133,69	4,000e-03	0,9369	99,056
RNA II por erro quadrado médio	1.026	16,08	229,61	118,82	5.139e-04	0,9773	99,490
RNA III por erro quadrado médio	1.668	03,10	213,79	171.15	1,636e-02	0,8352	73.060
RNA IV por erro quadrado médio	1.049	14,85	220,28	136,08	4,800e-03	0,9304	95,202

Fonte: Autor.

Neste experimento podemos destacar o modelo RNA II (GRU-DENSE) com o melhor resultado para R2. Este modelo obteve uma aproximação de 99,490% quando comparado ao resultado obtido com os valores originais, além de apresentar a melhor margem de erro com um valor para mais ou para menos de 118,82 Kg encontrada para a produção do período (baseada no índice RMSE). Além disso, obteve um tempo de evolução da rede insignificante comparado com os demais modelos testados nesse mesmo critério (Épocas Livres).

A Figura 24 apresenta o gráfico com a produção real e a produção predita no decorrer do tempo para a base de teste do modelo RNA II (GRU-DENSE), que apresentou o melhor desempenho. É possível observar os resultados de precisão da rede e as margens de erros máximas e mínimas, sendo esses modelos de gráficos apresentados também da Figura 25 à Figura 28.

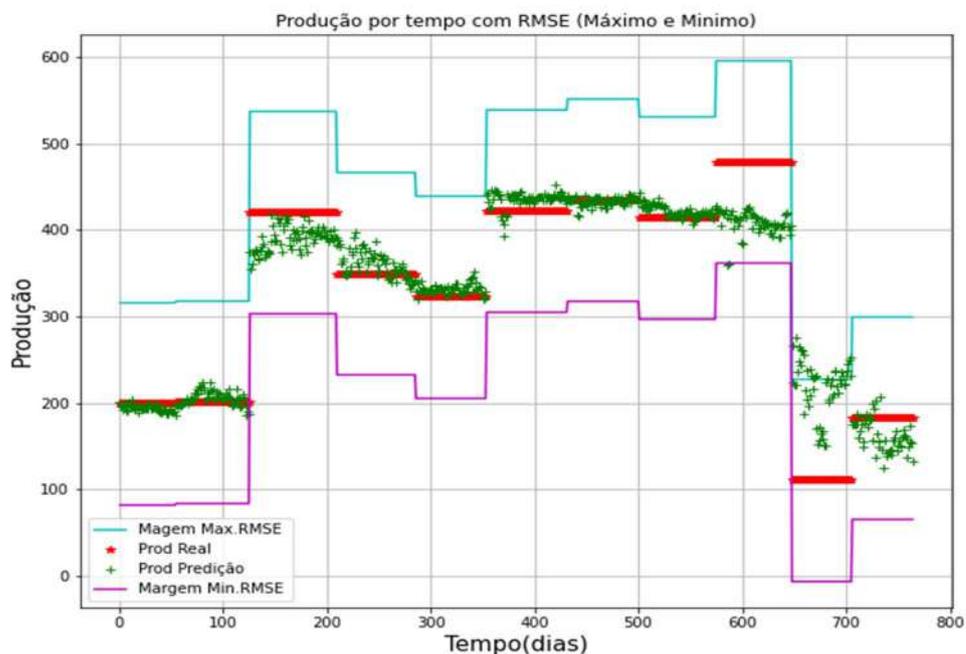


Figura 24. RNA II- Gráfico da Produção Real e Produção Predita com margens de erro  
Fonte: Autor.

Pode-se observar na Figura 24 que os resultados da produção predita, apresentaram-se espalhados próximos aos valores reais, mas em sua maioria dentro dos limites de erros máximo e mínimo do RMSE. Sendo esses valores ocasionados por ruídos que a rede não conseguiu corrigir durante seu aprendizado.

## 5.2 Resultado para 5.000 épocas

O critério de parada nestes testes foi estabelecido pelo número de 5.000 épocas, obtendo os resultados apresentados na Tabela 6.

Tabela 6. Métricas utilizadas na RNA – (5000 épocas)

Modelo RNA	Épocas	Tempo (m)	Desv. Pad. (Kg)	RMSE (kg)	MSE	ACC	R2 %
RNA I 5.000 Épocas	5.000	26,31	226,43	111,73	1,163e-05	0,997	99,988
RNA II 5.000 Épocas	5.000	41,23	227,17	111,89	1,477e-05	0,996	99,985
RNA III 5.000 Épocas	5.000	09,58	207,54	167,13	1,538e-03	0,846	76,513
RNA IV 5.000 Épocas	5.000	10,13	223,22	127,92	2,220e-03	0,953	97,772

Fonte: Autor.

Neste experimento pode-se destacar uma melhora de todos os modelos referente aos índices R2 e RMSE encontrados. Destacando-se o modelo RNA I (LSTM-DENSE) como o melhor para o índice R2, no qual se obteve um resultado de 99,988%, além de apresentar a melhor margem de erro com um valor para mais ou para menos de 111,73 Kg encontrada para a produção do período, o que pode ser visualizado no gráfico da Figura 25.

Observa-se ainda que o modelo RNA II (GRU-DENSE) apresentou uma boa performance com valores para R2, apenas com uma diferença de 0,03 e uma margem de erro RMSE de 0,15 Kg inferiores aos obtidos com o melhor resultado encontrado na RNA I.

Neste experimento observa-se, que o tempo de evolução da rede manteve-se insignificante quando comparado com o experimento de critérios de parada livre, já descrito anteriormente.

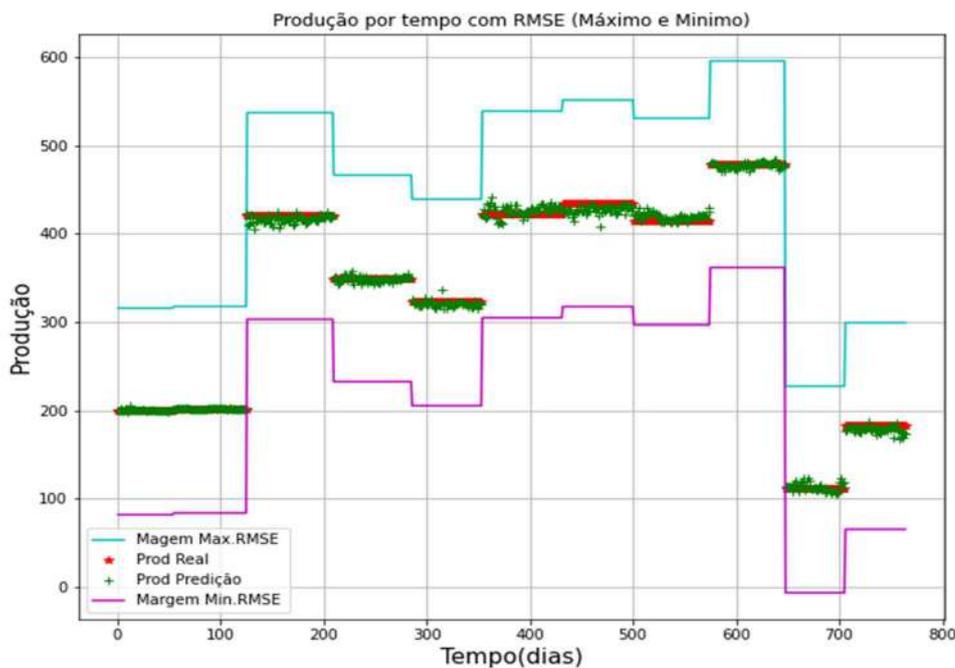


Figura 25. RNA I (Predição para 5000 épocas) - Gráfico da Produção Real e Produção Predita com margens de erro.

Fonte: Autor.

### 5.3 Resultado para 10.000 épocas

O critério de parada nestes testes foi estabelecido pelo número de 10.000 épocas, obtendo os resultados apresentados na Tabela 7.

Tabela 7. Métricas utilizadas na RNA – (10.000 épocas)

Modelo RNA	Épocas	Tempo (m)	Desv. Pad. (Kg)	RMSE (kg)	MSE	ACC	R2 %
RNA I 10.000 Épocas	10.000	53,36	226,59	111,51	7.862e-06	0,997	99,992
RNA II 10.000 Épocas	10.000	80,04	226,39	112,25	2.328e-05	0,995	99,976
RNA III 10.000 Épocas	10.000	24,08	210,18	168,72	1,632e-02	0,842	75,175
RNA IV 10.000 Épocas	10.000	20,01	220,44	134,54	1,702e-02	0,935	95,761

Fonte: Autor.

Obteve-se neste experimento uma melhora do índice R2 e RMSE para alguns modelos, destacando-se mais uma vez o modelo RNA I (LSTM-DENSE) como o melhor resultado para R2, 99,992% além de apresentar a melhor margem de erro com um valor para mais ou para menos de 111,51 kg encontrada para a produção do período, o que pode ser visto no gráfico da Figura 26.

Apesar de pioras nos índices em comparação aos testes com 5.000 épocas, o modelo RNA II (GRU-DENSE) ainda apresentou uma boa performance nos índices R2, com valor de 99,976% e uma margem de erro de 112,25 kg.

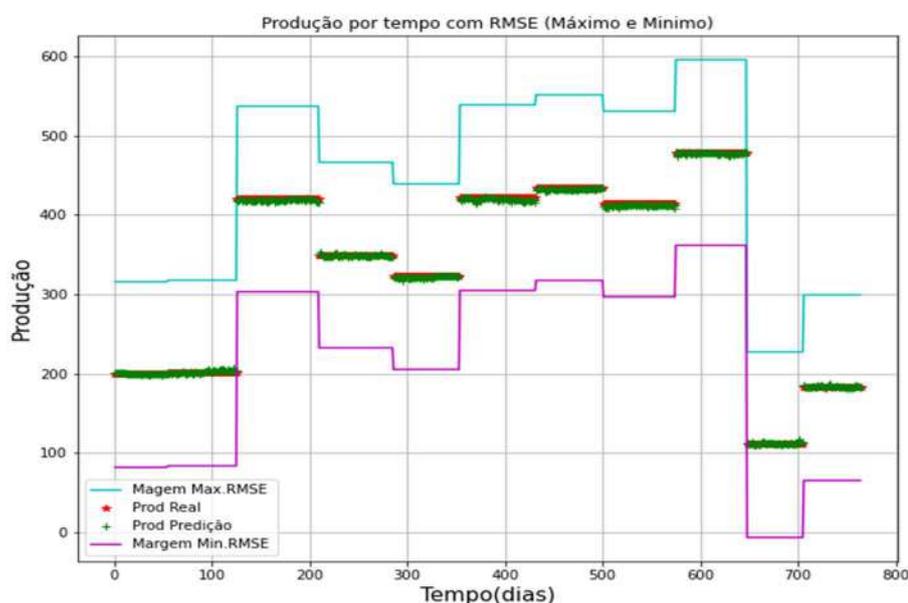


Figura 26. RNA I (Predição para 10.000 épocas) - Gráfico da Produção Real e Produção Predita com margens de erro.

Fonte: Autor.

#### 5.4 Resultado para 20.000 épocas

Nestes testes o critério de parada foi estabelecido pelo número de 20.000 épocas, obtendo os resultados apresentados na Tabela 8.

Tabela 8 - Métricas utilizadas na RNA – (20.000 épocas).

Modelo RNA	Épocas	Tempo (m)	Desv. Pad. (Kg)	RMSE (kg)	MSE	ACC	R2 %
RNA I 20.000 Épocas	20.000	101,21	227,42	110,54	3.471e-08	0,999	99,999
RNA II 20.000 Épocas	20.000	166,31	226,97	111,07	2.647e-06	0,998	99,997
RNA III 20.000 Épocas	20.000	39,45	218,70	157,51	1,632e-03	0,872	83,807
RNA IV 20.000 Épocas	20.000	38,49	221,95	129,71	2,794e-03	0,947	97,293

Fonte: Autor.

Neste experimento, obteve-se melhoramento em todos os índices R2 e RMSE encontrados, destacando-se novamente o modelo RNA I (LSTM-DENSE) como o melhor resultado para R2 com um resultado de 99,999%, reduzindo ainda mais a margem de erro com um valor para mais ou para menos de 110,54 kg para a produção do período. Conforme gráfico apresentado na Figura 27. Como nos experimentos anteriores, o modelo também obteve um índice de tempo de evolução da rede insignificante na comparação com os resultados dos demais modelos testados para essas paradas.

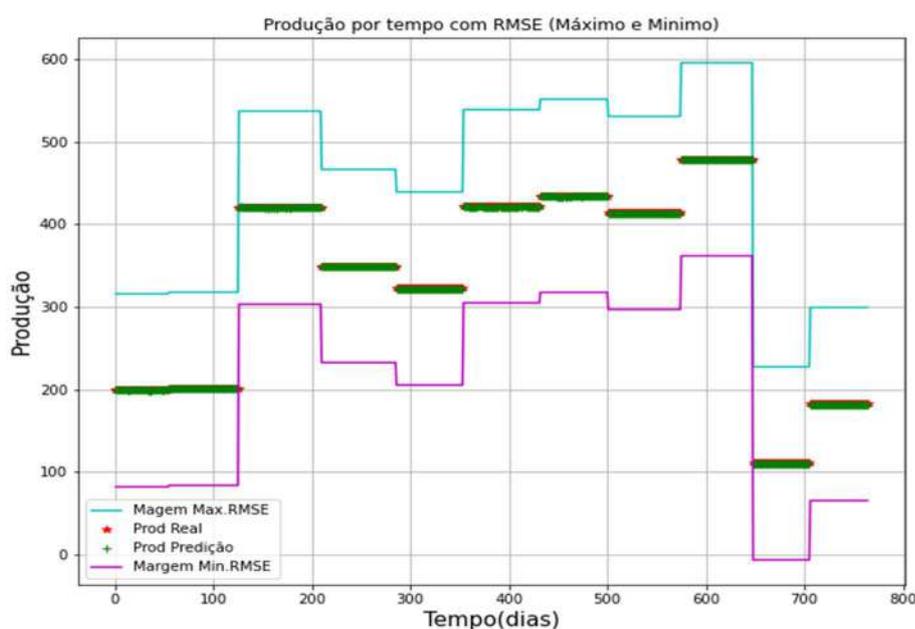


Figura 27. RNA I (Predição para 20000 épocas) - Gráfico da Produção Real e Produção Predita com margens de erro.

Fonte: Autor.

Pode-se destacar para esse experimento os modelos RNA II (GRU-DENSE) com margem de erro 111,07 kg e índices R2 de 99,998%, assim como o modelo RNA IV (CNN-DENSE - DENSE), com margem de erro 129,71 kg e índices R2 de 97,293%, tendo este último se destacado no tempo de aprendizado da rede (38,49 minutos) para evolução do modelo.

### 5.5 Resultado para 30.000 épocas

Nestes testes, o critério de parada foi estabelecido pelo número de 30.000 épocas, obtendo os resultados apresentados na Tabela 9. Nos resultados do teste, observa-se uma regressão em todos os índices encontrados para o teste com 20.000 épocas, o que definiu esse número de épocas como a quantidade máxima a ser estudada para os modelos apresentados.

Tabela 9. Métricas utilizadas na RNA – (30000 épocas).

<b>Modelo RNA</b>	<b>Épocas</b>	<b>Tempo (m)</b>	<b>Desv. Pad. (Kg)</b>	<b>RMSE (kg)</b>	<b>MSE</b>	<b>ACC</b>	<b>R2 %</b>
RNA I 30.000 Épocas	30.000	154,42	226,07	112,57	3,22E-05	0,992	99,968
RNA II 30.000 Épocas	30.000	222,15	226,16	116,36	2,55E-04	0,982	99,747
RNA III 30.000 Épocas	30.000	747,40	225,12	183,05	3,89E-02	0,935	60,087
RNA IV 30.000 Épocas	30.000	67,15	219,06	155,44	1,49E-02	0,856	85,206

Fonte: Autor.

Neste teste, os melhores índices também foram encontrados no modelo RNA I (LSTM-DENSE), como o melhor resultado para R2, com 99,968%, (Figura 28) e margem de erro com um valor para mais ou para menos de 112,57 kg para a produção do período. Os índices dos modelos RNA II (GRU-DENSE) ficaram com margem de erro 116,36 kg e índices R2 de 99,747%. Já o modelo RNA IV (CNN- DENSE - DENSE) teve uma queda significativa nos seus índices, ficando o R2 abaixo dos 90%.

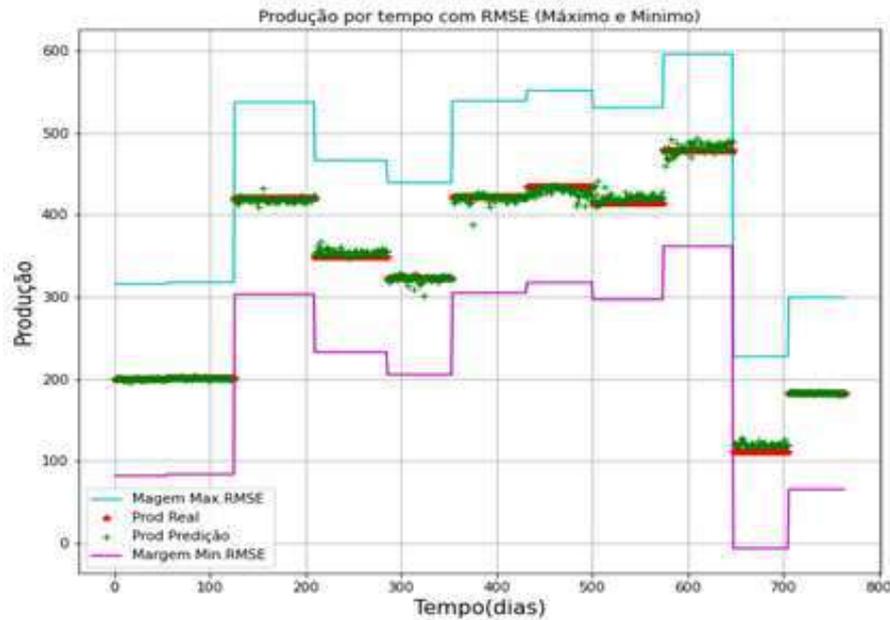


Figura 28. RNA I (Predição para 30000 épocas) - Gráfico da Produção Real e Produção Predita com margens de erro.

Fonte: Autor.

A Tabela 10 representa a junção de todos os testes aplicados. Analisando todos os dados encontrados, concluiu-se que:

- O modelo RNA III (CNN- DENSE) apresentou o menor desvio padrão dos resultados da tabela teste para o teste feito para 5.000 épocas, com o valor de 207,54 kg.
- O modelo RNA I (LSTM-DENSE) apresentou para 20.000 épocas o melhor índice RMSE e R2, com os valores de margem de erro de 110,54 kg e margem de precisão de 99,999%.
- Nos modelos apresentados encontram-se os melhores resultados para 20.000 épocas;
- Os modelos apresentados evoluíram dentro de um tempo médio de execução em um tempo médio de 98 minutos.
- O modelo de aprendizado evoluiu apesar de encontrar padrões próximo ao *Overfitting* dos modelos (Figura 29 , **Erro! Fonte de referência não encontrada.** e Figura 31).

Tabela 10. Métricas utilizada na RNA para todos os modelos testados.

Modelo RNA	Épocas	Tempo (m)	Desv. Pad. (Kg)	RMSE (kg)	MSE	ACC	R2 %
RNA I 30000 Épocas	30000	154,42	226,07	112,57	3,22E-05	0,992	99,968

RNA II	30000 Épocas	30000	222,15	226,16	116,36	2,55E-04	0,982	99,747
RNA III	30000 Épocas	30000	747,40	225,12	183,05	3,89E-02	0,935	60,087
RNA IV	30000 Épocas	30000	67,15	219,06	155,44	1,49E-02	0,856	85,206
<b>RNA I</b>	<b>20000 Épocas</b>	<b>20000</b>	<b>101,21</b>	<b>227,42</b>	<b>110,54</b>	<b>3,471e-08</b>	<b>0,999</b>	<b>99,999</b>
RNA II	20000 Épocas	20000	166,31	226,97	111,07	2,647e-06	0,998	99,997
RNA III	20000 Épocas	20000	39,45	218,70	157,51	1,632e-03	0,872	83,807
RNA IV	20000 Épocas	20000	38,49	221,95	129,71	2,794e-03	0,947	97,293
<b>RNA I</b>	<b>10000 Épocas</b>	<b>10000</b>	<b>53,36</b>	<b>226,59</b>	<b>111,51</b>	<b>7,862e-06</b>	<b>0,997</b>	<b>99,992</b>
RNA II	10000 Épocas	10000	80,04	226,39	112,25	2,328e-05	0,995	99,976
RNA III	10000 Épocas	10000	24,08	210,18	168,72	1,632e-02	0,842	75,175
RNA IV	10000 Épocas	10000	20,01	220,44	134,54	1,702e-02	0,935	95,761
<b>RNA I</b>	<b>5000 Épocas</b>	<b>5000</b>	<b>36,31</b>	<b>226,43</b>	<b>111,73</b>	<b>1,163e-05</b>	<b>0,997</b>	<b>99,988</b>
RNA II	5000 Épocas	5000	41,23	227,17	111,89	1,477e-05	0,996	99,985
RNA III	5000 Épocas	5000	09,58	207,54	167,13	1,538e-03	0,846	76,513
RNA IV	5000 Épocas	5000	10,13	223,22	127,92	2,220e-03	0,953	97,772
RNA I por estagnação de aprendizado ou 5000 épocas		1094	19,18	230,52	133,69	4,000e-03	0,9369	99,056
<b>RNA II por estagnação de aprendizado ou 5000 épocas</b>		<b>1026</b>	<b>16,08</b>	<b>229,61</b>	<b>118,82</b>	<b>5,139e-04</b>	<b>0,9773</b>	<b>99,490</b>
RNA III por estagnação de aprendizado ou 5000 épocas		1668	03,10	213,79	171,15	1,636e-02	0,8352	73,060
RNA IV por estagnação de aprendizado ou 5000 épocas		1049	14,85	220,28	136,08	4,800e-03	0,9304	95,202

Fonte: Autor.

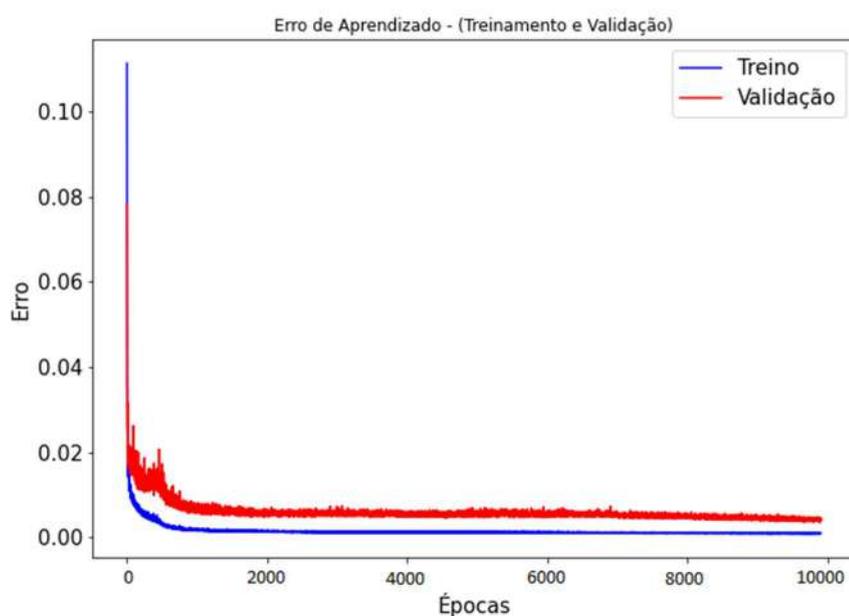


Figura 29. Curva de aprendizado para RNA I 10000 épocas.

Fonte: Autor.

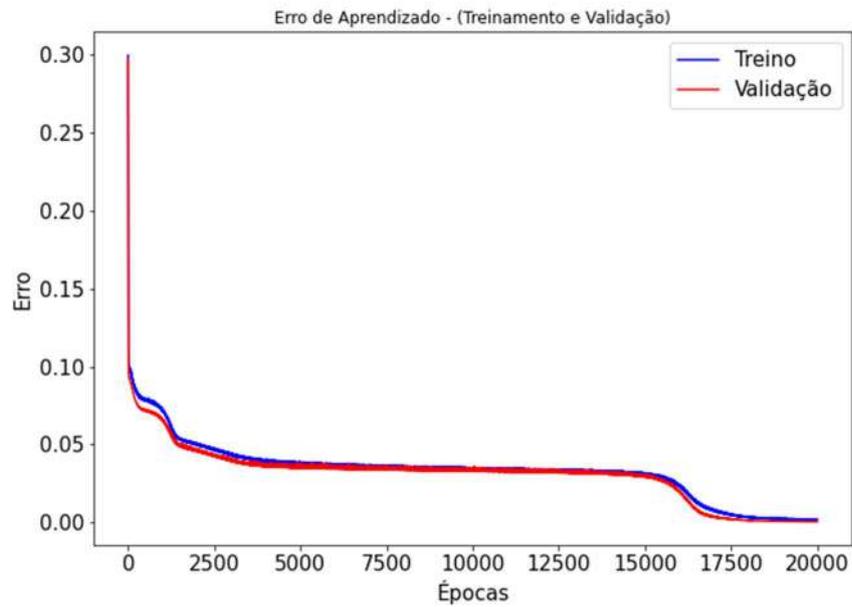


Figura 30 - Curva de aprendizado para RNA I 20000 épocas  
Fonte: Autor.

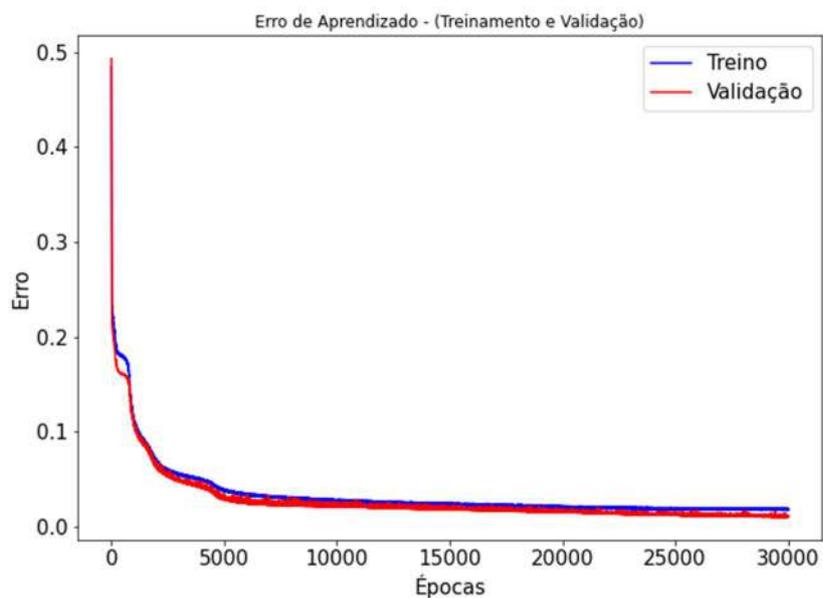


Figura 31-Curva de aprendizado para RNA I 30000 épocas.  
Fonte: Autor.

Este capítulo apresentou os resultados dos experimentos com a utilização dos modelos de RNAs propostos para a presente pesquisa, assim como teceu uma discussão sobre esses resultados. O próximo capítulo apresenta as considerações finais do trabalho.

## 6 CONSIDERAÇÕES FINAIS

Foi proposto no presente trabalho o desenvolvimento de um modelo de rede neural capaz de realizar a predição da produção do mel considerando os dados climáticos de uma região. Para o desenvolvimento do mesmo, foram utilizados os modelos de CNN e RNN, sendo este último, implementado os tipos LSTM e GRU. Foi possível realizar uma combinação dessas redes, gerando os modelos RNA I (LSTM-DENSE), RNA II (GRU-DENSE), RNA III (CNN-DENSE) e RNA IV (CNN- DENSE - DENSE).

Dos modelos experimentados, com exceção do modelo RNA III (CNN- DENSE), que obteve em seu melhor resultado um índice R2 de 83,8% de precisão, todos os demais modelos, em pelo menos um dos experimentos, ficaram acima dos 97% de precisão, e margem de erro de mais ou menos de 127,92 kg, o que representa uma margem de erro com menos de 3% da produção do período.

Os modelos de redes que utilizam RNN apresentaram os melhores resultados para o estudo de predição, obtendo em todos os testes índices de precisão R2 acima de 99%. Destes modelos pode-se destacar a RNA I (LSTM-DENSE), que obteve os melhores indicadores na maioria dos testes realizados tendo seu melhor resultado com uma precisão de 99,999% e a margem de erro de 110,54 kg para mais ou para menos obtidos.

Diante dos resultados dos experimentos, verifica-se que foi alcançado o objetivo de propor o uso de modelos de Redes Neurais capazes de prever a produção de mel baseando-se nas condições climáticas da região. Para esse objetivo, as RNN se apresentaram bastante eficiente para a tarefa, com resultados que demonstram sua eficiência.

Para a predição da produção de mel, pode-se afirmar que as redes se apresentaram eficientes a partir dos modelos apresentados. A rede LSTM apresentou-se mais eficiente em seus resultados, podendo elas serem utilizadas para a predição de mel para 45 dias. E o modelo RNA I (LSTM-DENSE), com um índice de 99,999%, pode ser aplicado em ferramentas que permitam aos apicultores e cooperativas a estimarem sua produção, o que possibilitaria uma maior segurança para a obtenção de recursos financeiros para investimentos na produção.

## 7 TRABALHOS FUTUROS

Os resultados apresentados neste estudo sugerem a possibilidade de se utilizar modelos no desenvolvimento de testes em outras regiões e municípios. O intuito seria consolidar os modelos no uso de ferramentas que permitam aos apicultores e cooperativas a conhecerem uma perspectiva da produção de mel, possibilitando a busca de investimentos para melhor desenvolver sua produção.

Outra possibilidade de estudo que se pode destacar é o conhecimento dos padrões climáticos ideais para produção, o que possibilitaria ao apicultor o manejo adequado de seu enxame, evitando assim a perda da colmeia por padrões climáticos.

## REFERÊNCIAS

- ALBAWI, S.; MOHAMMED, T. A.; AL-ZAWI, S. Understanding of a convolutional neural network. International conference on engineering and technology (ICET). [S.l.]: IEEE. 2017. p. 1-6.
- ALENCAR, L. C. Efeito do sombreamento no desenvolvimento, na produtividade e na qualidade do mel de abelhas africanizadas (*Apis mellifera* L.) em região semi-árida. UFPI. Teresina. 2005.
- ALMEIDA, G. Fatores que interferem no comportamento enxameatório de abelhas africanizadas. Ribeirão Preto-SP: USP, 2008.
- ALMEIDA, M.; CARVALHO, C. Apicultura: uma oportunidade de negócio sustentável. Salvador: SEBRAE, 2009.
- ALMEIDA, R. C. Uso de Redes Neurais long short-term memory como estratégia de algorithmic trading. Espírito Santo: UFES, 2019.
- ALVES, H. J. Proposição de modelo de predição de desempenho de estações convencionais de tratamento de água utilizando Redes Neurais Artificiais. UFMG. Tese de doutorado. Belo Horizonte MG. 2018.
- ARRUDA, J. B. F.; BOTELHO, B. D.; CARVALHO, T. C. Diagnóstico da cadeia produtiva da apicultura: um estudo de caso. XXXI Encontro Nacional de Engenharia de Produção. Belo Horizonte (MG): [s.n.]. 2011.
- BARRETO, J. M. Introdução as redes neurais artificiais. Introdução as Redes Neurais Artificiais. UFSC. Florianópolis - SC. 2002.
- BIER, A.; FERRAZ, E. T. Comparação de Metodologias de Preenchimento de Falhas em Dados Meteorológicos para Estações no Sul do Brasil. Revista Brasileira de Meteorologia, p. 215-226, 2017.
- BIERMANN, V. C. Predição de Características de Partículas Atmosféricas Utilizando Redes Neurais Convolucionais. Universidade Federal de Santa Catarina. Departamento de Informática e Estatística. Florianópolis. 2019.
- BÖHLKE, P. B.; PALMEIRA, E. M. Inserção competitiva do pequeno produtor de mel. Revista Acadêmica de Economia, 2006.

BORGES, R. R. et al. Sincronização de disparos em redes neuronais com plasticidade sináptica. *Revista Brasileira de Ensino de Física*, v. 37, São Paulo, 2015. 2310-1-2310-9.

CARDON, A.; MÜLLER, D. N.; NAVAU, P. Introdução às redes neurais artificiais. Porto Alegre: [s.n.], 1994.

CARVALHO, H. V. F. D. et al. Detecção de Anomalias em Comportamento de Abelhas Utilizando Redes Neurais Recorrentes. Sociedade Brasileira de Computação, Porto Alegre: , 2018.

CLARKE, D. . R. D. Predictive modelling of honey bee foraging activity using local weather conditions. *Apidologie*, n. 49, p. 386–396, 2018.

COMEX STAT. Portal para acesso gratuito às estatísticas de comércio exterior do Brasil. Estatísticas de Comércio Exterior Comex Stat, 2021. Disponível em: <<http://comexstat.mdic.gov.br/pt/home>>. Acesso em: 23 out. 2021.

CONTE, Y. L.; NAVAJAS, M. Climate change: Impact on honey bee populations and diseases. *Revue Scientifique et Technique-Office International des Epizooties*, v. 27, n. 2, 2008. 499-510. Acesso em: maio 2021.

CUNHA, H. Q.; SOBEL, L. F. Aplicação de Redes Neurais Artificiais na Predição de Geração de Energia Fotovoltaica no Nordeste do Brasil. *Revista de Engenharia e Pesquisa Aplicada*, v. 6, n. 5, 2021. 73-80.

CUNHA, H. Q.; SOBEL, L. F. Aplicação de Redes Neurais Artificiais na Predição de Geração de Energia Fotovoltaica no Nordeste do Brasil. *Revista de Engenharia e Pesquisa Aplicada*, v. 6, n. 5, 2021. 73-80.

DUTRA, T. F. S. Sistema de Monitoramento e eControle de Colmeias de Produção Apícola. MPES - Mestrado Profissional em Engenharia de Software, Rio Grande do Norte, 02 ago. 2016. Disponível em: <<https://repositorio.ufrn.br/jspui/handle/123456789/21775>>. Acesso em: 15 fev. 2021.

EMBRAPA. Criação de abelhas: apicultura. Brasília: Embrapa Informação Tecnológica, 2007.

EMBRAPA. Nordeste luta para produzir mais mel. [www.embrapa.br](http://www.embrapa.br), 03 jun. 2014. Disponível em: <<https://www.embrapa.br/busca-de-noticias/-/noticia/1833705/nordeste-luta-para-produzir-mais-mel>>.

EMBRAPA MEIO NORTE. Produção de própolis em regiões de caatinga e áreas de transição do Estado do Piauí. EMBRAPA Piauí, 01 nov. 2008. Disponível em:

<<http://quersaberpolitica.com.br/2016/embrapa-semiarido-apresenta-pesquisa-com-resultados-preocupantes-do-bioma-caatinga/>>.

FAO. Food and agriculture data. Food and Agriculture Organization, 02 mar. 2019. Disponível em: <<http://www.fao.org/faostat/en/#home>>.

FERREIRA, J. A. B. Redes Neurais Artificiais aplicadas em aprendizagem de trajetória em robótica móvel. UnB. Dissertação de mestrado. Brasília. 2020.

FGV, F. G. V. Brazilian Agribusiness Overview. Rio de Janeiro: Fundação Getulio Vargas, 2015.

FLECK, L. et al. Redes neurais artificiais: Princípios básicos. Revista Eletrônica Científica Inovação e Tecnologia, v. 1, n. 13, Medianeira, PR, 2016. 47-57.

FUNVERDE. Cristalização do mel. Funverde, 31 mar. 2018. Disponível em: <<https://www.funverde.org.br/blog/cristalizacao-do-mel/>>. Acesso em: 30 jun. 2021.

GLOBO, G. C. E. P. Exportação de mel do Brasil cresce quase 50% em volume em 2020. Globo Rural, 07 fev. 2021. Disponível em: <<https://g1.globo.com/economia/agronegocios/globo-rural/noticia/2021/02/07/exportacao-de-mel-do-brasil-cresce-quase-50percent-em-volume-em-2020.ghtml>>. Acesso em: 15 fev. 2021.

GUIMARÃES, D. P. et al. Uso de redes neurais para a projeção climática no Brasil. São Paulo. 2009.

GUIMARÃES, E. D. S. Aprendizado de Máquina aplicado à predição da produtividade da cultura da soja utilizando dados de clima e solo. Universidade de São Paulo. Tese de Doutorado. [S.l.]. 2019.

HAYKIN, S. Redes Neurais Princípios e Prática. 2ª edição. ed. Porto Alegre: Bookman, 2008.

HOLMES, W. The influence of weather on annual yields of honey. The Journal of Agricultural Science, p. 95 - 102, 2002.

HSEIH, W.; TANG, B. Applying neural network models to prediction and data analysis in meteorology and oceanography. ulletin of the American Meteorological Society, p. 1855, 1998.

IBGE. Censo Agropecuário 2017, 2017. Disponível em: <<https://www.ibge.gov.br/estatisticas/economicas/agricultura-e-pecuaria/9827-censo-agropecuario.html?=&t=o-que-e>>. Acesso em: 15 jan. 2021.

IBGE. Tabela 74 - Produção de origem animal, por tipo de produto. Tabela 74 - Produção de origem animal, por tipo de produto, 01 fev. 2020. Disponível em: <<https://sidra.ibge.gov.br/tabela/74#resultado>>.

IBGE, I. B. D. G. E. E. Cidades IBGE. IBGE Brasil, 05 jun. 2021. Disponível em: <<https://cidades.ibge.gov.br/brasil/pi/piracuruca/panorama>>.

INMET. Banco de Dados Meteorológicos do INMET, 2020. Disponível em: <<https://bdmep.inmet.gov.br/>>. Acesso em: 15 jan. 2021.

KARL CRAILSHEIM, U. R. B. B. R. N. N. H. Short-term effects of simulated bad weather conditions upon the behaviour of food-storer honeybees during day and night (*apis mellifera carnica pollmann*). *Apidologie*, v. 30, p. 299-310, 1999.

KIM, P. Matlab deep learning. With machine learning, neural networks and artificial intelligence. n. 21. ed. Seoul, Soul-t'ukpyolsi, Korea: Apress, v. 130, 2017.

KOSTADINOV, S. Recurrent Neural Networks with Python Quick Start Guide: Sequential learning and language modeling with TensorFlow. Birmingham: Packt Publishing Ltd, 2018.

KOVÁCS, Z. L. Redes neurais artificiais. Fundamentos e Aplicações: um texto básico. 4ª. ed. São Paulo: Livraria da Física, 2006.

LANGOSWSKA, A. et al. Long-term effect of temperature on honey yield. *Springerlink.com*, 2016.

LEE, K.-F. Inteligência artificial. Rio de Janeiro: Globo Livros, 2019.

LOPES, M. T. D. R. As abelhas e o clima. *Página Rural*, 15 dez. 2020. Disponível em: <<http://www.paginarural.com.br/artigo/2167/as-abelhas-e-o-clima>>.

MENDES, I. A. et al. A utilização das redes neurais artificiais na previsão de radiação solar global. Congresso Técnico Científico da Engenharia e da Agronomia CONTECC, 2017.

MENEZES JÚNIOR, J. M. P. D. Contribuições ao problema de predição recursiva de séries temporais univariadas usando redes neurais recorrentes. Fortaleza. 2012.

MUKHIJA, A. Top Agricultural Producing Countries in the World. *CATking*, 24 fev. 2021. Disponível em: <<https://catking.in/top-agricultural-producing-countries-in-the-world/>>.

OLIVEIRA, M. E. Cadeia produtiva do mel no estado do piauí. Anais do II congresso nordestino de produção animal. Teresina: Congresso da sociedade nordestina de produção animal. 2000. p. 233-239.

OMAR, J.; SABBAG, D. N. Viabilidade econômica para produção de mel em propriedade familiar1. Pesquisa Agropecuária Tropical, Goiania, p. p. 94-101, jan/mar 2011. Disponível em: <[www.agro.ufg.br/pat](http://www.agro.ufg.br/pat)>. Acesso em: 15 maio 2021.

OSÓRIO, F. S.; BITTENCOURT, J. R. Sistemas inteligentes baseados em redes neurais artificiais aplicados ao processamento de imagens. I workshop de inteligência artificial unisc– Universidade de Santa Cruz do Sul Departamento de Informática. [S.l.]: [s.n.]. 2000.

PEREIRA, M. D. M. Aprendizado profundo: redes LSTM. UFGD - Trabalho de Conclusão de Curso. Dourados. 2017.

PMP, P. M. D. P. Portal da Transparencia - Municipio de Piracuruca. Portal da Transparencia - Municipio de Piracuruca, 05 jun. 2020. Disponível em: <<http://piracuruca.pi.gov.br/piracuruca/informacoesgerais/municipio/?tipo=potencialidades>>.

RAIKAR, R. V. et al. Prediction of contraction scour using ANN and GA. Flow measurement and instrumentation, v. 50, p. 26-34, 2016.

RIBEIRO, M. D. F. Árvore do Conhecimento - Bioma Caatinga. Embrapa - Aceitec, 2020. Disponível em: <[http://www.agencia.cnptia.embrapa.br/gestor/bioma\\_caatinga/arvore/CONT000g5twggzg02wx5ok01edq5s5hfa3sp.html](http://www.agencia.cnptia.embrapa.br/gestor/bioma_caatinga/arvore/CONT000g5twggzg02wx5ok01edq5s5hfa3sp.html)>. Acesso em: 01 maio 2021.

SALEHINEJAD, H. et al. Recent advances in recurrent neural networks. arXiv preprint arXiv, 2018.

SANTOS, et al. Sombreamento de colmeias de abelhas africanizadas no semiárido brasileiro. Revista Verde, 2017.

SANTOS, G. Uma aplicação de redes neurais recorrentes do tipo LSTM à previsão dos preços de curto prazo do mercado de energia elétrica brasileiro. Escola de Economia de São Paulo da Fundação Getulio Vargas. Dissertação de mestrado. São Paulo. 2019.

SANTOS, J. A. A. D. Previsão do preço da arroba do boi gordo: um estudo de caso usando ARIMA E GRU. Tekhne e Logos, v. 12, n. 3, Botucatu, SP, 2021. 49-62.

SANTOS, N. T. D. Classificação automática de cobertura vegetal em imagens aéreas e orbitais para uso em planejamento energético. UFPA. Dissertação de mestrado. Belém. 2011.

SCHWITZER, P.; NOMBRE, I.; BOUSSIM, J. Honey Production for Assessing the Impact of Climatic Changes on Vegetation. Antwerpen, Belgium, p. pp.98-102. 2013.

SENAR. Manejo de apiário para a produção de Mel. Brasília: SENAR, 2011.

SOMBRA, D. D. S. Suplementação alimentar de abelhas africanizadas (*apis mellifera* l.) na região do semiárido. Mossoró: Universidade Federal Rural do Semi-árido, 2018.

SOUSA, J. R. et al. Python e predição de dados usando redes neurais multicamadas. Brasília: Brazilian Journal of Development, 2020.

SOUTO, E. J. P.; FIGUEIREDO, A. F.; OLIVEIRA, S. D. Dense Neural Networks for Stress Classification. J. Health Inform, dez. 2020. 8.

SOUZA, M. D. F. P. Ambiência interna de colmeias de *apis mellifera* com diferentes cores e materiais de cobertura no vale do submédio São Francisco. [S.l.]. 2015.

SOUZA, O. Usando Convolução Separável em Profundidade na Otimização da Arquitetura SqueezeNet. UFPE. Dissertação de mestrado. Recife. 2020.

SOUZA, P. V. D. D. Rede neural artificial para predição da produtividade da cultura do milho. Universidade Tecnológica Federal do Paraná. Trabalho de Conclusão de Curso. Santa Helena. 2021.

SOUZA, R. C. T. Previsão de séries temporais utilizando Rede Neural treinada por Filtro de Kalman e evolução diferencial. Pontifícia Universidade Católica do Paraná. Dissertação de mestrado. Curitiba - PR. 2008.

SOUZA, W. D. D. Aprendizado de máquina aplicado à previsão de infestações de pragas através de mudanças meteorológicas. Universidade Federal de Pelotas. Dissertação de Mestrado. Pelotas. 2019.

TAVARES, R.; COSTA, F.; AZEVEDO, M. Estudo da Influência das Variáveis Climáticas em Colônias de *Apis Mellifera*, em Ambientes de Sol e Sombra no Semiárido Pernambucano. 19º Congresso Brasileiro de Apicultura 5º Congresso Brasileiro de Meliponicultura. Gramado: Rio Doce. 2012.

USDA, U. S. D. O. A.-. Market News - Fruit and Vegetable. National honey report, 21 fev. 2020. Disponível em: <[www.marketnews.usda.gov/mnp/fv-home](http://www.marketnews.usda.gov/mnp/fv-home)>.

VARGAS, A. C. G.; PAES, A.; VASCONCELOS, C. N. Um estudo sobre redes neurais convolucionais e sua aplicação em detecção de pedestres. Proceedings of the xxix conference on graphics, patterns and images. Niterói: [s.n.]. 2016.

VASCO, L. P. Um estudo de redes neurais recorrentes no contexto de previsões no mercado financeiro. UFSCar. Trabalho de Conclusão de Curso. São Carlos. 2020.

VIDAL, M. D. F. Evolução da produção de mel na área de atuação do bnb. Caderno Setorial ETENE, n. 112, p. 1-10, abr. 2020. Disponível em: <[https://www.bnb.gov.br/documents/80223/6943261/112\\_Apicultura.pdf/78cc0645-0dea-3556-0b3e-7817306851d7](https://www.bnb.gov.br/documents/80223/6943261/112_Apicultura.pdf/78cc0645-0dea-3556-0b3e-7817306851d7)>. Acesso em: 15 fev. 2021.

WITS. Honey; natural exports by country in 2019. World Integrated Trade Solution, 02 fev. 2021. Disponível em: <<https://wits.worldbank.org/trade/comtrade/en/country/ALL/year/2019/tradeflow/Exports/partner/WLD/product/040900>>.

WP, W. S. Clima e Características de Piracuruca - Brasil. pt.weatherspark.com, 05 maio 2021. Disponível em: <<https://pt.weatherspark.com/y/30837/Clima-caracter%C3%ADstico-em-Piracuruca-Brasil-durante-o-ano>>.

ZHANG, D.; KABUKA, M. R. Combining weather condition data to predict traffic flow: A GRU-based deep learning approach. 2017 IEEE 15th Intl Conf on Dependable, Autonomic and Secure Computing, 15th Intl Conf on Pervasive Intelligence, doi: 10.1109/DASC-PICoM-DataCom-CyberSciTec, 2017. 1216-1219.



MINISTÉRIO DA EDUCAÇÃO  
UNIVERSIDADE FEDERAL DO PIAUÍ  
COORDENAÇÃO DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA/CT

MEMORANDO ELETRÔNICO Nº 25/2022 - PPGEE/CT (11.00.28.19)  
(Identificador: 202630556)

Nº do Protocolo: 23111.043236/2022-80

Teresina-PI, 05 de Setembro de 2022.

COORDENADORIA DE PROGRAMAS STRICTO SENSU/PRPG

**Título: Solicitação de emissão de diploma de mestrado de aluno do PPGEE-UFPI MARIO RODRIGUES GOMES MEIRELES FILHO**

Senhor Coordenador, solicitamos a emissão da certidão, com validade de 180 dias, e do diploma de mestrado de aluno MARIO RODRIGUES GOMES MEIRELES FILHO (CPF: 453.995.903-44/MATRÍCULA: 20191001850) por cumprimento e conclusão de todas as etapas para tal fim. Em anexo segue a seguinte documentação:

- . Requisição para confecção de diploma e formulário para cadastro de dissertação (retirado pelo SIGAA);
- . Requerimento de solicitação de diploma (impresso) devidamente preenchido pelo aluno;
- . Declaração da entrega da cópia da dissertação emitida pelo orientador e pela coordenação do programa;
- . Nada consta da Biblioteca da UFPI;
- . Histórico Escolar do mestrado;
- . Cópia do diploma e histórico escolar da Graduação;
- . Cópia do CNH com CPF;
- . Cópia da Ata da defesa;
- . Termo de Autorização para publicação eletrônica no Repositório Institucional - RI/UFPI;
- . Arquivo da dissertação em PDF;

Para realizar o download do(s) arquivo(s) anexado(s), clique no(s) link(s) abaixo:

**Anexo(s):**

MARIO RODRIGUES DOCUMENTOS.pdf [baixar](#).

ATA\_DA\_DEFESA\_MESTRADO-Mario\_ass\_Mario\_(1)\_assinado.pdf [baixar](#).

historico\_20191001850.pdf [baixar](#).

Declaracao\_de\_conclusao\_do\_Orientador\_Mario\_Meireles\_Filho\_UMA\_ABORDAGEM\_PREDITIVA\_PARA\_A\_PRODUCAO\_DE\_MEL\_assinado\_ [baixar](#).

Dissertacao Mário Meireles Filho UMA ABORDAGEM PREDITIVA PARA A PRODUÇÃO DE MEL COM BASE EM DADOS CLIMÁTICOS\_assinado:

(Autenticado em 05/09/2022 11:49)  
HERMES MANOEL GALVÃO CASTELO BRANCO  
COORDENADOR DE PÓS-GRADUAÇÃO - TITULAR  
Matrícula: 3095957